

**MEDİKAL GÖRÜNTÜ ANALİZİNDE DÖNÜŞÜM TABANLI
MODELLERE AÇIKLANABİLİR YAPAY ZEKA
YAKLAŞIMLARININ UYGULANMASI**

DELAL ŞEKER

KASIM 2025

DİYARBAKIR

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**MEDİKAL GÖRÜNTÜ ANALİZİNDE DÖNÜŞÜM TABANLI
MODELLERE AÇIKLANABİLİR YAPAY ZEKA
YAKLAŞIMLARININ UYGULANMASI**

DELAL ŞEKER

DİCLE ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM-ÖĞRETİM VE SINAV
YÖNETMELİĞİNİN BİR PARÇASI OLARAK
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALINDA
DOKTORA TEZİ
OLARAK HAZIRLANMIŞTIR

KASIM 2025

DİYARBAKIR

MEDİKAL GÖRÜNTÜ ANALİZİNDE DÖNÜŞÜM TABANLI MODELLERE AÇIKLANABİLİR YAPAY ZEKA YAKLAŞIMLARININ UYGULANMASI

Delal ŞEKER tarafından Dicle Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği'nin bir parçası olarak hazırlanan bu çalışma, aşağıda bilgileri yazılı jüri üyeleri tarafından değerlendirilerek **Elektrik-Elektronik Mühendisliği Ana Bilim Dalı**'nda **Doktora Tezi** olarak kabul edilmiştir.

Prof. Dr. Neslihan DALKILIÇ
Müdür, **Fen Bilimleri Enstitüsü**

Doç. Dr. Abdulnasır YILDIZ
Danışman, **Elektrik-Elektronik Mühendisliği Bölümü,**
Dicle Üniversitesi

Sınav Jürisi:

Prof. Dr. İbrahim TÜRKOĞLU (*)
Yazılım Mühendisliği Bölümü,
Fırat Üniversitesi

Doç. Dr. Abdulnasır YILDIZ (**)
Elektrik-Elektronik Mühendisliği Bölümü,
Dicle Üniversitesi

Prof. Dr. Necmettin SEZGİN
Elektrik Elektronik Mühendisliği Bölümü,
Batman Üniversitesi

Prof. Dr. Mehmet Sıraç ÖZERDEM
Elektrik Elektronik Mühendisliği Bölümü,
Dicle Üniversitesi

Prof. Dr. Mehmet AKIN
Elektrik Elektronik Mühendisliği Bölümü,
Dicle Üniversitesi

ONAY

Savunma Tarihi: 19 / 11 / 2025

(*) Jüri Başkanı.

(**) Tez Danışmanı.

Güller İindeki Gzel Anneme...

Dicle Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırlanan bu tez çalışmasında yer alan tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu beyan ederim. Ayrıca, bahse konu bu kural ve ilkelerin gerektirdiği üzere, bu çalışmada özgün olmayan tüm bilimsel içerikleri kurallara uygun biçimde alıntılıyıp kaynak gösterdiğimi beyan ederim. Beyanıyla çelişen herhangi bir delil bulunduğu takdirde tüm sorumluluğu üstleneceğimi kabul ederim.

Ad, Soyad: Delal ŞEKER

İmza:

TEŞEKKÜR

Bu tez çalışmasının fikir aşamasından başlayarak örneklem seçimi, deney setlerinin oluşturulması, analizlerin yorumlanması ve tez taslağındaki düzeltmeler dâhil tüm süreçlerde yol göstericiliği, desteği ve sabrıyla yanımda olan değerli danışmanım Doç. Dr. Abdulnasır YILDIZ'a içtenlikle teşekkür ederim. Tezimin daha nitelikli bir çalışmaya dönüşmesine katkı sağlayan eleştiri ve önerileri için saygıdeğer Tez İzleme Komitesi üyeleri Prof. Dr. Mehmet AKIN ve Prof. Dr. İbrahim TÜRKOĞLU'na şükranlarımı sunarım.

Lisans eğitimim boyunca engin deneyimi ve rehberliğiyle ufkumu genişleten lisans danışmanım Doç. Dr. Mustafa CANSIZ'a; lisansüstü çalışmalarına başlamamda ilham kaynağı olan ve fikirleriyle her zaman yolumu aydınlatan yüksek lisans danışmanım Prof. Dr. Mehmet Sıraç ÖZERDEM'e; tez sürecim boyunca bilgi ve nezaketiyle değerli katkılar sunan İstanbul Teknik Üniversitesi Arş. Gör. Dr. Onurcan KOYUN'a; tez çalışmalarına uzmanlık bilgileriyle değerlendirmeler ekleyen biricik kuzenim uzman dermatolog Dr. Taha Güven ve çok değerli dostum uzman pediatrist Dr. Ardıl AKINTÜRK'e; doktora çalışmam süresince Wake Forest Üniversitesi'nde görev aldığım dönemde, desteğini ve güvenini her zaman hissettiğim Wake Forest Üniversitesi Yapay Zeka Departmanı Direktörü Prof. Dr. Metin Nafi GÜRCAN'a en içten teşekkürlerimi sunarım.

Her koşulda manevi desteklerini esirgemeyen sevgi ve teşvikleriyle güç veren canım ablam Dr. Elif DOĞAN'a ve kıymetli abim Ekrem KABAK'a; enerjileriyle hayatıma her daim renk katan yeğenlerim Miran ve Beran'a; eşimin değerli annesi ve babası Pakize Annem ve Mustafa Babama gönülden teşekkür ederim.

Bu çalışmaya sağladıkları finansal destek için Dicle Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü (DÜBAP)'ne (Proje No: MÜHENDİSLİK.23.015-Proje ve No: MÜHENDİSLİK.25.015) minnettarım.

En önemlisi, her zaman yanımda duran sabrı, bilgisi, özverisi ve çalışkanlığıyla bana güç veren kıymetli eşim Dr. Öğr. Üyesi Mesut ŞEKER'e; hayatımın en renkli varlığı, kalbimin en derin köşesinde yer alan oğlum Mustafa Mesut'a sevgi ve teşekkürlerimi sunarım.

İÇİNDEKİLER

TEŞEKKÜR.....	v
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ.....	x
KISALTMALAR LİSTESİ.....	xii
ÖZET.....	xiv
ABSTRACT.....	xv
1. GİRİŞ	1
1.1 Patolojik Görüntülerin MÖ Yaklaşımındaki Yeri.....	3
1.2 Dermatolojik Görüntülerin MÖ Yaklaşımındaki Yeri.....	5
1.3 Otoskopik Görüntülerin MÖ Yaklaşımındaki Yeri.....	6
1.4 Mevcut Tez Çalışmasının Temel Motivasyonu Ve Hedefleri.....	7
1.5 Mevcut Tez Çalışmasında Metodolojik Olarak İzlenen Temel Yaklaşım ...	8
2. ÖNCEKİ ÇALIŞMALAR.....	9
2.1 Patolojik Görüntü Sınıflandırılmasına İlişkin Çalışmalar.....	9
2.1.1 Açıklanabilirlik içeren histopatolojik görüntü sınıflandırma çalışmaları	9
2.1.2 Açıklanabilirlik içermeyen performans metriği odaklı histopatolojik görüntü sınıflandırma çalışmaları	11
2.2 Dermatolojik Görüntü Sınıflandırılmasına İlişkin Çalışmalar.....	13
2.2.1 Açıklanabilirlik içeren dermatolojik görüntü sınıflandırma çalışmaları	13
2.2.2 Açıklanabilirlik içermeyen performans metriği odaklı dermatolojik görüntü sınıflandırma çalışmaları	14
2.3 Otoskopik Görüntü Sınıflandırılmasına İlişkin Çalışmalar	15
2.3.1 Görüntü temelli otoskopik sınıflandırma çalışmaları.....	15
2.3.2 Video temelli otoskopik sınıflandırma çalışmaları	18

3.	MATERYAL VE METOT	20
3.1	Materyal	20
3.1.1	Veri seti 1: Akciğer ve kolon kanserine ilişkin patolojik görüntü kümesi 20	
3.1.2	Veri seti 2: Meme kanserine ilişkin patolojik görüntü kümesi	21
3.1.3	Dermatolojik görüntü kümeleri olarak veri seti 3 ve veri seti 4	22
3.1.4	Veri seti 5: TM (kulak zarı) görüntü kümesi	23
3.2	Metot	24
3.2.1	Patolojik görüntü sınıflandırmasında LIME tabanlı açıklanabilirlik: Metodoloji ve uzman değerlendirmesi	25
3.2.2	Veri seri 3, 4 ve 5'in sınıflandırmasında dönüşüm tabanlı açıklanabilirlik: Grad-CAM, AR, LRP temelli hibrit ısı haritalarının nedensel metriklerle değerlendirilmesi	35
4.	BULGULAR VE TARTIŞMA	49
4.1	Akciğer, Kolon Ve Meme Kanserine İlişkin Veri Seti 1 ve 2'nin Analizine Yönelik Bulgular	49
4.1.1	Evrişim ve dönüşüm tabanlı modellerin karşılaştırılmasına ait bulgular	49
4.1.2	FNet ve Dönüşüm tabanlı modellerin karşılaştırılmasına ait bulgular ..	53
4.2	Maymun Çiçeği Hastalığına Ait Dermatolojik Veri Setlerinin Analizine Yönelik Bulgular	59
4.2.1	Dönüşüm modellerinden elde edilen özellik dağılımlarının t-SNE ve UMAP ile görselleştirilmesi	59
4.2.2	Dermatolojik görüntülerin sınıflandırılmasında ViT ve DeiT modellerinin karşılaştırmalı performans değerlendirmesi	60
4.2.3	Sınıflandırma sonrası AYZ metotlarından elde edilen nedensel metriklerle ait bulgular	64
4.3	Kulak Hastalıklarına Ait TM Veri Setinin Analizine Yönelik Bulgular....	67
4.3.1	Dönüşüm modellerinden elde edilen özellik dağılımlarının t-SNE ve UMAP ile görselleştirilmesi	67

4.3.2	TM görüntülerinin sınıflandırılmasında ViT ve DeiT modellerinin karşılaştırmalı performans değerlendirmesi	68
4.3.3	Sınıflandırma sonrası AYZ metotlarından elde edilen nedensel metriklerle ait bulgular	69
4.4	Tartışma.....	72
4.4.1	Akciğer, kolon, meme kanseri sınıflandırılması ve AYZ'nin önemi.....	72
4.4.2	Maymun çiçeği hastalığının sınıflandırılması ve AYZ'nin önemi	74
4.4.3	Kulak zarı hastalıklarının sınıflandırılması ve AYZ'nin önemi	78
5.	SONUÇLAR VE ÖNERİLER	84
	EKLER.....	95
	ÖZGEÇMİŞ	100

ŞEKİLLER LİSTESİ

Şekil 1.1 AYZ analizinin medikal görüntüleme alanındaki genel gösterim şeması	3
Şekil 3.1 Tez çalışması boyunca izlenen yol	20
Şekil 3.2 Metot 1' e ait çalışma akışı	26
Şekil 3.3 EfficientNet-B1 tabanlı yöntemsel akış	28
Şekil 3.4 Rastgele bir sınıftan seçilen patoloji görüntüsüne ait ViT modeli iç yapısı	30
Şekil 3.5 FNet mimarisinin iç blok yapısı.....	35
Şekil 3.6 Maymun çiçeği hastalığına ait yöntemsel çalışma akışının genel görünümü	36
Şekil 3.7 Veri seti 3'ten tedarik edilen maymun çiçeği hastalığı görüntüsünün ViT modelindeki gösterimi.....	39
Şekil 4.1 ADK, SHK ve ND örnek görüntülerine ilişkin uygulanan derin mimariler sonucu LIME AYZ metoduna ait gösterimler	53
Şekil 4.2 Dönüşüm modelleri tarafından çıkarılan dermatolojik görüntü özniteliklerinin t-SNE ve UMAP görselleştirmeleri	60
Şekil 4.3 (a) Grad-CAM, LRP ve AR yöntemleriyle elde edilen örnek ısı haritaları; (b) aynı yöntemler ile hibrit yaklaşımına ait silme ve ekleme eğrileri	65
Şekil 4.4 (a) Grad-CAM, LRP ve AR yöntemleriyle elde edilen üst üste bindirilmiş ısı haritaları; (b) aynı yöntemler ile hibrit (Grad-CAM+LRP) yaklaşımına ait silme ve ekleme eğrileri.....	66
Şekil 4.5 Lezyonu işaretlenmiş orijinal görüntü ile Grad-CAM ve LRP yöntemleri kullanılarak elde edilen ısı haritaları ve bunlardan türetilen hibrit ısı haritası çıktısı (maymun çiçeği sınıfına ait bir başka örnek)	67
Şekil 4.6 Dönüşüm modelleri kullanılarak elde edilen TM görüntü özniteliklerin t-SNE ve UMAP görselleştirmeleri	68
Şekil 4.7 (a) Efüzyon sınıfına ait örnek bir görüntü üzerinde Grad-CAM, LRP ve AR ile üretilen tekil ve hibrit ısı haritaları ile bunlara ilişkin nicel karşılaştırma amacıyla verilen silme eğrileri (b) Tekil AYZ yöntemlerine ait ısı haritalarının orijinal görüntü üzerine üst üste bindirilmiş gösterimleri; bu sayede farklı açıklama teknikleri arasında model dikkatinin sezgisel olarak görsel değerlendirilmesi mümkün kılınmaktadır	71

TABLÖLAR LİSTESİ

Tablo 3.1 Metot 1 kapsamında kullanılmış LC25000 ve BreakHis verilerinden alınan iyi ve kötü huylu patolojik yama görüntüleri	22
Tablo 3.2 MSID veri kümesinden elde edilen temsili görüntüler	23
Tablo 3.3 Kulak zarı veri kümesinden elde edilen temsili görüntüler	24
Tablo 3.4 ViT ve DeiT modellerinin eğitim aşamasında aşırı uyumu önlemeye yönelik kullanılan veri artırım örnekleri	37
Tablo 3.5 ViT ve DeiT modellerinin eğitim aşamasında kullanılan aşırı uyumu önlemeye yönelik stratejiler	38
Tablo 4.1 ESA, ViT ve EfficientNet-B1 DÖ mimarilerine ilişkin eğitim/doğrulama kümelerine ait epoklar boyunca doğruluk-kayıp değerleri ile test kümesi karmaşıklık matrisleri (ADK: Adenokarsinom, SHK: Skumaöz Hücreli Karsinom, ND: Normal Doku)	50
Tablo 4.2 Önerilen DÖ mimarileri sonucu elde edilen performans metrikleri (ADK: Adenokarsinom, SHK: Skumaöz Hücreli Karsinom, ND: Normal Doku)	51
Tablo 4.3 FNet üzerinden eğitilen kolon, akciğer ve meme histopatolojik görüntüleri için eğitim aşamasındaki epoklar boyunca elde edilen doğruluk-kayıp grafikleri ve test aşamasındaki karmaşıklık matrisi.....	54
Tablo 4.4 Önerilen DÖ mimarisinden elde edilen performans metrikleri (ADK: Adenokarsinom, SHK: Skumaöz Hücreli Karsinom, ND: Normal Doku, TD: Tümör Doku).....	55
Tablo 4.5 LIME açıklamaları kapsamında deneyimli patoloğ tarafından yapılan kolon doku görüntülerinin değerlendirmeleri (ADK: Adenokarsinom, SHK: Skumaöz Hücreli Karsinom, ND: Normal Doku).....	57
Tablo 4.6 LIME açıklamaları kapsamında deneyimli patoloğ tarafından yapılan akciğer doku görüntülerinin değerlendirmeleri (ADK: Adenokarsinom, SHK: Skumaöz Hücreli Karsinom, ND: Normal Doku).....	58
Tablo 4.7 MSLD veri setine ait, ViT ve DeiT modelleriyle her epok'ta elde edilen eğitim/doğrulama doğruluk ve kayıp grafikleri ile karmaşıklık matrisi	61
Tablo 4.8 MSID veri setine ait, ViT ve DeiT modelleriyle her epokta elde edilen eğitim/doğrulama doğruluk ve kayıp grafikleri ile karmaşıklık matrisi	61

Tablo 4.9 ViT ve DeiT modelleri ile MSLD veri seti için elde edilen performans ölçütleri	63
Tablo 4.10 ViT ve DeiT modelleri ile MSID veri seti için elde edilen performans ölçütleri	63
Tablo 4.11 MSLD test kümesi üzerinde ViT sınıflandırma modeli ile elde edilen ortalama nedensel skorlar.....	64
Tablo 4.12 MSID test kümesi üzerinde ViT sınıflandırma modeli ile elde edilen ortalama nedensel skorlar.....	64
Tablo 4.13 TM veri kümesi için, epoklar boyunca ViT ve DeiT modellerine ait eğitim/doğrulama doğruluk ve kayıp eğrileri ile karmaşıklık matrisi.....	69
Tablo 4.14 TM veri kümesine üzerinde ViT ve DeiT modellerine ilişkin performans metrikleri	69
Tablo 4.15 TM veri kümesi için ViT sınıflandırma modeli kullanılarak test kümesi üzerinde hesaplanan ortalama nedensel metrikler. (Tüm yöntemlerde birinci satır silme, ikinci satır ekleme değerlerini göstermektedir. Her yöntem için en iyi silme ve ekleme sonuçları kalın karakterle belirtilmiştir.)	70
Tablo 4.16 Patoloji verileri için tez kapsamında yararlanılan güncel literatür çalışmaları	74
Tablo 4.17 Dermatoloji verileri için tez kapsamında yararlanılan güncel literatür çalışmaları	78
Tablo 4.18 Otoskop verileri için tez kapsamında yararlanılan güncel literatür çalışmaları	83

KISALTMALAR LİSTESİ

Kısaltma	Açıklama
AFD	Ayrık Fourier Dönüşümü
AR	Attention Rollout
AOM	Akut Otitis Media
AYZ	Açıklanabilir Yapay Zeka
CSOM	Kronik İltihaplı Otitis Media
DÖ	Derin Öğrenme
DSÖ	Dünya Sağlık Örgütü
DeiT	Data Efficient Image Transformer
DVM	Destek Vektör Makinası
ESA	Evrişimsel Sinir Ağı
FNet	Fourier Net
GELU	Gaussian Error Linear Unit
Grad-CAM	Gradient Weighted Class Activation Map
KBB	Kulak Burun Boğaz
KKA	Kanonik Korelasyon Analizi
LIME	Local Interpretable Model-agnostic Explainable
LR	Lojistik Regresyon
LRP	Layer-wise Relevance Propagation
MLP	Multi Layer Perceptron
MÖ	Makine Öğrenmesi
MRI	Manyetik Rezonans Görüntüleme
MSID	Monkeypox Skin Image Dataset
MSLD	Monkeypox Skin Lesion Dataset
OME	Enfeksiyonlu Otitis Media
UMAP	Uniform Manifold Approximation and Projection
PET	Pozitron Emisyon Tomografisi

RELU	Rectified Linear Unit
RNN	Recurrent Neural Network
RO	Rastgele Orman
TBA	Temel Bileşenler Analizi
TM	Timpanik Membran
t-SNE	t-distributed Stochastic Neighbor Embedding
ViT	Vision Transformer
YZ	Yapay Zeka



ÖZET

MEDİKAL GÖRÜNTÜ ANALİZİNDE DÖNÜŞÜM TABANLI MODELLERE AÇIKLANABİLİR YAPAY ZEKA YAKLAŞIMLARININ UYGULANMASI

ŞEKER, Delal

Doktora, Elektrik Elektronik Mühendisliği Bölümü

Danışman: Doç. Dr. Abdulnasır YILDIZ

Kasım 2025, 116 sayfa

Son yıllarda medikal görüntü analizi alanında derin öğrenme tabanlı yöntemler, hastalık tanısında ve klinik tanı destek sistemlerinde önemli bir yer edinmiştir. Özellikle yüksek çözünürlüklü medikal görüntülerde karmaşık doku yapılarının incelenmesi geleneksel yöntemlerin ötesinde açıklanabilir ve güvenilir makine öğrenmesi yaklaşımlarına olan ihtiyacı artırmaktadır. Bu tez çalışmasının genel amacı, farklı medikal görüntüleme alanlarında (histopatoloji, dermatoloji ve otoskopi) dönüşüm ve evrişim tabanlı mimariler ile Açıklanabilir Yapay Zeka (AYZ) yöntemlerini bütünleştirerek yorumlanabilir ve genellenebilir sınıflandırma modelleri geliştirmektir. Bu kapsamda ilk aşamada, akciğer kanseri histopatolojik görüntülerinin otomatik sınıflandırılması için Evrişimsel Sinir Ağı, Vision Transformer (ViT) ve EfficientNet-B1 mimarileri karşılaştırılmış; açıklanabilirlik kapsamında Local Interpretable Model-agnostic Explainable (LIME) yöntemi uygulanmıştır. Ayrıca FourierNet (FNet) mimarisi ile LIME algoritmasının birlikte kullanıldığı ikinci bir çalışma (akciğer, kolon, meme kanseri) ile model çıktılarının medikal anlamlılığı değerlendirilmiş ve sonuçlar patolog görüşüyle doğrulanmıştır. Tezin ikinci aşamasında, farklı klinik alanlarda dönüşüm tabanlı modellerin genellenebilirliğini incelemek amacıyla deri lezyonu ve kulak zarı veri setleri üzerinde ViT ve Data-efficient Image Transformer (DeiT) modelleri eğitilmiştir. Deri lezyonları sınıflandırmasında en başarılı iki yöntem olarak tespit edilen Gradient Weighted Class Activation Map (Grad-CAM) ve Layer-wise Relevance Propagation (LRP) yöntemleri birleştirilerek Temel Bileşenler Analizi tabanlı yeni bir hibrit açıklanabilir yaklaşım önerilmiştir. Otoskopik görüntülerde ise yine en başarılı iki metot olarak bulunan Attention Rollout (AR) ve LRP yöntemlerinin Kanonik Korelasyon Analizi ile bütünleştirildiği hibrit bir açıklama stratejisi sunulmuştur. Açıklanabilirlik performansı, silme ve ekleme nedensel metrikleriyle nicel olarak değerlendirilmiştir. Elde edilen sonuçlar, ViT modelinin tüm veri kümelerinde en yüksek doğruluk, hassasiyet ve eğrinin altında kalan alan (AUC) değerlerini sağladığını göstermiştir. Deri lezyonları veri setinde ikili sınıflandırmada $AUC=0.9192$, çok sınıflı analizde $AUC=0.9784$ değerine ulaşılmış; kulak zarı görüntülerinde ise ViT modeli 0.9976 AUC değeriyle en yüksek başarıyı göstermiştir. Hibrit açıklanabilir yaklaşımlar, tekil AYZ yöntemlerine göre daha düşük silme ve daha yüksek ekleme skorlarıyla model kararlarının güvenilirliğini artırmıştır. Sonuç olarak, mevcut tez kapsamında geliştirilen modeller, farklı medikal görüntüleme alanlarında hem yüksek sınıflandırma başarıyı hem de güvenilir açıklanabilirlik sunarak klinisyenlerin güvenini ve karar destek sistemlerinin şeffaflığını artırmaktadır. Gelecekteki çalışmalar, çok merkezli veri kümeleri kullanarak farklı modalitelerin entegrasyonu ve gelişmiş nedensel analizlerle modelin klinik uygulanabilirliğini artırmayı hedeflemektedir.

Anahtar Kelimeler: Dönüşüm tabanlı derin öğrenme modelleri, Açıklanabilir Yapay Zekâ, Medikal görüntü analizleri, Nedensel metrikler, Klinik karar destek sistemleri

ABSTRACT

UTILIZING EXPLAINABLE ARTIFICIAL INTELLIGENCE APPROACHES TO TRANSFORMER-BASED MODELS IN MEDICAL IMAGE ANALYSIS

ŞEKER, Delal

Doctor of Philosophy in Department of Electrical-Electronics Engineering

Supervisor: Assoc. Prof. Dr. Abdulnasır YILDIZ

November 2025, 116 pages

In recent years, deep learning–based methods have gained significant prominence in the field of medical image analysis, particularly in disease diagnosis and clinical decision-support systems. The examination of complex tissue structures in high-resolution medical images has increased the need for explainable and reliable machine learning approaches beyond traditional methods. The overall objective of this thesis is to develop explainable and generalizable classification models by integrating convolution and transformer-based architectures with Explainable Artificial Intelligence (XAI) techniques across different medical imaging domains (histopathology, dermatology, and otoscopy). In the first phase, Convolutional Neural Network, Vision Transformer (ViT), and EfficientNet-B1 architectures were compared for the automatic classification of lung cancer histopathology images, and Local Interpretable Model-agnostic Explainable (LIME) method was applied for explainability. Additionally, a second study involving FourierNet (FNet) combined with LIME was conducted on lung, colon, and breast cancer datasets to evaluate the medical relevance of model outputs, which was confirmed through pathologist feedback. In the second phase, ViT and Data-efficient Image Transformer (DeiT) models were trained on skin lesion and tympanic membrane (TM) image datasets to investigate the generalizability of transformer-based models across different clinical domains. For skin lesion classification, the two best-performing XAI methods—Gradient-weighted Class Activation Map (Grad-CAM) and Layer-wise Relevance Propagation (LRP)—were fused to propose a novel hybrid explainability approach based on Principal Component Analysis. For otoscopic images, another hybrid strategy was introduced by integrating Attention Rollout (AR) and LRP using Canonical Correlation Analysis. Explainability performance was quantitatively evaluated using deletion and insertion causal metrics. The results demonstrate that the ViT model achieved the highest accuracy, precision, and area under the curve (AUC) across all datasets. On the skin lesion dataset, ViT achieved AUC values of 0.9192 (binary classification) and 0.9784 (multi-class classification), while on the TM dataset the model reached the highest AUC of 0.9976. The proposed hybrid explainability approaches improved the reliability of model decisions by yielding lower deletion and higher insertion scores compared to individual XAI methods. In conclusion, the models developed within current thesis provide both high classification performance and reliable explainability across different medical imaging domains, thereby enhancing clinician confidence and increasing the transparency of clinical decision-support systems. Future studies will focus on improving clinical applicability through the integration of multi-center datasets, multimodal data fusion, and advanced causal analysis strategies.

Keywords: Transformer-based Deep Learning methods, Explainable Artificial Intelligence, Medical image analysis, Causal metrics, Clinical decision support systems


1. GİRİŞ

Medikal görüntüleme teknolojilerindeki hızlı gelişmeler, hastalıkların erken tanısı, sınıflandırılması ve tedavi planlamasında devrim niteliğinde ilerlemeler sağlamıştır [1]. Görüntüleme yöntemleri sayesinde, doku ve organlardaki yapısal ya da fonksiyonel bozukluklar yüksek doğrulukla değerlendirilebilmektedir. Böylece klinik karar süreçleri nesnelleşmekte ve tedavi başarısı artmaktadır [1]. Bununla birlikte, görüntülerin doğru yorumlanması hâlâ büyük ölçüde uzman deneyimine bağlı olup, özellikle görsel benzerlik gösteren patolojik oluşumlarda gözlemciler arası farklılıklar ve yorumlama hataları sıklıkla ortaya çıkmaktadır [2]. Deri lezyonları (örneğin maymun çiçeği enfeksiyonu) [3], kulak zarı anomalileri (örneğin efüzyon, perforasyon) [4] ve kolon ya da akciğer kanserleri [5] gibi karmaşık hastalık gruplarında tanısız sürecin büyük oranda görsel değerlendirmeye dayanması, hata payını artırmakta ve erken tanı oranlarını düşürmektedir. Bu durum, özellikle çocukluk dönemindeki kronik kulak enfeksiyonları [6] veya erken evre kötüçöl tümörler gibi kritik klinik tabloların doğru ve zamanında teşhis edilmesini güçleştirmektedir [7].

Son yıllarda Yapay Zekâ (YZ) ve özellikle Derin Öğrenme (DÖ) tabanlı yaklaşımlar, medikal görüntü analizinde çığır açıcı başarılar elde etmiştir [8]. Evrişimsel Sinir Ağları (ESA), hiyerarşik özellik çıkarımı sayesinde karmaşık görüntü örüntülerini otomatik olarak öğrenebilmekte ve insan performansına yakın, hatta çoğu durumda üstün tanı doğrulukları sağlayabilmektedir [9]. ESA tabanlı yöntemler dermatolojik lezyonların sınıflandırılmasında [9], otoskopik görüntülerden kulak zarı patolojilerinin tespitinde [10] ve radyolojik ya da histopatolojik kanser görüntülerinin analizinde yaygın biçimde kullanılmaktadır [11]. Ancak ESA mimarileri, sabit görüş alanları nedeniyle geniş ölçekli uzamsal bağımlılıkları yakalamakta yetersiz kalmaktadır. Bu durum da özellikle düzensiz şekil, heterojen doku veya çok katmanlı yapıya sahip medikal görüntülerde performans sınırlılığına yol açmaktadır [12]. Örneğin maymun çiçeği lezyonlarında görülen heterojen deri dokuları [13], kulak zarı (Timpanik membran: TM) efüzyonunun neden olduğu ince kontrast değişimleri [4] veya patolojik tümörlerdeki karmaşık hücresele morfolojiler bu sınırlamaların tipik örneklerindendir.

Bu sorunların aşılması amacıyla geliştirilen dönüşüm tabanlı mimariler, son yıllarda medikal görüntü analizinde öne çıkan güçlü bir alternatif hâline gelmiştir. Vision Transformer (ViT) ve türevleri, kendine özgü öz-dikkat mekanizmaları aracılığıyla görüntüdeki hem yerel hem de küresel ilişkileri eşzamanlı olarak modelleyebilmektedir [14]. Böylece ESA'ların ötesinde bütüncül bir temsile ulaşmaktadır. Dönüşüm modelleri, pikseller arası uzun menzilli etkileşimleri dikkate alarak lezyon morfolojisini daha kapsamlı biçimde temsil etmekte ve görsel olarak benzer, ancak patolojik olarak farklı yapıları ayırt etme yeteneğini artırmaktadır. Bu yönüyle, deri, kulak veya kanser görüntülerinde dönüşüm temelli yaklaşımlar, sınıflandırma performansını ve genellenebilirliği anlamlı biçimde yükseltmiştir.

Medikal alanda YZ modellerinin klinik uygulamalarda güvenle kullanılabilmesi için yalnızca yüksek doğruluk değil, aynı zamanda açıklanabilirlik ve güvenilirlik de büyük önem taşımaktadır [15]. DÖ modellerinin 'kara kutu' doğası, klinisyenlerin model kararlarını anlamasını ve doğrulamasını güçleştirmekte, bu da YZ'ye duyulan güveni sınırlamaktadır. Bu nedenle, Açıklanabilir Yapay Zekâ (AYZ) kavramı son yıllarda medikal görüntüleme araştırmalarının merkezine yerleşmiştir [16], [17]. AYZ yöntemleri, modelin karar mekanizmasını görselleştirerek tahmin sonucuna en fazla katkı sağlayan görüntü bölgelerini vurgular. Şekil 1.1, tez kapsamında uygulanan açıklanabilir AYZ analizinin genel şemasını sunmaktadır. Bu bağlamda tez çalışmasında kullanılan Local Interpretable Model Agnostic Explanations (LIME), Gradient-weighted Class Activation Mapping (Grad-CAM), Layer-wise Relevance Propagation (LRP) ve Attention Rollout (AR) gibi teknikler, modelin hangi alanlara odaklandığını gösteren kümeler veya ısı haritaları üretmektedir. Ancak yalnızca görsel açıklamalar klinik geçerlilik için yeterli olmayabilir. Bu nedenle, son dönemde nicel açıklanabilir metrikleri de yaygınlaşmıştır [18], [19]. Sadakat değerlendirmesi, bölgesel bozunma analizi ve özellik önemi puanlaması gibi yöntemler, modelin dikkat ettiği bölgeler ile tahmin sonuçları arasındaki nedensel ilişkiyi ölçerek, açıklamaların güvenilirliğini artırmaktadır. Ayrıca silme ve ekleme eğrileri gibi nedensellik temelli metriklerin kullanılması modelin karar süreçlerinin istatistiksel olarak doğrulanmasına katkı sağlar.



Şekil 1.1 AYZ analizinin medikal görüntüleme alanındaki genel gösterim şeması

Sonuç olarak performans, açıklanabilirlik ve güven ekseninde geliştirilen bu yeni kuşak modeller, medikal YZ'nin klinik uygulanabilirliğini güçlendirmektedir. ESA tabanlı yöntemlerden dönüşüm tabanlı yapılara ve klasik ısı haritalarından nicel açıklanabilir ölçütlerine uzanan bu evrimsel süreç, hem tanısal doğruluğu hem de model şeffaflığını artırarak hekimlerin karar süreçlerini desteklemektedir [17]. Böylece YZ destekli sistemler, yalnızca yüksek doğrulukta tahminler üreten araçlar olmaktan çıkıp klinisyenler tarafından denetlenebilir, açıklanabilir ve güvenilir karar destek sistemlerine dönüşmektedir. Dermatolojik hastalıklardan kulak enfeksiyonlarına veya kötücül tümör analizlerine kadar geniş bir yelpazede yürütülen bu çalışmalar, YZ temelli medikal görüntü analizinin gelecekteki yönünü belirleyen önemli ve köklü bir değişimi temsil etmektedir. Bu tez çalışmasında iki farklı metodolojik yol izlenmiştir. Bu bağlamda kullanılan 5 veri setinden 4 farklı çalışma elde edilmiştir (Bk: Şekil 3.1). Bu çalışmalar patolojik, dermatolojik ve otoskopik olarak 3 kategoride makine öğrenmesi (MÖ) yaklaşımı adı altında irdelenmiştir.

