ÇANKIRI KARATEKİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

KALÇA RADYOGRAFİLERİNDE DERİN ÖĞRENME YÖNTEMLERİ İLE PROKSİMAL FEMUR KIRIKLARININ TANISI VE SINIFLANDIRILMASI

Hasan ERSÖNMEZ

ELEKTRİK – ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

ÇANKIRI
2022

Her hakkı saklıdır

TEZ ONAYI

Hasan ERSÖNMEZ tarafından hazırlanan **"Kalça Radyografilerinde Derin Öğrenme Yöntemleri İle Proksimal Femur Kırıklarının Tanısı ve Sınıflandırılması"** adlı tez çalışması tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Elektrik – Elektronik Mühendisliği Anabilim Dalı'nda **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Danışman : Prof. Dr. Murat ARI

Eş Danışman : Dr. Öğr. Üyesi Seda ŞAHİN

Jüri Üyeleri :

Başkan : Prof. Dr. Murat ARI
Elektrik-Elektronik Mühendisliği Anabilim Dalı
Çankırı Karatekin Üniversitesi

Üye : Prof. Dr. Halil Tanyer EYYUBOĞLU
Elektrik-Elektronik Mühendisliği Anabilim Dalı
Çankırı Karatekin Üniversitesi

Üye : Prof. Dr. Cemil YILDIZ
Ortopedi ve Travmatoloji Anabilim Dalı
Sağlık Bilimleri Üniversitesi

Üye : Prof. Dr. Hatice Tuba SANAL
Radyoloji Anabilim Dalı
Sağlık Bilimleri Üniversitesi

Üye : Dr. Öğr. Üyesi Seda ŞAHİN
Bilgisayar Mühendisliği Anabilim Dalı
Çankırı Karatekin Üniversitesi

Yukarıdaki sonucu onaylarım

Prof. Dr. İbrahim ÇİFTÇİ

Enstitü Müdürü

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Çankırı Karatekin Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğine göre hazırlamış olduğum "**Kalça Radyografilerinde Derin Öğrenme Yöntemleri İle Proksimal Femur Kırıklarının Tanısı ve Sınıflandırılması**" konulu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, tezin Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü'nden başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve bu çalışmanın Çankırı Karatekin Üniversitesi tarafından kullanılan "Bilimsel İntihal Tespit Programı"yla tarandığını, "intihal içermediğini" beyan ederim. Çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması halinde ortaya çıkacak tüm ahlaki ve hukuki sonuçlara razı olduğumu bildiririm. Çankırı Karatekin Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim.

Hasan ERSÖNMEZ

ÖZET

Yüksek Lisans Tezi

KALÇA RADYOGRAFİLERİNDE DERİN ÖĞRENME YÖNTEMLERİ İLE PROKSİMAL FEMUR KIRIKLARININ TANISI VE SINIFLANDIRILMASI

Hasan ERSÖNMEZ

Çankırı Karatekin Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik - Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Murat ARI
Eş Danışman: Dr. Öğr. Üyesi Seda ŞAHİN

