

ANKARA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

KANSER SINIFLANDIRMASI İÇİN HİBRİT MODELLER:  
KONVOLÜSYONEL SİNİR AĞLARININ TRANSFORMATÖRLERLE  
BİRLEŞTİRİLMESİ

Fiez Hussein KHLEAF

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

ANKARA  
2024

Her hakkı saklıdır

## ÖZET

Yüksek Lisans Tezi

### KANSER SINIFLANDIRMASI İÇİN HİBRİT MODELLER: KONVOLÜSYONEL SİNİR AĞLARININ TRANSFORMATÖRLERLE BİRLEŞTİRİLMESİ

Fiez Hussein KHLEAF

Ankara Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı

Danışman : Prof. Dr. Şahin EMRAH

Meme kanseri (MK), en yaygın ve en ölümcül malignite türlerinden biridir ve ister zengin ister az gelişmiş ülkelerde yaşıyor olsunlar, küresel olarak kadınlar arasındaki kayıpların önemli bir yüzdesini oluşturmaktadır. MK tespiti için, ultrasonografi ile birlikte radyografi yaygın görüntüleme teknikleridir. Bunlarla birlikte kanser histopatolojisi görüntüleri kullanılmaktadır. Kanser histopatolojisi görüntülerinin, yalnızca bir tümörün varlığını tespit edebilen ve kanserin iyi huylu veya kötü huylu olup olmadığını belirleyebilen radyografi ve ultrason görüntülerinin aksine, meme kanserinin spesifik alt türlerini belirleme kapasitesi vardır. Evrişimli sinir ağları on yılı aşkın bir süredir görüntü sınıflandırılmasında çok önemli bir rol oynamaktadır. Son zamanlarda, görüntü dönüştürücüler çeşitli bilgisayarla görme görevlerinde evrişimli sinir ağlarına (CNN'ler) karşı güçlü rakipler olarak ortaya çıkmıştır. Tıbbi görüntülerin sınıflandırılmasında hem konvolüsyonel sinir ağlarının (CNN'ler) hem de Swin dönüştürücü avantajlarından yararlanarak meme kanseri histopatoloji görüntülerinin sekiz alt sınıfını sınıflandırmak için dört yeni hibrit model önerdik. Önerdiğimiz modellerden MobileNetV2-Swin hibrit modeli, çok sınıflı sınıflandırma için %95.7 ile en yüksek test doğruluğunu elde ederken, bunu %94.4 ile DenseNet121-Swin hibrit modeli ve %91.5 ile VGG16-Swin hibrit modeli takip etmiştir. InceptionV3-Swin hibrit modeli %90.0 test doğruluğu ile sonuncu olmuştur.

**Temmuz 2024, 51 sayfa**

**Anahtar Kelimeler:** Meme kanseri, Görüntü Sınıflandırması, Dönüştürücüler, Bilgisayarlı Görü, Derin Öğrenme, Makine Öğrenmesi

# ABSTRACT

Master Thesis

## HYBRID MODELS FOR CANCER CLASSIFICATION: COMBINING CONVOLUTIONAL NEURAL NETWORKS WITH TRANSFORMERS

Fiez Hussein KHLEAF

Ankara University  
Graduate School of Natural and Applied Sciences  
Department of Computer Engineering

Supervisor: Prof. Dr. Şahin EMRAH

Breast cancer (BC) is one of the most prevalent and deadliest sorts of malignancies, accounting for a significant percentage of casualties among women globally, regardless of whether they are living in wealthy or underdeveloped countries. For BC detection, radiography along with ultrasonography are common imaging techniques. In addition, cancer histopathology images are used. Cancer histopathology images provide the capacity to identify the specific subtypes of breast cancer, in contrast to radiography and ultrasound images, which can only ascertain the presence of a tumor and establish if the cancer is benign or malignant. Convolutional neural networks have been crucial in image categorization for over a decade. In recent times, vision transformers have emerged as strong contenders to convolutional neural networks (CNNs) in several computer vision tasks. We proposed four new hybrid models to classify eight subclasses of breast cancer histopathology images by leveraging the advantages of both convolutional neural networks (CNNs) and Swin transformers in classifying medical images. Among the models we proposed the MobileNetV2-Swin hybrid model scored the highest test accuracy of 95.7% for multiclass classification, followed by the DenseNet121-Swin hybrid model at 94.4% and the VGG16-Swin hybrid model at 91.5%. The InceptionV3-Swin hybrid model came in last with 90.0% test accuracy.

**July 2024, 51 Pages**

**Key Words:** Breast Cancer, Image Classification, Transformers, Computer Vision, Deep Learning, Machine Learning

## ÖNSÖZ VE TEŞEKKÜR

Her şeyden önce, yüksek lisans programı danışmanım Prof. Dr. Şahin Emrah'a, bu çalışmanın tamamlanmasını sağlamada vazgeçilmez olan paha biçilmez danışmanlığı, ısrarlı desteği ve pratik rehberliği için en içten minnettarlığımı ve takdirimi ifade etmek istiyorum. Ayrıca, bu yolculuk boyunca yardımlarını esirgemeyen ebeveynlerime, kardeşlerime, özellikle de Mohammed ve Athari'ye şükranlarımı sunmak isterim. Son olarak, sürekli teşvik ve dostlukları için arkadaşlarım Anwar, Aous, Faysal ve tüm sınıf arkadaşlarıma içten teşekkürlerimi sunarım.

Fiez Hussein KHLEAF  
Ankara, Temmuz 2024

## İÇİNDEKİLER

<b>TEZ ONAYI</b>	
<b>ETİK.....</b>	<b>i</b>
<b>ÖZET.....</b>	<b>ii</b>
<b>ABSTRACT .....</b>	<b>iii</b>
<b>ÖNSÖZ VE TEŞEKKÜR .....</b>	<b>iv</b>
<b>KISALTMALAR DİZİNİ.....</b>	<b>viii</b>
<b>ŞEKİLLER DİZİNİ .....</b>	<b>ix</b>
<b>ÇİZELGELER DİZİNİ .....</b>	<b>x</b>
<b>1. GİRİŞ .....</b>	<b>1</b>
<b>2. KURAMSAL TEMELLER ve KAYNAK ÖZETLERİ .....</b>	<b>3</b>
<b>2.1 Kuramsal Temeller.....</b>	<b>3</b>
<b>2.1.1 Makine öğrenmesi .....</b>	<b>3</b>
<b>2.1.2 Derin öğrenme .....</b>	<b>4</b>
<b>2.1.3 Konvolüsyon sinir ağı (CNN) .....</b>	<b>4</b>
<b>2.1.3.1 Konvolüsyon katmanı (Convolution Layer) .....</b>	<b>5</b>
<b>2.1.3.2 Havuzlama katmanı (Pooling Layer) .....</b>	<b>5</b>
<b>2.1.3.3 Tam bağlantılı katman (FCL) .....</b>	<b>6</b>
<b>2.1.4 Transformatöre genel bakış.....</b>	<b>6</b>
<b>2.1.4.1 Kodlayıcı ünitesi açıklaması.....</b>	<b>7</b>
<b>2.1.4.2 Dekoder ünitesi açıklaması.....</b>	<b>8</b>
<b>2.1.4.3 Dikkat mekanizması .....</b>	<b>8</b>
<b>2.1.4.4 Ölçeklendirilmiş nokta-çarpım dikkat yöntemi .....</b>	<b>9</b>
<b>2.1.4.5 Çoklu baş dikkati (MHA).....</b>	<b>10</b>
<b>2.1.5 Görüntü transformatörü (VİT) açıklaması .....</b>	<b>10</b>
<b>2.2 İlgili Çalışmalar .....</b>	<b>11</b>
<b>3. METODOLOJİ ve MATERYALLER.....</b>	<b>17</b>
<b>3.1 Veri Kümesi Tanımı ve Veri Önleme.....</b>	<b>17</b>
<b>3.1.1 Veri kümesi tanımı .....</b>	<b>17</b>
<b>3.1.2 Veri ön işleme.....</b>	<b>19</b>
<b>3.2 Swin Transformatörü ve CNN'in Mimari Tanımı.....</b>	<b>19</b>
<b>3.2.1 Vgg16 mimari tanımı .....</b>	<b>20</b>
<b>3.2.2 Inception_V3 mimari açıklaması.....</b>	<b>20</b>

3.2.3 DenseNET121 mimari açıklaması .....	21
3.2.4 MobileNET_v2 mimari açıklaması.....	22
3.2.5 Swin transformatör mimarisi tanımı .....	23
3.3 Önerilen Hibrit Model Mimarisinin Tanımı.....	24
3.4 Deney Detayları .....	25
3.4.1 Eğitim ve hiperparametreler ayarları .....	25
3.4.2 Yazılım ve deney ortamı .....	26
3.5 Değerlendirme Matrisleri.....	26
4. BULGULAR ve TARTIŞMA .....	28
4.1 Bireysel Modellerin Performans Açıklaması .....	28
4.2 Önerilen Hibrit Modellerin Performans Analizi.....	29
4.2.1 Inceptionv2-Swin hibrit modeli .....	30
4.2.2 Vgg16-Swin hibrit modeli.....	32
4.2.3 Densenet121-Swin hibrit modeli .....	33
4.2.4 Mobilenetv2-Swin hibrit modeli .....	35
4.2.5 Dört hibrit modelin performansının karşılaştırılması.....	38
4.3 Tartışma .....	40
4.4 Çalışmanın Sınırlılıkları .....	43
5. SONUÇLAR .....	45
KAYNAKLAR.....	46
ÖZGEÇMİŞ.....	51

## KISALTMALAR DİZİNİ

A	Adenoz
YSA(ANN)	Yapay Sinir Ağı
MK(BC)	Meme Kanseri
CNN	Konvolüsyon Sinir Ağı
CV	Bilgisayarla Görme
CvT	Konvolüsyonel Görme Dönüştürücüsü
DC	Duktal Karsinom
DL	Derin Öğrenme
F	Fibroadenoma
FCL	Tam Bağlantılı Katman
FN	Yanlış Negatif
FP	Yanlış Pozitif
GWO	Gray Wolf Optimizer
K	Anahtar
KNN	K-En İyi Komşular
LBP	Yerel İkili Kalıp
LC	Lobüler Karsinoma
LSTM	Uzun-Kısa Süreli Hafıza
MC	Müsinöz Karsinoma
MHA	Çok Başlı Dikkat
MHSA	Çok Başlı Kendi Kendine Dikkat
ML	Makine Öğrenmesi
MLP	Çok Katmanlı Algılayıcı (Perceptron)
NLP	Doğal Dil İşleme
PC	Papiller Karsinoma
PCA	Temel Bileşenler Analizi
PiT	Havuzlama tabanlı Görüş Transformatörü
PT	Phyllodes Tümörü
Q	Sorgu
RBF SVM	Radyal Taban Fonksiyonu Destek Vektör Makinesi
RNN	Tekrarlayan Sinir Ağları
SepViT	Ayrılabilir Görme Transformatörü
SVM	Destek Vektör Makinesi
TA	Tübüler Adenom
TN	Doğru Negatif
TP	Doğru Pozitif
V	Değer
VGG	Görsel Geometri Grubu
ViT	Görüş Transformatörü
XGBOOST	Ekstrem Gradyan Güçlendirme

## ŞEKİLLER DİZİNİ

Şekil 2.1 Genel bir CNN çerçevesi .....	5
Şekil 2.2 Ortalama ve maksimum havuzlama.....	6
Şekil 2.3 Transformatör mimarisi .....	7
Şekil 2.4 Çok başlı dikkat (MHA) ve ölçeklendirilmiş nokta çarpımı dikkati .....	9
Şekil 2.5 Görüş transformatörü (ViT) mimarisi.....	11
Şekil 3.1 200x Büyüklük faktöründe tümör alt tiplerinin örnek görüntüleri .....	18
Şekil 3.2 Vgg16 mimarisi .....	20
Şekil 3.3 InceptionV3 mimarisi .....	21
Şekil 3.4 Densenet121 mimarisi .....	22
Şekil 3.5 Mobilenetv2 mimarisi.....	23
Şekil 3.6 Swin transformatör mimarisi .....	24
Şekil 3.7 Önerilen hibrit modelin mimarisi.....	25
Şekil 4.1 Bireysel modellerin performans karşılaştırması .....	29
Şekil 4.2'de Inceptionv3-Swin hibrit modelinin performansı. ....	31
Şekil 4.3 Inception-Swin'in hibrit modelinin karışıklık matrisi.....	31
Şekil 4.4'te Vgg16-Swin hibrit modelinin performansı .....	33
Şekil 4.5 Vgg16-Swin hibrit modelinin karışıklık matrisi .....	33
Şekil 4.6'da Densenet121-Swin hibrit modelinin performansı .....	35
Şekil 4.7 Densenet121-Swin hibrit modelinin karışıklık matrisi.....	35
Şekil 4.8 Mobilenetv2-Swin hibrit modelinin performansını .....	37
Şekil 4.9 Mobilenetv2-Swin hibrit modelinin karışıklık matrisi. ....	37
Şekil 4.10 Dört hibrit modelin genel performansının karşılaştırılması.....	39



## ÇİZELGELER DİZİNİ

Çizelge 3.1 200x Büyüklük faktöründe tümör tipi sayısı ve alt tip sayısı. ....	18
Çizelge 3.2 Hiperparametre ayarları .....	26
Çizelge 4.1 Bireysel modellerin sınıflandırma raporu .....	29
Çizelge 4.2 InceptionV3-Swin hibrit modelinin sınıflandırma raporu .....	30
Çizelge 4.3 Vgg16-Swin hibrit modelinin sınıflandırma raporu .....	32
Çizelge 4.4 Dense121-Swin hibrit modelinin sınıflandırma raporu .....	34
Çizelge 4.5 MobileV2-Swin hibrit modelinin sınıflandırma raporu .....	36
Çizelge 4.6 Dört hibrit modelin genel performansının karşılaştırılması.....	38
Çizelge 4.7 Dört Hibrit modelin kanser alt türlerini sınıflandırmadaki performansının.....	39
Çizelge 4.8 Sekiz sınıflı sınıflandırma rejimleri için BreacKHis veri kümesi histopatoloji görüntülerini .....	43

## 1. GİRİŞ

Uluslararası ve yerel sađlık kuruluřlarının raporlarına gore, meme kanseri vakalarının sayısı her geen yıl artmakta ve kadınlar için en olumcul hastalıklardan biri haline gelmektedir. Meme kanseri yařlı kadınlarda daha yaygındır ve ergenlik ađının üzerindeki her kadını etkileyebilir. Hastalıđın turu, derecesi ve evresi, bir kiřinin bu olumcul durumdan ne kadar iyi kurtulacađını etkiler. Zamanında teřhis bařarılı tedavi olasılıđını artırırken, gecikmiř teřhis uzak anatomik bogelere metastaz riskini artırarak tedavi surecini zorlařtırır (Aidossov vd., 2023; Trieu vd., 2023).

Takip eden tedavilerin zamanlaması erken teřhise bađlı olduđundan, mumkun olan en kısa surede yapılmalıdır. Bu hastalıđı tespit etmenin, kendi kendini surekli izlemek veya řuphendildiđinizde bir uzmana gorunmek gibi eřitli yolları vardır, ancak geliřmekte olan ulkelerde, uzak yerlerde ve atıřma bogelerinde bu hastalıđı teřhis edebilecek eđitilmiş uzmanlar bulmak nadirdir. Sonu olarak, bilim insanları yorgunluk veya deneyimsizlik nedeniyle teřhiste insan hatası olasılıđını azaltabilecek, tespiti hızlandırabilecek ve bu alanlardaki tıbbi uzmanlık eksikliđini telafi edebilecek teknolojik alternatifler aramak zorunda kalmıřtır (Abhisheka vd., 2023; Skelton vd., 2023).