1.1 Patolojik Görüntülerin MÖ Yaklaşımındaki Yeri

Küresel ölçekte kanser, kalp ve damar sistemi hastalıklarının ardından ikinci önde gelen ölüm nedenidir [5]. Dünya Sağlık Örgütü'nün (DSÖ) 2022 raporlarına göre kanser nedeniyle yaklaşık 10 milyon kişi yaşamını yitirmiştir. Akciğer kanseri 1.817.469 ölümle kanser ilişkili ölümlerin başlıca nedeniyken, kolon kanseri 538.167 ölümle beşinci sırada yer almaktadır. Ek olarak erkek nüfusta kolon ve akciğer kanserlerinin görülme sıklığı daha yüksektir [20]. Buna karşılık meme kanseri,

kadınlarda en sık tanı alan kanser olup 2020 yılında küresel ölçekte yaklaşık 2.3 milyon yeni olgu ve yaklaşık olarak 685 bin ölüm bildirilmiştir [21].

Biyolojik düzeyde, insan organizması bölünerek çoğalan sayısız hücreden oluşur. Hücre bölünmesi sırasında gelişen hatalar ya da genetik mutasyonlar, hücrelerin büyüme sinyallerine bağımlılığını ortadan kaldırıp apoptoza (programlanmış hücre ölümü) direnç kazandırabilir ve bu durum kontrolsüz çoğalmayı başlatarak tümör gelişimine zemin hazırlar. Kanser, farklı organlarda gelişebilmekle birlikte, özellikle kolon ve akciğer dokuları bu mekanizmaların sık gözlendiği ve kötücüllerin klinik açıdan en kritik olduğu bölgeler arasında yer almaktadır. Klinik olarak kolon ve akciğer kanserleri belirti ve etiyolojileri bakımından farklılık gösterse de en yaygın kötücüller arasında yer almakta ve nadiren eşzamanlı olarak görülebilmektedir [22]. Nitekim 76 aylık bir izlem çalışmasında, eşzamanlı kolon ve akciğer kanseri saptanan hastaların tıbbi bakımı ve sonuçları incelenmiş ve 3.102 akciğer kanserli hastanın 17'sine bir ay içinde kolon kanseri tanısı konmuştur. Söz konusu hasta grubunda kronik sigara içme ve fazla kilo belirgin ayırt edici özellikler olarak saptanmamıştır. Bu nedenle, nadir ve çoğu zaman tesadüfen saptanan eşzamanlı olgularda uygun klinik yönetim kritik önemdedir [23].

Erken saptama açısından, akciğer ve kolon gibi kanser türleri için manyetik rezonans görüntüleme (MRI), pozitron emisyon tomografisi (PET) ve X-ışını gibi ileri görüntüleme teknolojileri tanı ve hastalık evresi belirlemede önemli olanaklar sunmaktadır [24]. Bununla birlikte, yüksek riskli bireylerde akciğer kanseri taramasında göğüs radyografisinin rolüne ilişkin kanıtlar sınırlıdır ve tarama aracı olarak rutin kullanımı desteklenmemektedir [1]. Bu bağlamda, akciğer ve kolondan farklı olarak, meme kanseri taramasına ilişkin kılavuzlar daha net tanımlanmıştır. Amerika Birleşik Devletleri Önleyici Hizmetler Görev Gücü, meme kanserinde erken tanı için birincil tarama yönteminin mamografi olduğunu belirtmektedir. Kılavuza göre 40–74 yaş arası kadınlarda iki yılda bir mamografi önerilirken 75 yaş ve üzeri ile tamamlayıcı taramalara ilişkin kanıtın yetersiz olduğu ifade edilmektedir [25]. Erken tanı stratejilerinin ve tanısal yöntemlerin iyileştirilmesi bu güçlüklerin aşılmasına katkı sağlayabilir. Son olarak YZ teknikleri medikal görüntülerin erken tanısında, bozuklukların öngörülmesinde ve ciddi sağlık sorunlarının belirlenmesinde

giderek daha kritik bir rol üstlenmektedir [26]. Sistematik ve standartlaştırılmış tanı protokollerinin yetersizliği, özellikle evre I–II kanserlerin ve klinik/radyolojik olarak belirsiz kitlelerin doğru tanılanmasını güçleştirmektedir. Bu koşullarda klinisyenler tanıyı kesinleştirmek amacıyla çoğunlukla girişimsel biyopsiye başvurmaktadır. Alınan örneklerin patolojik incelemesiyle morfolojik ve hücresel düzeyde tümör histolojik alt tip ve evresi belirlenebilmektedir [27]. Bununla birlikte, girişimsel işlemlere bağlı komplikasyon riskleri göz önüne alındığında, gelişen görüntüleme teknolojileri ve YZ temelli yaklaşımlar aracılığıyla bu tür prosedürlerin gerekliliğinin azaltılması hedeflenmektedir [24]. Bu bağlamda, modern bilgisayar destekli görüntü analizi teknikleri patolojik ve diğer medikal görüntülerin değerlendirilmesini kısmen otomatikleştirmekte ve iş akışını hızlandırırken tanısal performansı yükseltebilmektedir [28]. Kullanılan yöntemler arasında ön-işleme, görüntü bölütleme, özellik çıkarımı ve sınıflandırma yer almaktadır. DÖ dâhil gelişmiş algoritmalar ve MÖ mimarileri, tümörlerin daha doğru özelliklendirilmesi, risk sınıflamasına ve kişiselleştirilmiş tedavi planlarının desteklenmesine katkı sağlayan klinik karar destek sistemlerinin temelini oluşturmaktadır.

1.2 Dermatolojik Görüntülerin MÖ Yaklaşımındaki Yeri

Maymun çiçeği, 20. yüzyılın ikinci yarısında insanlarda ilk kez tanımlanan hayvan kaynaklı bir viral enfeksiyondur. Çiçek virüsü ailesine ait bir virüs tarafından oluşturulur ve genellikle daha hafif seyretmekle birlikte, klinik olarak çiçek hastalığına benzer özellikler gösterir. Bulaş enfekte hayvanlarla, onların vücut sıvılarıyla, deri lezyonlarıyla temas ya da mikropla bulaşmış nesnelerin ortak kullanımı üzerinden gerçekleşebilir [29]. Hastalık tipik olarak ateş, lenf bezi büyümesi, kas ağrısı ve suçiçeğini ya da diğer kabarcıklı deri hastalıklarını taklit edebilen karakteristik deri döküntüleri ile seyretmektedir. Bu durum ayırıcı tanıyı güçleştirir. Her ne kadar maymun çiçeği çoğu olguda kendini sınırlayan bir klinik gidiş izlese de, bağışıklık sistemi zayıflamış bireylerde ve çocuklarda ciddi komplikasyonlar gelişebilmektedir [30].

Son küresel salgınlar, tanı ve tedavi stratejilerinin iyileştirilmesine yönelik acil gereksinimi ortaya koymuştur. Güncel tanısal yaklaşımlar öncelikle klinik

değerlendirme ve moleküler testlere (ör. PCR) dayansa da, deri lezyonlarının görsel değerlendirmesi öznel nitelik taşımakta ve gözlemciler arası değişkenliğe açıktır [3]. Ayrıca konvansiyonel görüntüleme teknikleri, lezyonların morfoloji ve dağılımını çoğu kez yeterli doğrulukla ortaya koyamayarak tanı ve dolayısıyla tedavide gecikmelere yol açabilmektedir. Bu güçlükler, hastalık yönetiminin iyileştirilmesi ve halk sağlığı risklerinin azaltılması için standartlaştırılmış olup ileri yöntemlere duyulan gereksinimi vurgulamaktadır [31]. DÖ ve YZ alanındaki son gelişmeler, özellikle dermatolojik hastalıkların otomatik tanısı başta olmak üzere, medikal görüntülemeyi anlamlı ölçüde ilerletmiştir [32].

1.3 Otoskopik Görüntülerin MÖ Yaklaşımındaki Yeri

DSÖ raporlarına göre, 2050 yılına dek yaklaşık 700 milyon kişi başka bir deyişle her 10 kişiden 1'i işitme kaybı yaşayacaktır. Bu işitme kaybının başlıca nedenlerinden biri, çocukluk döneminde geçirilen kronik kulak enfeksiyonlarıdır [33]. Otitis media (OM), yaygın adıyla orta kulak enfeksiyonu, kulak zarının arkasındaki hava dolu orta kulak boşluğunda gelişir ve çocuklarda erişkinlere kıyasla daha sık görülür [34]. OM olgularının önemli bir bölümünde izlem (bekle-gör) yaklaşımı önerilirken, akut OM tanısı doğrulanmış 2 yaş altı çocuklarda antibiyotik tedavisi önerilmektedir. Ayrıca, durumun erkeklerde kadınlara göre daha sık görüldüğü bildirilmektedir [35]. Ağır seyreden ya da yineleyen olgularda kulak tüpü yerleştirilmesi veya geniz eti gibi cerrahi girişimler düşünülebilir [4]. Tedavi edilmemiş OM, akut kulak kemik iltihabı, işitme kaybı, davranış değişiklikleri ve iletişimsel gelişimde gecikmelere yol açabilir [6]. Bu nedenle çocuklarda doğru tanı ve uygun tedavi yaklaşımları büyük önem taşımaktadır.

TM patolojilerinin efüzyon, perforasyon ve timpanoskleroz gibi doğru tanılanması klinik açıdan güç olmaya devam etmektedir. Çalışmalar, özgül olmayan semptomlara aşırı güvenilmesi ve yetersiz otoskopik muayene tekniklerinin yanlış tanıya katkıda bulunduğunu göstermektedir. Örneğin, TM kızarıklığının tek başına tanı ölçütü sayılması akut OM'nin aşırı tanı riskine yol açabilirken, kulak zarı hareketliliğini değerlendiren hava üfleme otoskopinin kullanımı rutin pratiğe yeterince entegre edilememiştir [36]. Böylece standartlaştırılmış tanı ölçütlerinin olmaması ve klinik bulguların değişkenliği, uygulayıcılar arasında tutarsız tanıya neden olabilmektedir

[2]. Nitekim ortalama doğru tanı oranı, çocuk sağlığı hekimlerinde %50, kulak burun boğaz (KBB) uzmanlarında ise %73 olarak bildirilmiştir [37]. Bu güçlükler, otoskopik değerlendirmelerin doğruluğunu artırmak için gelişmiş tanısal araçlara ve standart protokollere duyulan gereksinimi vurgulamaktadır. Son yıllarda klinisyenler, klinik bulgulara ek olarak bilgisayar destekli analizleri giderek daha sık kullanmaktadır [38], [39]. YZ temelli yaklaşımlar, klinik tanıyı desteklemeyi ve tanısal sürecin genel verimliliğini artırma potansiyeli taşımaktadır [40].

1.4 Mevcut Tez Çalışmasının Temel Motivasyonu Ve Hedefleri

Bu tez çalışmasının temel motivasyonu, medikal görüntü yorumunun öznel niteliği ve standardizasyon eksikliği nedeniyle erken tanıda yaşanan güçlüklerin giderilmesidir. Bu çerçevede, yerel görüş alanına dayanan evrişim tabanlı mimarilerin düzensiz şekil ve heterojen doku içeren yapılarda uzak bölgeler arasındaki ilişkileri yakalamakta sınırlı kalması öne çıkan bir sorundur. Öte yandan, dönüşüm tabanlı modeller küresel bağlamı etkili biçimde modelleyebilse de karar süreçlerinin klinik açıdan yeterince açıklanabilir olmaması, gerçek dünya uygulamalarında benimsenmesinin önünde bir engel oluşturmaktadır. Sadece görsel açıklama haritalarına dayalı yorumların ötesine geçerek nicel ve nedensel açıklanabilirlik ölçütlerine duyulan ihtiyaç ile birden fazla alan ve veri kümesinde genelleme yapabilen tekrarlanabilir ve şeffaf bir metodolojik çerçevenin gerekliliği, çalışmanın motivasyonunu destekleyen temel unsurlardır. Bu bağlamda iki eksenli bir araştırma yürütülmektedir. (i) Histopatoloji ekseninde, patoloji görüntülerinde dönüşüm ve evrişim tabanlı sınıflandırıcılar karşılaştırılmış açıklanabilirlik için LIME uygulanmıştır. LIME'in işaretlediği bölgelerin uzman (patolog) çizimleriyle nicel uyumu ölçülmüştür. Böylece, yalnızca sınıflandırma başarımı değil, açıklamaların klinik geçerliliği de doğrudan hekim anotasyonlarına göre değerlendirilmektedir. (ii) Dermatoloji ve otoskopi ekseninde, dönüşüm tabanlı modeller ince ayar ile eğitilerek; Grad-CAM, LRP ve AR gibi ısı haritalarının üretilmesi amaçlanmıştır. Üretilen ısı haritalarına ek olarak Temel Bileşenler Analizi (TBA) ve Kanonik Korelasyon Analizi (KKA) temelli hibrit ikili birleştirme yöntemleri ile kapsam ve kararlılığı artırılmaktadır. Her iki eksen de ortak bir değerlendirme protokolü izlenmiş olup sınıflandırma için doğruluk, f1-skoru, duyarlılık, özgüllük gibi temel metrikler elde edilmiştir. Tüm deneyler tekrarlanabilir

biçimde rapor edilmiştir. Bu bütüncül plan, performans ile açıklanabilirliği birlikte ele alarak gerçek dünyada güvenilebilir ve kullanılabilir karar destek çıktıları üretmeyi hedeflemektedir.

1.5 Mevcut Tez Çalışmasında Metodolojik Olarak İzlenen Temel Yaklaşım

Tez kapsamında belirtilen hedefleri gerçekleştirmek üzere patolojik, dermatolojik ve otoskopik görüntülerden oluşan toplam 5 veri seti kullanılmıştır. İlk aşamada, akciğer patolojisi içeren veri seti 1 üzerinde dönüşüm ve evrişim tabanlı yaklaşımlar karşılaştırılmış; doğru ve yanlış sınıflandırılan seçili test örneklerine LIME tabanlı açıklamalar uygulanmıştır.

Takip eden bir diğer çalışmada, 2 ve daha fazla sınıfa sahip patoloji görüntülerinden oluşan veri seti 1 ile veri seti 2 kullanılarak iki farklı dönüşüm modeliyle sınıflandırma analizi yapılmıştır. Ardından, doğru/yanlış sınıflanan örnekler arasından seçilen görüntüler için LIME açıklamaları üretilmiş; bu açıklamalar, patolog tarafından çizilen bölgelerle (anotasyonlar) karşılaştırılmış ve yorumlanmıştır.

Üçüncü çalışma, dermatolojik hastalıkları içeren veri seti 3 ve veri seti 4 üzerinde yürütülmüştür. Bu kapsamda ikili ve çok sınıflı problemler, dönüşüm tabanlı sınıflandırıcılarla analiz edilmiş; ardından Grad-CAM, LRP ve AR yöntemleriyle açıklamalar elde edilmiştir. Üretilen açıklamaların güvenilirliğini değerlendirmek amacıyla silme ve ekleme metrikleri hesaplanmış; tekil ısı haritalarından ikili hibrit ısı haritaları TBA kullanılarak oluşturulmuştur. Son adımda ise hibrit ve tekil açıklamaların performansları karşılaştırılmıştır.

Son olarak, kulak zarı hastalıklarını içeren veri seti 5 için bir önceki işlem hattı yeniden kullanılmıştır. Hibrit analizlerde KKA ile elde edilen açıklamalar değerlendirilmiş ve TM hastalıklarına ilişkin bulgular tartışılmıştır. Bu bütüncül yaklaşım, farklı modalite ve görevlerde hem sınıflandırma başarımını hem de açıklanabilirlik düzeyini sistematik biçimde incelemeyi amaçlamaktadır

2. ÖNCEKİ ÇALIŞMALAR

Bu tez çalışmasında, farklı modalitelerden (patoloji, dermatoloji ve otoskopi) elde edilen medikal görüntüler üzerinde sınıflandırma analizleri yürütülmüş; eğitilen DÖ modellerinin karar verme davranışlarını çözümlemek amacıyla AYZ yöntemleri kullanılmıştır. Sınıflandırma sonrası, modellerin görüntülerde hangi bölgelere odaklandığını ortaya koymak için çeşitli AYZ teknikleri uygulanmıştır. Seçili çalışmalarda üretilen açıklama haritaları patolog anotasyonlarıyla karşılaştırılarak görsel ve nicel uyum (ör. örtüşme ölçütleri) değerlendirilmiştir. Ayrıca, dermatolojik ve otoskopik veri kümeleri üzerinde dönüşüm tabanlı sınıflandırıcılar ile üretilen açıklamaların kapsam ve kararlılığını artırmak üzere hibrit bir yaklaşım önerilmiş; tekil ısı haritalarının birleştirilmesiyle elde edilen bu hibrit açıklamalar, nedensel metriklerle nicel olarak doğrulanmıştır.

Literatür incelendiğinde, mevcut çalışmaların büyük bölümünün DÖ tabanlı sınıflandırma doğruluğuna odaklandığı; buna karşın açıklamaların sayısal geçerliliğini ve klinik karşılığını sistematik biçimde test eden çerçevelerin sınırlı olduğu görülmektedir. Bu tez, söz konusu boşluğu iki yönden ele almaktadır: (i) patoloji verileri üzerinde DÖ modellerinin açıklanabilirliğini uzman anotasyonlarına dayalı bir kıyasla doğrudan sınamak; (ii) deri ve kulak zarı hastalığı görüntülerinde sınıflandırma performansı için hibrit açıklama haritaları geliştirip bunları nedensel metriklerle nicel olarak doğrulamak. Böylece çalışma, yalnızca yüksek sınıflandırma performansı sunmakla kalmayıp açıklanabilirliği ölçülebilir kılan ve klinik yorumlanabilirliği güçlendiren tekrarlanabilir ve şeffaf bir yöntemsel çerçeve ortaya koyarak literatüre anlamlı katkılar sağlamaktadır.

2.1 Patolojik Görüntü Sınıflandırılmasına İlişkin Çalışmalar

2.1.1 Açıklanabilirlik içeren histopatolojik görüntü sınıflandırma çalışmaları

Raju ve Rao (2022), histopatolojik görüntülerin sınıflandırmasını desteklemek ve görsel açıklamaları zenginleştirmek amacıyla Grad-CAM ve SmoothGrad tabanlı görselleştirme tekniklerinden yararlanmıştır. Çalışmada, kolon ve akciğer dokularına ait 5 farklı histopatolojik sınıf MobileNetV2 ve InceptionResNetV2 mimarileri kullanılarak sınıflandırılmıştır. Önerilen çerçevenin kanser dokularını tanımlamada en yüksek %99.95 doğruluğa ulaştığı rapor edilmiştir. Yazarlar, bu yaklaşımla

üretileen açıklamalar aracılığıyla modelin odaklandığı bölgeleri görünür kılmayı ve böylece klinik yorumlanabilirliği güçlendirmeyi hedeflemiş ve nihai amaç olarak da sağlık hizmet sunucularının kolon ve akciğere ilişkin çoklu kanser tiplerini saptamada kullanılabilecek, bilgisayar destekli ve güvenilir bir karar destek sistemi geliştirilmesine katkı sağlamayı belirtmişlerdir [41].

Tummala vd. (2023), kolon ve akciğer verisine dayalı 5 sınıflı sınıflandırma probleminde, 5 katlı çapraz doğrulama ile eğitilip sınanan EfficientNetV2 modelleriyle test kümesinde %99.97 doğruluk bildirmiştir. Ayrıca, model öngörülerinin dayandığı ayırt edici görüntü bölgelerini görünür kılmak ve bulguların klinik yorumlanabilirliğini güçlendirmek amacıyla çalışmayı ‘saliency’ haritalarıyla desteklemişlerdir [42].

Ahmed vd. (2023) ise yorumlanabilir bir akciğer kanseri tanı sistemi sunarak Rastgele Orman (RO), Karar Ağacı, Lojistik Regresyon (LR) ve Naif Bayes (NB) dâhil çeşitli MÖ modellerini aynı akciğer doku görüntü veri kümesi üzerinde karşılaştırmıştır. İncelenen modeller arasında en yüksek doğruluk oranına RO ve LR ile ulaşılmıştır. Akciğer kanserinin öngörülmesinde her iki model de %97 doğruluk raporlamıştır. Çalışma, kullanılan öğrenme yapılarının şeffaflığını artırmak ve karar süreçlerini görünür kılmak amacıyla SHAP (SHapley Additive exPlanations) ve LIME tabanlı açıklamalar üretmiş ve bu sayede hem küresel ölçekte özellik önemlerini hem de tekil örneklere ilişkin yerel açıklamaları ortaya koyarak klinik yorumlanabilirliği güçlendirmiştir [43].

Kaplun vd. (2021), modern dijital patolojinin sağladığı olanaklardan yararlanarak özellikle Hematoksilin–Eozin (H&E) boyalı mikroskopik görüntüler üzerinden kanser hücre dokularının otomatik ve nicel analizi için bir yöntem önermiştir. Çalışmada, kanser hücre görüntülerinden karmaşık biçimsel özellikleri çıkarmak amacıyla ‘zernike momentleri’ (şekil özellikleri çıkarma) kullanılmış ve bu betimleyiciler basit yapay sinir ağı (YSA) tabanlı bir sınıflandırıcıya beslenmiştir. Sınıflandırma çıktılarının yorumlanabilirliğini artırmak ve modelin hangi görsel ipuçlarına dayandığını göstermek için LIME çerçevesi uygulanmıştır. Çalışma böylece AYZ ilkeleriyle desteklenmiştir. Önerilen yüksek verimli çalışma,

‘BreaKHis’ veri kümesinin edinilmesiyle başlayıp görüntü işleme ve MÖ adımlarıyla sürmektedir. Sistem, 40× büyütme düzeyindeki iyi huylu ve kötü huylu kanser ayırımında %100 tanıma oranı bildirmiştir. AYZ bileşeni ise test sonuçlarının klinik açıdan şeffaf biçimde yorumlanmasına ve gerekli parametre ayarlarının rasyonel olarak yapılmasına katkı sağlamıştır [44].

Imouokhome vd. (2023), meme kanserinde erken evre teşhisini kolaylaştırmak amacıyla ‘Kaggle Challenge’ kapsamında sağlanan ‘BreaKHis’ veri kümesini kullanarak ResNet-50 mimarisini eğitmiş ve meme tümörlerinin kötü huylu ya da iyi huylu olarak sınıflandırmışlardır. Test evresinde %96.84 doğruluk elde edilmiş ve aynı DÖ metodolojisini kullanan diğer çalışmaların sonuçlarını aştıklarını raporlamışlardır. Sınıflandırma çıktıları, kararların hangi görsel ipuçlarına dayandığını gerekçelendirmek üzere AYZ teknikleri ile yorumlanmış ve Integrated Gradients (IG), GradientSHAP ve Occlusion yöntemleri uygulanmıştır. Üç yaklaşım karşılaştırıldığında, Occlusion tekniğinin görselleştirme kalitesi ve çalışma süresi açısından daha öngörücü ve pratik sonuçlar sunduğu rapor edilmiştir [45].

2.1.2 Açıklanabilirlik içermeyen performans metriği odaklı histopatolojik görüntü sınıflandırma çalışmaları

Aitazaz vd. (2023), kolon ve akciğer görüntülerinde ViT ile çeşitli ön-eğitilmiş ESA mimarilerinin tanısal başarımını sistematik olarak karşılaştırmıştır. Çalışmanın bulguları, ViT mimarisinin değerlendirmeye alınan ön-eğitilmiş ESA’lardan daha yüksek performans sunduğunu göstermiştir. Ayrıca, katman sayısı daha yüksek olan ViT-L32 modelinin, ViT-B32 varyantına kıyasla daha yüksek doğruluk elde ettiği rapor edilmiştir. Bu sonuçlar, söz konusu veri türlerinde dönüşüm tabanlı yaklaşımların güçlü bir alternatif oluşturduğunu ortaya koymaktadır [46].

Ali ve Ali (2021), kolon ve akciğer kanserlerinin ayırımına yönelik olarak geleneksel evrişim katmanları, ayrılabilir evrişim katmanları ve kapsül ağlarını bir araya getiren iki girişli hibrit bir mimari geliştirmiştir. Ön işleme aşamasında gama düzeltme, renk dengesi, görüntü keskinleştirme ve çok ölçekli birleştirme uygulanmıştır. Modelin birinci giriş kolunda ham görüntüler standart evrişim katmanlarından geçirilirken, ikinci giriş kolunda ön işlenmiş görüntüler ayrılabilir evrişim katmanları ile işlenmiş;

her iki koldan elde edilen temsil vektörleri nihai sınıflandırma için kapsül ağına beslenmiştir. Deneysel sonuçlar, önerilen yaklaşımın tüm sınıflar üzerinde anlamlı bir başarı sergilediğini ve kolon ile akciğer kanseri verisinde toplam doğruluk oranının %99.58'e ulaştığını göstermiştir [47].

Kumar vd. (2022), akciğer ve kolon kanseri sınıflandırması için el ile çıkarılmış (hand-crafted) özelliklerle DÖ tabanlı özellik çıkarımını karşılaştırmıştır. Çalışmada, yedi farklı aktarım öğrenmesi (transfer learning: TL) modelinden elde edilen derin özellikler ile el ile çıkarılmış betimleyiciler, Gradient Boosting (GB), RBF çekirdekli Destek Vektör Makineleri (DVM), Çok Katmanlı Algılayıcı (Multi Layer Perceptron: MLP) ve RO sınıflayıcıları kullanılarak değerlendirilmiştir. Bulgular, derin özelliklerin manuel olarak çıkarılmış özelliklere belirgin biçimde üstün geldiğini göstermiş ve özellikle DenseNet-121'den türetilen özellikler ile RO sınıflayıcısının birleşimi, doğrulukta %98.6 ve ROC-AUC'de 1.00 değerlerine ulaşarak en yüksek performans sağlamıştır [48].

Talukder vd. (2022), kolon ve akciğer kanserlerinin saptanmasına yönelik hibrit bir yöntem önermiştir. Önerilen yaklaşımda öznetelik çıkarımı için MobileNet mimarisi kullanılmış ve sınıflandırma aşamasında ise birden çok temel sınıflayıcının çıktılarını olasılıksal olarak birleştiren topluluk düzeni uygulanmıştır. Yapılan deneysel değerlendirmeler, yöntemin kolon ve akciğer kanserlerini tanımda %99.3 doğruluk sağladığını göstermiştir. Bu sonuç, hafif derin mimarilerden elde edilen temsil gücünün topluluk temelli karar verme mekanizmalarıyla birleştirilmesinin hem yüksek doğruluk hem de hesaplama verimliliği açısından etkili bir alternatif sunduğunu işaret etmektedir [49].

Wahid vd. (2023), önerdikleri sade ve özelleştirilmiş bir ESA mimarisini 3 farklı önceden eğitilmiş GoogLeNet, ResNet-18 ve ShuffleNet V2 mimarileri ile karşılaştırmıştır. Değerlendirme sonuçları, akciğer kanseri sınıflandırmasında en yüksek doğruluğun ResNet-18; kolon verisinin değerlendirilmesinde ise ShuffleNet V2 ile elde edildiğini ve her iki durumda da ortalama doğruluğun %99.87'ye ulaştığını göstermiştir. Önerilen özelleştirilmiş ESA modeli, akciğer verisi için %93.02 ve kolon verisi için %88.26 doğruluk sağlamıştır. Ayrıca yazarlar, bu

özelleştirilmiş modelin eğitim süresinin GoogLeNet ve ResNet-18'e kıyasla daha kısa olduğunu ortaya koymuştur [11].

Sayın vd. (2023) VGG, ResNet, Xception, Inception ve InceptionResNet mimarilerini karşılaştırmış ve sınıflandırma sonuçlarında Xception modeli en yüksek başarıyı f1-skoru 0.90 ve doğruluk %89 ile sağladığını rapor etmişlerdir. Inception ve InceptionResNet modelleri %87 doğruluk elde ederken, ilgili f1-skorları sırasıyla 0.87 ve 0.86 olarak raporlanmıştır. Bulgular, histopatolojik meme kanseri tanısında DÖ tabanlı yaklaşımların klinik doğruluğu artırma potansiyeline işaret etmekte ve tanısal hizmetlerin iyileştirilmesine katkı sağlayabileceklerini göstermektedir [50].

2.2 Dermatolojik Görüntü Sınıflandırılmasına İlişkin Çalışmalar

2.2.1 Açıklanabilirlik içeren dermatolojik görüntü sınıflandırma çalışmaları

Ahsan vd. (2023), 6 farklı ön-eğitilmiş TL modeli uyarlayıp sınıflandırmışlardır. InceptionResNetV2 ve MobileNetV2'nin %93–99 aralığında en yüksek doğruluklara ulaştığını göstermiştir. Yazarlar, maymun çiçeği ve maymun çiçeği olmayan olgulardan oluşan ikili veri kümesinin artırılmış ve artırılmamış sürümlerini ayrı ayrı değerlendirmişlerdir. Her iki senaryoda da LIME ile en yüksek katkı puanına sahip süper piksel özellikleri ortaya koyarak açıklanabilirliği güçlendirmişlerdir [51].

Raha vd. (2023), maymun çiçeği saptaması için dikkat mekanizmalı bir MobileNetV2 önermişlerdir. 2 farklı veri kümesi üzerinde yaptığı değerlendirmede MSID üzerinde %98.19 doğrulukla en iyi performansı rapor etmiş ve modelin yorumlanabilirliğini Grad-CAM ile LIME kullanarak desteklemişlerdir [52].

Saavedra vd. (2023), ResNet50, EfficientNetB0 ve MobileNetV2'den oluşan bir topluluk (ensemble) yaklaşımıyla %98 doğruluk elde etmişlerdir. Ayrıca, 3 sınıflı maymun çiçeği veri kümesi üzerinde Grad-CAM gibi AYZ tekniklerini topluluk modelleriyle birlikte uygulayan ilk çalışmalardan biri olduğunu belirtmişlerdir [53].

Nayak vd. (2023), 5 farklı önceden eğitilmiş derin sinir ağını eğitip değerlendirerek en yüksek doğruluğu ResNet-18 ile %99.49 olarak rapor etmişlerdir. Değiştirilmiş tüm modellerin doğrulama başarımının %95'in üzerinde olduğunu göstermiştir.

Maymun çiçeği tanısında model şeffaflığını artırmak amacıyla LIME ve Grad-CAM'ı kullanmış ve değerlendirmelerini artırılmış Maymun çiçeği deri lezyon verisi (Monkeypox Skin Lesion Dataset: MSLD) veri seti üzerinde gerçekleştirmişlerdir [54].

Siddick vd. (2024), ViT ile hibrit bir modelin test başarımında diğer yaklaşımları geçtiğini ve ViT'in %99.41 ve hibrit yaklaşımın %99.09 doğruluğa ulaştığını göstermişlerdir. Grad-CAM ile desteklenen bu modellerin, tahminlerin görselleştirilmesini güçlendirerek maymun çiçeği hastalığının doğru ve yorumlanabilir biçimde tanılanmasına katkı sunduğu belirtilmiştir [55].

Sitaula ve Sihahi (2022), 13 farklı ön-eğitilmiş DÖ modeli karşılaştırdıktan sonra olasılıksal çıktılar üzerinde çoğunluk oylaması ile topluluk kurmuşlardır. Maymun çiçeği deri görüntü verisi (Monkeypox Skin Image Dataset: MSID) veri setinde ortalama %87.13 doğruluk elde etmiş ve model kararlarının görselleştirilmesi için Grad-CAM ile LIME'dan yararlanmışlardır [56].

2.2.2 Açıklanabilirlik içermeyen performans metriği odaklı dermatolojik görüntü sınıflandırma çalışmaları

Abdelrahim vd. (2024), dönüşüm tabanlı modellerin çıkarım gücünü DVM ile birleştiren bir topluluk yaklaşımı sunmuş, ek olarak 7 farklı ESA mimarisini karşılaştırmışlardır. En iyi 4 modelden elde edilen yüksek boyutlu özellik vektörleri birleştirilmiş ve optimize edilmiştir. 2 sınıflı ve artırılmış veri kümesi üzerinde %95.45 doğruluk elde edilerek yöntemin veri değişkenliğine karşı dayanıklılığı ortaya konmuştur [57].

Kundu vd. (2024), veri artırımı amacıyla CycleGAN'ı kullanarak yapay görüntüler üretmiş ve bu zenginleştirilmiş veriyle sınıflandırma modellerini eğitmişlerdir. Veri güvenliğini gözetmek üzere Flower tabanlı federatif öğrenme altyapısını kullanmış ve ViT-B32 modelinin %97.90 doğrulukla en iyi sonucu verdiğini göstermişlerdir [55].

Haque vd. (2022), kanal ve uzamsal dikkat (CBAM) mekanizmalarını içeren 5 farklı DÖ mimarisini uygulamışlardır. Karşılaştırmalı analiz sonucunda Xception-CBAM-Dense yapısının maymun çiçeği ve diğer dermatolojik sınıfların ayırımında doğrulama doğruluğu %83.89 ile en iyi performansı sunduğunu ortaya koymuşlardır [58].

