T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME İLE RADYOLOJİK GÖRÜNTÜ ÜZERİNDEN KEMİK YAŞI TESPİTİ

Mahdi NEZHAD ASAD

YÜKSEK LİSANS TEZİ

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Elektronik Mühendisliği Programı

Danışman

Dr. Öğr. Üyesi Lale ÖZYILMAZ

Mayıs , 2019

T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME İLE RADYOLOJİK GÖRÜNTÜ ÜZERİNDEN KEMİK YAŞI TESPİTİ

Mahdi NEZHAD ASAD tarafından hazırlanan tez çalışması 15.05.2019 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı, Elektronik Mühendisliği Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Dr. Öğr. Üyesi Lale ÖZYILMAZ

Yıldız Teknik Üniversitesi

Danışman

Jüri Üyeleri

Dr. Öğr. Üyesi Lale ÖZYILMAZ
Yıldız Teknik Üniversitesi _____

Prof. Dr. Mehmet SAĞBAŞ
Yeni Yüzyıl Üniversitesi _____

Dr.Öğr.Üyesi Serkan KURT
Yıldız Teknik Üniversitesi _____

Danışmanım Dr. Öğr. Üyesi Lale ÖZYILMAZ sorumluluğunda tarafımca hazırlanan Derin Öğrenme ile Radyolojik Görüntü Üzerinden Kemik Yaşı Tespiti başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim

Mahdi NEZHAD ASAD

İmza

Aileme

TEŞEKKÜR

Bu çalışmanın gerçekleştirilmesinde, iki yıl boyunca değerli bilgilerini bizlerle payşalaşan, kullandığı her kelimenin hayatıma kattığı önemini asla unutmayacağım saygıdeğer danışman hocam; Dr. Öğr. Üyesi Lale ÖZYILMAZ'a, çalışmam boyunca benden bir an olsun yardımlarını esirgemeyen arkadaşım ve hocam Ar. Gör. Dr. İsmail CANTÜRK ve Fatih GENÇ'e ve Pedram KHATAMİNO'ya çalışma süresince tüm zorlukları benimle göğüsleyen ve hayatımın her evresinde bana destek olan değerli aileme ve eşime sonsuz teşekkürlerimi sunarım.

Mahdi NEZHAD ASAD

İÇİNDEKİLER

SİMGE LİSTESİ VII
KISALTMA LİSTESİ VIII
ŞEKİL LİSTESİ IX
TABLO LİSTESİ XI
ÖZET XII
ABSTRACT XVI
1 Giriş 17
1.1 Literatür Özeti 17
1.1.1 Kemik yaşı tespiti yöntemleri 17
1.1.2 Kemik gelişimi olgunlaşması 18
1.1.3 Greulich ve Pyle Yöntemi 19
1.1.4 Tanner-Whitehouse yöntemi 19
1.1.5 Gözlemci ve gözlemciler arası değişkenlik 20
1.1.6 Bilgisayar destekli kemik yaşı tespiti 21
1.1.7 Fels yöntemi 23
1.2 Tezin Amacı 23
1.3 Hipotez 23
2 Tam Otomatik Kemik Yaşı Tespit Yöntemi ve Ön İşleme 25
2.1 Veri seti 25
2.2 Tam otomatik Kemik Yaşı Tespit Yöntemi ve Ön İşleme 28
3 Filtre yöntemleri 30
3.1 Filtre yöntemleri 30

3.1.1 À Trous dalgacık dönüşümü yöntemi 30
3.1.2 Canny kenar algılama yöntemi 32
3.1.2 Diferansyiel Gauss yöntemi (DoG) 33
4 Kullanılan Evrişimsel Ağları ve Çeşitleri 35
4.1 Derin öğrenme tarihi 35
4.2 Evrişimsel ağlar 37
4.3 Havuzlama katmanı (Pooling layer) 40
4.4 Yığın Normalizasyonu(Batch Normalization) 41
4.5 Olasılıksal dereceli azalma(Stochastic gradient decent) 43
4.6 Parametrelerin hesaplanması 44
4.7 Doğrultmuş doğrusal birim (Rectified linear unit-Relu) fonksiyonu 44
4.8 Softmax Softmax fonksiyonu ve Tam bağlantılı katman 45
4.9 Resnet 50 45
4.10 Inception v3 50
4.11 Mobilnet Ağı 56
5 Sonuçlar ve öneriler 60
5.1 Sonuçlar ve öneriler 60
Kaynakça 84
Tezden Üretilmiş Yayınlar 88

SİMGE LİSTESİ

a_j	Maksiumum Havuzlama Değeri
β	Mini batch kaydırma değeri
DoG	Diferansiyel Gauss Filtresi
F(x)	Kalınıtı boloğu (Residual Block)
G	Gauss Filtresi
H_0	À Trous Filtresi
H_1	À Trous Filtresinin ikinci aşaması
K_y	Sobel Filtresinin yatay hali
K_x	Sobel Filtrsinin düzey hali
$\theta(x, y)$	Gradyanın yönü ve açısı
f	Maksiymum Havuzlamada pencere büyüklüğü
S(t)	Evreşimsel işlem
$\widehat{x^{(k)}}$	Normalize
μ_β	Mini_batch ortalaması
σ_β^2	Mini batch variansı
γ	Mini batch ölçeklenmek değeri

KISALTMA LİSTESİ

BN	Batch Normalization (Yığın Normalizayonu)
CAD	Computer Aided Diagnoises (Bilgisayar Destekli teşhis)
CHLA	Children's Hospital Los Angeles (Çocuk hastanesi Los Angeles)
Conv dw	deep wise convolutional (derinlemesine evrişim işlemi)
DoG	Differatial of Gaussian (Diferansyiel Gauss yöntemi)
GP	Greulich ve Pyle
ILSVRC	Large Scale Visual Recognition Challenge
Relu	Doğrultmuş doğrusal birim (Rectified linear unit-Relu)
RUS	Radius ulna ve short bones (Radius unla ve kısa kemikler)
SGD	Stochastic Gradient Decent (SGD)- Olasılıksal Dereceli Azalma
TW1	Tanner ve Whitehouse

ŞEKİL LİSTESİ

Şekil 2.1 Sol el görüntüler 26
Şekil 2.2 Sol el görüntüler 27
Şekil 2.3 Akış şeması 28
Şekil 3.1 Mallat'ın dalgacık dönüşümü algoritmasının grafiksel benzetimi 30
Şekil 3.2 À Trous dalgacık dönüşümü algoritmasının grafiksel benzetimi 31
Şekil 3.3 İki farklı Gauss filtresi birbirinden çıkararak bant geçiren filtre elde edilmesi 34
Şekil 4.1 Bir hopfield Ağın şeması 36
Şekil 4.2 Evrişimsel işlemin gerçekleşmesi 39
Şekil 4.3 Havuzlama işleminde gerçekleşen adımlar 40
Şekil 4.4 Relu fonksiyonu 45
Şekil 4. 5 Düz ağ ile Resnet50 arasındaki hata oranı farkı. 46
Şekil 4. 6 Bir Kalıntı blok şeması (Residual Block). 47
Şekil 4.7 Resnet50 Ağının mimarisi 48
Şekil 4.8 Darboğaz yapısı olan ağ ve darboğaz yapısı olmayan ağ 49
Şekil 4.9 Resnet ağlarının farklı versiyonları. 49
Şekil 4.10 Düz ağ ve Resnet ağında katman çoğalmasının etkisi. 50
Şekil 4.11 Inception v1 ağının 1*1 evrişim işlemi eklenmemiş hali. 51
Şekil 4.12 1*1 evrişim işlemi eklenerek oluşturulan Inception evrişim katmanı. 51
Şekil 4.13 Evrişim işleminde 5*5 evrişim yerinde iki 3*3 evrişim yapılması 52
Şekil 4.14 3*3'lük evrişim işlemi 52
Şekil 4.15 İşlem maliyetini düşürmek için farklı bir ağ yapısı 53
Şekil 4.16 işlem maliyetini düşürmek için farklı bir ağ katmaı 53
Şekil 4.17 Inception v3 ağının mimarisi 55
Şekil 4.18 Yardımcı sınıflandırıcı şeması 56
Şekil 4.19 Normal evrişim işlemi 57
Şekil 4.20 Derinlemesine ayrılabilen evrişim işlemi 57
Şekil 4.21 Normal evrişim ve derinlemesine ayrılabilen evrişim işleminin farkı . 58
Şekil 5.1 Görüntüleri gereksiz bilgilerden arındırma 60
Şekil 5.2 İkili segmentasyondan birkaç örnek 61

Şekil 5.3 İkili segmentasyondan birkaç örnek (devamı) 62
Şekil 5.4 Difransiyel Gauss yöntemi ile elde edilen sonuçlar 63
Şekil 5.5 À Trous dalgacık dönüşümü yöntemi ile elde edilen sonuçlar 64
Şekil 5.6 À Trous dalgacık dönüşümü yöntemi ile elde edilen sonuçlar 65
Şekil 5.7 Canny kenar belirleme yöntemi ile elde edilen sonuçlar 66
Şekil 5.8 Canny kenar belirleme yöntemi ile elde edilen sonuçlar 67
Şekil 5.9 Elin metakarpal bölgesi ve parmak kemiklerinin bulunduğu kısım 68
Şekil 5.10 Elin karpal bölgesi kemikleri 69
Şekil 5. 11 Filtrelere göre Resnet50 ağı için elde edilen doğruluk yüzdeleri 71
Şekil 5.12 Cinsiyete göre Resnet50 ağı için elde edilen doğruluk yüzdeleri 72
Şekil 5.13 Resnet50 Ağı için filtrelerin ve cinsiyetin etkisi 72
Şekil 5.14 Cinsiyete göre Mobilnet ağı için elde edilen doğruluk yüzdeleri 73
Şekil 5.15 Filtrelere göre Mobilnet ağı için elde edilen doğruluk yüzdeleri 74
Şekil 5.16 Filtrelere göre Inception v3 ağı için elde edilen doğruluk yüzdeleri 75
Şekil 5.17 Cinsiyete göre Inception v3 ağı için elde edilen doğruluk yüzdeler 75
Şekil 5.18 Karpal ve metakarpal elde edilen doğruluk yüzdeleri 76
Şekil 5.19 Karpal ve metakarpal bölgeler için doğruluk değerlerinin farkı 77
Şekil 5.20 Eğitim ve test veri setlerinden alınan doğruluk ve kayıp yüzdeleri için örnek sonuçlar 80
Şekil 5.21 Eğitim ve test veri setlerinden alınan doğruluk ve kayıp yüzdeleri için örnek sonuçlar 81
Şekil 5.22 Eğitim ve test veri setlerinden alınan doğruluk ve kayıp yüzdeleri için örnek sonuçlar 82

TABLO LİSTESİ

Tablo 4.1 Inception ağının mimarisi 54
Tablo 4.2 Mobilnet ağının mimarisi 59
Tablo 5.1 Farklı ağların parametre sayısı 70
Tablo5.2 Resnet50 ağı için elde edilen doğruluk yüzdeleri 70
Tablo 5.3 Mobilnet ağı için elde edilen doğruluk yüzdeleri 73
Tablo 5.4 Inception v3 ağı için elde edilen doğruluk yüzdeleri 74
Tablo 5.5 Karpal ve metakarpal bölgelerin yaş tespitinde incelenmesi 76
Tablo 5.6 Resnet50 Ağı ve Inception v3 Ağı arasındaki doğruluk yüzdesi farkı 77
Tablo 5.7 Resnet50 Ağı ve Mobilnet Ağı arasındaki doğruluk yüzdesi farkı 78
Tablo 5.8 Mobilnet Ağı ile Inception v3 Ağı arasındaki doğruluk yüzdesi farkı 78

ÖZET

DERİN ÖĞRENME AĞLARI İLE RADYOLOJİK GÖRÜNTÜ ÜZERİNDEN KEMİK YAŞININ TESPİTİ

Mahdi NEZHAD ASAD

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üyesi Lale ÖZYILMAZ

Çocuk gelişimini takip etmek, hormonel problemleri anlamak ve gidermek ayrıca terapik tedaviler için yaş tespiti yapmak çok önemlidir. Kemik yaşı ve kronolojik yaş arasında fark olması bir problemin olduğunu göstermektedir. Bu tez çalışmasında yaş tespiti gerçekleştirmek için evrişimsel sinir ağları ve görüntü işleme teknikleri kullanıldı. 7.9 ay hata payı ile yaşları sınıflandırılarak elde edilen sonuçlarla %88 doğruluğa ulaşıldı. Ayrıca ön işlemede Canny filtresi, Diferansiyel Gauss ve À Trous dalgacık kenar belirleme yöntemleri kullanılarak elde edilen doğruluk değerlerinde ortalama %10-15 artış sağlandı.

Kenar bulma filtresi uygulandığında doğruluk oranında artışlar görüldü. Maksimum artışlardan bir tanesi %18,82 değeri ile Resnet50 ağında DoG filtresi uygulaması ve ham görüntü arasındaki fark olarak ortaya çıktı. Doğruluk değerlerindeki değişiklik verinin ve kenar bulma yöntemlerinin farklı olmasından bununla beraber evrişim ağının yapısından kaynaklanmaktadır. Bazı durumlarda doğruluk oranı ile gürültü oranının ilişkisi olduğunu düşünülebilir. Burada kenar bulma yöntemlerinden biri olan A`Trous alt geçiren filtre en yüksek gürültüye sahiptir dolayısıyla daha yüksek

gürültü sonucu daha düşük doğruluk ile sonuç vermektedir. Diferansiyel Gauss ve Canny filtresi A` Trous'a göre daha az gürültü göstermektedir bu nedenle bazı durumlarda doğruluk oranı yüksek çıkmaktadır. Aynı veri seti için üç farklı evrişim ağı (Mobilnet-Inceptionv3-Resnet50) kullanıldı. Bu ağların mimarileri ve evrişim (konvolüsyon) işlemi farklı olduğu için farklı sonuçlar ortaya çıktı. Çalışmada yapılan diğer bir analiz ise elin karpal ve metakarpal bölgelerini ayrı ayrı değerlendirerek evrişim ağında elin hangi bölgesi yüksek bir doğruluk verdiği incelendi. Böylece hangi bölge yaş tespiti üzerine daha etkili olduğu ortaya konuldu. Elde edilen maksimum doğruluk değerlerinden bir tanesi kadın veri setinde Mobilnet ağı kullanılarak %92 olarak bulundu. Karpal ve metakarpal bölgeler arasındaki en büyük fark aynı kadın veri setinde Mobilnet üzerinde %24 değerinde ortaya çıktı.

Sonuç olarak bu çalışmada ön filtreleme işlemleri ve ikili segmentasyon yönteminin evrişim sinir ağlarının sonuçlarına büyük bir katkı sağladığı görünmektedir.

Anahtar Kelimeler: Derin öğrenme , Evrişimsel sinir ağlar, Kemik yaşı tespiti, A` Trous dalgacık dönüşümü, yapay sinir ağları, Diferansiyel Gauss yöntemi (DoG), Canny kenar algılama

ABSTRACT

BONE AGE ASSESSMENT WITH DEEP LEARNING, FROM RADIOLOGIC IMAGES

Mahdi NEZHAD ASAD

Department of Electronics and Communication

Master Thesis

Advisor: Dr.Lale ÖZYILMAZ

Radiographic image assessment is one of the most common methods to monitor physical conditions and diagnose disorders in the growth process. There are various methods for bone age assessment, such as Tanner-Whitehouse [TW], Greulich and Pyle (G&P) methods, In this theses, it is applied different convolutional neural networks (Resnet50, Mobilnet v1, Inceptionv3) for bone age assessment, additionally we compared different convolutional neural networks with different preprocessing based on edge detection (Canny edge detection, Differential Gaussian filters (DoG), À Trous wavelet low pass filter) , the result of CNN in filtered images exhibits a noticeable improvement compared to the result of non-filtered images. The ages between 0 and 7 are analyzed within 7.9 months with different categorical assessment of female, male, and female-male. It is observed that there is 18,86% improvement between filtered images and non-filtered images. The proposed method reached 88% for female dataset.

In this thesis we analyzed effect of different part of hand for bone age assessment, first we cropped carpal and metacarpal parts of hand then by classification with different three convolutional neural networks (Mobilnet, Inceptionv3, and Resnet50). It is obvious, which carpal section has a huge effect on bone age assessment, the output difference between carpal and metacarpal in the same

dataset has %24 percentage and it shows that through bone age assessment carpal parts of hand has more effect than metacarpal section.

Keywords: Deep learning, Convolutional neural network, Bone age assessment, A` Trous wavelets, neural networks, Difference of Gaussians, Canny edge detection, Resnet50, İnceptionv3, Mobilnet

1

Giriş

1.1 Literatür özeti

1.1.1 Kemik yaşı tespiti yöntemleri

Kemik yaşının belirlenmesi iki şekilde yapılmaktadır. Birinci durumda kemikte değişim gösteren bölgeler izlenir, ikinci durumda ise kemikte kalsiyum düzeyine bakılır.Bebeklik yaşlarından olgunluk yaşlarına kadar bu iki faktör kemikte belli bölgelerde dikkate alınmaktadır[1]. Genel bir olgunluk modeli bulunmasa da, genetik, beslenme, metabolik, sosyal ve duygusal etkenler, tiroksin, büyüme hormonları kemik gelişiminde önemli rol oynamaktadır. Yaşın belirlenebilmesi için pediatrik radyoloji çok yaygın olan bir yöntemdir. Özellikle çok kısa ve çok uzun boylu olan insanlar üzerinde uygulanmaktadır. Aynı zamanda kemik yaşı belirlenmesi büyüme problemi olan çocuklarda ve endokrinopatilerde önem taşımaktadır [2]. Kemik yaşı ve kronolojik yaş olmak üzere iki çeşit yaş tanımlanabilir. Kemik yaşı ölçümü çocuğun olgunluğunu gösteren bir kriter olarak kabul edilmektedir [3]. İnsanlarda kemik gelişimi birbirine benzemektedir, çünkü her kemiğin gelişim süreci sürekliliğe sahiptir ve benzer aşamalardan geçmektedir. Dolayısıyla kemiklerin belirli özellikleri bulunmaktadır. Bu nedenle kemik yaşı ve kronolojik yaşın belirlenmesi çocuk gelişimi düzeyi için kullanılabilmektedir. Bununla birlikte aynı kronolojik yaşta olan insanların farklı kemik yaşlarına sahip olması mümkündür. Ayrıca gelişme zamanı, miktarı ve oranı insandan insana değişim gösterebilmektedir. Büyüme süresi ve büyüme miktarı pubertal dönemde önemli ölçüde değişir [4]. Bazı bireyler nispeten kısa pubertal büyüme ile erken olgunlaşırlar, bazıları da daha uzun bir pubertal büyüme ile geç olgunlaşırlar.

1.1.2 Kemik gelişimi ve olgunlaşması

El ve bilek yapısı kısa kemikler ve uzun kemikler olmak üzere ikiye ayrılır. Uzun kemikler radius, ulna, ve falanks kemikleri olarak adlandırılır. Uzun kemikler birden fazla merkezde kemikleşebilmektedirler, örneğin çocukluk döneminde, kemik uçları (epifiz plakları) kemiğin şaftı (diafiz) ile kaynayana kadar bu kemikler büyümektedirler. Plakların içindeki hücrelerin çoğalmasına ve değişimine birçok faktör etki etmektedir aynı zamanda plağın büyümesi metafiz ile etkileşmektedir. Örneğin tiroid hormonunun eksik kalması hücrelerin çoğalmasına engel olabilmekte bu da çocuk gelişiminin önüne geçmektedir [5]. Bazen kemikleşme hemen doğumdan sonra gerçekleşmektedir bazen de 14-17 yaşına kadar devam etmektedir[6]. Kadınların kemikleri erkeklere göre daha çabuk olgunlaşmaktadır. İskelet olgunlaşma süreci, erkeklerde kızlara göre daha uzun sürmektedir ancak iskelet olgunluğundaki cinsiyet farklılık sebebi bilinmemektedir [3]. Epifiz kıkırdağının kapanması 10-25 yaş aralığında gerçekleşmektedir. Kızlarda kemikleşme erkeklere göre iki sene daha hızlı gerçekleşmektedir. Kısa kemiklerde dominant eksen gözükmemektedir ve uzun kemiklerden daha farklı gelişmektedirler. Uzun kemiklerde karpal bölgedeki gelişimler kemiğin şekline göre farklılık ve beklenmedik dağılımlar gösterebilir. Karpal kemikler doğumdan hemen sonra şekil almaya başlar ve kapitat kemiğinin olgunlaşması 2-4 ay içerisinde belli olur. Pisiform kemik için ise 9-12 sene arasında kemikleşme süreci değişiklik göstermektedir.

Pediatrik endokrinologlar, kemik gelişimini ve çocukların fiziksel gelişimini x-ray görüntüler üzerinden değerlendiren doktorlardır [7]. Vücudun farklı kısımlarındaki (el, ayak, diz, dirsek, omuz ve kalça) kemik yaşını daha yüksek doğruluk ile tespit etmek için araştırmalar yapılmaktadır. El ve el bileği çok farklı kemik yapısına sahip olduğu için olgunluk seviyelerindeki ilerlemeler zaman içinde daha rahat fark edilebilmektedir. Hastanın klinik olgunluk bilgileri belirli bir zaman içerisinde başka klinik bilgiler ile entegre edildiği zaman normal olan yaşı veya olmayanı ayırt edebilmek mümkün olmaktadır [8, 9]. Todd ilk kez atlas veri setlerini kullanarak 6 aylık aralıklarla el kemiğin olgunluğunu ve her yaşın özelliklerini belirtti [10]. Şu an hali hazırda kemik yaşı tespiti için yapılan radyolojik incelemede Greulich ve Pyle

(GP) ve Tanner and Whitehouse (TW2, TW3) en çok kullanılan yöntemlerdir. Bu yöntemlerde sol elin radyolojik görüntüleri kullanılmaktadır.

1.1.3 Greulich ve Pyle Yöntemi

Bu yöntem Greulich ve Pyle (GP) tarafından önerilmiştir. GP atlası 1931-1942 senelerinde Amerika'da beyaz ve orta-üst sınıf erkek ve kız çocuklarından el ve bilek radyolojik görüntülerin toplanması ile oluşturulmuştur ve bu nedenle bu yöntem daha çok Amerika'da kullanılmaktadır. Standart bir şablon 31 adet radyolojik fotoğraftan oluşmaktadır. Bu radyoloji görüntüleri 0 ile 19 yaş arasındaki bireylerden alınmıştır. Kız çocuklara yönelik standart şablonlar, 0-18 yaş arasındaki büyüme evrelerini kapsayan 27 radyoloji görüntüsünden oluşmaktadır [11]. Şablon serisinin kadın ve erkek çocuklar için ayrı ayrı geliştirilmesinin nedeni, kemik büyümesinin ve gelişiminin cinsiyete bağlı olarak farklılıklar göstermesidir. Bu şablon serisindeki görüntüler daha sonra değerlendirilen farklı radyolojik görüntüler ile karşılaştırılmaktadır. Karşılaştırmalar, daha önce değerlendirilmiş durumlar ile yapılır ve en yakın olanı seçilir. %100'lük bir eşleşme bulmak genellikle zordur. Bu gibi durumlarda, en yakın eşleşen radyolojik şablon seçilir ve yaş belli olur.

1.1.4 Tanner-Whitehouse yöntemi

Tanner-Whitehouse (TW) yönteminde kemikler bir yapı analizine tabi tutulmakta ve bu kemik analizinde kemik yapısı incelenerek puanlar toplanmaktadır. Analize tabi tutulan kemikler radius, ulna, kısa kemikler ve karpal kemiklerdir. Bu analiz içerisinde erkek ve kadın farklı şekilde değerlendirilmektedir ve her aşama farklı bilgileri içermektedir. Geliştirilen bu ilk yöntem TW1 olarak adlandırılmaktadır. Sonra TW2 ve TW3 yöntemleri geliştirilmiştir [12]. TW2'de kemik yaşı tespiti için el ve el bilek kemiği toplam 8 ana kemik olarak incelenmektedir ve ulna kemiği ile beraber 9 kemik olarak değerlendirme yapılmaktadır. Bu değerlendirmeyi yapmak için standartlaşmış kemik değerlendirmesi 1950 ve 1960'larda yapılmıştır. Bazı görüşlere göre kemik olgunlaşması 50 sene önceye göre daha hızlı bir şekilde gerçekleşmektedir. Dolayısıyla bu yöntem, kemik yaşını yüksek doğrulukta tespit etmek için modifiye edilmiştir. Bu metodun modifiyesi ile TW3 ortaya çıkmıştır. Farklı ülkelerde el kemiğini puanlanmak için (Belçika, İtalya, Arjantin, isveç, Japonya

ve Birleşmiş Milletler tarafından) güncellemeler yapılmıştır [13-17]. 10-12 yaşları arasında TW3'e göre ölçüler TW2'den bir sene fark göstermektedir, ancak erken yaşlarda daha az fark görünmektedir. TW3 yöntemi Greulich ve Pyle (GP) yöntemine göre daha erken yaşlara kadar tespit yapabilmektedir yani erkeklerde 16.25 (16 yaş ve üç ay)ve kızlarda 15 yaşına kadar tespit etmektedir ancak GP yöntemi 18 -19 yaşlarına kadar tespit yapabilmektedir. TW metodu Amerika'da geliştirilmiştir ve Avrupa'da kullanılmaya devam etmektedir. Ancak GP yönteminin kullanımı dünyada %76'nın üzerindedir.

1.1.5 Gözlemci ve gözlemciler arası değişkenlik

Atlas, el radyoloji datalarını toplayan bir veri setidir. Burada, veri setlerini kullanarak davranmak ve hareket etmek tamamen subjektiftir, görüntüler üzerine yorum yapmak gözlemciden gözlemciye göre değişebilmektedir ve yüzde yüz bir eşleşme bulmak çok zordur. Gözlemcinin ölçüm değişkenliği ve güvenilirliği bireyin iki zaman dilimi arasındaki stabilliğini ifade etmektedir. Gözlemciler arası değişkenlik ise, değerlendirme yapan iki veya daha fazla kişi arasındaki anlaşma ve stabilliktir. Her ikisi de kemik yaşı tespiti için çok önemlidir. Gözlemciler arası değişkenlik kemik yaşı tespitinin doğruluğu ve tekrarlanabilirliğinde bir azalmaya yol açmaktadır. Gözlemciler tarafından yapılan TW2 yaş tespiti yöntemi takip edilmesi daha uygun bir yöntemdir [18]. Hem GP hem de TW yöntemleri farklı gözlemciler tarafından ve subjektif bir analiz gördükleri için bir tutarsızlık göstermektedirler. Gözlemci için değişken ortalama TW2 için 0.74 yıl ve GP için 0.96 yıldır [19, 20]. GP yönteminde TW yönteminden daha çok değişkenlik olduğu görülmektedir. Aynı zamanda GP yöntemi yayınlandığından beri herhangi bir değişiklik olmamıştır. Bu konu ile uğraşan bazı bilim adamları GP yöntemin bugünkü çocukların kemik yapılarına uyumlu bir şekilde olması için değişmesi gerektiğini düşünmektedirler, özellikle klinik kararların verilmesi aşamasında siyahi, hispanik ve asyalı erkekler için daha doğru karar verilmesi önem arz etmektedir [21]. Bu model Amerika'da 1980'dan sonra doğu Avrupa ve Afrika kökenli çocukların üzerinde denenmiştir fakat bu yöntemin yetersiz olduğu sonucuna varılmıştır. Klinik kararlar vermek için yeni standartların daha yüksek

doğruluk sağlaması ve daha çok etnik kökeni kapsayacak şekilde olması gerekmektedir [3].

