



**OPTİMİZE EDİLMİŞ ÇOK KATMANLI EVRİŞİMSEL SİNİR AĞI  
MODELLERİ İLE DİŞ TÜRLERİNİN OTOMATİK SINIFLANDIRILMASI**

**Yusuf Fazıl GÖÇ**

**YÜKSEK LİSANS TEZİ  
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**OCAK 2024**

## ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

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

Yusuf Fazıl GÖÇ

10/01/2024

# OPTİMİZE EDİLMİŞ ÇOK KATMANLI EVRİŞİMSEL SİNİR AĞI MODELLERİ İLE DİŞ TÜRLERİNİN OTOMATİK SINIFLANDIRILMASI

(Yüksek Lisans Tezi)

Yusuf Fazıl GÖÇ

GAZİ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

Ocak 2024

## ÖZET

Otomatik diş tipi tanıma; diş sağlığı, adli odontoloji ve yaş tahmini gibi konularda kritik bir role sahiptir. Derin öğrenme işlemi, diş bilimi alanında ve dijital diş radyografilerinin analiz edilmesi konusunda potansiyeli yüksek bir husustur. Diş ve diş problemlerinin manuel teşhisinden sıyrılıp, makine destekli bir sinir ağı ile diş hekimlerine sağlanacak faydanın artırılması oldukça önemlidir. Bu çalışmada panoramik diş radyografilerinden elde edilen tek diş görüntüleri; kesici diş, köpek dişi, azı dişi ve küçük azı dişi olarak dört sınıfa ayrıldı. Veri setini oluşturan görüntüler, dört farklı evrişimsel sinir ağı modelini eğitmek ve test etmek için kullanıldı. Ayrıca performans olarak diğer iki modele kıyasla daha üstün başarı gösteren Resnet152 ve Mobilenetv2 modelleri optimizasyon işlemi için seçildi. Modelin omurga kısmındaki ağ derinliği, filtre boyutu ve artık katmanın modifikasyonunun modellere etkisi incelendi. Modellerin performansları karışıklık matrisinden elde edilen doğruluk, kesinlik ve duyarlılık değerleri ile ölçüldü. %84,25 olan, en yüksek doğruluk değerine adım adım modifikasyon ile ulaşılan model Mobilenetv2.4'tür. Evrişimsel katman sayısındaki artışın ağa etkisinin, filtre boyutu ve artık katman parametrelerinin etkisinden daha fazla olduğu gözlemlendi. Diş karakteristiğine uygun şekilde otomatik diş tanıma işleminin yapılması; dişçilik alanında dişlerin, diş kayıtlarıyla yüksek doğruluk ve kesinlik oranları ile eşleşmesini sağlamaktadır.

Bilim Kodu : 90507  
Anahtar Kelimeler : Derin öğrenme, evrişimsel sinir ağı, diş tipi tanıma, diş radyografisi  
Sayfa Adedi : 37  
Danışman : Dr. Öğr. Üyesi Özgür ERGÜL

AUTOMATIC CLASSIFICATION OF TOOTH TYPES WITH OPTIMIZED  
MULTILAYER CONVOLUTIONAL NEURAL NETWORK MODELS

(M. Sc. Thesis)

Yusuf Fazıl GÖÇ

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

January 2024

ABSTRACT

Automatic tooth type identification has a critical role in issues such as dental health, forensic odontology and age estimation. Deep learning has high potential in the field of dental science and in analyzing digital dental radiographs. It is very important to get rid of manual diagnosis of teeth and dental problems and increase the benefit to dentists with a machine-supported neural network. In this study, single tooth images are obtained from panoramic dental radiographs. They were divided into four classes: incisor, canine, molar and premolar. The images that make up the dataset were used to train and test four different convolutional neural network models. In addition, Resnet152 and Mobilenetv2 models, which showed superior performance compared to the other two models, were selected for the optimization process. The effect of modification of the network depth, filter size and residual layer in the backbone part of the model that is on the models was examined. The performance of the models was measured by the accuracy, precision and sensitivity values obtained from the confusion matrix. The model with the highest accuracy value of 84.25%, achieved by step-by-step modification, is Mobilenetv2.4. It was observed that the effect of the increase in the number of convolutional layers on the network was greater than the effect of the filter size and residual layer parameters. Performing automatic tooth identification in accordance with tooth characteristics ensures that teeth are matched with dental records with high accuracy and precision in the field of dentistry.

Science Code : 90507  
Key Words : Deep learning, convolutional neural network, tooth type identification, dental radiography  
Page Number : 37  
Supervisor : Assist. Prof. Dr. Özgür ERGÜL

## TEŐEKKÜR

Çalıőmam boyunca bilgi ve birikimlerini her daim benimle paylaőan ve verimli bir sonuca ulaőmam için her aőamada bana yol gősteren Sayın Dr. Öğr. Üyesi Mahmut Emin ÇELİK ve Sayın Dr. Öğr. Üyesi Özgür ERGÜL'e teőekkür ederim. Desteklerini hiçbir zaman esirgemeyen, bu süreci tamamlamam için sürekli beni motive eden sevgili eőim Türkan KAHVECİOĞLU GÖÇ'e gönülden teőekkür ederim. Her daim mantıklı fikirleriyle yanımda olan babam Engin GÖÇ'e ve annem Taliye GÖÇ'e teőekkür ederim.



## İÇİNDEKİLER

	Sayfa
ÖZET .....	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER .....	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ .....	x
RESİMLERİN LİSTESİ .....	xi
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ.....	1
2. LİTERATÜR ARAŞTIRMASI .....	3
2.1. İnsanın Diş Tipleri .....	3
2.2. Diş Tanıma ve Diş Tanımının Kullanıldığı Alanlar.....	3
2.3. Diş Radyografisi .....	4
2.4. Bazı Evrişimsel Sinir Ağı Modelleri .....	5
2.4.1. Resnet152 .....	5
2.4.2. Mobilenetv2 .....	6
2.4.3. Densenet201 .....	8
2.4.4. VGG19.....	9
2.5. Diş Radyografisi ile Yapılan Derin Öğrenme Çalışmaları .....	10
2.6. Evrişimsel Sinir Ağı Modellerinin Performansını Artırma Konusunda Yapılan Çalışmalar.....	14
3. GEREÇ VE YÖNTEM .....	17
3.1. Veri Seti .....	17
3.2. Resnet152 Model Modifikasyonu.....	18
3.3. Mobilenetv2 Model Modifikasyonu .....	20

	<b>Sayfa</b>
3.4. Deęerlendirme Kriterleri .....	21
4. BULGULAR .....	23
5. TARTIŞMA .....	29
6. SONUÇ VE ÖNERİLER .....	31
KAYNAKLAR .....	33
ÖZGEÇMİŞ .....	36



## ÇİZELGELERİN LİSTESİ

<b>Çizelge</b>	<b>Sayfa</b>
Çizelge 2.1. Artık boğum blok içerisindeki dönüşümler .....	8
Çizelge 3.1. Karışıklık matrisi .....	22
Çizelge 4.1. Dört modelin doğruluk değerleri .....	23
Çizelge 4.2. Dört modelin kesinlik değerleri .....	23
Çizelge 4.3. Dört modelin duyarlılık değerleri .....	24
Çizelge 4.4. Dört modelin fl skor değerleri .....	24
Çizelge 4.5. Modifiye modellerin doğruluk değerleri .....	25
Çizelge 4.6. Modifiye modellerin kesinlik değerleri .....	25
Çizelge 4.7. Modifiye modellerin duyarlılık değerleri .....	26
Çizelge 4.8. Modifiye modellerin fl skor değerleri.....	26
Çizelge 5.1. Benzer çalışmalar ile kıyaslama .....	30

## ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Artık öğrenme bloğu.....	6
Şekil 2.2. Çevrilmiş artık blok .....	7
Şekil 2.3. 5 katmanlı, büyüme oranı 4 olan Densenet bloğu .....	9
Şekil 3.1. Resnet152 boğum blok modifikasyonu .....	19
Şekil 3.2. Resnet152'ye evrişim katmanı eklenmesi .....	19
Şekil 3.3. Mobilenetv2 boğum blok modifikasyonu.....	20
Şekil 3.4. Mobilenetv2 artık katman ve taban evrişimsel katman modifikasyonu .....	21
Şekil 4.1. Resnet152 ve Resnet226 karışıklık matrisi kıyaslaması.....	26
Şekil 4.2. Mobilenetv2 ve Mobilenetv2.4 karışıklık matrisi kıyaslaması.....	27

## RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 3.1. Eğitim veri setinden örnek dış görselleri .....	18



## SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

### Simgeler

**M**

### Açıklamalar

Milyon

**$\theta$**

Theta

### Kısaltmalar

**AESA**

### Açıklamalar

Alan tabanlı evrişimsel sinir ağı

**BT**

Bilgisayarlı tomografi

**ESA**

Evrişimsel sinir ağı

**JPEG**

Joint photographic expert group

**KIBT**

Konik ışınlı bilgisayarlı tomografi

**LRN**

Local response normalization

**ReLU**

Rectified linear unit

**RGB**

Red green blue

**ROI**

Region of interest

**TDD**

Tufts dental database

**VGG**

Visual geometry group

## 1. GİRİŞ

Diş tanıma işleminin kullanıldığı en kritik husus insanların kimlik tespitidir. Birçok amaçla bu tespit işlemi yapılabilir. Özellikle adli odontolojide kullanımı; kazayla, cinayetle ve doğal afetle ölmüş kişilerin tespitini içermektedir. Kimlik tespitinde kullanılan diş tanıma işleminin çeşitli tipleri vardır. Bunların en başında; ölüm sonrası dişlerin, ölmeden önceki dişlerle kıyaslanması gelir. Bu işleme karşılaştırmalı diş tanıma adı verilir. Karşılaştırmalı diş tanımada; ölüm sonrası diş görüntüleri, ölmeden önce çekilen diş kayıtları ve diş radyografileri ile kıyaslanır. Birçok tedavi görmüş dişlerin kıyaslanarak kimlik tespitinin yapılması, hiç tedavi olmamış dişlere göre daha kolaydır. Ayrıca diğer dokulara göre dişin daha sağlam yapıya sahip olmasından ötürü, ölüm sonrası diş etken maruziyeti olduğunda diş yapısı daha az bozulur. Diğer bir önemli diş tanıma yöntemi ise ölüm sonrası diş profillemeye yöntemidir. Bu yöntem ölüm öncesine ait herhangi bir diş görüntüsü ve kaydı olmadığında kullanılır. Diş profillemeye ile ölünün yaşına, cinsiyetine ve akrabalık köklerine ulaşılabilir. Özellikle yaş konusunda diş yapısı çok bilgi verir. Çocuklarda diş gelişim grafiği ile dişin yapısından diş analizi yapılır. Yirmilik diş, genç erişkinlerde yaş tespiti için kullanılır. Orta yaş ve yaşlılarda ise dişlere yapılmış restorasyon işlemlerinden, diş aşınmalarından ve periodontal hastalığın ilerleme seviyesinden gelen bilgilerle analiz yapılır. Sigara ve alkol gibi bazı alışkanlıklar hakkında da diş bilgi sağlar. Carabelli tüberkülü ve kürek şekilli kesici dişler de etnik köken hakkında bilgi sağlar. Bu iki yöntem haricindeki yöntemlerde ise çıkarılabilir diş tellerinden ve etiketlenmiş protez dişlerden faydalanılır [1].

Derin öğrenmede kullanılan ESA'lar (Evrışimsel Sinir Ağı), fotoğraf ve radyografi görüntüleri gibi dijital görüntülerdeki bölgeleri algılama ve tanıma amacıyla diş hekimliğinde geniş bir kullanıma sahiptir. ESA'lar diş çürüklerinin, periapikal lezyonların ve periodontal kemik erimesinin teşhisinde kullanılır. Panoramik radyografilerde periodontal kemik kaybının tespitinde; ESA'ların kabiliyetinin, uzmanlarla karşılaştırılabilir seviyede olduğu görülmüştür. ESA'lar ayrıca, çene boşluğu sinüziti gibi ağız dışı problemleri de tespit etmek amacıyla kullanılır. ESA'lar, çeşitli klinik durumlarda, insanın analiz performansı ile kıyaslanabilir bir doğruluk seviyesine sahiptir. Ancak bazı limitler ESA'nın performansını etkilemektedir. Örneğin, veriyi oluşturan radyografilerin görüntü kalitesi ve boyutu önemli bir etkiye sahiptir [2].

