



**HİSTOPATOLOJİK MEME KANSERİ GÖRÜNTÜLERİNİN DERİN ÖĞRENME
YÖNTEMLERİ İLE SINIFLANDIRILMASI**

GİZEM IRMAK

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üyesi Ahmet SAYGILI

2022

T.C.
TEKİRDAĞ NAMIK KEMAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



HİSTOPATOLOJİK MEME KANSERİ GÖRÜNTÜLERİNİN DERİN ÖĞRENME
YÖNTEMLERİ İLE SINIFLANDIRILMASI

GİZEM IRMAK

ORCID: 0000-0002-6973-6556

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ
Danışman: Dr. Öğr. Üyesi Ahmet SAYGILI

HAZİRAN-2022

Her hakkı saklıdır.

BİLİMSEL ARAŞTIRMA VE YAYIN ETİĞİ KURALLARINA UYUM BEYANI

Tekirdağ Namık Kemal Üniversitesi Bilgisayar Mühendisliği Anabilim Dalında Yüksek Lisans Tezi olarak sunulan ve Fen Bilimleri Enstitüsü Lisansüstü Tez Yazım Kurallarına uygun olarak hazırlanan “Histopatolojik Meme Kanseri Görüntülerinin Derin Öğrenme Yöntemleri ile Sınıflandırılması” isimli bu tez çalışmasıyla ilgili olarak;

- Bu tez çalışmasının tarafımda hazırlanan özgün bir çalışma olduğunu,
- Hazırlık, veri toplama, analiz ve bulguların sunumu olmak üzere tüm aşamalarında “bilimsel araştırma ve yayın etiği kurallarına” uygun davrandığımı,
- Bu çalışma kapsamında elde edilmemiş olan tüm veri ve bilgiler için bilimsel normlara uygun kaynak gösterdiğimi ve bu kaynaklara tezin “Kaynaklar” bölümünde yer verdiğimi,
- Tez çalışmamın Tekirdağ Namık Kemal Üniversitesinde kullanılan “bilimsel intihal programı” ile tarandığını ve öngörülen standartları karşıladığımı,
- Çizelgede verilen bilgilerin doğruluğunu,

Şekil Sayısı	38	Çizelge Sayısı	19	Kaynak Sayısı	30
Ek Sayısı	0	Sayfa Sayısı	71	Tez Savunma Tarihi	30/06/22

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Gizem IRMAK
30/06/2022

ARAŐTIRMA FONU DESTEĐİ BEYANI

Tekirdađ Namık Kemal Üniversitesi Bilgisayar Mühendisliđi Anabilim Dalında Yüksek Lisans Tezi olarak sunulan ve Fen Bilimleri Enstitüsü Lisansüstü Tez Yazım Kurallarına uygun olarak hazırlanan bu tez çalışması; Tekirdađ Namık Kemal Üniversitesi BAP tarafından NKUBAP.06.GA.21.317 numaralı proje ile desteklenmiştir.

Gizem IRMAK

30/06/2022



ÖZET

HİSTOPATOLOJİK MEME KANSERİ GÖRÜNTÜLERİNİN DERİN ÖĞRENME YÖNTEMLERİ İLE SINIFLANDIRILMASI

Gizem IRMAK

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üyesi Ahmet SAYGILI

Görsel verilerin işlenmesi son yıllarda özellikle medikal alanda sıklıkla kullanılmaktadır. Yapay zekânın bir alt dalı olan derin öğrenme yöntemleri, görüntü işleme yöntemleri ile birlikte kullanılarak; doku analizi ve hastalıkların otomatik sınıflandırılması başta olmak üzere birçok alanda başarılı bir şekilde uygulanmaktadır. Derin öğrenme, bir dönem mevcut donanımların yetersiz kalması sebebiyle durgunluk noktasına gelmiş fakat 2000'li yıllar ile birlikte tekrar popüler bir alan olmaya başlamıştır. GPU gelişmeleriyle birlikte sığ yapay sinir ağlarından derin yapay sinir ağlarına geçiş yapılmıştır. Katmanlar arasında gerçekleşen geri yayılım algoritmaları sayesinde büyük veri kümelerindeki gizli ve ayırt edici özellikler keşfedilmektedir. Bu da yapay sinir ağlarının ve derin öğrenme yöntemlerinin etkinliğini ortaya çıkarmaktadır. Bu çalışmada BreakHis veri setinde yer alan histopatolojik meme kanseri görüntüleri, görüntü işleme ve derin öğrenme yöntemleri kullanılarak sınıflandırılmıştır. Aynı zamanda literatürde yapılan çalışmalar da incelenmiştir. Tezin amacı, özellikle kadınlarda son yıllarda oldukça sık rastlanan meme kanseri hastalığının erken ve doğru teşhisi için otomatik bir yöntem sunulmasıdır. Bu sayede gerçekleştirilen çalışmalar neticesinde tıp uzmanlarına alacakları kararlarda destek olacak nitelikte bir çalışma ortaya konmuştur.

Anahtar Kelimeler: Görüntü İşleme, Yapay Zekâ, Derin Öğrenme, Yapay Sinir Ağları, Histopatolojik Görüntüler, Meme Kanseri.

ABSTRACT

CLASSIFICATION OF HISTOPATHOLOGICAL BREAST CANCER IMAGES BY DEEP LEARNING METHODS

Gizem IRMAK

Department of Computer Engineering

MSc. Thesis

Supervisor: Assist. Prof. Dr. Ahmet SAYGILI

Processing of visual data has been used frequently in recent years, especially in the medical field. By using deep learning methods, a sub-branch of artificial intelligence, together with image processing methods; It has been successfully applied in many areas, especially tissue analysis and automatic classification of diseases. Deep learning experienced a stagnation due to the inadequacy of the existing hardware for a while, but it started to become a popular field again with the 2000s. With the developments in GPU, there has been a transition from shallow artificial neural networks to deep artificial neural networks. Thanks to back propagation algorithms between layers, hidden and distinctive features in large data sets are discovered. This reveals the effectiveness of artificial neural networks and deep learning methods. In this study, histopathological breast cancer images in the BreakHis dataset were classified using image processing and deep learning methods. At the same time, studies in the literature were also examined. The aim of the thesis is to present an automatic method for the early and accurate diagnosis of breast cancer, which is very common in women in recent years. As a result of the studies carried out in this way, a study has been put forward that will support medical professionals in their decisions.

Keywords: Image Processing, Artificial Intelligence, Deep Learning, Artificial Neural Networks, Histopathological Images, Breast Cancer.

İÇİNDEKİLER

ÖZET	i
ABSTRACT.....	ii
İÇİNDEKİLER.....	iii
ÇİZELGELER DİZİNİ.....	iv
SİMGELER DİZİNİ.....	vii
KISALTMALAR DİZİNİ	viii
TEŞEKKÜR	ix
1. GİRİŞ	1
1.1 Literatür Özeti.....	2
1.2 Çalışmanın Amacı ve Kapsamı.....	9
1.3 Veri Seti	10
2. DERİN ÖĞRENME.....	14
2.1 Tarihçe	14
2.2 Yapay Sinir Ağları	14
2.3 Derin Öğrenme Yöntemleri ile Sınıflandırma	16
2.4 Derin Öğrenme Mimarileri	17
2.4.1 RNN	17
2.4.2 CNN	18
2.4.2.1 Evrişim Katmanı (Convolutional Layer)	19
2.4.2.2 Doğrusal Olmayan Katman (Non-Linearity Layer)	20
2.4.2.3 Havuzlama Katmanı (Pooling Layer).....	20
2.4.2.4 Düzleştirme Katmanı (Flattening Layer).....	21
2.4.2.5 Tam Bağlantılı Katman (Fully Connected Layer)	21
2.4.2.6 Sınıflandırma Katmanı (Classification Layer)	21
2.5 Derin Öğrenme Kullanım Alanları	21
3. HİSTOPATOLOJİK MEME KANSERİ GÖRÜNTÜLERİNİN DERİN ÖĞRENME YÖNTEMLERİ İLE SINIFLANDIRILMASI.....	22
3.1 Tümör Özelliklerine Göre Sınıflandırma.....	22
3.2 Tümör Çeşitlerine Göre Sınıflandırma	38
4. DENEYSEL ÇALIŞMALAR.....	56
5. SONUÇ VE ÖNERİLER.....	58
KAYNAKLAR	59
ÖZGEÇMİŞ	61

ÇİZELGELER DİZİNİ

Çizelge 1.1 Literatürdeki Çalışmalar.....	2
Çizelge 1.2 Büyütme Oranı ve Sınıfa Göre Görüntü Dağılımı	10
Çizelge 1.3 Tümör Türleri ve Özellikleri	12
Çizelge 1.4 Büyütme Oranı ve Histolojik Alt Tiplere Göre “İyi Huylu” Görüntü Dağılımı ...	13
Çizelge 1.5 Büyütme Oranı ve Histolojik Alt Tiplere Göre “Kötü Huylu” Görüntü Dağılımı	13
Çizelge 3.1 40X Büyütme Oranının Tümör Özelliklerine Göre Sınıflandırılması.....	23
Çizelge 3.2 100X Büyütme Oranının Tümör Özelliklerine Göre Sınıflandırılması.....	26
Çizelge 3.3 200X Büyütme Oranının Tümör Özelliklerine Göre Sınıflandırılması.....	30
Çizelge 3.4 400X Büyütme Oranının Tümör Özelliklerine Göre Sınıflandırılması.....	34
Çizelge 3.5 İkili Sınıflandırma İçin Metrik Sonuçları.....	37
Çizelge 3.6 40X Büyütme Oranının Tümör Çeşitlerine Göre Sınıflandırılması	38
Çizelge 3.7 100X Büyütme Oranının Tümör Çeşitlerine Göre Sınıflandırılması	42
Çizelge 3.8 200X Büyütme Oranının Tümör Çeşitlerine Göre Sınıflandırılması	46
Çizelge 3.9 400X Büyütme Oranının Tümör Çeşitlerine Göre Sınıflandırılması	50
Çizelge 3.10 Çoklu Sınıflandırma İçin Metrik Sonuçları.....	54
Çizelge 4.1 Tümör Özelliklerine Göre Sınıflandırma Sonuçları.....	56
Çizelge 4.2 Tümör Çeşitlerine Göre Sınıflandırma Sonuçları	56
Çizelge 4.3 İkili Sınıflandırmanın Literatürdeki Çalışma ile Karşılaştırılması.....	57
Çizelge 4.4 Çoklu Sınıflandırmanın Literatürdeki Çalışmalar ile Karşılaştırılması	57

ŞEKİLLER DİZİNİ

Şekil 2.1. Derin Öğrenmenin Gelişimi	14
Şekil 2.2. Biyolojik Sinir Hücresinin Yapısı	15
Şekil 2.3. Yapay Sinir Hücresinin Yapısı.....	15
Şekil 2.4. Sinir Ağı Mimarisinin Genel Görünümü	17
Şekil 2.5. Basit Tekrarlayan Sinir Ağı (RNN)	18
Şekil 2.6. Basit Evrişimli Sinir Ağı (CNN).....	19
Şekil 3.1 40X Büyütme Oranının Tümör Özelliklerine Göre Doğruluk Grafiği	24
Şekil 3.2 40X Büyütme Oranının Tümör Özelliklerine Göre Karışıklık Matrisi.....	25
Şekil 3.3 40X Büyütme Oranının Tümör Özelliklerine Göre Gerçek ve Tahminlerinden Kesit	25
Şekil 3.4 40X Büyütme Oranının Tümör Özelliklerine Göre Eğitim Süresi Grafiği.....	26
Şekil 3.5 100X Büyütme Oranının Tümör Özelliklerine Göre Doğruluk Grafiği	28
Şekil 3.6 100X Büyütme Oranının Tümör Özelliklerine Göre Karışıklık Matrisi.....	28
Şekil 3.7 100X Büyütme Oranının Tümör Özelliklerine Göre Gerçek ve Tahminlerinden Kesit	29
Şekil 3.8 100X Büyütme Oranının Tümör Özelliklerine Göre Eğitim Süresi Grafiği.....	30
Şekil 3.9 200X Büyütme Oranının Tümör Özelliklerine Göre Doğruluk Grafiği	32
Şekil 3.10 200X Büyütme Oranının Tümör Özelliklerine Göre Karışıklık Matrisi.....	32
Şekil 3.11 200X Büyütme Oranının Tümör Özelliklerine Göre Gerçek ve Tahminlerinden Kesit	33
Şekil 3.12 200X Büyütme Oranının Tümör Özelliklerine Göre Eğitim Süresi Grafiği.....	33
Şekil 3.13 400X Büyütme Oranının Tümör Özelliklerine Göre Doğruluk Grafiği.....	35
Şekil 3.14 400X Büyütme Oranının Tümör Özelliklerine Göre Karışıklık Matrisi.....	36
Şekil 3.15 400X Büyütme Oranının Tümör Özelliklerine Göre Gerçek ve Tahminlerinden Kesit	36
Şekil 3.16 400X Büyütme Oranının Tümör Özelliklerine Göre Eğitim Süresi Grafiği.....	37
Şekil 3.17 40X Büyütme Oranının Tümör Çeşitlerine Göre Doğruluk Grafiği	40
Şekil 3.18 40X Büyütme Oranının Tümör Çeşitlerine Göre Karışıklık Matrisi	40

Şekil 3.19 40X Büyütme Oranının Tümör Çeşitlerine Göre Gerçek ve Tahminlerinden Kesit	41
Şekil 3.20 40X Büyütme Oranının Tümör Çeşitlerine Göre Eğitim Süresi Grafiği	42
Şekil 3.21 100X Büyütme Oranının Tümör Çeşitlerine Göre Doğruluk Grafiği	44
Şekil 3.22 100X Büyütme Oranının Tümör Çeşitlerine Göre Karışıklık Matrisi	44
Şekil 3.23 100X Büyütme Oranının Tümör Çeşitlerine Göre Gerçek ve Tahminlerinden Kesit	45
Şekil 3.24 100X Büyütme Oranının Tümör Çeşitlerine Göre Eğitim Süresi Grafiği.....	46
Şekil 3.25 200X Büyütme Oranının Tümör Çeşitlerine Göre Doğruluk Grafiği	48
Şekil 3.26 200X Büyütme Oranının Tümör Çeşitlerine Göre Karışıklık Matrisi	48
Şekil 3.27 200X Büyütme Oranının Tümör Çeşitlerine Göre Gerçek ve Tahminlerinden Kesit	49
Şekil 3.28 200X Büyütme Oranının Tümör Çeşitlerine Göre Eğitim Süresi Grafiği.....	49
Şekil 3.29 400X Büyütme Oranının Tümör Çeşitlerine Göre Doğruluk Grafiği	51
Şekil 3.30 400X Büyütme Oranının Tümör Çeşitlerine Göre Karışıklık Matrisi	52
Şekil 3.31 400X Büyütme Oranının Tümör Çeşitlerine Göre Gerçek ve Tahminlerinden Kesit	53
Şekil 3.32 400X Büyütme Oranının Tümör Çeşitlerine Göre Eğitim Süresi Grafiği.....	53

SİMGELER DİZİNİ

W_1	Giriş Görüntü Boyutunun Genişlik Değeri
W_2	Çıkış Görüntü Boyutunun Genişlik Değeri
H_1	Giriş Görüntü Boyutunun Yükseklik Değeri
H_2	Çıkış Görüntü Boyutunun Yükseklik Değeri
D_1	Giriş Görüntü Boyutunun Derinlik Değeri
D_2	Giriş Görüntü Boyutunun Derinlik Değeri
F	Filtre Boyutu
N	Adım Sayısı
F^E	Doğrusal Olmayan Bir Aktivasyon İşlevi
O_m	Çıktı Hacmi
$2k+1$	Tek Bir Evrişim Filtresine Sahip Bir Karenin Kenarı
a	Aktivasyon Fonksiyonu
b_m	m^{th} Özellik Haritasının bias Değeri

KISALTMALAR DİZİNİ

YSA	Yapay Sinir Ağları
CPU	Central Processing Unit (Merkezî İşlem Birimi)
GPU	Graphics Processing Unit (Grafik İşlemci Birimi)
CNN	Convolutional Neural Networks (Evrışimli Sinir Ağları)
RNN	Recurrent Neural Networks (Tekrarlayan Sinir Ağları)
DVM	Destek Vektör Makinesi
ESA	Evrışimli Sinir Ağları
SOB	Surgical Open Biopsy (Cerrahi Açık Biyopsi)
A	Adenosis
F	Fibroadenoma
PT	Filloid Tümör
TA	Tübüler Adenoma
DC	Duktal Karsinom
LC	Lobüler Karsinom
MC	Müsinöz Karsinom
PC	Papiller Karsinom

TEŐEKKÜR

Bugünlere gelmemde maddi ve manevi her türlü fedakarlıkta bulunan, bana karşı sonsuz güvenlerini her daim hissettiren ve bana her zaman güvenip beni her zaman motive eden başta melek annem Nevriye DEĞİRMENCİOĐLU olmak üzere tüm aileme sonsuz teşekkür ederim. Tüm eğitim hayatım boyunca bana yol gösteren ve üzerimde emeđi olan, benimle bilgi ve tecrübelerini paylaşan değerli öğretmenlerime çok teşekkür ederim. Lisansüstü eğitimim için beni danışmanlığına seçen ve bir müddet aradan sonra tekrar öğrenci olmama vesile olan, biz genç araştırmacılara büyük destek olup her zaman önünü açan tez hocam Sayın Dr. Öğr. Üyesi Ahmet SAYGILI başta olmak üzere, lisansüstü eğitimim boyunca bana yol gösteren, bilgi ve tecrübelerini paylaşan, ilgi ve merakımı karşılıksız bırakmayıp her türlü desteđi sunan çok değerli hocalarıma sonsuz teşekkürlerimi sunarım.

Gizem IRMAK

Bilgisayar Mühendisi

1. GİRİŞ

Görüntü insan beyninde algılanarak işlenir ve beyinde gerçekleşen yorumlama neticesinde anlam kazanır. Albert Mehrabian iletişimin daha çok görsel veriler ile sağlanmakta olduğunu ve sözel verilerin iletişimde etkisinin düşük olduğunu belirtmektedir. İnsan beyni görsel verileri sözel verilere nazaran 60.000 kat daha hızlı algılamaktadır [1]. Bu doğrultuda görüntünün ne kadar önemli veriler olduğu da anlaşılmaktadır.