Tıbbi goruntuleri analiz edebilen bilgisayar sistemlerinin geliřtirilmesi, hastalıkların tespiti ve teřhisinde doktorlara yardımcı olmak için yararlı bir adım olabilir. Ultrason Taraması, CT taramaları, MRI, X-iřinleri, Mamogram ve biyopsi goruntuleri gibi tıbbi goruntuler, doktorlar tarafından klinik muayenelerde kullanılmaktadır. Bugunlerde yapay zeka dunyayı deđiřtiriyor. Yapay zeka algoritmalarının uygulamaları her geen gun artıyor ve eđitim, sađlık, iř ve tarım dahil olmak uzere ok eřitli alanlarda kullanılıyor. Evriřimli sinir ađı tabanlı uygulamalar, meme kanserinin turu, derecesi ve malignitesi de dahil olmak uzere teřhis ve sınıflandırılmasında kayda deđer bir bařarı gostermiřtir. Ayrıca alt tipleri tanımlamada da yuksek derecede yetenek gostermiřlerdir. Bilgisayarla gormeyi kullanan uygulamalar, eřitli tıbbi goruntu turlerini analiz etme surecinin vazgeilmez bir parası haline gelmiřtir (Toa vd., 2023; Abdulaal vd., 2024).

Son birkaç yılda, bilgisayarla görme dönüştürücüleri, tıbbi görüntüler gibi karmaşık desenlere sahip görüntülerdeki ince ayrıntıları yakalamalarına olanak tanıyan dikkat mekanizmaları nedeniyle birçok bilgisayarla görme görevinde evrimsel sinir ağlarından daha iyi performans gösterebilen yeni teknikler haline gelmiştir (Atabansi vd., 2023).

Bu çalışmada, çeşitli kanser alt türlerini belirleyebilen daha doğru erken kanser tespit sistemleri geliştirmek için tek bir hibrit modelde evrimsel sinir ağlarını ve dikkat mekanizmasını entegre etmenin faydalarını araştırdık. Breakhis veri kümesinde tanımlanan sekiz meme kanseri alt türünü teşhis etmek için Swin dönüştürücüsünü ile dört farklı CNN (Vgg16, InceptionV3, DenseNET121, MobileNETV2) birleştiren dört hibrit model sağladık.

Meme kanserini teşhis etmek için otomatik tespit tekniklerinin kullanılmasının, hastalığın daha kısa sürede teşhis edilmesi, hastalığın teşhisinin daha doğru yapılması, patologların yorgunluğu nedeniyle oluşabilecek hastalığın yanlış teşhis edilmesi vakalarının azaltılmasına yardımcı olunması gibi birçok faydası vardır. Dahası, doğru tedavi kararları verme yeteneğini artırır.

Meme kanserinin sekiz alt tipi Fibroadenom (F), Tübüler Adenom (TA), Lobüler Karsinom (LT), Duktal Karsinom (DC), Papiller Karsinom (PC), Phyllodes Tümörü (PT), Adenozis (A) ve Müsinöz Karsinom (MC) bu çalışmada tanımlanabilen tek alt tiplerdir.

Birinci bölüm tezin konusuna bir giriş sunarken, ikinci bölüm teorik çerçeveyi ve ilgili literatürü açıklamaktadır. Önerilen yaklaşım, yöntemler ve kullanılan materyaller üçüncü bölümde ele alınmaktadır. Dördüncü bölümde araştırma sonuçları ve tartışma ele alınmaktadır. Tezin sonuç bölümü ise beşinci bölümde özetlenmektedir.

## **2. KURAMSAL TEMELLER ve KAYNAK ÖZETLERİ**

Bu bölümün ilk kısmında konvolüsyon sinir ağının ortalama bileşenlerine genel bir bakış sunulmakta ve dikkat mekanizmasının ana fikri açıklanırken, ikinci kısımda tez konusuyla ilgili çalışmalar sunulmaktadır.

### **2.1 Kuramsal Temeller**

Bu bölümde makine öğrenimi ve derin öğrenmenin tanımları verilmekte, ardından konvolüsyon sinir ağları ve dikkat mekanizmalarının altında yatan temel fikirler kısaca tartışılmakta ve son olarak da görüş dönüştürücülerinin temel prensibi açıklanmaktadır.

#### **2.1.1 Makine öğrenmesi**

Yapay zekanın popüler bir alanı makine öğrenmesidir. Makine öğreniminin temel amacı, tipik olarak verilerin altında yatan kalıpları anlamak ve verileri bireyler tarafından netleştirilebilecek ve etkili bir şekilde kullanılacak modellere doğru bir şekilde uydurmaktır. Makine öğrenimi, bilgisayar bilimleri alanına ait olmasına rağmen, geleneksel hesaplama yöntemlerinden farklıdır. Geleneksel bilgi işlem alanında algoritmalar, belirli bir problemi hesaplamak ve çözmek için bilgisayarlar tarafından kullanılan dikkatlice tasarlanmış talimatların derlemeleridir. Tipik olarak, makine öğrenimi bağlamında, faaliyetler denetimli veya denetimsiz olmak üzere iki genel gruba ayrılır. Bu kategoriler, algoritmaya yeni bilgi öğretmek için kullanılan yöntemlere veya nasıl öğrenildiğine bağlıdır. Oldukça popüler bir makine öğrenimi tekniği olan denetimli öğrenme, bir insan tarafından bilgisayara sağlanan etiketli verileri kullanarak algoritmaların eğitilmesini içerir (İbrahim ve Abdulazeez 2021). Çalışmamızda bu tür bir öğrenme uygulanmıştır.

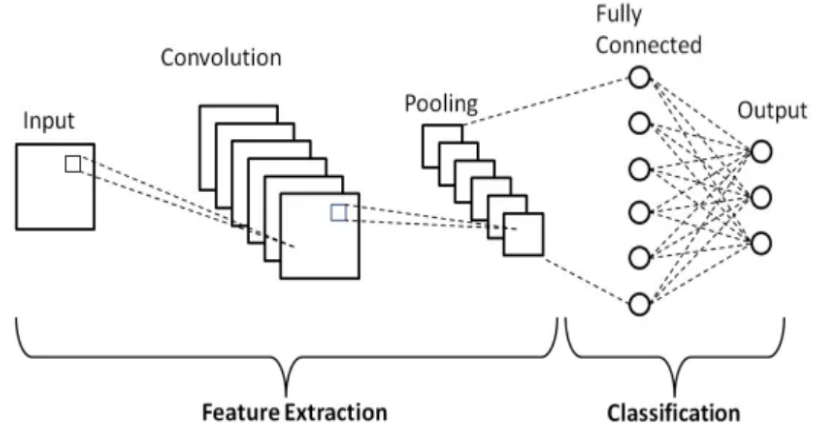
### 2.1.2 Derin öğrenme

Derin öğrenme (DL), daha geniş bir alan olan makine öğrenimi (ML) içinde bir alt alan olarak düşünülebilir. Birden fazla sinir ağı katmanının kullanılması derin öğrenme (DL) olarak adlandırılır. Bir sinir ağının (NN) bir "katmanı" genellikle giriş verileri üzerinde gerçekleştirilen doğrusal olmayan, parametrik bir işlemde oluşur; bu giriş verileri görüntü, ses, metin, video vb. olabilir. Bu dönüşümlerin bir araya getirilmesi, bir derin öğrenme modelinin girdi verilerinin haritasını çıktıya çizmesini sağlar. Eşleme işlemi, parametrelerin geliştirilmesi ve kayıp fonksiyonunu azaltmak için değiştirilmesiyle gerçekleştirilir. Derin öğrenme modelindeki parametre sayısı milyarlarca hatta birkaç milyona ulaşabilir, örneğin büyük dil modelleri (LLM) yüz milyardan fazla parametreye sahip olabilir. Bu büyük ölçek, derin öğrenme modellerinin karmaşık veri modellerini daha derin bir şekilde kavramasını sağlar. Derin öğrenmenin günümüzdeki popüleritesi, bu büyük ölçekli modellerin eğitimini ve uygulanmasını kolaylaştıran donanım yeteneklerinde kaydedilen ilerlemelere bağlanabilir (Shorten vd., 2021).

### 2.1.3 Konvolüsyon sinir ağı (CNN)

Konvolüsyonel sinir ağı, karmaşık örüntülerin işlenmesiyle ilgili birçok alanda başarılı performans elde etme kabiliyetiyle öne çıkmıştır. CNN derin öğrenme uygulamalarında kullanıldığında bir YSA'nın ihtiyaç duyabileceği parametre miktarı azalır. CNN'in bir avantajı, girdiler sinir ağının daha derin seviyelerine gittikçe bilgiyi soyutlama kapasitesine sahip olmasıdır. Ayrıca mekansal özelliklere dayanmadan problemleri çözme yeteneği de bulunmaktadır. (Albawi vd., 2018).

CNN'deki ana katman, giriş verilerinden çıkarılan özellikler için kullanılan konvolüsyon katmanı, çıkarılan özelliklerin boyutunu küçültmek için kullanılan havuzlama katmanıdır konvolüsyon katmanı ve sınıflandırma görevi için kullanılan tam bağlı katmanlar (Krishnakumar vd., 2019). Şekil 2.1'de yaygın CNN çerçevesi gösterilmektedir.



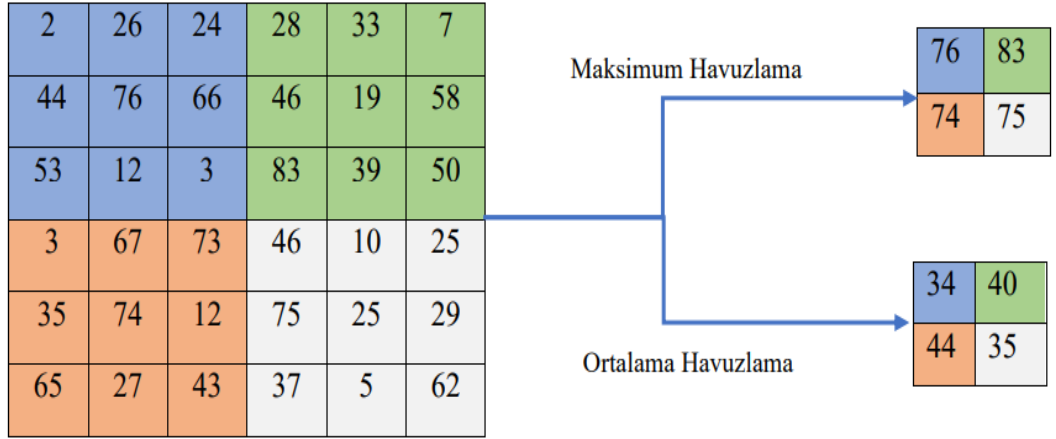
Şekil 2.1 Genel bir CNN çerçevesi

### 2.1.3.1 Konvolüsyon katmanı (convolution layer)

Bu tür bir katman, verilen fotoğraftan çeşitli özellikleri almak için kullanılır. Bu katmanın işlevi, verilen görüntünün belirli bölümlerine matematiksel hesaplamalar ve belirli bir  $N*N$  boyutunda uzamsal bir filtre uygulayarak elde edilen görüntünün ayrıntılarını kullanarak bir özellik haritası oluşturmaktır. Filtre ile giriş resminin parçaları arasındaki nokta çarpımı, filtrenin boyutlarına ( $N*N$ ) göre, filtrenin resim üzerinde kaydırılmasıyla hesaplanır. Filtreler, beyan edilen görüntünün yoğunluk değerindeki değişiklikleri tanıyarak bir görüntünün içindeki kenarlar gibi uzamsal desenleri anlama yeteneğine sahiptir (Krishnakumar vd., 2019).

### 2.1.3.2 Havuzlama katmanı (pooling layer)

Havuzlama katmanı, konvolüsyonel katman çıktısının uzamsal boyutlarını azaltır. Ortalama havuzlama ve maksimum havuzlama, havuzlama katmanlarının iki çeşididir. Bir havuzlama penceresi kullanıldığında, ortalama havuzlama ortalama değeri getirirken, maksimum havuzlama uzamsal boyutun maksimum değerini döndürür (Krishnakumar vd., 2019). Şekil 2.3'te en yaygın kullanılan havuzlama katmanı türleri gösterilmektedir.



Şekil 2.2 Ortalama ve maksimum havuzlama

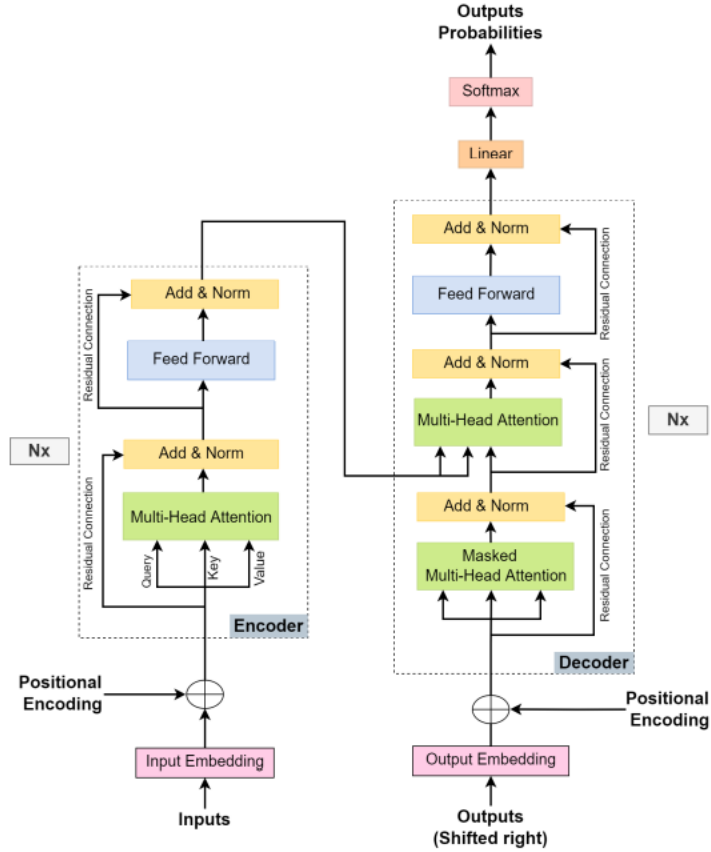
### 2.1.3.3 Tam bağlantılı katman (FCL)

Tam bağlantılı bir katman söz konusu olduğunda, belirli bir katmandaki her nöron, onu takip eden katmandaki her nörona bağlıdır. Verilerden karmaşık (doğrusal olmayan) örüntüleri öğrenmek için etkili bir yapı taşı olan çok katmanlı algılayıcı (MLP), birkaç tam bağlantılı katman üst üste yerleştirildiğinde oluşturulur. Bir CNN'in sonunda, tam bağlı katmanlar genellikle havuzlama ve konvolüsyon katmanlarından çıktı almak ve girdi olan görüntünün nihai kategorisini belirlemek için kullanılır (Krishnakumar vd., 2019).

### 2.1.4 Transformatöre genel bakış

Transformatörler, 2017'de ortaya çıkmasından bu yana makine çevirisi, metin oluşturma, görüntüden metne dönüştürme, metinden görüntüye dönüştürme gibi birçok yapay zeka dalının yeniden şekillendirilmesine katkıda bulunan bir tür akıllı sinir ağı yapısıdır. Geleneksel sinir ağlarından (CNN ve RNN), girdi verilerini paralel bir şekilde işleme yeteneği ile ayrılır; bu işlem geleneksel sinir ağlarında sıralı bir şekilde gerçekleştirilir ve bu da verilerin işlenmesi için gereken sürenin kısalmasına neden olur. Transformatörlerin kullanımı, bilim insanlarının ve mühendislerin uzun vadeli bağımlılık sorununu çözebilecek modeller oluşturmalarını sağlamıştır. Bu, kendi kendine dikkat mekanizması olarak bilinen bir mekanizma kullanılarak yapılır. Modeller, birbiri ardına sağlanan

dizinin her bir bölümünü ele almak yerine, aynı anda birden fazla bölüme bakma ve hangi bölümlerin diğerlerinden daha önemli olduğuna karar verme yeteneğine sahip olmuştur (Islam vd., 2023). Dönüştürücü mimarisi şekil 2.3'te gösterildiği gibi kodlayıcı ve kod çözücü olmak üzere iki ana bölümden oluşmaktadır. Aşağıdaki bölümde kodlayıcı, kod çözücü ve dikkat mekanizması hakkında daha fazla bilgi verilmektedir.



