T.C.
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

FARKLI DERİN ÖĞRENME MODELLERİ KULLANARAK HİSTOPATALOJİK GÖRÜNTÜLERDEN MEME TÜMÖRLERİNİN SINIFLANDIRILMASINDA YENİ YAKLAŞIMLAR

Sema Nizam ABDULGHANI

DOKTORA TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Ocak-2021
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

..... tarafından hazırlanan "……." adlı tez çalışması …/…/… tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü ……..... Anabilim Dalı'nda YÜKSEK LİSANS/DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri	**İmza**
Başkan Unvanı Adı SOYADI	……..
Danışman Unvanı Adı SOYADI	……..
Üye Unvanı Adı SOYADI	……..
Üye Unvanı Adı SOYADI	……..
Üye Unvanı Adı SOYADI	……..

Yukarıdaki sonucu onaylarım.

Prof. Dr. ……. ……..
FBE Müdürü

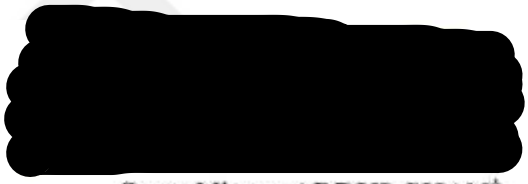
Bu tez çalışması ……. tarafından ……. nolu proje ile desteklenmiştir.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.



Sema Nizam ABDULGHANİ

Tarih: 03 / 03 /2021

ÖZET

DOKTORA TEZİ

FARKLI DERİN ÖĞRENME MODELLERİ KULLANARAK HİSTOPATOLOJİK GÖRÜNTÜLERDEN MEME TÜMÖRLERİNİN SINIFLANDIRILMASINDA YENİ YAKLAŞIMLAR

Sema Nizam ABDULGHANİ

Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Seyfettin Sinan GÜLTEKİN

2021, 106 Sayfa

Jüri
Doç. Dr. Seyfettin Sinan GÜLTEKİN
Prof. Dr. Gülay TEZEL
Doç. Dr. Murat CEYLAN
Dr. Öğr. Üyesi Onur İNAN
Dr. Öğr. Üyesi Muhammet Üsame ÖZİÇ

Günümüzde meme kanseri, kadın ölümlerinin en önemli sebeplerinden biridir. Bununla birlikte erken teşhise yönelik histopatolojik analiz, meme kanseri tanısına yönelik kullanılan en yaygın yöntemlerden biridir. Patologlar tarafından yapılan bu yöntemle, örneklerin mikroskop altında görsel olarak incelenmesi ile gerçekştirilmektedir. Bu yöntemin kabulü ne kadar yaygın olsada, zaman alıcı olması ve doğru karar vermede bazı olumsuzlukların yaşanmasıda gözden kaçırılmaması gereken bir hususdur. Bilgisayar destekli tanı sistemlerinin gelişmesi ise histopatolojik analize alternatif olmamış, aksine destekleyici bir unsur olmuştur. Böylelikle araştırmacılar, özellikle sınıflandırma sorunları gibi problemlerin çözümünde büyük başarı elde etmişler ve Evrişimsel Sinir Ağlarını (CNN) içeren derin öğrenme tekniklerine odaklanmışlardır. CNN, özellikle biyomedikal görüntü işleme problemlerinde büyük başarılar elde etmiş, derin ve ileri beslemeli bir ağ türüdür.

Bu çalışmada ise, CNN tekniklerinin avantajları düşünülerek, meme kanseri erken teşhis problemi üzerinde durulmuş ve açık kaynak (BreakHis) bir veri seti kullanılarak, histopatolojik görüntülerin sınıflandırması için üç farklı model önerilmiştir. Kullanılan veri seti, dört farklı büyütme faktörüne sahip iyi huylu ve kötü huylu görüntüleri içeren verilerdir. Önerilen üç modeldeki amaç ise, kötü huylu tümörlerin tehlikeli olması ve erken tedavi gerektirmesi esasından yola çıkarak, tümörün iyi huylu ve kötü huylu olduğuna karar vermeye yönelik ikili bir sınıflandırma sistemi tasarlamaktır. Modellerden ilki, özellik çıkarımı için 2 boyutlu bir ayrık dalgacık dönüşümünün (2-D DWT) kullanımı üzerinedir. İkinci model, Aktarım Öğrenimi (Transfer Learning) ve önceden eğitilmiş CNN modelini uyarlayan derin özellik çıkarma yöntemlerinin kullanımıdır. Üçüncü model ise, beş CNN yapısından (AlexNet, GoogleNet, VGG-16, ResNet50 ve InceptionV3) oluşan maksimum seçim kuralının uygulamasıdır.

Dört farklı büyütme faktörüne sahip veri seti içinde büyütme faktörleri için (5-kat) çapraz doğrulama yöntemi kullanılarak denemeler yapılmıştır. Denemeler sonucunda ilk önerilen model olan CNN tabanlı DWT modeli ile hasta düzeylerinde %90 ile %94 arasında bir doğrulukta sonuçlar alınmıştır. İkinci önerilen SVM sınıflandırma ve yama stratejisine sahip önceden eğitilmiş AlexNet modeli ile hasta düzeylerinde %92 ile %96 arasında bir doğruluk elde edilmiştir. Beş CNN modelli maksimum seçim gerçekleştirilen üçüncü modelde ise, ikili sınıflandırma görevi için önceki modeller, hasta düzeylerinde %96.4 ile %97.7 arasında bir performans sağlanmıştır. Hasta düzeylerinde elde edilen bu sonuçlar, BreakHis veri kümesinin ortalama tanıma doğruluğunun, aynı veri kümesinde test edilen

diğer makine öğrenme modellerine karşı yaklaşık %1 ile %5 oranında iyileşme gösterdiği belirlenmiştir. Ayrıca, sonuçlar büyütme faktöründen bağımsız olarak, sınıflandırıcıların hatalarının çoğunun, kötü huylu tümör olarak sınıflandırılan iyi huylu tümörler (fibroadenom ve tubular adenom) nedeniyle ortaya çıktığı tespit edilmiştir.

Anahtar Kelimeler: AlexNet; Ayrık Dalgacık Dönüşümü; Destek Vector Makinası; GoogleNet; Evrişimli Sinir Ağları; InceptionV3; Meme kanseri; ResNet; VGG-16.

ABSTRACT

Ph.D THESIS

NEW APPROACHES IN CLASSIFICATION OF BREAST TUMORS FROM HISTOPATHOLOGICAL IMAGES USING DIFFERENT DEEP LEARNING MODELS

Sema Nizam ABDULGHANİ

THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF SELÇUK UNIVERSITY

THE DEGREE OF DOCTOR OF PHILOSOPHY IN ELECTRICAL ELECTRONICS ENGINEERING

Advisor: Assoc. Prof. Dr. Seyfettin Sinan GÜLTEKİN

2021, 111 Pages

Jury
Assoc. Prof. Dr. Seyfettin Sinan GÜLTEKİN
Prof. Dr. Gülay TEZEL
Assoc. Prof. Dr. Murat CEYLAN
Asst. Prof. Dr. Onur İNAN
Asst. Prof. Dr. Muhammet Üsame ÖZİÇ

Breast cancer is one of the leading causes of women death worldwide currently. The Histopathological analysis is the most widely used method for Breast Cancer diagnosis. Breast cancer diagnosis that is done by pathologists depends on the visual inspection of the samples under the microscope, which is a time-consuming and less accurate decision-making process. Developing a computer-aided diagnosis system for breast cancer detection became an interesting problem for many researchers in recent years. Researchers focused on deep learning techniques for classification problems, including Convolutional Neural Networks (CNNs), which achieved great success. CNN is a particular type of deep, feedforward network that has gained attention from the research community and achieved great successes, especially in biomedical image processing.

This research proposes three different models for CNN to classify breast cancer histopathological images from the publically available (BreakHis dataset). The data set includes both benign and malignant images with four different magnification factors.The goal is to design a binary classification system to decide whether the tumor is benign or malignant, as malignant tumors is dangerous and need early treatment. The first proposed model uses a 2-dimensional discrete wavelet transform (2-D DWT) for feature extraction. The approximation Sub-band from the DWT feed to the CNN instead of the raw images itself. A patch strategy method proposed based on the extraction of image patches for training the CNN and the combination of these patches for final classification.The main observation is that the use of DWT features can generally achieve better results than the use of raw images itself. A further investigation was implemented using the step scheduler with increasing mini-batch size for updating Stochastic Gradient Descent (SGD) network parameters at the early stages of the training phase.

In the second model, transfer learning and deep feature extraction methods are used which adapt a pre-trained CNN model to classify breast cancer histopathological images. AlexNet model is considered with patch strategy, and pre-trained AlexNet is used for further fine-tuning. The obtained features are then classified by using support vector machines (SVM). In the third model, a max fusion model of five CNN

structures, namely AlexNet, GoogleNet, VGG-16, ResNet50, and InceptionV3, were performed. The features were extracted from the last fully connected layer of the pre-trained models. Then, the feature vectors were used with SVM classifier to boost the efficiency of the proposed models. Finally, the five models were fused using maximum selection rule to improve the accuracy of the model.

Experiments were performed using five-fold cross-validation technique for different magnification factors. The results show that the first proposed CNN based DWT model achieves the accuracy between 90% and 94% at patient levels. In addition, the second proposed pre-trained AlexNet with SVM classification and patch strategy yields accuracy between 92% and 96% at patient levels. The third proposed model (Max Fusion of five CNN) has beaten the previous ones for the binary classification task with a performance of between 96.4% and 97.7% at patient levels. In general, the experimental results presented in the patient levels shows approximately 1% to 5% improvement of average recognition accuracy on the BreakHis dataset against the other machine learning models tested on the same dataset. Besides, the results show that independently of the magnification factor, most of the errors of the classifiers are due to benign tumors (fibroadenoma) and (tubular adenoma) classified as a malignant tumor.

Keywords: AlexNet; Breast Cancer; Convolutional Neural Network; Discrete Wavelet Transform; GoogleNet; InceptionV3; ResNet; Support Vector Machin; VGG-16.

ÖNSÖZ

Tez çalışması boyunca bana devamlı yol gösteren, öncülük eden, danışmanım ve değerli hocam Doç. Dr. Seyfettin Sinan GÜLTEKİN'e, TİK üyesi Prof. Dr. Gülay TEZEL ve Doç. Dr. Murat CEYLAN'a, değerli arkadaşım Doç. Dr. Ahmed Freidoon Fadhil'e ve manevi yardımlarını hiçbir zaman esirgemeyen annem, babam ve kızkardeşlerime, ayrıca bu süreçte yanımdan hiç ayrılmayarak destek olan diğer arkadaşlarıma sonsuz sevgi ve saygı dileklerimle birlikte teşekkürlerimi sunarım.

Sema Nizam ABDULGHANİ
Konya - 2021

İÇİNDEKİLER

TEZ BİLDİRİMİ……..... **iii**

ÖZET……... **iv**

ABSTRACT…… **vi**

ÖNSÖZ…….…….…... **viii**

İÇİNDEKİLER……..……..... **ix**

SİMGELER VE KISALTMALAR…….…….. **xi**

1. GİRİŞ…….…….. **1**

1.1. Histopatolojiye yönelik CAD…….……... 3
1.2. Evrişimsel Sinir Ağı (CNN)…….. ……..……. 4
1.3. Amaç ve Hedef…….…. 6
1.4. Tez Özeti…….……..… 7

2. KAYNAK ARAŞTIRMASI…….…. 8

3. MATERYAL VE YÖNTEM……..... **12**

3.1. BreakHis Veri Kümesi…….. 12
3.2. Veri Arttırma……. 14
3.3. Ayrık Dalgacık Dönüşümü (DWT)……..… 15
3.4. CNN Mimarileri…… 17
3.4.1. AlexNet……...… 19
3.4.2. VGG-Net…….…….…….. 20
3.4.3. GoogleNet……..… 22
3.4.4. ResNet…….…….. 29
3.4.5. InceptionV3…….…….. 37
3.5. Eğitim Stratejiler…….…… 46
3.6. Aktarım Öğrenimi……..……..… 47
3.7. Çapraz Doğrulama Yöntemi …….. 49
3.8. Destek Vektör Makinesi (SVM) …….……..… 51

4. ÖNERİLEN MODELLER…….…….. **54**

4.1. Model 1: DWT Tabanlı CNN Modeli…….……. 54
4.1.1. Ön işleme bölümü…….……. 55
4.1.2. DWT bölümü…….....…… 55

4.1.3. CNN bölümü…….. 56
4.2. Model 2: SVM sınıflandırıcı Modeli ile önceden eğitilmiş AlexNet…. 58
4.2.1. Ön işleme bölümü…..…….….. 58
4.2.2. Önceden eğitilmiş AlexNet bölümü…….…….. 59
4.2.3. Aktarım öğrenim bölümü……..….. 59
4.2.4. SVM bölümü…… 60
4.3. Model 3: Önceden eğitilmiş CNN'lerin SVM sınıflandırıcı Modeli ile ……...birleştirilmesi…… 60
4.3.1. Ön işleme bölümü.…….…….…… 61
4.3.2. Veri arttırma bölümü……..…….…… 61
4.3.3. Önceden eğitilmiş CNN bölümü……..…….…….. 62
4.3.4. Aktarım öğrenim bölümü……..…….. 62
4.3.5. SVM bölümü.…….…… 62
4.3.6. Maksimum seçim kuralı bölümü.…….. 63

5. DENEYSELSONUÇLAR VE TARTIŞMA…… 65

5.1. Performans ölçüsü……..... 65
5.2. Model 1 için Deneysel Sonuçlar……..…….... 66
5.2.1 SGD yönteminin parametrelerinin araştırılması……..…… 68
5.2.2. Hatanın derinlemesine incelenmesi……..... 78
5.3. Model 2 için Deneysel Sonuçlar…….…….……. 82
5.3.1. Alexnet ve VGG16 mimarilerinin incelenmesi…….…. 82
5.3.2. Stokastik gradyan iniş parametrelerinin incelenmesi……. 83
5.3.3. Hatanın derinlemesine incelenmesi…….…….…….. 86
5.4. Model 3 için Deneysel Sonuçlar…….……. 89
5.5. Önceki Çalışmalarla Karşılaştırma……..……. 94
6. SONUÇ VE GELECEK ÇALIŞMALAR……..……... 98
6.1. Sonuç…….. 98
6.2. Gelecek Çalışmalar……..…… 99

7. KAYNAKLAR…….…….. **100**

ÖZGEÇMİŞ……..……. **106**

SİMGELER VE KISALTMALAR

Simgeler

g : Yüksek Geçiren Süzgeç

h : Düşük Geçiren Süzgeç

i : Yineleme Numarası

α : Öğrenme Hızı

θ : Parametre Vektörü

E : Kayıp Fonksiyonudur

W : Ağırlık Vektörü

Λ : Düzenlileştirme Faktörü

Ω : Düzenlileştirme Fonksiyonu

C : Ceza Parametresidir

K : Çekirdek İşlevi

N_{Toplam} : İlgili kanser görüntülerinin sayısıdır

N_{DS} : Doğru şekilde sınıflandırılmış kanser görüntülerinin sayısıdır

N_h : H Hasta ile ilgili kanser görüntülerinin sayısıdır

N_{pDS} : Doğru şekilde sınıflandırılmış kanser yama görüntülerinin sayısıdır

$N_{pToplam}$: Test kümesi ile ilgili kanser yama görüntülerinin sayısıdır

Kısaltmalar

A	: Adenosis
B	: İyi Huylu
CAD	: Bilgisayar Destekli Tespit
CNN	: Evrişimli Sinir Ağları
CNN-DW	: Evrişimsel Sinir Ağı-Ayrık Dalgacık
CNN-CT	: Evrişimsel Sinir Ağı-Eğrilik Dönüşüm
DCT	: Ayrık Eğrilik Dönüşümü
DCNN	: Derin Evrişimsel Sinir Ağı
DC	: Duktal Karsinom
DWT	: Ayrık Dalgacık Dönüşümü
De CAF	: Derin Evrişimli Etkinleştirme Özelliği
FC	: Tam Bağlı
F	: Fibroadenom
KNN	: K-En yakın komşu
LC	: Lobüler Karsinom
M	: Kötü Huylu
MC	: Müsinöz Karsinom
MCNN	**:** Ortalama Doğruluk oranları
MIL	: Çok Örnekli Öğrenmenin
NPA	: Parametrik Olmayan Algoritma
PC	: Papiller Karsinom
PT	: Filloid Tümör
ReLU	: Doğrultulmuş Doğrusal Birim
SVM	: Destek Vektör Makinası
SGD	: Stokastik Gradyan İniş
TA	: Tübüler Adenom
2-D	: İki Boyutlu

1. GİRİŞ

Günümüzde kanser, dünya çapında büyük bir halk sağlığı sorunudur. Uluslararası Kanser Araştırmaları Ajansı'na göre, kanserin neden olduğu ölümlerin 2030 yılına kadar 27 milyona ulaşması beklenmektedir (Boyle ve Levin, 2008). Diğer tüm kanser türleri arasında, meme kanseri ise kadınlar için en yaygın ikinci tür olarak kabul edilir. Ayrıca, meme kanserinden kaynaklı ölümlerin oranı diğer kanser türlerine kıyasla son derece yüksektir. Meme kanserinin tespiti ve teşhisi, tanısal mamogramlar (x-ışınları), manyetik rezonans görüntüleme, ultrason (Sonografi) ve termografi gibi görüntüleme prosedürleri ile sağlanabilir (Konsey, 2005). Kanser taramasına yönelik görüntüleme metotları, kırk yıldan fazla bir süredir araştırılmıştır. Bununla birlikte, biyopsi, kanser gerçekten mevcutsa güvenle teşhis etmenin tek yoludur. Biyopsi teknikleri arasında en yaygın olanları, ince iğne aspirasyonu, çekirdek iğne biyopsisi, vakum destekli ve açık cerrahi biyopsisidir (Spanhol ve ark., 2015). Prosedür, daha sonra yapılacak lekelenme ve mikroskobik incelemeye yönelik bir cam mikroskop slaydı boyunca sabitlenmiş hücre veya doku numunelerinin toplanmasından oluşur. Bu nedenle, histopatolojik görüntüden tanılama, meme kanseri dahil olmak üzere, hemen hemen tüm kanser türlerinin teşhisinde birincil standarttır. Derecelendirme ve evreleme de dahil olmak üzere son meme kanseri tanısı, histolojik numunelerin mikroskop altında görsel olarak incelenmesini uygulayan patologlar tarafından yapılır (Spanhol ve ark., 2015).

Histopatolojik analiz, diğer moleküler markörler arasında Meme Kanseri tanısı için en yaygın kullanılan yöntemdir. Patologlar, meme kanseri tanısını derecelendirmek ve evrelemek için numuneleri mikroskop altında görsel olarak incelerler (Lakhani ve ark., 2012). Patologlar tarafından yapılan histopatolojik analiz, doğruluk oranı patoloğun deneyimine bağlı olan, zaman alıcı bir görevdir. Bu nedenle, kanserli dokuyu (kötü huylu doku) (malign) kanserli olmayan dokudan (iyi huylu doku) (benign) ayırt etmek için Bilgisayar Destekli Tespit (CAD) sistemlerinin geliştirilmesi önemlidir (Veta ve ark., 2014). Böyle bir sistem, patologların tanıyı basitleştirmelerine, zamandan tasarruf etmelerine ve tanı verimliliğini artırmalarına yardımcı olmalıdır.

Son zamanlarda, makine öğrenimi ve dijital görüntü işleme alanlarındaki gelişme, araştırmacıların patologları tanıda daha üretken, nesnel ve tutarlı olmalarını sağlayan gelişmiş bir CAD sistemi oluşturmasına olanak tanımıştır (Araújo ve ark., 2017). Meme kanseri teşhisine yönelik otomatik bir görüntü işleme sisteminin

oluşturulması, histopatolojik görüntülerin doğal karmaşıklığı nedeniyle son yıllarda araştırmacılar için zor bir görev olarak kabul edilmiştir (Das ve ark., 2020). Meme kanserinin erken teşhisine ve komplikasyonların önlenmesine yönelik etkili bir CAD sistemi gereklidir (Dabeer ve ark., 2019).

Çoğu otomatik CAD sisteminde, hücre görüntüsünün veya hücre çekirdeğinin dokusunu, morfolojisini ve yapısal özelliklerini çıkarmak için geleneksel makine öğrenimine dayalı yöntemler kabul edilmiştir (Kowal ve ark., 2013). Daha sonra, görüntüler ve dokular üzerine kurulan özellikler, farklı patolojik görüntüleri sınıflandırmak ve otomatik bir sistem kurmak üzere elde edilip kullanılır. Bazı araştırmacılar, çekirdek özelliklerini çıkararak çekirdeği incelemişlerdir (Lee ve Street, 2003). Böylece iyi huylu ve kötü huylu hücrelerin sınıflandırılması için gerekli bilgileri sağlamışlardır (Zhang ve ark., 2014). Bilhassa, özellik çıkarmaya yönelik manuel yöntemler, eşikleme, kümeleme, aktif çevreleme, dönüm noktaları ve grafik kesimleri içermiştir. Geleneksel makine öğrenim algoritmalarına dayanarak, farklı çekirdek bölünmesi algoritmaları, destek vektör makineleri (SVM) ve rastgele ormanlar gibi algoritmalar özellik tanımlama için kullanılmıştır (Wang ve ark., 2016). Bu algoritmalar kullanılarak, ayırt edici özellikler, iyi huylu slaytları kötü huylu olandan ayırt etmek için çekirdekten çıkarılarak belirlenmiştir. Çekirdek sınıflandırmasında dalgacık dönüşümleri, tek hücreli bölgeleri keşfetmeye yönelik geliştirilmiş bir morfolojik özellik uygulamasıdır. Genellikle, kümeleme algoritmaları ve Hough dönüşümünü (Filipczuk ve ark., 2013; George ve ark., 2013) kullanan çekirdek bölünmesi ve sınıflaması benzer ilkeleri temsil eder. Aktif çevre teknolojisi, göğüs histopatolojik görüntülerinin arka planından hücreleri bölümlere ayırır. Bu yöntem, çekirdeğin morfolojik özelliklerini çıkarıp, bunları normal ve tümör hücreleri olan iki türe böler (Jan ve ark., 2016). Dönüm noktası bölünme teknolojisi ise, meme kanseri histopatolojik görüntülerinden çekirdek bilgilerini çıkarır.

Derin öğrenme modelleri, meme kanseri tespitinde sınıflandırma problemlerini çözmek için kullanılmıştır (Vo ve ark., 2019). Derin öğrenme, makine öğrenimine ait doğrusal olmayan bir temsil öğrenme yöntemidir. Bir tür derin öğrenme yöntemi olan evrişimsel sinir ağı (CNN), genel amaçlı bir özellik çıkarıcıdır. CNN, meme kanserinin histopatolojik görüntülerini bağımsız olarak büyüterek sınıflandırır, böylece daha yüksek bir tanıma oranı elde eder (Ching ve ark., 2018; Robertson ve ark., 2018). Buna ek olarak, CNN, kanserin yayılmasını daha doğru şekilde tespit edebilir (Bejnordi ve ark., 2017). Örneğin, AlexNet, meme kanserinin patolojik görüntülerini; iyi huylu ve

kötü huylu (Spanhol ve ark., 2016) olarak iki kategoriye ayırıp geleneksel makine öğrenim algoritmalarından daha yüksek doğruluk oranı elde etmiştir. Ayrıca, ResNet ve Inception, hücre tabanlı görüntü sınıflandırmasına yönelik hızlı ve doğru modellerdir (Khan ve ark., 2019). Yapay özelliklere sahip çeşitli makine öğrenme algoritmaları arasında, CNN ile ilgili en dikkat çeken özellik ise, özellik çıkarma yöntemlerini tasarlamaya gerek duymamasıdır (Li ve ark., 2019). Bununla birlikte, CNN tarafından üretilen özelliklerin sayısı önemli olabilir. Bu da aşırı uyum ve bilgi fazlalığına neden olabilir (Kowal ve ark., 2013). Sonuç olarak, sistemin doğruluğu, büyütme artışıyla gittikçe azalır.

1.1. Histopatolojiye Yönelik CAD

CAD sistemi, tıbbi görüntülerin otomatik veya yarı otomatik olarak değerlendirilmesine yönelik bilgisayarların kullanımı olarak tanımlanabilir. Meme görüntüleme alanında, doğru CAD yöntemlerinin kullanımı, mevcut meme tarama prosedürlerinin iyileştirilmesi için etkili olabilir. Meme görüntülerini okumak ve anlamak için iyi eğitimli ve deneyimli bir radyoloğa ihtiyaç duyulur ve CAD Sistemleri "ikinci görüş" olarak etkili bir şekilde kullanılıp radyologlara tarama programlarında yardımcı olabilir (Dinnes ve ark., 2001).

Klinik uygulamalarında kullanılabilecek histopatolojiye yönelik CAD sistemlerinin tasarlanması, tüm görüntü ve yama düzeylerinde çalışabilen sağlam ve yüksek verim algoritmalarının geliştirilmesini gerektirir. Histopatolojik görüntülerin analizi, çeşitli faktörlerin uygulanması ile karmaşık bir haldedir. Bu tür karmaşık yapıda öncelikle histolojik lekelerin renklerinde ve yoğunluklarında büyük değişkenliklerin olmasıdır. Bu tür farklılıklar, sayısal görüntü analizinin etkinliğini potansiyel olarak aksatabilir. Buna ek olarak, doku hazırlama ve sayısallaştırma işleminde, genellikle otomatik analiz zorluklarla karşılaşılmasıdır. Bu durum birçok yapay dokunun üretilmesine sebep olabilmektedir. Ayrıca, bir görüntünün içinde analiz edilmesi gereken büyük boyutlu bir görüntü ve çok sayıda farklı cinslerden oluşan yapı, histopatolojiye yönelik doğru ve güvenilir bir CAD geliştirilmesini zorlaştırabilir. Bu tez çalışmasınında amacı olan sözkonusu zorlukların giderilmesi için farklı yama düzeylerinde çalışabilen bilgisayar destekli veya bilgisayarlı teşhis araçlarının geliştirilmesine odaklanılmıştır. Bu nedenle sistemlerin uygulanabilir bir klinik ortamda kullanılması sağlanmıştır (Spanhol, 2018).

Çoğu CAD yönteminin merkezinde yer alan temel yöntem makine öğrenimidir. Makine öğrenimi algoritmalarının, karmaşık veri kümelerinden aralarındaki kalıpları ve ilişkileri belirleme ve tanımlama yeteneği, bilgisayarlı ve bilgisayar destekli teşhis sistemlerinin geliştirilmesi için oldukça popüler hale gelmiştir.

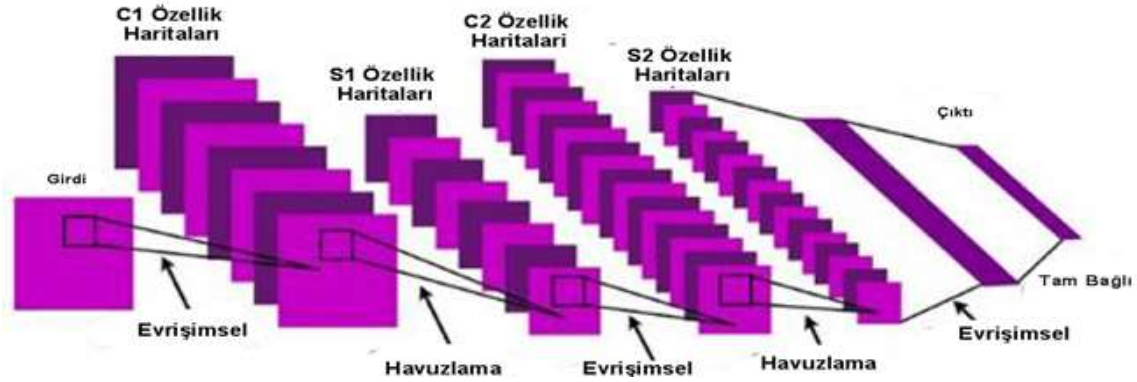
1.2. Evrişimsel Sinir Ağı (CNN)

Görsel içeriğe dayalı görüntü sınıflandırma, özellikle histopatolojik kesitlerden mikroskobik görüntüler, çok miktarda zengin geometrik yapılar ve karmaşık dokuları içeren birkaç sorun nedeniyle zorlu bir görevdir. Derin öğrenmenin temel amacı, daha yüksek seviyeli özelliklerin, verilerin daha soyut anlamını temsil etmesini amaçlayan çoklu temsil seviyelerini belirlemektir (LeCun ve ark., 2015). Bir derin öğrenme tekniği olan CNN'ler ile, tıbbi görüntü analizini içeren görüntü sınıflandırma problemlerinde oldukça başarılı sonuçlar alınmıştır (Ciresan ve ark., 2012; Cruz-Roa ve ark., 2013; Prasoon ve ark., 2013; Xing ve ark., 2015).

CNN, birbiri üzerine yerleştirilmiş denetimli bir sınıflandırıcıyı takip eden çok sayıda eğitilebilir aşamalardan ve her aşamanın hem girdi hem de çıktısını temsil eden ve özellik haritaları denilen dizi kümelerinden oluşur (LeCun ve ark., 2010). Giriş, görüntü, ses ve video gibi sinyallerden, çıkış ise, her bir özellik eşlemesinin ilişkili girdisinin konumlarından çıkarılan ve belirli bir özelliği temsil eden set dizilerinden oluşur.

Derin ağ, girdiyi besleyerek doğru cevapla karşılaştırmak üzere katman katman hesaplama yapar ve böylece nihai çıktıyı oluşturuncaya kadar eğitilir. Çıktıdaki hatayı hesapladıktan sonra, hata, geri yayılım yoluyla ağ üzerinden geriye doğru akar. Geriye doğru her adımda, model parametreleri hatayı azaltmaya çalışan bir yönde ayarlanır. Bu süreç, modelin ilerledikçe geliştirildiği ve verilerin tarandığı süreçtir. Genellikle eğitim, model bir noktada birleşene kadar, giriş verilerinin birden fazla geçişini içeren yinelemeli bir süreçtir.

CNN mimarileri oluşturmak için kullanılan üç ana katman türü vardır: evrişimli katman, havuzlama katmanı ve tam bağlı katman (FC). Normalde, bu katmanlardan birkaçının üst üste gelmesi ile tam bir CNN mimarisi elde edilir. İki özellik aşamasına sahip tipik CNN mimarisinin bir örneği, Şekil 1.1'de gösterilmiştir.



Şekil 1.1. İki özellik aşamasına sahip tipik bir CNN mimarisi. (LeCun ve ark., 2010)

Bir CNN'de, temel hesaplama, bir özellik detektörünün bir giriş sinyali ile evrişimidir. Evrişimli katman, her biri ağırlıkları ve giriş hacminde bağlı oldukları bölge arasında bir iç çarpımı hesaplayan girişteki yerel bölgelere bağlı nöronların çıktısını hesaplar. Girdi ile birleştirilmiş olan ağırlık kümesine filtre veya çekirdek denir. Her filtre uzamsal olarak küçüktür (genişlik ve yükseklik), ancak giriş hacminin tüm derinliği boyunca uzanır. Görüntüler gibi girişler için tipik filtreler küçük alanlar olup (örn.., 3 × 3, 5 × 5, veya 8 × 8) her nöron sadece önceki katmanda bu alana bağlanır. Ağırlıklar, filtreleri görüntünün herhangi bir yerinde meydana gelen sık kalıpları öğrenmeye yönlendiren nöronlar arasında paylaşılır. Filtre uygulamaları arasındaki mesafeye adım (stride) denir. Adım, hiper parametresinin filtre boyutundan daha küçük olup olmadığına bakılmaksızın, üst üste örtüşen pencerelerde evrişim uygulanır.

Bir filtre kolleksiyonuyla evrişim, temsili olarak geliştirilir: bir CNN'nin ilk katmanında, özellikler tek tek piksellerden yatay ve dikey çizgiler, daireler ve renk yamaları gibi basit ilkellere gider. Tek kanallı geleneksel görüntü işleme filtrelerinin aksine, bu CNN filtreleri tüm giriş kanallarında hesaplanır. Dönüşümle değişmeyen özelliğinden dolayı, evrişimli filtreler, bir özellik tespit edildiğinde yüksek bir yanıt verir. İki ardışık evrişimli katmanı arasında bir havuzlama (alt örnekleme) katmanının yerleştirilmesi yaygındır. Bu uygulamanın temel amacı, temsilin uzamsal boyutunu giderek azaltmaktır. Böylece, ağın ihtiyaç duyduğu parametrelerin hesaplama sayılarının azaltılması ve aşırı uyumun kontrol edilmesi sağlanmış olur.

Havuzlama katmanı, giriş hacminin her derinlik diliminde bağımsız ve uzamsal olarak örnekler. Böylece, havuzlama operatörü, etkinleştirmeleri göz ardı ederek girişi genişlik ve yükseklik boyunca yeniden boyutlandırır. Uygulamada, giriş yamasına bir pencere işlevi uygulayan ve o bölgedeki maksimum değeri hesaplayan maksimum

havuzlama işlevi daha iyi sonuçlar vermiştir (Scherer ve ark., 2010). Bununla birlikte, havuzlama birimleri ortalama havuzlama gibi diğer işlevleri gerçekleştirebilir. FC bir katmanda, nöronlar önceki katmandaki tüm etkinleştirmelerle tam bağlanıp, etkinleştirmeler, bir sapma dengelemesini takip eden bir matris çarpımı kullanılarak hesaplanabilir. Bu tür bir katman, normal bir sinir ağında standarttır. Son FC katman, sınıflar üzerindeki olasılık dağılımları gibi net çıktıyı tutar (Farabet ve ark., 2012; Krizhevsky ve ark., 2012).

1.3. Amaç ve Hedef

Günümüzde, meme kanseri için CNN kullanan histopatolojik görüntülerin otomatik olarak sınıflandırılması, CNN parametrelerindeki sistemin aşırı uyumuna neden olan ani bir artış nedeniyle hala karmaşık bir sorundur. Histopatolojik görüntülerin doğal karmaşıklığı, düzensiz renk dağılımı ve hücre örtüşmesini içeren zorlayıcı bir başka sorun olarak değerlendirilir (Gour ve ark., 2020). Bu çalışmada ile yapılan temel katkı, CNN'nin aşırı uyum sorunu ve histopatolojik görüntülerin karmaşıklığı da dahil olmak üzere mevcut zorlukların üstesinden gelmek için birçok modelin geliştirilmesidir. Patologların meme kanseri görüntülerini sınıflandırmasına yardımcı olmak için CNN dayanan değiştirilmiş üç CAD sistemi önerilmiştir. Asıl amaç, dokunun iyi huylu veya kötü huylu sınıflara ait olup olmadığına net olarak karar verebilmektir. Bunu sağlamak için önerilen modeller, her görüntü için bir kayan pencere stratejisi ile küçük yamaların çıkarılmasına dayanmaktadır. Tüm slayt görüntü yerine küçük yamaların kullanılması, araştırmacılar tarafından hem CNN yapılarının karmaşıklığını azaltmak, hemde eğitim süresini azaltmak için önerilmiş ve kullanılmıştır (Spanhol ve ark., 2016; Song ve ark., 2017; Spanhol ve ark., 2017; Gour ve ark., 2020)

İlk modelde, ayrık dalgacık dönüşümü (DWT) tabanlı CNN yöntemi geliştirilmiştir. Ayrıca, CNN parametrelerinin değiştirilmesinin etkisi, 5-kat çapraz doğrulama tekniği ile mini-batch boyutunu artıran adım planlayıcı kullanılarak sonuçlar değerlendirilmiştir. Görüntülerin boyutu, aşırı uyum sorununu önleyen DWT'den sadece bir alt bant kullanılarak azaltılmıştır. Ayrıca, DWT, düzensiz renk dağılımını azaltmak için çok uygun hale getiren uzamsal ve frekans alanlarındaki yerel özellikleri

ifade edebilir (Shen ve ark., 2015). Diğer yandan, DWT, farklı kalıplar arasında iyi bir ayrım sağladığı için hücre örtüşmesini azaltabilir (Medda ve ark., 2016).

İkinci modelde, AlexNet ağının önceden eğitilmiş sinir ağı yapısı, aktarım öğrenimi kullanılarak test edilmiştir. Daha sonra, önceden eğitilmiş AlexNet ağına dayalı sınıflandırma için özellik çıkarılmıştır. Bu çalışmada ele alınan özellikler, 4096 boyutlu özellik vektörleri üreten önceden eğitilmiş AlexNet modelinin (FC6) katmanından çıkarılmıştır. Daha sonra, önerilen modelin verimliliğini yükseltmeye yönelik, Destek Vektör Makinası (SVM) sınıflandırıcısı ile özellik vektörleri kullanılmıştır.

Üçüncü modelde, AlexNet, GooglNet, Resnet50, VGG-16 ve InceptionV3 olmak üzere beş CNN yapısından oluşan bir kombinasyon modeli tanıtılmıştır. İlk olarak, beş CNN yapısının önceden eğitilmiş sinir ağı yapısı, aktarım öğrenimi kullanılarak test edilmiştir. Özellikler, önceden eğitilmiş modellerin (FC6) katmanından çıkarılmış ve daha sonra önerilen modellerin verimliliğini artırmak için özellik vektörleri SVM sınıflandırıcısı ile birlikte kullanılmıştır. Son olarak, beş modelin sonuçları, modelin doğruluğunu artırmaya yönelik maksimum seçim kuralı kullanılarak birleştirilmiş ve sunulmuştur.

1.4. Tez Özeti

Tez, altı bölüme ayrılmıştır. Giriş bölümünde, meme kanseri kavramı, meme kanseri tanı sistemleri ve CNN kavramlarına değinilmiştir. Ayrıca, araştırmanın problem ifadesi tanıtılmış ve hedefler belirlenmiştir. 2. bölümde literatür taraması ile birlikte konu ile ilgili son çalışmalar verilmiştir. 3. bölümde BreakHis veri kümesi, CNN yapıları, DWT, Aktarım Öğrenimi, SVM ve Çapraz Doğrulama yönteminin ayrıntılı açıklamaları verilmiştir. 4. bölümde, histopatolojik meme kanseri tespitine yönelik CNN kullanımın üç geliştirilmiş modelini tanıtılmıştır. 5. bölümde, önerilen CNN modellerini değerlendirmek için yapılan deneyleri yer verilmişitr. Ayrıca bu algoritmaların performansları karşılaştırmalı olarak verilmiştir. 6. bölümde temel katkı ve bulgular özetlenmiş ve çalışmanın etkileri ayrıntılı olarak açıklanmıştır. Son olarak, çalışma ile ilgili nihai sonuçların gelecekteki araştırmalara ve çalışmalara yön verebilmesi amaçlı bir değerlendirme yapılmıştır.