Görüntü işleme, görüntü verilerinin, elektronik ortamda uygun yazılımlar yardımı ile amaca uygun şekilde işleminden geçirilmesine yönelik yapılan çalışmadır. Görüntülerin işlenmesi, değiştirilmesi, iyileştirilmesi veya yabancılaştırılması için kullanılır. Görüntü işleme sonucunda ya mevcut girdi görüntüsünden anlamlı bir sonuç çıkartılır ya da yeni bir görüntü elde edilir. Görüntü işleme teknikleri ile insan hayatı olumlu etkilenmekte, birçok işlem hızlı ve ekonomik şekilde yapılabilmektedir.

Görüntü işleme; tıp, tarım, hayvancılık, robotik, güvenlik, astronomi, coğrafya, askeri, endüstriyel, gazetecilik ve fotoğrafçılık gibi çok fazla alanda etkin bir şekilde kullanılmaktadır. Ayrıca, görüntü işleme yöntemleri her geçen gün gelişim göstermekte ve yeni uygulama alanları bulmaktadır. Bu da görüntü işlemenin uygulandığı alanlara hem verim hem de ekonomi anlamında olumlu yansımaktadır.

Yapay sinir ağları, beynimizin öğrenme yöntemlerinden esinlenilerek modellenmiş bir sistemdir. Derin öğrenme ise, yapay sinir ağlarını kullanarak beynimizin çalışma mekanizmasını taklit eden algoritmalara dayanmaktadır. Birden çok veri işleme katmanından oluşan derin öğrenme modelleri çok sayıda soyutlama katmanı ile verilerin temsillerini öğrenmesine olanak tanır. Bu yöntemler; konuşma tanıma, görsel nesne tanıma, nesne algılama ve ilaç keşfi gibi daha birçok alanda başarı ile uygulanmaktadır. Derin öğrenme, bir makinenin önceki katmandaki temsilden her katmandaki temsili hesaplamak için kullanılan dahili parametrelerini nasıl değiştirmesi gerektiğini belirtmek için geri yayılım algoritmasını kullanarak büyük veri kümelerinde yer alan karmaşık yapıyı ortaya çıkarır. Derin kıvrımlı ağlar görüntü, video, konuşma ve ses işlemede çığır açarken, tekrarlayan ağlar metin ve konuşma gibi sıralı verilere ışık tutmaktadır [2].

Derin öğrenme hesaplamalarının bilgisayarlı görüde kullanılması çok başarılı sonuçlar alınabilmesini ve karmaşık problemlerin basitçe çözüme ulaştırılabilmesini sağlamaktadır.

Gelişen teknolojiyle birlikte, modern cihazların tıp alanında kullanımı da artmıştır. Bu teknikler doktorlara zaman, teşhis ve tedavi konusunda büyük kolaylıklar sağlamaktadır.

Bu çalışmada, görüntü işleme ve derin öğrenme yöntemlerinin tıp alanındaki uygulamaları üzerine bir örnek teşkil eden histopatolojik meme kanseri görüntülerinin derin öğrenme yöntemleri ile sınıflandırılması konusu ele alınmıştır. Çalışmada BreakHis histopatolojik meme kanseri görüntülerini içeren veri seti kullanılmıştır. Konuyla ilgili daha önce yapılan çalışmalar hakkında ön araştırma yapılarak bilgi edinilmiş ve literatür araştırması yapılarak konuyla ilgili çalışmalar incelenmiştir. Yapılan incelemelerin ardından derin öğrenme yöntemleri ile farklı sınıf sayıları için modeller yapılarak özgün bir model ortaya çıkarılmaya çalışılmıştır.

1.1 Literatür Özeti

Literatürde meme kanserinin derin öğrenme algoritmaları kullanılarak tespit edilmesine yönelik bazı çalışmalar Çizelge 1.1’de gösterilmiştir.

Çizelge 1.1 Literatürdeki Çalışmalar

Çalışma	Kullanılan Yöntem	Başarı
Cruz-Roa ve ark., 2014 [3]	CNN.	F1: %71,80. Dengeli Doğruluk: %84,23.
Ertosun & Rubin, 2015 [4]	CNN (GoogleNet).	Doğruluk: %85.
Dubrovina ve ark., 2015 [5]	CNN.	İki büyüklük sırası kadar daha hızlı hesaplama.
Spanhol ve ark., 2016 [6]	1-NN, QDA, SVM, RF.	Doğruluk: %80-%85.
Wang ve ark., 2016 [7]	Derin Öğrenme.	Doğruluk: %89,7.
Bayramoğlu ve ark., 2016 [8]	CNN.	Doğruluklar: Tek görevli ESA: %82,13. Çok görevli ESA: %83,25.
Selvathi & Poornila, 2017 [9]	Derin Öğrenme.	Doğruluk: %98,5.

Çizelge 1.1'in devamı

Araújo ve ark., 2017 [11]	CNN, DVM.	Doğruluklar: İki sınıf için: %77,8. Dört sınıf için: %83,3. Duyarlılık: %95,6.
Han ve ark., 2017 [12]	Derin Öğrenme (CSDCNN).	Doğruluk: %93,2.
Motlagh ve ark., 2018 [13]	CNN (ResNet-V1-152).	Doğruluk: %98,7.
Bardou ve ark., 2018 [14]	CNN.	Doğruluk: %98,33.
Rakhlin ve ark., 2018 [15]	CNN.	Doğruluk: %93,8.
Liu ve ark., 2018 [16]	CNN (FCLF-CNN).	WDBC için: Doğruluk: %99,28. Duyarlılık: %98,65. Özgüllük: %99,57. WBCD için: Doğruluk: %98,71. Duyarlılık: %97,60. Özgüllük: %99,43.
Nazeri ve ark., 2018 [17]	CNN.	Doğruluk: %95.
Xi ve ark., 2018 [19]	CNN (VGGNet).	Doğruluk: %92,53.
Sadoughi ve ark., 2018 [20]	Makale bir derleme çalışmasıdır, çalışmalarda uygulanan teknikler ve başarı oranları yorumlanmıştır.	Ultrason: %95,85. Mamografi: %93,069. Termografi: %100.
Ekici & Jawzal, 2020 [21]	Ön işleme, bölütleme, özellik çıkarma, CNN.	Doğruluk: %98,95.
Toğaçar ve ark., 2020 [22]	CNN ve DA, özellik seçimi.	Alt veri kümesindeki başarı: %99,73. Tüm veri kümesindeki başarı: %98,59.

Çizelge 1.1'in devamı

SenthilKumar ve ark., 2021 [23]	CNN (VGG16)	Doğruluk: %88.
Sharma ve ark., 2021 [24]	CNN	Doğruluklar: 40X Büyütme: %80,76, 100X Büyütme: %76,58, 200X Büyütme: %79,90, 400X Büyütme: %74,21.
Agarwal ve ark., 2022 [25]	VGG16	Doğruluk: %94,67, Kesinlik: %92,60, F1: %85,21, Recall: %80,52.
Mayouf ve ark., 2022 [26]	Derin Öğrenme	Doğruluklar: İkili Sınıflandırma: %98,76, Çoklu Sınıflandırma: %95,93.

Cruz-Roa ve ark., meme kanseri görüntülerinde invaziv duktal karsinoma (IDC) yani yayılma ihtimali olan kötü huylu tümör içeren doku bölgelerinin otomatik tespiti ve görsel analizi için derin öğrenme yaklaşımı sunmaktadırlar. Sundukları yöntemin F-ölçüm ve dengeli doğruluk açısından (%71,80, %84,23) en iyi nicel sonuçları verdiğini belirtmişlerdir [3].

Ertosun ve ark., mamografi görüntülerinde kitlelerin otomatik olarak aranması ve sınırlanması için derin öğrenme temelli bir görsel arama sistemi geliştirmişlerdir. Sistemleri, sınıflandırma motoru ve yerelleştirme motoru olmak üzere iki modülden oluşur. Bu sistem ile kitle içeren görüntülerin tanımlanmasında %85 doğruluk elde etmişlerdir [4].

Dubrovina ve ark., mamografi görüntülerinde piksel yöntemli otomatik sınıf tahminini hızlandırmak için klasik tam bağlı katmanlar yerine evrişim katmanlarını kullanmışlardır. Bu yaklaşım aynı sınıflandırma doğruluğunu korurken, yaklaşık iki büyüklük sırası kadar daha hızlı hesaplama sağlamaktadır [5].

Spanhol ve ark., 82 hastadan elde edilen 7909 meme kanseri histopatoloji görüntüsünü içeren BreakHis veri seti üzerinde, son teknoloji makine öğrenmesi görüntü sınıflandırma

tekniklerini kullanarak iyi huylu ve kötü huylu olmak üzere sınıflandırma yapmışlardır. Doğruluk %80 ile %85 arasında değişmektedir [6].

Wang ve ark., çalışmasında mikrokalsifikasyonların (kanser/hastalık oluşumuna sebep olan kalsiyum çökeltilerin) teşhis doğruluğunu iyileştirmek için büyük veri kümeleri üzerinde derin öğrenmeye dayalı modellerin performansını değerlendirmişlerdir. Mikrokalsifikasyonların ve meme kitlelerinin doğruluğunu, meme lezyonlarını sınıflandırmak için tek başına veya kombinasyon halinde değerlendirmek adına bir sınıflandırıcı modeli oluşturulmuştur. Derin öğrenme modeli ile mikrokalsifikasyonların ve meme kitlelerinin birleşiminden %89,7 doğruluk elde etmişlerdir [7].

Bayramoğlu ve ark., BreakHis veri setini kullanarak histopatolojik meme kanseri görüntülerini sınıflandırmak amacıyla tek ve çok görevli olmak üzere iki farklı görevli evrişimsel sinir ağları kullanmışlardır. Tek görevli evrişimli sinir ağlarını kötü huylu tümörleri tahmin etmek için, çok görevli evrişimli sinir ağlarını da hem kötü huylu tümörleri hem de büyütme oranını eş zamanlı olarak tahmin etmek için kullanmışlardır [8].

Selvathi & Poornila, mamografi görüntülerinden meme kanserinin saptanmasına yönelik, denetimsiz, derin öğrenme tabanlı bir teknik önermişlerdir. Bu tekniği kullanarak daha küçük kütlelerin yerlerinin daha doğru tespit edilmesini amaçlamışlardır. Önerilen yöntem ile yoğun mamografi görüntülerinin sınıflandırılmasında %98,5'e varan bir doğruluk elde etmişlerdir [9].

Wang ve ark., meme kanserini hızlı bir şekilde teşhis etmek için meme tarama yöntemlerinde (özellikle mikrodalga görüntüleme) ve meme biyobelirteçlerinde ve biyosensörlerde son zamanlardaki önemli başarılarla genel bir bakış sunmuşlardır [10].

Araujo ve ark., hematoksilen ve eozinle boyanmış görüntülerle biyopsi dokusunun bilgisayar destekli sınıflandırılmasına yönelik bir evrişimli sinir ağları yöntemi önermişlerdir. Görüntüleri; normal doku, iyi huylu lezyon, in situ karsinoma ve invaziv karsinoma olmak üzere dört sınıfa, karsinoma (kanserli) ve non-karsinoma (kanserli olmayan) olmak üzere iki sınıfa ayırmışlardır. CNN ile çıkarılan öznitelikleri bir Destek Vektör Makinesi sınıflandırıcısını eğitmek için de kullanarak dört sınıflı sınıflandırma için %77,8, iki sınıflı sınıflandırma için %83,3 oranında doğruluk elde etmişlerdir. Yöntemin kanser vakalarına duyarlılığı %95,6'dır. [11].

Han ve ark., önerdikleri yeni bir derin öğrenme modelini kullanarak meme kanseri çoklu sınıflandırması gerçekleştirmişlerdir. Yapılandırılmış derin öğrenme modeli ile büyük ölçekli bir veri setinde ortalama %93,2 doğruluk elde etmişlerdir [12].

Motlagh ve ark., önceden eğitilmiş ResNet-V1-50 modelini kullanarak meme, mesane, akciğer ve lenf dâhil olmak üzere dört kanser tipinde ortalama %99,8 doğruluk elde etmişlerdir. Daha sonra meme kanseri alt tiplerinin sınıflandırılması için BreakHis veri tabanından 7,909 görüntüye bu yaklaşımı uygulayarak ResNet-V1-152 modeli ile %98,7'lik bir doğrulukla iyi ve kötü huylu meme kanserlerini sınıflandırmışlardır [13].

Bardou ve ark., evrişimsel sinir ağlarını kullanarak histolojik meme kanseri görüntülerini otomatik olarak iyi huylu ve kötü huylu olmak üzere sınıflandırmışlardır. İkili sınıflandırma için %96,15 ile %98,33 arasında doğruluk değeri elde etmişlerdir [14].

Rakhlin ve ark., hematoksilen ve eozin lekeli histolojik meme kanseri görüntülerinin sınıflandırılması için derin evrişimsel sinir ağlarına dayalı hesaplamalı bir yaklaşım geliştirmişlerdir. Birkaç derin sinir ağı mimarisini ve gradyan destekli ağaçlar sınıflandırıcısını kullanmışlardır. Sınıflandırma sonucunda %93,8'lik bir doğruluk elde etmişlerdir [15].

Liu ve ark., Wisconsin tanısal meme kanseri (WDBC) ve Wisconsin meme kanseri veri tabanı (WBCD) olmak üzere iki ayrı veri tabanındaki yapılandırılmış verilerin sınıflandırma performansını iyileştirmek amacıyla tam bağlı olan katmanların ilk evrişim katmanından önce yerleştirildiği bir evrişimsel sinir ağı yapısı (FCLF-CNN) önermişlerdir. Önerilen evrişimsel sinir ağı yapısı (FCLF-CNN) ile; WDBC için %99,28 doğruluk, %98,65 duyarlılık ve %99,57 özgüllük, WBCD için %98,71 doğruluk, %97,60 duyarlılık ve %99,43 özgüllük elde etmişlerdir [16].

Nazeri ve ark., mikroskop görüntülerinin meme dokusu sınıflandırması sorununu derin öğrenme tekniklerini kullanarak araştırmışlardır. Eğitim veri setindeki her görüntünün büyük boyutu nedeniyle, iki ardışık evrişimsel sinir ağından oluşan yama tabanlı bir teknik önermişlerdir. İlk "yama tabanlı" ağ, görüntü yamalarının özelliklerini çıkarırken, ikinci "görüntü tabanlı" ağ tüm görüntünün sınıflandırmasını gerçekleştirmiştir. Önerdikleri yöntem, literatürde daha önce bildirilen %77 doğruluk oranlarına kıyasla %95 doğruluk sağlamıştır [17].

Reiazi ve ark., yaptıkları çalışma ile mamografi görüntülerinden lezyon tespiti için basit bir seri evrişim sinir ağı uygulayan Daha Hızlı Bölgesel Evrişimsel Sinir Ağları (R-CNN/Region Convolution Neural Networks) detektörünün verimini değerlendirmişlerdir [18].

Xi ve ark., mamogram görüntülerinde kalsifikasyonları ve kitleleri sınıflandırmak ve sınırlandırmak için evrişimsel sinir ağlarını kullanmışlardır. Deneysel sonuçlarla VGGNet'in sınıflandırmalarda %92,53 ile en iyi genel doğruluğu aldığını göstermişlerdir. [19].

Sadoughi ve ark., meme kanserini taramak için kullanılan mamografi, ultrason ve termografi gibi farklı araçların, görüntü işleme ve yapay zekâ (AI) algoritmaları kullanılarak tasarlandığını, radyologların göğüs anormalliklerini daha verimli bir şekilde tanımlamasına yardımcı olduğu belirtilmiştir. Bu çalışmada, 2007-2017 yılları arasında yazılmış makaleler çıkarılmış, bunların arasında benzer teknikler kullanıp benzer sonuçlar bildirenler hariç tutulmuş ve son olarak 40 makale incelenmiştir. PubMed, Springer, IEEE, ScienceDirect ve Gray Literature (Google akademik dahil, konferanslarda yayınlanan makaleler, hükümet teknik raporları ve bilimsel yayıncılar tarafından kontrol edilen diğer alanlar) aracılığıyla tıbbi literatür analizi ve MEDLINE gibi veri tabanlarında meme kanseri, görüntü işleme ve yapay zeka anahtar kelimeleri ile araştırma yapılarak, tıbbi görüntü işleme teknikleri çıkarılmış ve meme kanserini teşhis etmek için görüntü işlemeyi kullanan bazı görüntü işleme ve yapay zeka yöntemleri incelenmiş ve sonuçlar son yıllarda farklı teknikleri ve sonuçlarını göstermek için tablolarda verilmiştir. Sonuç olarak, farklı görüntü tipleri için bakıldığında, desteklenen vektör makinelerinin en yüksek doğruluk yüzdesine sahip olduğu gösterilmiştir (ultrason = %95,85, mamografi = %93,069 ve termografi = %100). Bilgisayar destekli yöntemlerin yanlış pozitifleri azaltarak tanı doğruluğunu arttırdığı, meme kanserinin bilgisayarlı tanısının tıbbin gelişimine büyük katkı sağladığı ve radyologlar tarafından sürekli olarak kullanılmakta olduğu belirtilmiştir [20].

Ekici & Jawzal, meme kanseri hastalığının belirtilerini tespit etmek için görüntü işleme teknikleri ve algoritmaları kullanılarak meme kanserinin erken saptanmasına izin veren yazılım geliştirilmiş ve bu yazılımla termal meme görüntüleri analiz edilmiştir. Biyo-verilere, görüntü analizine ve görüntü istatistiklerine dayalı meme karakteristik özelliklerinin çıkarılması için yeni bir algoritma önerilmiştir. Çalışmanın girdisi, termal kamera tarafından yakalanan termal görüntüdür, bu görüntü Bayes algoritması ve yapay sinir ağları (CNN) kullanılarak optimize edilmiştir. Çalışma sonucunda görüntüler normal veya şüpheli olarak sınıflandırılabilmiştir.

Önerilen algoritma kullanılarak, veri setindeki 140 kişiye ait termal görüntüler için %98,95'lik bir doğruluk oranı elde edilmiştir [21].