GP ve RUS-TW2 RUS-TW3 yöntemlerinin karşılaştırıldığı bir çalışmaya göre 171 adet x-ray görüntüsünde 12-20 yaşlarında olan Danimarkalı gençler ve karışık etnik kökenden olan mültecilerde tüm yöntemler denendi ve sonuçların içinde Fels yöntemi kızlar için en yüksek doğruluk değerini, RUS-TW2 yöntemi de erkekler için en yüksek doğruluk değerini verdi. Bu sonuçlardan yola çıkarak kemik yaşının belirlenmesi için farklı yöntemlerin denenmesi gerektiği sonucuna varıldı [22]. Hormon Araştırma Derneği 2000 yılında kemik yaşının tespiti için ve büyüme problemi olan çocuklar için daha uygun yöntemler olduğunu belirtmiştir [23]. Fakat bu ölçümlerin kabul edilebilir ve tekrarlanabilir olması için deneyimli bir kişi tarafından yapılması gerekmektedir. Bununla birlikte gözlemcilerin, kronolojik yaşın bilinmediği zamanlarda radyografiyi normal olarak yorumlama olasılığı daha yüksektir. Genelde tek yaş tespiti ölçümü gerektiği durumda 0.5 yıllık bir toleransın kabul edileceği öne sürülmüştür.Kronolojik yaşın bilinmesinin kemik yaşı tespiti üzerinde herhangi bir etkisi bulunmamaktadır. Ancak kronolojik yaşın bilinmesi gözlemcilerin görüntüler üzerinden daha doğru bir yorum yapmasını sağlar [24]. Herhangi bir hastada yaş tespitinde 0.5 yıllık bir tolerans olmalıdır.

1.1.6 Bilgisayar destekli kemik yaşı tespiti

Pietka tarafından kemik yaşı tespiti için bilgisayar yardımı alarak insan faktörünü aradan kaldırma fikri önerildi. Bilgisayar ile kemik yaşı tespitinin avantajlarından biri radyoloğun zamandan tasarrufunu sağlamaktır. Bu yöntemde falanks kemiklerinin uzunluğu atlas veri setinde ölçülen uzunlukla karşılaştırlır ve eşleşmesi durumlarında kişinin yaşının tespiti gerçekleştirilir [25]. Görüntü dijitalleştirilerek ve bir takım matematiksel işlemler yapılarak dijital ortamda gösterilmektedir. Kemik yaşı tespiti genellikle sol el ve bilekten alınan xray görüntüsü ile yapılmaktadır. Yıllarca ve defalarca yapılan çalışmalardan sonra kemik üzerinden yaş tespiti otomatikleşmiştir. Bu analiz birkaç ön çalışma ile başlamıştır. İlk önce görüntü yatay ve dikey eksende düzgün hale getirilmiştir. Sonra istenmeyen arka plan silinip gerçek kemik yapısı ön plana çıkarılmıştır dolayısıyla istenilen kemik bölgesi ortaya çıkmaya başlamıştır. Bir sonraki aşama ise istenilen

kemik bölgesinin (Region of interest-ROI) özelliklerini çıkartmaya başlamaktır. Daha sonra her bir kemik için bir takım görüntü işleme teknikleri kullanılarak analizler yapılır [26].

Fakat bu işlemi gerçekleştirmek kolay olmadığı için literatürde var olan algoritmalar belirli bölgeyi çıkartmakta zorluk çekmişlerdir. Aynı zamanda görüntü işleme tekniğinde olan eksiklik, kemik yaşı değerlendirmesinin daha düşük doğrulukla sonuçlanmasına neden olmuştur. Bu nedenle geçerli otomatik sistemler yetersiz kalmıştır [27, 28]. Daha sonra Bone Expert adında klinik amaçlı otomatik bir kemik yaşı tespiti yöntemi geliştirilmiştir ve 2008 tarihinde piyasaya sürülmüştür. Bone Expert yöntemi üç aşamadan oluşmuştur. Birinci aşama eldeki 15 kemiğin sınır bölgelerini tanımlar. İkinci aşama eldeki 15 kemikten doğruluk oranı yüksek olan 13 kemiğin olgunluğunu tespit eder. Kemiklerin yaş tespiti sırasında tespit değeri tüm kemiklerin ortalamasından 2,4 yıldan daha fazla saparsa sonuç kabul edilemez. Üçüncü aşamada ise hesaplanan kemik yaşı GP yöntemi ile değerlendirilmek üzere bilgisayara gönderilir. Bu yöntemde elin karpal bölgesi dikkate alınmamaktadır. Ayrıca bu yöntem hem erkeklerde hem de kızlarda kullanılabilmektedir. Erkekler için yaş tespiti 2,5 ile 17 yaş aralığında olup kızlar için ise 2 ile 15 yaş aralığındadır. Bone Expert daha çok Avrupa'da kullanılmaktadır ve bu metodun doğruluk oranı %71-%72 arasında olup, hassasiyeti de 0,17-0,18 yıldır [28]. Aynı zamanda bu uygulama farklı etnik kökenden olan kişilerin endokrin hastalıklarının tespitinde de kullanılabilmektedir. Bu yöntem her bir görüntünün değerlendirilmesini 1,5 dakika ile 4 dakika arasında yapmaktadır. Eğer görüntüde yatay düzleme göre açı yoksa çevirme ve döndürme yani açı değiştirme işlemine gerek kalmayacaktır. Fakat orijinal görüntüde el bilek rotasyonu varsa veya el ve önkol arası bir açı oluşmuşsa sonucuna varmak çok zaman gerektirecektir. Görüntü kalitesi kötü olup, kontrast ve parlaklığı düşük olan görüntüler için bu yöntem çalışmamaktadır [28]. Otomatik kemik tespitinin yapılması radyolog ve pediatristlerin yaş tespiti yapmalarını tamamen ortadan kaldırmamaktadır. Bazı hastalıklar doğrudan görüntü üzerinden okunmaktadır. Bunlara örnek olarak kondrogenez ve / veya osteogenez kusurları (hipokondroplazi) ulnada yıpranmışlık, metakarpal kemik kısalığı, distal radial epifizin üçgen şekline dönüşmesi verilmektedir [29, 30].

1.1.7 Fels yöntemi

Fels yöntemi Roche tarafından objektif kemik yaşı belirlenmesi için geliştirilmiştir. Kuzey Amerika'daki çocuklardan toplanan veriler ile kemik uzunlukları üzerine araştırmalar yapılmıştır. Bu veriler 322 kız ve 355 erkekten 1928 ile 1974 yıllarında toplanmıştır. Veri seti 1 ay ile 22 yaş aralığında olan kişilerin sol ellerinden alınan x-ray cihazı görüntülerini içermektedir. Çocukların ellerinden alınmış olan x-ray görüntülerinden hem el olgunlaşması düzeyi hem de el bileğinin epifiz ve diyafizi ölçülerek yaş oranları belirlenmektedir. Fels yöntemi ile puanlandırma yapılmaktadır. Hesaplanan puanlar kemik yaşının belirlenmesinde bir bilgisayar programına girilerek tespit işlemi tamamlanır [31, 32].

1.2 Tezin Amacı

İnsan kemik yaşının belirlenmesinin başlıca kullanım alanları arasında spor, kimliği belli olmayan kişilerin (örneğin cesetlerin) yaş tespiti veya çocuk gelişimini takip etmek sayılabilir. Kemik yaşı tespiti ve takip edilmesi pratik, pediatrik ve endokronolijik durumlarda hayati öneme sahiptir. Kemik yaşı tespiti için radyolojik x-ray el görüntüleri kullanılmaktadır ve bu problemi çözmek için manual ve bilgisayar destekli algoritmalar, yarı otomatik ve tam otomatik yöntemler bulunmaktadır. Bu tez çalışmasında görüntü işleme yöntemleri, derin öğrenme mimarileri yardımı ile tam otomatik bir kemik yaşı tespiti yapılması amaçlanmıştır. Bu tez içerisinde farklı kenar bulma yöntemleri (Canny algoritması, À Trous wavelet ve diferansiyel Gauss) yardımı ile farklı derin öğrenme mimarileri (Mobilnet, resnet50 ve İnception v3) kullanarak yaş tespiti yapmak hedeflenmektedir. Bütün el görüntüsünün yanısıra sadece elin belli bölgeleri örneğin karpal, meta karpal ve flanks bölgeleri üzerinde analizler yapılmıştır. Bu tezin amacı farklı ön işleme yöntemleri ile farklı evrişimsel ağların kombinasyonunu kullanarak daha yüksek doğruluğa ulaşmaktır.

1.3 Hipotez

Endokrin problemi olan çocuklar için ve çocuk gelişimini takip etmek için kemik yaşı tespiti yapılmaktadır. Evrişimsel sinir ağları ile kemik yaşı tespiti çok daha kolay olmaktadır. Farklı filtreler ön işleme için kullanılarak evrişimsel ağların daha yüksek

doğruluklara ulaştığı varsayımı yapılmaktadır. Aynı zamanda karpal bölgesinin kemikleri farklı yapılarda olduğundan evrişimsel ağların yaş tespitinde daha yüksek doğruluk verdiği düşünülmektedir. Genel olarak, görüntüde özellik haritalarının belirgin olması evrişim ağlarının sınıflandırma yapmasını kolaylaştırmaktadır.

2

Tam Otomatik Kemik Yaşı Tespit Yöntemi ve Ön İşleme

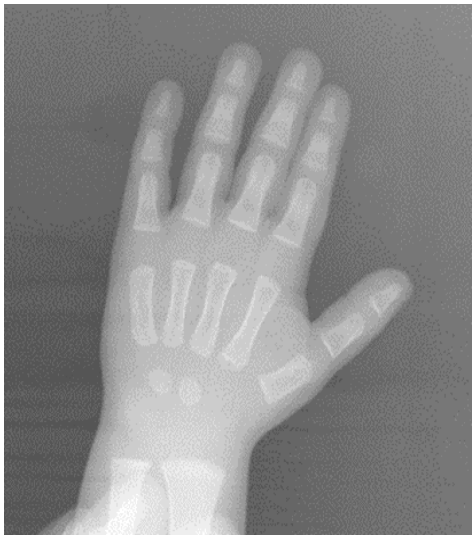
2.1 Veri seti

Kemik yaşı tespiti genel olarak pediatrik radyolojide bir kemiğin hangi aşamada olduğunu ve ne kadar olgun olduğunu saptamak için önem taşır. Kemik yaşı tespiti sol ele ait x-ray görüntüleri incelenerek yapılmaktadır. Kronolojik yaş ve kemik yaşının arasındaki farklar bir sağlık sorunu olduğunu göstermektedir. Kemik yaşı tespiti endokrin problemi olan insanların durumunu ve aynı zamanda çocuk gelişimini takip etmeye yardımcı olmaktadır. En çok kullanılan yöntemlerden bir tanesi olan Grulich ve Pyle (G&P) 1950'lerden beri Atlas radyolojik veri seti ile birlikte uygulanmaya başlanmıştır. Bu veri seti kız-erkek normal çocuklardan ve Asya, Afrika, Amerikan, Kafkasya ve hispanik ırklarından Los Angeles çocuk hastanesi tarafından (Children's Hospital Los Angeles - CHLA) toplanmıştır, 1400 adet radyolojik el görüntüsünden oluşmaktadır. Veri seti Bilgisayar Destekli Teşhis (Computer Aided Diagnoises - CAD) kullanılarak iki cinsiyet ve dört ırk üzerinde denenmiştir. Dijital El Atlası (Digital Hand Atlas - DHA) ve CAD yöntemleri kemik yaşının belirlenmesi için önemli rol oynamaktadır. Atlas radyolojik veri setinde 19 adet yaş grubu oluşturulmuştur. Bu gruplar içerisinde alt kategoriler bulunmaktadır. Yeni doğmuş bebek, (1-18) yaş aralığında olan çocuklar ve 8 kategoriden oluşan (örneğin: Kafkas, Afrikalı-Amerikalı, İspanyol ve Asyalı) erkek ve kadın olarak farklı alt kategorilerde toplanmıştır. Bu veriler Los Angeles County Kadın ve Çocuk Hastanesinde çocuk radyoloji şefi olan Dr. Linda Vachon ile işbirliği yapılarak elde edilmiştir [33].

İkili segmentasyon yapılmamış veri için 0-7 yaş arasındaki çocuk ellerinden alınan örnekler aşağıda gösterilmiştir .



Yeni doğan bebek x-ray görüntüsü



1 yaşındaki bir çocuğun x-ray sol el görüntüsü

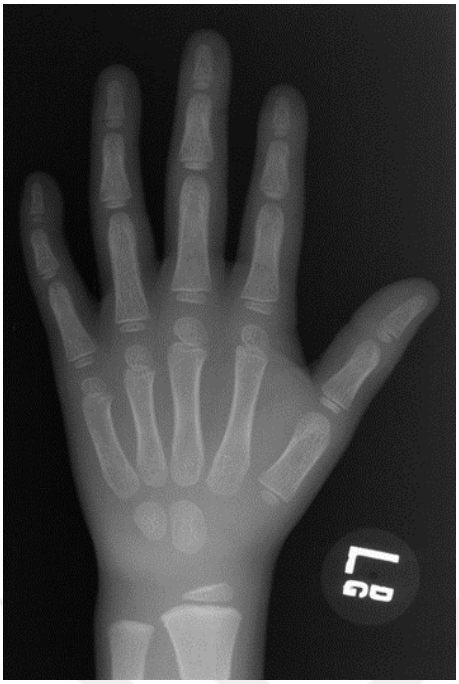


2 yaşındaki bir çocuğun x-ray el görüntüsü

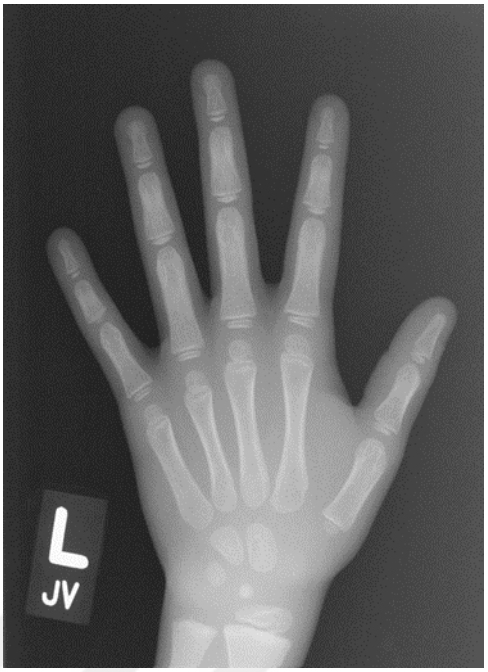


3 yaşındaki bir çocuğun x-ray el görüntüsü

Şekil 2.1 Sol el görüntüler



4 yaşındaki bir çocuğun x-ray el görüntüsü



5 yaşındaki bir çocuğun x-ray el görüntüsü



6 yaşındaki bir çocuğun x-ray el görüntüsü

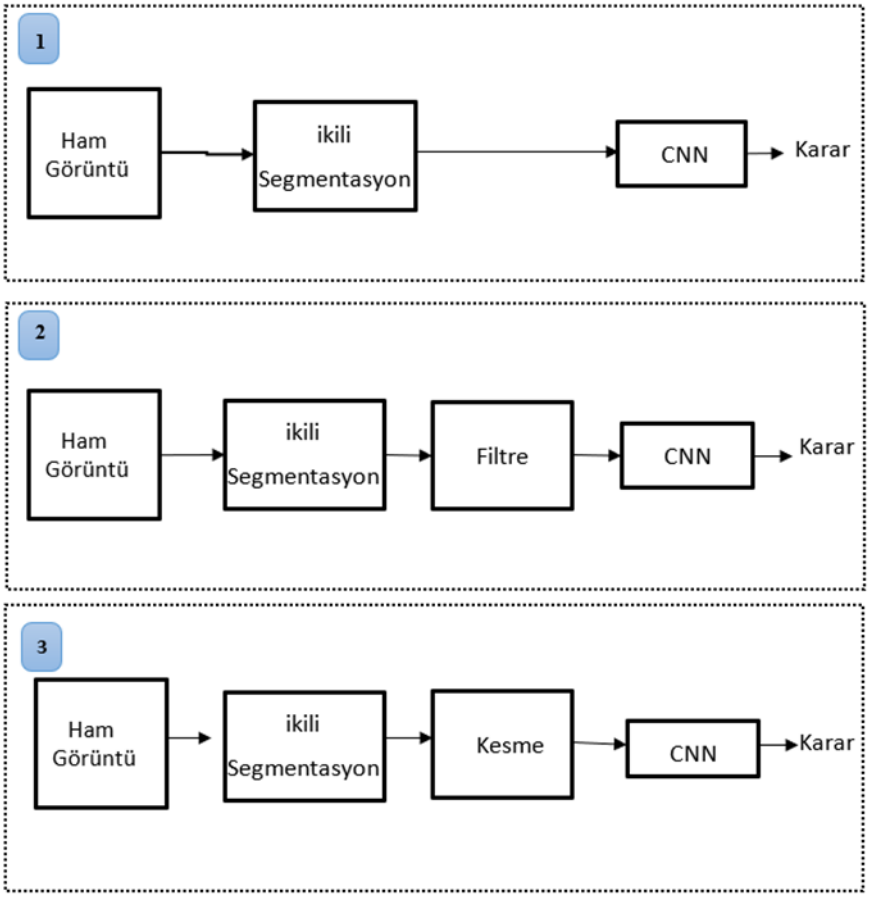


7 yaşındaki bir çocuğun x-ray el görüntüsü

Şekil 2.2 Sol el görüntüler (devamı)

2.2 Tam otomatik kemik yaşı tespit yöntemi ve ön işleme

Önerilen yöntem Şekil 2.3'de şematize edilmektedir. X-ray görüntülerinin değerlendirme sonuçlarını etkileyecek gereksiz bilgilerden kurtulmak için ikili segmentasyon yöntemi kullanılır. Sonuçlar kısmında ikili segmentasyon örnekleri eklenmiştir. Elin histogramına bakılarak, eşik değerinin tanımlanmasıyla yalnızca elin görüntüsü bırakılmakta sonuç olarak tespiti olumsuz etkileyecek gereksiz bilgiler ortamdan kaldırılmaktadır. Sonraki aşamada aşağıda açıklanan filtre yöntemleri ayrı ayrı kullanılarak el kemiklerinin açığa çıkması sağlanmaktadır.



Şekil 2.3 Akış şeması

Şekil 2.3'deki bir numaralı akış diyagramında ham x-ray görüntüsü doğrudan derin öğrenme ağına gönderilip eğitilmektedir. İki numaralı diyagramda ise ham görüntü ikili segmentasyon yöntemine tabi tutulmaktadır. Bu işlemde görüntülerin histogram eğrisi incelenerek yalnızca el görüntüsünü meydana çıkaracak diğer gereksiz bilgileri ortadan kaldıracak bir eşik değeri belirlenir. Gereksiz bilgilerden

arındırılan görüntüye filtre işlemi uygulanır. Buradaki amaç, el üzerindeki kemikleri meydana çıkarmak ve böylece daha iyi bir değerlendirme yapabilmektir. Elde edilen son görüntüler Konvolüsyonel Sinir Ağları (CNN) vasıtasıyla eğitilmektedir. Üç numaralı diyagramda ise ikinci diyagramda olduğu gibi ham görüntü ikili segmentasyon yöntemine tabi tutulur. Görüntülerin aynı şekilde histogram eğrisine bakılarak yalnızca el görüntüsünü meydana çıkacak şekilde diğer gereksiz bilgiler ortadan kaldırılır, bir eşik değeri belirlenir. El görüntüsündeki karpal ve metakarpal bölgeler kesilerek ayrı ayrı CNN'e gönderilir burada her bir görüntünün etkisi ve doğruluk yüzdesi incelenir.

3

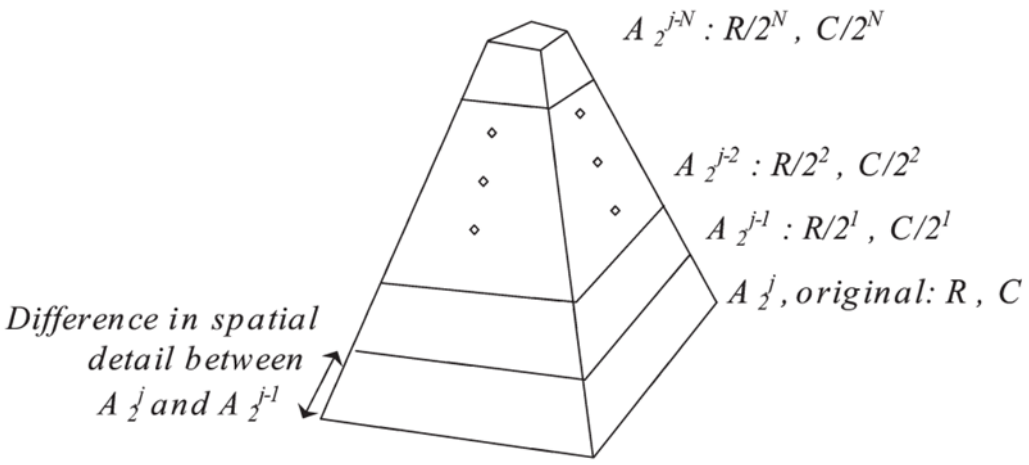
Filtre Yöntemleri

3.1 Filtre yöntemleri

X-Ray görüntülerinde eldeki kemikleri açığa çıkarmak için üç farklı filtre yöntemi kullanılmıştır. Bunlarla ilgi detaylı bilgiler aşağıda açıklanmaktadır.

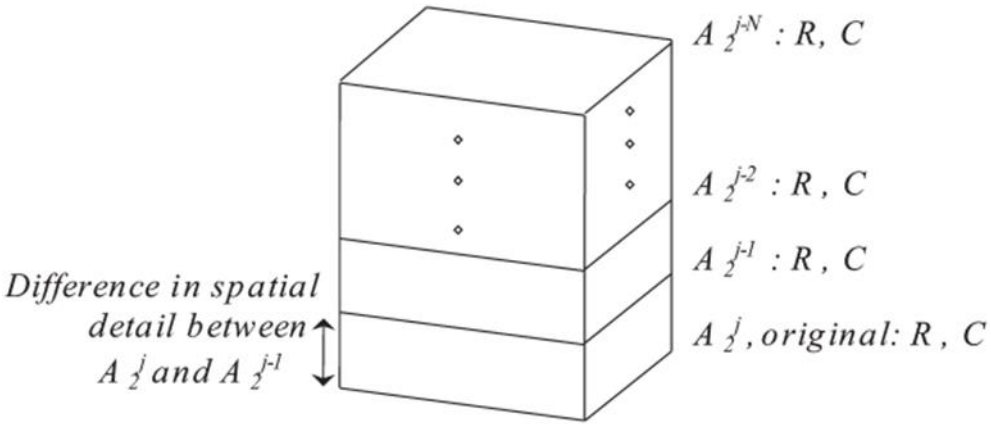
3.1.1 À Trous dalgacık dönüşümü yöntemi

À Trous dalgacık dönüşümünün temelini Mallat (1989)'ın dalgacık dönüşüm yöntemi oluşturmaktadır. Bu klasik dalgacık dönüşüm yöntemi öteleme ile değişen (shift-variant) bir yöntem olduğu için bir görüntünün dalgacık dönüşümü ile o görüntünün ötelenmiş biçiminin dalgacık dönüşümü indirgeme işlemi sebebiyle farklı olmaktadır. Mallat'ın yöntemi Şekil 3.1'deki gibi bir piramit yapısıyla ifade edilebilir[34].



Şekil 3.1 Mallat'ın dalgacık dönüşümü algoritmasının grafiksel benzetimi [35].

À Trous dalgacık dönüşümü de Şekil 3.2'deki gibi şematize edilebilir



Şekil 3.2 À Trous dalgacık dönüşümü algoritmasının grafiksel benzetimi[35] .

$C_0(x,y)$ orjinal görüntüyü temsil etmekte, $C_j(x,y)$ ise görüntünün J'deki ayrışma seviyesinin yaklaşık görüntüsünü temsil etmektedir.

$$C_{j+1}(x,y) = C_j(x,y) * H_j \tag{3.1}$$

$$W_{j+1} = C_j(x,y) - C_{j+1}(x,y) \tag{3.2}$$

W_{j+1} dalgacığın genliği olarak tanımlanır, H_0 ise iki bantlı alçak geçiren filtre olarak tanımlanır. Bu da $\delta(k)$ dirak fonksiyonu olduğu yerde À Trousun $H_{2k} = {\delta(k)}/{\sqrt{2}}$, koşulunu karşılamaktadır. H_j seviyesindeki alçak geçiren filtrenin $2^{j-1}-1$ katsayıları arasına sıfır ekleyerek j seviyesindeki dekopmpoziyon örnekleme yapılır. H_0 formülü bir boyutlu B3-spline'dan $B3 = ({}^{1}/_{16})[1,4,6,4,1]$ gelmektedir .

$$H_0 = \frac{1}{256}\begin{bmatrix} 1 & 4 & 6 & 4 & 1 \\ 4 & 16 & 24 & 16 & 4 \\ 6 & 24 & 36 & 24 & 6 \\ 4 & 16 & 24 & 16 & 4 \\ 1 & 4 & 6 & 4 & 1 \end{bmatrix} \tag{3.3}$$

$$H_1 = \frac{1}{256}\begin{bmatrix} 1 & 0 & 4 & 0 & 6 & 0 & 4 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 4 & 0 & 16 & 0 & 24 & 0 & 16 & 0 & 4 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 6 & 0 & 24 & 0 & 36 & 0 & 24 & 0 & 6 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 4 & 0 & 16 & 0 & 24 & 0 & 16 & 0 & 4 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 4 & 0 & 6 & 0 & 4 & 0 & 1 \end{bmatrix} \tag{3.2}$$

Orjinal ilk görüntü $C_0(x,y)$, son görüntü $C_p(x,y)$ ile dalgacık düzlemleri yaklaşık değerinin toplamına eşittir.

$$C_0(x,y) = C_p(x,y) + \sum_{\forall j} w_j \tag{3.5}$$

Matematiksel ifade tanımılanır[34].

3.1.2 Canny kenar algılama yöntemi

Son yıllarda birçok kenar bulma yöntemi ortaya çıkmıştır. Bunlardan bazıları Sobel, Canny, Prewitt, Robert, Laplacian gibi dijital diferansiyele dayanan yöntemlerdir. Canny kenar algılama yöntemi kenarlardan ve yapıdan bilgi alınmasına yardım etmektedir. Obje tanıma gibi birçok yerde kullanılan bu yöntem birkaç aşamadan oluşmaktadır. Bu aşamalar aşağıda sıra ile açıklanmaktadır.

1. İlk görüntü renkli halden (Red-Green- Blue RGB) griye dönüştürülür.
2. Görüntüde istenmeyen ve Canny yöntemi ile kenar şeklinde algılanabilecek gürültüler olabilir. Bu gürültüleri ortadan kaldırmak için Gauss filtresi uygulanmaktadır. Gauss filtresinin denklemi aşağıdaki şekilde yazılmaktadır.

$$G = \frac{1}{2\pi\sigma^2}\, e^{\frac{x^2+y^2}{2\sigma^2}} \tag{3.6}$$

3. Görüntünün kenarlarını bulmak için yoğunluğu ve yoğunluğun yönünü bilmek gerekir. Dolayısıyla piksel yoğunluğunu bulmak için görüntünün yatay ve düşey olarak gradyanı hesaplanmaktadır. Bunun için Sobel filtresi yatay ve düşey şekilde kullanılır. Sobel filtresini I görüntüsü ile konvolüsyon işleminine tabi tuttuktan sonra I_x ve I_y olarak görüntüler elde edilir. Gradyanın büyüklüğü I_y ve I_x ile, yönü ise açı ile hesaplanmaktadır.

$$K_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & 0 & -1 \end{bmatrix} \tag{3.7}$$

$$K_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \tag{3.8}$$

$$|G| = \sqrt[2]{I_x^2 + I_y^2} \tag{3.9}$$

$$\theta(x,y) = arctan(\frac{I_x}{I_y}) \quad (3.10)$$

4. Sonraki adım ise maksimum olmayan gradyanı ortadan kaldırmaktır. Bu nedenle bu adım Maksimum Olmayan Bastırma (Non-Maximum Supression) olarak adlandırılır. Başka bir deyişle piksellerin gradyanı ve komşu piksellerin gradyanına bakılır ve en yüksek gradyanı olan pikseller görüntüde kalır. Bu yöntem kenar bulmanın performansını ciddi bir şekilde olumlu yönde etkilemektedir.

