



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



DERİN ÖĞRENME YÖNTEMLERİ İLE
KEMİK YAŞI TESPİTİ

Fatma Feyza KAYA
208229001025

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Haziran-2023
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Fatma Feyza KAYA tarafından hazırlanan “Derin Öğrenme Yöntemleri İle Kemik Yaşı Tespiti” adlı tez çalışması 22/06/2023 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Halife KODAZ

.....

Danışman

Prof. Dr. Harun UĞUZ

.....

Üye

Dr. Öğr. Üyesi Onur İNAN

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN
Enstitü Müdürü

TEZ BİLDİRİMİ

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

DECLARATION PAGE

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

Fatma Feyza KAYA

Tarih: 22.06.2023

ÖZET

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME YÖNTEMLERİ İLE KEMİK YAŞI TESPİTİ

Fatma Feyza KAYA

**Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı**

Danışman: Prof. Dr. Harun UĞUZ

2023, 45 Sayfa

Jüri

**Prof. Dr. Harun UĞUZ
Prof. Dr. Halife KODAZ
Dr. Öğr. Üyesi Onur İNAN**

Kemik yaşının tespiti; çeşitli hastalıkların teşhis edilebilmesi, kemik gelişiminin takip edilebilmesi veya hormonal sorunların varlığının anlaşılabilmesi için önemli bir işlemdir. Özellikle çocuk yaşlarda, büyümenin en hızlı evrelerinde bu tespit daha büyük önem taşır. Boyun aşırı uzun olması ya da aşırı kısa olması gibi durumlarda, bireyin çocukluğunu ya da yetişkinliğini ispat edebilmesi; ergenliğin sonuna kadar kemiklerin gelişebileceği son noktanın yani boy uzunluğunun tespiti gibi durumlar da kemik yaşı değerlendirmesi ile mümkündür. Her bireyin iki yaşı vardır; bunlar kemik yaşı ve kronolojik yaştır. Kemik yaşı, bireylerin iskelet olgunluğunun derecesidir. Kronolojik yaş ise, doğum tarihinden mevcut tarihe kadar olan yılların hesaplamasıyla elde edilen; kaç yaşındasın sorusuna cevap olarak verilen, bilinen yaştır. Kemik yaşı tespitinin ana amacı; bu iki yaşın arasındaki farklılığın değerlendirilmesi ile ortaya çıkan sonuca bakılarak, bireyin gelişiminde bir sorun olup olmadığının anlaşılmasını sağlamaktır.

Bu çalışmada, 0-18 yaş arasındaki bireylerin 12611 sol ellerinin x-ray görüntüleri; evrimsel sinir ağları (Convolutional Neural Network - CNN) ile kıyaslanarak en iyi sonucu veren Inception V3 modeli üzerinde katman geliştirmeleri yapılmıştır ve yeni bir model oluşturulmuştur. Oluşturulan modeli kıyaslamak için yapılan deneysel çalışmalarda; VGG-16, Inception V3 ve MobileNet mimarileri kullanılmış olup, tüm mimariler Ortalama Mutlak Hata (Mean Absolute Error - MAE), Kök Ortalama Kare Hata (Root Mean Squared Error - RMSE) ve Korelasyon Katsayısı (Correlation Coefficient - CC) değerlerine göre kıyaslanmıştır. Yeni model, klasik Inception V3'e göre çok daha hızlı sonuç vermekte olup, aynı zamanda başarısı da daha yüksek elde edilmiştir. Literatürde aynı veri setini kullanan diğer çalışmaların MAE değerleri ile kıyaslandığında da modelin iyi sonuç verdiği gözlemlenmiştir.

Anahtar kelimeler: CNN, Derin Öğrenme, El X-Ray Görüntüsü, Kemik Yaşı, VGG16, Inception V3, MobileNet

ABSTRACT

MS THESIS

BONE AGE DETECTION WITH DEEP LEARNING METHODS

Fatma Feyza KAYA

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

Advisor: Prof.Dr. Harun UĞUZ

2023, 45 Pages

**Jury
Prof.Dr. Harun UĞUZ
Prof.Dr. Halife KODAZ
Asst.Prof.Dr. Onur İNAN**

Determination of bone age is an important procedure for diagnosing various diseases, monitoring bone development or understanding the presence of hormonal problems. This determination is especially important in childhood, during the fastest stages of growth. In cases such as an excessively long or excessively short neck, it is possible to prove the individual's childhood or adulthood; it is also possible to determine the last point where the bones can develop until the end of puberty, i.e. the length of the height, with bone age assessment. Each individual has two ages: bone age and chronological age. Bone age is the degree of skeletal maturity of individuals. Chronological age, on the other hand, is the age we know, which is obtained by calculating the years from the date of birth to the current date; it is the age we know when we answer the question of how old we are. The main purpose of bone age determination is to determine whether there is a problem in the development of the individual by evaluating the difference between these two ages.

In this study, x-ray images of 12611 left hands of individuals between the ages of 0-18 were compared with Convolutional Neural Network (CNN) and the Inception V3 model, which gave the best results, was improved and a new model was created. VGG-16, Inception V3 and MobileNet architectures were used in the experimental studies to compare the new model and all architectures were compared according to Mean Absolute Error (MAE), Root Mean Squared Error (RMSE) and Correlation Coefficient (CC) values. The new model gives much faster results than the classic Inception V3 and is also more accurate. When compared with the MAE values of other studies in the literature using the same dataset, it is observed that the model gives good results.

Keywords: CNN, Deep Learning, Hand X-Ray Image, Bone Age, VGG16, Inception V3, MobileNet

ÖNSÖZ

Yüksek lisans çalışmalarım boyunca yardımlarını hiçbir zaman esirgemeyen, her konuda destek olan, engin bilgi ve tecrübeleriyle beni her zaman en doğru şekilde yönlendiren kıymetli danışman hocam Sayın Prof. Dr. Harun UĞUZ'a, Konya Teknik Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümünün tüm öğretim elemanlarına teşekkür ederim. Bu süreçte bana maddi manevi desteklerini esirgemeyen, beni her zaman, her koşulda motive eden sevgili babam Mustafa Kemal KAYA'ya, annem Emine KAYA'ya, tüm aileme ve çok değerli arkadaşlarıma sonsuz teşekkürlerimi sunuyorum.

Fatma Feyza KAYA
KONYA-2023



İÇİNDEKİLER

ÖZET	vii
ABSTRACT.....	viii
ÖNSÖZ	ix
İÇİNDEKİLER.....	iv
ŞEKİLLER VE ÇİZELGELER.....	vi
SİMGELER VE KISALTMALAR.....	viii
1. GİRİŞ.....	1
1.1. Kemik Yaşı Değerlendirmesi.....	1
1.2. Kemik Yaşı Tespiti Yöntemleri	2
1.2.1. Greulich-Pyle yöntemi.....	2
1.2.2. Tanner-Whitehouse yöntemi.....	3
1.2.3. Yapay zeka ile kemik yaşı tespiti	5
1.3. Tezin Önemi ve Amacı	5
1.4. Tezin Literatüre Katkısı	6
2. KAYNAK ARAŞTIRMASI.....	8
2.1. Uzmanla Dayalı Yöntemler ile Yapılan Çalışmalar.....	8
2.2. Yapay Zeka ile Yapılan Çalışmalar	9
2.3. Derin Öğrenme Yöntemleri ile Yapılan Çalışmalar.....	10
3. MATERYAL VE YÖNTEM.....	13
3.1. Veri Seti	13
3.2. Ön İşleme	14
3.3. Veri Artırma	15
3.3.1. Yatay eksen etrafında simetri oluşturma (horizontal flip).....	15
3.3.2. Yükseklik kaydırma (height shift)	15
3.3.3. Genişlik kaydırma (width shift).....	16

3.3.4.	Görüntüyü döndürme (rotation).....	16
3.3.5.	Görüntüyü yaklaştırma (zoom).....	17
3.4.	Derin Öğrenme Yöntemi ve Katmanları	17
3.4.1.	Giriş katmanı.....	18
3.4.2.	Evrışim katmanı	19
3.4.3.	Aktivasyon katmanı	20
3.4.4.	Havuzlama katmanı	20
3.4.5.	Tam bağlı katman	21
3.4.6.	Seyreltme katmanı	22
3.4.7.	Sınıflandırma katmanı.....	22
3.4.8.	Yumuşatma katmanı	23
3.5.	Karşılaştırılan Mimariler	23
3.5.1.	VGG-16	24
3.5.2.	Inception V3	25
3.5.3.	MobileNet	28
3.6.	Inception V3 Üzerinden Geliştirilen Model.....	29
4.	ARAŞTIRMA SONUÇLARI.....	32
4.1.	Sonuçlar.....	34
5.	SONUÇ	41
KAYNAKLAR	42

ŞEKİLLER VE ÇİZELGELER

Şekiller	Sayfa
Şekil 1.1: Sol El Bileği Kemikleri Şematik Gösterimi	4
Şekil 3.1: Veri Seti Örnek Verileri	13
Şekil 3.2: Veri Seti Cinsiyet Dağılım Grafiği	14
Şekil 3.3: Veri Seti Kemik Yaşı Dağılım Grafiği	14
Şekil 3.4: Sol: Orijinal Görüntü; Sağ: Yatay Eksen Etrafında Simetri Oluşturulmuş Görüntü	15
Şekil 3.5: Sol: Orijinal Görüntü; Sağ: Yükseklik Kaydırma İşlemi Uygulanmış Görüntü	16
Şekil 3.6: Sol: Orijinal Görüntü; Sağ: Genişlik Kaydırma İşlemi Uygulanmış Görüntü	16
Şekil 3.7: Sol: Orijinal Görüntü; Sağ: Döndürme İşlemi Uygulanmış Görüntü.....	17
Şekil 3.8: Sol: Orijinal Görüntü; Sağ: Yaklaştırma İşlemi Uygulanmış Görüntü.....	17
Şekil 3.9: CNN Katmanları.....	18
Şekil 3.10: VGG-16 Mimarisi.....	24
Şekil 3.11: Inception V1 ve Inception V3 Modülleri.....	26
Şekil 3.12: Inception V3 Modülü Son Hali	27
Şekil 3.13: MobileNet Derinlemesine Ayrılabilir Evrişim Mimarisi.....	28
Şekil 3.14: Önerilen Modelin Katmanlarının Şeması.....	30
Şekil 3.15: Geliştirilen Model Katman Mimarisi	31
Şekil 4.1: VGG-16 (a), Inception V3 (b), MobileNet (c) ve Yeni Model (d) için Ay Bazında Gerçek Yaş ile Tahmini Yaş Kıyaslaması	36
Şekil 4.2: VGG-16 Modeli İçin Yaş Sonucu Tahmini Ara Yüzü	37
Şekil 4.3: Inception V3 Modeli İçin Yaş Sonucu Tahmini Ara Yüzü	38
Şekil 4.4: MobileNet Modeli İçin Yaş Sonucu Tahmini Ara Yüzü.....	39
Şekil 4.5: Önerilen Model İçin Yaş Sonucu Tahmini Ara Yüzü	40
Çizelgeler	Sayfa
Çizelge 3.1: Veri Setine Dair Excel Verilerinden Bazıları	13
Çizelge 3.2: VGG-16 Model Katmanları.....	25

Çizelge 3.3: Incepiton V3 Model Katmanları.....	27
Çizelge 3.4: MobileNet Model Katmanları	29
Çizelge 4.1: VGG-16, Inception V3, MobileNet ve Önerilen Model MAE, RMSE ve CC Sonuçları	34
Çizelge 4.2: Önerilen Modelin Epochlara Göre MAE Sonuçları	34
Çizelge 4.3: MAE Sonuçlarının Diğer Çalışmalarla Kıyaslanması.....	35



SİMGELER VE KISALTMALAR

Kısaltmalar

BAA	:	Kemik Yaşı Değerlendirmesi
CC	:	Korelasyon Katsayısı
CNN	:	Evrişimli Sinir Ağları
DCNN	:	Derin Evrişimli Sinir Ağları
GP	:	Greulich-Pyle
MAE	:	Ortalama Mutlak Hata
MSE	:	Ortalama Kare Hata
RSNA	:	Kuzey Amerika Radyoloji Derneği
RMSE	:	Kök Ortalama Kare Hata
TW	:	Tanner-Whitehouse
YSA	:	Yapay Sinir Ağları

1. GİRİŞ

Dijital çağa geçilmesiyle birlikte, artık dijital verilerin çok daha fazla önem arz ettiği şu dönemde; dijital verilerin analizi de aynı oranda büyük önem kazanmıştır. Dijital verilerin analizi ile ilgili sayısız alan ve yöntem vardır. Bu alanlardan biri de sağlıktır.

Sağlık alanında, hastaların tıbbi dijital verilerinin analizi; teknolojinin de hayatımıza iyice yerleşmesiyle birlikte sıklıkla kullanılan bir yöntem haline gelmiştir. Bu yöntemler kullanılarak özellikle hastalıkların erken teşhis edilebilmesi ya da henüz bireyde olmayan ama ileride olması muhtemel olan hastalıkların tahmin edilmesi ve bunlara göre önlem alınması büyük avantajdır.

Kemik yaşı ile kronolojik yaş arasındaki farkların değerlendirilmesi, bireylerde, özellikle çocuklarda; büyüme değerlendirmesi ve çok sayıda endokrin bozukluğun ve pediatrik sendromun teşhis edilmesi ve yönetilmesi amacıyla kullanılır (Gilsanz ve Ratib, 2005; Iglovikov ve ark., 2018). Kimliği belli olmayan veya yaşından emin olunmayan kişilerin yaşlarının tespiti için de adli tıp alanında kemik yaşı tespiti işlemi uygulanabilmektedir. Kemik yaşı değerlendirmesi, alanında uzman kişiler tarafından da yapılabilmektedir. Bu yöntem aslında kolay olmasına karşın, sonuçlar; değerlendirmeyi yapan radyoloğa bağlı olarak değişiklik gösterebilir. Aynı zamanda, bu işlem, beraberinde; oldukça uzun bir işlem süresi ve yüksek maliyet getirebilir (Sarić ve ark., 2019). Dolayısıyla son yıllarda, bu alandaki çalışmaların derin öğrenme ve makine öğrenmesi gibi dijital yöntemlerle yapılmasına ağırlık verilmiştir. Kuzey Amerika Radyoloji Derneği'nin (Radiological Society of North America – RSNA) 2017 yılında başlattığı “Pediatrik Kemik Yaşı Mücadelesi” bu alandaki çalışmalara yoğunlaşılmasına örnek olarak gösterilebilir (Halabi ve ark., 2019).