Diş hekimliğinde, güvenilirliği yüksek teşhisler koyabilmek ve bu yönde tedavi uygulayabilmek için farklı tipte radyografi görsellerine uygun daha yüksek doğruluk sağlayan ESA modellerine ihtiyaç vardır. Aynı şekilde, adli odontoloji alanında diş yapısının ve tipinin doğru şekilde tanımlanabilmesi için gelişmiş ESA modellerine ihtiyaç vardır.

Bu çalışmada, farklı alanlarda kullanılan diş tanıma işlemi için performansı artırılmış otomatik sınıflandırma işleminin yapılması amaçlanmıştır. Diş tanıma konusunda doğru şekilde bir sınıflandırma yapabilecek derin ağ yapısına sahip olan ESA modelleri seçildi. Panoramik diş radyografilerinden elde edilen tek diş görüntüleri ile bu seçilen modeller eğitilerek doğruluk değerleri elde edildi. Optimize edilip, doğruluk değerlerini yükseltmek için bu modeller arasından iki model seçildi. Modellerin modifikasyonu sonrası doğruluk değerlerinde artış gözlemlendi ve sınıflandırma işlemindeki başarı arttı. Modellerin eğitiminden daha fazla radyografi verisiyle de daha yüksek doğruluk değeri elde edilebilir ancak hem daha fazla veri toplama imkânı olmamıştır hem de bu çalışmanın esas odaklandığı nokta ESA model modifikasyonudur. Çalışmanın çerçevesine farklı veri setleri dahil edilmemiştir, ancak farklı tipte radyografi görüntüleri ile de optimize edilmiş modeller eğitilebilir. Diş tanımadan farklı bir amaç için, örneğin dişte çürük var mı, yok mu sınıflandırması gibi, optimize edilmiş modeller kullanılabilir. Eğitilmiş optimize modeller sayesinde tekli diş görüntülerinin hangi diş tipine ait olduğunun daha doğru şekilde tespit edilmesi çalışmanın ana katkısıdır.

## 2. LİTERATÜR ARAŞTIRMASI

### 2.1. İnsanın Diş Tipleri

İnsan çenesi, alt çene ve üst çene olarak ana iki bölümden oluşur. Bu bölümlere ait dişler üst çene veya alt çene dişi olarak isimlendirilir. Bu bölümler de kendi içinde sol üst çeyrek, sağ üst çeyrek ve sol alt çeyrek, sağ alt çeyrek olarak ikiye ayrılır. Doğduktan sonra insan ağızında bulunan geçici dişlere süt dişleri, sonradan süt dişlerinin yerine çıkan dişlere ise kalıcı diş adı verilir. İnsanların dişleri dört tip dişten oluşmaktadır: köpek dişi, kesici diş, azı dişi ve küçük azı dişi. Ağızdaki toplam kalıcı diş sayısı 32, toplam süt dişleri ise 20 adettir. Kalıcı dişlerde; alt ve üst çenede ortada bulunan ikişer adet kesici dişe merkezi kesici dişler, bu dişlerin bir sağında ve bir solunda bulunan dişlere ise yanal kesici dişler adı verilir. Bu yanal kesici dişlerin ardından birer adet köpek dişleri gelir. Köpek dişlerini ikişer adet küçük azı dişi, küçük azı dişini ise üçer adet azı dişi takip eder. Süt dişlerinde ise kesici ve köpek dişlerinin yeri ve sayısı aynıdır. Ancak köpek dişinden sonra gelen azı dişi birinci, bu azı dişini takip eden azı dişi ise ikinci azı dişi olarak adlandırılır. Merkezi kesici, yanal kesici ve köpek dişleri ön diş tipleridir. Küçük azı dişi ve azı dişi ise arka diş tipleridir. Dişin görünen kısmına, diş eti üzerinde olan kısmı, taç adı verilir. Ön diş tiplerinde sadece taç yüzeyleri varken, arka diş tiplerinde ise yüzeyler ve ayrıca taçta oyuklar ve çıkıntılar vardır. Kesici dişlerin taç kısmı keskin kenarlıyken, köpek dişlerinin taç kısmı bir sivri uca sahiptir. Küçük azı dişleri ve azı dişlerinin taç kısmı ise iki veya daha fazla sivri uç içerir [3].

### 2.2. Diş Tanıma ve Diş Tanımanın Kullanıldığı Alanlar

Diş tanıma, bir dişin hangi tipte bir diş olduğunun belirlenmesi işlemidir. Bu tanıma işlemi dişin alt veya üst çenede, kalıcı veya süt dişi, ağızın sağ veya sol tarafında, köpek dişi veya kesici diş veya küçük azı dişi veya azı dişi olmasına göre gerçekleştirilebilir. Diş tanıma işlemi, dişin boyut ve şekil olarak değişkenlik göstermesinden ötürü genellikle zorlayıcı bir işlemdir. Ayrıca dişler cinsiyete dayalı da farklılık gösterir. Diş tanıma işleminin başarılı bir şekilde gerçekleştirilebilmesi için diş anatomisinin (morfoloji) iyi bilinmesi gerekir. Diş anatomisi, dişin taç ve kök yapısı, diş gelişimindeki aşamalar ve prensipleri hakkında bilgileri toplar ve bu bilgileri kullanabilecek kişilere ve araştırma alanlarına sunar. Klinik dişçilikte, diş hastalıklarının teşhisi ve dişin tedavisi açısından diş tanıma işlemi önemli bir

rol oynamaktadır. Diş çürüklerinin hangi dişte olduğu ve hasarlı dişin hangi diş olduğu konusunda yardımcı olur. Karşılaştırmalı odontoloji; dişler üzerinden hayvanların besin tiplerini, tür karakteristiklerini ve evrim süreçlerini inceler. Adli odontoloji, kaza veya doğal felaket meydana geldiğinde bu durumlardan mağdur olmuş insanların diş tip bilgilerini kullanır. Kullandığı bu bilgiler ışığında mağdur olan insanların yaş, cinsiyet ve ırk bilgilerine ulaşılabilir. Fosillerden yeni canlı türlerinin keşfedilmesi ve türlerin tanımlanabilmesi açısından diş tanıma, paleontoloji için önemlidir. Diş antropolojisi, insan dişine özgü bilgileri ortaya koyarak, insan topluluğun içindeki diş yapısı farklılıklarını ortaya çıkarır. Farklılıkların ortaya koyulabilmesi diş tipinin ayırt edilebilmesi önemlidir [4-9].

### **2.3. Diş Radyografisi**

Diş radyografisi, dişleri ve ağzın içini gösteren bir x-ray (röntgen) görüntüsüdür. Elektromanyetik radyasyon formu olan röntgenler yüksek enerjisiyle vücutta bir bölgeye işleyip film üzerinde vücudun o bölgesinin resmini çıkartabilmektedir. Bu film üzerinde boşluklar siyah olarak, radyasyonu engelleyen yoğun kısımlar beyaz olarak, sıvı kısımlar ise gri olarak görünür. Kemikler radyasyonu emdiği için filmde beyaza yakın renkte görünürler. Bu nedenle diş ve kemikler x-ray görüntüsünde daha net belli olur. Diş eti gibi yumuşak dokular ise radyasyonu diş kadar emmediği için daha az belirgin olur. Diş radyografisi; dişlerdeki ve dişlerin arasındaki çürükleri, diş etindeki problemleri ve yirmilik dişlerin oluşumunu ve şeklini erkenden teşhis etme konusunda diş hekimlerine oldukça yardımcıdır. Diş röntgeni diğer röntgen tiplerine göre avantajlıdır. Röntgen çekildikten sonra röntgen filmi çok kısa sürede çıkar ve röntgende verilen radyasyon dozu diğer röntgenlerin yarısıdır. Diş hekimleri düzgün görüntü elde edemediğinde rahatlıkla tekrar röntgen çekebilirler [10].

Diş radyografilerinin çekim şekline göre ve çekilme amacına göre farklı tipleri vardır. Bitewing radyografisi; bu radyografi tipinin ismi, röntgen çekilirken kanat şeklinde içinde film bulunduran bir cihazın ısırılmasından dolayı verilmiştir. Üst ve alt, arka azı dişlerinin görüntülenmesinde kullanılır. Dişlerin taç kısımlarını aydınlatır. Diş hekimleri genelde bu radyografii dişlerin arasında oluşan çürükleri görüntülemek için kullanır. Periapikal radyografisi, tek veya iki diş içerisindeki çürükleri görmek için kullanılır. Diş kökünden taç kısmına kadar dişin kompleksini gösterir. Oklüzal radyografisi, dişlerin keskin yüzeyinde alt

ve üst çeneye bakan bir filmin oluşturduğu radyografi tipidir. Diş gelişimi ve yerleşimini kontrol etmek için kullanılır. Panoramik radyografi; tek görüntüde bütün dişleri, çeneyi ve dişlerin hizalanmasını gösteren radyografi tipidir. Diş kırıkları, tümörleri, çürükleri ve kistleri tespit etmek için kullanılır. KIBT (Konik Işınlı Bilgisayarlı Tomografi) radyografi, dişlerin üç boyutlu olarak görüntülenmesini sağlayan radyografi tipidir. Üç boyutlu görüntü sayesinde iki boyutlu görüntülere kıyasla diş ve çene hakkında daha detaylı bilgi sağlar. İmplant tedavisinde, implant yerleşiminde ve kemik yoğunluğu konusunda hata oluşmaması konusunda büyük bir etkiye sahiptir [10, 11].

#### **2.4. Bazı Evrişimsel Sinir Ağı Modelleri**

ESA herhangi bir görseldeki desenlerin ayırt edilebilmesi, görüntü tanıma amacıyla geliştirilmiş, basit ve üzerinde değişiklik yapılabilir bir sinir ağıdır. İleri beslemeli, öğrenme yoluyla kendini optimize eden bir sinir ağıdır. ESA'lar üç katmandan oluşur: evrişimsel katman, ortaklama katmanı ve tam bağlantı katmanı. Evrişimsel katman; giriş verisine filtre uygulayarak, girişteki değerler ile filtredeki ağırlıklar arasında skalar çarpım uygulayarak, çıkış verisi sağlar. Ortaklama katmanı, evrişimsel katmanın çıktısındaki örneklem sayısını azaltır. Tam bağlantı katmanı ise en sondaki çıktı ile sınıf başarısını ortaya koyar [12].


Bir ESA modeli genel olarak üç bölgeden oluşur. Bunlar işlem sırasına göre; omurga, boyun ve baş olarak adlandırılır. Omurga bölgesi, veriden temel özellik çıkartma işleminin yapıldığı bölgedir. Bütün evrişim katmanları, küme normalizasyonları ve ReLU (Rectified Linear Unit) gibi aktivasyon fonksiyonları bu bölgededir. Boyun bölgesi, omurga bölgesinin çıkardığı özellikleri güçlendirme işlemi yapar. Baş bölgesi ise sınıflandırma işleminin yapıldığı kısımdır.