Uysal (2023), MSID veri kümesi üzerinde güncel DÖ modellerini sistematik biçimde sınıflandırıcı olarak kullanmıştır. Sınıflandırma başarımını artırmak amacıyla en iyi 2 taban modeli uzun-kısa süreli bellek ağı (Long Short Term Memory: LSTM) ile birleştiren hibrit bir yapı önermiştir. Bu bağlamda test doğruluğunu %87, ‘Cohen’in kappa katsayısını’ ise 0.8222 olarak bildirmiştir [59].

Altun vd. (2023), açık kaynaklı maymun çiçeği verilerini derleyerek kendi veri kümelerini oluşturmuş ve çoklu model denemeleri sonrasında hibrit bir ESA mimarisi önermişlerdir. Optimize edilmiş MobileNetV3-Small tabanlı çözümün ortalama %96 doğrulukla en iyi performansı verdiğini göstermişlerdir [60].

2.3 Otoskopik Görüntü Sınıflandırılmasına İlişkin Çalışmalar

2.3.1 Görüntü temelli otoskopik sınıflandırma çalışmaları

Wu vd. (2021), ESA temelli sınıflandırma modeli önermişlerdir. Bu amaçla yaygın kullanılan 2 farklı ESA mimarisi (Xception ve MobileNet-V2) uyarlanmıştır. Görüntüler; akut OM (AOM), OM efüzyonu (OME) ve normal kulak kategorilerini içermektedir. Kalite ölçütlerini sağlayan otoskopik görüntüler arasından 10.703 görüntüyü eğitim, 1.500 görüntüyü ise test için ayrılmıştır. Test kümesinde tüm tanı kategorileri birlikte değerlendirildiğinde, Xception modelinin genel doğruluğu %97.45, MobileNet-V2’nin doğruluğu ise %95.7 olarak bulunmuştur. Ayrıca CAM analizi, akıllı telefonla edinilen görüntülerde çıkarılan ayırt edici bölgelerin otoskopik görüntülerdekilerle örtüştüğünü göstermiştir [61].

Elabbas vd. (2021), gelişmekte olan ülkelerde sık karşılaşılan yanlış tanı sorununu azaltmak amacıyla otoskopik görüntülerden AOM ve kronik iltihaplı OM (CSOM) olgularını saptamak için YOLOv3 temelli bir nesne algılama yaklaşımı uygulamıştır. Çalışmada hastalık türleri, görüntü üzerinde doğrudan tespit edilmesi hedeflenen

sınıflar olarak modellenmiş ve küçük ölçekli bir test kümesi üzerinde elde edilen doğruluk oranı %75 olarak raporlanmıştır. Yazarlar, veri kümesinin boyutu ve çeşitliliğinin artırılmasıyla birlikte performansın kayda değer ölçüde iyileştirilebileceğini belirtmiştir. YOLOv3'ün düşük donanım gereksinimi, görece düşük maliyetli uygulanabilirliği ve rapor edilmiş yapısı, özellikle kaynak kısıtlı sağlık ortamlarında orta kulak enfeksiyonlarının otomatik saptanması için pratik bir çözüm sunma potansiyeline işaret etmektedir [62].

Habib vd. (2023), Türkiye, Şili ve ABD'den toplanan otoskopik görüntüler üzerinde orta kulak hastalığının saptanmasına yönelik DÖ tabanlı algoritmaların genellenebilirliğini değerlendirmiştir. Modeller kurum içi veride yüksek ayırt edicilik sergilerken (AUC=0.95), kurum dışı veri setlerinde performansın AUC=0.76'ya gerilediği gösterilmiştir. Bu durum, veri dağılımı farklılıklarının genellenebilirliği azalttığını düşündürmektedir. Tüm veri kaynaklarının birleştirilmesiyle ikili sınıflandırma için performansın AUC=0.96'ya yükselmesi, çok-merkezli ve çeşitlendirilmiş veriyle eğitimin genellenebilir sorunlarını kısmen hafifletebileceğine işaret etmektedir [63].

Alhudhaif vd. (2021), kanal ve uzamsal dikkat bileşenleri, artık bloklar ve hiper-kolon temsilleriyle zenginleştirilmiş ESA tabanlı bir karar destek modeli önermiştir. 5 sınıflı TM veri kümesi üzerinde eğitilen model, standart ön-eğitilmiş ESA'ları geride bırakarak %98.26 doğruluk elde etmiştir. Bulgular, önerilen yaklaşımın tanısal öznellikleri azaltma ve klinik karar süreçlerini destekleme potansiyeline sahip olduğunu göstermektedir [64].

Akyol vd. (2024) birden çok ön-eğitilmiş ESA modelini bütünleyen DÖ tabanlı bir ensemble çerçevesi önermiş ve bu yaklaşımla otoskopik görüntülerden OM tanısında %98.8 düzeyinde, güncel en iyi sonuçlara ulaşmıştır. Elde edilen bulgular, yöntemin ön değerlendirme ve klinik karar verme süreçlerinde klinisyenleri güvenilir biçimde destekleyebilecek pratik bir araç olma potansiyeline işaret etmektedir [65].

Sundgaard vd. (2021), 1.336 otoskopik görüntüden AOM, OME ve normal kulak ayrımı yapmak üzere DÖ'ye dayalı bir metrik önermiştir. Çalışmada karşıt, üçlü ve

çok sınıflı kayıplar denenmiş ve dengesiz veri dağılımında en yüksek kesinliğin üçlü kayıp ile elde edildiği gösterilmiştir. Önerilen metrik öğrenme çerçevesi, sınıf-ağırlıklı çapraz entropi taban çizgilerini aşmış ve genel performans düzeyi klinik uzmanlarla karşılaştırılabilir bulunmuştur. Bu bulgular, özellikle dengesiz sınıf yapısına sahip otoskopik veri setlerinde, örnekler arası gömü uzayındaki ayrıştırıcılığı doğrudan optimize eden metrik öğrenme yöntemlerinin tanısallık doğruluğu artırmada etkili bir alternatif sunduğunu düşündürmektedir [66].

Çamalan vd. (2020), TM'nin normal, efüzyonlu ve kulak tüpü yerleştirilmiş durumlarını kapsayan görüntüler için 'OtoMatch' adlı içerik tabanlı görüntü getirme sistemini geliştirmiştir. Bu amaçla, başlangıçta sınıflandırma için eğitilmiş bir ESA'dan elde edilen gömme özellik temsilleri kullanılarak benzerlik tabanlı getirme yapısına geçilmiş ve sistem 454 etiketli görüntü üzerinde 10 katlı çapraz doğrulama ile değerlendirilmiştir. En benzer olgunun getirilmesi senaryosunda doğruluk 80.58 ± 5.37 olarak raporlanmıştır. Elde edilen sonuçlar, birinci basamak sağlık hizmetlerinde karar desteği amacıyla, hekime benzer vaka örnekleri üzerinden görsel referans sunan getirme temelli yaklaşımların uygulanabilir ve yararlı olduğunu göstermektedir [67].

Cai vd. (2021), OM tanısında iki aşamalı dikkat farkındalıklı ESA yaklaşımının yararlılığını ve performansını değerlendirmiştir. 2 yaygın ESA mimarisi eğitilip değerlendirilmiştir. Sınıflandırma doğruluğunu ve güvenilirliğini artırmak, uzman okumasını taklit etmek amacıyla CAM temelli iki aşamalı bir işlem hattı tasarlanmıştır. Çalışma, Çin'de bir KBB kliniğinden 2.022 katılımcıya ait 6.066 otoskopik görüntüden oluşan veri seti üzerinde yürütülmüştür. Önerilen yöntem, üç katlı çapraz doğrulamada (omurga: ResNet50) %93.4 genel doğruluk sağlamıştır. Bulgular, model performansının bir doçent düzeyi klinik tanı yetkinliğiyle karşılaştırılabilir olduğunu göstermektedir. Sonuç olarak, ESA'lar TM görüntülerinin otomatik sınıflandırılmasında etkili bir araç sunmakta; zayıf denetimli CAM kullanımı, ağır ayrıştırıcı bölgelere odaklanmasını sağlayarak nispeten küçük veri tabanlarında dahi performansı artırmaktadır [68].

Byun vd. (2021), çalışmasının amacı TM görüntülerinden orta kulak hastalıklarını tanılayacak bir MÖ ağı geliştirmek ve bu modelin tanı sürecindeki yardımcı rolünü değerlendirmektir. Kulak endoskopisi uygulanan olguların tıbbi kayıtları geriye dönük incelenmiş; bu kayıtlardan etiketlenmiş 2.272 tanısal TM görüntüsü modelin eğitimi için kullanılmıştır. Önerilen ResNet18 + Shuffle ağı geliştirilmiş ve beş katlı doğrulama ile %93'ün üzerinde doğruluk elde edilmiştir [69].

Choi vd. (2022), çoklu hastalık içeren otoskopik görüntülerden oluşan bir veri tabanı oluşturularak, eşzamanlı hastalıkların DÖ tabanlı sınıflandırma performansına etkisini araştırmışlardır. Eş zamanlı olarak yürütülen çalışmada, çok sınıflı sınıflandırma çerçevesinde özelleştirilmiş EfficientNet-B4 mimarisi kullanılmış; birincil sınıflar olarak OME, COM ve diğerleri (OME/COM dışı); ikincil sınıflar olarak üst kulak boşluğu doku birikintisi (kolesteatomu), kulak zarı iltihabı, kulak mantar enfeksiyonu ve kulak tüpü öngörülmüştür. Sonuçlar, DÖ sınıflandırmasının birincil sınıfları %95.19 Dice benzerlik katsayısı ile doğru tahmin ettiğini ve COM–OME karışıklığının nadiren görüldüğünü göstermiştir. İkincil sınıflar arasında üst kulak boşluğu kolesteatomu ve kulak zarı iltihabı tanılarında sırasıyla %88.37 ve %88.28 metrikleri elde edilmiştir. Bu bulgular, çoklu patoloji içeren TM görüntülerinde özelleştirilmiş EfficientNet-B4 yaklaşımının yüksek doğruluk ve klinik açıdan pratik hız sunduğunu göstermektedir [70].

2.3.2 Video temelli otoskopik sınıflandırma çalışmaları

Shaik vd. (2022), akıllı telefonla kaydedilmiş otoskopi videolarından AOM tanısı koymak üzere artık-yinelenen sinir ağı (Recurrent Neural Network: RNN) tabanlı derin bir model geliştirmiştir. 1.151 video ile eğitilen model, duyarlılıkta %93.8 ve özgüllükte %93.5'e ulaşarak karar ağacı tabanlı bir modelle benzer performans sergilemiştir [71].


Binol vd. (2022), otoskopi videolarından türetilen çoklu bileşik görüntüleri kullanan 'OtoXNet' adlı DÖ mimarisini sunmuştur. Tekil karelere ya da uzman tarafından seçilmiş ana karelere dayanan yaklaşımları geride bırakarak çok sınıflı sınıflandırmada %84.8 doğruluk elde etmiş ve kulak zarı anomalilerinin otomatik tanısında video-türetilmiş temsillerin üstünlüğünü göstermiştir [72].

Hao vd. (2025), uzman seçimi kare gerektirmeyen ‘VideoMAE’ adlı bir DÖ modeli önermiştir. Tüm video karelerinin kullanımı, veri artırma ve dengeli yeniden örnekleme ile 7 orta kulak durumunu sınıflandırmada 92.1 ± 4.0 doğruluk rapor etmiş ve gerçek yaşam senaryolarında tanısal performansın iyileştiğini göstermiştir [73].



3. MATERYAL VE METOT

Bu tez kapsamında, farklı modalitelere ait 5 veri kümesi üzerinde AYZ temelli yaklaşımların geliştirilmesi ve değerlendirilmesi amaçlanmıştır. Bu kapsamda, 4 ayrı deneysel çalışma yürütülmüş ve her birinde DÖ tabanlı modeller ile açıklanabilir yöntemler bütünleşik biçimde kullanılmıştır. Bu bölümde, kullanılan veri kümelerine ait özellikler, ön işleme süreçleri, uygulanan model mimarileri, AYZ metotları ve açıklanabilir düzeyinin nicel olarak incelenmesinde kullanılan metrikler ayrıntılı biçimde sunulmuştur. Tezde izlenen genel metodolojik yaklaşım Şekil 3.1’de şematik olarak özetlenmiştir.



Şekil 3.1 Tez çalışması boyunca izlenen yol

3.1 Materyal

Bu tez kapsamında AYZ temelli sınıflandırma ve analizler, toplam 5 farklı veri seti üzerinde yürütülmüştür. Kullanım dağılımı şu şekildedir: veri seti 1,2 Metot 1 kapsamında; veri seti 3,4,5 ise Metot 2 kapsamında değerlendirilmiştir. Böylece önerilen yöntemler hem tekil ve çoğul hem de farklı modalite senaryolarında sistematik olarak sınanmıştır.

3.1.1 Veri seti 1: Akciğer ve kolon kanserine ilişkin patolojik görüntü kümesi







Bu tez çalışmasında, açık erişimli bir kaynak olan ‘Kaggle’ platformundan temin edilen ‘LC25000 Veri Seti’ kullanılmıştır. İlgili veri seti, Florida’da bulunan James

Hastanesi bünyesinde görev yapan Andrew Borkowski ve çalışma ekibi tarafından oluşturulmuştur [74]. Veri seti, akciğer ve kolon kanseri olgularına ait histopatolojik görüntülerden oluşmaktadır. Veri seti akciğer kanseri görüntüleri için 3 farklı sınıfı, kolon kanseri görüntüleri için ise 2 farklı sınıfı içermektedir. Orijinal görüntülerin boyutu 1024×768 piksel olup veri setini oluşturan araştırmacılar tarafından tüm görüntüler 768×768 piksel boyutuna yeniden ölçeklendirilmiştir. Veri seti toplamda 750 akciğer kanseri ve 500 kolon kanseri örneği içermektedir. Veri çeşitliliğini genişletmeye yönelik artırma işlemleri de veri seti sağlayıcıları tarafından uygulanmıştır. Bu kapsamda sağa-sola döndürme ile yatay ve dikey çevirme adımları kullanılarak her sınıf için 5.000 görüntü üretilmiş ve böylece toplam örnek sayısı 25.000'e ulaşmıştır. Bu çalışmada, söz konusu ön-işlemler veri seti sahiplerince önceden gerçekleştirilmiş hâliyle kullanılmıştır.

3.1.2 Veri seti 2: Meme kanserine ilişkin patolojik görüntü kümesi

Bu tez çalışmasında kullanılan 'BrecaKHis Veri Seti', 82 hastadan toplanmış meme tümörü histopatoloji görüntülerinden oluşan açık erişimli bir kaynaktır [75]. Görüntüler dört büyütme düzeyinde (40×, 100×, 200×, 400×) elde edilmiş olup RGB renk uzayında 700×460 piksel, 8-bit derinlikte PNG formatındadır. Veri seti iki ana sınıfa ayrılır: Normal doku ve tümör dokusu. Güncel sürümde toplam 7.909 görüntü bulunmaktadır. Bunun 2.480'i normal doku, 5.429'u tümör dokusuna örnektir. Veri seti, Brezilya'daki P&D Laboratuvarı ile iş birliği içinde oluşturulup literatürde makine öğrenmesi çalışmalarında standart bir kıyas kümesi olarak yaygın biçimde kullanılmaktadır. Çalışmada kullanılan veri seti 1 ve 2'ye ait bazı görüntüler Tablo 3.1'de gösterilmektedir.

Tablo 3.1 Metot 1 kapsamında kullanılmış LC25000 ve BreakHis verilerinden alınan iyi ve kötü huylu patolojik yama görüntüleri

Sınıf	Akciğer patolojisi	Kolon patolojisi	Meme patolojisi
Kötü huylu			
İyi huylu			

3.1.3 Dermatolojik görüntü kümeleri olarak veri seti 3 ve veri seti 4

Bu tez çalışmasında kullanılan MSLD, maymun çiçeği tanısına yönelik deri lezyonu görüntülerinden oluşan ve literatürde yaygın biçimde başvurulanan bir veri setidir [76]. Veri seti 2 sınıftan oluşur: maymun çiçeği (102 görüntü) ve diğerleri (126 görüntü; kızamık ve suçiçeği dâhil). Toplam 228 özgün görüntü içeren bu veri setinde klasörlerde artırılmış örnekler bulunsa da çalışmada yalnızca orijinal görüntüler kullanılmış ve veri artırma işlemleri eğitim sırasında dinamik olarak uygulanmıştır. Sınıf etiketleri klinik olarak şu varlıkları temsil eder: Maymun çiçeği hayvan tabanlı, insanlara bulaşabilen bir enfeksiyon türüdür. Genellikle ateş, baş ağrısı, kas ağrısı ile çiçek benzeri döküntü bulguları gösterir; bulaş çoğunlukla enfekte hayvan/insanla yakın temas yoluyla gerçekleşir ve bağışıklığı baskılanmış bireylerde ağır seyredebilir [77]. ‘Diğerleri’ sınıfında yer alan suçiçeği, virüs kaynaklı kaşıntılı kabarcıklı döküntüyle seyreder ve erişkin olgularda zatürre ile beyin iltihabı gibi ciddi komplikasyonlara neden olabilir [78]. Kızamık ise yüksek bulaşıcılığa sahip bir RNA virüsü enfeksiyonudur ve lekeli/kabarık deri döküntüsü, yüksek ateş, öksürük, burun iltihabı ve göz iltihabı bulgularıyla seyreder. Kızamık virüs enfeksiyonu zatürre ve beyin iltihabı başta olmak üzere ağır komplikasyon riski taşır [79].

MSID, 4 sınıftan oluşan daha kapsamlı bir deri görüntüsü veri setidir [80]. Maymun çiçeği (279), suçiçeği (107), kızamık (91) ve normal (293) olmak üzere toplam 770 görüntü içerir. Bu sınıflar, benzer döküntü örüntülerine sahip viral hastalıkların

birbiriyle ayrımını değerlendirmeye imkân tanımaktadır. ‘Normal’ sınıfı ise herhangi bir lezyon bulgu içermeyen sağlıklı deri görüntülerini temsil ederek sınıflandırma performansının karşılaştırma düzeyini belirlemede kullanılır. Tablo 3.2’de bahsi geçen görüntüler verilmiştir. Bu çalışmada, MSLD’de olduğu gibi, MSID için de yalnızca orijinal görüntüler esas alınmış ve veri artırma eğitim aşamasında dinamik biçimde uygulanmıştır. Böylelikle her iki veri setinde de hem modelin genellenebilirliği artırılmış hem de klinik olarak anlamlı sınıfların ayrıştırılmasına yönelik sağlam bir deneysel zemin oluşturulmuştur.

Tablo 3.2 MSID veri kümesinden elde edilen temsili görüntüler




Sınıf	Dermatolojik vaka görüntüleri	
Maymun çiçeği		
Kızamık		
Suçiçeği		
Normal		

3.1.4 Veri seti 5: TM (kulak zarı) görüntü kümesi

Tezin bu bölümünde, Ohio Eyalet Üniversitesi ve Nationwide Çocuk Hastanesi, Columbus, ABD tarafından oluşturulan ve etik kurul onayı 2016H0011 numarasıyla yayımlanmış, açık erişimli TM veri seti kullanılmıştır [67]. Veri seti, erişkin ve

pediatrik hasta grubundan KBB ve birinci basamak sağlık birimlerinde elde edilmiş, anonimleştirilmiş, yüksek çözünürlüklü JPEG formatında 1440×1080 piksel otoskopi görüntülerini içermektedir. Ayrıca, kulak tüpü kategorisindeki örnek sayısını artırmak amacıyla otoskopi video kayıtlarından çıkarılan kareler de veri setine dâhil edilmiştir. Toplam 454 TM görüntüsü efüzyon (179), normal (179) ve kulak tüpü (96) olmak üzere 3 sınıfta etiketlenmiştir. Tablo 3.3’de veriye ait bazı görüntüler verilmiştir. Bu yapı, efüzyon varlığının ayırt edilmesi ve tüp veya normal bulguların sınıflandırılması gibi klinik açıdan anlamlı senaryoların modellenmesine olanak tanımaktadır. Veri setinin yüksek çözünürlüklü ve gerçek klinik koşullarda toplanmış olması hem DÖ modellerinin geliştirilmesi hem de açıklanabilir analizlerin klinik yorumlarla ilişkilendirilmesi bakımından güçlü bir temel sunmaktadır.

Tablo 3.3 Kulak zarı veri kümesinden elde edilen temsili görüntüler

Sınıf	Yüksek çözünürlüklü otoskopi görüntüleri
Efüzyon	
Tüp	
Normal	


3.2 Metot

Bu tez çalışması, iki temel metot altında yapılandırılmıştır. İlki patolojik görüntülerin sınıflandırılmasında LIME temelli açıklanabilirlik yaklaşımının entegrasyonu; ikincisi ise dönüşüm tabanlı modeller üzerinde Grad-CAM, AR ve LRP çıktılarının farklı analizlerle birleştirilerek hibrit ısı haritalarının oluşturulması ve bu

açıklamaların nicel metriklerle değerlendirilmesi şeklindedir. İlk metotta, evrişim ve dönüşüm tabanlı sınıflandırma modellerinin karar bölgeleri, LIME ile görselleştirilmiştir. Elde edilen açıklamalar, sınıflandırma çıktılarıyla birlikte raporlanarak patoloğ yorumları ile ilişkilendirilmiştir. İkinci metotta ise ViT gibi dönüşüm tabanlı mimarilerden elde edilen açıklama haritaları TBA/KKA tabanlı füzyon yöntemlerle birleştirilmiş ve böylece tekil yöntemlerin tamamlayıcı, güçlü yönlerini yansıtan hibrit ısı haritaları üretilmiştir. Açıklamaların güvenilirliği ve karar sürecine nedensel katkısı ekleme ve silme eğrileri olan nicel ölçütlerle sınanmıştır.

3.2.1 Patolojik görüntü sınıflandırmasında LIME tabanlı açıklanabilirlik: Metodoloji ve uzman değerlendirmesi

Bu bölümde, Şekil 3.1’de özetlenen Metot 1 ve veri seti 1-2 kapsamındaki çalışmalar detaylandırılmıştır. Bu çerçevede akciğer, kolon ve meme patolojik görüntülerine ait veri seti 1 ve veri seti 2’ye uygulanan ön işlem adımları, kullanılan sınıflandırma algoritmaları ve AYZ yöntemleri Şekil 3.2’de gösterilmiştir. Metot 1 içinde çalışma 1 ve 2’ye ait ortak olarak kullanılan ViT modeli ile LIME yaklaşımının kuramsal arka planı ve ayrıntıları çalışma 1 içinde verilmiştir. Bu bağlamda, çalışma 1 için ön işlem, DÖ modelleri ve LIME temelli açıklanabilirlik detaylandırılıp çalışma 2 için ise ön işlemin yanı sıra Fourier Net (FNet) mimarisine yoğunlaşmıştır. Ayrıca, çalışma 1 yalnızca veri seti 1’in akciğer patoloji verileriyle yürütülmüş olup çalışma 2 ise veri seti 1 ve 2 birlikte incelenmiştir. Çalışma 1’den farklı olarak, çalışma 2 AYZ uygulamasını takiben elde edilen LIME çıktıları alanında uzman patoloğ değerlendirmeleriyle karşılaştırılmış ve bulgular klinik açıdan yorumlanmıştır.



Şekil 3.2 Metot 1'e ait çalışma akışı

3.2.1.1 Çalışma 1 kapsamında önerilen metot

Veri seti 1 için kullanılan ön işlem basamakları

Metot 1'in ilk çalışmasında, akciğer patolojisine ait tüm görüntüler $128 \times 128 \times 3$ boyutuna yeniden boyutlandırılmıştır. ESA ve ViT modelleri için piksel değerleri [0–1] aralığına normalize edilmiştir. EfficientNet-B1'de ise modelin kendi ön işleme rutini (önceden tanımlı normalizasyon) kullanılmıştır. Veri, %80 eğitim ve %20 test olarak ayrılmış; eğitim kümesinin %20'si doğrulama için ayrılarak nihai dağılım %64 eğitim, %16 doğrulama ve %20 test şeklinde düzenlenmiştir. Sınıf dengesi sağlamak amacıyla her sınıftan 5.000 görüntü seçilmiş ve eğitim–test ayrımları dengeli oluşturulmuştur.

Çalışma 1 kapsamında kullanılan sınıflandırma analizleri

Evrışimsel Sinir Ağı (ESA)

Özellik çıkarımı ile sınıflandırmayı uçtan uca birlikte öğrenen bir DÖ mimarisidir [81]. Mimari, ham görüntüden ayrımcı temsillerin otomatik olarak elde edilmesini sağlayan evrişim katmanları, doğrusal olmayan aktivasyon fonksiyonları (ör. Rectified Linear Unit (ReLU) / Gaussian Error Linear Unit (GeLU)), uzamsal özetleme için havuzlama (maksimum/ortalama) katmanları, gerektiğinde normalizasyon ve düzenleştirme bileşenlerinden oluşur. Son aşamada, tam bağlantılı katmanlar veya global ortalama havuzlama ile elde edilen temsil, hedef sınıflara yönelik bir sınıflandırıcıya (ör. softmax) aktarılır.

Evrışim işlemi, paylaşımlı ağırlıklara sahip bir veya birden fazla filtre kullanılarak, giriş görüntüsünün yerel alıcı alanları üzerinde kayan bir pencerede uygulanır. Filtre,

belirlenen adım ve kenar doldurma ayarlarıyla giriş üzerinde kaydırılarak özellik haritaları üretilir. Böylece model, benzer örüntüleri uzamsal konumdan kısmen bağımsız biçimde algılayabilir. Evrişimin matematiksel ifadesi Denklem (3.1)'de verilmiştir.

$$y = \varphi(w * x + b) \quad (3.1)$$

Burada w filtre ağırlıklarını, $*$ evrişim işlemini, b yanlılık terimini, x ilgili yerel bölgeyi, φ aktivasyon fonksiyonunu ve y ise ortaya çıkan özellik haritasını temsil eder. ESA'nın tüm parametreleri (w ve b) geri-yayılım ile tipik olarak çapraz entropi kaybı ve modern bir sezgisel (ör. Adam/SGD momentum) kullanılarak optimize edilir. Bu sayede ağ, ham veriden elle özellik tasarlamaya gerek kalmaksızın, göreve özgü ayırmacı temsilleri ve karar sınırlarını birlikte öğrenir.

Model, 3 evrişim–havuzlama bloğundan oluşmakta olup sırasıyla 8, 16 ve 32 filtre içeren, 3×3 çekirdek boyutuna sahip 'Conv2D' katmanları kullanılmıştır. Her evrişim katmanını 2×2 maksimum havuzlama izlemiştir. Özellik haritaları düzleştirildikten sonra 256 ve 128 nöronlu iki tam bağlantılı katman yer almaktadır. Aşırı uyumu sınırlandırmak amacıyla ağın ilgili katmanlarında 0,3 budama uygulanmıştır. Çıkış katmanı, çok sınıflı sınıflandırma için 'softmax' aktivasyonuna sahiptir [82].


Eğitim protokolü şu şekilde yapılandırılmıştır: yığın boyutu 32, öğrenme oranı 0,001, eniyileyci 'Adam', kayıp işlevi çok sınıflı 'çapraz entropi' ve epok sayısı 50 olarak belirlenmiştir. Bu kurgu, mimarinin hafif bir temel model olarak dengeli performans ve genellenebilir olmasını hedeflemektedir.

Evrişim tabanlı sınıflandırıcı olarak EfficientNet-B1

Tan ve Le (2019) tarafından önerilen EfficientNet ailesi, evrişimsel ağların ölçeklendirilmesinde derinlik, genişlik ve giriş çözünürlüğünü aynı anda dengeleyen bileşik ölçekleme ilkesine dayanmaktadır [83]. Temel yapı taşı olan EfficientNet-B0, hesaplama maliyeti ile doğruluk arasındaki denge ilişkisi eniyilemek üzere mimari arama ile elde edilmiş; B1–B7 varyantları ise B0'nın derinlik, genişlik ve çözünürlüğünün dengeli katsayılarla birlikte ölçeklendirilmesiyle türetilmiştir. Bu yaklaşım, yalnızca katman ekleyip ağı daha derin ya da daha geniş yapmak yerine üç boyutu birlikte ayarlayarak, benzer hesaplama bütçesinde daha yüksek doğruluk

sağlamayı amaçlar. ‘ImageNet’ üzerinde raporlanan sonuçlar, özellikle üst seviye varyantlarda yüksek doğruluğa işaret etmektedir.

Bu çalışma kapsamında, giriş görüntülerinin boyutu ve eğitim maliyeti dikkate alınarak EfficientNet-B1 tercih edilmiştir. Model, ‘ImageNet’ görüntü kümesi ile önceden eğitilmiş ağırlıklarla bir özellik çıkarıcı olarak kullanılmış, ara katmanlar dondurulmuş ve sınıflandırma katmanı yeniden eğitilmiştir. Çalışmada kullanılan EfficientNet-B1 model akışı Şekil 3.3’te verilmiştir. Uygulamada, $128 \times 128 \times 3$ boyutundaki girişler modele verildikten sonra ortalama havuzlama katmanı ile öznetelik vektörü elde edilmekte ve bunu 2048, 1024, 512, 256 ve 128 nöronlu yoğun katmanlar izlemektedir. Çıkış katmanı, çok sınıflı problem için ‘softmax’ aktivasyonu ile yapılandırılmıştır. Modelin kendi ön-işlem rutini esas alınmış, bu nedenle harici bir piksel normalizasyonu uygulanmamıştır. Eğitim hiperparametreleri, denklik için ESA taban çizgisi ile uyumlu seçilmiştir. Yığın boyutu 32, öğrenme oranı 0,001, eniyileyici Adam, kayıp işlevi çok sınıflı çapraz entropi ve epok sayısı 50’dir. Bu kurgu ile EfficientNet-B1, sınırlı çözünürlükteki girişlerle dahi dengeli bir doğruluk-maliyet profili sunarken, TL’nin veri gereksinimini azaltıcı avantajlarından yararlanılmasını sağlamaktadır.



Şekil 3.3 EfficientNet-B1 tabanlı yöntemsel akış

Dönüşüm tabanlı sınıflandırıcı olarak ViT

Geleneksel ESA, evrişim işlemleri sayesinde görüntülerdeki uzamsal hiyerarşileri yakalayabildikleri için sınıflandırma görevlerinde yaygın biçimde kullanılmaktadır. Bununla birlikte, yerel alıcı alanlara dayalı olmaları nedeniyle uzun menzilli bağımlılıkları modelleme kapasiteleri sınırlıdır. Bu sınırlamayı gidermek amacıyla, Dosovitskiy vd. (2021) tarafından önerilen ViT [14], evrişim yerine öz-dikkat (self-attention) mekanizmasını kullanarak görüntü genelinde küresel bağlamın

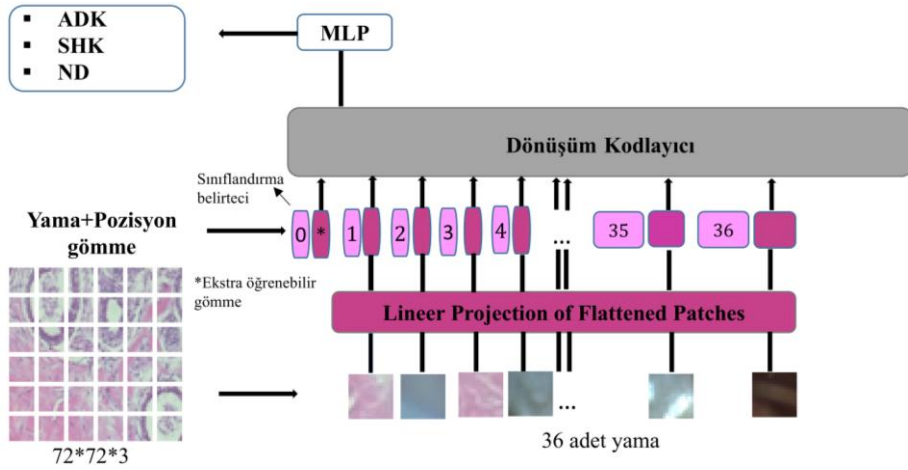
modellenmesini mümkün kılar. ViT, bir görüntüyü üst üste binmeyen yama dizisi olarak ele alır ve doğal dil işleme için tasarlanmış dönüşüm tabanlı mimari ile işler.

ViT, Vaswani vd. (2015) önerdiği standart dönüşüm kodlayıcı yapısını izler [84]. Evrişimle ham pikselleri işlemek yerine, görüntü sabit boyutlu yamalara bölünür. Bu yamalar düzleştirilerek doğrusal bir izdüşüm katmanından geçirilir ve yama gömüleri elde edilir. Biçimsel olarak, girdi görüntü $x \in \mathcal{R}^{H \times W \times C}$ olsun; burada H ve W sırasıyla yükseklik ve genişlik, C kanal sayısıdır. Görüntü, $P \times P$ boyutlu yamalara ayrılır ve toplam yama sayısı $N = HW/P^2$ olur. Her yama doğrusal bir gömme uzayına yansıtılarak bir gömme dizisi elde edilir. Başlangıç katmanı aşağıdaki gibi yazılabilir:

$$Z_0 = [X_1 E; X_2 E; \dots; X_n E] + E_{pos} \quad (3.2)$$

Burada E öğrenilebilir gömme matrisi, E_{pos} ise konumsal kodlamaları ifade eder. Dönüşüm yapıları permütasyon-değişmez olduğundan konumsal ilişkiler doğal olarak korunmaz. Bu nedenle konumsal kodlamalar, uzamsal bilginin saklanması sağlar.