1.1. Kemik Yaşı Değerlendirmesi

Kemik yaşı değerlendirmesi (Bone Age Assessment - BAA) iki şekilde yapılmaktadır. Bu yöntemlerden ilki kemiklerdeki değişen bölgeler incelenir. İkinci yöntem ise kemiklerin içerdikleri kalsiyum incelenir (Asad, 2019). Kemik incelemesinde çeşitli yöntemler vardır ancak en iyi sonuç el bileği kemiğinden alınmıştır (Sarić ve ark., 2019). El bilekleri arasında da sol el bileği, genelde daha az kullanılan el olması sebebiyle daha iyi sonuç vermektedir (Ren ve ark., 2018).

Dolayısıyla kemik yaşı tespiti ile ilgili çalışmalarda genelde sol el bileği röntgenleri kullanılır.

Kemik yaşı; beslenme alışkanlıklarına, ırka, cinsiyete veya yaşanılan bölgeye göre değişiklik gösterebilmektedir. Kadın iskeleti olgunlaşma süreci ile erkek iskeleti olgunlaşma süreci de farklılık göstermektedir. Kadınların iskeleti, erkeklere oranla daha hızlı olgunlaşmaktadır (Mora ve ark., 2001).

1.2. Kemik Yaşı Tespiti Yöntemleri

BAA için kullanılan iki farklı yöntem vardır. Bunlar Greulich-Pyle (GP) ve Tanner-Whitehouse (Howard ve ark., 2017) yöntemleridir. Bu iki yöntem de alanında uzman kişiler tarafından değerlendirme yapılmak üzere geliştirilmiştir. Dolayısıyla sonuçlar, değerlendirmeyi yapan uzmanlara göre değişebilir. 1999 yılında yapılan bir çalışmada, GP yönteminin TW yöntemine göre daha hızlı olmasına karşın; TW yöntemi ile daha doğru sonuçlar elde edildiği görülmüştür (Bull ve ark., 1999).

1.2.1. Greulich-Pyle yöntemi

Bu yöntem William Walter Greulich ve S. Idell Pyle kişileri tarafından bulunmuş olup GP atlasını kullanır (Pinchi ve ark., 2014). 1931 ile 1942 yılları arasında Amerika bölgesindeki çocukların el ve bilek röntgen filmleri toplanarak geliştirilmiştir. GP atlası, radyografiden kemik yaşını ölçmek için temsili bir yaş atlasıdır (Wibisono ve ark., 2019). Bu yöntem, el-bilek röntgen filmleri üzerinde kemik gelişimlerinin atlastaki yaşa bağlı gelişmelerle kıyaslanmasıdır. Cinsiyetin de kemik gelişim ve olgunlaşmasında etkisi vardır. Bu nedenle, atlas oluşturulurken 29 kız ve 31 erkek el-bilek görüntüleri alınmıştır. Cinsiyet ve yaşa göre kemik gelişiminin en benzediği görüntüler seçilerek tespit yapılmaktadır. İlk olarak kemik yaşı tespit edilmek istenen görüntünün ait olduğu bireyin yaşı ve cinsiyetine göre, GP atlasında o yaş ve cinsiyete karşılık gelen röntgen filmi bulunur ve bu iki röntgen filmi atlasta bulunan açıklamalara göre kıyaslanır. Kıyaslamalar tam olarak örtüşürse, ilgili görüntünün GP standartlarına göre ilgili yaşa uygun olduğu anlaşılır. İlgili görüntü kendi yaş ve cinsiyet görüntüsü ile tam olarak aynı değilse, atlastaki diğer tüm görüntülerle kıyaslanır ve en uygun görüntünün yaşı, incelenen kişinin kemik yaşı olarak kabul edilir. Tüm görüntüye bakılarak kemik yaşı


tespiti yapabilmenin yanında, kemiklerin tek tek incelenmesi de GP atlasında mümkündür.

1.2.2. Tanner-Whitehouse yöntemi

TW yöntemi kemik yaşını belirlemek için 20 özel kemiği inceleyen bir skorlama sistemi kullanır (Wibisono ve ark., 2019). Bu skorlar, her bir kemiğe özel verilmiş değerlerin toplanması sonucu elde edilir. İngiliz çocuklarının sol el-bilek röntgen filmleri kullanılarak geliştirilmiştir. İlk olarak TW1 ortaya konulmuştur. Bundan 21 yıl sonra TW2 ve TW2'den 18 sene sonra da TW3 geliştirilmiştir (Garn, 1986; Tanner, 1962). Seneler içinde yöntemlere gelen güncellemeler, incelenen kemiklerle alakalıdır. TW2 yönteminde 9 kemik (8 ana kemik ve ulna kemiği) incelenip skorlama yapılırken; TW3 yönteminde ise karpal kemikler, kısa kemikler, ulna ve radius incelenir (Kaymaz, 2022).

İlgili yöntemler, görüntüler üzerinde bir uzman yorumu gerektirdiğinden, sonuçlar uzmandan uzmana değişkenlik gösterebilmektedir. TW2 için ortalama 0.74 yıl, GP için de ortalama 0.96 yıl fark oluşabilmektedir (King ve ark., 1994; Ontell ve ark., 1996).

Şekil 1.1'de 1'den 8'e kadar numaralandırılmış bölge, karpal kemikleridir. Bu kemiklerin sıralanması; capitatum(1), hamatum(2), triquetrum(3), lunatum(4), trapezium(5), trapezoid(6), scaphoid(7) ve pisiforme(8) şeklindedir [Gilsanz ve Ratib, 2005].



Şekil 1.1: Sol El Bileği Kemikleri Şematik Gösterimi

Birincil merkezden kemikleşen, parmağın avuçtan ilk boğumuna kadar olan kemik diyafiz; ikincil merkezden kemikleşen, diyafiz ile avuç arasında kalan kemik ise epifizdir. İkincil merkez kademe kademe kemikleşirken; kıkırdak, sadece ince bir kıkırdak tabakası olan epifiz plakası, diyafiz kemiğini epifizden ayırana kadar kemik ile değiştirilir. Diyafiz ile epifiz arasında kalan kısma metafiz denir. Metafiz, kemiğin büyüyen ucunu temsil eder. Epifiz plakası büyümeye devam ettiği sürece diyafiz ve epifiz de büyümeye devam eder. Bir süre sonra olgunlaşmamış kemik hücrelerinin oluşumu durur ve epifiz plakası kemikleşir (Gilsanz ve Ratib, 2005).

1.2.3. Yapay zeka ile kemik yaşı tespiti

Uzmanlar tarafından kıyaslama yapılarak kemik yaşının tespit edildiği yıllarda, bilgisayarlı yöntemler henüz gelişme aşamasındaydı. Kemik yaşı tespitinin bölüm 1.2'de açıklanan GP ve TW atlaslarına bağlı olarak hesaplanması işlemi, uzman bir kişi tarafından yapıldığından insan bağımlı bir işlemdir. Dolayısıyla, kişiden kişiye sonuçların değişmesi kaçınılmazdı. Bunun üzerine bilgisayarlı yöntemler geliştirilmeye başlandı. 1991 yılında Pietka ve arkadaşları tarafından öne sürülen bilgisayarlı kemik yaşı tespiti yönteminde, dijitalleştirilen el-bilek röntgen filmi görüntüsü üzerinde falanks kemiklerinin uzunlukları çeşitli matematiksel işlemlere göre hesaplanıp atlasla karşılaştırılmaktadır (Pietka ve ark., 1991).

Geleneksel özellik çıkarma yöntemlerinde ilk olarak sol el-bilek röntgen filmleri görüntüleri üzerinde gürültü azaltmak için ön işlem yapılır. Sonrasında bu görüntüler üzerinde, kemiklerin uzunlukları, birbirlerine uzaklıkları, bulunan kemiklerin sayısı gibi çeşitli durumlar göz önünde bulundurularak özellik çıkarımı yapılır. Sonrasında bu özelliklere göre sınıflandırma yapılır veya hata oranları kıyaslanır.

Sonrasında derin öğrenme yöntemlerinin iyice gelişmesiyle, kemik yaşı tespitinde de derin öğrenme yöntemleri kullanılmaya ve geliştirilmeye başlanmıştır. Makine öğrenmesi yöntemleri daha hızlı sonuç vermesine karşın daha uzun sürede geliştirilirken, derin öğrenme yöntemleri daha uzun sürede sonuç verir ama daha kısa sürede geliştirilir.

1.3. Tezin Önemi ve Amacı

Sağlık alanında yapılan çalışmalar, günümüzde fazlaca dijitalleşmeye başlamıştır. Yapay zeka, tüm alanlarda olduğu gibi sağlık alanında da sıklıkla kullanılmaktadır. Özellikle kemik yaşı tespiti gibi tamamen uzman kişinin görüşüne bağlı olan alanlarda, doğruluğu ve güvenilirliği artırmak amacıyla, son yıllarda bu alanlarda yapılan bilgisayara dayalı çalışmalar da artmıştır.

Kemik yaşının belirlenmesi cezai yaş tespiti, kimliği belirsiz kişilerin yaşlarının tespiti, çocuklardaki büyüme ve hormon bozukluklarının tespiti gibi birçok sebepten dolayı önem arz etmektedir (Özdemir, 2022; A. Zhang ve ark., 2007).

Kemik yaşının tespit edilmesi bölüm 1.1’de de anlatıldığı gibi bireylerin kemik gelişimlerine bakılarak yapılır. Köprücük kemiği, diş kemiği gibi çok çeşitli kemiklere bakılarak yapılan kemik yaşı tespitinde en iyi sonuç sol el bileği kemiklerinden alınmaktadır (Çelik, 2016; Kasımoğlu ve Tuna-İnce, 2016; Reddy ve ark., 2020). Bilgisayarla tespit işlemi yapılmadan önce kullanılan diğer yöntemler yukarıda açıklanmıştır. Ancak tüm o yöntemler sadece ilgili el bileği röntgen görüntüsünü inceleyen uzmanın görüşüne bağlı kalmaktadır. Bunun sonucunda kemik yaşı tespiti hem uzun sürmekte hem uzman kişinin çok fazla emek harcaması gerekmekte hem de her zaman tam doğru sonucu vermemektedir (Spampinato ve ark., 2017). Tüm bunlar sebebiyle bilgisayarlı tespit yöntemleri geliştirilmiştir. Bu yöntemlere de bölüm 1.2’de değinilmiştir.

Makine öğrenmesi yöntemleri ile özellik çıkarımları yapılabilir ve kemik yaşı tespit edilebilir. Ancak bu özellik çıkarımlarının yapılabilmesi için yine uzman kişilerin görüşlerine ve yönlendirmelerine ihtiyaç duyulmaktadır. Derin öğrenme yöntemlerinde ise, çalıştırılan model; özellikleri kendi öğrenerek çıkardığından hem daha etkili bir sonuç alınmaktadır hem de uzman kişi bağımlılığı yoktur (Larson ve ark., 2018; Zakiroğlu, 2019). Tabi geliştirilen modelin de veri setine uygun olması gerekmektedir.

Bu çalışmada literatürde en çok kullanılan modellerden biri olan Inception V3 modeli üzerinde katman geliştirmesi yapılarak sonuçların iyileştirilmesi amaçlanmıştır.

1.4. Tezin Literatüre Katkısı

Kemik yaşı tespiti bölüm 1.3’de anlatıldığı gibi büyük önem arz etmektedir. Henüz olgunlaşmamış çocuklarda endokrin bozukluklarının erken teşhisi, kimliği tespit edilemeyen kişilerin ya da cesetlerin yaş tespiti, suç işlemiş bireylerin cezai ehliyeti olup olmadığının belirlenebilmesi gibi konularda sıklıkla kullanılan bir yöntemdir. Tüm bu olağan dışı durumlar olmasa bile, özellikle çocuklarda doktorlar tarafından genel kontrol amacıyla kemik yaşı tespiti yapılmaktadır. Bu işlemin bilgisayar tabanlı olarak otomatik şekilde yapılabilmesi için birçok çalışma yapılmıştır. Ancak yapılan literatür taraması sonucunda, hala geliştirilmeye devam edilmesi gereken bir alan olduğu görülmüştür.

Yapılan literatür arařtırmaları sonucunda, kemik yaşı tespiti için çeřitli CNN modelleri kullanıldıđı, üretildiđi, var olan modellerin geliřtirildiđi, makine öğrenmesi yöntemleri kullanılarak özellik çıkarımları ile sonuç alınmaya çalışıldıđı görölmüřtür. Fakat kemik yaşı tespiti ay bazında yapıldıđından, birkaç ayın bile önemi olmaktadır. Örneđin herhangi bir cezai iřlem uygulanacađında bireyin yařının tam olarak belirlenmesi çok büyük önem arz etmektedir.

Literatürde en iyi sonuçlar CNN modelleri geliřtirilerek elde edilmiřtir. Dolayısıyla bu tezde de CNN modeli geliřtirmek üzerine çalışılmıřtır.

Yapılan deneysel çalışmalar sonucunda, bu alanda en çok kullanılan derin öğrenme mimarilerinden, en iyi sonuç Inception V3 ile alınmıřtır. Sadece kemik yaşı tespiti deđil; tüm dünya için büyük risk ve önem arz eden Covid-19 hastalık tespiti (Mujahid ve ark., 2022; Sađlam ve ark., 2022), beyin tümörü tespiti (Sevli, 2021) ya da alzheimer erken teřhisi (Can ve Eyüpođlu, 2021) gibi çok çeřitli konularda da yine CNN mimarileri kullanımı ve Inception V3 üzerinde katman geliřtirilmesi birçok kaynakta görölmüřtür. Tüm bu örneklerin ortak noktası ise hepsinin radyografi görüntüleri üzerine çalışılan sađlık uygulamaları olmasıdır ve hepsinin ortak amacı, çeřitli kořullar tarafından etkilenebilen uzman görüşünü en aza indirebilmek hatta bu ihtiyacı ortadan kaldırmaktır (Zhao ve ark., 2018). Bu çalışmada da literatür arařtırmalarına göre daha çok kullanıldıđı ve başarı sađlandıđı görölen Inception V3 modeli üzerinde katman geliřtirme yapılmıř olup sonucun iyileřtirilmesi ve kemik yaşı tespitindeki hatanın azaltılması amaçlanmıřtır. Böylelikle çeřitli kořullara bađlı olarak deđiřebilen uzman görüşüne olan ihtiyaç ortadan kaldırılmıř olup, cihaza bađlı görüntü alma hatalarının da sonucu etkilememesi sađlanmıřtır.