Şekil 2.3 Transformatör mimarisi (Vaswani vd., 2017)

#### 2.1.4.1 Kodlayıcı ünitesi açıklaması

Transformatör dokusundaki birleştirilmiş birim iki temel katman içerir; birincisi İleri Besleme Katmanı, ikincisi ise Çok Başlı Dikkat Katmanıdır. Ayrıca, her iki katmanı çevreleyen Artık bağlantıları ve çok önemli olan iki Ekleme ve Norm katmanını içerir (Vaswani vd., 2017). Bir metni çevirirken, girdinin anlam ve konum verileri Gömme ve Konum Kodlama katmanları tarafından bir gömme girdisi oluşturmak için kullanılır ve



bu girdi daha sonra kodlayıcı birimine gönderilir. Konum verilerine ek olarak üç parametre matrisi-Sorgu (Quary(Q)), Anahtar (Key(K)) ve Değer (Value(V)) matrisleri - dahil edilen bilgilerden oluşturulur ve "Çok Kafalı Dikkat" katmanına gönderilir. İleri Besleme katmanı, bu tekniği kullanarak hesaplama sırasında ortaya çıkabilecek potansiyel sıralama çökmesi sorunuyla ilgilendirir. Her aşama ayrıca, kullanılan ağırlıkları normalleştiren ve her katmanın gradyan hesaplamasında katmanlar arasındaki karşılıklı bağımlılığı azaltan ek bir normalleştirme katmanı içerir. Hem ileri besleme hem de dikkat katmanlarından elde edilen her bir sonuç için Artık Bağlantısının kullanılması, gradyanların kaybolması sorununu çözmektedir (Islam vd., 2023).

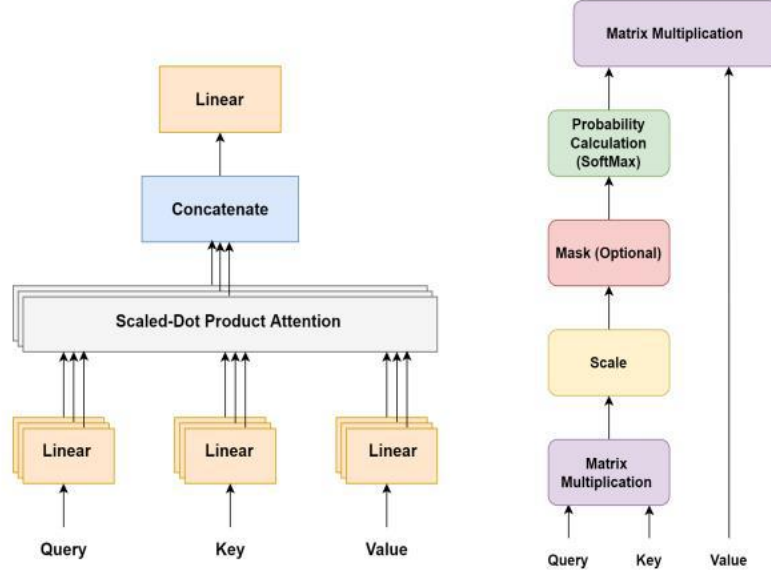
#### **2.1.4.2 Dekoder ünitesi açıklaması**

Kod çözücü ünitesi, Maskeli Çok Kafalı Dikkat katmanı da dahil olmak üzere daha fazla katmana sahip olması dışında Kodlayıcı ünitesiyle karşılaştırılabilir. Bu katmanlar sadece geçmiş çıktılar dikkate alır ve ölçeklendirilmiş nokta çarpımı ve Maske İşlemlerini kullanarak gelecekteki tahminleri ortadan kaldırır. Kod Çözücü dikkat sistemini iki kez kullanır: bir kez kodlama girdileri ve istenen sonuç içindeki farkındalığı tanımlamak için ve tekrar istenen sonucun parçaları arasındaki dikkati hesaplamak için. Katmanların nihai sonucu daha iyi anlamasına yardımcı olmak için, her farkındalık vektörü daha sonra ileri besleme birimi aracılığıyla gönderilir. İleri besleme kısmı daha sonra katmanın sonuçları kavramasını geliştirmek için tüm farkındalık vektörlerini değerlendirir. Doğrusal kod çözücü katmanı ve SoftMax kod çözücü katmanı nihai çıktıyı hesaplar. Adımlar, bir cümlenin nihai belirteci keşfedilene kadar tekrarlanır (Vaswani vd., 2017).

#### **2.1.4.3 Dikkat mekanizması**

Bir dikkat fonksiyonu, bir çıktı üretmek için bir sorguyu ve anahtar-değer çiftleri koleksiyonunu ilişkilendirme süreci olarak tanımlanabilir; burada tüm bileşenler-sorgu, anahtarlar, değerler ve çıktı-vektörler olarak temsil edilir. Elde edilen değer, değerlerin ağırlıklı bir kombinasyonunun hesaplanmasıyla elde edilir ve her değere, sorguyu ilgili anahtarla karşılaştıran bir uyumluluk fonksiyonu tarafından belirlenen bir ağırlık atanır

(Vaswani vd., 2017). Şekil 2.4 te çok başlı dikkat (MHA) ve ölçeklendirilmiş nokta çarpımı dikkati gösterilmiştir.



Şekil 2.4 Çok başlı dikkat (MHA) ve ölçeklendirilmiş nokta çarpımı dikkati (Vaswani vd., 2017)

#### 2.1.4.4 Ölçeklendirilmiş nokta-çarpım dikkat yöntemi

"Scaled Dot-Product Attention" adlı dikkat işlevi, bir sorgunun tüm anahtarlarla nokta çarpımlarını hesaplar, her birini  $\sqrt{d_k}$ 'ya böler ve değerler üzerinde ağırlıklar elde etmek için bir SoftMax işlevi uygular. Algoritma, Q, K ve V matrislerine paketlenmiş bir dizi sorgu üzerinde kullanılır ve çıktıların matrisini şu şekilde hesaplar:

$$\text{Dikkat}(Q, K, V) = \text{SoftMax}(QK^T/\sqrt{d_k})V$$

Eklemeli dikkat ve nokta çarpımlı dikkat yaygın olarak kullanılan dikkat işlevleridir, ancak eklemeli dikkat, daha büyük  $d_k$  değerleri için ölçekleme yapmadan nokta çarpımlı dikkatten daha iyi performans gösterir (Vaswani vd., 2017).

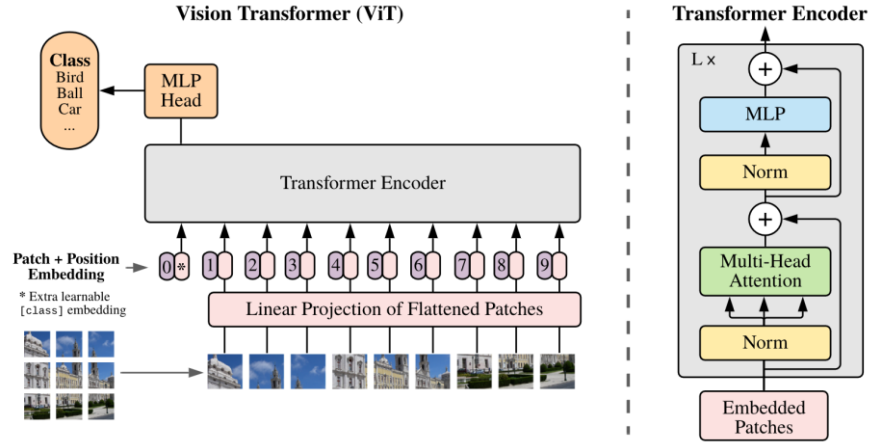
#### **2.1.4.5 Çoklu baş dikkati (MHA)**

Bir modelin öğrendiği bilgiler, aynı sekans için paralel olarak birden fazla kez (öz) dikkat hesaplanarak geliştirilebilir. Buna Çok Başlı Dikkat (MHA) adı verilir. Birden fazla alt uzaya anahtarların, değerlerin ve sorguların doğrusal izdüşümleri verilir. Dikkat her alt uzay için hesaplanır ve daha sonra birleştirilir (Vaswani vd., 2017). Bu, modellerin aynı dizi içinde farklı bilgiler edinmesini sağlar.

#### **2.1.5 Görüntü transformatörü (ViT) açıklaması**

Görme Dönüştürücüsü (ViT), model bir çıkış dizisi oluşturmayı gerektirmediğinden yalnızca kodlayıcı bileşenini kullanır. Başlangıçta, giriş görüntüsü işlenerek model için bir giriş dizisi oluşturulur. Görüntü, aynı boyutlarda örtüşmeyen birçok bölüme ayrılır. Düzleştirildikten sonra, her yama doğrusal olarak 1 boyutlu bir vektöre yansıtılır. Yamanın konumu hakkında bilgi içeren konumsal gömme daha sonra bu vektöre eklenir. Ayrıca, girdi dizisine [sınıf] kategorisinin ek bir belirteci dahil edilir. Nihai çıktı görüntüsünün sınıfını tahmin etmek için bu ekstra yama, görüntünün küresel bir temsilini öğrenmeyi amaçlamaktadır (Dosovitskiy vd., 2020).

Kodlayıcı içinde vektörler birden fazla öğrenme bloğundan geçer. Her blokta bir MHSA katmanı ve bir MLP katmanı bulunur ve normalleştirilmenin daha sonra yapıldığı NLP Dönüştürücüsünün aksine her ikisinden önce bir normalleştirme katmanı yer alır. Mimari ayrıca MHSA ve MLP'den eşzamanlı olarak bilgi aktaran atlama bağlantılarından oluşmaktadır. Şekil 2.5'te Görüş Transformatörü (ViT) mimarisini göstermektedir.



Şekil 2.5 Görüş transformatörü (ViT) Mimarisi (Dosovitskiy vd., 2020)

Kodlayıcı bir dizi üretmesine rağmen, görüntü yamaları ile ilişkili dizi elemanları sınıflandırma işleminde kullanılmaz. Görüntünün sınıfını tahmin etmek için [sınıf] belirteciyle ilişkili çıktı vektörü için yalnızca bir MLP kullanılır. Bu mimari tarzı, herhangi bir evrimsel bileşenden yoksun olarak yalnızca kendi kendine dikkat mekanizmasını kullanır (Dosovitskiy vd., 2020).

## 2.2 İlgili Çalışmalar

Birçok yapay zeka araştırmacısı, hastalığın artan yaygınlığı, her yıl artan vaka sayısı ve erken teşhisin tedavide oynadığı kritik rol nedeniyle son yıllarda meme kanserinin erken teşhisine yardımcı olacak sistemler oluşturmak için çalışıyor.

(Deniz vd., 2018) tarafından tanıtılan model, özellik çıkarıcı olarak AlexNET ve sınıflandırıcı olarak SVM'den oluşmakta ve meme kanserini iyi huylu ve kötü huylu olmak üzere iki kategoride sınıflandırmak için kullanılmaktadır. Araştırmacılar bu modeli hazırlamak için AlexNET'in son üç katmanını rafine etmişlerdir. Model, 1100 epok boyunca eğitilmesine rağmen Breakhis veri setinin 40x, 100x, 200x ve 400x büyüklük

faktörlerinde sırasıyla %90,96, %90,58, %91,37 ve %91,30 gibi nispeten iyi bir doğruluk oranı göstermiştir.

(Kassani vd., 2019) tarafından bir topluluk derin öğrenme modeli önerilmiş ve önceden eğitilmiş üç CNN (MobileNet, VGG19 ve DenseNet) bu modele uyarlanmıştır. Bu modelde özellik gösterimi ve çıkarımı prosedürleri, topluluk modeli kullanılarak gerçekleştirilmektedir. Meme kanseri için ikili sınıflandırma mücadelesi daha sonra toplanan özelliklerin çok katmanlı bir algılayıcı sınıflandırıcıya beslenmesiyle yapılmaktadır. ICIAR, BreakHis, Patch-Camelyon ve Bioimaging, önerilen topluluk modelini eğitmek için kullanılan dört hasta-patoloji görüntüsü veri kümesidir. BreakHis, ICIAR, PatchCamelyon ve Bioimaging veri kümeleri için önerilen topluluk tekniği, modeli 1000 epok boyunca eğittikten sonra sırasıyla %98,13, %95,00, %94,64 ve %83,10 tahmin doğruluğu testlerine ulaşmıştır.

(Yan vd. 2019) tarafından konvolüsyon sinir ağını (InceptionV3) tekrarlayan sinir ağı (BLSTM) ile entegre ederek sunulan bir hibrit modelin genel tüm doğruluğu, Bioimaging2015 veri setinin genişletilmiş versiyonunda meme kanseri sınıflandırma görevinin dört alt sınıfında (normal, iyi huylu, in situ karsinom ve invaziv karsinom) %91,3'ün üzerine çıkmamıştır.

(Jiang vd., 2019) tarafından tanıtilen bir başka yöntemde, araştırmacılar çok sınıflı meme kanseri histopatoloji görüntüleri için küçük bir SE-ResNet modülü ile CNN uygulamıştır. SE-ResNet modülü üç elemandan oluşmaktadır: ilk eleman bir konvolüsyonel katman, ikinci eleman küçük bir SE-ResNet modülü ve üçüncü eleman bir (FCL) tam bağlı katman, artık modül ve Sıkıştırma ve Uyarma bloğunun entegrasyonunu geliştirmek için SE-ResNet modülünün uygulanmasında kullanılarak az sayıda parametre ile tatmin edici performans elde edilmiştir. Bu model, Breakhis veri setinin dört büyüklük faktörü üzerinde çok sınıflı sınıflandırma için %90,66 ile %93,81 arasında doğruluk sağlamıştır.

(Nguyen vd., 2019) tarafından oluşturulan özel CNN modelinin beş konvolüsyon katmanını, her katmanda bir toplu normalleştirme katmanı takip etmektedir. Üçüncü ve dördüncü katmanlarda 128 filtre, ikinci katmanda 64 filtre ve birinci katmanda 32 filtre

yer alırken beşinci katmanda 512 filtre kullanılmıştır. Breakhis veri kümesi kullanılarak sekiz sınıf sınıflandırma görevinde modelin genel doğruluğu %73,69 olmuştur.

Dört malign meme kanseri alt tipini (normal, iyi huylu, in situ karsinom ve invaziv karsinom) içeren BACH veri setinden öznetelikler çıkarmak için (Elmannai vd., 2021), iki CNN ön eğitilmiş model (Inception-Resnet ve Xception) tarafından çıkarılan öznetelikleri birleştirmiş, daha sonra sınıflandırma görevini yapmak için tam bağlı katmanlar kullandıktan sonra bırakma katmanı kullanarak öznetelik haritalarının boyutlarını azaltmışlardır. Görüntüleri sınıflandırmak için iki yöntem kullanılmıştır: en yüksek olasılıklı füzyon ve çoğunluk kararı. İlk yöntem doksan beşlik bir test doğruluğu elde ederken, ikinci yöntem yüzde yüz test doğruluğu elde etmiştir.

ResNET50'ye dayanarak (Behar ve Shrivastava 2021) meme kanserini iyi huylu ve kötü huylu olarak sınıflandırmak için mükemmel bir model hazırladılar ve model doğruluğu %99,24'e ulaştı. Deney yapılandırmalarındaki her Resnet50 katmanı, Breakhis veri kümesi biyopsi resimlerinden ek özellikler almak için görünür bırakılmıştır. Değiştirilmiş FC katmanı, Resnet-50 katmanlarından özellik vektörlerini toplarken, tahmin katmanı sigmoid fonksiyonunu kullanmıştır.