2. KAYNAK ARAŞTIRMASI

Filipczuk ve arkadaşları iyi ve kötü huylu olmak üzere iki sınıfın histopatolojik görüntülerini incelemiş ve önemli sonuçlar elde etmişlerdir. Bu çalışmarında Dairesel Hough dönüşümü kullanarak Otsu'nun eşikleme yöntemi ve doku özellikleri, meme kanseri teşhis sistemi için tanımlamışlardır. Görüntülerin sınıflandırılmasında dört farklı sınıflandırıcı tarafından 25 özellik kümesi belirlemişlerdir. Tam tanı prosedürü için hastalardan elde edilen 737 mikroskobik görüntü üzerinde test edilmiş ve %98.51 etkililik değeri elde etmişlerdir (Filipczuk ve ark., 2013).

Benzer şekilde Dairesel Hough dönüşümü ve Otsu'nun eşik yöntemini sadece 12 özellikli sinir ağları ile kullanan George ve arkadaşları, dört sınıflandırma modeli (geri yayılımlı algoritması, olasılıksal sinir ağı, vektör nicemlemenin öğrenilmesi ve destek vektör makinesi) kullanarak çok katmanlı bir algılayıcı oluşturmuşlardır. Sadece 92 meme görüntüsünde on kat çapraz doğrulama kullanarak elde edilen sınıflandırma sonuçları, %76 ile %94 arasında değişmiştir (George ve ark., 2013).

Bununla birlikte, bu çalışmalar, küçük bir veri kümesine ve karmaşıklık ve çözülmemiş teknolojilerle ilgili birçok endişeyi içeren ve hala birçok dezavantajı olan Tüm Slayt Görüntülemeye odaklanmıştır (Evans ve ark., 2015).

Spanhol ve arkadaşları 82 hastadan elde edilen 7909 görüntüden oluşan kapsamlı bir histopatolojik meme veri kümesi (BreakHis) ile altı farklı dokusal tanımlayıcıyı ve farklı sınıflandırıcıyı değerlendirmişler ve görüntü büyütme faktörüne bağlı olarak %80 ile %85 arasında değişen doğruluklar elde etmişlerdir. Bunun için dört farklı sınıflandırıcı (En Yakın Komşu, Karesel Doğrusal Analiz, (SVM) ve Rastgele Karar Ormanları kullanmışlardır. Ancak, özellik dönüştürmeye bağlı olan bu yöntemlerin, histopatolojik görüntüleri temsil etmede zayıf yönleri bulunmaktadır. Halbuki CNN dahil olmak üzere, derin öğrenme teknikleri, üst düzey özelliklere sahip histopatolojik görüntüleri tanımlamak için yaygın olarak kullanılmıştır (Spanhol ve ark., 2015).

CNN, diğer yaklaşımların yanı sıra çeşitli tanıma problemlerinde en gelişmiş sonuçları elde etmek için kullanılmıştır. CNN ağı, konuşma tanıma, sinyal işleme, nesne tanıma, doğal dil işleme ve aktarım öğrenme gibi görevlerde deneysel başarılar elde ederek araştırma topluluğunun ve endüstrinin dikkatini çekmiştir. Krizhevsky ve arkadaşları, bu kapsamda bazılarını maksimum havuzlama katmanları ve son 1000 yollu

softmax ile FC üç katman tarafından takip edilen, beş evrişimli katmandan oluşan 60 milyon parametre ve 650.000 nöron içeren AlexNet CNN yapısını araştırmışlardır (Krizhevsky ve ark., 2012).

Mikroskobik görüntüler için CNN kullanımının, geleneksel dokusal tanımlayıcılarını kullanarak sunulan zorlukların üstesinden gelebileceği gösterilmiştir (Niu ve Suen, 2012; Hafemann ve ark., 2014).

Bu kapsamda yazarlar (Spanhol ve ark., 2016), CNN ağını eğitmek için görüntü yamalarını çıkarmaya ve son sınıflandırma için bu yamaları birleştirmeye dayanan bir yöntem önermişlerdir. Bu yöntem, BreakHis veri kümesinden gelen yüksek çözünürlüklü histopatolojik görüntülerin mevcut CNN ağında girdi olarak kullanılmasına ve modelin daha karmaşık ve hesaplama zorluklu bir mimariye yol açabilecek uyarlamalardan kaçınmaya yönelik olmuştur. CNN performansı, el yapımı dokusal tanımlayıcılarla eğitilmiş diğer makine öğrenme modellerinden elde edilen daha önce bildirilen sonuçlara kıyasla daha iyidir. Yazarlar ayrıca, basit füzyon kurallarını kullanan ve tanıma oranlarında bir miktar iyileşme sağlayan farklı CNN ağlarının kombinasyonunu araştırdılar. Daha sonraki çalışmalarında yazarlar (Spanhol ve ark., 2017) BreaKHis veri kümesini kullanarak meme kanserini tanımak için önceden eğitilmiş CNN ile Derin Evrişimli Etkinleştirme özelliği (DeCAF) gibi özellikler kullandılar. Sonuçlar, bu özelliklerin görsel özellik tanımlayıcılarını kullanan önceki sistemlerden daha iyi performans gösterdiğini ve meme kanseri görüntülerinde %84'lük bir doğruluk elde ettiğini gösterdiler.

Başka bir derin sınıflandırıcı, CNN tabanlı Fisher vektörlerini daha fark gözeten bir temsil öğrenmeye dönüştürerek temsil edilir (Song ve ark., 2017). Yazarlar, çok katmanlı bir sinir ağı modeline ve bir CNN ağına sahip yeni denetimli, içe gömülü bir algoritma geliştirdiler ve bu kodlama yöntemi özelliğini, iki genel veri kümesine uyguladılar. Ayrıca Jadoon ve arkadaşlarıda (Jadoon, M.M., et al) (DWT) ve ayrık eğrilik dönüşümünü (DCT) CNN ağı ile birlikte kullanıldılar. Böylece yazarlar, evrişimsel sinir ağı-ayrık dalgacık (CNN-DW) ve evrişimsel sinir ağı-eğrilik dönüşüm (CNN-CT) olmak üzere iki yöntem geliştirdiler ve mamografi yamaları kullanarak artırılmış bir veri kümesi meydana getirdiler. Bu arada CNN-DW yönteminde, CNN ağını beslemeden önce özellik çıkarımı için tüm DWT alt bantları kullanmışlardır. Sınıflandırma ve CNN ağını eğitmek için Softmax katmanı ve SVM katmanı kullanılmıştır. Sonuç olarak CNN-DW ve CNN-CT, sırasıyla, %81.83 ve %83.74 doğruluk oranına ulaşmışlardır.

Deniz ve arkadaşları önceden eğitilmiş CNN AlexNet ve VGG-16 modellerine uyum sağlayan aktarım öğrenimi ve derin özellik çıkarımı yöntemlerini değerlendirdiler (Deniz ve ark., 2018),. Bu çalışmada elde edilen özellikler, daha sonra destek vektör makineleri (SVM) tarafından sınıflandırılmıştır. Değerlendirme sonuçları, aktarım öğreniminin derin özellik çıkarımı ve SVM sınıflandırmasından daha iyi sonuç verdiğini göstermiştir ve görüntü düzeylerinde %90.5 ile %91.4 arasında bir doğruluk elde edilmiştir. Kassani ve arkadaşları önceden eğitilmiş beş Derin Evrişimsel Sinir Ağı (DCNN) mimari yapılarını, InceptionV3 dahil, Xception ve VGGNet modellerini de içeren özellik çıkarımı olarak kullanmışlardır (Kassani ve ark., 2019). Yazarlar böylece, meme kanserinin sınıflandırılması için bir DCNN tanımlayıcısı ve havuzlama işlemi kullanarak derin öğrenme tabanlı etkili bir yöntem önermişlerdir. Ayrıca, sınıflandırma performansını hızlandırmak için farklı veri arttırma teknikleri kullanılmış ve farklı boyama normalleştirme yöntemlerinin etkileri de araştırılmıştır. Deneysel sonuçlar, önceden eğitilmiş Xception modelini kullanan ve önerilen ağ mimarisinin, ortalama sınıflandırma doğruluğu açısından diğer tüm DCNN mimarilerinden %92.50'lik bir doğruluk oranıyla daha iyi performans ortaya koyduğunu göstermiştir.

Sudharshan ve arkadaşları, histopatolojik görüntülerin analizine dayanarak, gözetimli bir öğrenme sistemi önerdiler. Bu sistemle hastalarda bilgisayar destekli meme kanseri teşhisi için Çok Örnekli Öğrenmenin (MIL) ilişki düzeylerini araştırmış oldular. Yazarlar, K-En Yakın Komşu Algoritması (KNN), SVM, Parametrik Olmayan Algoritma (NPA) ve CNN gibi farklı MIL yöntemlerinin performansını incelediler. NPA MIL tekniği kullanarak %83.4 ile %92.1 arasında bir doğruluk elde etmiş oldular (Sudharshan ve ark., 2019).

Gour ve arkadaşları ResHist olarakta adlandırılan artık öğrenme tabanlı 152 katmanlı evrişimsel sinir ağını tanıttılar (Gour ve ark., 2020). Önerilen model, histopatolojik meme görüntülerinden zengin özellikler kazanmış ve boyama normalleştirme, görüntü yamaları üretimi ve afin dönüşümüne (veya ilgin dönüşümü, uzaylar arasında noktaları, düz çizgileri ve düzlemleri koruyan bir eşleme) dayanan veri arttırma tekniğini kullanmışlardır. Önerilen yaklaşımın performansı, kamuya açık BreaKHis veri kümesinde değerlendirilmiştir. Elde edilen sonuçlarla histopatolojik görüntülerin sınıflandırılması için %84.34 doğrulukta olduğunu göstermişlerdir. Ayrıca, veri artırımı ile doğruluk oranını %92.52'ye çıkarmışlardır. Deneysel sonuçlar, bu yaklaşımın histopatolojik görüntülerin

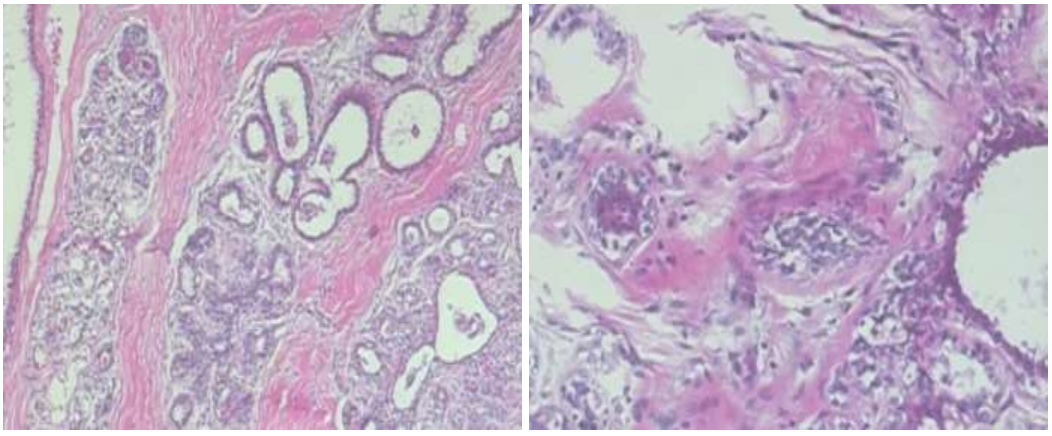
sınıflandırılması için önceden eğitilmiş ağlar, yani AlexNet, VGG-16, VGG-19, GoogleNet, InceptionV3, ResNet50 ve ResNet152 üzerindeki üstünlüğünü göstermiştir.

Wenzhong ve arkadaşları derin erişimsel sinir ağlarına dayanan meme kanserinin patolojik görüntülerinin sınıflandırılması için yeni bir Derin Meme Kanseri sınıflandırma yöntemi önermişlerdir (Wenzhong ve ark., 2020). Değerlendirme sonuçları, derin meme kanserinin, hastaların ve görüntülerin sınıflandırılmasında sırasıyla %92 ve %96.43 doğruluk oranlarına ulaştığını ve F1 skorunun %97.38 olduğunu ve bu sonuçlarında en gelişmiş yöntemlerden daha iyi olduğunu göstermiştir. Şu anda, meme kanseri için CNN kullanan histopatolojik görüntülerin otomatik olarak sınıflandırılması, CNN parametrelerindeki sistemin aşırı yüklenmesine neden olan ani bir artış nedeniyle hala karmaşık bir sorundur. Histopatolojik görüntülerin doğasında bulunan karmaşıklık bir başka zorlu problem olarak kabul edilir.

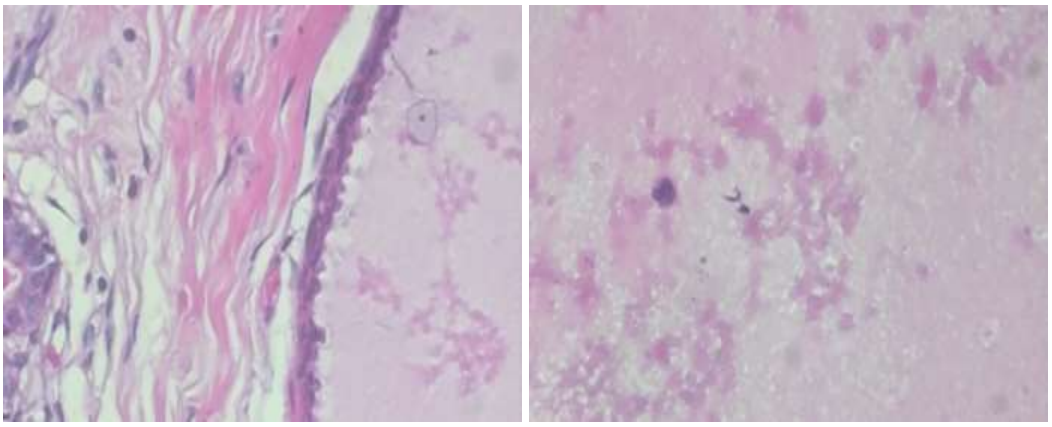
3. METERYAL VE YÖNTENLER

3.1. BreakHis Veri Kümesi

Histopatolojik meme kanseri görüntüleri için çeşitli veri kümeleri mevcuttur (Münir ve ark., 2019). BreakHis veri kümesi, dört farklı büyütme faktörüyle 82 hastadan alınan çok sayıda örnek görüntü nedeniyle bu çalışmada kullanılmıştır. BreakHis veri kümesi iyi huylu ve kötü huylu meme tümörlerinin mikroskobik biyopsi görüntülerini içerir (Spanhol ve ark., 2015). Görüntüler Ocak 2014'ten Aralık 2014'e kadar bir klinik çalışması yoluyla toplanmıştır. Bu süre boyunca, meme kanseri'nin klinik belirtisi olan Brezilya'daki P&D laboratuvarına sevk edilmek suretiyle tüm hastalar çalışmaya davet edilmiştir. Kurumsal inceleme kurulu çalışmayı onaylamış ve tüm hastalara yazılı bilgilendirmeler yapılmış ve veriler anonimleştirilmiştir. Görüntüler, 3 kanallı RGB (Kırmızı-Yeşil-Mavi) Gerçek Renk (24 bit renk derinliği, renk kanalı başına 8 bit) renk alanında 40 ×, 100 ×, 200 × ve 400 × büyütme faktörleri kullanılarak elde edilmiştir. Objektif lens 4 ×, 10 ×, 20 × ve 40 ×'dır. Farklı büyütme faktörlerine sahip bu verilerin iyi ve kötü huylu olarak BreakHis veri kümesinden bir örnek, sırasıyla Şekil 3.1 ve 3.2'de gösterilmiştir.

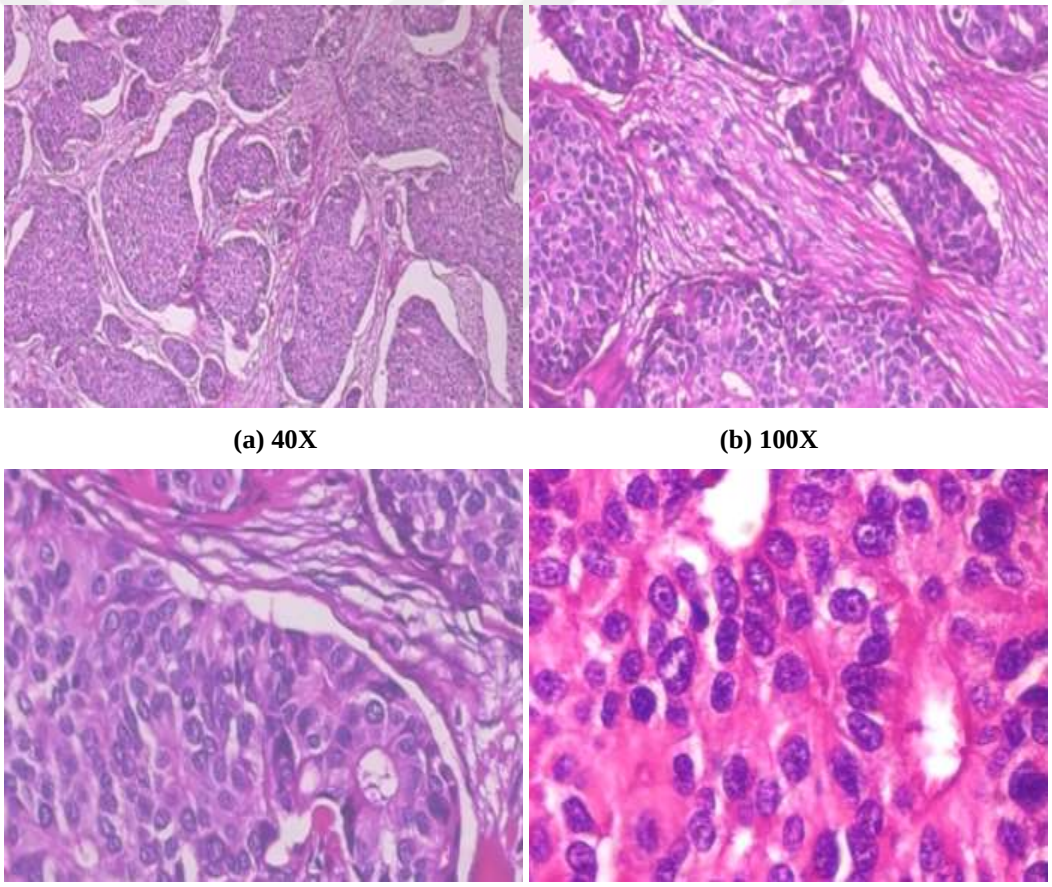


(a) 40X **(b) 100X**



(c) 200X **(d) 400X**

Şekil 3.1. Farklı büyütme faktörlerine sahip iyi huylu sınıftan örnek görüntüler



(a) 40X **(b) 100X**

(c) 200X **(d) 400X**

Şekil 3.2. Farklı büyütme faktörlerine sahip kötü huylu sınıftan örnek görüntüler

Veri Kümesi, iyi huylu ve kötü huylu tümörlere bölünmüş 7909 görüntüden oluşmaktadır. Çizelge 3.1, görüntü dağılımını özetlemektedir. İyi huylu ve kötü huylu her iki meme tümörü, mikroskop altındaki tümör hücrelerinin görünümüne göre farklı tiplere ayrılabilir. Veri kümesi, dört farklı iyi huylu meme tümörü tipini içermektedir: adenosis (A), fibroadenom (F), filloid tümör (PT) ve tübüler adenom (TA); ve dört kötü huylu tümör (göğüs kanseri): duktal karsinom (DC), lobüler karsinom (LC), müsinöz karsinom (MC) ve papiller karsinom (PC). Bu sınıflardaki iyi huylu ve kötü huylu tümörlerin dağılımı da Çizelge 3.1'de sunulmuştur (Spanhol ve ark., 2015).

Çizelge 3.1. BreakHis veri kümesinin büyütme faktörü ve sınıfına göre görüntü dağılımı

Sınıflar	**Alt Sınıflar**	**Büyütme Faktörleri**				**Görüntü Sayıları**	**Hasta Sayıları**
		40 ×	**100 ×**	**200 ×**	**400 ×**		
İyi huylu (B)	**A**	114	113	111	106	**444**	**4**
	F	253	260	264	237	**1014**	**10**
	PT	109	121	108	115	**453**	**3**
	TA	149	150	140	130	**569**	**7**
Kötü huylu (M)	**DC**	864	903	896	788	**3451**	**38**
	LC	156	170	163	137	**626**	**5**
	MC	205	222	196	169	**792**	**9**
	PC	145	142	135	138	**560**	**6**
Toplam		**1995**	**2081**	**2013**	**1820**	**7909**	**82**

3.2. Veri Arttırma

Veri artırma, aşırı uyumu azaltmak, modelin genellemesini ve performansı artırmak için iyi bir çözümdür. Modeller eğitim verilerinden ayrıntıları çok iyi öğrendiklerinde CNN'lerde aşırı uyum meydana gelir. Ancak, gelecekteki görünmeyen veriler hakkında iyi tahminler yapmak için eğitim verilerinden iyi bir şekilde genelleme yapması zor olacaktır. Sonuç olarak, eğitilen modelin performansı, verileri test etmek için zayıf kalacaktır. Bu genellikle, eğitim veri kümesinin boyutu ve öğrenilmesi gereken model parametrelerinin sayısıyla karşılaştırıldığında çok küçük olduğunda gerçekleşir (Abdelhafiz ve ark., 2019).

Veri artırma işleminde, gerçek verilere çevirme ve döndürme gibi dönüştürmelerin uygulanmasıyla yapay olarak yeni örnek görüntüler oluşur. Mamografi görüntüleri için yaygın veri büyütme teknikleri yatay olarak çevirme, döndürme (90, 180 ve 270 derece), titreme ve rastgele ölçeklendirmedir. Bu tür veri arttırma, ilgili eğitim örneklerini oluşturur çünkü tümörler çeşitli yönelim ve boyutlar sergileyebilir. Böylece, arttırma teknikleri kitlelerin altında yatan patolojiyi değiştirmez. Bu tür veri artırma işlemi bir çok çalışmada'da kullanılmıştır (Lévy ve Jain, 2016; Wichakam ve Vateekul, 2016; Jadoon ve ark., 2017; Yi ve ark., 2017; Xi ve ark., 2018; Abdelhafiz ve ark., 2019; Gour ve ark., 2020).

3.3. Ayrık Dalgacık Dönüşümü (DWT)

DWT, bir sinyalin zaman-frekans gösterimini sağlar. $x[k]$ Bir sinyal verildiğinde, DWT, g ile gösterilen düşük geçiren ve h ile gösterilen yüksek geçiren filtrelerden ayrı ayrı geçirerek hesaplanabilir. (Fadhil, 2014). Matematiksel ifadeleri denklem'de (3.1 ve 3.2) verilmektedir:

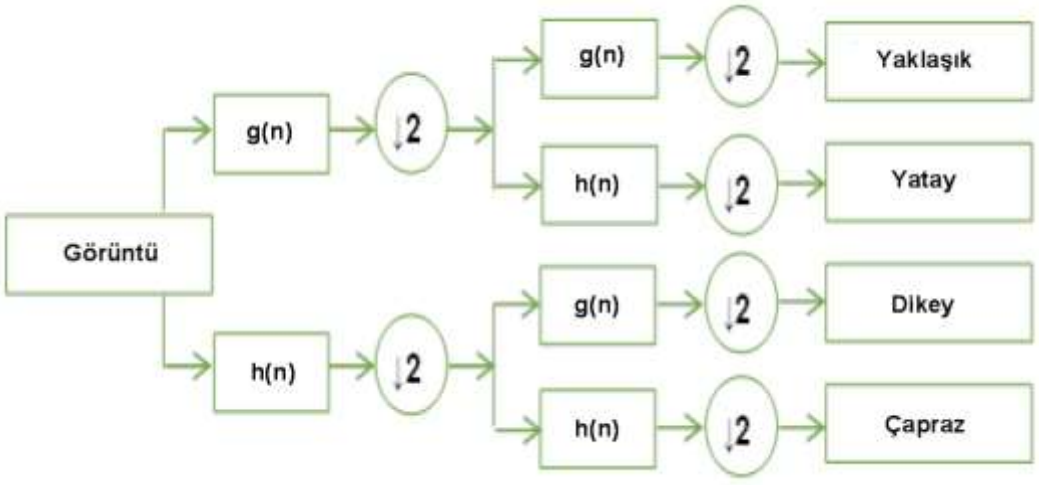
$$y_{low}[n] = (x * g)[n] = \sum_{k=-\infty}^{\infty} x[k].g[n-k] \quad (3.1)$$

$$y_{high}[n] = (x * h)[n] = \sum_{k=-\infty}^{\infty} x[k].h[n-k] \quad (3.2)$$

Elde edilen sonuç, ayrıntı katsayıları (yüksek geçiren filtreden) ve yaklaşık katsayılardır (düşük geçiren filtreden). İki filtrenin birbiriyle ilişkili olması ve dörtlü ayna filtresi olarak bilinmeleri önemlidir. Bununla birlikte, sinyalin frekanslarının yarısı artık kaldırıldığından, örneklerin yarısı Nyquist kuralına göre atılabilir.

Çoğu sinyal için düşük frekanslı içerik en önemli kısımdır. Sinyale kimliğini veren şey ise aslında budur. Öte yandan, yüksek frekanslı içerik, kulağa hoş gelsede, insan sesi düşünüldüğünde ve yüksek frekanslı bileşenler kaldırıldığında, ses farklı çıkar, ancak yine de ne söylendiği anlaşılabilir. Ancak, düşük frekans bileşenleri çıkarıdığında anlamsız sesler duyulur. Yani dalgacık analizinde, tüm konuşma yaklaşımları ayrıntılarla ilgilidir. Yaklaşımlar, sinyalin yüksek ölçekli ve düşük frekanslı bileşenlerindedir. Ayrıntılar ise, düşük ölçekli ve yüksek frekanslı bileşenlerdedir.

Görüntüler gibi 2 boyutlu (2-D) sinyaller için bu işlem, görüntü piksellerinin alçak geçiren ve yüksek geçiren filtrelerden iki kez geçirilmesi ile yapılır. Alçak geçiren filtreler yaklaşık alt bantlar üretirken, yüksek geçiren filtreler dikey, yatay ve çapraz alt bantlardan oluşan ayrıntılı alt bantlar üretir. Her seviyede sinyal, düşük ve yüksek frekanslara ayrıştırılır. Ayrıştırma süreci nedeniyle, giriş sinyali 2n'nin katı olmalıdır. Burada n, düzey sayısıdır. Görüntü ayrıştırma genellikle görüntü verilerini uzamsal alandan frekans alanına dönüştüren kayıpsız bir işlemdir, burada dönüştürülmüş katsayılar ilişkisizdir. 2-D DWT, Şekil 3.3'te gösterildiği gibi, dijital filtreler ve aşağı örnekleyiciler kullanılarak uygulanabilir. Birinci görüntü seviyesi (2-D Sinyal) ayrıştırma, görüntü verilerini yaklaşık, yatay, dikey ve çapraz olarak etiketlenmiş dört alt banda böler. Her katsayı, orijinal görüntü boyutunun dörtte birine karşılık gelen bir uzamsal alanı temsil eder. Düşük frekanslar, $0 < |\omega| < \pi/2$'a karşılık gelen bir bant genişliğini temsil ederken, yüksek frekanslar bandı $\pi/2 < |\omega| < \pi$ temsil eder. Bir sonraki ayrıştırma düzeyini elde etmek için, alt bandı bir sonraki dört alt bant düzeyine ayrıştırılır. İkinci düzey ayrışmanın düşük frekansları ($0 < |\omega| < \pi/4$ arasındaken, yüksek frekanslar $\pi/4 < |\omega| < \pi/2$ arasında olacaktır. Bu ayrıştırma, gerektiği kadar çok seviyeye kadar devam ettirilebilir (Shi ve Sun, 1999).



Şekil 3.3. DWT'nin 2-D ayrıştırılması

Daubechies dalgacık alçak geçiren ve yüksek geçiren filtre katsayıları aşağıdaki denklemde verilmektedir:

$$h(n) = \left[\frac{1+\sqrt{3}}{4\sqrt{2}} \quad \frac{3+\sqrt{3}}{4\sqrt{2}} \quad \frac{3-\sqrt{3}}{4\sqrt{2}} \quad \frac{1-\sqrt{3}}{4\sqrt{2}}\right] \tag{3.3}$$

$$g(n) = \left[\frac{1-\sqrt{3}}{4\sqrt{2}} \quad -\frac{3-\sqrt{3}}{4\sqrt{2}} \quad \frac{3+\sqrt{3}}{4\sqrt{2}} \quad -\frac{1+\sqrt{3}}{4\sqrt{2}}\right] \tag{3.4}$$

3.4. CNN Mimarileri

Görsel içeriğe dayalı görüntü sınıflandırma, özellikle histopatolojik kesitlerden mikroskobik görüntüler, çok miktarda zengin geometrik yapılar ve karmaşık dokuları içeren birkaç sorun nedeniyle zorlu bir görevdir. Derin öğrenmede, yüksek seviyeli özellikler verilerin birden fazla düzeyde gösterimi kullanılarak temsil edilebilir (LeCun ve ark., 2015). Diğer derin öğrenme tekniklerinin yanı sıra CNN, tıbbi görüntü analizini de içeren görüntü sınıflandırma sorunlarında başarılı sonuçlar elde etmiştir (Yamashita ve ark., 2018).

AlexNet (Krizhevsky ve ark., 2012), GoogleNet (Szegedy ve ark., 2015), VGG-Net (Simonyan ve Zisserman, 2014), InceptionV3 (Szegedy ve ark., 2016) ve ResNet (He ve ark., 2016), bir ağı sıfırdan eğitmek yerine tıbbi görüntüleri etki alanlarına yönelik sınıflandırmak için önceden eğitilmiş ağlar olarak geniş ölçüde kullanmıştır. Çizelge 3.2, en popüler CNN konfigürasyonlarını göstermektedir. Derinlemesine CNN eğitimi, genellikle kapsamlı hesap ve bellek kaynaklarını gerektirir. Bu ağların modern grafik işlemci birimlerinde sıfırdan eğitilmesi genellikle günler veye haftalar sürer. Tüm bu ağlar, ImageNet veri kümesindeki nesnelerin 1000 kategoride sınıflandırılarak eğitildi (Russakovsky ve ark., 2015). ImageNet veri kümesi 1,2M görüntü eğitim kümesi, 50K görüntü doğrulama kümesi ve 100K görüntü test kümesinden oluşmaktadır. Bu ağlar için iki hata oranı bildirilir: ‘Top-5’ hata oranı, doğru etiketin ilk 5 arasında yer aldığı test görüntülerinin oranı'iken, ‘Top-1 hata oranı'ise, en çok doğru etiketin değerlendirildiği test görüntülerinin oranıdır. Tüm bu ağ mimarileri, ilk başta 0.5 değerine ayarlanmış olan bırakma katmanı (Dropout Layer) ile aşırı uyumunu önlemek için veri artırma tekniğini kullanır. AlexNet (Krizhevsky ve ark., 2012), 2012 yılında ImageNet mücadele ödülünü kazanan ilk CNN olmuştur. AlexNet’e ait CNN, beş evreşimsel katmanı ve üç FC katmandan oluşur. Her bir evreşimsel katmanında 96 ile 384 filtre mevcut olup, her biri 3 ile 256 kanala sahip filtreler, 3×3, 5×5, 11×11 boyutlarına sahiptir. Her katmanda doğrusal olmayan bir Doğrultulmuş Doğrusal Birim

(ReLU) kullanılır. 1, 2 ve 5 katmanlarının çıktılarına, 3x3 boyutundaki maksimum havuzlama uygulanır. AlexNet, ağın ilk katmanında adım sayısını 4 olarak belirlemiştir. AlexNet'in modeli, 227×227 boyutundaki bir girdi görüntüsünün işlenmesi için (%16,40'lik Top-5 hata oranıyla) 61M ağırlık gerektirir. VGG-Net (Simonyan ve Zisserman, 2014) modeli, CNN'lerin derin bir katman ağına sahip olmaları gerektiğini desteklemektedir. GoogleNet'in (Szegedy ve ark., 2015) 22 katmandan oluşmaktadır. Böylece CNN modeline bir başlangıç modülü getirmiştir. Sadece tek bir seri bağlantıya sahip önceki CNN modellerinin aksine paralel çalışan ağ parçalarına sahiptir. Artık ağ (Residual Net) olarak da bilinen ResNet (He ve ark., 2016), daha da derine inmek için artık bağlantılar kullanır. ResNet bir nesnenin kesin konumunu belirler, bu da CNN'lerde büyük bir sıçrama anlamına gelmektedir. ResNet, VGG-Net'ten 8 kat daha derin olup, karmaşıklığı dahada düşüktür ve 60M ağırlığa sahiptir. ResNet (%3,57'lik Top-5 hata oranıyla) 2015 (Russakovsky ve ark., 2015) yılında ImageNet mücadele ödülünü kazanmıştır. Google InceptionV3 (Szegedy ve ark., 2016), nispeten düşük bir hesaplama maliyeti ile yüksek performans ağı sunan bir mimaridir. InceptionV3, %5,6'lık Top-5 hata oranına ve %21,2'lik Top-1 hata oranına ulaşmayı başarmıştır.

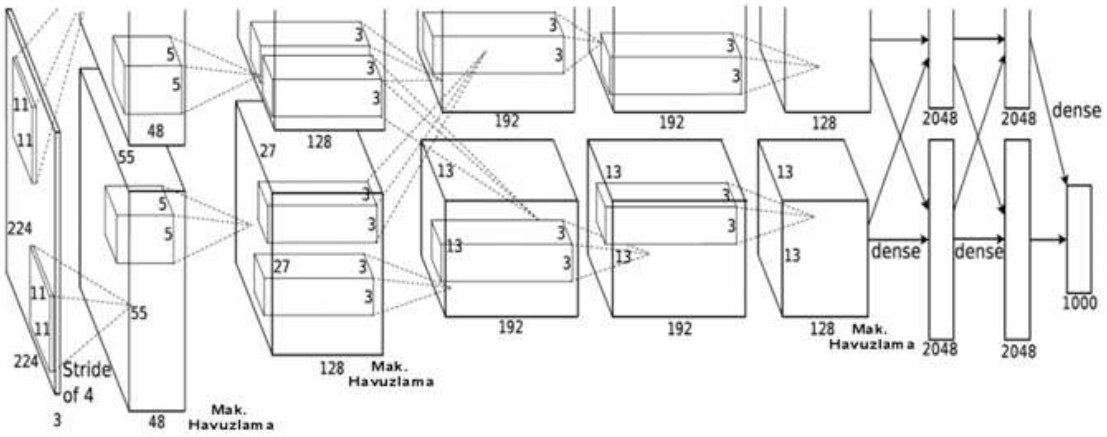
Çizelge 3.2. CNN Modellerinin yapılandırması

Model adı	AlexNet	VGG-16	GoogleNet	ResNet50	InceptionV3
Yıl	2012	2014	2014	2015	2015
Görüntü Çözünürlüğü	227x227	224x224	224x224	224x224	299x299
Katman Sayısı	8	16	22	50	48
Evreşimli Katmanlar Sayısı	5	13	21	49	94
FC Katman Sayısı	3	3	1	1	1

MATLAB, derin sinir ağları oluşturmak, eğitmek ve görselleştirmek için algoritmalar oluşturan bir sinir ağı araç kutusuna sahiptir. Aktarım öğrenimi, önceden eğitilmiş derin CNNs modelleri (InceptionV3, ResNet-50, GoogleNet, AlexNet ve VGG-16 dahil) ile yapılabilir. MATLAB, paralel hesaplama araç kutusu ile çok çekirdekli işlemciler ve GPU'lar arasında hesaplamalara ve veri dağıtımına izin vermektedir.

3.4.1. AlexNet

AlexNet (Krizhevsky ve ark., 2012) 2012'de ImageNet Büyük Ölçekli Görsel Tanıma mücadelesini kazanan ilk CNN olmuştur. AlexNet'in CNN'si, Şekil 3.4'te gösterildiği gibi ilk 5'i evrişimsel katmanlar ve son 3'ü FC olmak üzere toplam 8 katmandan oluşmaktadır. İlk yapı, 1000 sınıf etiketini sınıflandırmak için tasarlanmıştır. Şekil 3.4'te AlexNet modelinin bir örneği gösterilmektedir.



Şekil 3.4. AlexNet modelinin bir örneği (Krizhevsky ve ark., 2012)

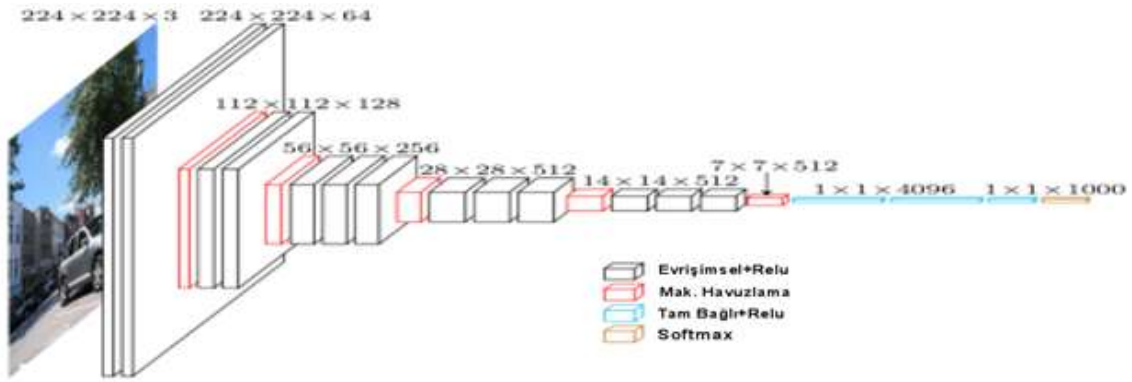
İlk evrişimsel katman filtresi, 96 çekirdek boyutunda (11 x 11) ve 4 piksel adımda (227 x 227) giriş görüntüsü ile beslenir. İlk katmandan gelen yanıt, ikinci katmandan beslenmeden önce normalize edilir ve havuzlanır. İkinci evrişimsel katman 256 çekirdek boyutunda (5x5) kullanır. Kalan evrişimsel katmanlar, üçüncü, dördüncü ve beşinci, herhangi bir normalleştirme veya havuzlama katmanları olmadan bağlanır. Üçüncü evrişimsel katman, ikinci evrişimsel katmanın normalleştirilmiş ve havuzlanmış çıktılarına bağlı 384 çekirdek boyutuna (3x3) sahiptir. Dördüncü evrişimsel katman 384 çekirdek boyutuna (3x3) ve beşinci evrişimsel katman 256 çekirdek boyutuna (3x3) sahiptir. FC katmanlar 4096 özellik vektörüne sahiptir. Son çıktı katmanı, bir softmax aktivasyon katmanına bağlanır, AlexNet ağı için ilk altı katmanın tümü, Çizelge 3.3'te gösterildiği gibi, ReLU aktivasyon işlevi tarafından takip edilir. Model, eğitim için grup boyutu, momentum katsayısı ve ağırlık azalması ile stokastik bir gradyan iniş optimizasyon işlevini kullanır. AlexNet, eğitim sırasında aşırı uyumu gidermek için bırakma katmanlarını kullanır. Çizelge 3.3'te AlexNet Katmanlarının detayları gösterilmektedir.