Yapılan deneysel çalışmalarda, geliřtirilen yeni modelin klasik CNN yöntemlerine göre çok daha hızlı ve iyi sonuç verdiđi görölmüřtür. Literatür taramasında, yeni modeller oluřturulurken veya var olan modeller geliřtirilirken yapılan çalışmalar dikkate alınmıřtır ve daha iyi sonuç için eklenecek katmanlara bu şekilde karar verilmiřtir. Eklenen katmanlar ve açıklamaları bölüm 3.6'da açıklanacaktır.

2. KAYNAK ARAŞTIRMASI

Kemik yaşı tespiti ile ilgili dünya genelinde birçok çalışma yapılmıştır. Gün geçtikçe insan tarafından değerlendirme yapılan yöntemler yerine, dijital çözümler artmaktadır.

Ülkemizde, 1974 yılından bu yana YÖK Ulusal Tez Merkezi resmi web sitesinde, kemik yaşı değerlendirmeleri ile ilgili 35 kayıt listelenmektedir. Bunlardan 13 tanesi (%37,1) yüksek lisans tezi, 6 tanesi (%17,1) doktora tezi, 4 tanesi (%11,5) diş hekimliği uzmanlık tezi ve 12 tanesi (%34,3) de tıpta uzmanlık tezidir.

2.1. Uzmana Dayalı Yöntemler ile Yapılan Çalışmalar

Kaplan ve Yılmaz, 2020 yılında yürüttükleri bir çalışmada ise; kemik yaşı tayininde kullanılan en genel yöntemlerden olan GP ve TW yöntemlerini kıyaslamışlardır. GP, TW, TW2 ve TW3 yöntemlerini yaş ve cinsiyet bazında kıyaslamışlar ve birbirine yakın sonuçlar elde etmişlerdir (Kaplan ve Yılmaz, 2020).

Kasımoğlu ve İnce, 2016 yılındaki bir çalışmalarında; diş hekimliğinde kemik yaşı tespitinde kullanılan yöntemleri irdelemişlerdir. Parmak, el bileği ve boyun omurları yöntemlerini incelemişlerdir. Boyun omurlarının incelenmesinde ek radyografi ihtiyacı bulunmamaktadır, buna karşın radyasyon dozu hususunda güvenilirliği kanıtlanmış değildir. Üçüncü parmak radial falanks gelişiminin değerlendirilmesi ile yapılan kemik yaşı tespitleri de basit bir teknik olduğundan kullanılabilir. Ancak yine de genel manada en başarılı sonuçların el bileği yönteminden elde edildiğini görmüşlerdir (Kasımoğlu ve Tuna-İnce, 2016).

Cole, Webb ve Cole 1988 yılında, o dönemin kemik yaşı tespiti yöntemlerini karşılaştırmışlardır. Bu yöntemler GP ve TW2 yöntemleridir. 97 çocuktan alınan el bileği röntgen filmleri üzerine çalışmışlardır. TW2 yöntemi ile yapılan yaş tahminlerinin, GP yöntemine kıyasla gerçek yaşa daha yakın olduğu görülmüştür. Yine de TW2 yönteminin daha zahmetli olması sebebiyle bu yöntemi önermekten kaçınmışlardır (Cole ve ark., 1988).

2.2. Yapay Zeka ile Yapılan Çalışmalar

Yılmaz 2011 yılında hazırladığı yüksek lisans tez çalışmasında, bulanık mantık yöntemi ile kemik yaşı değerlendirmesi yapmıştır. Yılmaz, hazırladığı çalışmada GP yöntemini baz almıştır. Karpal kemiklerin pre-puberte dönemi gelişimlerini ve ilgili kemiklerin alanlarındaki değişimleri incelemiştir. Görselleri 512x512 boyutunda kullanmıştır. Matlab programında, görseller üzerinde ilgili kemiklerin alanları ve bilgileri çıkarılmıştır, sonrasında bu bilgiler cinsiyetlere ayrılarak veritabanına kaydedilmiştir. İlgili kemiklerinin alanlarının, capitata kemiğinin alanına oranı hesaplanmış ve buna göre bir hesaplama yapılmıştır. Çalışmasının sonucunda, en iyi sonucu kızlarda %92 başarı oranı ile 7 yaş grubunda; erkeklerde ise %77 başarı oranı ile 1 yaş grubunda gözlemlemiştir (Yılmaz, 2011).

Wibisono ve arkadaşları 2019 yılında, kemik yaşı değerlendirmesi için klasik makine öğrenmesi yöntemleri ile derin öğrenme yöntemlerini karşılaştırmışlardır. Çalışmalarının sonucunda, kullandıkları algoritmalar arasında derin öğrenme yöntemlerinin daha iyi sonuç verdiği ancak makine öğrenmesi yöntemlerinin hem daha hızlı sonuç verdiği hem de daha esnek çalışma alanı sağladığı görülmüştür (Wibisono ve ark., 2019).

Pietka ve arkadaşları 2004 yılında yaptıkları çalışmalarında, bilgisayar destekli bir kemik yaşı değerlendirme aracı hazırlamışlardır. Görüntü işleme ve karşılaştırmalar için kullanıcı arayüzü ekledikleri bu çalışmalarının sonucunda, insana dayalı sistemlere göre daha nesnel ve hızlı bir sonuç alındığı gözlemlenmiştir (Pietka ve ark., 2004).

Zakiroğlu 2019 yılında yaptığı yüksek lisans tez çalışmasında, makine öğrenmesi ve derin öğrenme yöntemlerini kullanarak kemik yaşı tespiti yapmış ve kullandığı algoritmalar arasında kıyaslama yapmıştır. Çalışmasının sonucunda derin öğrenme yöntemlerinden biri olan VGG-16 mimarisinin en iyi başarıyı elde ettiğini görmüştür (Zakiroğlu, 2019).

Güraksın 2015 yılında yaptığı doktora tezi çalışmasında, kemik yaşı değerlendirmesi için yapay zeka yöntemlerini kullanmıştır. Yapılan çalışmada, benzer yöntemlerin kullanıldığı diğer yöntemlere göre çok daha yüksek başarı oranı sağlandığı görülmüştür. Bu başarıyı yapılan ön işleme yöntemleri etkilemiştir (Güraksın, 2015).

Çelik 2016 yılında hazırladığı yüksek lisans tezinde, kemik yaşı değerlendirmesi için yeni bir yöntem geliştirmiş ve Yapay Sinir Ağları (YSA) kullanarak otomatik bir sistem ortaya koymuştur. Yapılan bu çalışmada dirsek ve ön kol kemiklerinin görüntüleri üzerine çalışılmıştır. Tasarlanan sistem sonucunda uzman ihtiyacı ortadan kaldırılmış olup, daha önce iki uzman tarafından yaş etiketi yapılan 170 röntgen filmi üzerinde çalışılmıştır. Bu çalışmanın sonucunda ise 0.39 yıl Ortalama Karesel Hata (Mean Squared Error - MSE) ile kemik yaşı tahmini yapılmıştır (Çelik, 2016).

2.3. Derin Öğrenme Yöntemleri ile Yapılan Çalışmalar

Li ve arkadaşlarının 2023 yılında hazırladıkları bir çalışmada, iki aşamalı derin öğrenme modeli önerilmiştir. İlk olarak el bilek röntgen görüntüleri üzerinde, geliştirilmiş bir Inception V3 ağı kullanılarak kemikler üzerindeki kritik bölgeler tespit edilmiştir. Tespit edilen kritik bölgeler, görsel üzerinde belirlenerek ilgili alan tekrar kritik bölge tespitinden geçirilmiştir. Daha sonra kırılan görüntülerden özellik çıkarımı için, Xception ve ResNet50 modelleri çalıştırılmıştır. Bu çalışmanın sonucu iki ayrı veri setinde değerlendirilmiş olup; RSNA veri setinde 5.45 ay MAE hesaplanırken; özel edinilen veri setinde ise 3.34 ay MAE hesaplanmıştır (Z. Li ve ark., 2023).

Liu ve arkadaşlarının 2022 yılında yapmış olduğu bir çalışmada, iki aşamalı yeni bir kemik yaşı tespiti yöntemi önerilmiştir. Bu yöntemde ilk olarak el segmentasyon yöntemi ile el bilek röntgen görüntülerinde ince özellik noktaları çıkarılmıştır. Bu işlem için Kabadan İnceye Segmentasyon (Coarse-to-Fine Segmentation – C2FS) önerilmiştir. Kaba segmentasyon esnasında, görüntü üzerinde özellik noktaları çıkarılmıştır, sonrasında uygun şekilde kırpabilmek için gürültü algoritması ile işlenir. Hassas segmentasyon esnasında ise, kaba segmentlere ayrılan görüntüler üzerinde U-Net ağı çalıştırılarak görüntüler inceltir. Sonrasında ise Inception V3, Inception ResNet-V2, MobileNet-V2, ResNet-V2-50 ve VGG-16 gibi temel ağları istifleyen bir topluluk CNN'i (Ensemble CNNs - ECNNs) önerilmiştir. Bu çalışmaların sonucunu iki ayrı veri setinde değerlendirmişlerdir. RSNA veri setinde erkeklerde 5.43 MAE, kadınlarda 5.98 MAE hesaplanmışken; Chongqing Tıp Fakültesi Çocuk Hastanesi (Children's Hospital of Chongqing Medical University - CQMU) veri setinde ise erkeklerde 6.58 MAE ve kadınlarda 6.15 MAE hesaplanmıştır (Liu ve ark., 2022).

Su, Fu ve Hu'nun 2021 yılında yaptıkları çalışmada, el bilek röntgenleri kullanılarak kemik yaşı tespiti yapılabilmesi için yeni bir CNN modeli ve veri artırma için yeni bir çerçeve önermişlerdir. Önerilen model ve çerçevenin başarısı çalışmalarında kanıtlanmıştır (Su ve ark., 2021).

Vaca ve Danudibroto 2021 yılında, kemikleşen bölgelerin tespitine dayanan bir kemik yaşı değerlendirme çalışması gerçekleştirmişlerdir. Çalışmalarında yeni bir yöntem olan EfficientBA'yı tanıtan Vaca ve Danudibroto; yöntemlerini detaylı şekilde açıklamış ve ispatlamışlardır (Vaca ve Danudibroto, 2021).

Zhang ve Davison 2021 yılında, el bileği röntgen filmleri kullanılarak kemik yaşı tespiti için Karşıt Regresyon Öğrenme Ağı (Adversarial Regression Learning Network - ARLNet) önermişlerdir. Bu çalışmada öncelikle ince ayarlanmış bir Inception V3 ağında kemik özellikleri çıkarılmış olup eğitim için ise regresyon yüzdesi kaybı önerilmiştir (Y. Zhang ve Davison, 2021).

Sarić ve arkadaşları 2019 yılında yaptıkları çalışmada derin evrişimli sinir ağları (Deep Convolutional Neural Network - DCNN) algortimasını kullanarak cinsiyet ve kemik yaşı değerlendirmesi yapmışlardır. Sonuç olarak da klasik metodlardan daha hızlı bir şekilde sonuç elde edildiği görülmüştür (Sarić ve ark., 2019).

Wu ve arkadaşlarının 2019 yılında yaptıkları bir çalışmada, derin öğrenme yöntemleri ile kemik yaşı tespiti yapmak için kullanılan röntgen filmlerine uygulanması üzerine bir çerçeve denemişlerdir. Çalışmanın sonucunda çerçevenin işe yaradığı görülmüştür (Wu ve ark., 2019).

Tang, Wu ve Shen'in 2019 yılında yaptıkları kemik yaşı tahmini çalışmasında, evrişimsel sinir ağları (Convolutional Neural Network - CNN) tabanlı bir ağ önermişlerdir. Önerdikleri ağ ile ilgili elde ettikleri sonuçları da çalışmalarında sunmuşlardır (Tang ve ark., 2019).

Reddy ve arkadaşları 2020 yılında yaptıkları çalışmada, bu alanda çoğunlukla kullanılan sol el bileği verilerinin aksine, yalnızca işaret parmağı röntgen verisini ve CNN algoritmasını kullanarak kemik yaşı değerlendirmesi yapmışlardır. Çalışmalarının sonucunda, insan tabanlı değerlendirmelere karşın çok daha iyi sonuç alındığı raporlanmıştır (Reddy ve ark., 2020).

Li ve arkadaşlarının 2021 yılında yaptıkları çalışmada ise, kemik yaşı tespiti için derin öğrenme yöntemleri önerilmiştir. Çalışmanın sonucunda, insan tabanlı yöntemlere göre daha iyi başarımlar elde edildiği görülmüştür (S. Li ve ark., 2021).




3. MATERYAL VE YÖNTEM

Bu çalışmada kullanılan veri seti, kullanılan teknolojilerin açıklamaları, derin öğrenme mimarileri ve katmanları, önerilen model bu bölümde ele alınmıştır.

3.1. Veri Seti

RSNA Pediatrik Kemik Yaşı Mücadelesinde kullanılan; Stanford Üniversitesi ve Colorado Üniversitesi tarafından geliştirilen el röntgen görsel verileri ve bu görsel verilere ait excel dosyalarındaki veriler kullanılmıştır. Toplamda 12611 el röntgen verisi kullanılmıştır. Röntgen verileri 0-18 yaş grubuna aittir ve 6833 erkek, 5778 kadın grafisi mevcuttur. Kemik yaşı, ay cinsinden etiketlenmiş olup 1-228 aralığındadır. Şekil 3.1’de, bu veri setinde bulunan el röntgen görsellerinden birkaçı yer almaktadır.




Şekil 3.1: Veri Seti Örnek Verileri

Çizelge 3.1’de, kullanılan görsel veri setine ait excel verilerinden bazıları yer almaktadır.