Toğaçar ve ark., kadınlarda en sık görülen meme kanseri türü olan ve süt kanallarını yok ederek meme dokularını istila eden “invaziv duktal karsinom kanseri” ele alınmıştır. Meme kanseri hastalarının yaklaşık %80'inde invaziv duktal karsinom olduğu ve bu hastaların yaklaşık %66,6'sının 55 yaşından büyük olduğu belirtilmiş ve bu durumun meme kanseri tipi ile ilerleyen kadın yaşı arasında güçlü bir ilişki olduğuna işaret etmekte olduğuna dikkat çekilmiştir. Çalışmada, “invaziv duktal karsinom meme kanseri”nin sınıflandırılması için görüntü işleme teknikleri ve yapay zekanın alt dalı olan derin öğrenme modelleri kullanılmıştır. Sonuç olarak, ilk etapta alt veri kümesinde %99,73'lük bir başarı oranı elde edilmiş, veri kümesinin tamamı önerilen yaklaşımla işlendiğinde ise sınıflandırmada en iyi başarı oranının %98,59 olduğu tespit edilmiş ve önerilen yaklaşımın sınıflandırmada başarılı bir model olarak kabul edilebileceği belirtilmiştir [22].

SenthilKumar ve ark., histoloji görüntüleri kullanılan çeşitli araştırmaları gözden geçirerek durumlarını detaylandırılmıştır. Meme kanseri histoloji görüntülerini iyi huylu ve kötü huylu olarak sınıflandırmak için VGG16 modelini kullanmışlar ve test verilerinde %88 doğruluk elde etmişlerdir. Bulguları benzer şekilde diğer yaklaşımlarla da karşılaştırmışlardır [23].

Sharma ve ark., meme kanseri histopatolojik görüntülerinin büyütmeden bağımsız çoklu sınıflandırması için otomatik bir sistem oluşturmak için bir CNN mimarisi önermişlerdir. Bu otomatik sistem, dengeli bir BreakHis veri setinden sekiz farklı meme kanseri sınıfını teşhis etmede yüksek üretkenlik ve tutarlılık sunmuştur. Sistemde farklı büyütme seviyelerindeki görüntülerden ayırt edici özellikleri öğrenmek için verimli bir eğitim metodolojisi, aşırı uyum sorununun üstesinden gelmek için de veri büyütme teknikleri kullanılmıştır. Ek olarak, uygun bir havuzlama stratejisi ve optimizasyon tekniği benimsenerek CNN mimarisinin performansı önemli ölçüde iyileştirilmiştir. Buna dayanarak 40X, 100X, 200X ve 400X büyütmede sırasıyla %80,76, %76,58, %79,90 ve %74,21 doğruluk elde edilmiştir. Önerilen model, 40X büyütme seviyesinde ortalama %80,47 doğrulukla el yapımı yaklaşımlardan daha iyi performans göstermektedir [24].

Agarwal ve ark., histopatolojik görüntülerde meme kanseri sınıflandırması için kamuya açık BreakHis veri setinde derin CNN ve dört popüler CNN tabanlı mimaride: VGG16,

VGG19, MobileNet ve ResNet50 performans analizi gerçekleştirdik. Sınıflandırıcılar arasında VGG16, en yüksek %94,67 doğruluk, %92,60 kesinlik, %85,21 f1-skoru ve %80,52 geri çağırma değeri ile en iyi performansı göstermiştir [25].

Mayouf ve ark., BreakHis veri seti üzerinde müfredat artımlı öğreniminin ikili sınıflandırma için %98,76 doğruluğa ulaştığını, en son teknoloji yaklaşımının ise yalnızca %96,78'e ulaştığını göstermişlerdir. Çok sınıflı sınıflandırma ile ilgili olarak da, müfredat artımlı öğrenmenin %95,93'e ulaştığını, son teknoloji yaklaşımlar sadece %95,49'a ulaştığını belirtmişlerdir. Ayrıca müfredat dışı bir öğrenme yaklaşımına göre, aşamalı müfredat öğrenme yaklaşımının hem hesaplama süresi hem de öğrenme sürecinin stabilizasyon süresinin (sırasıyla %6 ve %20'den fazla) azaltıldığı belirtilmiştir [26].

1.2 Çalışmanın Amacı ve Kapsamı

Histopatoloji; hastalık belirtisi olan organ, doku veya hücrelerde çeşitli yöntemler kullanılarak yapılan histolojik incelemeler ve normal, kötü ve iyi huylu hücreleri ayırmayı amaçlar. Histopatolojik olarak incelenecek dokular biyopsi yöntemi ile elde edilir. En yaygın biyopsi yöntemi olan Cerrahi Açık Biyopsi (SOB) yönteminde, görüntüleme yöntemlerinin biriyle tespit edilip tel ile belirgin hale getirilen şüpheli parçanın bir kısmı ya da tamamı cerrahi operasyonla çıkarılır [27]. Meme biyopsilerinde patologlar, dokunun mikroskobik yapısını histolojik olarak değerlendirir ve görsel muayene ile son teşhisi koyar [28]. Bu aşamada patoloğun tecrübesi, dikkati, yorgunluk seviyesi vb. durumlar yanlış teşhis oranını arttırmaktadır. Kanserin doğru ve daha yüksek oranda tespiti için insan beyninden esinlenen derin öğrenme yöntemlerine ihtiyaç duyulmaktadır.

Çalışmanın amacı, önceden eğitilmiş evrimsel sinir ağlarını farklı transfer öğrenme yöntemleri üzerinden uygulayarak histopatolojik meme kanseri görüntülerinin sınıflandırmasında kullanmaktır.

Çalışma için BreakHis veri seti kullanılmıştır. Uygulamada, uygulama ortamı için Python programlama dili ve Google Colaboratory (Colab) Notebook kullanılmıştır. Colab, ücretsiz GPU desteği sunan ve G-Mail ile Drive kullanıcılarının Drive'a veri kümeleri yüklemesine ve doğrudan Drive'a bağlanmasına olanak tanıyan bir bulut desteğidir. Aynı zamanda Colab, makine öğrenimi araştırmalarına ve çalışmalarına yardımcı olmak için oluşturulmuş bir projedir. Kurulum gerektirmeyen ve tamamen bulutta çalışan bir Jupyter Notebook ortamıdır.

Bölüm 1’de literatür özeti, çalışmanın amacı ve kapsamı, veri seti hakkında detaylı bilgi verilmektedir. Bölüm 2’de derin öğrenmenin tarihçesi, derin öğrenmenin temelini oluşturan yapay sinir ağları, derin öğrenme yöntemleri ile sınıflandırma, derin öğrenme mimarileri ve derin öğrenme kullanım alanları anlatılmıştır. Bölüm 3’de histopatolojik meme kanseri görüntülerinin derin öğrenme yöntemleri ile sınıflandırılması çalışması yer almaktadır. Bölüm 4’te bu çalışmaya ait deneysel sonuçlar ve öneriler paylaşılmıştır.

1.3 Veri Seti

Göğüs Kanseri Histopatolojik Görüntü Sınıflandırması (BreakHis) veri seti, Parana, Brezilya’daki Patolojik Anatomi ve Sitopatoloji Laboratuvarı (P&D) (<http://www.prevencaoediagnose.com.br>) ile iş birliği içinde oluşturulmuştur.

Veri seti, farklı büyütme faktörleri (40X, 100X, 200X ve 400X) kullanılarak 82 hastadan toplanan meme tümörü dokusunun toplam 7109 mikroskopik görüntüsünden oluşur. Bu görüntülerin 2480 tanesi 24 hastaya ait ve iyi huylu, 5429 tanesi ise 58 hastaya ait ve kötü huylu örnek içermektedir. İyi ve kötü huylu görüntülerin büyütme oranlarına göre dağılımı Çizelge 1.2’de gösterilmiştir.

Çizelge 1.2 Büyütme Oranı ve Sınıfa Göre Görüntü Dağılımı

Büyütme Oranı	İyi Huylu	Kötü Huylu	Toplam
40X	625	1370	1995
100X	644	1437	2081
200X	623	1390	2013
400X	588	1232	1820
Toplam Görüntü	2480	5429	7909
Toplam Hasta	24	58	82

Meme tümörü örnekleri, İmmünohistokimya (IHC) ile değerlendirilmiştir. Veri setinde bulunan örnekler, kısmi mastektomi veya eksizyonel biyopsi olarak da adlandırılan Cerrahi Açık Biyopsi (SOB) yöntemi ile ~3µm kalınlığında kesitler alınarak toplanmıştır. Bu tür bir prosedür, herhangi bir iğne biyopsisi yöntemine kıyasla, daha büyük doku örneğini çıkarır ve genel anestezi ile bir hastanede yapılır.

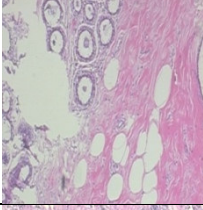
Örnekler, bahsi geçen meme dokusu biyopsi slaytlarından hematoxilen ve eozin (HE) ile boyanarak üretilmiştir. Histolojik çalışma için hazırlanmış ve P&D Laboratuvarı patoloğları tarafından etiketlenmiştir.

Görüntüler için SCC-131AN Samsung dijital renkli kamera ile birleştirilmiş 3,3X büyütmele röle lensli Olympus BX-50 sistem mikroskobu kullanılmıştır. Büyütme oranları 40X, 100X, 200X ve 400X'dir. Kamera piksel boyutu 6,5 µm'dir. Görüntüler PNG formatında, normalleştirme veya renk standardizasyonu olmayan ham görüntülerdir. 700x460 piksel, 3 kanallı (RGB) ve her kanalda 8 bit derinliğe sahiptir.

Veri seti, iki ana gruba ayrılır: İyi huylu tümörler ve kötü huylu tümörler. Histolojik olarak iyi huylu, herhangi bir malignite kriterine uymayan bir lezyona atıfta bulunan bir terimdir. Normalde, iyi huylu tümörler nispeten "masumdur", yavaş büyür ve lokalize kalır. Kötü huylu tümör, kanser ile eş anlamlıdır; lezyon, bitişik yapıları istila edip yok edebilir (yerel olarak invaziv) ve ölüme neden olmak için uzak bölgelere yayılabilir (metastaz yapabilir).

Hem iyi huylu hem de kötü huylu meme tümörleri, tümör hücrelerinin mikroskop altında nasıl görüldüğüne bağlı olarak farklı tiplere ayrılabilir. Göğüs tümörlerinin çeşitli tipleri/alt tipleri, farklı prognozlara ve tedavi sonuçlarına sahip olabilir. Veri seti şu anda dört farklı iyi huylu meme tümörü tipini: Adenosis (A), Fibroadenoma (F), Filloid Tümör (PT) ve Tübüler Adenoma (TA); ve dört habis tümör (göğüs kanseri) tipini: Duktal Karsinom (DC), Lobüler Karsinom (LC), Müsinöz Karsinom (MC) ve Papiller Karsinom (PC) içermektedir. Bu tümör türleri ve özellikleri, Çizelge 1.3'te gösterilmiştir. Ayrıca iyi ve kötü huylu tümör görüntülerinin büyütme oranı ve histolojik alt tiplere göre dağılımı Çizelge 1.4 ve Çizelge 1.5'te gösterilmiştir.

Çizelge 1.3 Tümör Türleri ve Özellikleri

Tümör Türü	Görüntü	Tümör Özellikleri
Adenosis (A)		Bazı lobüller (süt üreten keseler) büyüdüğünde ve normalden daha fazla bez içerdiğinde ortaya çıkan iyi huylu meme tümörleridir.
Fibroadenoma (F)		Hem glandüler dokudan hem de stromal (bağ) dokudan oluşan yaygın, iyi huylu meme tümörleridir.
Filloid Tümör (PT)		Memenin stromal dokusunda başlayan nadir iyi huylu meme tümörleridir.
Tübüler Adenoma (TA)		Yoğun şekilde paketlenmiş düzenli yuvarlak sınırlı bir kitleden ve tübüllerden oluşan iyi huylu bir meme lezyonu olarak tanımlanır.
Duktal Karsinom (DC)		Memede süt kanalı içinde kötü huylu (anormal) hücrelerin varlığıdır.
Lobüler Karsinom (LC)		Memenin süt üreten bezlerinde (lobüller) başlayan bir meme kanseri türüdür.
Müsinöz Karsinom (MC)		Nadir görülen bir meme kanseri türüdür. Adını, kanser hücrelerinin müsin adı verilen bir madde ile çevrelenmesinden alır.
Papiller Karsinom (PC)		Tüm meme kanserlerinin %1'inden daha azını oluşturan çok nadir görülen bir kanser türüdür. Adı, hücrelere mikroskop altında bakıldığında görülen parmak benzeri çıkıntılardan veya papüllerden gelir.

Çizelge 1.4 Büyütme Oranı ve Histolojik Alt Tiplere Göre “İyi Huylu” Görüntü Dağılımı

Büyütme Oranı	A	F	PT	TA	Toplam
40X	114	253	149	109	625
100X	113	260	150	121	644
200X	111	264	140	108	623
400X	106	237	130	115	588
Toplam	444	1014	569	453	2480
Toplam Hasta	4	10	7	3	24

Çizelge 1.5 Büyütme Oranı ve Histolojik Alt Tiplere Göre “Kötü Huylu” Görüntü Dağılımı

Büyütme Oranı	DC	LC	MC	PC	Toplam
40X	864	156	205	145	1370
100X	903	170	222	142	1437
200X	896	163	196	135	1390
400X	788	137	169	138	1232
Toplam Görüntü	3451	626	792	560	5429
Toplam Hasta	38	5	9	6	58

2. DERİN ÖĞRENME

2.1 Tarihçe

Derin öğrenme, makine öğrenmesinin bir alt dalıdır, makine öğrenmesi ise yapay zekânın bir alt dalıdır. Son yıllarda veri sayısının artmasıyla (özellikle son 10 yılda oluşan “Büyük Veri” ile birlikte), makine öğrenmesi yöntemleri performans açısından iyi sonuçlar vermemeye ve yetersiz kalmaya başlamıştır. Bu durum derin öğrenme sıçramasını beraberinde getirmiştir. Derin öğrenme, performans ve başarı sonucu açısından, diğer makine öğrenmesi yöntemlerine göre daha iyi sonuçlar vermektedir.



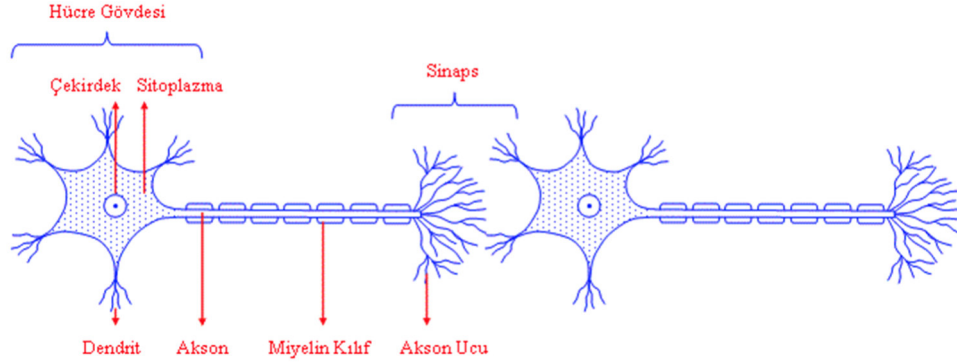
Şekil 2.1. Derin Öğrenmenin Gelişimi

Derin öğrenme, çok katmanlı YSA'dan oluşur. 90'lı yıllarda veri setlerinin yeterli olmaması, bilgisayarların CPU açısından yetersiz kalması, yanlış şekilde başlatma (initialization) ve doğru olmayan nonlinear aktivasyon fonksiyonları gibi problemler sebebi ile bir dönem durgunluk yaşayan YSA ve derin öğrenme, zamanla teknolojinin gelişmesi bilgisayarların güçlenmesiyle birlikte 2000'li yılların başında yeniden ilgi gören bir alan olmaya başlamıştır. GPU gelişimiyle birlikte daha yüzeysel ağlardan daha derin ağlara geçiş yapılmıştır. Şekil 2.1'de derin öğrenmenin bu gelişimi gösterilmektedir.

2.2 Yapay Sinir Ağları

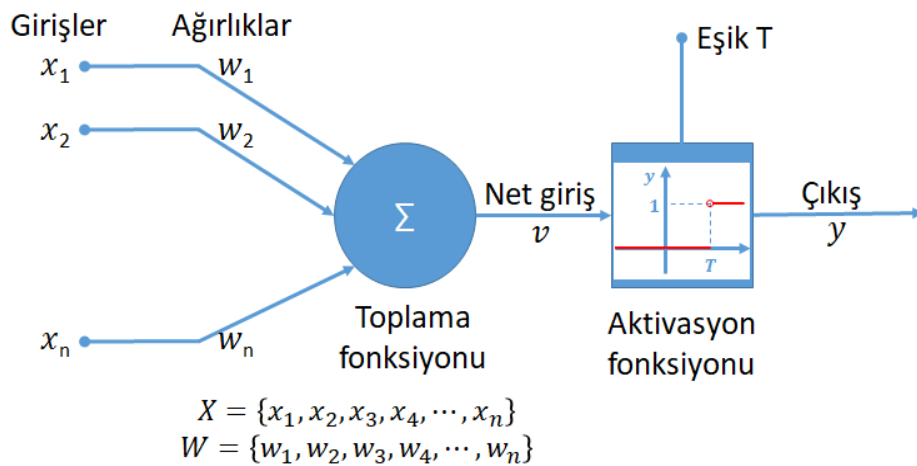
YSA, beynimizin yapısını ve çalışma mekanizmasını taklit eden sistemlerdir ve çok sayıda işlem birimine (nöron) sahiptir. Biyolojik sinirlerden, yapay sinir ağlarına geçerken

nöron = işlem elemanı, dentrit = toplama fonksiyonu, hücre gövdesi = aktivasyon fonksiyonu, akson = eleman çıkışı, sinaps = ağırlık şeklinde dönüşüm geçirir. Şekil 2.2’de biyolojik sinir hücresinin yapısı gösterilmiştir.