Çizelge 3.3. AlexNet Katmanları

CNN Katmanı	Katman Türü	Açıklama
-	Görüntü Girişi	"Sıfır merkez" normalleştirme ile 227x227 görüntüler
1.Katman	Evrişimsel	Adım [4 4] ve dolgu [0 0 0 0] ile 96 11x11 evrişimseller
	Maksimum Havuzlama	Adım [2 2] ve dolgu [0 0 0 0] ile maksimum 3x3 havuzlama
2. Katman	Evrişimsel	Adım [1 1] ve dolgu [2 2 2 2] ile 256 5x5 evrişimseller
	Maksimum Havuzlama	Adım [2 2] ve dolgu [0 0 0 0] ile maksimum 3x3 havuzlama
3. Katman	Evrişimsel	Adım [1 1] ve dolgu [1 1 1 1] ile 384 3x3 evrişimseller
4. Katman	Evrişimsel	Adım [1 1] ve dolgu [1 1 1 1] ile 384 3x3 evrişimseller
5. Katman	Evrişimsel	Adım [1 1] ve dolgu [1 1 1 1] ile 256 3x3 evrişimseller
	Maksimum Havuzlama	Adım [2 2] ve dolgu [0 0 0 0] ile maksimum 3x3 havuzlama
6. Katman	FC	4096 FC katman
	Bırakmak	% 50 bırakma
7. Katman	FC	4096 FC katman
	Bırakmak	% 50 bırakma
8. Katman	FC	2 FC katman
	Sınıflandırma	Softmax işlevi
-	Sınıflandırma Çıkışı	İyi huylu veya kötü huylu

3.4.2. VGG-Net

VGG-Net, Oxford Üniversitesi'nden K. Simonyan ve A. Zisserman tarafından önerilen evrişimsel bir sinir ağı modelidir (Simonyan ve Zisserman, 2014). Büyük çekirdek boyutlu filtreleri (sırasıyla birinci ve ikinci evrişimli katmanda 11 ve 5) birden çok 3 × 3 çekirdek boyutlu filtrelerle birbiri ardına değiştirerek AlexNet'e göre daha iyi iyileştirme sonuçları elde etmiştir. Bunun yanısıra VGG-Net, NVIDIA Titan Black GPU'ları kullanarak eğitim haftalarca sürmüştür. VGG-16'nın yapısı Şekil 3.5'te gösterilmektedir.



Şekil 3.5. VGG-16 Yapısı (Thakur, 2019)

Giriş, sabit boyutlu 224 × 224 RGB görüntüdür. Görüntü, çok küçük boyutlu (3 × 3) filtrelerin kullanıldığı bir evrişimsel katman dizisinden geçirilir. Evrişimsel 1 adım piksele sabitlenmiştir; evrişimsel katman girdisinin uzamsal dolgusu (Padding), uzamsal çözünürlüğün evrişimden sonra korunacağı şekildedir. Uzamsal havuzlama, bazı evrişimselleri izleyen beş maksimum havuzlama katmanı tarafından gerçekleştirilir. Maksimum havuzlama, 2 adım ile 2 × 2 piksellik bir pencere üzerinde gerçekleştirilir. Bir evrişimsel katman dizisini üç FC katman izler: ilk ikisinin her biri 4096 nörun sahiptir, üçüncüsü 1000 etiket sınıflandırması gerçekleştirir ve bu nedenle 1000 kanal içerir (her sınıf için bir tane). Son katman, Çizelge 3.4'te gösterildiği gibi soft-max katmanıdır. VGG ağı için tüm gizli katmanları, ReLU aktivasyon işlevi izler. FC katmanların konfigürasyonu tüm ağlarda aynıdır (Simonyan ve Zisserman, 2014).

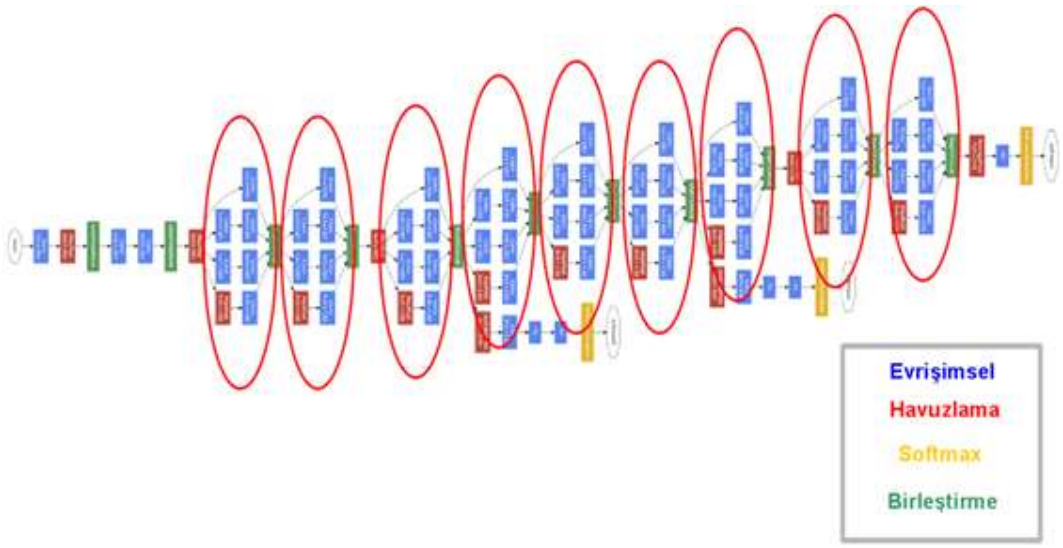
VGG ağında bir görüntüyü eğitmek, AlexNet'in eğitimine benzer teknikler kullanır. Çok ölçekli eğitim görüntüleri söz konusu olduğunda yalnızca birkaç istisna vardır. Tüm eğitim süreci, geri yayılmaya dayalı mini-batch gradyan inişi kullanılarak çok terimli lojistik regresyon hedefini optimize ederek gerçekleştirilir. Bir VGG ağı ile çalışılıyorsa dikkat edilmesi gereken iki önemli dezavantaj vardır. İlki, eğitim süreci çok uzundur. İkincisi, ağ mimarisi ağırlıkları oldukça büyüktür. FC düğümlerin derinliği ve sayısı nedeniyle, eğitimli VGG-16 modeli 500MB'nin üzerindedir. VGG-16 birçok derin öğrenme görüntü sınıflandırma probleminde kullanılmaktadır; ancak, AlexNet ve GoogleNet gibi daha küçük ağ mimarileri genellikle daha çok tercih edilmektedir.

Çizelge 3.4. VGG-16 Katmanları

CNN Katmanı	Katman Türü	Açıklama
-	Görüntü Girişi	"Sıfır merkez" normalleştirme ile 224x224 görüntü
1. Katman	Evrişimsel	Adım [1 1] ve dolgu [1 1] ile 64 3x3 evrişimseller
2. Katman	Evrişimsel	Adım [1 1] ve dolgu [1 1] ile 64 3x3 evrişimseller
	Maksimum Havuzlama	Adım [2 2] ve dolgu [0 0] ile maks. 2x2 havuzlama
3. Katman	Evrişimsel	Adım [1 1] ve dolgu [1 1] ile 128 3x3 evreşimseller
4. Katman	Evrişimsel	Adım [1 1] ve dolgu [1 1] ile 128 3x3 evreşimseller
	Maksimum Havuzlama	Adım [2 2] ve dolgu [0 0] ile maks. 2x2 havuzlama
5. Katman	Evrişimsel	Adım [1 1] ve dolgu [1 1] ile 256 3x3 evrişimseller
6. Katman	Evrişimsel	Adım [1 1] ve dolgu [1 1] ile 256 3x3 evrişimseller
7. Katman	Evrişimsel	Adım [1 1] ve dolgu [1 1] ile 256 3x3 evrişimseller
	Maksimum Havuzlama	Adım [2 2] ve dolgu [0 0] ile maks. 2x2 havuzlama
8. Katman	Evrişimsel	Adım [1 1] ve dolgu [1 1] ile 512 3x3 evrişimseller
9. Katman	Evrişimsel	Adım [1 1] ve dolgu [1 1] ile 512 3x3 evrişimseller
10. Katman	Evrişimsel	Adım [1 1] ve dolgu [1 1] ile 512 3x3 evrişimseller
	Maksimum Havuzlama	Adım [2 2] ve dolgu [0 0] ile maks. 2x2 havuzlama
11. Katman	Evrişimsel	Adım [1 1] ve dolgu [1 1] ile 512 3x3 evrişimseller
12. Katman	Evrişimsel	Adım [1 1] ve dolgu [1 1] ile 512 3x3 evrişimseller
13. Katman	Evrişimsel	Adım [1 1] ve dolgu [1 1] ile 512 3x3 evrişimseller
	Maksimum Havuzlama	Adım [2 2] ve dolgu [0 0] ile maks. 2x2 havuzlama
14. Katman	FC	4096 FC katman
	Bırakmak	% 50 bırakma
15. Katman	FC	4096 FC katman
	Bırakmak	% 50 bırakma
16. Katman	FC	2 FC katman
	Sınıflandırma	Softmax işlevi
-	Sınıflandırma Çıkışı	İyi huylu veya kötü huylu

3.4.3. GoogleNet

Inception Ağı, Sinir Ağları alanlarında, özellikle CNN'ler için en büyük atılımlardan biriydi. Fakat Inception ağının (1, 2 ve 3) üç versiyonu bulunmakta ve bu ağ, ImageNet geniş çapta görsel tanıma alanının mücadelesinde, görüntülerin sınıflandırma ve teşhis için yeni bir teknoloji ürünü olarak belirtirmiştir. Inception ağının bu ilk versyonu, GoogleNet olarak tanıtılmıştır (Szegedy ve ark., 2015). Şekil 3.6 GoogleNet ağının yapısını göstermektedir.



Şekil 3.6. GoogleNet ağı (Szegedy ve ark., 2015)

GoogleNet Mimarisi 22 katman derinliğindedir (havuzlama katmanlarınıda saymış olursak, toplam 27 katmandan oluşmaktadır) (Szegedy ve ark., 2015). Toplamda, doğrusal olarak kümelenmiş 9 başlangıç modülü vardır. Başlangıç modüllerinin uçları, küresel ortalama havuzlama katmanına bağlanır. Önceden eğitilmiş ağların her ikisi de Çizelge 3.5'te gösterildiği gibi (224x224) bir görüntü giriş boyutuna sahiptir. Bir ağ birçok derin katmanla kurulursa, aşırı uyum sorunu ile karşılaşabilir. Bu sorunu çözmek için, aynı seviyede çalışabilen birden fazla boyuta sahip filtreler ile GoogleNet mimarisi önerilmiştir. Bu fikirle, ağ katmanlarının sıralaması derinleşmek yerine genişemektedir. Evrişim işlemi, (1 × 1), (3 × 3) ve (5 × 5) üç filtre boyutuna sahip girişlerde gerçekleştirilir. Evrişimsel katmanlardan sonra bir maksimum havuzlama işlemi de gerçekleştirilir ve ardından bir sonraki başlangıç modülüne gönderilir. Sinir ağları zaman alıcı ve eğitilmesi biraz pahalı olduğundan, ağın boyutlarını azaltmak ve daha hızlı hesaplamalar gerçekteştirmek için (3 × 3) ve (5 × 5) evrişimsellerden önce, fazladan (1 × 1) bir evrişimsel eklenerek giriş kanal sayısı sınırlandırılmıştır.

Çizelge 3.5. GoogleNet Katmanları

CNN Katmanı	Katman Türü	Açıklama
-	Görüntü Girişi	"Sıfır merkez" normalleştirme ile 224x224 görüntü
1.Katman	Evrişimsel	Adım [2 2] ve dolgu [3 3 3 3] ile 64 7x7 evrişimseller
	Maksimum Havuzlama	Adım [2 2] ve dolgu [0 1 0 1] ile maksimum 3x3 havuzlama
2.Katman	Evrişimsel	Adım [1 1] ve dolgu [0 0 0 0] ile 64 1x1 evrişimseller
3. Katman	Evrişimsel	Adım [1 1] ve dolgu [1 1 1 1] ile 192 3x3 evrişimseller
	Maksimum Havuzlama	Adım [2 2] ve dolgu [0 1 0 1] ile maksimum 3x3 havuzlama
4 + 5 Katman	Başlangıç (3a)	(6 Evrişimsel + Max Havuzlama + birleştirme) katmanları
6 +7 Katman	Başlangıç (3b)	(6 Evrişimsel + Max Havuzlama + birleştirme) katmanları
	Maksimum Havuzlama	Adım [2 2] ve dolgu [0 1 0 1] ile maksimum 3x3 havuzlama
8 + 9 Katman	Başlangıç (4a)	(6 Evrişimsel + Max Havuzlama + birleştirme) katmanları
10. katman + 11. katman	Başlangıç (4b)	(6 Evrişimsel + Max Havuzlama + birleştirme) katmanları
12 + 13 Katman	Başlangıç (4c)	(6 Evrişimsel + Max Havuzlama + birleştirme) katmanları
14 + 15 Katman	Başlangıç (4g)	(6 Evrişimsel + Max Havuzlama + birleştirme) katmanları
16 + 17 Katman	Başlangıç (4e)	(6 Evrişimsel + Max Havuzlama + birleştirme) katmanları
	Maksimum Havuzlama	Adım [2 2] ve dolgu [0 1 0 1] ile maksimum 3x3 havuzlama
18 +19 Katman	Başlangıç (5a)	(6 Evrişimsel + Max Havuzlama + birleştirme) katmanları
20 + 21 Katman	Başlangıç (5b)	(6 Evrişimsel + Max Havuzlama + birleştirme) katmanları
	Ortalama Havuzlama	Adım [1 1] ve dolgu [0 0 0 0] ile 7x7 ortalama havuzlama
	Bırakmak	% 40 bırakma
22. Katman	FC	2 FC katman
	Sınıflandırma	Softmax işlevi
-	Sınıflandırma Çıkışı	İyi huylu veya kötü huylu

Inception katmanlarının ayrıntıları sırasıyla (3a), (3b), (4a), (4b), (4c), (4d), (4e), (5a) ve (5b) Çizelge 3.6 - 3.14'te gösterilmektedir.

Çizelge 3.6. GoogleNet Başlangıç (3a) Katmanları

CNN Katmanı	Katman Türü	Açıklama
4. Katman ve 5. Katman	Başlangıç (3a) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 64 1x1 evrişimseller
	Başlangıç (3a) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 96 1x1 evrişimseller
	Başlangıç (3a) [Evrişimsel]	Adım [1 1] ve dolgu [1 1 1 1] ile 128 3x3 evrişimseller
	Başlangıç (3a) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 16 1x1 evrişimseller
	Başlangıç (3a) [Evrişimsel]	Adım [1 1] ve dolgu [2 2 2 2] ile 32 5x5 evrişimseller
	Başlangıç (3a) [Maks. Havuzlama]	Adım [1 1] ve dolgu [1 1 1 1] ile maksimum 3x3 havuzlama
	Başlangıç (3a) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 32 1x1 evrişimseller
	Başlangıç (3a) [Birleştirme]	4 girişin derinlik birleşimi

Çizelge 3.7. GoogleNet Başlangıç (3b) Katmanları

CNN Katmanı	Katman Türü	Açıklama
6. Katman ve 7. Katman	Başlangıç (3b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 128 1x1 evrişimseller
	Başlangıç (3b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 128 1x1 evrişimseller
	Başlangıç (3b) [Evrişimsel]	Adım [1 1] ve dolgu [1 1 1 1] ile 192 3x3 evrişimseller
	Başlangıç (3b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 32 1x1 evrişimseller
	Başlangıç (3b) [Evrişimsel]	Adım [1 1] ve dolgu [2 2 2 2] ile 96 5x5 evrişimseller
	Başlangıç (3b) [Maks. Havuzlama]	Adım [1 1] ve dolgu [1 1 1 1] ile maksimum 3x3 havuzlama
	Başlangıç (3b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 64 1x1 evrişimseller
	Başlangıç (3b) [Birleştirme]	4 girişin derinlik birleşimi

Çizelge 3.8. GoogleNet Başlangıç (4a) Katmanları

CNN Katmanı	Katman Türü	Açıklama
8. Katman ve 9. Katman	Başlangıç (4a) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 192 1x1 evrişimseller
	Başlangıç (4a) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 96 1x1 evrişimseller
	Başlangıç (4a) [Evrişimsel]	Adım [1 1] ve dolgu [1 1 1 1] ile 208 3x3 evrişimseller
	Başlangıç (4a) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 16 1x1 evrişimseller
	Başlangıç (4a) [Evrişimsel]	Adım [1 1] ve dolgu [2 2 2 2] ile 48 5x5 evrişimseller
	Başlangıç (4a) [Maks. Havuzlama]	Adım [1 1] ve dolgu [1 1 1 1] ile maksimum 3x3 havuzlama
	Başlangıç (4a) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 64 1x1 evrişimseller
	Başlangıç (4a) [Birleştirmesel]	4 girişin derinlik birleşimi

Çizelge 3.9. GoogleNet Başlangıç (4b) Katmanları

CNN Katmanı	Katman Türü	Açıklama
10. Katman ve 11. Katman	Başlangıç (4b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 160 1x1 evrişimseller
	Başlangıç (4b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 112 1x1 evrişimseller
	Başlangıç (4b) [Evrişimsel]	Adım [1 1] ve dolgu [1 1 1 1] ile 224 3x3 evrişimseller
	Başlangıç (4b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 24 1x1 evrişimseller
	Başlangıç (4b) [Evrişimsel]	Adım [1 1] ve dolgu [2 2 2 2] ile 64 5x5 evrişimseller
	Başlangıç (4b) [Maks. Havuzlama]	Adım [1 1] ve dolgu [1 1 1 1] ile maksimum 3x3 havuzlama
	Başlangıç (4b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 64 1x1 evrişimseller
	Başlangıç (4b) [Birleştirme]	4 girişin derinlik birleşimi

Çizelge 3.10. GoogleNet Başlangıç (4c) Katmanları

CNN Katmanı	Katman Türü	Açıklama
12. Katman ve 13. Katman	Başlangıç (4c) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 128 1x1 evrişimseller
	Başlangıç (4c) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 128 1x1 evrişimseller
	Başlangıç (4c) [Evrişimsel]	Adım [1 1] ve dolgu [1 1 1 1] ile 256 3x3 evrişimseller
	Başlangıç (4c) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 24 1x1 evrişimseller
	Başlangıç (4c) [Evrişimsel]	Adım [1 1] ve dolgu [2 2 2 2] ile 64 5x5 evrişimseller
	Başlangıç (4c) [Maks. Havuzlama]	Adım [1 1] ve dolgu [1 1 1 1] ile maksimum 3x3 havuzlama
	Başlangıç (4c) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 64 1x1 evrişimseller
	Başlangıç (4c) [Birleştirme]	4 girişin derinlik birleşimi

Çizelge 3.11. **GoogleNet Başlangıç (4d) Katmanları**

CNN Katmanı	Katman Türü	Açıklama
14. Katman ve 15. Katman	Başlangıç (4d) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 112 1x1 evrişimseller
	Başlangıç (4d) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 144 1x1 evrişimseller
	Başlangıç (4d) [Evrişimsel]	Adım [1 1] ve dolgu [1 1 1 1] ile 288 3x3 evrişimseller
	Başlangıç (4d) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 32 1x1 evrişimseller
	Başlangıç (4d) [Evrişimsel]	Adım [1 1] ve dolgu [2 2 2 2] ile 64 5x5 evrişimseller
	Başlangıç (4g) [Maks. Havuzlama]	Adım [1 1] ve dolgu [1 1 1 1] ile maksimum 3x3 havuzlama
	Başlangıç (4d) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 64 1x1 evrişimseller
	Başlangıç (4d) [Birleştirme]	4 girişin derinlik birleşimi

Çizelge 3.12. GoogleNet Başlangıç (4e) Katmanları

CNN Katmanı	Katman Türü	Açıklama
16. Katman ve 17. Katman	Başlangıç (4e) [Evrişimsel]	Adum [1 1] ve dolgu [0 0 0 0] ile 256 1x1 evrişimseller
	Başlangıç (4e) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 160 1x1 evrişimseller
	Başlangıç (4e) [Evrişimsel]	Adım [1 1] ve dolgu [1 1 1 1] ile 320 3x3 evrişimseller
	Başlangıç (4e) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 32 1x1 evrişimseller
	Başlangıç (4e) [Evrişimsel]	Adım [1 1] ve dolgu [2 2 2 2] ile 128 5x5 evrişimseller
	Başlangıç (4e) [Maks. Havuzlama]	Adım [1 1] ve dolgu [1 1 1 1] ile maksimum 3x3 havuzlama
	Başlangıç (4e) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 128 1x1 evrişimseller
	Başlangıç (4e) [Birleştirme]	4 girişin derinlik birleşimi

Çizelge 3.13. GoogleNet Başlangıç (5a) Katmanları

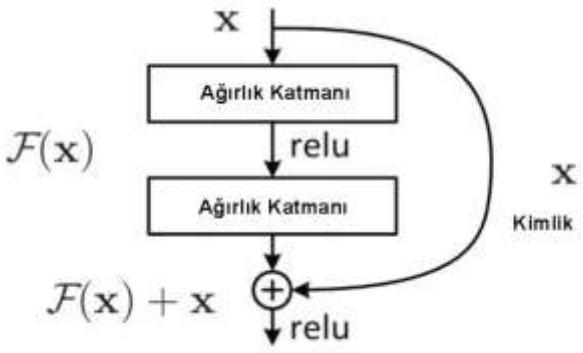
CNN Katmanı	Katman Türü	Açıklama
18. Katman Ve 19. Katman	Başlangıç (5a) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 256 1x1 evrişimseller
	Başlangıç (5a) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 160 1x1 evrişimseller
	Başlangıç (5a) [Evrişimsel]	Adım [1 1] ve dolgu [1 1 1 1] ile 320 3x3 evrişimseller
	Başlangıç (5a) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 32 1x1 evrişimseller
	Başlangıç (5a) [Evrişimsel]	Adım [1 1] ve dolgu [2 2 2 2] ile 128 5x5 evrişimseller
	Başlangıç (5a) [Maks. Havuzlama]	Adım [1 1] ve dolgu [1 1 1 1] ile maksimum 3x3 havuzlama
	Başlangıç (5a) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 128 1x1 evrişimseller
	Başlangıç (5a) [Birleştirme]	4 girişin derinlik birleşimi

Çizelge 3.14. GoogleNet Başlangıç (5b) Katmanları

CNN Katmanı	Katman Türü	Açıklama
20. Katman ve 21. Katman	Başlangıç (5b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 384 1x1 evrişimseller
	Başlangıç (5b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 192 1x1 evrişimseller
	Başlangıç (5b) [Evrişimsel]	Adım [1 1] ve dolgu [1 1 1 1] ile 384 3x3 evrişimseller
	Başlangıç (5b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 48 1x1 evrişimseller
	Başlangıç (5b) [Evrişimsel]	Adım [1 1] ve dolgu [2 2 2 2] ile 128 5x5 evrişimseller
	Başlangıç (5b) [Maks. Havuzlama]	Adım [1 1] ve dolgu [1 1 1 1] ile maksimum 3x3 havuzlama
	Başlangıç (5b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 128 1x1 evrişimseller
	Başlangıç (5b) [Birleştirme]	4 girişin derinlik birleşimi

3.4.4. ResNet

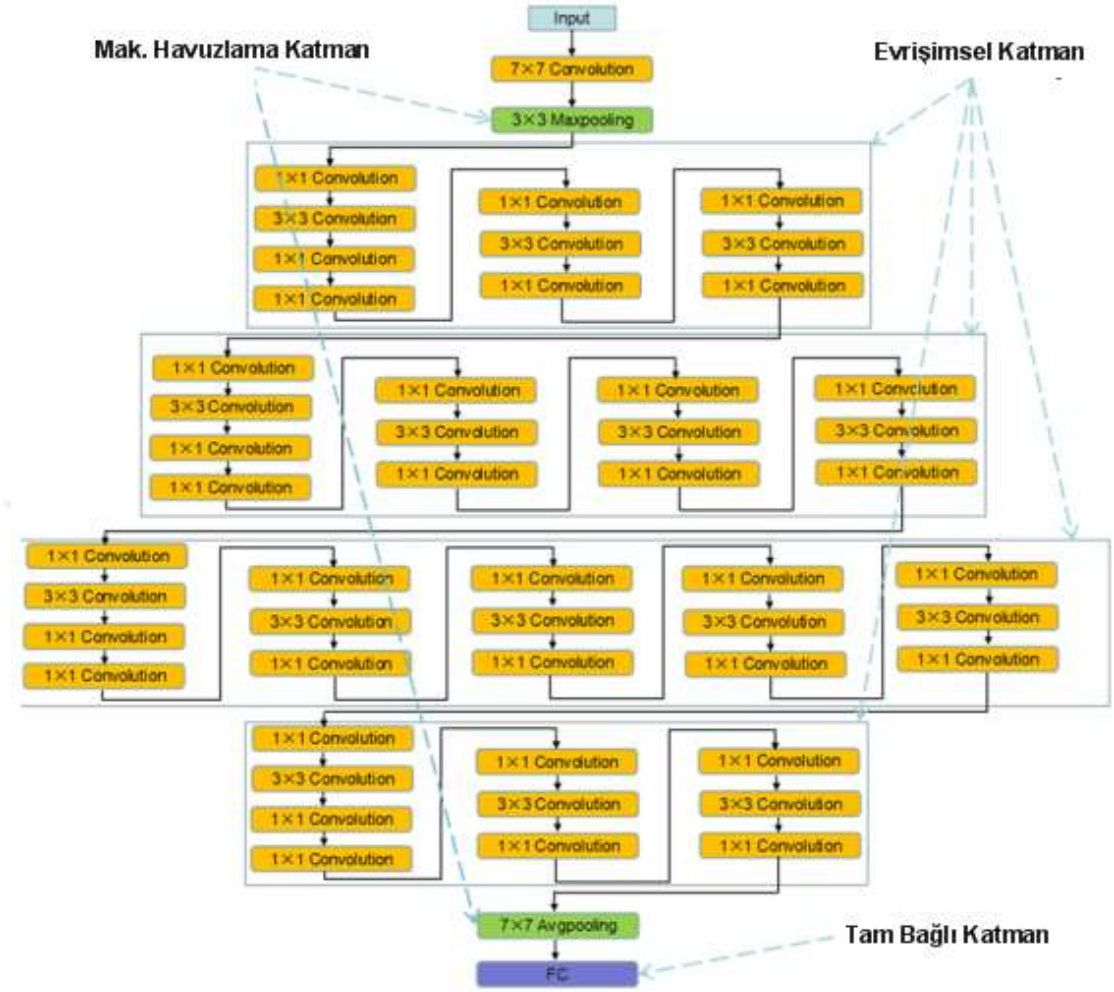
Derin sinir ağlarının hem eğitilmesi zaman alıcı, hem de aşırı uyuma eğilimli olduğu için, Microsoft'taki bir ekip, daha önce kullanılanlardan oldukça daha derin olan ve ResNet olarakta adlandırılan ağların eğitimini iyileştirmek için bir Artık öğrenme (Residual Learning) çerçevesi geliştirdi (He ve ark., 2016). Aslında daha derin ağlar, yakınlaşmaya başlamakla birlikte, bir bozulma sorununuda ortaya çıkarır. Bu buzulmanın artması ağ'ın derinliğinin artmasıyla orantılıdır. Bu da bir doğruluk doygunluğuna sebeb olmasına neden olur ve hızlı bozulmaya neden olur. ResNet ağı, bozulma sorunu ile mücadele etmek için ve "artık haritalama" adı verilen bir teknik kullanmaktadır. Bozulma sorunu, her kümelenmiş katmanın, bir temel eşlemeye doğrudan uyacağını beklemek yerine, Artık Ağ bu katmanların "artık haritalama" uymasına direk izin vermesine neden olur. Şekil 3.7'de bir Artık ağın yapısı görülmektedir.



Şekil 3.7. Artık öğrenme yapısı (He ve ark., 2016)

Geleneksel sinir ağı mimarileri ile karşılaştırıldığında, ResNets'in anlaşılması nispeten daha kolaydır. Önceki ağda, aynı çıktı özelliği haritası için, katmanlar aynı sayıda filtreye sahiptir. Çıktı özelliklerinin boyutu yarıya indirilirse, filtre sayısı ikiye katlanır ve bu da eğitim sürecini daha karmaşık hale getirir. Bu arada, Artık Sinir Ağında, önceki ağlara göre eğitim sırasında çok daha az filtre ve daha düşük oranda karmaşıklık oluşur. Bunun için ağa karşılık gelen ve artık sürümüne dönüştüren bir kısayol bağlantısı eklenir. Bu kısayol bağlantısı ile boyutları artırmak için fazladan sıfır girişi doldurularak kimlik eşleştirme gerçekleştirilir. Bu seçenek ek bir parametre anlamına gelir.

ResNet modellerinin ana yapısı, esas olarak VGG ağlarının felsefesinden esinlenmiştir (He ve ark., 2016). Evrişimsel katmanlar çoğunlukla 3 x 3 filtreye sahiptir ve iki basit tasarım kuralını izler: (i) aynı çıktı özelliği harita boyutu için, katmanlar aynı sayıda filtreye sahiptir ve (ii) özellik haritası boyutu yarıya indirilirse, katman başına zaman karmaşıklığını korumak için filtre sayısı ikiye katlanır. Böylelikle doğrudan 2 adımlı evrişimsel katmanlarla bir havuzlama gerçekleştirilmiş olur. Böylece ağ, genel ortalama bir havuzlama katmanı ve softmax ile 1000 yollu ve FC bir katmanla sona ermiş olur. Şekil 3.8'de toplam ağırlıklı katman sayısı 50'dir ve tüm katmanların detayı Çizelge 3.15'te verilmiştir.



Şekil 3.8. ResNet50 Ağ Mimarisi (Peng ve ark., 2020)

Çizelge 3.15. **ResNet Katmanları**

CNN Katmanı	Katman Türü	Açıklama
-	Görüntü Girişi	"Sıfır merkez" normalleştirme ile 224x224 görüntü
1. Katman	Evrişimsel	Adım [2 2] ve dolgu [3 3 3 3] ile 64 7x7 Evrişimseller
	Maksimum Havuzlama	Adım [2 2] ve dolgu [0 0 0 0] ile maksimum 3x3 havuzlama
2-4 Katmanlar	Res (2a)	(4 Evrişimsel + Toplama) katmanlar
5-7 Katmanlar	Res (2b)	(3 Evrişimsel + Toplama) katmanları
8-10 katmanlar	Res (2c)	(3 Evrişimsel + Toplama) katmanları
11-13 Katmanlar	Res (3a)	(4 Evrişimsel + Toplama) katmanlar
14-16 Katmanlar	Res (3b)	(3 Evrişimsel + Toplama) katmanları
17-19 Katmanlar	Res (3c)	(3 Evrişimsel + Toplama) katmanları
20-22 Katmanlar	Res (3d)	(3 Evrişimsel + Toplama) katmanları
23-25 Katmanlar	Res (4a)	(4 Evrişimsel + Toplama) katmanlar
26-28 Katmanlar	Res (4b)	(3 Evrişimsel + Toplama) katmanları
29-31 Katmanlar	Res (4c)	(3 Evrişimsel + Toplama) katmanları
32-34 Katmanlar	Res (4d)	(3 Evrişimsel + Toplama) katmanları
35-37 Katmanlar	Res (4e)	(3 Evrişimsel + Toplama) katmanları
38-40 Katmanlar	Res (4f)	(3 Evrişimsel + Toplama) katmanları
41-43 Katmanlar	Res (5a)	(4 Evrişimsel + Toplama) katmanlar
44-46 Katmanlar	Res (5b)	(3 Evrişimsel + Toplama) katmanları
47-49 Katmanlar	Res (5c)	(3 Evrişimsel + Toplama) katmanları
50. Katman	FC	2 FC katman
	Sınıflandırma	Softmax işlevi
-	Sınıflandırma Çıkışı	İyi huylu veya kötü huylu

Kalan katmanların ayrıntıları sıresıyla (2a), (2b), (2c), (3a), (3b), (3c), (3d), (4a), (4b), (4c), (4d), (4e), (4f), (5a), (5b) ve (5c) Çizelge 3.16-3.31'te sırasıyla gösterilmektedir.