Dönüşüm kodlayıcı L katmandan oluşur ve her katmanda etkin öğrenme ve temsil gücü için temel bileşenler bulunur. Çok başlı öz mekanizması, yamalar arası bağımlılıkları yakalayarak küresel bağlam ilişkilerini kurar. Bunu izleyen beslemeli ağ (Feed-Forward Network, iki katmanlı çok katmanlı algılayıcı), GELU [85] etkinleştirmesi ile karmaşık özellik temsillerinin öğrenilme kapasitesini artırır. Eğitim kararlılığı için katman normalizasyonu uygulanır, artık bağlantılar ise gradyan akışını dengede tutarak sönümlenen gradyan sorununu azaltır ve yakınsamayı hızlandırır. Bu çalışmada kullanılan ViT mimarisinin şematik gösterimi Şekil 3.4'te sunulmuştur.



Şekil 3.4 Rastgele bir sınıftan seçilen patoloji görüntüsüne ait ViT modeli iç yapısı (ADK: Adenokarsinom, SHK: Skumöz Hücreli Karsinom, ND: Normal Doku)

Her dönüşüm kodlayıcı katmanı, gömme dizisini öz-dikkat ile işler. Öz-dikkat aşağıdaki gibi tanımlanır:

$$Attention(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (3.3)$$

Denklem 3.3'te sorgular (Q), anahtarlar (K) ve değerler (V), giriş gömmelerinin doğrusal izdüşümleridir; d_k ise ölçekleme sabitidir. Son aşamada, giriş dizisine bir sınıflandırma belirteci (Class Token: CLS) eklenir ve bu belirtecin son katmandaki gömüsü, tam bağlantılı bir MLP sınıflandırıcı başlığı üzerinden çıktı üretmek için kullanılır [86].

Metot 1 kapsamında kullanılan açıklanabilir analiz

Bir AYZ yöntemi olarak LIME

Bu tez çalışmasında, eğitim ve test süreçlerinin tamamlanmasının ardından sınıflandırma kararlarının yerel düzeyde yorumlanabilmesi amacıyla LIME yöntemi kullanılmıştır. LIME, bir DÖ modelinin belirli bir örnek etrafındaki davranışını, küresel karmaşıklığına girmeden o örneğin yakın komşuluğunda kurulmuş basit ve yorumlanabilir bir vekil model ile yaklaşıklar. Model-agnostik yapısı sayesinde herhangi bir DÖ mimarisiyle birlikte çalışabilir ve literatürde temel bir açıklayıcı yaklaşım olarak yaygın biçimde tercih edilir [87]. Yöntemin çalışma ilkesi kısaca şu şekilde açıklanmaktadır: Açıklanmak istenen bir görüntü x alınır; görüntü, süper

piksel tabanlı bölütlemeyeyle anlamlı parçalara ayrılır ve bu parçalar rastgele kapatılıp-açılarak x 'in yakın çevresinde çok sayıda bozunmuş örnek üretilir. Hedef model f , bu örneklerin her biri için olasılık üretir. Bozunmuş örnekler, x 'e benzerlik derecelerini ifade eden bir yakınlık çekirdeği π_x ile ağırlıklandırılır ve bu ağırlıklı veri üzerinde doğrusal regresyon ya da karar ağacı gibi yorumlanabilir bir vekil model g uydurulur. Böylece g 'nin katsayıları, modelin x üzerinde hangi bölgelerden ve özelliklerden etkilendiğine ilişkin yerel bir açıklama sağlar. Bu süreçte LIME, özgün modelin ağırlıklarını güncellenememektedir. Sadece x 'in lokal komşuluğunda, f 'in davranışına en iyi uyan yorumlanabilir bir g üretir. LIME'in biçimsel ifadesi denklem 3.4'te verilmiştir:

$$Açıklama(x) = \underset{g \in G}{\operatorname{argmin}} L(f, g, \pi_x) + \Omega(g) \quad (3.4)$$

Burada x açıklanacak örneği, f asıl sınıflandırıcıyı, g yorumlanabilir vekil modeli, π_x x 'e göre yakınlığı tanımlayan ağırlıklandırma fonksiyonunu; $L(f, g, \pi_x)$ vekil modelin, hedef modelin x 'in komşuluğundaki çıktısını ne ölçüde doğru yaklaşıkladığını ölçen kaybı; $\Omega(g)$ ise açıklanabilirliği korumak için vekil modelin karmaşıklığını (ör. kullanılan özellik sayısı) cezalandıran düzenleme terimini ifade eder. Uygulamada, g 'nin karmaşıklığına ilişkin sınırlar çoğu zaman alan uzmanı tarafından belirlenmektedir.

Bu çalışmada LIME, test kümesinden doğru sınıflandırılan örneklerin yerel açıklamalarını üretmek için kullanılmıştır. Görseller, modele uygun olacak şekilde $1 \times 128 \times 128 \times 3$ tensör boyutuna yeniden ölçeklendirilmiştir. Her bir örnekte LIME'in ürettiği önem haritaları üzerinden, modelin kararında etkili olan bölgeler nitel olarak incelenmiştir. Böylece, sınıflandırma çıktıları yalnızca sayısal doğruluk değerleriyle değil, aynı zamanda görsel düzeyde hangi doku bölgelerinin karara katkı sunduğu gösterilerek raporlanmıştır. Yöntemin doğası gereği, üretilen açıklamaların yerel doğruluk taşıdığı bölütleme ve bozunma ayarlarının (ör. süperpiksel sayısı, örnekleme sayısı, çekirdek genişliği) açıklamaların ayrıntı düzeyini etkileyebileceği not edilmelidir [88].

3.2.1.2 Çalışma 2 kapsamında önerilen metot

Veri seti 1 ve 2 için kullanılan ön işlem basamakları

Çalışma 2’de kullanılan veri seti 1’in ön işlem adımlarının veri seti sağlayıcıları tarafından yeniden yapılandırıldığı Bölüm 3.1.1’de bahsedildi [74]. Bu veriden farklı olarak, meme kanseri görüntülerini içeren veri seti 2 üzerinde herhangi bir yapay artırma uygulanmamış ve tüm görüntüler özgün hâlleriyle korunmuş ve örnekleme düzeyini artırmak ile alt-bölgesel dokusal örüntüleri yakalayabilmek için yama tabanlı bir işleme adımı tercih edilmiştir. Bu üçlü ön işleme kurgusu, hem eğitilecek modellerin genelleme yeteneğini artırmayı hem de sınıflar arası örneklem dengesizliğinden doğabilecek yanlılıkları azaltmayı hedeflemiştir [75]. Bunun dışında görüntüler okunmuş, etiketlenmiş ve modele uygun giriş boyutuna dönüştürülmüştür. Bu kapsamda tüm görüntüler $128 \times 128 \times 3$ boyutuna yeniden ölçeklendirilmiş, piksel değerleri ise $[0-1]$ aralığına normalize edilmiştir. Veri ayrımı aşamasında sınıf dengesini korumak amacıyla 5 katlı tabakalı ayırım (stratified çapraz doğrulama) uygulanmıştır. Her yinelemede bir kat test kümesi olarak ayrılmış, kalan dört kat eğitim kümesini oluşturmuş ve eğitim kümesinin %20’si ayrıca doğrulama için kullanılmıştır. Böylece her katlamada her sınıftan eşit sayıda örnek içeren eğitim/doğrulama/test alt kümeleri elde edilmiştir. Eğitim süresince, epoklar boyunca eğitim ve doğrulama kümeleri üzerinde kayıp ve doğruluk değerleri izlenmiş ve tüm modeller aynı katlamalar üzerinden eğitilip değerlendirilerek kıyaslanabilirlik sağlanmıştır.

Görüntü sınıflandırma için modern birçok katmanlı algılayıcı: FNet

Dönüşüm tabanlı dikkat mekanizması, özellikle doğal dil işleme alanında önemli başarılar elde eden DÖ modellerinin temelini oluşturmuştur. İlk olarak Vaswani vd. tarafından ‘*Attention Is All You Need*’ çalışmasında tanıtılan bu mimari, önceki rekabetçi modellerdeki çeşitli sınırlamaları aşmak üzere geliştirilmiştir. Uzun ve bağımlılık içeren dizilerde küresel bağlamı verimli biçimde modelleyebilme, aynı zamanda paralel işlemeye elverişli olma özellikleriyle öne çıkmıştır [84]. Dikkat mekanizması, bir dizideki her ögenin diğer tüm öğelerle olan ilişkisini ağırlıklandırarak hesaplar ve böylece her ögenin katkısı, diğer öğelerin içeriğine bağlı olarak nicelenir.

Lee-Thorp vd. dönüşüm kodlayıcı katmanındaki görece karmaşık öz-dikkat alt-katmanının, belirli token karıştırma işlemleriyle sadeleştirilip sadeleştirilemeyeceğini incelemiştir [89]. Önce satır ve gizli boyutu ayrı ayrı karıştıran iki parametrelili doğrusal çarpım ile öz-dikkati ikame etmiş sonrasında bu doğrusal karıştırma şemasının umut verici sonuçları üzerine, daha hızlı ve yapısal doğrusal dönüşümleri değerlendirmişlerdir. Parametre içermeyen Fourier dönüşümünün uzun girişlerde son derece iyi ölçeklendiği gözlemlenmişlerdir. Elde edilen doğruluk, daha karmaşık doğrusal karıştırma yöntemleriyle karşılaştırılabilir bulunmuştur. Bu doğrultuda önerilen FNet, öz-dikkat yerine Fourier dönüşümünü kullanan bir kodlayıcı yapısıdır. FNet'in temel fikri, dönüşüm bloğundaki öz-dikkat alt-katmanını parametresiz iki boyutlu Ayrık Fourier Dönüşümü (AFD) alt-katmanı ile değiştirmektir. Uygulamada, gömme tensörü üzerinde iki ardışık bir boyutlu AFD uygulanır. İlki dizi boyutu boyunca, ikincisi gizli boyut boyunca. Fourier dönüşümü, bir sinyali frekans bileşenlerine ayıran matematiksel bir işlemdir. $\{x_n\}$ dizisine $n \in [0, N - 1]$ uygulanan AFD, aşağıdaki gibi tanımlanır:

$$X_k = \sum_{n=0}^{N-1} x_n e^{-\frac{2\pi}{N}nk}, 0 \leq k \leq N - 1 \quad (3.5)$$

Bu işlem matris biçiminde W ile gösterilen AFD matrisi aracılığıyla da yazılabilir. Birlik kökleri kullanılarak kurulan ve normalizasyon içeren bu matris denklem 3.6'da verilmiştir:


$$W_{nk} = (e^{-\frac{2\pi}{N}nk} / \sqrt{N}) \quad (3.6)$$

Doğrudan matris çarpımı $n, k = 0, \dots, N - 1$ karmaşıklığa sahiptir. Hızlı Fourier Dönüşümü ile hızlandırılmış uygulamalar ise n için $O(N^2)$ karmaşıklığa iner. Çalışmada, nispeten kısa diziler ve Tensor Processing Unit (TPU) benzeri donanımlarda doğrudan uygulamanın pratikte hızlı olabildiği raporlanmıştır. FNet'in kodlayıcı katmanı, Fourier alt-katmanını takiben standart beslemeli ağ, artık bağlantılar ve katman ölçekleme bileşenleriyle klasik dönüşüm blok yapısını korur. FNet katmanının özeti denklem 3.7'de verilmiştir:

$$y = R(F_{seq}(F_h(x))) \quad (3.7)$$

Burada F_h gizli boyut, F_{seq} dizi boyutu boyunca uygulanan birer boyutlu AFD'yi, $Re(\cdot)$ operatörü ise karmaşık çıktının gerçel kısmının alınmasını ifade eder. Her bloktan sonra MLP, artık bağlantı ve katman ölçekleme ile temsil gücü artırılır. FNet çalışmasında vurgulandığı üzere [89], gömme boyutunun ve blok sayısının artırılması ve daha uzun süre eğitim yapılmasıyla doğruluğun daha da yükseltilebildiği ve ayrıca daha büyük giriş görüntüleri ve farklı yama boyutlarıyla deney yapmanın sonuçları iyileştirebildiği gösterilmiştir. FNet, uzun girdilerde verimli ölçeklenmesi, öz-dikkat tabanlı dönüşümlere kıyasla belirgin hız kazanımı sunması ve rekabetçi doğruluk sağlaması sayesinde geniş ölçekli uygulamalara uygun bir alternatif olarak değerlendirilmektedir.

Tez çalışmasında kullanılan FNet mimarisinin hiper-parametreleri, doğruluk ile eğitim maliyeti arasında dengeli bir yapı elde etmek amacıyla öncül denemeler ve doğrulama kümesi performansı gözetilerek belirlenmiştir. Bu bağlamda; ağırlık azalımı 0.0001, yığın boyutu 128, epok sayısı 50, budama oranı 0.2, giriş görüntü boyutu 64×64 , yama boyutu 8×8 , yama sayısı 64, gömme boyutu 256, blok sayısı 4 olarak sabitlenmiştir. Blok sayısı, mimarinin derinliğini belirleyen bir hiper-parametredir ve yapılan deneylerde 4 blok, performans ile hesaplama maliyeti arasında uygun bir denge sunmuştur. Hiper-parametre seçimi, doğrulama öğrenme eğrilerinin izlenmesiyle yönlendirilmiş ve böylece aşırı uyum riskini sınırlarken sağlam bir genelleme elde etmede tutarlı bir yol izlenmiştir. Bu tez çalışmasında kullanılan FNet mimarisinin N kodlayıcı bloktan oluşan şematik gösterimi Şekil 3.5'te verilmiş olup, her kodlayıcı katmandaki öz-dikkat alt-katmanının Fourier alt katmanı ile değiştirilerek elde edildiği yapı açıkça görülmektedir.



Şekil 3.5 FNet mimarisinin iç blok yapısı


3.2.2 Veri seri 3, 4 ve 5'in sınıflandırmasında dönüşüm tabanlı açıklanabilirlik: Grad-CAM, AR, LRP temelli hibrit ısı haritalarının nedensel metriklerle değerlendirilmesi

Bu bölümde, Şekil 3.1'de özetlenen Metot 2 kapsamındaki çalışmaların yöntemsel akışı incelenmiştir. Bu çerçevede, maymun çiçeği hastalıklarını içeren Veri seti 3 ve veri seti 4 ile kulak zarı görüntülerinden oluşan veri seti 5 üzerinde uygulanan ön işleme adımları, kullanılan sınıflandırma algoritmaları ve AYZ yöntemleri sistematik biçimde sunulmuştur. Metot 2 kapsamında her iki çalışma için ortak kullanılan ön işlemler, ViT ve DeiT sınıflandırma modeli, t-dağılımlı Stokastik Komşuluk Gömme (t-distributed Stochastic Neighbor Embedding:t-SNE) ve Üiform Çeşitlilik Yaklaşırması ve Yansıtması (Uniform Manifold Approximation ve Projection: UMAP) özellik görselleştirmeleri, açıklanabilir metotlar ve nedensel metriklerin kuramsal arka planı ve uygulama ayrıntıları çalışma 3 içinde verilmiştir. Çalışma 4'te ise bu yöntemlerin kullanımına yalnızca kısaca atıf yapılacaktır. Bu bağlamda, çalışma 3'te ön işleme, DÖ modelleri ve AYZ metotları, Temel Bileşen Analizi (TBA) incelenmiş olup çalışma 4'te Kanonik Korelasyon Analizine (KKA) odaklanılmıştır.

3.2.2.1 Çalışma 3 kapsamında önerilen metot

Bu bölümde, Şekil 3.6'da sunulan yöntemsel akış izlenerek çalışma kapsamındaki adımlar sistematik biçimde aktarılmaktadır. İlk olarak, veri kümelerine uygulanan ön

işlem adımları detaylandırılmıştır. İkinci aşamada, sınıflandırma deney düzenekleri ve elde edilen özellik temsillerine ilişkin görsel çıktılar sunulmuştur. Bu bağlamda, sınıflandırma protokollerini esas alarak modellerde aşırı uyumu önlemek amacıyla uygulanan başlıca stratejiler ele alınmıştır. Bunu izleyen kısımda, açıklanabilirlik metotları olarak Grad-CAM, LRP ve AR yöntemleri incelenmiştir. Devamında, önerilen hibrit yaklaşımın bileşenleri matematiksel gösterimle formüle edilmiştir. Son olarak, açıklamaların güvenilirliğini ve nedensel bağımlı olarak nicel olarak değerlendirmek amacıyla kullanılan metrikler ve hesaplama adımları incelenmiştir.



Şekil 3.6 Maymun çiçeği hastalığına ait yöntemsel çalışma akışının genel görünümü

Veri seti 3,4 ve 5 için kullanılan ön işlem adımları





Bu çalışmada veri setlerindeki sınırlı örnek sayısının aşırı uyuma yol açmasını azaltmak amacıyla bir dizi önlem uygulanmıştır. Veriler %80 eğitim ve %20 test olacak şekilde ayrılmış olup eğitim kümesinin %10'u doğrulama için ayrılarak nihai dağılım yaklaşık %72 eğitim, %8 doğrulama ve %20 test biçiminde düzenlenmiştir. Tüm görüntüler 224×224 piksel çözünürlüğe yeniden ölçeklendirilmiştir. Ayrıca, ön işlem aşamasında piksel değerleri, önceden eğitilmiş modellerle uyumu sağlamak üzere 'ImageNet' veri kümesinden türetilen kanal-başına ortalama ve standart sapma değerleri (ortalama: [0.485, 0.456, 0.406]; standart sapma: [0.229, 0.224, 0.225])

kullanılarak normalize edilmiştir. Bu işlem, her bir kanal için piksel değerinden ilgili ortalamanın çıkarılıp standart sapmaya bölünmesiyle gerçekleştirilmiştir. Böylece eğitim sırasında sayısal kararlılık ve yakınsama davranışı iyileştirilmiştir.

Metot 2 kapsamında kullanılan model genellenabilirliğini artırmaya yönelik eğitim stratejileri

DeiT ve ViT modellerinin başarımını artırmak amacıyla, eğitim sürecinde bir dizi veri artırma stratejisi ve düzenleme tekniği uygulanmıştır. Tablo 3.4’de, kullanılan veri artırma yöntemlerine ilişkin örnek görseller ve Tablo 3.5’te de kullanılan artırıcılar ile regularizasyon ve optimizasyona yönelik uygulanan hiper-parametre detayları sunulmaktadır. Bu yöntemler, özgün mimaride anlamlı bir değişiklik gerektirmeksizin, modellerin genelleme kapasitesini yükseltmeyi ve aşırı uyumu önlemeyi hedefler. Hiper-parametrelerin seçimi, literatürde yerleşik uygulamalar ile sınırlı kapsamlı pilot deneylerden elde edilen bulgulara dayandırılmıştır. Bu pilot aşamada dar kapsamlı bir ızgara araması (grid search) ve eğitim verisinin bir alt kümesi üzerinde doğrulama taramaları yürütülmüştür.

Tablo 3.4 ViT ve DeiT modellerinin eğitim aşamasında aşırı uyumu önlemeye yönelik kullanılan veri artırım örnekleri

Sınıf	Metotlar								
	Original	Horizontal Flip	Vertical Flip	Rotation (30°)	Color Jitter	Resized Crop	Affine	Perspective	Gaussian Blur
Normal									
Kızamık									
Su çiçeği									
Maymun çiçeği									

Tablo 3.5 ViT ve DeiT modellerinin eğitim aşamasında kullanılan aşırı uyumu önlemeye yönelik stratejiler


Metotlar	Hiper-parametre detayları	Nümerik değerler
Regularizasyon ve optimizasyon	Label smoothing	0.1
	Early stopping	patience:10
	Cut mix/Mix up	random choice
	Horizontal flip	probability:0.5
	Vertical flip	
	Rotation	degrees:30
		brightness:0.2
	Color jitter	contrast:0.2
		saturation:0.2
		hue:0.1
Veri artırımı	Resized crop	scale: 0.8–1.0
		translate: 10%
	Affine	degrees:10
		scale:0.8-1.2
		distortion scale:0.5
	Perspective	probability:0.5
		interpolation:3
	Gaussian blur	kernel size:3

Metot 2 kapsamında kullanılan dönüşüm tabanlı sınıflandırıcı olarak ViT ve DeiT

Bu tez çalışmasında ViT ve DeiT modelleri ikili ve çoklu sınıflandırma problemleri için ince ayar ile uyarlanmıştır. ViT'in kuramsal temeli Bölüm 3.2.1.1'de sunulduğundan, burada ViT'in maymun çiçeği ve kulak zarı verisi üzerindeki uygulama ayrıntıları ele alınmıştır. Ardından, DeiT mimarisinin temel özellikleri ve çalışma kapsamındaki kullanım biçimi açıklanmıştır. Ayrıca bilinmelidir ki ince ayar sürecinde, her iki model de ImageNet-1k üzerinde önceden eğitilmiş ağırlıklarla başlatılmıştır [90].

Kullanılan ViT yapılandırması [14], üst üste binmeyen yamalara ayrılmış girişten doğrusal iz düşünüm ile elde edilen yama gömmeleri, öğrenilebilir sınıflandırma belirteci, eklemeli konumsal kodlamalar ve L katmanlı dönüşüm kodlayıcı yığını bileşenlerinden oluşmaktadır ve bu bağlamda şematik gösterim Şekil 3.7'de verilmiştir. DeiT, Facebook AI tarafından tanıtılan ve ViT mimarisini temel alan, ancak özellikle daha küçük veri kümeleri ve kaynak kısıtlı ortamlarda eğitim

verimliliğini artıracak biçimde tasarlanmış bir yaklaşımdır [91]. ViT, etkin bir biçimde eğitilebilmek için büyük ölçekli veriye ve yüksek hesaplama gücüne gereksinim duyarken, DeiT bilgi damıtma stratejisi kullanır. Daha büyük bir öğretmen modelin çıktılarından yararlanarak daha küçük bir öğrenci modelin eğitilmesini sağlar. Bu yöntem, yakınsamayı hızlandırır ve genelleme yeteneğini iyileştirir. Böylece DeiT, özellikle eğitim verisinin sınırlı olduğu durumlarda geniş bir görüntü sınıflandırma yelpazesi için daha pratik bir çözüm sunar.



Şekil 3.7 Veri seti 3'ten tedarik edilen maymun çiçeği hastalığı görüntüsünün ViT modelindeki gösterimi (MSID: Monkeypox Skin Image Dataset, MSLD: Monkeypox Skin Lesion Dataset)

Mimari açıdan DeiT, ViT ile büyük ölçüde paralel olup, görüntü yamaları üzerinde küresel bağımlılıkları modellemek için öz-dikkat mekanizmasını kullanır. Bununla birlikte, DeiT bu yaklaşımı çok başlı öz-dikkat katmanının üzerinde konumlanan bir İleri Beslemeli Ağ (Feed Forward Network: FFN) ile güçlendirir. FFN, arada GELU etkinleştirilmesi bulunan iki doğrusal katmandan oluşur ve modelin daha karmaşık özellik temsillerini yakalamasına olanak tanır. Ayrıca DeiT, dönüştürücülerin doğası

gereği permütasyon-değişmez yapısına karşın yamaların görelî konum bilgisini koruyabilmek için konum temelli kodlamalar içerir. Böylece uzamsal yapı ve düzenin modele yansıtılması güvence altına alınır.

Metot 2 kapsamında çıkarılan görüntü özelliklerinin t-SNE ve UMAP ile görsel incelenmesi

t-SNE ve UMAP, yüksek boyutlu veri kümelerinin görselleştirilmesinde yaygın biçimde kullanılan başlıca boyut indirgeme teknikleridir. t-SNE, yüksek ve düşük boyutlu uzaylarda tanımlanan olasılık dağılımları arasındaki ‘Kullback–Leibler sapmasını’ eniyileyerek örnekler arasındaki yerel benzerlikleri korumaktadır. Bu sayede karmaşık, doğrusal olmayan örüntüleri yakalamada etkilidir [92]. Buna karşılık, UMAP grafik tabanlı bir yöntem olup topolojik yapının korunmasına ve belirli geometrik varsayımlara dayanır. Özellikle büyük veri kümeleri için daha hızlı ve ölçeklenebilir boyut indirgeme sağlar [93].

Bu tez çalışmada ViT ve DeiT modelleri çok sınıflı sınıflandırma (çalışma 3 ve 4) görevleri için ince ayar ile uyarlanmıştır. Eğitimin ardından, sınıflandırma başlığı çıkarılarak her bir modelin sondan bir önceki katmanından özellik temsilleri elde edilmiştir. Bu temsiller, öğrenilen gömülerin ayırt edicilik niteliğini değerlendirmek amacıyla t-SNE ve UMAP kullanılarak iki boyutlu uzaya yansıtılmıştır.

Metot 2 kapsamında kullanılan AYZ tabanlı analizler

AYZ, YZ sistemlerinin şeffaflığını ve yorumlanabilirliğini artırmayı amaçlamaktadır. Model çıktıları için anlaşılabilir açıklamalar üreterek güvenilirliği güçlendirir. Bu yaklaşım, özellikle sağlık gibi güvenlik ve etik uygulama açısından YZ destekli kararların açık ve gerekçeli olmasının zorunlu olduğu kritik alanlarda önem taşır [94]. Tez kapsamında, modelin karar mekanizmalarının görselleştirilmesi amacıyla AYZ yöntemi olarak Grad-CAM, AR ve LRP uygulanmıştır.

Grad-CAM

Grad-CAM, başlangıçta ESA için geliştirilmiş gradyan güdümlü bir yerelleştirme tekniğidir [95]. Yöntem, sınıfa özgü çıktının belirli bir evrişim katmanındaki etkileşimlere (özellik haritası) göre türevlerini kullanarak, kestirimi belirgin biçimde etkileyen görüntü bölgelerini vurgulayan kaba bir yerelleştirme haritası üretmektedir. Biçimsel olarak, y^c sınıf c için softmax öncesi skoru, A^k ise son evrişim katmanından elde edilen k_{th} özellik haritasını göstermektedir. Nöron önem ağırlıkları α_k^c , uzamsal boyutlar boyunca gradyanların global ortalaması alınarak (global average pooling) Denklem 3.8'deki gibi hesaplanmıştır:

$$\alpha_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{ij}^k} \quad (3.8)$$

Burada Z , uzamsal konumların toplam sayısını ifade eder. Ardından, sınıfa özgü son yerelleştirme haritası, etkileşim haritalarının bu ağırlıklarla toplanması ve yalnızca y^c üzerinde olumlu etki yapan bileşenleri korumak üzere ReLU uygulanmasıyla Denklem 3.9' da gösterildiği gibi elde edilmektedir:

$$L_{Grad-CAM}^c = ReLU \left(\sum_k \alpha_k^c A^k \right) \quad (3.9)$$

Bu yaklaşım daha sonra ViT mimarilerine uyarlanmaktadır. ESA'ların aksine ViT'ler, görüntüyü üst üste binmeyen yamalara böler ve bu yamaları bir token olarak gömmektedirler. Bu yamalar konumsal kodlamalarla zenginleştirilir ve öz-dikkat katmanlarıyla işlenirler [96]. Hedef sınıf c için, y^c skorunun yama gömmeleri Z_i (her yama için i . token) açısından gradyanı hesaplanır. Her yama için önem ağırlığı α_i^c , gömme boyutları boyunca gradyanların ortalaması alınarak Denklem 3.10'da verildiği gibi elde edilir:

$$\alpha_i^c = \frac{1}{D} \sum_{j=1} \frac{\partial y^c}{\partial Z_{i,j}} \quad (3.10)$$

,burada D gömme boyutunu ifade eder. Sınıfa özgü yerelleştirme vektörü, bu yama önem ağırlıklarına ReLU uygulanarak Denklem 3.11'deki gibi tanımlanmaktadır:

$$L_{ViT-GradCAM}^c = ReLU(\alpha_1^c, \alpha_2^c, \dots, \alpha_N^c) \quad (3.11)$$

,burada N toplam yama sayısıdır. ViT'ler ESA'lardaki gibi doğrudan uzamsal özellik haritaları üretmediklerinden, elde edilen önem skorları önce $\sqrt{Nx}\sqrt{N}$ ızgaraya yeniden şekillendirilir, ardından orijinal görüntü boyutlarına (H, W) çift doğrusal enterpolasyon ile Denklem 3.12'deki gibi ölçeklenmektedir:

$$L_{ViT-GradCAM}^c = Interp(Reshape(L_{ViT-GradCAM}^c, \sqrt{Nx}\sqrt{N}), H, W) \quad (3.12)$$

Bu uyarlama, yamalara dayalı dönüştürücü temsillerinden sınıfa özgü uzamsal önem haritaları türeterek ViT kararlarının görsel olarak yorumlanabilmesini sağlamaktadır.

LRP

LRP, DÖ modellerinin karar verme süreçlerini açıklamak amacıyla geliştirilen, gradyan tabanlı bir açıklanabilirlik yöntemidir [97]. Bu yaklaşım, modelin çıktı katmanından giriş özelliklerine doğru önem değerlerini geriye yayarak modelin tahminine hangi girdilerin ne ölçüde katkı sunduğunu nicel olarak ortaya koyar. LRP'nin temel prensibi, belirli bir girdi x için modelin çıktı tahminini $f(x)$, her bir giriş özelliğinin katkı paylarına ayırmak ve bu katkıların toplamının çıktı skoruna eşit olmasını sağlamaktır. Bu ilke Denklem 3.13'te verilmiştir:

$$f(x) = \sum_i R_i \quad (3.13)$$

Burada R_i , her bir giriş özelliğinin önem skorunu ifade etmektedir. ViT bağlamında LRP, özellikle öz-dikkat mekanizmalarını analiz etmede etkilidir. Öyle ki bu

mekanizmalar, görüntü yamaları arasındaki küresel bağımlılıkları yakalamaktadırlar. Belirli bir hedef sınıf c için, önem değerlerinin geriye yayılımı çıktı logit'i (olasılık oranının logaritması) y^c 'den başlar ve korunum ilkesine bağlı kalarak katmanlar arasında dağıtılır. Ağırlıkları W ve aktivasyonları a olan doğrusal bir katman için, bir önceki katmandaki j nöronunun önemi R_j Denklem 3.14'te gösterildiği şekilde hesaplanmaktadır:

$$R_j = \sum_k \frac{a_j W_{jk}}{\sum_{j'} a_{j'} W_{j',k}} R_k \quad (3.14)$$

,burada R_k mevcut katmandaki k nöronunun önemini temsil eder ve böylece katmanlar arasında toplam önemin korunumu sağlanır.

ViT modellerinde LRP, öz-dikkat haritalarının küresel bağımlılıklarını inceleyecek biçimde uyarlanmıştır. Son katman LRP yaklaşımında, önem değerleri modelin son öz-dikkat katmanından elde edilen dikkat haritaları (A) ve gradyanlar (G) kullanılarak hesaplanır. Her bir yama için önem değeri R , Denklem 3.15'deki şekilde tanımlanmaktadır:

$$R = \frac{1}{H} \sum_{h=1}^H \max(G_h \odot A_h, 0) \quad (3.15)$$

,burada H dikkat başı (attention head) sayısını; G_h ve A_h sırasıyla h . baş için gradyan ve dikkat haritasını; $\odot$ ise eleman bazlı çarpımı ifade etmektedir. $\max(\cdot, 0)$ işlemi yalnızca pozitif katkıların korunmasını sağlar. Elde edilen önem skorları tüm başlar boyunca ortalaması alınarak birleştirilir ve yalnızca görüntü yamalarına odaklanmak için CLS token hariç tutulur ($R_{patches} = R[1:]$). Bu yöntem, modelin tahmini için en kritik görüntü bölgelerini vurgulayan sınıfa özgü bir ısı haritası üretmektedir [96].

AR

AR, dönüşüm modellerinde bilginin katmanlar boyunca nasıl yayıldığını nicel olarak ölçmeye yönelik bir tekniktir. Böylece dikkat mekanizmalarının girdiyi ağ genelinde nasıl dağıttığına ilişkin iç görüler sunmaktadır [98]. L katmanlı bir dönüşüm için AR,

dikkat ağırlıklarını yinelemeli biçimde biriktirerek, giriş belirteçlerinin sonraki katmanlara birikimli katkısını değerlendirir. l_i katmanı ve $j < i$ olmak üzere daha erken bir l_j katmanı verildiğinde, l_i için birikimli AR'yi $\tilde{A}(l_i)$ aşağıdaki gibi tanımlanmaktadır:

$$\tilde{A}(l_i) = \begin{cases} A(l_i)\tilde{A}(l_{i-1}), & \text{if } i > j \\ A(l_i), & \text{if } i = j \end{cases} \quad (3.16)$$

,burada $A(l)$, l . katmana ait ham dikkat matrisini; $\tilde{A}(l)$ ise birikimli AR matrisini ifade eder. Bu formülasyon, dikkat ağırlıklarının katmanlar boyunca geriye doğru aktarılmasını güvence altına alır ve bilgi akışının sistematik biçimde analiz edilmesini sağlar. $j = 0$ seçildiğinde her bir giriş belirtecinin modelin son gösterimindeki etkisi ölçülebilmektedir. Böylelikle girişe ilişkin dikkat etkili biçimde yakalanır. Özetle AR, katmanlar arası dikkati birleştirerek sınıfa özgü görsel açıklamalar üretir; bilgi akışını görselleştirip sınıflandırmayı etkileyen kritik görüntü bölgelerini öne çıkararak modelin açıklanabilirlik ve güvenilirliğini artırır.