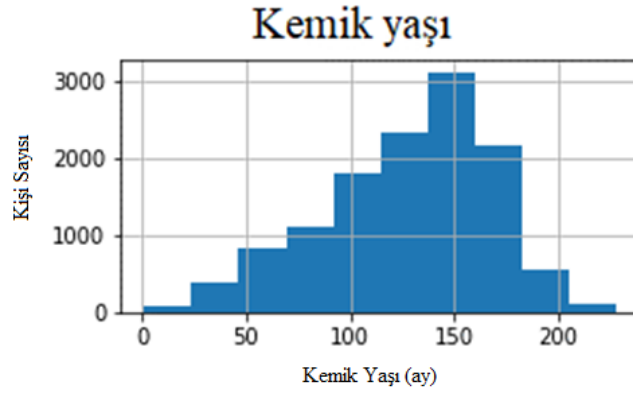
Çizelge 3.1: Veri Setine Dair Excel Verilerinden Bazıları

ID	Erkek	Kemik Yaşı (ay)
1386	Yanlış	30
1392	Doğru	162
1397	Yanlış	18
1401	Yanlış	132
1410	Doğru	57
1413	Doğru	150
1421	Doğru	24



Şekil 3.2: Veri Seti Cinsiyet Dağılım Grafiği

Şekil 3.2’de veri setindeki cinsiyet dağılımının grafiği görülmektedir.



Şekil 3.3: Veri Seti Kemik Yaşı Dağılım Grafiği

Şekil 3.3’de veri setindeki el röntgenlerinin sahibi deneklerin kemik yaşlarının dağılımının grafiği görülmektedir.

3.2. Ön İşleme


Bu çalışmada kullanılan RSNA veri setindeki x-ray görüntülerinin, derin öğrenme yöntemlerinde kullanılabilmesi için çeşitli ön işlemlerden geçirilmesi gerekmektedir. Ham görüntülerin her biri farklı boyutlarda ve görünümündedir. İlk olarak bu görüntüler 512x512 olarak yeniden boyutlandırılmıştır. Bu boyutun seçilme sebebi ise, yapılan araştırmalara göre görüntülerde daha fazla ayrıntının yakalanabilmesidir. Bununla birlikte her modelin beklediği minimum giriş boyutu farklılık gösterebilir. Verilen hedef boyut yükseldikçe, model; görüntülerde daha fazla ayrıntı yakalayabilirken boyut azaldıkça daha az ayrıntı öğrenilir. Buna karşın boyut arttıkça model daha uzun sürede eğitilir.

3.3. Veri Artırma

Veri seti içerisinde tüm cinsiyet ve yaşlarda eşit veriler olmadığından, daha sağlıklı bir sonuç alınabilmesi ve aşırı öğrenmeden kaçınılması amacıyla veri artırımı yapılmıştır. Veri artırımı yapılırken kullanılan yöntemler ise, orijinal veri üzerinde; yatay eksen etrafında simetri oluşturma, yükseklik kaydırma, genişlik kaydırma, görüntüyü döndürme ve yaklaştırmadır.

3.3.1. Yatay eksen etrafında simetri oluşturma (horizontal flip)

Yatay eksen etrafında simetri oluşturarak veri artırma, görüntüleri yatay olarak çevirerek veri artırma işlemi uygular. Bu, aynı görüntülerin ek varyasyonlarına maruz bırakarak bir modelin doğruluğunu artırmaya yardımcı olabilir. Aşağıdaki Şekil 3.4'de soldaki görüntü orijinal el bilek röntgen görüntüsüdür. Sağdaki görsel ise aynı görüntünün yatay eksen etrafında simetri oluşturma işlemi uygulanmış görüntüsüdür.



Şekil 3.4: Sol: Orijinal Görüntü; Sağ: Yatay Eksen Etrafında Simetri Oluşturulmuş Görüntü

3.3.2. Yükseklik kaydırma (height shift)

Yükseklik kaydırma işlemiyle veri artırımı, görüntünün aşağı veya yukarı rastgele kaydırılmasıyla elde edilir. Böylece aynı görüntünün farklı modellerini veri setine eklemiş oluruz. Aşağıdaki Şekil 3.5'de, soldaki görüntü orijinal el bilek röntgen görüntüsüdür ve sağdaki de aynı görüntünün yükseklik kaydırma işlemi uygulanmış halidir.



Şekil 3.5: Sol: Orijinal Görüntü; Sağ: Yükseklik Kaydırma İşlemi Uygulanmış Görüntü
(Kaymaz, 2022)

3.3.3. Genişlik kaydırma (width shift)


Genişlik kaydırma işlemiyle veri artırımı, görüntünün sağa veya sola rastgele kaydırılmasıyla elde edilir. Böylece aynı görüntünün farklı modellerini veri setine eklemiş oluruz. Aşağıdaki Şekil 3.6'da, soldaki görüntü, orijinal el bilek röntgen görüntüsü olup sağdaki görüntü ise, aynı görüntünün genişlik kaydırma yöntemi ile elde edilen yeni bir varyasyondur.



Şekil 3.6: Sol: Orijinal Görüntü; Sağ: Genişlik Kaydırma İşlemi Uygulanmış Görüntü
(Kaymaz, 2022)

3.3.4. Görüntüyü döndürme (rotation)

Görüntüyü döndürme işlemiyle veri artırımı, görüntünün belirli bir derecede rastgele döndürülmesiyle elde edilir. Böylece aynı görüntünün farklı varyasyonları elde edilmiş olur. Aşağıdaki Şekil 3.7'de, soldaki görüntü, orijinal el bilek röntgen görüntüsü olup sağdaki görüntü ise, aynı görüntünün döndürme yöntemi ile elde edilen yeni bir halidir.



Şekil 3.7: Sol: Orijinal Görüntü; Sağ: Döndürme İşlemi Uygulanmış Görüntü

3.3.5. Görüntüyü yaklaştırma (zoom)

Yakınlaştırma ile veri artırımı, görüntü üzerinde rastgele bir yakınlaştırma yaparak veriyi çoğaltır. 1,0'dan küçük bir yakınlaştırma görüntüyü büyütürken, 1,0'dan büyük bir yakınlaştırma görüntüyü uzaklaştırır. Aşağıdaki Şekil 3.8'de, soldaki görüntü, orijinal el bilek röntgen görüntüsü olup sağdaki görüntü ise, aynı görüntünün yakınlaştırma yöntemi ile elde edilen yeni bir varyasyonudur.



Şekil 3.8: Sol: Orijinal Görüntü; Sağ: Yakınlaştırma İşlemi Uygulanmış Görüntü

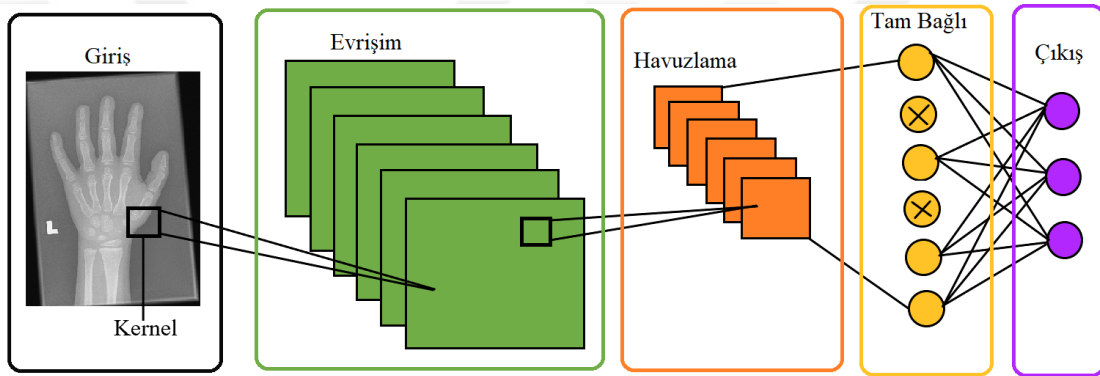
(Kaymaz, 2022)

3.4. Derin Öğrenme Yöntemi ve Katmanları

Derin öğrenme deyimini ilk kez 2000'li yıllarda Igor Aizenberg ve arkadaşları tarafından YSA hakkında konuşulurken kullanılmıştır (Aizenberg ve ark., 2000). Derin öğrenme, makine öğrenmesinin; makine öğrenmesi de yapay zekanın bir alt koludur

denebilir. İlk makine öğrenme algoritması 1952 yılında IBM laboratuvarlarında geliştirilmiştir.

Bu çalışmada derin öğrenme yöntemleri kullanılmıştır. Derin öğrenme, makine öğrenmesinin aksine; ham görüntülerden özellik çıkarma yeteneğine sahiptir. Makine öğrenmesi yöntemlerinde ise özellik çıkarımını geliştirici yapmak zorundadır. Dolayısıyla derin öğrenme yöntemi daha sağlıklı sonuçlar verebilmektedir. Görüntü sınıflandırması için kullanılan algoritma, derin öğrenme tabanlı CNN algoritmasıdır. CNN, çok katmanlı sinir ağı türüdür ve görüntülerin pixel değerleri direkt olarak algoritmaya yüklenerek görüntü tanınması için kullanılabilir. CNN, 3 katmandan oluşur. Bu katmanlar; giriş katmanı, gizli katman ve çıkış katmanıdır.



Şekil 3.9: CNN Katmanları

Yukarıdaki Şekil 3.9’da CNN katmanları görülmektedir. Giriş katmanından giren görüntü, evrişim ve havuzlama katmanları ile özellik çıkardıktan sonra tam bağlı ve çıkış katmanlarında sınıflandırma işlemini yapar. Tam bağlı katmanlarda çarpı ile gösterilen katmanların sebebi; görseldeki CNN mimarisinde seyreltme işleminin uygulanmış olmasıdır. Seyreltme katmanı olmadığında, tüm katmanlar işleme dahil olmaktadır.

3.4.1. Giriş katmanı

CNN mimarisinin ilk ve veri girişinin sağlandığı katmandır. Girdi görüntülerinin boyutları mimarilere göre çeşitlilik gösterebilmektedir. Veri boyutları yüksek seçilirse, başarı oranı artabilir. Veri boyutu arttıkça eğitim süresi ve bellek ihtiyacı da artar. Veri boyutları küçük seçilirse, süre ve bellek ihtiyacı azalırken başarı oranı da düşer. Bu

boyut, kullanılacak olan mimarinin gereksinimlerine ve çalışmada kullanılacak veri setine uygun olarak seçilmelidir. Seçilen boyut, tüm çalışmanın seyrini değiştirebilir.

3.4.2. Evrişim katmanı

Derin öğrenme mimarilerinde yaygın olarak kullanılır. Özellikle görüntü işleme alanında etkili sonuçlar veren bir yapay sinir ağı katmanıdır (LeCun ve ark., 2015). Evrişim katmanı, görüntü verilerinin özelliklerini öğrenmek ve temsil etmek için kullanılır.

Evrişim katmanı, girdi veri üzerinde filtreleme işlemi yapar ve özellik haritası çıkarır. Bu filtreler, girdi görüntüleri üzerinde belirli boyutlarda kayarak görüntüdeki özellikleri yakalamaya çalışır (Zeiler ve Fergus, 2014). Her bir kaydırma işlemi sonucunda elde edilen çıktı, özellik haritasının bir kanalını oluşturur. Bu işlem, farklı filtrelerin uygulanmasıyla tekrarlanır ve böylece farklı özellik haritaları elde edilir.

Evrişim katmanları, paylaşılan ağırlıkları kullanarak ağırlık parametrelerini önemli ölçüde azaltır, bu da modelin daha hızlı ve daha verimli çalışmasını sağlar.

Bu katman, derin öğrenme modellerinde önemli bir bileşen olarak kabul edilir ve birçok başarılı görüntü sınıflandırma, nesne tanıma ve segmentasyon modeli tarafından kullanılmıştır (LeCun ve ark., 2015). Evrişim katmanlarının başarıları, 2012 yılında AlexNet modelinin ImageNet veri seti üzerindeki görüntü sınıflandırma yarışmasını kazanmasıyla kanıtlanmıştır (Krizhevsky ve ark., 2017).

Evrişim katmanında kullanılan filtreler, özelliklerin belirli boyutlarda yakalanmasını sağlar (Zeiler ve Fergus, 2014). Farklı boyutlardaki filtreler, farklı özellikleri algılamak için kullanılır. Örneğin, küçük boyutlu filtreler kenarları ve çizgileri yakalamak için etkili iken, büyük boyutlu filtreler ise daha geniş yapıları, örneğin yüzleri veya nesnelere algılamada daha etkilidir.

Evrişim katmanındaki filtreler, veriye uyarlanabilir ağırlıklarla başlar ve ardından eğitim süreci boyunca bu ağırlıklar optimize edilir (Simonyan ve Zisserman, 2014). Bu optimizasyon süreci, filtrelerin görüntü verilerindeki önemli özellikleri algılaması ve çıktılarını oluşturması için gereklidir. Eğitim süreci, genellikle büyük veri setleri üzerinde gerçekleştirilir ve gradient tabanlı optimizasyon algoritmaları kullanılır.

Evrişim katmanında kullanılan filtreler, bir filtre tarafından öğrenilen bir özelliğin aynı özellikleri içeren farklı bölgelerde de tanınabilir hale gelmesini

sağlayacak şekilde işler (Zeiler ve Fergus, 2014). Paylaşılan ağırlıklar sayesinde, ağı öğrenme sürecinde önemli ölçüde parametre tasarrufu sağlanır ve model daha hızlı çalışır.

3.4.3. Aktivasyon katmanı

Aktivasyon katmanı, aktivasyon fonksiyonları aracılığıyla sinir ağındaki çıktıların belirli bir aralığa dönüştürülmesini sağlar. Sigmoid, ReLU (Rectified Linear Unit), tanh (hyperbolic tangent) gibi popüler aktivasyon fonksiyonları, non-lineerlik ekleyerek ve sıkıştırma işlemi yaparak sinir ağına esneklik ve ifade gücü katmaktadır (Glorot ve ark., 2011).

Aktivasyon katmanı, geriye doğru yayılım sürecinde gradientin etkin bir şekilde iletilmesini sağlar. Aktivasyon fonksiyonları, gradientin geriye doğru, doğru şekilde iletilmesini ve ağı öğrenme sürecinde uygun güncellemelerin yapılabilmesini sağlar (Nielsen, 2015).