Çizelge 3.16. ResNet Res (2a) Katmanları

CNN Katmanı	Katman Türü	Açıklama
2-4 Katmanlar	Res (2a) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 64 1x1 evrişimseller
	Res (2a) [Evrişimsel]	Adım [1 1] ve 'aynı' dolgulu 64 3x3 evrişimseller
	Res (2a) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 256 1x1 evrişimseller
	Res (2a) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 256 1x1 evrişimseller
	Res (2a) [Ekleme]	2 girişin faktör bazında eklenmesi

Çizelge 3.17. ResNet Res (2b) Katmanları

CNN Katmanı	Katman Türü	Açıklama
5-7 Katmanlar	Res (2b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 64 1x1 evrişimseller
	Res (2b) [Evrişimsel]	Adım [1 1] ve 'aynı' dolgulu 64 3x3 evrişimseller
	Res (2b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 256 1x1 evrişimseller
	Res (2b) [Toplama]	2 girişin faktör bazında eklenmesi

Çizelge 3.18. ResNet Res (2c) Katmanları

CNN Katmanı	Katman Türü	Açıklama
8-10 Katmanlar	Res (2c) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 64 1x1 evrişimseller
	Res (2c) [Evrişimsel]	Adım [1 1] ve 'aynı' dolgulu 64 3x3 evrişimseller
	Res (2c) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 256 1x1 evrişimseller
	Res (2c) [Toplama]	2 girişin faktör bazında eklenmesi

Çizelge 3.19. ResNet Res (3a) Katmanları

CNN Katmanı	Katman Türü	Açıklama
11-13 Katmanlar	Res (3a) [Evrişimsel]	Adım [2 2] ve dolgu [0 0 0 0] ile 128 1x1 evrişimseller
	Res (3a) [Evrişimsel]	Adım [1 1] ve 'aynı' dolgulu 128 3x3 evrişimseller
	Res (3a) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 512 1x1 evrişimseller
	Res (3a) [Evrişimsel]	Adım [2 2] ve dolgu [0 0 0 0] ile 512 1x1 evrişimseller
	Res (3a) [Ekleme]	2 girişin faktör bazında eklenmesi

Çizelge 3.20. ResNet Res (3b) Katmanları

CNN Katmanı	Katman Türü	Açıklama
14-16 Katmanlar	Res (3b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 128 1x1 evrişimseller
	Res (3b) [Evrişimsel]	Adım [1 1] ve 'aynı' dolgulu 128 3x3 evrişimseller
	Res (3b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 512 1x1 evrişimseller
	Res (3b) [Toplama]	2 girişin faktör bazında eklenmesi

Çizelge 3.21. ResNet Res (3c) Katmanları

CNN Katmanı	Katman Türü	Açıklama
17-19 Katmanlar	Res (3c) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 128 1x1 evrişimseller
	Res (3c) [Evrişimsel]	Adım [1 1] ve 'aynı' dolgulu 128 3x3 evrişimseller
	Res (3c) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 512 1x1 evrişimseller
	Res (3c) [Toplama]	2 girişin faktör bazında eklenmesi

Çizelge 3.22. ResNet Res (3d) Katmanları

CNN Katmanı	Katman Türü	Açıklama
20-22 Katmanlar	Res (3d) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 128 1x1 evrişimseller
	Res (3d) [Evrişimsel]	Adım [1 1] ve 'aynı' dolgulu 128 3x3 evrişimseller
	Res (3d) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 512 1x1 evrişimseller
	Res (3d) [Ekleme]	2 girişin faktör bazında eklenmesi

Çizelge 3.23. ResNet Res (4a) Katmanları

CNN Katmanı	Katman Türü	Açıklama
23-25 Katmanlar	Res (4a) [Evrişimsel]	Adım [2 2] ve dolgu [0 0 0 0] ile 256 1x1 evrişimseller
	Res (4a) [Evrişimsel]	Adım [1 1] ve 'aynı' dolgulu 256 3x3 evrişimseller
	Res (4a) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 1024 1x1 evrişimseller
	Res (4a) [Evrişimsel]	Adım [2 2] ve dolgu [0 0 0 0] ile 1024 1x1 evrişimseller
	Res (4a) [Ekleme]	2 girişin faktör bazında eklenmesi

Çizelge 3.24. ResNet Res (4b) Katmanları

CNN Katmanı	Katman Türü	Açıklama
26-28 Katmanlar	Res (4b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 256 1x1 evrişimseller
	Res (4b) [Evrişimsel]	Adım [1 1] ve 'aynı' dolgulu 256 3x3 evrişimseller
	Res (4b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 1024 1x1 evrişimseller
	Res (4b) [Toplama]	2 girişin faktör bazında eklenmesi

Çizelge 3.25. ResNet Res (4c) Katmanları

CNN Katmanı	Katman Türü	Açıklama
29-31 Katmanlar	Res (4c) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 256 1x1 evrişimseller
	Res (4c) [Evrişimsel]	Adım [1 1] ve 'aynı' dolgulu 256 3x3 evrişimseller
	Res (4c) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 1024 1x1 evrişimseller
	Res (4c) [Toplama]	2 girişin faktör bazında eklenmesi

Çizelge 3.26. ResNet Res (4d) Katmanları

CNN Katmanı	Katman Türü	Açıklama
32-34 Katmanlar	Res (4d) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 256 1x1 evrişimseller
	Res (4d) [Evrişimsel]	Adım [1 1] ve 'aynı' dolgulu 256 3x3 evrişimseller
	Res (4d) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 1024 1x1 evrişimseller
	Res (4d) [Toplama]	2 girişin faktör bazında eklenmesi

Çizelge 3.27. ResNet Res (4e) Katmanları

CNN Katmanı	Katman Türü	Açıklama
35-37 Katmanlar	Res (4e) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 256 1x1 evrişimseller
	Res (4e) [Evrişimsel]	Adım [1 1] ve 'aynı' dolgulu 256 3x3 evrişimseller
	Res (4e) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 1024 1x1 evrişimseller
	Res (4e) [Toplama]	2 girişin faktör bazında eklenmesi

Çizelge 3.28. ResNet Res (4f) Katmanları

CNN Katmanı	Katman Türü	Açıklama
38-40 Katmanlar	Res (4f) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 256 1x1 evrişimseller
	Res (4f) [Evrişimsel]	Adım [1 1] ve 'aynı' dolgulu 256 3x3 evrişimseller
	Res (4f) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 1024 1x1 evrişimseller
	Res (4f) [Toplama]	2 girişin faktör bazında eklenmesi

Çizelge 3.29. ResNet Res (5a) Katmanları

CNN Katmanı	Katman Türü	Açıklama
41-43 Katmanlar	Res (5a) [Evrişimsel]	Adım [2 2] ve dolgu [0 0 0 0] ile 512 1x1 evrişimseller
	Res (5a) [Evrişimsel]	Adım [1 1] ve 'aynı' dolgulu 512 3x3 evrişimseller
	Res (5a) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 2048 1x1 evrişimseller
	Res (5a) [Evrişimsel]	Adım [2 2] ve dolgu [0 0 0 0] ile 2048 1x1 evrişimseller
	Res (5a) [Ekleme]	2 girişin faktör bazında eklenmesi

Çizelge 3.30. ResNet Res (5b) Katmanları

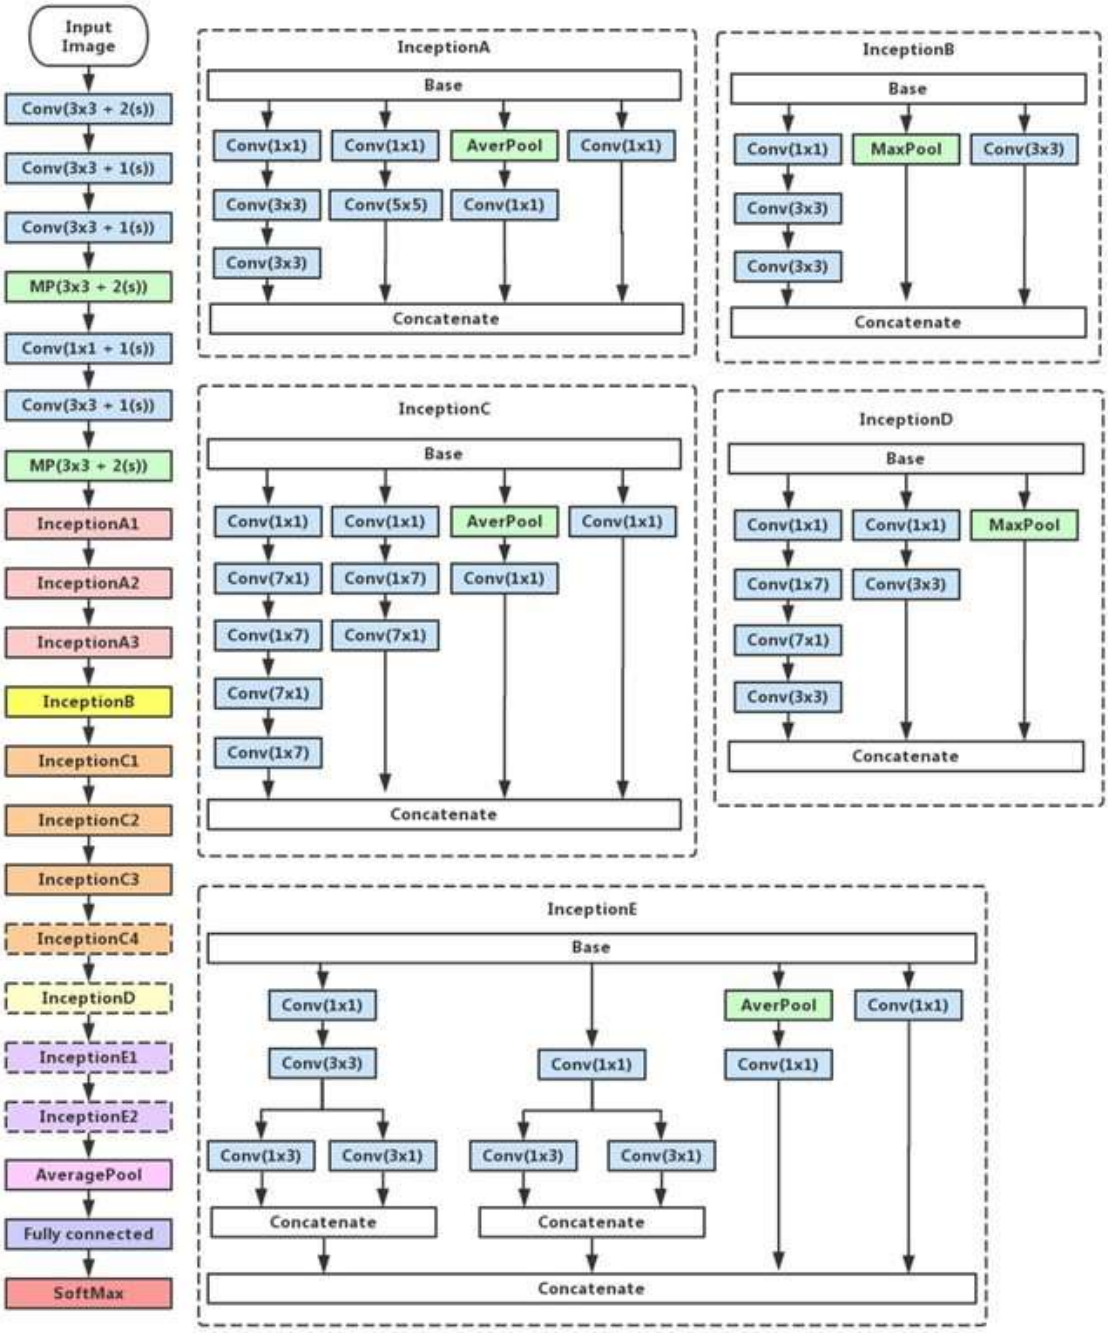
CNN Katmanı	Katman Türü	Açıklama
44-46 Katmanlar	Res (5b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 512 1x1 evrişimseller
	Res (5b) [Evrişimsel]	Adım [1 1] ve 'aynı' dolgulu 512 3x3 evrişimseller
	Res (5b) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 2048 1x1 evrişimseller
	Res (5b) [Toplama]	2 girişin faktör bazında eklenmesi

Çizelge 3.31. ResNet Res (5c) Katmanları

CNN Katmanı	Katman Türü	Açıklama
47-49 Katmanlar	Res (5c) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 512 1x1 evrişimseller
	Res (5c) [Evrişimsel]	Adım [1 1] ve 'aynı' dolgulu 512 3x3 evrişimseller
	Res (5c) [Evrişimsel]	Adım [1 1] ve dolgu [0 0 0 0] ile 2048 1x1 evrişimseller
	Res (5c) [Toplama]	2 girişin faktör bazında eklenmesi

3.4.5. InceptionV3

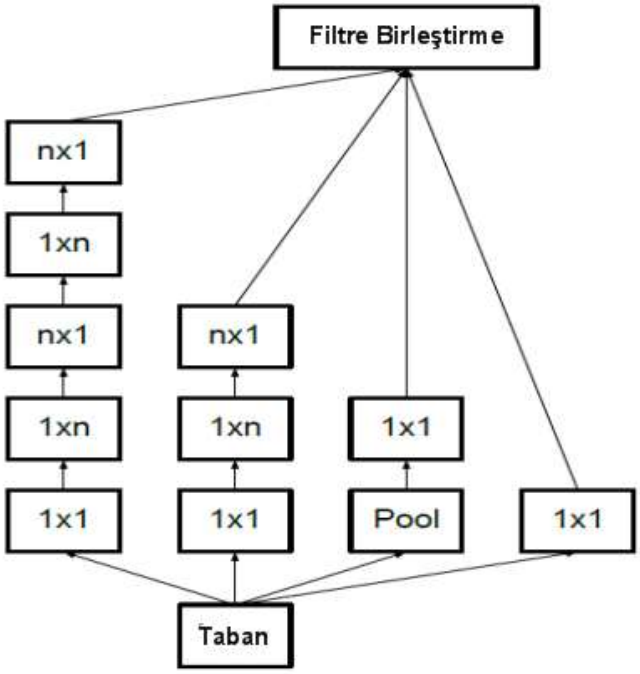
InceptionV3 temel olarak önceki Inception mimarilerini değiştirerek daha az hesaplama gücü harcamaya odaklanır. VGG-Net ile karşılaştırıldığında, Inception Ağları (GoogleNet / InceptionV1) hem ağ tarafından oluşturulan parametre sayısı hem de oluşan ekonomik maliyet (bellek ve diğer kaynaklar) açısından hesaplama adına daha verimli olduğu kanıtlanmıştır. Bir Inception Ağında herhangi bir değişiklik yapılacaksa, hesaplama avantajlarının kaybolmadığına özen gösterilmelidir. Aksi durumda, bir Inception ağının farklı kullanım durumlarına uyarlanması, yeni ağın verimliliğinin belirsizliği nedeniyle bir sorun olarak ortaya çıkar. Bir InceptionV3 modelinde, daha kolay model adaptasyonu için kısıtlamaları çözmek için ağı optimize etmeye yönelik çeşitli teknikler önerilmiştir. Teknikler, çarpanlara ayrılmış Evrişimler (Factorized Convolutions), düzenleştirme (Regularization), boyut azaltma (Dimension Reduction) ve paralelleştirilmiş hesaplamalar (Parallelized Computations) gibi yöntemleri içerir. InceptionV3 modelinin yapısı Şekil 3.9'de gösterilmektedir.



Şekil 3.9. (Sol) InceptionV3 mimarisi. Noktalı çizgi olan kısım, deneylerimizde kaldırılabilecek modülleri temsil eder. **(Sağ)** Farklı Inception modülleri. Inception A, C, E üç çeşit çarpanlara ayırma modülüdür. Inception B, D, verimli sistem boyutu küçültme sağlayan modüllerdir.(Ji ve ark., 2019)

Daha büyük uzamsal filtrelere (örneğin 5 x 5 veya 7 x 7) sahip dönüştürmeler, daha küçük filtrelere (3 x 3) kıyasla hesaplama açısından orantısız biçimde daha pahalı olma eğilimindedir (Szegedy ve ark., 2016). Bununla birlikte, 5 x 5'lik bir filtre, önceki katmanlarda daha uzaktaki birimlerin etkinleştirmeleri arasındaki sinyaller arasındaki bağımlılıkları yakalayabilir. Bu nedenle, filtrelerin geometrik boyutunda bir azalma,

büyük bir ifade gücü gerektirir. Bu nedenle, 5 x 5'lik bir evrişimseli, aynı giriş boyutu ve çıktı derinliğine sahip daha az parametre ile çok katmanlı bir ağ ile değiştirmek önemlidir. Teoride, Şekil 3.10'de gösterildiği gibi bir (n x n) evrişim, (1 x n) evrişim ve ardından (n x 1) evrişim ile değiştirilebilir. n büyüdükçe hesaplama maliyet tasarrufuda çarpıcı bir şekilde artacaktır.



Şekil 3.10: nxn evrişimsellerinin çarpanlarına ayrılmasından sonra Inception modülleri (Szegedy ve ark., 2016).

InceptionV3, daha az parametreye sahip diğer CNN mimarilerine kıyasla daha iyi sonuçlar elde etmektedir. InceptionV3 mimarisi, Çizelge 3.32'de gösterildiği gibi 48 katman derinliğindedir (katmanların sayısı paralel olarak hesaplanırsa 94 evrişim katmanı ve bir FC katmanı içermektedir).

Çizelge 3.32. InceptionV3 Katmanları

CNN Katmanı	Katman Türü	Açıklama
-	Görüntü Girişi	229x229 görüntüler
1. Katman	Evrişimsel 1	Adım [2 2] ve dolgu [0 0 0 0] ile 32 3x3 evrişimseller
2. Katman	Evrişimsel 2	Adım [1 1] ve dolgu [0 0 0 0] ile 32 3x3 evrişimseller
3. Katman	Evrişimsel 3	Adım [1 1] ve 'aynı' dolgulu 64 3x3 evrişimseller
	Maksimum Havuzlama	Adım [2 2] ve dolgu [0 0 0 0] ile maksimum 3x3 havuzlama
4. Katman	Evrişimsel 4	Adım [1 1] ve dolgu [0 0 0 0] ile 80 1x1 evrişimseller
5. Katman	Evrişimsel 5	Adım [1 1] ve dolgu [0 0 0 0] ile 192 3x3 evrişimseller
	Maksimum Havuzlama	Adım [2 2] ve dolgu [0 0 0 0] ile maksimum 3x3 havuzlama
6-8 Katmanlar	Karışık0 [4]	(7 Evrişimsel + Ortalama Havuzlama + birleştirme) katmanları
9-11 Katmanlar	Karışık1 [4]	(7 Evrişimsel + Ortalama Havuzlama + birleştirme) katmanları
12-14 Katmanlar	Karışık2 [4]	(7 Evrişimsel + Ortalama Havuzlama + birleştirme) katmanları
15-17 Katmanlar	Karışık3 [3]	(4 Evrişimsel + Maks Havuzlama + birleştirme) katmanları
18-22 Katmanlar	Karışık4 [4]	(10 Evrişimsel + Ortalama Havuzlama + birleştirme) katmanları
23-27 Katmanlar	Karışık5 [4]	(10 Evrişimsel + Ortalama Havuzlama + birleştirme) katmanları
28-32 Katmanlar	Karışık6 [4]	(10 Evrişimsel + Ortalama Havuzlama + birleştirme) katmanları
33-37 Katmanlar	Karışık7 [4]	(10 Evrişimsel + Ortalama Havuzlama + birleştirme) katmanları
38-41 Katmanlar	Karışık8 [4]	(6 Evrişimsel + Maks. Havuzlama + birleştirme) katmanları
42-44 Katmanlar	Karışık9 [3]	(9 Evrişimsel + Ortalama Havuzlama +3 birleştirme) katmanları
45-47 Katmanlar	Karışık10 [3]	(9 Evrişimsel + Ortalama Havuzlama + 3 birleştirme) katmanları
48. Katman	Ortalama Havuzlama	Adım [8 8] ve dolgu [0 0 0 0] ile ortalama 8x8 havuzlama
	FC	2 FC katman
	Sınıflandırma	Softmax işlevi
-	Sınıflandırma Çıkışı	İyi huylu veya kötü huylu

Karışık katmanların ayrıntıları (Karışık0), (Karışık1), (Karışık2), (Karışık3), (Karışık4), (Karışık5), (Karışık6), (Karışık7), (Karışık8), (Karışık9) ve (Karışık10) sırasıyla Çizelge (3.33 - 3.43)'te gösterilmektedir.

Çizelge 3.33. InceptionV3 Karışık 0 Katmanları

CNN Katmanı	Katman Türü	Açıklama
6-8 Katmanlar	Karışık0 [Evrişimsel 9]	Adım [1 1] ve dolgu [0 0 0 0] ile 64 1x1 evrişimseller
	Karışık0 [Evrişimsel 7]	Adım [1 1] ve 'aynı' dolgulu 48 adet 1x1 evrişimseller
	Karışık0 [Evrişimsel 10]	Adım [1 1] ve 'aynı' dolgulu 96 3x3 evrişimseller
	Karışık0 [Ortalama Havuzlama 1]	Adım [1 1] ve 'aynı' dolgu ile ortalama 3x3 havuzlama
	Karışık0 [Evrişimsel 6]	Adım [1 1] ve 'aynı' dolgulu 64 1x1 evrişimseller
	Karışık0 [Evrişimsel 8]	Adım [1 1] ve 'aynı' dolgulu 64 5x5 evrişimseller
	Karışık0 [Evrişimsel 11]	Adım [1 1] ve 'aynı' dolgulu 96 3x3 evrişimseller
	Karışık0 [Evrişimsel 12]	Adım [1 1] ve 'aynı' dolgulu 32 adet 1x1 evrişimseller
	Karışık0 [Birleştirme]	4 girişin derinlik birleşimi

Çizelge 3.34. InceptionV3 Karışık 1 Katmanları

CNN Katmanı	Katman Türü	Açıklama
9-11 Katmanlar	Karışık1 [Evrişimsel 16]	Adım [1 1] ve 'aynı' dolgulu 64 1x1 evrişimseller
	Karışık1 [Evrişimsel 14]	Adım [1 1] ve 'aynı' dolgulu 48 adet 1x1 evrişimseller
	Karışık1 [dönş2d_17]	Adım [1 1] ve 'aynı' dolgulu 96 3x3 evrişimseller
	Karışık1 [Ortalama Havuzlama 2]	Adım [1 1] ve 'aynı' dolgu ile ortalama 3x3 havuzlama
	Karışık1 [Evrişimsel 13]	Adım [1 1] ve 'aynı' dolgulu 64 1x1 evrişimseller
	Karışık1 [Evrişimsel 15]	Adım [1 1] ve 'aynı' dolgulu 64 5x5 evrişimseller
	Karışık1 [Evrişimsel 18]	Adım [1 1] ve 'aynı' dolgulu 96 3x3 evrişimseller
	Karışık1 [Evrişimsel 19]	Adım [1 1] ve 'aynı' dolgulu 64 1x1 evrişimseller
	Karışık1 [Birleştirme]	4 girişin derinlik birleşimi

Çizelge 3.35. InceptionV3 Karışık 2 Katmanları

CNN Katmanı	Katman Türü	Açıklama
12-14 Katmanlar	Karışık2 [Evrişimsel 23]	Adım [1 1] ve 'aynı' dolgulu 64 1x1 evrişimseller
	Karışık2 [Evrişimsel 21]	Adım [1 1] ve 'aynı' dolgulu 48 adet 1x1 evrişimseller
	Karışık2 [Evrişimsel 24]	Adım [1 1] ve 'aynı' dolgulu 96 3x3 evrişimseller
	Karışık2 [Ortalama Havuzlama 3]	Adım [1 1] ve 'aynı' dolgu ile ortalama 3x3 havuzlama
	Karışık2 [Evrişimsel 20]	Adım [1 1] ve 'aynı' dolgulu 64 1x1 evrişimseller
	Karışık2 [Evrişimsel 22]	Adım [1 1] ve 'aynı' dolgulu 64 5x5 evrişimseller
	Karışık2 [Evrişimsel 25]	Adım [1 1] ve 'aynı' dolgulu 96 3x3 evrişimseller
	Karışık2 [Evrişimsel 26]	Adım [1 1] ve 'aynı' dolgulu 64 1x1 evrişimseller
	Karışık2 [Birleştirme]	4 girişin derinlik birleşimi

Çizelge 3.36. InceptionV3 Karışık 3 Katmanları

CNN Katmanı	Katman Türü	Açıklama
15-17 Katmanlar	Karışık3 [Evrişimsel 28]	Adım [1 1] ve 'aynı' dolgulu 64 1x1x288 evrişimseller
	Karışık3 [Evrişimsel 29]	Adım [1 1] ve 'aynı' dolgulu 96 3x3x64 evrişimseller
	Karışık3 [Evrişimsel 27]	Adım [2 2] ve dolgu [0 0 0 0] ile 384 3x3 evrişimseller
	Karışık3 [Evrişimsel 30]	Adım [2 2] ve dolgu [0 0 0 0] ile 96 3x3 evrişimseller
	Karışık3 [Maks. Havuzlama 3]	Adım [2 2] ve dolgu [0 0 0 0] ile maksimum 3x3 evrişimseller
	Karışık3 [Birleştirme]	4 girişin derinlik birleşimi

Çizelge 3.37. InceptionV3 Karışık 4 Katmanları

CNN Katmanı	Katman Türü	Açıklama
18-22 Katmanlar	Karışık4 [Evrişimsel 35]	Adım [1 1] ve 'aynı' dolgulu 128 1x1 evrişimseller
	Karışık4 [Evrişimsel 36]	Adım [1 1] ve 'aynı' dolgulu 128 7x1 evrişimseller
	Karışık4 [Evrişimsel 32]	Adım [1 1] ve 'aynı' dolgulu 128 1x1 evrişimseller
	Karışık4 [Evrişimsel 37]	Adım [1 1] ve 'aynı' dolgulu 128 1x7 evrişimseller
	Karışık4 [Evrişimsel 33]	Adım [1 1] ve 'aynı' dolgulu 128 1x7 evrişimseller
	Karışık4 [Evrişimsel 38]	Adım [1 1] ve 'aynı' dolgulu 128 7x1 evrişimseller
	Karışık4 [Ortalama Havuzlama 4]	Adım [1 1] ve 'aynı' dolgu ile ortalama 3x3 havuzlama
	Karışık4 [Evrişimsel 31]	Adım [1 1] ve 'aynı' dolgulu 192 1x1 evrişimseller
	Karışık4 [Evrişimsel 34]	Adım [1 1] ve 'aynı' dolgulu 192 7x1 evrişimseller
	Karışık4 [Evrişimsel 39]	Adım [1 1] ve 'aynı' dolgulu 192 1x7 evrişimseller
	Karışık4 [Evrişimsel 40]	Adım [1 1] ve 'aynı' dolgulu 192 1x1 evrişimseller
	Karışık4 [Birleştirme]	4 girişin derinlik birleşimi

Çizelge 3.38. InceptionV3 Karışık 5 Katmanları

CNN Katmanı	Katman Türü	Açıklama
23-27 Katmanlar	Karışık5 [Evrişimsel 45]	Adım [1 1] ve 'aynı' dolgulu 160 1x1 evrişimseller
	Karışık5 [Evrişimsel 46]	Adım [1 1] ve 'aynı' dolgulu 160 7x1 evrişimseller
	Karışık5 [Evrişimsel 42]	Adım [1 1] ve 'aynı' dolgulu 160 1x1 evrişimseller
	Karışık5 [Evrişimsel 47]	Adım [1 1] ve 'aynı' dolgulu 160 1x7 evrişimseller
	Karışık5 [Evrişimsel 43]	Adım [1 1] ve 'aynı' dolgulu 160 1x7 evrişimseller
	Karışık5 [Evrişimsel 48]	Adım [1 1] ve 'aynı' dolgulu 160 7x1 evrişimseller
	Karışık5 [Ortalama Havuzlama 5]	Adım [1 1] ve 'aynı' dolgu ile ortalama 3x3 havuzlama
	Karışık5 [Evrişimsel 41]	Adım [1 1] ve 'aynı' dolgulu 192 1x1 evrişimseller
	Karışık5 [Evrişimsel 44]	Adım [1 1] ve 'aynı' dolgulu 192 7x1 evrişimseller
	Karışık5 [Evrişimsel 49]	Adım [1 1] ve 'aynı' dolgulu 192 1x7 evrişimseller
	Karışık5 [Evrişimsel 50]	Adım [1 1] ve 'aynı' dolgulu 192 1x1 evrişimseller
	Karışık5 [Birleştirme]	4 girişin derinlik birleşimi

Çizelge 3.39. InceptionV3 Karışık 6 Katmanları

CNN Katmanı	Katman Türü	Açıklama
28-32 Katmanlar	Karışık6 [Evrişimsel 55]	Adım [1 1] ve 'aynı' dolgulu 160 1x1 evrişimseller
	Karışık6 [Evrişimsel 56]	Adım [1 1] ve 'aynı' dolgulu 160 7x1 evrişimseller
	Karışık6 [Evrişimsel 52]	Adım [1 1] ve 'aynı' dolgulu 160 1x1 evrişimseller
	Karışık6 [Evrişimsel 57]	Adım [1 1] ve 'aynı' dolgulu 160 1x7 evrişimseller
	Karışık6 [Evrişimsel 53]	Adım [1 1] ve 'aynı' dolgulu 160 1x7 evrişimseller
	Karışık6 [Evrişimsel 58]	Adım [1 1] ve 'aynı' dolgulu 160 7x1 evrişimseller
	Karışık6 [Ortalama Havuzlama 6]	Adım [1 1] ve 'aynı' dolgu ile ortalama 3x3 havuzlama
	Karışık6 [Evrişim 51]	Adım [1 1] ve 'aynı' dolgulu 192 1x1 evrişimseller
	Karışık6 [Evrişimsel 54]	Adım [1 1] ve 'aynı' dolgulu 192 7x1 evrişimseller
	Karışık6 [Evrişimsel 59]	Adım [1 1] ve 'aynı' dolgulu 192 1x7 evrişimseller
	Karışık6 [Evrişimsel 60]	Adım [1 1] ve 'aynı' dolgulu 192 1x1 evrişimseller
	Karışık6 [Birleştirme]	4 girişin derinlik birleşimi

Çizelge 3.40. InceptionV3 Karışık 7 Katmanları

CNN Katmanı	Katman Türü	Açıklama
33-37 Katmanlar	Karışık7 [Evrişimsel 65]	Adım [1 1] ve 'aynı' dolgulu 192 1x1 evrişimseller
	Karışık7 [Evrişimsel 66]	Adım [1 1] ve 'aynı' dolgulu 192 7x1 evrişimseller
	Karışık7 [Evrişimsel 62]	Adım [1 1] ve 'aynı' dolgulu 192 1x1 evrişimseller
	Karışık7 [Evrişimsel 67]	Adım [1 1] ve 'aynı' dolgulu 192 1x7 evrişimseller
	Karışık7 [Evrişimsel 63]	Adım [1 1] ve 'aynı' dolgulu 192 1x7 evişimseller
	Karışık7 [Evrişimsel 68]	Adım [1 1] ve 'aynı' dolgulu 192 7x1 evrişimseller
	Karışık7 [Ortalama Havuzlama 7]	Adım [1 1] ve 'aynı' dolgu ile ortalama 3x3 havuzlama
	Karışık7 [Evrişimsel 61]	Adım [1 1] ve 'aynı' dolgulu 192 1x1 evrişimseller
	Karışık7 [Evrişimsel 64]	Adım [1 1] ve 'aynı' dolgulu 192 7x1 evrişimseller
	Karışık7 [Evrişimsel 69]	Adım [1 1] ve 'aynı' dolgulu 192 1x7 evrişimseller
	Karışık7 [Evrişimsel 70]	Adım [1 1] ve 'aynı' dolgulu 192 1x1 evrişimseller
	Karışık7 [Birleştirme]	4 girişin derinlik birleşimi

Çizelge 3.41. InceptionV3 Karışık 8 Katmanları

CNN Katmanı	Katman Türü	Açıklama
38-41 Katmanlar	Karışık8 [Evrişimsel 73]	Adım [1 1] ve 'aynı' dolgulu 192 1x1 evrişimseller
	Karışık8 [Evrişimsel 74]	Adım [1 1] ve 'aynı' dolgulu 192 1x7 evişimseller
	Karışık8 [Evrişimsel 71]	Adım [1 1] ve 'aynı' dolgulu 192 1x1 evrişimseller
	Karışık8 [Evrişimsel 75]	Adım [1 1] ve 'aynı' dolgulu 192 7x1 evrişimseller
	Karışık8 [Evrişimsel 72]	Adım [2 2] ve dolgu [0 0 0 0] ile 320 3x3 evrişimseller
	Karışık8 [Evrişimsel 76]	Adım [2 2] ve dolgu [0 0 0 0] ile 192 3x3 evrişimseller
	Karışık8 [Maks. Havuzlama 4]	Adım [2 2] ve dolgu [0 0 0 0] ile maksimum 3x3 havuzlama
	Karışık8 [Birleştirme]	4 girişin derinlik birleşimi

Çizelge 3.42. InceptionV3 Karışık 9 Katmanları

CNN Katmanı	Katman Türü	Açıklama
42-44 Katmanlar	Karışık9 [Evrişimsel 81]	Adım [1 1] ve 'aynı' dolgulu 448 1x1 evrişimseller
	Karışık9 [Evrişimsel 78]	Adım [1 1] ve 'aynı' dolgulu 384 1x1 evrişimseller
	Karışık9 [Evrişimsel 82]	Adım [1 1] ve 'aynı' dolgulu 384 3x3 evrişimseller
	Karışık9 [Evrişimsel 79]	Adım [1 1] ve 'aynı' dolgulu 384 1x3 evrişimseller
	Karışık9 [Evrişimsel 80]	Adım [1 1] ve 'aynı' dolgulu 384 3x1 evrişimseller
	Karışık9 [Evrişimsel 83]	Adım [1 1] ve 'aynı' dolgulu 384 1x3 evrişimseller
	Karışık9 [Evrişimsel 84]	Adım [1 1] ve 'aynı' dolgulu 384 3x1 evrişimseller
	Karışık9 [Ortalama Havuzlama 8]	Adım [1 1] ve 'aynı' dolgu ile ortalama 3x3 havuzlama
	Karışık9 [Evrişimsel 77]	Adım [1 1] ve 'aynı' dolgulu 320 1x1 evrişimseller
	Karışık9 [Evrişimsel 85]	Adım [1 1] ve 'aynı' dolgulu 192 1x1 evrişimseller
	Karışık9 [Birleştirme_1]	2 girişin derinlik birleşimi
	Karışık9 [Birleştirme_2]	2 girişin derinlik birleşimi
	Karışık9 [Birleştirme]	4 girişin derinlik birleşimi

Çizelge 3.43. InceptionV3 Karışık 10 Katmanlar

CNN Katmanı	Katman Türü	Açıklama
45-47 Katmanlar	Karışık10 [Evrişimsel 90]	Adım [1 1] ve 'aynı' dolgulu 448 1x1 evrişimseller
	Karışık10 [Evrişimsel 87]	Adım [1 1] ve 'aynı' dolgulu 384 1x1 evrişimseller
	Karışık10 [Evrişimsel 91]	Adım [1 1] ve 'aynı' dolgulu 384 3x3 evrişimseller
	Karışık10 [Evrişimsel 88]	Adım [1 1] ve 'aynı' dolgulu 384 1x3 evrişimseller
	Karışık10 [Evrişimsel 89]	Adım [1 1] ve 'aynı' dolgulu 384 3x1 evrişimseller
	Karışık10 [Evrişimsel 92]	Adım [1 1] ve 'aynı' dolgulu 384 1x3 evrişimseller
	Karışık10 [Evrişimsel 93]	Adım [1 1] ve 'aynı' dolgulu 384 3x1 evrişimseller
	Karışık10 [Ortalama Havuzlama 9]	Adım [1 1] ve 'aynı' dolgu ile ortalama 3x3 havuzlama
	Karışık10 [Evrişimsel 86]	Adım [1 1] ve 'aynı' dolgulu 320 1x1 evrişimseller
	Karışık10 [Evrişimsel 94]	Adım [1 1] ve 'aynı' dolgulu 192 1x1 evrişimseller
	Karışık10 [Birleştirme_1]	2 girişin derinlik birleşimi
	Karışık10 [Birleştirme_2]	2 girişin derinlik birleşimi
	Karışık10 [Birleştirme]	4 girişin derinlik birleşimi

3.5. Eğitim Stratejileri

Burada kullanılan eğitim stratejisi, konuşma ve görüntü tanıma için pratik sistemlerde sıklıkla kullanılan bir denetimli strateji tipidir. Ağın parametrelerini (ağırlıklar ve önyargılar) (weights and biases) güncellemek için, denetimli modda her zaman olduğu gibi, gradyanları hesaplamak için geri yayılım, Öğrenme oranı ve mini-batch boyutu için farklı değerler içeren Stokastik Gradyan İniş (SGD) yöntemi kullanılmıştır (Bottou, 2012). Standart gradyan iniş algoritması, kaybın negatif gradyanı yönünde her seferinde küçük adımlar atarak kayıp fonksiyonunu en aza indirmek için ağ parametrelerini güncelleyen bir optimizasyon algoritmasıdır. Parametreler, aşağıdaki deklem ile hesaplanabilir;

$$\theta_{i+1} = \theta_i - \alpha \nabla E(\theta_i) \tag{3.5}$$

Burada i yineleme numarası, α > 0 öğrenme hızı, θ parametre vektörü ve E (θ) kayıp fonksiyonudur. Standart gradyan iniş algoritmasında, kayıp fonksiyonunun gradyanı, ∇E (θ), tüm eğitim kümesi kullanılarak değerlendirilir ve standart gradyan iniş algoritması, tüm veri kümesini aynı anda kullanacaktır.

Bunun tersine, SDG algoritması, gradyanı değerlendirir ve eğitim verilerinin bir alt kümesini kullanarak her yinelemede parametreleri günceller. Her yinelemede mini-batch adı verilen farklı bir alt küme kullanılır. Mini-batch boyutları kullanılarak, eğitim algoritmasının tüm eğitim kümesi üzerindeki tam geçişi, bir Epoch olarak tanımlanır. SDG'i stokastiktir, çünkü bir mini-batch kullanılarak hesaplanan parametre güncellemeleri, tam veri kümesinin kullanılmasından kaynaklanacak parametre güncellemesinin gürültülü bir tahminidir. Stokastik gradyan basit ve etkili olsa da, model hiper parametrelerinin, özellikle optimizasyonda kullanılan öğrenme oranının dikkatlice ayarlanmasını gerektirir. Öğrenme oranı, ağın ağırlıklarını kayıp gradyanına göre ne kadar ayarlandığını kontrol eden bir hiper parametredir. Daha yüksek bir öğrenme oranı CNN eğitiminin sürecinde sapmaya yol açarken, daha küçük bir öğrenme oranı CNN eğitiminin yavaşça yakınlaşmasını neden olabilir. Genellikle araştırmacılar, ağın daha hızlı yakınlaşmasını ve daha iyi performans elde etmesini sağlamak için çeşitli boyutlarda öğrenme oranlarıyla deneyler yapmaları gerekebilir. Kayıp fonksiyonuna E (θ) ağırlıklar için bir düzenlileştirme terimi eklemek, aşırı uyumu azaltmanın bir yoludur (Murphy, 2012). Düzenlilik terimine, ağırlık kaybı da denir. Düzenlilik ile kayıp işlevi, denklem 3.6'da verilmiştir.

$$E_R(\theta) = E(\theta) + \lambda\, \Omega(w) \tag{3.6}$$

burada w ağırlık vektörü, λ düzenleştirme faktörü (katsayı) ve Ω (w) düzenleştirme fonksiyonu olarak tanımlanır ve aşağıdaki denklem 3.7 ile hesaplanabilir.

$$\Omega(w) = \frac{1}{2}\, w^T\, w \tag{3.7}$$

3.6. Aktarım Öğrenimi

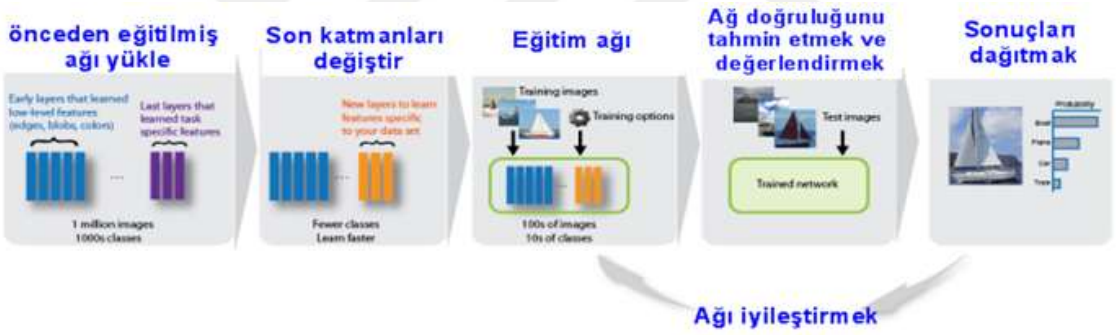
Aktarım öğrenimi, belirli bir uygulama için benzer bir görevde birçok sınıflı büyük bir veri kümesi üzerinde eğitilmiş bir ağ kullanan derin öğrenme yöntemidir. Bir

modeli sıfırdan eğitmek yerine, aktarım öğrenmeyi kullanarak modele ince ayar yapmak genellikle çok daha hızlı ve kolaydır. Bu yaklaşım, nesne algılama, görüntü tanıma ve konuşma tanıma gibi farklı algılama görevleri için sıklıkla kullanılmaktadır (Abd Almisreb ve ark., 2018). Derin bir CNN eğitimi, büyük miktarda etiketli eğitim verisi gerektirir (Hedjazi ve ark., 2017). Bilgiyi büyük veri kümelerinden daha küçük veri kümelerine aktarmak, toplanan veri eksikliğini önler. Tıbbi görüntü sınıflandırma sistemlerinde CNN'leri kullanırken, aktarım öğrenme, açıklamalı (annotated) doğal görüntülerin varlığı nedeniyle verilerin yetersiz olduğu durumlarda faydalıdır (Huang ve ark., 2017). Literatür taramasında karşılaşılan sadece birkaç çalışma olmuştur. Bunlardan biri tüm CNN'leri rastgele başlatma ile sıfırdan eğitmekle yapılmıştır. Diğerleri ise; aktarım öğrenimi yaklaşımlarını kullanarak, önceden eğitilmiş bir ağda ince ayar yaparak (Dhungel ve ark., 2015; Huynh ve ark., 2016; Lévy ve Jain, 2016; Samala ve ark., 2017; Mohamed ve ark., 2018) ve özellik çıkarıcı olarak önceden eğitilmiş bir ağ kullanarak yapılmıştır (Carneiro ve ark., 2015; Huynh ve ark., 2016; Wichakam ve Vateekul, 2016; Wang ve ark., 2017).

Tıbbi alanda aktarım öğrenmeye duyulan ihtiyaç, verilerin sınırlı ve pahalı olması, halka açık olmamaları ve profesyonel radyologlar tarafından toplanıp etiketlenmesi zaman alıcı olduğu için ortaya çıkmaktadır (Greenspan ve ark., 2016; Huynh ve ark., 2016; Jiao ve ark., 2016). Dahası, derin bir CNN eğitimi, kapsamlı hesaplama ve bellek kaynakları gerektirir (Krizhevsky ve ark., 2012; Greenspan ve ark., 2016). Önceden eğitilmiş bir CNN'nin (doğal görüntülerde) ilk katmanlardan çıkarılmış özellikleri, birçok görev için yararlı olan daha genel özellikler (örn. Kenar detektörleri veya leke detektörleri) içerir; ancak sona doğru katmanlarda, genel özellikler birleştirilir ve eğitim veri kümesinde yer alan sınıfların ayrıntılarına daha özellikli hale gelir. Böylece, derin bir CNN, bir alandan diğerine aktarılabilen birden fazla soyutlama düzeyinde bir dizi ayırt edici özelliğin çıkarılmasına izin vermektedir (Abdelhafiz ve ark., 2019). Bununla birlikte, gerekli ince ayar düzeyi bir uygulamadan diğerine farklılık göstermektedir.