TBA tabanlı hibrit açıklanabilir ısı haritalarının oluşturulması

Bu tez çalışmasında, 2 farklı AYZ yöntemiyle üretilen ısı haritalarının birleştirilmesi için TBA kullanılmaktadır. TBA, yüksek boyutlu verideki değişkenliği en iyi yakalayan bileşenleri ortaya çıkaran bir boyut indirgeme tekniğidir [99].

Öncelikle, Grad-CAM ısı haritalarında kimi zaman lezyon bölgesi dışının daha yüksek, gerçek lezyon bölgelerinin ise daha düşük yoğunlukla vurgulandığı gözlemlendiğinden, histogram analizi uygulanarak ilgisiz sınır bölgeleri arka plana atanır. Lezyonu daha belirgin kılmak ve ilişkisiz alanları elemek için bağlı bileşenler fonksiyonu kullanılır. Ardından 2 ısı haritasının her bir pikseline karşılık gelen yoğunluklar piksel düzeyinde birleştirilerek iki boyutlu bir öznitelik vektörü Denklem 3.17 esas alınarak oluşturulur:

$$x_i = \begin{bmatrix} h_{1,i} \\ h_{2,i} \end{bmatrix} \quad (3.17)$$

Burada $h_{1,i}$ ve $h_{2,i}$ i. piksel için birinci ve ikinci ısı haritasının yoğunluk değerleridir. TBA'nın değişkenliği yansıtmasına, merkezi eğilimden etkilenmemesine dikkat etmek için takip eden denklemde gösterildiği gibi önce ortalama çıkarma yapılır:

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (3.18)$$

,daha sonra iki ısı haritası arasındaki ilişkileri yakalamak amacıyla kovaryans matrisi Denklem 3.19'daki gibi hesaplanır:

$$C = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)(x_i - \mu)^T \quad (3.19)$$

Bunu takiben öz değer ayrışımı gerçekleştirilmektedir ($Cv = \lambda v$). En büyük öz değere karşılık gelen öz vektör v_1 , birinci ana bileşeni temsil eder ve veri tek boyuta şu şekilde yansıtılmaktadır:

$$y_i = v_1^T (x_i - \mu) \quad (3.20)$$

Bu işlem, her iki ısı haritasındaki en bilgilendirici ortak değişimi tek bir hibrit gösterimde bir araya getirir. Son aşamada, görselleştirme tutarlılığı ve farklı veri kümeleri arasında kıyaslanabilirlik sağlamak için normalizasyon uygulanmaktadır. Hibrit ısı haritasının değerleri $[0,1]$ aralığına ölçeklenir. Böylece 2 AYZ yönteminden gelen açıklayıcı bilgi entegre edilerek daha açıklanabilir ve kapsamlı bir temsil elde edilir.

Metot 2 kapsamında kullanılan AYZ tabanlı nedensel metrikler

MÖ modelleri karmaşıktıkça, bu modellerin kararlarını anlamlandırmak önemli bir araştırma odağı hâline gelmiştir. Şeffaflık ve güveni sağlamak amacıyla, AYZ teknikleri açıklanabilirliği ölçmek için doğruluğa bağlılık, sağlamlık ve karmaşıklık gibi ölçütlerden yararlanılmaktadır [100], [101]. Doğruluğa bağlılık ölçütleri, sunulan açıklamaların modelin altında yatan akıl yürütmeyi ne ölçüde yansıttığını

değerlendirir. Uygulamada yaygın olarak kullanılan iki ölçüt, AYZ yöntemlerinin vurguladığı özneliliklerin önemini test eden ‘silme ve ekleme’ puanlarıdır. Silme metriği, açıklamanın en belirgin olarak işaretlediği öznelilikler görüntüden çıkarıldığında model performansındaki düşüşü nicelerken; ekleme metriği, bu öznelilikler kademeli olarak geri eklendikçe model performansındaki artışı ölçer [102]. Bu ölçütler, ısı haritalarından türetilen önem skorlarına göre piksellerin kademeli olarak kaldırılıp geri getirilmesi sırasında model güvenindeki değişimi izleyen nedensel bir değerlendirme çerçevesi içinde hesaplanmaktadır.

Çalışma 3 ve 4 kapsamında kullanılan model tahminlerinin görüntünün en kritik bölgelerine ne ölçüde bağımlı olduğunu belirlemek için silme ve ekleme metrikleri analiz edilmiştir. Ön işlem olarak, görüntüler 224×224 çözünürlüğe yeniden ölçeklendirilir; aynı boyutta ısı haritaları üretilir ve $[0,1]$ aralığına normalize edilir. Modelin tahmin fonksiyonu $f(\cdot)$, bir görüntüyü girdi olarak alır ve çıktı olarak sınıf olasılıklarını (softmax) üretir. Silme metriği, ısı haritasına göre en önemli pikselleri kademeli biçimde kaldırıp model güvenindeki azalmayı ölçerek çalışır. Önem skorlarına göre azalan sırada dizilmiş piksel kümesi S_d ile, en üst $\%t$ pikselleri dışlayan ikili maske $M_d(t)$ tanımlansın. Normalize edilmiş giriş görüntüsü $\bar{I}$ ve eleman düzeyinde çarpımı gösteren $\bar{I} \odot$ notasyonu ile silme eğrisi izleyen denklemde verilmektedir:

$$D(t) = f(\bar{I} \odot M_d(t)) \quad (3.21)$$

Her adımda değiştirilen görüntü $\bar{I} \odot M_d(t)$ modele verilir ve $f(\bar{I} \odot M_d(t))$ güven skoru hesaplanır. Böylece, en kritik pikseller kademeli olarak kaldırıldıkça model güvenindeki düşüşü gösteren bir eğri elde edilir. Eğrinin altında kalan alan (AUC), modelin bu bölgelerden ne ölçüde beslendiğinin bir ölçüsüdür. Eğrinin hızlı ve belirgin biçimde düşmesi, kaldırılan piksellere güçlü bir bağımlılığa işaret eder. Buna karşılık ekleme metriği, en önemli pikseller görüntüye kademeli olarak geri eklendikçe model güvenindeki artışı ölçer. Ön işleme adımları silme metriği ile aynıdır. Önem skorlarına göre azalan sırada dizilmiş küme S_i ve en üst $\%t$ pikselleri geri ekleyen ikili maske $M_i(t)$ kullanılır. Arka plan bölgelerine yumuşak bir geçiş

sağlamak için ‘Gauss bulanıklaştırma’ uygulanır. Ekleme eğrisi Denklem 3.22’de tanımlanmaktadır:

$$I(t) = f(\bar{I} \odot M_i(t)) \quad (3.22)$$

Her adımda $(\bar{I} \odot M_i(t))$ modele verilerek $f(\bar{I} \odot M_i(t))$ hesaplanır ve kritik pikseller kademeli olarak geri getirildikçe model güvenindeki artışı gösteren bir eğri elde edilir. AUC, bu belirgin bölgelerin varlığına modelin duyarlılığını niceler: Eğrinin hızlı yükselmesi, söz konusu özniteliklerin modelin öngörü performansı açısından yüksek önem taşıdığını göstermektedir.

3.2.2.1 Çalışma 4 kapsamında önerilen metot

Bu bölümde kulak zarı görüntülerini içeren çalışma 4 incelenmiştir. Bölüm 3.2.1’de ayrıntılandırıldığı üzere, izlenen yöntem büyük ölçüde Çalışma 3 ile örtüştüğünden önerilen stratejiler önceki bölümlerde sunulmuş olup burada yinelenmemiştir. Çalışma 3’ten farklı olarak bu bölümde hibrit ısı haritalarının üretimi için KKA yaklaşımı benimsenmiş ve yalnızca KKA temelli analize odaklanmıştır.

KKA tabanlı hibrit açıklama ısı haritalarının sentezi

KKA, iki veya çok değişkenli rastgele değişken arasında en yüksek bağlantılı doğrusal izdüşümleri belirleyen istatistiksel bir tekniktir [103]. $X \in R^{n \times p}$ ve $Y \in R^{n \times q}$ verildiğinde, KKA; $\{a_k\} \in R^p$ ve $\{b_k\} \in R^q$ projeksiyon vektörlerini bulmaktadır. Böylece kanonik değişkenler $U_k = a_k^T X$ ve $V_k = b_k^T Y$ en yüksek bağlantıya sahip olacak şekilde takip eden denklemden yola çıkılarak elde edilmektedir:

$$(a_k, b_k) = \arg \max_{a,b} \text{corr}(a^T X, b^T Y) \quad (3.23)$$

Aşağıda verilen denklemdeki ortogonalite (diklik) kısıtları altında:

$$\text{cov}(a^T X, a_j^T X) = 0, \text{ cov}(b^T Y, b_j^T Y) = 0, \forall j < k \quad (3.24)$$

Bu kısıtlar, her yeni kanonik değişken çiftinin $\min(p, q)$ çifte kadar, kendisinden önceki tüm çiftlerden bağımsız olmasını garanti etmektedir.

Bu çalışmada KKA, iki açıklanabilir yöntem arasındaki ortak belirgin bilgiyi çıkartarak hibrit ısı haritaları üretmek için kullanılmıştır. Bunlar Grad-CAM-LRP, Grad-CAM-AR ve LRP-AR çiftleridir. Boyutu $h \times w$ olan her ısı haritası önce 224×224 boyutuna yeniden örneklenmiş, gerekiyorsa gri-düzeye dönüştürülmüş ve ölçekleme ile $[0,1]$ aralığına normalize edilmiştir. Ardından iki normalize ısı haritası vektörü düzleştirilerek sırasıyla X ve Y matrislerinin sütunları halinde (eşleşmiş örnekler olarak) düzenlenmiştir. KKA uygulanarak en güçlü ortak sinyali yakalayan ilk kanonik değişken çifti $U_1 = a_1^T X$ ve $V_1 = b_1^T Y$ elde edilir. Bunlar $[0,1]$ aralığına normalize edildikten sonra element düzeyinde çarpım ile Denklem 3.25'teki gibi birleştirilir:

$$z = \text{normalize}(U_1) \odot \text{normalize}(V_1) \quad (3.25)$$

Son olarak z , 224×224 uzamsal harita biçimine geri şekillendirilerek hibrit ısı haritası oluşturulur. Bu füzyon süreci, metriklere göre en iyi silme ekleme sonucu veren iki yöntemin birlikte vurguladığı özellikleri koruyarak hem anlamsal soyutlamayı hem de ince ölçekli ayrıntıyı birleştiren bir hibrit ısı haritası üretmektedir. Böylece görsel açıklamaların sağlamlığı güçlendirilmektedir.

4. BULGULAR VE TARTIŞMA







Bu tez çalışmasında medikal görüntülerin analizinde AYZ modellerinin geliştirilmesi amaçlanmıştır. İzlenen yöntemler sonucunda elde edilen sonuçlar değerlendirilmiş ve tartışmalar bu bölümde ele alınmıştır.

4.1 Akciğer, Kolon Ve Meme Kanserine İlişkin Veri Seti 1 ve 2'nin Analizine Yönelik Bulgular

4.1.1 Evrişim ve dönüşüm tabanlı modellerin karşılaştırılmasına ait bulgular

Tablo 4.1'de veri seti 1'in akciğer kanseri görüntüleri için 50 epok boyunca yürütülen eğitim ve doğrulama süreçlerine ait doğruluk ve kayıp eğrileri ile test kümelerinde elde edilen karmaşıklık matrisleri sunulmaktadır. Bu grafikler incelendiğinde, tüm mimarilerde eğitim ve doğrulama eğrilerinin birbirine yakın seyrettiği, aşırı öğrenme eğiliminin düşük olduğu ve modellerin genel olarak dengeli bir öğrenme süreci izlediği gözlenmektedir. Bununla birlikte, epok ilerledikçe ViT ve EfficientNet-B1 mimarilerinde doğruluk eğrilerinin daha yüksek seviyelere ulaştığı, ESA mimarisinde ise doğruluk değerlerinin belirgin biçimde daha düşük kaldığı görülmektedir.

Tablo 4.1 ESA, ViT ve EfficientNet-B1 DÖ mimarilerine ilişkin eğitim/doğrulama kümelerine ait epoklar boyunca doğruluk-kayıp değerleri ile test kümesi karmaşıklık matrisleri (ADK: Adenokarsinom, SHK: Skumaöz Hücreli Karsinom, ND: Normal Doku)

	Eğitim/doğrulama doğruluğu	Eğitim/doğrulama kaybı	Karmaşıklık matrisi																
ESA			<table border="1"> <tr> <td>ADK</td><td>636</td><td>355</td><td>9</td></tr> <tr> <td>SHK</td><td>4</td><td>996</td><td>0</td></tr> <tr> <td>ND</td><td>0</td><td>0</td><td>1000</td></tr> <tr> <td></td><td>ADK</td><td>SHK</td><td>ND</td></tr> </table>	ADK	636	355	9	SHK	4	996	0	ND	0	0	1000		ADK	SHK	ND
ADK	636	355	9																
SHK	4	996	0																
ND	0	0	1000																
	ADK	SHK	ND																
ViT			<table border="1"> <tr> <td>ADK</td><td>985</td><td>12</td><td>2</td></tr> <tr> <td>SHK</td><td>33</td><td>967</td><td>0</td></tr> <tr> <td>ND</td><td>1</td><td>0</td><td>999</td></tr> <tr> <td></td><td>ADK</td><td>SHK</td><td>ND</td></tr> </table>	ADK	985	12	2	SHK	33	967	0	ND	1	0	999		ADK	SHK	ND
ADK	985	12	2																
SHK	33	967	0																
ND	1	0	999																
	ADK	SHK	ND																
EfficientNet-B1			<table border="1"> <tr> <td>ADK</td><td>915</td><td>83</td><td>2</td></tr> <tr> <td>SHK</td><td>1</td><td>999</td><td>0</td></tr> <tr> <td>ND</td><td>0</td><td>5</td><td>995</td></tr> <tr> <td></td><td>ADK</td><td>SHK</td><td>ND</td></tr> </table>	ADK	915	83	2	SHK	1	999	0	ND	0	5	995		ADK	SHK	ND
ADK	915	83	2																
SHK	1	999	0																
ND	0	5	995																
	ADK	SHK	ND																

Karmaşıklık matrislerinden hesaplanan performans metrikleri Tablo 4.2’de özetlenmiştir. ESA mimarisi %87.93 ortalama doğruluk ile en düşük performansı göstermiştir. Özellikle ADK sınıfında kesinlik değeri yüksek (0.99) olmasına rağmen duyarlılık değerinin düşük (0.64) kalması, modelin bu sınıfa ait örneklerin bir kısmını doğru tespit edemediğini göstermektedir. Buna karşın SHK sınıfında %100 duyarlılık değeri elde edilmesi, bu sınıfa ait örneklerin tamamının doğru sınıflandırıldığını ortaya koymaktadır. ND sınıfında ise %99 kesinlik ve %100 duyarlılık ile oldukça yüksek bir başarı sağlanmıştır. Bu sonuçlar, ESA mimarisinin bazı sınıflarda güçlü olsa da özellikle ADK sınıfında duyarlılık sorunu yaşadığını göstermektedir. EfficientNet-B1 mimarisi %96.97 ortalama doğruluk ile ESA’ya


kıyasla oldukça güçlü sonuçlar elde etmiştir. ADK sınıfında kesinlik değeri %100, duyarlılık değeri %92 olarak hesaplanmış, SHK sınıfında ise duyarlılık %100'e ulaşmıştır. ND sınıfında %100 kesinlik ve %99 duyarlılık değerleri ile neredeyse hatasız sınıflandırma yapılmıştır. Bu bulgular EfficientNet-B1'in dengeli bir performans sergilediğini ve her üç sınıfta da yüksek başarı elde ettiğini göstermektedir. ViT mimarisi ise %98.40 ortalama doğruluk ile en yüksek başarıya ulaşmıştır. ADK sınıfında %97 kesinlik ve %99 duyarlılık değerleri elde edilerek hem duyarlılık hem de özgüllük açısından oldukça güçlü sonuçlar raporlanmıştır. SHK sınıfında %99 kesinlik ve %97 duyarlılık, ND sınıfında ise %100 kesinlik ve %100 duyarlılık değerleri elde edilmiştir. Bu sonuçlar, ViT'in tüm sınıflarda dengeli ve yüksek başarı sağladığını ve özellikle ND sınıfında kusursuz sınıflandırma gerçekleştirdiğini göstermektedir.


Tablo 4.2 Önerilen DÖ mimarileri sonucu elde edilen performans metrikleri (ADK: Adenokarsinom, SHK: Skumöz Hücreli Karsinom, ND: Normal Doku)

DÖ Mimarisi	Sınıflar	Kesinlik	Duyarlılık	f1-skoru	Doğruluk
ESA	ADK	0.99	0.64	0.78	0.88
	SHK	0.74	1.00	0.85	0.88
	ND	0.99	1.00	1.00	0.88
ViT	ADK	0.97	0.99	0.98	0.98
	SHK	0.99	0.97	0.98	0.98
	ND	1.00	1.00	1.00	0.98
EfficientNet-B1	ADK	1.00	0.92	0.96	0.97
	SHK	0.92	1.00	0.96	0.97
	ND	1.00	0.99	1.00	0.97

Sonuç olarak, ESA mimarisi bazı sınıflarda yüksek kesinlik değerleri ile öne çıkmasına rağmen duyarlılık açısından zayıf kalmış ve genel doğruluk oranı %87.93'te kalmıştır. EfficientNet-B1 %96.97 doğruluk ile daha dengeli bir performans sergilerken, ViT mimarisi %98.40 doğruluk ve tüm sınıflarda yüksek f1-skoru değerleri ile en başarılı model olmuştur. Bu bulgular, ViT'in evrişim tabanlı mimarilerden farklı olarak görüntüdeki uzun menzilli bağımlılıkları daha iyi modellediğini ve özellikle çok sınıflı sınıflandırma problemlerinde üstün performans sergilediğini göstermektedir. Ayrıca, modellerin karar verme süreçleri LIME yöntemi kullanılarak görselleştirilmiş ve farklı doku örneklerinden çıkarılan ayırt

edici özelliklerin konumları Şekil 4.1’de verilmiştir. Böylece, sınıflandırma performansının yanı sıra modellerin açıklanabilirliği de değerlendirilmiş ve klinik güvenilirliği artıracak ek bir doğrulama sağlanmıştır.













Şekil 4.1 ADK, SHK ve ND örnek görüntülerine ilişkin uygulanan derin mimariler sonucu LIME AYZ metoduna ait gösterimler (ADK: Adenokarsinom, SHK: Skumaöz Hücreli Karsinom, ND: Normal Doku)

4.1.2 FNet ve Dönüşüm tabanlı modellerin karşılaştırılmasına ait bulgular

Önerilen FNet mimarisi, veri seti 1 ve 2 kapsamında kolon (ADK –ND), akciğer (ADK – SHK – ND) ve meme (ND-TD) dokularına ait histopatolojik görüntüler üzerinde 50 epok boyunca eğitilmiştir. Eğitim sürecinde her epok sonunda doğruluk ve kayıp değerleri hesaplanmış, ayrıca test kümesi için karmaşıklık matrisleri Tablo 4.3’de oluşturulmuştur. Bu kapsamda üç farklı doku tipi üzerinde gerçekleştirilen deneyler, FNet’in genel performansını ortaya koymakta ve ek olarak ViT mimarisi ile kıyaslamalı sonuçlar sunmaktadır.

Tablo 4.3 FNet üzerinden eğitilen kolon, akciğer ve meme histopatolojik görüntüleri için eğitim aşamasındaki epoklar boyunca elde edilen doğruluk-kayıp grafikleri ve test aşamasındaki karmaşıklık matrisi

	Eğitim/doğrulama doğruluğu	Eğitim/doğrulama kaybı	Karmaşıklık matrisi
Akciğer			
Kolon			
Meme			

Akciğer dokusu sınıflandırma sonuçları incelendiğinde, ADK görüntülerinin büyük çoğunluğunun doğru sınıflandırıldığı, yalnızca 7 örneğin SHK olarak hatalı sınıflandırıldığı görülmektedir. Benzer şekilde, SHK örneklerinin 6'sı ADK olarak yanlış etiketlenmiş, geri kalanları ise doğru biçimde sınıflandırılmıştır. Normal akciğer dokularının ise tamamı doğru tanımlanmıştır. Bu sonuçlar, FNet'in akciğer dokularında %100'e yakın bir doğruluk ve tüm sınıflarda yüksek hassasiyet ve duyarlılık değerlerine ulaştığını göstermektedir. Kolon dokusu sonuçları, ADK ve normal dokuların yüksek doğruluk oranıyla ayrıştırıldığını ortaya koymaktadır. Toplam 1000 ADK örneğinin 995'i doğru sınıflandırılmış, yalnızca 5 örnek normal olarak yanlış etiketlenmiştir. Normal örneklerde ise sadece tek bir yanlış sınıflandırma gözlenmiştir. Bu sonuçlarla Tablo 4.4'ye bakıldığında FNet kolon

dokusu için %100 doğruluk seviyesine ulaşmıştır. Meme dokusu sınıflandırmasında veri dengesizliği önemli bir zorluk oluşturmıştır. Normal sınıfa ait 495 örnekten 43'ü tümör olarak, tümör sınıfa ait 1061 örnekten 35'i ise normal olarak hatalı sınıflandırılmıştır. Buna rağmen FNet, normal sınıf için %93 kesinlik ve %91 duyarlılık; tümör sınıfı için %96 kesinlik ve %97 duyarlılık sağlamıştır. Genel doğruluk oranı %95 olarak hesaplanmıştır. Bu bulgu, veri dengesizliğine rağmen FNet'in güvenilir sonuçlar üretebildiğini göstermektedir. Eğitilebilir parametre sayısı FNet için 580.611 iken dönüşüm tabanlı görüntü sınıflandırma mimarisi için 21.659.588 şeklindedir.

Tablo 4.4 Önerilen DÖ mimarisinden elde edilen performans metrikleri (ADK: Adenokarsinom, SHK: Skumaöz Hücreli Karsinom, ND: Normal Doku, TD: Tümör Doku)

Dönüşüm Modelleri	Patolojik Veriler	Performans Metrikleri	En iyi Çapraz Doğrulama
FNet	Akciğer	Kesinlik	ADK:0.99; SHK:0.99; ND:1
		Duyarlılık	ADK:0.99; SHK:0.99; ND:1
		f1-skoru	ADK:0.99; SHK:0.99; ND:1
		Doğruluk	%100
	Kolon	Kesinlik	ADK:1; ND:1
		Duyarlılık	ADK:0.99; ND:1
		f1-skoru	ADK:1; ND:1
		Doğruluk	%100
	Meme	Kesinlik	ND:0.93; TD:0.96
		Duyarlılık	ND:0.91; TD:0.97
		f1-skoru	ND:0.92; TD:0.96
		Doğruluk	%0.95
ViT	Akciğer	Kesinlik	ADK:0.98; SHK:0.99; ND:1
		Duyarlılık	ADK:0.99; SHK:0.98; ND:1
		f1-skoru	ADK:0.99; SHK:0.99; ND:1
		Doğruluk	%0.99
	Kolon	Kesinlik	ADK:1; ND:0.99
		Duyarlılık	ADK:0.99; ND:1
		f1-skoru	ADK:0.99; ND:0.99
		Doğruluk	%0.99
	Meme	Kesinlik	ND:0.90; TD:0.96
		Duyarlılık	ND:0.93; TD:0.95
		f1-skoru	ND:0.91; TD:0.96
		Doğruluk	%0.94



FNet'in elde ettiđi sonuçlar, ViT mimarisi ile kıyaslandığında daha belirgin hale gelmektedir. ViT modeli akciđer ve kolon dokularında yüksek performans göstermesine karşın meme dokusu sınıflandırmasında FNet'e göre daha düşük doğruluk (0.94) üretmiştir. Ayrıca ViT'in eğitilebilir parametre sayısı yaklaşık 22 M iken FNet yalnızca 580.611 parametre ile eğitilmiş ve buna rağmen daha yüksek doğruluk ve daha kararlı bir öğrenme süreci sergilemiştir. Bu durum, FNet'in hem hesaplama maliyeti açısından daha verimli olduğunu hem de sınıflandırma başarısı bakımından daha üstün sonuçlar verdiğini ortaya koymaktadır.

Sonuç olarak, yapılan deneyler FNet'in farklı doku tiplerinde yüksek doğruluk, kesinlik ve duyarlılık oranlarına ulaştığını ve ViT gibi daha karmaşık dönüşüm tabanlı mimarilere kıyasla hem daha hızlı hem de daha doğru sonuçlar elde edebildiğini göstermiştir. Bu bulgular, FNet'in histopatolojik görüntülerin otomatik sınıflandırılmasında güçlü ve klinik açıdan uygulanabilir bir çözüm sunduğunu ortaya koymaktadır.





Önerilen çalışmada FNet mimarisi üzerine LIME yöntemi uygulanmış ve modelin öğrendiđi bölgeler görselleştirilerek açıklanabilirlik önemli ölçüde artırılmıştır. Böylece yalnızca sınıflandırma performansı değerlendirilmemiş, aynı zamanda modelin hangi bölgelerden, hangi hücresel özelliklerden etkilendiđi de ortaya konmuştur. Örneğin; ADK dokularında önerilen MÖ yönteminin tanıdığını çekirdek bölgelerinde veziküler (baloncuklu) görünüm, kümelenme ve belirgin çekirdekçikler gibi olağandışı bulguların öne çıkarıldığını, SHK dokularda ise nükleer büyüme, şekil düzensizliği ve hiperkromazi (çekirdek boyanma yoğunluğunda artış) gibi özelliklerin dikkate alındığını gözlemlenmiştir. Buna karşılık, normal dokuların yanlış sınıflandırıldığı örneklerde genellikle düşük hücresellik, monoton nükleus yapıları veya sitoplazma yoğunluğu gibi faktörlerin model kararını yanıltıcı şekilde etkilediğini görülmüştür. Bu bulgular, LIME açıklamalarının yalnızca modelin kararlarını görselleştirmekle kalmayıp aynı zamanda modelin hangi histopatolojik özelliklerden etkilendiğini ortaya koyarak patoloğların karar mekanizması ile uyumlu olup olmadığını anlamaya da yardımcı olduğunu göstermektedir. Örneğin kolon dokusunda ADK, ND olarak yanlış sınıflandırıldığı bir durumda, MÖ'nün düşük hücresellik nedeniyle normal dokuyu andıran alanları seçmiş olması, algoritmanın karar sürecindeki zayıf noktaları işaret etmektedir. Benzer şekilde akciđer dokusunda

ND'nin SHK olarak etiketlendiği örneklerde, YZ tarafından seçilen nükleer büyüme ve hiperkromazi bulguları modelin aşırı duyarlı olduğunu göstermektedir. Ayrıntılı örnekler Tablo 4.5 ve Tablo 4.6'da verilmiştir. Bu tablolar, LIME yöntemiyle elde edilen görselleştirmelerin deneyimli patolog tarafından yapılan değerlendirmeleriyle birlikte sunulmakta ve modelin doğru/yanlış sınıflandırma kararlarının altında yatan morfolojik özellikleri ayrıntılı olarak ortaya koymaktadır.

Tablo 4.5 LIME açıklamaları kapsamında deneyimli patolog tarafından yapılan kolon doku görüntülerinin değerlendirmeleri (ADK: Adenokarsinom, SHK: Skumaöz Hücreli Karsinom, ND: Normal Doku)

Tanımlanan Doku Görüntüsü	Açıklamalar
	Doğru şekilde ADK olarak sınıflandırılmış örnek Bu görüntüde, YZ tarafından seçilen çekirdek boyutları birbirine benzerlik göstermekte ve alanda tekdüze bir görünüm sergilemektedir. Normal epitel hücrelerinden farklı olarak kümelenme, veziküler görünüm ve belirgin nükleoller dikkat çekmektedir. Bu özellikler olağandışı bulgular olarak değerlendirildiğinde, doğru sınıflandırmanın yapılması mümkün olmaktadır. Nitekim fotoğrafta kırmızı üçgen ile işaretlenen bölgede yer alan nükleer özellikler tümör tanısını destekleyici niteliktedir.
	ADK olmasına rağmen ND olarak sınıflandırılmış örnek YZ, seçilen bölgelerdeki hücresel yoğunluğun düşük olması (daire ile işaretlenen alan) nedeniyle bu kareyi ND olarak değerlendirmiş olabilir. Ayrıca, seçilen alanda mevcut çekirdeklerin küçük ve tekdüze görünmesi de yanlış sınıflandırmaya yol açmış olabilir.

Tablo 4.6 LIME açıklamaları kapsamında deneyimli patolog tarafından yapılan akciğer doku görüntülerinin değerlendirmeleri (ADK: Adenokarsinom, SHK: Skumaöz Hücreli Karsinom, ND: Normal Doku)

Tanımlanan doku görüntüsü	Açıklamalar
	Doğru şekilde ADK olarak sınıflandırılmış örnek: Bu görüntü karesinde, YZ tarafından tanısal olarak belirlenen bölgede yer alan hücreler; büyüme, şekil ve boyut farklılıkları ile hiperkromazi gibi olağandışı hücresel özellikler sergilemektedir. Belirgin bir çevre dokulara yayılım gözlenmemekle birlikte, bu olağandışı görünüme dayanarak doğru sınıflandırmanın yapılmış olduğu değerlendirilebilir.
	Doğru şekilde SHK olarak sınıflandırılmış örnek: Oval ile işaretlenen bu karedeki hücrelerde nükleer büyüme, hiperkromazi ve düzensiz şekil belirgin özellikler olarak dikkat çekmektedir. Belirgin bir çevre dokulara yayılım gözlenmemekle birlikte, YZ tarafından işaretlenen alanlarda çekirdeklerin daha yoğun bir şekilde görüldüğü izlenmektedir.
	ND olmasına rağmen SHK olarak sınıflandırılmış örnek: Bu görüntüde, YZ tarafından tanısal olarak belirlenen alanda dairesel sembollerle işaretlenen çekirdeklerde büyüme, hiperkromazi ile şekil ve boyut farklılıkları gözlenmektedir. Bu özellikler olağandışı bulgular olarak değerlendirilebilir.
	SHK olmasına rağmen ND olarak sınıflandırılmış örnek: Bu görüntüde, YZ tarafından periferik (çevresel) olarak tanımlanan alanlar genellikle sitoplazma ile karakterize olup, nükleer yapıya daha az rastlanmaktadır. Mevcut çekirdekler boyut ve şekil açısından benzerlik göstermekte ve tekdüze bir görünüm sergilemektedir. Ayrıca, kapalı bölgelerde sitoplazmanın daha yoğun bulunması nedeniyle YZ bu alanı normal doku olarak değerlendirmiş olabilir.


4.2 Maymun Çiçeği Hastalığına Ait Dermatolojik Veri Setlerinin Analizine Yönelik Bulgular

4.2.1 Dönüşüm modellerinden elde edilen özellik dağılımlarının t-SNE ve UMAP ile görselleştirilmesi

Özellik çıkarımı sonrası, DÖ modellerinin ürettiği özelliklerin kalitesini değerlendirmek ve sınıflar arası ayrışma performansını gözlemlemek amacıyla t-SNE ve UMAP gibi boyut indirgeme tabanlı görselleştirme yöntemleri kullanılmıştır. Bu yöntemler, yüksek boyutlu uzayda temsil edilen derin özellikleri iki boyutlu düzleme yansıtarak sınıf kümelerinin ayrışma düzeyini daha somut biçimde ortaya koymaktadır.

MSLD veri kümesi (maymun çiçeği ve diğerleri) yalnızca 2 sınıf içerdiğinden, görselleştirmeler sonucunda kümelerin oldukça belirgin biçimde ayrıştığı gözlemlenmiştir. Bu durum, 2 sınıf arasındaki farklılıkların yüksek düzeyde belirgin olduğunu ve ayrımın görece kolay yapıldığını göstermektedir. Buna karşılık, 4 sınıftan (maymun çiçeği, suçiçeği, kızamık ve normal) oluşan MSID veri kümesinde elde edilen dağılımlar daha karmaşık bir yapı sergilemiştir. Özellikle Normal sınıfının diğer üç sınıftan belirgin biçimde ayrıldığı görülürken maymun çiçeği, suçiçeği ve kızamık örneklerinin kümeleri arasında ciddi örtüşmeler gözlenmiştir. Bu durum, söz konusu hastalıkların deri lezyonlarının görsel benzerliklerinden kaynaklanmakta olup çok sınıflı problemlerde ayrıştırmanın daha zor olduğunu ortaya koymaktadır.

Şekil 4.2’de sunulan t-SNE ve UMAP görselleri incelendiğinde ViT modelinin ürettiği özellik dağılımlarının DeiT modeline kıyasla daha iyi ayrışma sağladığı dikkat çekmektedir. ViT, özellikle maymun çiçeği, suçiçeği ve kızamık sınıflarının üst üste binen bölgelerini daha belirgin şekilde ayrıştırarak daha kompakt ve sınıf-temelli kümeler ortaya çıkarmıştır. DeiT ise sınıflar arasında belirli ölçüde ayrışma sağlamakla birlikte, kümelerin sınırlarında kaynaşmaların daha sık olduğu görülmüştür. Bu bulgular, ViT modelinin karmaşık veri yapıları üzerinde daha güçlü özellik temsil yeteneğine sahip olduğunu ve sınıflar arası ayrımı daha başarılı biçimde gerçekleştirdiğini göstermektedir. Ayrıca, çok sınıflı senaryolarda sınıflar arası görsel benzerliklerin yüksek olması daha gelişmiş özellik çıkarımı yapabilen DÖ modellerine duyulan ihtiyacı bir kez daha ortaya koymaktadır.