##### **2.4.1. Resnet152**

Derin artık öğrenme çerçevesinin bir parçası olan Resnet152 modeli, önceki Resnet mimarilerine göre oldukça derin olan ağların eğitimini kolaylaştırmak için özel olarak tasarlanmıştır. Bunu, referans verilmeyen fonksiyonları öğrenmek yerine; katmanları, katman girdileriyle ilişkili olarak artık fonksiyonları öğrenecek şekilde yeniden formüle ederek başarır. Bu yaklaşımın, bu ağların optimize edilmesini kolaylaştırdığı ve önemli

ölçüde artan derinlikten doğruluk elde etmelerine olanak sağladığı gösterilmiştir. Artık öğrenme işlemi, birkaç katman yığınının Eş. 2.1 fonksiyonuna uydurulmasıdır. Bu fonksiyonda  $H(x)$ ; öğrenilmesi gereken temel eşleme,  $x$  ise bu katmanların girdisidir. Bu yöntem, kimlik eşlemesi etrafında oluşan sapmaları bulmayı kolaylaştırarak öğrenme sürecini basitleştirmeyi amaçlar. Resnet; Şekil 2.1’de görüldüğü gibi, bir veya daha fazla katmanı atlayan kısayol bağlantıları sunar. Örneğin, giriş ve çıkış boyutları aynıysa, kısayol kimlik haritalaması yapar ve çıktısını yığılmış katmanların çıktısına ekler. Bu tasarım, ekstra parametre veya hesaplama karmaşıklığı getirmez. Giriş/çıkış boyutları farklı olduğunda, boyutları eşleştirmek için genellikle  $1 \times 1$  evrişimler aracılığıyla doğrusal bir projeksiyon kullanılır. Resnet152 modeli, boğum bloğu tasarımını kullanır. Resnet152’deki her boğum bloğu, üç katmanlı bir yapıya sahiptir: boyutu azaltan bir  $1 \times 1$  evrişim, bir  $3 \times 3$  evrişim (boğum katmanı) ve boyutu geri eski haline getiren başka bir  $1 \times 1$  evrişim. Bu yapı, ağ boyunca istenen derinliğe ulaşmak için farklı aşamalarda farklı sayıda tekrarlanır. Resnet152 modelinin toplam katman sayısı ise 152’dir. Resnet152, artık öğrenme ve verimli kısayol bağlantıları kullanarak derin ağların eğitimini kolaylaştırmaya odaklanmış, ayrıca karmaşık görüntü tanıma görevleri için de oldukça etkili bir tasarım olduğunu kanıtlamıştır [13].

$$F(x) = H(x) - x \quad (2.1)$$




Şekil 2.1. Artık öğrenme bloğu [13]

#### 2.4.2. Mobilenetv2

Mobilenetv2 mimarisi, mobil ve kaynak kısıtlı ortamlar için özel olarak tasarlanmış olup, doğruluk değerini korurken işlem sayısını ve bellek gereksinimlerini önemli ölçüde azaltır.

"Ters çevrilmiş artık ile lineer boğum" olarak adlandırılan Şekil 2.2’de görüldüğü gibi, yenilikçi bir katman modülü sunar. Ters çevrilmiş artık yapısı, ince darboğaz katmanları arasındaki kısayol bağlantılarını kullanır. Ara genişletme katmanı, özellik filtreleme için doğrusal olmayan bir kaynak olarak görev yapan hafif, “derinlemesine evrişimler” kullanır. Daha da önemlisi, temsil gücünü korumak için dar katmanlardaki doğrusal olmayan unsurlar kaldırılır. Derinlemesine ayrılabilir evrişimler, evrişimi iki ayrı katmana böler. İlk katman derinlemesine evrişim, her bir giriş kanalı için bir evrişim sağlar. İkinci katman noktasal evrişim 1x1, giriş kanallarının doğrusal kombinasyonları yoluyla yeni özellikler oluşturur. Bu yaklaşım çok daha verimlidir ve standart evrişimlerle karşılaştırıldığında hesaplama maliyetini neredeyse 9 kat azaltır. Doğrusal boğumlar, doğrusal olmayan katmanların bilgiyi yok etmesini önlemek için kullanılır [14].



Şekil 2.2. Çevrilmiş artık blok [14]

Mobilenetv2 mimarisi, artık katmanlar ile bir dizi derinlemesine ayrılabilir evrişimsel boğum bloklarından oluşur. Çizelge 2.1’de gösterildiği üzere temel blok, “s” adım değeri ve “t” genişleme faktörü ile k sayıda kanalı k’ sayıda kanala dönüştürür. Bu blok 1x1 evrişimsel katman, 3x3 derinlemesine evrişimsel katman ve lineer 1x1 evrişimsel katmandan oluşur. İlk ve ikinci katman lineer olmadığı için bu katmanlardan sonra ReLU6 aktivasyon fonksiyonu kullanılır. Ağ 32 adet filtre (kanal sayısı) ile başlar ve 17 adet artık boğum blokları ile devam eder. Genişleme faktörü ağ boyunca 6’dır. Genişlik çarpanı ve girdinin görüntü çözünürlüğü gibi ayarlanabilir hiper parametreler kullanılarak mimarı performansı farklı performans noktalarına uyarlanabilir. Genişlik çarpanı 1’den küçükse, ağın incelmeye yani kanal sayılarının düşürülmesini sağlar. Bunun sonucunda hesaplama maliyeti düşer ve performans artırılmış olur. Çözünürlük çarpanı ise ağ içerisinde

ayarlanabilir olduğu için hesaplama maliyetini düşürüp, doğruluk değerinin artmasını sağlayabilir [14].


Çizelge 2.1. Artık boğum blok içerisindeki dönüşümler [14]

Input	Operator	Output
$h \times w \times k$	1x1 conv2d, ReLU6	$h \times w \times (tk)$
$h \times w \times tk$	3x3 dwise s=s, ReLU6	$\frac{h}{s} \times \frac{w}{s} \times (tk)$
$\frac{h}{s} \times \frac{w}{s} \times tk$	linear 1x1 conv2d	$\frac{h}{s} \times \frac{w}{s} \times k'$

### 2.4.3. Densenet201

Densenet, ESA'ya benzersiz bir mimari yaklaşım sunmaktadır. Geleneksel ESA'lardan önemli ölçüde farklı olarak, her katmanı ileri beslemeli bir şekilde diğer tüm katmanlarla bağlar. Bu tasarımın; kaybolan gradyan problemini hafifletme, özellik yayılımını güçlendirme, özelliğin yeniden kullanımını teşvik etme ve parametre sayısını azaltma gibi birçok avantajı olduğu gösterilmiştir. Densenet modelinde büyüme oranı,  $k$  olarak belirtilen, ağır önemli bir hiper parametresidir. Her katmanın ürettiği özellik haritalarının sayısını temsil eder. Bu parametre, her katmanın ağır genel durumuna ne kadar yeni bilgi kattığını kontrol eder. Hesaplama verimliliğini artırmak için Densenet, boğum katmanları kullanır. Her 3x3 evrişimden önce, girdi özellik haritalarının sayısını azaltmak için 1x1 evrişim katmanı getirilir. Deneylerde, bu boğum katmanlarının özellikle etkili olduğu bulunmuştur ve Densenet-B olarak adlandırılan ağda, her 1x1 evrişim 4k özellik haritası üretmiştir. Model kompaktlığını daha da artırmak için, geçiş katmanlarında özellik haritası sayısını azaltılabilir. Yoğun blokta  $m$  özellik haritası varsa, takip eden geçiş katmanı  $\theta m$  kadar çıkış özellik haritası üretir. Buradaki  $\theta$ , " $0 < \theta \leq 1$ ", sıkıştırma faktörü olarak adlandırılır. Densenet-C olarak adlandırılan Densenet'te " $\theta < 1$ " olarak kullanılır ve deneylerde  $\theta=0,5$  olarak ayarlanmıştır. Densenet, eşit sayıda katmana sahip üç yoğun bloktan oluşur. İlk yoğun bloğa girmeden önce, girdi görüntüler üzerinde 16 çıkış kanallı bir evrişim yapılır. 3x3 çekirdek boyutlu evrişimli katmanlar için, özellik haritası boyutunu sabit tutmak amacıyla girdilerin her tarafı bir piksel sıfırla doldurulur. İki ardışık yoğun blok arasındaki geçiş katmanları olarak 1x1 evrişim ve 2x2 ortalama ortaklama katmanı kullanılır. Son yoğun bloktan sonra genel ortalama ortaklama katmanı uygulanır ve ardından bir softmax sınıflandırıcı kullanılır. Üç yoğun blokta özellik haritası boyutları sırasıyla 32x32, 16x16 ve 8x8'dir. Densenet-BC'nin, Resnet ile karşılaştırıldığında, Resnet

ile benzer doğruluk seviyesi elde etmek için yaklaşık üçte bir oranda daha az parametreye ihtiyaç duyduğu tespit edilmiştir. Örneğin, 20M parametrelili bir Densenet201 modeli, Resnet modellerine benzer sonuçlar elde ederken Resnet modellerine kıyasla çok daha az parametre kullanır. Yoğun bağlantılı, darboğaz katmanlarına odaklanan ve ağ boyunca bilgi ve gradyan akışını iyileştiren Densenet mimarisi, özellikle görüntü tanıma gibi görevlerde daha az parametre ile üstün performans gösteren geleneksel derin ESA'lara güçlü ve verimli bir alternatif oluşturur [15].



Şekil 2.3. 5 katmanlı, büyüme oranı 4 olan Densenet bloğu [15]

#### 2.4.4. VGG19

VGG19 mimarisi, derinliği ve basitliği ile dikkat çeken VGG (Visual Geometry Group) ağının bir varyasyonu olan derin bir evrişimsel sinir ağıdır. Mimari, geleneksel ESA mimarilerinde artan derinliğin sınıflandırma doğruluğunu önemli ölçüde iyileştirebileceğini göstermektedir. Ağ; sabit boyutlu, 224x224 RGB (Red Green Blue), görüntü kabul eder. Tek yapılan ön işlem, eğitim setinde hesaplanan ortalama RGB değerinin her pikselden çıkarılmasıdır. VGG19, ağ boyunca küçük 3x3 algılama alanına sahip filtreler kullanır. Bu boyut; sol veya sağ, yukarı veya aşağı ve merkez kavramını

yakalayabilecek en küçük boyuttur. Evrişim adımı 1 piksele sabitlenmiştir. Evrişimsel katman girdisinin üzerinde yapılan uzamsal doldurma işlemi, evrişim işleminden sonra uzamsal çözünürlüğün korunmasını sağlar. VGG modelinde ağ derinliği değişkendir. Örneğin, VGG19 modelinde 16 evrişim ve 3 tam bağlantı katmanı olmak üzere 19 katman vardır. Evrişim katmanlarındaki kanal sayısı, ilk katmanda 64'ten başlar ve her maksimum ortaklama katmanından sonra 512'ye ulaşana kadar iki katına çıkar. Ağ, ilk ikisi 4096 kanala sahip, üçüncüsü ise 1000 kanala sahip üç adet tam bağlantı katmanı içerir. Son katman softmax katmanıdır. VGG modelinde tüm gizli katmanlar, ReLU aktivasyon fonksiyonunu kullanır. VGG11 modelinin bir konfigürasyonu haricinde, normalizasyon işlemi kullanılmaz. VGG19 ağı; derinliği, küçük evrişim filtreleri ve basitliği ile derin öğrenmede, özellikle görüntü sınıflandırma işlemlerine önemli katkılarda bulunmuştur [16].

## **2.5. Diş Radyografisi ile Yapılan Derin Öğrenme Çalışmaları**

Maria Prados-Privado ve arkadaşları yaptıkları çalışmada, diş tanılmasında zaman alan manuel diş numaralandırma işlemini otomatikleştirmeyi hedeflemişlerdir. Sundukları ESA'yı, derin öğrenme tekniklerini kullanarak panoramik diş röntgenlerinde dişleri tanımlayıp numaralandırmak için tasarlamışlardır. Çalışmada, 5121 adet anonimleştirilmiş panoramik diş görüntüsünden oluşan bir veri seti kullanılmıştır. 5121 adet görselden bazıları elenmiştir, eğitime ve doğrulama işlemi için 1217 adet görsel kullanılmıştır. Nesne tespiti ve sınıflandırma olmak üzere iki ana katmandan oluşan bir ESA mimarisi kullanılmış, hesaplama süresi ve doğruluk için transfer öğrenme desteklenmiştir. Kullanılan teknolojiler arasında, nesne tespiti için Matterport Mask AESA (Alan tabanlı Evrişimsel Sinir Ağı) ve sınıflandırma katmanı için Resnet101 bulunmaktadır. ESA modeli, diş tespitinde %99,24 ve diş numaralandırmada %93,83 doğruluk oranı elde etmiş, bu da ESA'nın dişleri tanıma ve numaralandırmada yüksek etkinlik sağladığını göstermektedir. Model, eksik dişlerin veya metal parçaların bulunması gibi anomalilere sahip diş görüntülerini işleme konusunda güçlü bir performans sergilemiştir. Çalışma, önerilen ESA'nın diş numaralandırmada otomasyonu konusunda etkili olduğunu vurgulamakta ve klinik ortamlarda pratik uygulama potansiyeline işaret etmektedir. Yazarlar, modelin performansını diğer çalışmalarla karşılaştırarak hem diş tespiti hem de numaralandırma konusunda modelin daha yüksek doğruluk gösterdiğini belirtmişlerdir [17].