Aktarım Öğrenmeyi kullanan çalışmaların çoğu ImageNet'in veri kümesini kullanarak (Russakovsky ve ark., 2015) ağı önceden eğitmek içindir (Huynh ve ark., 2016; Lévy ve Jain, 2016; Suzuki ve ark., 2016; Carneiro ve ark., 2017). Mamografi için yaygın olarak kullanılan ağlar, önceden eğitilmiş CNN mimarileri Alex-Net'dir (Huynh ve ark., 2016; Lévy ve Jain, 2016; Suzuki ve ark., 2016; Carneiro ve ark., 2017; Samala ve ark., 2017; Mohamed ve ark., 2018), VGG16 (Shen, 2017; Xi ve ark., 2018),

ResNet50 (Shen, 2017; Xi ve ark., 2018) ve GoogleNet'tir (Lévy ve Jain, 2016; Jiang ve ark., 2017; Xi ve ark., 2018). ImageNet kullanılarak önceden eğitilmiş tüm derin CNN mimarileri, 1000 sınıflı bir sınıflandırma görevi için tasarlanmıştır. Bunları mevcut göreve uyarlamak için, her ağdan son üç katman kaldırılıp ve her ağın kalan yapısına üç yeni katman (FC katmanı, soft-max katmanı ve sınıflandırma katmanı) eklenmektir. Mamografi için büyük ölçekli tıbbi görüntü veri kümeleri mevcut olana kadar, aktarım öğrenimi ve veri artırmanın kombinasyonları, derin CNN'lerin eğitimi için çok umut verici bir yaklaşım olmuştur. Eğitim süreci boyunca farklı katmanlarda öğrenilen özellikler görselleştirilerek, bir modelin performansını yakından gözlemlemek ve izlemek için görüntülenir (Yi ve ark., 2017). Öğrenilen özellikler, bir modelin başarılı bir şekilde öğrenip öğrenmediğini gösterebilir ve kullanıcının eğitim sürecini erken durdurmasına olanak tanır (Hohman ve ark., 2018). Şekil 3.11'de aktarım öğrenimin tekniğini ve önceden eğitilmiş bir ağı yeniden kullanma yöntemini göstermektedir.



Şekil 3.11. Önceden Eğitilmiş Ağı Yeniden Kullanma (Beale ve ark., 2019)

3.7. Çapraz Doğrulama Yöntemi

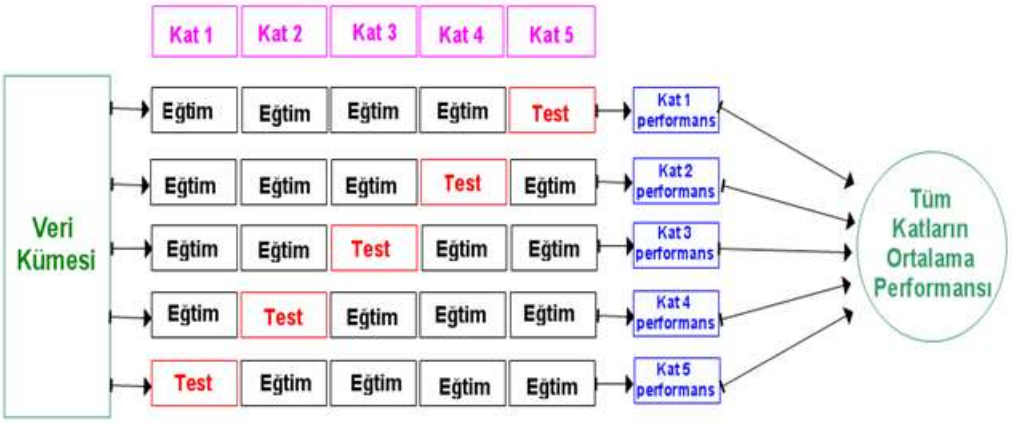
Çapraz doğrulama, makine öğrenimi modellerinin performansını değerlendirmek için kullanılan istatistiksel bir yöntemdir. Rastgele örnekleme yöntemleri ile ortaya çıkan kümelerin birbiri ile çakışmayacağı şekilde kullanılır (Berrar ve Biyoloji, 2019). Çapraz doğrulama, orijinal veri kümesini eğitim ve test kümelerine bölmektedir. Literatürde doğrulama için kullanılan üç yaygın türü vardır. Uzatma bölmeleri (hold-out splits) (Lee ve ark., 2017), üç yönlü veri bölmeleri (three-way data splits) (Kooi ve ark., 2017) ve K-katlamalı çapraz doğrulama (K-fold cross-validation) (Samala ve ark.,

2017). Uzatma veri bölünmelerinde veriler eğitim ve test kümesine bölünür (örneğin sırasıyla %80 ve %20). Eğitim kümesi, modeli eğitmek için kullanılırken, test kümesi eğitilen modelin hata oranını tahmin etmek için kullanılır. Üç yollu veri bölmelerinde, veriler rastgele olarak eğitim, doğrulama ve test kümelerine ayrılır. CNN modeli, eğitim kümesinde eğitilir ve doğrulama kümesinde değerlendirilir. En iyi model bulunana kadar eğitim ve doğrulama birkaç kez yinelenebilir. En son modelde test kümesi değerlendirilir (Abdelhafiz ve ark., 2019).

K-kat çapraz doğrulamasında, veri kümesi rastgele örnekleme ile k farklı alt kümeye (veya katlara) bölünür. Çapraz doğrulama süreci, k kümesinin her biri test kümesi olarak tam bir kez kullanılmak üzere k-kez (katlar) tekrarlanır. k Katlardan hata tahminlerinin ortalaması, daha sonra tek bir tahmin oluşturmak için alınır. Çapraz doğrulanmış performans, k doğrulama kümlerindeki, k performans ölçümlerinin ortalamasıdır (Berrar ve Biyoloji, 2019). Çapraz doğrulama, aşırı uyumu önler ve modelin performansının daha az önyargılı bir tahminini vermektedir (Yadav ve Shukla, 2016). Uygulamada, kat sayısının seçimi, veri kümesinin boyutuna bağlıdır. Literatürde ortak strateji, mamografi için k-kat çapraz doğrulama kullanmaktır. Büyük veri kümeleri için, 3 ile 5 kat arası çapraz doğrulama, küçük mamografi veri kümelerinde 10 kat çapraz doğrulama kullanmak yaygın bir şekilde seçilmektedir. Bu çalışmada, veri kümesi, çizelge 3.44 gösterildiği gibi hasta bazında beş kata ayrılmıştır. Şekil 3.12'da 5-kat çapraz doğurlama tekniğini göstermektedir.

Çizelge 3.44. Çapraz Doğurlama, 5-kattaki Hasta Sayısı

Sınıflar	Alt Sınıflar	Hasta Sayısı	Kat 1	Kat 2	Kat 3	Kat 4	Kat 5
İyi Huylu (B)	A	4	1	1	1	1	---
	F	10	2	2	2	2	2
	PT	3	1	1	---	1	---
	TA	7	1	1	2	1	2
Kötü Huylu (M)	DC	38	7	7	8	8	8
	LC	5	1	1	1	1	1
	MC	9	2	2	1	2	2
	PC	6	2	1	1	1	1
Toplam		82	17	16	16	17	16



Şekil 3.12. 5-kat Çapraz Doğrulama Tekniğini

3.8. Destek Vektör Makinesi (SVM)

SVM, iki sınıf vektörü arasındaki bölünebilir mesafeyi en üst düzeye çıkararak iki sınıflı vektörleri (her iki sınıftan özellikler) ayırmak için etkili bir ayrılabilir hiper düzlem bulmaya çalışan bir sınıflandırma tekniğidir (Duda ve ark., 2012). Sınıflandırıcı doğrusal olabilir ya da olmayabilir. *d* boyut için (x_i, y_i), $i = 1, 2, 3, \ldots, n$, formlu bir eğitim kümesi verildiğinde, $x_i \in R^d$ *ve* $y_i \in \{1,-1\}$ olmak üzere, x_i özellik vektörleri ve y_i iyi huylu ve kötü huylu iki sınıfı temsil eder. Hiper düzlemin denklemi denklem 3.8'deki gibi olacaktır:

$$< w, x > + b = 0 \tag{3.8}$$

burada, $w \in R^d$, <*w*, *x*> x ve w'ın iç (nokta) çarpımları olup, b gerçek kısımdır. Denklem 3.9'daki durum ise en iyi ayıran altdüzlemi tanımlar. En aza indiren *w* ve b bulunur || w ||. Öyle ki, (x_i, y_i) tüm veri noktaları için, denklem 3.9'daki gibi;

$$y_i(< w, x_i > + b) \geq 1 \tag{3.9}$$

Destek vektörleri, sınır üzerindedir ve x_i olmak üzere, aşağıdaki denklem 3.10'de verilmektedir

$$y_i(< w, x_i > +b) = 1 \tag{3.10}$$

şeklindedir. Matematiksel kolaylık için, problem genellikle <w, w> / 2'yi minimize etme eşdeğer problemi olarak verilir. Bu ikinci dereceden bir programlama problemidir. Sonuçta, optimal çözüm *w* ve *b*, bir z vektörünün denklem 3.11'daki gibi sınıflandırılmasını sağlamaktadır:

$$class(z) = sign(< w, z > + b) \tag{3.11}$$

SVM'nin çözmeye çalıştığı ikili problemin matematiksel formülasyonu ise, aşağıdaki denklem 3.12'de gösterilmektedir;

$$\max_{\alpha} \sum_i \alpha_i - \frac{1}{2} \sum_i \sum_j \alpha_i \, \alpha_j \, y_i \, y_j \, K(x_i, x_j) \tag{3.12}$$

Kısıtlamalara tabi tutulursa, denklem 3.13'ki şeklinde verilebilir.,

$$\sum_i y_i \, \alpha_i = 0 \qquad 0 \leq \alpha_i \leq C \tag{3.13}$$

Burada, *C*, kutu kısıtlaması olarak da adlandırılan penelti parametresidir ve $K(x_i, x_j)$ bir çekirdek işlevidir. Doğrusal ayrılabilir alt düzlem, çekirdek işlevi denklem 3.14'te gösterilmektedir;

$$(x_i, x_j) = < \emptyset(x_i), \emptyset(x_j) > \tag{3.14}$$

Doğrusal olmayan ayrılabilir alt düzlem, çekirdek işlevi farklı olacaktır. Aşağıdaki denklem 3.15'e radyal temel fonksiyon buna bir örnek olarak verilmektedir.

$$K(x_i, x_j) = exp(-< (x_i - x_j), (x_i - x_j) > /(2\sigma 2)) \tag{3.15}$$

Burada, σ pozitif bir tamsayıdır. Genel olarak, sınıf aşağıdaki denklem 3.16'da kullanılarak belirlenebilir.

$$class(z) = sign(\sum_{i=1}^{N_S} \alpha_i y_i K(S_i, z) + b) \quad (3.16)$$

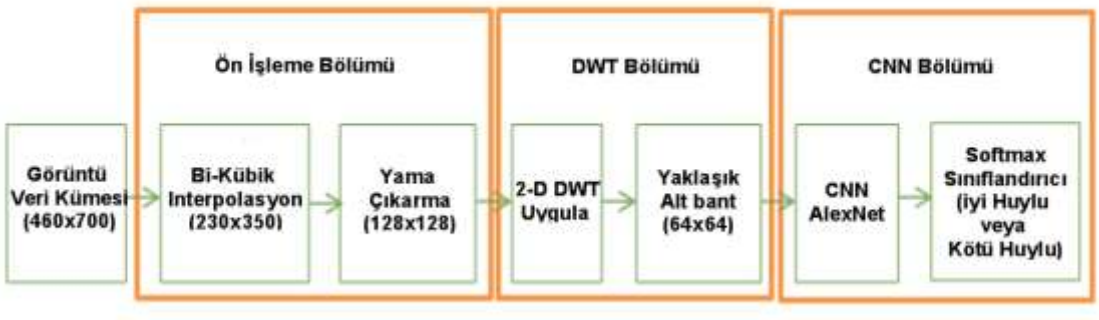
burada, S_i eğitim örnekleri, $\alpha_i > 0$ ile z_i (destek vektörleri), ve N_S destek vektörlerinin sayısıdır (Fadhil, 2014).

4. ÖNERİLEN MODELLER

Bu bölümde, histopatolojik meme kanseri tespitine yönelik CNN kullanımın üç geliştirilmiş CAD modeli tanıtılmaktayız. Birincisi, DWT (Ayrık Dalgacık Dönüşümü) Tabanlı CNN. İkinci ve üçüncüsü sırasıyla, SVM sınıflandırıcı ile önceden eğitilmiş CNN'lerin modelerinin birleştirilmesi ve SVM sınıflandırıcı ile önceden eğitilmiş CNN'lerin modelerinin birleştirilmesi.

4.1. Model 1: DWT Tabanlı CNN Modeli

Bu model, DWT ile birlikte AlexNet'i kullanarak gelişmiş CNN modelini sunmaktadır (Spanhol ve ark., 2016). Önerilen sistemin temel fikri, orijinal ham görüntüler yerine, DWT gelen yaklaşık (Approximation) alt bantlarını CNN ile kullanmaktır. DWT özelliklerini kullanmak CNN'nın aşırı uyum sorununu önleyecek ve değişken renk dağılımı ve hücre örtüşmesi gibi histopatolojik görüntülerin doğal karmaşıklığını azaltacaktır. Girdi görüntülerinin boyutu, bikübik enterpolasyon (Bi-cubic Interpolation) kullanılarak azaltacaktır. Daha sonra, kayan pencere stratejisi kullanılarak 128x128 boyutundaki yamalar çıkarılmıştır. Çıkarılan yamalara DWT uygulanmış, sadece aklaşık alt band kullanılacaktır. Sonrasında, 64x64 boyutundaki yamalar, eğitim ve test için AlexNet modelini besleyecektir. Önerilen modelin akış şeması, Şekil 4.1'de gösterilmiştir.



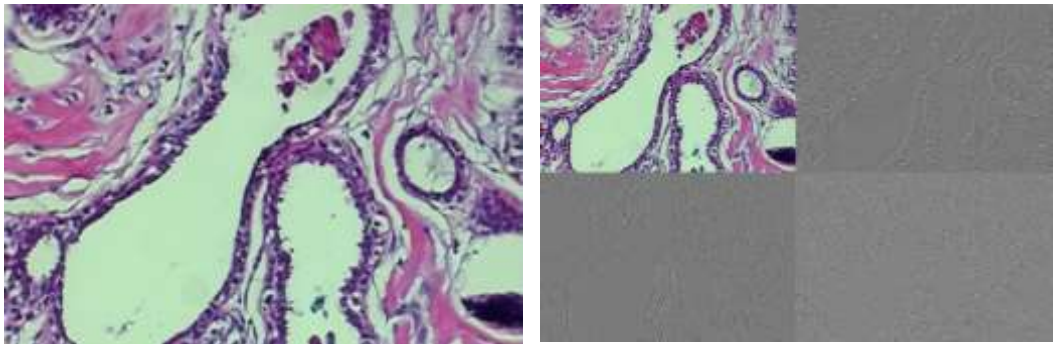
Şekil 4.1. Önerilen DWT tabanlı CNN modelinin akış şeması

4.1.1. Ön işleme bölümü

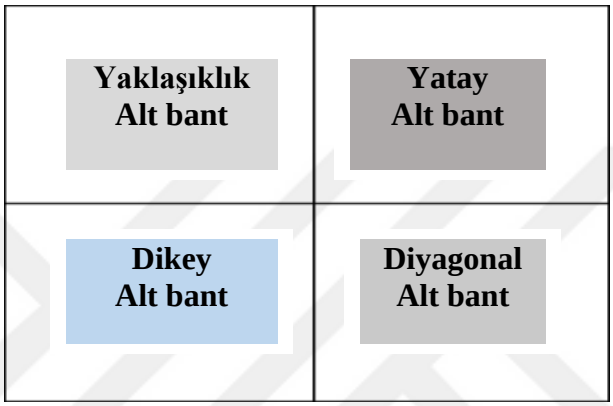
İlk adım, görüntü kalitesini arttırmak ve istenmeyen gürültüyü kaldırmak için ham görüntüleri önceden işlemektir (Munir ve ark., 2019). Önerilen yöntem, karmaşıklığı ve sistemin kapsamlı parametre kümesini azaltmak için büyük görüntüler yerine küçük görüntü yamalarıyla ile çalışmaktır. Ayrıca, parametrelerin eğitimi için gereken süre azaltılmıştır. Orijinal görüntü 460x700 yüksek çözünürlüğe sahip olduğundan, boyutlarını 230x350 seviyesine azaltmak için bikübik enterpolasyon uygulanmıştır. Bu adım, gereksiz pikselleri ortadan kaldırmak ve hesaplama yükünü azaltmak için gereklidir (Dabeer ve ark., 2019). Daha sonra, küçük boyutlu yamalar 128x128, her görüntü için 28 yama ile sonuçlanan yamalar arasında %25 örtüşme ile kayan pencere stratejisi ile çıkarılmıştır. Tam slayt görüntüler yerine küçük yamaların kullanılması, CNN yapılarının karmaşıklığını ve eğitim süresini azaltmak için araştırmacılar tarafından yaygın olarak kullanılmaktadır (Spanhol ve ark., 2016; Song ve ark., 2017; Spanhol ve ark., 2017; Gour ve ark., 2020). Önerilen model, eğitim kümesinin ortalama görüntüsünü her girdi görüntüsünden çıkararak veri normalleştirmeyi gerçekleştirecektir.

4.1.2. DWT bölümü

128x128 boyutundaki yama görüntüleri, 2-D DWT'den geçirilmiş ve sadece yaklaşık alt bantlar seçilmiştir. Yaklaşık alt bant, görüntüdeki bilgilerin çoğunu içerir ve birçok uygulamada orijinal görüntü pikselleri yerine kullanılmaktadır. Yama görüntülerinden sadece yaklaşık alt bandı kullanarak, boyutun 64x64'e düşürülmesi ile sistemin zaman tüketiminin azaltmasına yardımcı olduğu görülmüştür. Daubechies dalgacık kullanarak veri kümesinden bir örnek görüntü üzerinde 2-D DWT gerçekleştirilmesinin bir örneği Şekil 4.2'de gösterilmektedir.



(a) **(b)**



(c)

Şekil 4.2. Veri kümesinden DWT'nin 2-D ayrıştırılmasına bir örnek, **a)** Asıl görüntü, **b)** Görüntünün DWT temsili, **c)** DWT alt bant ayrıntıları

4.1.3. CNN bölümü

Önerilen modeldeki AlexNet yapısı, çizelge 4.1'de gösterildiği gibi toplam beş katmana sahiptir. İlk katmanda, tüm giriş kanallarında basit ilkel özellikler hesaplanırken, ardından, ardışık iki evrişimli katman arasına bir maksimum havuzlama katmanı yerleştirilmektedir. Her evrişimsel katmandan sonra bir havuzlama katmanı kullanmanın temel amacı, özelliklerin boyutluluğunu azaltmaktır. FC katmanda, nöronlar bir önceki katmanda olan tüm aktivasyonlara tam olarak bağlanacak ve sınıflandırma modelinin sonunda bir softmax işlevi kullanılacaktır. Bu modelde sunulan CNN katman mimarisi çizelge 4.1'de ayrıntılı olarak gösterilmektedir. Özellikleri çıkarmak için 5 x 5 filtre boyutunda olan üç evrişimsel katmana sahiptir. Modellerdeki tüm evrişimli katmanları maksimum bir havuzlama katmanı izlemektedir (Nannia ve ark., 2020).

Çizelge 4.1. CNN AlexNet Katmanları

CNN Katmanı	1. Katman	2. Katman	3. Katman	4. katman	5. katman
Katman Türü	**Evrişimsel + Havuzlama**	**Evrişimsel + Havuzlama**	**Evrişimsel + Havuzlama**	**FC**	**FC**
Evrişimsel Özellik haritaları	32	32	64	-	-
Evrişimsel Filtre Boyutu	5 x 5	5 x 5	5 x 5	-	-
Evrişimsel Çıktı Boyutu	60 x 60 x 32	27 x 27 x 32	11 x 11 x 64	-	-
Evrişimsel Stride	1 x 1	1 x 1	1 x 1	-	-
Havuzlama Tipi	Max	Ortalama	Ortalama	-	-
Havuzlama Boyutu	3 x 3	3 x 3	3 x 3	-	-
Havuzlama Stride	2 x 2	2 x 2	2 x 2	-	-
Dolgu Boyutu	2 x 2	2 x 2	2 x 2	-	-
Havuzlama Çıktı Boyutu	31 x 31 x 32	15 x 15 x 32	7 x 7 x 64	-	-
TB Giriş Boyutu	-	-	-	3136	64
TB Çıkış Boyutu	-	-	-	64	2

SGD optimizasyon yöntemi, ağ parametrelerini güncellemek için kullanılır. Stokastik gradyan basit ve etkili olmasına rağmen, model hiper parametrelerinin, özellikle optimizasyonda kullanılan öğrenme oranının, dikkatlice ayarlanmasını gerektirir. CNN eğitiminde düşük öğrenme oranı kullanılırsa, sistem yavaş bir şekilde birleşirken, daha büyük değerlerde sampmalara yol açabilir. Genellikle, araştırmacıların ağın daha hızlı yakınlaşmasını ve daha iyi performans elde etmesini sağlamak için çeşitli boyutlarda öğrenme oranlarını denemeleri gerekmaktedir. Bu model başlangıçta 100'lük bir mini-batch boyutu, 10^{-2} bir öğrenme oranı, 0.9'lük bir momentum katsayısı, 4^{-5} ağırlık azalması ve hem CNN hem de farklı büyütme faktörlerine sahip önerilen DWT tabanlı CNN yöntemleri için maksimum 5 epoch kullanılmıştır. Ardından önerilen model için farklı stratejiler sunulmuştur.

FC katmanın, çıktı katmanında bir sınıflandırıcı kullanır. Önerilen model, softmax, CNN yapısının FC katmanında sınıflandırıcı olarak kullanılmıştır. CNN'nin çıktısı, girdi yama görüntüsünün sınıf kararıdır. Bu noktada, her bir görüntü için sonuçlar yama sonuçları birleştirilerek gerçekleştirilebilir. Bu strateji, pratikte

sınıflandırma performansı ile hesaplama maliyeti arasında makul bir denge gösterme nedeniyle, eğitim için de kullanılmaktadır.

4.2. Model 2: SVM Sınıflandırıcı Modeli ile Önceden Eğitilmiş AlexNet

Bu modelde, bir CNN olan orijinal AlexNet yapısı kullanılmıştır (Krizhevsky ve ark., 2012). AlexNet, en çok çalışılan CNN olarak (Shin ve ark., 2016) ve aynı zamanda hız ve doğruluk arasındaki uygun ödünleşmeler nedeniyle bu çalışmada kullanılırmıştır (Chatfield ve ark., 2014). AlexNet'in önceden eğitilmiş sinir ağı yapısı, aktarım öğrenimi kullanılarak test edilmiştir. Daha sonra, önceden eğitilmiş AlexNet ağına dayalı olarak sınıflandırma için özellik çıkarma işlemi gerçekleştirilmiştir. Ağ parametreleri, geri yayılımlı SGD yöntemi kullanılarak güncellenmektedir (Bottou, 2012). Derin özellik çıkarma, bir tür aktarım öğrenimi olarak düşünülebilir. AlexNet modelinin aktivasyon katmanları, önceden eğitilmiş AlexNet modeline ince ayar yapmak yerine özellik vektörlerini çıkarmak için kullanılabilir. Bu çalışmada ele alınan özellikler, 4096 boyutlu özellik vektörleri üreten önceden eğitilmiş AlexNet modelinin FC6 katmanından çıkarılmaktadır. Ardından, önerilen modelin verimliliğini artırmak için özellik vektörleri SVM sınıflandırıcısı ile birlikte kullanılmıştır.

4.2.1. Ön işleme bölümü

BreakHis veri kümesinin tüm görüntüleri renkli ve 460x700 piksel boyutundadır. Daha önce, AlexNet yapısıyla kolaylık sağlamak için tüm giriş görüntüleri başlangıçta boyut 227x227 olarak yeniden boyutlandırılıyordu (Deniz ve ark., 2018; Wenzhong ve ark., 2020). Yeniden boyutlandırma, görüntülerin ana özelliklerini etkiler ve bazı pikselleri atarak piksel bilgilerini değiştirir. Yeniden boyutlandırma işlemi yerine yama stratejisi kullanmak, meme kanseri görüntülerinin orijinal içeriğini koruyacaktır. BreakHis veri kümsinin görüntülerinin orijinal boyutu 460x700 olduğundan, önerilen yöntem, yeniden boyutlandırmak yerine orijinal görüntülerden 227x227 boyuttaki görüntü yamalarının çıkarılmasını önermektedir. Sonuç olarak, BreakHis veri kümesinin her bir görüntüsünden 227x227 boyutta 6 farklı yama görüntüsü çıkarılmıştır.

4.2.2. Önceden eğitilmiş AlexNet bölümü

AlexNet, ImageNet Veri Kümesinden yaklaşık 1.2 milyon görüntü üzerinde eğitim almıştır (http://image-net.org/index). AlexNet yapısı, 1000 farklı nesnenin sınıflandırılması için sekiz katmana sahiptir. Bu nedenle model, çeşitli uygulamalardan görüntüleri sınıflandırmak için zengin bir özellik sunumu kazanmıştır. Önceden eğitilmiş AlexNet'ten gelen ilk beş katman, evrişimsel katmanlar, sabit özellik çıkarıcılar olarak kaydedilmektedir. Buna karşılık, FC katmanlar olan son üç katman, sadece iki sınıfı sınıflandırabilen yeni bir katman kümesiyle değiştirilmektedir (Abd Almisreb ve ark., 2018). FC son katman, 1000 sınıfa bağlanır ve ağın geri kalanı bir özellik çıkarıcı olarak kabul edilir.

4.2.3. Aktarım öğrenim bölümünü

Önceden eğitilmiş AlexNet modelinden ilk katmanları, kenarlar gibi görüntülerden düşük seviyeli özellikleri temsil ederken, buna karşılık FC son katmanlar, görüntü sınıflandırması için daha yüksek düzey özellikleri temsil eder. Önceden eğitilmiş AlexNet CNN'nin ilk katmanları, BreakHis veri kümesi için sabit özellik çıkarıcı olarak tutulmaktadır. Aktarım Öğrenmenin ilk adımı, önceden eğitilmiş AlexNet'teki son üç katmanı, 2-sınıfı sınıflandırabilen bir dizi katmanla değiştirmektir. FC katmanların (FC6 ve FC7) ilk iki katmanından gelen özellikler sıklıkla sınıflandırma problemlerinde kullanılmıştır. Bu katmanlar, giriş görüntüsünün sınıfına karar vermek için SVM sınıflandırıcısı ile kullanılabilen 4096 özellik vektörü içerir (Deniz ve ark., 2018). Bu bölümde, 4096 boyutlu özellik vektörleri üreten önceden eğitilmiş AlexNet modelinin FC6 katmanından çıkarılan özelliklerdir.

AlexNet'teki 1000 çıkış nöronlarının uzunluğu, model 2 çalışmasındaki, sınıfların sayısına eşit olmadığından, karşılık gelen softmax ve sınıflandırma katmanını gözden geçirilmesi gerekiyordu. Aktarım öğrenme şemasında, iki nöron, bir softmax katmanı ve sadece iki sınıf (iyi huylu ve kötü huylu) içeren yeni bir sınıflandırma katmanı ile rastgele başlatılmış (randomly initialized) FC yeni bir katman kullanılmıştır.

Daha sonra eğitim seçenekleri belirlenmiştir. Eğitimden öncelikle şu üç incelik kontrol edilmiştir. İlk olarak, bir aktarım öğrenimi için tüm eğitim epoch'ı küçük olmalıdır. Bu çalışmada, eğitim epoch sayısı 5 olarak belirlenmiştir. İkinci olarak, küresel öğrenme oranı 10^{-2} seçilerek ve sinir ağının ilk kısımları önceden eğitilmiş olduğundan, öğrenmeyi yavaşlatmak için küçük bir değere ayarlanmıştır. Üçüncüsü ise, deneyler, mini-batch boyutu 100, öğrenme oranı 10^{-4}, momentum katsayısı 0.9, ağırlık azalması 4^{-5} ve maksimum 20 epoch'a, SGD yöntemi kullanılarak gerçekleştirilmiştir.

4.2.4. SVM bölümü

Bu bölümde görüntü yamaları, özelliklerine göre iyi huylu veya kötü huylu olarak sınıflandırılmıştır. SVM, meme kanseri sınıflandırma probleminde yüksek sınıflandırma oranları elde ettiği için kullanılmaktadır. SVM, verileri sınıflandırma için analiz eden bir makine öğrenme algoritmasıdır ve verileri kategorilere göre sıralayan denetimli bir öğrenme yöntemidir. SVM'in amacı, yüksek boyutlu bir özellik uzayında hiper düzlemleri ayırarak hesaplama açısından verimli bir öğrenme yöntemi formüle etmektir. İki veri kümesinin sınıflandırabilen birçok hiper düzlem vardır. Seçilmesi gereken optimum hiper düzlem, maksimum mesafeye sahip olandır. Kenar boşluğu, sınırın bir veri noktasına ulaşmadan önce artabileceği genişlik olarak tanımlanır. Destek vektörleri, kenarları yukarı itilen veri noktaları olarak kabul edilir (Ragab ve ark., 2019). CNN'nin çıktısı, girdi yama görüntüsünün sınıf kararıdır. Son olarak, her bir görüntü için sonuçlar, yama sonuçları birleştirilerek gerçekleştirilmiştir.

4.3. Model 3: SVM Sınıflandırıcı ile Önceden Eğitilmiş Beş CNN'nin Modelinin Birleştirilmesi

Üçüncü modelde, AlexNet, GooglNet, ResNet50, VGG-16 ve InceptionV3 olmak üzere beş CNN yapısından oluşan bir maksimum seçim kuralı gerçekleştirilmiştir. İlk olarak, beş CNN yapısının önceden eğitilmiş sinir ağı yapısı, aktarım öğrenimi kullanılarak test edilmiştir. Özellikler, önceden eğitilmiş modellerin FC son katmanından çıkartılmaktadır. Ağ parametreleri, geri yayılımlı SGD yöntemi kullanılarak güncellenmiştir. Ardından, önerilen modellerin verimliliğini artırmak için özellik vektörleri SVM sınıflandırıcısı ile birlikte kullanılmıştır. Son olarak, beş

modelin sonuçları, modelin doğruluğunu artırmak için maksimum seçim kuralı kullanılarak birleştirilmiştir. Yama düzeyindeki her CNN modelinin çıktı kararı, seçim için dikkate alınacaktır. Beş CNN yapısına sahip olunduğu için, bu sınıflandırıcılardan en az üç tanesi aynı sonuç veya kararda olursa, birleşik modelin çıktı kararı yama görüntülerine karar verecek ve bunları sınıflandıracaktır.

4.3.1. Ön işleme bölümü

BreakHis veri kümesinin tüm görüntüleri renkli ve 460x700 piksel boyutundadır. Önerilen yöntem, CNN yapısına göre orijinal görüntülerden (mxm) boyuttaki görüntü yamalarının çıkarılmasını önermektedir. Burada m, her CNN yapısının girdi görüntü boyutuna göre farklılık gösterir. AlexNet yapısı için 227x227, GoogleNet, VGG-Net ve ResNet50 yapıları için 224x224 ve InceptionV3 yapısı için 299x299 boyuttaki görüntü yamaları çıkarılmıştır. Sonuç olarak, BreakHis veri kümesinin her bir görüntüsünden 6 farklı (mxm) boyutta yama görüntüsü çıkarılmıştır.

4.3.2. Veri arttırma bölümü

Sağlam olması için, bir örüntü tanıma modelinin belirli bir etiketin çeşitli girdileriyle değişmeyen tahminler yapması gerekmektedir. Basit bir yaklaşım, veri toplama ve etiketlemedeki zorluklara bakılmaksızın, çok sayıda çeşitliliğe sahip çok sayıda eğitim örneği toplamaktır. Bu sorunu çözmenin başka bir yolu, etiket korumalı örnek kopyalar eklenerek elde edilen veri artırmadır. Veri artırma, gerçek verilere çevirme ve döndürme gibi dönüştürmeler uygulayarak yapay olarak yeni örnek görüntüler oluşturmak demektir. Mamografi görüntüleri için yaygın veri büyütme teknikleri yatay olarak çevirme, döndürme (90, 180 ve 270 derece), titreme ve rastgele ölçeklendirmedir. Bu tür veri arttırma, ilgili eğitim örneklerini üretir, çünkü tümörler çeşitli yönelim ve boyutlar sergileyebilir. Böylece, büyütme teknikleri kitlelerin altında yatan patolojiyi değiştirmez. Bu modelde, veri büyütme tekniği (90, 180 ve 270 derece) rotasyonlar kullanılarak uygulanmıştır. Ön işleme ve arttırma bölümlerinden sonra her görüntüden toplam 24 yama çıkarılmıştır.

4.3.3. Önceden eğitilmiş CNN bölümü

Bu bölümde, eğitim ve ince ayar stratejileri için beş spesifik CNN mimarisi türü değerlendirilmiştir. AlexNet, GoogleNet, VGG-Net, ResNet50 ve InceptionV3 modelleri, ImageNet Veri Kümesinden yaklaşık 1.2 milyon görüntü üzerinde eğitilmiştir. Son yıllarda, bu iyi bilinen mimarilerin tümü, ImageNet Büyük Ölçekli Görsel Tanıma Mücadelesi sınıflandırma kıyaslamasının kazananları olmuşlardır. Bu mimarileri histopatolojik meme görüntülerinin farklı büyütme faktörleri ile sınıflandırılması için uyarlanmış ve performansları karşılaştırılmıştır. Önceden eğitilmiş tüm CNN'lerden ilk katmanlar, sabit özellik çıkarıcılar olarak kaydedilmiştir. FC son katman 1000 sınıfa bağlanmış ve ağın geri kalanı bir özellik çıkarıcı olarak kabul edilmiştir.

4.3.4. Aktarım öğrenim bölümünü

CNN yapıları, ilk olarak 1000 sınıfın sınıflandırılması için 1.2 milyon doğal görüntü içeren ImageNet veri kümesi kullanılarak önceden eğitilmiştir. Daha sonra, son FC katman, iki sınıfın sınıflandırılması için yeni bir katmanla değiştirilmiştir (iyi huylu ve kötü huylu kitleler). FC katmanı iki sınıfa göre ayarladıktan sonra CNN'ı yeniden eğitmek için bazı parametrelerin ayarlanması gerekir. Bunun için maksimum epoch sayısı ve temel öğrenme hızı sırasıyla 5ve 10^{-4} olarak ayarlanmıştır. Momentum katsayısı 0.9 ve ağırlık azalması 4^{-5} olarak ayarlanmıştır. Bu konfigürasyonlar, parametrelerin tıbbi meme kanseri teşhisi için ince ayarlı olmasını sağlamak içindir. Diğer parametreler ise varsayılan değerlere göre ayarlanmıştır. Kullanılan optimizasyon algoritması, mini-batch boyutu 100 olan SGD yöntemidir.

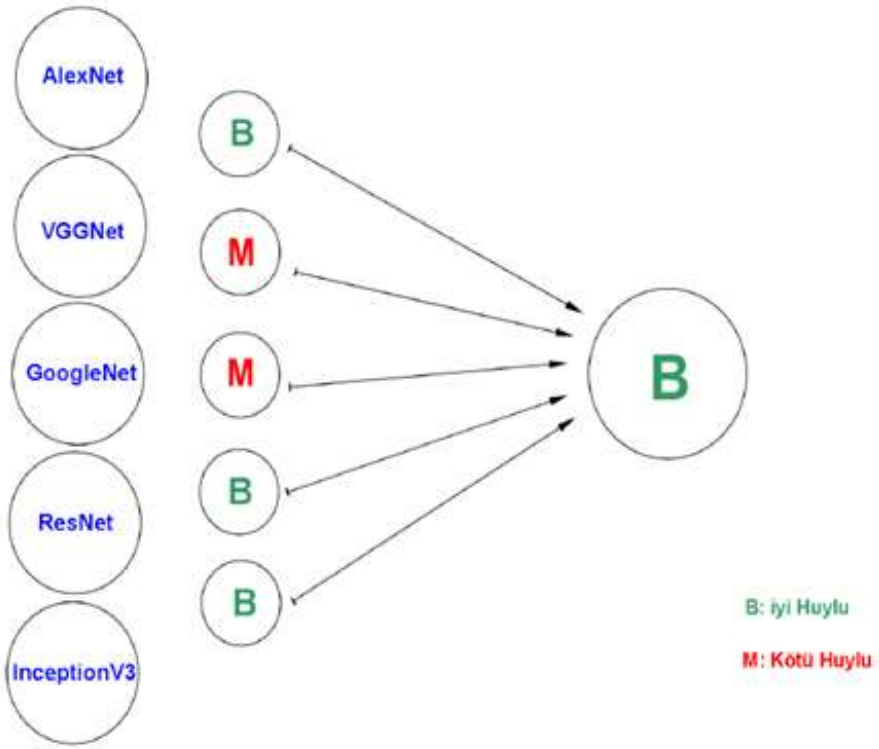
4.3.5. SVM bölümü

Bu bölümde görüntü yamaları, özelliklerine göre iyi huylu veya kötü huylu olarak sınıflandırılır. SVM, meme kanseri sınıflandırma probleminde yüksek sınıflandırma oranları elde ettiği için kullanılmaktadır. SVM, verileri sınıflandırma için analiz eden bir makine öğrenimi algoritmasıdır ve verileri kategorilere ayıran denetimli bir öğrenme yöntemidir. SVM'nin amacı, yüksek boyutlu bir özellik uzayında hiper düzlemleri

ayırarak hesaplama açısından verimli bir öğrenme yöntemi formüle etmektir (Ragab ve ark., 2019). CNN'nin çıktısı, girdi yama görüntüsünün sınıf kararıdır. Son olarak, her bir görüntü için sonuçlar yama sonuçları birleştirilerek gerçekleştirilebilecektir.

