



**T.C.**  
**KONYA TEKNİK ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**DERİN ÖĞRENME ALGORİTMALARI**  
**KULLANILARAK DIŞ ve ORTA KULAK**  
**HASTALIKLARININ TESPİT EDİLMESİ**

**Mehmet Reşat ÖNER**

**YÜKSEK LİSANS TEZİ**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Haziran-2023**  
**KONYA**  
**Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Mehmet Reşat ÖNER tarafından hazırlanan “Derin Öğrenme Algoritmaları Kullanılarak Dış ve Orta Kulak Hastalıklarının Tespit Edilmesi” adlı tez çalışması 21/06/2023 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

### İmza

#### Başkan

Prof. Dr. İsmail BABAOĞLU

.....

#### Danışman

Doç. Dr. Ersin KAYA

.....

#### Üye

Dr. Öğr. Üyesi Bahaeddin TÜRKOĞLU

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN  
Enstitü Müdürü

## 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.

Mehmet Reşat ÖNER

Tarih: 21.06.2023

## ÖZET

### YÜKSEK LİSANS TEZİ

## DERİN ÖĞRENME ALGORİTMALARI KULLANILARAK DIŞ ve ORTA KULAK HASTALIKLARININ TESPİT EDİLMESİ

Mehmet Reşat ÖNER

Konya Teknik Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Ersin KAYA

2023, 89 Sayfa

Jüri

Doç. Dr. Ersin KAYA  
Prof. Dr. İsmail BABAOĞLU  
Dr. Öğr. Üyesi Bahaeddin TÜRKÖĞLU

Kulak hastalıkları erken teşhis ve uygun tıbbi bakım ile kolaylıkla tedavi edilebilir. Bununla birlikte, uzman sayısının az olması ve nispeten düşük teşhis doğruluğu, derin öğrenmenin önemli bir rol oynayabileceği yeni bir teşhis stratejisi gerektirmektedir. Bu tezde, klinik ortamda elde edilen çok sayıda otoendoskopik görüntüden yola çıkılarak kulak hastalıklarını tespit etmek için derin öğrenme modelleri kullanılmakta ve bu modellerin başarı oranları gösterilmektedir. Bu tezde, kulak hastalıklarını kapsayan 10 adet hastalık sınıfına (Normal, Adesiv, Akut Otit, Eksternal, Miringoskleroz, Opere, Perfore, Seröz, Serümen, Süpüratif Kronik Otit) sahip bir veri seti kullanılmıştır. Bu veri setinde 1049 adedi sağlıklı (Normal) ve 1076 adedi hastalıklı olmak üzere toplam 2.125 otoendoskopik görüntü bulunmaktadır. Ayrıca bu veri setine çeşitli ön işlemler ve veri artırımı işlemleri uygulanmıştır. Bu veri setinde yer alan hastalıkları sınıflandırmak için Evrişimsel Sinir Ağları (CNN) yöntemine başvurulmuştur. Sınıflandırma işleminin gerçekleştirilebilmesi için önceden eğitilmiş EfficientNetB2, EfficientNetB3, InceptionV3, Resnet50, Resnet50V2, ResNet101, ResNet101V2, VGG-16, Xception ve InceptionResNetV2 modelleri kullanılmıştır ayrıca bu modellerin tam bağlı katmanlarına 2048 ve 1024 nörondan oluşan iki adet gizli katman eklenmiştir. Bu tezde farklı optimizasyon algoritmaları ve farklı epok-batch size değerleri ile deneyler yapılmıştır. Optimizasyon deneylerinin neticesinde Adam optimizasyonu en iyi sonucu vermiştir ve epok-batch size deneylerinde kullanılmıştır. Epok-batch size deneylerinde ise en iyi sonucu 40 epok – 32 batch size çalışmasında %96 doğruluk değeri ile EfficientNetB2 ve ResNet50 modelleri vermiştir. CNN modelleri tarafından en iyi tanınan hastalıklar ise Adesiv ve Opere hastalıkları olmuştur.

**Anahtar Kelimeler:** Derin Öğrenme, Doğruluk, Evrişimsel Sinir Ağları, Karışıklık Matrisi, Otoendoskopik Görüntü, Transfer Öğrenimi.

## ABSTRACT

## MS THESIS

# DETECTING EXTERNAL AND MIDDLE EAR DISEASES USING DEEP LEARNING ALGORITHMS

**Mehmet Reşat ÖNER**

**Konya Technical University  
Institute of Graduate Studies  
Department of Computer Engineering**

**Advisor: Assoc. Prof. Dr. Ersin KAYA**

**2023, 89 Pages**

**Jury  
Assoc. Prof. Dr. Ersin KAYA  
Prof. Dr. İsmail BABAOĞLU  
Asst. Prof. Dr. Bahaeddin TÜRKOĞLU**

Ear diseases are easily treatable with early detection and appropriate medical care. However, the small number of experts and the relatively low diagnostic accuracy require a new diagnostic strategy in which deep learning can play an important role. In this thesis, deep learning models are used to detect ear diseases based on a large number of autoendoscopic images obtained in the clinical setting and the success rates of these models are shown. In this thesis, a data set with 10 disease classes (Normal, Adesiv, Akut Otit, Eksternal, Miringoskleroz, Opere, Perfore, Seröz, Serümen, Süpüratif Kronik Otit) covering ear diseases was used. In this data set, there are a total of 2,125 autoendoscopic images, of which 1049 are healthy (normal) and 1076 are diseased. In addition, various pre-processes and data augmentation processes were applied to this data set. Convolutional Neural Networks (CNN) method was used to classify the diseases in this data set. Pre-trained models EfficientNetB2, EfficientNetB3, InceptionV3, Resnet50, Resnet50V2, ResNet101, ResNet101V2, VGG-16, Xception and InceptionResNetV2 were used to perform the classification process, and two hidden layers consisting of 2048 and 1024 neurons were added to the fully connected layers of these models. In this thesis, experiments were carried out with different optimizer algorithms and different epoch-batch size values. As a result of the optimizer experiments, the Adam optimizer gave the best results and was used in the epoch-batch size experiments. EfficientNetB2 and ResNet50 models gave the best results in epoch-batch size experiments, with an accuracy of 96% in 40 epoch-32 batch size studies. Adesiv and Opere diseases were the diseases best recognized by CNN models.

**Keywords:** Deep Learning, Accuracy, Convolutional Neural Networks, Confusion Matrix, Autoendoscopic Image, Transfer Learning.

## ÖNSÖZ

Bu tez, dış kulak yolu, kulak zarı ve orta kulak hastalıklarının dijital ortamda tespit edilebilmesi amacıyla derin öğrenme yöntemi olan evrimsel sinir ağıyla uygun parametrelerin belirlenmesi üzerine bir çalışmayı kapsamaktadır. Teknolojinin ilerlemesi ile derin öğrenme yöntemleri birçok alanda kendini göstermeye başlamıştır. Özellikle sağlık alanında farklı yöntemler kullanılarak büyük başarılar elde edilmiştir. Günümüzde derin öğrenme yöntemleri ile elde edilen başarı, zaman ve kaynak kullanımını açısından önceden kullanılan yöntemlerin başarısına göre kıyaslandığında ön plana çıkmaktadır.

Bu tez çalışmasında beni yönlendiren, destekleyen ve önerileriyle yolumu aydınlatan danışmanım Doç. Dr. Ersin KAYA'ya en içten teşekkürlerimi sunarım. Ayrıca annem, babam ve kardeşlerime de bu uzun ve zorlu süreçte desteklerini esirgemedikleri için teşekkür ediyorum.

Mehmet Reşat ÖNER  
KONYA-2023

# İÇİNDEKİLER

<b>ÖZET</b> .....	<b>iv</b>
<b>ABSTRACT</b> .....	<b>v</b>
<b>ÖNSÖZ</b> .....	<b>vi</b>
<b>İÇİNDEKİLER</b> .....	<b>vii</b>
<b>SİMGELER VE KISALTMALAR</b> .....	<b>ix</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
<b>2. KAYNAK ARAŞTIRMASI</b> .....	<b>3</b>
<b>3. MATERYAL VE YÖNTEM</b> .....	<b>10</b>
3.1. Derin Öğrenme .....	13
3.2. Evrişimsel Sinir Ağı (CNN) .....	13
3.2.1. Evrişimsel sinir ağı yapısı ve modelleri.....	15
3.2.1.1. Evrişim katmanı (Convolution layer).....	15
3.2.1.2. Piksel ekleme (Padding) .....	17
3.2.1.3. Adım aralığı (Stride).....	17
3.2.1.4. Normalizasyon.....	19
3.2.1.5. Havuzlama katmanı (Pooling layer).....	19
3.2.1.6. Dropout.....	20
3.2.1.7. Tam bağlı katman (Fully connected layer) ve softmax .....	21
3.2.1.8. Optimize edici (Optimizer).....	22
3.3. Değerlendirme Metrikleri .....	22
3.4. ResNet50.....	24
3.5. ResNet101 .....	25
3.6. InceptionV3 .....	26
3.7. InceptionResNetV2.....	31
3.8. Xception.....	44
3.9. EfficientNet (B0-B7) .....	48
3.10. VGG-16 .....	48
3.11. Veri Seti .....	50
3.11.1. Adesiv .....	50
3.11.2. Akut Otit.....	51
3.11.3. Eksternal.....	52
3.11.4. Miringoskleroz .....	52
3.11.5. Opere .....	53
3.11.6. Perfore .....	54
3.11.7. Seröz.....	54
3.11.8. Serumen.....	55
3.11.9. Supuratif Kronik Otit .....	56
3.12. Veri Ön İşleme Süreci.....	57
3.13. Çalışma Ortamı .....	60

<b>4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....</b>	<b>61</b>
4.1. Model İnşası ve Parametreleri .....	61
4.2. Sonuçlar .....	61
4.3. Tartışma .....	73
<b>5. SONUÇLAR VE ÖNERİLER.....</b>	<b>75</b>
<b>KAYNAKLAR.....</b>	<b>76</b>





## SİMGELER VE KISALTMALAR

### Kısaltmalar

CNN-Evrişimsel Sinir Ağı (Convolutional Neural Network)

KBB-Kulak Burun Boğaz

YSA-Yapay Sinir Ağı



## 1. GİRİŞ

Derin öğrenme, çeşitli alanlara uygulanmış ve dikkate değer sonuçlar üretilmiş önemli bir çalışma alanıdır. Derin öğrenme, makine öğreniminin bir alt disiplini. Derin öğrenme, derin sinir ağları olarak da bilinir. Bunun sebebi, sinir ağları yapısını örnek almasıdır. Özelliklerin, makine öğrenmesindeki gibi kodlamayla öğrenilmesi yerine orijinal veri üzerinde kendi kendine öğrenilmesini ve hiyerarşik olarak sergilenmesini sağlamaktadır. Derin öğrenmede, öğrenme süreci katmanlarda gerçekleşmektedir. Derin öğrenmenin bir komut bloğuna bağlı kalmadan örneklerle öğrenebilmesi esneklik sağlamaktadır. Bu esneklik özelliği, daha yüksek doğruluklara ulaşmasında önemli rol oynamaktadır. Makine öğrenmesi veya görüntü işleme teknikleri yerine derin öğrenme yönteminin tercih edilmesinin sebebi, klasik makine öğreniminde özellik vektörünün çıkarılması gerekliliğinin ve bu sürecin zahmetli oluşunun ortadan kalkmasıdır. Derin öğrenme teknikleri, esneklik özelliği sayesinde orijinal veri üzerinde doğrudan işlem yapabilme yeteneğine sahiptir, bu da zamandan ve kaynak kullanımından tasarruf sağlamaktadır. Bu durum, derin öğrenmenin makine öğrenimi disiplini karşısında bir üstünlük oluşturmasına katkıda bulunmaktadır (İnik ve Ülker 2017, Sharma ve ark 2021, YILMAZ ve YAYIN 2021). Görüntü işleme, görsel verilerdeki nesnelere, insanları ve araçları tanımlama amacıyla kullanılan bir araştırma alanıdır. Bununla birlikte, modern görüntü işleme teknolojisinin başarı oranını artırmak için derin öğrenme modellerinden yararlanılmıştır (Zhang ve ark 2022).

Derin öğrenme, artık birçok alanda kullanımı yaygınlaşmış bir yöntemdir. Bitki yapraklarındaki hastalıkların tespiti, Covid-19 teşhisi, kanser hastalıklarının erken teşhisi, bitkilerin sınıflandırılması, finansal piyasa tahmini, ses tanıma, kredi riski değerlendirmesi, satış tahmini, metin ve konuşma sentezi gibi birçok alanda yapılan çalışmalar göz önüne alındığında son zamanlardaki popüler çalışma alanlarından biri olmuştur.

Kulak hastalıkları, erken teşhis edildiği zaman kolayca tedavi edilebilen bir hastalıktır ancak erken teşhis edilemediği durumlarda işitme kaybına kadar uzanan sonuçları ağır bir hastalığa dönüşebilmektedir. Kliniklerde kulak hastalıklarını teşhis ederken genelde ilk olarak konvansiyonel otoskopi veya otoendoskopi yöntemleri kullanılır. İlk yöntem Kulak Burun Boğaz (KBB) uzmanı olmayan kişiler tarafından yapılırsa doğru teşhis oranı ortalama %50'lerde kalmaktadır. Ancak sayısı oldukça az olan KBB uzmanı kişilerde bile doğru teşhis oranı ortalama %73 gibi yetersiz bir değerde

kalmaktadır (Cha ve ark 2019). Bu deęerler göz önüne alındığı zaman, bir KBB uzmanı kişinin bile doğru karar verebilmesi oldukça zordur. Ayrıca KBB uzmanı sayısının da az olması ve bazı klinik imkân eksiklikleri de bu alanda uzmanlık ihtiyacını zorunlu hale getirmiştir. Bu durum, derin öğrenme tekniklerine dayalı otomatik teşhis sistemlerinin geliştirilmesine olan ilgiyi artırmıştır. Böylece hızlı ve doğru çalışan derin öğrenme modelleri bu sorunların üstesinden gelmeyi ve hastaların hastalıklarını erkenden teşhis etmeyi, zamanında ve doğru tedavi için yardımcı olmayı amaçlamaktadır. Derin öğrenmenin göstermiş olduğu performans ve KBB alanındaki bu kısıtlar göz önüne alınırsa, derin öğrenme yöntemlerinin kulak hastalığı teşhisinde oldukça önemli bir yeri olduğu görülmektedir.

Bu tez, çeşitli ön işlemden geçmiş dış kulak yolu, kulak zarı ve orta kulak görüntülerinin Evrişimsel Sinir Ağları'nın (CNN) farklı modelleri ile sınıflandırılmasına değinecektir. Tezin; ikinci bölümünde benzer çalışmaların yer aldığı kaynak araştırması, üçüncü bölümünde yapılan deneyler, kullanılan veri seti ve kullanılan yöntemin anlatıldığı materyal ve yöntem, dördüncü bölümünde yapılan deneylerin sonuçları ve bu sonuçların yorumlarının yer aldığı araştırma bulguları ve tartışma, beşinci bölümünde ise çalışma sonunda elde edilen çıkarım ve çalışmanın ileride hangi boyutlara ulaşabileceğinin yer aldığı sonuçlar ve öneriler kısımlarına yer verilmiştir.

## 2. KAYNAK ARAŞTIRMASI

Derin öğrenme yöntemi sahip olduğu faydalı özelliklerden dolayı oldukça yaygın bir kullanıma sahiptir. Göstermiş olduğu başarılarından dolayı tıp alanlarından tarımsal alanlara kadar uzanan geniş kullanım alanları vardır. Bu bölümde, derin öğrenme yöntemlerinin kullanıldığı farklı alanlar incelenmektedir.

Chai ve arkadaşlarının (2010) yaptıkları çalışmada domates bitkisinin yapraklarındaki Erken Yanıklık, Geç Yanıklık, Yaprak Küfü ve Yaprak Lekesi şeklinde 4 çeşit hastalığı teşhis etmek için görüntü işleme ve örüntü tanıma tekniklerinden faydalanmışlardır. Yapraktaki hastalıklı bölgeyi tespit edebilmek için görüntü ön işleme teknikleri kullanılmıştır. Daha sonra hastalıklı yaprak görüntüsünden renk, doku ve şekil bilgisine göre 18 tane karakteristik özellik çıkartılmıştır. 4 adet hastalığı sınıflandırabilmek için ise Bayes diskriminant analizi ile birleştirilmiş Aşamalı diskriminant analizi ve Fisher diskriminant analizi ile birleştirilmiş Temel Bileşen Analizi (PCA) teknikleri kullanılmıştır. Aşamalı diskriminant analizi ile yapılan deneyde %94,71 doğruluk (accuracy) elde edilirken, 2 bileşene indirgenmiş Temel Bileşen Analizi deneyinde %98,32 doğruluk (accuracy) elde edilmiştir (Chai ve ark 2010).

Karthik ve arkadaşlarının (2020) domates bitkileri ile ilgili yaptıkları bir çalışmada, CNN yapısının hastalık probleminin çözümüne yönelik avantajlarına yer verilmiştir. Domates oldukça hassas bir bitki olduğu için çeşitli faktörden fazlasıyla etkilenir. Domates bitkileri; bakteriyel leke, yanıklık (en çok görülen çeşittir) ve yaprak küfü gibi hastalıklardan da oldukça etkilenir ve bitkinin verimi düşer. Hastalıkların hızlı bir şekilde tespit edilmesini sağlayarak verimliliği artırabilen bir yöntem olarak, CNN mimarisi kullanılabilir. Bu çalışmada 3 farklı CNN modeli oluşturulmuştur: Temel (Baseline) CNN model (doğruluk (accuracy): %84), Kalıntı (Residual) CNN model (doğruluk (accuracy): %95), Dikkat Eklenmiş Artık (Attention Embedded Residual) CNN model (doğruluk (accuracy): %98). Veriler göstermiştir ki Dikkat Eklenmiş Artık (Attention Embedded Residual) CNN model kullanılarak yapılan model oldukça başarılı bir tespit yaparak verimliliğin artırılmasına katkıda bulunmuştur (Karthik ve ark 2020). Şekil 2.1 ve şekil 2.2'de önerilen sistemin detayları verilmiştir.



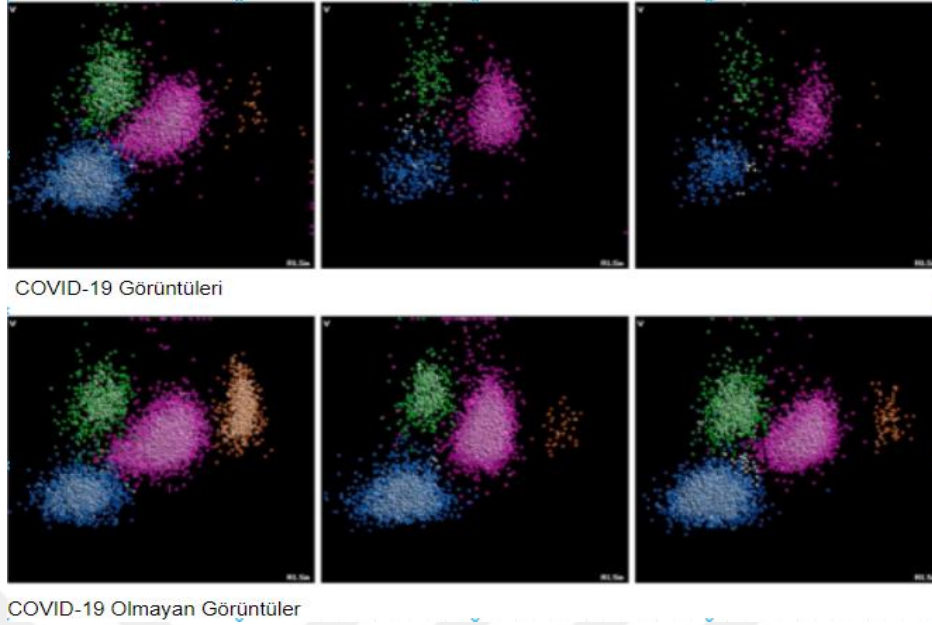
(accuracy))'tür. Bu modeller, düşük güçlü cihazlarda çalışabilen bir mimariye sahip olduğu için seçilmiştir. Bu modeller daha sonra düşük güç tüketen Raspberry Pi ortamına taşınarak arazilerde kullanılabilir hale gelişmiştir. Veri seti, 18160 adet RGB görüntüden oluşan Plantvillage'dir (Gonzalez-Huitron ve ark 2021).

Carneiro ve arkadaşlarının (2022) asma yaprakları üzerine yaptıkları bir çalışmada, derin öğrenme tekniklerinden biri olan U-Net modeli kullanılarak asma yapraklarından zar ve yaprak segmentasyonu yapılmaktadır. Şarap, Portekiz'de üretilen önemli bir üründür ve buradaki çiftçiler elde edilen ürünlerdeki kaliteyi koruyarak yeni ürünler geliştirmek istemektedirler, bunun için de asma bitkilerini tanımlamak istemektedirler. Bu çalışmada, asma yaprağının görüntülerinden zar ve gövde bölgesinin ayrımını yapmak için U-Net CNN modeli kullanılmıştır. Özel bir veri seti kullanılmıştır. Bu veri seti, 733 asma görüntüsünden oluşmaktadır. Bu model, %95,6'lık zar ve %91,6'lık gövde tanıma doğruluğuna erişmiştir (Carneiro ve ark 2022). Şekil 2.3'te oluşturulan sistemin detayları gösterilmiştir.

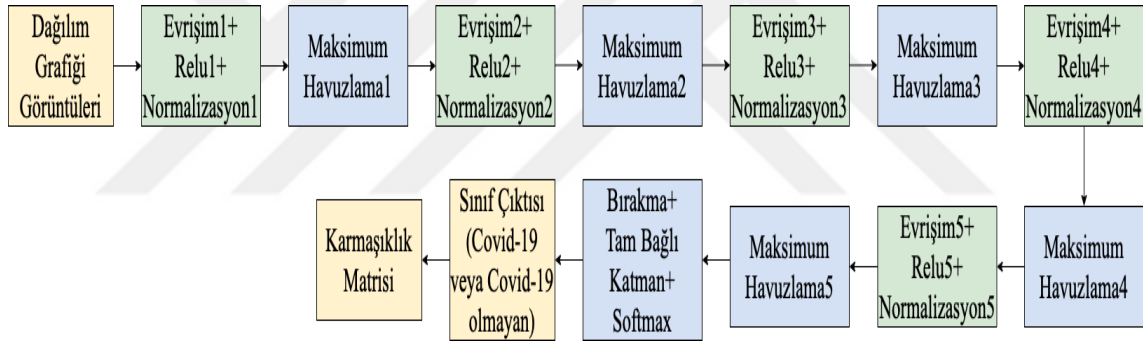


Şekil 2.3. Önerilen yöntem (Carneiro ve ark 2022)

Tuncer ve arkadaşlarının (2021) Covid-19 teşhisi ile ilgili yaptıkları bir çalışmada, CNN yapısını kullanılarak hastanın gerçekten Covid-19'a yakalanıp yakalanmadığı tespit edilmeye çalışılmıştır. Covid-19 dünya geneline yayılan salgın bir hastalıktır. Teşhisi için RT-PCR ve BT tarama teknolojileri sıklıkla kullanılmaktadır. Ancak RT-PCR, %10-15'lik bir yanılma payı göstermektedir. Eğer uzman kişi bu test sonucundan şüphelenirse BT tarama yöntemini kullanmaktadır. Ancak virüs hücreleri henüz ciğerlere ulaşmadıysa bu test sonucu da negatif çıkararak uzman doktoru yanıltabilmektedir. Bu sebeplerden dolayı, BT tarama ve RT-PCR yerine kullanılacak CNN tabanlı bir yöntem önerilmiştir. Dağılım Grafiği (Scattergram) görüntüleri kullanılarak yapılan bu sınıflandırma, 25 katman derinlikli CNN modeli olan Scat-NET mimarisine gerçekleştirilmiştir ve %92,4'lük bir doğruluk (accuracy) değerine ulaşarak derin öğrenmenin bu alan için de ne kadar önemli olduğunu göstermiştir (Tuncer ve ark 2021). Şekil 2.4'te dağılım grafiği görüntüsü verilirken, şekil 2.5'te önerilen sistemin detaylarına yer verilmiştir.