(Gheshlaghi vd., 2021) veri kümesi örneklerini genişletmek için bir veri artırma tekniği olarak ACGAN kullanmıştır. ACGAN bir GAN türüdür. Oluşturucusu, her biri aktivasyon fonksiyonu olarak Relu kullanan beş dekonvolüsyon katmanından oluşur. Ayırıcısı, her biri aktivasyon fonksiyonu olarak Leaky Relu kullanan yedi dekonvolüsyon seviyesinden oluşur. XGBOOST sınıflandırıcısı resnet-50'nin çıkardığı özellikleri almıştır. Breakhis veri setindeki ikili ve çok sınıflı sınıflandırma görevlerinde, model test doğruluğu sırasıyla %90,15 ve %86,33 olmuştur.

(Sethy ve Behera 2022) Bioimaging veri setinde dört malign meme kanseri alt tipini (normal, iyi huylu, in situ ve invaziv) sınıflandırmak için yazarlar, derin öğrenme ağı (VGG16) tarafından çıkarılan özelliği el aşısı (LBP yöntemi) ile çıkarılan özellik ile birleştirdiler ve daha sonra sınıflandırmak için birleştirilmiş özellikleri KNN sınıflandırıcısına beslediler. Model doğruluğu %84,2 olmuştur.

(Zheng vd., 2022), dört CNN ağını (Vgg16, Xception, Resnet50 ve Densenet201) birleştiren topluluk modeli üretmek için topluluk öğrenme tekniğini kullandı; yazarlar, nihai tahmini yapmak için ağırlıklı oylamayı kullandılar. Bu topluluk modeli, Breakhis veri kümesindeki ikili sınıflandırma görevinde %98,90 doğruluk elde etti.

(Zerouaoui ve Idri 2022) tarafından yapılan geniş ve kapsamlı bir çalışmada, ikili meme kanseri teşhisi için yirmi sekiz hibrit model geliştirilmiştir. Bu modelleri dört popüler sınıflandırıcı (K-En Yakın Komşular (KNN), Karar Ağacı, Destek Vektör Makinesi (SVM), Çok Katmanlı Algılayıcı (MLP)) ve özellik çıkarıcı olarak yaygın olarak kullanılan yedi CNN'i (Vgg19, Vgg16, Resnet50, Inception-Resnet V2, Inceptionv3, Mobilenetv2 ve Densenet201) birleştirerek oluşturmuşlardır. Yazarlar bu çalışmada Çok Katmanlı Algılayıcı (MLP) sınıflandırıcı ve DenseNet201 özellik çıkarıcıdan oluşan hibrit modelin, geliştirdikleri tüm modeller arasında en başarılı model olduğunu gözlemlemişlerdir. Bu model, FNAC veri kümesinde %99, Breakhis veri kümesinin dört büyüklük faktörü (40x, 100x, 200x ve 400x) için sırasıyla %92,61, %92, %93,93 ve %91,73 doğruluk elde etmiştir.

(Nakach vd., 2022) Inception V3'ü bir özellik çıkarıcı olarak 9 Rastgele Orman ağacını bir sınıflandırıcı olarak entegre ederek oluşturdukları hibrit model, bir rastgele orman sınıflandırıcısında değişen sayıda ağaç içeren üç CNN ağına (MobileNetV2, Inception V3, Densenet201) performansını değerlendirip karşılaştırdıklarında diğer modellerden daha iyi performans göstermiştir. Yazarlar Breakhis veri kümesi üzerindeki ikili sınıflandırma görevinde %85,88'lik bir doğruluğu elde etmişlerdir..

İki CNN ön eğitilmiş model (VGG19 ve ResNET18) tarafından çıkarılan özellikleri birleştirerek, (Al-Jabbar vd., 2023) tarafından meme kanserinin erken teşhisine yardımcı olmak için hibrit bir model önerilmiştir. Bu modelde araştırmacılar, üç doğrusal katmandan oluşan bir YSA sınıflandırıcı kullanmadan önce birleştirilmiş özelliklere PCA algoritmasını uygulamıştır. Temel bileşen analizi algoritmasının uygulanması, veri noktalarının temsiline boyutsallığını azaltırken en önemli ayrıntıları korumayı amaçlamıştır. Breakhis veri setinde, bu tekniğin doğruluğu 40x ve 400x büyüklük faktörleri için sırasıyla %94,3 ve %94,8 olmuştur.

(Sriwastawa ve Jothi 2023) bilgisayarlı görü dönüştürücülerinin yeteneklerini test etmek amacıyla Breakhis veri seti ve IDC veri seti üzerinde yedi bilgisayarlı görü dönüştürücüsünün (CrossFormer, CrossViT, Evrişimsel Görme Dönüştürücüsü (Convolutional Vision Transformer (CvT)), MaxViT, iç içe dönüştürücü bloklar( nested transformer blocks(NesT)), Ayrılabilir Görme Transformatörü (Separable Vision Transformer (SepViT)) ve Havuzlama tabanlı Görüntü Transformatörü (Pooling based Vision Transformer (PiT))) performansı arasında kapsamlı bir karşılaştırma yapmıştır. Çalışmalarının sonuçları, MaxViT dönüştürücüsünün iyi huylu veya kötü huylu meme kanseri sınıflandırmasında diğer görüş dönüştürücülerinden daha iyi performans gösterdiğini ve %91 genel doğruluk elde ettiğini göstermiştir. CvT dönüştürücüsü ise %88'lik bir doğruluk elde ederek ikinci sırada yer almıştır.

(Kutluer vd., 2023) SVM sınıflandırıcısını uygulamadan önce özellik çıkarma adımından sonra özellik seçimi yaklaşımını kullanmıştır. Yazarlar, GWO adı verilen bir özellik seçme tekniği kullanmış ve özellik çıkarma adımı sırasında önceden eğitilmiş dört CNN ağı (MobilenetV2, GoogleNET, ResNET ve InceptionV3) kullanmıştır. Sınıflandırmayı iyileştirmek için sınıflandırıcıya gönderilecek en iyi özelliklerin seçilmesi özellik seçiminin hedefi olmuştur. Yazarlar, BACH veri kümesinde, GWO yaklaşımını kullanan modelin dört meme kanseri türünü (normal, karsinoma in situ, iyi huylu ve invaziv karsinoma) sınıflandırmak için %92,17'lik bir doğruluğa sahip olduğunu, GWO yöntemini kullanmayan model için ise bu oranın %91,30 olduğunu gözlemlemişlerdir. Ayrıca, Elazığ Fethi Sekin Şehir Hastanesi'nden Bingen ve malign meme kanserinin 303 histopatolojik görüntüsünü içeren bir veri kümesi üzerinde modelin doğruluğu %98,89 olmuştur.

(Srishtank Chandrasekhar 2023), BACH veri kümesinde bulunan dört Duktal Karsinom Histolojik alt türünü (normal, karsinoma in situ, iyi huylu ve invaziv karsinom) sınıflandırmak için HistoFormer adlı bir topluluk görüş dönüştürücü modeli tanıtmıştır. Bu, üç görüş dönüştürücüsü kullanılarak gerçekleştirilmiştir: Swin dönüştürücü, Vit dönüştürücü ve Segformer. Birleştirme yaklaşımı, Swin, ViT ve Segformer bireysel dönüştürücü modelleri için sırasıyla %92,5, %87,9 ve %86'ya kıyasla görsel dönüştürücülerin doğruluğunu %96,8'e önemli ölçüde artırmıştır. BRACS veri kümesi



üzerinde değerlendirildiğinde, HistoFormer modeli bireysel modellerden (Swin, Vit ve SegFormer) daha iyi performans göstermiş ve bireysel dönüştürücülerin sırasıyla %75, %85 ve %80 doğruluğuna kıyasla %88'lik bir doğruluk elde etmiştir.

(Sharma vd., 2024) tarafından sunulan daha yeni bir çalışmada, Databiox veri setinde bildirilen üç meme kanseri kategorisini sınıflandırmak için beş evrişimli sinir ağı (InceptionV3, Xception, NasNET, MobileNET ve VGG19) bir topluluk modeline entegre edilmiştir. Databiox veri setinin 4X, 10X, 20X ve 40X büyüklük faktörlerinde, önerilen model %79, %75, %89 ve %82 doğruluk oranına sahipti. Araştırmacılar, Macenko renk normalleştirme tekniğini kullandıktan sonra modelin doğruluğunun 4x, 10x, 20x ve 40x büyütmelemlerde sırasıyla %80, %100, %100 ve %82'ye yükseldiğini beyan etmişlerdir.

(Roy vd., 2024) vgg16 sinir ağının modifiye edilmiş bir versiyonu olan FA-VGG16 modelini sunmuştur. Konvolüsyon katmanlarından sonra dört kanal dikkat modülü eklenerek vgg16 modifiye edilmiş, bu sayede vgg16'nın daha önemli özellikleri çıkarma yeteneği artırılmıştır. Modelin genel doğruluğu, Breakhis veri kümesinde çok sınıflı sınıflandırma için %92,4 ve ikili sınıflandırma görevi için %97'ye ulaşmıştır. Bu dikkat modülleri, kaybolan gradian (vanishing gradient) sorununa bir çare sunmanın yanı sıra modelin özellik çıkarma kabiliyetini de geliştirmektedir.

Kanser uzmanları tarafından kullanılabilir sonuçlar sağlamaya çalışan birçok çalışma olmasına rağmen, bunların çoğu bu hedefe ulaşamamıştır. Benzer şekilde, meme tümörlerinin patolojik anatomik görüntülerinin sınıflandırılması görevinde Swin transformatörünün CNN modelleriyle entegre edilmesinin etkinliğini test eden daha önce yapılmış bir çalışma bulunmamaktadır, ki biz de bu tezde bunu yaptık.

### **3. METODOLOJİ ve MATERYALLER**


Bu bölümde, çok sınıflı bir sınıflandırma görevi için hibrit bir derin öğrenme modelinde CNN'in önceden eğitilmiş ağlarının bir swin dönüştürücüsü ile birleştirilmesi yoluyla histopatoloji görüntülerinden meme kanseri teşhisi için önerilen yaklaşım gösterilmektedir. İlk bölümde, kullanılan veri kümesine ayrıntılı bir genel bakış sunduk ve gerçekleştirilen görüntü işleme prosedürlerini açıkladık. İkinci bölümde, bu çalışmada kullanılan swin transformer mimarisi ve önceden eğitilmiş CNN mimarileri hakkında ayrıntılı bir açıklama yaptık. Üçüncü bölümde, bu çalışma için önerdiğimiz hibrit model mimarisini açıkladık. Dördüncü bölümde, deneyin uygulanması ve kullanılan ortam hakkında kapsamlı bir açıklama yer almaktadır. Beşinci bölümde, çalışmamızda geliştirilen dört hibrit modelin etkinliğini değerlendirmek için kullandığımız değerlendirme matrislerini detaylandırdık.

#### **3.1 Veri Kümesi Tanımı ve Veri Ön İşleme**

##### **3.1.1 Veri kümesi tanımı**

BreaKHis veri seti, Ocak 2014'ten Aralık 2014'e kadar yürütülen klinik çalışmalardan elde edilen hem iyi huylu hem de kötü huylu meme kanserlerinin biyopsi görüntülerinden oluşmaktadır. Söz konusu zaman diliminde, meme kanserinin klinik belirtilerini gösteren tüm bireyler, bilimsel bir çalışmaya katılmak üzere saygın Brezilya P&D laboratuvarına davet edilmiştir. Örnekler cerrahi açık biyopsi (SOB) kullanılarak elde edilmiş ve ardından hematoksilin ve eozin ile boyanmıştır. Bu görüntüler histolojik incelemeler için uygundur ve P&D laboratuvarındaki patologlar tarafından yorumlanabilmektedir. BreaKHis veri kümesi, 82 hastadan elde edilen 7909 meme tümörü dokusu mikroskobik görüntüsünden oluşmaktadır. Bu görüntüler, 24 hastadan alınan iyi huylu tümörleri temsil eden 2480 görüntü ve 58 hastadan alınan kötü huylu tümörleri temsil eden 5429 görüntü ile iyi huylu ve kötü huylu tümörler olarak kategorize edilmiştir. Her tümör kategorisi için dört alt sınıf bulunmaktadır. İyi huylu kategori Adenozis (A), Phyllodes Tümörü (PT), Fibroadenom (F) ve Tübüler Adenomu (TA) içerirken, kötü huylu kategori Lobüler Karsinom (LC), Papiller Karsinom (PC), Müsinöz Karsinom (MC) ve Duktal Karsinom

(DC) içermektedir. Görüntüler, her biri 700 x 460 piksel boyutlarında ve 40, 100, 200 ve 400 büyütme oranlarına sahip üç kanallı RGB (kırmızı, yeşil ve mavi) gerçek renk uzayında çekilmiştir (Spanhol vd., 2016). Veri kümesi, 200X büyütme bağımsız bir veri kümesi olarak kullanmamıza olanak tanıyan bu büyüklük faktörlerine göre yapılandırılmıştır. Hesaplama maliyeti için 200x büyüklük faktörüne sahip görüntüleri kullanıyoruz. 200x büyütme faktöründeki tümör alt tipi sayıları çizelge 3.1'de ayrıntılı olarak verilirken, Şekil 3.1'de 200x büyütme faktöründeki tümör alt tiplerinin örnek görüntüleri gösterilmektedir.



Şekil 3.1 200x Büyüklük faktöründe tümör alt tiplerinin örnek görüntüleri

Çizelge 3.1 200x Büyüklük faktöründe tümör tipi sayısı ve alt tip sayısı

Tümör Tipi	Tümör Türleri Sayıları	Tümör Alt Tipleri	Tümör Alt Tip Sayıları
<b>İyi Huylu</b>	632	Adenozis (A)	111
		Fibroadenom (F)	264
		Phyllodes Tümörü (PT)	108
		Tübüler Adenom (TA)	140
<b>Kötü Huylu</b>	1390	Duktal Karsinom (DC)	896
		Lobüler Karsinom (LC)	135
		Müsinöz Karsinom (MC)	163
		Papiller Karsinom (PC)	196
<b>Toplam Sayısı</b>		<b>2013</b>	

### 3.1.2 Veri ön işleme

Deneyleer sırasında 200x büyüklüğündeki veri kümesi eğitim için %80'e ve test için %20'ye bölünmüştür. Görüntülerin boyutu eğitim süreci için 224 x 224 x 3 boyutlarına normalize edilmiştir. Görüntü dönüşümü, bir derin öğrenme modelinin etkinliğini artırmak ve aşırı uyumu hafifletmek için kullanılan bir veri artırma tekniğidir. Bu yöntem kullanılarak eski görüntülerden yeni görüntüler oluşturulabilir ve eğitim görüntülerinin esnekliği artırılabilir. En çok kullanılan iki görüntü değiştirme tekniği olan yatay çevirme ve dikey çevirme yöntemlerini kullandık.

### 3.2 Swin Transformatörü ve CNN'in Mimari Tanımı

Bu tezin temel amacı, tıbbi görüntü sınıflandırma görevi için farklı hibrit derin öğrenme modellerinin performansını karşılaştırmaktır. Bu amaca ulaşmak için, önceden eğitilmiş dört CNN modelini bir Swin Dönüştürücüsü ile entegre ederek dört hibrit model geliştirdik ve daha sonra etkinliklerini değerlendirdik. Bu dört hibrit model aşağıdaki gibidir:


1. Vgg16-Swin
2. InceptionV3-Swin
3. Densenet121-Swin
4. MobilenetV2-Swin

Bildiğimiz kadarıyla bu çalışma, BreakHis veri kümesi üzerinde çok sınıflı görüntü sınıflandırma görevleri için yukarıda bahsedilen önceden eğitilmiş CNN modelleri ile bir Swin Dönüştürücüsünü birleştiren ilk çalışmadır.