Şekil 2.2. Biyolojik Sinir Hücresinin Yapısı

Dış ortamdan veya diğer sinir hücrelerinden alınan girdiler, ağırlıklar yardımıyla yeni hücreye bağlanır. Toplama fonksiyonu ile net girdi bulunur. Net girdinin aktivasyon fonksiyonundan geçirilmesiyle ise net çıktı bulunur (bir yapay sinir ağındaki tüm hücrelerin toplama ve aktivasyon fonksiyonu aynı olmak zorunda değildir). Her düğümün bir ağırlık değeri vardır. YSA, kendisine örnekler gösterildikçe bu ağırlık değerlerini günceller. Amaç, ağa gösterilen örnekler için doğru çıkışları verecek ağırlıkları bulmaktır.



Şekil 2.3. Yapay Sinir Hücresinin Yapısı

Aktivasyon fonksiyonu, yapay sinir ağındaki nöronun aktif olup olmayacağına karar veren bir fonksiyondur. Söz konusu probleme göre karar verilecek "sigmoid", "tanh", "relu" ve "softmax" gibi çeşitli aktivasyon fonksiyonları vardır. Şekil 2.3'te bir yapay nöron modeli

görülmektedir. “ X_1, X_2, \dots, X_n ” giriş değerleri ve “ W_1, W_2, \dots, W_n ” karşılık gelen ağırlık değerleridir. Aktivasyon fonksiyonu, girdiler ve ağırlıkların çarpımlarının toplamına bias sapma değerinin eklenmesiyle oluşan bir fonksiyondur.


YSA’da bilgiler ağıın tamamına yayılarak saklanır. Ağlar eğitildikten sonra eksik veriler içerse dahi çıktı üretebilirler. Olayları öğrenirler ve benzer olaylarla karşılaştıklarında yorum yapıp karar verebilirler. Aynı zamanda birden fazla işi aynı anda yapabilecek alt yapıya sahiptir.

YSA’da ilgili tüm örneklerin ağa gösterilerek modelin eğitilmesi gerekmektedir. Modelin başarısı, seçilen örnekler ile doğrudan ilişkilidir. Yani modele olay bütün yönleri ile tanıtılmazsa model yanlış çıktılar üretebilir.

2.3 Derin Öğrenme Yöntemleri ile Sınıflandırma

Klasik öğrenme yöntemleri, girdilerin ve çıktıların çok büyük olduğu yüksek boyutlu verileri işleme yetenekleri bakımından sınırlıdır. Bu verilerin işlenmesi, problem karmaşıklığı arttıkça performans ve doğruluk açısından daha zor hale gelir. Bu aşamada derin öğrenme, karmaşık gerçek dünya sorunlarına çözümler sunar. Görev daha karmaşık hale geldikçe, nöronlar bilgiyi iletmek için daha karmaşık bir ağ yapısı oluşturur.

Derin öğrenme, özellikleri doğrudan verilen verilerden öğrenir. Sinir ağları, diğer algoritmaların kolayca keşfedemeyeceği nitelikleri ve aralarındaki ilişkileri kolayca öğrenebilir. Sinir ağları, verileri matematiksel olarak dönüştüren nöron katmanlarını kullanarak karmaşık bir model öğrenir. Sıradan bir sinir ağı modeli, bir giriş katmanı, bir çıkış katmanı ve ikisi arasındaki bilgi akışını sağlayan bir gizli katmandan oluşur. Derin öğrenme terimi, birçok gizli katmana sahip modeller için kullanılır. Şekil 2.4'te her daire bir nöronu temsil etmektedir. Her nöron; bir ağırlık değeri, bias değeri ve aktivasyon fonksiyonu olan matematiksel bir fonksiyondur. Nöronların bir veya daha fazla girişi vardır. Bilgi, giriş katmanından gizli katmana hareket eder, gizli katmanlar işleyerek bilgiyi çıkış katmanına gönderir.



Şekil 2.4. Sinir Ağı Mimarisinin Genel Görünümü

2.4 Derin Öğrenme Mimarileri

Yapay görme uygulamalarında kullanılan CNN başta olmak üzere birçok derin öğrenme mimarisinin çalışma prensibi, insan beynindeki görme sistemine benzer. Şöyle ki:


- Gözlerden nöronlar aracılığıyla gelen sinyaller birkaç katmanlı sistematik bir yapıda değerlendirilir.
- Sinyalin gözden sonra ilk uğradığı bölgede köşe ve kenar gibi görüntünün başlıca özellikleri tanınır.
- Devam eden katmanlarda bu köşe ve kenarlar bir araya getirilerek göz, burun ve ağız gibi bölgeler, ardındaki katmanlarda yüzler, ardındaki katmanlarda ise nesne ve kişi yerleşimi gibi görüntünün tümüne ait olan özellikler tanınır.

En temel derin öğrenme model mimarileri: RNN ve CNN'dir.

2.4.1 RNN

RNN'in diğer mimarilerden farkı hatırlama özelliğidir. Bu hatırlama işlemi, RNN'de girdiler arasında ilişki kurulmasıyla sağlanır. Eğitim sırasında kurulan tüm bu ilişkiler hatırlanır. Şekil 2.5.te görüldüğü gibi çıktı sonucu üretilen sonuç bir sonraki adımı

beslemektedir. Genellikle metin ve ses verileri üzerinde kullanılmaktadır. Kendi içerisinde döngü gibi çalışarak işlemler yapıldığı için çok derin RNN yapıları kurulmaz.



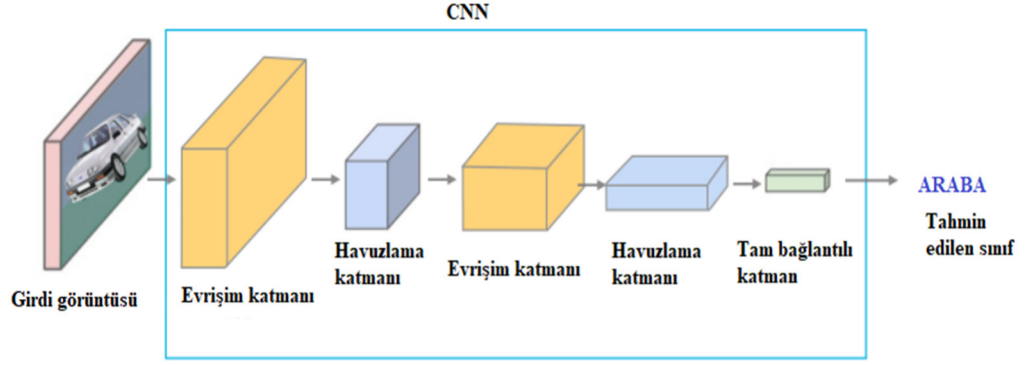
Şekil 2.5. Basit Tekrarlayan Sinir Ağı (RNN)

2.4.2 CNN

Evrişimli sinir ağı (CNN), art arda yerleştirilmiş birden fazla eğitilebilir bölümden oluşur ve genellikle görsel verinin çeşitli katmanlarla işlenmesinde kullanılan bir derin öğrenme yöntemidir. CNN, ham görüntüleri alıp çeşitli katmanlarla işleyerek eğitim sürecini gerçekleştirir ve özelliklerin otomatik olarak çıkarılmasını sağlar.

CNN, özel bir yapay sinir ağı türüdür. CNN'ler özellikle görüntü problemlerinde yaygın olarak kullanılan derin öğrenme mimarileridir. Bir CNN, klasik sinir ağları yapısına benzer nöronlardan oluşur ve öğrenme için ağırlıkları ve önyargıları vardır. Her nöron girdileri alır, birleştirir ve genellikle doğrusal olmayan bir işleve sahip bir çıktı üretir. CNN uygulamaları, girdileri görüntü olarak kabul eder ve özellikleri mimariye kodlamamıza izin verir.

Evrişimli sinir ağları, derin öğrenmenin bir alt dalıdır ve genellikle görsel bilgilerin analizinde kullanılır. Yaygın kullanımlar görüntü ve video tanımadır. Esasen çok katmanlı bir sinir ağı modeli kategorisine aittirler. Klasik öğrenme yöntemlerine göre çok fazla ön işleme aşaması gerektirmeyen, özellik çıkarımı gerçekleştiren ve daha yüksek performans sunan bir yöntemdir [29]. Katmanlarıyla birlikte CNN yapısı Şekil 2.6'da gösterilmektedir. CNN; evrişim, doğrusal olmayan, havuzlama, düzleştirme ve tam bağlantılı katmanlardan oluşur. *Evrişimli Katman (Convolutional Layer)*, özelliklerin tespiti için kullanılır, *Doğrusal Olmayan Katman (Non-Linearity Layer)*, sisteme doğrusal olmayanlığı getirmektir, *Havuzlama Katmanı (Pooling Layer)*, ağırlıkların sayısını azaltmak ve uygunluklarını kontrol etmektedir. Verileri ağ için hazırlama işlemi *Düzleştirme Katmanı'nın (Flattening Layer)* görevidir. Verilerin sınıflandırılması *Tam Bağlı Katman'da (Full-Connected Layer)* gerçekleştirilir.



Şekil 2.6. Basit Evrişimli Sinir Ağı (CNN)

2.4.2.1 Evrişim Katmanı (Convolutional Layer)

CNN algoritmalarında görüntüyü işleyen ilk katmandır. Görüntüler, içinde belirli değerler bulunan piksellerden oluşan matrislerdir. Evrişim katmanında, orijinal görüntü boyutundan daha küçük bir filtre görüntünün üzerine gelir ve bu görüntülerden belirli özellikleri yakalamaya çalışır.

Evrişim katmanı, bir 'I' girişi ve bir dizi 'n' evrişim filtresi ve ardından ' F^E ' doğrusal olmayan bir aktivasyon işlevi içerir. Bu işlemler sonucunda Formül (2.1)'de gösterildiği gibi, 'O' çıktı hacmi elde edilir.

$$O_m(i, j) = a \left(\sum_{d=1}^D \sum_{u=-2k-1}^{2k+1} \sum_{v=-2k-1}^{2k+1} F_{md}^E(u, v) I_d(i - u, j - v) \right) + b_m \quad (2.1)$$

' $2k+1$ ', tek bir evrişim filtresine sahip bir karenin kenarıdır.

'a', aktivasyon fonksiyonunu ifade eder.

' b_m ', m^{th} özellik haritasının bias değerini ifade eder.

Yukarıdaki bağıntının yardımıyla üretilen aktivasyon haritaları, düşük boyutlu bir uzayda 'I' girişinin kodlanmasıdır, yani her özellik haritasını 'c' oluşturmak için kullanılan parametreleri ifade eder. ' O_m ' hesaplandıktan sonra, alt örnekleme için bir maksimum havuzlama işlemine tabi tutulur. Sezgisel olarak, bu mimarideki her evrişimli katman, memedeki tümör tiplerini büyütme oranlarına göre tespit etmek için ayırt edici kalıpları yakalayan çeşitli nitelikleri öğrenir [30].

2.4.2.2 Doğrusal Olmayan Katman (Non-Linearity Layer)

Bu katman, aktivasyon işlevlerinden birini kullandığı için "Aktivasyon Katmanı" olarak adlandırılır. Geçmişte "sigmoid" ve "tanh" gibi doğrusal olmayan fonksiyonlar kullanılırken, şimdi nöral ağ eğitiminin hızı için en iyi sonuçları verdiği için Doğrultulmuş Liner Birim (ReLU) fonksiyonu kullanılmaktadır. ReLU işlevi Formül (2.2)'de görülür ve $[0, +\infty]$ değerindedir.

$$f(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ x & \text{for } x > 0 \end{cases} \quad (2.2)$$

2.4.2.3 Havuzlama Katmanı (Pooling Layer)

Havuzlama katmanı, evrişim katmanı gibi boyutsallığı azaltmak için tasarlanmıştır. Bu sayede hem gerekli işlem gücü azaltılır hem de yakalanan gereksiz özellikler göz ardı edilir ve daha önemli özelliklere odaklanılır. CNN modellerinde yaygın olarak kullanılan üç farklı havuzlama tekniği vardır. Bunlar; "Minimum" (Min), "Maksimum" (Max) ve "Ortalama" havuzlamadır. Havuzlama işlemi sonucunda oluşan görüntünün boyutu Formül (2.3)'te görüldüğü şekilde hesaplanır:

$$\text{Oluşturulan görüntünün boyutu} = W_2 \times H_2 \times D_2 \quad (2.3)$$

$$W_2 = (W_1 - F) / N + 1 \quad (2.4)$$

$$H_2 = (H_1 - F) / N + 1 \quad (2.5)$$

$$D_2 = D_1 \quad (2.6)$$

W_1 = Giriş görüntü boyutunun genişlik değeri,

H_1 = Giriş görüntü boyutunun yükseklik değeri,

D_1 = Giriş görüntü boyutunun derinlik değeri,

F = Filtre boyutu,

N = Adım sayısı.

2.4.2.4 Düzleştirme Katmanı (Flattening Layer)

Bu katmanın görevi, Tam Bağlantılı Katman'a girilecek verileri hazırlamaktır. Genel olarak, sinir ağları, tek boyutlu bir diziden girdi verilerini alır. Bu katmanda kullanılan veriler, Evrişim ve Havuzlama katmanlarından alınan tek boyutlu matris tipi verilerdir.

2.4.2.5 Tam Bağlantılı Katman (Fully Connected Layer)

Tam Bağlantılı Katmanda, evrişim katmanından ve havuz katmanından birkaç kez geçen matris görüntüsü düz bir vektöre dönüştürülür.

2.4.2.6 Sınıflandırma Katmanı (Classification Layer)

Sınıflandırma katmanı, ayrışık sınıflarla sınıflandırma ve ağırlıklı sınıflandırma görevleri için çapraz entropi kaybını hesaplar. Katman, tam bağlı katmanın çıktı boyutundan sınıf sayısını çıkarır.

2.5 Derin Öğrenme Kullanım Alanları

Derin öğrenme yöntemlerinin birçok alanda uygulaması mevcuttur. Uygulandığı alanlardan bazıları;

- Görüntü iyileştirilmesinde,
- Ses tanıma sistemlerinde,
- Yüz tanıma sistemlerinde,
- Araçlarda oto pilot özelliğinde veya sürücüsüz araçlarda,
- Sağlık sektöründe kanser, tümör vb. araştırmalarında,
- Siber tehdit analizlerinde,
- Öneri sistemlerinde, beğenilebilecek film ve müzik tavsiye sunmada,
- Alarm sistemlerinde kamera kayıtlarını sürekli kontrol etmek yerine, yalnızca olağandışı hareketlerde alarm sisteminin devreye girmesi amacıyla kullanılmaktadır.

3. HİSTOPATOLOJİK MEME KANSERİ GÖRÜNTÜLERİNİN DERİN ÖĞRENME YÖNTEMLERİ İLE SINIFLANDIRILMASI

Bu çalışmada, BreakHis veri setindeki 40X, 100X, 200X ve 400X büyütme oranlarının her biri için ayrı ayrı olmak üzere iki tür sınıflandırma yapılmıştır. İlki tümör özelliklerine (“İyi Huylu” ve “Kötü Huylu”), ikincisi ise iyi ve kötü huylu tümörlerin çeşitlerine (“Adenosis (A)”, “Fibroadenoma (F)”, “Filloid Tümör (PT)”, “Tübüler Adenoma (TA)”, “Duktal Karsinom (DC)”, “Lobüler Karsinom (LC)”, “Müsinöz Karsinom (MC)” ve “Papiller Karsinom (PC)”)” görelerdir.

Veri seti, açık kaynak kodlu bir sinir ağı kütüphanesi olan Keras kütüphanesinde yer alan şu modeller üzerinde eğitilmiştir: DenseNet121, DenseNet169, DenseNet201, EfficientNetB0, EfficientNetB1, EfficientNetB2, EfficientNetB3, EfficientNetB4, EfficientNetB5, EfficientNetB6, EfficientNetB7, InceptionResNetV2, InceptionV3, MobileNet, MobileNetV2, MobileNetV3Large, MobileNetV3Small, NASNetMobile, ResNet101, ResNet101V2, ResNet152, ResNet152V2, ResNet50, ResNet50V2, VGG16, VGG19 ve Xception.

Çizelge 1.4 ve Çizelge 1.5’te gösterildiği gibi; veri setinde her bir büyütme oranı için tümör çeşidine göre yer alan görüntü sayıları eşit olmadığından, her bir tümör çeşidi için eşit ve 100 tane rastgele görüntü seçilerek sistem gerçekleştirilmiştir.

3.1 Tümör Özelliklerine Göre Sınıflandırma

Meme tümörleri öncelikle özelliklerine göre “İyi Huylu” ve “Kötü Huylu” olarak sınıflandırılmışlardır. Derin öğrenme mimarileri 40X, 100X, 200X ve 400X olmak üzere her büyütme oranına ayrıca uygulanmıştır. Çizelge 3.1, Çizelge 3.2, Çizelge 3.3 ve Çizelge 3.4’te büyütme oranlarının tümör özelliklerine göre sınıflandırma sonuçları ayrıntılı olarak yer almaktadır. Bu sonuçlara göre; 40X büyütme oranı için ResNet50V2 modeli %95,88 ile, 100X büyütme oranı için DenseNet201 modeli %96,38 ile, 200X büyütme oranı için ResNet152V2 modeli %95,5 ile ve 400X büyütme oranı için ResNet152V2 modeli %96 ile en yüksek test doğruluğuna sahiptir.

Çizelge 3.1 40X Büyütme Oranının Tümör Özelliklerine Göre Sınıflandırılması


Model	Test Doğruluğu (%)	Eğitim Süresi (Saniye)
ResNet50V2	95,88	57,93
DenseNet201	95,5	111,33
DenseNet169	95,38	89,61
ResNet152V2	94,5	146,75
ResNet101V2	93,75	103,90
DenseNet121	92,5	146,03
MobileNetV2	91,25	42,60
MobileNet	89,62	37,75
NASNetMobile	88,25	58,75
Xception	87,88	88,83
InceptionV3	87,62	52,79
InceptionResNetV2	83,12	125,47
VGG19	76,88	79,65
VGG16	76,12	115,32
ResNet152	57,75	166,00
ResNet50	53,5	70,28
ResNet101	53,12	120,81
EfficientNetB3	50	94,99
EfficientNetB7	50	116,87
EfficientNetB2	50	70,88
MobileNetV3Small	50	37,09
EfficientNetB1	50	66,77
MobileNetV3Large	50	43,55
EfficientNetB0	50	49,39

Çizelge 3.1'in devamı

EfficientNetB4	50	121,72
EfficientNetB5	50	116,67
EfficientNetB6	50	115,61


Çizelge 3.1 incelendiğinde 40X büyütme oranı için en yüksek başarı oranının %95,88 ve bunun da yaklaşık 58 saniyede gerçekleştiği görülmektedir. Burada gerçekleştirilen işlem iyi huylu kötü huylu tümör ayırımıdır.