Şekil 2.4. Dağılım Grafiği (Scattergram) görüntüleri (Tuncer ve ark 2021)

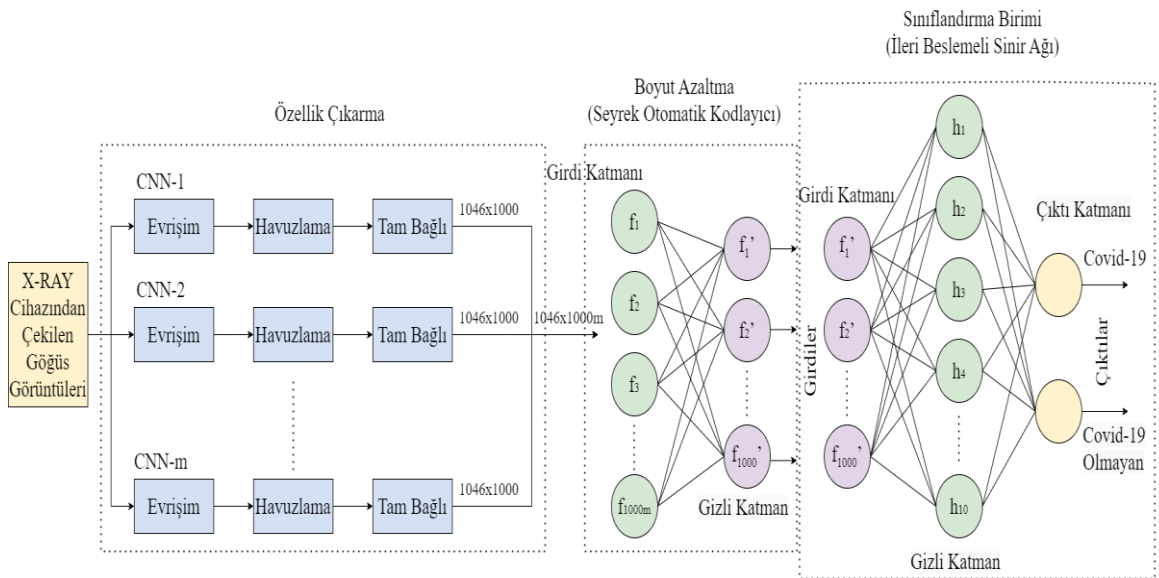


Şekil 2.5. Önerilen yöntem (25 Katmanlı Scat-Net) (Tuncer ve ark 2021)

Habib ve Rahman'ın (2021) Covid-19 teşhisi ile ilgili yaptıkları bir çalışmada, makine öğrenimi algoritmaları ve CNN kullanılarak ilişkili genlerden ve X-ışını görüntülerinden korona hastalıklarının teşhisi yapılmaya çalışılmıştır. Covid-19 hızla yayılan bir hastalıktır. Erken teşhis, her hastalıkta olduğu gibi bu hastalıkta da çok önemlidir ancak bazı tıbbi yetersizlikler teşhis için engel oluşturmaktadır. Bu çalışma erken teşhisi sağlayabilmek için iki farklı yol sunmaktadır: İlki, Covid-19 hastalığını tespit etmek ve onu Pnömoniden ayırt etmek için gen tabanlı bir çözüm bulmak. İkincisi ise, farklı makine öğrenimi algoritmaları (Random Forest, Naive Bayes vs.) ile sınıflandırma yaparak Pnömoni ve Covid-19'u ayırt etmektir. Bu çalışmada ilk yöntem %93 doğruluk (accuracy) sağlarken ikinci yaklaşım %99'luk bir doğruluk (accuracy) sağlamıştır (Habib ve Rahman 2021).

Narin ve arkadaşlarının (2021) yaptıkları çalışmada; COVID-19 hastalığının hızla yayılmasının önüne geçmek için erken teşhiste kullanılabilecek otomatik bir yöntem ortaya koymuşlardır. Akciğer röntgen görüntülerinin kullanıldığı çalışmada; COVID-19 hastası, sağlıklı, bakteriyel pnömoni ve viral pnömoni olacak şekilde 4 farklı sınıfı tespit etmek için CNN modelleri olan ResNet50, ResNet101, ResNet152 ve InceptionV3 ve InceptionResNetV2 modelleri kullanılmıştır. Çalışmadaki röntgen görüntülerinden toplamda 3 farklı veri seti oluşturulmuştur ve bu 3 farklı veri setlerinin tamamında da sırasıyla; %96,1 doğruluk (accuracy), %99,5 doğruluk (accuracy) ve %99,7 doğruluk (accuracy) ile ResNet50 modeli oldukça yüksek bir başarı göstermiştir (Narin ve ark 2021).

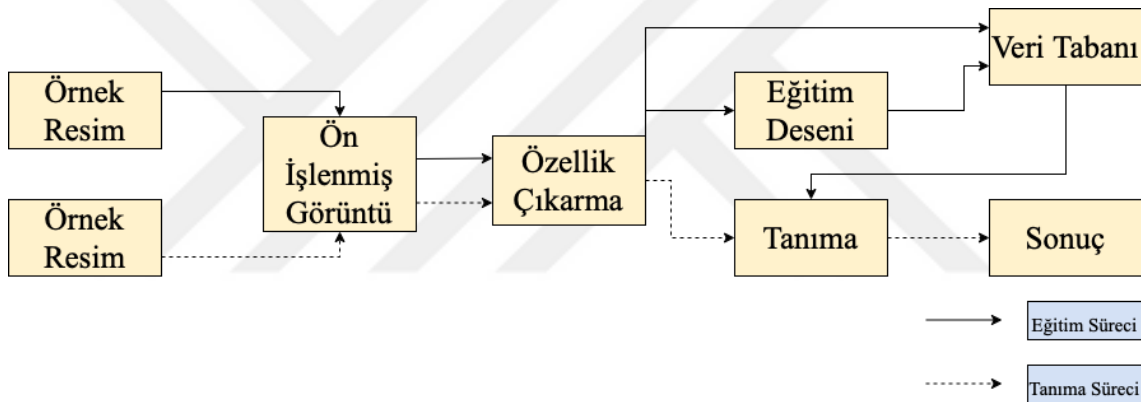
Gayathri ve arkadaşlarının (2022) Covid-19 teşhisi ile ilgili yaptıkları bir çalışmada, pandemi ile mücadele için göğüs röntgeni görüntülerini kullanan bilgisayar destekli bir tespit modeli sunmaktadır. RT-PCR, Covid-19'un teşhisi için bir standart olarak kabul ediliyor. Ancak RT-PCR ve diğer kaynaklar kısıtlıdır. Bu kaynak kullanımını azaltmak için radyografik görüntüleri kullanan bir CNN modeli öne sürülüyor. Modeli geliştirirken önceden eğitilmiş ağlar kullanılıyor. InceptionResnetV2 ve Xception modellerinden faydalanılan çalışmada, 504 Covid-19 hasta görüntüsü ve 542 Covid-19 olmayan (sağlıklı) birey görüntüsü kullanılmıştır. Modelde boyut azaltmak için Seyrek Otomatik Kodlayıcı ve İleri Beslemeli Sinir Ağı kullanılmıştır. Doğruluk (accuracy) değerinin %95,7 çıkması kullanılan tekniklerin fayda sağladığını göstermiştir (Gayathri ve ark 2022). Şekil 2.6'da önerilen yöntem sunulmuştur.



Şekil 2.6. Önerilen yöntem (Gayathri ve ark 2022)



Kruthika ve arkadaşlarının (2019) yaptıkları Alzheimer hastalığı ile ilgili bir çalışmada, Alzheimer'ın erken teşhisi için 3D Kapsül Ağı (CapsNet), 3D CNN ve önceden eğitilmiş 3D otomatik kodlayıcı teknolojisini kullanan bir CBIR sistemi ile hastalığın erken teşhisinin yapılabileceği gösterilmiştir. Alzheimer hastalığı, bilişsel yeteneklerin ileri düzeyde bozulması hastalığıdır. Alzheimer hastalığının indans oranı çok yüksektir ve yaşlıların %60-%80'inde gözlemlenen bir hastalıktır.(Gao ve Lima 2021) İçerik Tabanlı Görüntü Alma (CBIR) ile bilgisayar destekli erken teşhis uygulamaları yapılmaya başlanmış ve olumlu sonuçlar vermiştir. 3D Kapsül Ağı (CapsNet), 3D Evrişimsel Sinir Ağı (CNN) ve önceden eğitilmiş 3D otomatik kodlayıcı kullanılarak yapılan uygulama, sadece CNN kullanılarak yapılan uygulamadan daha başarılı olmuş ve %98,42 doğruluk (accuracy) değerine ulaşmıştır (Kruthika ve ark 2019). Şekil 2.7'de önerilen sistem gösterilmiştir.



Şekil 2.7. Alzheimer hastalığının sınıflandırılması için önerilen blok diyagram (Kruthika ve ark 2019)

Asaoka ve arkadaşlarının (2019) yaptıkları bir çalışmada Maküler Optik Koherens Tomografi görüntülerinden erken başlangıçlı Glokomu doğru teşhis edebilmek için Derin Öğrenme ve Transfer Öğrenmeyi tekniklerini kullanmışlardır. Bu çalışmada Açık Açılı Glokomlu (OAG) 1371 göz ve 193 normal göz kullanılmıştır. Çalışmada Derin Öğrenme disiplinlerinden biri olan CNN kullanılmıştır. Eğitim için OAG'li 94 farklı hastanın 94 göz görüntüsü ve sağlıklı 84 farklı bireyin 84 göz görüntüsü kullanılmıştır. Test için ise OAG'li 114 farklı hastanın 114 göz görüntüsü ve sağlıklı 82 farklı bireyin göz görüntüsü kullanılmıştır. CNN ile kurulan model iki aşamalı eğitilmiştir, ilk adımda ön eğitim veri seti kullanılmıştır, ikinci adımda ise ön eğitilmiş olmayan farklı bir veri seti ile eğitim yapılmıştır. CNN mimarisinin başarısını kıyaslamak için Rastgele Orman ve Destek Vektör Makinesi algoritmalarından faydalanılmıştır. Bu çalışmada başarıyı

değerlendirmek için Alıcı Çalışma Karakteristik Eğrisi Altındaki Alan (AROC) metriği kullanılmıştır. CNN modeli %93,7 AROC elde ederken, Rastgele Orman %82 ve Destek Vektör Makinesi %67,4 AROC elde etmiştir (Asaoka ve ark 2019).

Myburgh ve arkadaşlarının (2016) yaptıkları çalışmada Orta Kulak İltihabı hastalığını teşhis etmek için görüntü işleme tekniklerini kullanan otomatik bir sistem geliştirmişlerdir. 5 teşhis türü üzerinde yapılan çalışmada sınıflandırma yapmak için Karar Ağacı kullanılmıştır. Farklı kameralardan alınan görüntülere göre test doğruluğu değişen çalışmada, ticari video otoskop kamera ile çekilen görüntülerde %80,6 doğruluk (accuracy) elde edilirken özel yapım video otoskop kamera ile hemşire tarafından çekilen görüntülerde %78,7 doğruluk (accuracy) elde edilmiştir (Myburgh ve ark 2016).

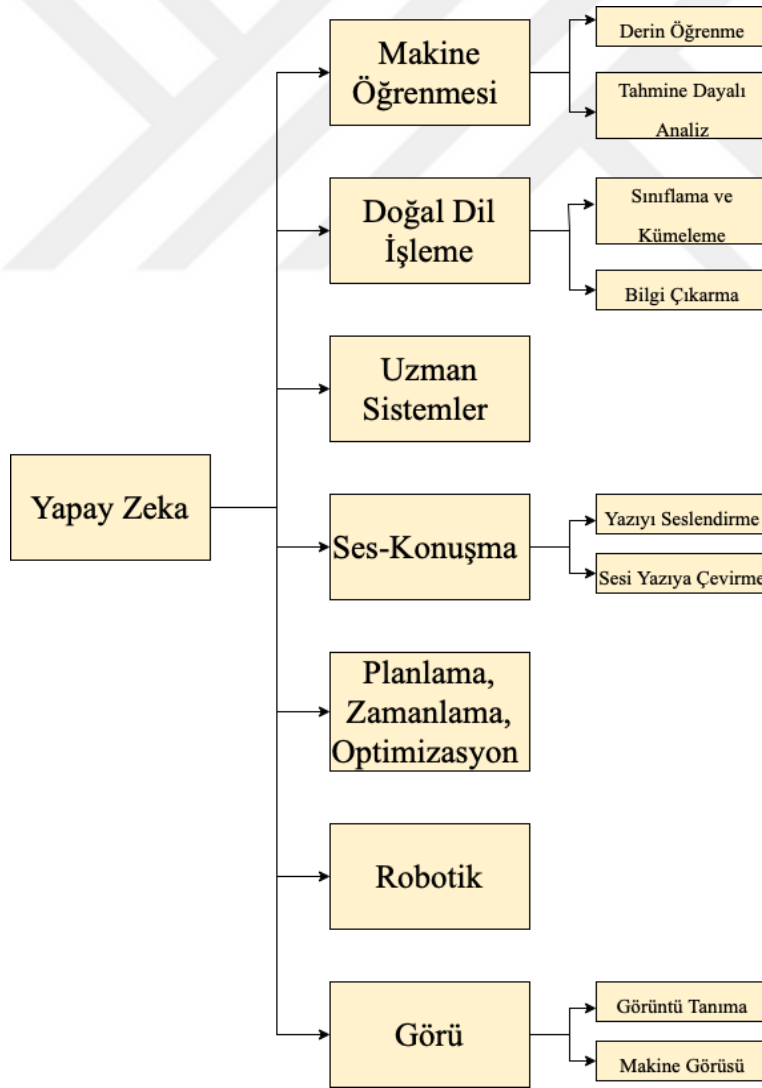
Myburgh ve arkadaşlarının (2018) yaptıkları çalışmada Android cihazlarda çalışabilen bir uygulama geliştirerek otomatik olarak Orta Kulak İltihabı (Otitis Media) hastalığını teşhis etmektedir. Bu çalışmada oluşturulan modelin eğitiminde 311 adet görüntü kullanılmıştır. Karar Ağacı kullanılarak yapılan sınıflandırmanın performansı %81,58 ve Sinir Ağı kullanılarak yapılan sınıflandırmanın performansı ise %86,84 olmuştur (Myburgh ve ark 2018).

Pham ve arkadaşlarının (2021) kulak zarı ile ilgili yaptıkları bir çalışmada, EAR-UNet derin öğrenme modeli kullanılarak hiçbir ön işlemde geçmemiş kulak zarı görüntülerinin segmentasyonu yapılmaktadır. Bu modelde U-Net modelinin üzerine EAR modeli eklenmiştir. EAR modeli şunları içermektedir: Kodlayıcı için EfficientNet, atlamalı bağlantı için Dikkat (Attention) katsayısı, kod çözücü için Artık (Residual) blok yapısı. EfficientNet-B4 modeli, U-NET modelinin üzerine kayıp fonksiyonu olarak kullanılmak üzere entegre edilmektedir. Kod çözücü kısmı da Artık blok sistemini kullanan ResNet modelini kullanmaktadır. Veri seti olarak, orta kulak iltihabı olan hastalar ve sağlıklılar şeklinde iki sınıf olarak 1012 tane otoskopik görüntü kullanılmıştır. Çalışmanın sonucunda %92,9'luk bir başarı sağlanmıştır (Pham ve ark 2021).

### 3. MATERYAL VE YÖNTEM

Bu bölümde dış kulak yolu, kulak zarı ve orta kulak görüntülerinin hastalıklarına göre sınıflandırılmasında kullanılan yöntemler ele alınmaktadır. Bu yöntemler sayesinde dış kulak yolu, kulak zarı ve orta kulak görüntüleri kullanılarak model eğitilir ve sınıflandırma yapılır. Sınıflandırma sonunda görüntünün sağlıklı olduğu ya da hasta ise hangi hastalığı taşıdığı öğrenilmektedir.

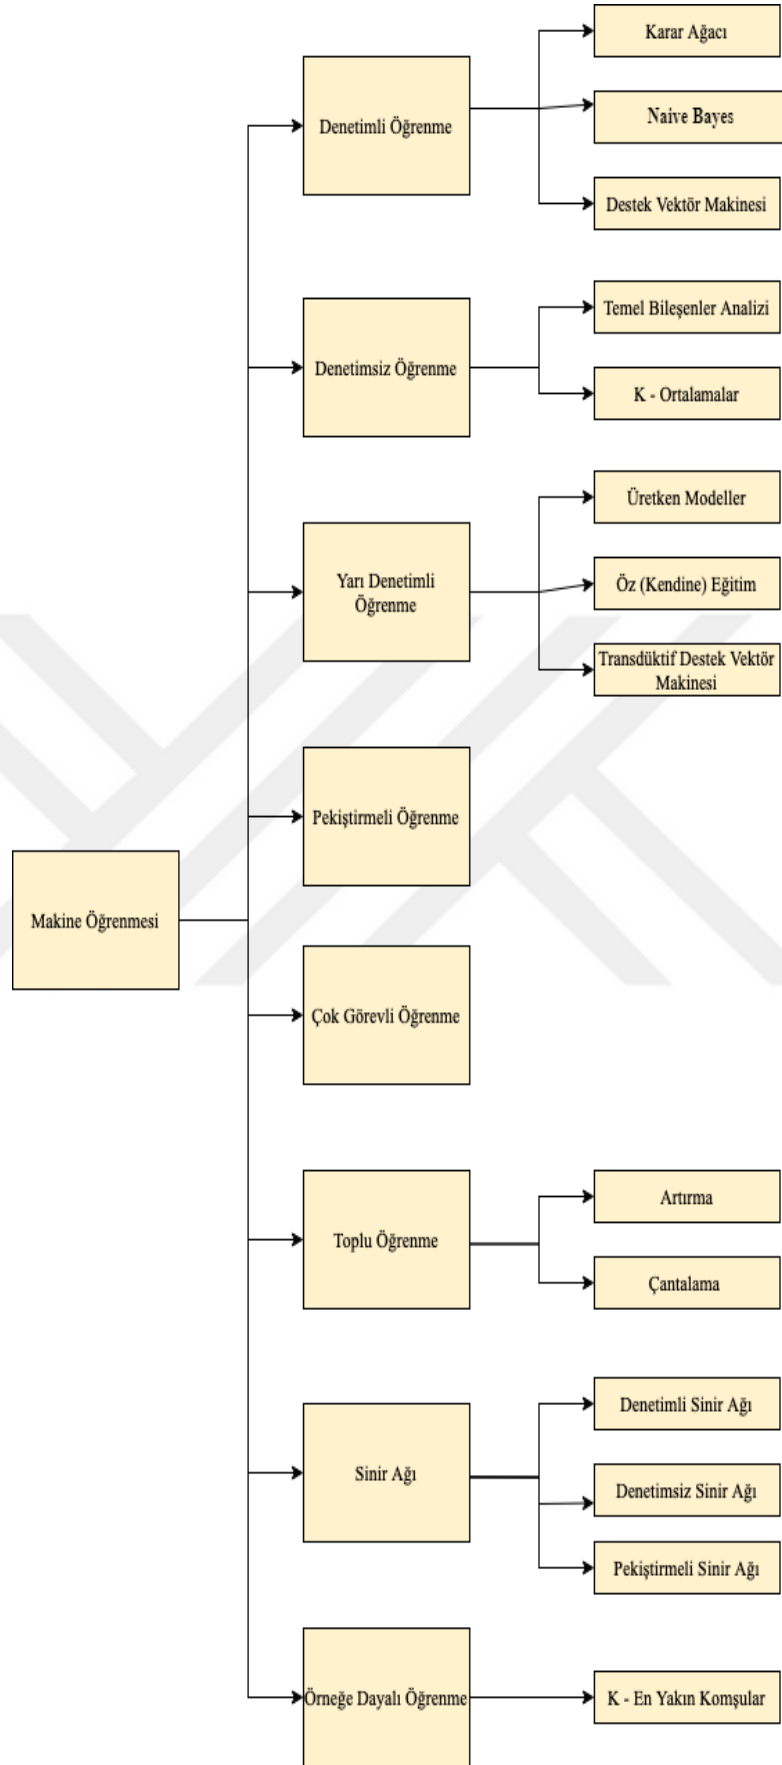
Yapay zekâ; makinelerin insanlar gibi düşünebilmesini, karar verebilmesini, geçmiş tecrübelerini değerlendirip davranışlarını güncelleyebilmesini sağlayan insanlığı ve doğayı kendine model alan bir disiplindir. Günümüzde bilimsel çalışmalarda daha çok sınıflandırma, kümeleme gibi çalışmalarda sıkça kullanılmaktadır (Demirhan ve ark 2010, Balaban ve Kartal 2015). Şekil 3.1’de yapay zekâ çalışma kapsamı gösterilmiştir.



Şekil 3.1. Yapay zeka çalışma kapsamı (Villanueva ve Salenga 2018)

Makine öğrenmesi, yapay zekanın önemli bir alt disiplinidir. Makinelere, verileri nasıl daha etkin kullanabileceğini ve verilerden nasıl anlamlı bilgiler çıkarabileceğini tanımlayan disiplindir. El yazısı tanıma, ses tanıma gibi alanlarda başarıları kanıtlanmış olduğu gibi farklı alanlarda da (medikal görüntüler gibi) oldukça başarılı olduğu yapılan çalışmalarda görülmektedir (Peng 2015). Lineer Regresyon, Lojistik Regresyon, Naive Bayes, Destek Vektör Makinesi, Karar Ağaçları, KNN (K en yakın komşu (K Nearest Neighbors)) algoritmaları bazı bilinen makine öğrenmesi algoritmalarıdır. Şekil 3.2’de makine öğrenmesi alt disiplinleri gösterilmiştir.






Şekil 3.2. Makine öğrenmesi alt disiplinleri (Mahesh 2020)

### 3.1. Derin Öğrenme

Derin öğrenme 2012 yılından beri oldukça ilgi gören bir alan olmuştur. Görüntü tanıma, ses tanımanın yanı sıra sağlık alanında da oldukça başarılı çalışmaların ortaya çıkmasına yol açmıştır. Derin öğrenmede bilgisayara elle kural girişi yapılmaksızın derin öğrenme her bir kavramı daha temel olan kavramlarla ilişkilendirir ve bu ilişkiler sayesinde öğrenme gerçekleşir (Özcan 2014, Goodfellow ve ark 2016).

Derin öğrenme, makine öğreniminin bir alt disiplindir. Derin öğrenme, doğrusal olmayan katmanlarda öğrenme sağlar. Önceki katmandan elde edilen sonuçlar bir sonraki katmanda girdi olarak kullanılmaktadır. Katmanlarda çıkarılan özelliklerden bazıları verinin daha iyi anlaşılmasını sağlar. Çeşitli derin öğrenme mimarileri mevcuttur (Şeker ve ark 2017). Şekil 3.3'te Imagenet yarışmalarında derin öğrenmenin yıllar içindeki hata oranları gösterilmektedir (İnik ve Ülker 2017).



Şekil 3.3. Derin öğrenmenin yıllara göre hata oranları (İnik ve Ülker 2017)

### 3.2. Evrimsel Sinir Ağı (CNN)

CNN mimarisi ilk olarak Yann LeCun tarafından 1998 yılında LeNet olarak adlandırılan mimari ile ortaya çıkmıştır. Günümüzde CNN çok yaygın olarak kullanılmaktadır. Bunun en büyük sebebi, özellik çıkartmaya gerek kalmadan verilerin direkt ağı verilip modelin katmanlarında öğrenme işlemi sağlamasıdır. Bu işlem büyük bir kullanım kolaylığı sağlamaktadır. CNN tekniğinin yaygın olmasının bir diğer önemli sebebi ise şudur; CNN katmanları parametre azaltarak ilerlemektedir ve bu da karmaşık problemlerin hızlı bir biçimde çözülmesini sağlayarak performansı arttırmaktadır (Akılotu ve ark 2019).