Bu bölümde swin dönüştürücü mimarisi ve CNN'in önceden eğitilmiş modellerinin mimarisine genel bir bakış sunulmuştur. Hibrit modelin yapısının açıklaması bu bölümün bir sonraki kısmına bırakılmıştır.

### 3.2.1 Vgg16 mimari tanımı


VGG16 modeli, Oxford Üniversitesi'ndeki Görsel Geometri Laboratuvarı tarafından üretilen bir CNN'dir (evrişimli sinir ağı). İlk yayınlandığı 2014 yılından bu yana görüntü tanımlama için en çok sevilen derin öğrenme modellerinden biri haline gelmiştir. VGG16 modelinin 16 katmanını on üç evrişimli katman ve üç tam bağlantılı katman oluşturmaktadır. Her konvolüsyonel katman bir piksellik bir adım ve 3'e 3'lük bir filtre boyutuna sahiptir. Özellik haritalarının çözünürlüğünü azaltmak ve girdinin uzamsal boyutlarını azaltmak için havuzlama katmanları kullanılır. Çıkarılan özellikler kullanılarak, görüntüleri kategorize etmek için tam bağlantılı katmanlar kullanılır (Karen Simonyan ve Andrew Zisserman 2014). Şekil 3.2'de gösterilen Vgg16 mimarisi.



### 3.2.2 Inception\_V3 mimari açıklaması

Inception V3'te görüntüler derin sinir ağı teknolojisi kullanılarak sınıflandırılmaktadır. Google araştırmacıları tarafından geliştirilen 2014 Inception mimarisinden geliştirilmiştir. Inception V3, 2015 yılında geliştirilmesinden bu yana en yaygın kullanılan görüntü tanıma programlarından biri haline gelmiştir. Inception V3'ün ana konsepti, bir dizi konvolüsyonel filtre kullanarak giriş görüntüsündeki farklı ölçeklerin özelliklerini eşzamanlı olarak yakalamaktır. Bunu başarmak için "Inception modülleri"

kullanılır ve çeşitli filtre boyutlarına sahip birkaç konvolüsyonel katmanın çıktıları bir sonraki katmana taşınmadan önce birleştirilir. Bu tekniklerin yanı sıra InceptionV3, performansı artırmak ve aşırı uyumu azaltmak için yardımcı sınıflandırıcılar, dropout ve toplu normalizasyon da kullanır. Her katmanın girdileri, aşırı uyumu azaltan ve eğitim verimliliğini artıran toplu normalleştirme ile normalleştirilir. Aşırı uyumu (overfitting) önlemek için, dropout adı verilen düzenli hale getirme tekniği, model eğitilirken belirli nöronları seçici olarak ortadan kaldırır. Gradyan akışına yardımcı olmak ve daha fazla eğitim sinyali sağlamak için ağ katmanları arasına yardımcı sınıflandırıcılar adı verilen başka bir sınıflandırıcı seti eklenir. Inception V3'ü diğer son teknoloji modellerden ayıran şeylerden biri de içerdiği parametre sayısının nispeten az olmasıdır. 1x1 konvolüsyonlar gibi boyutsallık azaltma stratejileri kullanılarak, bilgiden ödün vermeden özellik haritalarındaki kanal sayısını azaltmak mümkündür (Szegedy vd., 2015). Şekil 3.3'te gösterilen InceptionV3 mimarisi.




Şekil 3.3 InceptionV3 mimarisi (Kirelli ve Aydın 2023)

### 3.2.3 DenseNET121 mimari açıklaması

Densenet121 derin evrişimli ağlarda katmanlar arasında daha az bağlantının daha fazla hassasiyet, sistematikleştirme ve eğitim kolaylığı sağladığını göstermiştir. Ancak bu bağlantılar, kimlik eşleme yoluyla bilgiyi koruduklarından ve birkaç katmanın potansiyel olarak minimum etki yaratmasına veya hiç etki yaratmamasına neden olduklarından, Artık Ağlara benzer şekilde kaybolan gradyan sorununa yol açabilir. Bunu çözmek için, her katmanın çıktısının ileri beslemeli bir ağ aracılığıyla diğer her katmanın girdisine

bağlandığı yoğun bir konvolüsyon ağı geliştirilmiştir. Önceki katmanlardan elde edilen özellik haritası, kapsamlı bilgi toplamak için sonraki katmanlarda kullanılır. Daha doğru ve verimli bir şekilde eğitmenin yanı sıra daha küresel ve ilgili bilgiler elde etmek için bu ağ tasarımı kullanılabilir. Araştırmacılar tüm seviyelerden gelen bilgileri yeniden işlemiş ve daha sonra veri sınıflandırması için bu birleştirilmiş özellikleri kullanmıştır. Çok sayıda özellik haritasını birbirine bağlayan bu yöntemin amacı, katmanlar arasında özelliklerin yeniden kullanımını teşvik etmek değildir. Bu nedenle, önceki tüm seviyeler, tüm özellik haritalarını entegre etmek yerine girdi katmanları olarak işlev görür. Densenet121, Bileşim katmanı(Composition layer), Havuzlama katmanı (Pooling layer), Darboğaz katmanı (Bottleneck layer) ve Sıkıştırma katmanı (Compression layer) dahil olmak üzere çeşitli katman bloklarından oluşur (G. Huang vd., 2016). Şekil 3.4'te gösterilen Densenet121 mimarisi.

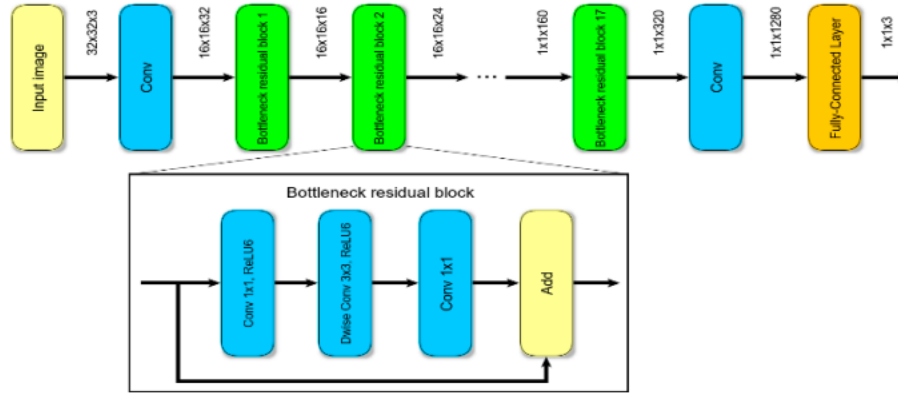


Şekil 3.4 Densenet121 mimarisi (G. Huang vd., 2016)

### 3.2.4 MobileNET\_v2 mimari açıklaması

Geleneksel 2D konvolüsyon katmanlarını kullanmak yerine, derinlemesine ayrılabilir konvolüsyon (depthwise separable convolution) katmanları, verimlilik sunan MobileNetV2 mimarisinin temelini oluşturmaktadır. Derinlemesine ayrılabilir konvolüsyon katmanı iki ana işlemin birleşimini içerir: derinlemesine konvolüsyon ve noktasal konvolüsyon (point-wise convolution). Derinlemesine konvolüsyon işlemi, giriş

resminin her kanalının çekirdeğin ilgili izole kanalıyla ayrı ayrı konvolüsyonunu içerir. Bu yaklaşım, giriş resmindeki bilgileri çeşitli kanallar üzerinden birleştirdiği için geleneksel 2D (iki boyutlu) konvolüsyon işleminden farklıdır. Noktasal konvolüsyon, geleneksel 2D konvolüsyon ile aynı çıktıyı elde etmek için derinlik konvolüsyonundan sonra uygulanmıştır. Noktasal konvolüsyon esasen  $1 \times 1$  çekirdeğe sahip geleneksel bir 2D konvolüsyondur, bu da yalnızca minimum miktarda parametre gerektirdiği anlamına gelir. Normal 2D konvolüsyon ile aynı sonucu veren derinlemesine ayrılabilir konvolüsyon katmanının etkinliğini en üst düzeye çıkarmak için ilgili parametre sayısını azaltın (Sandler vd., 2018). Şekil 3.5'te gösterilen MobilenetV2 mimarisi.




Şekil 3.5 Mobilenetv2 mimarisi (Seidaliyeva vd., 2020)

### 3.2.5 Swin transformatör mimarisi tanımı

Swin, hiyerarşik bir görme dönüştürücüsü olan genel amaçlı bir bilgisayarla görme omurgasıdır. Swin, yerel öz dikkati gerçekleştirmek için görsel yamaları sabit boyutlu pencereler halinde düzenleme yeteneği ile karakterize edilir. Birbirini takip eden iki yerel dikkat aşamasında, pencereler arasında bilgi aktarımını kolaylaştırmak için pencereleme tekniği yama boyutunun yarısı kadar ayarlanır. Genel yapı, hem yerel dikkatin hem de kaydırılmış yerel dikkatin birçok kez uygulandığı 4 adımdan oluşur. Dört komşu yama, her adımdan sonra yama boyutunun iki katı olan bir gömme kullanılarak birleştirilir. Swin, görüntü yamalarını ardışık katmanlarda birleştirerek hiyerarşik özellik haritaları oluşturur ve giriş görüntü boyutuna göre doğrusal bir hesaplama karmaşıklığını korur. Bu yaklaşım, Evrimsel Sinir Ağlarında (CNN'ler) yaygın olarak bulunan bazı önceki



özellikleri yeniden sunar (Ze Liu vd., 2021). Şekil 3.6'da gösterilen Swin Transformatör mimarisi.

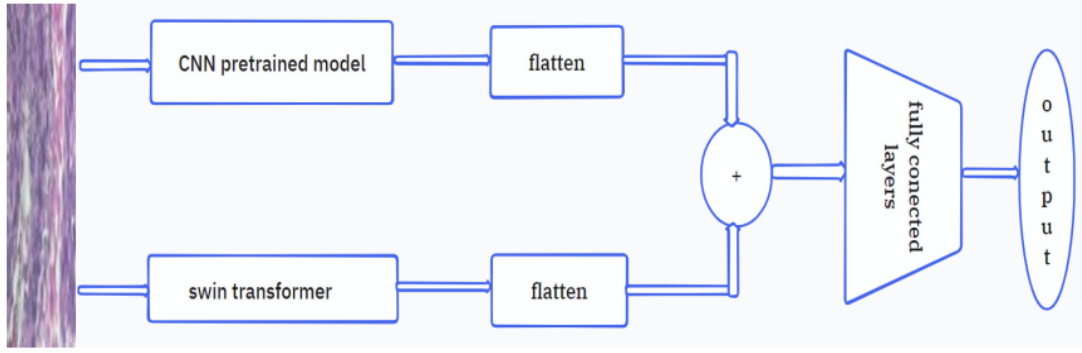


Şekil 3.6 Swin transformatör mimarisi (Ze Liu vd., 2021)

### 3.3 Önerilen Hibrit Model Mimarisinin Tanımı

Bu çalışma, yerel özellikleri yakalamada CNN'lerin önceden eğitilmiş modellerinin ve küresel özellikleri yakalamada Swin Transformer önceden eğitilmiş modelinin güçlü yönlerini birleştirerek görüntü sınıflandırması için hibrit bir derin öğrenme mimarisi önerdi. Katmanlarını dondurarak ve eğitim sırasında güncellenmelerini engelleyerek özellik çıkarma için önceden eğitilmiş modellerden yararlanıyoruz. Bu yaklaşım, aşırı uyumu azaltmayı ve öğrenilen özelliklerden faydalanmaya devam ederken potansiyel olarak eğitim süresinden tasarruf etmeyi amaçlamaktadır.

Önerilen hibrit modelde, hem CNN'ler hem de swin dönüştürücü giriş görüntüsünü bağımsız olarak işleyerek ayrı özellik tensörleri oluşturur. Bu özellikler daha sonra 1 boyutlu özellik tensörlerine düzleştirilir ve birleştirilerek her iki model tarafından çıkarılan bilgileri birleştiren tek bir özellik vektörü oluşturulur. Bu füzyon, görüntünün daha zengin ve daha kapsamlı bir temsiliyi yakalamayı amaçlamaktadır. daha sonra, nihai sınıf puanları ve olasılıkları oluşturmak için birleştirilmiş özellikleri tam bağlı katmanlardan oluşan eğitilebilir sınıflandırıcıya besleriz. Önerilen hibrit modelin genel mimarisi Şekil 3.7'de gösterilmektedir.



Şekil 3.7 Önerilen hibrit modelin mimarisi

### 3.4 Deneysel Detayları

#### 3.4.1 Eğitim ve hiperparametreler ayarları

Çalışma uygulama süreci iki aşamadan oluşmaktadır. İlk aşamada, performanslarını değerlendirmek ve en iyi kontrol noktasını kaydetmek için CNN'leri ve swin transformatör modellerini bağımsız olarak eğittik. İkinci aşamada ise CNNs modellerini swin transformer ile birleştirerek hibrit model mimarileri oluşturduk.

İlk aşamada, modelleri 15 epok için eğittik. CNN modellerini optimize etmek için 0.00001 öğrenme oranına sahip Adam optimizer ve swin transformer modellerini optimize etmek için 0.1 öğrenme oranına sahip Adadelta optimizer kullandık.

Hibrit modeller ikinci aşamada on epok boyunca eğitilmiştir. Hibrit model eğitim aşamasında, öğrenme oranı (0.00001) olarak ayarlanmış Adam optimize edicileri kullanılmıştır. Her iki aşamada da, yığın boyutu (batch size) için 32 seçtik ve kayıp fonksiyonu olarak çapraz entropiyi (cross entropy) kullandık. Tablo 3.2 hiperparametre ayarlarını göstermektedir. Tablo 3.2 hiperparametre ayarlarını göstermektedir.

Çizelge 3.2 Hiperparametre ayarları

Model adı	İlk Aşama Hiperparametreleri		İkinci Aşama Hiperparametreleri
	CNN'lerin ön eğitilmiş modelleri	Swin-base transformatör	Önerilen hibrit modeller
Optimizer	Adam	Adadelata	Adam
Weight Decay	0.01	-	-
Öğrenme Oranı(Lr)	0.00001	0.1	0.00001
Epok	15	10	10
Yığın Boyutu (Batch Size)	32	32	32
Kayıp Fonksiyonu (Loss Function)	Cross entropy	Cross entropy	Cross entropy

### 3.4.2 Yazılım ve deney ortamı

Deneysel çalışma Windows 11 işletim sistemi üzerinde Python versiyonu (3.8.8) programlama dili kullanılarak gerçekleştirilmiştir. Modellerimizi oluşturmak için derin öğrenme çerçevesi olarak PyTorch sürümünü (1.13.0) kullandık. Deneylerimizde V100 GPU ile google Colab Pro+ kullanılmıştır.

### 3.5 Değerlendirme Matrisleri

Tümör tipleri arasındaki örnek sayılarındaki dengesizlik nedeniyle, doğruluğa ek olarak F1-skoru, geri çağırma ve kesinlik gibi ek performans ölçütlerinin de dikkate alınması tavsiye edilir. Karışıklık matrisleri kullanılmıştır. Aşağıda, gerçek pozitifler (TP), gerçek negatifler (TN), yanlış pozitifler (FP) ve yanlış negatifler (FN) kullanılarak hesaplanan çeşitli performans ölçütlerinin matematiksel formülleri yer almaktadır. Sekiz sınıflı sınıflandırma görevi için, geri çağırma, özgüllük ve kesinliği hesaplamak için bire karşı geri kalan stratejisi kullanılmıştır. Karışıklık matrisi analizine dayanarak, köşegenin üzerinde yer alan yanlış sınıflandırmalar Yanlış Pozitifler (FP'ler) olarak tanımlanırken, köşegenin altındaki yanlış sınıflandırmalar Yanlış Negatifler (FN'ler) olarak etiketlenmiştir. TN'ler, verilen sınıf dışındaki sınıflar için doğru sınıflandırılmış örneklerin sayısını temsil eder. Aşağıda, Denklem (1) - (4)'te gösterildiği gibi performans ölçütleri için matematiksel formüller yer almaktadır.