James Faure ve Andries Engelbrecht; çalışmada, Güney Afrika gibi gelişmekte olan ülkelerdeki kamu sağlık merkezlerinde, hasta sayılarının yüksek ve uzman personelin sınırlı olduğu durumlarda, diş hekimleri ve ortodontik radyologlar için zaman alıcı bir görev olan panoramik radyografi analizinin zorluklarını ele almışlardır. Çalışmada, 2500 adet panoramik radyografi görüntüsü içeren bir veri seti kullanılmıştır. Bu görüntüler, TIFF'ten PNG formatına dönüştürme, normalleştirme ve 150x150 piksele yeniden boyutlandırma gibi ön işlemlerden geçirilmiştir. Veri seti eğitme, doğrulama ve test alt kümelerine ayrılmıştır. ESA kullanılarak, "çalışılabilir" ve "çalışılamaz" olarak iki sınıfta, radyografi görüntülerini ayırt edebilen bir görüntü sınıflandırma modeli oluşturulmuştur. Model mimarisi; evrişim katmanlarından, maksimum ortaklama katmanlarından, düzleştirme katmanlarından ve tam bağlı katmanlardan oluşmuştur. Veri setindeki sınıfları dengelemek için veri çoğaltma teknikleri kullanılmıştır. Eğitim sürecinin küme büyüklüğü 32 olarak ayarlanmış ve eğitim işlemi 10 devir ile çalıştırılmıştır. Model, doğrulama adımında %92,06 doğruluk elde etmiştir. Eğitim süreci, modelin görüntü veri seti ile uyumlaştırılmasını içermiş, toplu iş boyutu 32 olarak ayarlanmış ve 10 dönem çalıştırılmıştır. Aşırı uyum sağlama, modelin efektini belirlemek için takip edilmiştir. Doğrulama adımındaki veri setinden elde edilen karışıklık matrisi, modelin radyografi görüntülerini sınıflandırma konusunda doğruluğunu onaylamıştır [18].

Yuma Miki ve arkadaşları çalışmada, özellikle adli tanımlama için, KIBT radyografi görüntülerinde diş türlerini sınıflandırmak amacıyla derin evrişimsel sinir ağı kullanılmasına odaklanmışlardır. Bu yaklaşımla, özellikle büyük çaplı afet senaryolarında, diş hekimleri için yoğun emek isteyen ve stresli olan ölüm sonrası diş bulgularında manuel çizelgeleme işlemini otomatikleştirmeyi amaçlamışlardır. Sınıflandırma yapmak için 7 tip diş görüntüsü kullanılmıştır: merkezi kesici dişler, yanal kesici dişler, köpek dişleri, birinci ve ikinci küçük azı dişleri, birinci ve ikinci azı dişleri. Araştırmada, 42'si eğitim ve 10'u test için olmak üzere 52 adet BT (Bilgisayarlı Tomografi) seti kullanılmıştır. Bu setlerden 7 farklı diş tipi sınıfı, için ROI'ler (Region of Interest) çıkartılmıştır. Bu setlerden çıkarılan toplam ROI sayıları ise her sınıf için sırasıyla 6653, 6766, 7928, 5794, 3346, 2115 ve 2657'dir. Üç farklı rastgele sayıda eğitim seti ile model eğitilmiştir. Görüntüler döndürülerek ve görüntülerin yoğunlukları değiştirilerek görüntülere veri çoğaltma tekniği uygulanmıştır. Kullanılan derin ESA modeli, beş evrişim katmanı, üç ortaklama katmanı ve iki tam bağlı katman içeren Alexnet'tir. Araştırmada, veri çoğaltmanın sınıflandırma doğruluğunu yaklaşık %5 oranında iyileştirdiği tespit edilmiştir. Artırılmış eğitim verileri

kullanılarak elde edilen ortalama doğruluk oranı %88,8 olmuştur [19].

Dankai Liao ve Carol Anne Hargreaves; çalışmada, ESA modeli kullanarak üç farklı kategoride (normal, çürük ve dolgulu) panoramik diş radyografisi sınıflandırması yapmışlardır. Araştırmada, 116 hastadan toplanan 3712 tek diş görüntüsü içeren bir veri setini kullanmıştır. Bu görüntüler, bir keskinleştirme filtresi ve bir yoğunluk renk haritası kullanılarak ön işlemden geçirilmiştir. Tüm görseller 300x300 piksel boyutuna getirilerek toplam veri sayısı 3700 olarak yeniden düzenlenmiştir. Eğitim ve doğrulama veri sayısı 2960 ve test veri sayısı 740 olarak ayarlanmıştır. Ayrıca eğitim verisine üç farklı veri çoğaltma uygulanmıştır. İlk veri çoğaltmada bütün kategoriler beş katına çıkarılmıştır. İkinci veri çoğaltmada “normal” ve “dolgulu” kategorileri 5 katına, “çürük” kategorisi ise 15 katına çıkarılmıştır. Üçüncü veri çoğaltmada “çürük” kategorisi 20 katına, “normal” kategorisi 5 katına, “dolgulu” kategorisi ise 10 katına çıkarılmıştır. Veri çoğaltma işlemleri: çevirme, parlaklık değiştirme, bulanıklık değiştirme, -15 ve +15 derece arasında döndürme, kaydırma, çözünürlük artırma ve düşürme. Çalışma, özellik çıkarıcı olarak eğitilmiş bir transfer öğrenme modeli olan NASNetMobile ve sınıflandırıcı olarak bir ESA modelini kullanmıştır. Üçüncü veri çoğaltma işleminin uygulandığı eğitim veri setinden "normal", "çürük" ve "dolgulu" için sırasıyla 0,92, 0,90 ve 0,91 yüksek duyarlılık değerleri elde edilmiştir. Test veri setinde, bu değerler sırasıyla 0,86, 0,81 ve 0,85 olarak elde edilmiştir. NASNetMobile özellik çıkarıcı tarafından desteklenen ESA modeli, diş röntgen görüntülerini belirtilen kategorilere etkili bir şekilde sınıflandırmıştır. Bu yaklaşımın; özellikle zorlu vakalarda veya kötü görüntü kalitesiyle uğraşılırken, diş hekimleri için bir karar destek aracı olarak hizmet edebileceği gösterilmiştir [20].

Ayşe Betül Oktay tarafından yürütülen çalışma, panoramik diş röntgen görüntülerinde otomatik diş tespiti için bir yöntem geliştirmeyi amaçlamıştır. Araştırmada, panoramik diş röntgen görüntülerinden oluşan bir veri seti kullanılmıştır. Diş görüntülerinde kırılma işlemi yapılmamıştır, bütün dişler ve çene görüntülerde aynı şekilde kalmıştır. Görüntülerin; ESA modeli tarafından analiz edilebilmesi için, görüntüler boyut ayarlamaları ve normalleştirme gibi ön işleme adımlarından geçmiştir. Diş ve ağız boşluğu tespiti için Alexnet mimarisinin modifiye edilmiş bir versiyonu kullanılmıştır. ESA modelinin, röntgen görüntülerindeki üç farklı diş türünü ve arka planı tanıması ve sınıflandırması için model eğitilmiştir. Model, dişleri tespit etme ve sınıflandırmada yüksek doğruluk değeri elde etmiştir. Çalışma; azı dişi sınıflandırılmasında %94,32, küçük

azı diři sınıflandırılmasında %91,74 ve kesici diř sınıflandırılmasında %92,47 dođruluk deđeri gstererek, modelin diř grntlerini analiz etmedeki bařarisını gstermiřtir [21].

Anıl Grses ve Ayře Betl Oktay tarafından yrtlen alıřmada; panoramik diř grntlerinden, diřlere yapılan iřlemlerin ve restorasyon trlerinin otomatik olarak tespit edilmesi amalanmıřtır. alıřmada; Googlenet, Densenet ve Resnet olmak zere c adet farklı evriřimsel sinir ađı mimarisi kullanılmıřtır. İmplantlar, kanal kk tedavileri, amalgam ve kompozit dolgular, diř telleri ve restore edilmemiř diřler gibi diř iřlem trlerine odaklanılmıřtır. ESA'lar, 3013 adet diř grntsnden oluřan bir veri setindeki 900 adet test verisiyle deđerlendirilmiř ve Densenet %94 ile en yksek dođruluđa ulařmıřtır. alıřma, diř tellerinin ve implantların diđer diř iři trlerine gre daha yksek dođrulukla tespit edildiđini bulmuřtur. alıřma, zellikle Densenet iin yksek kesinlik ve duyarlılık deđerleri bildirmiřtir. Densenet'in performansı ođu durumda Googlenet ve Resnet'i geride bırakmıřtır. Diř implantları, tm ESA'lar arasında en yksek tespit dođruluđuna sahipken, dolgular en dřk dođruluđa sahip olmuřtur [22].

Lawrence Y. Deng ve arkadařları tarafından yrtlen alıřmada, 200 000 rntgen grnts arasından kırılma iřlemiyle 3953 adet rntgen grnts elde edilmiřtir. Bu grntler alıřmanın veri setini oluřturmuřtur. Bu veri seti; “normal”, “dolgulu”, “implant” ve “rk” olarak drt sınıfa ayrılmıřtır. Farklı eđitim ve test verileri oranına gre yedi farklı grup oluřturulmuřtur. Bu grupların her biri 100, 150, 200 ve 250 řeklinde drt farklı devir deđerleriyle eđitilmiřtir. Eđitim iin kullanılan ESA modeli 3x3 boyutunda 192 adet evriřim filtresi, 3 adet ortaklama katmanı, 2 adet ıkarma katmanı iermektedir. En yksek dođruluk deđerleri, test verisinin toplam veriye oranı %16 olan nc grupta elde edilmiřtir. En yksek dođruluk deđeri 200 devirde %93,04 olarak elde edilmiřtir. Sınıf bazında; “normal” sınıfı %87, “dolgulu” sınıfı %98, “implant” sınıfı %98 ve “rk” sınıfı %89 dođruluk deđerleriyle sonu vermiřtir [23].

Rames Aliyev ve arkadařları, panoramik diř grselleri zerinden ocukların yařlarının tahmini alıřmasını, genellikle bu ama iin kullanılan Demirjian metodunu geliřtirerek yapmıřlardır. alıřmada, diř geliřim ařamasını sınıflandırmak iin ESA modeli ve yař tahmini iin ise regresyon tahmin edici olarak LightGBM kullanılmıřtır. Sunulan yntem iki ařamadan oluřmaktadır. İlk ařamada ESA modeli, diř grntlerini deđerlendirerek geliřim evresine gre diřleri sınıflandırır. İkinci ařamada LightGBM regresyonu,

sınıflandırılmış diş evresine göre yaş tahmininde bulunur. Veri seti yaşları 6 ile 13,8 arasında olan, 256'sı kız ve 219'u erkek olmak üzere toplam 475 kişiden alınmış panoramik diş görüntülerini içermektedir. Demirjian metodundaki evrelere göre 7 farklı diş tipi etiketlenmiştir. Veri setine histogram eşitleme ile parlaklık artırılarak ve k-ortalama sınıflandırma ile yoğunluk değiştirilerek ön işlem uygulanmıştır. Panoramik görsellerdeki dişler kırılmış ve 224x224 piksel boyutuna getirilmiştir. Veri seti %64 eğitim, %16 doğrulama ve %20 test verisi olacak şekilde üçe bölünmüştür. Cinsiyete göre aynı yaştaki çocuklarda diş gelişimi farklı olabileceği için iki cinsiyete göre ayrı tahminleme işlemi yürütülmüştür. ESA modeli 4 evrışımsel katmandan ve 3 tam bağlantı katmanından oluşmaktadır. Eğitim işlemi yapılırken veri çoğaltma işlemi de yapılmıştır. Küme büyüklüğü 8 olarak belirlenmiştir. 7 adet diş tipi için 7 kere model eğitilmiştir. En yüksek doğruluk değeri %79,3 ile azı dişi sınıfı tarafından elde edilmiştir. Ayrıca yaş tahmini konusunda Demirjian metodu ve önerilen metodun ikisi de kullanılmış ve sonuçları kıyaslanmıştır. Yaş tahminlemede; ay hatası yönünden önerilen regresyon yöntemi, ortalama 3,5 ay farkla Demirjian yönteminden daha iyi olduğunu ortaya koymuştur [24].