Aktivasyon katmanı, çıktıları ölçeklendirme ve normalizasyon işlemleri için de kullanılabilir. Örneğin, Softmax aktivasyon fonksiyonu, sınıflandırma problemlerinde çıktıları olasılık dağılımına dönüştürürken, Batch Normalization katmanı; çıktıları normalize ederek daha kararlı ve hızlı bir öğrenme süreci sağlar (Ioffe ve Szegedy, 2015).

3.4.4. Havuzlama katmanı

Havuzlama katmanı, derin öğrenme modellerinde kullanılan ve özellik haritalarını küçültmek, özelliklerin ölçeklendirilmesini sağlamak ve çeşitli veri dönüşümlerini gerçekleştirmek için kullanılan bir yapay sinir ağı katmanıdır.

Havuzlama katmanı, özellik haritalarını küçültmek ve boyutsal karmaşıklığı azaltmak için kullanılır. Bu, ağı hesaplama yükünü azaltır ve daha hızlı öğrenme süreci sağlar (Srivastava ve ark., 2014). Havuzlama işlemi, çeşitli boyutlarla uygulanabilir. Maksimum havuzlama veya ortalama havuzlama gibi farklı işlemlerle gerçekleştirilebilir.

Havuzlama katmanı, özelliklerin belirli bir konuma göre durumuna değil, varlığına odaklanır. Örneğin, bir nesnenin farklı konumlarında aynı özellikleri

yakalamak için havuzlama katmanı kullanılabilir. Bu da nesne tanıma ve yerel desenlere dayalı görevlerde daha iyi performans sağlar (He ve ark., 2015).

Havuzlama katmanı, sinir ağındaki öğrenme kapasitesini azaltabilir. Bu, özelliklerin küçültülmesi ve ölçeklendirilmesiyle birlikte, bazı ayrıntıların kaybedilmesine neden olabilir. Ancak bu, genel bir öğrenme performansını olumsuz yönde etkilemeden modelin hesaplama gücünü azaltır ve aşırı öğrenmeye karşı daha dirençli hale getirebilir (Bengio ve ark., 2013).

3.4.5. Tam bağlı katman

Tam bağlı katman, derin öğrenme modellerinde yaygın olarak kullanılan ve yapay sinir ağındaki tüm girdi birimleriyle bağlantı kurarak çıktıları hesaplayan katmandır (LeCun ve ark., 2015).

Tam bağlı katmanda, her çıktı birimi (nöron), giriş katmanındaki tüm birimlerle bağlantı kurar ve ağırlıklar ile çarpılarak aktivasyon fonksiyonuna tabi tutulur. Bu sayede girdi verileri üzerinde öğrenilen ağırlıklar ve aktivasyon fonksiyonu aracılığıyla çıktılar hesaplanır (Goodfellow ve ark., 2016).

Bu katmanda, her bir bağlantı arasında bir ağırlık parametresi bulunur. Bu ağırlıklar, geriye doğru yayılım algoritmasıyla öğrenilir ve güncellenir. Ayrıca, her bir çıktı birimi için bir bias terimi kullanılır. Bu ayarlanabilir parametreler, modelin veriye uyum sağlaması ve doğru çıktıları üretmesi için optimize edilir (Nielsen, 2015).

Tam bağlı katman, veri üzerinde yüksek seviyede özneliklerin öğrenilmesini sağlar. Önceki katmanlarda çıkarılan düşük seviyeli özelliklerin kombinasyonu ile daha karmaşık ve soyut öznelikler oluşturulabilir. Bu sayede, veri setindeki karmaşık yapılar ve ilişkiler model tarafından daha iyi yakalanabilir (Krizhevsky ve ark., 2017).

Tam bağlı katman, genellikle önceki katmanların çıktılarının boyutlarını dikkate alır. Girdi boyutlarına uyum sağlamak için boyut dönüşümü işlemi uygulanabilir. Özellikle, konvolüsyonel sinir ağı gibi diğer katman türleriyle birleştirildiğinde, verinin düzleştirilerek tam bağlı katmana beslenmesi gerekebilir.

3.4.6. Seyreltme katmanı

Seyreltme katmanı, derin öğrenme modellerinde kullanılan ve aşırı öğrenmeyi azaltmak ve ağın sağlamlığını artırmak için kullanılan bir yapay sinir ağı katmanıdır.

Seyreltme katmanı, aşırı öğrenmeyi azaltmak için etkili bir yöntemdir. Aşırı öğrenme, bir modelin eğitim verilerine çok fazla uyum sağlaması ve yeni verilere tahmin yapma yeteneğinin düşmesidir. Seyreltme katmanı, her öğrenme adımında rastgele bazı çıktı birimlerini devre dışı bırakarak ağın öğrenimini sınırlar. Bu sayede, aşırı uyum engellenir ve modelin başarısı artar.

Seyreltme katmanında seyreltme oranı (dropout rate) olarak adlandırılan bir parametre belirlenir. Seyreltme oranı, her bir öğrenme adımında devre dışı bırakılacak birimlerin yüzdesini belirler. Örneğin, 0.5 seyreltme oranı, her adımda rastgele olarak %50 birim devre dışı bırakılır. Bu hesaplama süreci, öğrenme ve geriye yayılım algoritmaları arasında gerçekleştirilir (Goodfellow ve ark., 2016).

Seyreltme katmanı, ağın sağlamlığını artırmak için kullanılır. Sağlamlık, modelin gürültülü veya eksik veriyle karşılaştığında bile doğru sonuçlar üretme yeteneğidir. Seyreltme katmanı, her birimin devre dışı bırakılmasıyla ağın birimlere bağımlılığını azaltır ve daha istikrarlı bir öğrenme süreci sağlar. Böylece, model gürültülü veya eksik veriyle karşılaştığında bile güvenilir sonuçlar elde edebilir (Krizhevsky ve ark., 2017).

3.4.7. Sınıflandırma katmanı

Sınıflandırma katmanı, derin öğrenme modellerinde kullanılan ve girdi verilerini farklı sınıflara veya kategorilere ayırmak için kullanılan bir yapay sinir ağı katmanıdır.

Sınıflandırma katmanında genellikle softmax aktivasyon fonksiyonu kullanılır. Softmax fonksiyonu, her bir çıktı biriminin bir sınıfa ait olasılık değerini hesaplar. Bu sayede modelin çıktıları bir olasılık dağılımı olarak yorumlanabilir ve en yüksek olasılığa sahip sınıf tahmini seçilebilir (Goodfellow ve ark., 2016).

Sınıflandırma katmanı, ikili ya da daha fazla sınıflandırma problemlerinde kullanılabilir. Çok sınıflı sınıflandırmada, çıktı birimleri sınıf sayısı kadar olur ve her bir birim bir sınıfı temsil eder. İkili sınıflandırmada ise genellikle bir çıktı birimi kullanılır ve sonuç 0 veya 1 olarak yorumlanır (Bishop ve Nasrabadi, 2006).

Sınıflandırma katmanında, genellikle cross-entropy kayıp fonksiyonu kullanılır. Cross-entropy, modelin tahminlerinin gerçek sınıf etiketleriyle ne kadar uyumlu olduğunu ölçer. Modelin eğitimi, geriye yayılım (backpropagation) algoritması ve gradyan inişi (gradient descent) gibi optimizasyon yöntemleri kullanılarak gerçekleştirilir (Haykin, 2009).

3.4.8. Yumuşatma katmanı

Yumuşatma katmanı, derin öğrenme modellerinde kullanılan ve özellik haritalarının boyutunu küçültmek ve özelliklerin ölçeklendirilmesini sağlamak için kullanılan bir yapay sinir ağı katmanıdır (LeCun ve ark., 2015).

Yumuşatma katmanı, özellik haritalarının boyutunu azaltarak hesaplama yükünü azaltır ve ağın işlem hızını artırır. Bu işlem, girdi verilerini daha küçük bölgelere ayırır ve her bölgeden tek bir özellik değeri elde eder. Böylece, özellik haritalarının boyutu küçülürken önemli özellikler korunur.

Yumuşatma katmanında yaygın olarak kullanılan işlemler, maksimum havuzlama ve ortalama havuzlama olarak bilinir. Maksimum havuzlama, her bir bölgedeki maksimum özellik değerini alarak boyut azaltmayı sağlar. Ortalama havuzlama ise her bir bölgedeki özellik değerlerinin ortalamasını alarak ölçeklendirmeyi gerçekleştirir (Goodfellow ve ark., 2016).

Yumuşatma katmanında, havuzlama boyutu ve adımı gibi parametreler belirlenir. Havuzlama boyutu, girdi verilerinin bölgelere bölünme büyüklüğünü belirler. Havuzlama adımı ise bölgelerin birbirinden ne kadar kaydırılacağını belirler. Bu parametreler, modelin ölçeklendirme ve konumsal duyarlılık özelliklerini kontrol etmede önemli bir rol oynar (Haykin, 2009).

3.5. Karşılaştırılan Mimariler

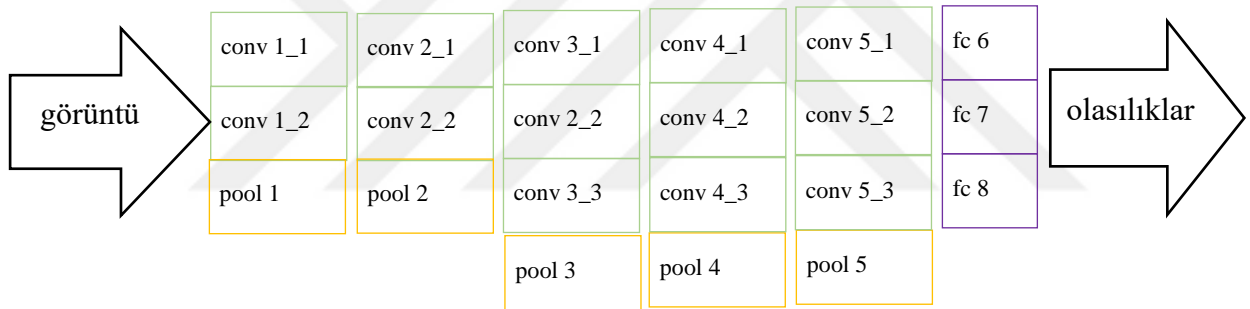
CNN ile işlem yapılabilmesi için oldukça uzun bir zaman ve çok fazla veri gereklidir. Bu nedenle önceden eğitilmiş VGG-16, MobileNet, Inception V3 gibi çeşitli mimariler tanıtılmıştır (Wibisono ve ark., 2019).

Önceden eğitilmiş mimariler; veri sınıflandırması için veya özellik çıkarmak için de kullanılabilirler. Bu çalışma kapsamında yapılan deneysel çalışmalarda önceden

eđitilmiş VGG-16, Inception V3 ve MobileNet mimarileri kullanılmıř ve sistem CNN ile tekrar eđitilmiřtir. Karřılařtırma sonucuna gore en iyi sonucu veren model uzerinde katman geliřtirme uygulanmıřtır.

3.5.1. VGG-16

VGG-16 mimarisi, en sade modellerden biridir. İsmindeki 16; 16 parametrelilikatmandan oluřtuđunu vurgulamaktadır. Sistemattiktir. Őekil 3.10’da de gorolduđu gibi; 21 ana katmandan oluřur. Mimari artan ađ yapısına sahiptir. VGG-16 icin goruntu giriř boyu minimum 224 x 224 olmalıdır. Gelen goruntu, evriřimsel katmanında 3 x 3 boyutunda filtreden gecirilir. Son katmanlar ise tam bađlantılı katmanlardan oluřur. Tam bađlantılı katmanlar ozellik ıkarımlarının yapıldıđı katmanlardır (Tođaar ve ark., 2020).



Őekil 3.10: VGG-16 Mimarisi

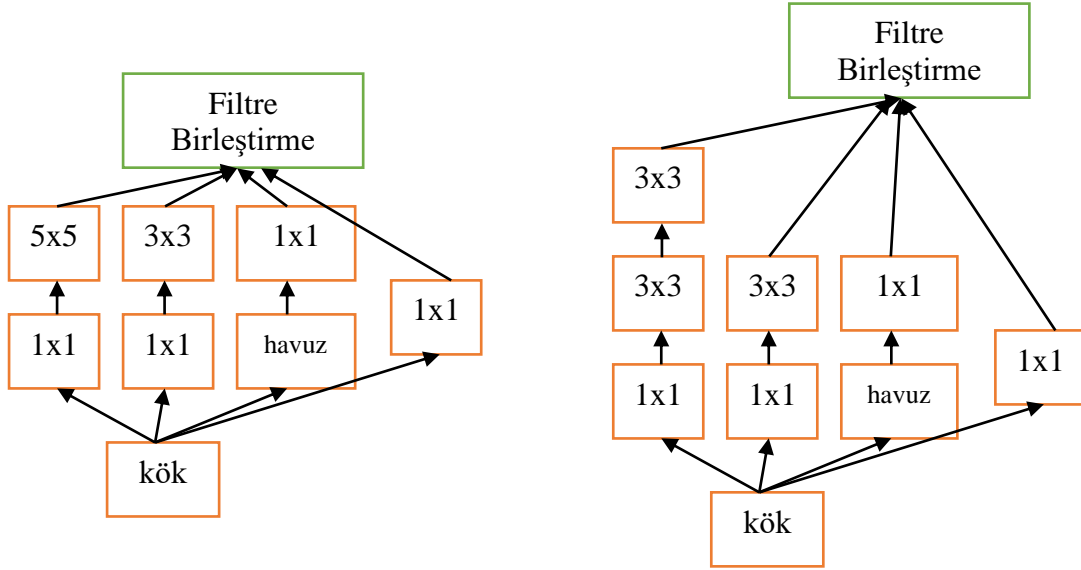
Ařađıda izelge 3.2’de, VGG-16 katmanları gorlmektedir.