Doğruluk (Accuracy): test için kullanılan tüm gerçek görüntülerden doğru tanımlanan görüntülerin yüzdesini hesaplayarak bir modelin doğruluğunu değerlendiren bir metriktir.

$$\text{Doğruluk(Accuracy)}=(\text{TP}+\text{TN})/(\text{TP}+\text{TN}+\text{FP}+\text{FN}) \quad (1)$$

Hassasiyet (Sensitivity): genellikle geri çağırma olarak adlandırılır ve bir modelin kapsamlılığını değerlendirir. Bu metrik, gerçekten aynı sınıfa ait olan tüm görüntülere kıyasla belirtilen sınıfa ait olarak doğru şekilde tanımlanan görüntülerin oranını hesaplar.

$$\text{Geri Çağırma (Recall)} = \text{TP}/(\text{TP}+\text{FN}) \quad (2)$$

Kesinlik (Precision): aynı sınıfa ait olduğu gösterilen tüm görüntüler arasında doğru tanımlanan hedef sınıf görüntülerinin oranını belirleyerek bir modelin doğruluğunu değerlendiren bir metriktir.

$$\text{Kesinlik (Precision)} = \text{TP}/(\text{TP}+\text{FP}) \quad (3)$$

F1-skoru (F1-score): hem geri çağırma hem de hassasiyetin harmoniklerinin ortalamasıdır ve genellikle geri çağırma veya hassasiyet için modele ince ayar yapmak için kullanılır.

$$\text{F-1 skoru (F1-score)} = 2 * ((\text{Geri Çağırma} * \text{Kesinlik}) / (\text{Geri Çağırma} + \text{Kesinlik})) \quad (4)$$

## 4. BULGULAR ve TARTIŞMA

Bu çalışmanın amacı konvolüsyonel sinir ağları ve dikkat mekanizmalarının bir hibrit modelde kombinasyonunu hazırlamak ve değerlendirmek olduğu için bu bölümü dört ana bölüm halinde düzenledik. İlk bölümde, bireysel modellerin performansının bir özetini sunduk. Bunu takiben, ikinci bölümde hazırlanan hibrit modellerin performans analizini daha ayrıntılı olarak inceledik. Daha sonra, üçüncü bölümde, geliştirdiğimiz hibrit modellerin sonuçlarını önceki araştırmalarla karşılaştırdık. Daha sonra, bu bölümü tamamlamak için dördüncü bölümde çalışmanın kısıtlamalarını tartıştık.

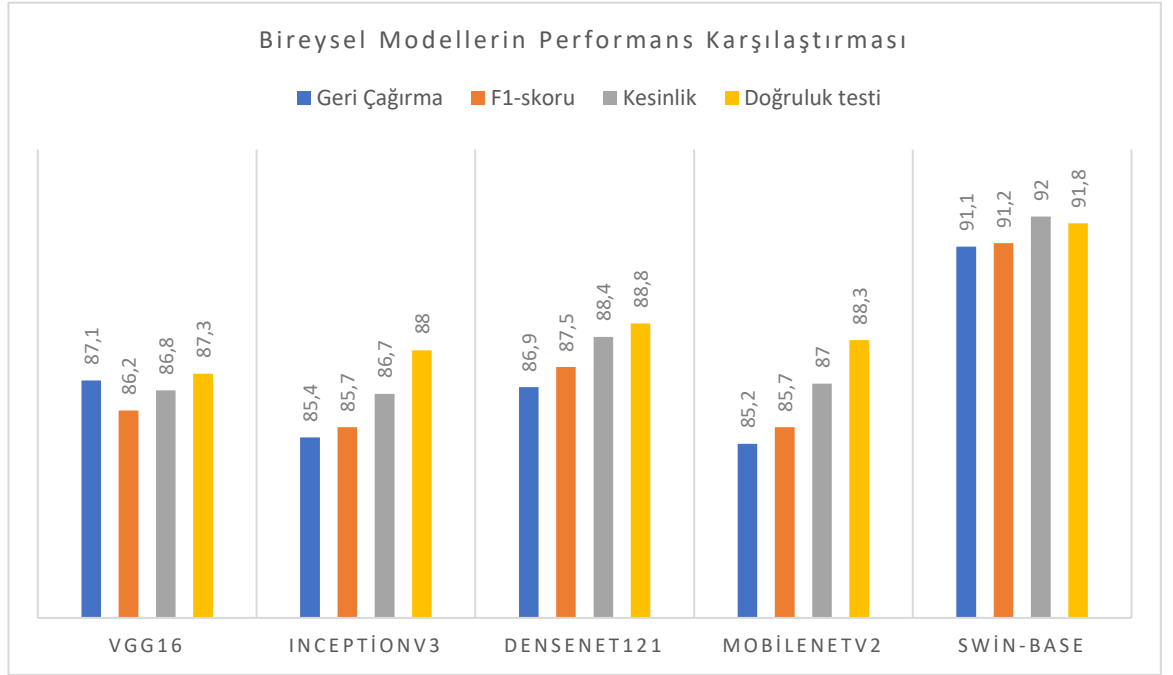
Bu bölümde, her bir hibrit modeli, performansını değerlendirmek için test doğruluğu, hassasiyet (geri çağırma), kesinlik ve F1-skoru gibi belirlenmiş kriterlere göre değerlendirdik.

### 4.1 Bireysel Modellerin Performans Açıklaması

Bireysel modellerin performansı incelendiğinde, swin transformatörü %91,8 test doğruluğu, %91,1 geri çağırma, %92 kesinlik ve %91,2 f1-skoru elde ederek daha önce tanımlanan kriterlerin tümünde konvolüsyon sinir ağını geçmiştir. Konvolüsyonel sinir ağlarının performansı ile ilgili olarak, DenseNet121'in %88,4 hassasiyet, %87,5 f1-skor ve %88 test doğruluğu elde ederek diğer CNN modellerini geride bıraktığı gözlemlenmiştir. Mobilenet-V2, Vgg16 ve Inception-V3 ise nispeten karşılaştırılabilir bir performans sergilemiştir. Çizelge 4.1 tek tek modellerin (Vgg16, Inception-v3, Densenet121, Mobilenet-V2 ve Swin-base) performanslarının sınıflandırma raporunu gösterirken, şekil 4.1'de bu modellerin performanslarının karşılaştırmasını göstermektedir.

Çizelge 4.1 Bireysel modellerin sınıflandırma raporu

Model Adı	Geri Çağırma	F1-skoru	Kesinlik	Doğruluk Testi
Vgg16	87.1%	86.2%	86.8%	87.3%
InceptionNET-V3	85.4%	85.7%	86.7%	88.0%
DenseNET121	86.9%	87.5%	88.4%	88.8%
MobileNET-V2	85.2%	85.7%	87.0%	88.3%
Swin-base	91.1%	91.2%	92.0%	91.8%



Şekil 4.1 Bireysel modellerin performans karşılaştırması

#### 4.2 Önerilen Hibrit Modellerin Performans Analizi

Bu bölümde, önerilen dört hibrit model olan Inceptionv3-Swin, VGG16-Swin, Densenet121-Swin ve MobilenetV2-Swin'in performansını çok sınıflı sınıflandırma görevinde 200x büyüklük faktörüne sahip görüntüler üzerinde karşılaştırdık. İş akışımızda, her hibrit modelin sonuçlarının bir analizini yaparak başladık. Daha sonra dört hibrit modelin performansını değerlendirmeye ve karşılaştırmaya devam ettik.


#### 4.2.1 Inceptionv2-Swin hibrit modeli

Model, %96.0'lık doğruluk oranıyla papiller karsinomların ve fillodların sınıflandırılmasında oldukça başarılı olmuştur. Adenozun sınıflandırılması, %94.0 test doğruluk oranı ile mükemmel olduğu bir başka alandı. Tübüler adenom ve fibroadenomun sınıflandırılmasında, sırasıyla yaklaşık %91.0 ve %90.0 sınıflandırma testi doğruluğu ile iyi performans göstermiştir. Ayrıca, lobüler karsinom, duktal karsinom ve müsinöz karsinom için sırasıyla %87.0, %83.0 ve %79.0 sınıflandırma testi doğruluğu ile başarılı olmuştur. Çizelge 4.2 InceptionV3-Swin hibrit modelinin sınıflandırma raporunu gösterirken, şekil 4.2 inceptionV3-Swin hibrit modelinin performansını göstermektedir.


InceptionV2-swin hibrit modelinin genel test doğruluğu %90.0 iken, modelin genel hassasiyet, geri çağırma ve f1-skoru sırasıyla %89.7, %89.9 ve %89.4'tür. Şekil 4.3 Inception-Swin'in hibrit modelinin karışıklık matrisi gösterilmektedir.

Çizelge 4.2 InceptionV3-Swin hibrit modelinin sınıflandırma raporu

InceptionV3-Swin Hibrit Modelinin Sınıflandırma Raporu			
Tümör Alt Türü	Kesinlik	Geri Çağırma	F1-Skoru
Adenozis	85.0%	94.0%	89.0%
Fibroadenom	95.0%	90.0%	92.0%
Phyllodes Tümörü	93.0%	96.0%	95.0%
Tübüler Adenom	67.0%	92.0%	78.0%
Duktal Karsinom	86.0%	83.0%	85.0%
Lobüler Karsinom	96.0%	79.0%	87.0%
Müsinöz Karsinom	100.0%	88.0%	93.0%
Papiller Karsinom	97.0%	97.0%	97.0%
Genel Test Doğruluğu	90.0%		



Şekil 4.2 Inceptionv3-Swin hibrit modelinin performansı



Şekil 4.3 Inception-Swin'in hibrit modelinin karışıklık matrisi




#### 4.2.2 Vgg16-Swin hibrit modeli

Model, Fibroadenom ve Duktal Karsinom sınıflandırmasında %97.0 test doğruluk oranıyla olağanüstü bir performans göstermiştir. Benzer şekilde, model Papiller Karsinom sınıflandırmasında %96.0 test doğruluk oranı göstermiştir. Model, sırasıyla %93.0 ve %91.0 test doğruluğu ile Phyllodes Tümörü ve Adenosis sınıflandırmasında iyi performans göstermiştir. Performans tatmin edici olmakla birlikte, Müsinöz Karsinom ve Lobüler Karsinom sınıflandırmasında test doğruluğu sırasıyla %86.0 ve %80.0 olmuştur.


Ancak, Tübüler Adenom sınıflandırmasındaki test doğruluğu sadece %60.0'tır ve bu da bir zayıflığa işaret etmektedir. Çizelge 4.3'te Vgg16-Swin hibrit modelinin sınıflandırma raporu gösterilirken, şekil 4.4'te Vgg16-Swin hibrit modelinin performansı gösterilmektedir. Modelin genel test doğruluğu %91.5'e ulaşırken, modelin genel kesinlik, geri çağırma ve f1-skoru sırasıyla %92.7, %87.8 ve %89.9 olmuştur. Şekil 4.5 karışıklık matrisi vgg16-swin hibrit modeli gösterilmektedir.

Çizelge 4.3 Vgg16-Swin hibrit modelinin sınıflandırma raporu

Vgg16-Swin Hibrit Modelinin Sınıflandırma Raporu			
Tümör Alt Türü	Kesinlik	Geri Çağırma	F1-Skoru
Adenozis	100.0%	91.0%	95.0%
Fibroadenom	89.0%	98.0%	93.0%
Phyllodes Tümörü	95.0%	93.0%	94.0%
Tübüler Adenom	78.0%	60.0%	68.0%
Duktal Karsinom	97.0%	97.0%	97.0%
Lobüler Karsinom	100.0%	80.0%	89.0%
Müsinöz Karsinom	87.0%	87.0%	87.0%
Papiller Karsinom	97.0%	97.0%	97.0%
Genel Test Doğruluğu	91.5%		



Şekil 4.4 Vgg16-Swin hibrit modelinin performansı



Şekil 4.5 Vgg16-Swin hibrit modelinin karışıklık matrisi

#### 4.2.3 Densenet121-Swin hibrit modeli

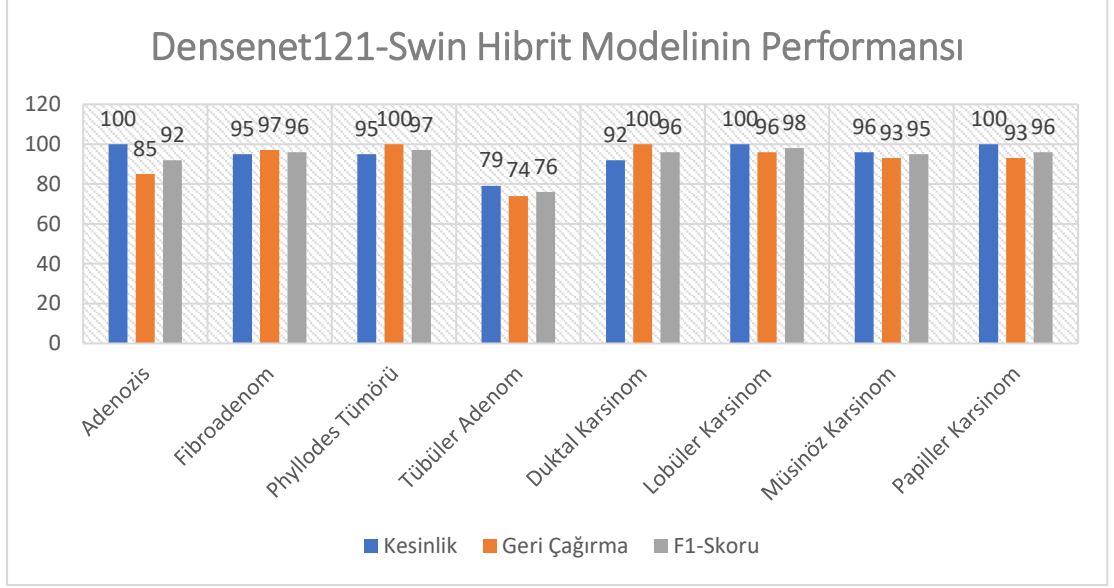
Hibrit Densenet-Swin modelinin karışıklık matrisine dayanarak, model tümörlerin yedek alt tipleri olan Phyllodes tümörü ve duktal karsinomunu tanımlamada %100.0 başarı oranı

elde etmiştir. Ayrıca fibroadenom ve lobüler karsinom sınıflandırmasında %96.0 başarı oranına sahiptir. Model ayrıca iki tümör alt tipi olan müsinöz karsinom ve papiller karsinomu sınıflandırmada yaklaşık %93.0'lük değerli bir test doğruluğu göstermiştir. Adenoza sınıflandırma kabiliyeti de %85.0'lik test doğruluk oranıyla kayda değerdi. Aynı zamanda, tübüler adenomu kabul edilebilir bir doğrulukla sınıflandırmada yetersizlik göstermiştir; bu oran %74.0'tür.


Densenet121-Swin hibrit modelinin genel test doğruluğu %94,4 iken, modelin genel kesinlik, geri çağırma ve f1-skoru sırasıyla %94,6, %92,2 ve %93,2'dir. Çizelge 4.4'te Densenet121-Swin hibrit modelinin sınıflandırma raporu gösterilirken, Şekil 4.6'da Densenet121-Swin hibrit modelinin performansı gösterilmektedir. Şekil 4.7 Densenet121-Swin hibrit modelinin karışıklık matrisi.