## **2.6. Evrışımsel Sinir Ağı Modellerinin Performansını Artırma Konusunda Yapılan Çalışmalar**

Sanjit Maitra ve arkadaşları; farklı giriş parametrelerinin ESA modelini nasıl etkilediğini tespit etmek için, beş sınıflı diyabetik retinopati evrelerinin sınıflandırılması işlemini, renkli göz içi retinal görsel veri seti kullanarak yapmışlardır. Çalışmada; evrişim katmanı sayısı, her katmandaki evrişim filtresi sayısı, evrişim filtre boyutu ve aktivasyon fonksiyonu tipi gibi farklı parametrelerin ESA'ya etkisi incelenmiştir. Bir evrişim katmanındaki filtre sayısı az olduğunda daha iyi doğruluk ve daha az işlem zamanı elde edilmiştir. Daha küçük boyuttaki filtreler daha yüksek doğruluk ve daha az işlem zamanı sağlamıştır. Sabit sayıda filtre sayısı içeren evrışımsel katman sayısı artırıldıkça, doğruluk değerinin arttığı gözlemlenmiştir. Aktivasyonu fonksiyonu tipinin değiştirilmesi ise model doğruluğunu etkilememiştir [25].

Ahmed Fakhry ve arkadaşları; geçirmeli elektron mikroskobu beyin görüntüleri üzerinde segmentasyon işlemi yapmışlardır. Bu işlemi yaparken kendi geliştirdikleri farklı ağ derinliğine ve taban filtre boyutuna sahip dört farklı ESA modellerini kullanmışlardır. Bu farklı modellere verilen eğitim verisindeki görsel boyutları da farklılık göstermiştir. İki modelde maksimum ortaklama katmanından önce iki yerde LRN (Local Response

Normalization) kullanılmıştır. Ama bunun, sonuçlara pek bir etkisinin olmadığı fark edilmiştir. Dört model arasından en az hatayla segmentasyon yapan model, en çok evrişimsel katmana sahip, taban evrişimsel filtre boyutu en yüksek olan ve görsel girdi boyutu en yüksek olan modeldir. Ayrıca ağın tabanından tepesine ilerlerken evrişimsel filtre boyutlarının büyükten başlayıp küçülerek gitmesinin, modelin performansına pozitif etkide bulunduğu tespit edilmiştir [26].



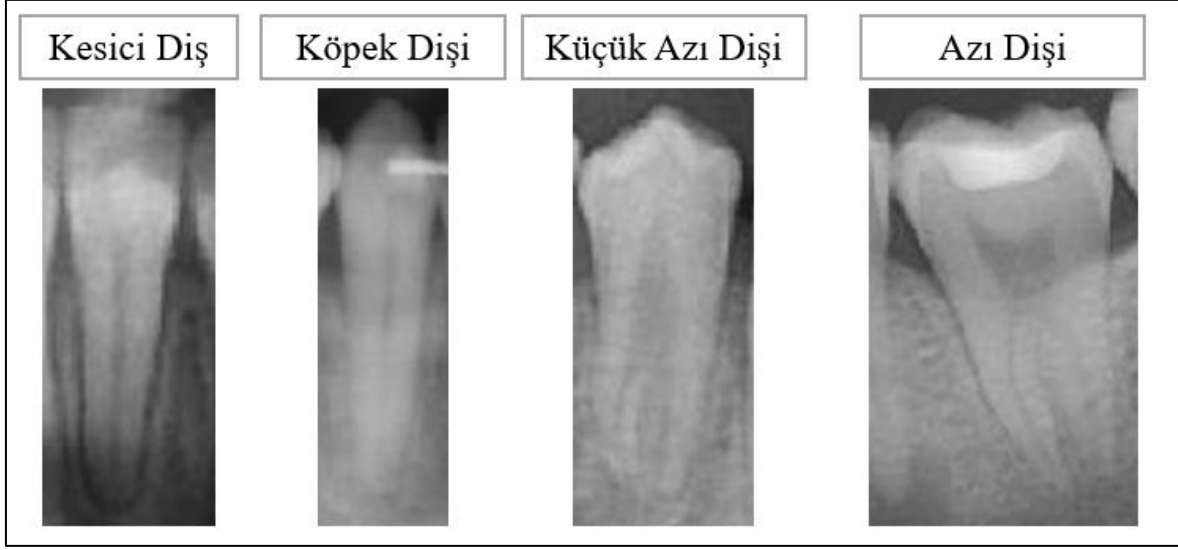


### 3. GEREÇ VE YÖNTEM

#### 3.1. Veri Seti

Bu çalışmanın veri seti, açık erişimi olan TDD'deki (Tufts Dental Database) panoramik diş radyografi görüntülerinden elde edilmiştir [27]. Bu veri tabanındaki radyografi görüntüleri; dişleri, anomalileri, alt ve üst çenedeki bütün dişleri gösteriyor. Geleneksel tipte radyografi görüntüleri arasında panoramik görüntü çeşitli avantajlar sağlıyor: röntgenin bütün ağız bölgesini kapsıyor olması, tek bir röntgende bütün alt ve üst çenedeki bütün dişlerin görülebiliyor olması ve dişlerin tam olarak yerinin görülebiliyor olması. Az radyasyon yayılımı sağlaması, teşhisi sağlama kapasitesinin yüksek olması, hızlı kullanım sağlaması ve hastalar tarafından tercih edilen bir yöntem olması sebepleriyle de panoramik radyografi diş hekimliğinde ideal bir yöntemdir. Bitewing ve periapikal radyografi ağız içinde spesifik bölgeyi görüntüler ancak ağız içerisinde birden fazla alan taranmak istendiğinde birkaç kere röntgen çekilmesi gerekebilir, bu da hastanın radyasyon maruziyetini artırır.

1000 adet panoramik görselden tek tek dişler kırıldı. Kırpma işleminden sonra, toplam 10877 adet görsel elde edildi. Görsellerin hepsi JPEG (Joint Photographic Expert Group) formatındadır. Bütün bu görseller, “kesici diş”, “köpek dişi”, “küçük azı dişi” ve “azı dişi” olarak dört farklı sınıf olacak şekilde sınıflandırma işlemi için etiketlendi. Her sınıf için görsel sayısı aynı olmayacak şekilde, görseller sınıflara ayrıldı. Toplam görsel sayısı %80 eğitim verisi, %10 doğrulama verisi, %10 test verisi olarak üçe bölündü. Eğitim seti; köpek dişi sınıfında 1298, kesici diş sınıfında 2542, azı dişi sınıfında 2667, küçük azı dişi sınıfında 2198 adet görsel olacak şekilde hazırlandı. Test seti; köpek dişi sınıfında 162, kesici diş sınıfında 317, azı dişi sınıfında 333, küçük azı dişi sınıfında 274 adet görsel olacak şekilde hazırlandı. Eğitim işleminden önce eğitim görselleri rastgele kırpma, test görselleri ise merkezi kırpma ile 224x224 piksel boyutuna getirildi. Eğitim görsellerine ön işleme olarak 0,5 ihtimalle yatay çevirme uygulandı.



Resim 3.1. Eğitim veri setinden örnek diş görselleri

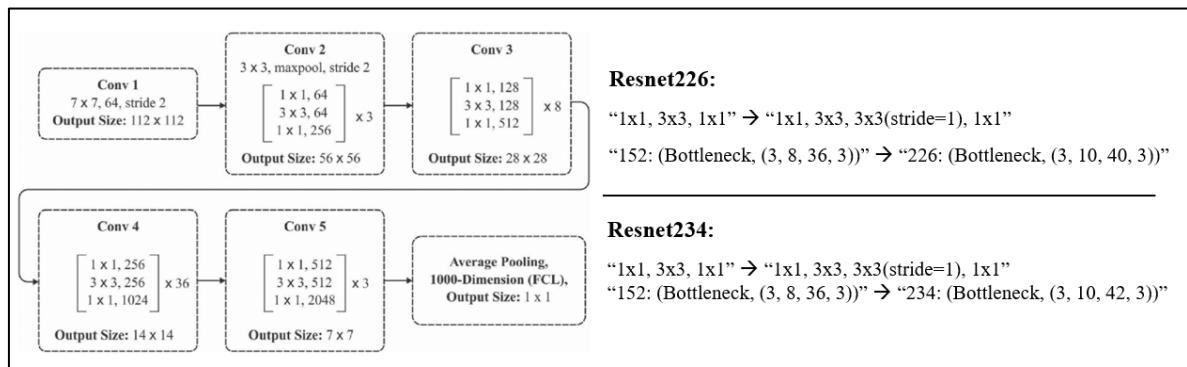
Veri setini eğitmek için dört farklı model kullanıldı. Bunlar Resnet152, Mobilenetv2, VGG19 ve Densenet201 modelleridir. VGG19 hariç bütün modellerin boyun bölgesinde genel ortalama ortaklama katmanı, baş bölgesinde lineer sınıflandırıcı kullanıldı. VGG19 modelinde boyun bölgesi çıkartıldı ve baş bölgesinde lineer olmayan, normal sınıflandırma kullanıldı. Bütün modellerin omurga kısımları modellerin tanımlanan yapısı nasılsa o şekilde bırakıldı. Bu modellerin eğitim performansı kıyaslaması sonrası modifikasyon için Resnet152 ve Mobilenetv2 modelleri seçildi. Tüm modellerde; veriyi hazırlama kısmında kullanılan normalizasyon işlemi, ortalama değer olarak [123,675, 116,28, 103,53] matrisini ve standart sapma olarak [58,395, 57,12, 57,375] matrisini içermektedir.

### 3.2. Resnet152 Model Modifikasyonu

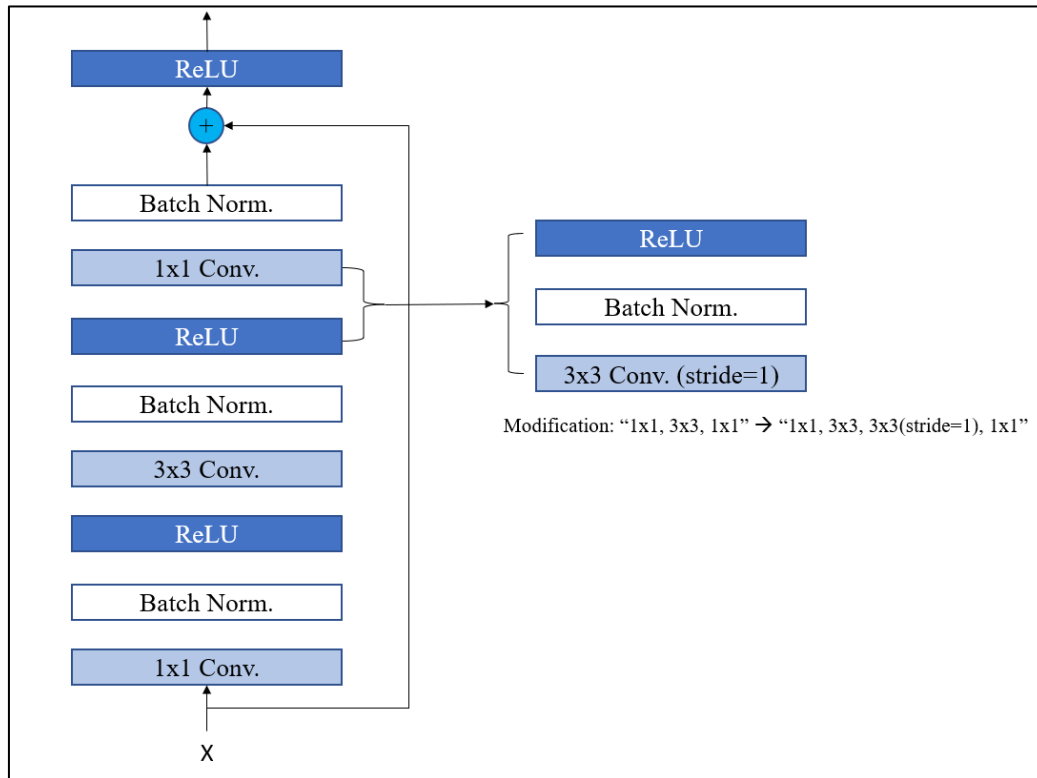
Resnet152 modeli, modelin doğruluk değeri performansını artırmak için seçilen birinci modeldir. Bu modelde değiştirilebilecek parametreler; aktivasyon fonksiyon tipi, artık boğum bloğu tekrarı ve evrişim katmanı sayısı olarak seçilmiştir. Resnet152 modelinin, daha etkili bir özellik haritası elde etmek için, sadece omurga kısmında değişiklik yapıldı. Boyun ve baş bölgesi aynı şekilde bırakıldı.