Şekil 4.2 Dönüşüm modelleri tarafından çıkarılan dermatolojik görüntü özneteliklerinin t-SNE ve UMAP görselleştirmeleri


Sonuç olarak, yapılan analizler ViT modelinin hem iki sınıflı hem de çok sınıflı veri kümelerinde daha ayırık ve anlamlı küme yapıları ürettiğini, dolayısıyla maymun çiçeği tanısı gibi kritik klinik uygulamalarda daha güvenilir bir alternatif sunduğunu ortaya koymaktadır.

4.2.2 Dermatolojik görüntülerin sınıflandırılmasında ViT ve DeiT modellerinin karşılaştırmalı performans değerlendirmesi


Bu tez çalışmasında ViT ve DeiT modelleri 50 epok boyunca eğitilmiş ve elde edilen eğitim/doğrulama doğruluk-kayıp eğrileri, karmaşıklık matrisleri, ROC-AUC sonuçları ve performans metrikleri Tablo 4.7-4.10'da sunulmuştur. Elde edilen eğriler, 50 epokun yakınsama için yeterli olduğunu, daha uzun süreli eğitimin doğruluk değerlerinde yalnızca sınırlı iyileşme sağladığını ve kayıplarda minimal azalma ile sonuçlandığını göstermektedir. Ayrıca, önceden eğitilmiş ağırların ince ayarı ve 15 epok boyunca uygulanan erken durdurma stratejisi sayesinde, daha uzun süreli eğitimin yalnızca hesaplama maliyetini artıracak ancak anlamlı bir performans kazanımı sağlamayacağı görülmüştür. Kayıp değerleri de epok ilerledikçe azalma eğilimi göstermiş ve aşırı öğrenme bulgusu gözlenmemiştir. Karmaşıklık matrisine göre ViT, 19 maymun çiçeği vakasından 15'ini doğru sınıflandırmış, diğerleri sınıfındaki 28 örneğin tamamını hatasız tahmin etmiştir. ROC eğrisi altında kalan

alan (AUC) değeri 0.92 olarak hesaplanmıştır. DeiT modeli ise benzer eğilim göstermiş ancak diğerleri sınıfında 2 sınıfı yanlış sınıflandırmış olup maymun çiçeği sınıfında ise 15/19 doğru sınıflandırma ile %78.9 duyarlılık elde etmiştir. AUC değeri 0.90 olup ViT'e kıyasla daha düşük kalmıştır. Bu bulgular, ikili sınıflandırma probleminde ViT'in daha kararlı ve yüksek doğruluk sağlayan bir yapı sunduğunu göstermektedir.

Tablo 4.7 MSLD veri setine ait, ViT ve DeiT modelleriyle her epok'ta elde edilen eğitim/doğrulama doğruluk ve kayıp grafikleri ile karmaşıklık matrisi



Tablo 4.8 MSID veri setine ait, ViT ve DeiT modelleriyle her epokta elde edilen eğitim/doğrulama doğruluk ve kayıp grafikleri ile karmaşıklık matrisi



İkili sınıflandırma (MSLD veri seti) sonuçlarına göre, ViT modeli ortalama %91.49 doğruluk ve 0.9192 AUC değeri ile DeiT modelinden daha üstün performans sergilemiştir. ViT modeli özellikle diğerleri sınıfında %100 duyarlılık ve %93.33 f1-skoru ile yüksek doğruluk sağlamıştır. Maymun çiçeği sınıfında ise %1.000 kesinlik ve %78.95 duyarlılık elde edilmiştir. Buna karşılık DeiT modeli, ortalama %87.23 doğruluk ve 0.9004 AUC ile görece daha düşük performans göstermiştir. Özellikle maymun çiçeği sınıfında ViT modeline kıyasla daha düşük f1-skoru (0.8333) elde edilmiştir. Bu sonuçlar, maymun çiçeği verisinin sınırlı sayıda olması nedeniyle sınıf dengesizliğinin performans üzerinde belirleyici bir faktör olduğunu ortaya koymaktadır.

Çoklu sınıflandırma (MSID veri seti) sonuçlarında ise ViT modeli yine DeiT'e göre daha başarılı olmuştur. ViT modeli ortalama %89.61 doğruluk ve 0.9784 AUC ile yüksek bir performans sergilemiştir. Özellikle normal sınıfta 0.9688 f1-skoru ve %98.41 duyarlılık değerleri ile dikkat çekmektedir. Maymun çiçeği sınıfında 0.8909 f1-skoru ile başarılı bir ayırım yapılmıştır. Buna karşın suç çiçeği ve kızamık sınıfları, lezyon benzerlikleri nedeniyle daha zor ayrıştırılmış ve f1-skorları sırasıyla 0.6842 ve 0.8750 olmuştur. Ancak bu değerler, DeiT modelinin aynı sınıflardaki performansına göre (suç çiçeği 0.7059, kızamık 0.8148) daha dengeli ve güvenilir bir ayırım gücü sunduğunu göstermektedir. DeiT modeli, MSID veri setinde ortalama %88.31 doğruluk ve 0.9708 AUC sağlamış olsa da, özellikle Normal sınıfta yüksek duyarlılığa (%100) rağmen kesinliğin (%86.30) düşük kalması dikkat çekmektedir. Bu durum, DeiT'in bazı durumlarda yanlış pozitif üretmeye eğilimli olduğunu göstermektedir.

Tablo 4.9 ViT ve DeiT modelleri ile MSLD veri seti için elde edilen performans ölçütleri

Dönüşüm metodu	Sınıflar	Kesinlik	Duyarlılık	f1-skoru	Ort. doğruluk	AUC
ViT	Diğerleri	0.8750	1.0000	0.9333		
	Maymun çiçeği	1.000	0.7895	0.8824	0.9149	0.9192
DeiT	Diğerleri	0.8667	0.9286	0.8966		
	Maymun çiçeği	0.8824	0.7895	0.8333	0.8723	0.9004

Tablo 4.10 ViT ve DeiT modelleri ile MSID veri seti için elde edilen performans ölçütleri

Dönüşüm metodu	Sınıflar	Kesinlik	Duyarlılık	f1-skoru	Ort. doğruluk	AUC
ViT	Suçiçeği	0.5909	0.8125	0.6842		
	Kızamık	0.8235	0.9333	0.8750	0.8961	0.9784
	Maymun çiçeği	0.9800	0.8167	0.8909		
	Normal	0.9538	0.9841	0.9688		
	Suçiçeği	0.6667	0.7500	0.7059		
DeiT	Kızamık	0.9167	0.7333	0.8148	0.8831	0.9708
	Maymun çiçeği	0.9804	0.8333	0.9009		
	Normal	0.8630	1.000	0.9265		

Sonuç olarak, her iki veri setinde de ViT modeli, DeiT modeline kıyasla daha yüksek doğruluk, f1-skoru ve AUC değerleri ile öne çıkmıştır. Bu bulgular, ViT'in daha karmaşık veri yapılarında dahi sınıflar arası ayrımı daha iyi gerçekleştirebildiğini ve maymun çiçeği gibi görsel olarak benzer özellikler taşıyan deri hastalıklarının ayırıcı tanısında daha güvenilir bir alternatif sunduğunu göstermektedir.

Sınıflandırma deneylerinde ViT modelinin genel olarak en yüksek doğruluk ve AUC değerlerine ulaşması nedeniyle, açıklanabilirlik çalışmaları kapsamındaki ısı haritaları da tutarlılık sağlamak amacıyla yalnızca ViT üzerinden üretilmiştir. Böylece görselleştirmeler, en güçlü sınıflandırma performansını veren modelin özellik uzayını yansıtmaktadır.

4.2.3 Sınıflandırma sonrası AYZ metotlarından elde edilen nedensel metriklere ait bulgular

Tablo 4.11–4.12, MSLD ve MSID için farklı AYZ yöntemleri kapsamında elde edilen nedensel metrik sonuçlarını sunmaktadır. Önerilen hibrit AYZ yaklaşımında, eşleştirilmiş ısı haritalarını üretmek üzere yalnızca Grad-CAM ve LRP birleştirilmiştir. AR ise, Tablo 4.11 ve 4.12’de görüldüğü üzere, eşleştirilmiş hibrite kıyasla daha yüksek silme ve daha düşük ekleme değerleri ürettiği için yani temel özelliklerin yerleştirilmesinde daha az güvenilir davranış gösterdiği için dışarıda bırakılmıştır. Böylelikle hibrit yaklaşım, önemli bölgelerin korunmasını en üst düzeye çıkarırken ilgisiz alanları en aza indirerek daha doğru ve yorumlanabilir açıklamalar sağlamaktadır. Grad-CAM ve LRP’den türetilen eşleştirilmiş hibrit yaklaşım, MSLD için ortalama ekleme (0.865 ± 0.005) ve silme (0.209 ± 0.026); MSID için ise ortalama ekleme (0.899 ± 0.004) ve silme (0.192 ± 0.010) değerlerine ulaşmıştır. Bu da yöntemin temel özellikleri koruma ve ilgili olmayanları azaltma konusundaki üstünlüğünü göstermektedir. MSID verisi için normal sınıf, lezyon bulgusu taşımadığı için değerlendirmeye dahil edilmemiştir. Bu değerler, AYZ yöntemlerinin değerlendirilmesinin yalnızca görsel yorumlamaya dayanmaması, aynı zamanda nedensel metriklerle desteklenmesi amacıyla tüm test görüntüleri üzerinden ortalama alınarak hesaplanmıştır.

Tablo 4.11 MSLD test kümesi üzerinde ViT sınıflandırma modeli ile elde edilen ortalama nedensel skorlar


Nedensel metrik	Grad-CAM	LRP	AR	TBA (Grad-CAM+LRP)
Silme	0.278 ± 0.002	0.228 ± 0.017	0.345 ± 0.032	0.209 ± 0.026
Ekleme	0.842 ± 0.011	0.859 ± 0.013	0.843 ± 0.026	0.865 ± 0.005

Tablo 4.12 MSID test kümesi üzerinde ViT sınıflandırma modeli ile elde edilen ortalama nedensel skorlar

Nedensel metrik	Grad-CAM	LRP	AR	TBA (Grad-CAM+LRP)
Silme	0.238 ± 0.015	0.219 ± 0.012	0.265 ± 0.018	0.192 ± 0.010
Ekleme	0.873 ± 0.009	0.888 ± 0.006	0.855 ± 0.014	0.899 ± 0.004


Şekil 4.3, Grad-CAM, LRP ve AR açıklanabilirlik yöntemleri kullanılarak kızamık sınıfından örnek bir görüntü üzerinde elde edilen örtüşük sonuçlar ve bunlara karşılık gelen silme ile ekleme grafiklerini sunmaktadır (Bk. Şekil 4.3(a)). Bu görselleştirmeler, her yöntemin belirlediği ilgi bölgelerinin (ROI) farklılığını ortaya

koyarak modelin karar verme sırasında hangi özellikleri önceliklendirdiğine ilişkin içgörüler sağlar. Sonuçların da açıkça gösterdiği gibi TBA ile elde edilen Grad-CAM + LRP hibriti en iyi performansı sergilemiş; daha keskin ve daha yorumlanabilir ısı haritaları üretmiş olup gerçek değerler (ground truth: GT) ile daha yakından örtüşmüştür (Bk. Şekil 4.3(b)). Bu üstünlük, nicel grafiklerle de desteklenmektedir. Hibrit yöntemle ait silme eğrisi hızlı ve dik bir düşüş göstermekte; bu da kritik bölgeler çıkarıldığında modelin tahmin gücünü neredeyse anında kaybettiğine işaret etmektedir. Bu davranış, Grad-CAM ve LRP'nin tekil kullanımında gözlenen daha kademeli düşüşle kıyas edildiğinde hibrit yaklaşımın ilgili özelliklere yoğun biçimde odaklanma kapasitesini vurgulamaktadır. Ekleme metriği de hibrit yöntemin etkinliğini doğrulamaktadır. Kritik bölgeler kademeli olarak eklendiğinde model performansının daha yüksek doğrulukla geri kazanılması ayrıştırıcı özellikleri yakalamadaki sağlamlığını ortaya koymaktadır.




Şekil 4.3 (a) Grad-CAM, LRP ve AR yöntemleriyle elde edilen örnek ısı haritaları; (b) aynı yöntemler ile hibrit yaklaşımına ait silme ve ekleme eğrileri

Ayrıca Şekil 4.4(a)–(b), maymun çiçeği sınıfından örnek bir görüntü için silme ve ekleme sonuçlarını sunarak, Grad-CAM ve LRP'nin üstün performansını daha da belirginleştirmektedir.




(a)



(b)

Şekil 4.4 (a) Grad-CAM, LRP ve AR yöntemleriyle elde edilen üst üste bindirilmiş ısı haritaları; (b) aynı yöntemler ile hibrit (Grad-CAM+LRP) yaklaşımına ait silme ve ekleme eğrileri

Şekil 4.5’de, maymun çiçeği sınıfından başka bir görüntü için yalnızca LRP ve Grad-CAM kullanılarak üretilen ısı haritaları ve hibrit çıktı sunulmaktadır. Hibrit ısı haritası, tek ve kritik bir ilgi bölgesini etkin biçimde vurgulayarak doğru sınıflandırma için en ayırt edici özelliklerin belirlenmesinde iki yöntemin birleşik gücünü göstermektedir. Bu bulgu, özellikle maymun çiçeği gibi zorlu olgularda kilit özelliklerin kesin yerleştirilmesinin tanısal doğruluk üzerindeki etkisinin yüksek olduğu durumlarda hibrit yaklaşımın değerini öne çıkarmaktadır.




Şekil 4.5 Lezyonu işaretlenmiş orijinal görüntü ile Grad-CAM ve LRP yöntemleri kullanılarak elde edilen ısı haritaları ve bunlardan türetilen hibrit ısı haritası çıktısı (maymun çiçeği sınıfına ait bir başka örnek)

4.3 Kulak Hastalıklarına Ait TM Veri Setinin Analizine Yönelik Bulgular

4.3.1 Dönüşüm modellerinden elde edilen özellik dağılımlarının t-SNE ve UMAP ile görselleştirilmesi

Şekil 4.6’ da t-SNE ve UMAP görselleştirmeleri, daha önce açıklanan prosedürün (Bk. Bölüm 4.2.1) TM verisine uygulanmasıyla elde edilmiştir. Görseller, ViT’in ürettiği gömülerin DeiT’e kıyasla daha kompakt ve ayırık kümeler oluşturduğunu göstermektedir. Normal sınıf belirgin biçimde ayrışırken, efüzyon ile tüp arasında klinik/görsel benzerliklerle tutarlı kısmi örtüşmeler gözlenmektedir. Bu örtüşme bölgeleri, olası sınır karışımlarına işaret eden alanları temsil eder ve hata analizi ile veri zenginleştirme (sınır örneklerinin artırılması, sınıf dengesinin iyileştirilmesi) için yol göstericidir. Kısacası, gömü uzayındaki sınıf ayrımı, modellerin ayırt edici örüntüleri ne ölçüde yakaladığını görsel olarak ortaya koymakta ve nicel değerlendirmeleri nitel açıdan tamamlamaktadır.




Şekil 4.6 Dönüşüm modelleri kullanılarak elde edilen TM görüntü öznelitliklerinin t-SNE ve UMAP görselleştirmeleri

4.3.2 TM görüntülerinin sınıflandırılmasında ViT ve DeiT modellerinin karşılaştırmalı performans değerlendirmesi

Bu tez çalışmasında ViT ve DeiT modelleri TM veri kümesi üzerinde 50 epok boyunca eğitilmiş; eğitim/doğrulama doğruluk–kayıp eğrileri ile karmaşıklık matrisleri Tablo 4.13’de, sınıf bazlı performans metrikleri Tablo 4.14’de sunulmuştur. ViT tüm sınıflarda tutarlı biçimde güçlü sonuçlar vermiştir. Normal sınıfında kesinlik 1.000, duyarlılık 1.000, f1-skoru 1.000; Efüzyon için kesinlik 0.9474, duyarlılık 1.000, f1-skoru 0.9730; tüp sınıfı için kesinlik 1.000, duyarlılık 0.8889, f1-skoru 0.9412 elde edilmiştir. Bu dağılım ortalama doğruluk 0.9778 ve AUC 0.9976 değerleriyle birlikte, modelin duyarlılık–özgüllük dengesini koruduğunu göstermektedir. Karmaşıklık matrisi, ViT’ in yalnızca bir tüp örneğini efüzyon olarak etiketlediğini, diğer sınıflarda ise hata yapmadığını göstermektedir. DeiT, normal sınıfta ViT ile aynı düzeyde sonuçlar üretse de tüp sınıfında belirgin düşüş göstermiştir. Efüzyon için kesinlik 0.9412, duyarlılık 0.8889, f1-skoru 0.9143; küresel ölçekte ortalama doğruluk 0.9333 ve AUC 0.9935 bulunmuştur. Karmaşıklık matrisi, DeiT’ in Efüzyon sınıfında iki örneği tüp olarak, tüp sınıfında ise bir örneği efüzyon olarak yanlış sınıflandırdığını göstermektedir.

Tablo 4.13 TM veri kümesi için, epoklar boyunca ViT ve DeiT modellerine ait eğitim/doğrulama doğruluk ve kayıp eğrileri ile karmaşıklık matrisi



Tablo 4.14 TM veri kümesine üzerinde ViT ve DeiT modellerine ilişkin performans metrikleri

Dönüşüm metodu	Sınıflar	Kesinlik	Duyarlılık	f1-skoru	Ort. doğruluk	AUC
ViT	Efüzyon	0.9474	1.000	0.9730		
	Normal	1.000	1.000	1.000	0.9778	0.9976
	Tüp	1.000	0.8888	0.9412		
DeiT	Efüzyon	0.9412	0.8889	0.9143		
	Normal	1.000	1.000	1.000	0.9333	0.9935
	Tüp	0.8000	0.8889	0.8421		

Sonuçlar, veri ve kaynak kısıtlı senaryolarda DeiT'in uygulanabilirliğini korumakla birlikte, hesaplama olanaklarının elverdiği durumlarda ViT'in daha güvenilir ve istikrarlı performans sunduğunu ortaya koymaktadır.

4.3.3 Sınıflandırma sonrası AYZ metotlarından elde edilen nedensel metriklerle ait bulgular


Bu tez çalışmasında ViT ve DeiT modellerinin performansları birbirine yakın olmakla birlikte, ViT'in test doğruluğunun bir miktar daha yüksek olması nedeniyle, açıklanabilirlik potansiyelini nesnel olarak ortaya koymak amacıyla tüm ısı haritası ve hibritleştirme uygulamaları ViT üzerinden yürütülmüştür. TM veri kümesi için

farklı AYZ yöntemleri altında hesaplanan nedensel metrik sonuçları Tablo 4.15’de ayrıntılandırılmıştır. Şekil 4.7 (a) TM’den örnek bir görüntü üzerinde Grad-CAM, LRP ve AR’nin tekil ısı haritalarını, bunların ikili hibritlerini ve ilgili ekleme-silme eğrilerini; Şekil 4.7 (b) ise aynı yöntemlerin orijinal görüntü üzerine üst üste bindirilmiş sürümlerini göstermektedir.

Tablo 4.15 TM veri kümesi için ViT sınıflandırma modeli kullanılarak test kümesi üzerinde hesaplanan ortalama nedensel metrikler. (Tüm yöntemlerde birinci satır silme, ikinci satır ekleme değerlerini göstermektedir. Her yöntem için en iyi silme ve ekleme sonuçları kalın karakterle belirtilmiştir.)

		Efüzyon	Normal	Tüp	Ort. metrikler
Grad-CAM	Del↓	0.2222	0.2262	0.6008	0.3497
	Ins↑	0.8965	0.8625	0.8866	0.8819
LRP	Del↓	0.1942	0.2229	0.5362	0.3178
	Ins↑	0.9012	0.8625	0.8958	0.8865
AR	Del↓	0.1786	0.2642	0.5166	0.3198
	Ins↑	0.9006	0.8475	0.9110	0.8864
KKA (GradCAM-LRP)	Del↓	0.2470	0.2162	0.5936	0.3523
	Ins↑	0.8950	0.8551	0.8891	0.8797
KKA (GradCAM-AR)	Del↓	0.2335	0.2197	0.5851	0.3461
	Ins↑	0.8974	0.8600	0.8858	0.8811
KKA (LRP-AR)	Del↓	0.1720	0.2140	0.5163	0.3008
	Ins↑	0.9002	0.8594	0.9159	0.8918

Şekil 4.7 (a)-(b)’deki görseller bu bulguları nitel olarak desteklemektedir. Tekil yöntemlerde Grad-CAM daha sınıf ayrımlı fakat mekânsal olarak kaba bölgeleri, LRP daha ince dokusal ayrıntıları öne çıkarırken, AR’nin dikkat örüntüsü kimi zaman ilgi bölgesi dışına taşabilmektedir. LRP ve AR hibriti ise bu iki davranışı tamamlayıcı biçimde birleştirerek klinik olarak anlamlı, daha keskin ve kompakt ilgi bölgeleri üretmektedir. Silme eğrilerinde hibrit yaklaşımın daha hızlı ve daha dik düşüş sergilemesi, kritik bölgeler kaldırıldığında model çıktısının hemen bozulduğunu, ekleme eğrilerinde daha erken ve daha yüksek toparlanma göstermesi ise bilginin yoğunlaştığı bölgelerin doğru tespit edildiğini göstermektedir.



Şekil 4.7 (a) Efüzyon sınıfına ait örnek bir görüntü üzerinde Grad-CAM, LRP ve AR ile üretilen tekil ve hibrit ısı haritaları ile bunlara ilişkin nicel karşılaştırma amacıyla verilen silme eğrileri (b) Tekil AYZ yöntemlerine ait ısı haritalarının orijinal görüntü üzerine üst üste bindirilmiş gösterimleri; bu sayede farklı açıklama teknikleri arasında model dikkatinin sezgisel olarak görsel değerlendirilmesi

Bu bağlamda, sınıflandırma tarafında ViT'in kararlı başarımı ile açıklanabilirlik tarafında LRP-AR hibritinin nedensel metrik üstünlüğü tutarlı bir bütün oluşturmakta; TM veri kümesinde hem doğru sınıflandırma hem de yorumlanabilir ısı haritası üretimi açısından tercih edilmesi gereken kombinasyonun ViT + LRP-AR olduğunu göstermektedir.

4.4 Tartışma

4.4.1 Akciğer, kolon, meme kanseri sınıflandırılması ve AYZ'nin önemi

Bu tez çalışmasının patolojik değerlendirme kısmı iki aşamada yürütülmüştür. İlk aşamada yalnızca 3 sınıflı akciğer verileriyle sınıflandırma yapılmış, ikinci aşamada ise akciğer, kolon ve meme verileri birlikte ele alınmıştır. Bu kapsamda, akciğer patolojisi için DÖ temelli 3 farklı mimari incelenmiştir. AYZ odağında kurgulanan bu çalışma, LIME temelli açıklanabilirlik çıktılarıyla modelin karar mekanizmalarını nicel ve nitel olarak görünür kılarak, benzer performans odaklı çalışmalara kıyasla metodolojik bir üstünlük ortaya koymaktadır [104], [105], [106].

Akciğer, kolon ve meme verileriyle gerçekleştirilen diğer çalışmada 2 farklı dönüşüm tabanlı model karşılaştırılmıştır. Az sayıda ayarlanabilir parametre gereksinimi ve yüksek işlem hızıyla öne çıkan FNet mimarisi akciğer kolon ve memede yüksek doğruluk elde etmiştir. Ayrıca AYZ kapsamında LIME çıktıları, patolojik değerlendirmeleriyle birlikte yorumlanarak modelin açıklanabilirliği güçlendirilmiştir. Bununla birlikte, literatürdeki birçok çalışmanın sınırlı örneklem büyüklüğüne, tek merkezli veri kaynaklarına veya sınırlı doku çeşitliliğine dayanması, modellerin genellenebilirliğini kısıtlamaktadır. Çalışma, akciğer ve kolon verilerinin benzer doku tiplerinden ve aynı örneklem grubundan elde edilmesi nedeniyle, farklı bir hastalık türü ile farklı doku ve örnekleme sahip olan meme verilerini de kapsamıyla literatürdeki diğer çalışmalardan ayrılmaktadır. Özellikle farklı organ patolojilerini birlikte değerlendiren çalışmalar oldukça sınırlıdır [49], [104], [106]. Önceki çalışmalarda çoğunlukla model doğrulukları ön planda tutulmuş, ancak açıklanabilirlik boyutu çoğu zaman ihmal edilmiştir. Tablo 4.16'da kullanılan yöntemler ve açıklanabilirlik uygulamaları açıkça gösterilmiştir. Oysa klinik uygulamalarda kararların açıklanabilir olması, patoloğların model çıktılarıyla güven temelli bir ilişki kurmasını sağlar. Bu çalışmada LIME tabanlı analizlerin ve patolojik yorumlarının karşılaştırmalı analizinin dahil edilmesi, modelin karar mekanizmalarının görsel olarak doğrulanabilmesine olanak sağlamıştır [47], [107]. Diğer taraftan, bazı DÖ mimarileri yüksek doğruluk sağlasa da yüksek hesaplama maliyeti ve karmaşık hiper-parametre yapıları nedeniyle klinik ortamlarda pratik değildir. FNet mimarisi bu açıdan daha az parametreyle yüksek doğruluk sunarak literatürdeki benzer modellere kıyasla önemli bir avantaj sağlamıştır [104], [108].

Her ne kadar LIME yöntemi açıklanabilirlik açısından güçlü bir araç olsa da yalnızca bu yöntemin kullanılması çok yönlü yorumlanabilirlik açısından bir sınırlılıktır. Gelecek çalışmalarda farklı bir tamamlayıcı AYZ tekniklerinin de entegre edilmesi, modelin karar mantığının daha kapsamlı şekilde değerlendirilebilmesini sağlayacaktır. Bunun yanında, FNet mimarisinin düşük parametre sayısına rağmen yüksek doğruluk elde etmesi önemli bir avantaj olmakla birlikte, bu modelin farklı veri türlerinde veya çok sınıflı, dengesiz veri senaryolarında nasıl performans göstereceği henüz tam olarak test edilmemiştir. Bu durum, modelin genişletilmiş klinik senaryolara uyarlanmasında ek doğrulama gereksinimini doğurmaktadır. Son olarak, çalışmada kullanılan veri artırma yöntemleri, sınırlı örneklem boyutunun olumsuz etkilerini azaltmak açısından yararlı olsa da gerçek klinik çeşitliliği tam olarak yansıtamayabilir. Bu nedenle ilerleyen çalışmalarda, daha büyük ve çok merkezli veri setlerinin kullanılması, modelin hem doğruluk hem de güvenilirlik açısından daha kapsamlı biçimde değerlendirilmesini sağlayacaktır.

Tablo 4.16 Patoloji verileri için tez kapsamında yararlanılan güncel literatür çalışmaları

Yazar	Veri Türü	Yöntem	Açıklanabilirlik	Performans
Raju ve Rau(2022)	Kolon- Akciğer	MobilNet, InceptionResNet	Grad-CAM, SmoothGrad	%95.5
Tummala (2023)	Kolon- Akciğer	EfficientV2	Saliency Haritaları	%99.97
Ahmed vd. (2023)	Akciğer	RO, RL, Karar Ağacı	SHAP, LIME	%97
Kaplun vd. (2021)	Meme	Zernike Momentleri ve YSA	LIME	%100
Imouokhome vd. (2023)	Meme	ResNet-50	IG, GradientSHAP	%96.84
Aitazaz vd. (2023)	Kolon- Akciğer	ViT	-	%98
Ali ve Ali vd. (2021)	Kolon- Akciğer	Hibrit ESA + Kapsül ağları	-	%99.58
Kumar vd.(2022)	Kolon- Akciğer	TL modeller + YSA, DVM	-	%98.06
Talukder vd. (2022)	Kolon- Akciğer	MobileNet ve Topluluk yöntemleri	-	%99.33
Wahid vd. (2023)	Kolon- Akciğer	GoogleNet, ResNet, ShuffleNet-V2	-	%99.87
Sayın vd. (2023)	Meme	VGG, ResNet, Xception, Inception	-	%87

4.4.2 Maymun çiçeği hastalığının sınıflandırılması ve AYZ'nin önemi

Mevcut tez çalışmasında, kızamık ve suçiçeği gibi benzer durumlara karşı maymun çiçeği lezyonlarını sınıflandırmak amacıyla dönüşüm tabanlı modeller başarıyla ince ayar edilmiştir. Bulgular, güvenilir bir ayırıcı tanıya olanak sağlamanın yanı sıra modelin yorumlanabilirliğinde kayda değer iyileşmeler elde edildiğini göstermektedir. Birden çok AYZ tekniğini bütünleştirerek ve TBA aracılığıyla hibrit ısı haritaları üreterek, karar verme sürecine ilişkin nicel ve kapsamlı görsel açıklamalar sunulmuştur.

Literatür, maymun çiçeği tespiti çalışmalarında iki belirgin eğilimi ortaya koymaktadır. Bir yandan, bazı çalışmalar LIME ve Grad-CAM gibi AYZ tekniklerini ESA tabanlı [54], [109] ve daha sınırlı ölçüde dönüşüm tabanlı çerçevelere entegre

ederek model yorumlanabilirliğini artırmıştır [110]. Bu çalışmalar arasında, MSLD veri kümesi için en iyi doğruluk %97.63 ile ESA tabanlı bir model tarafından raporlanmıştır. Artırılmış veri kullanan dönüşüm tabanlı model ise %94.6 doğruluk elde etmiştir. Ayrıca MSID kullanılarak en yüksek doğruluk %98.19 ile dikkat tabanlı bir model tarafından raporlanmış ve öngöruları aynı açıklanabilirlik teknikleriyle yorumlanmıştır [52]. Literatürdeki MSLD'nin özgün ve artırılmış olmak üzere iki sürüm sunduğu da not edilmelidir. Çalışmaların çoğu genellikle artırılmış sürümü kullanmıştır. Buna karşın, bu çalışmada AYZ yöntemlerinden kaynaklanabilecek olası yanlış sonuçları önlemek için verinin özgün sürümü tercih edilmiş, artırma işlemleri eğitim aşamasında uygulanmıştır. Söz konusu çalışmalar ilgili bölgeleri vurgulayarak şeffaflığı artırsa da, sağlam bir nicel doğrulama olmaksızın nitel ısı haritası değerlendirmelerine dayanmaktadır. Öte yandan, hatırı sayılır sayıda çalışma yalnızca sınıflandırma başarımına odaklanmaktadır. Herhangi bir açıklanabilirlik sunmadan DÖ modellerini kullanmaktadır [111] [57]. Bu tür yaklaşımlar doğruluk, kesinlik ve duyarlılık gibi ölçütleri öne çıkarsa da modelin karar alma sürecine ilişkin iç görüş sağlamadıkları için klinik güven ve kavrayışı sınırlamaktadır. Dahası, literatürde mevcut maymun çiçeği veri kümeleri esasen MSLD'ye dayanmaktadır. MSID'nin temel farkı, tanı için lezyon içermeyen bir normal sınıfı içermesidir. Bu nedenle, açıklanabilirlik yöntemlerinin bu sınıfa uygulanması anlamlı olmayacaktır. Genel olarak, mevcut literatür performans ve yorumlanabilirlik açısından önemli ilerlemeler kaydetmiş olsa da, kritik bir boşluk devam etmektedir. Gelişmiş dönüşüm tabanlı sınıflandırıcılar, geleneksel tekniklerin ötesine geçen yenilikçi AYZ metodolojileriyle kapsamlı biçimde bütünleştirilmemiş ve üretilen açıklamalar nicel olarak doğrulanmamıştır. Tablo 4.17'de bu açıkça gösterilmektedir. Bu boşluk, güçlü dönüşüm mimarilerinin, son teknoloji ve nicel olarak değerlendirilen AYZ yöntemleriyle sistematik biçimde birleştirilmesine yönelik araştırma gereksinimini vurgulamaktadır. Böylece maymun çiçeği tespitinde hem tanısal doğruluk hem de model şeffaflığı artırılabilir. Bu çalışmanın pratik önemi, dönüşüm tabanlı sınıflandırma modellerinin maymun çiçeği veri kümeleri üzerinde yorumlanabilirliğini ve tanısal güvenilirliğini artırma potansiyelinde yatmaktadır. Çalışmada, küçük veri kümelerinde dönüşüm eğitimi zorluğunu gidermek üzere etkili bir eğitim stratejisi benimsenmiştir. Dönüşüm modelleri genelleme için tipik olarak geniş ölçekli veri kümeleri gerektirdiğinden, önceden

eđitilmiş model ağırlıkları belirli sayıda (50 epok) ince ayar ile tekrar eđitilmiştir. Eđitim sırasında en iyi performans gösteren kat kaydedilmiş ve test aşamasında kullanılarak eniyilenmiş model başarımı güvence altına alınmıştır. Diđer çalışmalardan farklı olarak bir dizi özgün eđitim stratejisi uygulanmıştır. Mevcut artırmalar, modelin sađlamlığını ve genelleme yeteneđini güçlendirmede kritik öneme sahiptir. Veri kümesinin sınırlı boyutu göz önüne alındığında, artırmalar modelin gerçek dünya varyasyonlarını daha iyi işlemlerine yardımcı olmuş ve aşırı uyum riskini azaltmıştır.