Çizelge 3.2: VGG-16 Model Katmanları

Tip	Adım	Boyut	Çekirdek Boyutu
2 x Evrişim	1	224 x 224 x 64	3 x 3
Max Havuzlama	2	112 x 112 x 64	3 x 3
2 x Evrişim	1	112 x 112 x 128	3 x 3
Max Havuzlama	2	56 x 56 x 128	3 x 3
3 x Evrişim	1	56 x 56 x 256	3 x 3
Max Havuzlama	2	28 x 28 x 256	3 x 3
3 x Evrişim	1	28 x 28 x 512	3 x 3
Max Havuzlama	2	14 x 14 x 512	3 x 3
3 x Evrişim	1	14 x 14 x 512	3 x 3
Max Havuzlama	2	7 x 7 x 512	3 x 3
FC	-	25088	-
FC	-	4096	-
FC	-	4096	-
Softmax	-	1000	-

3.5.2. Inception V3

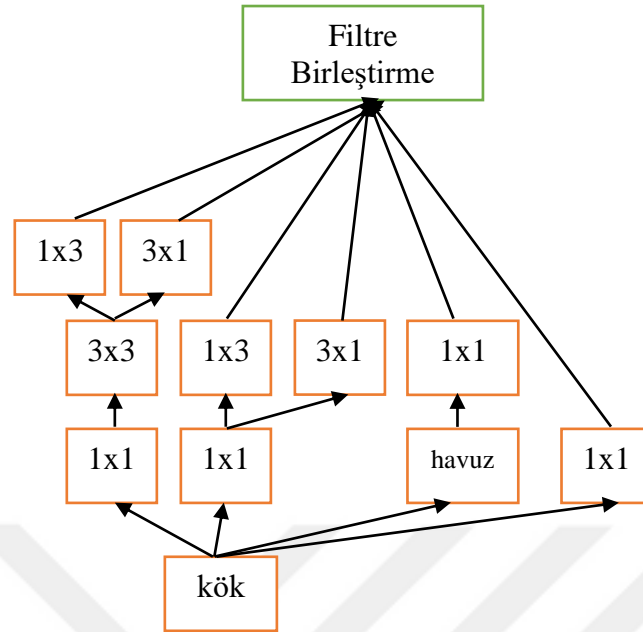
Inception V3 mimarisi, görüntü sınıflandırma işlemlerinde en çok kullanılan ve en gelişmiş mimarilerden biridir. Google tarafından geliştirilen Inception V1 modelinin geliştirilmiş versiyonudur. Bu model, birden fazla modülden oluşur. Temel modül; 1x1 evrişim, 3x3 evrişim, 5x5 evrişim ve 3x3 maksimum havuzlama olarak 4 paralel katmandan oluşur. Evrişim, görüntüdeki her piksele ve komşularına bir çekirdek uygulayarak görüntüyü dönüştürme işlemidir. Havuzlama ise, özellik haritasının boyutlarını küçültmek için uygulanan işlemidir. Resimdeki farklı boyutlardaki bilgileri yakalamak için farklı boyutlarda evrişimler uygulanır. Inception V3 modelinde ise, V1 modeli geliştirilmiş ve optimize edilmiştir. V1 ve V2'ye göre daha derin bir ağ yapısı vardır, buna rağmen hızlıdır. Yüksek verimliliğe sahiptir. 42 katmandan oluşur ve önceki Inception modellerine göre çok daha düşük hata oranı vardır. Farklı boyutlardaki 2 veya daha fazla evrişimsel filtreleri, bir filtrede birleştiren bir model kullanır. Böylece eğitilmesi gereken parametre sayısı, dolayısı ile de hesaplamadaki karmaşıklık azalır.



Şekil 3.11: Inception V1 ve Inception V3 Modülleri

Yukarıdaki Şekil 3.11’de Inception V1 ve V3 modellerinin modülleri görülmektedir. Modül yapılarına bakıldığında, V1 modelinde 5x5 olan evrişim katmanının, V3 modelinde 3x3lük iki evrişim katmanı ile değiştirildiği görülür. Bu güncelleme, parametre sayısını, dolayısı ile hesaplama maliyetini azaltır.

Inception V3 modelinde asimetrik evrişim katmanları da geliştirilmiştir. Asimetrik evrişim katmanlarındaki $n \times n$ yerine $n \times 1$ ve $1 \times n$ olmak üzere iki katmanı art arda kullanır. Buraya kadar anlatılan 2 optimizasyon işlemi de uygulandıktan sonra, V3 için modül görünümü Şekil 3.12’deki gibi olur.



Şekil 3.12: Inception V3 Modülü Son Hali

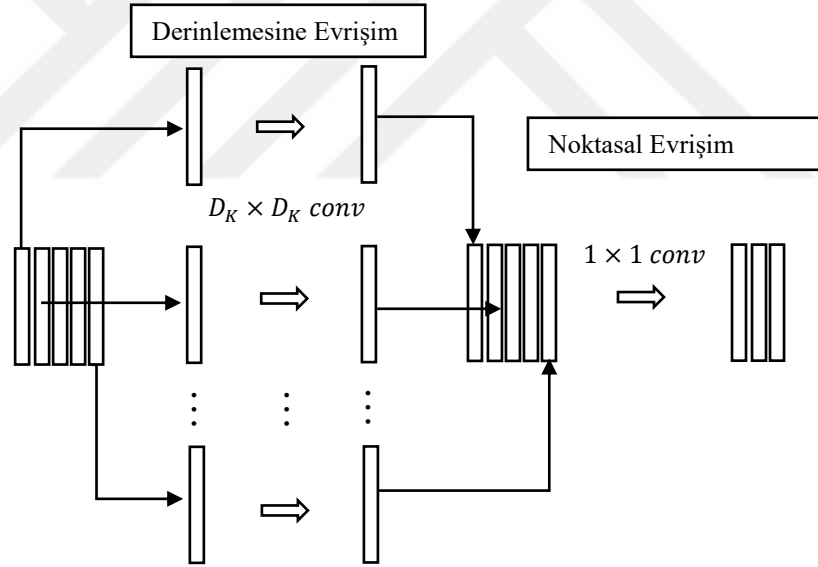
Aşağıdaki Çizelge 3.3’de Inception V3’ün katmanları görülmektedir.

Çizelge 3.3: Inception V3 Model Katmanları

Tip	Adım	Boyut	Çekirdek Boyutu
Evrişim	2	299 x 299 x 3	3 x 3
Evrişim	1	149 x 149 x 32	3 x 3
Evrişim	1	147 x 147 x 32	3 x 3
Havuzlama	2	147 x 147 x 64	3 x 3
Evrişim	1	73 x 73 x 64	3 x 3
Evrişim	2	71 x 71 x 80	3 x 3
Evrişim	1	35 x 35 x 192	3 x 3
Inception Modül	-	35 x 35 x 288	Üç Modül
Inception Modül	-	17 x 17 x 768	Beş Modül
Inception Modül	-	8 x 8 x 1280	İki Modül
Havuzlama	-	8 x 8 x 2048	8 x 8
Linear	-	1 x 1 x 2048	Logits
Softmax	-	1 x 1 x 1000	Output

3.5.3. MobileNet

MobileNet modeli, özellikle mobil uygulamalarda kullanılmak üzere tasarlanmıştır. Derinlemesine ayrılabilir evrişimler kullanarak işlem yapar. Derinlemesine ayrılabilir evrişimler, derinlemesine evrişimden ve noktasal evrişim olarak adlandırılan 1×1 evrişiminden oluşur. MobileNet modelinde derinlemesine evrişim, her giriş kanalına tek filtre uygular. Daha sonra, noktasal evrişim; evrişim çıktılarını derinlik yönünden birleştirebilmek için 1×1 evrişimini uygular. Standart bir evrişim, yeni bir dizinin çıktısına tek adımda, giriş değerlerini hem filtreler hem de birleştirir. Derinlemesine ayrılabilir evrişim ise bu işlemi, filtreleme katmanı ve birleştirme katmanı olmak üzere iki ayrı katmanda yapar. Bu işlem sayesinde parametre sayısı önemli ölçüde azaltılır ve daha hafif bir ağ oluşumu sağlanır. Şekil 3.13'de derinlemesine ayrılabilir evrişim mimarisi görülmektedir.



Şekil 3.13: MobileNet Derinlemesine Ayrılabilir Evrişim Mimarisi

Aşağıdaki Çizelge 3.4'de ise, MobileNet modelinin katmanları görülmektedir.

Çizelge 3.4: MobileNet Model Katmanları

Tip	Adım	Filtre	Boyut
Evrişim	2	3 x 3 x 3 x 32	224 x 224 x 3
Derinlemesine Evrişim	1	3 x 3 x 32 de	112 x 112 x 32
Evrişim	1	1 x 1 x 32 x 64	112 x 112 x 32
Derinlemesine Evrişim	2	3 x 3 x 64 de	112 x 112 x 64
Evrişim	1	1 x 1 x 64 x 128	56 x 56 x 64
Derinlemesine Evrişim	1	3 x 3 x 128 de	56 x 56 x 128
Evrişim	1	1 x 1 x 128 x 128	56 x 56 x 128
Derinlemesine Evrişim	2	3 x 3 x 128 de	56 x 56 x 128
Evrişim	1	1 x 1 x 128 x 256	28 x 28 x 128
Derinlemesine Evrişim	1	3 x 3 x 256 de	28 x 28 x 256
Evrişim	1	1 x 1 x 256 x 256	28 x 28 x 256
Derinlemesine Evrişim	2	3 x 3 x 256 de	28 x 28 x 256
Evrişim	1	1 x 1 x 256 x 512	14 x 14 x 256
5 x (Evrişim	1	3 x 3 x 512 de	14 x 14 x 512
Derinlemesine Evrişim)	1	1 x 1 x 512 x 512	14 x 14 x 512
Derinlemesine Evrişim	2	3 x 3 x 512 de	14 x 14 x 512
Evrişim	1	1 x 1 x 512 x 1024	7 x 7 x 512
Derinlemesine Evrişim	2	3 x 3 x 1024 de	7 x 7 x 1024
Evrişim	1	1 x 1 x 1024 x 1024	7 x 7 x 1024
Ort. Havuzlama	1	Havuzlama 7 x 7	7 x 7 x 1024
FC	1	1024 x 1000	1 x 1 x 1024
Softmax	1	Sınıflandırıcı	1 x 1 x 1000

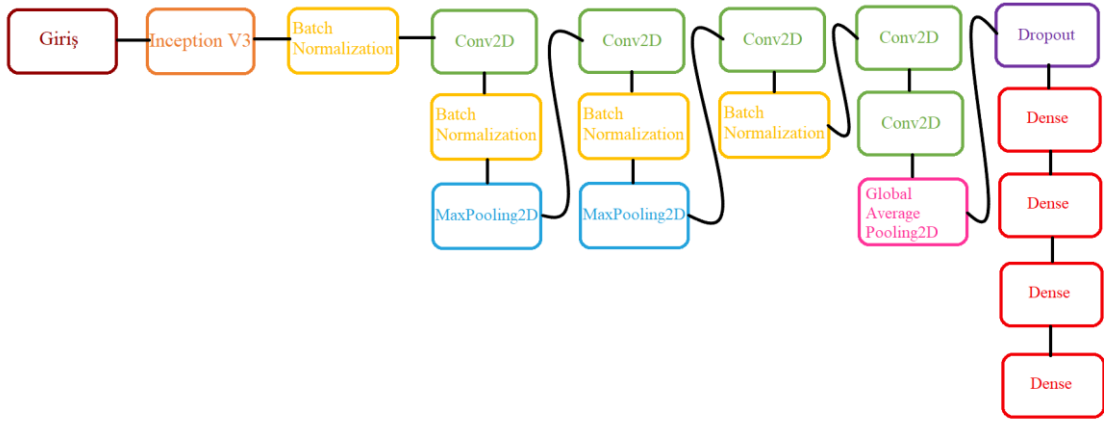
3.6. Inception V3 Üzerinden Geliştirilen Model

Inception V3 modeli, yaygın modeller arasında da en iyi sonucu vermiştir. Literatür incelendiğinde, var olan modeller üzerinde katman geliştirilmesi yapılarak; radyografi görüntüleri üzerinde tespit ve tahmin sonuçlarının başarılarının artırıldığı görülmüştür (Mujahid ve ark., 2022; Sağlam ve ark., 2022). Buna dayanarak, bu çalışmada Inception V3 üzerine yeni katmanlar eklenerek bir model oluşturulmuştur.



Şekil 3.14: Önerilen Modelin Katmanlarının Şeması
(Input, Inception_V3, BatchNormalization, Conv2D, MaxPooling2D, GlobalAveragePooling2D, Dropout, Dense)

Yukarıdaki Şekil 3.14’de bu çalışmada kullanılan CNN modelinin katmanlarının şeması görülmektedir. Input katmanından 512x512 boyutundaki el-bilek röntgen film görüntüleri modele giriş yapmaktadır. Bu boyutların neden seçildiği bölüm 3.2’de açıklanmıştır. Girdi görüntülerine Inception V3 modeli uygulanır. Inception V3 modelini eğitmek çok maliyetli olduğundan, transfer öğrenme yöntemi kullanılmış olup modelin daha önceki ağırlıkları korunarak çalıştırılmıştır. Inception V3 modelinin son katmanının çıktı şekli alınarak yeni katmanlar eklenmiştir. Inception V3 modelinin hemen ardından modeli daha düzenli hale getirmek için BatchNormalization katmanı eklenmiştir. Sonrasında modele eklenen evrişim katmanları sayesinde minimum kayıp ile daha iyi sonuçlara ulaşmak hedeflenmiştir (Şahin, 2017). Evrişim katmanları sırasıyla 512, 256 ve 128 çıktıya sahiptir. Aktivasyon fonksiyonu olarak, daha hızlı sonuç verdiği bilindiğinden ReLu kullanılmıştır. Eklenen her evrişim katmanı öğrenme sürecini artıracığından, ardından batch normalization katmanları eklenmiştir. Bunun sonucunda modelin eğitim süresi kısaltılmış ve modelin daha düzenli hale gelmesi amaçlanmıştır. Sonrasında ağırlıkların korunarak daha hızlı sonuç verebilmesi için yumuşatma yapılır ve sonrasında ise 4 tane dense katmanı eklenmiştir. Dense katmanları elu aktivasyon fonksiyonu ile eğitilmiş olup çıktıları sırasıyla 1024, 512 ve 128’dir. Son katmanda ise Linear aktivasyon fonksiyonu kullanılmıştır. Model oluşturulurken, CNN modeli oluşturma prensipleri dikkate alınmıştır. Başlangıçta yoğun öğrenme, ortalarda hafifletirme ve son katmanlarda tekrardan yoğun öğrenme gerçekleştirilmesi hedeflenmiştir. Aşağıdaki Şekil 3.15’de, geliştirilen modelin katmanları detaylı olarak gösterilmiştir.