4.3.6. Maksimum seçim kuralı bölümü

Her ağ farklı CNN yapısı (aynı sayıda yama) ile eğitildiğinden, her sınıflandırıcı kendi temsilini oluşturur. Buda sınıflandırıcıların kombinasyonu yoluyla bu tür sonuçları iyileştirme avantajını verecektir. Daha önce belirtildiği gibi, CNN'ler, ağların çıktılarını gerideki olasılıkların tahmini olarak yorumlama izin veren, SVM sınıflandırıcı ile FC son bir katmana sahiptir. Bu nedenle farklı kombinasyon kuralları uygulanabilir. Bu çalışmada, maksimum seçim kuralı kullanılarak beş CNN yapısını birleştirirken elde edilen sonuçlar sunulmuştur. Yama düzeyindeki her CNN modelinin çıktı kararı seçim için dikkate alınacaktır. Beş CNN yapı olduğundan, bu sınıflandırıcılardan en az üçü aynı kararda olursa, birleşik modelin çıktı kararı yama görüntülerine karar verecek ve bunları sınıflandıracaktır. Birleşik model, yama görüntülerini sedece bir CNN yapısı yerine, beş CNN yapısına bağlı olarak sınıflandırabilecektir. Sonuç olarak, birleşik model sağlam olacak, öte yandan, bir veya iki CNN modelinin meme kanseri yama görüntülerinin yanlış tahminlerini göz ardı edecektir. Maksimum seçim kuralı tekniğinin akış şemesının bir öğrneği aşağıdaki şekil 4.3'te gösterilmektedir.



Şekil 4.3. Maksimum seçim kuralı tekniğinin akış şemesının bir öğrneği

5. DENEYSEL SONUÇLAR VE TARTIŞMA

5.1. Performans Ölçüsü

Literatürde (Spanhol ve ark., 2015; Spanhol ve ark., 2016; Jadoon ve ark., 2017; Song ve ark., 2017; Spanhol ve ark., 2017; Sudharshan ve ark., 2019; Gour ve ark., 2020) araştırmalar tarafından sunulan tanıma oranı, görüntü veya hasta düzeyinde değerlendirilmiştir. Bu durum görüntü düzeyi, CNN'nin basit görüntü sınıflandırma doğruluğunu sağlamaktadır. Görüntü düzeyinde tanıma oranı, aşağıdaki denklem 5.1 ile hesaplanabilir:

$$Görüntü\ Tanıma\ Oranı\ = \frac{N_{DS}}{N_{Toplam}} \tag{5.1}$$

N_{Toplam} , test kümesi ile ilgili kanser görüntülerinin sayısıdır ve N_{DS} doğru şekilde sınıflandırılmış kanser görüntülerinin sayısıdır.

Hasta bazında karar verebilinmesini sağlamak için tanıma oranı hasta düzeyinde hesaplanır. Ve önceden hasta skoru denklem 5.2 ile hesaplanır:

$$hasta\ skoru = \frac{N_{DS}}{N_h} \tag{5.2}$$

ve küresel hasta tanıma oranı denklem 5.3 ile tanımlanır:

$$Hasta\ Tanıma\ oranı = \frac{\sum hasta\ skoru}{Toplam\ hasta\ sayısı} \tag{5.3}$$

N_h, h hastası için, ilgili kanser görüntülerinin sayısıdır ve N_{DS} her hastaya yönelik doğru şekilde sınıflandırılmış kanser görüntülerinin sayısıdır.

Hasta düzeyinde iyi bir sonuca sahip olmak, bu sistemin tüm hasta görüntülerini doğru bir şekilde sınıflandırdığı anlamına gelmediğinden, önceki iki ölçümün yanı sıra yama görüntüsü tanıma oranını da dikkate almak oldukça önemlidir. Yama görüntüsü düzeyindeki tanıma oranı aşağıdaki denklem 5.4 ile kolayca hesaplanabilir:

$$Yama\ Görüntüsü\ Tanıma\ Oranı = \frac{N_{pDS}}{N_{pToplam}} \quad (5.4)$$

$N_{pToplam}$, test kümesi ile ilgili kanser yama görüntülerinin sayısıdır ve N_{pDS} doğru şekilde sınıflandırılmış kanser yama görüntülerinin sayısıdır.

5.2. Model 1 için Deneysel Sonuçlar

Deney platformu, Intel Core i7-7820 CPU ve 32 GB belleğe sahip MacBook Pro kullanılarak, önerilen CNN modeli BreaKHis veri kümesi kullanılarak eğitilmiştir (Spanhol ve ark., 2015). Amaç, görüntüleri yama, görüntü ve hasta düzeylerinde iyi huylu veya kötü huylu vakalar halinde sınıflandırmaktır. Deneyler, hasta düzeyinde beş kat çapraz doğrulama kullanılarak değerlendirilmiştir. Veri kümesi, çapraz doğrulama için beş bölüme ayrılmış ve her bölüm, görüntülerin %20'sini içermektedir. Model, eğitim kümesini temsil eden dört bölüm kullanılarak eğitilmiş ve test kümesini temsil eden kalan bölüme uygulanmıştır. Deneyler, her bir bölünme test kümesi olarak görev yapana kadar beş kez tekrarlanmış, performans beş ölçümün doğruluklarının ortalaması kullanılarak ölçülmüştür. Sınıflandırıcı, hasta bölme işlemini tüm hastalar kapsanmış olmak üzere, veri kümesindeki hastaları dengeli bir şekilde böler. Önerilen yaklaşım, 100 mini-batch boyutu, 10^{-2} öğrenme oranı, 0.9 momentum terimi, 4^{-5} ağırlık azalması ve maksimum 1 epoch ile SGD yöntemi kullanılarak aynı veri kümesi deney kurulumuna sahip (Spanhol ve ark., 2016) mevcut bir yaklaşımla karşılaştırılmıştır. Yaklaşımdaki yazarlar (Spanhol ve ark., 2016) sonuçlarını çapraz doğrulama yöntemi kullanmadan 5 testin doğruluğunu kullanarak kaydetmişlerdir. Farklı yöntemleri, iki veri bölme yöntemi kullanarak karşılaştırıldı; biri rasgele bölme yoluyla beş deneme, diğeri ise çapraz doğrulama yöntemi kullanarak yapıldı. Çizelge 5.1'de, hem CNN hem de farklı büyütme faktörlerine sahip önerilen DWT tabanlı CNN yöntemleri için çapraz doğrulamasız ve beş kat çapraz doğrulama yöntemini kullanarak yama görüntüsü düzeyinde ortalama doğruluğu kaydedildi.

Çizelge 5.1. CNN ve DWT tabanlı CNN yöntemleri için Ortalama Doğruluk oranları ve standart sapmalar.

Veri Bölme Yöntemi	Strateji	Büyütme Faktörleri			
		40X	100X	200X	400X
Çapraz Doğrulama Olmadan	CNN	83.62 ± 1.7	77.65 ± 4.2	81.22 ± 0.5	72.69 ± 2.9
	MCNN	84.55 ± 2.5	82.77 ± 2.2	83.50 ± 2.4	75.30 ± 4.6
	Önerilen (CNN-DWT)	82.05 ± 0.5	81.25 ± 1.5	84.38 ± 0.9	77.20 ± 4.8
	Önerilen (MCNN-DWT)	85.44 ± 1.9	85.20 ± 1.7	85.98 ± 1.7	78.10 ± 2.6
5 Kat Çapraz Doğrulama	CNN	83.68 ± 1.5	78.01 ± 2.6	82.58 ± 1.5	77.57 ± 1.3
	MCNN	84.71 ± 2.1	83.15 ± 2.2	83.63 ± 0.7	81.35 ± 2.6
	Önerilen (CNN-DWT)	83.77 ± 0.7	83.50 ± 0.9	84.31 ± 1.0	80.62 ± 0.9
	Önerilen (MCNN-DWT)	**85.45 ± 0.6**	**85.44 ± 1.2**	**86.01 ± 1.2**	**81.85 ± 1.1**

Çizelge 5.1'de, çapraz doğrulama yöntemi kullanılarak tüm yöntemlerin sonuçlarının daha yüksek olduğunu göstermektedir. Ayrıca, 2-D DWT'den yaklaşık alt bant kullanan önerilen MCNN-DWT yöntemi, aynı şekilde ham görüntüler kullanan aynı CNN mimarisinin sonuçlarına kıyasla tüm büyütme faktörleri için yama görüntü düzeyinde en iyi ortalama doğruluğunu vermektedir. Temel olarak, DWT özelliklerinin kullanımı ile elde edilen sonuçların, genellikle ham görüntüler ile elde edilen sonuçlardan daha iyi sonuç vereceği belirlenmişitr. Eğitim sürecinde dalgacık dönüşümünün kullanılması ile sistemin aşırı uyumunu, tek başına CNN kullanımından daha iyi önlediği görülmüştür. Ayrıca dalgacık özelliklerinin kullanılması, histopatolojik görüntülerin doğal karmaşıklığını azaltarak görüntülerin kalitesini artırmıştır.

5.2.1. SGD yönteminin parametrelerinin araştırılması

SGD ağ parametreleri, eğitim aşamasının erken evrelerinde sistemin performansını araştırmak için güncellenmiştir. Mini-batch boyutunu değiştirmenin etkisi, sabit bir öğrenme oranıyla değerlendirilebilir. Ardından, dinamik öğrenme oranına sahip adım planlayıcı (step scheduler) gerçekleştirilmiştir. Mini-batch boyutu eğitim numunelerinin sayısını eşit olarak bölmezse, ağın her epoch'ta bazı eğitim verilerini atacağını bilmek önemlidir. Bu nedenle, her seferinde aynı verilerin atılmasını önlemek için veri kümesi her epoch'ta karıştırılmıştır. Her kattaki numune sayısı farklı olduğu için, eğitim numunelerinin sayısını eşit olarak bölen bir mini-batch boyutu seçmek imkansızdır. Bu nedenle, herhangi bir parametreyi değiştirmeden önce ağ her seferinde beş epoch için eğitilmiştir.

Ayrıca, öğrenme hızının, sinir ağını yapılandırmak çok önemli bir hiper parametre olduğundan, öğrenme hızının model performansı üzerindeki etkileri de dikkate alınmıştır. Önceki çalışmaların çoğu, eğitim aşamasında öğrenme oranının değiştirilmesinin sistem performansını etkilediğini göstermiştir. Tezin bu kısmında dinamik bir öğrenme oranı stratejisi önerilmiş ve yürütülmüştür. Adım planlayıcı, SGD öğrenme oranlarını programlamak için en çok kullanılmaktadır. Adım planlayıcı'da, dört hiper parametrenin dikkatlice ayarlanması gerekmektedir. Bunlar; başlangıç öğrenme hızı, eğitim epoch'ları, azalma aşamaları ve azalma oranıdır. Belirli bir faktörle çarparak, belirtilen her epoch sayısında, öğrenme oranını güncellenmiştir.

Mini-batch boyutunu değiştirmenin araştırılması için, üç farklı strateji test edilmiş ve farklı büyütme faktörleri kullanılarak karşılaştırılmıştır. İlk stratejide, mini-batch boyutu 10^{-2} öğrenme oranıyla her beş epoch'ta bir, 100 olarak sabitlenmiştir. İkinci stratejide, mini-batch boyutu 100 değeriyle başlatılmış ve daha sonra 10^{-2}öğrenme oranıyla her beş epoch'ta bir 25 azaltılmıştır. Üçüncü stratejide ise, mini-batch boyutu her beş epoch'ta bir 50 artırılmıştır. Daha sonra, iki ek strateji test edilmiş ve farklı büyütme faktörleri kullanılarak dinamik öğrenme oranı için karşılaştırılmıştır. Dördüncü stratejide, adım planlayıcı 10^{-2}'den başlayarak dinamik öğrenme oranını kullanmış ve ardından 100'lük sabit bir mini-batch boyutu ile her beş epoch'ta bir faktör 10^{-1} düşürülmüştür. Beşinci strateji ise, mini-batch boyutunu her beş epoch'ta bir 50 artırarak aynı adım planlayıcıyı kullanmıştır. Çizelge 5.2 - 5.6'da sırasıyla her bir strateji için tüm büyütme faktörlerinin sonuçları verilmiştir.

Çizelge 5.2. MCNN-DWT yöntemi için sunulan Ortalama Tanıma Doğruluğu (Birinci Strateji)

BF	Maksimum Epoch	Mini-batch Boyutu	Öğrenme oranı	Tanıma Oranı		
				Yama	Görüntü	Hasta
40X	5	100	10^{-2}	81.54	82.68	84.06
	10	100	10^{-2}	84.27	85.52	**87,99**
	15	100	10^{-2}	82.58	83.52	86.03
	20	100	10^{-2}	**85.73**	**87.19**	**87.99**
100X	5	100	10^{-2}	86.56	88.21	88.11
	10	100	10^{-2}	**88.37**	**89.36**	**92.03**
	15	100	10^{-2}	86.60	87.55	88.11
	20	100	10^{-2}	87.00	88.54	92.03
200X	5	100	10^{-2}	85.22	86.03	85.90
	10	100	10^{-2}	87.11	**88,20**	87.86
	15	100	10^{-2}	**87.39**	87.49	**87.99**
	20	100	10^{-2}	87.16	87.23	87.86
400X	5	100	10^{-2}	85.50	**86.81**	90.07
	10	100	10^{-2}	85.13	86.19	90.07
	15	100	10^{-2}	**85.87**	**86.78**	**90.07**
	20	100	10^{-2}	85.07	85.82	90.07

Çizelge 5.3. MCNN-DWT yöntemi için sunulan Ortalama Tanıma Doğruluğu (İkinci Strateji)

BF	Maksimum Epoch	Mini-batch Boyutu	Öğrenme oranı	Tanıma Oranı		
				Yama	Görüntü	Hasta
40X	5	100	10^{-2}	81.54	82.69	84.07
	10	75	10^{-2}	83.56	84.17	**86.03**
	15	50	10^{-2}	83.23	84.71	**86.03**
	20	25	10^{-2}	**84.06**	**85.26**	85.91
100X	5	100	10^{-2}	86.56	88.33	88.11
	10	75	10^{-2}	**88.24**	88.60	88.11
	15	50	10^{-2}	87.80	**88.92**	**92.03**
	20	25	10^{-2}	87.45	88.49	90.07
200X	5	100	10^{-2}	85.23	86.03	85.91
	10	75	10^{-2}	86.39	87.31	87.87
	15	50	10^{-2}	85.16	85.07	85.91
	20	25	10^{-2}	**87.48**	**88,17**	**92.03**
400X	5	100	10^{-2}	85.51	86.82	90.07
	10	75	10^{-2}	86.81	87.77	**92.03**
	15	50	10^{-2}	**86.96**	**88.07**	**92.03**
	20	25	10^{-2}	86.09	87.25	**92.03**

Çizelge 5.4. MCNN-DWT yöntemi için sunulan Ortalama Tanıma Doğruluğu (Üçüncü Strateji)

BF	Maksimum Epoch	Mini-batch Boyutu	Öğrenme oranı	Tanıma Oranı		
				Yama	Görüntü	Hasta
40 X	5	100	10^{-2}	81.54	82.69	84.07
	10	150	10^{-2}	**84.39**	**86.12**	**87.99**
	15	200	10^{-2}	83.72	85.79	87.87
	20	250	10^{-2}	84.27	85.64	**87.99**
100X	5	100	10^{-2}	86.56	88.33	88.11
	10	150	10^{-2}	89.00	**90.51**	92.03
	15	200	10^{-2}	88.00	88.88	89.95
	20	250	10^{-2}	**88.21**	**89.72**	**92.03**
200X	5	100	10^{-2}	85.23	86.03	85.91
	10	150	10^{-2}	86.46	87.38	89.95
	15	200	10^{-2}	86.78	87.49	**92.03**
	20	250	10^{-2}	**88.64**	**89.24**	**92.03**
400X	5	100	10^{-2}	85.51	86.82	90.07
	10	150	10^{-2}	85.83	86.86	90.07
	15	200	10^{-2}	86.21	87.37	90.07
	20	250	10^{-2}	**88.15**	**88.82**	**92.03**

Çizelge 5.5. MCNN-DWT yöntemi için sunulan Ortalama Tanıma Doğruluğu (Dördüncü Strateji)

BF	Maksimum Epoch	Mini-batch Boyutu	Öğrenme oranı	Tanıma Oranı		
				Yama	Görüntü	Hasta
40X	5	100	10^{-2}	81.54	82.69	84.07
	10	100	10^{-3}	**84.47**	**85.50**	85.91
	15	100	10^{-4}	84.44	85.20	**87,99**
	20	100	10^{-5}	84.33	85.13	**87,99**
100X	5	100	10^{-2}	86.56	88,33	88.11
	10	100	10^{-3}	88.30	89.15	**90.07**
	15	100	10^{-4}	**88.64**	**89.42**	92.03
	20	100	10^{-5}	88.46	89,37	**90.07**
200X	5	100	10^{-2}	85.23	86.03	85.91
	10	100	10^{-3}	87.83	**88.62**	**92.03**
	15	100	10^{-4}	87.90	88.61	89.95
	20	100	10^{-5}	**87,99**	88.56	89.95
400X	5	100	10^{-2}	85.51	**86.82**	**90.07**
	10	100	10^{-3}	85.05	86,38	**90.07**
	15	100	10^{-4}	**85.66**	86.59	**90.07**
	20	100	10^{-5}	85.56	86.46	**90.07**

Çizelge 5.6: MCNN-DWT yöntemi için sunulan Ortalama Tanıma Doğruluğu (Beşinci Strateji)

BF	Maksimum Epoch	Mini-batch boyutu	Öğrenme oranı	Tanıma Oranı		
				Yama	Görüntü	Hasta
40X	5	100	10^{-2}	81.54	82.69	84.07
	10	100	10^{-2}	84.27	85.52	87.99
	15	200	10^{-3}	84.91	86.72	89.95
	20	200	10^{-3}	**85.36**	**89.10**	**90.81**
100X	5	100	10^{-2}	86.56	88.21	88.11
	10	100	10^{-2}	88.37	89.36	**92.03**
	15	200	10^{-3}	88.25	89.20	90.07
	20	200	10^{-3}	**88.71**	**89.92**	**92.03**
200X	5	100	10^{-2}	85.22	86.03	85.90
	10	100	10^{-2}	87.11	88.20	87.86
	15	200	10^{-3}	88.18	89.12	89.95
	20	200	10^{-3}	**88.60**	**89.79**	**93.99**
400X	5	100	10^{-2}	85.50	86.81	90.07
	10	100	10^{-2}	85.13	86.19	90.07
	15	200	10^{-3}	86.50	87.64	**92.03**
	20	200	10^{-3}	**87.34**	**88.90**	**92.03**

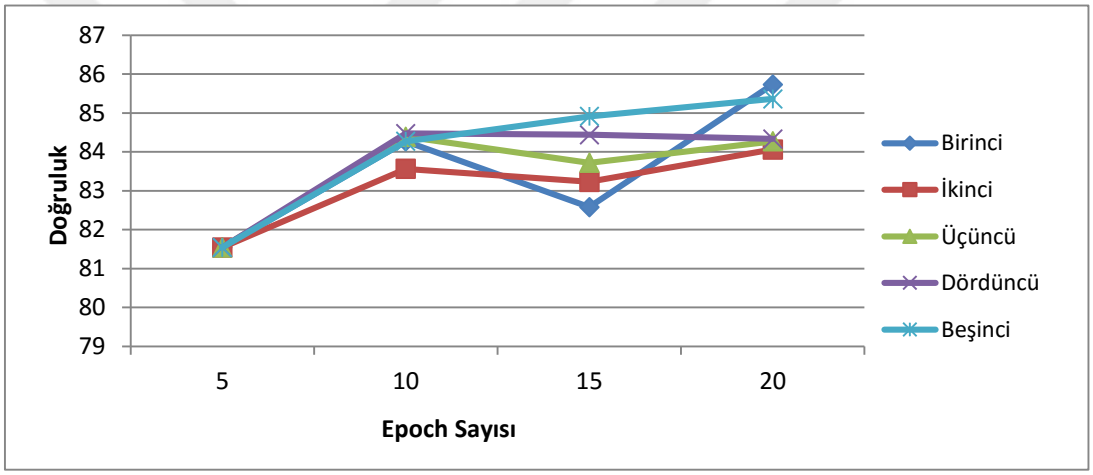
Çizelge 5.2, 10 epoch'tan sonra, doğruluk oranının 40X ve 100X büyütme faktörleri için %2 ve 200X büyütme faktörü için %1 azalmaya başladığını göstermektedir. 400X büyütme faktörü için, eylemi hakkında net bir görüş olmadan her 5 epoch'ta bir değişmeye devam ettmektedir.

Çizelge 5.3 ve 5.4'den, Mini-batch boyutunu artırmak, mini-batch boyutunu azaltmaktan daha iyi sonuçlara vermektedir. Mini-batch boyutunun artırılması tekniği, 40X büyütme faktörüne sahip görüntüler dışında farklı büyütme faktörlerine sahip tüm görüntülerin doğruluğunu artırmıştır. Doğruluk, görüntü düzeyinde çizelge 5.2'de %87.19'dan (sabit mini yığın boyutuyla) ve çizelge 5.4'de %85.64'e (artırılmış mini yığın boyutuyla) düşürülmüştür. Genel olarak, en iyi sonuçlar, eğitim aşamasının erken aşamalarında mini-batch boyutunu artırarak elde edilmiştir.

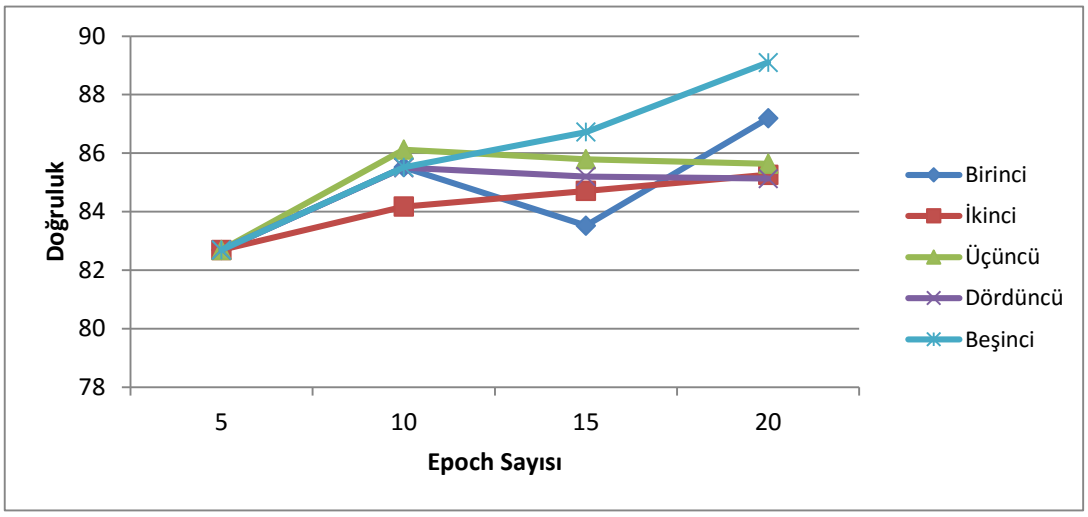
Çizelge 5.5'de, tüm büyütme faktörleri için öğrenme oranı azaltılırken doğruluk oranları 10 veya 15 epoch'tan sonra azalmaktadır. Bu sonuçlar, modelin sabit bir mini-batch numarasıyla etkili bir şekilde öğrenmesi için her 5 epoch'ta daha küçük bir öğrenme oranı kullanmanın yeterli olmadığını göstermektedir. Bu sonuçlara dayanarak, mini-batch değerini sabitlerken öğrenme oranının değiştirilmesinin tek başına doğru şekilde çalışmadığı varsayımı ortaya çıkar. Çizelge 5.6'de mini-batch

boyutunu 100 faktör ile artırarak ve her 10 epoch'ta bir önceki aynı adım planlayıcı kullanılarak farklı bir senaryo uygulanmıştır.

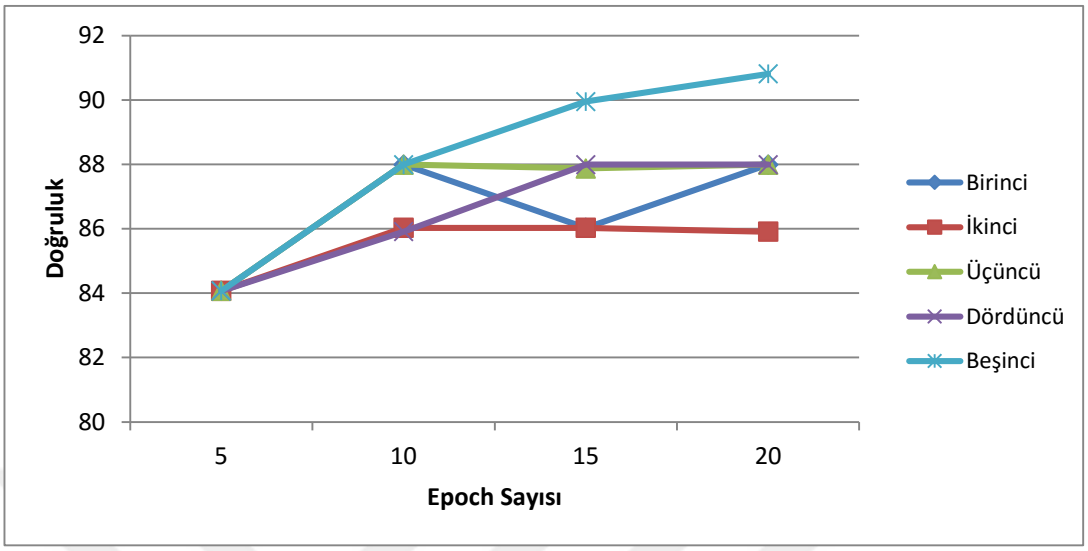
Çizelge 5.6'dan elde edilen sonuçlar, mini-batch boyutu öğrenme oranıyla bağlantılı olarak değiştiğinde, kombinasyonun daha iyi sonuçlar verdiğini göstermektedir. Doğruluk, yalnızca 20 epoch'tan sonra farklı büyütme faktörleri için görüntü düzeyinde yaklaşık %87 ile %90 arasında değişim göstermektedir. Genel olarak, CNN'nin öğrenme oranını düşürürken mini-batch boyutunu değiştirmek daha iyidir. Ayrıca, beş farklı stratejiyi farklı büyütme faktörleri ile birlikte karşılaştırmak önemlidir. 40X, 100X, 200X ve 400X büyütme faktörleri ile yama, görüntü ve hasta düzeylerinde beş farklı stratejinin kullanılmasının sonuçları sırasıyla Şekil 5.1-5.3'de gösterilmektedir.



(a)

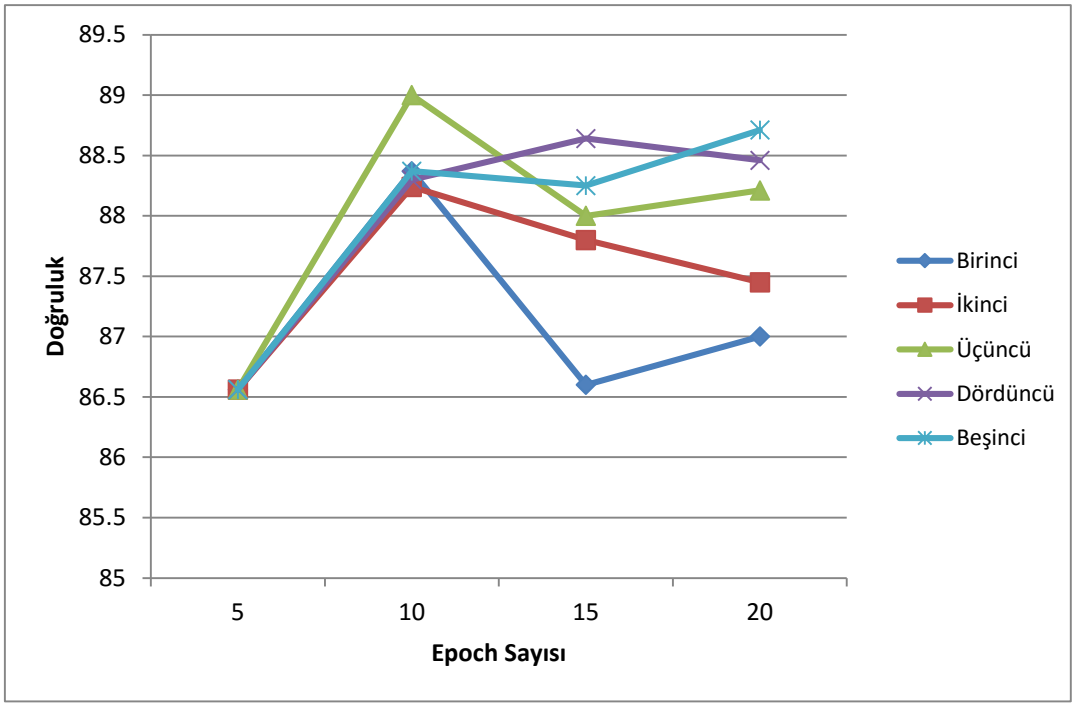


(b)

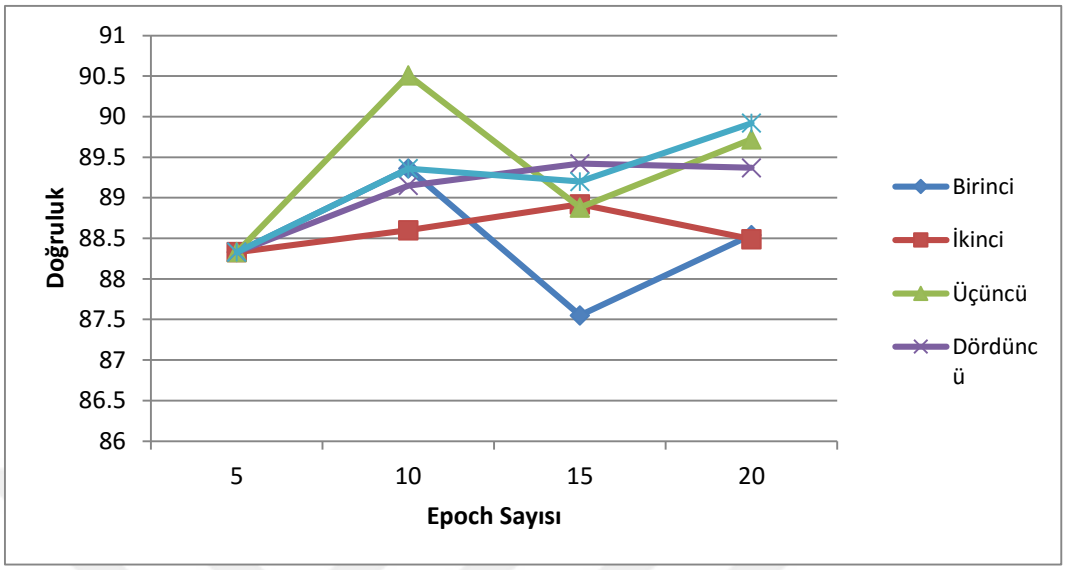


(c)

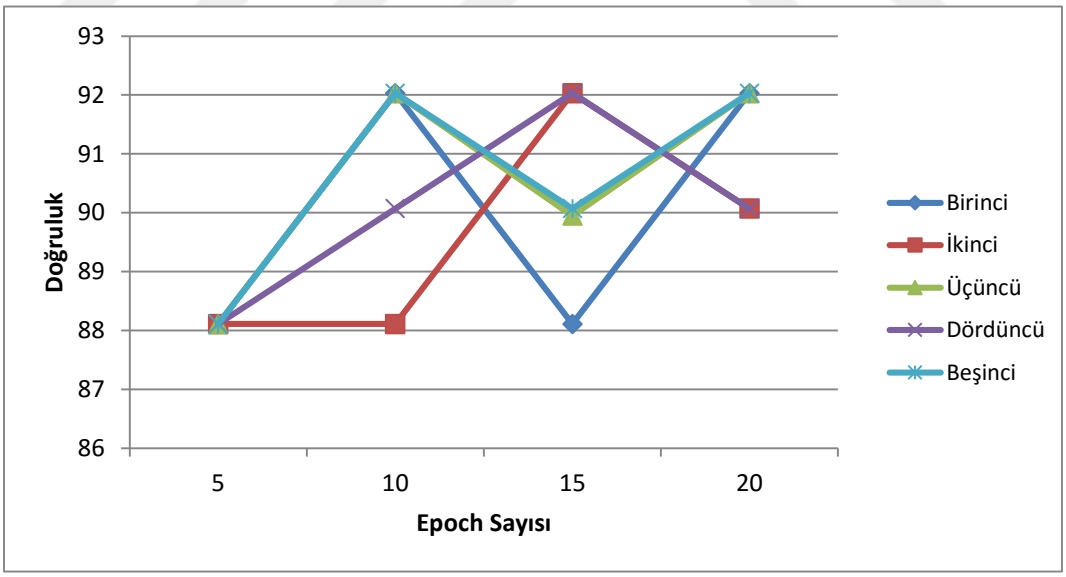
Şekil 5.1. 40X büyütme faktörü için önerilen yöntem stratejilerinin doğruluğu: (a) Yama düzeyinde (b) Görüntü düzeyinde (c) Hasta düzeyinde



(a)

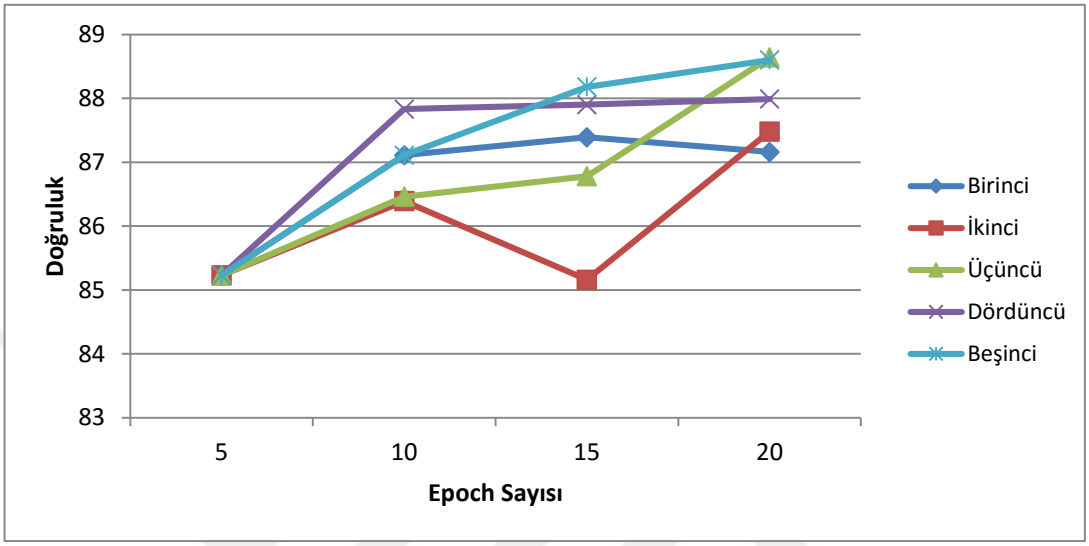


(b)

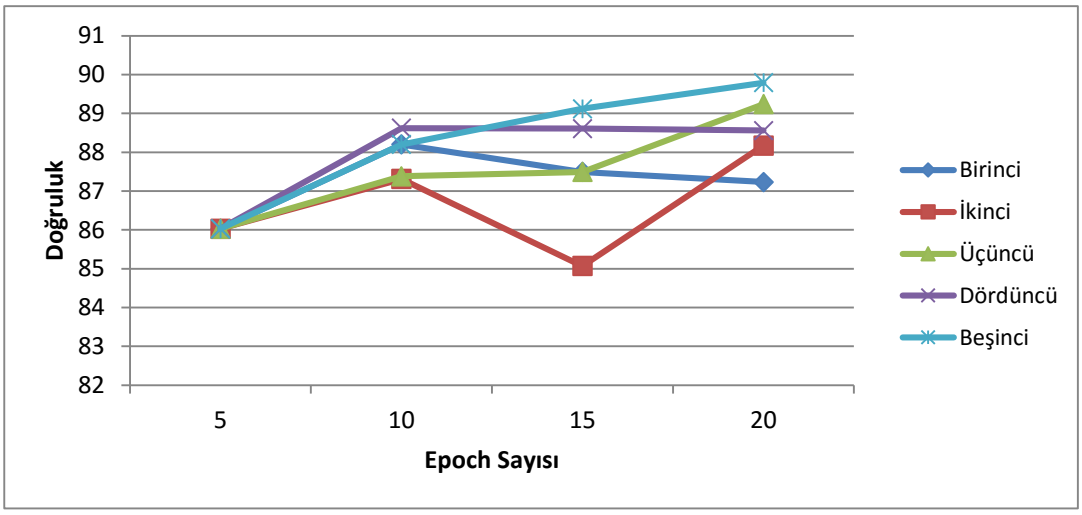


(c)

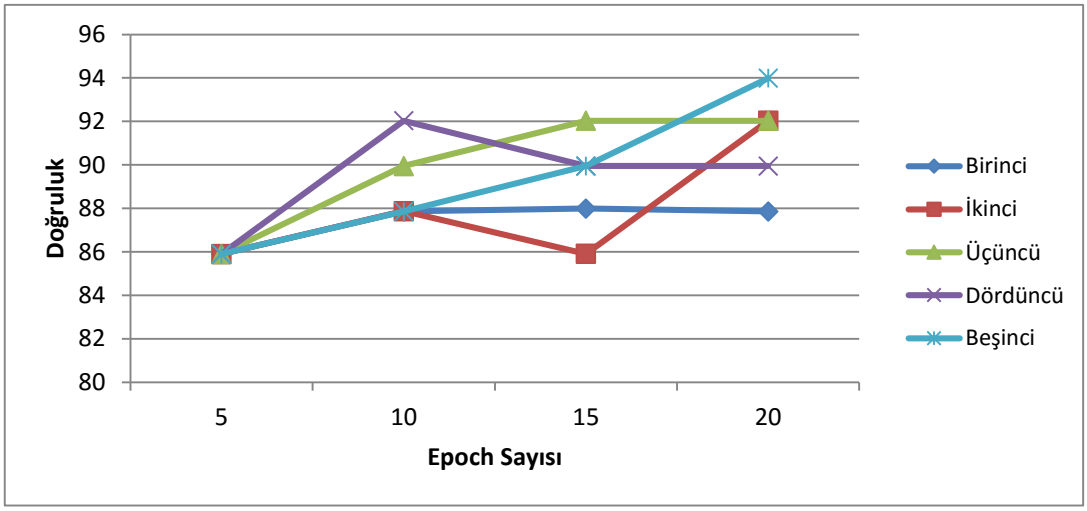
Şekil 5.2. 100X büyütme faktörü için önerilen yöntem stratejilerinin doğruluğu:
(a) Yama düzeyinde (b) Görüntü düzeyinde (c) Hasta düzeyinde