Proksimal femur kırığı geçirmiş olan hastaların %4'ü hastanede, %30'u ise tedaviden sonra 1 yıl içerisinde yaşamlarını kaybederler. Acil servislerin yoğunlukları ve hastalara ayrılan zamanın kısalığı nedeniyle kalça radyografilerinde proksimal femur kırıkların tanısı atlanabilmektedir. Proksimal femur kırıklarına doğru ve hızlı tanı konulması ile tedaviye erken başlanması hasta morbidite ve mortalitesini azaltmaktadır. Dört veri seti hazırlanmıştır. İlk veri setimizde (VS-1) 178 x-ray görüntüsü, ikinci veri setimiz (VS-2), VS-1'e görüntü işleme yöntemlerinden CLAHE filtresi uygulanmış halidir, üçüncü veri setimizde (VS-3), VS-1'e veri artırımı yapılarak elde edilmiş olup 316 adet x-ray görüntüsü ve son olarak dördüncü veri setimizde (VS-4) ise VS-3'e CLAHE filtresi uygulanarak elde edilmiştir. Kırıkların teşhisinde öğrenim aktarımı modellerinden DenseNet201, Xception, ResNet152V2 ve InceptionResNetV2 kullanılmıştır. Bu modeller bütün veri setlerinde eğitilmiştir. VS-1'de InceptionResNetV2 modeli ile F1 score 0.9500 başarı elde edilmiştir. VS-2'de DenseNet201 ve InceptionResNetV2 modellerinde F1 score 0.9500 başarı elde edilmiştir. VS-3'de Xception ve InceptionResNetV2 modellerinde F1 score 0.9000 başarı elde edilmiştir. VS-4'te ise DenseNet201 modelinde F1 score 0.9250 başarı elde edilmiştir. Genel olarak baktığımızda veri seti artırıldığında ve görüntü işleme yöntemlerinden CLAHE filtresi uygulandığında başarısı düşük olan modellerde başarı oranları artmaktadır. Bu çalışmamızda yeterli miktarda veri olduğunda ve görüntü işleme teknikleri ile desteklendiğinde Yapay Zeka teknolojisini proksimal femur kırıklarının optimize tespiti için kullanılabilir ve ayrıca klinisyenlerin çalışmalarını kolaylaştırabilir olduğunu gördük.

2022, 71 sayfa

ANAHTAR KELİMELER: Proksimal femur kırığı, Kalça radyografisi, Yapay zeka, Makine öğrenmesi, Derin öğrenme, Öğrenim aktarımı

ABSTRACT

Master of Science Thesis

DIAGNOSIS AND CLASSIFICATION OF PROXIMAL FEMUR FRACTURES ON HIP RADIOGRAPHS WITH DEEP LEARNING METHODS

Hasan ERSÖNMEZ

Çankırı Karatekin University
Graduate School of Natural and Applied Sciences
Department of Electrical and Electronics Engineering

Advisor: Prof. Dr. Murat ARI
Co-Advisor: Asst. Prof. Dr. Seda ŞAHİN

4% of patients who have had a proximal femur fracture die in hospital, and 30% die within 1 year after treatment. The diagnosis of proximal femur fractures can be missed on hip radiographs due to the intensity of the emergency services and the short time allocated to the patients. Accurate and rapid diagnosis of proximal femur fractures and early initiation of treatment reduce patient morbidity and mortality. Four data sets were prepared. 178 x-ray images in our first dataset (VS-1), our second dataset (VS-2), VS-1 with CLAHE filter applied from image processing methods, in our third dataset (VS-3), VS-1 316 x-ray images and finally in our fourth data set (VS-4) were obtained by applying CLAHE filter to VS-3. Learning transfer models DenseNet201, Xception, ResNet152V2 and InceptionResNetV2 were used in the diagnosis of fractures. These models are trained on all datasets. F1 score of 0.9500 was achieved with the InceptionResNetV2 model in VS-1. F1 score of 0.9500 was achieved in DenseNet201 and InceptionResNetV2 models in VS-2. F1 score of 0.9000 was achieved in Xception and InceptionResNetV2 models in VS-3. In VS-4, F1 score of 0.9250 was achieved in the DenseNet201 model. In general, when the data set is increased and the CLAHE filter is applied from the image processing methods, the success rates of the models with low success increase. In this study, we have seen that when there is sufficient data and supported by image processing techniques, Artificial Intelligence technology can be used for optimized detection of proximal femur fractures and can also facilitate the work of clinicians.

2022, 71 pages

Keywords: Proximal femur fracture, Hip radiography, Artificial intelligence, Machine learning, Deep learning, Transfer learning

ÖNSÖZ VE TEŞEKKÜR

Tez çalışmam sürecinde yardımlarını ve desteğini esirgemeyen değerli danışman hocam Prof. Dr. Murat ARI'ya, bu çalışmada yardım, destek ve önerilerini esirgemeyen, yol göstericiliğiyle desteğini her zaman yanımda hissettiğim, güler yüzlülüğüyle beni motive eden değerli eş danışman hocam Dr. Öğr. Üyesi Seda ŞAHİN'e, görüntülerin elde edilmesinde ve bu tez çalışmasının gerçekleşmesinde büyük emeği olan Sağlık Bilimleri Üniversitesi Ortopedi ve Travmatoloji Bölümü Öğretim Üyesi Prof. Dr. Cemil YILDIZ'a, çalışma süresince bilgi ve tecrübelerini esirgemeyen, teknik konularda bana destek olan değerli hocam Arş. Gör. Esra SİVARİ'ye teşekkürlerimi sunarım.