CNN mimarisinin klasik YSA'ya kıyasla en büyük avantajı tensörleri kullanmasıdır. Matrislerdeki komşuluk ilişkisi sayesinde veri kaybı önlenmektedir. Öte yandan, YSA vektörleri kullanması nedeniyle büyük bir dezavantajla karşılaşmaktadır (Traore ve ark 2018).

Yaygın CNN modellerinden bazıları; InceptionResNetV2, InceptionV3, ResNet50, ResNet50V2, ResNet101, ResNet101V2, VGG-16, EfficientNetB2, EfficientNetB3, Xception modelleridir. Bu modellerin yaygın olarak kullanılmasının sebebi benzer çalışmalarda göstermiş oldukları yüksek başarılarıdır. Çizelge 3.1'de bahsedilen bu başarılarla yönelik bir örnek gösterilmektedir.

**Çizelge 3.1.** Benzer bir çalışmada yer alan modeller ve doğruluk (accuracy) değerleri (Cha ve ark 2019)

Transfer Öğrenme Yapılan Modeller	Doğruluk (Accuracy)
SqueezeNet	%85,55
AlexNet	%87,2
ResNet18	%90,65
MobileNetV2	%90,75
GoogleNet	%90,9
Resnet50	%91,2
Resnet101	%91,55
InceptionV3	%92
InceptionResnetV2	%92,1

Bu modellerin, ImageNet veri seti ile önceden eğitilmiş versiyonlarını kullanarak transfer öğrenimi yapılmıştır ancak daha sonra bu modeller baştan tekrar eğitilmiştir. ImageNet veri setinin seçilmesinin sebebi ise şudur: ImageNet, farklı disiplinlere ait 14 milyondan fazla görüntü içeren geniş çaplı bir veri setidir. İçerisinde hemen hemen her disiplinden etiketlenmiş bir görüntü bulmak mümkündür. İçerisinde bu çalışmada kullanılan verilere de yakın veriler olacağı göz önüne alınarak, sahip olduğu çeşitlilik ve büyük boyutlu olmasından dolayı tercih edilmiştir. Transfer öğrenimi yönteminin uygulanmasının sebebi ise şöyle açıklanabilir: Geleneksel makine öğrenimi yöntemlerinde önceden eğitilmemiş ağlara veri seti verilmekte ve böylelikle eğitim gerçekleşmektedir. Bu eğitilen ağ ise sadece bu problemin çözümünde kullanılmaktadır. Transfer öğrenme yönteminde ise büyük bir veri seti ile bir ağ eğitilmekte sonra bu eğitilen ağ diğer başka problemlerde de kullanılabilir. Modelin yapısının yeni veri setine uygun hale getirilmesine olanak tanınması büyük avantaj sağlamaktadır. Böylelikle eğitilmiş ağa küçük boyutlu bir veri seti verilse bile önceden elde ettiği bu ağırlıkları

kullanarak iyi derecede öğrenme sağlayabilmektedir (Hussain ve ark 2018, Akilotu ve ark 2019). Bu avantajlarından dolayı bu çalışmada hem maliyeti düşürmek hem de çalışmaya hız kazandırmak amacıyla ImageNet veri seti ile önceden eğitilmiş modeller kullanılmıştır.

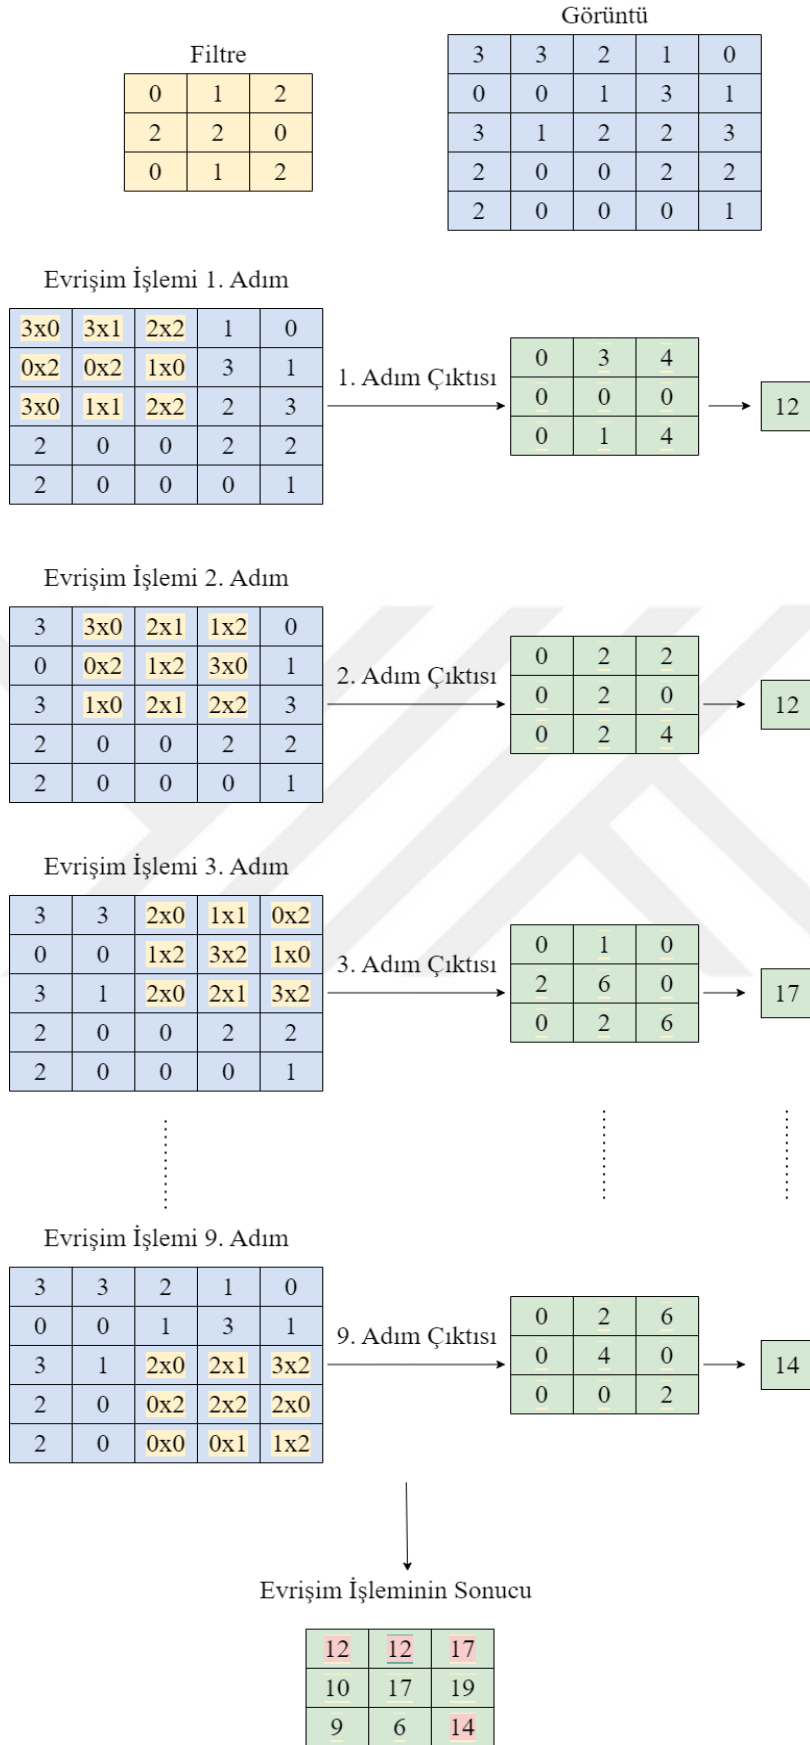
### **3.2.1. Evrişimsel sinir ağı yapısı ve modelleri**

Evrişimsel Sinir Ağları (CNN) çeşitli görevleri başarıyla gerçekleştirebilmek için birçok yapıdan oluşmaktadır. Bu bölümde bu yapılara ve çalışmada kullanılan bazı modellere yer verilmektedir.

#### **3.2.1.1. Evrişim katmanı (Convolution layer)**

Evrişim katmanı (Convolution layer), CNN mimarisinin temelidir. Görüntüdeki özellikleri çıkartma görevi üstlenmektedir. Görüntüdeki özellikleri çıkartmak için çeşitli filtreler uygular. Görüntüye uygulanan bu filtreler neticesinde bir aktivasyon haritası oluşturulur. Bu aktivasyon haritası sayesinde önemli noktalar belirlenmiş olur. Bu özelliklere ek olarak; evrişim katmanı, boyut ve kanal sayısını değiştirmektedir (Tuncer ve ark 2021). Şekil 3.4'te görüntü boyutlarına uygun olarak belirlenmiş bir filtrenin bir görüntü üzerinde uygun adım sayısına (stride) ve piksel ekleme değerine (padding) göre konvolüsyonuna yer verilmiştir (Murphy 2016).

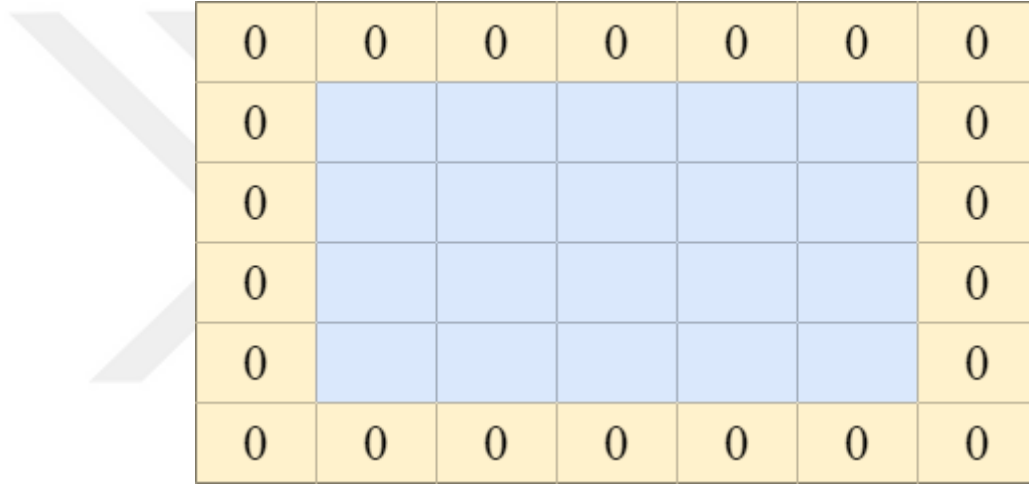




**Şekil 3.4.** Adım aralığının (stride) 1 olduğu ve piksel eklemenin (padding) olmadığı basit evrşim işlemi (Murphy 2016)

### 3.2.1.2. Piksel ekleme (Padding)

Piksel Ekleme (Padding) girdi görüntüsüne ait matrisin etrafındaki piksellere sıfır ekleyerek çıktı matrisinin boyutunun çok fazla azalmasına engel olmak için kullanılmaktadır. Çok katmanlı ağlarda arka arkaya gelen evrişim katmanları girdi görüntüsüne ait matrisin boyutunu oldukça azaltmaktadır ve bu durum da bazı ağlarda problemlere sebep olmaktadır. Bunun önüne geçmek için Piksel Ekleme kullanılmaktadır (Murphy 2016). Şekil 3.5'te görüntüye ait matrisin etrafına 1 birim boyutunda ve değeri 0 olan piksellerin eklenmesi işlemine ait örnek verilmiştir (Wahyudi Setiawan ve ark 2019).



0	0	0	0	0	0	0
0						0
0						0
0						0
0						0
0	0	0	0	0	0	0

Şekil 3.5. Görüntü matrisinin etrafına 1 birim boyutunda 0 değerli piksellerin eklenmesi (Wahyudi Setiawan ve ark 2019)

### 3.2.1.3. Adım aralığı (Stride)

Adım aralığı, görüntü matrisi üzerinde gezinerek aktivasyon haritasının oluşmasını sağlamak için uygulanan filtrenin (kernel) görüntü matrisi üzerinde yatayda ve dikeyde kaç birim kaydırılacağını ifade etmektedir. Adım aralığı ne kadar büyük olursa çıktı matrisinin boyutu o kadar küçük olacaktır (Murphy 2016). Şekil 3.6'da adım aralığı 2 olarak belirlenen filtrenin (kernel) görüntü matrisi üzerinde kaydırılması işlemi gösterilmiştir (Wahyudi Setiawan ve ark 2019).



**Şekil 3.6.** Adım aralığı 2 olarak belirlenen filtrenin (kernel) görüntü matrisi üzerinde kaydırılması (Wahyudi Setiawan ve ark 2019)

### 3.2.1.4. Normalizasyon



Normalizasyon, CNN işlem süresini azaltmayı hedefleyen katmandır. Denklem 3.1’de verilen ifade ile normalleştirme işlemi yapılmaktadır (Tuncer ve ark 2021).

$$x' = \frac{x}{\left(K + \frac{\alpha \cdot ss}{\text{pencereKanalBoyutu}}\right)^\beta} \quad (3.1)$$

Bu denklemden;  $x$  girdi,  $K$ ,  $\alpha$ , ve  $\beta$  hiperparametrelerdir. Son olarak  $ss$  ise kareler toplamını ifade etmektedir. CNN mimarilerinde genelde ReLU fonksiyonu kullanılır. Bunun sebebi ise girdi olarak verilen değerlerden negatif olanları sıfıra çekmesi ve daha hızlı bir öğrenme sağlamasıdır (Tuncer ve ark 2021).

### 3.2.1.5. Havuzlama katmanı (Pooling layer)


Havuzlama katmanı (Pooling Layer), Evrişim katmanını takiben kullanılır. Modelin parametre sayısını ve boyutunu azaltır. Maksimum değerlerle çalışan maksimum havuzlama ve ortalama değerlerle çalışan ortalama havuzlama olarak iki çeşidi vardır. Scherer ve arkadaşlarının yapmış olduğu bir çalışmada maksimum ve ortalama havuzlamanın bir kıyası mevcuttur. Yapılan çalışmada maksimum havuzlamanın daha hızlı yakınsama yapabildiği ve genelleştirmelerinin daha iyileştirilmiş olduğu görülmüştür (Scherer ve ark 2010). Avantajları göz önüne alındığında maksimum havuzlama kullanmak daha doğru olmaktadır ve literatüre bakıldığında da oldukça başarılı sonuçlar elde edildiği görülmektedir. Havuzlama katmanı Evrişim katmanına çok benzer olarak bir filtrenin (kernel) kaydırılmasıyla gerçekleşir, teknik olarak benzer olsa da içeriğinde küçük farklar mevcuttur (Dumoulin ve Visin 2016, Murphy 2016, Tuncer ve ark 2021). Evrişim katmanından gelen matrisin derinliğini korurken boyutlarını azaltmaya çalışmaktadır. Şekil 3.7’de havuzlama işlemlerine örnek verilmektedir.



Şekil 3.7. Maksimum havuzlama ve Ortalama havuzlama işlemlerine örnek (Wahyudi Setiawan ve ark 2019)

### 3.2.1.6. Dropout

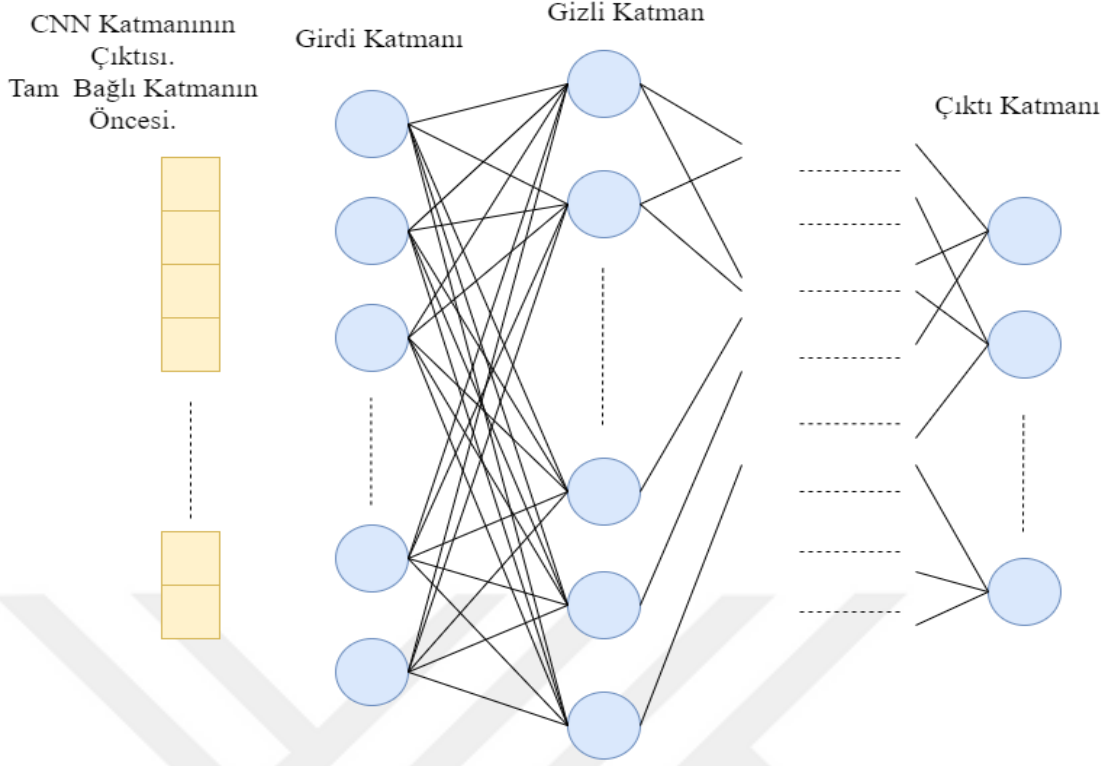
Dropout, aşırı öğrenmenin önüne geçmek için eğitim esnasında bazı nöronların unutulmasını sağlamaktadır. Dropout uygulandığı gizli katmandaki nöronun çıkışını sıfıra ayarlayarak o nöronun dondurulmasını, dolayısıyla da hem ileri yayılım hem de geri yayılıma katılmasını engelleyerek nöronun bir sonraki nörona güvenmesini engellemiş yani aşırı öğrenmenin önüne geçmiş olur. Dropout eğitim esnasında uygulanarak daha sağlam bir öğrenme süreci gerçekleştirilmiş olunur. Test aşamasında uygulanamaz (Krizhevsky ve ark 2017). Şekil 3.8’de dropout uygulandıktan sonraki ağıın görüntüsü verilmiştir.



Şekil 3.8. Bir sinir ağına dropout uygulandıktan sonraki durumu

### 3.2.1.7. Tam bağlı katman (Fully connected layer) ve softmax

Tam bağlı katman (Fully Connected Layer), her nöronun kendisinden bir sonraki katmanda yer alan tüm nöronlara bağlı olduğu yapıdır. CNN mimarisinin sonunda bulunur ve sınıf değerleri burada belli olur. En son sınıflandırma katmanında, genellikle Softmax aktivasyon fonksiyonundan faydalanılarak çıktılar elde edilir (Tuncer ve ark 2021). Bu çıktılarda Softmax aktivasyon fonksiyonundan faydalanarak sınıflara 0-1 arasında belli oranlar verir, en çok hangi sınıfın oranı yüksekse o ait olunan sınıf olmaktadır. Şekil 3.9'da tam bağlı katmanın basit bir gösterimi mevcuttur (Sindi ve ark 2021).



Şekil 3.9. Tam bağlı katmanın gösterimi (Sindi ve ark 2021)

### 3.2.1.8. Optimize edici (Optimizer)

Optimizer algoritmalarının görevi, modelin başarısını artırmak için kayıp fonksiyonundan alınan çıktının değerini en düşük değere getirmek üzere modele ait ağırlıkları ve öğrenme oranını en uygun değerlere güncellemektir. Çeşitli optimizer algoritmaları mevcuttur. Adadelta, Adagrad, Adamax, Adam, Ftrl, Nadam, RMSprop, SGD bunlardan bazılarıdır. En çok tercih edilen optimizer ise Adam algoritmasıdır. Adam, adını Adaptif Moment Tahmini (Adaptive Moment Estimation) kelimelerinden almıştır. Adaptif momentum tahminlerinin gradyan inişi ile birleşerek kayıp fonksiyonunun değerini en aza indirmeyi amaçlayan bir optimizördür. Uygulanmasının kolay olması, hesaplama açısından verimli ve az bellek gereksinimine sahip olması gibi birçok pozitif özelliği barındırdığı için büyük problemlerde de kullanılmaktadır (Kingma ve Ba 2014, Llugsi ve ark 2021).

### 3.3. Değerlendirme Metrikleri

Bir deneyin sınıf çıktısının elde edilmesini sağlayan yöntem sınıflandırıcı denir. Sınıflandırma işleminden önce yapılan tahminin, sınıflandırma işleminden sonra elde

edilen sonuçla kıyaslanması, çalışmanın performansının kolaylıkla yorumlanması ve bilimsel açıdan değerli olması sebebiyle önemli ve gereklidir. Bu kıyaslamanın gösterildiği matrise karmaşıklık matrisi denir. Karmaşıklık matrisinin satır ve sütun sayısı veri setinde yer alan sınıf sayısına göre belirlenir (Ruuska ve ark 2018). Şekil 3.10'da örnek bir karmaşıklık matrisi verilmiştir.

		Tahmini Sınıf Etiketi	
		Negatif	Pozitif
Gerçek Sınıf Etiketi	Negatif	DP	YN
	Pozitif	YP	DN

Şekil 3.10. Karmaşıklık matrisine basit bir örnek (Polat ve Güneş 2007)

Çalışmadaki sınıflandırma işlemlerinin sonuçlarını gösteren karmaşıklık matrisleri; doğru pozitifler (DP), doğru negatifler (DN), yanlış pozitifler (YP), yanlış negatifler (YN) değerlerinden oluşmaktadır. Modelin değerlendirilmesi için de doğruluk (accuracy), kesinlik (precision), duyarlılık (recall), f1-skor (f1-score) metrikleri kullanılmaktadır. Bahsedilen metriklerin hesaplanması için gerekli formüller denklem (3.2), denklem (3.3), denklem (3.4) ve denklem (3.5)'de verilmiştir (Gonzalez-Huitron ve ark 2021).

$$accuracy = \frac{DP+DN}{DP+DN+YP+YN} \quad (3.2)$$

$$precision = \frac{DP}{DP+YP} \quad (3.3)$$


$$recall = \frac{DP}{DP+YN} \quad (3.4)$$

$$f1 - score = \frac{2*precision*recall}{precision+recall} \quad (3.5)$$



### 3.4. ResNet50

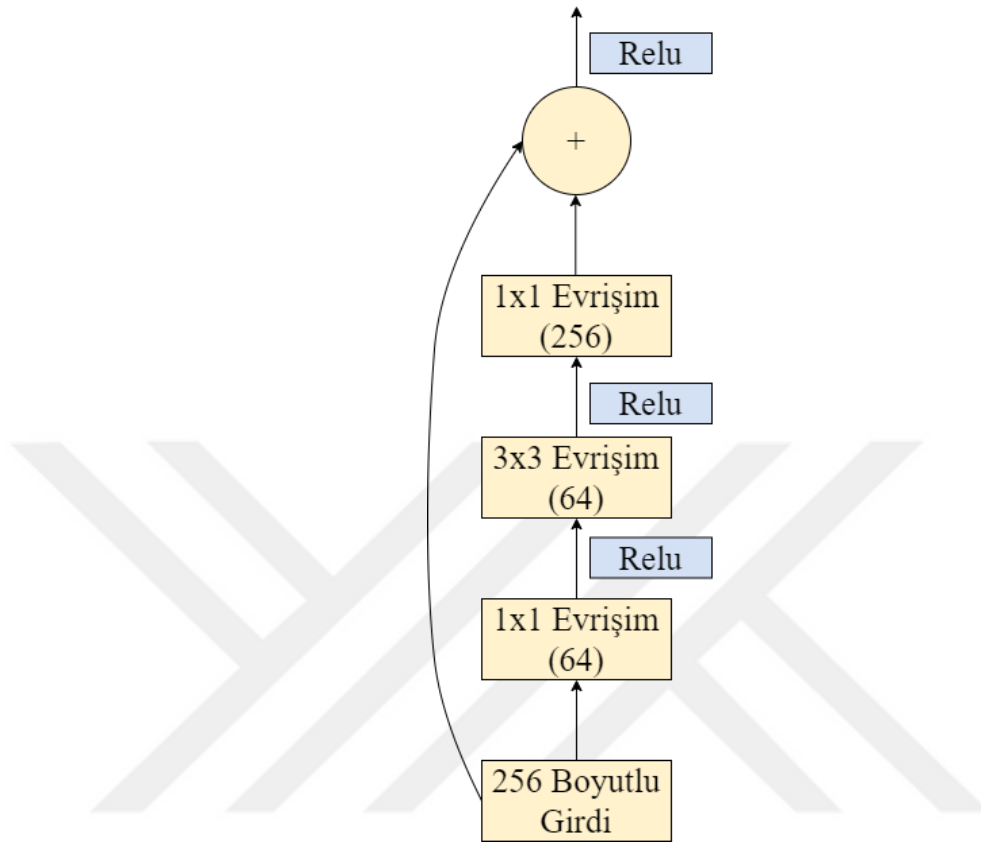
Evrişimsel Sinir Ağlarında (CNN) genelde derinlik arttıkça modellerin doğruluk (accuracy) oranlarının artması beklenir ancak bir noktaya kadar artan doğruluk (accuracy) oranı bir yerden sonra azalmaya başladığı gözlemlenmiştir. ResNet50 modeli bu probleme çözüm getirmektedir. ResNet50 mimarisi içerisinde bir kavram geliştirilmiştir, bu kavramda önceki ağına girdileri ile sonraki ağına çıktıları arasında bir katman atlanarak birleştirme işlemi gerçekleştirilmektedir. Bu işlem, "Res Blok" olarak adlandırılmaktadır. Res Blok yapılmasının temel amacı, ara değerlerde sıfır değerleri olsa bile önceki değerlerle işlem yapmaya devam ederek veri kaybını en aza indirmek ve modelin güvenliğini sağlamaktır. Ek olarak Res blok, öğrenmeyi sağlayan gradyanların kaybolmasını da önlemektedir (He ve ark 2016, Demir ve ark 2019, Talo 2019). Şekil 3.11'de geliştirilmiş olan model görselleştirilmiştir.