Bir sonraki adımda kenarlar için iki eşik değer tanımlanmaktadır, küçük eşik değeri ve büyük eşik değeri seçilerek görüntünün tüm pikselleri bu iki eşik değer ile karşılaştırılır. Bu değer aralıklarından büyük eşik değerinden yüksek olan değerler 255'e ve küçük eşikten düşük gelen değerler ise 0'a eşitlenir. Sonuç olarak eşik değerleri tanımlandıktan sonra görüntü kenarları ortaya çıkacaktır. Bu aşamalar geçildikten sonra verilerin son hali sonuçlar kısmına aktarılır. [36].

3.1.3 Diferansiyel Gauss yöntemi (DoG)

Orijinal görüntüde Gauss filtresi kullanılarak iki farklı sigma değeri ile iki farklı görüntü elde edilir. Elde edilen iki görüntü birbirinden çıkartılır, yüksek frekans bileşenleri ve alçak frekans bileşenleri ortadan kaldırılır. Böylece bir bant geçiren filtre oluşturulur. Sonuç olarak iki görüntünün birbirinden çıkarılmasıyla yeni görüntü oluşur. Sigma değerlerini değiştirerek elde edilen bu görüntüde kenar bilgileri daha çok ortaya çıkmıştır. İki Gauss filtresinin farkı dijital görüntülerde kenar özelliğini arttırabilmektedir böylece görüntüyü işlenmesi için en uygun hale getirir. DoG'un en büyük dezavantajı görüntünün kontrastını azaltmasıdır [37].

Görüntüdeki kenarlar aşağıda açıklanan adımlarla elde edilebilir:

1. Resme DoG uygulanır.
2. Görüntüdeki sıfır geçişlerinin tespiti yapılır.
3. Yalnızca güçlü olanları korumak için sıfır geçişlerine eşik değer uygulanır. (pozitif maksimum ile negatif minimum arasındaki büyük fark alınır.)

$$G_{\sigma_e} = [{}^{1}\!/_{(2\pi)^{\frac{1}{2}}} * \sigma_e\ ] * \exp\ (-x^2 + \frac{y^2}{2\sigma_e}) \quad (3.11)$$

Sonra:

$$g_1(\mathrm{x}) = G_{\sigma_e}(\mathrm{x}, \mathrm{y}) * f(x, y) \tag{3.12}$$

$$G_{\sigma_i} = [1/(2\pi)^{\frac{1}{2}} * \sigma_I] * \exp(-x^2 + \frac{y^2}{2\sigma_i}) \tag{3.13}$$

Ikinci yumuşatılmış görüntü elde edilir.

$$G_2(\mathrm{x}, \mathrm{y}) = G_{\sigma_i}(\mathrm{x}) * f(x, y) \tag{3.14}$$

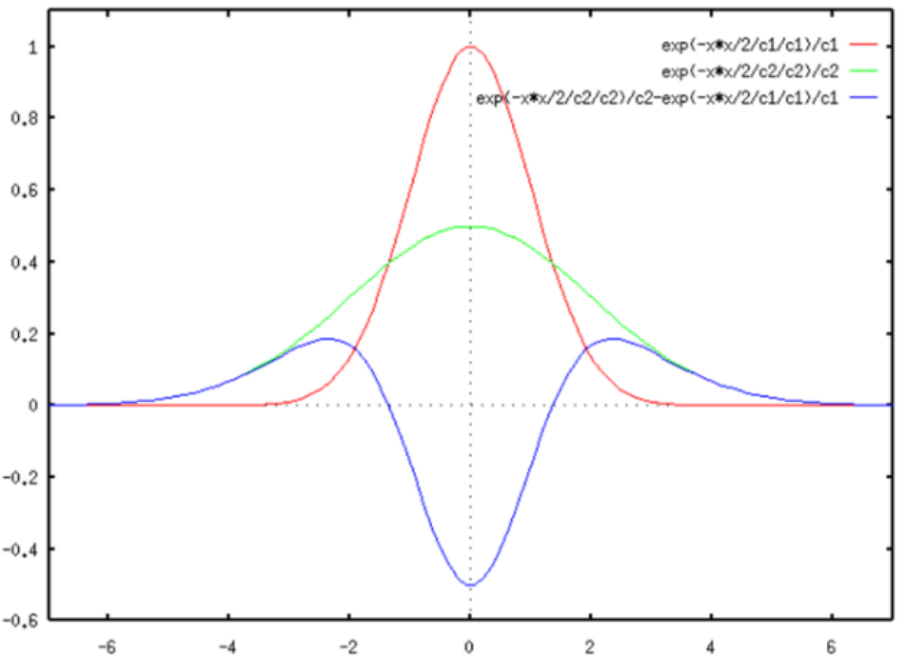
$$\mathrm{DoG}(\sigma_e, \sigma) = [1/(2\pi)^{\frac{1}{2}} * \sigma_e] * \exp(-x^2 + \frac{y^2}{2\sigma_e{}^2}) - 1/(2\pi)^{\frac{1}{2}} * \sigma_i] \exp(-x^2 + \frac{y^2}{2\sigma_i{}^2}) \tag{3.15}$$

Sonuç olarak:

$$\mathrm{DoG} = (\sigma_e, \sigma_i) * f \tag{3.16}$$

yazılabilir.

Şekil 3.3'de görüldüğü gibi DoG filtresi band geçiren bir filtredir ve bu filtre vasıtası ile şekildeki kenarlar rahatlıkla bulunabilmektedir.



Şekil 3.3 İki farklı Gauss filtresi birbirinden çıkararak bant geçiren filtre elde edilmesi [38]

4

Kullanılan Evrişimsel Ağları ve Çeşitleri

4.1 Derin öğrenme tarihi

Derin öğrenme, bilgisayar programlarının "düşünebilmesi", buna karşılık bir davranış biçimi oluşturması ve istenenleri bir insanın yapabileceği gibi yapması şeklinde tanımlanabilir. Makine öğrenmesinin bir alt kümesi olduğunu söylemek mümkündür. Sıralamak gerekirse şu şekilde yazılabilir: Yapay Zeka > Makine öğrenmesi > Derin öğrenme.

Derin öğrenme deyimi ilk defa Igor Aizenberg ve meslektaşları tarafından 2000'li yıllarda Yapay Sinir Ağları (YSA) hakkında konuşulurken duyulmaya başlandı. Derin öğrenme, makine öğrenmesini sağlamanın bir yoludur. 2017 yılında bu ağların derinliği 1000 katına kadar ulaşmıştır. Derin öğrenmede sinir ağının etiketli veriler kullanılarak eğitildiği algoritmalara denetimli (supervised), etiketsiz (unlabeled) olarak eğitildiği algoritmalara ise denetimsiz (unsupervised) algoritmalar denir.

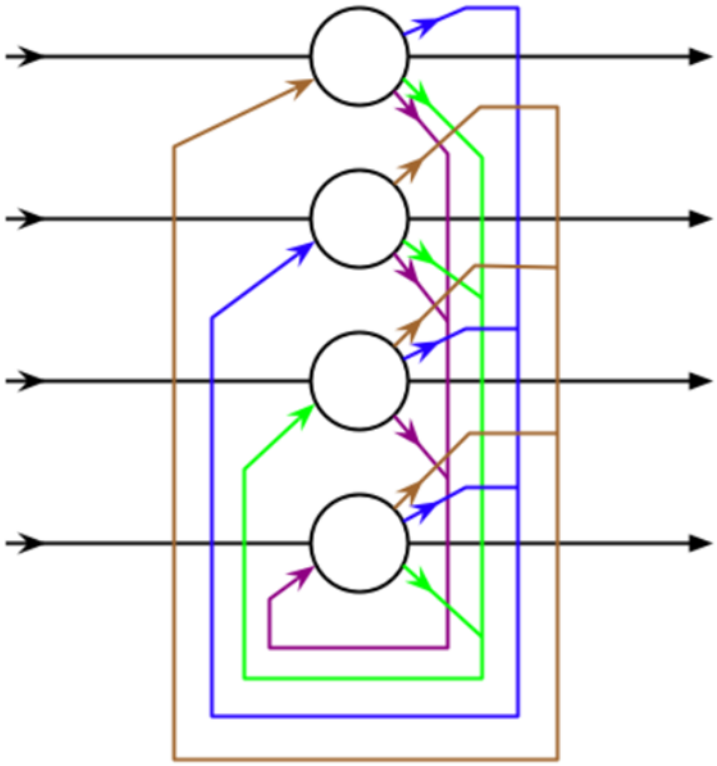
Walter Pitts ve Warren McCulloch tarafından ilk defa nöron ağlarının matematiksel ifadesi 1943'de sunulmuştur [39]. 1950'de Alan Turing tarafından makine öğrenmesinde genetik algoritma oluşturulmuş ve makine öğrenmesinin ilerideki gelişmeleri için birtakım tahminler yapılmıştır. İlk makine öğrenme algoritması 1952'de IBM laboratuvarında gerçekleştirilmiştir.

1957'de Frank Rosenblatt tarafından ''The Perceptron: A Perceiving and Recognizing Automaton'' (Algılayıcı: Otomatik Algılama ve Tanıma) makalesi yazılmış ve yapay sinir ağlarının ilk oluşumu başlamıştır [40] .

1960'da Henry J.Kelley tarafından ''Gradient Theory of Optimal Flight Paths'' (Optimal Uçuş Yollarının Gradyan Teorisi) isimli çalışma yayınlandı. Bu makaledeki bilgiler daha çok havacılık alanında kullanılmaya başlandı. Bir süre sonra yapay zeka ve yapay sinir ağlarına uygulandı. Geriye yayılma (Backpropagation) yönteminin ilk adımları Kelley tarafından atıldı [41].

1979-80 yılları arasında Kunihiko Fukushima tarafından ilk defa yapay sinir ağlarını kullanarak sayıları tanımak için denemeler yapıldı. Bu çalışmanın neticesinde Evrişimsel sinir ağları ortaya çıktı.

1982 yılında Hopfield tarafından yeni bir sinir ağı mimarisi ortaya konuldu, bu yeni ağ Hopfield Ağı olarak adlandırıldı. Hopfield ağı kendini tekrarlayan sinir ağlarından oluşmaktadır. Şekil 4.1'de Hopfield Ağının yapısı görünmektedir.



Şekil 4.1 Bir hopfield Ağın şeması [42]

1989 yılında Yann LeCun tarafından sayıları tanımak için makine öğrenmesi ve evrişimsel sinir ağları kullanıldı. Evrişimsel ağlarda hatayı geriye yayma yönteminden de (backpropagation) yararlanıldı.1989 yılında Q-learning yöntemi, Watkins tarafından yazılan "Learning from Delayed Rewards" isimli makalede ortaya konuldu. Q-learning pekiştirmeli öğrenmenin (Reinforcement Learning) temellerini oluşturdu [43].

Jürgen Schmidhuber tarafından 1993 yılında 1000 katmanlı, kendini tekrarlayan sinir ağı (Recurrent neural network) oluşturuldu.

2009 yılında Standford üniversitenin laboratuvarında Fei-Fei Li tarafından imagenet oluşturuldu. Imagenet 14 milyona yakın görüntü bulundurmaktadır, bu görüntüler içerisinde sınıflandırma ve obje tanıma için veri setleri bulunmaktadır.

2011 yılında Alex Krizhevsky birkaç makine öğrenme yarışmasını kendi yaptığı ağ mimarisi ile kazandı. Bu mimarinin ismi Alexnet olarak adlandırıldı [44].

2014 yılında Deep Face ortaya çıktı. Deep Face bir CNN ağı olup, yüzleri fotoğraf içinde ayırt etme olanağı sağlamaktadır. Deep Face Facebook tarafından geliştirildi ve yaklaşık %97 doğruluk vermektedir. Facebooktan sonra Google da aynı şekilde buna benzer bir ağ geliştirdi.

2016 yılında Üretken Ters Ağlar (GAN-Generative Adversarial Networks) Yann LeCun tarafından ortaya konuldu. Bu ağ denetimsiz (unsupervised) bir ağdır [45].

GAN-Generative Adversarial Networks (üretken ters ağlar) iki aşamadan oluşur. İlk olarak birtakım veriyi alıp ayırt edilmez yeni veriler üretir. İkinci aşamada oluşan veriler ve orijinal veriler arasındaki farklar ayırt edilir.

2016'dan bu tarafa yapay zekanın gelişimi için ve yapay zekayı ekonomiye kazandırmak için birçok start up projesi ve alt yapı çalışmaları gerçekleştirilmiştir.

4.2 Evrişimsel ağlar

Evrişimsel sinir ağları (Convolutional Neural Networks-CNN) (LeCun, 1989), verilerin işlenmesi için ızgaraya benzer ağlar şeklinde tanımlandı. Zaman serisi için olan verilerde bir boyutlu evrişimsel ağlar ve görüntüler için olan verilerde ise iki boyutlu 2D (iki boyutlu) evrişimsel ağlar kullanılmaktadır. Evrişimsel sinir ağları verilerin üzerinde doğrusal bir matematiksel işlem yapmaktadır[46] .

Evrişim Operasyonu:

En genel haliyle evrişim, iki gerçek değerli fonksiyonun üzerine yapılan bir işlemdir. Bu operasyonu daha iyi anlamak için aşağıda örneklendirme yapılmıştır:

Bir lazer sensörüyle uçağın yerinin takip edildiği varsayılırsa, lazer sensörü, t zamanında uçağın konumunu x (t) olarak gösterir, burada x ve t' nin tanım kümeleri gerçek değerler alır, yani t zamanının değişken olduğu her durumda lazer sensörü farklı değerler verecektir. Ancak lazer sensörünün gürültülü ortamda ölçüm yaptığı

düşünülürse, uçağın konumuyla ilgili daha az gürültülü ve daha doğru bir tahmin elde etmek için birkaç ölçüm yapıp ortalama değerini almak gerekir. Sensörle ölçüm işlemi için Eşitlik 4.1'de verilen W(a) ağırlık fonksiyonu olarak tanımlanır ve (a) tekrarlama sayısını belirtmektedir. Son alınan ağırlıklar çok önemlidir. Bunun için son ağırlığa yakın bir ortalama beklenmektedir. Gerçek değerli zamanda ağırlık ölçümü yapılırsa, uçağın konumunun bulunmasında daha düzgün bir tahmin sağlanır, yeni bir fonksiyon elde edilir. Bu işlem evrişim olarak adlandırılır.

$$S(t) = \int X(a)W(t-a)da \qquad (4.1)$$

Verilen örnekte, W'nin geçerli bir olasılık yoğunluk işlemi olması gerekmektedir yoksa çıkışın ağırlık ortalaması tanımsız olur. Ayrıca W'nın tüm negatif değerleri sıfırdır. Genel olarak, evrişim işlemi 4.1 eşitliğindeki integralin geçerli olduğu tüm işlemler için tanımlıdır.

Evrişimsel ağlarda x fonsiyonu genellikle giriş ve w fonksiyonu ağırlık olarak tanımlanmaktadır. Ağırlık ve girişlerin çarpımı özellik haritası matrisini (Feature map)ortaya çıkartmaktadır.

Bilgisayar ortamlarında belirli zaman dilimlerinde evrişim işlemi yapılır. Zaman t ile gösterilirse ve bu değerler tam değerler alırsa x ve w değerleri ayrık bir şekilde ilerler dolayısıyla bu işlem ayrık bir konvolüsyon oluşturur. Ayrık foksiyon 4.2 eşitliğindeki gibi yazılır.

$$S(t) = (x \otimes w)(t) = \sum_{a=-\infty}^{\infty}(x(a)w(t-a)) \qquad (4.2)$$

Makine öğrenimi uygulamalarında, çoğu zaman çok boyutlu dizi kullanılır ve çekirdeği (kernel) çok boyutlu bir paremetre dizisi oluşturur. Bu çok boyutlu dizilere tensör denilmektedir. Giriş ve çekirdeğin her bir ögesinin ayrı ayrı depolanması gerekmektedir. Görüntüler üzerine konvolüsyonel işlem yapıldığı zaman çekirdekte iki boyut oluşması gerekir. Eğer K çekirdekse (kernel) ve I görüntü ise konvolüsyonel işlem 4.3 eşitiliğindeki gibi ifade edilir.

$$S(i,j) = (I \otimes K)(i,j) = \sum_m \sum_n I(m,n)K(i-m, j-n) \qquad (4.3)$$

Konvolüsyon işlemi kümülatif bir işlemdir ve 4.4 eşitliğindeki gibi yazıldığında 4.3 eşitliğindeki formül ile eşdeğer olmaktadır.

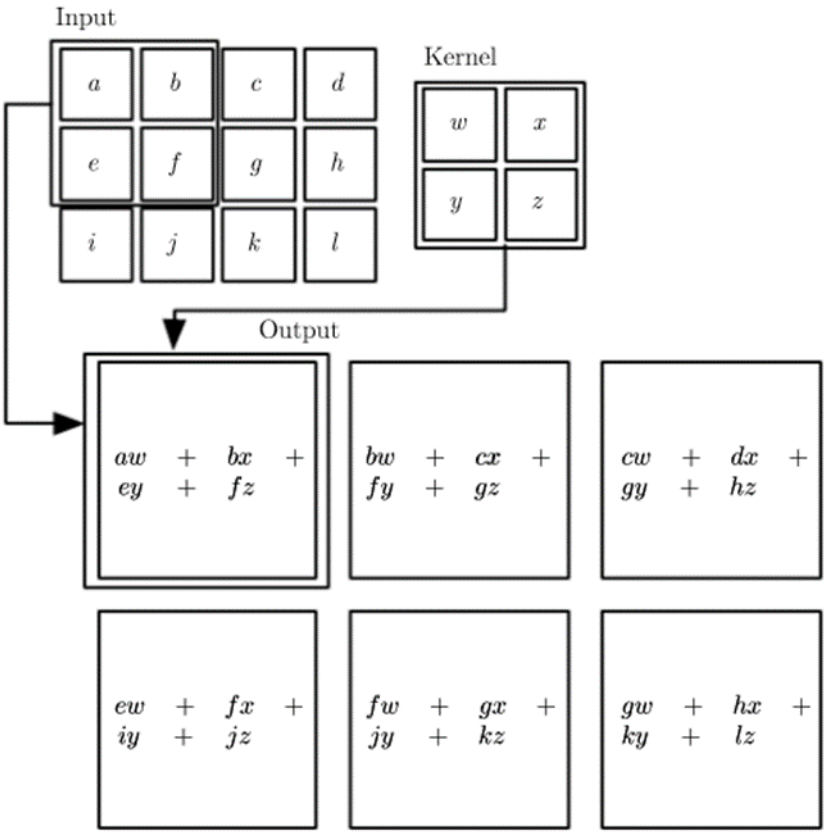
$$S(i,j) = (K \otimes I)(i,j) = \sum_n \sum_m I(i-m, j-n)K(m,n) \qquad (4.4)$$

Genelikle m ve n'nın tanımlı değerleri daha az değişiklik gösterdiği için 4.4 eşitliğindeki formülün makine öğrenmesi kütüphanelerinde uygulanması daha kolaydır.

Aynı konvolüsyon davranışının oluşması için birçok derin öğrenme kütüphanelerinde cross-correlation (çapraz korelasyon) yöntemi kullanılmaktadır. Bu durumda bir uçtan diğer uca dönme yapılmaz.

$$S(i,j) = (I \otimes K)(i,j) = \sum_m \sum_n I(i+m, j+n) K(m,n) \tag{4.5}$$

4.5 formülünde ifade edilen konvolüsyonel işlem aşağıdaki şekilde gösterilmektedir [47].



Şekil 4.2 Evrişimsel işlemin gerçekleşmesi [47]

4.3 Havuzlama katmanı (Pooling layer):

Havuzlama (pooling) katmanında asıl amaç işlem yükünü azaltmaktır. Özellikler haritası (feature maps) azlatılarak havuzlama işlemi gerçekleşmektedir. Havuzlama yapıldığında özellik haritası için yeni matrisler oluşur. Bu işlem için (n*n) lik pencereler seçilmektedir, pencereler büyük veya küçük seçilebilir.

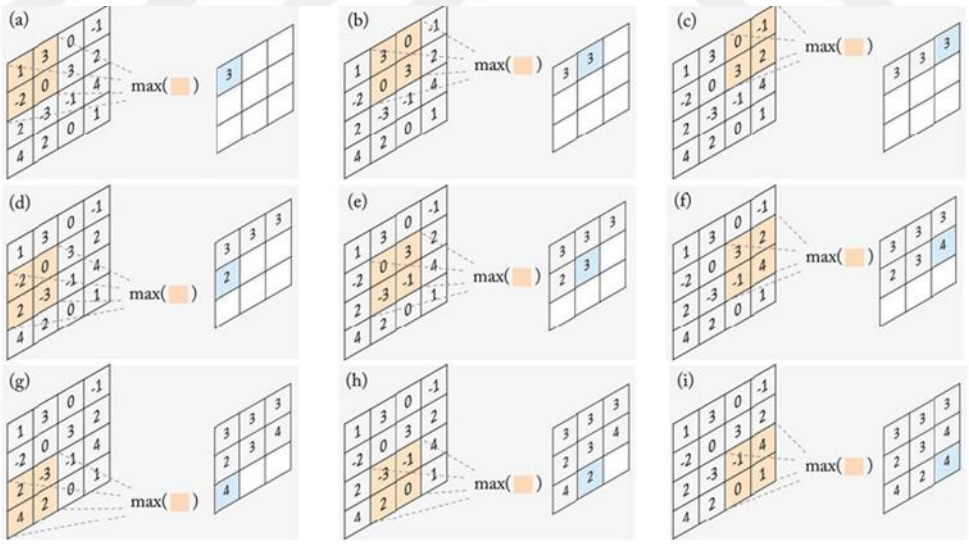
Havuzlama, maksimum havuzlama (maximum pooling) ve ortalama havuzlama (average pooling) olarak ikiye ayrılır. Maksimum havuzlama fonksiyonu bir pencerenin içinde olan maksimum değeri alır, ortalama havuzlama ise ortalama değeri göz önünde bulundurur.

$$a_j = \underset{N*N}{max}\left(a_i^{n*n} u(n,n)\right) \qquad (4.6)$$

Havuzlama katmanı oluşturulduktan sonra çıkışın büyüklüğü hesaplanır. f*f eğer giriş penceresi olursa ve bunun üzerine bir s adımı atılarak maksimum havuzlama yapılıyorsa, çıkış penceresi 4.7 eşlitliğinde hesaplanır.

$$\acute{h} = \left\lfloor \frac{h-f+s}{s} \right\rfloor \text{ ve } \acute{W} = \left\lfloor \frac{w-f+s}{s} \right\rfloor \qquad (4.7)$$

Şekil 4.3'de maksimum havuzlama işlemi gösterilmektedir [48].



Şekil 4.3 Havuzlama işleminde gerçekleşen adımlar [48]

4.4 Yığın Normalizasyonu (Batch Normalization)

Derin öğrenmede ve evrişim ağlarında eğitim sırasında giriş katmanı veri dağılımı ile katmanlar arasındaki veri dağılımı değişiklik göstemektedir. Bu dağılımlar öğrenmeyi yavaşlatır ve doğrusal olmayan modellerde eğitme yapmak çok daha zorlaşır. İç kovaryant değişimi (internal covariate shift) yani giriş verisinin dağılımı diğer katmanlardaki veri dağılımından farklı olmaktadır. Bu problemi çözmek için katmanların çıkışları normalize edilmektedir. Yığın normalizasyonu ağın daha yüksek doğruluklara ulaşılmasını ve ilk ağırlık ile bias değerlerinin seçiminde daha verimli olmayı sağlamaktadır. Yığın normalizasyonunda bir regülasyon işlemi yapılmaktadır ve bazen bırakma (Dropout) işlemine gerek kalmaksızın regülasyon tamamlanmaktadır. Bu yöntem yardımı ile Imagenet sınıflandırmasında validasyon hatası % 4.9 ve test hatası % 4.8 olarak elde edilmiştir.

Yığın normalizasyonu işleminde sadece giriş ve çıkış katmanlarının değil, her katmanın bağımsız şekilde skalar özelliklerini seçmek için ortalamayı sıfıra düşürüp varyansı 1'e çekmek gerekmektedir. Bir katmanın d boyutunda bir girişi olduğu düşünülürse, girişin x= (x^1 x^2..x^d) her boyutunu normalize etmek için 5.8,5.10 eşitliklerinden faydalanılır.

Her giriş katmanının normalizasyonu verinin temsil etme şeklini değiştirebilir. Mesela sigmoid fonksiyonunun normalize edilmesi ile fonksiyon lineer olmadığı halde lineermiş gibi davranabilir. Bu konuyu ele almak için ve temsil edilen verinin orijinal veri ile farkı olmadığını anlamak için kimlik dönüşümü yapılmaktadır.

Her aktivasyon fonksiyonunda (lineer, relu) $\widehat{x^{(k)}}$ girişleri için iki öğrenebilir parametre tanımlanmaktadır $\widehat{\beta^{(k)}}$ ve $\widehat{\gamma^{(k)}}$ ile gösterilen bu iki parametre her katmanda çıkışların zamanda kaydırma (shift) ve ölçeklenebilirliğini sağlamaktadır. Bu parametreler orijinal model parametreleriyle birlikte öğrenilir ve ağın temsil gücünü yeniden kazandırır. Eğer $\widehat{\gamma^{(k)}} = \sqrt{Var[x^{(k)}]}$ ve $\beta^{(k)} = E\left[x^{(k)}\right]$ seçilirse orijinal aktivasyon fonksiyonun çıkış değerleri elde edilebilir.

Bir küçük yığın (mini-batch) düşünülürse her bir aktivasyon için normalizasyon bağımsız bir şekilde uygulandığında $x^{(k)}$ aktivasyon fonksiyonun değeri olur. Küçük yığın (Mini-batch) için katmanlar arasında m tane aktivasyon fonksiyonu çıkışı

oluşur. $\beta = \{x_1 \dots m\}$ ile normalize edildikten sonra sonuç $\widehat{x_1}$ olarak tanımlanır daha sonra lineer değişim transfomasyonu ile $y_1 \dots . m$ dönüşür.

Dönüşüm ve normalizasyon (Batch Normalization- BN) $BN_{\gamma,\beta}$:$x_1 \dots . m \rightarrow\ y_1 \dots \dots m$ şeklinde gerçekleşmektedir.

Aşağıdaki algoritmada yığın normalizasyonunun (Batch Normalization-BN) nasıl gerçekleştirildiği daha detaylı bir şekilde gösterilmiştir.

Giriş verisi: Küçük-Yığın'daki x değerleri: $\beta = \{ x_1 \dots . m\}$:

Öğrenilecek parametreler: $\gamma\ ve\ \beta$.