Çalışmamın her aşamasında yanımda olan, stresli dönemlerimde sabır gösterip bana destek olan değerli eşim Ülkü ERSÖNMEZ'e, ve canım oğlum Kerem ERSÖNMEZ'e teşekkürlerimi sunarım.

Hasan ERSÖNMEZ
Çankırı, Temmuz 2022

İÇİNDEKİLER

ÖZET ..... **i**
ABSTRACT ..... **ii**
ÖNSÖZ VE TEŞEKKÜR ..... **iii**
İÇİNDEKİLER ..... **iv**
KISALTMALAR DİZİNİ ..... **vi**
ŞEKİLLER DİZİNİ ..... **vii**
ÇİZELGELER DİZİNİ ..... **ix**
1. GİRİŞ **1**
1.1 Tezin Amacı **1**
2. KAYNAK ÖZETİ **3**
3. GENEL KISIMLAR **4**
3.1 Yapay Zeka **4**
3.2 Makine Öğrenmesi **4**
3.3 Derin Öğrenme **4**
3.3.1 Yapay sinir ağları **7**
3.3.2 Tek katmanlı algılayıcılar **8**
3.3.3 Çok katmanlı algılayıcılar **9**
3.3.4 Evrişimli sinir ağları **10**
3.4 Görüntü İşleme **16**
3.4.1 Tıbbi görüntüleme teknikleri **17**
4. MATERYAL VE YÖNTEM **18**
4.1 Veri Seti Hakkında Bilgi **18**
4.2 Kullanılan Yazılım Dili ve Donanım **20**
4.3 Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (CLAHE) **20**
4.4 Veri Ön İşleme **21**
4.5 Keras **21**
4.6 Evrişimsel Sinir Ağı Modelleri **22**
4.6.1 Densenet **22**
4.6.2 Resnet **24**
4.6.3 Inceptionresnetv2 ..... **25**

4.6.4 Xception **26**
4.7 Öğrenim Aktarımı **27**
4.8 Optimizasyon **28**
4.8.1 Rmsprop **29**
4.8.2 Adam **29**
5. BULGULAR **30**
5.1 Karışıklık Matrisi (KM) **30**
5.2 Veri Setlerinde Yapılan İşlemler **30**
5.3 Ham Veri Setinde (VS-1) Yapılan Test Sonuçları **32**
5.4 Ham Veri Setine CLAHE Filtresi Uygulanarak Elde Edilen Veri Setinde (VS-2) Yapılan Test Sonuçları **35**
5.5 Ham Veri Setine Simetrileri Eklenerek Elde Edilen Veri Setinde (VS-3) Yapılan Test Sonuçları **39**
5.6 Simetrileri Eklenerek Elde Edilen Veri Setine CLAHE Filtresi Uygulanarak Elde Edilen Veri Setinde (VS-4) Yapılan Test Sonuçları **43**
5.7 Veri Setlerinin Başarı Kıyaslamaları **47**
5.7.1 VS-1 ile VS-3'ün aynı modeldeki başarı kıyaslamaları **47**
5.7.2 VS-1 ile VS-2'nin aynı modeldeki başarı kıyaslamaları **49**
5.7.3 VS-3 ile VS-4'ün aynı modeldeki başarı kıyaslaması **52**
6. SONUÇ **56**
KAYNAKLAR **60**
EKLER **66**
ÖZGEÇMİŞ **71**

KISALTMALAR DİZİNİ

CLAHE	Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme
DICOM	Digital Imaging and Communications in Medicine
DÖ	Derin Öğrenme
ESA	Evrişimli Sinir Ağları
GPU	Ekran Kartı
KM	Karışıklık Matrisi
MÖ	Makine Öğrenmesi
ÖA	Öğrenim Aktarımı
VS-1	Ham Veri Seti
VS-2	Ham Veri Setine (VS-1) CLAHE Filtresi Uygulanarak Elde Edilen Veri Seti
VS-3	Ham Veri Setine (VS-1) Simetrileri Eklenerek Elde Edilen Veri Seti
VS-4	Simetrileri Eklenerek Elde Edilen Veri Setine (VS-3) CLAHE Filtresi Filtresi Uygulanarak Elde Edilen Veri Seti
YSA	Yapay Sinir Ağı
YZ	Yapay Zeka