Çizelge 4.4 Dense121-Swin hibrit modelinin sınıflandırma raporu

Dense121-Swin Hibrit Modelinin Sınıflandırma Raporu			
Tümör alt tipi	Kesinlik	Geri Çağırma	F1-Skoru
Adenozis	100.0%	85.0%	92.0%
Fibroadenom	95.0%	97.0%	96.0%
Phyllodes Tümörü	95.0%	100.0%	97.0%
Tübüler Adenom	79.0%	74.0%	76.0%
Duktal Karsinom	92.0%	100.0%	96.0%
Lobüler Karsinom	100.0%	96.0%	98.0%
Müsinöz Karsinom	96.0%	93.0%	95.0%
Papiller Karsinom	100.0%	93.0%	96.0%
Genel Test Doğruluğu	94.4%		



Şekil 4.6 Densenet121-Swin hibrit modelinin performansı



Şekil 4.7 Densenet121-Swin hibrit modelinin karışıklık matrisi

#### 4.2.4 Mobilenetv2-Swin hibrit modeli


Model, beş kanser alt türünün doğru teşhisinde mükemmel performans göstermiştir: Adenozis, Phyllodes Tümörü, lobüler karsinom, müsinöz karsinom ve papiller karsinom;

%100.0'lük mükemmel bir test doğruluk oranı elde etmiştir. Buna ek olarak, iki kanser türünün teşhisinde üstün performans göstermiştir: fibroadenom ve duktal karsinom, teşhiste sırasıyla yüzde %94.0 ve %95.0 doğrulukla. Tübüler adenomu tanımlamadaki doğruluk yüzdesi ise %87.0'dir. Çizelge 4.5 mobilenetV2-Swin hibrit modelinin sınıflandırma raporunu gösterirken, şekil 4.8 MobileNetV2-Swin hibrit modelinin performansını göstermektedir.


MobileNetV2-Swin hibrit modelinin genel test doğruluğu %95,7 iken, modelin genel kesinlik, geri çağırma ve f1-skoru sırasıyla %96.0, %97.0 ve %96,5'tir. Şekil 4.9 mobilenetV2-Swin hibrit modelinin karışıklık matrisi.

Çizelge 4.5 MobileV2-Swin hibrit modelinin sınıflandırma raporu

MobileV2-Swin hibrit modelinin sınıflandırma raporu			
Tümör alt tipi	Kesinlik	Geri Çağırma	F1-Skoru
Adenozis	100.0%	100.0%	100.0%
Fibroadenom	96.0%	94.0%	95.0%
Phyllodes Tümörü	100.0%	100.0%	100.0%
Tübüler Adenom	81.0%	87.0%	84.0%
Duktal Karsinom	97.0%	95.0%	96.0%
Lobüler Karsinom	94.0%	100.0%	97.0%
Müsinöz Karsinom	100.0%	100.0%	100.0%
Papiller Karsinom	100.0%	100.0%	100.0%
Genel Test Doğruluğu	95.7%		



Şekil 4.8 Mobilenetv2-Swin hibrit modelinin performansını



Şekil 4.9 Mobilenetv2-Swin hibrit modelinin karışıklık matrisi

#### 4.2.5 Dört hibrit modelin performansının karşılaştırılması

Bu çalışmada geliştirilen dört hibrit modelden MobilenetV2-Swin hibrit modeli %95.7'lik genel doğruluk oranıyla en yüksek performansı göstermiştir. Beş tümör alt tipini (adenozis, fillodes tümör, Lobüler Karsinom, Müsinöz Karsinom ve pupiller Karsinom) %100.0 test doğruluğu ile doğru bir şekilde kategorize edebilmiştir.

Densenet121-Swin hibrit modeli yüzde 94.4 ile genel doğrulukta ikinci sırada yer almasına rağmen, aşağıdaki çekme alt kategorilerini (Phyllodes Tümörü, Duktal Karsinom) sınıflandırmada mükemmel doğruluk göstermiştir. Vgg16-Swin hibrit modelinin performansı, genel olarak %91.5'lik bir test doğruluk oranıyla nispeten iyiydi. Ürettiğimiz dört model arasında, InceptionV3-Swin hibrit modeli %90.0'ın üzerine çıkmayan test doğruluğu ile en kötü performansı göstermiştir. Ancak, yüzde 91.0'e ulaşan doğruluk oranıyla Tübüler Adenomu sınıflandırmada en iyisiydi.


Dört hibrit modelin genel performansının karşılaştırılması Çizelge 4.6 ve Şekil 4.10'da gösterilirken, dört hibrit modelin kanser alt türlerini sınıflandırmadaki performansının karşılaştırılması Çizelge 4.7'de ayrıntılı olarak verilmiştir.

Çizelge 4.6 Dört hibrit modelin genel performansının karşılaştırılması

Model Adı	Geri Çağırma	F1-Skoru	Kesinlik	Test Doğruluğu
Vgg16-Swin	87.8%	89.9%	92.7%	91.5%
InceptionV3-Swin	89.9%	89.4%	89.7%	90.0%
Dense121-Swin	92.2%	93.2%	94.6%	94.4%
Mobilev2-Swin	97.0%	96.5%	96.0%	95.7%

Çizelge 4.7 Dört hibrit modelin kanser alt türlerini sınıflandırmadaki performansının karşılaştırılması

Dört Hibrit Modelin Kanser Alt Türlerini Sınıflandırmadaki Performansının Karşılaştırılması				
Tümör alt tipi	Inceptionv3-swin	Vgg16-Swin	Densenet121-Swin	MobilenetV2-Swin
Adenozis	94.0%	91.0%	85.0%	100.0%
Fibroadenom	90.0%	97.0%	100.0%	94.0%
Phyllodes Tümörü	96.0%	93.0%	100.0%	100.0%
Tübüler Adenom	91.0%	60.0%	74.0%	87.0%
Duktal Karsinom	83.0%	97.0%	100.0%	95.0%
Lobüler Karsinom	87.0%	80.0%	96.0%	100.0%
Müsinöz Karsinom	79.0%	86.0%	93.0%	100.0%
Papiller Karsinom	96.0%	96.0%	93.0%	100.0%



Şekil 4.10 Dört hibrit modelin genel performansının karşılaştırılması



### 4.3 Tartışma

Bu tezde, dört CNN ön eğitimli modeli (inceptionV3, Vgg16, Densenet121, MobilenetV2) ve bir swin dönüştürücüsünü temel alan dört hibrit model önerdik. Çizelge 4.8'da gösterildiği gibi, önerdiğimiz hibrit model (MobilenetV2-Swin) önceki çalışmalardan daha iyi performans göstermiştir. Buna karşılık, önerilen hibrit modelimiz (Densenet121-Swin) meme kanseri histopatolojik görüntülerini sınıflandırmada rekabetçi bir sonuç elde etmiştir (test doğruluğu, geri çağırma, kesinlik, F1-skoru ve karışıklık matrisine dayalı olarak). Bildiğimiz kadarıyla, swin transformatörünün bu dört CNN ön eğitimli modelle kombinasyonu ilk kez meme kanseri histopatoloji görüntülerinin çoklu sınıflandırmasına uygulanmıştır. Histopatoloji görüntülerinin doğru sınıflandırılması, meme kanserinin erken teşhisinde çok önemli bir rol oynamaktadır. CNN ve swin transformer'ı entegre eden hibrit model, CNN'in yerel bilgi özelliklerini yakalama gücünden ve swin transformer'ın uzun menzilli modelleme yeteneklerinden yararlanır. Bu kombinasyon, modelin kısa bir eğitim süresi içinde olumlu sonuçlar vermesini sağlar. Dikkat mekanizmasının dahil edilmesi, uzamsal bilgileri daha etkili bir şekilde kavrama yeteneğini geliştirmiştir. İkinci olarak, iki farklı yol kullanarak yerel ve küresel bilgileri çıkardık. Sonuçta, görüntünün farklı sınıfı hem küresel hem de yerel bilgiler birleştirilerek belirlendi ve bu da olağanüstü sınıflandırma doğruluğu ve güçlü genelleme yetenekleri ile sonuçlandı. Üçüncü olarak, geçmiş bilgi olmadan sıfırdan başlarken ağır eğitim iş yükü sorununu ele almak için transfer öğrenimi kullanıldı ve eğitim süresinde bir azalma sağlandı. Önceden eğitilmiş ağırlıkların kullanılması modelin performansının artmasını sağlamıştır. BreakHis veri kümesi üzerinde yapılan önceki çalışmalara ilişkin analizimiz, çalışmaların çoğunun yalnızca klasik Evrişimsel Sinir Ağları (CNN) veya Görme Dönüştürücüleri kullandığını ve her iki metodolojiyi entegre etmediğini ortaya koymuştur. Örneğin (Bardou vd., 2018), özellik çıkarıcı olarak özel bir Evrişimsel Sinir Ağı (CNN) kullanarak ve CNN çıktısında sınıflandırıcı olarak K-En Yakın Komşuları (KNN) kullanarak hibrit bir yöntem uygulamıştır. Ancak, bu yaklaşımın test doğruluğu %70,08'i geçmemiş, KNN sınıflandırıcısını doğrusal destek vektörü (SVM) ile değiştirdiklerinde test doğruluğu %66,45'e düşmüştür.

(Boumaraf vd., 2021) çalışmalarında ResNet-18'in önceden eğitilmiş modelinin görüntü sınıflandırma performansını artırmayı amaçlamıştır. Bunu, ResNet-18'in son iki artık bloğunun ağırlıklarını BreakHis veri kümesi üzerinde yeniden eğiterek belirli görevlere daha uygun hale getirerek başardılar. Çabaları %91,29'luk kayda değer bir test doğruluğu ile sonuçlanmıştır. (Boumaraf vd., 2021) tarafından yapılan bir başka çalışma, Breakhis veri kümesinde Vgg-19'a blok blok ince ayar yaparak başka bir derin öğrenme modeli üzerinde önceki çalışmalarındaki aynı başarıyı tekrarlamaya çalışmıştır. Ancak, son araştırmaları, test doğruluğunun %79,12'yi geçmediği ResNET-18 modeli üzerindeki önceki çalışmalarıyla aynı başarı düzeyine ulaşamamıştır.

(Albhashish vd., 2021) Vgg16'yı bir özellik çıkarıcı olarak kullanmış ve çeşitli sınıflandırıcılarla test etmiştir. En başarılı sonuç, %89,83'lük bir test doğruluğu sağlayan RBF SVM sınıflandırıcısı kullanıldığında gözlemlenmiştir. Meme kanseri vakalarını sınıflandırmak için (Kate ve Shukla 2021) rastgele yamaların çıkarılmasına dayanan ve derinlemesine konvolüsyonları zorlayan bir konvolüsyonel Derin Ağ modeli tanıtmıştır. Nihai görüntü sınıflandırma kategorisi, rastgele seçilen yamaların sınıflandırma sonuçlarının çoğunluk oylama yöntemiyle toplanmasıyla belirlenir. Yüzde 86,53'lük bir doğruluk oranı elde edilmiştir.

Önceden eğitilmiş beş CNN modelinin (Xception, DenseNet201, Inception ResNet V2, VGG19 ve ResNet152) performansı, meme tümörü teşhisi için güvenilir bir DL modeli keşfetmek üzere (Zaalouk vd., 2022) tarafından iki senaryo ile incelenmiştir. İlk durumda 0.0001 olan öğrenme oranı ikinci durumda 0.00001 olarak kullanılmıştır. DenseNet201 ikinci senaryoda en iyi performansı göstererek %86,07 test doğruluğu elde ederken, Xception ilk senaryoda %91,54 ile en yüksek doğruluğu elde etmiştir. Daha önce bahsedilen çalışmalarla aynı hedefe ulaşmak için (Srikantamurthy vd., 2023) bir konvolüsyonel sinir ağını (CNN) bir LSTM RNN ile birleştiren hibrit bir model oluşturmuştur. Hibrit modelin doğruluğu %88,04'ün üzerine çıkmamıştır. (Tummala vd., 2022) swin transformatörünün varyant versiyonlarını (swin-tiny, swin-small, swin-base, swin-large) incelemiş ve çok sınıflı meme kanserini sınıflandırmak için bir topluluk modeli geliştirmiş, sırasıyla %90.4, %91.6, %92.3, %92.3 ve %93.5 doğruluk elde etmişlerdir.

Evrişimsel Blok Dikkat Modülü adı verilen çift dikkat modülü ve Evrişimsel Çok Katmanlı Algılayıcı (Liang ve Meng 2023) tarafından önerilen Brea-NET adlı esnek bir sınıflandırıcı kullanılarak, brea-net tarafından elde edilen test doğruluğu %95,32 olmuştur. (Wangsaputra vd., 2023) tarafından yazılan bir deneyde, bir torbalama sınıflandırıcısı uygulamadan önce Vgg16 kullanarak özellikleri çıkarmak için bir ön işleme adımı olarak bir Uyarlanabilir Ortalama Filtre (AMF) kullanılmıştır. Bu elde edilen doğruluk oranı  $62,64 \pm 2,0$  olarak bildirilmiştir.

(Vikranth vd., 2022) meme kanseri sınıflandırması için önerilen model, önceden eğitilmiş bir MobileNetV2 ağını, ardından küresel ortalama havuzlama katmanını, bırakmayı ve toplu normalleştirmeyi içermektedir. Sınıflandırma görevinin üstesinden gelmek için SVM sınıflandırıcı kullanılmıştır. Model test doğruluğu %88'e ulaşmıştır. Buna ek olarak, (Xu vd., 2022) tarafından geliştirilen çok etkili bir model %95,39 gibi etkileyici bir doğruluk oranı göstermiştir. Yaklaşımları, özellik çıkarıcı olarak densenet201'in uygulanmasını ve sınıflandırıcı olarak SVM RPF'nin kullanılmasını içeriyordu.

Bu tezde, Swin tabanlı dönüştürücünün, histopatolojik görüntülerden meme kanserinin otomatik sınıflandırılması için önceden eğitilmiş dört CNN modeliyle birleştirilmesinin etkinliği, BreaKHis veri kümesinin 200x büyüklük yakınlaştırma faktörü kullanılarak sekiz sınıflı sınıflandırma sistemleri için incelenmiştir. Bu nedenle, adil bir yargıya varmak için, önerdiğimiz modellerin performansını Breakhis veri kümesinin aynı büyüklükteki yakınlaştırma faktörü (200x) üzerinde yapılan önceki çalışmaların sonuçlarıyla karşılaştırdık.

Çizelge 4.8 Sekiz sınıflı sınıflandırma rejimleri için BreaKHis veri kümesi histopatoloji görüntülerini

Çalışma	Yıl	Yöntem	Doğruluk
Bardou vd.,	2018	Deep CNN features (trained from scratch) with KNN classifier on top	70.08%
Bardou vd.,	2018	Deep CNN features (trained from scratch) with Linear SVM classifier on top.	66.45%
Boumaraf vd.,	2021	Vgg19	79.12%
Boumaraf vd.,	2021	ResNET-18	91.29%
Kate ve Shukla	2021	Deep net model	86.53%
Albashish vd.,	2021	Vgg16 +RBF SVM Classifier	89.83%
Zaalouk vd.,	2022	Xception	91.54%
Zaalouk vd.,	2022	DenseNet201	86.07%
Tummala vd.,	2022	Swin-Tiny	90.60%
Tummala vd.,	2022	Swin-Small	91.60%
Tummala vd.,	2022	Swin-Base	92.30%
Tummala vd.,	2022	swin-Large	92.30%
Tummala vd.,	2022	Ensemble Swin,s	93.50%
Vikranth vd.,	2022	MobileNetV2 +SVM classifier	88.00%
Xu vd.,	2022	DenseNet201 +SVM RBF	95.38%
Srikantamurthy vd.,	2023	Hybrid CNN-LSTM	88.04%
Liang ve Meng	2023	Brea net	95.32%,
Wangsaputra vd.,	2023	Adaptive Mean Filter (AMF)+Vgg16+bagging classifier	62.64±2.0
<b>Önerdiğimiz model</b>	<b>2024</b>	<b>Hibrit model (Densenet121-Swin)</b>	<b>94.40%</b>
<b>Önerdiğimiz model</b>	<b>2024</b>	<b>Hibrit model (MobilenetV2-Swin)</b>	<b>95.70%</b>

200x büyüklük yakınlaştırma faktörü ile kullanan daha önceki çalışmalar ile bizim çalışmamızı karşılaştırmaktadır

#### 4.4 Çalışmanın Sınırlılıkları

Hesaplama maliyeti nedeniyle, önerilen yöntemlerin Breakhis veri kümesi kullanılarak 200x ölçeğinde test edildiğini belirtmek gerekir. Bununla birlikte, Breakhis veri setindeki performansı 40x, 100x ve 400x büyütmelemlerde değerlendirmek için ek bir inceleme gereklidir.