Çıkış verisi: $\{y_i = BN_{\gamma\beta}(x_i)\}$.

$$\mu_B \leftarrow \frac{1}{m}\sum_{i=1}^{m} x_i \qquad \text{/küçük yığın ortalaması} \qquad (4.8)$$

$$\sigma_\beta^2 \leftarrow \frac{1}{m}\sum_{i=1}^{m}(x_i - \mu_B)^2 \qquad \text{/küçük yığın varyasyon} \qquad (4.9)$$

$$\widehat{x_i} \leftarrow \frac{x_i - \mu_\beta}{\sqrt{\sigma_\beta^2 + \in}} \qquad \text{/ Normalizasyon işlemi} \qquad (4.10)$$

$$y_i \leftarrow \gamma\widehat{x_i} + \beta \equiv BN_{\gamma,\beta}(x_i) \quad \text{/ ölçeklenmiş ve zamanda kayma (scale and shift)} \quad (4.11)$$

Yukarıdaki formüllerden de anlaşıldığı gibi $\beta\ ve\ \gamma$ parametreleri eğitim boyunca elde edilecektir ve BN transformu bağımsız şekilde, aktivasyon fonksiyonunu etkilememektedir. Yığın normalizasyonu (Batch Normalization -BN) $BN_{\beta\,\gamma}$ fonksiyonu sadece örneklere bağlı değilken, küçük-yığın (mini-batch) örneklere de bağlıdır. Eğitim esnasında l kaybının geriye yayılması gerekmektedir. Bunun yanısıra parametrelere göre gradyan hesaplanmalıdır. Geriye yayılmada (Backpropagation) hatayı hesaplamak için zincir kuralı kullanılmaktadır. Zincir kuralı 4.12 ile 4.17 eşitliklerinde verilmektedir.

$$\frac{\partial l}{\partial \hat{x}_i} = \frac{\partial l}{\partial y_i}.\gamma \qquad (4.12)$$

$$\frac{\partial l}{\partial \sigma_\beta^2} = \sum_{i=1}^{m} \frac{\partial l}{\partial \hat{x}_i}.\left(x_i - \mu_\beta\right).\frac{-1}{2}\left(\sigma_\beta^2 + \in\right)^{-3/2} \qquad (4.13)$$

$$\frac{\partial l}{\partial \mu_\beta} = \left(\sum_{i=1}^{m} \frac{\partial l}{\partial \hat{x}_i}.\frac{-1}{\sqrt{\sigma_\beta^2 + \in}}\right) + \frac{\partial l}{\partial \sigma_\beta^2}\ .\frac{\sum_{i=1}^{m} -2(x_i - \mu_\beta)}{m} \qquad (4.14)$$

$$\frac{\partial l}{\partial x_i} = \frac{\partial l}{\partial \hat{x}_i} \cdot \frac{1}{\sqrt{\sigma_\beta^2 + \epsilon}} + \frac{\partial l}{\partial \sigma_\beta^2} \cdot \frac{2(x_i - \mu_\beta)}{m} + \frac{\sigma l}{\sigma \mu_\beta} \cdot \frac{1}{m} \quad (4.15)$$

$$\frac{\partial l}{\partial \gamma} = \sum_{i=1}^{m} \frac{\partial l}{\partial y_i} \cdot \hat{x}_i \quad (4.16)$$

$$\frac{\partial l}{\partial \beta} = \sum_{i=1}^{m} \frac{\partial l}{\partial y_i} \quad (4.17)$$

Yığın normalizasyonu türevlenebilir bir işlem olmakla birlikte aktivasyon fonksiyonlarını normalize ederek katmanlardaki veri kovaryant (eşdeğişken) ötelenmesini azaltır ve böylece öğrenmeyi hızlandırır.

4.5 Olasılıksal dereceli azalma (Stochastic gradient decent)

İyi bir optimizasyon yöntemi seçmek makine öğrenmesinin vazgeçilmez bir parçasıdır. Optimizasyon yöntemi algoritmanın performansını çok etkilemektedir. Olasılıksal dereceli azalma her bir eğitim iterasyonu bitişinden sonra parametreleri güncellemektedir. Hızlı çalıştığı için yerel minimuma hızlı bir şekilde ulaşmaktadır. Standart olasılıksal dereceli azalma optimizasyonu için θ maliyet fonskiyonu $J(\theta)$ eşitlik 4.18 ve 4.19'de verilmiştir. Bu denklemde α öğrenme oranıdır ve $E[J(\theta)]$ beklenen değerdir. Her eğitim iterasyonu için $x^{(i)}$ eğitim veri setini ve $y^{(i)}$ ise etiketlenen değerleri temsil etmektedir.

$$\theta \leftarrow \theta - \alpha \nabla_\theta E[J(\theta)] \quad (4.18)$$

$$\theta \leftarrow \theta - \alpha \nabla_\theta (\theta; x^{(i)}, y^{(i)}) \quad (4.19)$$

Olasılıksal dereceli azalma yönteminde sarsılma yani en optimum yolu seçerken farklı yönlere sapma oranını azaltmak ve hızlı bir şekilde hedefe ulaşmayı sağlamak için momentumlu olasılıksal dereceli azalma yöntemi ortaya çıkmıştır. Bu yöntemde tüm geçmiş iterasyonlardaki gradiyenti hesaba katarak güncellemeler yapılmaktadır. Eşitlik 4.20'de momentum dereceli azalma yöntemi ifadesi açıklanmaktadır.

$$v = \gamma v + \alpha \nabla_\theta J(\theta; x^{(i)}, y^{(i)}) \quad (4.20)$$

$$\theta = \theta - v \quad (4.21)$$

γ *değeri* $0 - 1$ *arasında olmaktadır.*

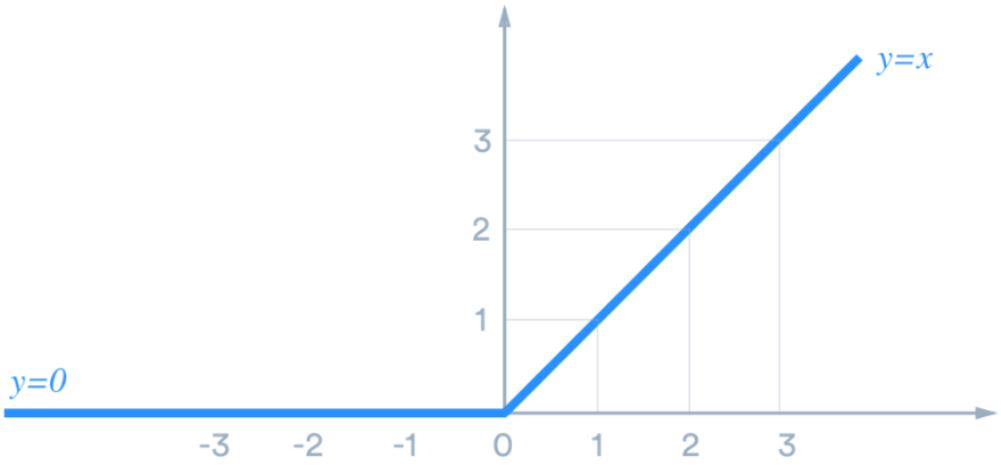
4.6 Parametrelerin hesaplanması

Bir evrişim katmanında giriş katında l kadar giriş olduğu, çıkış katmanında k adet çıkış olduğu, filtrelerin büyüklüklerinin n*m boyutunda olduğu ve son olarak her bir katmanın bias değerine sahip olduğu düşünülürse bir evrişim ağının toplam parametre sayısı (m*n*l+1)*k olarak hesaplanır. Evrişim ağlarında hesaplama yapılabilecek diğer katman ise tam bağlantılı katmandır, bir tam bağlantılı katmanda n giriş ve m çıkış olduğu düşünülürse ve bias değeri eklenirse tam bağlantılı katman için parametre sayısı (n+1)*m adet olur. Tüm evrişim ağlarındaki hesaplamalar ve tam bağlantıdaki hesaplamalar toplanarak ağın parametre değeri bulunur.

4.7 Doğrultmuş doğrusal birim (Rectified linear unit-Relu) aktivasyon fonksiyonu

Yapay sinir ağlarında birçok aktivasyon fonksiyonu mevcuttur. Aktivasyon fonksiyonlarının en önemli amacı işlem yükününü azaltmak ve en güçlü bilgi ve özellikleri elde etmektir. Farklı aktivasyon fonksiyonlarına örnek olarak sigmoid ve lineer fonksiyonlarını göstermek mümkündür. Doğrultulmuş doğrusal birim (Relu) aktivasyon fonksiyonu evrişimsel sinir ağlarında en çok ara katmanlarda kullanılmaktadır. Bu fonksiyon ilk defa 2012'de Krizhevsky tarafından kullanılmıştır [44]. ve tanh fonksiyonundan daha hızlı eğitim işlemini gerçekleştirmektedir. Doğrultumuş doğrusal birim fonksiyonu 4.22 eşitliğinden hesaplanmaktadır.

$$f(x) = \max(0, x) \qquad (4.22)$$



Şekil 4.4 Relu fonksiyonu [49].

4.8 Softmax fonksiyonu ve Tam bağlantılı katman(Fully connected layer)

Softmax fonksiyonu son katmanda sınıflandırma işlemini yapmak için kullanılmaktadır. Softmax fonksiyonu giriş katmanındaki verilerin olasılık dağılımını gerçekleştirmektedir . Bu olasılık dağılımının toplamı bir olmaktadır.

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{K=1}^{K} e^{z_k}} \quad j = 1,2,3,4, \ldots \quad .... \qquad (4.23)$$

Tam bağlantılı katman(Fully connected layer) :

Tam bağlantılı katman, evrişimsel sinir ağlarında yer alan en son katmandır. Görüntüden elde edilen tüm özellikler tam bağlantılı katmanda tek boyutlu matris haline getirilmektedir. Veri setleri için sınıflandırma işlemi bu katmanda gerçekleşmektedir. Her bir nöron kendinden sonraki nörona bağlandığı için bu katman tam bağlantılı katman adını almaktadır.

4.9 Resnet 50

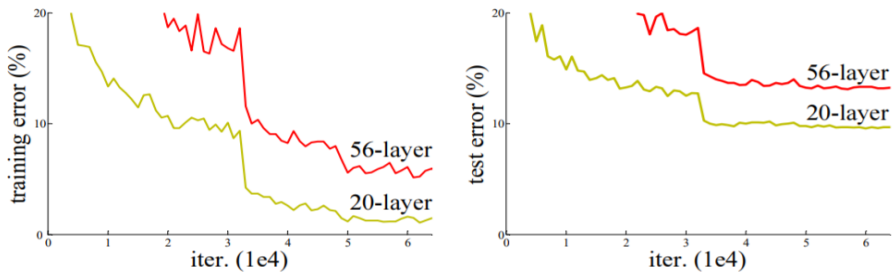
Konvolüsyonel nöron ağları çok katmanlı bir nöron ağ yapısına sahiptir; görüntü tanımak ve obje ayırt etmek için tasarlanmıştır. Görüntü ve obje tanımada kullanılan büyük kaynaklardan bir tanesi Imagenet'tir. Imagenet proje ve yazılım yarışmaları her sene belirli aralıklarda düzenlenir. Yazılım geliştiriciler Imagenet Large Scale Visual Recognition Challenge (ILSVRC) adında bir yarışmada biraraya gelip görüntüler üzerinde sınıflandırma ve obje tanıma gibi problemlere çözüm

aramaktadırlar. Imagenet 15 milyon üzerinde etiketlenmiş görüntüye ve 22000 üzerinde sınıf sayısına sahiptir.

Bu tez çalışmasında kullanılan veri seti Resnet50 derin öğrenme ağına uygulanmıştır. 2015 yılında Resnet ağı görüntü sınıflandırma, obje tanıma ve aynı zamanda Ms Coco veri setinde segmentasyon ve obje tanıma üzerinde başarı sağlamıştır. Resnet50 derin öğrenme ağı aşağıdaki başlıklarda açıklanmıştır. Resnet50 ile ilgili tüm görüntüler ve açıklamalar "Deep Residual Learning for Image Recognition" isimli makaleden alınmıştır.

- Resnet50, düz ağların problemlerini çözmektedir.
- Atlama bağlantısı (skip connection)
- Resnet50'nin ağ mimarisi.
- Darboğaz(bottelneck) tasarımı.
- Resnet ve düz ağların karşılaştırılması

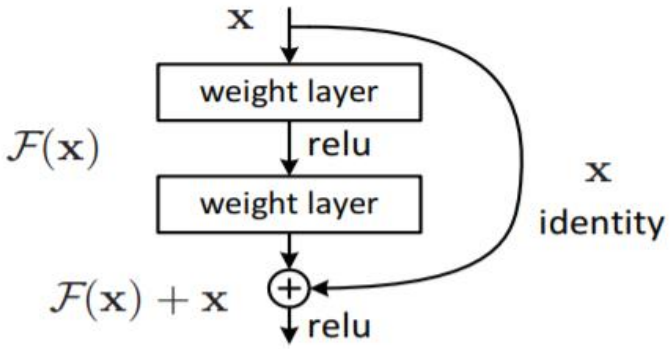
1. Düz ağlardaki gradyan problemini çözmek için Resnet50 ortaya çıkmıştır. Derin konvolüsyonel ağlarda iki önemli katman vardır, biri konvolüsyon katmanı diğeri ise tam bağlı katmandır (fully connected). Alexnet, ZFNet, VGGnet gibi ağlarda atlatma bağlantısı (skip connection) ve kısa yol bağlantısı yoktur, bu tür ağlar düz (plain) ağ olarak adlandırılmaktadır. Düz ağlarda katmanlar çoğaldıkça ve ağ derinleştikçe hatayı geriye yaymada (backpropagation) gradyan kaybı yaşanmaktadır. Derin öğrenme ağlarında hatayı hesaplamak için gradyan o anki ağırlığına göre her iterasyonda geriye yayılır. Düz derin ağlarda gradyanın küçük değerlerinin çarpılması kayıp (vanished) durumu olarak, gradyanın büyümesi ise patlama (explode) durumu olarak adlandırılır[50].



Şekil 4.5 Düz ağ ile Resnet50 arasındaki hata oranı farkı [50].

Şekil 4.5'de görüldüğü gibi 20 katmanlı düz ağ 56 katmanlı düz ağa göre daha düşük eğitim ve test hatası vermektedir. Daha derin ve düz ağlarda gradyan kaybı olduğu için daha çok hata meydana gelir.

Gradyan kaybı veya büyümesini (patlaması) engellemek için atlama veya kısa yol bağlantısı yapılmaktadır. Kısa yol bağlantısında giriş değerleri bir önceki katmandaki değerlerden alınarak sonraki katmana eklenmektedir. Şekil 4.6 bu konuyu daha açık bir şekilde anlatmaktadır.

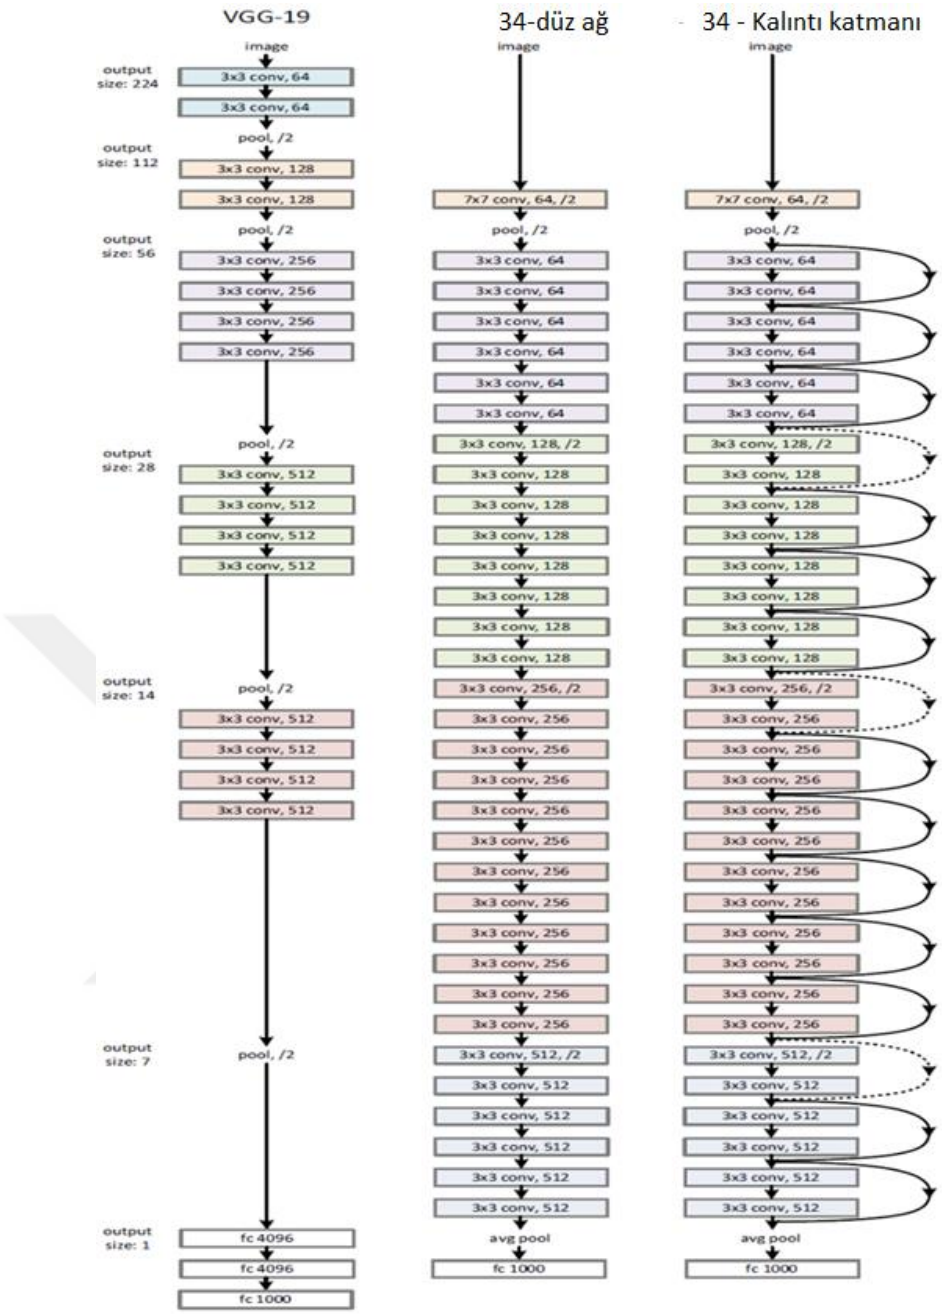


Şekil 4.6 Bir Kalıntı blok şeması (Residual Block) [50].

Gradyan kaybını önlemek için ağırlık katmanlarında, düz ağlardan farklı olarak bir x girişi yani kimlik haritası (identity map) oluşturulur.

2. Resnetin mimari için 34-kalıntı katmanı ağı, 34-düz ağ ve VGG-19 evrişimsel ağı Şekil 4.7'de gösterilmiştir. Tüm ağ yapıları arasındaki farklılıklar şemada gösterilmektedir. Resnet ağı kısa yol bağlantılarının ardarda bağlanması ile oluşmaktadır. VGG19 ile 34-düz ağ yapısının arasındaki tek fark 34-düz ağ yapısının daha derin olmasıdır. Düz ağlar derinleştikçe gradyan kaybı oluşur, bunu gidermek için 34-kalıntı katmanı yapısı oluşturulmuştur.

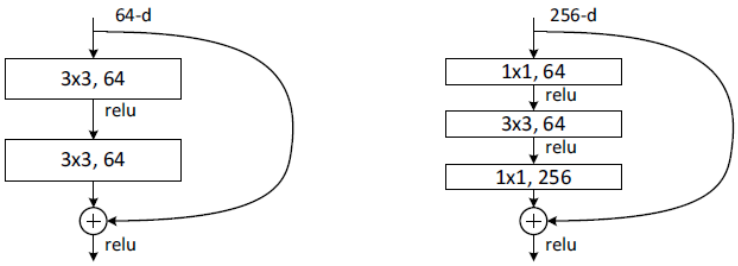
Şekil 4.8 'de görüldüğü gibi 34-kalıntı katmanı yapısında katmanlar arasında 3*3 evrişim katmanları vardır. Bu 3* 3 lük katmanlar arasına 1*1 evrişim katmanı eklendiği zaman Resnet50 ağı oluşur.



Şekil 4.7 Resnet50 Ağının mimarisi [50].

3. Darboğaz tasarımı:

Residual(kalıntı*)* derin bir ağ olduğu için, parametrelerin hesaplanması çok zaman gerektirmektedir. Darboğaz tasarımı parametre hesaplamalarını azaltmak için yapılmaktadır. Şekilde 4.8 görüldüğü gibi sağ resimde parametre sayısı daha azdır.



Şekil 4.8 Darboğaz yapısı olan ağ ve darboğaz yapısı olmayan ağ [50].

Bire bir (1*1) konvolüsyonel ağlar şekilde de görüldüğü gibi ağın başında ve sonunda yer almaktadır. Bu teknik Googlenet makalesinde ağ içinde ağ (Network in Network) olarak adlandırmıştr. 1*1'lik konvolüsyonel işlem bağlanan parameteleri ve sonucunda işlem yükünü azaltmaktadır oysa ki performanslarda herhangi bir değişim göstermemektedir. Darboğaz tasarımı ile 34-katmanlı bir ağ 50 katmanlı bir Resnet ağına dönüşebilmektedir. Tüm mimariler Şekil 4.9'da görülmektedir

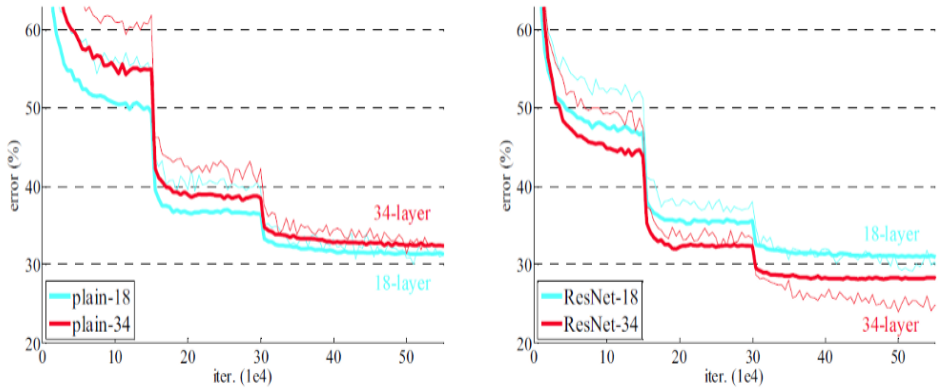
layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
conv2_x	56×56	3×3 max pool, stride 2 [3×3, 64; 3×3, 64] ×2	[3×3, 64; 3×3, 64] ×3	[1×1, 64; 3×3, 64; 1×1, 256] ×3	[1×1, 64; 3×3, 64; 1×1, 256] ×3	[1×1, 64; 3×3, 64; 1×1, 256] ×3
conv3_x	28×28	[3×3, 128; 3×3, 128] ×2	[3×3, 128; 3×3, 128] ×4	[1×1, 128; 3×3, 128; 1×1, 512] ×4	[1×1, 128; 3×3, 128; 1×1, 512] ×4	[1×1, 128; 3×3, 128; 1×1, 512] ×8
conv4_x	14×14	[3×3, 256; 3×3, 256] ×2	[3×3, 256; 3×3, 256] ×6	[1×1, 256; 3×3, 256; 1×1, 1024] ×6	[1×1, 256; 3×3, 256; 1×1, 1024] ×23	[1×1, 256; 3×3, 256; 1×1, 1024] ×36
conv5_x	7×7	[3×3, 512; 3×3, 512] ×2	[3×3, 512; 3×3, 512] ×3	[1×1, 512; 3×3, 512; 1×1, 2048] ×3	[1×1, 512; 3×3, 512; 1×1, 2048] ×3	[1×1, 512; 3×3, 512; 1×1, 2048] ×3
	1×1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10^9	3.6×10^9	3.8×10^9	7.6×10^9	11.3×10^9

Şekil 4.9 Resnet ağlarının farklı versiyonları **[**50**] .**

4.Resnet ve düz ağların karşılaştırılması:

Gradyan kaybı problemi çok derin ağlarda mevcuttur dolayısıyla bir 18 katmanlı düz ağ 34 katmanlı bir düz ağdan daha iyi sonuçlar vermektedir. Bu kayıp kısa bağlantılı (shortcut connection) kalıntı (Residual) ağlarda tersine dönüşmekte yani bir 34

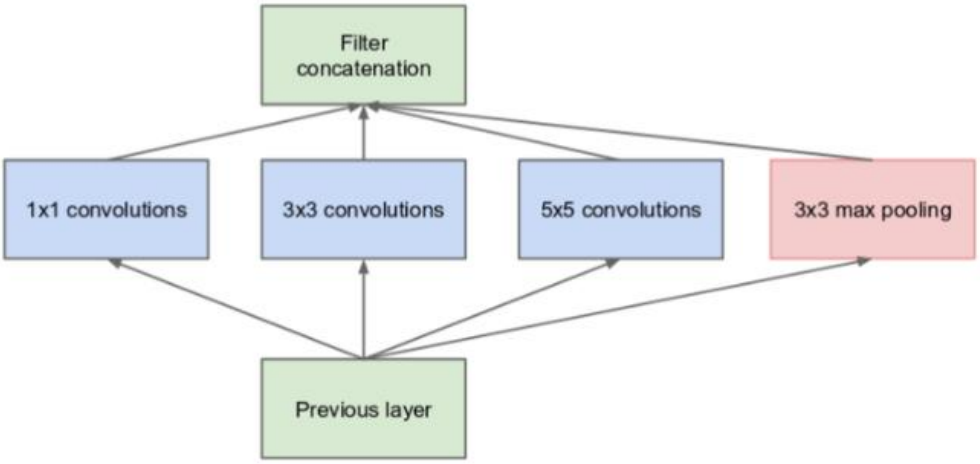
katmanlı ağ bir 18 katmanlı ağdan daha iyi sonuç üretmektedir. Aşağıdaki şekilden de anlaşılacağı üzere Residual (kalıntı) ağlar düz ağlardan oldukça farklıdır ve hatanın azalmasını aynı zamanda da doğruluğun yükselmesini sağlarlar.



Şekil 4.10 Düz ağ ve Resnet ağında katman çoğalmasının etkisi [50].

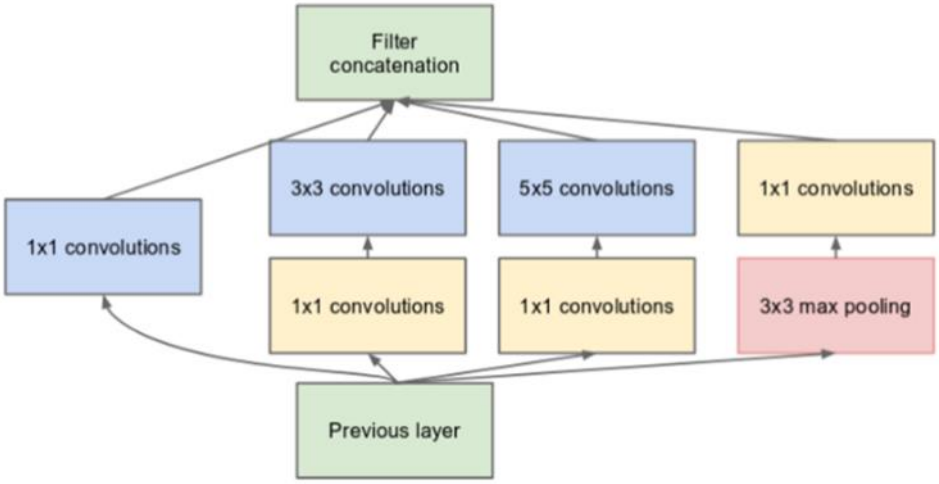
4.10 Inception v3

Evrişimsel sinir ağlarına başka bir örnek olarak Inception verilebilir. Inception ağı ilk defa 2015 yılında Szegedy tarafından ortaya konuldu. Derin öğrenme ağlarında katmanlar derinleştikçe hem hesaplama maliyeti hem de gradyan kaybı yaşanmaktadır. Inception ağlarında derin öğrenme ağlarından farklı olarak; hesaplama maliyetini ve gradyan kaybını azaltmak için ağın genişlemesi ile daha iyi sonuçlar elde edilmektedir. Bu ağlarda doğru sonuç almak için farklı çekirdek boyutları kullanılarak hem lokal bilgilere hem de global bilgilere erişilir. Büyük çekirdekler seçilerek görüntüde global bilgilere ve küçük çekirdeklerde ise lokal bilgilere ulaşmak mümkün olmaktadır. Bu şekilde ağın derinleşmesi yerine ağ genişlemektedir. Inception v1 olarak adlandırılan ilk modelde farklı çekirdek (kernel) boyutları seçilip sonra da havuzlama işlemi yapılarak tüm bilgiler birleştirilir. Böylece tek bir katman oluşturulur.



Şekil 4.11 Inception v1 ağının 1*1 evrişim işlemi eklenmemiş hali [51].

Şekil 4.11'deki ağda her çekirdek boyutunda evrişim işlemi gerçekleşmektedir dolayısıyla ağın işlem maliyeti yüksektir, bu problemi çözmek için ağa 1*1 evrişim işlemi yapan çekirdekler eklenmektedir.