ŞEKİLLER DİZİNİ

Şekil 3.1 Nöron yapısının temel gösterimi (Fikir.gen.tr, n.d.) 5
Şekil 3.2 Nöron yapısının formülleştirilmiş hali (Ayyucekizrak.medium, n.d.) 6
Şekil 3.3 Yapay zeka, makine öğrenmesi ve derin öğrenme'nin şema ile gösterimi 7
Şekil 3.4 Yapay sinir ağı modeli (Derinogrenme.com, n.d.) 8
Şekil 3.5 Tek katmanlı algılayıcı modeli 9
Şekil 3.6 Çok katmanlı algılayıcılar 9
Şekil 3.7 LeNet mimarisi (Lecun, 1989) 11
Şekil 3.8 Evrişimsel sinir ağı mimarisi 11
Şekil 3.9. Evrişim işlemi 1. adım sonucu 12
Şekil 3.10 Evrişim işlemi uygulandıktan sonra elde edilen çıktı 12
Şekil 3.11 Maksimum havuzlama 13
Şekil 3.12 Minimum Havuzlama 14
Şekil 3.13 Ortalama havuzlama 14
Şekil 3.14 Tam bağlı katman yapısı (Stanford.edu, n.d.) 15
Şekil 3.15 Relu aktivasyon fonksiyonu 15
Şekil 3.16 Sigmoid aktivasyon fonksiyonu 16
Şekil 3.17 Proksimal Femur Kırık 17
Şekil 3.18 Proksimal Femur Sağlam 17
Şekil 4.1 Veri setleri hakkında bilgi 19
Şekil 4.2 Tesla K80 GPU (Nvidia, n.d.) 20
Şekil 4.3 Büyüme oranı k = 4 olan 5 katmanlı yoğun blok. (Huang et al., 2017). 23
Şekil 4.4 Residual blokların yapısı (He et al., 2016a) 25
Şekil 4.5 Xception mimarisinin katmanları (François Chollet, 2017) 27
Şekil 5.1 Veri setlerinde yapılan işlemler 31
Şekil 5.2 VS-1 DenseNet201 KM görseli 32
Şekil 5.3 VS-1 Xception KM görseli 33
Şekil 5.4 VS-1 ResNet152V2 KM görseli 34
Şekil 5.6 Normal x-ray 35
Şekil 5.7 CLAHE uygulanmış x-ray 35
Şekil 5.8 VS-2 DenseNet201 KM görseli 36
Şekil 5.9 VS-2 Xception KM görseli 37
Şekil 5.10 VS-2 ResNet152V2 KM görseli 38
Şekil 5.11 VS-2 InceptionResNetV2 KM görseli 39
Şekil 5.12 Normal x-ray görüntüsü 40
Şekil 5.13 Simetrisi oluşturulmuş x-ray 40
Şekil 5.14 VS-3 DenseNet201 KM görseli 40
Şekil 5.15 VS-3 Xception KM görseli 41
Şekil 5.16 VS-3 ResNet152V2 KM görseli 42
Şekil 5.17 VS-3 InceptionResNetV2 KM 42

Şekil 5.18 VS-4 DenseNet201 KM görseli 43
Şekil 5.19 VS-4 Xception KM görseli 44
Şekil 5.20 VS-4 Xception KM görseli - 2 45
Şekil 5.21 VS-4 ResNet152V2 KM görseli 45
Şekil 5.22 VS-4 InceptionResNetV2 KM görseli 46
Şekil 5.23 VS-1 ve VS-3 DenseNet201 (optimizer = Adam(0,001)) KM görseli 47
Şekil 5.24 VS-1 ve VS-3 ResNet152V2 (optimizer = RMSprop(0,001)) KM görseli .. 48
Şekil 5.25 VS-1 ve VS-2 DenseNet201 (optimizer = Adam(0,001)) KM görseli 49
Şekil 5.26 VS-1 ve VS-2 Xception (optimizer = RMSprop(0,001)) KM görseli 50
Şekil 5.27 VS-1 ve VS-2 InceptionResNetV2 (optimizer = RMSprop(2e-5)) KM..... 51
Şekil 5.28 VS-3 ve VS-4 DenseNet201 (optimizer = Adam(0,001)) KM görseli 52
Şekil 5.29 VS-3 ve VS-4 ResNet152V2 (optimizer = RMSprop(0,001)) KM görseli .. 53
Şekil 5.30 VS-3 ve VS-4 InceptionResNetV2 (optimizer = RMSprop(0,001)) KM..... 54