Şekil 3.1'de 40X büyütme oranının tümör özelliklerine göre doğrulukları grafik olarak gösterilmiştir. Şekil 3.2'de model sonucu oluşturulan karışıklık matrisi yer almaktadır. Şekil 3.3'te 40X büyütme oranının tümör özelliklerine göre gerçek ve tahmin sonuçlarından bir kesit ve Şekil 3.4'te de 40X büyütme oranının tümör özelliklerine göre eğitim zaman grafiği gösterilmiştir.




Şekil 3.1 40X Büyütme Oranının Tümör Özelliklerine Göre Doğruluk Grafiği

Şekil 3.1'de 40X büyütme oranı için en yüksek doğruluğun **ResNet50V2** modeliyle elde edildiği grafiksel olarak da görülmektedir.




Şekil 3.2 40X Büyütme Oranının Tümör Özelliklerine Göre Karışıklık Matrisi

Şekil 3.2 40X büyütme oranı için iyi huylu ve kötü huylu ayrımının ne kadar doğru yapıldığına dair net bulgular ortaya koyan karışıklık matrisini göstermektedir. Şekil incelendiğinde gerçekte kötü huylu olan 18 görüntünün iyi huylu olarak sınıflandırıldığı, gerçekte iyi huylu olan 8 görüntünün de kötü huylu olarak sınıflandırıldığı görülmektedir. Buradan kötü huylu tümörlerin karıştırılma ihtimalinin daha yüksek olduğu yorumu yapılabilir.



Şekil 3.3 40X Büyütme Oranının Tümör Özelliklerine Göre Gerçek ve Tahminlerinden Kesit

Şekil 3.3 40X büyütme oranı için tümör özelliklerine göre gerçekleştirilmiş olan sınıflandırma işlemi neticesinde hatalı ve doğru yapılan tahminlere örnekler göstermektedir. Görseller incelendiğinde hatalı tespit edilen görüntünün diğer sınıfa ait benzer yönleri olan görüntüler olduğu düşünülmektedir.



Şekil 3.4 40X Büyütme Oranının Tümör Özelliklerine Göre Eğitim Süresi Grafiği

Şekil 3.4'te 40X büyütme oranında ikili sınıflandırma için en kısa eğitim süresinin **MobileNetV3Small** modeliyle elde edildiği grafiksel olarak da görülmektedir.

Çizelge 3.2 100X Büyütme Oranının Tümör Özelliklerine Göre Sınıflandırılması

Model	Test Doğruluğu (%)	Eğitim Süresi (Saniye)
DenseNet201	96,38	52,09
ResNet152V2	95,12	51,04
ResNet50V2	94,88	37,23
DenseNet121	93,12	163,65
Xception	92,62	39,08
ResNet101V2	92,5	46,56
MobileNet	92	34,65
MobileNetV2	90,62	36,45


Çizelge 3.2'nin devamı

DenseNet169	89,88	48,1
NASNetMobile	89,5	53,47
InceptionV3	84,38	40,71
InceptionResNetV2	83,12	54,64
VGG19	78,25	34,65
VGG16	76,62	43,46
ResNet50	61,62	38,06
ResNet101	60,75	45,58
MobileNetV3Small	54,25	36,63
ResNet152	50,5	51,52
EfficientNetB2	50	45,46
MobileNetV3Large	50	38,95
EfficientNetB7	50	53,06
EfficientNetB0	50	41,31
EfficientNetB6	50	52,03
EfficientNetB5	50	52,99
EfficientNetB4	50	52,49
EfficientNetB3	50	49,01
EfficientNetB1	50	45,71

Çizelge 3.2 incelendiğinde 100X büyütme oranı için en yüksek başarı oranının %96,38 ve bunun da yaklaşık 52 saniyede gerçekleştiği görülmektedir. Burada gerçekleştirilen işlem iyi huylu kötü huylu tümör ayırımıdır.


Şekil 3.5'te 100X büyütme oranının tümör özelliklerine göre doğrulukları grafik olarak gösterilmiştir. Şekil 3.6'da model sonucu oluşturulan karışıklık matrisi yer almaktadır. Şekil

3.7’de 100X büyütme oranının tümör özelliklerine göre gerçek ve tahmin sonuçlarından bir kesit ve Şekil 3.8’de de 100X büyütme oranının tümör özelliklerine göre eğitim zaman grafiği gösterilmiştir.



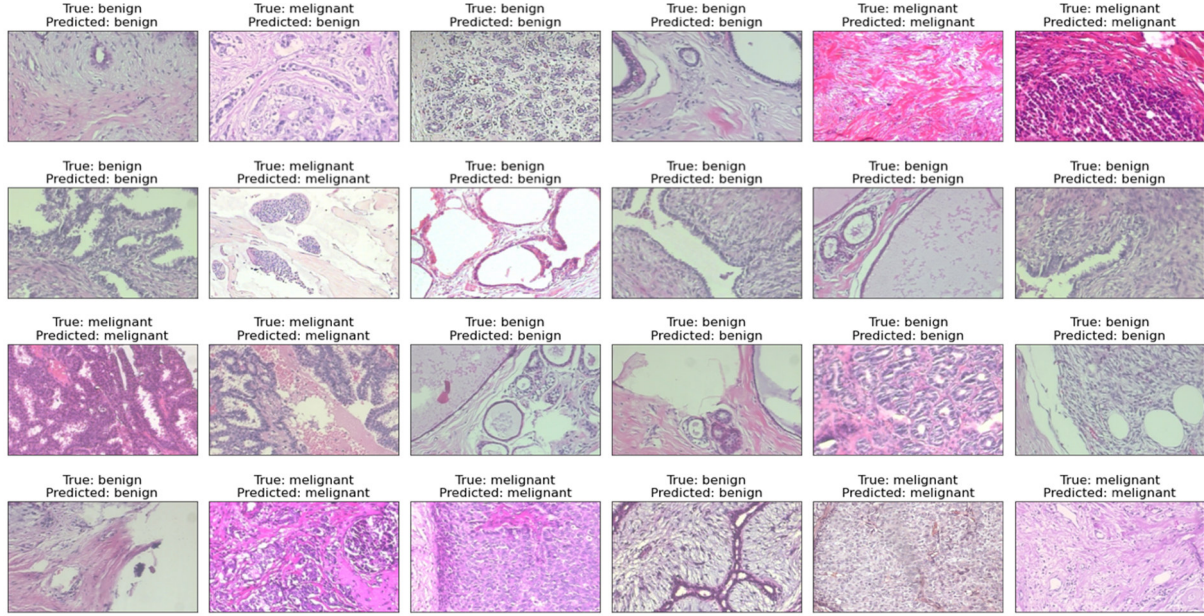
Şekil 3.5 100X Büyütme Oranının Tümör Özelliklerine Göre Doğruluk Grafiği

Şekil 3.5’te 100X büyütme oranı için en yüksek doğruluğun **DenseNet201** modeliyle elde edildiği grafiksel olarak da görülmektedir.




Şekil 3.6 100X Büyütme Oranının Tümör Özelliklerine Göre Karışıklık Matrisi

Şekil 3.6 100X büyütme oranı için iyi huylu ve kötü huylu ayrımının ne kadar doğru yapıldığına dair net bulgular ortaya koyan karışıklık matrisini göstermektedir. Şekil incelendiğinde gerçekte kötü huylu olan 16 görüntünün iyi huylu olarak sınıflandırıldığı, gerçekte iyi huylu olan 12 görüntünün de kötü huylu olarak sınıflandırıldığı görülmektedir. Buradan kötü huylu tümörlerin karıştırılma ihtimalinin daha yüksek olduğu yorumu yapılabilir.



Şekil 3.7 100X Büyütme Oranının Tümör Özelliklerine Göre Gerçek ve Tahminlerinden Kesit

Şekil 3.7 100X büyütme oranı için tümör özelliklerine göre gerçekleştirilmiş olan sınıflandırma işlemi neticesinde hatalı ve doğru yapılan tahminlere örnekler göstermektedir. Görseller incelendiğinde hatalı tespit edilen görüntünün diğer sınıfa ait benzer yönleri olan görüntüler olduğu düşünülmektedir.



Şekil 3.8 100X Büyütme Oranının Tümör Özelliklerine Göre Eğitim Süresi Grafiği

Şekil 3.8’te 100X büyütme oranı için oranında ikili sınıflandırma için en kısa eğitim süresinin **MobileNet** ve **VGG19** modelleriyle elde edildiği grafiksel olarak da görülmektedir.

Çizelge 3.3 200X Büyütme Oranının Tümör Özelliklerine Göre Sınıflandırılması


Model	Test Doğruluğu (%)	Eğitim Süresi (Saniye)
ResNet152V2	95,5	46,99
DenseNet201	95,12	48,68
DenseNet169	94,5	47,42
MobileNet	93,75	32,67
ResNet50V2	93,25	34,74
ResNet101V2	92,62	43,44
Xception	92,5	36,9
DenseNet121	88,25	164,03
MobileNetV2	88,12	35,41
NASNetMobile	86,62	49,58
InceptionResNetV2	85,38	49,49
VGG16	81,62	41,36

Çizelge 3.3'ün devamı

VGG19	77,62	32,58
InceptionV3	77,38	37,01
ResNet50	53,5	35,03
ResNet101	52,62	42,81
ResNet152	52,25	48,05
EfficientNetB3	50	45,48
MobileNetV3Large	50	34,6
MobileNetV3Small	50	33,49
EfficientNetB5	50	47,52
EfficientNetB2	50	42,61
EfficientNetB1	50	42,86
EfficientNetB0	50	37,74
EfficientNetB7	50	47,34
EfficientNetB6	50	47,52
EfficientNetB4	50	49,09


Çizelge 3.3 incelendiğinde 200X büyütme oranı için en yüksek başarı oranının %95,5 ve bunun da yaklaşık 47 saniyede gerçekleştiği görülmektedir. Burada gerçekleştirilen işlem iyi huylu kötü huylu tümör ayırımıdır.

Şekil 3.9'de 200X büyütme oranının tümör özelliklerine göre doğrulukları grafik olarak gösterilmiştir. Şekil 3.10'da model sonucu oluşturulan karışıklık matrisi yer almaktadır. Şekil 3.11'de 200X büyütme oranının tümör özelliklerine göre gerçek ve tahmin sonuçlarından bir kesit ve Şekil 3.12'de de 200X büyütme oranının tümör özelliklerine göre eğitim zaman grafiği gösterilmiştir.



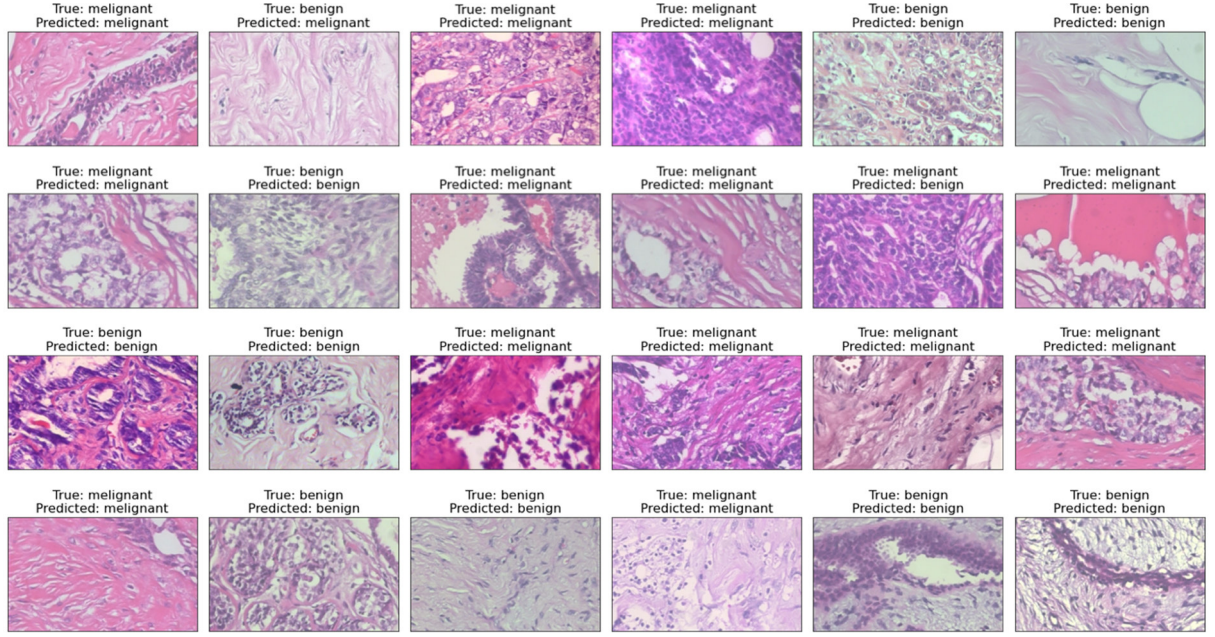
Şekil 3.9 200X Büyütme Oranının Tümör Özelliklerine Göre Doğruluk Grafiği

Şekil 3.9’da 200X büyütme oranı için en yüksek doğruluğun **ResNet152V2** modeliyle elde edildiği grafiksel olarak da görülmektedir.



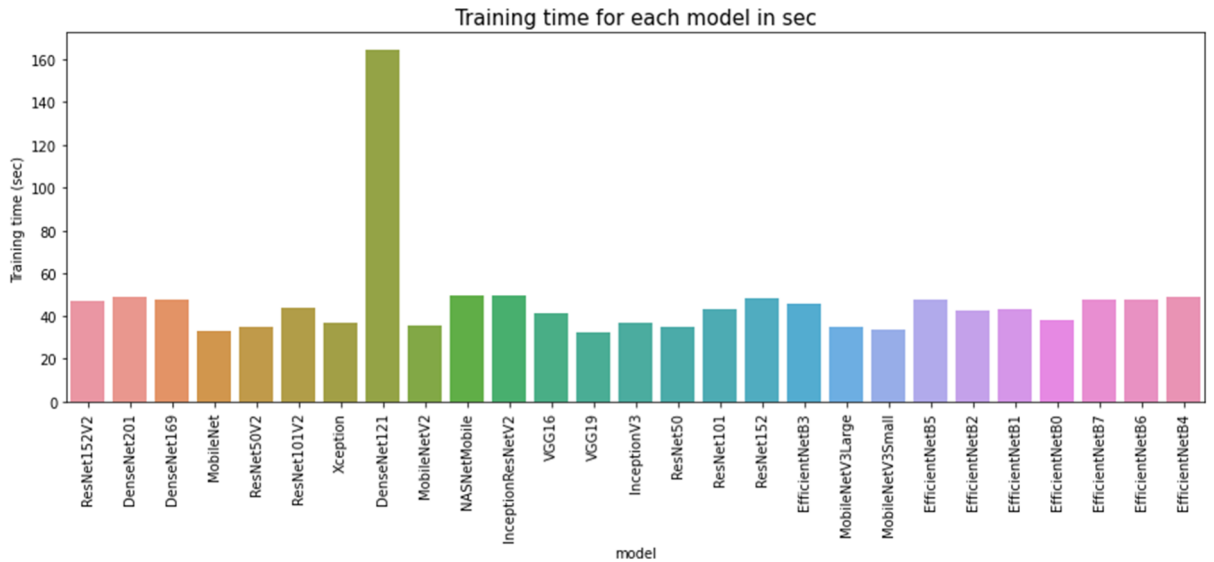
Şekil 3.10 200X Büyütme Oranının Tümör Özelliklerine Göre Karışıklık Matrisi

Şekil 3.10 200X büyütme oranı için iyi huylu ve kötü huylu ayrımının ne kadar doğru yapıldığına dair net bulgular ortaya koyan karışıklık matrisini göstermektedir. Şekil incelendiğinde gerçekte kötü huylu olan 20 görüntünün iyi huylu olarak sınıflandırıldığı, gerçekte iyi huylu olan 16 görüntünün de kötü huylu olarak sınıflandırıldığı görülmektedir. Buradan kötü huylu tümörlerin karıştırılma ihtimalinin daha yüksek olduğu yorumu yapılabilir.



Şekil 3.11 200X Büyütme Oranının Tümör Özelliklerine Göre Gerçek ve Tahminlerinden Kesit

Şekil 3.11 200X büyütme oranı için tümör özelliklerine göre gerçekleştirilmiş olan sınıflandırma işlemi neticesinde hatalı ve doğru yapılan tahminlere örnekler göstermektedir. Görseller incelendiğinde hatalı tespit edilen görüntünün diğer sınıfa ait benzer yönleri olan görüntüler olduğu düşünülmektedir.



Şekil 3.12 200X Büyütme Oranının Tümör Özelliklerine Göre Eğitim Süresi Grafiği

Şekil 3.12’de 200X büyütme oranında ikili sınıflandırma için en kısa eğitim süresinin VGG19 modeliyle elde edildiği grafiksel olarak da görülmektedir.