89
88
87
86
85
84
83
Doğruluk
5
10
15
20
Epoch Sayısı
Birinci
İkinci
Üçüncü
Dördüncü
Beşinci

(a)

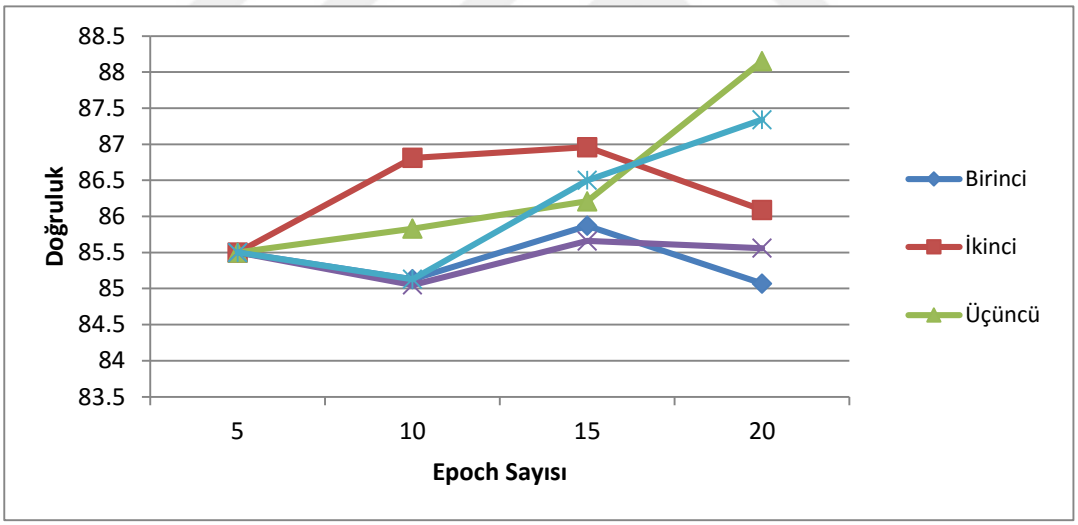

91
90
89
88
87
86
85
84
83
82
Doğruluk
5
10
15
20
Epoch Sayısı
Birinci
İkinci
Üçüncü
Dördüncü
Beşinci

(b)

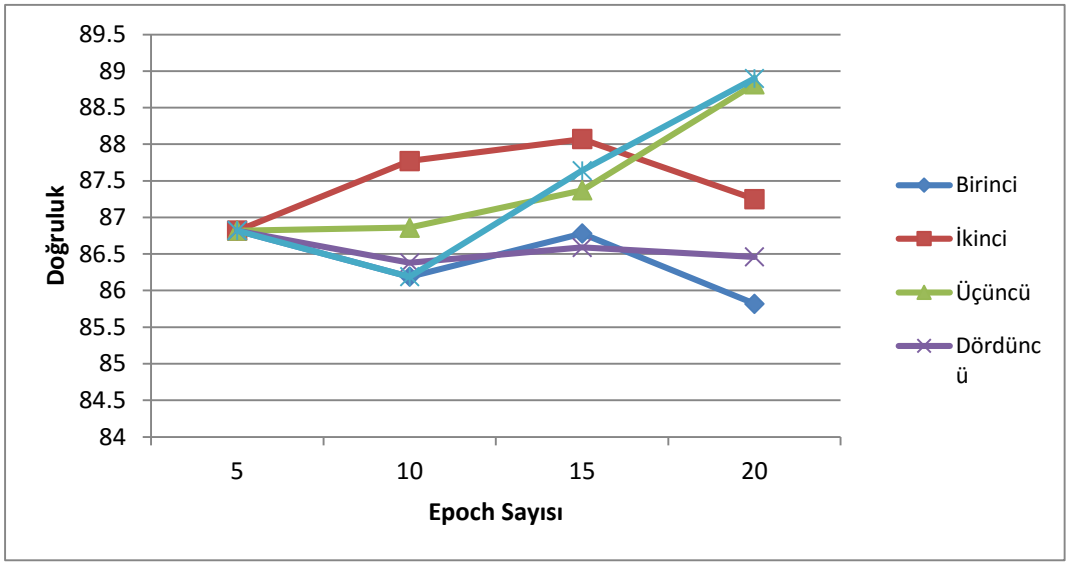


(c)

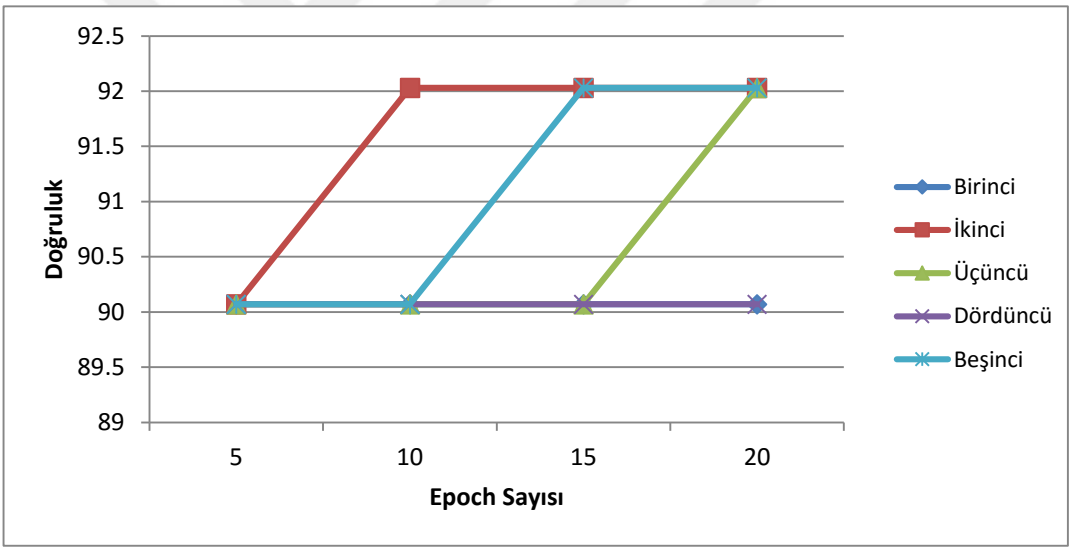
Şekil 5.3. 200X büyütme faktörü için önerilen yöntem stratejilerinin doğruluğu:
(a) Yama düzeyinde (b) Görüntü düzeyinde (c) Hasta düzeyinde



(a)



(b)



(c)

Şekil 5.4: 400X büyütme faktörü için önerilen yöntem stratejilerinin doğruluğu:
(a) Yama düzeyinde (b) Görüntü düzeyinde (c) Hasta düzeyinde

Şekil 5.1, 40X büyütme faktörü için beş farklı strateji kullanarak önerilen yöntemin doğruluğunu göstermektedir. En iyi doğruluk, artan mini-batch boyutu ile dinamik öğrenme oranını ve beşinci stratejiyi kullanılarak %90.81 hasta düzeyi faktörlerinde elde edilmiştir. Ayrıca, aynı strateji, aynı büyütme faktörü için görüntü

düzeyinde %89.1 ile en yüksek doğruluğu elde edilmiştirr. İlk strateji, sabit bir öğrenme oranı ve sabit mini-batch boyutunu kullanan, yama düzeyinde %85.73 doğrulukla beşinci stratejiden daha iyi bir performans göstermiştir. Beşinci strateji, yama düzeyinde %85.36 ile ikinci en yüksek doğruluğu göstermiştir.

100X büyütme faktörü için Şekil 5.2, beşinci stratejinin tüm düzeylerinde diğer tüm stratejiler arasında en yüksek doğruluğu elde ettiğini göstermektedir. Beşinci stratejinin doğrulukları yama, görüntü ve hasta düzeylerinde sırasıyla %88.71, %89.92 ve %92.03 olarak gösterilmiştir. Benzer şekilde, Şekil 5.3'deki 200X büyütme faktörü için sonuçlar, beşinci stratejinin diğer stratejilere kıyasla tüm düzeylerde ilk sırada olup, sırasıyla yama, görüntü ve hasta düzeyinde %88.60, %89.79 ve %93.99 doğruluk oranlarını vermektedir.

400X büyütme faktörünü test ederken ve en iyi doğruluk olan %92.03, Şekil 5.4'te gösterildiği gibi beşinci strateji kullanılarak hasta düzeylerinde elde edilmiştir. Ayrıca, beşinci strateji görüntü düzeyinde %88.90 ile en iyi doğruluk oranını vermektedir. Artan mini-batch boyutu ile sabit bir öğrenme oranı kullanan üçüncü strateji, yama düzeylerinde %88.15 oranla en iyi doğruluğu elde etmiştir. Beşinci strateji, yama düzeyleride %87.34 doğrulukla ikinci sırada gelmektedir. Genel olarak deneysel sonuçlar, artan mini-batch boyutu ile dinamik öğrenme oranını kullanan beşinci strateji ile önerilen modelin hem görüntü hem de hasta düzeylerinde tüm büyütme faktörlerinde diğer stratejilere göre daha iyi doğruluk sonuçları verdiği gösterilmiştir.

5.2.2. Hatanın derinlemesine incelenmesi

Beş katlamanın sonuçları, çizelge 5.7'deki karışıklık matrisi, hatayı analiz etmek ve hastaların çoğu zaman hangi alt sınıfta yanlış sınıflandırdığını araştırmak için kullanılmıştır.

Çizelge 5.7. Karışıklık Matrisi

Karışıklık Matrisi		**Tahmin edilen**	
		İyi huylu	Kötü huylu
Gerçek	İyi huylu	Gerçek Negatif (a)	Yanlış Pozitif (b)
	Kötü huylu	Yanlış Negatif (c)	Gerçek Pozitif (d)

Matris elemanları aşağıdaki 5.5 ve 5.6 denklemlerde verilmiştir:

$$Yanlış\ Pozitif\ (False\ Positive)\ (FP)\ rate = \frac{b}{a+b} \tag{5.5}$$

$$Yanlış\ Negatif\ (False\ Negative)\ (FN)\ rate = \frac{c}{c+d} \tag{5.6}$$

Burada FP, kötü huylu tümörler olarak sınıflandırılan iyi huylu tümörlerin oranını, FN ise iyi huylu tümörler olarak sınıflandırılan kötü huylu tümörlerin oranını temsil etmektedir.

Beş katın sonuçları karışıklık matrisini anlamak ve sonuçları analiz etmek için kullanılmıştır. Çizelge 5.8'de, farklı büyütme faktörleri için sonuçlanan karışıklık matrisini ayrıntılı olarak göstermektedir.

Çizelge 5.8. MCNN-DWT yöntemi için Karışıklık Matrisi (Beşinci Strateji)

BF	Test Edilmiş Kat sayısı	Maks. Epoch	Karışıklık matrisi	FP	FN
40X	1	20	[3133 1235; 502 7982]	0.28	0.06
	2	20	[2201 1411; 511 6349]	0.39	0.07
	3	20	[2399 1129; 588 7812]	0.32	0.07
	4	20	[2000 660; 507 6521]	0.25	0.07
	5	20	[2574 758; 607 6981]	0.32	0.08
100X	1	20	[3039 1021; 741 8499]	0.25	0.08
	2	20	[2673 1163; 132 7008]	0.30	0.02
	3	20	[2661 1027; 643 8569]	0.28	0.07
	4	20	[2154 450; 426 6910]	0.17	0.06
	5	20	[2901 963; 512 6796]	0.25	0.07
200X	1	20	[3299 1265; 259 8561]	0.28	0.03
	2	20	[2028 940; 222 6414]	0.32	0.03
	3	20	[2644 1080; 663 8801]	0.29	0.07
	4	20	[2201 627; 448 6552]	0.22	0.06
	5	20	[2554 806; 560 6440]	0.24	0.08
400X	1	20	[2859 1229; 622 7414]	0.30	0.08
	2	20	[2127 841; 184 5892]	0.28	0.03
	3	20	[2667 889; 469 7343]	0.25	0.06
	4	20	[2033 515; 507 5933]	0.20	0.08
	5	20	[2432 872; 491 5641]	0.26	0.08

Çizelge 5.8'den elde edilen sonuçlar, iyi huylu tümörlerin %20'sinden fazlasının kötü huylu tümörler olarak yanlış sınıflandırıldığını (yüksek yanlış pozitif oran) gösterirken, kötü huylu tümörlerin %8'inden daha azının iyi huylu tümörler olarak sınıflandırılmadığını (düşük yanlış negatif oran) göstermektedir.

Karışıklığın çoğu, iyi huylu tümörlerin, kötü huylu tümörler olarak sınıflandırıldığında meydana geldiğinden, iyi huylu tümörlerden her bir alt sınıfın hasta

skoru değerlendirilerek karşılaştırılmıştır. İyi huylu tümörlerden tüm alt sınıfların hasta skorları Çizelge 5.9'da gösterilmiştir.

Çizelge 5.9. MCNN-DWT yöntemi için iyi huylu tümörlerin Hasta Skoru (Beşinci Strateji)

BF	Test Edilmiş Kat sayısı	Hasta Skoru A	Hasta Skoru F	Hasta Skoru F	Hasta Skoru PT	Hasta Skoru TA	Hasta Skoru TA
40X	1	0.91	**0.44**	0.70	0.97	0.59	---
	2	0.90	0.61	0.95	0.98	**0.04**	---
	3	0.91	0.81	**0.11**	---	0.67	0.61
	4	0.68	1.00	**0.06**	0.90	0.98	---
	5	---	0.99	0.55	---	0.92	**0.23**
100X	1	0.98	0.57	**0.07**	0.88	0.79	---
	2	0.85	0.71	0.98	0.93	**0.33**	---
	3	0.71	0.96	**0.07**	---	**0.45**	0.62
	4	0.99	1.00	**0.06**	0.87	1.00	---
	5	---	0.91	0.57	---	0.93	**0.26**
200X	1	0.97	0.57	0.91	0.90	**0.39**	---
	2	0.96	1.00	0.52	0.73	**0.16**	---
	3	0.67	0.98	**0.05**	---	0.85	1.00
	4	1.00	1.00	**0.21**	0.76	0.80	---
	5	---	1.00	0.54	---	0.92	**0.32**
400X	1	0.93	0.76	**0.05**	0.83	0.55	---
	2	0.75	0.84	0.93	0.98	**0.36**	---
	3	0.58	0.90	**0.07**	---	**0.01**	0.53
	4	0.97	1.00	**0.15**	0.98	0.85	---
	5	---	0.99	0.51	---	0.86	**0.29**

Çizelge 5.9, iki alt sınıftan (fibroadenom) ve (tübüler adenom) hastaların farklı büyütme faktörleri için kötü huylu tümörler olarak sınıflandırıldığını göstermektedir.

Araştırmacılar (Niu ve Suen, 2012) ve (LeCun ve ark., 2015)'de, fibroadenom (F) tipi tümörlerin kötü huylu tümörlerle benzer özellikleri paylaştığına dikkat çekmektedirler. Bu varsayım, bu çalışmada farklı vakalar için hasta skoru analiz edilerek doğrulanmıştır. Ek olarak, tübüler adenom (TA) tipi, farklı bir kötü huylu tümöre benzer özelliklere sahip olabilir. Önerilen model, görüntüleri ikili (Binary) bir sınıflandırma olan iyi huylu ve kötü huylu olarak sınıflandırdığı için, model tam olarak

hangi kötü huylu tümörlerin (fibroadenom) ve (tübüler adenom) tümörlerle benzer özellikleri paylaştığını söylememektedir.

5.3. Model 2 için Deneysel Sonuçlar

5.3.1. AlexNet ve VGG16 mimarilerinin incelenmesi

İlk deneyler, AlexNet ve VGG16 CNN mimarileri kullanılarak sıfırdan eğitilerek gerçekleştirildi. Çizelge 5.10, mini-batch boyutu 10 ve ilk öğrenme oranı 10^{-2} kullanılarak sistemlerin eğitiminin sonuçlarını göstermektedir. İlk öğrenme oranı, ağların öğrenmeyi sıfırdan başlatıldığı için büyük seçilmiştir. Maksimum epoch sayısı 5 olarak belirlenmiş ve CNN modeli, momentum katsayılı SGD'i ile eğitilmiştir. Çizelge 5.10, beş kat çapraz doğrulama yöntemi kullanan tüm büyütme faktörleri için AlexNet ve VGG16 modellerinin ortalama doğruluk sonuçlarını göstermektedir.

Çizelge 5.10. AlexNet ve VGG16 algoritmaları için Ortalama Doğruluk

MF	CNN yapısı	Tanıma Oranı		
		Yama	Görüntü	Hasta
40X	AlexNet	68.02	68.02	69.98
	VGG16	68.02	68.02	69.98
100X	AlexNet	69.44	69.44	69.98
	VGG16	69.44	69.44	69.98
200X	AlexNet	69.44	69.44	69.98
	VGG16	69.44	69.44	69.98
400X	AlexNet	68.74	68.74	69.98
	VGG16	68.74	68.74	69.98

Çizelge 5.10'dan elde edilen sonuçlar, AlexNet veya VGG16'yı sıfırdan eğitimle kullanmanın doğruluğunun aynı sonuçları verdiğini göstermektedir. Sonuçlar üzerinde derin bir inceleme yapıldığında, sistemlerin verileri her zaman kötü huylu sınıfı olarak sınıflandırdığını göstermektedir. İki sistemin başarısız olmasının nedeni, verilerin sağlam bir sistem oluşturmak için yeterli olmamasıdır. Bu sorunun üstesinden gelmek için ve daha iyi sonuçlara ulaşmak için GPU desteğiyle yüzlerce epoch kullanılmalıdır (Kassani ve ark., 2019; Wenzhong ve ark., 2020). Çalışmanın bu

kısmında, yama stratejisi kullanılarak veri kümesinin görüntü başına 6 yama elde etmektedir. Ayrıca, CNN'i sıfırdan eğitmek yerine, sistemin daha hızlı yakınlaşmasını sağlayan aktarım öğrenimi kullanıldı. Ardından, sınıflandırma sürecini iyileştirmek için AlexNet yapısının son katmanlarında SVM'si ile desteklendırıldı.

5.3.2. SDG parametrelerinin incelenmesi

Çizelge 5.11 ve Çizelge 5.12'de, farklı öğrenme hızı değerleri, maksimum 5 epoch ve 100'lük mini-batch boyutu kullanılarak test edilmiştir. Çizelge 5.11, farklı başlangıç öğrenme oranlarını kullanan önceden eğitilmiş AlexNet yöntemi için ortalama doğruluk sonuçlarını gösterirken, Çizelge 5.12, farklı başlangıç öğrenme oranlarını kullanan SVM yöntemi ile önceden eğitilmiş AlexNet için ortalama doğruluk sonuçları gösterilmektedir.

Çizelge 5.11. Önceden eğitilmiş AlexNet yöntemi için Ortalama Doğruluk (farklı öğrenme oranı)

BF	Öğrenme oranı	Tanıma Oranı		
		Yama	Görüntü	Hasta
40X	10^{-2}	68.02	68.02	69.98
	10^{-3}	82.53	86.94	89.95
	10^{-4}	**85.65**	**89.30**	**92.04**
	10^{-5}	81.87	85.32	87.99
100X	10^{-2}	69.44	69.44	69.98
	10^{-3}	87.28	90.52	94.00
	10^{-4}	**88.96**	**91.84**	**90.07**
	10^{-5}	86.44	90.13	89.95
200X	10^{-2}	68.74	68.74	69.98
	10^{-3}	86.95	88.95	87.99
	10^{-4}	**89.01**	**91.68**	**92.04**
	10^{-5}	86.71	90.07	92.04
400X	10^{-2}	68.37	68.37	69.98
	10^{-3}	85.13	86.96	90.07
	10^{-4}	**86.12**	**88.92**	**92.04**
	10^{-5}	83.57	88.43	89.95

Çizelge 5.12. Önceden eğitilmiş AlexNet için SVM yöntemiyle Ortalama Doğruluk (farklı öğrenme oranı)

MF	Öğrenme oranı	Tanıma Oranı		
		Yama	Görüntü	Hasta
40X	10^{-2}	68.02	68.02	69.98
	10^{-3}	84.90	88.79	95.96
	10^{-4}	**85.90**	**90.36**	**92.04**
	10^{-5}	82.30	85.69	87.99
100X	10^{-2}	69.44	69.44	69.98
	10^{-3}	89.01	91.04	94.00
	10^{-4}	**88.58**	**91.08**	**92.04**
	10^{-5}	87.03	90.81	94.00
200X	10^{-2}	68.74	68.74	69.98
	10^{-3}	88.00	90.73	92.04
	10^{-4}	**88.79**	**91.82**	**92.04**
	10^{-5}	87.05	90,31	92.04
400X	10^{-2}	68.37	68.37	69.98
	10^{-3}	83.10	85.66	84,19
	10^{-4}	**86.67**	**89.92**	**94.00**
	10^{-5}	83.19	88.30	89.95

Çizelge 5.11 ve 5.12'den alınan sonuçlar, 10^{-4} değerindeki bir başlangıç öğrenme oranının kullanılmasının daha iyi doğruluk sonuçları verdiğini göstermektedir. Yüksek öğrenme hızı kullanmak, sapmaya yol açarken, daha küçük değerler kullanmak, aktarılan katmanlardaki öğrenmeyi yavaşlatır ve daha hızlı birleşir.

Daha sonra deneyler, mini-batch boyutu 100, öğrenme oranı 10^{-4}, momentum katsayısı 0.9, ağırlık azalması 4^{-5} ve maksimum 20 epoch'ta, SGD yöntemi kullanılarak gerçekleştirilmiştir. Çizelge 5.13, beş kat çapraz doğrulama kullanılarak 40X, 100X, 200X ve 400X büyütme faktörleri için görüntü ve hasta düzeylerinde önerilen, önceden eğitilmiş AlexNet yönteminin en iyi ortalama doğruluğunu belirtmektedir. Çizelge 5.14, önerilen, önceden eğitilmiş AlexNet'in SVM yöntemi ile 40X, 100X, 200X ve 400X büyütme faktörleri için beş kat çapraz doğrulama kullanarak görüntü ve hasta düzeylerinde en iyi ortalama doğruluğunu vermektedir.

Çizelge 5.13. Önceden eğitilmiş AlexNet yöntemi için Ortalama Doğruluk (öğrenme oranı = 10^{-4})

BF	Mak. Epoch	Tanıma Oranı		
		Yama	Görüntü	Hasta
40 X	5	85.65	89.30	92.04
	10	86.71	90.78	94.00
	15	87.60	91.05	92.04
	20	**88.40**	**91.74**	**92.04**
100X	5	88.96	91.84	90.07
	10	**88.68**	**91.92**	**92.03**
	15	89.38	91.77	95.96
	20	88.48	90.95	94.00
200X	5	89.01	91.68	92.04
	10	88.75	90.42	89.95
	15	89.03	91.07	94.00
	20	**89.54**	**91.68**	**92.04**
400X	5	86.67	89.92	94.00
	10	**86.90**	**90.24**	**94.12**
	15	86.27	89.65	94.12
	20	86.86	89.95	94.12

Çizelge 5.14. Önceden eğitilmiş AlexNet için SVM yöntemi ile Ortalama Doğruluk (öğrenme oranı = 10^{-4})

BF	Mak. Epok	Tanıma Oranı		
		Yama	Görüntü	Hasta
40X	5	85.90	90.36	92.04
	10	87.32	92.57	94.00
	15	87.27	91.97	95.96
	20	**87.68**	**92.05**	**94.00**
100X	5	88.58	91.08	92.04
	10	**88.60**	**91.90**	**94.00**
	15	88.75	91.70	90.08
	20	88.65	91.14	92.04
200X	5	88.79	91.82	92.04
	10	89.06	91.71	92.04
	15	**89.02**	**91.96**	**92.04**
	20	89.03	91.75	89.95
400X	5	86.67	89.92	94.00
	10	**86.85**	**90.62**	**96.08**
	15	86.28	89.95	92.04
	20	86.35	89.41	94.12

Çizelge 5.13 ve 5.14'de görüldüğü gibi, 40X büyütme faktörü için maksimum 20 epoch, SVM ile önceden eğitilmiş AlexNet kullanılarak görüntü düzeyinde %92.05 ve hasta düzeyinde %94'lük en iyi sınıflandırma doğruluğu gösterilmiştir. 100X büyütme faktörü için doğruluk oranı SVM ile önceden eğitilmiş AlexNet kullanmak, önceden eğitilmiş AlexNet yönteminden daha iyi olup'ta yalnızca 10 epoch ile görüntü düzeyinde %91.90 ve hasta düzeyinde %94'tür. 200X büyütme faktörü, önerilen her iki yöntem için de hasta düzeyinde benzer doğruluk sağladı ve görüntü düzeylerindeki sınıflandırma doğruluğu, önceden eğitilmiş AlexNet modeline kıyasla SVM ile önceden eğitilmiş AlexNet için daha iyi sonuçlar gösterdi.

Ek olarak, SVM ile önceden eğitilmiş AlexNet kullanılarak 400X büyütme faktörü için doğruluk oranı, önceden eğitilmiş AlexNet yönteminden daha iyi olup, yalnızca 10 epoch ile görüntü düzeyinde ve hasta düzeyinde sırasıyla %90.62 ve %96 olmuştur.

5.3.3. Hatanın derinlemesine incelenmesi

Beş katın sonuçları, Karışıklık matrisini anlamak ve sonuçları analiz etmek için, Çizelge 5.15, farklı büyütme faktörleri için SVM yöntemiyle önceden eğitilmiş AlexNet'in karışıklık matrisi ayrıntılı olarak gösterilmektedir.

Çizelge 5.15. Önceden eğitilmiş AlexNet için SVM yöntemi ile Karışıklık Matrisi

BF	Test Edilen Kat Sayısı	Mak. Epoch	Karışıklık Matrisi	FP	FN
40X	1	20	$\begin{bmatrix} 681 & 255 \\ 33 & 1785 \end{bmatrix}$	0.27	0.02
	2	20	$\begin{bmatrix} 495 & 279 \\ 92 & 1378 \end{bmatrix}$	0.36	0.06
	3	20	$\begin{bmatrix} 471 & 285 \\ 137 & 1663 \end{bmatrix}$	0.38	0.08
	4	20	$\begin{bmatrix} 438 & 132 \\ 63 & 1443 \end{bmatrix}$	0.23	0.04
	5	20	$\begin{bmatrix} 583 & 131 \\ 84 & 1542 \end{bmatrix}$	0.18	0.05
100X	1	20	$\begin{bmatrix} 625 & 245 \\ 83 & 1897 \end{bmatrix}$	0.28	0.04
	2	20	$\begin{bmatrix} 545 & 277 \\ 48 & 1482 \end{bmatrix}$	0.34	0.03
	3	20	$\begin{bmatrix} 482 & 304 \\ 201 & 1773 \end{bmatrix}$	0.39	0.10
	4	20	$\begin{bmatrix} 451 & 107 \\ 83 & 1489 \end{bmatrix}$	0.19	0.05
	5	20	$\begin{bmatrix} 590 & 130 \\ 137 & 1363 \end{bmatrix}$	0.18	0.09
200X	1	20	$\begin{bmatrix} 712 & 266 \\ 14 & 1876 \end{bmatrix}$	0.27	0.01
	2	20	$\begin{bmatrix} 396 & 240 \\ 32 & 1390 \end{bmatrix}$	0.38	0.02
	3	20	$\begin{bmatrix} 482 & 316 \\ 184 & 1844 \end{bmatrix}$	0.40	0.09
	4	20	$\begin{bmatrix} 453 & 153 \\ 143 & 1357 \end{bmatrix}$	0.25	0.10
	5	20	$\begin{bmatrix} 590 & 130 \\ 137 & 1363 \end{bmatrix}$	0.18	0.09
400X	1	20	$\begin{bmatrix} 660 & 216 \\ 126 & 1596 \end{bmatrix}$	0.25	0.07
	2	20	$\begin{bmatrix} 463 & 173 \\ 71 & 1231 \end{bmatrix}$	0.27	0.05
	3	20	$\begin{bmatrix} 437 & 325 \\ 135 & 1539 \end{bmatrix}$	0.43	0.08
	4	20	$\begin{bmatrix} 376 & 170 \\ 123 & 1257 \end{bmatrix}$	0.31	0.09
	5	20	$\begin{bmatrix} 490 & 218 \\ 133 & 1181 \end{bmatrix}$	0.31	0.10

Çizelge 5.15'den elde edilen sonuçlar, iyi huylu tümörlerin %20'den fazlasının kötü huylu tümörler olarak yanlış sınıflandırıldığını (yüksek yanlış pozitif oran) gösterirken, kötü huylu tümörlerin %10'undan daha azının iyi huylu tümörler olarak sınıflandırılmadığını (düşük yanlış negatif oran) göstermektedir. Karışıklığın çoğu, iyi huylu bir tümör, kötü huylu tümörler olarak sınıflandırılması durumunda meydana geldiğinden, iyi huylu tümörlerden her bir alt sınıfın hasta skoru, çizelge 5.16'de gösterildiği gibi dikkate alınacaktır.

Çizelge 5.16. Önceden eğitilmiş AlexNet için SVM yöntemi ile iyi huylu tümörlerin Hasta Skoru

BF	Test Edilen Kat Sayısı	Hasta Skoru A	Hasta Skoru F	Hasata Skoru F	Hasta Skoru PT	Hasta Skoru TA	Hasta Skoru TA
40X	1	0.91	0.60	0.95	0.96	**0.40**	---
	2	0.78	0.91	0.99	0.88	**0.01**	---
	3	0.67	0.97	**0.00**	---	0.89	0.91
	4	0.87	0.99	**0.00**	0.96	0.94	---
	5	---	0.98	0.63	---	1.00	**0.20**
100X	1	0.95	0.55	0.53	0.94	**0.47**	---
	2	0.80	0.84	1.00	1.00	**0.09**	---
	3	0.58	0.97	**0.06**	---	0.81	0.92
	4	0.81	1.00	**0.00**	0.99	0.99	---
	5	---	0.84	0.83	---	0.73	**0.10**
200X	1	0.96	0.61	0.99	0.91	**0.30**	---
	2	0.81	1.00	**0.38**	0.77	**0.12**	---
	3	0.75	1.00	**0.11**	---	0.60	1.00
	4	1.00	0.99	**0.00**	0.73	0.90	---
	5	---	0.99	1.00	---	0.60	**0.43**
400X	1	0.95	0.79	**0.29**	0.88	0.56	---
	2	0.79	0.89	0.93	0.64	0.52	---
	3	0.62	0.98	**0.07**	---	0.52	0.81
	4	0.81	1.00	**0.04**	0.67	0.73	---
	5	---	0.90	0.98	---	0.67	**0.47**

Çizelge 5.16'de görüldüğü gibi, Kat 1 için, iyi huylu alt sınıftan (TA) hastalar, büyütme faktörleri 40X, 100X ve 200X için kötü huylu tümörler olarak sınıflandırılmıştır. Kat 1 için en kötü doğruluk oranı 0.29, 400X büyütme faktörü ile elde edilmiştir. Kat 2 için, iki iyi huylu alt sınıftan (F) ve (TA) olan hastalar, 200X büyütme faktörü için kötü huylu tümörler olarak sınıflandırılmıştır. Diğer büyütme faktörleri 40X, 100X ve 400X için sadece iyi huylu alt sınıftan (TA) hastalar kötü huylu tümörler olarak sınıflandırılmıştır. Kat 3 için, iki iyi huylu alt sınıftan (F) ve (TA) hastalar, 400X büyütme faktörü için kötü huylu tümörler olarak sınıflandırılmıştır. Diğer büyütme faktörleri 40X, 100X ve 200X için sadece iyi huylu alt sınıftan (F) hastalar kötü huylu tümörler olarak sınıflandırılmıştır. Kat 4 için, iyi huylu alt sınıftan (F) hastalar, tüm büyütme faktörleri 40X, 100X, 200X ve 400X için kötü huylu tümörler olarak sınıflandırılmıştır. 40X büyütme faktörü dışında, kat 4 için elde edilen sonuçlar, kötü huylu alt sınıftan (MC) hastaların iyi huylu tümör olarak sınıflandırıldığını göstermektedir. Son olarak, kat 5 için, iyi huylu alt sınıftan (TA) hastalar, tüm büyütme faktörleri 40X, 100X, 200X ve 400X için kötü huylu tümörler olarak sınıflandırılmıştır. Genel olarak, iyi huylu alt sınıf (fibroadenom), tüm büyütme faktörleri için Kat 3 ve Kat 4'te hataya neden olurken (tübüler adenom) alt sınıfı, 40X, 100X ve 200X büyütme faktörleri için Kat 1, 2 ve 5'te hataya neden olmaktadır.

5.4. Model 3 için Deneysel Sonuçlar

Model 3 için deneyler, önceden eğitilmiş AlexNet, GoogleNet, VGG-16, ResNet50 ve InceptionV3 CNN mimarileri kullanılarak gerçekleştirilmiştir. CNN sistemleri, bir mini-batch boyutu 100 ve başlangıç öğrenme oranı 10^{-4} kullanılarak eğitilmiştir. Ağlarda, aktarım öğrenimi kullanıldığı için, başlangıçtaki öğrenme oranı yeterince küçük seçilmelidir. Maksimum epoch sayısı 5 olarak belirlenip ve tüm CNN modelleri, katsayılı SGD ile eğitilmektedir. Çizelge 5.17, beş CNN modeli için tüm katların ayrıntılı doğruluk sonuçlarını ve bunların 40X büyütme faktörü ile maksimum seçimini göstermektedir.

Çizelge 5.17. (40X) Büyütme Faktörü için önerilen model 3 için beş kat Doğruluk sonuçları

Kat Sayısı	CNN Türü	Tanıma Oranı		
		Yama	**Görüntü**	**Hasta**
1. Kat	AlexNet	87.36	90.36	87.50
	GoogleNet	82.73	88.21	93.75
	VGG-16	86.63	89.81	93.75
	ResNet50	**88.51**	90.64	87.50
	InceptionV3	83.49	89.88	87.50
	Maksimum Seçim	88.37	**90.88**	**93.75**
2. Kat	AlexNet	86.98	90.85	100
	GoogleNet	85.57	90.23	93.75
	VGG-16	89.45	93.73	93.75
	ResNet50	91.84	94.17	93.75
	InceptionV3	87.69	93.73	93.75
	Maksimum Seçim	**92.89**	**95,49**	**100**
3. Kat	AlexNet	**90.02**	91.76	94.12
	GoogleNet	87.65	90.76	94.12
	VGG-16	88.67	91.33	94.12
	ResNet50	87.08	88.04	88.24
	InceptionV3	80.00	83.88	88.24
	Maksimum Seçim	89.97	**92.69**	**94.12**
4. Kat	AlexNet	87.89	89.86	94.12
	GoogleNet	87.21	89.11	88.24
	VGG-16	85.89	87.88	94.12
	ResNet50	85.57	86.92	94.12
	InceptionV3	83.23	87.26	94.12
	Maksimum Seçim	**89.63**	**91.38**	**94.12**
5. Kat	AlexNet	83.89	89.63	93.75
	GoogleNet	81.20	89.75	93.75
	VGG-16	85.40	90.28	93.75
	ResNet50	88.81	92.89	93.75
	InceptionV3	82.63	91.65	100
	Maksimum Seçim	**90.13**	**93.60**	**100**

Çizelge 5.17'da 40X büyütme faktörü için beş kat doğruluk sonuçları verilmektedir. Beş CNN yapısının önerilen maksimum seçimi, görüntü ve hasta düzeylerinde sırasıyla %100 ve %95.5, beş CNN sonucuna kıyasla beş katın tümü için en yüksek doğruluk sonuçlarına sahiptir. Öte yandan, AlexNet ve ResNet50 yapıları yama düzeylerinde her biri yalnızca bir kat için daha yüksek doğruluk elde edilmiştir. Beş CNN yapısının önerilen maksimum seçimi, 2. kat için %92.89 ile kalan üç kat için en yüksek doğruluk sonuçlarına sahip olmuştur.

Çizelge 5.18'de, beş CNN modeli için tüm katların ayrıntılı doğruluk sonuçlarını ve bunların 100X büyütme faktörü ile maksimum seçim kuralı sonucu göstermektedir.

Çizelge 5.17. (100X) Büyütme Faktörü için önerilen üçüncü modelin beş kat Doğruluk sonuçları

Kat Sayısı	CNN Türü	Tanıma Oranı		
		Yama	Görüntü	Hasta
1. Kat	AlexNet	84.96	87.86	87.50
	GoogleNet	83.67	89.56	100
	VGG-16	81.64	84.01	87.50
	ResNet50	**88.52**	**91.77**	100
	InceptionV3	84.72	91.02	100
	Maksimum Seçim	87.90	91.19	**100**
2. Kat	AlexNet	86.97	91.95	87.50
	GoogleNet	87.82	92.26	100
	VGG-16	87.93	91.95	100
	ResNet50	90.76	94.39	100
	InceptionV3	83.47	90.43	81.25
	Maksimum Seçim	**91.57**	**95.30**	**100**
3. Kat	AlexNet	85.90	88.49	94.12
	GoogleNet	83.83	87.06	88.24
	VGG-16	85.62	87.72	94.12
	ResNet50	86.25	85.84	88.24
	InceptionV3	84.34	88.28	88.24
	Maksimum Seçim	**86.64**	**89.18**	**94.12**
4. Kat	AlexNet	89.02	91.67	94.12
	GoogleNet	86.65	90.76	94.12
	VGG-16	87.67	**91.33**	94.12
	ResNet50	86.08	88.04	88.24
	InceptionV3	79.00	83.88	82.35
	Maksimum Seçim	**88.97**	90.69	**94.12**
5. Kat	AlexNet	84.67	89.75	93.75
	GoogleNet	83.32	91.53	100
	VGG-16	86.88	91.30	100
	ResNet50	85.88	90.03	93.75
	InceptionV3	82.48	92.28	100
	Maksimum Seçim	**91.08**	**94.64**	**100**

Çizelge 5.18'de 100X büyütme faktörü için beş kat doğruluk sonuçlarını gösterilmiştir. Beş CNN yapısının önerilen maksimum seçimi, sırasıyla hasta, görüntü ve yama düzeylerinde beş CNN sonucuna kıyasla beş katın tümü, yalnızca 3. ve 4.

katlar için en yüksek doğruluk sonuçlarına sahip olmuştur. En yüksek doğruluk sonucu hasta, görüntü ve yama düzeylerinde sırasıyla %100, %95.3 ve %91.6 idi.