ÇİZELGELER DİZİNİ

Çizelge 4.1 DenseNet mimarisinin yapısı. (Huang et al., 2017) 24
Çizelge 4.2 ResNet mimarisinin yapısı (He et al., 2016a) 25
Çizelge 4.3 Inception-ResNetV2 mimarisinin yapısı (Alruwaili et al., 2021) 26
Çizelge 5.1 VS-1 DenseNet201 sonuç tablosu 33
Çizelge 5.2 VS-1 Xception sonuç tablosu 33
Çizelge 5.3 VS-1 ResNet152V2 sonuç tablosu 34
Çizelge 5.4 VS-1 InceptionResNetV2 sonuç tablosu 35
Çizelge 5.5 VS-2 DenseNet201 sonuç tablosu 36
Çizelge 5.6 VS-2 Xception sonuç tablosu 36
Çizelge 5.7 VS-2 ResNet152V2 sonuç tablosu 38
Çizelge 5.9 VS-3 DenseNet201 sonuç tablosu 40
Çizelge 5.10 VS-3 Xception sonuç tablosu 41
Çizelge 5.11 VS-3 ResNet152V2 sonuç tablosu 42
Çizelge 5.17 VS-4 InceptionResNetV2 sonuç tablosu 46
Çizelge 5.19 VS-3 DenseNet201 sonuç tablosu 48
Çizelge 5.20 VS-3 ResNet152V2 sonuç tablosu 48
Çizelge 5.21 VS-1 DenseNet201 sonuç tablosu 49
Çizelge 5.23 VS-2 Xception sonuç tablosu 50
Çizelge 5.24 VS-1 InceptionResNetV2 sonuç tablosu 51
Çizelge 5.25 VS-2 InceptionResNetV2 sonuç tablosu 51
Çizelge 5.26 VS-3 DenseNet201 sonuç tablosu 52
Çizelge 5.27 VS-4 DenseNet201 sonuç tablosu 53

1. GİRİŞ

Acil servislerin yoğunlukları ve hastalara ayrılan zamanın kısalığı nedeniyle proksimal femur kırıklarının tanısı atlanabilmektedir. Proksimal femur kırıklarına doğru ve hızlı tanı konulması ile tedaviye erken başlanması hasta morbidite ve mortalitesini azaltmaktadır. Bu çalışmamızın amacı, proksimal femur kırıkları 'Yapay Zeka' uygulamalarından olan 'Derin Öğrenme' yöntemi kullanılarak otomatik, hızlı ve güvenilir tanısını sağlayan bir 'Yapay Zeka Modeli' geliştirmektir.

Bu çalışmada Sağlık Bilimleri Üniversitesi Gülhane Bilimsel Araştırmalar Etik Kurul Başkanlığı'nın 14.01.2021 tarih ve 2021/04 protokol numaralı protokolü ile Ocak 2011-Kasım 2020 tarihleri arasında 18 yaş üstü 111 hastanın radyoloji görüntüleri proksimal femur kırıkların doğru ve optimize tespiti için kullanılmıştır. Öncelikle veri setimizi hazırladık ve python programlama dilinde oluşturulmuş bir derin öğrenme kütüphanesi olan Keras ile öğrenim aktarma modelleri kullanılarak bir yapay zeka modeli geliştirdik. Derin öğrenme modelimizi oluşturduktan sonra veri setimiz ile modelimiz eğitildi ve model çıktıları uzman hekimler ile karşılaştırıldı.