Şekil 3.15: Geliştirilen Model Katman Mimarisi

Oluşturulan model Windows 10 işletim sistemi bulunan, AMD Ryzen 7 5700G işlemcili, 16GB RAM olan bilgisayar üzerinde 75 epoch 3 defada her seferinde 25 olacak şekilde çalıştırılmıştır. Modelin sonuç iyileştirip iyileştirmediği görülmesi için 75 epochluk birden fazla deneme yapılmıştır. Epoch sayısının 75'te bitirilmesinin sebebi; bir sonraki 25'lik epochluk eğitimde, modelin öğrenmesini çok iyi geliştirememesinin yanında işlem süresinin de çok artmasıdır. Tüm çalışmanın sonuçları kaydedilmiştir.

4. ARAŞTIRMA SONUÇLARI

Sinir ağı için gereken giriş boyunun her modelde farklı olması gerektiği ve ön işleme hızının normal düzeyde kalabilmesi için; veriler 512 x 512 olarak yeniden boyutlandırılmıştır. Daha büyük değerler ile daha iyi sonuçlar elde edilebilir ancak işlem süresi de oldukça artmaktadır. Daha küçük değerler ise daha hızlı sonuç vermekte ancak daha kötü sonuçlar elde edilmektedir. Dolayısıyla her model için en ideal boyut seçilmiştir.

Giriş görüntüleri VGG-16, Inception V3 ve MobileNet ağlarından ayrı ayrı geçirilir. Modeller, Adam optimizasyon yöntemi kullanılarak ortalama kare hata kaybı (Mean Squared Error - MSE) ile eğitilmiştir. Adam optimizasyon yöntemi, eğitim sürecinde ağırlıklarında değişiklikler yaparak ağ performansında iyileştirme yapmayı hedeflemektedir. Denklem 4.1, MSE hesaplaması için gereken formülü göstermektedir. Bu denklemde n, gözlem sayısıdır; e ise gerçek değer ile tahmin edilen değer arasındaki farktır. MSE makine öğrenmesi modelinin, tahmin sistemlerinin performansını ölçmek için kullanılır. Değeri her zaman pozitifdir ve sifıra yaklaştıkça tahmin performansı artar.

$$MSE = \frac{1}{n} \sum_{j=1}^n e_j^2 \quad (4.1)$$

Transfer öğrenme; öğrenimi daha verimli ve doğru bir hale getirebilmek için, daha önceki tecrübelerine bakarak öğrenme sürecini hızlandırır ve performansı artırır.

Yukarıda anlatılan işlemler yapıldıktan sonra klasik modeller kendi aralarında kıyaslanmıştır. Bu kıyaslama sonucunda MobileNet'in daha hızlı sonuç vermesine karşılık, Inception V3'ün daha iyi sonuç verdiği görülmüştür. Inception V3 taban alınarak bir model geliştirilmiştir. Geliştirilen bu model de yine Adam ve MSE yöntemleri kullanılarak eğitilmiştir.

En sonunda tüm modellerin sonuçlarının kıyaslanması için MAE ve RMSE değerlendirmesi kullanılmıştır ve CC ile sonuçlar arasındaki farklılıklar değerlendirilmiştir.

MAE, iki sürekli değişken arasındaki farkı ölçer. Gerçek değerlerle verilere en uygun çizgi arasındaki ortalama yatay mesafedir. Sıfırdan sonsuza kadar değer alabilir.

Daha düşük değerler, daha iyi performansın göstergesidir. Denklem 4.2, MAE hesaplaması için gereken formüldür. Bu denklemde n, gözlem sayısıdır; e ise gerçek değer ile tahmin edilen değer arasındaki farktır. Bu hata, MSE ile benzerlik göstermektedir ancak burada matematiksel olarak, ilgili farkın tam karşılığı işleme alınmaktadır.

$$MAE = \frac{1}{n} \sum_{j=1}^n |e_j| \quad (4.2)$$

RMSE, MSE'nin kareköküdür. Sonuçların, gerçek sonuçlardan ne kadar uzak olduğuna dair bir sonuç verir. Böylece diğer modellerle kıyaslama yapılabilir ve en optimum model seçilebilir. MSE değeri çok büyük olduğundan karşılaştırmak zordur. Bu yüzden karekökü alınarak karşılaştırma yapılabilir. MSE aykırı değerlere aşırı duyarlıdır. Denklem 4.3, RMSE formülünü göstermektedir. Bu denklemde n, gözlem sayısıdır; e ise gerçek değer ile tahmin edilen değer arasındaki farktır

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e^2} \quad (4.3)$$

CC, iki değişken arasındaki ilişkinin ne kadar güçlü olduğunu göstermek için kullanılan bir yöntemdir. Sonuç, -1 ile 1 arasında bir değerdir ve 1'e yaklaştıkça karşılaştırılan değerler arasındaki ilişkinin pozitif güçlü olduğu, -1'e yaklaştıkça da negatif güçlü olduğu anlaşılır. Sonuç sıfır ise, karşılaştırılan değerler arasında hiçbir ilişki yok demektir. En yaygın kullanılan korelasyon katsayısı yöntemi Pearson Korelasyondur.

$$Pearson Korelasyon = \frac{n(\sum xy) - (\sum x)(\sum y)}{\sqrt{[n \sum x^2 - (\sum x)^2][n \sum y^2 - (\sum y)^2]}} \quad (4.4)$$

Yukarıdaki Denklem 4.4, bu çalışmada kullanılan korelasyon katsayısının formülüdür. n değeri gözlem sayısını, x değeri gerçek değeri ve y değeri ise tahmin edilen değeri temsil etmektedir.

4.1. Sonular

Veri seti zerinde VGG-16, MobileNet, Inception V3 ve Inception V3 tabanlı yeni model uygulanmıř olup; modeller tarafından tahmin edilen yař ile gerek yař arasında farkın llebilmesi iin MAE, RMSE ve CC yntemleri kullanılmıřtır. Model eđitilirken Adam optimizasyon yntemi ve MSE kullanılmıřtır. Veri seti 80:20 oranında eđitim:test olarak ayrılmıřtır. Modellerin eđitimlerinde CNN transfer eđitimi kullanılmıřtır. nceden eđitilmıř ađırlıklar, yeni veri setleri zerinde bařlangı ađırlıkları olarak seilip tekrar eđitilmıřtir ve en iyi ađırlıklar tespit edilmiřtir. 0.93 CC sonucu ile bařarılı bir model geliřtirilmiřtir.

izelge 4.1: VGG-16, Inception V3, MobileNet ve nerilen Model MAE, RMSE ve CC Sonuları

Model	MAE	RMSE	CC
VGG-16	15.43	18.88	0.90
Inception V3	14.89	18.42	0.89
MobileNet	17.37	21.95	0.87
nerilen Model	8.23	10.74	0.93

izelge 4.1’de, uygulamada kıyaslanan modellerin MAE, RMSE ve CC sonuları yer almaktadır. Sonulara gre, nerilen modelin daha iyi sonu verdiđi; MobileNet modelinin ise daha kt sonu verdiđi grlmektedir.

izelge 4.2: nerilen Modelin Epochlara Gre MAE Sonuları

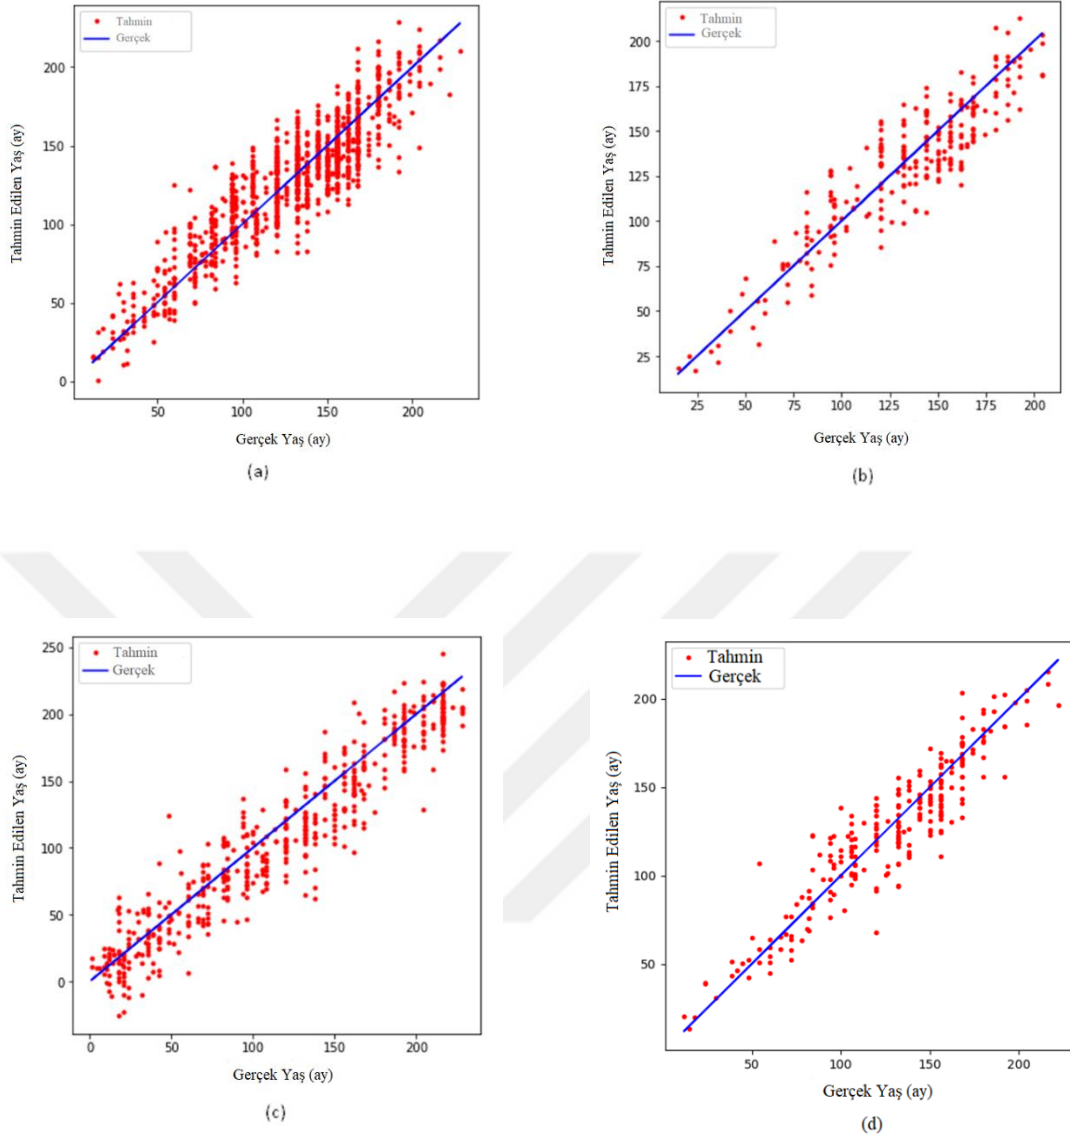
Epoch	MAE min	MAE max	MAE ortalama
25	11.67	12.34	11.90
50	8.96	9.23	9.11
75	8.11	8.71	8.23

izelge 4.2’de nerilen modelin alıřtırıldıđı epoch sayısına gre elde ettiđi maksimum, minimum ve ortalama MAE sonuları yer almaktadır. Tabloya bakıldıđında, epoch sayısı arttıca daha iyi sonu alındıđı grlmektedir.

Çizelge 4.3: MAE Sonuçlarının Diğer Çalışmalarla Kıyaslanması


Metod	Veri Seti	Epoch	MAE
(Spampinato ve ark., 2017)	RSNA	150	9.12
(Larson ve ark., 2018)	RSNA	-	6.24
(Zakiroğlu, 2019)	RSNA	25	14.43
(Pan ve ark., 2020)	RSNA	100	8.59
(Z. Li ve ark., 2023)	RSNA	160	6.2
Önerilen Model	RSNA	75	8.23

Çizelge 4.3’de, bu çalışmada önerilen modelin ve farklı çalışmaların MAE hesaplamasına göre verdiği sonuçlar yer almaktadır. Aynı zamanda hangi çalışmanın kaç epoch çalıştığı bilgisi de tabloda yer almaktadır. Tabloda – ile gösterilen alanların bilgisi, ilgili çalışmada paylaşılmadığı için eklenememiştir. Tabloya bakıldığında MAE hesaplamasına göre, en iyi sonucu Li ve arkadaşlarının 2023 yılında hazırladığı çalışmanın verdiği görülmektedir. Ancak en çok çalıştırılan epoch sayısı da aynı çalışmadadır. Bu çalışmada geliştirilen model ise, ilgili çalışmaya çok yakın bir sonucu 75 epoch denemesinde elde etmiştir.




Şekil 4.1: VGG-16 (a), Inception V3 (b), MobileNet (c) ve Yeni Model (d) için Ay Bazında Gerçek Yaş ile Tahmini Yaş Kıyaslaması

Şekil 4.1’de, uygulamada kullanılan 4 CNN modeli için tahmin edilen yaş ile gerçek yaş arasındaki fark grafikleri görülmektedir.




Şekil 4.2: VGG-16 Modeli İçin Yaş Sonucu Tahmini Ara Yüzü

Şekil 4.2'de VGG-16 modeli için bazı görüntüler üzerinde elde edilen gerçek yaş ve tahmini yaş sonuçları görülmektedir.




Şekil 4.3: Inception V3 Modeli İçin Yaş Sonucu Tahmini Ara Yüzü

Şekil 4.3'de Inception V3 modeli için bazı görüntüler üzerinde elde edilen gerçek yaş ve tahmini yaş sonuçları görülmektedir.



Şekil 4.4: MobileNet Modeli İçin Yaş Sonucu Tahmini Ara Yüzü

Şekil 4.4’de MobileNet modeli için bazı görüntüler üzerinde elde edilen gerçek yaş ve tahmini yaş sonuçları görülmektedir.



Şekil 4.5: Önerilen Model İçin Yaş Sonucu Tahmini Ara Yüzü

Şekil 4.5’de önerilen model için bazı görüntüler üzerinde elde edilen gerçek yaş ve tahmini yaş sonuçları görülmektedir.