Çizelge 3.4 400X Büyütme Oranının Tümör Özelliklerine Göre Sınıflandırılması


Model	Test Doğruluğu (%)	Eğitim Süresi (Saniye)
ResNet152V2	96	50,15
ResNet101V2	93,38	46,14
ResNet50V2	92,75	37,53
DenseNet121	90,12	155,59
DenseNet201	89,25	51,67
MobileNet	86,75	33,52
NASNetMobile	85,5	52,37
Xception	84,25	39,52
DenseNet169	83,88	48,29
VGG16	81,5	44,37
MobileNetV2	81,25	35,32
VGG19	79,5	34,79
InceptionV3	78,75	39,63
InceptionResNetV2	73,62	53,2
ResNet152	56,62	50,76
ResNet50	55,38	37,63
MobileNetV3Large	55,12	37,27
EfficientNetB1	50	45,39
EfficientNetB0	50	40,88
EfficientNetB4	50	51,32
ResNet101	50	43,76
EfficientNetB5	50	51,95

Çizelge 3.4'ün devamı

MobileNetV3Small	50	35,75
EfficientNetB3	50	47,69
EfficientNetB7	50	52,11
EfficientNetB6	50	51,22
EfficientNetB2	50	44,56

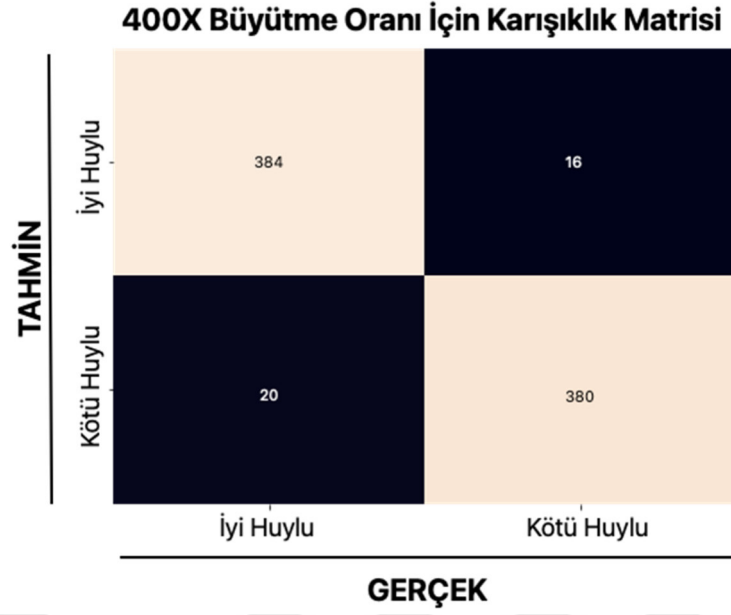
Çizelge 3.4 incelendiğinde 400X büyütme oranı için en yüksek başarı oranının %96 ve bunun da yaklaşık 50 saniyede gerçekleştiği görülmektedir. Burada gerçekleştirilen işlem iyi huylu kötü huylu tümör ayırımıdır.

Şekil 3.13'te 400X büyütme oranının tümör özelliklerine göre doğrulukları grafik olarak gösterilmiştir. Şekil 3.14'te model sonucu oluşturulan karışıklık matrisi yer almaktadır. Şekil 3.15'te 400X büyütme oranının tümör özelliklerine göre gerçek ve tahmin sonuçlarından bir kesit ve Şekil 3.16'da da 400X büyütme oranının tümör özelliklerine göre eğitim zaman grafiği gösterilmiştir.



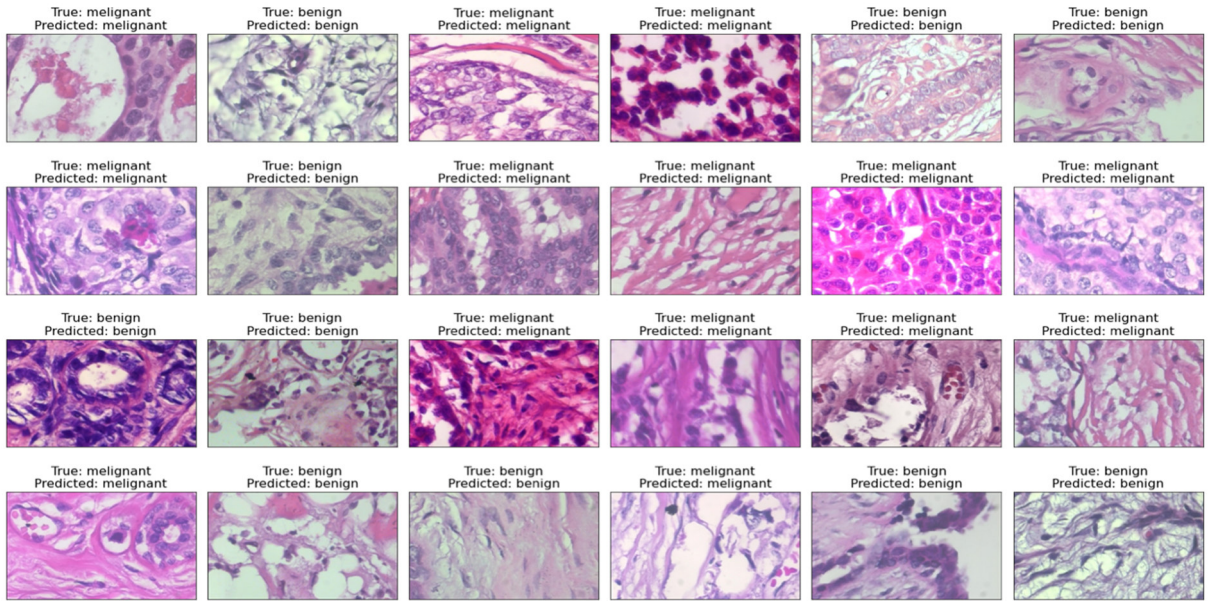
Şekil 3.13 400X Büyütme Oranının Tümör Özelliklerine Göre Doğruluk Grafiği

Şekil 3.13'te 400X büyütme oranı için en yüksek doğruluğun **ResNet152V2** modeliyle elde edildiği grafiksel olarak da görülmektedir.



Şekil 3.14 400X Büyütme Oranının Tümör Özelliklerine Göre Karışıklık Matrisi

Şekil 3.14 400X büyütme oranı için iyi huylu ve kötü huylu ayrımının ne kadar doğru yapıldığına dair net bulgular ortaya koyan karışıklık matrisini göstermektedir. Şekil incelendiğinde gerçekte kötü huylu olan 16 görüntünün iyi huylu olarak sınıflandırıldığı, gerçekte iyi huylu olan 20 görüntünün de kötü huylu olarak sınıflandırıldığı görülmektedir. Buradan iyi huylu tümörlerin karıştırılma ihtimalinin daha yüksek olduğu yorumu yapılabilir.



Şekil 3.15 400X Büyütme Oranının Tümör Özelliklerine Göre Gerçek ve Tahminlerinden Kesit

Şekil 3.15 400X büyütme oranı için tümör özelliklerine göre gerçekleştirilmiş olan sınıflandırma işlemi neticesinde hatalı ve doğru yapılan tahminlere örnekler göstermektedir. Görseller incelendiğinde hatalı tespit edilen görüntünün diğer sınıfa ait benzer yönleri olan görüntüler olduğu düşünülmektedir.



Şekil 3.16 400X Büyütme Oranının Tümör Özelliklerine Göre Eğitim Süresi Grafiği

Şekil 3.16’da 400X büyütme oranında ikili sınıflandırma için en kısa eğitim süresinin **MobileNet** modeliyle elde edildiği grafiksel olarak da görülmektedir.

Çizelge 3.5 İkili Sınıflandırma İçin Metrik Sonuçları

Büyütme Oranı	Tümör Özelliği	Kesinlik (%)	Duyarlılık (%)	F1-Skoru (%)
40X	İyi Huylu	96	95	96
	Kötü Huylu	96	96	96
100X	İyi Huylu	97	96	96
	Kötü Huylu	96	97	96
200X	İyi Huylu	96	95	95
	Kötü Huylu	95	96	96
400X	İyi Huylu	96	97	96
	Kötü Huylu	97	95	96

Çizelge 3.5’te ikili sınıflandırma üzerinde elde edilen metrik sonuçları yer almaktadır. Bu sonuçlara göre en yüksek kesinlik değeri; %97 ile 100X büyütme oranında iyi huylu tümörler ve 400X büyütme oranında kötü huylu tümörler için, en yüksek duyarlılık değeri; %97 ile 100X büyütme oranında kötü huylu tümörler ve 400X büyütme oranında iyi huylu tümörler için elde edilmiştir. F1-Skoru değeri ise 200X büyütme oranında iyi huylu tümörler için %95 iken diğer büyütme oranları ve tümör türlerinde ise %96’dır.

3.2 Tümör Çeşitlerine Göre Sınıflandırma

Meme tümörleri daha sonra çeşitlerine göre “Adenosis (A)”, “Fibroadenoma (F)”, “Filloid Tümör (PT)”, “Tübüler Adenoma (TA)”, “Duktal Karsinom (DC)”, “Lobüler Karsinom (LC)”, “Müsinöz Karsinom (MC)” ve “Papiller Karsinom (PC)” olarak sınıflandırılmışlardır. Derin öğrenme mimarileri yine 40X, 100X, 200X ve 400X olmak üzere her büyütme oranına ayrıca uygulanmıştır. Çizelge 3.5, Çizelge 3.6, Çizelge 3.7 ve Çizelge 3.8’te büyütme oranlarının tümör çeşitlerine göre sınıflandırma sonuçları ayrıntılı olarak yer almaktadır. Bu sonuçlara göre; 40X büyütme oranı için MobileNetV2 modeli %86,75 ile, 100X büyütme oranı için MobileNetV2 modeli %88,88 ile, 200X büyütme oranı için MobileNet modeli %83,12 ile ve 400X büyütme oranı için ResNet101V2 modeli %79,12 ile en yüksek test doğruluğuna sahiptir.

Çizelge 3.6 40X Büyütme Oranının Tümör Çeşitlerine Göre Sınıflandırılması


Model	Test Doğruluğu (%)	Eğitim Süresi (Saniye)
MobileNetV2	86,75	34,24
ResNet101V2	86,62	42,61
ResNet50V2	84,5	35,52
MobileNet	84,12	32,4
Xception	82,25	38,45
ResNet152V2	80	47,82
DenseNet169	79,75	45,75
DenseNet201	78,87	49,5
DenseNet121	74,5	194,2

Çizelge 3.6'nın devamı

InceptionResNetV2	70,88	50,47
NASNetMobile	69,25	50,34
InceptionV3	66,25	37,97
VGG16	60,62	41,69
VGG19	51,5	33,39
ResNet50	26,5	36,27
ResNet152	26,5	48,05
ResNet101	25,12	43,2
MobileNetV3Large	23,62	37,36
MobileNetV3Small	23,5	34,35
EfficientNetB1	17,62	43,3
EfficientNetB3	13,25	46,31
EfficientNetB5	12,88	49,61
EfficientNetB6	12,5	48,81
EfficientNetB2	12,5	43,16
EfficientNetB0	12,5	38,82
EfficientNetB4	12,5	49,78
EfficientNetB7	12,5	49,76


Çizelge 3.6 incelendiğinde 40X büyütme oranı için en yüksek başarı oranının %86,75 ve bunun da yaklaşık 34 saniyede gerçekleştiği görülmektedir. Burada gerçekleştirilen işlem kanser türleri (Adenosis (A), Fibroadenoma (F), Filloid Tümör (PT), Tübüler Adenoma (TA), Duktal Karsinom (DC), Lobüler Karsinom (LC), Müsinöz Karsinom (MC) ve Papiller Karsinom (PC)) ayrımıdır.

Şekil 3.17’de 40X büyütme oranının tümör çeşitlerine göre doğrulukları grafik olarak gösterilmiştir. Şekil 3.18’de model sonucu oluşturulan karışıklık matrisi yer almaktadır. Şekil 3.19’da 40X büyütme oranının tümör çeşitlerine göre gerçek ve tahmin sonuçlarından bir kesit ve Şekil 3.20’de de 40X büyütme oranının tümör çeşitlerine göre eğitim zaman grafiği gösterilmiştir.



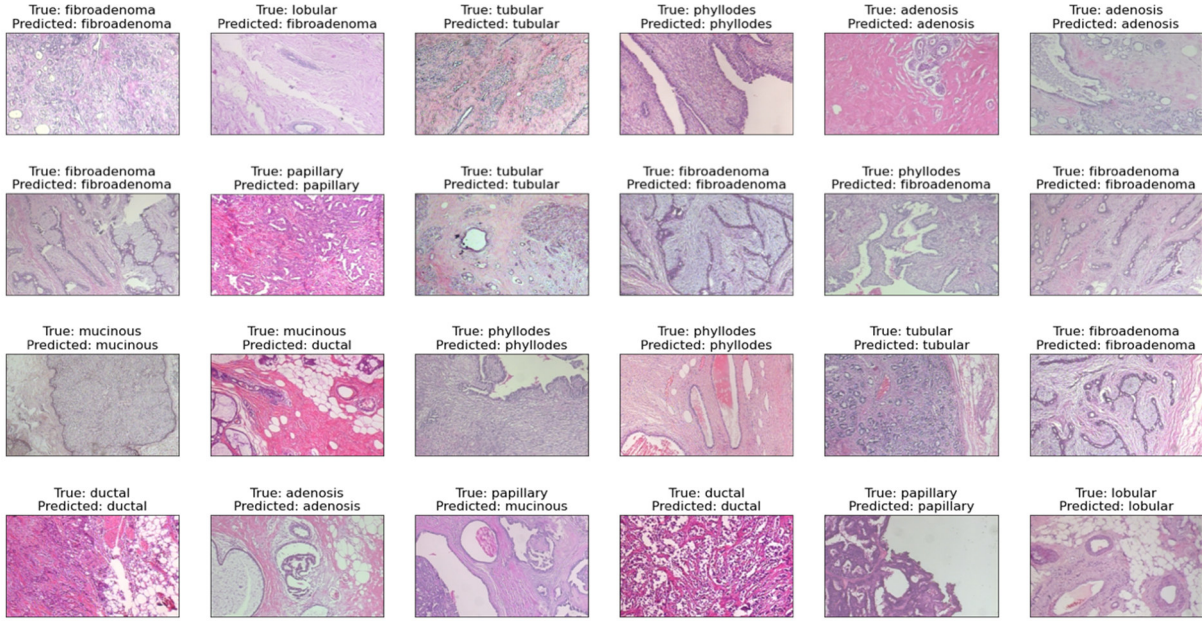
Şekil 3.17 40X Büyütme Oranının Tümör Çeşitlerine Göre Doğruluk Grafiği

Şekil 3.17’de 40X büyütme oranı için en yüksek doğruluğun **MobileNetV2** modeliyle elde edildiği grafiksel olarak da görülmektedir.




Şekil 3.18 40X Büyütme Oranının Tümör Çeşitlerine Göre Karışıklık Matrisi

Şekil 3.18 40X büyütme oranı için tümör çeşitleri ayrımının ne kadar doğru yapıldığına dair net bulgular ortaya koyan karışıklık matrisini göstermektedir. Şekil incelendiğinde en yüksek doğruluğun iyi huylu bir tümör çeşidi olan Fibroadenoma (F)'ya, en düşük doğruluğun ise kötü huylu bir tümör çeşidi olan Müsinöz Karsinom (MC)'a ait olduğu görülmektedir. Diğer yandan; en yüksek yanlış tahmin, gerçekte Fibroadenoma (F) olan 14 görüntünün, Tübüler Adenoma (TA) olarak sınıflandırılması sonucu oluşmuştur.



Şekil 3.19 40X Büyütme Oranının Tümör Çeşitlerine Göre Gerçek ve Tahminlerinden Kesit

Şekil 3.19 40X büyütme oranı için tümör çeşitlerine göre gerçekleştirilmiş olan sınıflandırma işlemi neticesinde hatalı ve doğru yapılan tahminlere örnekler göstermektedir. Görseller incelendiğinde hatalı tespit edilen görüntünün diğer sınıfa ait benzer yönleri olan görüntüler olduğu düşünülmektedir.



Şekil 3.20 40X Büyütme Oranının Tümör Çeşitlerine Göre Eğitim Süresi Grafiği

Şekil 3.20’de 40X büyütme oranında çoklu sınıflandırma için en kısa eğitim süresinin **MobileNet** modeliyle elde edildiği grafiksel olarak da görülmektedir.

Çizelge 3.7 100X Büyütme Oranının Tümör Çeşitlerine Göre Sınıflandırılması

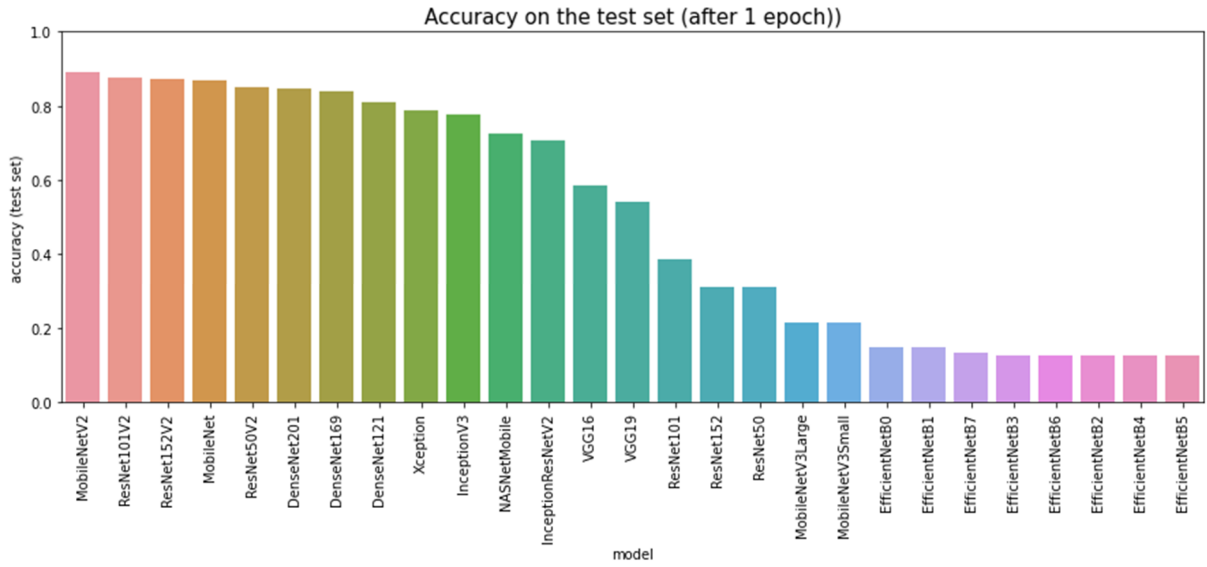
Model	Test Doğruluğu (%)	Eğitim Süresi (Saniye)
MobileNetV2	88,88	33,78
ResNet101V2	87,62	41,38
ResNet152V2	87,12	47,15
MobileNet	87	32,6
ResNet50V2	84,88	35,18
DenseNet201	84,62	49,99
DenseNet169	83,88	45,22
DenseNet121	81	188,43
Xception	78,87	37,39
InceptionV3	77,5	38,3
NASNetMobile	72,62	49,81
InceptionResNetV2	70,5	49,94

Çizelge 3.7'nin devamı

VGG16	58,38	41,96
VGG19	54,25	32,98
ResNet101	38,5	42,32
ResNet152	31	47,45
ResNet50	30,75	35,47
MobileNetV3Large	21,38	37,43
MobileNetV3Small	21,38	34,04
EfficientNetB0	14,88	39,37
EfficientNetB1	14,75	43,79
EfficientNetB7	13,12	55,69
EfficientNetB3	12,5	46,89
EfficientNetB6	12,5	48,77
EfficientNetB2	12,5	43,68
EfficientNetB4	12,5	54,76
EfficientNetB5	12,5	49,73


Çizelge 3.7 incelendiğinde 100X büyütme oranı için en yüksek başarı oranının %88,88 ve bunun da yaklaşık 34 saniyede gerçekleştiği görülmektedir. Burada gerçekleştirilen işlem kanser türleri (Adenosis (A), Fibroadenoma (F), Filloïd Tümör (PT), Tübüler Adenoma (TA), Duktal Karsinom (DC), Lobüler Karsinom (LC), Müsinöz Karsinom (MC) ve Papiller Karsinom (PC)) ayrımıdır.