Şekil 3.11. Geliştirilen konsept

ResNet50 mimarisi, ILSVRC 2015 ve COCO 2015 yarışmalarında birinci olmuş bir mimaridir. Farklı veri setlerinde oldukça kolay kullanılabilir. Bu mimaride; 1x1, 3x3 ve 1x1 boyutlarında beş tane evrişim katmanı kullanılmaktadır. 1x1 olanlar boyut azaltmak amacıyla kullanılırken 3x3 olanlar daha fazla boyutlarda filtreleme işlemi gerçekleştirmek için kullanılmaktadır. Mimaride bir tane maksimum havuzlama (maximum pooling) ve bir tane de ortalama havuzlama (average pooling) kullanılmıştır. Tam bağlı katmanının çıkışında 1000 kategoriden oluşan bir çıkış verilmiştir. Bu mimari 25,6 milyon parametreden oluşmaktadır. ResNet50 224x224'lük bir giriş boyutuna sahiptir. 3 katman derinliğinden oluşan bu mimari, 16x3 katmanlı derinlikli konvolüsyon işlemi uygulamaktadır. Modelin mimarisi: Evrişim, maksimum havuzlama, evrişim, evrişim, evrişim (3 derinlik x 6), evrişim, ortalama havuzlama, tam bağlı (1000 sınıflı

çıkış vermektedir) şeklindedir (He ve ark 2016, Talo 2019). Şekil 3.12’de ResNet50 modelinin blok yapısı gösterilmiştir.



Şekil 3.12. ResNet50 blok yapısı (He ve ark 2016)

ResNet50V2 modeli, ResNet50 modelinin daha da geliştirilmiş halidir.

### 3.5. ResNet101

ResNet101, ResNet50’ye çok benzerdir. Sadece mimari anlamda bazı farklılıkları vardır. ResNet101, 101 katmana sahip Evrişimsel Sinir Ağıdır (CNN). 3 katman derinliğindedir. ResNet101 224x224’lük bir giriş boyutuna sahiptir. ResNet101 CNN modelinin mimarisi: Evrişim, maksimum havuzlama, evrişim, evrişim, evrişim (3 derinlik x 23), evrişim, ortalama havuzlama, tam bağlı (1000 sınıflı çıkış vermektedir) şeklindedir. ResNet50 ile 4. evrişim katmanında yapısal olarak bir farkları olduğu görülmektedir. Çizelge 3.2’de ResNet modeline ait mimari çeşitler ve dizilimlerine ait ayrıntılar verilmiştir (He ve ark 2016, Demir ve ark 2019).

Çizelge 3.2. ResNet mimarileri (He ve ark 2016)

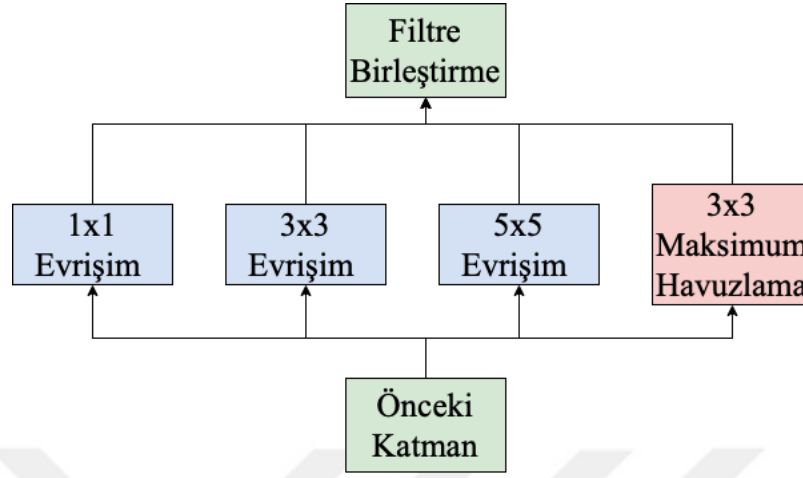
Katman Adı	Çıktı Boyutu	ResNet18 (18 Katman)	ResNet34 (34 Katman)	ResNet50 (50 Katman)	ResNet101 (101 Katman)	ResNet152 (152 Katman)
Evrişim-1	112x112	7x7, 64, adım aralığı 2				
Evrişim-2_x	56x56	3x3 maksimum havuzlama, adım aralığı 2				
		3x3, 64 3x3, 64 (Bu katmandan 2 adet mevcut)	3x3, 64 3x3, 64 (Bu katmandan 3 adet mevcut)	1x1, 64 3x3, 64 1x1, 256 (Bu katmandan 3 adet mevcut)	1x1, 64 3x3, 64 1x1, 256 (Bu katmandan 3 adet mevcut)	1x1, 64 3x3, 64 1x1, 256 (Bu katmandan 3 adet mevcut)
Evrişim-3_x	28x28	3x3, 128 3x3, 128 (Bu katmandan 2 adet mevcut)	3x3, 128 3x3, 128 (Bu katmandan 4 adet mevcut)	1x1, 128 3x3, 128 1x1, 512 (Bu katmandan 4 adet mevcut)	1x1, 128 3x3, 128 1x1, 512 (Bu katmandan 4 adet mevcut)	1x1, 128 3x3, 128 1x1, 512 (Bu katmandan 8 adet mevcut)
Evrişim-4_x	14x14	3x3, 256 3x3, 256 (Bu katmandan 2 adet mevcut)	3x3, 256 3x3, 256 (Bu katmandan 6 adet mevcut)	1x1, 256 3x3, 256 1x1, 1024 (Bu katmandan 6 adet mevcut)	1x1, 256 3x3, 256 1x1, 1024 (Bu katmandan 23 adet mevcut)	1x1, 256 3x3, 256 1x1, 1024 (Bu katmandan 36 adet mevcut)
Evrişim-5_x	7x7	3x3, 512 3x3, 512 (Bu katmandan 2 adet mevcut)	3x3, 512 3x3, 512 (Bu katmandan 3 adet mevcut)	1x1, 512 3x3, 512 1x1, 2048 (Bu katmandan 3 adet mevcut)	1x1, 512 3x3, 512 1x1, 2048 (Bu katmandan 3 adet mevcut)	1x1, 512 3x3, 512 1x1, 2048 (Bu katmandan 3 adet mevcut)
	1x1	Ortalama havuzlama, 1000 sınıflı çıktı, Softmax aktivasyon fonksiyonu				
TOPLAM		1,8 x 10 <sup>9</sup>	3,6 x 10 <sup>9</sup>	3,8 x 10 <sup>9</sup>	7,6 x 10 <sup>9</sup>	11,3 x 10 <sup>9</sup>

ResNet101V2 ise, ResNet101 modelinden daha gelişmiş bir versiyondur. Bu versiyonda artık (residual) blokta farklı mimari düzenlemeler yapılmıştır ve toplu normalleştirme ile Relu aktivasyon fonksiyonu, evrişim katmanından önce yerleştirilerek kullanılmıştır (Rahaman ve ark 2020).

### 3.6. InceptionV3

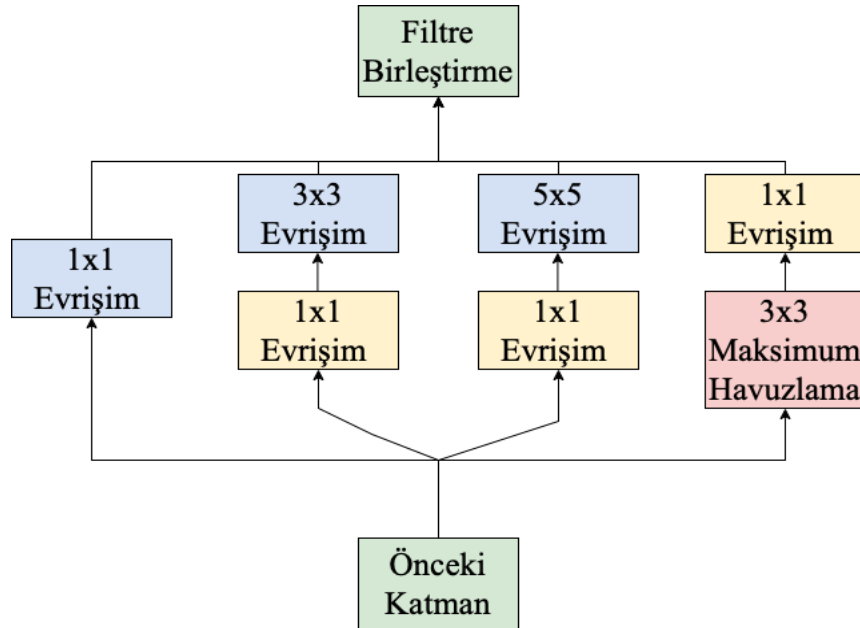
GoogleNet olarak da bilinen InceptionV1 modeli, 2014'te yapılan ILSRVRC'de ImageNet veri seti üzerinde yapılan çalışmada en düşük hata (error) oranını yakalayan ün kazanmıştır. InceptionV1, 5x5 boyutunda konvolüsyon uygulayarak girdi boyutunu önemli ölçüde azaltır. Bu durum veri kaybını da beraberinde getireceği için doğruluk (accuracy) azalacaktır. Bu gibi noktalar göz önüne alındığında modelin geliştirilmesi

gerektiğine karar verilmiştir (Szegedy ve ark 2015). Şekil 3.13'te InceptionV1 modelinin yapısı gösterilmiştir.



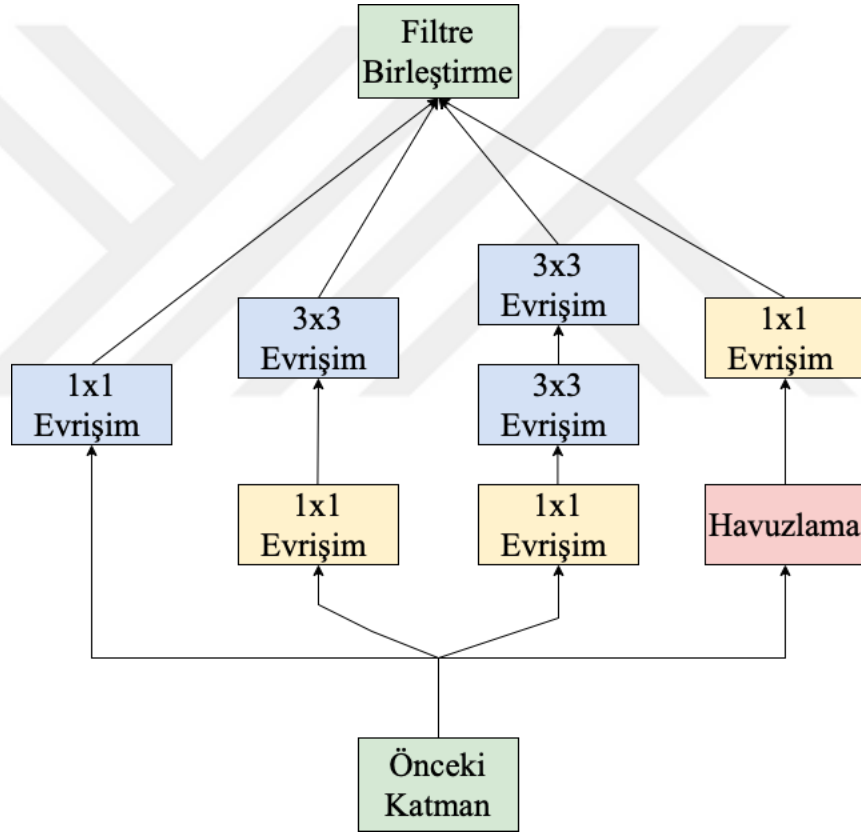
Şekil 3.13. Naif Inception modülü (Szegedy ve ark 2015)

Naif Inception modülünde çıkış bloğu yüksek boyutlu olduğu için parametre sayısını da arttırmaktadır, bu da probleme neden olmaktadır. Bu problemi çözmek için darboğaz (bottleneck) denilen 1x1 boyutunda tensörler kullanılmıştır. Burada görüntü, 1x1 boyutunda tensörlerle çarpılarak kanal sayısını azaltmış dolayısıyla da parametre sayısını azaltarak hedeflenen düşük maliyet elde edilmiştir (Szegedy ve ark 2015). Şekil 3.14'te modelin detayları gösterilmiştir.

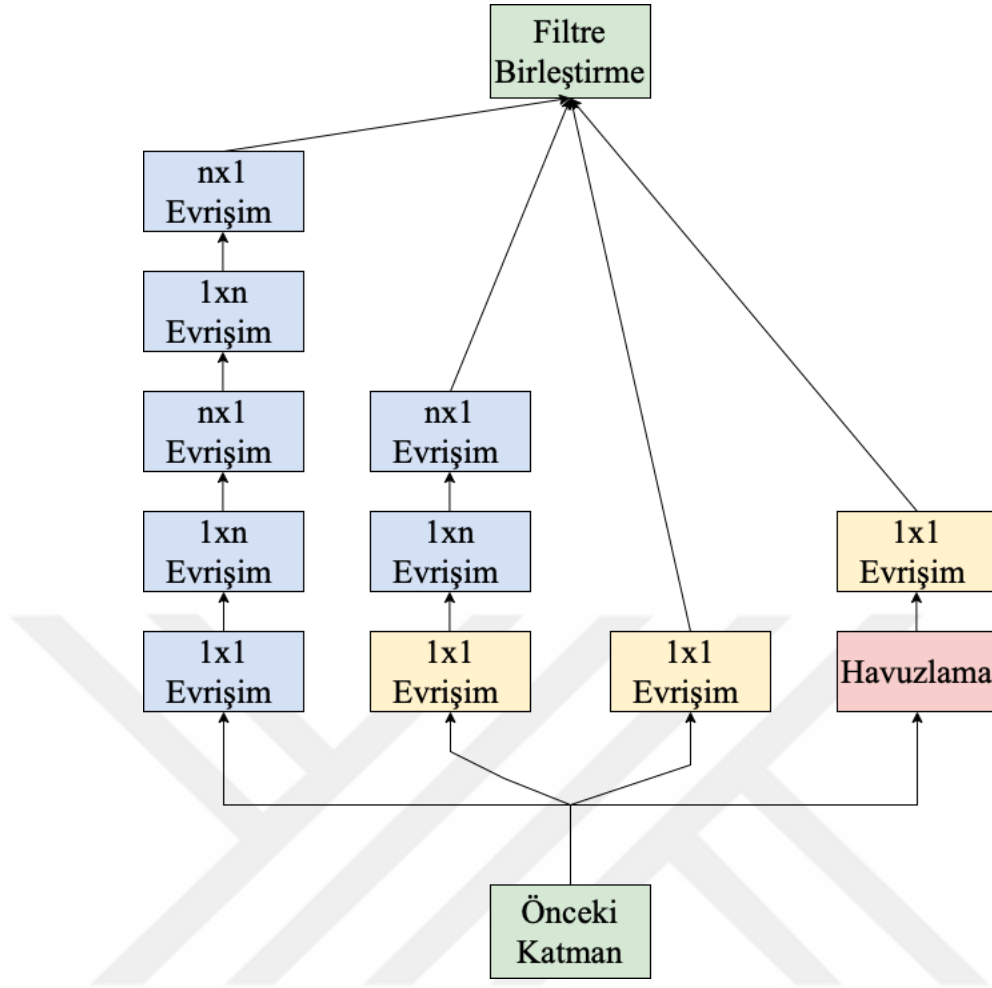


Şekil 3.14. Boyut azaltmalı Inception modülü (Szegedy ve ark 2015)

Bir CNN modelinden en iyi şekilde faydalanmak için genişlik ve derinlik arasında denge kurmak gerekmektedir. InceptionV1 ise ardışık olarak derinleşmektedir. Karmaşıklığı azaltmak adına çeşitli yöntemler sunulmuştur. 5x5 filtre yerine 3x3 boyutlu filtreler kullanılabilir ve bu sayede maliyet düşürülür çünkü 5x5 filtreler 3x3 boyutundaki filtrelere göre 2,78 kat daha maliyetlidir. Hatta bu maliyetten de fazladan %33 oranında kar elde etmekte mümkündür. Bunun için de 3x3 boyutlu filtreleri direkt uygulamak yerine, 1x3 ve 3x1 olarak uygulamak yeterli olmaktadır. Bu yeniliklerin gerçekleştirildiği Inception modülüne ise InceptionV2 adı verilmiştir (Szegedy ve ark 2016). Şekil 3.15'te 5x5 filtrenin yerine 3x3 filtrelerin uygulanmış hali sunulmuştur. Şekil 3.16'da ise 3x3 filtrelerin 1x3 ve 3x1 şeklinde uygulanmasının temel mantığı görselleştirilmiştir.

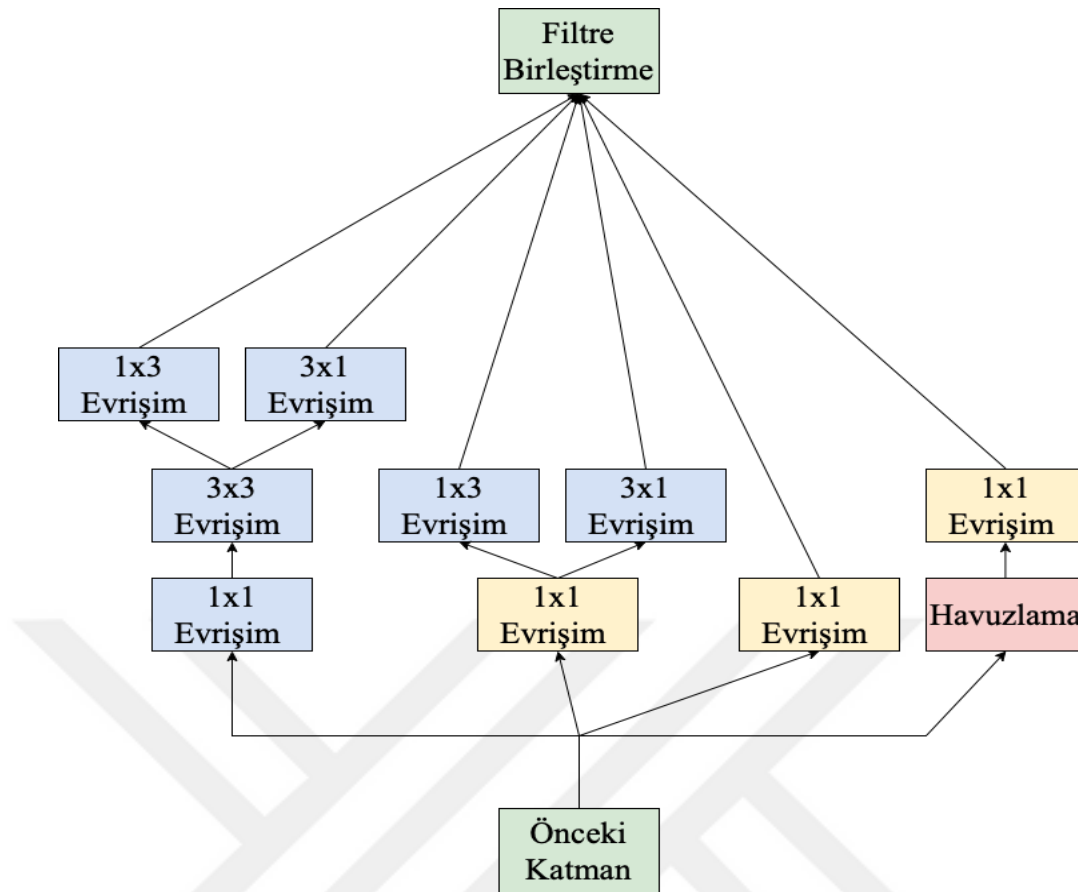


**Şekil 3.15.** 5x5 boyutundaki filtrenin yerine 3x3 boyutundaki iki filtrenin uygulanmış hali (Szegedy ve ark 2016)



Şekil 3.16.  $nxn$  boyutundaki her bir filtre  $1xn$  ve  $nx1$  olarak iki kere uygulanmıştır (Szegedy ve ark 2016)

Şekil 3.16’da görüldüğü üzere  $1x1$ ’lerden oluşan darboğaz (bottleneck) sorununu çözmek üzere, modeli derinleştirmek yerine onu genişletme fikri ortaya çıkmıştır. Şekil 3.17’de model gösterilmiştir.



Şekil 3.17. Derinliğin artışının önüne geçmek için daha geniş bir modül (Szegedy ve ark 2016)

Özetle, InceptionV2 modelinin mimarisi çizelge 3.3'te verildiği şekildedir.