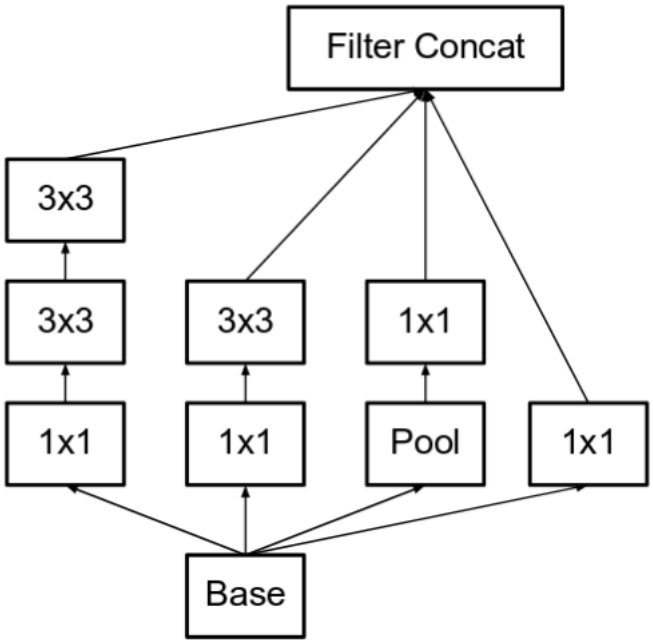


Şekil 4.12 1*1 evrişim işlemi eklenerek oluşturulan Inception evrişim katmanı[51].

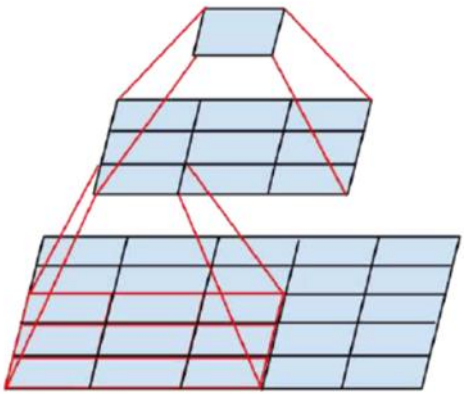
İlk olarak Inception v1 ortaya çıkmış sonraki zamanlarda yığın normalizasyonu yöntemi kullanılarak Inception v2 geliştirilmiştir. Faktorizasyon fikri ile de Inception v3 ortaya çıkmıştır. Inception v3'deki en önemli yeniliklerden bir tanesi faktorizasyonun olmasıdır. Faktorizasyon iki amacı hedeflemektedir. İlk aşamada

işlemsel parametrelerin azaltılması ve ikinci aşamada ağın aynı derecede etkili kalması hedeflenir.

Inception v3'de 3*3'lük bir konvolüsyon işlemi yapılmaktadır. Bu sayede işlem sayısı azalmaktadır. Mesela 5*5 filtre ile yapılan işlem sayısı 25'tir. Ama bu işlem yerine iki katmanlı 3*3'lük işlem yapıldığı takdirde işlem sayısı 3*3+3*3 =18 olmaktadır, yani %28 tasarruf edilmektedir [52].

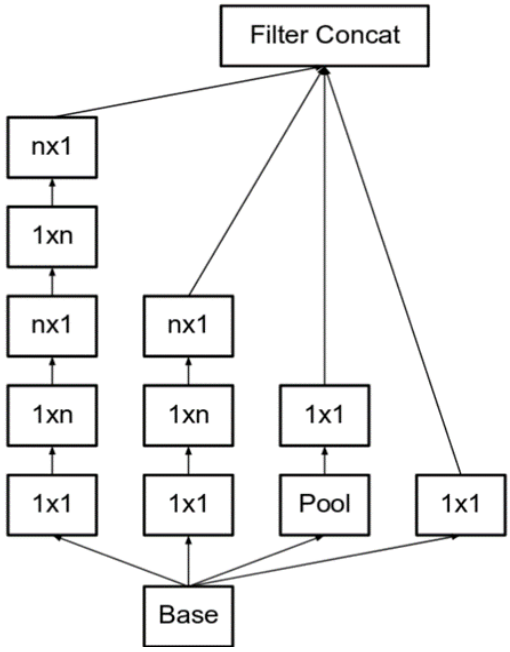


Şekil 4.13 Evrişim işleminde 5*5 evrişim yerinde iki 3*3 evrişim yapılması



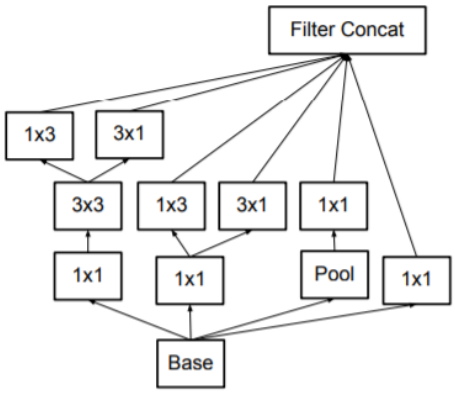
Şekil 4.14 3*3'lük evrişim işlemi[52].

Inception v3' de n*n'lik bir filtre yerine 1*n ve n*1'lik evrişim işlemi yapan çekirdekler kullanılır. Örneğin bir 3*3'lük bir konvolüsyon ilk önce 1*3'lük konvolüsyon sonra da 3*1'lik konvolüsyon haline dönüştürülerek çıkışa uygulanır. Şekil 4.15'de gösterilen bu yöntem yüzde %33 daha az işlem gerektirir.



Şekil 4.15 İşlem maliyetini düşürmek için farklı bir ağ yapısı [52].

Diğer bir farklı evrişim yönteminde işlem maliyetini düşürmek için iki 3*3 evrişim yerine bir 3*3 evrişim ve iki tane 1*3 ve 3*1 evrişim kullanılmaktadır.



Şekil 4.16 işlem maliyetini düşürmek için farklı bir ağ katmaı

Modeller derinleştikçe boyutlar daralacaktır, dolayısıyla bilgi kaybı yaşanacaktır. Bilgi kaybını önlemek için Inception v1'deki model Inception v3'e genişletilir. Inception v3 mimarisi Tablo 4.1'de verilmiştir.

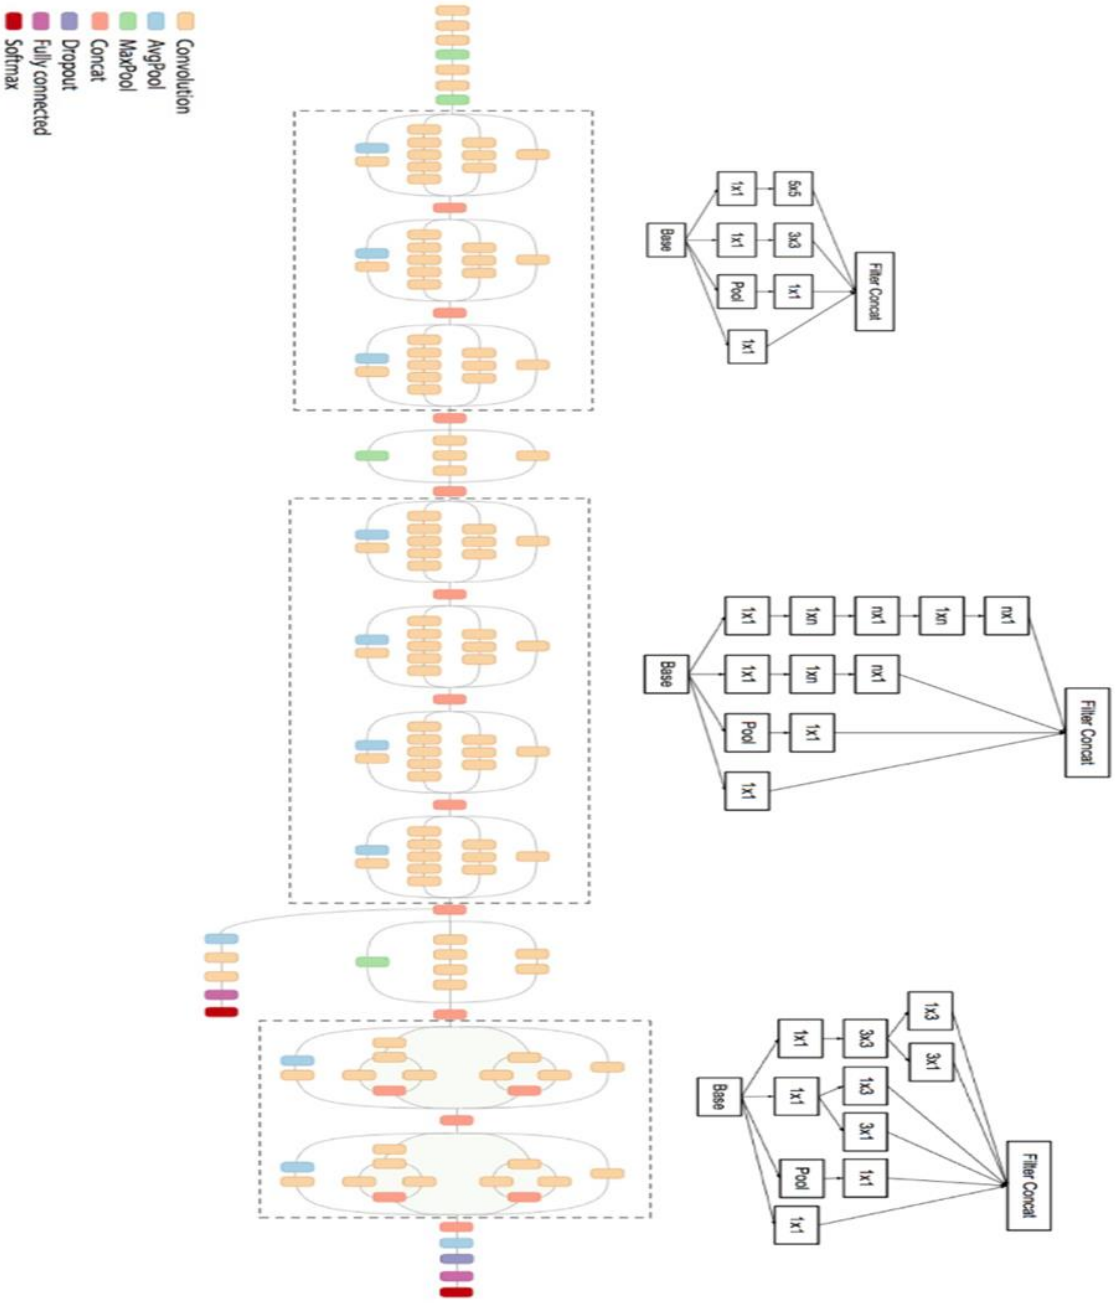
Tablo 4.1 Inception ağının mimarisi [52]

Tür	küme büyüklüğ/ kaydırma adımı	Verinin giriş boyutu
konv	3×3/2	299×299×3
konv	3×3/1	149×149×32
konv padded	3×3/1	147×147×32
Havuzlama	3×3/2	147×147×64
konv	3×3/1	73×73×64
konv	3×3/2	71×71×80
konv	3×3/1	35×35×192
3×Inception	Şekil 5-13	35×35×288
5×Inception	Şekil 5-15	17×17×768
2×Inception	Şekil 5-16	8×8×1280
Havuzlama	8 × 8	8 × 8 × 2048
linear	logits	1 × 1 × 2048
softmax	Sınıflandırıcı	1 × 1 × 1000

Inception v2 yapısı ile Inception v3 yapısı neredeyse aynıdır fakat bazı farkları bulunmaktadır.

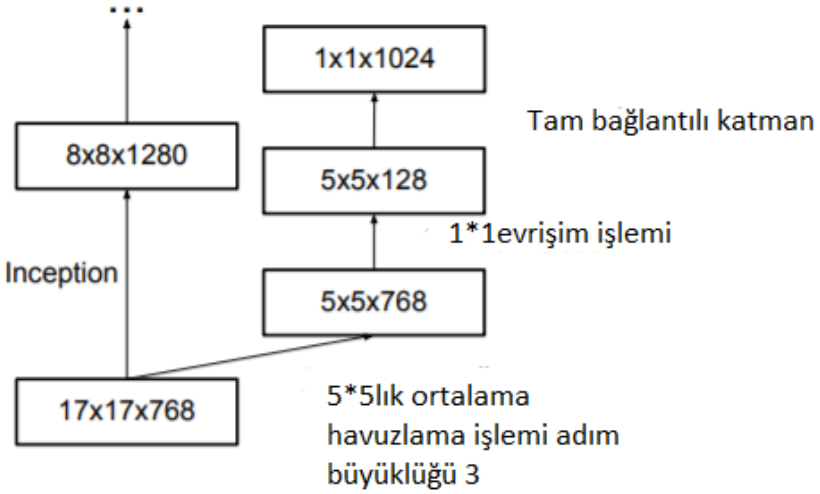
Farklılıklar şu şekildedir;

- RMSProp optimizasyonu
- 7*7 faktörize etmek
- Yardımıcı sınıflandırcıda (Auxillary classifier) yığın normalizasyonu kullanılması



Şekil 4.17 Inception v3 ağının mimarisi [53]

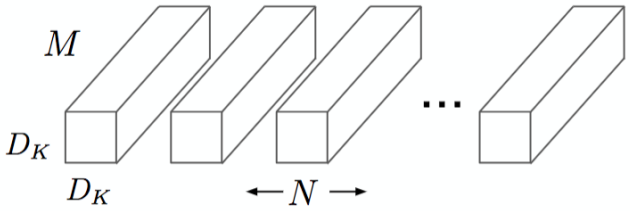
Farklı bir katman ise yardımcı sınıflandırıcı katmanıdır , bu katman ağın eğitim kısmında katkı sağlamamaktadır ancak Inception v3'de bir regulasyon rolü oynamaktadır [52].



Şekil 4.18 Yardımcı sınıflandırıcı şeması [52]

4.11 Mobilnet Ağı

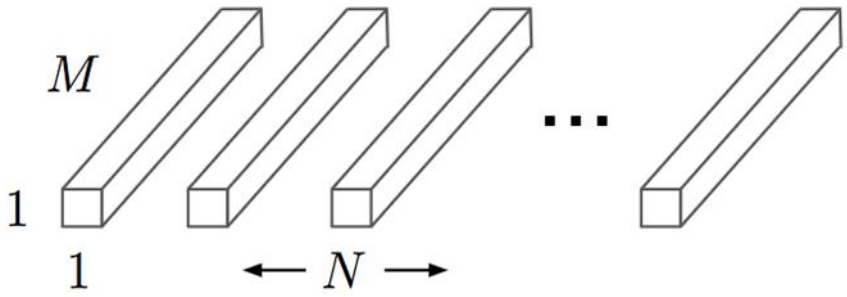
Mobilnet'deki evrişim işlemi değişikliği, Inception ve Resnet'te olduğu gibi konvolüsyon işleminden kaynaklıdır. Mobilnette evrişim yöntemi derinlemesine ayrılabilen evrişim (depthwise separable convolutions) olarak adlandırılır. Derinlemesine ayrılabilen evrişim işlemi ilk defa Xception ağında ortaya koyulmuştur. Standart evrişim işlemi uzaysal boyutta sadece öznitelik haritası (feature map) içerisinde giriş ve çıkış kanalları üzerinde çalışmaktadır. Standart evrişim sisteminde hesaplama maliyeti $Df^2 * M * N * Dk^2$ ile bulunur. Burada Df öznitelik haritasının boyutudur. M ve N giriş ve çıkış kanallarının sayısını ve Dk filtre boyutunu göstermektedir[54].



Şekil 4.19 Normal evrişim işlemi [54]

Derinlemesine ayrılabilen evrişim, iki aşamadan oluşmaktadır. Birincisi derinlemesine evrişim ikincisi noktasal evrişim olarak adlandırılır. Derinlemesine ayrılabilen evrişim işlemi her bir kanal için ayrı tek bir evrişim işlemi oluşturur. Dolayısıyla girişteki kanal sayısı çıkıştaki kanal sayısı ile eşitlenir.

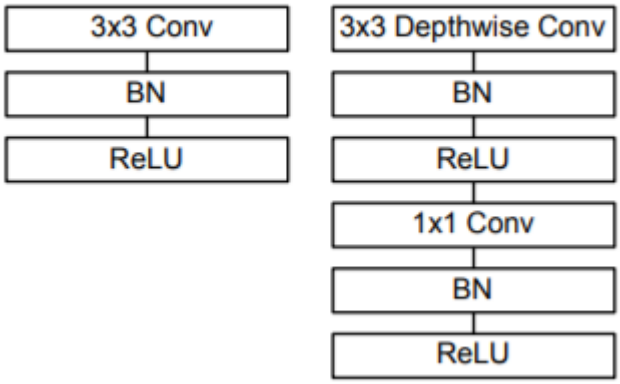
Hesaplama maliyeti $Df^2 * M * Dk^2$ ile ifade edilir. Bu evrişim yöntemi için bir diğer adım olan noktasal evrişim ağı kullanılmalıdır. Noktasaldan anlaşıldığı gibi 1*1 şeklinde evrişim işlemi yapılmaktadır. Bu 1*1 evrişim işleminin sonucu derinlemesine evrişim işleminin sonucuna eklenmektedir. Noktasal işlemin maliyeti ise $M * N * Df^2$ olmaktadır [54].



Şekil 4.20 Derinlemesine ayrılabilen evrişim işlemi [54]

Derinlemesine ayrılabilen evrişim işlemi uzaysal evrişim işlemi ile noktasal evrişim işleminin toplamına eşittir. Normal evrişim ile karşılaştırılmak istenirse $^1/_N + ^1/_{Dk^2}$ hesaplama maliyeti derinlemesine ayrılabilen evrişimde daha düşüktür. 3*3 kernel (çekirdek) ile normal evrişimden 8 kat daha az parametrede işlem

yapılmaktadır. Sonuç olarak normal ve derinlemesine ayrılabilen evrişim işlemi aşağıdaki şekilde daha açık olarak gösterilmiştir [54].



Şekil 4.21 Normal evrişim işlemi ile derinlemesine ayrılabilen evrişim işleminin farkı [54]

Mobilnet ağının telefonlarda çalışabilmesi için işlem yükünü azaltmak gerekmektedir. Bunun için genişlik çarpanı tanımlanmalı ve filtre kanallarının genişliği azaltılmalıdır. Genişlik çarpanı α (0-1) arasında bir sayıdır. Kanal sayısına çarpma işlemi yapılarak kanal sayısı incelenmektedir. Her katmanda N kanal yerine N* α alınarak işlem yapılır.Derinlemesine ayrılabilen evrişim işlemi α ile çarpıldıktan sonra işlem maliyeti eşitlik 4.24 ile hesaplanmaktadır.

$$D_k . D_k . \alpha M . D_F . D_F + \alpha M . \alpha N . D_F . \mathrm{D_F} \tag{4.24}$$

Hızı artırmak için ve hesaplama maliyetini düşürmek için çözünürlük çarpanı ρ görüntülerin girişlerine ve ara katmalara çarpan olarak eklenmektedir ve ρ 'nun aldığı değerler 0-1 aralığında olmaktadır. Bu eklentiden sonra hesaplama maliyeti eşitlik 4.25 gibi oluşmaktadır.

$$D_k . D_k . \alpha M . \rho D_F . \rho D_F + \alpha M . \alpha N . \rho D_F . \rho D_F \tag{4.25}$$

Mobilnetin mimarisi Tablo 4.2'de verilmiştir [54].

Tablo 4.2 Mobilnet ağının mimarisi [54]

Tür/ Kaydırma Adımı	Filtre biçimi	Giriş boyutu
Conv2/s2	3*3*3*32	224*224*3
Conv dw/ s1	3*3*32 dw	112*122*32
Conv /s1	1*1*32*64	112*112*32
Conv dw/ s2	3*3*64 dw	112*112*64
Conv /s1	1*1*64*128	56*56*64
Conv dw/ s1	3*3*128 dw	56*56*64
Conv /s1	1*1*128*128	56*56*128
Conv dw/ s2	3*3*128 dw	56*56*128
Conv /s1	1*1*128*256	28*28*56
Conv dw/ s1	3*3*256 dw	28*28*56
Conv /s1	1*1*256*256	28*28*256
Conv dw/ s2	3*3*256 dw	28*28**256
Conv /s1	1*1*256*512	14*14*256
5*(Conv dw/ s1 Conv/s1)	3*3*512 dw 1*1*512*512	14*14*512 14*14*512
Conv dw/s2	3*3*512*dw	14*14*512
Conv /s1	1*1*512*1024	7*7*512
Conv dw/s2	3*3*1024 dw	7*7*1024
Conv /s1	1*1*1024*1024	7*7*1024
Avg Pool / s1	Havuzlama 7*7	7*7*1024
Fc/s1	1024*1000	1*1*1024
Softmax/s1	Sınıflandırıcı	1*1*1000

5

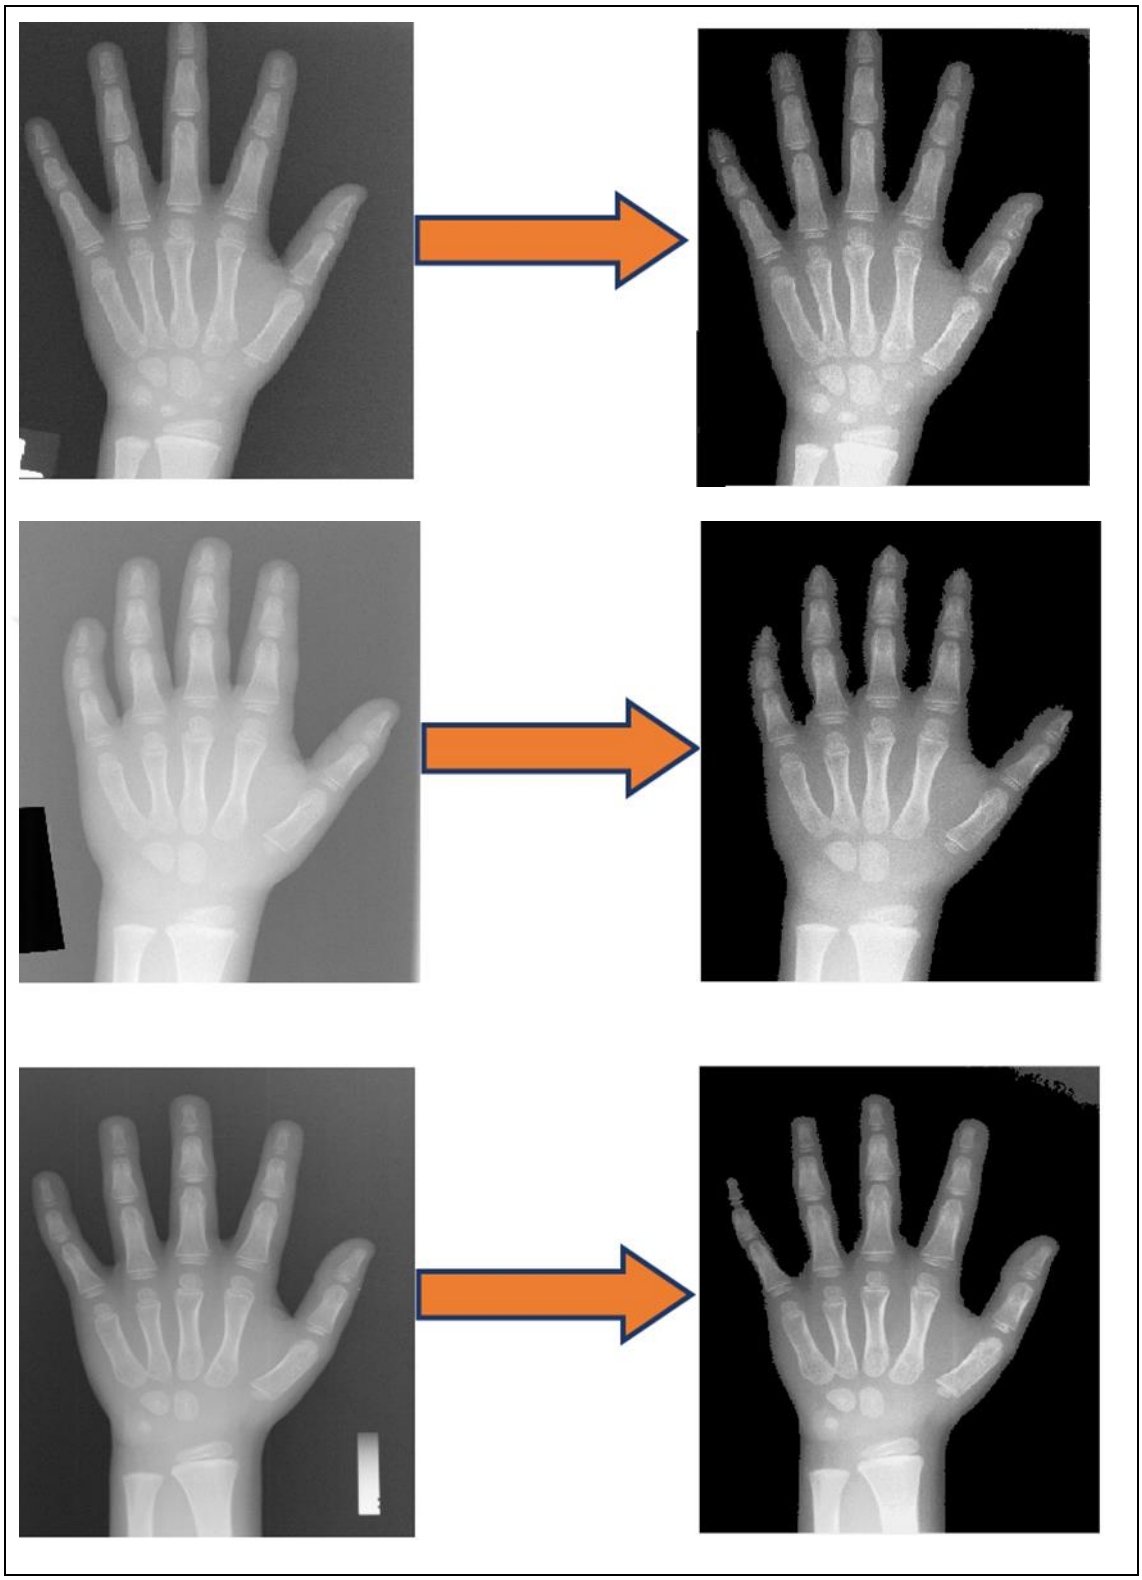
Sonuçlar ve Öneriler

5.1 Sonuçlar ve Öneriler

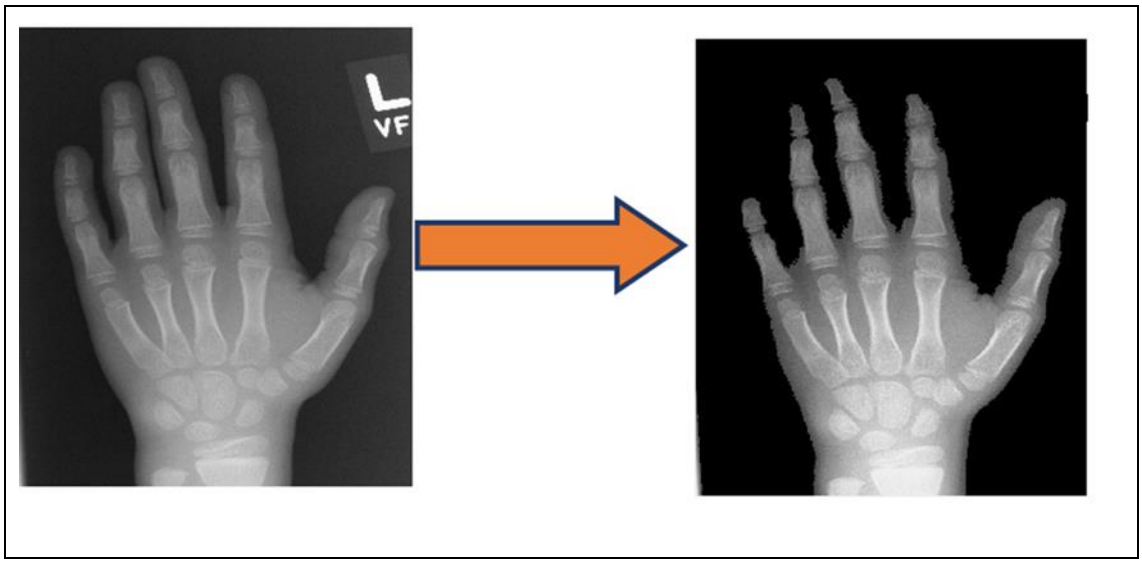
Bu bölümde veri setine uygulanan yöntemler ve elde edilmiş sonuçlar açıklanmaktadır. Veriler üzerinde ilk olarak ikili segmentasyon işlemi uygulanır. İkili segmentasyon ile görüntüdeki elin etrafındaki gereksiz bilgilerden kurtulmak için histogram eğrisi incelenir sonra histogram eğrisine göre bir eşik değeri verilip elin maskesi çıkartılır. Verilen eşik değeri tüm görüntüler üzerinde histogram eşitliği yapıldıktan sonra uygulanmaktadır. Şekil 5.1'de görüldüğü gibi ilk olarak elin sınırları çizilmektedir sonra histogram eğirisi incelenmektedir, elin eşik değeri belirlendikten sonra maske yapılarak el gürültüsüz hale getirilmektedir.