Önerilen tekniklerin Swin Transformer temel modeli kullanılarak değerlendirildiğini belirtmek önemlidir. Bu yaklaşımların diğer görüntü dönüştürücüler üzerinde test edilmesi çok önemlidir.

Ayrıca, önerilen yöntemlerin bu araştırmaya dahil edilmeyen CNN ağları üzerinde test edilmesinin uygulanabilirliğini incelemek için daha fazla araştırma yapılması gerektiğini belirtmek de önemlidir.

## 5. SONUÇLAR

Bu tezde, histopatoloji slaytlarını kullanarak meme kanserinin sekiz sınıf sınıflandırma görevi için farklı hibrit modeller sunduk. Dört iyi huylu sınıfı (Phyllodes Tümörü (PT), Adenosis (A), Tubular Adenoma (TA) ve Fibroadenoma (F)) ve dört kötü huylu sınıfı (Mucinous Carcinoma (MC), Lobular Carcinoma (LC), Ductal Carcinoma (DC) ve Papillary Carcinoma (PC)) temsil eden Breakhis veri kümesinde 200x büyüklük faktörü kullandık. Swin dönüştürücüsünü dört popüler CNN ön eğitilmiş modeller (Inceptionv2, Densenet121, Mobilenetv2 ve Vgg16) entegre ederek dört hibrit model önerdik. Önerilen hibrit modellerin performansını adil bir şekilde değerlendirmek için hassasiyet, doğruluk, geri çağırma ve f1 puanı dahil olmak üzere dört değerlendirme ölçütü uyguladık. Mobilenetv2-Swin hibrit modeli, son derece yüksek performans elde ettiği umut verici bir sonuç göstermiştir. Meme tümörü histopatoloji görüntülerinin beş alt türünü (Adenosis (A), Papiller Karsinom (PC), Phyllodes Tümörü (PT), Müsinöz Karsinom (MC) ve Lobüler Karsinom (LC)) %100,0'lük mükemmel bir test doğruluğu oranıyla sınıflandırabildi. MobilenetV2-Swin hibrit modeli genel test doğruluğu %95.7 model genel hassasiyeti, geri çağırma ve f1-skoru sırasıyla %96.0, %97.0 ve %96.5 olmuştur. Önceki modele ek olarak, Densenet121-Swin hibrit modeli, meme kanserinin iki alt türünü ((Phyllodes Tümörü (PT) ve Duktal Karsinom (DC)) 100.0 test doğruluğu ile sınıflandırarak mükemmel performans elde etmiştir. Ayrıca, Densenet121-Swin hibrit modeli sırasıyla %94.4, %94.6 %92.2 ve %93.2 genel test doğruluğu, kesinlik, geri çağırma ve f1-skoru elde etmiştir. Diğer iki hibrit model olan VGG16-Swin ve InceptionV2-Swin'in performansı tatmin edici olsa da, sırasıyla %91.5 ve %90.0 doğruluk elde ederek rekabetçi olamamıştır. Bu çalışmanın sonuçlarının hem araştırmacılar hem de sağlık uzmanları için faydalı olacağını umuyoruz.

Gelecekte araştırmamızı, mamografi ve röntgen görüntüleri de dahil olmak üzere çeşitli meme tümörü görüntülerini incelemenin yanı sıra meme kanseri derecesinin sınıflandırılmasını da içerecek şekilde genişletmeyi planlıyoruz.

## KAYNAKLAR

- Abdulaal, A.H., Valizadeh, M., Albaker, B.M., Yassin, R.A., Amirani, M.C. and Shah, A.S., 2024. Enhancing Breast Cancer Classification using a Modified GoogLeNet Architecture with Attention Mechanism. *Al-Iraqia Journal for Scientific Engineering Research*, 3(1), pp.47-63.
- Aidossov, N., Zarikas, V., Zhao, Y., Mashekova, A., Ng, E.Y.K., Mukhmetov, O., Mirasbekov, Y. and Omirbayev, A., 2023. An integrated intelligent system for breast cancer detection at early stages using ir images and machine learning methods with explainability. *SN Computer Science*, 4(2), p.184.
- Abhisheka, B., Biswas, S.K. and Purkayastha, B., 2023. A comprehensive review on breast cancer detection, classification and segmentation using deep learning. *Archives of Computational Methods in Engineering*, 30(8), pp.5023-5052.
- Albashish, D., Al-Sayyed, R., Abdullah, A., Ryalat, M.H. and Almansour, N.A., 2021, July. Deep CNN model based on VGG16 for breast cancer classification. In 2021 International conference on information technology (ICIT) (pp. 805-810). IEEE
- Albawi, S., Mohammed, T.A. and Al-Zawi, S., 2017, August. Understanding of a convolutional neural network. In 2017 international conference on engineering and technology (ICET) (pp. 1-6). Ieee.
- Al-Jabbar, M., Alshahrani, M., Senan, E.M. and Ahmed, I.A., 2023. Analyzing Histological Images Using Hybrid Techniques for Early Detection of Multi-Class Breast Cancer Based on Fusion Features of CNN and Handcrafted. *Diagnostics*, 13(10), p.1753.
- Atabansi, C.C., Nie, J., Liu, H., Song, Q., Yan, L. and Zhou, X., 2023. A survey of Transformer applications for histopathological image analysis: New developments and future directions. *BioMedical Engineering OnLine*, 22(1), p.96.
- Bardou, D., Zhang, K. and Ahmad, S.M., 2018. Classification of breast cancer based on histology images using convolutional neural networks. *Ieee Access*, 6, pp.24680-24693.
- Behar, N. and Shrivastava, M., 2022. ResNet50-Based Effective Model for Breast Cancer Classification Using Histopathology Images. *CMES-Computer Modeling in Engineering & Sciences*, 130(2).
- Boumaraf, S., Liu, X., Wan, Y., Zheng, Z., Ferkous, C., Ma, X., Li, Z. and Bardou, D., 2021. Conventional machine learning versus deep learning for magnification dependent histopathological breast cancer image classification: A comparative study with visual explanation. *Diagnostics*, 11(3), p.528.
- Boumaraf, S., Liu, X., Zheng, Z., Ma, X. and Ferkous, C., 2021. A new transfer learning based approach to magnification dependent and independent classification of breast

- cancer in histopathological images. *Biomedical Signal Processing and Control*, 63, p.102192.
- Chandrasekhar, V., 2023, September. Early Prediction of Ductal Carcinoma Histological Subtypes Via Ensemble Transformer Pipelines in Digital Pathology. In *2023 6th International Conference on Information Communication and Signal Processing (ICICSP)* (pp. 114-122). IEEE.
- Deniz, E., Şengür, A., Kadiroğlu, Z., Guo, Y., Bajaj, V. and Budak, Ü., 2018. Transfer learning based histopathologic image classification for breast cancer detection. *Health information science and systems*, 6, pp.1-7.
- Guo, Y., Bajaj, V. and Budak, Ü., 2018. Transfer learning based histopathologic image classification for breast cancer detection. *Health information science and systems*, 6, pp.1-7.
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S. and Uszkoreit, J., 2020. An image is worth 16x16 words: Transformers for image recognition at scale. *arXiv preprint arXiv:2010.11929*.
- Elmannai, H., Hamdi, M. and AlGarni, A., 2021. Deep learning models combining for breast cancer histopathology image classification. *International Journal of Computational Intelligence Systems*, 14(1), p.1003.
- Gheshlaghi, S.H., Kan, C.N.E. and Ye, D.H., 2021, November. Breast cancer histopathological image classification with adversarial image synthesis. In *2021 43rd annual international conference of the IEEE engineering in medicine & biology society (EMBC)* (pp. 3387-3390). IEEE.
- Huang, G., Liu, Z., Van Der Maaten, L. and Weinberger, K.Q., 2017. Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- Ibrahim, I. and Abdulazeez, A., 2021. The role of machine learning algorithms for diagnosing diseases. *Journal of Applied Science and Technology Trends*, 2(01), pp.10-19.
- Islam, S., Elmekki, H., Elsebai, A., Bentahar, J., Drawel, N., Rjoub, G. and Pedrycz, W., 2023. A comprehensive survey on applications of transformers for deep learning tasks. *Expert Systems with Applications*, p.122666.
- Jiang, Y., Chen, L., Zhang, H. and Xiao, X., 2019. Breast cancer histopathological image classification using convolutional neural networks with small SE-ResNet module. *PloS one*, 14(3), p.e0214587.
- Kassani, S.H., Kassani, P.H., Wesolowski, M.J., Schneider, K.A. and Deters, R., 2019. Classification of histopathological biopsy images using ensemble of deep learning networks. *arXiv preprint arXiv:1909.11870*.



- Kate, V. and Shukla, P., 2021. Breast cancer image multi-classification using random patch aggregation and depth-wise convolution based deep-net model.
- KIRELLI, Y. and AYDIN, G., 2023. Classification of Histopathological Images in Automatic Detection of Breast Cancer with Deep Learning Approach. *International Journal of Computational and Experimental Science and Engineering*, 9(4), pp.359-367.
- Krishnakumar, B., Kousalya, K., Mohana, R.S., Dinesh, K. and Santhiya, S., 2019. Classification of Breast Cancer using Deep Learning Architecture. *International Journal of Recent Technology and Engineering (IJR)*.
- Kutluer, N., Solmaz, O.A., Yamacli, V., Eristi, B. and Eristi, H., 2023. Classification of breast tumors by using a novel approach based on deep learning methods and feature selection. *Breast Cancer Research and Treatment*, 200(2), pp.183-192.
- Liang, Y. and Meng, Z., 2023. Brea-Net: An interpretable dual-attention network for imbalanced breast cancer classification. *IEEE Access*.
- Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S. and Guo, B., 2021. Swin transformer: Hierarchical vision transformer using shifted windows. In *Proceedings of the IEEE/CVF international conference on computer vision* (pp. 10012-10022).
- Nakach, F.Z., Zerouaoui, H. and Idri, A., 2022. Hybrid deep boosting ensembles for histopathological breast cancer classification. *Health and Technology*, 12(6), pp.1043-1060.
- Nguyen, P.T., Nguyen, T.T., Nguyen, N.C. and Le, T.T., 2019, October. Multiclass breast cancer classification using convolutional neural network. In *2019 International symposium on electrical and electronics engineering (ISEE)* (pp. 130-134). IEEE.
- Roy, S., Jain, P.K., Tadepalli, K. and Reddy, B.P., 2024. Forward attention-based deep network for classification of breast histopathology image. *Multimedia Tools and Applications*, pp.1-30.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. and Chen, L.C., 2018. Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4510-4520).
- Seidaliyeva, U., Akhmetov, D., Ilipbayeva, L. and Matson, E.T., 2020. Real-time and accurate drone detection in a video with a static background. *Sensors*, 20(14), p.3856.
- Sethy, P.K. and Behera, S.K., 2022. Automatic classification with concatenation of deep and handcrafted features of histological images for breast carcinoma diagnosis. *Multimedia Tools and Applications*, 81(7), pp.9631-9643.
- Sharma, S., Kumar, S., Sharma, M. and Kalkal, A., 2024. An ensemble of deep CNNs for automatic grading of breast cancer in digital pathology images. *Neural Computing and Applications*, pp.1-21.

- Shorten, C., Khoshgoftaar, T.M. and Furht, B., 2021. Deep Learning applications for COVID-19. *Journal of big Data*, 8(1), pp.1-54.
- Simonyan, K. and Zisserman, A., 2014. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Skelton, M., Al-Mash'hadani, A.K., Abdul-Sater, Z., Saleem, M., Alsaad, S., Kahtan, M., Al-Samarai, A.H., Al-Bakir, A.M. and Mula-Hussain, L., 2023. War and oncology: cancer care in five Iraqi provinces impacted by the ISIL conflict. *Frontiers in Oncology*, 13, p.1151242.
- Sowrirajan, S.R., Balasubramanian, S. and Raj, R.S.P., 2022. MRI brain tumor classification using a hybrid VGG16-NADE model. *Brazilian Archives of Biology and Technology*, 66, p.e23220071.
- Spanhol, F.A., Oliveira, L.S., Petitjean, C. and Heutte, L., 2015. A dataset for breast cancer histopathological image classification. *Ieee transactions on biomedical engineering*, 63(7), pp.1455-1462.
- Srikantamurthy, M.M., Rallabandi, V.S., Dudekula, D.B., Natarajan, S. and Park, J., 2023. Classification of benign and malignant subtypes of breast cancer histopathology imaging using hybrid CNN-LSTM based transfer learning. *BMC Medical Imaging*, 23(1), p.19.
- Sriwastawa, A. and Arul Jothi, J.A., 2023. Vision transformer and its variants for image classification in digital breast cancer histopathology: a comparative study. *Multimedia Tools and Applications*, pp.1-23.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. and Wojna, Z., 2016. Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818-2826).
- Tummala, S., Kim, J. and Kadry, S., 2022. Breast-net: Multi-class classification of breast cancer from histopathological images using ensemble of swin transformers. *Mathematics*, 10(21), p.4109.
- Trieu, P.D., Mello-Thoms, C.R., Barron, M.L. and Lewis, S.J., 2023. Look how far we have come: BREAST cancer detection education on the international stage. *Frontiers in oncology*, 12, p.1023714.
- Toa, C.K., Elsayed, M. and Sim, K.S., 2023. Deep residual learning with attention mechanism for breast cancer classification. *Soft Computing*, pp.1-11.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, Ł. and Polosukhin, I., 2017. Attention is all you need. *Advances in neural information processing systems*, 30.
- Vikranth, C.S., Jagadeesh, B., Rakesh, K., Mohammad, D., Krishna, S. and AS, R.A., 2022, February. Computer assisted diagnosis of breast cancer using histopathology

- images and convolutional neural networks. In 2022 2nd International Conference on Artificial Intelligence and Signal Processing (AISP) (pp. 1-6). IEEE.
- Wangsaputra, D.S., Anam, C., Adi, K. and Naufal, A., 2023. Impact of Adaptive Mean Filter as the Preprocessing Stage of Histopathological Image Classification of Breast Tumor Using Transfer Learning VGG16 for Various Magnifications. *Int. J. Sci. Res. Sci. Technol*, pp.274-280.
- Xu, Y., Dos Santos, M.A., F. Souza, L.F., Marques, A.G., Zhang, L., da Costa Nascimento, J.J., de Albuquerque, V.H.C. and Rebouças Filho, P.P., 2022. New fully automatic approach for tissue identification in histopathological examinations using transfer learning. *IET Image Processing*, 16(11), pp.2875-2889.
- Yan, R., Ren, F., Wang, Z., Wang, L., Zhang, T., Liu, Y., Rao, X., Zheng, C. and Zhang, F., 2020. Breast cancer histopathological image classification using a hybrid deep neural network. *Methods*, 173, pp.52-60.
- Zaalouk, A.M., Ebrahim, G.A., Mohamed, H.K., Hassan, H.M. and Zaalouk, M.M., 2022. A deep learning computer-aided diagnosis approach for breast cancer. *Bioengineering*, 9(8), p.391.
- Zerouaoui, H. and Idri, A., 2022. Deep hybrid architectures for binary classification of medical breast cancer images. *Biomedical Signal Processing and Control*, 71, p.103226.
- Zheng, Y., Li, C., Zhou, X., Chen, H., Zhang, H., Li, Y., Sun, H. and Grzegorzec, M., 2022, June. Image Classification in Breast Histopathology Using Transfer and Ensemble Learning. In *International Conference on Information Technologies in Biomedicine* (pp. 295-306). Cham: Springer International Publishing.