Şekil 3.21'de 100X büyütme oranının tümör çeşitlerine göre doğrulukları grafik olarak gösterilmiştir. Şekil 3.22'de model sonucu oluşturulan karışıklık matrisi yer almaktadır. Şekil 3.23'te 100X büyütme oranının tümör çeşitlerine göre gerçek ve tahmin sonuçlarından bir kesit ve Şekil 3.24'te de 100X büyütme oranının tümör çeşitlerine göre eğitim zaman grafiği gösterilmiştir.



Şekil 3.21 100X Büyütme Oranının Tümör Çeşitlerine Göre Doğruluk Grafiği

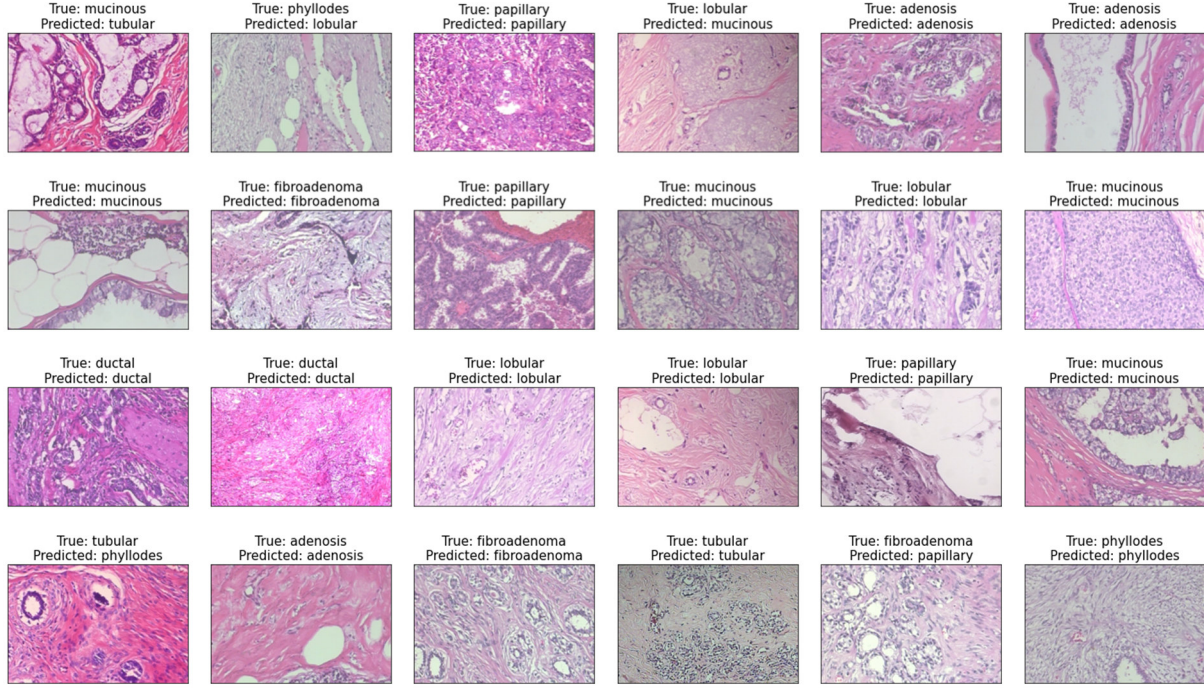
Şekil 3.21’de 100X büyütme oranı için en yüksek doğruluğun **MobileNetV2** modeliyle elde edildiği grafiksel olarak da görülmektedir.



Şekil 3.22 100X Büyütme Oranının Tümör Çeşitlerine Göre Karışıklık Matrisi


Şekil 3.22 100X büyütme oranı için tümör çeşitleri ayrımının ne kadar doğru yapıldığına dair net bulgular ortaya koyan karışıklık matrisini göstermektedir. Şekil incelendiğinde en yüksek doğruluğun kötü huylu bir tümör çeşidi olan Duktal Karsinom (DC)’a, en düşük

doğruluğun ise iyi huylu bir tümör çeşidi olan Adenosis (A) ve kötü huylu bir tümör çeşidi olan Müsinöz Karsinom (MC)'a ait olduğu görülmektedir. Diğer yandan; en yüksek yanlış tahmin, gerçekte Lobüler Karsinom (LC) olan 7 görüntünün, Adenosis (A) olarak sınıflandırılması sonucu oluşmuştur.



Şekil 3.23 100X Büyütme Oranının Tümör Çeşitlerine Göre Gerçek ve Tahminlerinden Kesit

Şekil 3.23 100X büyütme oranı için tümör çeşitlerine göre gerçekleştirilmiş olan sınıflandırma işlemi neticesinde hatalı ve doğru yapılan tahminlere örnekler göstermektedir. Görseller incelendiğinde hatalı tespit edilen görüntünün diğer sınıfa ait benzer yönleri olan görüntüler olduğu düşünülmektedir.



Şekil 3.24 100X Büyütme Oranının Tümör Çeşitlerine Göre Eğitim Süresi Grafiği

Şekil 3.24'te 100X büyütme oranında çoklu sınıflandırma için en kısa eğitim süresinin **MobileNet** modeliyle elde edildiği grafiksel olarak da görülmektedir.

Çizelge 3.8 200X Büyütme Oranının Tümör Çeşitlerine Göre Sınıflandırılması


Model	Test Doğruluğu (%)	Eğitim Süresi (Saniye)
MobileNet	83,12	26,67
DenseNet169	82,62	35,61
ResNet101V2	81,88	33,21
ResNet50V2	80,88	28,97
MobileNetV2	80,75	28,37
ResNet152V2	77,5	36,6
DenseNet201	77,12	37,69
Xception	75	29,7
DenseNet121	72,38	214,57
InceptionV3	63,25	30,69
NASNetMobile	59	39,61
InceptionResNetV2	54,88	38,98

Çizelge 3.8'in devamı

VGG16	50	33,11
VGG19	45,25	28,21
ResNet152	27,75	37,06
ResNet50	27,38	29,26
ResNet101	25,75	33,83
MobileNetV3Small	20,75	28,19
EfficientNetB3	17,13	36,17
EfficientNetB0	16,38	31,1
MobileNetV3Large	15,88	30,39
EfficientNetB1	13	34,25
EfficientNetB6	12,5	37,55
EfficientNetB2	12,5	33,93
EfficientNetB4	12,5	38,03
EfficientNetB7	12,5	38,66
EfficientNetB5	12,5	38,42


Çizelge 3.8 incelendiğinde 200X büyütme oranı için en yüksek başarı oranının %83,12 ve bunun da yaklaşık 27 saniyede gerçekleştiği görülmektedir. Burada gerçekleştirilen işlem kanser türleri (Adenosis (A), Fibroadenoma (F), Filloïd Tümör (PT), Tübüler Adenoma (TA), Duktal Karsinom (DC), Lobüler Karsinom (LC), Müsinöz Karsinom (MC) ve Papiller Karsinom (PC)) ayrımıdır.

Şekil 3.25'te 200X büyütme oranının tümör çeşitlerine göre doğrulukları grafik olarak gösterilmiştir. Şekil 3.26'da model sonucu oluşturulan karışıklık matrisi yer almaktadır. Şekil 3.27'de 200X büyütme oranının tümör çeşitlerine göre gerçek ve tahmin sonuçlarından bir kesit ve Şekil 3.28'de de 200X büyütme oranının tümör çeşitlerine göre eğitim zaman grafiği gösterilmiştir.



Şekil 3.25 200X Büyütme Oranının Tümör Çeşitlerine Göre Doğruluk Grafiği

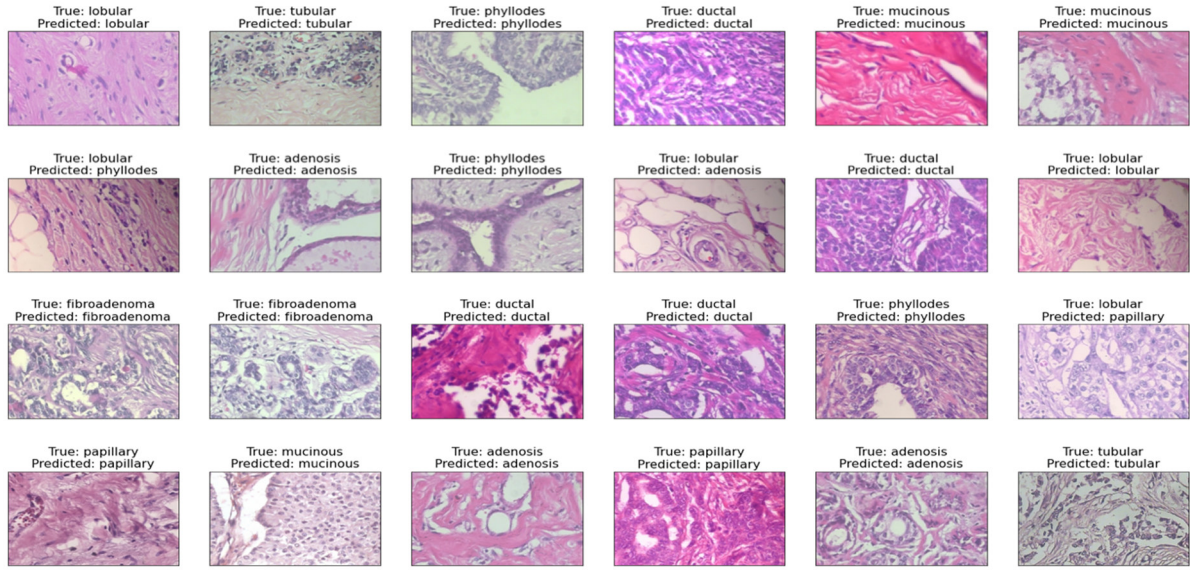
Şekil 3.25'te 200X büyütme oranı için en yüksek doğruluğun **MobileNet** modeliyle elde edildiği grafiksel olarak da görülmektedir.



Şekil 3.26 200X Büyütme Oranının Tümör Çeşitlerine Göre Karışıklık Matrisi


Şekil 3.26 200X büyütme oranı için tümör çeşitleri ayırımının ne kadar doğru yapıldığına dair net bulgular ortaya koyan karışıklık matrisini göstermektedir. Şekil incelendiğinde en yüksek doğruluğun iyi huylu tümör çeşitleri olan Fibroadenoma (F) ve Tübüler Adenoma (TA)'ya, en düşük doğruluğun ise kötü huylu bir tümör çeşidi olan Papiller Karsinom (PC)'a

ait olduğu görülmektedir. Diğer yandan; en yüksek yanlış tahmin, gerçekte Fibroadenoma (F) olan 11 görüntünün, Adenosis (A) olarak sınıflandırılması sonucu oluşmuştur.



Şekil 3.27 200X Büyütme Oranının Tümör Çeşitlerine Göre Gerçek ve Tahminlerinden Kesit

Şekil 3.27 200X büyütme oranı için tümör çeşitlerine göre gerçekleştirilmiş olan sınıflandırma işlemi neticesinde hatalı ve doğru yapılan tahminlere örnekler göstermektedir. Görseller incelendiğinde hatalı tespit edilen görüntünün diğer sınıfa ait benzer yönleri olan görüntüler olduğu düşünülmektedir.



Şekil 3.28 200X Büyütme Oranının Tümör Çeşitlerine Göre Eğitim Süresi Grafiği

Şekil 3.28’de 200X büyütme oranında çoklu sınıflandırma için en kısa eğitim süresinin **MobileNet** modeliyle elde edildiği grafiksel olarak da görülmektedir.

Çizelge 3.9 400X Büyütme Oranının Tümör Çeşitlerine Göre Sınıflandırılması


Model	Test Doğruluğu (%)	Eğitim Süresi (Saniye)
ResNet101V2	79,12	34,33
MobileNetV2	77,75	28,05
ResNet152V2	77,75	36,41
DenseNet169	75,62	35,5
MobileNet	74,25	26,42
ResNet50V2	73,12	28,74
DenseNet201	71,5	37,8
InceptionV3	70,88	30,6
Xception	70,62	29,39
DenseNet121	68,12	35,73
InceptionResNetV2	64,12	38,54
NASNetMobile	57	39,22
VGG19	45,75	26,72
VGG16	39,5	32,4
ResNet101	27,12	33,26
ResNet50	26,88	28,86
ResNet152	24,12	36,81
MobileNetV3Large	20,13	29,05
MobileNetV3Small	14,5	44,14
EfficientNetB4	13,38	37,96
EfficientNetB3	12,5	36,42
EfficientNetB6	12,5	37,62

Çizelge 3.9'un devamı

EfficientNetB2	12,5	33,74
EfficientNetB1	12,5	34,07
EfficientNetB0	12,5	31,1
EfficientNetB7	12,5	38,81
EfficientNetB5	12,5	38,41


Çizelge 3.9 incelendiğinde 400X büyütme oranı için en yüksek başarı oranının %79,12 ve bunun da yaklaşık 34 saniyede gerçekleştiği görülmektedir. Burada gerçekleştirilen işlem kanser türleri (Adenosis (A), Fibroadenoma (F), Filloid Tümör (PT), Tübüler Adenoma (TA), Duktal Karsinom (DC), Lobüler Karsinom (LC), Müsinöz Karsinom (MC) ve Papiller Karsinom (PC)) ayırımıdır.

Şekil 3.29'da 400X büyütme oranının tümör çeşitlerine göre doğrulukları grafik olarak gösterilmiştir. Şekil 3.30'da model sonucu oluşturulan karışıklık matrisi yer almaktadır. Şekil 3.31'de 400X büyütme oranının tümör çeşitlerine göre gerçek ve tahmin sonuçlarından bir kesit ve Şekil 3.32'de de 400X büyütme oranının tümör çeşitlerine göre eğitim zaman grafiği gösterilmiştir.



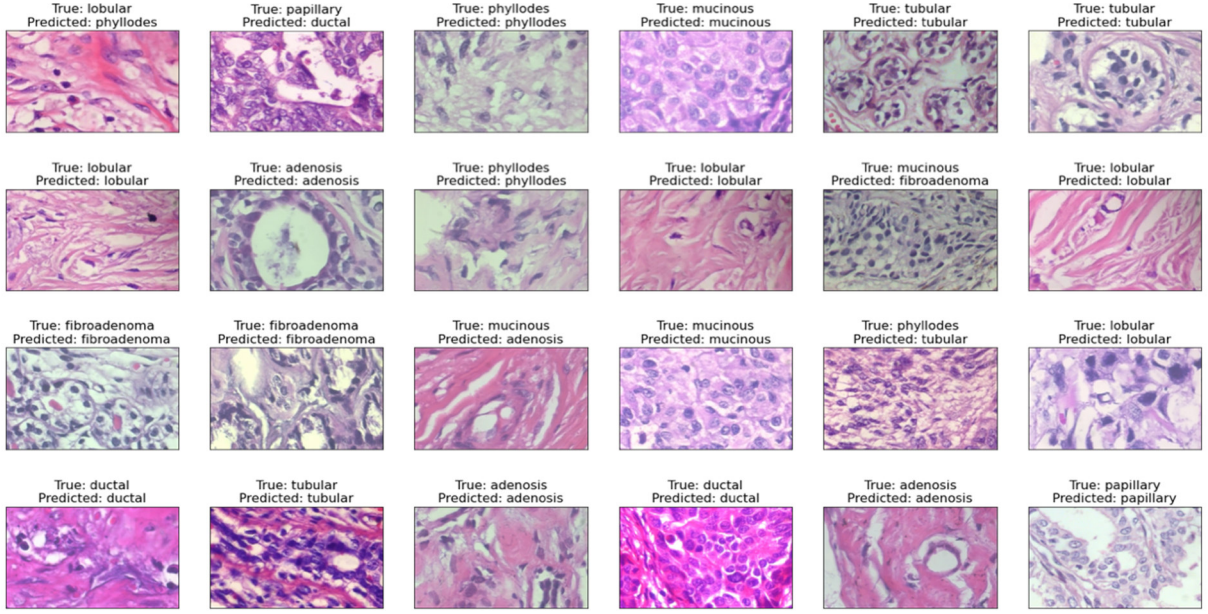
Şekil 3.29 400X Büyütme Oranının Tümör Çeşitlerine Göre Doğruluk Grafiği

Şekil 3.25'te 400X büyütme oranı için en yüksek doğruluğun ResNet101V2 modeliyle elde edildiği grafiksel olarak da görülmektedir.