Şekil 5.1 Görüntüleri gereksiz bilgilerden arındırma



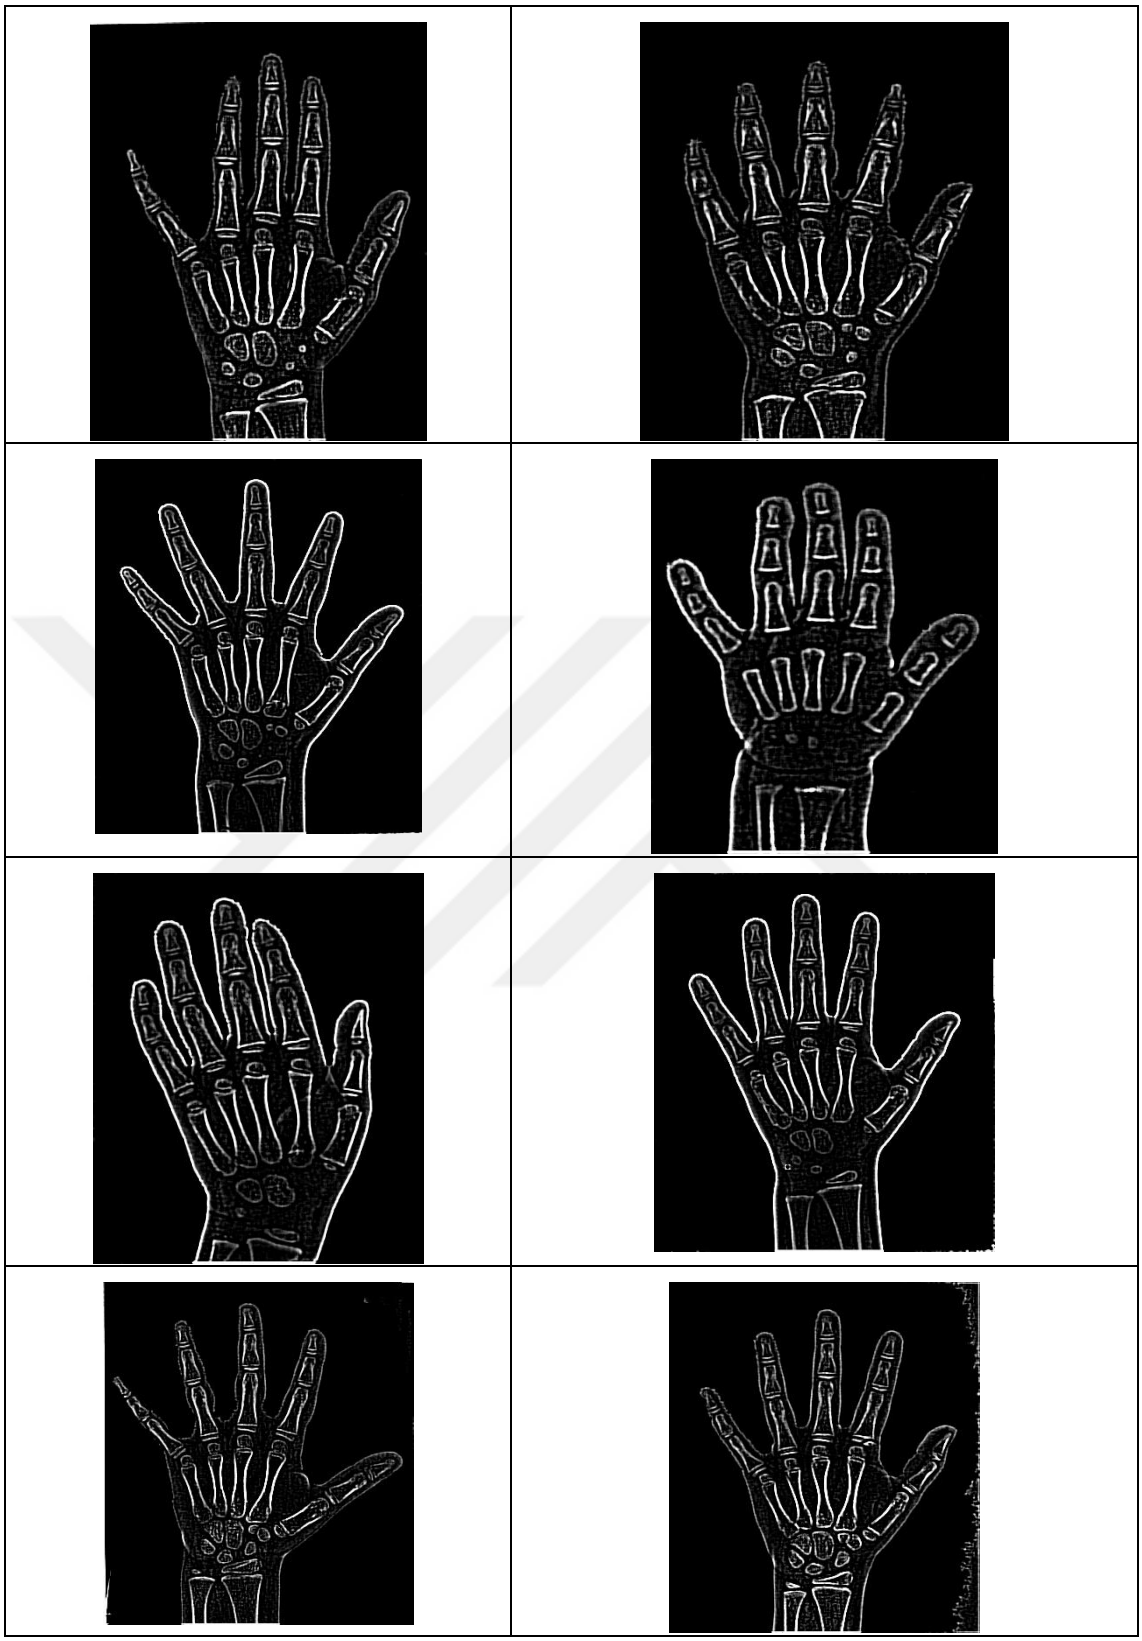
Şekil 5.2 İkili segmentasyondan birkaç örnek



Şekil 5.3 İkili segmentasyondan birkaç örnek (devamı)

Şekil 5.2 ve 5.3'de ikili segmentasyon yapıldıktan sonra elin etrafındaki görüntüler ortadan kalkmaktadır ancak bazen elin bazı kısımlarını da etkileyip dokuların bir kısmını da ortadan kaldırmaktadır.

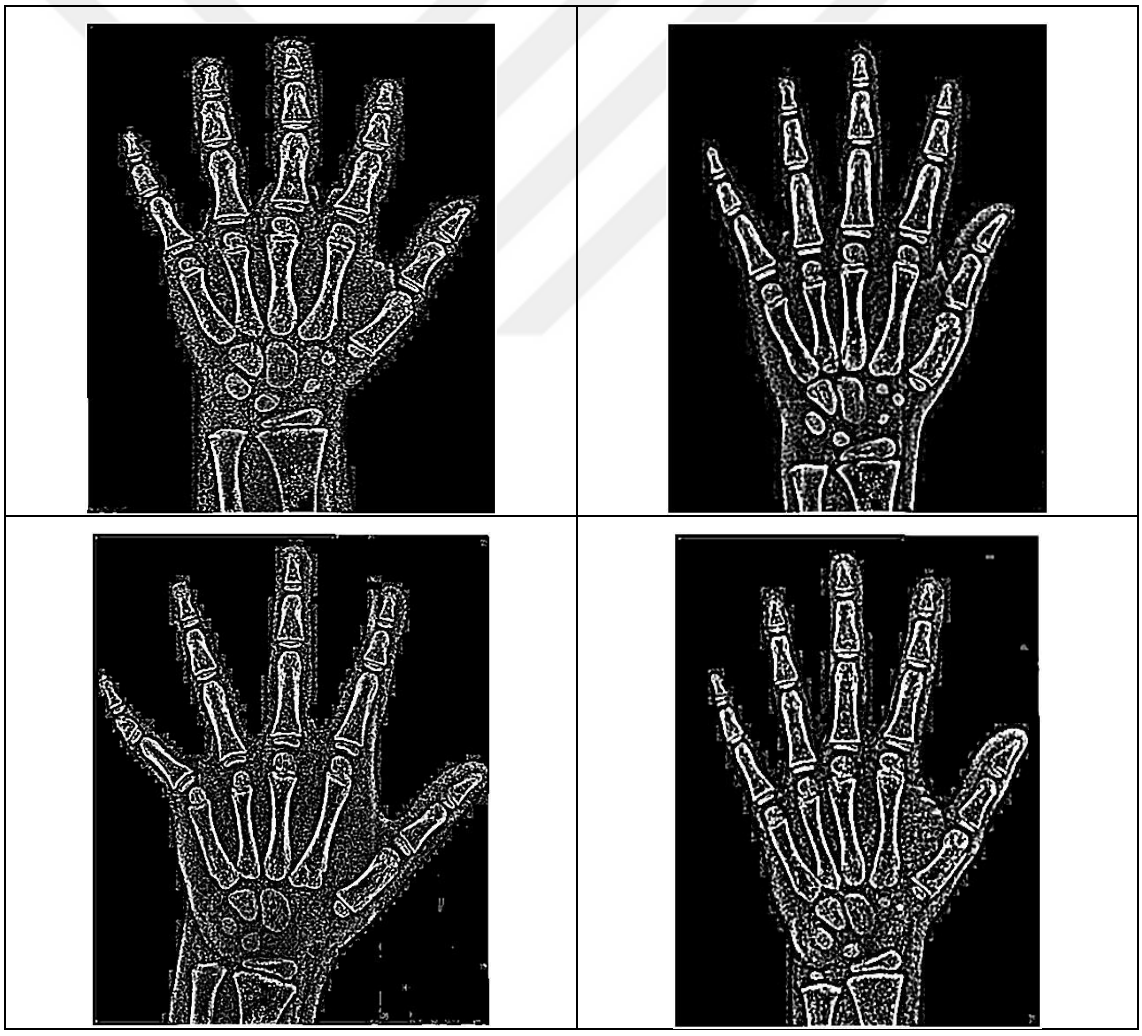
İkinci aşamada değişik filtreler veri seti üzerinde uygulanmıştır. Burada ilk olarak Diferansiyel Gauss Filtresi kullanılmıştır. Bant geçiren bu filtre için iki farklı sigma değeri ile ($\sigma_1 = 10$ ve $\sigma_2 = 40$) işlem yapılmıştır. Bu görüntüler Şekil 5.4'de verilmiştir.



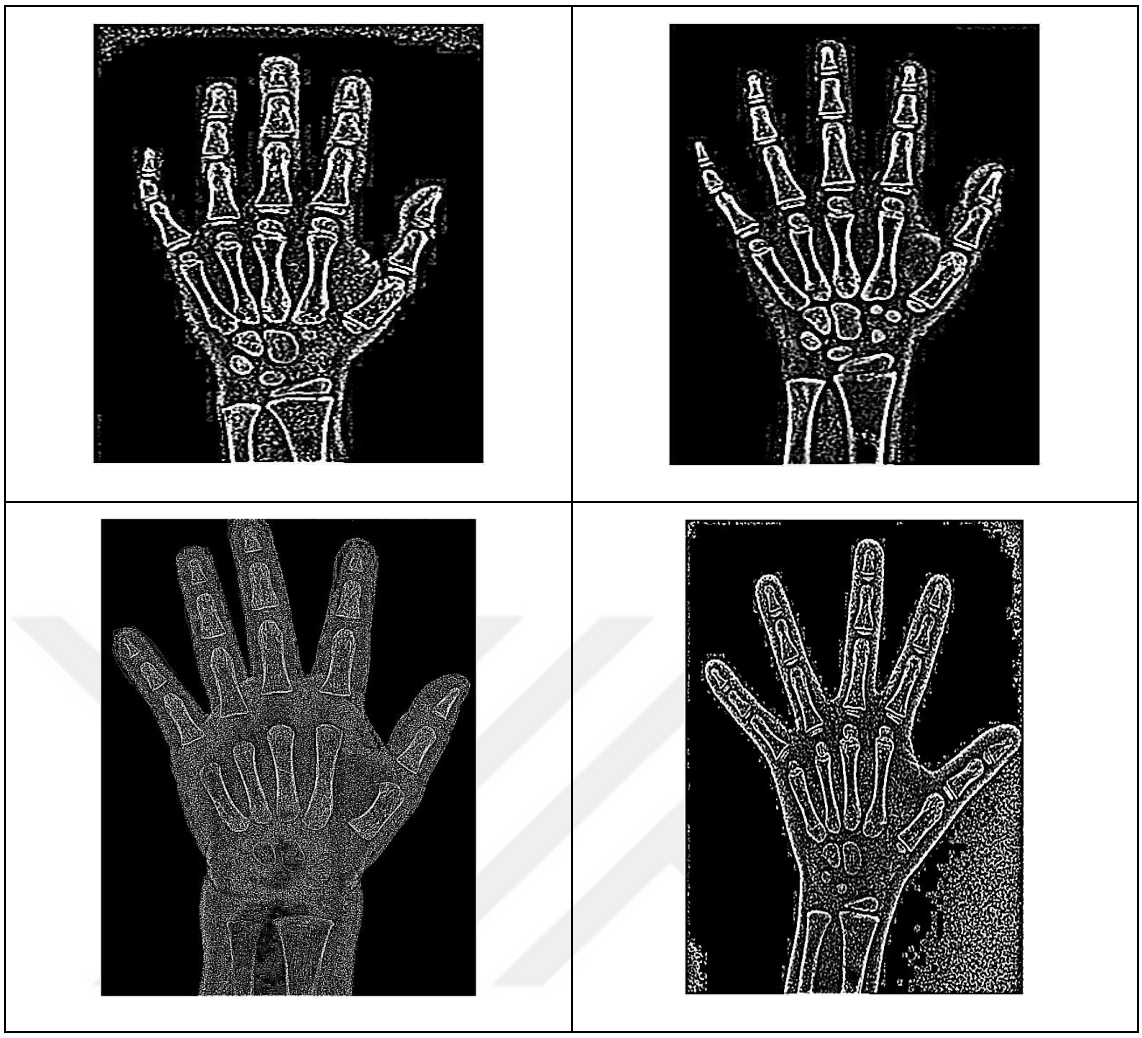
Şekil 5.4 Difransiyel Gauss yöntemi ile elde edilen sonuçlar

Görüldüğü gibi Diferansiyel Gauss Filtresinde elin kemik ve dokuları çok açık ve net bir şekilde ortaya çıkarmaktadır. Bunun yanında filtre büyük bir ölçekte gürültüleri azaltmaktadır. Dolayısıyla bu filtre elin kemik kısımlarını ve dokularını ortaya çıkararak konvolüsyonel sinir ağlarında özellik haritası çıkarılması için yardımcı olmaktadır. Diferansiyel Gauss Filtresi dokuları, kenarları ve elin sınırlarını çok belirgin bir şekilde ve az gürültülü olarak ortaya çıkarıp kemik yaşı tespitini daha kolaylaştırmaktadır. Ancak bazen görüntülerde görüldüğü gibi kenarlarda küçük gürültüler oluşturmaktadır.

Üçüncü aşamada À Trous dalgacık dönüşüm yöntemi uygulanarak elde edilen görüntüler incelenmektedır. À Trous dalgacık dönüşümü bir alçak geçiren filtredir ve görüntülerde kenarları bulmak için kullanılmaktadır.



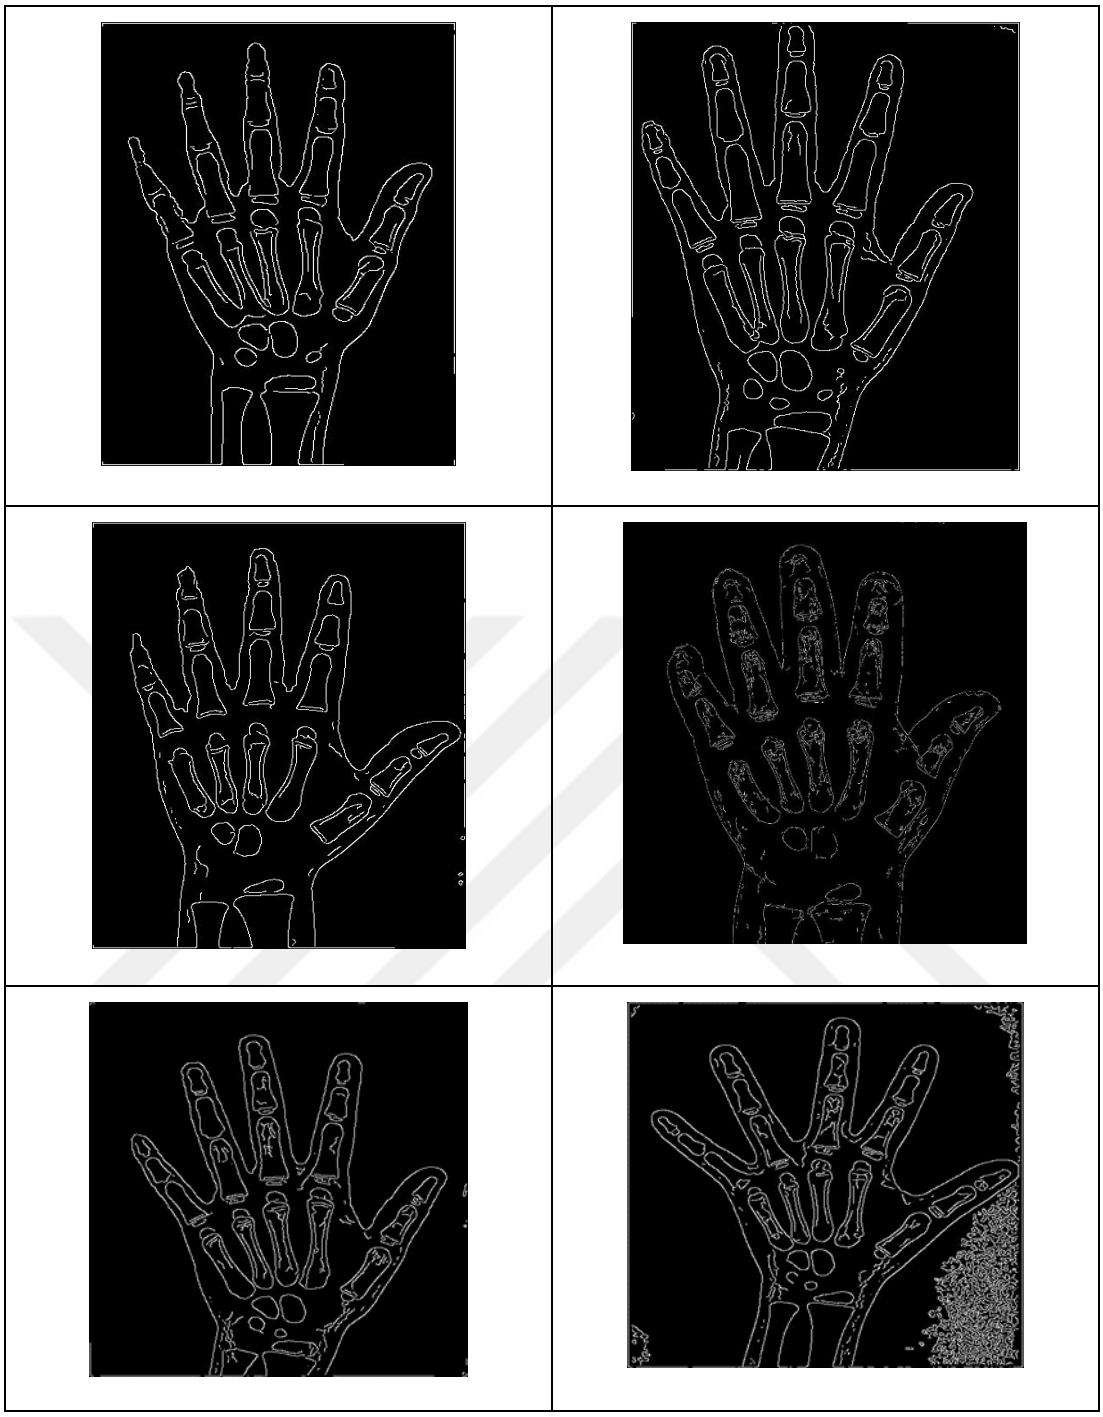
Şekil 5.5 À Trous dalgacık dönüşümü yöntemi ile elde edilen sonuçlar



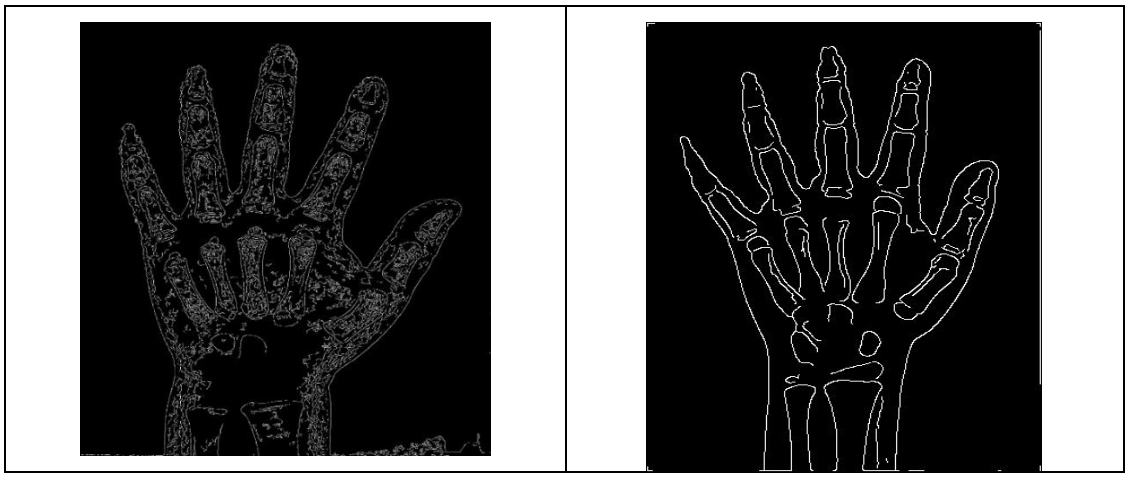
Şekil 5.6 À Trous dalgacık dönüşümü yöntemi ile elde edilen sonuçlar (devamı)

Şekil 5.5 ve 5.6'da görüldüğü gibi À Trous dalgacık dönüşüm filtresi el kemiklerini ve dokuları ortaya çıkartmaktadır. Ancak el radyolojisi görüntülerindeki gürültü miktarının çok olması evrişimsel sinir ağlarının sonucunu etiklemektedir.

Kullanılan diğer bir yöntem ise Canny kenar belirleme yöntemidir. Bu yöntem ile elde edilen sonuçlar Şekil 5.7 ve 5.8'de gösterilmektedir.



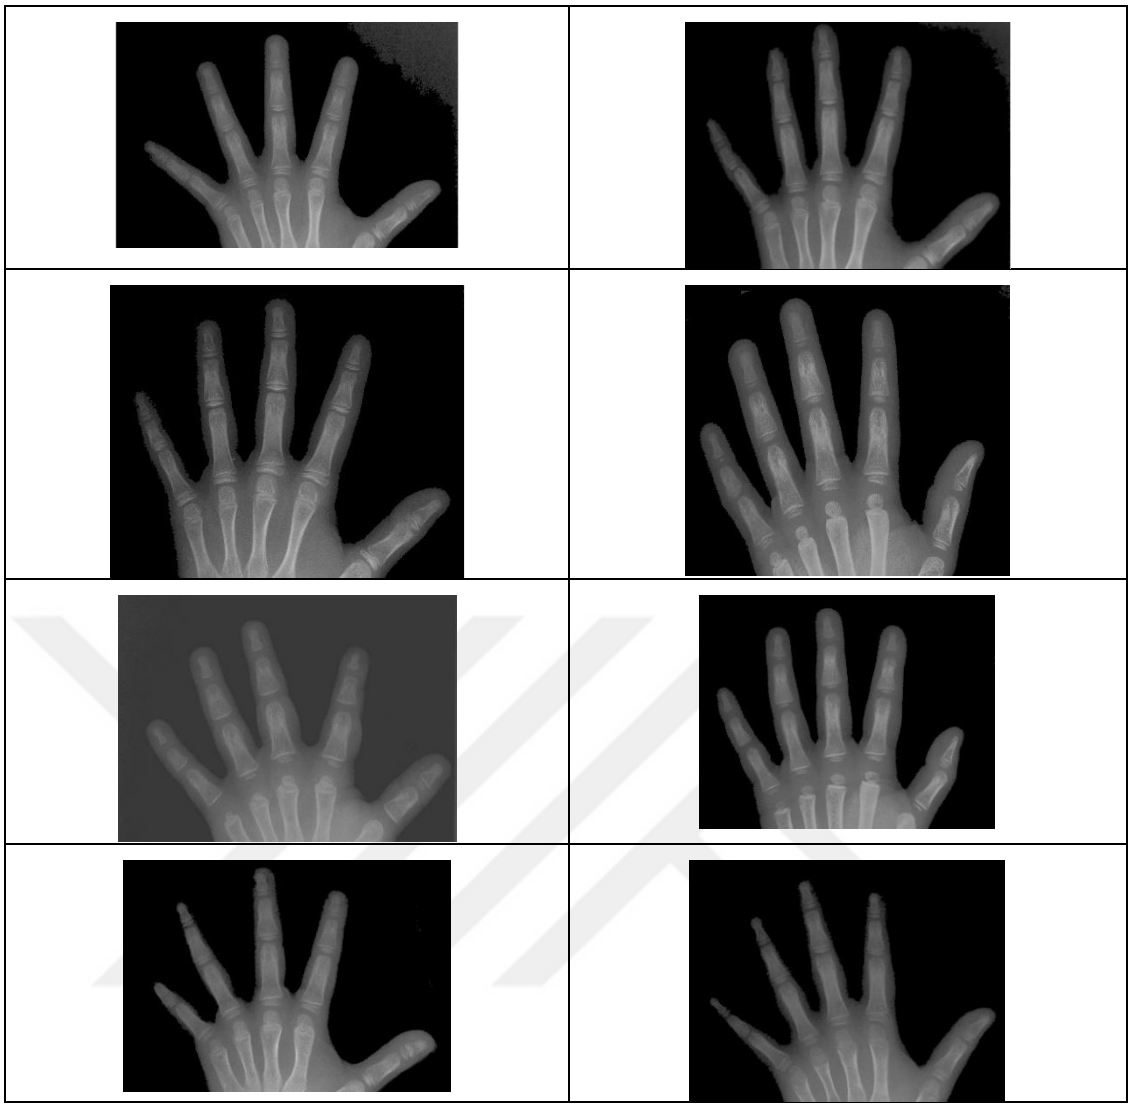
Şekil 5.7 Canny kenar belirleme yöntemi ile elde edilen sonuçlar



Şekil 5.8 Canny kenar belirleme yöntemi ile elde edilen sonuçlar (devamı)

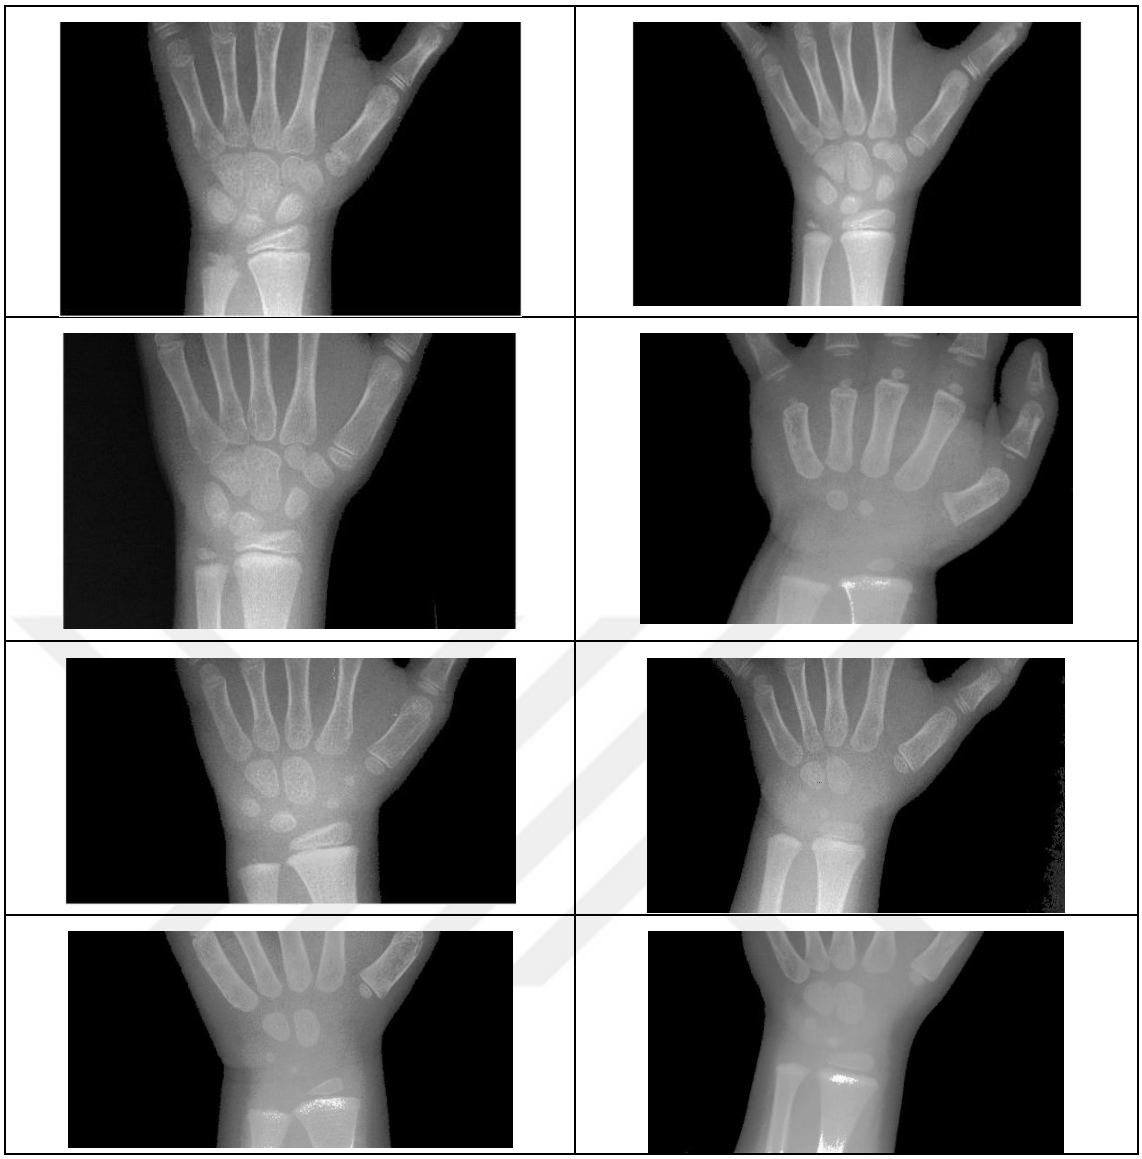
Canny kenar belirleme yöntemi diğer kenar bulma yöntemlerine göre görüntüyü çok daha az gürültülü şekilde ortaya çıkartmaktadır. Dokular bu yöntemde diğer kenar çıkarma yöntemlerine göre daha az belirgin olmaktadır. Daha çok elin kenar ve kemik yapısı ortaya konulmaktadır. Bu yöntemde görüntülere iki farklı eşik değeri uygulanır, bu değerler 0.085 , 0.01'dir. Yöntemde bu değerden daha küçük olan gradyan değerleri dikkate alınmaz.