Bu çalışmada, CNN öğrenim modellerinin kemik yaşı tespitinde sergilediği performanslar incelenmiştir. Modeller, aynı ortamda, aynı oranda ayrılmış aynı veri seti kullanılarak çalıştırılmıştır. Önerilen model, klasik Inception V3 modeline göre daha kısa sürede daha başarılı bir sonuç vermiştir. Literatürdeki diğer çalışmalara bakıldığında ise yine başarı sağlandığı görülmüştür.

5. SONUÇ

Bu çalışmada derin öğrenme yöntemleri ile kemik yaşı tespiti yapılmıştır ve sonuçlar kaydedilmiştir. Literatüre bakıldığında, kemik yaşı tespiti için çok çeşitli yöntemler olduğu görülmektedir. Uzmana dayalı yöntemler, klasik yapay zeka yöntemleri ve derin öğrenme yöntemleri ile kemik yaşını tespit etmek mümkündür. Kemik yaşının tespit edilebilmesi için vücudun çeşitli bölgelerindeki kemik gelişimlerine bakılabildiği görülmüştür. Örneğin boyun omurları, diş kemikleri, el bileği kemikleri vb. Araştırmalar sonucunda en iyi kemik yaşı tespitinin sol el bilek kemiklerinin röntgen görüntülerinden yapılabildiği görülmüştür. Sebebi ise bölüm 1.1’de açıklandığı gibi; sol elin normalde daha az kullanılması ve kemiklerin gelişimlerinin çok fazla etkilenmemesinden kaynaklıdır. Bu çalışmada da RSNA el-bilek röntgen görüntülerinden oluşan veri seti kullanılarak, derin öğrenme yöntemleri ile kemik yaşı tespiti yapılmıştır.

İlk olarak deneysel çalışmalarla, klasik derin öğrenme yöntemlerinin kemik yaşı tespiti üzerindeki sonuçları karşılaştırılmış, sonra en iyi sonuç veren model üzerinde katman geliştirmesi uygulanmıştır. Katman geliştirmeleri uygulanırken, sağlık alanında röntgen filmlerinin kullanılarak geliştirildiği diğer modeller incelenmiştir. Literatürdeki diğer birçok çalışmaya ve klasik derin öğrenme yöntemlerine göre, önerilen modelin hızlı ve iyi sonuç verdiği görülmüştür. Sonuçların geliştirilebilmesi için; veri setine ön işleme ve segmentasyon yöntemleri uygulanabilir veya daha büyük ve farklı bir veri seti ile eğitilebilir. Mevcut kullanılan veri seti üzerinde rastgele eğitim uygulanabilir.

KAYNAKLAR

- Aizenberg, I. N., Aizenberg, N. N., Vandewalle, J., Aizenberg, I. N., Aizenberg, N. N., & Vandewalle, J. (2000). Multiple-Valued threshold logic and multi-valued neurons. *Multi-Valued and Universal Binary Neurons: Theory, Learning and Applications*, 25-80.
- Asad, M. N. (2019). *Derin öğrenme ile radyolojik görüntü üzerinden kemik yaşı tespiti*. (Yüksek Lisans Yüksek Lisans), Yıldız Teknik Üniversitesi, İstanbul. (603518)
- Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8), 1798-1828.
- Bishop, C. M., & Nasrabadi, N. M. (2006). *Pattern recognition and machine learning* (Vol. 4): Springer.
- Bull, R., Edwards, P., Kemp, P., Fry, S., & Hughes, I. (1999). Bone age assessment: a large scale comparison of the Greulich and Pyle, and Tanner and Whitehouse (TW2) methods. *Archives of disease in childhood*, 81(2), 172-173.
- Can, F., & Eyüpoğlu, C. (2021). *Convolutional Neural Network Architectures Used in Computer Vision*. Paper presented at the 2021 5th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT).
- Cole, A. L., Webb, L., & Cole, T. (1988). Bone age estimation: a comparison of methods. *The British journal of radiology*, 61(728), 683-686.
- Çelik, H. (2016). *Çocuklarda kemik yaşının yeni bir yöntem ile tayini*. Fen Bilimleri Enstitüsü.
- Garn, S. M. (1986). Assessment of Skeletal Maturity and Prediction of Adult Height (TW2 Method): JSTOR.
- Gilsanz, V., & Ratib, O. (2005). *Hand bone age: a digital atlas of skeletal maturity* (Vol. 1): Springer.
- Glorot, X., Bordes, A., & Bengio, Y. (2011). *Deep sparse rectifier neural networks*. Paper presented at the Proceedings of the fourteenth international conference on artificial intelligence and statistics.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*: MIT press.
- Güraksın, G. E. (2015). *Yapay zeka teknikleri kullanarak kemik yaşı tespiti*. (Doktora), Selçuk Üniversitesi. (380829)
- Halabi, S. S., Prevedello, L. M., Kalpathy-Cramer, J., Mamonov, A. B., Bilbily, A., Cicero, M., . . . Abdala, N. (2019). The RSNA pediatric bone age machine learning challenge. *Radiology*, 290(2), 498-503.
- Haykin, S. (2009). *Neural networks and learning machines, 3/E*: Pearson Education India.
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Spatial pyramid pooling in deep convolutional networks for visual recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 37(9), 1904-1916.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., . . . Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- Iglovikov, V. I., Rakhlin, A., Kalinin, A. A., & Shvets, A. A. (2018). *Paediatric bone age assessment using deep convolutional neural networks*. Paper presented at the Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop, DLMIA 2018, and 8th

- International Workshop, ML-CDS 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 20, 2018, Proceedings 4.
- Ioffe, S., & Szegedy, C. (2015). *Batch normalization: Accelerating deep network training by reducing internal covariate shift*. Paper presented at the International conference on machine learning.
- Kaplan, A., & Yılmaz, H. (2020). Kemik Yaşı Tayininde Kullanılan Greulich-Pyle ve Tanner-Whitehouse Yöntemlerinin Karşılaştırılması. *Adli Tıp Bülteni*, 25(1), 6-15.
- Kasımoğlu, Y., & Tuna-İnce, E. B. (2016). Diş hekimliğinde kemik yaşı tayininde kullanılan yöntemler: derleme. *Acta Odontologica Turcica*, 33(1), 39-46.
- Kaymaz, E. (2022). *Derin öğrenme kullanılarak çocukların el-bilek radyoloji görüntülerinden kemik yaşı tahmini*. Fırat Üniversitesi, Elazığ.
- King, D., Steventon, D., O'sullivan, M., Cook, A., Hornsby, V., Jefferson, I., & King, P. (1994). Reproducibility of bone ages when performed by radiology registrars: an audit of Tanner and Whitehouse II versus Greulich and Pyle methods. *The British journal of radiology*, 67(801), 848-851.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- Larson, D. B., Chen, M. C., Lungren, M. P., Halabi, S. S., Stence, N. V., & Langlotz, C. P. (2018). Performance of a deep-learning neural network model in assessing skeletal maturity on pediatric hand radiographs. *Radiology*, 287(1), 313-322.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Li, S., Liu, B., Li, S., Zhu, X., Yan, Y., & Zhang, D. (2021). A deep learning-based computer-aided diagnosis method of X-ray images for bone age assessment. *Complex & Intelligent Systems*, 1-11.
- Li, Z., Chen, W., Ju, Y., Chen, Y., Hou, Z., Li, X., & Jiang, Y. (2023). Bone age assessment based on deep neural networks with annotation-free cascaded critical bone region extraction. *Frontiers in Artificial Intelligence*, 6.
- Liu, R., Zhu, H., Wang, L., Han, B., Du, J., & Jia, Y. (2022). Coarse-to-fine segmentation and ensemble convolutional neural networks for automated pediatric bone age assessment. *Biomedical Signal Processing and Control*, 75, 103532.
- Mora, S., Boechat, M. I., Pietka, E., Huang, H., & Gilsanz, V. (2001). Skeletal age determinations in children of European and African descent: applicability of the Greulich and Pyle standards. *Pediatric research*, 50(5), 624-628.
- Mujahid, M., Rustam, F., Álvarez, R., Luis Vidal Mazón, J., Díez, I. d. l. T., & Ashraf, I. (2022). Pneumonia Classification from X-ray Images with Inception-V3 and Convolutional Neural Network. *Diagnostics*, 12(5), 1280.
- Nielsen, M. A. (2015). *Neural networks and deep learning* (Vol. 25): Determination press San Francisco, CA, USA.
- Ontell, F., Ivanovic, M., Ablin, D. S., & Barlow, T. (1996). Bone age in children of diverse ethnicity. *AJR. American journal of roentgenology*, 167(6), 1395-1398.
- Özdemir, C. (2022). *Derin öğrenme yöntemleri ile el bilek grafisinden kemik yaşının tahmini*. (Doktora), Siirt Üniversitesi, Siirt.
- Pan, X., Zhao, Y., Chen, H., Wei, D., Zhao, C., & Wei, Z. (2020). Fully automated bone age assessment on large-scale hand X-ray dataset. *International journal of biomedical imaging*, 2020.

- Pietka, E., Gertych, A., Pospiechâ“Kurkowska, S., Cao, F., Huang, H., & Gilzanz, V. (2004). Computer-assisted bone age assessment: graphical user interface for image processing and comparison. *Journal of Digital Imaging*, *17*, 175-188.
- Pietka, E., McNitt-Gray, M. F., Kuo, M., & Huang, H. (1991). Computer-assisted phalangeal analysis in skeletal age assessment. *IEEE transactions on medical imaging*, *10*(4), 616-620.
- Pinchi, V., De Luca, F., Ricciardi, F., Focardi, M., Piredda, V., Mazzeo, E., & Norelli, G.-A. (2014). Skeletal age estimation for forensic purposes: A comparison of GP, TW2 and TW3 methods on an Italian sample. *Forensic science international*, *238*, 83-90.
- Reddy, N. E., Rayan, J. C., Annapragada, A. V., Mahmood, N. F., Scheslinger, A. E., Zhang, W., & Kan, J. H. (2020). Bone age determination using only the index finger: a novel approach using a convolutional neural network compared with human radiologists. *Pediatric radiology*, *50*, 516-523.
- Ren, X., Li, T., Yang, X., Wang, S., Ahmad, S., Xiang, L., . . . Shen, D. (2018). Regression convolutional neural network for automated pediatric bone age assessment from hand radiograph. *IEEE journal of biomedical and health informatics*, *23*(5), 2030-2038.
- Saglam, S., Kumrular, R. K., & Aysel, H. I. (2022). *COVID-19 Detection from X-ray Images Using a New CNN Approach*. Paper presented at the 2022 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS).
- Sarić, R., Kevrić, J., Čustović, E., Jokić, D., & Beganović, N. (2019). *Evaluation of skeletal gender and maturity for hand radiographs using deep convolutional neural networks*. Paper presented at the 2019 6th International Conference on Control, Decision and Information Technologies (CoDIT).
- Sevli, O. (2021). Beyin MR Görüntülerini Sınıflandırmada Farklı Önceden Eğitilmiş Derin Öğrenme Modellerinin Performans Karşılaştırması. *Acta Infologica*, *5*(1), 141-154.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Spampinato, C., Palazzo, S., Giordano, D., Aldinucci, M., & Leonardi, R. (2017). Deep learning for automated skeletal bone age assessment in X-ray images. *Medical image analysis*, *36*, 41-51.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, *15*(1), 1929-1958.
- Su, L., Fu, X., & Hu, Q. (2021). Generative adversarial network based data augmentation and gender-last training strategy with application to bone age assessment. *Computer Methods and Programs in Biomedicine*, *212*, 106456.
- Şahin, Ö. (2017). *iOS Platformunda Görme Engelliler İçin TL Tanıma Uygulaması*. (Yüksek Lisans), Selçuk Üniversitesi. (489324)
- Tang, W., Wu, G., & Shen, G. (2019). *Improved Automatic Radiographic Bone Age Prediction with Deep Transfer Learning*. Paper presented at the 2019 12th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), Suzhou, China.
- Tanner. (1962). A new system for estimating skeletal maturity derived from study of 2600 healthy british children.

- Toğaçar, M., Ergen, B., & Özyurt, F. (2020). Evrişimsel Sinir Ağı Modellerinde Özellik Seçim Yöntemlerini Kullanarak Çiçek Görüntülerinin Sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 32(1), 47-56.
- Vaca, E., & Danudibroto, A. (2021). *Pediatric Bone Age Assessment based on Detection of Ossification Regions*. Paper presented at the 2021 IEEE EMBS International Conference on Biomedical and Health Informatics (BHI).
- Wibisono, A., Saputri, M. S., Mursanto, P., Rachmad, J., Yudasubrata, A. T. W., Rizki, F., & Anderson, E. (2019). *Deep learning and classic machine learning approach for automatic bone age assessment*. Paper presented at the 2019 4th Asia-Pacific Conference on Intelligent Robot Systems (ACIRS).
- Wu, E., Kong, B., Wang, X., Bai, J., Lu, Y., Gao, F., . . . Lyu, S. (2019). *Residual attention based network for hand bone age assessment*. Paper presented at the 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019).
- Yılmaz, Y. (2011). *Bulanık Mantık İle Kemik Yaşı Tespiti*. (Yüksek Lisans), Gazi Üniversitesi.
- Zakiroğlu, N. (2019). *Yapay zeka teknikleri kullanarak kemik yaşı tespiti üzerinde bir uygulama*. Fen Bilimleri Enstitüsü.
- Zeiler, M. D., & Fergus, R. (2014). *Visualizing and understanding convolutional networks*. Paper presented at the Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part I 13.
- Zhang, A., Gertych, A., & Liu, B. J. (2007). Automatic bone age assessment for young children from newborn to 7-year-old using carpal bones. *Computerized Medical Imaging and Graphics*, 31(4-5), 299-310.
- Zhang, Y., & Davison, B. D. (2021). *Adversarial regression learning for bone age estimation*. Paper presented at the Information Processing in Medical Imaging: 27th International Conference, IPMI 2021, Virtual Event, June 28–June 30, 2021, Proceedings 27.
- Zhao, C., Han, J., Jia, Y., Fan, L., & Gou, F. (2018). Versatile framework for medical image processing and analysis with application to automatic bone age assessment. *Journal of Electrical and Computer Engineering*, 2018, 1-13.