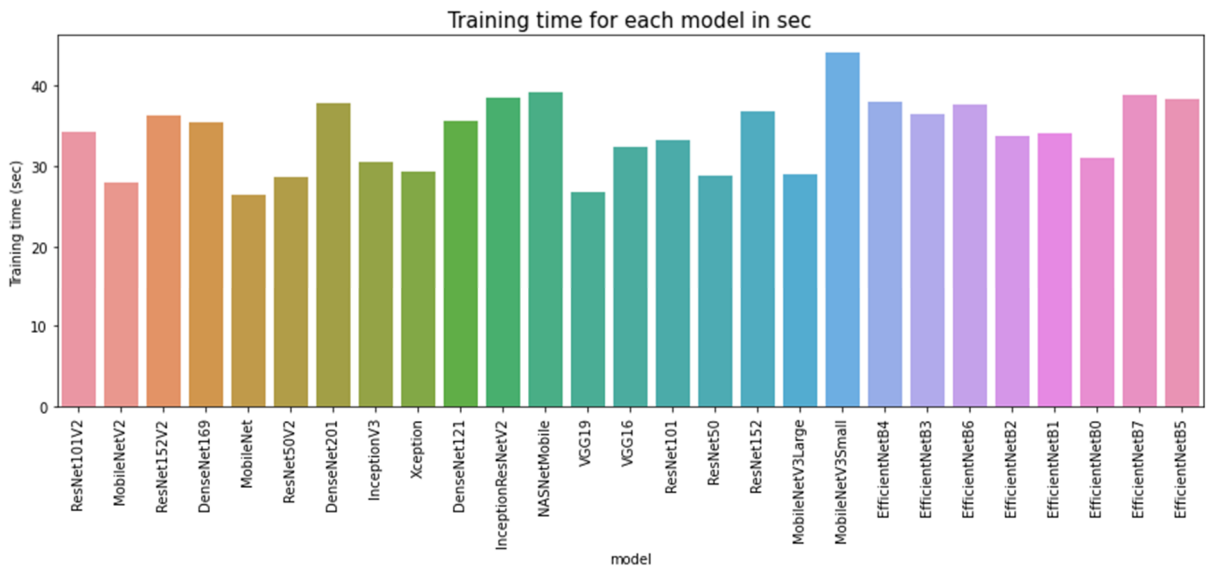
Şekil 3.30 400X Büyütme Oranının Tümör Çeşitlerine Göre Karışıklık Matrisi

Şekil 3.30 400X büyütme oranı için tümör çeşitleri ayrımının ne kadar doğru yapıldığına dair net bulgular ortaya koyan karışıklık matrisini göstermektedir. Şekil incelendiğinde en yüksek doğruluğun kötü huylu bir tümör çeşidi olan Duktal Karsinom (DC)'a, en düşük doğruluğun ise kötü huylu bir tümör çeşidi olan Papiller Karsinom (PC)'a ait olduğu görülmektedir. Diğer yandan; en yüksek yanlış tahmin, gerçekte Filloid Tümör (PT) olan 16 görüntünün, Papiller Karsinom (PC) olarak sınıflandırılması sonucu oluşmuştur.



Şekil 3.31 400X Büyütme Oranının Tümör Çeşitlerine Göre Gerçek ve Tahminlerinden Kesit

Şekil 3.31 400X büyütme oranı için tümör çeşitlerine göre gerçekleştirilmiş olan sınıflandırma işlemi neticesinde hatalı ve doğru yapılan tahminlere örnekler göstermektedir. Görseller incelendiğinde hatalı tespit edilen görüntünün diğer sınıfa ait benzer yönleri olan görüntüler olduğu düşünülmektedir.



Şekil 3.32 400X Büyütme Oranının Tümör Çeşitlerine Göre Eğitim Süresi Grafiği

Şekil 3.32’de 400X büyütme oranında çoklu sınıflandırma için en kısa eğitim süresinin **MobileNet** modeliyle elde edildiği grafiksel olarak da görülmektedir.

Çizelge 3.10 Çoklu Sınıflandırma İçin Metrik Sonuçları

Büyütme Oranı	Tümör Çeşidi	Kesinlik (%)	Duyarlılık (%)	F1-Skoru (%)
40X	Adenosis	81	91	85
	Ductal Carcinoma	86	93	89
	Fibroadenoma	73	95	83
	Lobular Carcinoma	95	91	93
	Mucinous Carcinoma	88	67	76
	Papillary Carcinoma	93	91	92
	Phyllodes Tumor	96	86	91
	Tubular Adenoma	90	80	85
100X	Adenosis	92	84	88
	Ductal Carcinoma	96	97	97
	Fibroadenoma	87	90	88
	Lobular Carcinoma	79	92	85
	Mucinous Carcinoma	88	84	86
	Papillary Carcinoma	90	88	89
	Phyllodes Tumor	91	90	90
	Tubular Adenoma	90	86	88
200X	Adenosis	82	79	81
	Ductal Carcinoma	98	87	92
	Fibroadenoma	63	88	74
	Lobular Carcinoma	92	80	86
	Mucinous Carcinoma	89	83	86

Çizelge 3.10'un devamı

	Papillary Carcinoma	94	78	85
	Phyllodes Tumor	73	82	77
	Tubular Adenoma	87	88	88
	Adenosis	90	84	87
	Ductal Carcinoma	76	96	85
	Fibroadenoma	67	89	76
	Lobular Carcinoma	87	89	88
400X	Mucinous Carcinoma	88	60	71
	Papillary Carcinoma	96	54	69
	Phyllodes Tumor	66	83	74
	Tubular Adenoma	80	78	79

Çizelge 3.10'da çok sınıflandırma üzerinde elde edilen metrik sonuçları yer almaktadır.

Bu sonuçlara göre en yüksek kesinlik değeri; %98 ile 200X büyütme oranında Ductal Carcinoma tümör çeşidi için, en yüksek duyarlılık değeri; %97 ile 100X büyütme oranında Ductal Carcinoma tümör çeşidi için ve en yüksek F1-Skoru değeri de %97 ile 100X büyütme oranında Ductal Carcinoma tümör çeşidi için elde edilmiştir.

4. DENEYSEL ÇALIŞMALAR

Yapılan çalışmalar neticesinde büyütme oranlarının, tümör türlerine ve çeşitlerine göre en başarılı olduğu modellerdeki doğruluk oranları Çizelge 4.1 ve Çizelge 4.2’de özetlenmiştir. Çizelge 4.1 incelendiğinde iyi huylu ve kötü huylu ayrımı için en yüksek başarı oranının 100X büyütme oranı için elde edildiği görülmektedir. Bu büyütme oranını %96’lık başarı oranı ile 400X büyütme oranı izlemiştir. En yüksek başarıya sahip model ise DenseNet201 olmuştur. İkili sınıflandırma için başarı oranının oldukça yüksek olduğu da Çizelge 4.1’den görülmektedir.

Çizelge 4.1 Tümör Özelliklerine Göre Sınıflandırma Sonuçları

	Model	Doğruluk (%)
40X	ResNet50V2	%95,88
100X	DenseNet201	%96,38
200X	ResNet152V2	%95,5
400X	ResNet152V2	%96

Çalışmamızda gerçekleştirdiğimiz bir diğer sınıflandırma işlemi tümör çeşitlerine göre sınıflandırmadır. Toplamda 8 farklı tümör çeşidinin yer aldığı bu işlemde en yüksek başarı oranı 100X büyütme oranında %88,88 olarak elde edilmiştir. İkili sınıflandırma işlemi ile karşılaştırıldığında Çizelge 4.1 ve 4.2 incelendiğinde ikili sınıflandırmanın daha yüksek bir başarı oranına sahip olduğu görülmektedir. Bu durum sınıf sayısı arttıkça sınıfların birbirinden ayrılması da daha zorlaşmaktadır şeklinde yorumlanabilir. Hem ikili sınıflandırma da hem de 8 sınıflı sınıflandırma da 100X büyütme ile en yüksek başarı oranının elde edilmiş olması dikkat çekici ve önemlidir. Çizelge 4.1’den de görüldüğü gibi ikili sınıflandırma da en yüksek başarı DenseNet201 modeli ile elde edilirken, Çizelge 4.2’de 8 sınıflı sınıflandırma da en yüksek başarının MobileNetV2 modeli ile elde edildiği görülmektedir.

Çizelge 4.2 Tümör Çeşitlerine Göre Sınıflandırma Sonuçları

	Model	Doğruluk (%)
40X	MobileNetV2	%86,75
100X	MobileNetV2	%88,88
200X	MobileNet	%83,12
400X	ResNet101V2	%79,12

İkili sınıflandırma ve çoklu sınıflandırma sonuçları ayrı ayrı değerlendirildiğinde hem büyütme oranının hem de yöntemlerin başarıyı etkileyen faktörler olduğu görülmektedir. Çizelge 4.1 ve 4.2 incelendiğinde histopatolojik görüntülerin sınıflandırılmasında büyütme oranının doğru seçilmesi gerektiği net bir şekilde görülmektedir.

Literatürde Spanhol ve ark. [6] BreakHis veri setini kullanarak yaptığı çalışma, farklı özellik tanımlayıcıları ve farklı geleneksel makine öğrenimi sınıflandırıcıları aracılığıyla ikili sınıflandırma tanıma oranları için bir temel sağlamıştır ve doğruluk aralığı %80 ile %85 arasındadır. Bu çalışmada ise derin öğrenme yöntemlerinden CNN kullanılarak DenseNet201 modeli ile %96,38 oranında doğruluk elde edilmiştir. Bu karşılaştırma Çizelge 4.3'te görülmektedir.

Çizelge 4.3 İkili Sınıflandırmanın Literatürdeki Çalışma ile Karşılaştırılması

Çalışma	Yöntem	Doğruluk Başarısı
Spanhol ve ark. [6]	1-NN, QDA, SVM, RF	%80-%85.
Bu Çalışma	CNN (DenseNet201)	%96,38.

Literatürde BreakHis veri setinde çoklu sınıflandırma için CNN kullanılarak elde edilen doğruluk oranları ile bu çalışmanın doğruluk oranları Çizelge 4.4'te karşılaştırılmıştır. Bu çalışmada diğer çalışmalardan farklı olarak MobileNetV2 modeli ile %88,88 oranında doğruluk elde edilmiştir.

Çizelge 4.4 Çoklu Sınıflandırmanın Literatürdeki Çalışmalar ile Karşılaştırılması

Çalışma	Yöntem	Doğruluk Başarısı
Bayramoğlu ve ark. [8]	CNN	Tek görevli ESA: %82,13. Çok görevli ESA: %83,25.
Han ve ark. [12]	Derin Öğrenme (CSDCNN)	%93,2.
Motlagh ve ark. [13]	CNN (ResNet152V1)	%98,7.
Bardou ve ark. [14]	CNN	%98,33.
Bu Çalışma	CNN (MobileNetV2)	%88,88.

5. SONUÇ VE ÖNERİLER

Kanser hastalığı erken tanı ve tedavinin hayat kurtardığı hastalıklardandır. Bu nedenle bu hastalığın erken tanı ve tedavisine destek sağlayabilecek tüm çalışmalar önemlidir. Gerçekleştirilen bu çalışmada da erken tanı ve tedaviye destek sağlayabilecek nitelikte bir çalışma ortaya konulmuştur. Uzman patologların uzun saatler neticesinde gerçekleştirdiği tümör sınıflandırması işlemi otomatik bir şekilde gerçekleştirilmektedir. Bu tez çalışmasının temel hedefi bilgisayar temelli yöntemlerin en popüler olanı yani derin öğrenme mimarisini kullanarak histopatolojik görüntülerde tümörlerin sınıflandırılmasıdır. Sınıflandırma işlemi hem iyi huylu kötü huylu şeklinde yapılmakta hem de tümörlerin çeşitleri kendi içerisinde ayrıca sınıflandırılmaktadır.

Gelecekteki çalışmalarda farklı mimarilerde farklı hiperparametreler ile başarılar daha üst seviyeye çıkarılabilir. Bunun yanı sıra kötü huylu tümörlere ait görüntüler üzerinde yer alan hastalıklı bölgelerin bölütlenmesi gibi konularda da gelişmeler sağlanabileceği düşünülmektedir. U-net gibi derin öğrenme ağlarının bölütlemedeki başarıları düşünüldüğünde çalışılan görüntüler üzerinde de bölütleme anlamında iyi sonuçlar üretilebileceği düşünülmektedir.

KAYNAKLAR

- [1] B. Chitradevi, P.Srimathi, “An Overview on Image Processing Techniques”, *International Journal of Innovative Research in Computer and Communication Engineering*, Cilt 2, Konu 11, Kasım 2014.
- [2] LeCun, Y., Bengio, Y., Hinton. G. “Deep learning” *Nature*, 521, pp.436-444, May, 2015.
- [3] Cruz-Roa, A., Basavanhally, A., González, F., Gilmore, H., Feldman, M., Ganesan, S., Shih, N., Tomaszewski, J., Madabhushi, A. “Automatic detection of invasive ductal carcinoma in whole slide images with convolutional neural networks” *In Medical Imaging 2014: Digital Pathology* (Vol. 9041, p. 904103). International Society for Optics and Photonics.
- [4] Ertosun, M. G., Rubin, D. L. “Probabilistic visual search for masses within mammography images using deep learning” *IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, pp.1310-1315, 2015.
- [5] Dubrovina, A., Kisilev, P., Ginsburg, B., Hashoul, S., Kimmel, R. “Computational mammography using deep neural networks” *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 6(3), pp.243-247, 2015.
- [6] Spanhol, F. A., Oliveira, L. S., Petitjean, C., Heutte, L. “A Dataset for Breast Cancer Histopathological Image Classification”, *IEEE Transactions on Biomedical Engineering*, Vol. 63(7), pp. 1455-1462, 2016.
- [7] Wang, J., Yang, X., Cai, H., Tan, W., Jin, C., Li, L. “Discrimination of breast cancer with microcalcifications on mammography by deep learning” *Scientific reports*, 6, 27327, 2016.
- [8] Bayramoglu, N., Kannala, J., Heikkilä, J. “Deep learning for magnification independent breast cancer histopathology image classification” *In Pattern Recognition (ICPR), IEEE, 23rd International Conference on*, pp. 2440-2445, 2016.
- [9] Selvathi, D., Poornila A. A. “Breast Cancer Detection In Mammogram Images Using Deep Learning Technique” *Middle East Journal of Scientific Research* 25 (2), pp. 417-426, 2017.
- [10] Wang, L. “Early Diagnosis of Breast Cancer”, *Sensors*, vol.17-1572, pp.1-20, 2017.
- [11] Araújo, T., Aresta, G., Castro, E., Rouco, J., Aguiar, P., Eloy, C., Polónia, A., Campilho, A. “Classification of breast cancer histology images using Convolutional Neural Networks” *PloS one* 12(6), e0177544, 2017.
- [12] Han, Z., Wei, B., Zheng, Y., Yin, Y., Li, K., Li, S. “Breast cancer multi- classification from histopathological images with structured deep learning model” *Scientific reports*, 7(1), 4172, 2017.
- [13] Motlagh, N. H., Jannesary, M., Aboulkheyr, H., Khosravi, P., Elemento, O., Totonchi, M., & Hajirasouliha, I. “Breast Cancer Histopathological Image Classification: A Deep Learning Approach” *bioRxiv*, 242818, 2018.
- [14] Bardou, D., Zhang, K., Ahmad, S. M. “Classification of breast cancer based on histology images using convolutional neural networks” *IEEE Access*, vol. 6, pp. 24680-24693, 2018.

- [15] Rakhlin, A., Shvets, A., Iglovikov, V., Kalinin, A.A. "Deep Convolutional Neural Networks for Breast Cancer Histology Image Analysis" *arXiv preprint arXiv: 1802.00752*, 2018.
- [16] Liu, K., Kang, G., Zhang, N., Hou, B., "Breast Cancer Classification Based on Fully-Connected Layer First Convolutional Neural Networks" *IEEE Access*, 6, pp.23722-23732, 2018.
- [17] Nazeri, K., Aminpour, A., Ebrahimi, M. "Two-Stage Convolutional Neural Network for Breast Cancer Histology Image Classification" *arXiv preprint arXiv: 1803.04054*, 2018.
- [18] Reiazi, R., Paydar, R., Ardakani, A. A., Etedadialiabadi, M. "Mammography Lesion Detection Using Faster R-Cnn Detector" *Computer Science & Information Technology*, 111, 2018.
- [19] Xi, P., Shu, C., Goubran, R. "Abnormality Detection in Mammography using Deep Convolutional Neural Networks" *arXiv preprint arXiv:1803.01906*, 2018.
- [20] Sadoughi F., Kazemy Z., Hamedan F., Owji L., Rahmanikatiğari M. & Azadboni T. T., "Artificial intelligence methods for the diagnosis of breast cancer by image processing: A review", *In Breast Cancer: Targets and Therapy*, 2018.
- [21] Ekici S. & Jawzal H., "Breast cancer diagnosis using thermography and convolutional neural networks", *Medical Hypotheses*, 137, 2020.
- [22] Toğaçar M., Ergen B. & Cömert Z., "Application of breast cancer diagnosis based on a combination of convolutional neural networks, ridge regression and linear discriminant analysis using invasive breast cancer images processed with autoencoders". *Medical Hypotheses*, 135, 2020.
- [23] Prajoth SenthilKumar, A. L., et al. "Breast cancer Analysis and Detection in Histopathological Images using CNN Approach" *Proceedings of International Conference on Intelligent Computing, Information and Control Systems*, pp. 335-343, *Springer*, Singapore, 2021.
- [24] Sharma, Shallu, Rajesh Mehra, and Sumit Kumar. "Optimised CNN in conjunction with efficient pooling strategy for the multi-classification of breast cancer" *IET Image Processing* 15.4, pp. 936-946, 2021.
- [25] Agarwal Pinky, Anju Yadav, and Pratistha Mathur. "Breast Cancer Prediction on BreakHis Dataset Using Deep CNN and Transfer Learning Model" *Data Engineering for Smart Systems*. Springer, Singapore, pp. 77-88, 2022.
- [26] Mayouf, Mona Sabrine, and Florence Dupin de Saint Cyr-Bannay. "Curriculum Incremental Deep Learning on BreakHis DataSet" *8th International Conference on Computer Technology Applications (ICCTA)*, 2022.
- [27] American Cancer Society "Breast Biopsy". [Çevrimiçi]. Erişim adresi: <https://www.cancer.org/cancer/breast-cancer/screening-tests-and-early-detection/breast-biopsy.html>. [Erişim tarihi 1 May 2022].

- [28] James, T.A., Mace, J.L., Virnig, B.A., Geller, B.M. "Preoperative needle biopsy improves the quality of breast cancer surgery" *Journal of the American College of Surgeons*, 215(4), pp.562-568, 2012.
- [29] Prajwala TM, Pranathi A., Ashritha K. S., Chittaragi N. B., Koolagudi S. G., "Eleventh International Conference on Contemporary Computing (IC3) - Noida, India, 2018.
- [30] Bejnordi, B.E., Veta, M., et al. "Diagnostic assessment of deep learning algorithms for detection of lymph node metastases in women with breast cancer." *Jama* 318(22), pp.2199-2210, 2017.