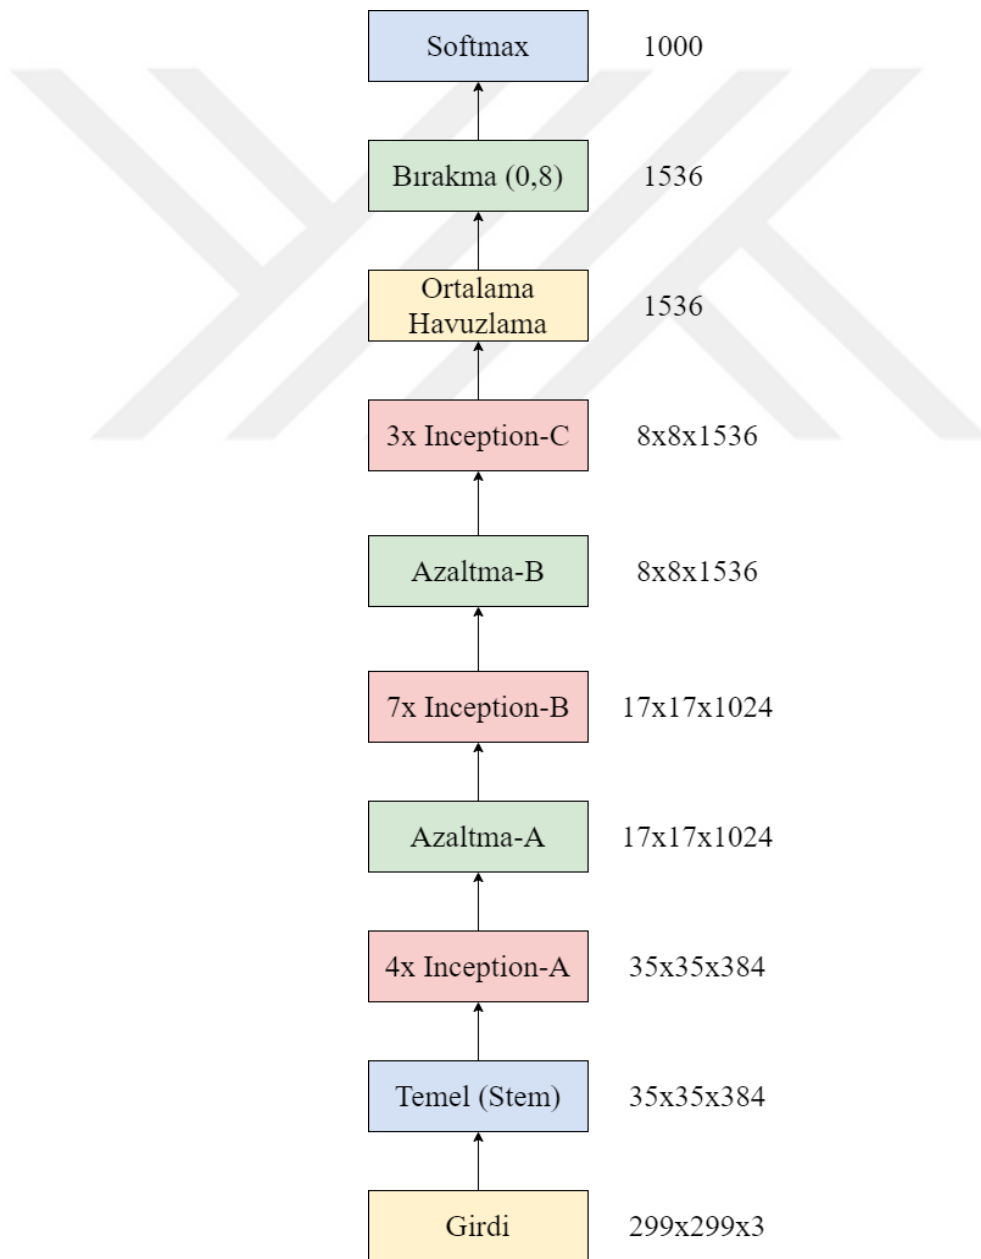
Çizelge 3.3. InceptionV2 modeli özetidir. Burada ifade edilen şekil 5, 6, 7 sırasıyla; şekil 3.9, şekil 3.10 ve şekil 3.11'e karşılık gelmektedir (Szegedy ve ark 2016)

Katman	Yama Boyutu/ Adım veya Açıklamalar	Girdi Boyutu
Evrişim	3x3 / 2	299x299x3
Evrişim	3x3 / 1	149x149x32
Dolgu Eklenmiş Evrişim	3x3 / 1	147x147x32
Havuzlama	3x3 / 2	147x147x64
Evrişim	3x3 / 1	73x73x64
Evrişim	3x3 / 2	71x71x80
Evrişim	3x3 / 1	35x35x192
3 x Inception	Şekil 5	35x35x288
5 x Inception	Şekil 6	17x17x768
2 x Inception	Şekil 7	8x8x1280
Havuzlama	8x8	8x8x2048
Lineer	Düzleştirme	1x1x2048
Softmax	Sınıflandırıcı	1x1x1000

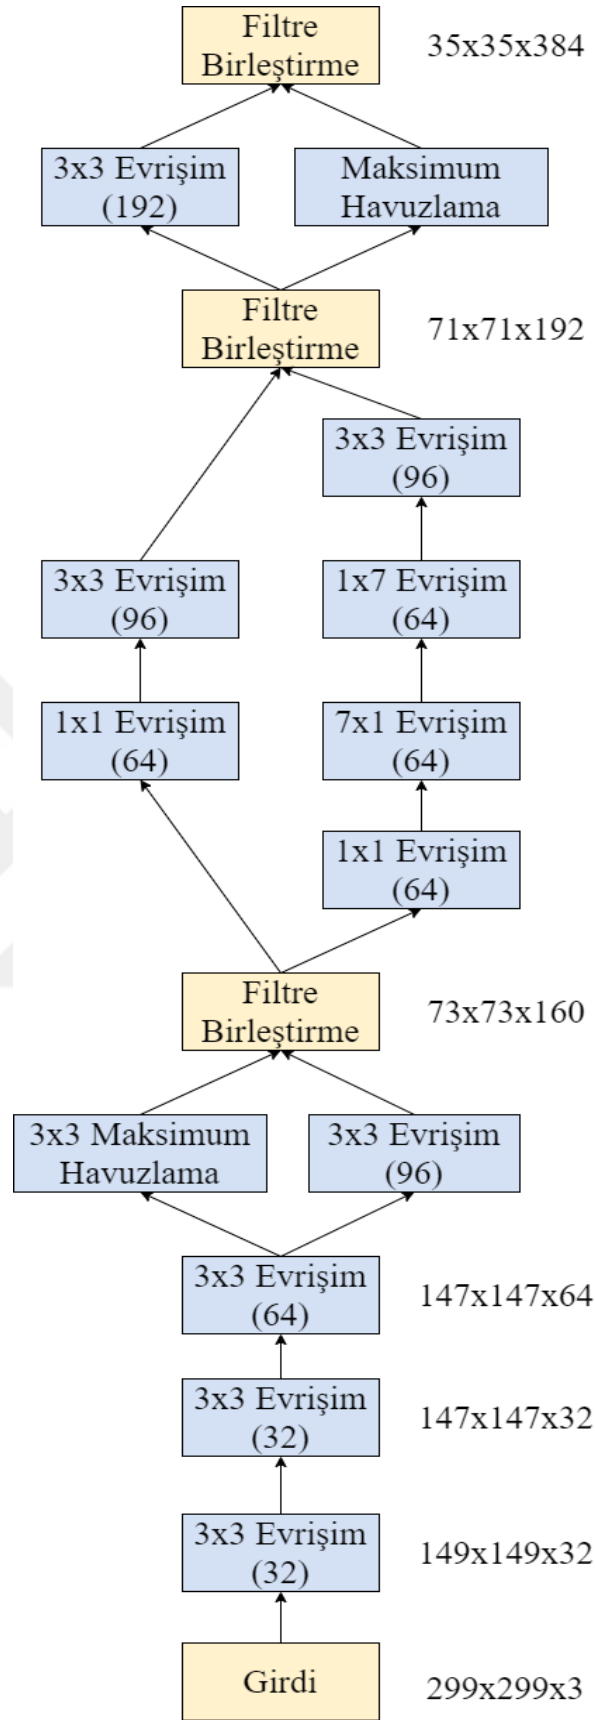




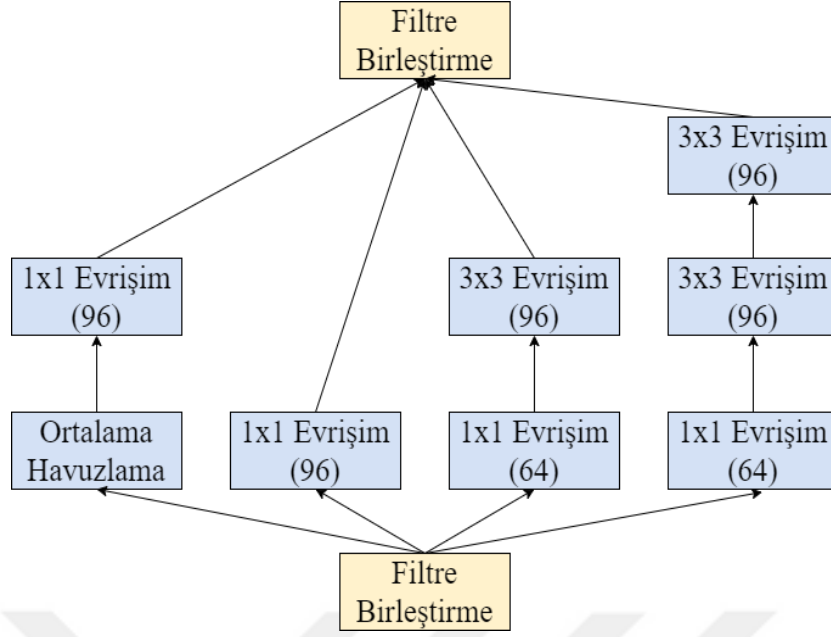
normalleştirme (batch normalization) işlemini sadece artık (residual) toplamların üzerine uygulamak daha yararlı olacaktır, hem maliyeti düşürecek hem de hedeflenen başarıya ulaşmayı sağlayacaktır (Szegedy ve ark 2017). Şekil 3.19’da InceptionV4 modelinin mimarisi verilirken şekil 3.20’de InceptionV4 modeli mimarisinde yer alan temel (stem) bölümüne ait detaylar verilmiştir. Şekil 3.21’de InceptionV4 modelinin mimarisinde yer alan Inception-A bölümüne ait detaylar verilmiştir. Şekil 3.22’de InceptionV4 modelinin mimarisinde yer alan Inception-B bölümüne ait detaylar verilmiştir. Şekil 3.23’te InceptionV4 modelinin mimarisinde yer alan Inception-C bölümüne ait detaylar verilmiştir.



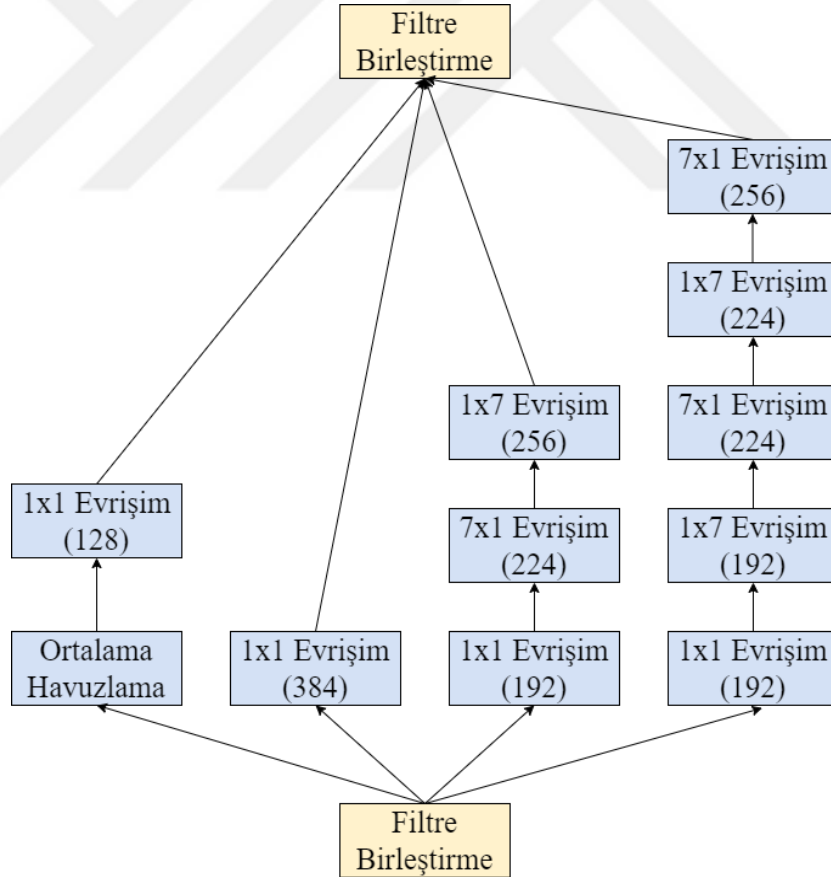
Şekil 3.19. InceptionV4 modeli mimarisi (Szegedy ve ark 2017)



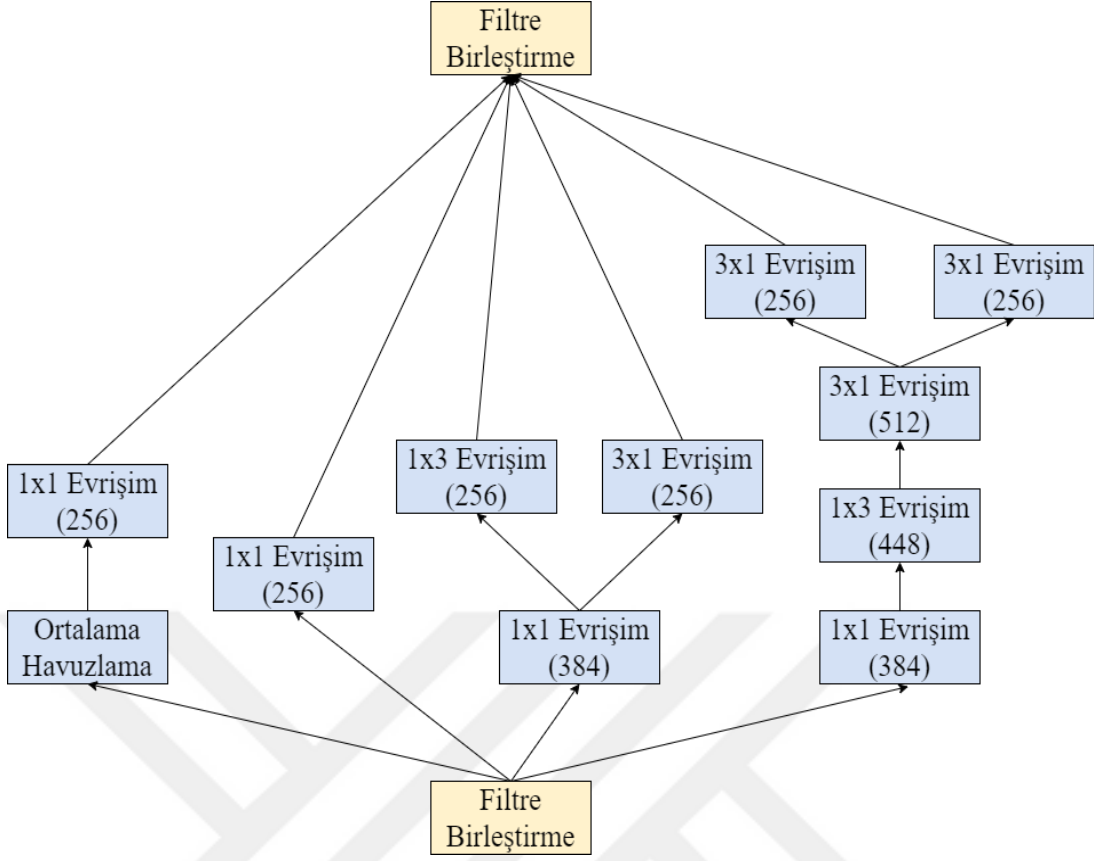
**Şekil 3.20.** InceptionV4 modeli mimarisine ait temel (stem) kısmının detayları gösterilmektedir (Szegedy ve ark 2017)



**Şekil 3.21.** Şekil 3.19'deki InceptionV4 modeline ait Inception-A modülü detayları (Szegedy ve ark 2017)

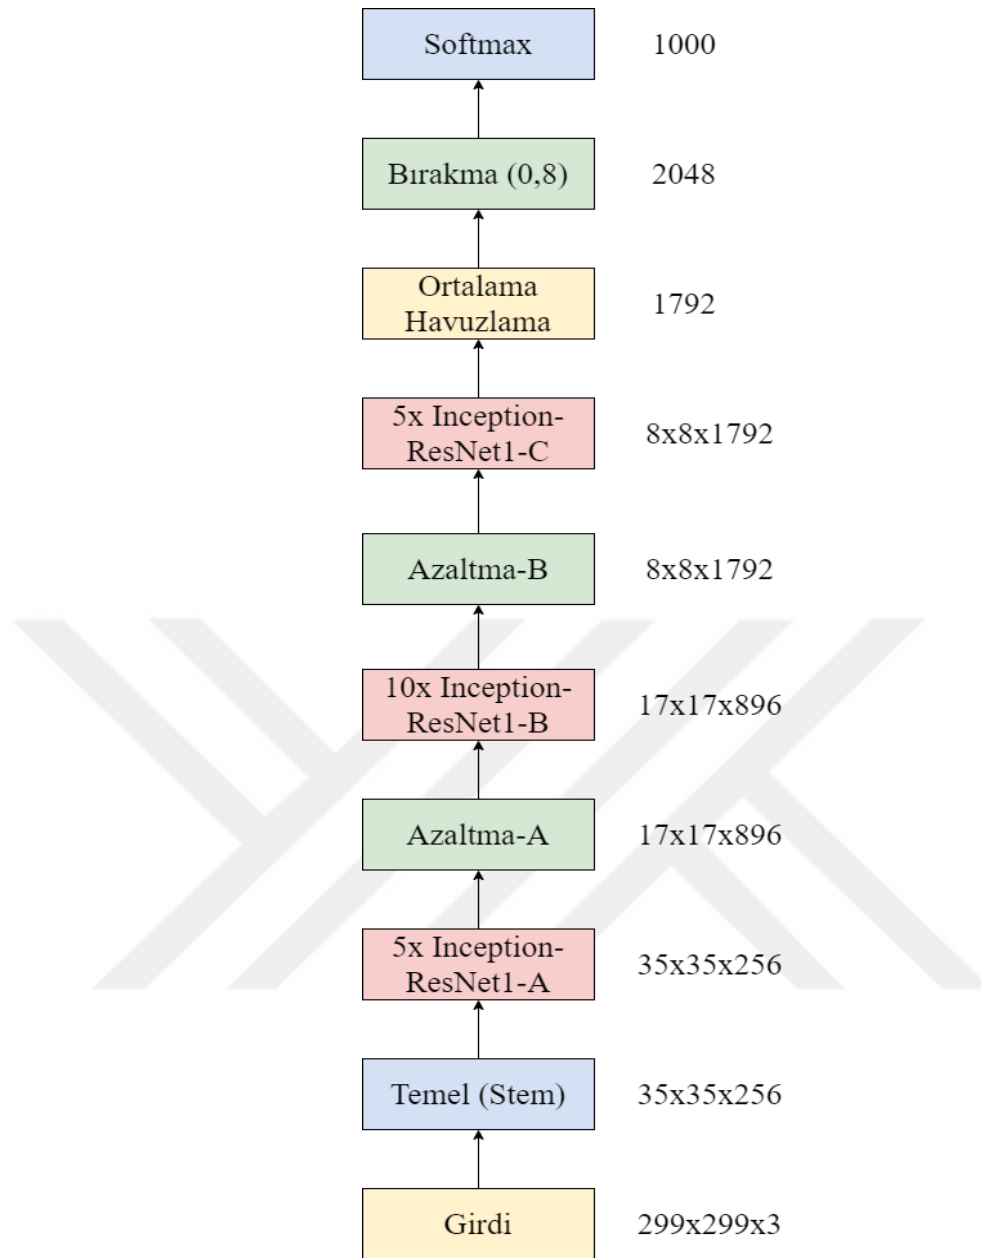


**Şekil 3.22.** Şekil 3.19'deki InceptionV4 modeline ait Inception-B modülü detayları (Szegedy ve ark 2017)

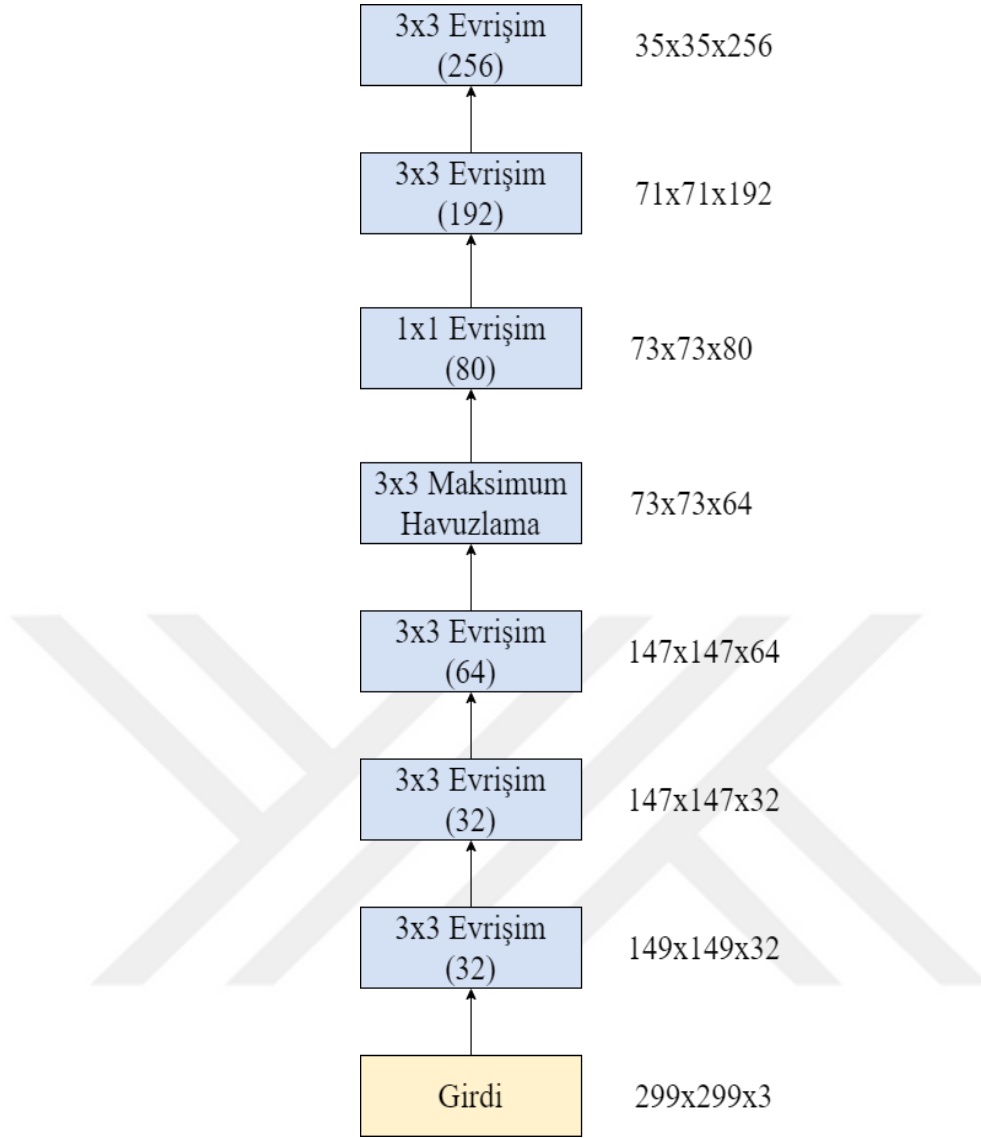


**Şekil 3.23.** Şekil 3.19'deki InceptionV4 modeline ait Inception-C modülü detayları (Szegedy ve ark 2017)

InceptionResNetV2 modelini InceptionResNetV1 modelinden ayıran temel (stem) yapısı şekil 3.20'de gösterilmiştir. InceptionResNetV2 modeli, InceptionV4 modeli ile aynı yapıya sahiptir. InceptionResNetV1 ve InceptionResNetV2 modellerinin yapısı şekil 3.24'te verilmiştir. InceptionResNetV1 modelinin temel (stem) yapısı ise şekil 3.25'te verilmiştir (Szegedy ve ark 2017).