Resnet152 modelinde ilk değişiklik olarak ReLU aktivasyon fonksiyonu yerine ReLU6 aktivasyon fonksiyonu kullanıldı. Bu işlemten sonra ReLU aktivasyon fonksiyonu ile model optimize edilmeye devam edildi. Giriş verisine daha fazla evrişim katmanı uygulayıp daha fazla öğrenilecek özellik çıkartmak için boğum bloklarının tekrar sayısı

artırıldı [26]. Şekil 3.1 ve Şekil 3.2’de görüldüğü üzere; “Conv3” bloğundaki tekrar sayısı 8’den 10’a, “Conv4” bloğundaki tekrar sayısı 36’dan 40’a çıkartıldı. Ayrıca her artık blokta, her 3x3 evrişim katmanından sonra adım değeri 1 olan 3x3 evrişim katmanı, küme normalizasyonu ve ReLU içeren, eklendi. Modelin derinliği; boğum blok tekrarı ile değil, direkt katman eklenilerek, modelin farklı bir noktasına müdahale edilerek artırıldı. Bu yeni model katman sayısındaki artıştan ötürü Resnet226 olarak isimlendirildi. Resnet226 modelinin üzerine “Conv4” bloğunun tekrar sayısı 40’tan 42’ye çıkarıldı ve yeni modelin ismi Resnet234 olarak belirlendi.



Şekil 3.1. Resnet152 boğum blok modifikasyonu

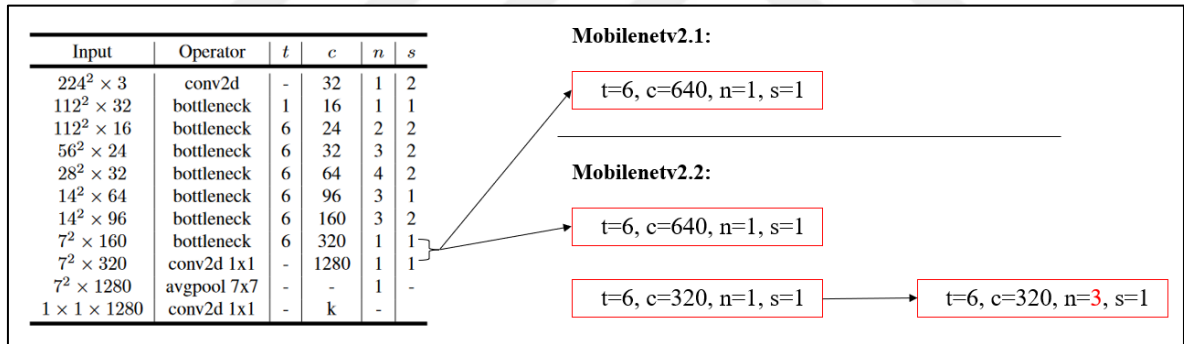


Şekil 3.2. Resnet152’ye evrişim katmanı eklenmesi

### 3.3. Mobilenetv2 Model Modifikasyonu

Mobilenetv2 modeli, modelin doğruluk değeri performansını artırmak için seçilen ikinci modeldir. Bu modelde değiştirilebilecek parametreler; ters çevrilmiş artık boğum bloğu tekrarı ve sayısı, evrişim katmanı sayısı, evrişim katmanını atlayıp çıktıya eklenen girdi sayısı, taban evrişimsel filtre boyutu olarak seçilmiştir. Mobilenetv2 modelinin, daha etkili bir özellik haritası elde etmek için, sadece omurga kısmında değişiklik yapıldı. Boyun ve baş bölgesi aynı şekilde bırakıldı.

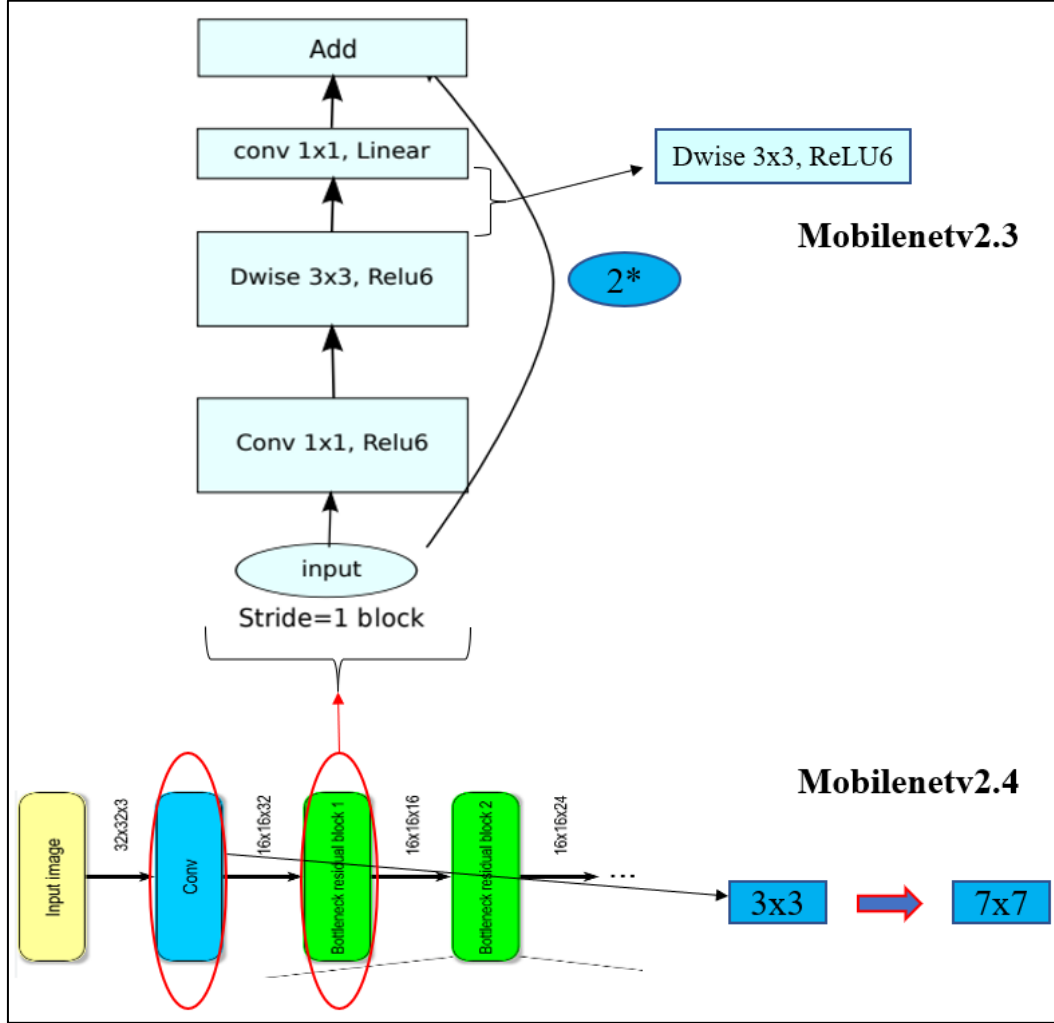
Mobilenetv2 modelinde; kanal sayısı 320, genişleme faktörü 6, tekrar sayısı 1 ve adım değeri 1 olan boğum bloğundan sonra kanal sayısı 640, genişleme faktörü 6, tekrar sayısı 1 ve adım değeri 1 olan boğum bloğu eklendi. Şekil 3.3'te görüldüğü gibi, yeni model ismi, versiyon yükseltmesiyle Mobilenetv2.1 olarak belirlendi. Mobilenetv2.1 versiyonun üzerine kanal sayısı 320 olan bloğun tekrar sayısı 1'den 3'e çıkarıldı. Yeni modele isim Mobilenetv2.2 olarak verildi.



Şekil 3.3. Mobilenetv2 boğum blok modifikasyonu

Sinir ağı derinliği arttıkça doğruluk değeri doygunluk seviyesine ulaşır. Bu durum, bozulma problemi olarak adlandırılır [13]. Hata oranındaki artışın sebebi de ağa ekstra evrişimsel katmanlar eklenmesidir. Bu problemi çözmek için Şekil 3.4'te görüldüğü gibi boğum bloğunda katmanları atlayıp direkt çıktıya eklenen girdi, artık kısım, 2 ile çarpıldı. Ayrıca 3x3 derinlemesine evrişimsel katman ile 1x1 evrişimsel katman arasına adım değeri 1 olan 3x3 derinlemesine evrişimsel bir katman daha eklendi. Bu yapılan değişiklikler Mobilenetv2.2 modeli üzerinde yapılarak, yeni modele Mobilenetv2.3 adı verildi. Taban evrişimsel filtrenin boyutu ne çok büyük ne de çok küçük olmalı. Büyük boyutlu filtreler gürültülü veriye, küçük boyutlu filtreler ise girdiden daha az özellik çıkartılmasına neden olur [26]. Bu nedenle; taban evrişimsel filtre boyutunun değiştirilmesinin, doğruluk

değerine olumlu yönde katkı sağlayabileceği kanısına varıldı. Resnet152 modelindeki taban evrişimsel filtresinin boyutu  $7 \times 7$ 'dir. Bu boyutun Mobilenetv2 modelinde de kullanılabilceği ön görüldü.  $3 \times 3$  olan taban filtre boyutu,  $7 \times 7$  olarak değiştirildi ve bu değişiklik Mobilenetv2.3 üzerinde yapıldı. Yeni modele Mobilenetv2.4 adı verildi.



Şekil 3.4. Mobilenetv2 artık katman ve taban evrişimsel katman modifikasyonu

### 3.4. Değerlendirme Kriterleri

Model eğitme işlemi sonucunun değerlendirilmesi için nicel sonuçlara ihtiyaç vardır. Bu nicel sonuçlar için çeşitli formüllerle metrikler ortaya çıkartılır. Bu çalışmada kullanılan metrikler: doğruluk, kesinlik, duyarlılık ve f1 skorudur. Bu metriklerin değerlendirmeleri çalışmanın içeriğine göre yapılır.

Çizelge 3.1’de gösterilen karışıklık matrisindeki doğru pozitif, yanlış pozitif, yanlış negatif ve doğru negatif değerleriyle doğruluk, kesinlik, duyarlılık ve f1 skor metrikleri hesaplanır. Doğruluk değeri; veri setindeki örneklerden elde edilen, doğru olarak tahmin edilip doğru çıkan pozitif ve negatif örnek sayısının, tüm örnek sayısına oranını temsil eder. Kesinlik değeri; doğru olarak tahmin edilip doğru çıkan pozitif örnek sayısının, doğru olarak tahmin edilen örneklerin sayısına oranıdır. Duyarlılık değeri; doğru olarak tahmin edilip doğru çıkan pozitif örnek sayısının, doğru olarak çıkan örnek sayısına oranıdır. Yani pozitif olarak doğru tahmin edilmiş örnek oranını temsil eder [28].

Çizelge 3.1. Karışıklık matrisi

		Tahmin Edilen	
		Doğru	Yanlış
Gerçekleşen	Doğru	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Yanlış	Yanlış Pozitif (YP)	Doğru Negatif (DN)

$$Doğruluk = (DP + DN) / (DP + DN + YP + YN) \quad (3.1)$$

$$Kesinlik = DP / (DP + YP) \quad (3.2)$$

$$Duyarlılık = DP / (DP + YN) \quad (3.3)$$

$$F1 Skor = 2 * Duyarlılık * Kesinlik / (Duyarlılık + Kesinlik) \quad (3.4)$$

## 4. BULGULAR

Bütün modellerin eğitimi, 50 devir ve 32 küme boyutu değerleri ile yapıldı. Bu parametreler sabit tutularak, parametrelerin model başarısına etkisi önlendi. Dört modelin eğitiminden ve doğrulamasından sonra test aşamasında elde edilen doğruluk değerleri Çizelge 4.1’de görülmektedir. Resnet152 ve Mobilenetv2 modellerinin doğruluk değerleri %80’den yukarı olduğu için bu iki model modifikasyon için seçildi.