ViT ile yapılan deneylerde, model yorumlanabilirliği için Grad-CAM, LRP ve AR yöntemleri kullanılmıştır. Grad-CAM ve LRP görüntülerinin TBA ile hibritleştirilmesi ile en iyi silme ve ekleme ölçütlerine ulaşılmıştır. Dikkat çekici olarak tek başına LRP, bu nedensel ölçütlerde ikinci en iyi sonucu vermiştir. MSLD veri kümesinde silme 0.228 ± 0.017 ve ekleme 0.859 ± 0.013 iken MSID’de ise silme 0.219 ± 0.012 ve ekleme 0.888 ± 0.006 olarak raporlanmıştır. LRP, önem skorlarını katmanlar boyunca geriye yayarak alaka düzeyini öznel haritaları üzerinde daha hassas dağıtır. Bu durumun ViT’in öz-dikkat mekanizmalarıyla iyi örtüştüğü görülmektedir. Böylece model öngörülerini etkileyen kritik bölgeleri lokal olarak etkili biçimde yakalayan yöntem geliştirilmiştir [112]. Hibrit yaklaşımın üstün performansı muhtemelen Grad-CAM’in yerelleştirmesinin, LRP’nin katman-içi hassas yayılımıyla tamamlayıcı biçimde birleşmesinden kaynaklanmaktadır [113]. Buna karşılık, AR yöntemi test görüntü kümeleri boyunca tutarlı biçimde daha düşük performans göstermiştir. MSLD’de silme 0.345 ± 0.032 ve ekleme 0.843 ± 0.026 iken MSID’de silme 0.265 ± 0.018 ve ekleme 0.855 ± 0.014 olarak raporlanmıştır. AR, çoklu katmanlardan dikkat ağırlıklarını biriktirdiğinden, ayrıntılı dikkat örüntülerini seyreltebilir ve daha az bilgi taşıyan bölgelerden kaynaklanan gürültüyü artırabilir [98]. Sonuç olarak bu aşırı toplanma, kritik yerel ayrıntıların yitirilmesine yol açarak nedensel ölçütleri olumsuz etkileyebilir. Bulgular, tek başına LRP’nin etkili olmakla birlikte, TBA aracılığıyla Grad-CAM ile bütünleştirildiğinde açıklanabilirliğin daha da güçlendiğini ve temel özelliklerin daha doğru korunup ilgisiz olanların daha etkin şekilde elendiğini doğrulamaktadır. Burada, zorlu ve görece az incelenmiş bir alan olan maymun çiçeđi tespiti için gelişmiş AYZ tekniklerini dönüşüm tabanlı mimarilerle bütünleştirerek kapsamlı bir yaklaşım

sunulmaktadır. Başlıca güçlü yön, en güvenilir açıklanabilirlik ölçütlerine ulaşmak amacıyla hibrit teknikleri de içeren nitel ve nicel değerlendirme yöntemleriyle titiz bir doğrulama yapılmasıdır. Yalnızca sınıflandırma başarımı ya da ısı haritası değerlendirmelerine dayanan mevcut çalışmaların çoğunun aksine, bu çalışma nicel olarak doğrulanmış daha derin bir açıklanabilir çerçeve önerir. Bununla birlikte, bazı sınırlılıklar kabul edilmelidir. İlk olarak, nispeten küçük veri kümesi, kapsamlı artırmalara başvurulsa dahi modellerin genellenebilirliğini kısıtlayabilir. Ek olarak, hibrit yöntemin üstünlüğüne karşın, ısı haritalarının TBA ile birleştirilmesinin karmaşıklığı, gerçek dünya klinik uygulamalarında zorluklar doğurabilir. Son olarak yaklaşım umut verici sonuçlar sergilese de dönüşüm tabanlı modellerin aşırı uyumu önlemek için genellikle büyük ölçekli veri kümelerine ihtiyaç duyması, düşük kaynaklı senaryolardaki uygulanabilirliği sınırlandırabilir. Bu bağlamda tez kapsamında kullanılan çalışma, maymun çiçeği sınıflandırmasını iyileştirirken, sağlam ve doğrulanmış bir açıklanabilir çerçeve de sunmaktadır. Sonuçlar, hibrit AYZ'nin, dönüşüm tabanlı modellerin şeffaflığını ve klinik güvenilirliğini artırma potansiyeline işaret etmektedir.

Tablo 4.17 Dermatoloji verileri için tez kapsamında yararlanılan güncel literatür çalışmaları

Yazar	Veri Türü	Yöntem	Açıklanabilirlik	Performans
Ahsan vd. (2023)	2 sınıflı maymun çiçeği verisi	TL Modelleri	LIME	%99
Raha vd. (2023)	MSLD ve MSID	Attention-MobileNetV2	Grad-CAM ve LIME	%98.19
Saavedra vd. (2023)	3 sınıflı maymun çiçeği verisi	Topluluk Öğrenmeleri	Grad-CAM	%98
Nayak vd. (2023)	MSLD	ResNet-18	Grad-CAM ve LIME	%99.49
Siddick vd. (2024)	Maymun çiçeği verisi	ViT ve Hibrit Modeller	Grad-CAM	%99.41
Sitaula ve Sihahi (2022)	MSID	TL modelleri ve Topluluk öğrenmeleri	Grad-CAM ve LIME	%87.13
Abdelrahim vd. (2024)	Maymun çiçeği verisi	ESA ve DVM topluluk öğrenmesi	-	%95.45
Kundu vd. (2024)	Maymun çiçeği verisi	Federe öğrenme ve ViT	-	%97.90
Haque vd. (2022)	Maymun çiçeği verisi	CBAM-Xception	-	%83.89
Uysal (2023)	MSID	DÖ ve LSTM Hibrit	-	%87
Altun vd. (2023)	Maymun çiçeği verisi	MobileNet-V3	-	%96

4.4.3 Kulak zarı hastalıklarının sınıflandırılması ve AYZ'nin önemi

Mevcut tez çalışmasında, 3 farklı AYZ yöntemi ile bunların 3 farklı hibrit kombinasyonu kullanılmıştır. En iyi performans gösteren yöntem, nedensel bir ölçüt aracılığıyla kesin biçimde belirlenmiştir. LRP ve AR'nin birleştirildiği ikili hibrit yaklaşım, tutarlı biçimde en düşük silme ve ekleme puanlarını elde ederek kritik özellikleri belirlemede ve korumada üstün yetkinlik sergilerken ilgisiz unsurların etkisini de etkili biçimde azaltmıştır. Bu bağlamda kullanılan yöntem, hem yetişkin hem de pediatrik popülasyonları kapsayan otoskopik görüntü kareleri üzerinden TM durumlarını sınıflandırmak üzere ViT ve DeiT modellerinin performansını değerlendirmektedir. Önceki çalışmaların çoğu esas olarak ESA tabanlı mimarilere dayanırken [61], [62], [64], [65], [67] bu çalışma TM sınıflandırması için dönüşüm tabanlı modelleri sistematik biçimde inceleyen az sayıdaki çalışmadan biridir. Ayrıca

literatürdeki ESA tabanlı bazı çalışmalar yüksek doğruluk değerine ulaşmış olsalar da bu çalışmalar dönüşüm mimarileri veya gelişmiş açıklanabilir çerçeveleri içermemektedir [64], [65], [114]. Dolayısıyla, çalışmanın yeniliği yalnızca en güncel ESA'larla rekabetçi performans elde etmekte değil; aynı zamanda dönüşüm tabanlı modellemeyi sistematik bir hibrit açıklanabilir analiziyle birleştirerek OM'nin otomatik tanısına hem doğruluk hem de şeffaflık kazandırmasında yatmaktadır. Tablo 4.18'de güncel OM literatürünün genellikle performans arttırmaya yönelik çalışmalarla baskılandığı görülmüştür. Buna paralel olarak son dönemde bazı çalışmalar otoskopik tanıda zamansal bilgiden yararlanmak üzere video-tabanlı yaklaşımları incelemiştir [71], [72], [73]. Bu çalışmalara kıyasla, önerdiğimiz ViT modeli yalnızca tekil yüksek çözünürlüklü görüntülere dayanarak %97.78 ortalama doğruluk ve 0.9976 AUC elde etmiş; daha karmaşık veri toplama ve işlem hatları gerektiren video-tabanlı düzenekleri aşmıştır. Video-tabanlı yöntemler zamansal dinamikleri yakalasa da klinik uygulanabilirliği sınırlayabilecek karmaşık süreçler gerektirir. Buna karşılık yaklaşımın, dönüşüm mimarilerin hibrit açıklanabilir analiziyle birleştirildiğinde, daha basit ve yaygın olarak erişilebilir statik otoskopik görüntülerle hem üstün tanısallık performans hem de şeffaf karar desteği sağlayabildiğini göstermektedir. Bu ilerlemeler üzerine inşa edilen çalışma, açıklanabilirlik teknikleri ve nedensel ölçütleri de içerecek şekilde farklılaşmaktadır. Özellikle, model şeffaflığı ve açıklanabilirliği artırmak amacıyla silme ve ekleme puanları (Bk. Tablo 4.15) kullanılmıştır. Böylece karar verme sürecine daha kapsamlı bir bakış sunulmuştur. Çalışma, OM tanısına yönelik klinik karar destek literatürüyle uyumludur. TM koşullarının çok sınıflı sınıflandırma sonrası kullanılan AYZ metotlarından elde edilen ısı haritaları için hibrit bir yöntem olan KKA yaklaşımı kullanılmıştır. TM veri kümesindeki tüm test görüntüleri üzerinden hesaplandığında, hibrit yaklaşım ortalama silme puanı olarak 0.3008 ± 0.053 ve ortalama ekleme puanı olarak 0.8918 ± 0.065 değerlerine ulaşmıştır. Sonuçların daha yakından incelenmesi, tablolardan hemen fark edilmeyebilecek örüntüleri de ortaya koymaktadır. Her ne kadar ViT, DeiT'e kıyasla daha yüksek ortalama doğruluk (0.9778) ve AUC (0.9976) değerleri elde etmiş olsa da (0.9333 ve 0.9935), bu farkın katma değeri, açıklanabilirlik puanlarıyla ilişkilendirildiğinde daha belirgin hâle gelmektedir. Örneğin, DeiT'in en düşük f1-skorunu 0.8421 verdiği Tüp sınıfı, öznetelik çıkarım yöntemleri arasında daha yüksek silme puanlarıyla da örtüşmektedir (Grad-CAM =

0.6008, Grad-CAM-LRP = 0.5936). Bu durum, DeiT'in bu sınıftaki kestirimlerinin daha geniş veya daha az ayırt edici bölgelere dayandığını ve dolayısıyla sağlamlığının azaldığını düşündürmektedir. Buna karşılık ViT, daha düşük ortalama silme (LRP-AR=0.3008) ve daha yüksek ekleme değerleri (AR=0.8864, LRP = 0.8865) ile daha tutarlı bir performans sergileyerek, daha kararlı ve anlamsal olarak anlamlı özelliklere odaklandığını göstermektedir.

Ayrıca LRP temelli yöntemler, tutarlı biçimde en elverişli dengeyi sağlamış ve en düşük silme (LRP-AR için 0.3008) ve en yüksek ekleme puanlarını (LRP-AR için 0.8918) üretmiştir. Üstün sınıflandırma ölçütleri (ör. ViT için efüzyon sınıfında 0.9730 ve Normal sınıfında 1.000 f1-skoru) ile güçlü nedensel yorumlanabilirlik sonuçları arasındaki bu hizalanma, ViT'in yalnızca nicel olarak daha iyi performans göstermekle kalmayıp aynı zamanda kararlarını görüntüler içindeki daha güvenilir kanıtlara dayandırıldığını ortaya koymaktadır. Bu bulgular, AYZ yöntemlerinin değerlendirilmesinin yalnızca görsel açıklanabilirlik değil; aynı zamanda sağlam nedensel ölçütlere de dayandırıldığını güvence altına almaktadır ve hibrit yaklaşımın model kestirimleri için en etkili görüntü bölgelerini vurgulamadaki güvenilirliğini güçlendirmektedir. Model doğruluğu ve açıklanabilirlik boyutlarında gözlenen bu tutarlılık, ViT'in şeffaflık ve güvenilirliğin kritik olduğu klinik uygulamalara özel uygunluğunu vurgulamaktadır. Bu durum, Şekil 4.6'da sunulan t-SNE ve UMAP görselleştirmelerinde de açıkça görülmektedir. Sınıflar arasındaki ayrışma belirgin biçimde ortaya çıkmaktadır. Şekil 4.7(a) ve 4.7(b)'de, TM'nin tamamının net görülebildiği için efüzyon sınıfından örnek bir görüntü sunulmuştur. Şekil 4.7(a)'da Grad-CAM, LRP ve AR'nin karşılaştırmalı değerlendirmesi, LRP'nin TM üzerinde en odaklı dikkati sağladığını; LRP-AR hibritinin ise en iyi ROI odaklanmasını sunduğunu göstermektedir. Özellikle GT işaretlemeleriyle vurgulanan efüzyon bölgelerinde, LRP tabanlı yaklaşımların silme ve ekleme ölçütleriyle uyumlu biçimde daha kararlı davrandığı görülmektedir. Şekil 4.7(b)'de özgün görüntüler, karşılık gelen AYZ ısı haritalarıyla üst üste bindirilerek görsel karşılaştırma sunulmuştur. AR'nin TM dışına doğru yayılma eğilimi gösterdiği ve ROI'yi yeterince yerleştiremediği ve Grad-CAM'in ise ilgisiz bölgeleri vurguladığı gözlenmektedir. Buna karşılık LRP, daha tutarlı ve kompakt bir odaklanma

sergileyerek klinik açıdan anlamlı bölgeleri yakalamadaki güvenilirliğini pekiştirmektedir.

LRP ve AR tek başlarına uygulandığında karşılaştırılabilir sonuçlar üretmiş olsalar da bunların hibrit bir yöntem olarak birleştirilmesi TM veri kümesi genelinde en tutarlı ve üstün performansı sağlamıştır. Özel olarak LRP-AR, bütün diğer açıklanabilirlik yöntemlerinden daha iyi olacak şekilde en düşük ortalama silme (0.3008) ve en yüksek ortalama ekleme (0.8918) puanlarını elde etmiştir. Bu durum, hibrit yöntemin model kestirimleri açısından en bilgi taşıyan görüntü bölgelerini belirlemede ve korumada daha etkili olduğunu göstermektedir. Tekil yöntemler arasında AR'nin en düşük silme değerine (0.3198) ulaştığı ve LRP'nin rekabetçi ekleme performansı (0.8865) sergilediği görülse de bu iki yaklaşımın tamamlayıcı özellikleri birlikte kullanıldığında belirginleşmektedir. AR, küresel bağlamsal bilgiyi daha geniş bir haritalama ile ortaya koyarken [98] LRP, ilgililik korunumu ilkesine dayalı olarak katmanlar boyunca ince taneli, piksel düzeyinde atıflar üretmektedir [97]. Bu iki perspektifin yaratıcı birleşimi, hibrit LRP-AR çerçevesinin küresel ve yerel açıklama düzeyleri arasında köprü kurmasına ve hem anlamsal açıdan anlamlı hem de mekânsal olarak hassas ısı haritaları üretmesine olanak tanımaktadır. Buna karşılık, Grad-CAM ve onun hibrit varyantları daha yüksek silme değerleri (Grad-CAM için 0.3497 ve Grad-CAM-LRP için 0.3523) sergilemiş ve ekleme puanları LRP-AR'nin gerisinde kalmıştır. Bu durum, Grad-CAM tabanlı yaklaşımların daha az ayırt edici ya da ilgisiz bölgeleri vurgulama eğiliminde olduğunu ve TM görüntülerinde bulunan ince efüzyon örüntülerini yakalama kapasitelerini sınırladığını düşündürmektedir. Birlikte ele alındığında, bu bulgular LRP ve AR'nin birleştirilmesinin değerini vurgulamaktadır. Söz konusu entegrasyon, otoskopik görüntülemelerde dönüşüm tabanlı sınıflandırma için daha güvenilir bir açıklanabilir çerçeve sunmaktadır.

Tez çalışmasının bu kısmı literatürde birkaç temel noktada ayrılmaktadır. Birincisi, yalnızca pediatrik popülasyonlara odaklanan çalışmalardan [61] farklı olarak bu çalışmada kullanılan veri seti hem yetişkin hem de pediatrik otoskopik görüntüleri içermekte olup modelin farklı yaş gruplarına uygulanabilirliğini artırmaktadır. İkincisi, önceki çalışmaların sıklıkla ikili sınıflandırmaya [10], [63] dayanmasına

karşın, burada benimsenen çok sınıflı sınıflandırma, daha geniş bir TM durum yelpazesini kapsamakta ve daha zorlayıcı ancak gerçekçi bir değerlendirme çerçevesi sunmaktadır. Üçüncüsü, açıklanabilirlik yöntemlerinin nedensel etki analizi ve karşı-olgusal değerlendirmelerle birlikte entegrasyonu, çalışmalarını esasen CAM veya Grad-CAM görselleştirmelerine dayandıran [61], [68] gibi çalışmalardan ayrılmaktadır. Bu yaklaşım, yanlış sınıflandırmaların daha derinlemesine incelenmesini mümkün kılarak klinisyen güvenini artırmakta ve modelin klinik karar destek sistemlerine uygunluğunu güçlendirmektedir. Tüm bunlarında yanında çalışmada kullanılan otoskopik veri seti hem yetişkin hem de pediatrik popülasyonu içerse de örneklem büyüklüğü ve veri kaynaklarının çeşitliliği sınırlıdır. Görüntüler tek veya az sayıda merkezden elde edildiği için, farklı cihazlar, ışık koşulları ve çekim protokollerinden kaynaklanabilecek varyasyonlar modele tam olarak yansımamış olabilir. Bu durum, modelin genellenebilirliğini ve farklı klinik koşullarda performansını kısıtlayabilir. Ayrıca model yalnızca statik otoskopik görüntüler üzerinde eğitilmiş ve değerlendirilmiştir. Video-temelli yaklaşımlar zamansal bilgiyi (ör. efüzyonun sıvı hareketi) yakalayabildiği hâlde, bu çalışmada o dinamik bilgi değerlendirme dışı kalmıştır. Bu durum, açıklanabilirlik analizinin zaman boyutunda sınırlı kalmasına neden olabilir.

3 farklı AYZ yöntemi ve bunların hibrit kombinasyonları kullanılmış olsa da daha farklı açıklanabilirlik yaklaşımları değerlendirmeye dahil edilmemiştir. LRP-AR hibrit yaklaşımı güçlü sonuçlar üretse de, yöntemin uygulanması çok katmanlı hesaplama adımları, KKA işlemleri ve çoklu ısı haritası füzyonu gerektirmektedir. Bu da yöntemin klinik entegrasyonunu zorlaştırabilir ve gerçek zamanlı karar destek sistemlerinde kullanımı için ek optimizasyon gerektirebilir. Bu bağlamda kullanılan nedensel değerlendirme için sadece tek metrik türü kullanılmıştır. Diğer metriklerin de çalışmaya dahil edilmesi modelin açıklanabilirliği çok boyutlu olarak doğrulama imkânı sağlayabilirdi.

Sonuç olarak yöntem umut verici bulgular üretmekle birlikte, dönüşüm tabanlı modellerin aşırı uyumu sınırlamak için çoğunlukla geniş ölçekli veri gerektirmesi, TM sınıflandırması gibi düşük kaynaklı ortamlarda uygulanabilirliği kısmen kısıtlayabilir. Bununla beraber, bu tezde önerilen çerçeve, TM görüntülerinde

sınıflandırma başarımını artırmanın yanı sıra, nicel olarak doğrulanmış ve sağlam bir açıklanabilir altyapı sunmaktadır. Elde edilen sonuçlar, hibrit AYZ yaklaşımının dönüşüm temelli modellerin şeffaflığını ve klinik güvenilirliğini TM sınıflandırması bağlamında anlamlı ölçüde güçlendirdiğini göstermektedir.

Tablo 4.18 Otoskop verileri için tez kapsamında yararlanılan güncel literatür çalışmaları

Yazar	Veri Türü	Yöntem	Açıklanabilirlik	Performans
Wu vd. (2021)	3 sınıflı(AOM-OME-Normal)	Xception, MobileNet-V2	Nesne algılama açıklamaları	%97.45
Elabbas vd. (2021)	AOM ve CSOM görüntüleri	YOLOv3	-	%75
Habib vd. (2023)	Çok merkezli TM görüntüleri	EfficientNet, ResNet	-	%76
Alhudhaif vd. (2021)	5 sınıflı TM görüntüleri	ESA + CBAM+ Hiper kolon	-	%98.26
Akyol vd. (2024)	3 sınıflı TM görüntüleri	Topluluk öğrenmeleri	-	%98.8
Sundgaard vd. (2021)	AOM, OME ve Normal sınıf görüntüleri	Metrik öğrenme	-	Yüksek doğruluk
Çamalan vd. (2020)	Tezde kullanılan veri seti (3 sınıflı)	ESA gömme	-	%80.58
Cai vd. (2021)	OME odaklı	ResNet-50	CAM	%93.4
Byun vd. (2021)	Çoklu TM veri seti	ResNet- 18+Shuffle	-	%93
Choi vd (2022)	Çoklu TM veri seti	EfficientNet-B4	-	%95
Shaik vd. (2022)	Telefondan kaydedilmiş AOM odaklı görüntüler	Residual RNN	-	%93
Binol vd. (2022)	Özel video verisi	OtoXNet	-	%84.8
Hao vd. (2025)	Özel video verisi	VideoMAE	-	%92

5. SONUÇLAR VE ÖNERİLER

Bu tez çalışması, dönüşüm tabanlı DÖ modellerinin klinik patoloji ve medikal görüntüleme alanlarında sınıflandırma ve açıklanabilirlik boyutundaki potansiyelini sistematik biçimde değerlendirmeyi amaçlamıştır. Çalışma, iki farklı klinik senaryo üzerinde yürütülmüş, her biri özgün veri kümeleri, dönüşüm tabanlı mimariler ve AYZ yöntemleriyle kapsamlı biçimde ele alınmıştır. Tez genelinde hem sınıflandırma başarımı hem de model açıklanabilirliği, klinik karar desteği açısından bütüncül bir çerçevede değerlendirilmiştir. Bu kapsamda, tezin ilk aşamasında patoloji temelli bir değerlendirme çerçevesi benimsenmiş; farklı organlara ait veri setlerine erişilerek çeşitli doku tiplerinde gözlenen kötücül dokuların otomatik sınıflandırılması gerçekleştirilmiştir. Dönüşüm tabanlı DÖ mimarileri sistematik biçimde karşılaştırıldığında, FNet mimarisinin hem hesaplama verimliliği (daha az ayarlanabilir parametre ve yüksek işlem hızı) hem de tanısal başarımları açısından öne çıktığı gözlenmiştir. Nitekim FNet, incelenen deney düzeneklerinde akciğer ve kolon verileri üzerinde %100 doğruluk düzeyine ulaşarak, değerlendirmeye alınan alternatif DÖ mimarilerine kıyasla en hızlı ve en işlevsel çözümü sunmuştur. Bu bulgu, FNet'in patoloji görüntülerinde sınıflar arası ayırt edici örüntüleri etkin biçimde yakalayabildiğini ve klinik iş akışlarında gerçek-zamanlı kullanım için güçlü bir aday olduğunu göstermektedir. Bununla birlikte, söz konusu performansın genellenebilirliğinin farklı cihazlardan ve örnekleme stratejilerinden elde edilecek daha geniş ve heterojen hasta gruplarında ilave doğrulama çalışmalarıyla desteklenmesi, yöntemin klinik ölçeğe taşınmasında kritik önemdedir. Tezin esas odağını oluşturan AYZ kısmında ise literatürde nadiren görülen bir biçimde, patolog yorumları ile LIME tabanlı açıklamalar birlikte kullanılarak doğru ve yanlış sınıflandırmaların eş zamanlı olarak incelenmesi sağlanmıştır. Bu yaklaşım, modelin karar mantığını hem nitel hem de nicel (LIME işaretlemeleri) kanıtlarla görünür kılarak tezin patoloji bileşenine anlamlı bir değer ve yenilik katmıştır. Ayrıca klinik geçerlilik ve güvenilirlik açısından yorumların çapraz doğrulanmasına imkân tanımıştır.

Tezin ikinci aşamasında, iki farklı modaliteden elde edilen veri kümeleri üzerinde aynı işlem hattı izlenmiştir. Bunlardan ilki, son yıllarda dünya genelinde yeniden önem kazanan maymun çiçeği (deri lezyon görüntüleri) verisi; diğeri ise çocukluktan

yetişkinliğe uzanan geniş bir yaş aralığını etkileyen kulak zarı hastalıkları verisidir. Her iki alanda da klinik pratikte bazı hastalık türleri sıklıkla birbiriyle karıştırılmakta ve doğru tanı güçleşebilmektedir. Bu nedenle, bilgisayar destekli tanı sistemleri son yıllarda giderek daha kritik bir rol üstlenmektedir. Çalışmada dönüşüm tabanlı sınıflandırma çerçevesinde yüksek doğruluk performansı ile öne çıkan ViT modeli, her iki veri kümesi üzerinde de başarılı sonuçlar vermiştir. Maymun çiçeği veri setinde, karmaşıklık matrisi temelli hesaplamalara göre maymun çiçeği sınıfının sınıf-doğruluğu yaklaşık %96 olarak elde edilmiştir. Kulak zarı veri setinde ise hastalık sınıflarından efüzyon %100 doğrulukla sınıflandırılmıştır. Bu bulgular, önerilen dönüşüm tabanlı yaklaşımın hem deri lezyonu hem de otoskopik görüntülerde yüksek ayırt edicilik ve klinik açıdan anlamlı bir tanısal performans sunduğunu göstermektedir. AYZ yaklaşımları bağlamında, bu tez çalışmasında açıklanabilir metotların irdelenmesi amacıyla 3 farklı metot uygulanmış ve her biri modelin karar mekanizmalarını farklı boyutlardan ortaya koymak üzere değerlendirilmiştir. Kullanılan bu yöntemler kapsamında, maymun çiçeği verileri için TBA tabanlı yeni bir hibrit açıklama yaklaşımı önerilmiş; kulak zarı verileri için ise özgün bir yaklaşımla KKA temelli hibrit açıklama haritaları geliştirilmiştir. Bu sayede her iki veri kümesinde de modelin dikkat ettiği bölgeler, farklı açıklanabilirlik yöntemlerinin birleştirilmesiyle daha tutarlı ve nedensel olarak yorumlanabilir biçimde görselleştirilmiştir. Bu çalışmayı literatürden ayırtıran temel unsur, görsel açıklama haritalarının sunulmasıyla yetinilmeyip bu ısı haritalarının matematiksel olarak da doğrulanması ve nedensel metriklerle (ekleme ve silme) nicel biçimde değerlendirilmesidir. Bu yaklaşım, mevcut tez çalışmasının bilimsel geçerliliğine ve klinik güvenilirliğine kayda değer bir katkı sağlamıştır.

İleriki dönemlerde, bu tezde kullanılan veri setlerine ek olarak daha geniş ölçekli ve çok merkezli verilerin dahil edilmesi; cihaz, çekim protokolü, yaş grubu ve patolojik varyasyon açısından yüksek çeşitliliğe sahip örneklerle modelin genellenebilirliğinin artırılması hedeflenmektedir. Bu doğrultuda, dönüşüm tabanlı mimarilerde öznitelik çıkarım katmanlarının güncellenmesi (ör. daha derin çoklu-kafa dikkat modülleri, çok-ölçekli temsil ve ince ayarlı ön-eğitim stratejileri), düşük maliyetli ve hızlı çalışan alternatif sınıflandırıcıların (ör. hafif MLP/DVM tabanlı başlıklar, bilgi damıtma ile hızlandırılmış çözümler) sistematik karşılaştırması ve klinik iş akışına

uygun senaryoların deęerlendirilmesi planlanmaktadır. AYZ tarafında, mevcut yöntemlerin dayanıklılık ve tutarlılık açılarından iyileştirilmesi; farklı yöntemlerin hibritleştirilmesi (ör. LRP–Grad-CAM++, AR–IG, karşı-olgusal + dikkat yayılımı) ve bu hibritlerin matematiksel olarak çoklu nedensel metriklerle (yalnızca silme/ekleme deęil, yeterlilik/gereklilik, silme–ekleme AUC, sadakat/doęruluk, kapsayıcılık, anlamsal uygunluk vb.) nicel doęrulanması öngörülmektedir. Bu çerçevede, klinisyenlerin gereksinimlerine yönelik kullanıcı merkezli raporlama ve karar desteęinin şeffaflığı artırılacaktır. Sonuç olarak geniş ve heterojen veri, güncellenmiş öznitelik çıkarımı, hesapça verimli sınıflandırıcılar, gelişmiş/hibrit AYZ ve zengin nedensel metriklerin birlikte ele alınmasıyla; klinisyenler ve medikal alanda çalışan araştırmacılar için hızlı, güvenilir ve açıklanabilir hastalık tespiti yolları sunan taşınabilir ve ölçeklenebilir bir karar destek altyapısı geliştirilmesi amaçlanmaktadır.

KAYNAKLAR

- [1] D. Crosby *et al.*, “Early detection of cancer,” *Science* (80-.), vol. 375, no. 6586, p. eaay9040, 2022, doi: 10.1126/science.aay9040.
- [2] K. M. Harmes, R. A. Blackwood, H. L. Burrows, J. M. Cooke, R. Van Harrison, and P. P. Passamani, “Otitis media: diagnosis and treatment.,” *Am. Fam. Physician*, vol. 88, no. 7, pp. 435–40, Oct. 2013, [Online]. Available: <http://www.ncbi.nlm.nih.gov/pubmed/24134083>
- [3] A. Catala, J. Riera, and I. Fuertes, “[Translated article] Mpox - - Formerly Monkey Pox - - in Dermatology : A Review of Epidemiologic Features , Clinical Presentation , Diagnosis , and Treatment,” *Actas dermosifiliogriáficas*, vol. 114, no. 4, pp. T318–T326, 2023, doi: 10.1016/j.ad.2023.02.012.
- [4] R. M. Rosenfeld *et al.*, “Clinical Practice Guideline: Otitis Media with Effusion (Update),” *Otolaryngol. Neck Surg.*, vol. 154, no. S1, Feb. 2016, doi: 10.1177/0194599815623467.
- [5] D. Collaborators, “Global , regional , and national life expectancy , all-cause mortality , and cause-specific mortality for 249 causes of death , 1980 – 2015 : a systematic analysis for the Global Burden of Disease Study 2015,” pp. 1980–2015, 2017, doi: 10.1016/S0140-6736(16)31012-1.
- [6] A. S. Lieberthal *et al.*, “The Diagnosis and Management of Acute Otitis Media,” *Pediatrics*, vol. 131, no. 3, pp. e964–e999, Mar. 2013, doi: 10.1542/peds.2012-3488.
- [7] C. Bladder *et al.*, “Bladder Cancer Early Detection , Diagnosis , and Staging Can Bladder Cancer Be Found Early,” *Am. Cancer Soc.*, no. cancer.org, pp. 1–24, 2023, [Online]. Available: <https://www.cancer.org/content/dam/CRC/PDF/Public/8661.00.pdf>
- [8] G. Litjens *et al.*, “A survey on deep learning in medical image analysis,” *Med. Image Anal.*, vol. 42, pp. 60–88, Dec. 2017, doi: 10.1016/j.media.2017.07.005.
- [9] A. Esteva *et al.*, “Dermatologist-level classification of skin cancer with deep neural networks,” *Nature*, vol. 542, no. 7639, pp. 115–118, Feb. 2017, doi: 10.1038/nature21056.
- [10] E. Başaran, Z. Cömert, and Y. Çelik, “Convolutional neural network approach for automatic tympanic membrane detection and classification,” *Biomed. Signal Process. Control*, vol. 56, p. 101734, Feb. 2020, doi: 10.1016/j.bspc.2019.101734.
- [11] R. R. Wahid, C. Nisa’, R. P. Amaliyah, and E. Y. Puspaningrum, “Lung and colon cancer detection with convolutional neural networks on histopathological images,” *AIP Conf. Proc.*, vol. 2654, no. 1, p. 20020, Feb. 2023, doi: 10.1063/5.0114327.
- [12] W. Luo, Y. Li, R. Urtasun, and R. Zemel, “Understanding the Effective Receptive Field in Deep Convolutional Neural Networks,” Jan. 2017, [Online]. Available: <http://arxiv.org/abs/1701.04128>
- [13] S. Prasad *et al.*, “A dermatologic assessment of 101 mpox (monkeypox) cases from 13 countries during the 2022 outbreak: Skin lesion morphology, clinical course, and scarring,” *J. Am. Acad. Dermatol.*, vol. 88, no. 5, pp. 1066–1073, May 2023, doi: 10.1016/j.jaad.2022.12.035.