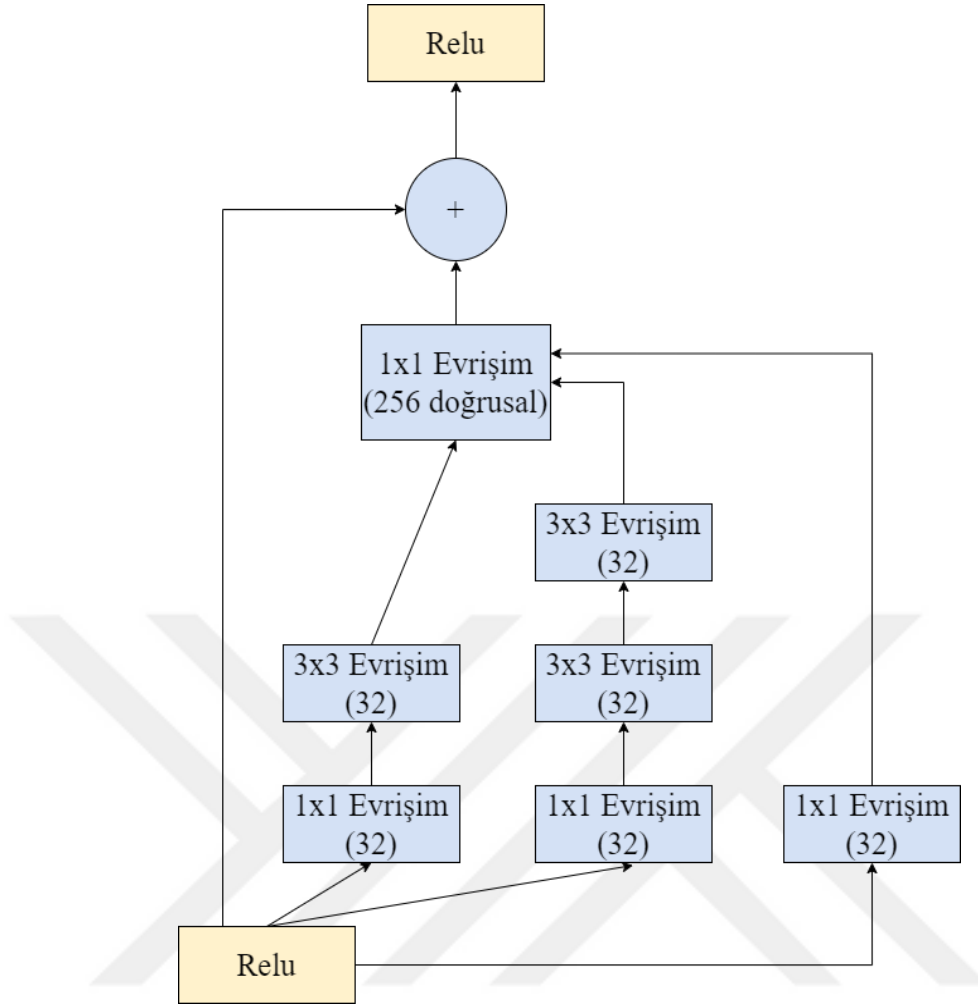


**Şekil 3.24.** InceptionResNetV1 ve InceptionResNetV2 modellerinin genel mimarisi (Szegedy ve ark 2017)

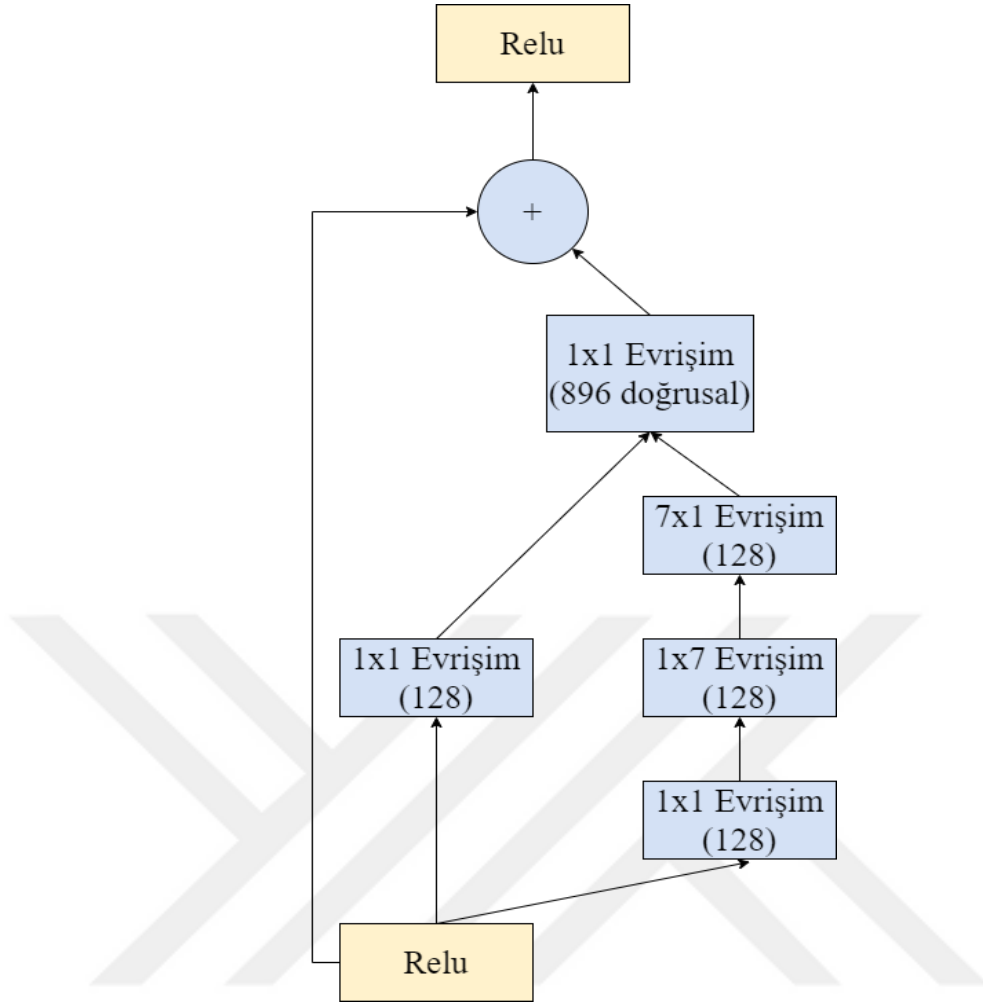


**Şekil 3.25.** InceptionResNetV1 modelinin temel (stem) mimarisi (Szegedy ve ark 2017)

Şekil 3.24'e bakıldığında her iki model (InceptionResNetV1 ve InceptionResNetV2) içinde aynı şema verilse de yapı dizilimleri her bir model için farklıdır. Modellerin dizilimleri ise şekil 3.26, şekil 3.27, şekil 3.28, şekil 3.29, şekil 3.30 ve şekil 3.31'de verildiği şekildedir.




**Şekil 3.26.** Şekil 3.24'teki InceptionResNetV1 modelinin yapısındaki InceptionResNet1-A modülü detayları (Szegedy ve ark 2017)

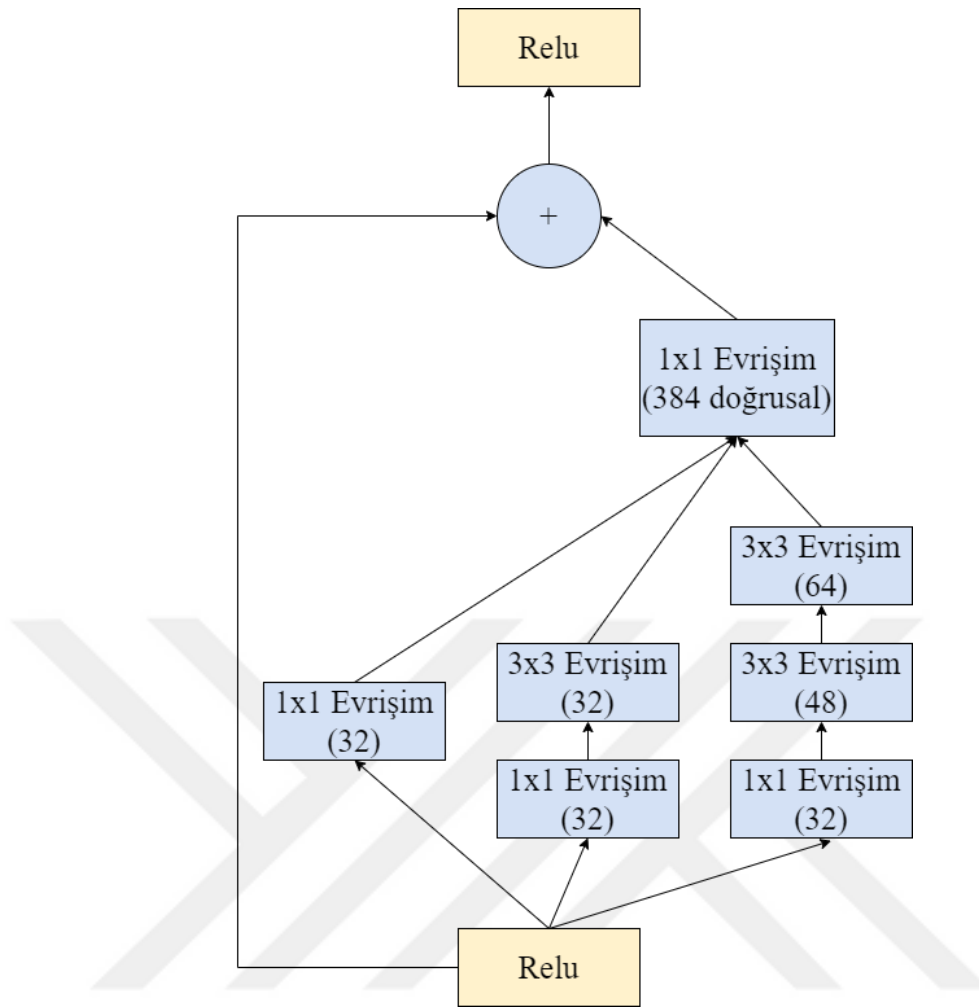


**Şekil 3.27.** Şekil 3.24'teki InceptionResNetV1 modelinin yapısındaki InceptionResNet1-B modülü detayları (Szegedy ve ark 2017)

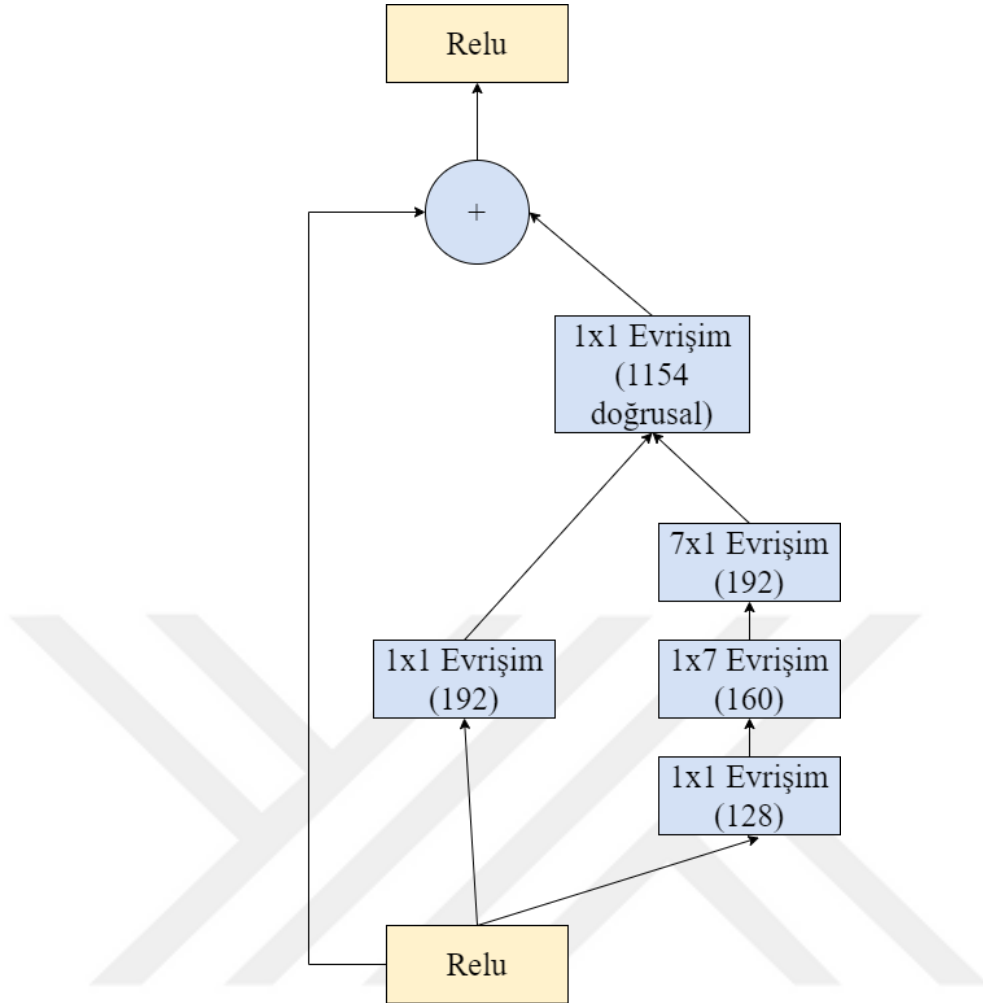





**Şekil 3.28.** Şekil 3.24'teki InceptionResNetV1 modelinin yapısındaki InceptionResNet1-C modülü detayları (Szegedy ve ark 2017)



**Şekil 3.29.** Şekil 3.24'teki InceptionResNetV2 modelinin yapısındaki InceptionResNet1-A modülü detayları (Szegedy ve ark 2017)




**Şekil 3.30.** Şekil 3.24'teki InceptionResNetV2 modelinin yapısındaki InceptionResNet1-B modülü detayları (Szegedy ve ark 2017)



**Şekil 3.31.** Şekil 3.24'teki InceptionResNetV2 modelinin yapısındaki InceptionResNet1-C modülü detayları (Szegedy ve ark 2017)

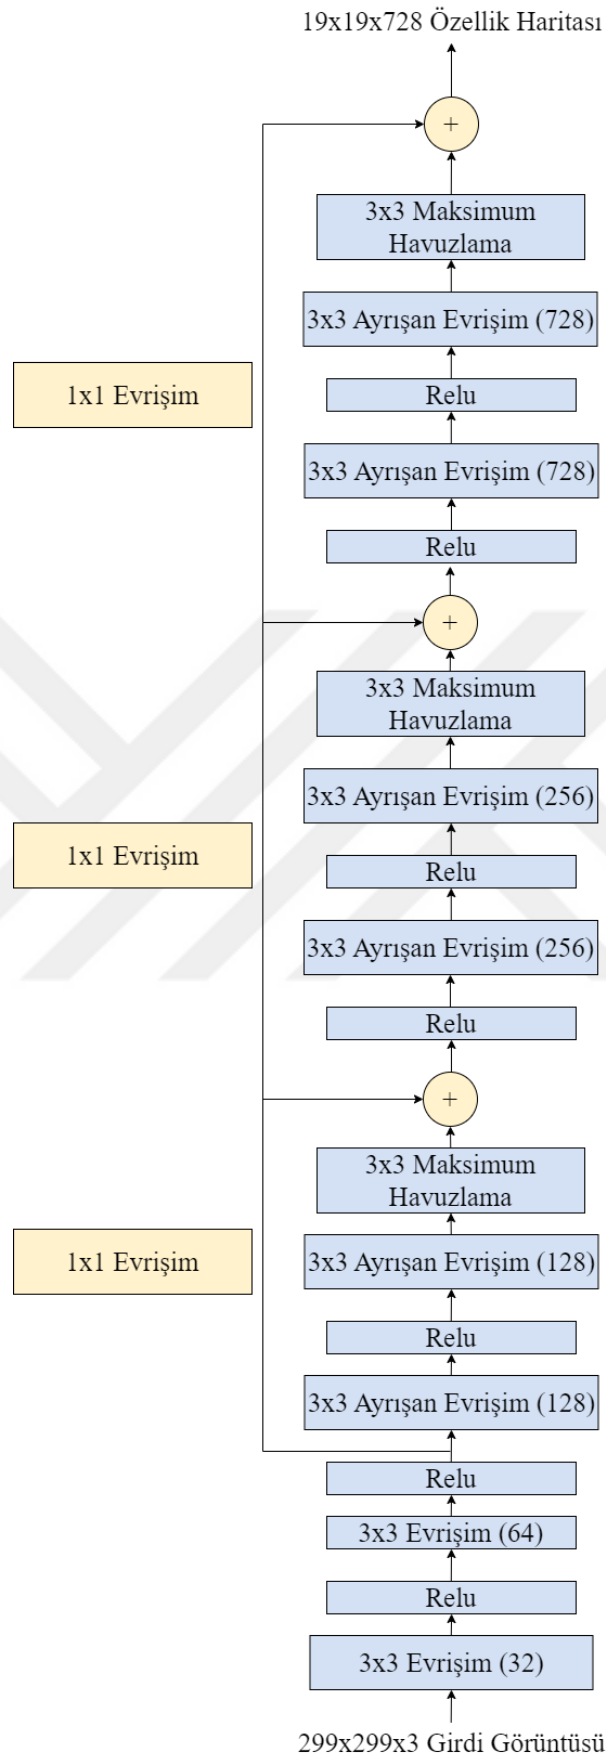
Şekil 3.26, şekil 3.27, şekil 3.28, şekil 3.29, şekil 3.30 ve şekil 3.31'de görüldüğü üzere InceptionResNetV1 ve InceptionResNetV2 modellerinin mimari detayları birbirinden farklıdır. Hem Inception modelinden gelen avantajlardan hem de artık (residual) konseptin avantajlarından faydalanılarak ve InceptionResNetV1 modelinin eksikliklerini de gidererek en verimli çalışan versiyon InceptionResNetV2 olmuştur. Şekil 3.32'de Error (top-5) faktörüne göre performans değerlendirmesi verilerek InceptionResNetV2 modelinin başarısı sergilenmiştir.



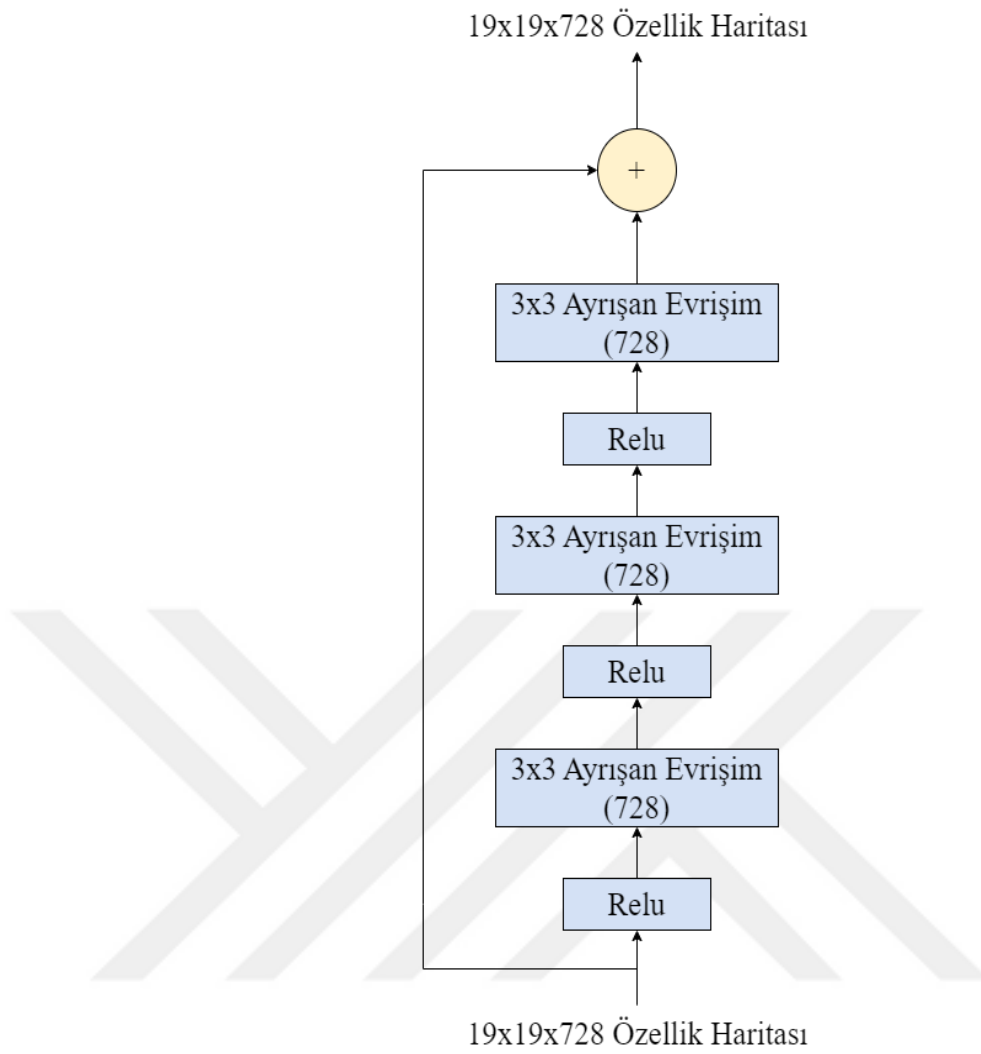
Şekil 3.32. Error (top-5) – Epok kıyaslaması (Szegedy ve ark 2017)

### 3.8. Xception

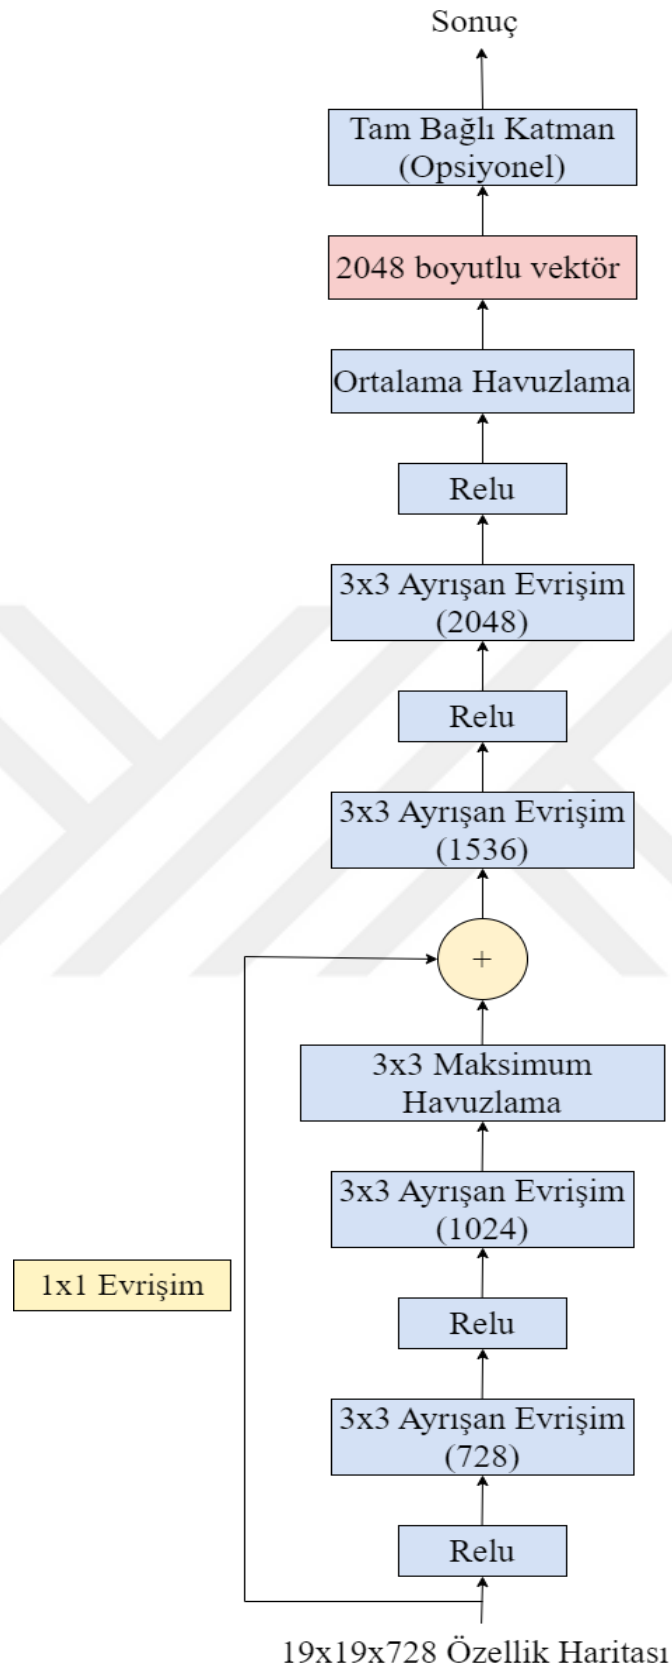
Xception ağı, Inception modelini temel alan bir modeldir. Inception modelinin temel mantığından daha derin yaklaşımlar sergilediği için adını Aşırı Inception'ın (Extreme Inception) kısaltmasından almıştır. Modelin çalışma performansını artırmak için ise artık (residual) bağlantısı olan ve özellik çıkartma görevi üstlenen 36 adet Evrişim katmanları kullanılmaktadır (Chollet 2017, Fitriyasi ve Rizkinia 2021). Şekil 3.33, şekil 3.34 ve şekil 3.35'te sırasıyla Xception modelinin mimarisine ait giriş şeması, orta kısım şeması ve çıkış şeması gösterilmektedir. Şekil 3.33, şekil 3.34 ve şekil 3.35'te gösterilmeyen ancak bilinmesi gereken şey ise, Evrişim ve Ayrışan Evrişim katmanlarını toplu normalleştirme takip etmektedir (Chollet 2017).