Bir sonraki aşamada ikili segmentasyon yapılmamış görüntüler iki kısma ayrılarak her bir kısmın kemik yaşı tespiti üzerindeki etkisi incelenmiştir. İlk önce elin üst bölgesi (metakarpal va parmakların kemiklerini dahil ederek) için bu incelemeler üç farklı konvolüsyonel sinir ağında yapılmıştır sonra karpal kısmındaki kemikleri inceleyerek bu bölgedeki gelişimin yaş tespiti üzerindeki etkisi incelenmiştir. Metakarpal ve karpal bölgelerdeki incelemeler için erkek, kadın ve erkek kadın birlikte üç farklı kategori ve üç farklı konvolüsyonel sinir ağı kullanılarak toplam 18 farklı sonuç elde edilmiştir. Şekil 5.9 ve 5.10'da karpal ve metarkarpal bölgeler için görüntüler sunulmuştur.



Şekil 5.9 Elin metakarpal bölgesi ve parmak kemiklerinin bulunduğu kısım

Diğer kısımda ise karpal bölgesinin yaş tespitindeki etkisi incelenmiştir.



Şekil 5.10 Elin karpal bölgesindeki kemikler

Verilen tüm şekilerdeki el görüntüleri üç farklı ağda üç grupta incelenmiştir. Bahsedilen üç ağ farklı yapılara ve farklı parametre sayılarına sahiptir. İncelemeler kadın, erkek ve erkek kadın olarak ayrılan veri setleri üzerinde yapılmıştır. Sonuçlar için 7.9 aylık fark ile yani 7.9 ay hata ile kabul edilebilecek şekilde yaş tespiti gerçekleştirilmiştir. 0-7 yaş aralığında olan el görüntüleri dört sınıfa ayrılarak 9-25, 26-42, 43-59, 60-80 aylarında olan çocukların görüntüleri incelenmiştir. Inception v3 Resnet50 ve Mobilnet ağlarının kaç hesaplama parametresine sahip oldukları Tablo 5.1'de gösterilmektedir. Hesaplama parametreleri ne kadar az olursa sınıflandırma işlemi o kadar hızlı bir şekilde gerçekleşmektedir.

.

Tablo 5.1 Farklı ağların parametre sayısı

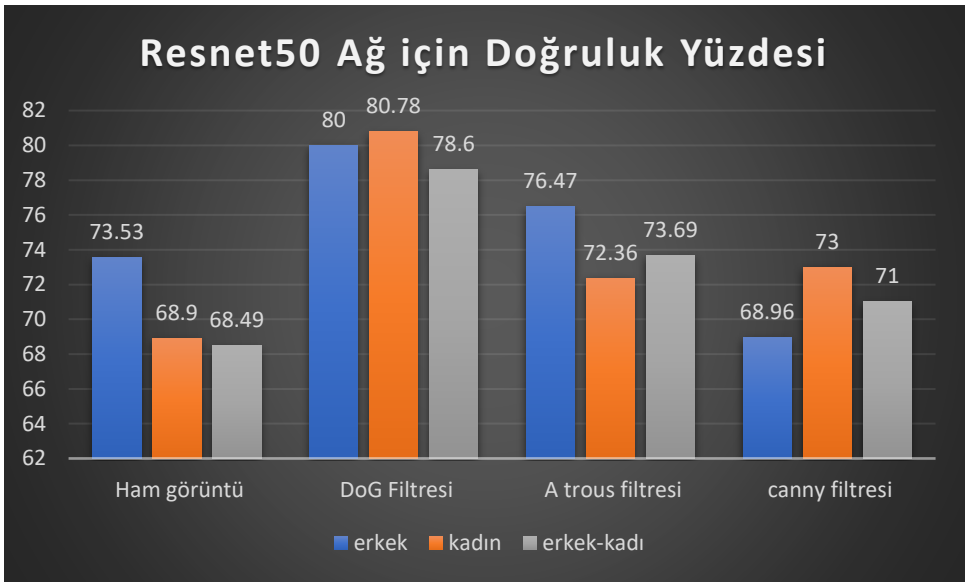
Evrişim ağı	Inception V3	Resnet50	MobilnetV2
Parametre sayısı	23,116,580	75,233,156	4,018,372

Eğitim işlemi 800-1000 iterasyonda ancak bazı durumlarda 2000-3000 iterasyonda gerçekleşmiştir. Eğitimde SGD optimizsayon parametresi 0,007 ve momentum katsayısı 0,9 olarak kullanılmıştır. Eğitim %80 veri seti ile gerçekleşmiş, %20 veri seti ile test yapılmıştır.

À Trous, DoG ve Canny filtreleri ile elde edilen sonuçlar erkek, kadın, erkek-kadın olmak üzere üç farklı kategoride ve üç farklı ağda incelenmiştir. İlk olarak Resnet50'den alınan sonuçlar Tablo 5.2'de gösterilmiştir.

Tablo5.2 Resnet50 ağı için elde edilen doğruluk yüzdeleri

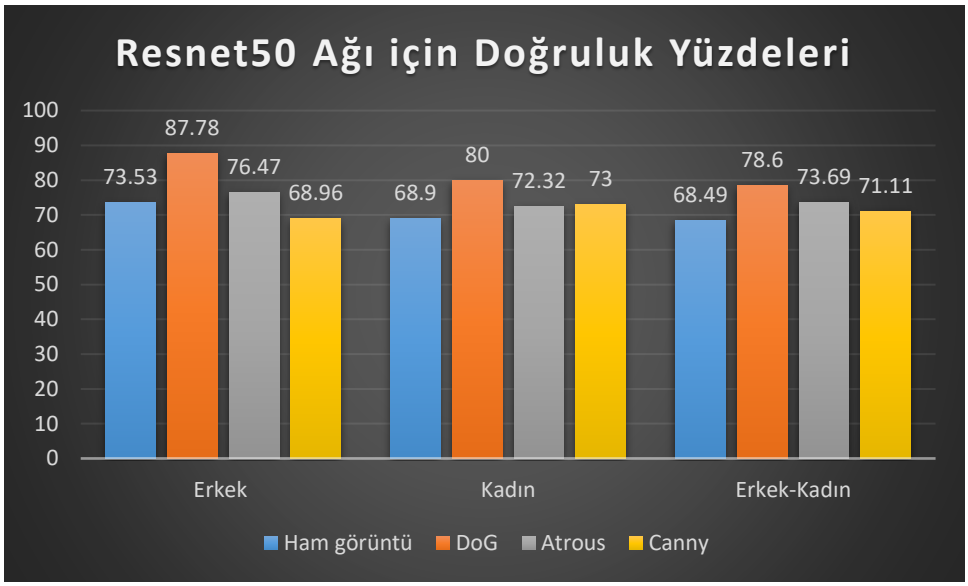
Resnet50 Ağı	Erkek Doğruluk Oranı (%)	Kadın Doğruluk Oranı (%)	Erkek_Kadın beraber Doğruluk Oranı (%)
Canny Filtresi	68,96	73	71
DoG Filtresi	80	80.78	78,6
À Trous Filtresi	76,47	72,36	73,69
Ham Görüntü	73,53	68,9	68,49



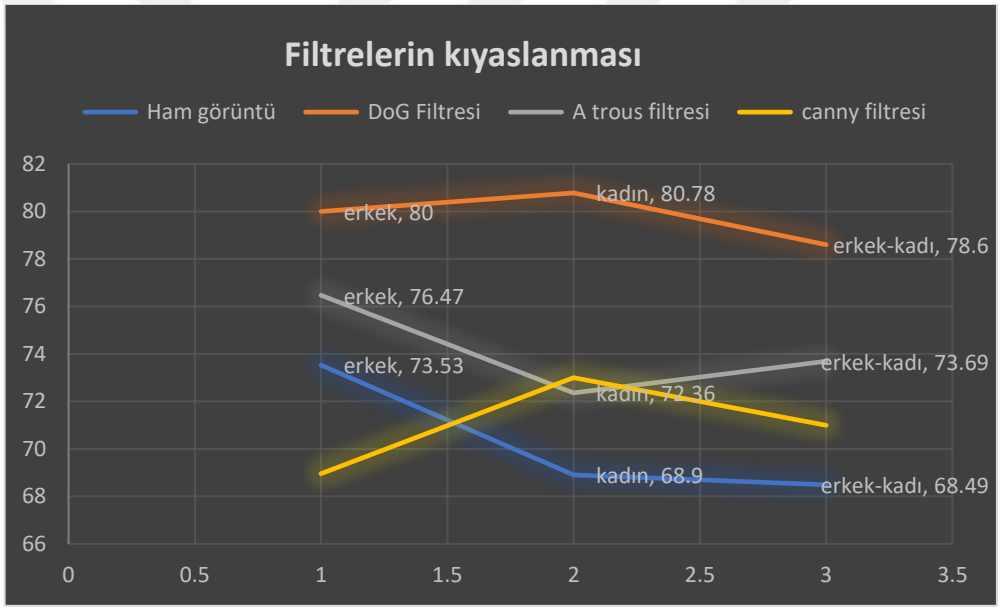
Şekil 5. 11 Filtrelere göre Resnet50 ağı için elde edilen doğruluk yüzdeleri

Şekil 5.11'de görüldüğü gibi Resnet50 ağında en büyük doğruluk değeri DoG filtresi uygulanmış veri seti üzerinde elde edilmiştir.

DoG filtresi ham görüntüye nazaran dokular ve kemikler için daha çok bilgi vermektedir. Bant geçiren bir filtre olduğu için hem À Trous dalgacık dönüşüm yönteminden hem de Canny filtresinden daha çok bilgi sunmaktadır. Canny filtresi kemik kenarlarını ortaya çıkarmakta ancak DoG ve À Trous'a dalgacık dönüşümü yöntemine göre daha az bir bilgi sunmaktadır. Ham görüntü görüldüğü gibi en az yüzdeye sahip olan veri setidir çünkü ağ bu görüntüden gerekli bilgileri ortaya çıkaramamaktadır. À Trous filtresi kullanıldığında ise DoG filtresinden daha çok gürültü oluşmaktadır. Dolayısıyla Resnet50 ağında DoG'dan daha az doğruluk değerine sahip olmaktadır. Filtrelerin uygulanması ile Resnet50 ağı istenen bilgilere ulaşabilmekte ve sınıflandırma işlemini yapabilmektedir.



Şekil 5.12 Cinsiyete göre Resnet50 ağı için elde edilen doğruluk yüzdeleri



Şekil 5. 13 Resnet50 Ağı için filtrelerin ve cinsiyetin etkisi

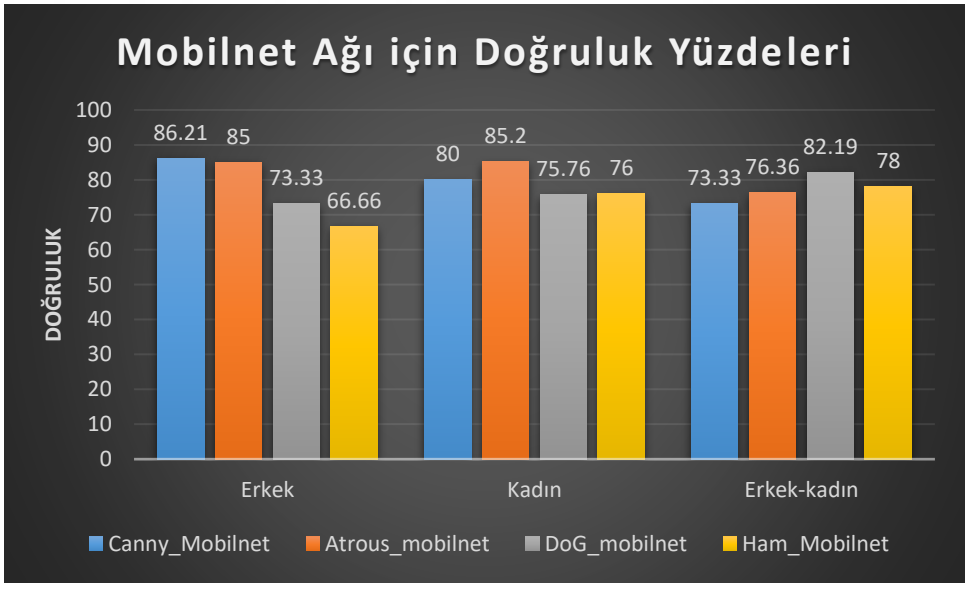
Şekil 5.12 ve 5.13'da görüldüğü gibi DoG filtresi bu ağ için daha iyi sonuç vermektedir. Cinsiyet ile incelendiği zaman erkek kategorisi için daha iyi sonuçlar alınmıştır. Bu durum ağın yapısı ile ilgili bir durum olarak değerlendirlebilir.

Aynı işlemler Mobilnet ağı ile yapılmıştır ve elde edilen sonuçlar Tablo 5.3'te verilmiştir.

Tablo 5.3 Mobilnet ağı için elde edilen doğruluk yüzdeleri

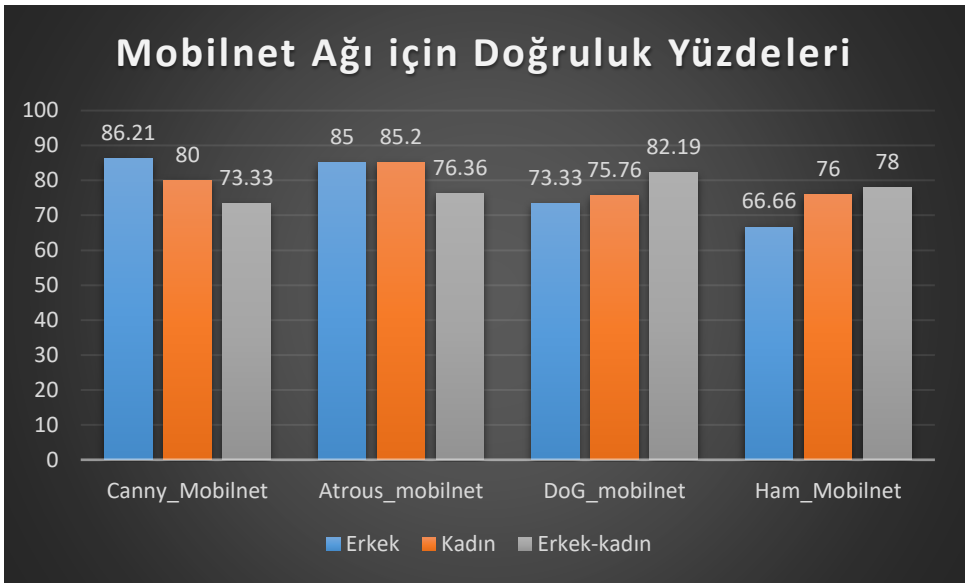
Mobilnet Ağı	Erkek Doğruluk Oranı (%)	Kadın Doğruluk Oranı (%)	Erkek_Kadın beraber Doğruluk Oranı (%)
À Trous Filtresi	85	85,2	76,36
DoG Filtresi	73,33	75,76	82,19
Canny Filtresi	86,21	80	73,33
Ham Görüntü	66,66	76	78

Mobilnet ağında sınıflandırma yüzdeleri birbirlerine çok yakın çıkmıştır. Bunun aşikar bir nedeni derinlemesine evrişim işlemi gerçekleşmesinden dolayı bu ağın farklı filtrelerde istediği tüm bilgilere ulaşmasıdır. Dolayısıyla filtreler için elde edilen doğruluk yüzdeleri yakın olmakta ancak ham görüntüde daha düşük doğruluk değeri elde edilmektedir. Bunun sebebi filtrelerin özellikleri çıkarak Mobilnet ağının bu kararı vermesine yardımcı olmasıdır.



Şekil 5. 14 Cinsiyete göre Mobilnet ağı için elde edilen doğruluk yüzdeleri

Şekil 5.14'e göre en yüksek doğruluk değeri Mobilnette erkek ve Canny filtresinde, en düşük doğruluk değeri ise erkek ve ham görüntüde elde edilmektedir.



Şekil 5. 15 Filtrelere göre Mobilnet ağı için elde edilen doğruluk yüzdeleri

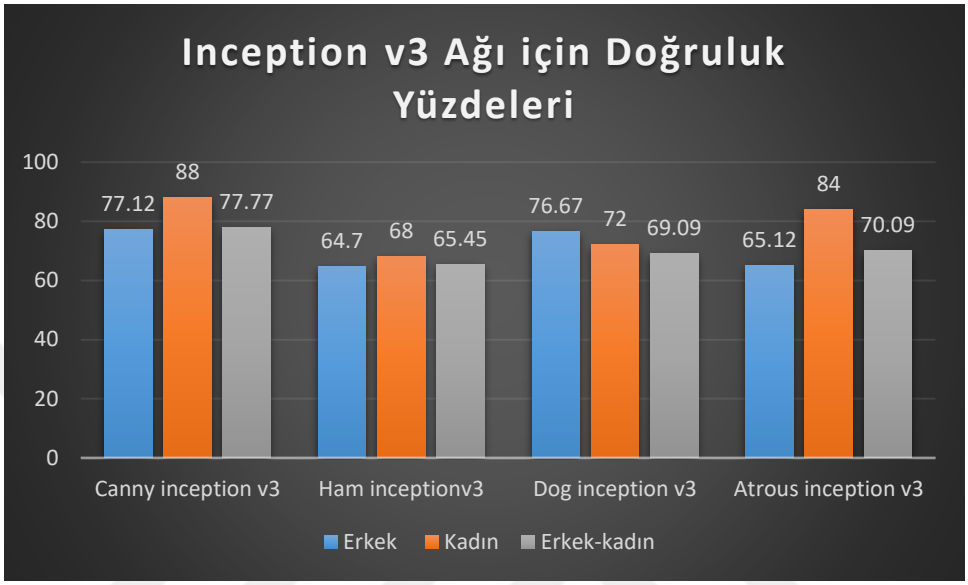
Farklı bir bakış açısıyla bakıldığında ise Şekil 5.15'de görüldüğü gibi DoG filtresinde ve ham görüntüde erkek ve kadın veri seti beraber kullanıldığı zaman daha iyi sonuç elde edilmektedir. Diğer filtreler ile erkek ve kadın veri setleri ayrı ayrı kullanıldığında daha iyi sonuç alınmaktadır.

Son olarak Inception v3 ağı için elde edilen doğruluk yüzdeleri Tablo 5.4 de sunulmuştur.

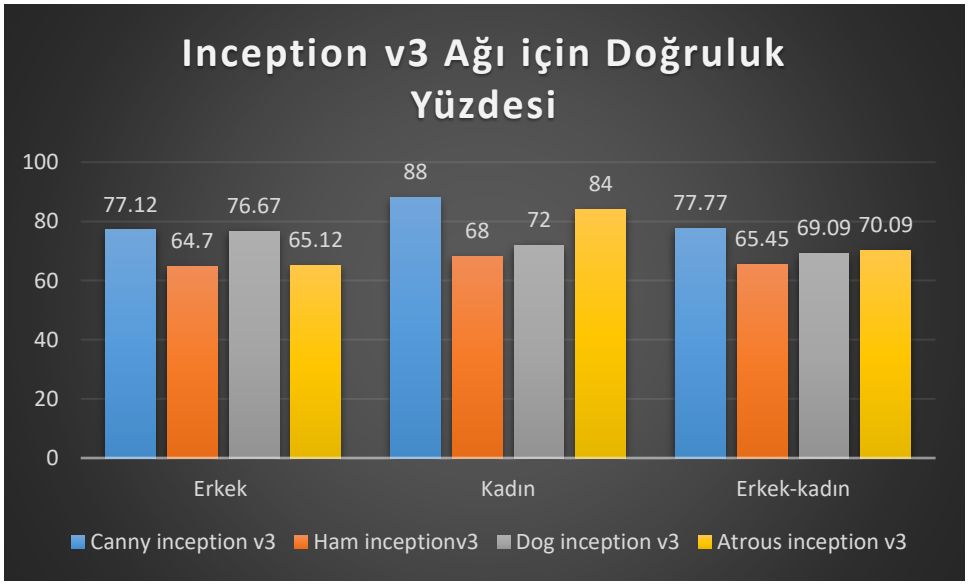
Tablo 5.4 Inception v3 ağı için elde edilen doğruluk yüzdeleri

Inception v3 Ağı	Erkek Doğruluk Oranı (%)	Kadın Doğruluk Oranı (%)	Erkek_Kadın beraber Doğruluk Oranı (%)
Canny Filtresi	77,12	88,00	77,77
Ham Görüntü	64,7	68,00	65,45
DoG Filtresi	76,67	72,00	69,09
À Trous Filtresi	65,12	84,00	70,09

Tablo 5.4 ve Şekil 5.16 de görüldüğü üzere Inception v3 modelinde en yüksek doğruluk değeri kadın veri seti için kullanılan Canny filtresi ile elde edilmiştir. Genel anlamda da Canny filtresi ile en yüksek doğruluk değerlerine ulaşılmıştır.Inception v3'de farklı çekirdek boyutları kullanılarak hem global hem de lokal özellikler çıkartılmış ve sınıflandırma işlemi yapılmıştır.



Şekil 5.16 Filtrelere göre Inception v3 ağı için elde edilen doğruluk yüzdeleri

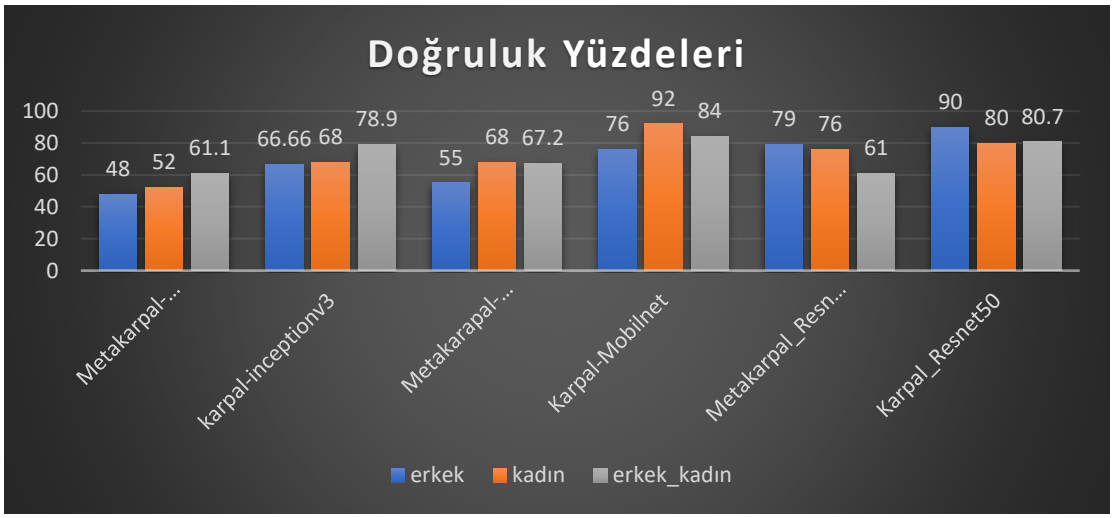


Şekil 5.17 Cinsiyete göre Inception v3 ağı için elde edilen doğruluk yüzdeleri

Yaş tespiti için farklı filtreler ve ağlar kullanarak elin özellik haritası kolay bir şekilde ortaya çıkartılmış, evrişimsel ağların yüksek bir doğruluğa ulaştığı görülmüştür. Bu analizlerde elin hangi kısmının yaş tespiti için daha uygun olduğu araştırılmıştır. Bunun için eli iki kısma bölerek karpal ve metakarpal bölgelerine işlemler ayrı ayrı olarak uygulanmıştır. Tablo 5.5'de her bir ağda karpal ve metakarpal kısımlar için elde edilen doğruluk oranları verilmiştir.