Çizelge 4.1. Dört modelin doğruluk değerleri

MODELLER	DOĞRULUK
Resnet152	%80,48
VGG19	%76,06
Mobilenetv2	%82,14
Densenet201	%78,08

Çizelge 4.2, Çizelge 4.3 ve Çizelge 4.4’teki kesinlik, duyarlılık ve f1 skor değerlerine bakıldığında, dört modelde azı dişinin ortalama kesinlik değeri %93,19, ortalama duyarlılık değeri %97,38, ortalama f1 skor değeri %95,19’dur. Azı dişisi sınıfının, model eğitimine diğer sınıflara göre daha çok uyum sağladığı görülmektedir. Köpek dişinin ortalama kesinlik değeri %57,60, ortalama duyarlılık değeri %60,81 ve ortalama f1 skor değeri %59,08’dir. Köpek dişisi sınıfının, model eğitimine diğer sınıflara göre çok daha az uyum sağladığı görülmektedir.

Çizelge 4.2. Dört modelin kesinlik değerleri

MODELLER	KESİNLİK			
	Köpek Dişi	Kesici Diş	Azı Dişi	Küçük Azı Dişi
Resnet152	%57,46	%73,32	%95,61	%89,06
VGG19	%53,24	%76,09	%87,67	%73,87
Mobilenetv2	%60,11	%77,26	%96,38	%86,40
Densenet201	%59,60	%70,19	%93,08	%80,36

Çizelge 4.3. Dört modelin duyarlılık değerleri

MODELLER	DUYARLILIK			
	Köpek Dişi	Kesici Diş	Azı Dişi	Küçük Azı Dişi
Resnet152	%64,20	%85,80	%98,20	%62,41
VGG19	%55,56	%77,29	%98,20	%59,85
Mobilenetv2	%67,90	%83,60	%96,10	%71,90
Densenet201	%55,56	%81,70	%97	%64,23

Çizelge 4.4. Dört modelin f1 skor değerleri

MODELLER	F1 SKOR			
	Köpek Dişi	Kesici Diş	Azı Dişi	Küçük Azı Dişi
Resnet152	%60,64	%79,07	%96,89	%73,39
VGG19	%54,38	%76,68	%92,63	%66,13
Mobilenetv2	%63,77	%80,30	%96,24	%78,49
Densenet201	%57,51	%75,51	%95	%71,40

Dört model arasından modifikasyon için en yüksek doğruluk değerine sahip iki model seçildi. Bu modeller Resnet152 ve Mobilenetv2'dir. Resnet152 modelinde ReLU yerine ReLU6 kullanıldığında doğruluk değeri %80,11 olarak elde edildi. Orijinal modelden daha düşük bir değer gelmesi sebebiyle aktivasyon fonksiyonun modellerde değiştirilmesi fikrinden vazgeçildi.

Resnet152'de bazı artık boğum bloklarının tekrarı artırıldığında ve ekstra evrimsel katman eklendiğinde Çizelge 4.5'te görüldüğü gibi Resnet226 için doğruluk değeri %81,40 olarak elde edildi. Resnet152 modeline göre neredeyse %1'lik bir artış görüldü. Ancak artık boğum blok tekrarı biraz daha artırıldığında, Resnet234 modelinde, doğruluk değeri %81,22 olarak elde edildi. Doğruluk değerindeki düşüştüen sonra artık boğum blok tekrarı daha fazla artırılmadı.

Mobilenetv2'de yeni bir ters çevrilmiş artık boğum bloğu son blok olarak eklendiğinde, Çizelge 4.5'te görüldüğü gibi Mobilenetv2.1 modeli için %83,15 doğruluk değeri elde edildi. Mobilenetv2 modeline göre yaklaşık %1'lik artış görüldü. Mobilenetv2.1'de sondan bir önceki boğum bloğunun tekrar sayısı artırıldığında, Mobilenetv2.2 modeli için %83,61 doğruluk değeri elde edildi. Mobilenetv2.2'de artık bağlantı üzerinden evrimsel katmanları atlayıp direkt çıktıya eklenen girdi 2 ile çarpıldığında ve adım değeri 1 olan bloklara ekstra derinlemesine evrimsel katman eklendiğinde, Mobilenetv2.3 modeli için %83,70 doğruluk değeri elde edildi. Son olarak Mobilenetv2.3'te taban evrimsel filtrenin

boyutu 7x7'ye çıkarıldığında, Mobilenetv2.4 için %84,25 doğruluk değeri elde edildi. Mobilenetv2 modeline göre yaklaşık %2,1'lik artış görüldü.

Çizelge 4.6, Çizelge 4.7 ve Çizelge 4.8 incelendiğinde, modifiye edilmiş modellerin eğitim işlemine, azı dişi sınıfının diğer sınıflara göre daha çok uyum sağladığı ortaya çıktı. Köpek dişi sınıfının ise daha az uyum sağladığı görülmektedir. Hemen hemen bütün sınıfların kesinlik, duyarlılık ve f1 skor değerlerinde, modifikasyon sonrasında bir iyileşme gözlemlendi.

Çizelge 4.5. Modifiye modellerin doğruluk değerleri

MODELLER	DOĞRULUK	MODİFİKASYON
Resnet152	%80,48	-
Resnet226	%81,40	Evrişimsel katman eklenerek, katman sayısı artırıldı. Conv3 ve Conv4 boğum bloklarının tekrar sayısı artırıldı.
Resnet234	%81,22	Conv4 boğum bloğunun tekrar sayısı artırıldı.
Mobilenetv2	%82,14	-
Mobilenetv2.1	%83,15	Kanal sayısı 640 olan boğum bloğu eklendi.
Mobilenetv2.2	%83,61	Kanal sayısı 320 olan boğum bloğunun tekrar sayısı artırıldı.
Mobilenetv2.3	%83,70	Adım değeri 1 olan boğum bloklarındaki artık katman, 2 ile çarpıldı. Adım değeri 1 olan bloklara evrişimsel katman eklenerek, katman sayısı artırıldı.
Mobilenetv2.4	%84,25	Taban evrişimsel filtre boyutu, 7x7 yapılarak, artırıldı.

Çizelge 4.6. Modifiye modellerin kesinlik değerleri

MODELLER	KESİNLİK			
	Köpek Dişi	Kesici Diş	Azı Dişi	Küçük Azı Dişi
Resnet152	%57,46	%73,32	%95,61	%89,06
Resnet226	%61,36	%76,78	%97,49	%80,97
Resnet234	%72,22	%70,68	%94,78	%83,33
Mobilenetv2	%60,11	%77,26	%96,38	%86,40
Mobilenetv2.1	%66,43	%78,00	%97,84	%80,94
Mobilenetv2.2	%61,25	%81,79	%96,12	%83,52
Mobilenetv2.3	%73,44	%76,73	%95,34	%83,07
Mobilenetv2.4	%76,11	%79,38	%96,48	%78,78


Çizelge 4.7. Modifiye modellerin duyarlılık değerleri

MODELLER	DUYARLILIK			
	Köpek Dişi	Kesici Diş	Azı Dişi	Küçük Azı Dişi
Resnet152	%64,20	%85,80	%98,20	%62,41
Resnet226	%66,67	%78,23	%93,39	%79,20
Resnet234	%48,15	%88,96	%98,20	%71,17
Mobilenetv2	%67,90	%83,60	%96,10	%71,90
Mobilenetv2.1	%58,64	%83,91	%95,20	%82,12
Mobilenetv2.2	%60,49	%83,60	%96,70	%81,39
Mobilenetv2.3	%58,02	%87,38	%98,20	%77,00
Mobilenetv2.4	%53,09	%88,64	%98,80	%79,93

Çizelge 4.8. Modifiye modellerin f1 skor değerleri


MODELLER	F1 SKOR			
	Köpek Dişi	Kesici Diş	Azı Dişi	Küçük Azı Dişi
Resnet152	%60,64	%79,07	%96,89	%73,39
Resnet226	%63,90	%77,50	%95,40	%80,07
Resnet234	%57,78	%78,77	%96,46	%76,77
Mobilenetv2	%63,77	%80,30	%96,24	%78,49
Mobilenetv2.1	%62,30	%80,85	%96,50	%81,52
Mobilenetv2.2	%60,87	%82,68	%96,41	%82,44
Mobilenetv2.3	%64,83	%81,71	%96,74	%79,92
Mobilenetv2.4	%62,54	%83,76	%97,63	%79,35

Resnet152 modeline modifikasyon yapıldıktan sonra, Şekil 4.1’de koyu yeşil renkteki karede görüldüğü gibi, küçük azı dişi sınıfında doğru pozitif değeri yükseldi. Diğer sınıfların doğru pozitif değerleri çok yükselmese veya düşse de küçük azı dişi sınıfının artışı, doğruluk değerini kayda değer bir şekilde yükseltti.



Şekil 4.1. Resnet152 ve Resnet226 karışıklık matrisi kıyaslaması

Mobilenetv2 modeline modifikasyon yapıldıktan sonra, Şekil 4.2’de açık mavi renkteki karede görüldüğü gibi, köpek dişi sınıfı hariç bütün sınıfların doğru pozitif değerleri yükseldi. Resnet152 modelinde olduğu gibi küçük azı dişi sınıfının doğru pozitif değeri en fazla yükselişi gösterdi. Modifikasyon öncesi ve sonrası kıyaslandığında, modifikasyona en çok pozitif tepkiyi veren küçük azı dişi sınıfı oldu.



Şekil 4.2. Mobilenetv2 ve Mobilenetv2.4 karışıklık matrisi kıyaslaması



## 5. TARTIŞMA

Farklı derin öğrenme modelleri, diş radyografisiyle birlikte tespit ve sınıflandırma işlemleri için kullanılabilir. Kullanılan modelin özellikleri, veri seti boyutu, radyografi tipi ve değerlendirme kriterleri; modelin performansını etkileyen önemli faktörlerdir. Çizelge 5.1’de incelenmiş çalışmalar ile bu çalışma farklı yönlerden kıyaslandı.

Ayşe Betül Oktay’ın çalışmasında bütün sınıfların doğruluk değerleri %91 ile %95 arasındadır. Azı dişi sınıfı, en yüksek doğruluk değerine yani %94,32’ye sahiptir. Bu çalışmada ise azı dişi sınıfı, Mobilenetv2.1 modelinde %97,84 ile en yüksek kesinlik değeri ve Mobilenetv2.4 modelinde %98,80 ile en yüksek duyarlılık değerini elde etti. İki çalışmanın sonucu, azı dişi sınıfının ESA’lara daha çok uyum sağladığını işaret etmektedir [21].

Anıl Gürses ve Ayşe Betül Oktay’ın çalışmasında en yüksek doğruluk değerine Densenet modeli ulaşmıştır. Katman sayısı olarak Resnet18 modeli, bu çalışmada kullanılan Resnet152 modelinin performansına ulaşamamıştır. Resnet18 modeli %93 doğruluk değerini elde etmiş olsa da Densenet modelinin doğruluk değerini geçememiştir. Bu çalışmada ise Resnet152 modelinin evrimsel katman sayısı olarak Resnet18’den fazla olmasından ötürü; Densenet201, her ne kadar her katman bütün önceki katmanlar tarafından beslense de Resnet152 modelinden yüksek doğruluk değeri elde edememiştir [22].

Yuma Miki ve arkadaşlarının çalışmasında yedi diş tipi için yapılan sınıflandırmada, birbirine komşu yatay ve merkezi kesici; birinci ve ikinci küçük azı dişlerinin sınıflandırılması daha yüksek hata ile gerçekleşti. Çünkü bu diş tiplerinin birbirlerine olan benzerlikleri yüksek. Bu çalışmaya benzer şekilde, birinci azı dişi sınıfının kesinlik değeri %96,9 ile en yüksek değerdir. Azı dişi sınıfının derin öğrenmede etkili olduğu ortaya çıkartılmıştır [19].

Lawrence Y. Deng ve arkadaşlarının çalışmasında tasarlanan ESA modeli 192 adet evrimsel filtreye sahiptir. Bu çalışmanın temel modifikasyon konusu olan, derin bir ağ tasarlanmasından ötürü yüksek doğruluk değerleri elde edilmiştir. Ayrıca eğitim ve test

setinin yüzdesel olarak dağılımında, en yüksek doğruluk değeri %16'lık test seti ile sağlanmıştır [23].