Şekil 3.33. Xception modeline ait giriş bölümü mimarisi (Chollet 2017)



Şekil 3.34. Xception modeline ait orta bölüm mimarisi (Chollet 2017)



Şekil 3.35. Xception modeline ait çıkış bölümü mimarisi (Chollet 2017)

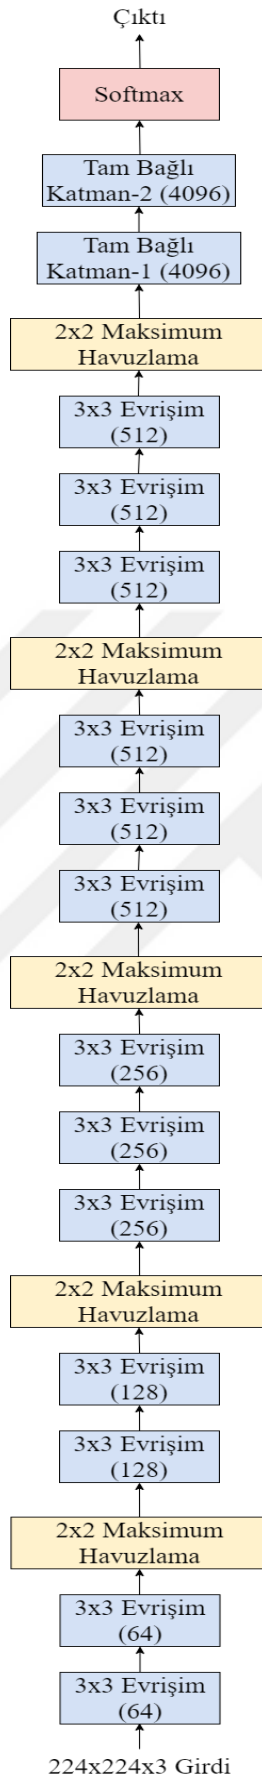


### 3.9. EfficientNet (B0-B7)

EfficientNet birçok versiyona sahip CNN modelidir. Adından da anlaşılacağı üzere kendisinden önce ortaya çıkan diğer modellerden başarı anlamında daha etkilidir. B0'dan B7'ye doğru gittikçe modellerin doğruluk (accuracy) yüzdeleri artmaktadır ancak buna karşın parametre sayıları da artmaktadır. Modellerin başarılı olmasını sağlayan üç özellik vardır: İlki Derinlemesine Evrişim (Depthwise Convolution) ile Noktasal Evrişim (Pointwise Convolution), hesaplama maliyetini azaltmak için standart evrişim katmanını ikiye ayırmaktadır. İkincisi Ters Çevrilmiş Res, ResNet bloklarının mimarisinde kanalları önce sıkıştırılan sonra genişleten bir yapı mevcuttur. Burada ise aynı bloklar ters işlev için kullanılarak önce genişleten sonra sıkıştırılan bir mimari benimsenmiştir. Böylece her seferinde atlama bağlantıları daha az katmana bağlanacaktır. Üçüncüsü ise Doğrusal Darboğaz, genelde evrişim katmanlarında kullanılan Relu aktivasyon fonksiyonunu bu mimaride bilgi kaybını önlemek amacıyla devre dışı bırakır, her blokta o katmanın çıkışında yer alan aktivasyon fonksiyonunu kullanır (Esen ve Aytuğ 2022).

### 3.10. VGG-16

Bu model Oxford Üniversitesinde çalışmalarını sürdüren bir ekip tarafından geliştirilmiştir. Adını da bu grubun adı olan Görsel Geometri Grubu'ndan (Visual Geometry Group) almıştır. 16 katmandan (13 adet evrişim katmanına sahiptir) oluşan bu model ağı derinliğini artırarak modelin doğruluğunu artırmayı amaçlamıştır. 3x3 filtreler (kernel) ile evrişim işlemi gerçekleştirilirken, mimarinin sonunda tam bağlı katmanlar ve en son çıkışta Softmax aktivasyon fonksiyonu ile sınıflandırma gerçekleştirilmektedir. Şekil 3.36'da VGG-16 modelinin mimarisi gösterilmektedir (Srivastava ve ark 2020).




Şekil 3.36. VGG-16 modelinin mimarisi (Tammina 2019)

### 3.11. Veri Seti

Dış kulak yolu, kulak zarı ve orta kulak hastalıklarını sınıflandırmak için gerçekleştirdiğimiz bu çalışmada kullandığımız veri seti hastalara ait gerçek otoendoskopik dış kulak yolu, kulak zarı ve orta kulak görüntülerinden oluşmaktadır. Görüntüler Konya Sağlık Bilimleri Üniversitesi Konya Beyhekim Eğitim ve Araştırma Hastanesi, Kulak Burun Boğaz Hastalıkları polikliniğindeki hastalardan elde edilmiştir. 2015 – 2019 yılları arasında KBB muayenesine gelen hastaların otoendoskopik muayenesindeki görüntüleri kullanılmıştır. Muayene 0 derece 4mm teleskop kullanılarak yapılmıştır (medicam lccd M SD 100). Veri setinde yer alan görüntüler, bir KBB uzmanı doktor yardımıyla toplanmış olup 24.05.2022 tarihinde etik kurul izni alınmıştır. Veri setinin orijinal halinde tüm görüntüler; 720 piksel genişlik, 576 piksel yükseklik ve 24 bit derinliğine sahip RGB görüntülerdir. Toplam 2125 adet görüntü mevcuttur. Bunların; 1049 tanesi Normal sınıfına ait sağlıklı verilerdir, 1076 tanesi ise 9 farklı sınıftan oluşan (Adesiv, Akut Otit, Eksternal, Miringoskleroz, Opere, Perfore, Seröz, Serümen, Süpüratif Kronik Otit) hasta verilerdir. Ancak veri sayısını ve kalitesini artırmak amacıyla eğitim için ayrılan görüntülere çeşitli ön işlemler yapılmış ve farklı boyutlarda toplam 5785 adet görüntü elde edilmiştir. Bunların; 1049 tanesi Normal sınıfına ait sağlıklı verilerdir, 4736 tanesi ise 9 farklı sınıftan oluşan (Adesiv, Akut Otit, Eksternal, Miringoskleroz, Opere, Perfore, Seröz, Serümen, Süpüratif Kronik Otit) hasta verilerdir.

#### 3.11.1. Adesiv


Adesiv, geri dönüşü neredeyse imkânsız olan işitme kaybına sebep olabilecek bir orta kulak hastalığıdır. Timpanik membranın tamamen promontoryuma yapışması ile oluşur (İsmi ve ark , Bayindir ve ark 2013). Şekil 3.37’de Adesiv hastalığına ait veri setinden bir görüntü yer almaktadır.



Şekil 3.37. Adesiv hastalığına ait görüntü

### 3.11.2. Akut Otit

Akut Otit, orta kulağın akut enfeksiyonuna sahip olduğu hastalıktır. Genelde 3 yaşına kadar çocukların yaklaşık %70'inde görülür. Ortaya çıkmasında ırk, cinsiyet, bağışıklık sisteminin gücü gibi çeşitli faktörler rol oynar (KARA ve ark 1997). Şekil 3.38'de Akut otit hastalığına ait veri setinden bir görüntü verilmiştir.



Şekil 3.38. Akut otit hastalığına ait görüntü

### 3.11.3. Eksternal

Eksternal, bakteriyel veya dış kulak kanalı enfeksiyonu olarak bilinmektedir. Dış kulak yolunda herhangi bir kapanma olmadığı sürece bu hastalık işitme kaybına sebep olmamaktadır (Şahin ve ark 2022). Şekil 3.39’da Eksternal hastalığına ait veri setinden bir görüntü verilmiştir.



Şekil 3.39. Eksternal hastalığına ait görüntü

### 3.11.4. Miringoskleroz

Timpanosklerozun sadece kulak zarını etkilemesine miringoskleroz adı verilir (ÖZEL ve ark). Şekil 3.40’ta Miringoskleroz hastalığına ait veri setinden bir görüntü verilmiştir.



Şekil 3.40. Miringoskleroz hastalığına ait görüntü

### 3.11.5. Opere


Orta kulakta hastalığın meydana geldiği bölgeye yapılan müdahaleye ait görüntülerdir. Şekil 3.41’de Opere sınıfına ait veri setinden bir görüntü verilmiştir.



Şekil 3.41. Opere sınıfına ait bir görüntü

### 3.11.6. Perfore


Tıpta Perforasyon olarak da bilinen Perfore, hastalıklı bölgenin (örneğin sıvı toplanması olan bir bölgenin) delinerek açılması işlemidir. Şekil 3.42’de Perfore sınıfına ait veri setinden bir görüntü verilmiştir.



Şekil 3.42. Perfore sınıfına ait bir görüntü

### 3.11.7. Seröz

Efizyonlu otit media, orta kulakta sıvı birikmesi hastalığıdır. Bu biriken sıvı işitme kaybına sebep olabilmektedir. Eğer orta kulakta biriken bu sıvının rengi berrak ise bu hastalığa Seröz denilmektedir (Şentürk 2019). Şekil 3.43’te Seröz hastalığına ait veri setinden bir görüntü verilmiştir.




Şekil 3.43. Seröz hastalığına ait görüntü

### 3.11.8. Serumen

Serumen, dış kulak yolunun kıkırdak kısmında yer alan koruyucu bir maddedir. Sebace, apokrin, serumen glandları gibi maddelerin bir araya gelmesiyle oluşur. Serumen'in az salgılandığı veya hiç salgılanmadığı durumlarda kulakta şiddetli kaşıntılar meydana gelmekte ve hastanın yaşam kalitesini oldukça düşürmektedir (KAYTEZ ve ark). Şekil 3.44'te Serumen hastalığına ait veri setinden bir görüntü verilmiştir.






Şekil 3.44. Serumen hastalığına ait görüntü

### 3.11.9. Supratif Kronik Otit


Kulak akıntısı ve kulak zarının perforasyonu sonucu oluşan bir hastalıktır. Kulağın kemik yapısında geri dönüşü olmayan tahribatlar yapan Supratif Kronik Otit, son derece tehlikeli ve hızla ilerleme eğilimindedir (KAZKAYASI ve ark). Şekil 3.45'te Supratif Kronik Otit hastalığına ait veri setinden bir görüntü verilmiştir.



Şekil 3.45. Supuratif kronik otit hastalığına ait görüntü

### 3.12. Veri Ön İşleme Süreci

Veri setinde yer alan veriler, daha yüksek doğruluk (accuracy) oranları elde edebilmek adına çeşitli ön işleme adımlarından geçmiştir. Bu aşamalardan ilki ise kırpma işlemi olmuştur. Görüntülerde yer alan ilgisiz kısımlar kırpılırken sırasıyla; başlangıç satırı ve sütunu 0,13 ve 0,14 katsayıları ile çarpılmıştır ve sonlandırma satırı ve sütunu ise 0,87 ve 0,84 katsayıları ile çarpılmıştır. Şekil 3.46'da kırpma işlemine ait örnek görüntü verilmiştir.




Kırpmadan önceki görüntü

Kırpmadan sonraki görüntü

Şekil 3.46. Kırpma işlemine ait bir örnek

Kırpma işleminden sonra veri setindeki görüntüleri gri ölçeklendirme gibi teknikler de uygulanmıştır. Renkli görüntüler (RGB) genelde görüntü için çok fazla bilgi taşırlar ancak bunu arka arkaya işlenen 3 matris (R-G-B) ile yapmaktadırlar. Bir renk 8 bit ile ifade edilmektedir. Bu hesaptan yola çıkarak, renkli görüntülerde tek bir pikselde 24 bit (8 bit x 3) veri tutulmaktadır. Bu durumda, bir görüntüyü gri ölçeklendirmek o görüntünün bir pikselinin sadece 8 bit ile ifade edileceği anlamına gelir. Bu durum işlem süresini kısaltmak gibi avantajlara sahip olsa da görüntüdeki detayları kaybetmek gibi dezavantajları da beraberinde getirmektedir (Gonzalez ve Woods 2014, Yılmaz 2016). Şekil 3.47’de veri setine ait örnek görüntüler, gri ölçeklendirilmiş olarak sunulmuştur.





Adesiv




Akut Otit




Eksternal




Miringoskleroz




Opere




Perfore



Seröz



Serümen



Süpüratif Kronik Otit



Normal

Şekil 3.47. Gri ölçeklendirilmiş veri setine ait örnek görüntüler

Bu işlemden sonra rastgele (random) veri artırma yapılmıştır. Burada; özellik tabanlı normalizasyon, yatay çevirme, dikey çevirme uygulamalarının yanı sıra 45 derecelik döndürme, yatayda ve dikeyde 0,4 oranında genişletme uygulanarak rastgele veri artırma yapılmıştır. Ancak bu hazır veri artırma yöntemleriyle istenen veri çeşitliliği sağlanamamıştır. Bundan dolayı Python programlama dilinde kodu yazılarak elle (manuel bir biçimde) veri artırma uygulaması yapılmıştır. Bu uygulamanın en büyük artısı, görüntülere en uygun artırma yönteminin ve artırma oranının denenerek bulunması ve uygulanması olmuştur. Bu uygulama özelinde, bütün hasta sınıflarındaki görüntülere döndürme işlemi uygulanmıştır. Döndürme işlemine ek olarak; Perfore sınıfındaki görüntülere Gaussian gürültü, elastik dönüşüm, yatay döndürme ve parlaklığı artırma işlemi uygulanmıştır. Eksternal ve Seröz sınıfındaki görüntülere Gaussian gürültü, parlaklığı artırma ve kontrast işlemleri uygulanmıştır. Serümen sınıfındaki görüntülere Gaussian gürültü ve kontrast işlemleri uygulanmıştır. Süpüratif Kronik Otit sınıfındaki görüntülere Gaussian gürültü, parlaklığı artırma, kontrast ve yatay döndürme işlemleri uygulanmıştır. Adesiv, Akut Otit, Miringoskleroz, Opere sınıflarındaki görüntülere ise Gaussian gürültü, elastik dönüşüm, yatay döndürme, parlaklığı artırma, karanlığı artırma, dikey döndürme ve bulanıklık ekleme işlemleri uygulanmıştır. Normal (sağlıklı) sınıfında görüntü sayısı ve çeşitliliği yeterli seviyede olduğu için herhangi bir veri artırım işlemi uygulanmamıştır. Yapılan tüm işlemler sadece eğitim görüntülerine uygulanmış olup başarılı veri artırma işlemlerinin sonunda hasta olarak kabul edilen 4413 adet ve sağlıklı (Normal etiketli sınıf) olarak kabul edilen 734 adet otoendoskopik eğitim görüntüsü elde edilmiştir.

### 3.13. Çalışma Ortamı

Bu çalışmada dış kulak yolu, kulak zarı ve orta kulak görüntülerinin sınıflandırma işlemi, Google Collaboratory ortamında Python programlama dili kullanılarak gerçekleştirilmiştir. Kullanılan veri setindeki görüntülerin büyük boyutlu ve fazla sayıda olması sebebiyle iyi bir ekran kartına ihtiyaç duyulmuştur. Bunun için GPU hizmeti de sağlayan Google Collaboratory ortamı tercih edilmiştir. Burada GPU olarak, NVIDIA Tesla K80 24GB ve NVIDIA Tesla P100 PCIe 16 GB ekran kartları ile çalışılmıştır. İşlemci olarak Intel(R) XEON(TM) 2.20GHz sunulmuştur.

## 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

### 4.1. Model İnşası ve Parametreleri

Bu çalışmada, hastalardan elde edilen dış kulak yolu, kulak zarı ve orta kulak görüntülerine çeşitli ön işleme ve veri artırımı adımları uygulandıktan sonra görüntüler üzerinde sınıflandırma yapılmıştır. Sınıflandırma için EfficientNetB2, EfficientNetB3, InceptionResNetV2, InceptionV3, ResNet50, ResNet50V2, ResNet101, ResNet101V2, VGG-16, Xception CNN modelleri kullanılmıştır. Bu modellerle yapılan tüm deneylerde başarıyı arttırmak için tam bağlı (fully connected) katmanın sonuna iki adet daha gizli katman eklenmiştir. Bu gizli katmanlar sırasıyla 2048 ve 1024 tane nörondan oluşmakta ve aktivasyon fonksiyonu olarak da ReLU kullanılmaktadırlar. Çıkış katmanının da ise Softmax aktivasyon fonksiyonu kullanılmıştır. Veri seti %70 eğitim (bunun %20'si doğrulama) ve %30 test olarak ayrılmıştır. Yapılan tüm deneylerde kayıp fonksiyonu olarak çok sınıflı çalışmalarda sıklıkla kullanılan, etiketler ve tahminler arasında çapraz entropi hesabını tutan kategorik çapraz entropi kullanılmıştır. Öğrenme oranı sabit 0,0001 olarak belirlenmiştir ve veri seti veri artırımı işlemleriyle dengelendiği için metrik olarak doğruluk (accuracy) metriği kullanılması yeterli görülmüştür. Bu çalışmada iki adet deney yapılmıştır. İlk deneyde farklı optimizier algoritmaları modellere entegre edilmiştir ve doğruluk (accuracy) değerleri karşılaştırılarak en başarılı optimizier algoritması belirlenmeye çalışılmıştır. İkinci deneyde ise farklı epok- batch size değerleri altında modeller eğitilmiştir ve sonrasında test doğruluk (accuracy) değerleri karşılaştırılmıştır.


### 4.2. Sonuçlar

Optimizier algoritmalarının değiştirilmesiyle yapılan deneye ait sonuçlar şekil 4.1'de verilmiştir. Bu deneyde 3 adet CNN modeli tercih edilmiştir. Bunlar InceptionV3, ResNet50V2 ve ResNet101V2 modelleridir. Bu modellerin tercih edilme sebebi hem temel modeller olmaları hem de çok derin bir mimariye sahip olmamalarıdır. Özellikle derin mimariye sahip olmamaları zamandan ve kaynaktan tasarruf sağlamaktadır, bu durum da Colab ortamında çalışmayı kolaylaştırmıştır. Bu deneydeki tüm modellerde 20 epok – 50 batch size değerlerinde çalışılmıştır. Çizelge 4.1'de yapılan çalışmaya ait sonuçlara yer verilmiştir.

**Çizelge 4.1.** Optimizer algoritmaları ve uygulandıkları modellerin doğruluk (accuracy) değerleri

Modeller/Optimizer algoritmaları	Adadelata	Adagrad	Adamax	Adam	Ftrl	Nadam	RMSprop	SGD
InceptionV3	%22	%42	%90	<b>%95</b>	%8	%91	%95	%96
ResNet50V2	%8	%48	%95	%91	%8	%92	%90	%95
ResNet101V2	%21	%93	%94	%93	%8	%91	%89	%15

Çizelge 4.1 incelendiğinde, Adam optimizer algoritması modellerin tamamında hem yüksek hem de daha stabil (en iyi ve en kötü değeri arasında sadece %4 oranında fark var) doğruluk (accuracy) değerleri elde edilmiştir. Göstermiş olduğu bu başarıdan dolayı ikinci deneydeki tüm çalışmalarda Adam optimizer algoritması kullanılmıştır. Şekil 4.1’de Adam optimizer algoritmasının en başarılı olduğu model olan InceptionV3 modelinin karmaşıklık matrisi (confusion matrix) gösterilmektedir. Ayrıca Çizelge 4.2’de InceptionV3 modelinin sınıflandırma raporu (classification report), Şekil 4.2’de doğruluk-epok (accuracy-epoch) grafiği ve Şekil 4.3’te kayıp-epok (loss-epoch) grafiği gösterilmektedir.




**Şekil 4.1.** InceptionV3 modeline ait karmaşıklık matrisi

**Çizelge 4.2.** InceptionV3 modeline ait sınıflandırma raporu


	Precision	Recall	F1-score	Accuracy
ADESIV	1,00	1,00	1,00	
AKUT_OTIT	1,00	0,90	0,95	
EKSTERNAL	0,94	0,82	0,87	
MIRINGOSKLEROZ	0,87	1,00	0,93	
NORMAL	0,98	0,97	0,98	
OPERE	1,00	1,00	1,00	
PERFORE	0,98	0,81	0,89	
SERÖZ	0,92	0,98	0,95	
SERÜMEN	0,93	1,00	0,96	
SÜPÜRATİF KRONİK OTİT	0,78	1,00	0,88	
				<b>0,95</b>



Şekil 4.1 ve onun özeti olan çizelge 4.2 incelendiğinde 20 epok – batch size için InceptionV3 modeli tarafından en az tanınan hastalığın Eksternal hastalığı (f1-skor'a (f1-score) göre (%87)) olduğu, en çok tanınan hastalıkların ise Adesiv ve Opere (f1-skor'a (f1-score) göre (%100)) olduğu görülmektedir.



Şekil 4.2. InceptionV3 modeline ait doğruluk-epok grafiği



Şekil 4.3. InceptionV3 modeline ait kayıp-epok grafiği

İkinci deneyde yapılan çalışma ise farklı epok- batch size değerlerinin uygulanması neticesinde modellerin doğruluk (accuracy) değerlerinin karşılaştırılması çalışmasıdır. Bu çalışmada Adam optimizyer algoritması kullanılmıştır. Bu çalışmada 10 adet CNN modeli kullanılmıştır. Bunlar EfficientNetB2, EfficientNetB3, InceptionResNetV2, InceptionV3, ResNet50, ResNet50V2, ResNet101, ResNet101V2,

VGG-16 ve Xception modelleridir. Çizelge 4.3'te yapılan çalışmanın detayları verilmiştir.

**Çizelge 4.3.** Farklı epok- batch size değerleri ve uygulandıkları modellerin doğruluk (accuracy) değerleri (- ile ifade edilen çalışmalar, bazı modellerin veri setindeki görüntülerle belirtilen epok- batch size değerlerinde çalışamaması sebebiyle gerçekleştirilemeyen çalışmalardır)

Modeller/Deneyler	20 Epok – 32 Batch size	20 Epok – 50 Batch size	25 Epok – 32 Batch size	40 Epok – 32 Batch size	40 Epok – 50 Batch size	40 Epok – 64 Batch size
EfficientNetB2	<b>%96</b>	%93	-	<b>%96</b>	%95	-
EfficientNetB3	%95	-	%95	-	-	-
InceptionResNetV2	%91	%94	-	%93	-	%95
InceptionV3	%93	%95	-	%93	%95	%94
ResNet50	%89	%93	-	<b>%96</b>	%93	%90
ResNet50V2	%92	%91	-	%90	%92	%92
ResNet101	%93	%92	-	%95	%94	-
ResNet101V2	%91	%93	-	%93	%88	-
VGG-16	%49	%8	-	%49	%49	-
Xception	%93	%94	-	%93	%94	-

Çizelge 4.3'teki sonuçlara bakıldığında 40 epok – 32 batch size çalışması diğer çalışmalardan daha yüksek doğrulukta sonuçlar vererek en başarılı çalışma olmuştur. Ancak 20 epok – 32 batch size çalışması, kısa süren eğitim aşaması göz önüne alındığında 40 epok – 32 batch size çalışmasındaki başarılı değerlere yakın sonuçlar verdiği ve tüm modellerde çalışabildiği için bu çalışma da başarılı sayılmaktadır. 20 epok – batch size çalışmasında en başarılı sonucu EfficientNetB2 modeli vermiştir. 40 epok – 32 batch size çalışmasında ise başarılı iki sonuç vardır. Bu başarılı sonuçları ise EfficientNetB2 ve ResNet50 modelleri vermiştir. Şekil 4.4'te 20 epok – 32 batch size çalışmasına ait en başarılı sonucu veren EfficientNetB2 modeline ait karmaşıklık matrisi verilirken, Çizelge 4.4'te bu modele ait sınıflandırma raporu, Şekil 4.5'te doğruluk-epok grafiği ve Şekil 4.6'da kayıp-epok grafiği verilmiştir.