- [14] A. Dosovitskiy, L. Beyer, A. Kolesnikov, and D. Weissenborn, “An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale,” in *ICLR 2021*, 2021.
- [15] D. Minh, H. X. Wang, Y. F. Li, and T. N. Nguyen, *Explainable artificial intelligence: a comprehensive review*, vol. 55, no. 5. Springer Netherlands, 2022. doi: 10.1007/s10462-021-10088-y.
- [16] A. Das and P. Rad, “Opportunities and Challenges in Explainable Artificial Intelligence (XAI): A Survey,” Jun. 2020, [Online]. Available: <http://arxiv.org/abs/2006.11371>
- [17] A. Das and P. Rad, “Opportunities and Challenges in Explainable Artificial Intelligence {(XAI):} {A} Survey,” *CoRR*, vol. abs/2006.1, 2020, [Online]. Available: <https://arxiv.org/abs/2006.11371>
- [18] J. Adebayo, J. Gilmer, M. Muelly, I. Goodfellow, M. Hardt, and B. Kim, “Sanity Checks for Saliency Maps,” Nov. 2020, [Online]. Available: <http://arxiv.org/abs/1810.03292>
- [19] V. Petsiuk and K. Saenko, “arXiv: 1806 . 07421v3 [cs . CV] 25 Sep 2018 RISE : Randomized Input Sampling for Explanation of Black-box Models,” vol. 1, 2018.
- [20] B. F. Ferlay J, Ervik M, Lam F, Laversanne M, Colombet M, Mery L, Piñeros M, Znaor A, Soerjomataram I, “WHO.” [Online]. Available: <https://gco.iarc.who.int>
- [21] H. Sung *et al.*, “Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries,” *CA. Cancer J. Clin.*, vol. 71, no. 3, pp. 209–249, May 2021, doi: 10.3322/caac.21660.
- [22] P. L. Nunez and R. Srinivasan, “A theoretical basis for standing and traveling brain waves measured with human EEG with implications for an integrated consciousness,” *Clin. Neurophysiol.*, vol. 117, no. 11, pp. 2424–2435, 2006, doi: 10.1016/j.clinph.2006.06.754.
- [23] K. Kurishima *et al.*, “Lung cancer patients with synchronous colon cancer,” *Mol. Clin. Oncol.*, pp. 137–140, 2017, doi: 10.3892/mco.2017.1471.
- [24] L. Succony, D. M. Rassl, A. P. Barker, F. M. McCaughan, and R. C. Rintoul, “Adenocarcinoma spectrum lesions of the lung: Detection, pathology and treatment strategies,” *Cancer Treat. Rev.*, vol. 99, no. May, p. 102237, 2021, doi: 10.1016/j.ctrv.2021.102237.
- [25] “U.S Preventive Services,” 30 April 2024. [Online]. Available: <https://www.uspreventiveservicestaskforce.org/uspstf/recommendation/breast-cancer-screening>
- [26] B. H. M. van der Velden, H. J. Kuijf, K. G. A. Gilhuijs, and M. A. Viergever, “Explainable artificial intelligence (XAI) in deep learning-based medical image analysis,” *Med. Image Anal.*, vol. 79, p. 102470, 2022, doi: 10.1016/j.media.2022.102470.
- [27] W. D. Travis, “Pathology of Lung Cancer,” *Clin. Chest Med.*, vol. 32, no. 4, pp. 669–692, 2011, doi: 10.1016/j.ccm.2011.08.005.
- [28] S. Huang, J. Yang, S. Fong, and Q. Zhao, “Artificial intelligence in cancer diagnosis and prognosis: Opportunities and challenges,” *Cancer Lett.*, vol. 471, no. December 2019, pp. 61–71, 2020, doi: 10.1016/j.canlet.2019.12.007.
- [29] World Health Organization (WHO), “Mpox.” [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/mpox>

- [30] mayoclinic, “Mpox (monkeypox): What is it and how can it be prevented?” [Online]. Available: <https://www.mayoclinic.org/diseases-conditions/infectious-diseases/expert-answers/monkeypox-faq/faq-20533608>
- [31] M. W. McCarthy, “Recent advances in the diagnosis monkeypox : implications for public health ARTICLE HISTORY,” *Expert Rev. Mol. Diagn.*, vol. 00, no. 00, pp. 1–6, 2022, doi: 10.1080/14737159.2022.2116979.
- [32] Z. Li, K. C. Koban, T. L. Schenck, R. E. Giunta, Q. Li, and Y. Sun, “Artificial Intelligence in Dermatology Image Analysis: Current Developments and Future Trends,” *J. Clin. Med.*, vol. 11, no. 22, 2022, doi: 10.3390/jcm11226826.
- [33] World Health Organization (WHO), “Deafness and hearing loss.” [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/deafness-and-hearing-loss>
- [34] M. C. Staff, “Ear infection (middle ear).” [Online]. Available: <https://www.mayoclinic.org/diseases-conditions/ear-infections/symptoms-causes/syc-20351616>
- [35] M. Daniel, A. Qureishi, Y. Lee, K. Belfield, and J. Birchall, “Update on otitis media – prevention and treatment,” *Infect. Drug Resist.*, p. 15, Jan. 2014, doi: 10.2147/IDR.S39637.
- [36] M. E. Pichichero, “Acute otitis media: Part I. Improving diagnostic accuracy,” *Am. Fam. Physician*, vol. 61, no. 7, pp. 2051–6, Apr. 2000, [Online]. Available: <http://www.ncbi.nlm.nih.gov/pubmed/10779248>
- [37] M. E. Pichichero and M. D. Poole, “Assessing Diagnostic Accuracy and Tympanocentesis Skills in the Management of Otitis Media,” *Arch. Pediatr. Adolesc. Med.*, vol. 155, no. 10, p. 1137, Oct. 2001, doi: 10.1001/archpedi.155.10.1137.
- [38] J. Sandström, H. Myburgh, C. Laurent, D. W. Swanepoel, and T. Lundberg, “A Machine Learning Approach to Screen for Otitis Media Using Digital Otoscope Images Labelled by an Expert Panel,” *Diagnostics*, vol. 12, no. 6, p. 1318, May 2022, doi: 10.3390/diagnostics12061318.
- [39] A. Habib *et al.*, “Artificial intelligence to classify ear disease from otoscopy: A systematic review and meta-analysis,” *Clin. Otolaryngol.*, vol. 47, no. 3, pp. 401–413, May 2022, doi: 10.1111/coa.13925.
- [40] S. Ngombu, H. Binol, M. N. Gurcan, and A. C. Moberly, “Advances in Artificial Intelligence to Diagnose Otitis Media: State of the Art Review,” *Otolaryngol. Neck Surg.*, vol. 168, no. 4, pp. 635–642, Apr. 2023, doi: 10.1177/01945998221083502.
- [41] M. S. N. Raju and B. S. Rao, “Classification of Colon and Lung Cancer through Analysis of Histopathology Images Using Deep Learning Models,” *Ing. des Syst. d’Information*, vol. 27, no. 6, pp. 967–971, 2022, doi: 10.18280/isi.270613.
- [42] S. Tummala, S. Kadry, A. Nadeem, H. T. Rauf, and N. Gul, “An Explainable Classification Method Based on Complex Scaling in Histopathology Images for Lung and Colon Cancer,” *Diagnostics*, vol. 13, no. 9, 2023, doi: 10.3390/diagnostics13091594.
- [43] M. S. Ahmed, K. N. Iqbal, and M. G. R. Alam, “Interpretable Lung Cancer Detection using Explainable AI Methods,” in *2023 International Conference for Advancement in Technology (ICONAT)*, 2023, pp. 1–6. doi: 10.1109/ICONAT57137.2023.10080480.

- [44] D. Kaplun, A. Krasichkov, P. Chetyrbok, N. Oleinikov, A. Garg, and H. S. Pannu, "Cancer Cell Profiling Using Image Moments and Neural Networks with Model Agnostic Explainability: A Case Study of Breast Cancer Histopathological (BreakHis) Database," *Mathematics*, vol. 9, no. 20, 2021, doi: 10.3390/math9202616.
- [45] O. G. E. and F. O. C. Francis A. U. Imouokhome, "Diagnosis and Interpretation of Breast Cancer Using Explainable Artificial Intelligence," *NIPES - J. Sci. Technol. Res.*, vol. 5, no. 2 SE-Articles, Jun. 2023, doi: 10.5281/zenodo.8014197.
- [46] T. Aitazaz, A. Tubaishat, F. Al-Obeidat, B. Shah, T. Zia, and A. Tariq, "Transfer learning for histopathology images: an empirical study," *Neural Comput. Appl.*, vol. 35, no. 11, pp. 7963–7974, 2023, doi: 10.1007/s00521-022-07516-7.
- [47] M. Ali and R. Ali, "Multi-Input Dual-Stream Capsule Network for Improved Lung and Colon Cancer Classification," *Diagnostics*, vol. 11, no. 8, 2021, doi: 10.3390/diagnostics11081485.
- [48] N. Kumar, M. Sharma, V. P. Singh, C. Madan, and S. Mehandia, "An empirical study of handcrafted and dense feature extraction techniques for lung and colon cancer classification from histopathological images," *Biomed. Signal Process. Control*, vol. 75, p. 103596, 2022, doi: <https://doi.org/10.1016/j.bspc.2022.103596>.
- [49] M. A. Talukder, M. M. Islam, M. A. Uddin, A. Akhter, K. F. Hasan, and M. A. Moni, "Machine learning-based lung and colon cancer detection using deep feature extraction and ensemble learning," *Expert Syst. Appl.*, vol. 205, p. 117695, 2022, doi: <https://doi.org/10.1016/j.eswa.2022.117695>.
- [50] İ. Sayın *et al.*, "Comparative Analysis of Deep Learning Architectures for Breast Cancer Diagnosis Using the BreakHis Dataset," Sep. 2023, doi: arXiv:2309.01007.
- [51] M. M. Ahsan *et al.*, "Monkeypox Diagnosis With Interpretable Deep Learning," *IEEE Access*, vol. 11, pp. 81965–81980, 2023, doi: 10.1109/ACCESS.2023.3300793.
- [52] A. D. Raha *et al.*, "Attention to Monkeypox: An Interpretable Monkeypox Detection Technique Using Attention Mechanism," *IEEE Access*, vol. 12, pp. 51942–51965, 2024, doi: 10.1109/ACCESS.2024.3385099.
- [53] L. Muñoz-Saavedra, E. Escobar-Linero, J. Civit-Masot, F. Luna-Perejón, A. Civit, and M. Domínguez-Morales, "A Robust Ensemble of Convolutional Neural Networks for the Detection of Monkeypox Disease from Skin Images," *Sensors*, vol. 23, no. 16, 2023, doi: 10.3390/s23167134.
- [54] T. Nayak *et al.*, "Deep learning based detection of monkeypox virus using skin lesion images," *Med. Nov. Technol. Devices*, vol. 18, no. March, p. 100243, 2023, doi: 10.1016/j.medntd.2023.100243.
- [55] D. Kundu *et al.*, "Federated Deep Learning for Monkeypox Disease Detection on GAN-Augmented Dataset," *IEEE Access*, vol. 12, no. March, pp. 32819–32829, 2024, doi: 10.1109/ACCESS.2024.3370838.
- [56] C. Sitaula and T. Bahadur, "Monkeypox Virus Detection Using Pre - trained Deep Learning - based Approaches," *J. Med. Syst.*, 2022, doi: 10.1007/s10916-022-01868-2.
- [57] E. M. Abdelrahim, H. Hashim, E.-S. Atlam, R. A. Osman, and I. Gad, "TMS: Ensemble Deep Learning Model for Accurate Classification of Monkeypox

- Lesions Based on Transformer Models with SVM,” *Diagnostics*, vol. 14, no. 23, 2024, doi: 10.3390/diagnostics14232638.
- [58] M. E. Haque, M. R. Ahmed, R. S. Nila, and S. Islam, “Classification of Human Monkeypox Disease Using Deep Learning Models and Attention Mechanisms,” 2022, [Online]. Available: <http://arxiv.org/abs/2211.15459>
 - [59] F. Uysal, “Detection of Monkeypox Disease from Human Skin Images with a Hybrid Deep Learning Model,” *Diagnostics*, vol. 13, no. 10, 2023, doi: 10.3390/diagnostics13101772.
 - [60] M. Altun, H. Gürüler, O. Özkaraca, F. Khan, J. Khan, and Y. Lee, “Monkeypox Detection Using CNN with Transfer Learning,” *Sensors*, vol. 23, no. 4, 2023, doi: 10.3390/s23041783.
 - [61] Z. Wu *et al.*, “Deep Learning for Classification of Pediatric Otitis Media,” *Laryngoscope*, vol. 131, no. 7, Jul. 2021, doi: 10.1002/lary.29302.
 - [62] A. I. Elabbas, K. K. Khan, and C. C. Hortinela, “Classification of Otitis Media Infections using Image Processing and Convolutional Neural Network,” in *2021 IEEE 13th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM)*, IEEE, Nov. 2021, pp. 1–6. doi: 10.1109/HNICEM54116.2021.9732013.
 - [63] A.-R. Habib *et al.*, “Evaluating the generalizability of deep learning image classification algorithms to detect middle ear disease using otoscopy,” *Sci. Rep.*, vol. 13, no. 1, p. 5368, Apr. 2023, doi: 10.1038/s41598-023-31921-0.
 - [64] A. Alhudhaif, Z. Cömert, and K. Polat, “Otitis media detection using tympanic membrane images with a novel multi-class machine learning algorithm,” *PeerJ Comput. Sci.*, vol. 7, p. e405, Feb. 2021, doi: 10.7717/peerj-cs.405.
 - [65] K. Akyol, E. Uçar, Ü. Atila, and M. Uçar, “An ensemble approach for classification of tympanic membrane conditions using soft voting classifier,” *Multimed. Tools Appl.*, vol. 83, no. 32, pp. 77809–77830, Feb. 2024, doi: 10.1007/s11042-024-18631-z.
 - [66] J. V. Sundgaard *et al.*, “Deep metric learning for otitis media classification,” *Med. Image Anal.*, vol. 71, p. 102034, Jul. 2021, doi: 10.1016/j.media.2021.102034.
 - [67] S. Camalan *et al.*, “OtoMatch: Content-based eardrum image retrieval using deep learning,” *PLoS One*, vol. 15, no. 5, pp. 1–16, 2020, doi: 10.1371/journal.pone.0232776.
 - [68] Y. Cai *et al.*, “Investigating the use of a two-stage attention-aware convolutional neural network for the automated diagnosis of otitis media from tympanic membrane images: a prediction model development and validation study,” *BMJ Open*, vol. 11, no. 1, p. e041139, Jan. 2021, doi: 10.1136/bmjopen-2020-041139.
 - [69] H. Byun *et al.*, “An Assistive Role of a Machine Learning Network in Diagnosis of Middle Ear Diseases,” *J. Clin. Med.*, vol. 10, no. 15, p. 3198, Jul. 2021, doi: 10.3390/jcm10153198.
 - [70] Y. Choi, J. Chae, K. Park, J. Hur, J. Kweon, and J. H. Ahn, “Automated multi-class classification for prediction of tympanic membrane changes with deep learning models,” *PLoS One*, vol. 17, no. 10, p. e0275846, Oct. 2022, doi: 10.1371/journal.pone.0275846.
 - [71] N. Shaikh *et al.*, “Development and Validation of an Automated Classifier to Diagnose Acute Otitis Media in Children,” *JAMA Pediatr.*, vol. 178, no. 4, p.

- 401, Apr. 2024, doi: 10.1001/jamapediatrics.2024.0011.
- [72] H. Binol, M. K. K. Niazi, C. Elmaraghy, A. C. Moberly, and M. N. Gurcan, “OtoXNet—automated identification of eardrum diseases from otoscope videos: a deep learning study for video-representing images,” *Neural Comput. Appl.*, vol. 34, no. 14, pp. 12197–12210, Jul. 2022, doi: 10.1007/s00521-022-07107-6.
 - [73] H. Lu, S. Camalan, C. Elmaraghy, A. C. Moberly, and M. N. Gurcan, “A video classification method for diagnosing ear diseases using otoscope imaging,” in *Medical Imaging 2025: Computer-Aided Diagnosis*, S. M. Astley and A. Wismüller, Eds., SPIE, Apr. 2025, p. 117. doi: 10.1117/12.3046822.
 - [74] A. A. Borkowski, M. M. Bui, L. B. Thomas, C. P. Wilson, L. A. DeLand, and S. M. Mastorides, “Lung and Colon Cancer Histopathological Image Dataset (LC25000),” pp. 1–2, 2019.
 - [75] F. A. Spanhol, L. S. Oliveira, C. Petitjean, and L. Heutte, “A Dataset for Breast Cancer Histopathological Image Classification,” *IEEE Trans. Biomed. Eng.*, vol. 63, no. 7, pp. 1455–1462, 2016, doi: 10.1109/TBME.2015.2496264.
 - [76] S. N. Ali *et al.*, “Monkeypox Skin Lesion Detection Using Deep Learning Models: A Feasibility Study,” pp. 2–5, 2022, [Online]. Available: <http://arxiv.org/abs/2207.03342>
 - [77] O. Mitjà *et al.*, “Monkeypox,” *Lancet*, vol. 401, no. 10370, pp. 60–74, Jan. 2023, doi: 10.1016/S0140-6736(22)02075-X.
 - [78] H. M. Saleh, F. Ayoade, and S. Kumar, *Varicella-Zoster Virus (Chickenpox)*. 2025. [Online]. Available: <http://www.ncbi.nlm.nih.gov/pubmed/30103889>
 - [79] A. A. Minta *et al.*, “Progress Toward Measles Elimination — Worldwide, 2000–2023,” *MMWR. Morb. Mortal. Wkly. Rep.*, vol. 73, no. 45, pp. 1036–1042, Nov. 2024, doi: 10.15585/mmwr.mm7345a4.
 - [80] D. Bala, S. Hossain, and M. Alamgir, “MonkeyNet: A robust deep convolutional neural network for monkeypox disease detection and classification,” *Neural Networks*, vol. 161, pp. 757–775, 2023, doi: 10.1016/j.neunet.2023.02.022.
 - [81] Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, May 2015, doi: 10.1038/nature14539.
 - [82] A. Jiménez-Sánchez, S. Albarqouni, and D. Mateus, “Capsule Networks Against Medical Imaging Data Challenges,” 2018, pp. 150–160. doi: 10.1007/978-3-030-01364-6_17.
 - [83] M. Tan and Q. V. Le, “EfficientNet: Rethinking model scaling for convolutional neural networks,” *36th Int. Conf. Mach. Learn. ICML 2019*, vol. 2019-June, pp. 10691–10700, 2019.
 - [84] A. Vaswani, N. Shazeer, and N. Parmar, “Attention is All You Need,” in *31st Conference on Neural Information Processing Systems (NIPS)*, Long Beach, 2015.
 - [85] D. Hendrycks and K. Gimpel, “Gaussian Error Linear Units (GELUs),” pp. 1–10, 2016, [Online]. Available: <http://arxiv.org/abs/1606.08415>
 - [86] R. Azad *et al.*, “Advances in medical image analysis with vision Transformers: A comprehensive review,” *Med. Image Anal.*, vol. 91, p. 103000, 2024, doi: <https://doi.org/10.1016/j.media.2023.103000>.
 - [87] M. T. Ribeiro, S. Singh, and C. Guestrin, “‘Why Should I Trust You?’ Explaining the Predictions of Any Classifier,” *NAACL-HLT 2016 - 2016 Conf. North Am. Chapter Assoc. Comput. Linguist. Hum. Lang. Technol. Proc.*

- Demonstr. Sess.*, pp. 97–101, 2016, doi: 10.18653/v1/n16-3020.
- [88] L. Schallner, J. Rabold, O. Scholz, and U. Schmid, “Effect of Superpixel Aggregation on Explanations in LIME -- A Case Study with Biological Data,” Oct. 2019, [Online]. Available: <http://arxiv.org/abs/1910.07856>
 - [89] J. Lee-Thorp, J. Ainslie, I. Eckstein, and S. Ontañón, “FNet: Mixing Tokens with Fourier Transforms,” *NAACL 2022 - 2022 Conf. North Am. Chapter Assoc. Comput. Linguist. Hum. Lang. Technol. Proc. Conf.*, pp. 4296–4313, 2022, doi: 10.18653/v1/2022.naacl-main.319.
 - [90] O. Russakovsky *et al.*, “ImageNet Large Scale Visual Recognition Challenge,” *Int. J. Comput. Vis.*, vol. 115, no. 3, pp. 211 – 252, 2015, doi: 10.1007/s11263-015-0816-y.
 - [91] H. Touvron, M. Cord, M. Douze, F. Massa, A. Sablayrolles, and H. Jégou, “Training data-efficient image transformers & distillation through attention,” *Proc. Mach. Learn. Res.*, vol. 139, pp. 10347–10357, 2021.
 - [92] G. Maaten, Laurens van der; Hinton, “Visualizing Data using t-SNE,” *J. Mach. Learn. Res.*, vol. 9, pp. 2579–2605, 2008, [Online]. Available: <https://www.jmlr.org/papers/v9/vandemaaten08a.html>
 - [93] L. McInnes, J. Healy, and J. Melville, “UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction,” 2018, [Online]. Available: <http://arxiv.org/abs/1802.03426>
 - [94] V. Hassija *et al.*, “Interpreting Black-Box Models: A Review on Explainable Artificial Intelligence,” *Cognit. Comput.*, vol. 16, no. 1, pp. 45–74, 2024, doi: 10.1007/s12559-023-10179-8.
 - [95] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, “Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization,” in *2017 IEEE International Conference on Computer Vision (ICCV)*, 2017, pp. 618–626. doi: 10.1109/ICCV.2017.74.
 - [96] H. Chefer, S. Gur, and L. Wolf, “Transformer Interpretability Beyond Attention Visualization,” in *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2021, pp. 782–791. doi: 10.1109/CVPR46437.2021.00084.
 - [97] S. Bach, A. Binder, G. Montavon, and F. Klauschen, “On Pixel-Wise Explanations for Non-Linear Classifier Decisions by Layer-Wise Relevance Propagation,” pp. 1–46, 2015, doi: 10.1371/journal.pone.0130140.
 - [98] S. Abnar and W. Zuidema, “Quantifying Attention Flow in Transformers,” in *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*, D. Jurafsky, J. Chai, N. Schluter, and J. Tetreault, Eds., Online: Association for Computational Linguistics, 2020, pp. 4190–4197. doi: 10.18653/v1/2020.acl-main.385.
 - [99] “Principal Component Analysis for Special Types of Data,” in *Principal Component Analysis*, New York: Springer-Verlag, pp. 338–372. doi: 10.1007/0-387-22440-8_13.
 - [100] C. Molnar, *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable*. 2020. [Online]. Available: <https://christophm.github.io/interpretable-ml-book/>
 - [101] K.-R. Samek, Wojciech; Wiegand, Thomas; Müller, “Explainable Artificial Intelligence: Understanding, Visualizing and Interpreting Deep Learning Models,” 2017, doi: 10.48550/arXiv.1708.08296.
 - [102] V. Petsiuk, A. Das, and K. Saenko, “Rise: Randomized input sampling for

- explanation of black-box models,” *arXiv Prepr. arXiv1806.07421*, 2018.
- [103] D. R. Hardoon, S. Szedmak, and J. Shawe-Taylor, “Canonical Correlation Analysis: An Overview with Application to Learning Methods,” *Neural Comput.*, vol. 16, no. 12, pp. 2639–2664, Dec. 2004, doi: 10.1162/0899766042321814.
 - [104] S. Mangal, A. Chaurasia, and A. Khajanchi, “Convolution Neural Networks for diagnosing colon and lung cancer histopathological images.” 2020.
 - [105] S. Mehmood *et al.*, “Malignancy Detection in Lung and Colon Histopathology Images Using Transfer Learning With Class Selective Image Processing,” *IEEE Access*, vol. 10, pp. 25657–25668, 2022, doi: 10.1109/ACCESS.2022.3150924.
 - [106] J. Fan, J. Lee, and Y. Lee, “A Transfer Learning Architecture Based on a Support Vector Machine for Histopathology Image Classification,” *Appl. Sci.*, vol. 11, no. 14, 2021, doi: 10.3390/app11146380.
 - [107] K. Adu, Y. Yu, J. Cai, K. Owusu-Agyemang, B. A. Twumasi, and X. Wang, “DHS-CapsNet: Dual horizontal squash capsule networks for lung and colon cancer classification from whole slide histopathological images,” *Int. J. Imaging Syst. Technol.*, vol. 31, no. 4, pp. 2075–2092, 2021, doi: <https://doi.org/10.1002/ima.22569>.
 - [108] M. Masud, N. Sikder, A.-A. Nahid, A. K. Bairagi, and M. A. AlZain, “A Machine Learning Approach to Diagnosing Lung and Colon Cancer Using a Deep Learning-Based Classification Framework,” *Sensors*, vol. 21, no. 3, 2021, doi: 10.3390/s21030748.
 - [109] A. Sorayaie Azar, A. Naemi, S. Babaei Rikan, J. Bagherzadeh Mohasefi, H. Pirnejad, and U. K. Wiil, “Monkeypox detection using deep neural networks,” *BMC Infect. Dis.*, vol. 23, no. 1, p. 438, 2023, doi: 10.1186/s12879-023-08408-4.
 - [110] M. Aloraini, “An effective human monkeypox classification using vision transformer,” *Int. J. Imaging Syst. Technol.*, vol. 34, no. 1, p. e22944, Jan. 2024, doi: <https://doi.org/10.1002/ima.22944>.
 - [111] V. Kumar, “Analysis of CNN features with multiple machine learning classifiers in diagnosis of monkeypox from digital skin images,” pp. 28–31, 2022.
 - [112] R. Achtabat *et al.*, “AttnLRP: Attention-Aware Layer-Wise Relevance Propagation for Transformers,” *Proc. Mach. Learn. Res.*, vol. 235, pp. 135–168, 2024.
 - [113] V. Dhore, A. Bhat, V. Nerlekar, K. Chavhan, and A. Umare, “Enhancing Explainable AI: A Hybrid Approach Combining GradCAM and LRP for CNN Interpretability,” pp. 1–10, 2024, [Online]. Available: <http://arxiv.org/abs/2405.12175>
 - [114] S. Kılıçarslan, A. Diker, C. Közkurt, E. Dönmez, F. B. Demir, and A. Elen, “Identification of multiclass tympanic membranes by using deep feature transfer learning and hyperparameter optimization,” *Measurement*, vol. 229, p. 114488, Apr. 2024, doi: 10.1016/j.measurement.2024.114488.



EKLER

Ek 1: Veri seti 1'e ait ilgili bağlantılar

<https://arxiv.org/abs/1912.12142v1>

https://github.com/tampapath/lung_colon_image_set



Ek 2: Veri seti 2'ye ait ilgili bağlantı ve ayrıntılar

<https://www.kaggle.com/datasets/ambarish/breakhis>

Veri setinin güncel sürümündeki örnekler, SOB yöntemiyle toplanmıştır. SOB; parsiyel mastektomi veya eksizyonel biyopsi olarak da adlandırılan ve iğne biyopsisi yöntemlerine kıyasla daha büyük doku örneği sağlayan bir prosedürdür. Bu işlem genellikle hastane ortamında ve genel anestezi altında uygulanır. Hem iyi huylu hem de kötücül meme tümörleri, tümör hücrelerinin mikroskop altındaki morfolojik özelliklerine göre çeşitli alt tiplere ayrılabilir. Farklı tümör tipleri/profilleri, farklı prognozlara ve tedavi yaklaşımlarına işaret edebilir. Veri seti, halihazırda dört farklı iyi huylu meme tümörü alt tipini içermektedir: adenozis, fibroadenom, fillodes tümörü ve tübüler adenom (TA). Buna ek olarak, dört kötücül meme tümörü (meme kanseri) alt tipi bulunmaktadır: duktal karsinom, lobüler karsinom, müsinöz karsinom ve papiller karsinom. Her bir görüntü dosyasının adı; biyopsi yöntemini, tümör sınıfını, tümör tipini, hasta kimliğini ve büyütme oranını içeren bilgiler barındırır. Örneğin “SOB_B_TA-14-4659-40-001.png” dosyası; SOB prosedürüyle alınmış, iyi huylu sınıfa ait tübüler adenom tipindeki bir tümörün, 14-4659 numaralı preparattan elde edilen ve 40X büyütmede kaydedilmiş birinci görüntüsünü ifade etmektedir.

Ek 3: Veri seti 3 ve 4'e ait ilgili bağlantı ve ayrıntılar (MSID ve MSLD veri setleri)

1. <https://www.kaggle.com/datasets/dipuiucse/monkeypoxskinimagedataset>

MSID Veri seti dört sınıftan oluşmaktadır: Maymun Çiçeği, Suçiçeği, Kızamık ve Normal. Tüm görüntü sınıfları internet tabanlı kaynaklardan toplanmıştır. Veri setinin tamamı, Bangladeş İslam Üniversitesi Bilgisayar Bilimleri ve Mühendisliği Bölümü (Kushtia-7003) tarafından geliştirilmiştir.

2. <https://www.kaggle.com/datasets/nafin59/monkeypox-skin-lesion-dataset>

MSLD haber portalları, web siteleri ve herkese açık olgu raporları gibi çeşitli çevrimiçi kaynaklardan web kazıma (web-scraping) yöntemleriyle toplanan görüntüler kullanılarak veri sağlayıcıları tarafından oluşturulmuştur. Veri setinin oluşturulmasındaki temel amaç, maymun çiçeği vakalarını benzer görünüme sahip olmayan vakalardan ayırt edebilmektir. Bu doğrultuda, 'Maymun çiçeği' sınıfına ek olarak, başlangıç evresinde maymun çiçeği döküntü ve püstüllerine benzerlik gösteren suçiçeği ve kızamık lezyon görüntüleri de veri setine dâhil edilmiştir. Bu iki sınıf, ikili sınıflandırma yapılabilmesi için 'Diğerleri' adı altında birleştirilmiştir.

Ek 4: Veri seti 5'e ait ilgili bağlantı

<https://zenodo.org/records/3595567>



ÖZGEÇMİŞ

Kişisel Bilgiler

Soyad, Ad

ŞEKER, Delal

Web sayfası
(Research Gate, Academia, vs.)

<https://www.researchgate.net/profile/Delal-Seker>

Eğitim Bilgileri

Derece	Kurum	Mezuniyet Yılı
Yüksek Lisans	Dicle Üniversitesi	2021
Lisans	Dicle Üniversitesi	2017
Lise	Rekabet Kurumu Anadolu Lisesi	2011

İş Deneyimi

Dönem (Yıl)	Şirket, Kurum	Görev
2023-2024	Acıbadem Hastanesi Tıp Fakültesi Wake Forest	Araştırmacı bursiyer
2024-2025	Üniversitesi Tıp Fakültesi	Projesi araştırmacısı

Yabancı Dil

İngilizce

Yayınlar

- 1.Classification and Statistical Analysis of Schizophrenic and Normal EEG Time Series
- 2.A classification approach for focal/non-focal eeg detection using cepstral analysis
- 3.Akciğer Kanseri Tespitinde Dönüşüm ve Evrişim Tabanlı Modeller ile Açıklanabilir Yapay Zeka Uygulaması
- 4.Choosing the right artificial intelligence solutions for your radiology department: key factors to consider
- 5.Pix2Pix generative-adversarial network in improving the quality of T2-weighted prostate magnetic resonance imaging: a multi-reader study
- 6.A Deep-XAI Method for Histopathological Image Classification: Utilizing Transformer based FNet Architecture and LIME Method
- 7.Enhancing Monkeypox Diagnosis with Transformers: Bridging Explainability and Performance with Quantitative Validation

Özel İlgi

Seyahat etmek, yüzmek, tenis oynamak vs.

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
TEZ BENZERLİK BİLDİRİMİ FORMU

Öğrencinin Adı, Soyadı	Delal ŞEKER
Öğrenci No	21805966
Ana Bilim Dalı	Elektrik-Elektronik Mühendisliği Bölümü ABD
Program Türü	Proje ☐ Yüksek Lisans ☐ Doktora ☒
Tez Danışmanı (Ünvanı, Adı, Soyadı)	Doç. Dr. Abdulnasır YILDIZ
(Varsa) II. Tez Danışmanı (Ünvanı, Adı, Soyadı)	-
Tez Başlığı	Medikal Görüntü Analizinde Dönüşüm Tabanlı Modellere Açıklanabilir Yapay Zeka Yaklaşımlarının Uygulanması
RAPOR BİLGİLERİ	
Raporlama Aşaması	Tez Savunma Sınavı Sonrası
Sayfa Sayısı	116
Raporlama Tarihi	28.11.2025
Benzerlik Oranı (%)	%17

Yukarıda bilgileri verilen tez çalışmamın toplam 116 sayfalık kısmına ilişkin, 28/11/2025 tarihinde şahsım/tez danışmanım tarafından *Turnitin* isimli intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı % 17 olarak tespit edilmiştir.

Uygulanan filtrelemeler:

☐Başlangıç Bölümleri (Kabul ve Onay sayfası, Teşekkür sayfası, Özet/Abstract) hariç

☐Kaynaklar hariç

☐Alıntılar hariç/dâhil

☒Diğer (Her şey dahil)

Tezimin benzerlik oranı, Dicle Üniversitesi Fen Bilimleri Enstitüsü İntihal Raporu Uygulama Esaslarında belirtilen üst sınır benzerlik oranını aşmamaktadır. Tez benzerlik oranı üst sınır benzerlik oranının altında olsa dahi aksinin tespit edilmesi durumunda her türlü yasal sorumluluğu kabul ettiğimi ve hukuki sonuçlarına razı olduğumu bildirir, gereğini arz ederim.

Öğrencinin Adı, Soyadı: Delal ŞEKER

Tarih:28.11.2025

İmza:

Danışman Adı, Soyadı: Abdulnasır YILDIZ

İmza:

Tarih:28.11.2025

ABD Başkanı Adı, Soyadı: Muhammed

İmza:

Bahaddin KURT

Tarih:28.11.2025