Rames Aliyev ve arkadaşlarının sınıflandırma çalışmasında veri setindeki görsel sayısı oldukça azdır. Veri çoğaltma işlemi yapılmış olsa dahi yüksek %80'den yüksek bir doğruluk değeri elde etmek için yeterli olmamıştır. Yedi farklı diş tipi için ortalama doğruluk değeri %70,4 olarak elde edilmiştir. Daha fazla radyografi görseli kullanılarak bu değer daha yukarılara çıkartılabilir. Bu çalışmadaki görsellerin sayısı, dört farklı diş tipi olmasına rağmen incelenen çalışmadakine göre çok daha fazladır [24].

Çizelge 5.1. Benzer çalışmalar ile kıyaslama

Yazar	Amaç	Radyografi Tipi	Model	Veri Sayısı	Metrikler
A. B. Oktay [21]	Tespit	Panoramik	Alexnet	100	Doğruluk: 0,91 – 0,95
A. Gürses [22]	Tespit	Panoramik	Resnet18 Densenet Googlenet	3013	Doğruluk: 0,89 – 0,94 Kesinlik (Makro Ortalama): 0,91 – 0,95 Duyarlılık (Makro Ortalama): 0,87 – 0,96
Y. Miki [19]	Sınıflandırma	KIBT	Alexnet	2500	Doğruluk: 0,888
L. Y. Deng [23]	Sınıflandırma	-	Özgün ESA	3953	Doğruluk: 0,93 Kesinlik (Makro Ortalama): 0,93 Duyarlılık (Makro Ortalama): 0,93 F1 Skor (Makro Ortalama): 0,93
R. Aliyev [24]	Sınıflandırma	Panoramik	Özgün ESA	475	Doğruluk (Ortalama): 0,704 Kesinlik (Makro Ortalama): 0,64 Duyarlılık (Makro Ortalama): 0,61 F1 Skor (Makro Ortalama): 0,598
Bu çalışma	Sınıflandırma	Panoramik	MobileNet V2.4 Resnet226	10877	Doğruluk: 0,81 – 0,85 Kesinlik (Makro Ortalama): 0,79 – 0,83 Duyarlılık (Makro Ortalama): 0,79 – 0,81 F1 Skor (Makro Ortalama): 0,79 – 0,81

## 6. SONUÇ VE ÖNERİLER

Dişlerin sınıflandırılarak diş tanıma işleminin yapılmasında dört ESA modelinin performansı bu çalışmada ortaya koyulmuştur. Resnet152 ve Mobilenetv2 modelleri en yüksek doğruluk değerlerini verdiği için, modifikasyon için bu iki model seçilmiştir. Bu modellerdeki ağ derinliği, artık bağlantı ve filtre boyutu güncellemeleri ile orijinal model eğitimine kıyasla daha yüksek doğruluk değerleri elde edilmiştir. Bu sonuçlar da modifikasyon işleminin başarısını ortaya koymaktadır. Dört diş tipinden azı dişi sınıfının diğerlerine göre daha yüksek başarı elde etmesi, görseldeki dişin ayırt edilebilirliğin yüksek olmasından kaynaklanmıştır. Azı dişi şekil olarak diğer dişlere göre daha belirgin ve özgün bir yapı ortaya koymaktadır. Köpek dişi sınıfının metrik değerlerinin diğer sınıflara göre düşük olması, köpek dişi sınıfının görsel sayısının diğer sınıflara göre çok daha az olmasından kaynaklanmıştır. Doğruluk değerlerinde bütün sınıfların ortalaması alındığı için köpek dişi sınıfının doğru pozitif değerinin az olması, bütün modellerdeki ortalamayı düşürmüştür. Çalışmanın özgünlüğü, bu iki modeldeki modifikasyon işleminin içeriğinden gelmektedir. Farklı modellerde, farklı optimizasyon işlemlerinin uygulanması incelenen çalışmalarda da görülmüştür. Ayrıca, eğitilen modifiye edilmiş modeller diş tanıma konusunda adli odontoloji gibi farklı diş alanlarında kullanılabilirliğe ulaşmıştır.

Çalışmanın genişletilebileceği veya geliştirilebileceği birçok husus mevcuttur. Çalışmada modifiye edilmiş modeller daha fazla sayıda farklı diş radyografileri ile eğitilebilir. Farklı amaçlı diş sınıflandırmaları için eğitilmiş modeller kullanılabilir. Veri setinde veri çoğaltma işlemi veya gürültü giderme gibi ön işleme yöntemleri ile veri setinden daha fazla verim alınabilir. Modellerde yapılan modifikasyonlardan farklı modifikasyonlar aynı modellere uygulanabilir. Örneğin, ağın boyun kısmında genel ortalama ortaklama katmanı yerine rastgele şekilde ortalama ortaklama veya maksimum ortaklama katmanını devreye sokan karışık ortaklama katmanı kullanılabilir [29]. Bu katman sayesinde model gerektiği yerde sadece belirgin özellikleri katmandan geçirebilir. Bu da hem işlem maliyeti hem de doğruluk değeri anlamında pozitif etki gösterebilir. Modellerin tam bağlantı katmanında veya her katmanından sonra bırakma tekniği uygulanabilir [30]. Bu teknik sayesinde nöron bağlantıları arasındaki ağırlıkların rastgele azaltılmasıyla fazla uyum problemi ortadan kaldırılabilir. Modellerde, tepeye yakın son iki veya üç boğum bloğundaki 3x3 evrişimsel katmanı yerine 2x2 evrişimsel katmanı kullanılabilir [26]. Modellerin

optimizasyonu ile birlikte ESA modellerindeki farklı parametrelerin modifikasyonu konusunda cesaretlendirici bir sonuç elde edilmiştir.

Gelişen diş teknolojileri ile, diş üzerinde çalışılan derin öğrenme konusunda da ilerleme yolu açıktır. Çürüklerin, kırık dolguların, diş tümörlerinin ve diş eti hastalıklarının teşhisi ve tedavisi konusunda segmentasyon, sınıflandırma ve tespit işlemleri önemli bir faktör olmaya devam edecektir. Bu işlemlerdeki genel ilerleyiş; derin öğrenmenin, diş bilimine katkısını artırarak devam ettirecektir.



## KAYNAKLAR

1. Pretty, I. A., and Sweet, D. (2001). A look at forensic dentistry--part 1: The role of teeth in the determination of human identity. *British Dental Journal*, 190, 359-366.
2. Corbella, S., Srinivas, S., and Cabitza, F. (2021). Applications of deep learning in dentistry. *Oral Surgery Oral Medicine Oral Pathology Oral Radiology*, 132(2), 225-238.
3. İnternet: ALShami, A., ALHarthi, S., Binshabaib, M., and Wahi, M. (2020). Tooth morphology overview, *IntechOpen*, Web: <https://www.semanticscholar.org/reader/d5a814f97c9ff617b8a9a8cec26e93dcdab1c57f>, Son Erişim Tarihi: 19.11.2023.
4. Kondo, S., Morita, W., and Ohshima, H. (2022). The biological significance of tooth identification based on developmental and evolutionary viewpoints. *Journal of Oral Biosciences*, 64(3), 287-302.
5. Çelik, B., Savaştaer, E. F., Kaya, H. I., and Çelik, M. E. (2023). The role of deep learning for periapical lesion detection on panoramic radiographs. *Dentomaxillofacial Radiology*, 52(8).
6. Çelik, B., and Çelik, M. E. (2023). Root dilaceration using deep learning: a diagnostic approach. *Applied Sciences*, 13(14).
7. Çelik, B., and Çelik, M. E. (2022). Automated detection of dental restorations using deep learning on panoramic radiographs. *Dentomaxillofacial Radiology*, 51(8).
8. Çelik, M. E. (2022). Deep learning based detection tool for impacted mandibular third molar teeth. *Diagnostics*, 12(4).
9. Bacanlı, G., Savaştaer, E. F., and Çelik, M. E. (2022). *Dental filling detection using deep learning in periapical radiography*. In 2022 International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), Turkey, 721-724.
10. Solanki, A. J., and Mahant P. M. (2017). A review on dental radiographic images. *International Journal of Engineering Research and Applications*, 7(7), 49-53.
11. Venkatesh E., and Venkatesh Elluru, S. (2017) Cone beam computed tomography: basics and applications in dentistry. *Journal of Istanbul University Faculty of Dentistry*, 51(3), 102-121.
12. İnternet: O'Shea, K., and Nash, R. (2015). An Introduction to Convolutional Neural Networks. *ArXiv e-prints*. Web: <https://arxiv.org/pdf/1511.08458v2.pdf>, Son Erişim Tarihi: 21.11.2023.
13. He, K., Zhang, X., Ren, S., and Sun, J. (2016). *Deep residual learning for image recognition*. In 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), USA, 2016, 770-778.

14. Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., and Chen, L. -C. (2018). *MobileNetV2: inverted residuals and linear bottlenecks*. In 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, USA, 4510-4520.
15. Huang, G., Liu, Z., Van Der Maaten, L., and Weinberger, K. (2017). *Densely connected convolutional networks*. In 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), USA, 2261-2269.
16. Simonyan, K., and Zisserman, A. (2015). *Very deep convolutional networks for large-scale image recognition*. In 3rd International Conference on Learning Representations (ICLR 2015), USA, 1-14.
17. Prados-Privado, M., García Villalón, J., Blázquez Torres, A., Martínez-Martínez, CH., and Ivorra, C. (2021). A convolutional neural network for automatic tooth numbering in panoramic images. *Biomed Research International*, 2021, 1-7.
18. Faure, J., and Engelbrecht, A. (2021). *A convolutional neural network for dental panoramic radiograph classification*. ISMSI 2021: 2021 5th International Conference on Intelligent Systems, Metaheuristics & Swarm Intelligence, Seychelles, 54-59.
19. Miki, Y., Muramatsu, C., Hayashi, T., Zhou, X., Hara, T., Katsumata, A., and Fujita, H. (2017). Classification of teeth in cone-beam CT using deep convolutional neural network. *Computers in Biology and Medicine*, 80, 24-29.
20. İnternet: Liao, D., and Hargreaves, C. (2023). Classification of dental teeth x-ray images using a deep learning CNN model. *Preprints*. Web: <https://www.preprints.org/manuscript/202305.0513/v1>, Son Erişim Tarihi: 22.11.2023.
21. Oktay, A. B. (2017). *Tooth detection with convolutional neural networks*. In TIPTEKNO, Turkey, 1-4.
22. Gurses, A., and Oktay, A. B. (2020). *Tooth restoration and dental work detection on panoramic dental images via CNN*. In TIPTEKNO, Turkey, 1-4.
23. Deng, L. Y., Ho, S. S., and Lim, X. Y. (2020). *Diseases classification utilizing tooth x-ray images based on convolutional neural network*. In IS3C, Taiwan, 300-303.
24. Aliyev, R., Arslanoglu, E., Yasa, Y., and Oktay, A. B. (2022). *Age estimation from pediatric panoramic dental images with CNNs and lightGBM*. In TIPTEKNO, Turkey, 1-4.
25. Maitra, S., Ojha, R. K., and Ghosh, K. (2018). *Impact of convolutional neural network input parameters on classification performance*. In 2018 4th International Conference for Convergence in Technology (I2CT), India, 1-5.
26. Fakhry A., Peng H., Ji S. (2016). Deep models for brain EM image segmentation: novel insights and improved performance. *Bioinformatics*, 32(15), 2352-2358.
27. Panetta, K., Rajendran, R., Ramesh, A., and Rao, S. (2021). Tufts dental database: a multimodal panoramic x-ray dataset for benchmarking diagnostic systems. *IEEE Journal of Biomedical and Health Informatics*, 26(4), 1650-1659.

28. Dalianis, H. (2018). *Clinical Text Mining*. Switzerland: Springer, 45-53.
29. Yu, D., Wang, H., Chen, P., and Wei, Z. (2014). *Mixed pooling for convolutional neural networks*. Rough Sets and Knowledge Technology: 9th International Conference, China, 364-375.
30. Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research*, 15(1), 1929-1958.





*Gazili olmak ayrıcalıktır*