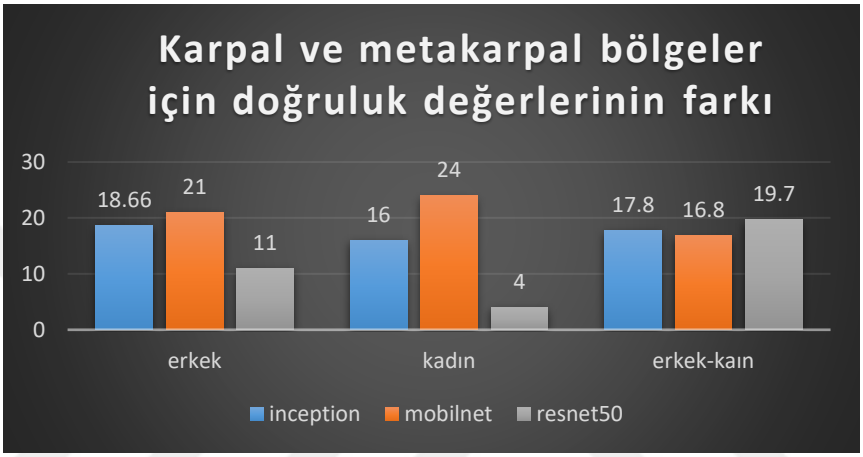
Tablo 5.5 Karpal ve metakarpal bölgelerin yaş tespitinde incelenmesi

Ham görüntünün karpal ve metakarpal bölgeleri	Erkek Doğruluk Oranı (%)	Kadın Doğruluk Oranı (%)	Erkek_Kadın beraber Doğruluk Oranı (%)
Metakarpal-Inceptionv3	48.00	52.00	61,1
Karpal-Inceptionv3	66,66	68.00	78,9
Metakarpal-Mobilnet	55.00	68.00	67,2
Karpal-Mobilnet	76.00	92.00	84.00
Metakarpal-Resnet50	79.00	76.00	61.00
Karpal-Resnet50	90.00	80.00	80,7



Şekil 5.18 Karpal ve metakarpal bölgeler için filtrelere göre elde edilen doğruluk yüzdeleri

Şekil 5.18'de görüldüğü gibi karpal ve metakarpal arasında %4'den %24'e kadar ulaşan doğruluk artışı oluşmuştur. Bu sonuçlardan yola çıkarak karpal bölgenin yaş tespiti için daha önemli ve değerli bilgiler sunduğu söylenebilir. Bu bölgede genelde Hamate, Triquetrum, Pisiform, Lunate, Capitate gibi kemikler bulunmaktadır. Bu kemikler doğuştan itibaren 18 yaşına kadar gelişmektedir. Bu kemiklerin evrişimsel sinir ağlarının yaş tepsiti için diğer bölgelere göre daha çok etkisi olmaktadır. Karpal ve metakarpal bölgeler için doğruluk değerleri arasındaki fark Şekil 5.19'da gösterilmiştir.



Şekil 5.19 Karpal ve metakarpal bölgeler için doğruluk değerlerinin farkı

Aynı veri seti üzerinde değişik ağların ne kadar fark oluşturduğu Tablo 5.6 ve Tablo 5.7'de gösterilmektedir.

İlk olarak Resnet50 ağı ile Inception v3 ağı arasındaki fark incelenerek Tablo 5.6 da sunulmuştur.

Tablo 5.6 Resnet50 Ağı ve Inception v3 Ağı arasındaki doğruluk yüzdesi farkı

Resnet50-InceptionV3	Erkek	Kadın	Erkek_Kadın
Ham Görüntü	8,83	0,9	3,04
DoG Filtresi	11,11	8	9,51
À Trous Filtresi	11,35	-11,68	3,6
Canny Filtresi	-8,16	-15	-6,66

Tablo 5.6 incelendiğinde Resnet50'nin genel olarak Inception v3'den daha çok doğruluk yüzdesine sahip olduğu, ancak Inception v3'ün Canny filtresinde Resnet50'ye göre daha yüksek doğruluk değeri ürettiği görülmektedir.

İkinci olarak Resnet50 ağı ile Mobilnet ağı arasındaki fark incelenerek Tablo 5.7'da sunulmuştur.

Tablo 5.7 Resnet50 Ağı ve Mobilnet Ağı arasındaki doğruluk yüzdesi farkı

Resnet50 -Mobilnet	Erkek	Kadın	Erkek_Kadın
Ham Görüntü	6,87	-7,1	-9,51
DoG Filtresi	14,45	4,24	-3,59
À Trous Filtresi	-8,53	-12,88	-2,67
Canny Filtresi	2,3	-3	-6,89

Tablo 5.7'ye göre genel bir kural söylenmesi mümkün olmamaktadır ancak Mobilnet'in Resnet50'ye göre birçok veri setinde daha yüksek bir doğruluk değeri verdiği görülmektedir.

Son olarak Mobilnet ağı ile Inception v3 ağı arasındaki fark incelenerek Tablo 5.8' da sunulmuştur.

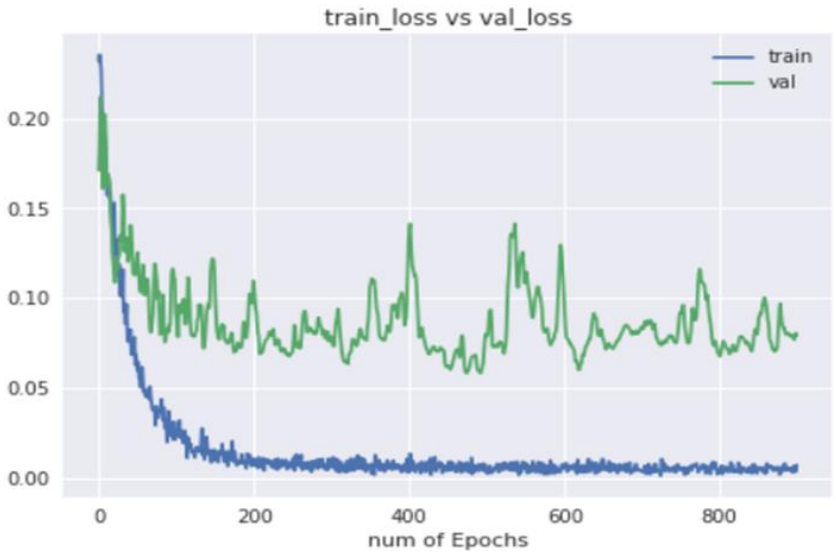
Tablo 5.8 Mobilnet Ağı ile Inception v3 Ağı arasındaki doğruluk yüzdesi farkı

Mobilnet- Inception	Erkek	Kadın	Erkek_Kadın
Ham Görüntü	1,96	8	12,55
DoG Filtresi	-3,34	3,76	13,1
À Trous Filtresi	19,88	1,2	6,27
Canny Filtresi	9,09	-8	-4,44

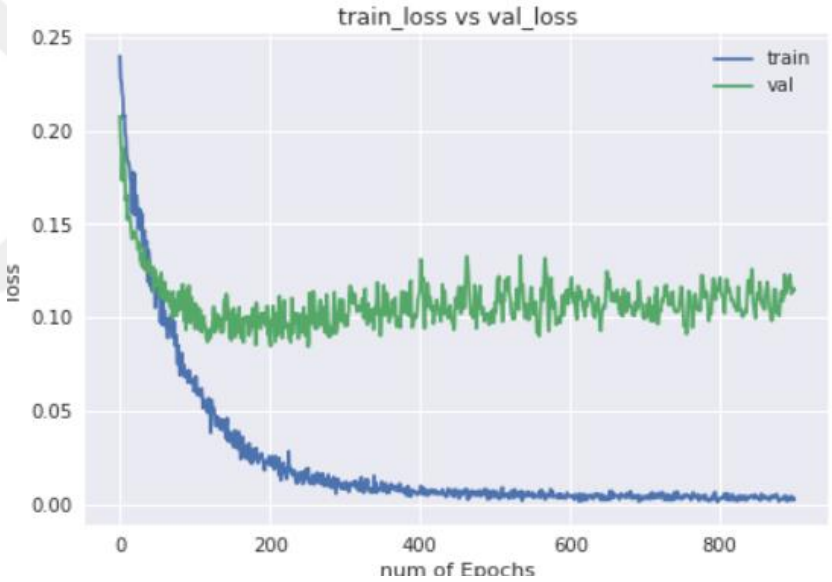
Görüldüğü gibi Mobilnet birçok veri setinde daha yüksek bir başarı elde etmektedir, ancak iki durumda Inception v3 daha yüksek bir doğruluk vermiştir. Mobilnet

derinlemesine evrişim işlemi yaptığı için görüntülerden daha fazla özellikler çıkartarak daha yüksek doğruluk değeri üretmektedir. Bu tezde, farklı ağların aynı veri setindeki doğruluk değerlerine etkisi, filtrelerin aynı veri setindeki etkisi, ve elin hangi bölgesinin yaş tahmini için daha uygun olduğu incelenmiştir.

Uygulama sırasında her bir iterasyonda eğitim ve test veri setlerinden alınan doğruluk ve kayıp yüzdeleri örnek olarak şekil 5.19,5.20,5.21'de gösterilmektedir.

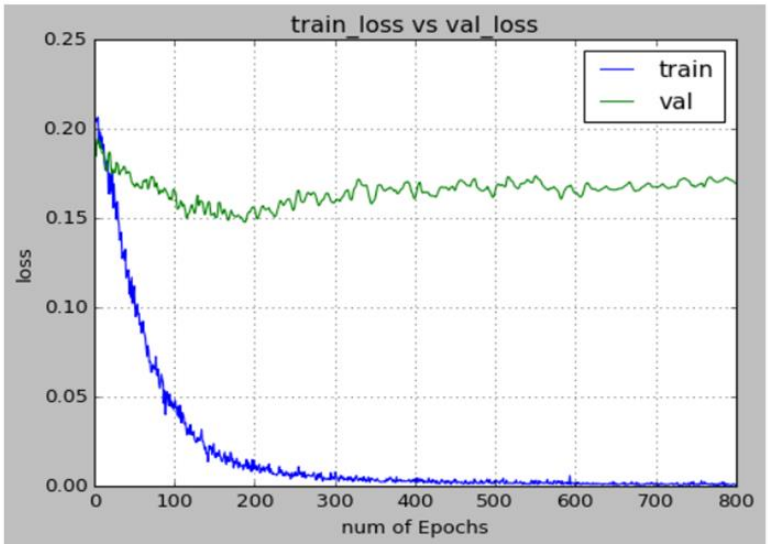


Canny Filtresi, kadın veri seti ve Mobilnet ağı için kayıp değeri

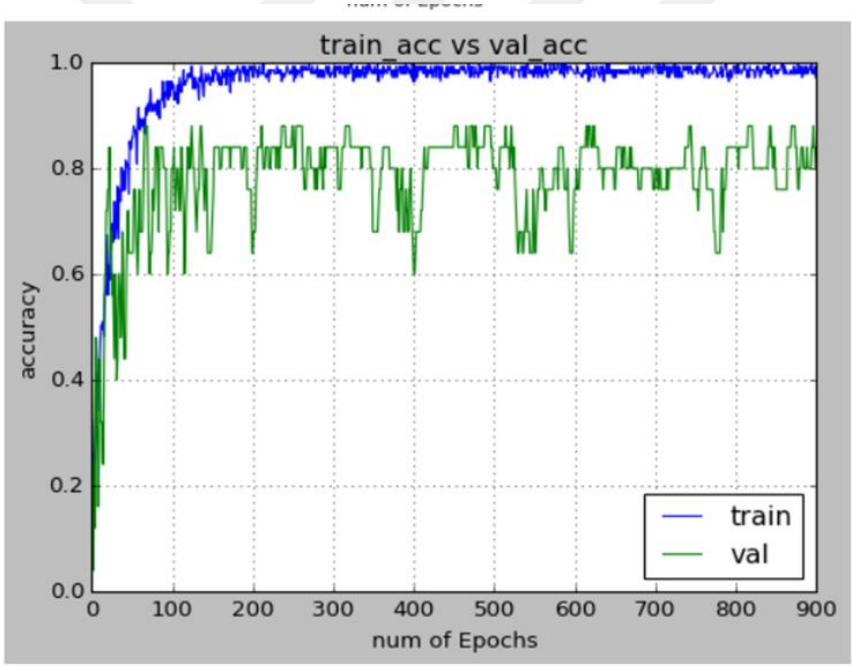


Erkek_kadın veri seti ve Mobilnet ağı için kayıp değeri

Şekil 5.20 Eğitim ve test veri setlerinden alınan doğruluk ve kayıp yüzdeleri için örnek sonuçlar

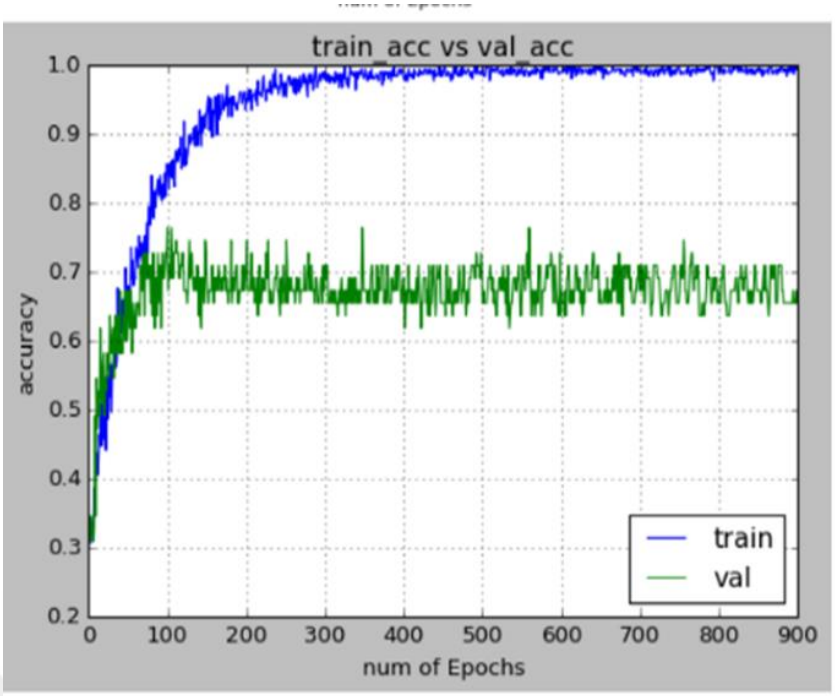


Erkek veri seti, karpal bölge ve Inception v3 ağı için kayıp değeri

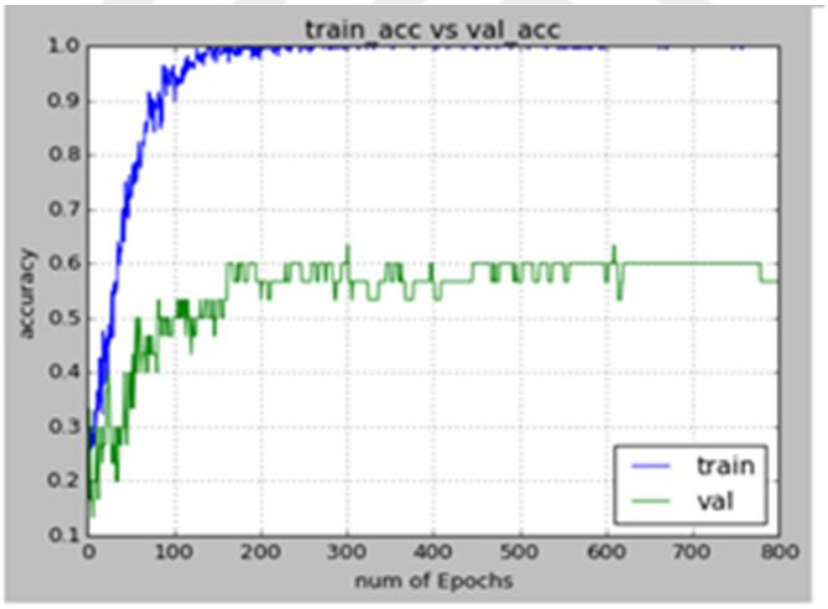


Canny Filtresi, kadın veri seti ve Mobilnet ağı için doğruluk değeri değeri

Şekil 5.21 Eğitim ve test veri setlerinden alınan doğruluk ve kayıp yüzdeleri için örnek sonuçlar



Erkek_kadın veri seti ve Mobilnet ağı için doğruluk değeri



Erkek veri seti, karpal bölge ve Inception v3 ağı için doğruluk değeri

Şekil 5.22 Eğitim ve test veri setlerinden alınan doğruluk ve kayıp yüzdeleri için örnek sonuçlar

Sonuç olarak görülmüştür ki, genel olarak filtreli görüntüler ağlarda ham görüntülerden daha yüksek bir doğruluk değeri vermektedir. Çoğu durumda DoG bant geçiren bir filtre özelliği gösterdiği ve az gürültülü olduğu için yüksek doğruluk vermiştir ancak farklı ağlarda bu kural değişmektedir. Mobilnet ağında A` Trous filtresi daha yüksek doğruluk değerine ulaşmıştır. Ağlar arasında Mobilnet ağı evrişim işleminden dolayı çoğu zaman daha yüksek bir doğruluk yüzdesi üretmiştir. Mobilnet'ten sonra Resnet50'nin başarılı olduğu, InceptionV3'ün ise başarı açısından son sırada yer aldığı söylenebilir. Elin metakarpal ve karpal bölgeleri ayrı ayrı incelenirken her ağ yapısı için karpal bölgenin daha yüksek doğruluk değeri verdiği görülmüştür ve bu nedenle kemik yaşı tespiti yaparken bu bölgenin daha özenle incelenmesi gerektiği söylenebilir.

Kaynakça

[1] V. Gilsanz and O. Ratib, *Hand bone age: a digital atlas of skeletal maturity*. Springer Science & Business Media, 2005.

[2] V. De Sanctis, S. Di Maio, A. T. Soliman, G. Raiola, R. Elalaily, and G. Millimaggi, "Hand X-ray in pediatric endocrinology: Skeletal age assessment and beyond," *Indian journal of endocrinology and metabolism,* 18, no. Suppl 1, p. S63, 2014.

[3] S. Mora, M. I. Boechat, E. Pietka, H. Huang, and V. Gilsanz, "Skeletal age determinations in children of European and African descent: applicability of the Greulich and Pyle standards," *Pediatric research,* 50, no. 5, p. 624, 2001.

[4] J. M. Tanner, R. Whitehouse, N. Cameron, W. Marshall, M. Healy, and H. Goldstein, *Assessment of skeletal maturity and prediction of adult height (TW2 method)*. Academic Press London, 1975.

[5] J. R. Lieberman, A. Daluiski, and T. A. J. J. Einhorn, "The role of growth factors in the repair of bone: biology and clinical applications," 84, no. 6, pp. 1032-1044, 2002.

[6] S. M. Garn and C. G. J. A. J. o. P. A. Rohmann, "Variability in the order of ossification of the bony centers of the hand and wrist," 18, no. 3, pp. 219-230, 1960.

[7] C. M. Gaskin, M. M. S. L. Kahn, J. C. Bertozzi, and P. M. Bunch, *Skeletal development of the hand and wrist: a radiographic atlas and digital bone age companion*. Oxford University Press, 2011.

[8] J. Tanner, R. Whitehouse, W. Marshall, and B. J. A. o. d. i. c. Carter, "Prediction of adult height from height, bone age, and occurrence of menarche, at ages 4 to 16 with allowance for midparent height," 50, no. 1, pp. 14-26, 1975.

[9] S. Dreizen, C. N. Spirakis, and R. E. J. T. J. o. p. Stone, "A comparison of skeletal growth and maturation in undernourished and well-nourished girls before and after menarche," 70, no. 2, pp. 256-263, 1967.

[10] T. W. Todd, "Atlas of skeletal maturation," 1937.

[11] O. E. Gungor, M. Celikoglu, B. Kale, A. Y. Gungor, and Z. J. E. j. o. d. Sari, "The reliability of the Greulich and Pyle atlas when applied to a Southern Turkish population," 9, no. 2, p. 251, 2015.

[12] H. Goldstein, N. Cameron, J. Healy, and M. Tanner, "Assessment of Skeletal Maturity and Predication of Adult height (TW3 Method)," ed: WB Saunders, 2001.

[13] G. Beunen, J. Lefevre, M. Ostyn, R. Renson, J. Simons, and D. J. A. o. h. b. Van Gerven, "Skeletal maturity in Belgian youths assessed by the Tanner-Whitehouse method (TW2)," 17, no. 5, pp. 355-376, 1990.

[14] M. Vignolo, A. Naselli, P. Magliano, E. Di Battista, M. Aicardi, and G. J. H. R. i. P. Aicardi, "Use of the new US90 standards for TW-RUS skeletal maturity scores in youths from the Italian population," 51, no. 4, pp. 168-172, 1999.

[15] M. Vignolo, S. Milani, E. DiBattista, A. Naselli, M. Mostert, and G. J. E. j. o. p. Aicardi, "Modified Greulich-Pyle, Tanner-Whitehouse, and Roche-Wainer-Thissen (knee) methods for skeletal age assessment in a group of Italian children and adolescents," 149, no. 5, pp. 314-317, 1990.

[16] H. Lejarraga, L. Guimarey, and V. J. A. o. h. b. Orazi, "Skeletal maturity of the hand and wrist of healthy Argentinian children aged 4–12 years, assessed by the TWII method," 24, no. 3, pp. 257-261, 1997.

[17] J. Tanner, D. Oshman, F. Bahhage, and M. J. T. J. o. p. Healy, "Tanner-Whitehouse bone age reference values for North American children," 131, no. 1 Pt 1, pp. 34-40, 1997.

[18] R. Bull, P. Edwards, P. Kemp, S. Fry, and I. J. A. o. d. i. c. Hughes, "Bone age assessment: a large scale comparison of the Greulich and Pyle, and Tanner and Whitehouse (TW2) methods," 81, no. 2, pp. 172-173, 1999.

[19] D. King *et al.*, "Reproducibility of bone ages when performed by radiology registrars: an audit of Tanner and Whitehouse II versus Greulich and Pyle methods," 67, no. 801, pp. 848-851, 1994.

[20] F. K. Ontell, M. Ivanovic, D. S. Ablin, and T. W. J. A. A. j. o. r. Barlow, "Bone age in children of diverse ethnicity," 167, no. 6, pp. 1395-1398, 1996.

[21] R. T. Loder *et al.*, "Applicability of the Greulich and Pyle skeletal age standards to black and white children of today," 147, no. 12, pp. 1329-1333, 1993.

[22] S. T. Larsen, S. Demant, and N. Lynnerup, "GPA, TW2RUS, TW3RUS and FELS-a comparative study on bone-age of the left hand and wrist," in *AMERICAN JOURNAL OF PHYSICAL ANTHROPOLOGY*, 2012, 147, pp. 189-189: WILEY-BLACKWELL COMMERCE PLACE, 350 MAIN ST, MALDEN 02148, MA USA.

[23] G. R. J. T. J. o. C. E. Society and Metabolism, "Consensus guidelines for the diagnosis and treatment of growth hormone (GH) deficiency in childhood and adolescence: summary statement of the GH research society," 85, no. 11, pp. 3990-3993, 2000.

[24] M. J. Berst, L. Dolan, M. M. Bogdanowicz, M. A. Stevens, S. Chow, and E. A. J. A. J. o. R. Brandser, "Effect of knowledge of chronologic age on the variability of pediatric bone age determined using the Greulich and Pyle standards," 176, no. 2, pp. 507-510, 2001.

[25] E. Pietka, M. F. McNitt-Gray, M. Kuo, and H. J. I. t. o. m. i. Huang, "Computer-assisted phalangeal analysis in skeletal age assessment," 10, no. 4, pp. 616-620, 1991.

[26] S. A. Adeshina and T. Cootes, *Automatic determination of skeletal maturity using statistical models of appearance*. University of Manchester, 2010.

[27] R. R. van Rijn, M. H. Lequin, and H. H. J. P. r. Thodberg, "Automatic determination of Greulich and Pyle bone age in healthy Dutch children," 39, no. 6, pp. 591-597, 2009.

[28] H. H. Thodberg, S. Kreiborg, A. Juul, and K. D. Pedersen, "The BoneXpert method for automated determination of skeletal maturity," *IEEE transactions on medical imaging*, no. 1, pp. 52-66, 2009.

[29] G. Binder, M. B. Ranke, D. D. J. T. J. o. C. E. Martin, and Metabolism, "Auxology is a valuable instrument for the clinical diagnosis of SHOX haploinsufficiency in school-age children with unexplained short stature," 88, no. 10, pp. 4891-4896, 2003.

[30] M. Vincenzo De Sanctis, A. T. Soliman, M. Salvatore Di Maio, and S. Bedair, "Are the new automated methods for bone age estimation advantageous over the manual approaches?," *Pediatric Endocrinology Reviews (PER),* . 12, no. 2, 2014.

[31] R. M. Malina, C. Bouchard, and O. Bar-Or, *Growth, maturation, and physical activity*. Human kinetics, 2004.

[32] W. C. Chumela, A. F. Roche, and D. J. A. J. o. H. B. Thissen, "The FELS method of assessing the skeletal maturity of the hand-wrist," . 1, no. 2, pp. 175-183, 1989.

[33] Available: https://ipilab.usc.edu/computer-aided-bone-age-assessment-of-children-using-a-digital-hand-atlas-2/2018.9.12

[34] E. Ayhan and G. J. J. o. t. I. S. o. R. S. Atay, "Spectral and spatial quality analysis in pan sharpening process," . 40, no. 3, pp. 379-388, 2012.

[35] M. González-Audícana, X. Otazu, O. Fors, and A. Seco, "Comparison between Mallat's and the 'à trous' discrete wavelet transform based algorithms for the fusion of multispectral and panchromatic images," *International Journal of Remote Sensing,* . 26, no. 3, pp. 595-614, 2005.

[36] J. Canny, "A computational approach to edge detection," in *Readings in computer vision*: Elsevier, 1987, pp. 184-203.

[37] D. Marr and E. J. P. o. t. R. S. o. L. S. B. B. S. Hildreth, "Theory of edge detection," . 207, no. 1167, pp. 187-217, 1980.

[38] DoG. Available: http://fourier.eng.hmc.edu/e161/lectures/gradient/node9.html 2018.9.12

[39] W. S. McCulloch and W. J. T. b. o. m. b. Pitts, "A logical calculus of the ideas immanent in nervous activity," , no. 4, pp. 115-133, 1943.

[40] F. Rosenblatt, *The perceptron, a perceiving and recognizing automaton Project Para*. Cornell Aeronautical Laboratory, 1957.

[41] H. J. J. A. J. Kelley, "Gradient theory of optimal flight paths," no. 10, pp. 947-954, 1960.

[42] Hopfield. Available: http://www.scholarpedia.org/article/Hopfield_network 2018.9.12

[43] C. J. C. H. Watkins, "Learning from delayed rewards," King's College, Cambridge, 1989.

[44] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in *Advances in neural information processing systems*, 2012, pp. 1097-1105.

[45] I. Goodfellow *et al.*, "Generative adversarial nets," in *Advances in neural information processing systems*, 2014, pp. 2672-2680.

[46] Y. LeCun *et al.*, "Backpropagation applied to handwritten zip code recognition," *Neural computation*, no. 4, pp. 541-551, 1989.

[47] I. Goodfellow, Y. Bengio, A. Courville, and Y. Bengio, *Deep learning*. MIT press Cambridge, 2016.

[48] S. Khan, H. Rahmani, S. A. A. Shah, and M. Bennamoun, "A guide to convolutional neural networks for computer vision," *Synthesis Lectures on Computer Vision*, no. 1, pp. 1-207, 2018.

[49] A. F. Agarap, "Deep learning using rectified linear units (relu)," *arXiv preprint arXiv:1803.08375,* 2018.

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

[51] C. Szegedy *et al.*, "Going deeper with convolutions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 1-9.

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

[53] i. v3. Available: https://www.kaggle.com/shivamb/cnn-architectures-vgg-resnet-inception-tl 2018.12

[54] A. G. Howard *et al.*, "Mobilenets: Efficient convolutional neural networks for mobile vision applications," *arXiv preprint arXiv:1704.04861,* 2017.

Tezden Üretilmiş Yayınlar

İletişim Bilgisi: Mahdinezhadasad@gmail.com

Konferans Bildirileri

1 Mahdi NEZHAD ASAD, İ. C.Fatih GENÇ, Lale ÖZYILMAZ, "Investigation of bone age assessment with convolutional neural network by using DoG filtering and à trous wavelet as preprocessing techniques " presented at the CEIT 2018, ISTANBUL, 2018.