Çizelge 5.19, beş CNN modeli için tüm katların ayrıntılı doğruluk sonuçlarını ve bunların 200X büyütme faktörü ile maksimum seçimini göstermektedir.

Çizelge 5.19. (200X) Büyütme Faktörü için önerilen üçüncü modelin beş kat Doğruluk sonuçları

Kat Sayısı	CNN Türü	Tanıma Oranı		
		Yama	Görüntü	Hasta
1. Kat	AlexNet	86.84	88.89	93.75
	GoogleNet	85.91	**89.91**	93.75
	VGG-16	86.67	89.33	100
	ResNet50	86.47	88.63	100
	InceptionV3	82.47	87.61	93.75
	Maksimum Seçim	**87.06**	89.40	**100**
2. Kat	AlexNet	90.05	93.68	93.75
	GoogleNet	87.39	92.08	100
	VGG-16	89.91	93.87	100
	ResNet50	90.89	94.99	100
	InceptionV3	84.52	92.41	100
	Maksimum Seçim	**92.59**	**95.32**	**100**
3. Kat	AlexNet	85.44	91.30	94.12
	GoogleNet	81.79	87.62	88.24
	VGG-16	85.88	90.30	94.12
	ResNet50	**87.27**	**93.03**	94.12
	InceptionV3	82.66	89.46	88.24
	Maksimum Seçim	85.31	91.62	**94.12**
4. Kat	AlexNet	**90.23**	**93.36**	94.12
	GoogleNet	87.63	92.43	100
	VGG-16	86.34	90.12	94.12
	ResNet50	86.35	89.90	88.24
	InceptionV3	79.14	86.66	88.24
	Maksimum Seçim	89.57	92.50	**94.12**
5. Kat	AlexNet	91.17	92.17	93.75
	GoogleNet	88.28	**94.56**	100
	VGG-16	90.08	91.81	93.75
	ResNet50	91.42	93.89	100
	InceptionV3	87.48	93.90	100
	Maksimum Seçim	**92.17**	93.90	**100**

Çizelge 5.19'de, 200X büyütme faktörü için beş kat doğruluk sonuçları gösterilmektedir. Beş CNN yapısının önerilen maksimum seçim, sırasıyla hasta, görüntü ve yama düzeylerinde beş CNN sonucuna kıyasla beş katın tümü, yalnızca 1. ve 3. kat

için en yüksek doğruluk sonuçlarına sahip olmuştur. En yüksek doğruluk sonucu hasta, görüntü ve yama düzeylerinde sırasıyla % 100,
%95.3 ve %92.6 idi.

Çizelge 5.20'da, beş CNN modeli için tüm katların ayrıntılı doğruluk sonuçlarını ve bunların 400X büyütme faktörü ile maksimum seçimi göstermektedir.

Çizelge 5.20. (400X) Büyütme Faktörü için önerilen üçüncü modelin beş kat Doğruluk sonuçları

Kat Sayısı	CNN Türü	Tanıma Oranı		
		Yama	Görüntü	Hasta
1. Kat	AlexNet	88.46	91.86	100
	GoogleNet	89.42	**93.56**	100
	VGG-16	89.69	91.69	100
	ResNet50	90.11	92.93	100
	InceptionV3	87.76	92.59	93.75
	Maksimum Seçim	**91.96**	93.42	**100**
2. Kat	AlexNet	84.00	88.65	93.75
	GoogleNet	84.82	90.3	93.75
	VGG-16	87.43	91.57	100
	ResNet50	89.30	**93.59**	100
	InceptionV3	86.15	93.51	93.75
	Maksimum Seçim	**90.31**	92.39	**100**
3. Kat	AlexNet	86.99	89.81	94.12
	GoogleNet	85.41	89.05	94.12
	VGG-16	87.41	90.16	94.12
	ResNet50	88.27	90.16	94.12
	InceptionV3	85.08	88.87	94.12
	Maksimum Seçim	**88.69**	**90.28**	**94.12**
4. Kat	AlexNet	**89.71**	**93.77**	94.12
	GoogleNet	85.57	91.75	88.24
	VGG-16	85.44	88.44	88.24
	ResNet50	85.41	89.45	88.24
	InceptionV3	84.70	91.10	94.12
	Maksimum Seçim	89.28	91.61	**94.12**
5. Kat	AlexNet	86.61	92.38	87.50
	GoogleNet	77.22	86.33	93.75
	VGG-16	87.96	93.74	**100**
	ResNet50	88.79	**94.09**	93.75
	InceptionV3	83.80	92.10	93.75
	Maksimum Seçim	**91.18**	93.81	93.75

Çizelge 5.20'da, 400X büyütme faktörü için beş kat doğruluk sonuçları gösterilmiştir. Beş CNN yapısının önerilen maksimum seçimi, sırasıyla hasta, görüntü ve yama düzeylerinde beş CNN sonucuna kıyasla yalnızca 4., 1., ve 3. katları için en

yüksek doğruluk sonuçlarına sahip olmuştur. En yüksek doğruluk sonucu hasta, görüntü ve yama düzeylerinde sırasıyla %100, %94.1 ve %92.0 idi.

Çizelge 5.21, beş CNN modeli için tüm katların ortalama doğruluk sonuçlarını ve bunların tüm büyütme faktörleriyle maksimum seçimi gösterilmiştir.

Çizelge 5.21. Tüm Büyütme Faktörleri için önerilen üçüncü modelin Ortalama Doğruluğu

Kat Sayısı	CNN Türü	Tanıma Oranı		
		Yama	Görüntü	Hasta
40 X	AlexNet	87.23	90.49	93.90
	GoogleNet	84.87	89.61	92.72
	VGG-16	87.21	90.61	93.90
	ResNet50	88.38	90.53	91.47
	InceptionV3	83.41	89.28	92.72
	Maksimum Seçim	**90.20**	**92.81**	**96.40**
100X	AlexNet	86.3	89.94	91.4
	GoogleNet	85.06	90.23	96.47
	VGG-16	85.95	89.26	95.15
	ResNet50	87.5	90.01	94.05
	InceptionV3	82.8	89.18	90.37
	Maksimum Seçim	**89.23**	**92.2**	**97.65**
200X	AlexNet	88,75	91.88	93.9
	GoogleNet	86.2	91.32	96.4
	VGG-16	87.78	91.09	96.4
	ResNet50	88.48	92.09	96.47
	InceptionV3	83.25	90.01	94.05
	Maksimum Seçim	**89.34**	**92.55**	**97.65**
400X	AlexNet	87.15	91.29	93.9
	GoogleNet	84.49	90.2	93.97
	VGG-16	87.59	91.12	96.47
	ResNet50	88.38	92.04	95.22
	InceptionV3	85.5	91.63	93.9
	Maksimum Seçim	**90.28**	**92.3**	**96.4**

Çizelge 5.21'de, tüm büyütme faktörleri için ortalama doğruluk sonuçlarını göstermektedir. Beş CNN yapısının önerilen maksimum seçim, yama, görüntü ve hasta düzeylerinde beş CNN sonucuna kıyasla en yüksek ortalama doğruluk sonuçlarına sahiptir. En yüksek doğruluk hasta, görüntü ve yama düzeylerinde sırasıyla %97.7, %92.8 ve %90.3 idi.

5.5. Önceki Çalışmalarla Karşılaştırma

Bu çalışmada sunulan üç modelin en iyi sonuçları hem hasta hem de görüntü düzeyinde, literetüedeki çalışmalarla karşılaştırılmıştır (Spanhol ve ark., 2015; Spanhol ve ark., 2016; Song ve ark., 2017; Spanhol ve ark., 2017; Deniz ve ark., 2018; Sudharshan ve ark., 2019; Gour ve ark., 2020; Wenzhong ve ark., 2020). Çizelge 5.22 ve Çizelge 5.23, sırasıyla farklı büyütme faktörleri için beş kat çapraz doğrulama kullanan hasta ve görüntü düzeylerinde önerilen modellerin ortalama doğruluğunu bildirmektedir.

Çizelge 5.22. Hasta Düzeyinde literatürdeki farklı stratejilerle karşılaştırmalı Doğruluk oranları

Düzey	**Strateji**	**Büyütme Faktörleri**			
		40X	**100X**	**200X**	**400X**
Hasta Düzeyi	CNN (Toplam) (Spanhol ve ark., 2016)	88.4	88.4	83.8	85.3
	CNN (Çarpım) (Spanhol ve ark., 2016)	89.2	88.4	83.8	85.3
	CNN (Maks.) (Spanhol ve ark., 2016)	90.0	88.4	84.6	86.1
	CNN + DeCAF (Spanhol ve ark., 2017)	88.5	88.5	90.3	87.1
	Fisher Vektörleri içine gömme (Song ve ark., 2017)	90.2	91.2	87.8	87.4
	MIL (CNN) (Sudharshan ve ark., 2019)	90.0	88.4	84.6	86.1
	MIL (Parametrik değil) (Sudharshan ve ark., 2019)	92.1	89.1	87.2	82.7
	VGG-16(Wenzhong ve ark., 2020)	50,00	83.33	33.33	57.14
	AlexNet (Wenzhong ve ark., 2020)	83.33	83.33	83.33	85.71
	AlexNet-Augmented(Gour ve ark., 2020)	83.1	85.5	88.4	81.8
	VGG-16-Artırılmış (Gour ve ark., 2020)	86.6	81.3	88.2	82.9
	ResNet50-Artırılmış (Gour ve ark., 2020)	83.8	84.8	89.3	85.9
	ResHist- Artırılmış (Gour ve ark., 2020)	87.5	88.2	92.5	87.8
	Önerilen İlk Model (MCNN-DWT) (28 yama)	**90.8**	**92.0**	**94.0**	**92.0**
	Önerilen İkinci Model (SVM ile önceden eğitilmiş AlexNet) (6 yama)	**94.0**	**94.0**	**92.0**	**96.1**
	Önerilen Üçüncü Model (Beş CNN'nin Maksimum Seçim) (24 yama)	**96.4**	**97.7**	**97.7**	**96.4**

Çizelge 5.22. Görüntü Düzeyinde literatürdeki farklı stratejilerle karşılaştırmalı Doğruluk oranları

Düzey	Strateji	Büyütme Faktörleri			
		40X	**100X**	**200X**	**400X**
Görüntü Düzeyi	CNN (Toplam) (Spanhol ve ark., 2016)	85.4	83.3	83.1	80.8
	CNN (Çarpım) (Spanhol ve ark., 2016)	85.5	83.4	83.0	80.8
	CNN (Maks.) (Spanhol ve ark., 2016)	85.6	83.5	82.7	80.7
	CNN + DeCAF (Spanhol ve ark., 2017)	88.0	88.8	88.7	86.7
	Fisher Vektörleri içine gömme (Song ve ark., 2017)	87.7	87.6	86.5	83.9
	AlexNet-fc6 + VGG-16-fc6 (Deniz ve ark., 2018)	84.87	89.21	88.65	86.75
	AlexNet-fc7 + VGG-16-fc7 (Deniz ve ark., 2018)	84.58	89.03	88.31	86,00
	İnce ayarlı AlexNet (Deniz ve ark., 2018)	**90.96**	**90.58**	**91.37**	**91.30**
	MIL (CNN) (Sudharshan ve ark., 2019)	85.6	83.5	83.1	80.8
	MIL (Parametrik değil) (Sudharshan ve ark., 2019)	87.8	85.6	80.8	82.9
	AlexNet- Artırılmış (Gour ve ark., 2020)	80.6	83.6	86.3	81.0
	VGG-16- Artırılmış (Gour ve ark., 2020)	86.0	81.4	86.9	81.3
	ResNet50- Artırılmış (Gour ve ark., 2020)	83.4	84.3	88.6	84.5
	ResHist- Artırılmış (Gour ve ark., 2020)	87.4	87.3	91.1	86.3
	Önerilen İlk Model (MCNN-DWT) (28 yama)	**89.1**	**89.9**	**89.8**	**88.9**
	Önerilen İkinci Model (SVM ile önceden eğitilmiş AlexNet) (6 yama)	**92.0**	**91.9**	**92.0**	**91.6**
	Önerilen Üçüncü Model (Beş CNN'nin Maksimum Seçim) (24 yama)	**92.8**	**92.2**	**92.6**	**92.3**

Çizelge 5.22 ve Çizelge 5.23, artan mini-batch boyutu ile adım hata zamanlayıcı kullanan ilk önerilen modelin (MCNN-DWT), hasta düzeyinde %90,8 ile %94,0 arasında doğruluklara ulaştığını göstermektedir. Önerilen ilk model (MCNN-DWT), yalnızca 40X büyütme faktöründe daha yüksek bir doğruluğa sahip olan ve Sudharshan ve arkadaşları tarafından sunulan yaklaşım dışında, dikkate alınan tüm yaklaşımlardan daha iyi performans göstermektedir.

Ayrıca, beşinci strateji kullanılarak, görüntü düzeyinde %88.9 ile %89.9 arasında doğruluk elde eden önerilen ilk model (MCNN-DWT), Deniz ve arkadaşları

haricinde, tüm büyütme faktörlerde yüksek bir doğruluk elde etmiştir. Deneysel sonuçlar, DWT ile CNN kullanıldığında, mevcut birçok yönteme göre önemli bir gelişme olduğunu göstermektedir. DWT, histopatolojik görüntülerin doğasında olan karmaşıklığı daha önce sunulan yöntemlerden daha iyi ele aldığından, elde edilen sonuçlar beklenen sonuçlar olacaktır.

Ayrıca Çizelge 5.22'de görüldüğü gibi önerilen ikinci model SVM ile önceden eğitilmiş AlexNet yöntemi, doğruluk açısından literatürde önerilen yaklaşımlardan daha iyi performans gösteren ve hasta düzeyinde %92.0 ile %96.1 arasında doğruluk elde edilen bir modeldir. Önerilen yöntem, çizelge 5.23'te gösterildiği gibi, tüm büyütme faktörleri için görüntü düzeyinde yaklaşık %92'lik bir doğruluk elde etmektedir. Önerilen SVM ile önceden eğitilmiş AlexNet yöntemi, tüm büyütme faktörleri için hem görüntü hem de hasta düzeylerinde en yüksek ortalama doğruluk sonuçlarını vermiştir. Genel olarak, çizelge 5.22'de görüldüğü gibi tüm büyütme faktörleri için önerilen üçüncü model (Beş CNN'nin Maks. Seçim) kullanılarak hasta düzeyinde %96.4 ile %97.7 arasında ulaşılan en yüksek doğruluk sonuçlarını vermektedir. Ayrıca, çizelge 5.23'de önerilen üçüncü modelin beş CNN ile Maksimum seçim, %92.2 ile %92.8 arasında en yüksek doğruluk sonuçlarını vermiştir.

6. SONUÇ VE GELECEK ÇALIŞMALAR

6.1. Sonuç

Bu çalışmada, farklı boyut ve tipte CNN yapılarına dayalı olarak üç yeni model önerilmiştir. Önerilen ilk model, küçük yama boyutları 64x 64 olan DWT ile bir CNN kullanırken, ikinci model önceden eğitilmiş AlexNet yapısı ve büyük yama boyutları 227x227 olan SVM sınıflandırıcısını kullanmıştır. Üçüncü modelde AlexNet, GoogleNet, VGG-16, ResNet50 ve InceptionV3 olmak üzere beş farklı CNN yapısının maksimum seçim kuralı önerilmiştir. Önerilen modellerin performansı, BreaKHis veri kümesi kullanılarak hasta, görüntü ve yama düzeylerinde beş kat çapraz doğrulama tekniği ile değerlendirilmiştir. BreaKHis veri kümesi deneysel çalışmalarda önemli sayıda örnek görüntü olması nedeniyle tercih edilmiştir. Ayrıca, eğitim aşamasının başlangıç evrelerinde sistemin performansını araştırmak için SGD ağ parametreleri test edilmiştir.

İlk modelde, gelişmiş bir DWT tabanlı CNN yöntemi önerilmiştir. Ayrıca, CNN parametrelerini değiştirmenin etkisi, artan mini-batch boyutu ile adım planlayıcı kullanılarak araştırılmıştır. DWT'den yalnızca bir alt bant (Yaklaşık alt bant) kullanılarak görüntülerin boyutu küçültülmüş ve bu durum aşırı sığdırma problemini önlemiştir. İkinci modelde, AlexNet'in önceden eğitilmiş sinir ağı yapısı aktarım öğrenimi kullanılarak test edilmiştir. Sonrasında, önceden eğitilmiş AlexNet ağının son FC katmanına dayalı olarak sınıflandırma için özellik çıkarma işlemi gerçekleştirilmiştir. Daha sonra, önerilen modelin verimliliğini artırmak için özellik vektörleri SVM sınıflandırıcısı ile birlikte kullanılmıştır. Üçüncü modelde, AlexNet, GoogleNet, VGG-16, ResNet50 ve InceptionV3 olmak üzere beş CNN yapısının maksimum seçim modeli gerçekleştirilmiştir. Özellikler, önceden eğitilmiş modellerin FC son katmanından çıkarılmıştır. Sonrasında önerilen modellerin verimliliğini artırmak için özellik vektörleri SVM sınıflandırıcısı ile birlikte kullanılmıştır. Son olarak, modelin doğruluğunu artırmak için beş model maksimum seçim kuralı kullanılarak birleştirilmiştir.

Beş kat çapraz doğrulama kullanılarak hasta düzeylerinde sunulan deneysel sonuçlar, aynı veri kümesinde test edilen diğer makine öğrenimi modellerine göre BreakHis veri kümesinde ortalama tanıma doğruluğunda yaklaşık %1 ile %5 iyileşme

göstermektedir. Ayrıca önerilen üçüncü model (beş CNN'nin maksimum seçim), hasta düzeyinde %96.4 ile %97.7 arasında bir performansla ikili sınıflandırma görevi için öncekilere göre daha iyi sonuçlar vermektedir.

Neticede sonuçlar, büyütme faktöründen bağımsız olarak, sınıflandırıcıların hatalarının çoğunun, kötü huylu bir sınıf olarak sınıflandırılan iyi huylu tümörler (fibroadenom) ve (tübüler adenom) nedeniyle olduğunu göstermektedir.

6.2. Gelecek Çalışmalar

Gelecek çalışmalar, daha yüksek epoch sayıları ve farklı SGD parametreleri kullanarak aynı önerilen modeler araştırmak. Daha fazla CNN mimarileri, diğer veri arttırma yöntemleriyle test etmek. Çoklu Dalgacık Dönüşümü özellikleri, aynı mimariye sahip DWT özellikleri yerine kullanmak. Ayrıca, daha uyarlanabilir öğrenme hızı yöntemleri geliştirerek, mevcut SGD optimizasyon yöntemi ile karşılaştırmak, bunlar arasında kök ortalama kare yayılım optimizasyonu ve uyarlamalı moment tahmin optimizasyonu bulmak gibi bir çok yöntem önerilebilir.

7. KAYNAKLAR

Abd Almisreb, A., Jamil, N. ve Din, N. M., 2018, Utilizing AlexNet deep transfer learning for ear recognition, *2018 Fourth International Conference on Information Retrieval and Knowledge Management (CAMP)*, 1-5.

Abdelhafiz, D., Yang, C., Ammar, R. ve Nabavi, S., 2019, Deep convolutional neural networks for mammography: advances, challenges and applications, *BMC bioinformatics*, 20 (11), 281.

Araújo, T., Aresta, G., Castro, E., Rouco, J., Aguiar, P., Eloy, C., Polónia, A. ve Campilho, A., 2017, Classification of breast cancer histology images using convolutional neural networks, *PloS one*, 12 (6), e0177544.

Beale, M., Hagan, M. ve Demuth, H., 2019, MATLAB Deep Learning Toolbox™ User's Guide: PDF Documentation for Release R2019a, *The MathWorks, Inc*.

Bejnordi, B. E., Veta, M., Van Diest, P. J., Van Ginneken, B., Karssemeijer, N., Litjens, G., Van Der Laak, J. A., Hermsen, M., Manson, Q. F. ve Balkenhol, M., 2017, Diagnostic assessment of deep learning algorithms for detection of lymph node metastases in women with breast cancer, *Jama*, 318 (22), 2199-2210.

Berrar, D. J. E. o. B. ve Biology, C., 2019, Cross-validation, 1, 542-545.

Bottou, L., 2012, Stochastic gradient descent tricks, In: Neural networks: Tricks of the trade, Eds: Springer, p. 421-436.

Boyle, P. ve Levin, B., 2008, World cancer report 2008, IARC Press, International Agency for Research on Cancer, p.

Carneiro, G., Nascimento, J. ve Bradley, A. P., 2015, Unregistered multiview mammogram analysis with pre-trained deep learning models, *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 652-660.

Carneiro, G., Nascimento, J. ve Bradley, A. P., 2017, Automated analysis of unregistered multi-view mammograms with deep learning, *IEEE transactions on medical imaging*, 36 (11), 2355-2365.

Chatfield, K., Simonyan, K., Vedaldi, A. ve Zisserman, A., 2014, Return of the devil in the details: Delving deep into convolutional nets, *arXiv preprint arXiv:1405.3531*.

Ching, T., Himmelstein, D. S., Beaulieu-Jones, B. K., Kalinin, A. A., Do, B. T., Way, G. P., Ferrero, E., Agapow, P.-M., Zietz, M. ve Hoffman, M. M., 2018, Opportunities and obstacles for deep learning in biology and medicine, *Journal of The Royal Society Interface*, 15 (141), 20170387.

Ciresan, D., Giusti, A., Gambardella, L. ve Schmidhuber, J., 2012, Deep neural networks segment neuronal membranes in electron microscopy images, *Advances in neural information processing systems*, 25, 2843-2851.

Council, N. R., 2005, Saving women's lives: strategies for improving breast cancer detection and diagnosis, National Academies Press, p.

Cruz-Roa, A. A., Ovalle, J. E. A., Madabhushi, A. ve Osorio, F. A. G., 2013, A deep learning architecture for image representation, visual interpretability and automated basal-cell carcinoma cancer detection, *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 403-410.

Dabeer, S., Khan, M. M. ve Islam, S., 2019, Cancer diagnosis in histopathological image: CNN based approach, *Informatics in Medicine Unlocked*, 16, 100231.

Das, A., Nair, M. S. ve Peter, S. D., 2020, Computer-Aided Histopathological Image Analysis Techniques for Automated Nuclear Atypia Scoring of Breast Cancer: a Review, *Journal of Digital Imaging*, 1-31.

Deniz, E., Şengür, A., Kadiroğlu, Z., Guo, Y., Bajaj, V., Budak, Ü. J. H. i. s. ve systems, 2018, Transfer learning based histopathologic image classification for breast cancer detection, 6 (1), 18.

Dhungel, N., Carneiro, G. ve Bradley, A. P., 2015, Deep learning and structured prediction for the segmentation of mass in mammograms, *International Conference on Medical image computing and computer-assisted intervention*, 605-612.

Dinnes, J., Moss, S., Melia, J., Blanks, R., Song, F. ve Kleijnen, J., 2001, Effectiveness and cost-effectiveness of double reading of mammograms in breast cancer screening: findings of a systematic review, *The Breast*, 10 (6), 455-463.

Duda, R. O., Hart, P. E. ve Stork, D. G., 2012, Pattern classification, John Wiley & Sons, p.

Evans, A. J., Krupinski, E. A., Weinstein, R. S. ve Pantanowitz, L., 2015, 2014 American Telemedicine Association clinical guidelines for telepathology: another important step in support of increased adoption of telepathology for patient care, *Journal of pathology informatics*, 6.

Fadhil, A. F., 2014, Formulation of detection strategies in images, Southern Illinois University at Carbondale, p.

Farabet, C., Couprie, C., Najman, L. ve LeCun, Y., 2012, Learning hierarchical features for scene labeling, *IEEE transactions on pattern analysis and machine intelligence*, 35 (8), 1915-1929.

Filipczuk, P., Fevens, T., Krzyżak, A. ve Monczak, R., 2013, Computer-aided breast cancer diagnosis based on the analysis of cytological images of fine needle biopsies, *IEEE transactions on medical imaging*, 32 (12), 2169-2178.

George, Y. M., Zayed, H. H., Roushdy, M. I. ve Elbagoury, B. M., 2014, Remote computer-aided breast cancer detection and diagnosis system based on cytological images, *IEEE Systems Journal*, 8 (3), 949-964.

Gour, M., Jain, S. ve Sunil Kumar, T., 2020, Residual learning based CNN for breast cancer histopathological image classification, *International Journal of Imaging Systems and Technology*.

Greenspan, H., Van Ginneken, B. ve Summers, R. M., 2016, Guest editorial deep learning in medical imaging: Overview and future promise of an exciting new technique, *IEEE transactions on medical imaging*, 35 (5), 1153-1159.

Hafemann, L. G., Oliveira, L. S. ve Cavalin, P., 2014, Forest species recognition using deep convolutional neural networks, *2014 22nd International Conference on Pattern Recognition*, 1103-1107.

He, K., Zhang, X., Ren, S. ve Sun, J., 2016, Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778.

Hedjazi, M. A., Kourbane, I. ve Genc, Y., 2017, On identifying leaves: A comparison of CNN with classical ML methods, *2017 25th Signal Processing and Communications Applications Conference (SIU)*, 1-4.

Hohman, F., Kahng, M., Pienta, R. ve Chau, D. H., 2018, Visual analytics in deep learning: An interrogative survey for the next frontiers, *IEEE transactions on visualization and computer graphics*, 25 (8), 2674-2693.

Huang, Z., Pan, Z. ve Lei, B. J. R. S., 2017, Transfer learning with deep convolutional neural network for SAR target classification with limited labeled data, 9 (9), 907.

Huynh, B. Q., Li, H. ve Giger, M. L., 2016, Digital mammographic tumor classification using transfer learning from deep convolutional neural networks, *Journal of Medical Imaging*, 3 (3), 034501.

Jadoon, M. M., Zhang, Q., Haq, I. U., Butt, S. ve Jadoon, A., 2017, Three-class mammogram classification based on descriptive CNN features, *BioMed research international*, 2017.

Jan, Z., KHAN, S., Islam, N., ANSARI, M. ve Baloch, B., 2016, Automated Detection of Malignant Cells Based on Structural Analysis and Naive Bayes Classifier, *Sindh University Research Journal-SURJ (Science Series)*, 48 (2).

Ji, Q., Huang, J., He, W. ve Sun, Y., 2019, Optimized Deep Convolutional Neural Networks for Identification of Macular Diseases from Optical Coherence Tomography Images, *Algorithms*, 12 (3), 51.

Jiang, F., Liu, H., Yu, S. ve Xie, Y., 2017, Breast mass lesion classification in mammograms by transfer learning, *Proceedings of the 5th international conference on bioinformatics and computational biology*, 59-62.

Jiao, Z., Gao, X., Wang, Y. ve Li, J., 2016, A deep feature based framework for breast masses classification, *Neurocomputing*, 197, 221-231.

Kassani, S. H., Kassani, P. H., Wesolowski, M. J., Schneider, K. A. ve Deters, R. J. a. p. a., 2019, Breast cancer diagnosis with transfer learning and global pooling.

Khan, S., Islam, N., Jan, Z., Din, I. U. ve Rodrigues, J. J. C., 2019, A novel deep learning based framework for the detection and classification of breast cancer using transfer learning, *Pattern Recognition Letters*, 125, 1-6.

Kooi, T., Litjens, G., Van Ginneken, B., Gubern-Mérida, A., Sánchez, C. I., Mann, R., den Heeten, A. ve Karssemeijer, N., 2017, Large scale deep learning for computer aided detection of mammographic lesions, *Medical image analysis*, 35, 303-312.

Kowal, M., Filipczuk, P., Obuchowicz, A., Korbicz, J. ve Monczak, R., 2013, Computer-aided diagnosis of breast cancer based on fine needle biopsy microscopic images, *Computers in biology and medicine*, 43 (10), 1563-1572.

Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012, Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, 1097-1105.

Lakhani, S. R., Ellis, I. O., Schnitt, S., Tan, P. H. ve van de Vijver, M., 2012, WHO Classification of Tumours of the Breast.

LeCun, Y., Kavukcuoglu, K. ve Farabet, C., 2010, Convolutional networks and applications in vision, *Proceedings of 2010 IEEE international symposium on circuits and systems*, 253-256.

LeCun, Y., Bengio, Y. ve Hinton, G., 2015, Deep learning, *nature*, 521 (7553), 436-444.

Lee, K.-M. ve Street, W. N., 2003, An adaptive resource-allocating network for automated detection, segmentation, and classification of breast cancer nuclei topic area: image processing and recognition, *IEEE transactions on neural networks*, 14 (3), 680-687.

Lee, R. S., Gimenez, F., Hoogi, A., Miyake, K. K., Gorovoy, M. ve Rubin, D. L., 2017, A curated mammography data set for use in computer-aided detection and diagnosis research, *Scientific data*, 4, 170177.

Lévy, D. ve Jain, A., 2016, Breast mass classification from mammograms using deep convolutional neural networks, *arXiv preprint arXiv:1612.00542*.

Li, Y., Wu, J. ve Wu, Q., 2019, Classification of breast cancer histology images using multi-size and discriminative patches based on deep learning, *IEEE Access*, 7, 21400-21408.

Medda, A., Hoffmann, L., Magnuson, M., Thompson, G., Pan, W.-J. ve Keilholz, S., 2016, Wavelet-based clustering of resting state MRI data in the rat, *Magnetic resonance imaging*, 34 (1), 35-43.

Mohamed, A. A., Berg, W. A., Peng, H., Luo, Y., Jankowitz, R. C. ve Wu, S., 2018, A deep learning method for classifying mammographic breast density categories, *Medical physics*, 45 (1), 314-321.

Munir, K., Elahi, H., Ayub, A., Frezza, F. ve Rizzi, A., 2019, Cancer diagnosis using deep learning: a bibliographic review, *Cancers*, 11 (9), 1235.

Murphy, K. P., 2012, Machine learning: a probabilistic perspective, MIT press, p.

Nannia, L., Ghidoni, S. ve Brahnam, S., 2020, Ensemble of convolutional neural networks for bioimage classification, *Applied Computing and Informatics*.

Niu, X.-X. ve Suen, C. Y., 2012, A novel hybrid CNN–SVM classifier for recognizing handwritten digits, *Pattern Recognition*, 45 (4), 1318-1325.

Peng, J., Kang, S., Ning, Z., Deng, H., Shen, J., Xu, Y., Zhang, J., Zhao, W., Li, X. ve Gong, W., 2020, Residual convolutional neural network for predicting response of transarterial chemoembolization in hepatocellular carcinoma from CT imaging, *European radiology*, 30 (1), 413-424.

Prasoon, A., Petersen, K., Igel, C., Lauze, F., Dam, E. ve Nielsen, M., 2013, Deep feature learning for knee cartilage segmentation using a triplanar convolutional neural network, *International conference on medical image computing and computer-assisted intervention*, 246-253.

Ragab, D. A., Sharkas, M., Marshall, S. ve Ren, J., 2019, Breast cancer detection using deep convolutional neural networks and support vector machines, *PeerJ*, 7, e6201.

Robertson, S., Azizpour, H., Smith, K. ve Hartman, J., 2018, Digital image analysis in breast pathology—from image processing techniques to artificial intelligence, *Translational Research*, 194, 19-35.

Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A. ve Bernstein, M., 2015, Imagenet large scale visual recognition challenge, *International journal of computer vision*, 115 (3), 211-252.

Samala, R. K., Chan, H.-P., Hadjiiski, L. M., Helvie, M. A., Cha, K. H. ve Richter, C. D., 2017, Multi-task transfer learning deep convolutional neural network: application to computer-aided diagnosis of breast cancer on mammograms, *Physics in Medicine & Biology*, 62 (23), 8894.

Scherer, D., Müller, A. ve Behnke, S., 2010, Evaluation of pooling operations in convolutional architectures for object recognition, *International conference on artificial neural networks*, 92-101.

Shen, L., 2017, End-to-end training for whole image breast cancer diagnosis using an all convolutional design, *arXiv preprint arXiv:1711.05775*.

Shen, X., Li, Q., Tian, Y. ve Shen, L., 2015, An uneven illumination correction algorithm for optical remote sensing images covered with thin clouds, *Remote Sensing*, 7 (9), 11848-11862.

Shi, Y. Q. ve Sun, H., 1999, Image and video compression for multimedia engineering: Fundamentals, algorithms, and standards, CRC press, p.

Shin, H.-C., Roth, H. R., Gao, M., Lu, L., Xu, Z., Nogues, I., Yao, J., Mollura, D. ve Summers, R. M., 2016, Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning, *IEEE transactions on medical imaging*, 35 (5), 1285-1298.

Simonyan, K. ve Zisserman, A., 2014, Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*.

Song, Y., Chang, H., Huang, H. ve Cai, W., 2017, Supervised intra-embedding of fisher vectors for histopathology image classification, *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 99-106.

Spanhol, F. A., Oliveira, L. S., Petitjean, C. ve Heutte, L., 2015, A dataset for breast cancer histopathological image classification, *IEEE Transactions on Biomedical Engineering*, 63 (7), 1455-1462.

Spanhol, F. A., Oliveira, L. S., Petitjean, C. ve Heutte, L., 2016, Breast cancer histopathological image classification using convolutional neural networks, *2016 international joint conference on neural networks (IJCNN)*, 2560-2567.

Spanhol, F. A., Oliveira, L. S., Cavalin, P. R., Petitjean, C. ve Heutte, L., 2017, Deep features for breast cancer histopathological image classification, *2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 1868-1873.

Spanhol, F. A., 2018, Automatic breast cancer classification from histopathological images: a hybrid approach.

Sudharshan, P., Petitjean, C., Spanhol, F., Oliveira, L. E., Heutte, L. ve Honeine, P., 2019, Multiple instance learning for histopathological breast cancer image classification, *Expert Systems with Applications*, 117, 103-111.

Suzuki, S., Zhang, X., Homma, N., Ichiji, K., Sugita, N., Kawasumi, Y., Ishibashi, T. ve Yoshizawa, M., 2016, Mass detection using deep convolutional neural network for mammographic computer-aided diagnosis, *2016 55th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE)*, 1382-1386.

Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. ve Rabinovich, A., 2015, Going deeper with convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1-9.

Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. ve Wojna, Z., 2016, Rethinking the inception architecture for computer vision, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2818-2826.

Thakur, R., 2019, Step by step VGG16 implementation in Keras for beginners, *Medium*.

Veta, M., Pluim, J. P., Van Diest, P. J. ve Viergever, M. A., 2014, Breast cancer histopathology image analysis: A review, *IEEE Transactions on Biomedical Engineering*, 61 (5), 1400-1411.

Vo, D. M., Nguyen, N.-Q. ve Lee, S.-W., 2019, Classification of breast cancer histology images using incremental boosting convolution networks, *Information Sciences*, 482, 123-138.

Wang, J., Ding, H., Bidgoli, F. A., Zhou, B., Iribarren, C., Molloi, S. ve Baldi, P., 2017, Detecting cardiovascular disease from mammograms with deep learning, *IEEE transactions on medical imaging*, 36 (5), 1172-1181.

Wang, P., Hu, X., Li, Y., Liu, Q. ve Zhu, X., 2016, Automatic cell nuclei segmentation and classification of breast cancer histopathology images, *Signal Processing*, 122, 1-13.

Wenzhong, L., Huanlan, L., Caijian, H. ve Liangjun, Z. J. m., 2020, Classifications of Breast Cancer Images by Deep Learning.

Wichakam, I. ve Vateekul, P., 2016, Combining deep convolutional networks and SVMs for mass detection on digital mammograms, *2016 8th international conference on knowledge and smart technology (KST)*, 239-244.

Xi, P., Shu, C. ve Goubran, R., 2018, Abnormality detection in mammography using deep convolutional neural networks, *2018 IEEE International Symposium on Medical Measurements and Applications (MeMeA)*, 1-6.

Xing, F., Xie, Y. ve Yang, L., 2015, An automatic learning-based framework for robust nucleus segmentation, *IEEE transactions on medical imaging*, 35 (2), 550-566.

Yadav, S. ve Shukla, S., 2016, Analysis of k-fold cross-validation over hold-out validation on colossal datasets for quality classification, *2016 IEEE 6th International conference on advanced computing (IACC)*, 78-83.

Yamashita, R., Nishio, M., Do, R. K. G. ve Togashi, K., 2018, Convolutional neural networks: an overview and application in radiology, *Insights into imaging*, 9 (4), 611-629.

Yi, D., Sawyer, R. L., Cohn III, D., Dunnmon, J., Lam, C., Xiao, X. ve Rubin, D., 2017, Optimizing and visualizing deep learning for benign/malignant classification in breast tumors, *arXiv preprint arXiv:1705.06362*.

Zhang, Y., Zhang, B., Coenen, F., Xiao, J. ve Lu, W., 2014, One-class kernel subspace ensemble for medical image classification, *EURASIP Journal on Advances in Signal Processing*, 2014 (1), 17.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı	**:**	[redacted]
Uyruğu	**:**	
Doğum Yeri ve Tarihi	**:**	
Telefon	**:**	
Faks	**:**	
E-Posta	**:**	

EĞİTİM

Lise :	İzdihar kız Lisesi - Kerkük	2003
Üniversite :	Kerkük Teknik Üniversitesi – Kerkük	2007
Yüksek Lisans :	Ankara Üniversitesi – Ankara	2012

İŞ DENEYİMLERİ

2012 - 2013	Irak Büyükelçiliği	Tercüman
2013 -	Kerkük Üniversiresi / Mühendislik Fakültesi	Öğretim Üyesi

UZMANLIK ALANI

Görüntü ve Sinyal İşleme

YABANCI DİLLER

İngilizce, Arapça, Türkçe

YAYINLAR*

"Multispectral Image Fusion Based on the Multiwavelet and IHS Transforms", Z. Telatar and S. Nizam**,** 20th Signal Processing and Communications Applications Conference (SIU)**,** 2012 (Yüksek Lisans Tezinden yapılmıştır).

"A Low-Power 30 MHz, 6th Order Band-Pass Differential Gm-C Filter Using Improved Floating Current Source", Sema NİZAM and Arsen AHMED, 6th International Conference and Workshop on Basic and Applied Sciences, 2017

"Transfer Learning Using Alexnet with Support Vector Machine for Breast Cancer Detection", Sema Nizam Abdulghani, Ahmed Freidoon Fadhil and Seyfettin Sinan Gültekin, European Journal of Science and Technology (EJOSAT), 2020 (Doktora Tezinden yapılmıştır).

"Breast cancer histopathological image classification using CNN based DWT strategies", Sema Nizam Abdulghani, Ahmed Freidoon Fadhil, and Seyfettin Sinan Gültekin, Indonesian Journal of Electrical Engineering and Computer Science (IJEECS), 2021 (Doktora Tezinden yapılmıştır).