**Şekil 4.4.** 20 epok – 32 batch size çalışmasında en iyi sonucu veren EfficientNetB2 modeline ait karmaşıklik matrisi


**Çizelge 4.4.** 20 epok – 32 batch size çalışmasında en iyi sonucu veren EfficientNetB2 modeline ait sınıflandırma raporu

	Precision	Recall	F1-score	Accuracy
ADESIV	1,00	1,00	1,00	
AKUT_OTIT	0,90	0,86	0,88	
EKSTERNAL	1,00	0,75	0,86	
MIRINGOSKLEROZ	0,93	1,00	0,96	
NORMAL	0,98	0,98	0,98	
OPERE	1,00	1,00	1,00	
PERFORE	0,98	0,94	0,96	
SERÖZ	0,96	1,00	0,98	
SERÜMEN	0,86	1,00	0,93	
SÜPÜRATİF KRONİK OTİT	0,92	1,00	0,96	
				<b>0,96</b>

Şekil 4.4 ve onun özeti olan çizelge 4.4 incelendiğinde 20 epok – 32 batch size için EfficientNetB2 modeli tarafından en az tanınan hastalığın Eksternal hastalığı (f1-skor'a (f1-score) göre (%86)) olduğu, en çok tanınan hastalıkların ise Adesiv ve Opere (f1-skor'a (f1-score) göre (%100)) olduğu görülmektedir.




Şekil 4.5. 20 epok – 32 batch size çalışmasında en iyi sonucu veren EfficientNetB2 modeline ait doğruluk-epok grafiği



Şekil 4.6. 20 epok – 32 batch size çalışmasında en iyi sonucu veren EfficientNetB2 modeline ait kayıp-epok grafiği

40 epok – 32 batch size çalışmasındaki başarılı modellerden biri olan EfficientNetB2 modeline ait karmaşıklık matrisi Şekil 4.7’de verilirken, Çizelge 4.5’te sınıflandırma raporu, Şekil 4.8’de doğruluk-epok grafiği ve Şekil 4.9’da kayıp-epok grafiği verilmiştir.




**Şekil 4.7.** 40 epok – 32 batch size çalışmasında iyi sonuç veren EfficientNetB2 modeline ait karmaşıklık matrisi


**Çizelge 4.5.** 40 epok – 32 batch size çalışmasında iyi sonuç veren EfficientNetB2 modeline ait sınıflandırma raporu

	Precision	Recall	F1-score	Accuracy
ADESIV	1,00	1,00	1,00	
AKUT_OTIT	0,95	0,90	0,93	
EKSTERNAL	1,00	0,88	0,94	
MIRINGOSKLEROZ	0,93	1,00	0,96	
NORMAL	0,98	0,97	0,97	
OPERE	1,00	1,00	1,00	
PERFORE	0,98	0,83	0,90	
SERÖZ	0,89	1,00	0,94	
SERÜMEN	0,94	1,00	0,97	
SÜPÜRATİF KRONİK OTİT	0,86	1,00	0,92	
				<b>0,96</b>

Şekil 4.9 ve onun özeti olan çizelge 4.3'e bakıldığı zaman 40 epok – 32 batch size için EfficientNetB2 modeli tarafından en az tanınan hastalığın Perfore hastalığı (f1-skor'a (f1-score) göre (%90)) olduğu, en çok tanınan hastalıkların ise Adesiv ve Opere (f1-skor'a (f1-score) göre (%100)) olduğu görülmektedir.



**Şekil 4.8.** 40 epok – 32 batch size çalışmasında iyi sonuç veren EfficientNetB2 modeline ait doğruluk-epok grafiği



**Şekil 4.9.** 40 epok – 32 batch size çalışmasında iyi sonuç veren EfficientNetB2 modeline ait kayıp-epok grafiği

40 epok – 32 batch size çalışmasındaki diğer başarılı model olan ResNet50 modeline ait karmaşıklık matrisi ise Şekil 4.10’da verilirken, Çizelge 4.6’da sınıflandırma raporu, Şekil 4.11’de doğruluk-epok grafiği ve Şekil 4.12’de kayıp-epok grafiği verilmiştir.




**Şekil 4.10.** 40 epok – 32 batch size çalışmasında iyi sonuç veren ResNet50 modeline ait karmaşıklık matrisi

**Çizelge 4.6.** 40 epok – 32 batch size çalışmasında iyi sonuç veren ResNet50 modeline ait sınıflandırma raporu


	Precision	Recall	F1-score	Accuracy
ADESIV	1,00	1,00	1,00	
AKUT_OTIT	1,00	0,86	0,92	
EKSTERNAL	0,98	0,88	0,93	
MIRINGOSKLEROZ	0,93	1,00	0,96	
NORMAL	0,98	0,97	0,97	
OPERE	1,00	1,00	1,00	
PERFORE	0,94	0,92	0,93	
SERÖZ	0,96	0,98	0,97	
SERÜMEN	0,88	1,00	0,94	
SÜPÜRATİF KRONİK OTİT	0,95	1,00	0,97	
				<b>0,96</b>



Şekil 4.12 ve onun özeti olan çizelge 4.4'e bakıldığı zaman 40 epok – 32 batch size için ResNet50 modeli tarafından en az tanınan hastalığın Akut Otit hastalığı (f1-skor'a (f1-score) göre (%92)) olduğu, en çok tanınan hastalıkların ise Adesiv ve Opere (f1-skor'a (f1-score) göre (%100)) olduğu görülmektedir.



Şekil 4.11. 40 epok – 32 batch size çalışmasında iyi sonuç veren ResNet50 modeline ait doğruluk-epok grafiği



Şekil 4.12. 40 epok – 32 batch size çalışmasında iyi sonuç veren ResNet50 modeline ait kayıp-epok grafiği

### 4.3. Tartışma

KBB uzmanlarının karşılaştığı dış kulak yolu, kulak zarı ve orta kulak hastalıkları insanların yaşam kalitesini olumsuz etkileyen sağlık sorunlarından biridir. Derin öğrenme yöntemleri, KBB uzmanlarının tanı ve tedavi süreçlerinde birçok avantaj sağlamaktadır. Bu sayede, KBB uzmanları hastaların durumlarını daha hızlı ve doğru bir şekilde teşhis edebilirler. Ayrıca derin öğrenme yöntemleri, kulak hastalıkları dışında KBB alanında kullanılan diğer teknolojilerde de kullanılabilir. Örneğin, işitme kaybı teşhisi ve tedavisi, ses bozuklukları teşhisi, işitsel işleme tedavisi gibi alanlarda derin öğrenme yöntemleri başarılı bir şekilde uygulanmaktadır. Tüm bu avantajlar, KBB uzmanlarının hasta bakımı kalitesini artırmalarına yardımcı olmaktadır ve hasta memnuniyetini artırmaktadır.

Çeşitli ön işlemlerden geçen ve son durumda %18,13 oranında sağlıklı (Normal etiketli sınıf) ve %81,87 oranında hasta (9 farklı sınıf) olmak üzere toplam 5785 adet otoendoskopik görüntüden oluşan veri seti üzerinde yapılan çalışmalar incelendiğinde, 40 epok – 32 batch size uygulamasının daha başarılı ve yeterli sonuçlar verdiği görülmüştür. Ancak zaman ve kaynak kısıtı göz önüne alındığında 20 epok – 32 batch size çalışması da iyi bir alternatif oluşturmaktadır. Bu deneylerde en başarılı olan modeller %96 doğruluk (accuracy) değerleri ile EfficientNetB2 ve ResNet50 modelleri olmuştur. EfficientNetB2 modeli hem 40 epok – 32 batch size hem de 20 epok – 32 batch size çalışmasında en yüksek değer olan %96 doğruluk (accuracy) ile başarısını ortaya koymuştur. EfficientNetB2 modeline alternatif model olarak ise InceptionV3 modeli seçilebilir. Hem çok sayıda farklı çalışmalar yapmaya daha uygun mimarisi hem de elde ettiği doğruluk (accuracy) değerlerinin yüksek ve stabil olması en iyi alternatif olarak InceptionV3 modelini işaret etmektedir. Tüm bunlara ek olarak, bütün modellerde en iyi tanınan hastalıklar ise Adesiv ve Opere hastalıkları olmuştur. F1 skor (f1-score) metriğine göre %100 tanınma oranına ulaşmışlardır. Çalışmanın başarılı olduğu 20 epok - 32 batch size ve 40 epok - 32 batch size değerleri incelendiğinde, 20 epok - 32 batch size çalışması için en kötü tespit ResNet101V2 modeli tarafından %51 f1 skor (f1-score) değeri ile Miringoskleroz hastalığı olduğu görülmüştür. 40 epok – 32 batch size çalışmasında ise ResNet50V2 modeli %71 f1 skor (f1-score) değeri ile Eksternal hastalığını en kötü şekilde tespit etmiştir.

Bu çalışma, dış kulak yolu, kulak zarı ve orta kulak görüntülerinin ihtiyaca uygun ve başarılı olan bir derin öğrenme modeli ve teknik ile sınıflandırılmasıyla hem hastalara hem de doktorlara tanı ve tedavide yardımcı olunabileceğini göstermektedir.



## 5. SONUÇLAR VE ÖNERİLER

Sonuç olarak, dış kulak yolu, kulak zarı ve orta kulak hastalıklarının teşhisinde derin öğrenmenin ve özellikle de CNN tekniklerinin kullanılması oldukça başarılı sonuçlar vermektedir. Başarısı yapılan çalışmalarla ortaya konulan Adam optimizer algoritması kullanılarak, 40 epok – 32 batch size çalışmasında EfficientNetB2 ve ResNet50 modellerinin %96 doğruluk (accuracy) elde etmesi bu durumu doğrulamıştır.

Elde edilen bu sonuçlar, özellikle dış kulak yolu, kulak zarı ve orta kulak hastalıklarının doğru tanı ve tedavisi için oldukça önemlidir. Ancak daha fazla sayıda ve farklı çalışmalara hala açık bir çalışma alanıdır. Örneğin, veri ön işlemenin çeşitlenmesi, daha büyük ölçekli ve çeşitli dış kulak yolu, kulak zarı ve orta kulak görüntülerinden oluşan veri setleri ile yapılan eğitimler modellerin doğruluğunu artırabilir. Ayrıca bu çalışmadaki veri setinde yer almayan ancak var olan diğer dış kulak yolu, kulak zarı ve orta kulak hastalıkları görüntülerinin de mevcut olduğu farklı veri setleri kullanımı yapılan çalışmaya daha fazla değer katacaktır.

Bu tez ile CNN modellerinin dış kulak yolu, kulak zarı ve orta kulak görüntülerinin sınıflandırılmasında oldukça etkili olduğu gösterilmiştir. Ayrıca veri artırımı ve görüntüleri temizlemek için uygulanan veri ön işleme tekniklerinin de modellerin başarısı üzerinde olan olumlu etkisi dikkat çekmektedir. Ancak yapılan çalışmaların bahsedildiği şekilde detaylandırılması KBB uzmanlarına daha etkili ve hızlı yardımda bulunacak bir sistemin oluşmasını sağlayacaktır.

## KAYNAKLAR

- Akilotu BN, Kadiroğlu Z, Şengür A, Kayaoğlu M, (2019). Evrişimsel Sinir Ağları ve Transfer Öğrenme Yöntemi Kullanılarak Sıtma Tespiti. International Engineering and Science Symposium (IESS) 2019. Siirt, Türkiye.
- Asaoka R, Murata H, Hirasawa K, Fujino Y, Matsuura M, Miki A, Kanamoto T, Ikeda Y, Mori K, Iwase A, 2019. Using deep learning and transfer learning to accurately diagnose early-onset glaucoma from macular optical coherence tomography images. *American journal of ophthalmology*, 198, 136-45.
- Balaban ME, Kartal E, 2015. Veri Madenciliği ve Makine Öğrenmesi Temel Algoritmaları ve R Dili ile Uygulamaları. Çağlayan Kitabevi, İstanbul.
- Bayindir T, Toplu Y, Kizilay A, 2013. Adenotonsiller Hipertrofinin Effüzyonlu Otitis Media Üzerine Etkileri. *Journal of Turgut Ozal Medical Center*, 20, 1, 92-5.
- Carneiro GA, Magalhães R, Neto A, Sousa JJ, Cunha A, 2022. Grapevine Segmentation in RGB Images using Deep Learning. *Procedia Computer Science*, 196, 101-6.
- Cha D, Pae C, Seong S-B, Choi JY, Park H-J, 2019. Automated diagnosis of ear disease using ensemble deep learning with a big otoendoscopy image database. *EBioMedicine*, 45, 606-14.
- Chai A, Li B, Shi Y, Cen Z, Huang H, Liu J, 2010. Recognition of tomato foliage disease based on computer vision technology. *Acta Horticulturae Sinica*, 37, 9, 1423-30.
- Chollet F. Xception: Deep learning with depthwise separable convolutions. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1251-8.
- Demir A, Yilmaz F, Kose O. Early detection of skin cancer using deep learning architectures: resnet-101 and inception-v3. 2019 medical technologies congress (TIPTEKNO), 1-4.
- Demirhan A, Kılıç YA, İnan G, 2010. Tıpta yapay zeka uygulamaları.
- Dumoulin V, Visin F, 2016. A guide to convolution arithmetic for deep learning. arXiv preprint arXiv:1603.07285.
- Esen FA, Aytuğ O, 2022. Derin Öğrenme Yöntemleri ile Bitki Yaprakları Üzerindeki Hastalıkların Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, 40, 151-5.
- Fitriasari HI, Rizkinia M. Improvement of Xception-ResNet50V2 Concatenation for COVID-19 Detection on Chest X-Ray Images. 2021 3rd East Indonesia Conference on Computer and Information Technology (EIconCIT), 343-7.
- Gao S, Lima D, 2021. A review of the application of deep learning in the detection of Alzheimer's disease. *International Journal of Cognitive Computing in Engineering*, 3, 1-8.

- Gayathri J, Abraham B, Sujarani M, Nair MS, 2022. A computer-aided diagnosis system for the classification of COVID-19 and non-COVID-19 pneumonia on chest X-ray images by integrating CNN with sparse autoencoder and feed forward neural network. *Computers in Biology and Medicine*, 141, 105134.
- Gonzalez-Huitron V, León-Borges JA, Rodriguez-Mata A, Amabilis-Sosa LE, Ramírez-Pereda B, Rodriguez H, 2021. Disease detection in tomato leaves via CNN with lightweight architectures implemented in Raspberry Pi 4. *Computers and Electronics in Agriculture*, 181, 105951.
- Gonzalez RC, Woods RE, 2014. Sayısal görüntü işleme: Üçüncü baskıdan çeviri, Palme Yayıncılık, p.
- Goodfellow I, Bengio Y, Courville A, 2016. Deep learning, MIT press, p.
- Habib N, Rahman MM, 2021. Diagnosis of corona diseases from associated genes and X-ray images using machine learning algorithms and deep CNN. *Informatics in Medicine Unlocked*, 100621.
- He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-8.
- Hussain M, Bird JJ, Faria DR. A study on cnn transfer learning for image classification. *UK Workshop on computational Intelligence*, 191-202.
- İnik Ö, Ülker E, 2017. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *GAZİOSMANPAŞA BİLİMSEL ARAŞTIRMA DERGİSİ (GBAD)*, 6, 85-104.
- İsmi O, Özcan C, Yedigöz NG, Ventilation tubes and indications.
- KARA CO, KILIÇ İ, ARDIÇ FN, Ergin H, Burun PÜTFK, DENİZLİ D, 1997. AKUT OTİTİS MEDİANIN ETYOLOJİSİNDE SİGARA VE DİĞER ÇEVRESEL FAKTÖRLERİN ÖNEMİ.
- Karthik R, Hariharan M, Anand S, Mathikshara P, Johnson A, Menaka R, 2020. Attention embedded residual CNN for disease detection in tomato leaves. *Applied Soft Computing*, 86, 105933.
- KAYTEZ SK, Ramazan Ö, ÇELİK H, KESİCİ GG, Zeynep B, HEMODİYALİZ HASTALARINDA ÜREMİK KULAK KAŞINTISI: PREVELANS VE ŞİDDET ANALİZİ. *Ankara Eğitim ve Araştırma Hastanesi Tıp Dergisi*, 53, 1, 57-60.
- KAZKAYASI M, ÖZÜNLÜ A, GEREK M, BAYSALLAR M, KRONİK SÜPÜRATİF OTİTİS MEDİA'DA TIBBİ TEDAVİ.
- Kingma DP, Ba J, 2014. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.

- Krizhevsky A, Sutskever I, Hinton GE, 2017. Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60, 6, 84-90.
- Kruthika K, Maheshappa H, Initiative AsDN, 2019. CBIR system using Capsule Networks and 3D CNN for Alzheimer's disease diagnosis. *Informatics in Medicine Unlocked*, 14, 59-68.
- Llugsí R, El Yacoubi S, Fontaine A, Lupera P. Comparison between Adam, AdaMax and Adam W optimizers to implement a Weather Forecast based on Neural Networks for the Andean city of Quito. 2021 IEEE Fifth Ecuador Technical Chapters Meeting (ETCM), 1-6.
- Mahesh B, 2020. Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*. [Internet], 9, 381-6.
- Murphy J, 2016. An overview of convolutional neural network architectures for deep learning. *Microway Inc*, 1-22.
- Myburgh HC, Jose S, Swanepoel DW, Laurent C, 2018. Towards low cost automated smartphone-and cloud-based otitis media diagnosis. *Biomedical Signal Processing and Control*, 39, 34-52.
- Myburgh HC, Van Zijl WH, Swanepoel D, Hellström S, Laurent C, 2016. Otitis media diagnosis for developing countries using tympanic membrane image-analysis. *EBioMedicine*, 5, 156-60.
- Narin A, Kaya C, Pamuk Z, 2021. Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks. *Pattern Analysis and Applications*, 24, 1207-20.
- Özcan H, 2014. Çok düşük çözünürlüklü yüz imgelerinde derin öğrenme uygulamaları. *Deniz Harp Okulu/Deniz Bilimleri ve Mühendisliği Enstitüsü, İstanbul, Erişim adresi: <https://tez.yok.gov.tr/UlusalTezMerkezi/tezDetay.jsp>*.
- ÖZEL BF, YASAN H, ÇİRİŞ M, DOĞRU H, ÇANDIR Ö, MİRİNGOSKLEROZ GELİŞİMİ ve KULAK ZARI PERFORASYONU İYİLEŞMESİ ÜZERİNE FARKLI AJANLARIN ETKİLERİ.
- Peng H, 2015. Air quality prediction by machine learning methods, *University of British Columbia*.
- Pham V-T, Tran T-T, Wang P-C, Chen P-Y, Lo M-T, 2021. EAR-UNet: A deep learning-based approach for segmentation of tympanic membranes from otoscopic images. *Artificial Intelligence in Medicine*, 115, 102065.
- Polat K, Güneş S, 2007. A hybrid approach to medical decision support systems: Combining feature selection, fuzzy weighted pre-processing and AIRS. *Computer methods and programs in biomedicine*, 88, 2, 164-74.

- Rahaman MM, Li C, Yao Y, Kulwa F, Rahman MA, Wang Q, Qi S, Kong F, Zhu X, Zhao X, 2020. Identification of COVID-19 samples from chest X-Ray images using deep learning: A comparison of transfer learning approaches. *Journal of X-ray Science and Technology*, 28, 5, 821-39.
- Ruuska S, Hämäläinen W, Kajava S, Mughal M, Matilainen P, Mononen J, 2018. Evaluation of the confusion matrix method in the validation of an automated system for measuring feeding behaviour of cattle. *Behavioural processes*, 148, 56-62.
- Scherer D, Müller A, Behnke S. Evaluation of pooling operations in convolutional architectures for object recognition. *Artificial Neural Networks–ICANN 2010: 20th International Conference, Thessaloniki, Greece, September 15-18, 2010, Proceedings, Part III 20*, 92-101.
- Sharma N, Sharma R, Jindal N, 2021. Machine Learning and Deep Learning Applications-A Vision. *Global Transitions Proceedings*, 2, 1, 24-8.
- Sindi H, Nour M, Rawa M, Öztürk Ş, Polat K, 2021. Random fully connected layered 1D CNN for solving the Z-bus loss allocation problem. *Measurement*, 171, 108794.
- Srivastava S, Kumar P, Chaudhry V, Singh A, 2020. Detection of ovarian cyst in ultrasound images using fine-tuned VGG-16 deep learning network. *SN Computer Science*, 1, 1-8.
- Szegedy C, Ioffe S, Vanhoucke V, Alemi AA, (2017). Inception-v4, inception-resnet and the impact of residual connections on learning. [Thirty-first AAAI conference on artificial intelligence 2017.](#)
- Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, Erhan D, Vanhoucke V, Rabinovich A, (2015). Going deeper with convolutions. [Proceedings of the IEEE conference on computer vision and pattern recognition 2015.:](#) 1-9.
- Szegedy C, Vanhoucke V, Ioffe S, Shlens J, Wojna Z, (2016). Rethinking the inception architecture for computer vision. [Proceedings of the IEEE conference on computer vision and pattern recognition 2016.:](#) 2818-26.
- Şahin M, ALTINKAYNAK S, ADALILAR I, KILIÇ S, Sendesen E, D'ALESSANDRO HD, TÜRKYILMAZ D, 2022. Erişkinlerde sık görülen dış ve orta kulak hastalıklarında odyolojik bulgular. *Türk Odyoloji ve İşitme Araştırmaları Dergisi*, 5, 1, 24-7.
- Şeker A, Diri B, Balık HH, 2017. Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi (GMBD)*, 3, 3, 47-64.
- Şentürk M, 2019. Orta kulak patolojilerinin geniş bant timpanometri ve absorbands sonuçlarına etkileri.
- Talo M, 2019. Meme Kanseri Histopatolojik Görüntülerinin Evrimsel Sinir Ağları ile Sınıflandırılması. *Fırat Üniversitesi Müh. Bil. Dergisi*, 31, 2, 391-8.



- Tamma S, 2019. Transfer learning using vgg-16 with deep convolutional neural network for classifying images. International Journal of Scientific and Research Publications (IJSRP), 9, 10, 143-50.
- Traore BB, Kamsu-Foguem B, Tangara F, 2018. Deep convolution neural network for image recognition. Ecological informatics, 48, 257-68.
- Tuncer SA, Ayyıldız H, Kalaycı M, Tuncer T, 2021. Scat-NET: COVID-19 Diagnosis with a CNN Model using Scattergram Images. Computers in Biology and Medicine, 104579.
- Villanueva MB, Salenga MLM, 2018. Bitter melon crop yield prediction using machine learning algorithm. International Journal of Advanced Computer Science and Applications, 9, 3.
- Wahyudi Setiawan M, Utoyo I, Rulaningtyas R, 2019. Classification of neovascularization using convolutional neural network model.
- Yılmaz M, 2016. Görüntü işleme teknikleriyle zirai tuzaklardaki böcek adedi tespiti, Maltepe Üniversitesi, Fen Bilimleri Enstitüsü.
- YILMAZ ÖÜA, YAYIN K, 2021. DERİN ÖĞRENME, KODLAB YAYIN DAĞITIM YAZILIM LTD. ŞTİ., p.
- Zhang J, Li C, Rahaman MM, Yao Y, Ma P, Zhang J, Zhao X, Jiang T, Grzegorzec M, 2022. A comprehensive review of image analysis methods for microorganism counting: from classical image processing to deep learning approaches. Artificial Intelligence Review, 1-70.