Toplam 178 görüntünün bulunduğu çalışmaya sonuçları daha iyileştirmek amacıyla veri setine görüntülerin simetrileri eklenerek veri artırımı yapılmıştır. Böylelikle veri setimizde görüntü sayısı 316 olmuştur. Bu görüntülere görüntü işleme filtrelerinden CLAHE uygulayarak başarı oranını daha da iyileştirmeyi amaçladık.

Son yıllarda yapay zeka uygulamaları ve görüntü işleme yöntemleri ile kırıkların radyogramlar üzerinde tanınması ve sınıflandırılması ile ilgili çalışmalar öne çıkmaktadır.

1.1. Tezin Amacı

Proksimal femur kırıkları çok ciddi ve ekonomik olarak en önemli kırıklardandır. Proksimal femur kırığı geçirmiş olan hastaların %4'ü hastanede, %30'u ise tedaviden sonra 1 yıl içerisinde yaşamlarını kaybederler (Soydemir & Kuran, 2010). Kalça kırığı

olan birçok hasta bağımsız yaşama yeteneğini kaybeder ve kırık sonrası ilk yıldan sonra yaşayanların yaklaşık %10'u kalıcı olarak yatağa bağımlı kalırlar (Lüthje et al., 2009). Kalça kırığı vakasından sonra 12 kişiden birinin 2 yıl içinde tekrar kalça kırığı vakası geçirme ihtimali yüksektir (Kirazlı, 2009).

Yaşlanmayla birlikte kırılganlık artmaktadır. İnsanların yaşamı boyunca kırık vakası riski kadınlarda %40 ile %50 arasında, erkeklerde ise %13 ile %22 arasındadır (Tanrıover et al., 2010). Proksimal femur kırıklarının üçte biri erkeklerde görülür ve ölüm oranları kadınlara göre 2-3 kat daha fazladır (Briot et al., 2009). Kırıkların %50'si normal kemik yoğunluğuna sahip kişilerde meydana gelebilmektedir. Bundan dolayı son yıllarda kemik mineral yoğunluğu taramasının yanında her bireyin risk değerlendirmesi yapması hakkında görüş birliği artmaktadır (White et al., 2006).

Yaşlılarda proksimal femur kırığı önemli bir morbidite ve mortalite kaynağıdır (Morita et al., 2005). Bu nedenle kalça kırıklarına sebep olan risklerin tespit edilmesi gereklidir (Benetos et al., 2007).

Yapmış olduğumuz çalışma ile rutin olarak çekilen radyografileri kullanarak proksimal femur kırıklarına kusursuz ve hızlı olarak tanı koymak amaçlanmıştır.
Geliştirmiş olduğumuz yapay zeka modeli ile;

- Hatalı tanı oranını en aza indirmek,
- Gözlemciler arasındaki (interobserver) tanısal farkları minimalize etmek (standardizasyon),
- Proksimal femur kırıklarının tedavisindeki maliyetlerin azaltılması,
- Yazılımın geliştirilmesi ile klinik kullanıma sokularak ülke adına katma değer sağlanması amaçlanmaktadır.

Bütün bu nedenlerden dolayı proksimal femur kırıklarına doğru ve hızlı tanı konulması ile tedaviye erken başlanması hasta morbidite ve mortalitesini azalttığından bu sorunu günümüzde bir çok problemde çözüm olarak kullanılan yapay zeka ile çözmeye çalıştık.

2. KAYNAK ÖZETİ

Takaaki Urakawa ve arkadaşlarının konvolüsyonel sinir ağı ve ortopedi cerrahları arasında proksimal femoral radyografilerden intertrokanterik kalça kırıklarının teşhisinde performansları karşılaştırmak üzere çalışma yapmışlardır. Bu çalışmada toplam 1.773 hastanın radyoloji görüntüleri kullanılmıştır. 3.346 kalça görüntüsü (1.773 kırık ve 1.573 sağlam) elde etmişlerdir. Ortopedi cerrahlarının performansı %92,2 iken VGG 16 öğrenme aktarma modeli ile ağın performansı %95,5 olarak gerçekleşmiştir (Urakawa et al., 2019).

Jusitn Krogue ve arkadaşları derin öğrenme yöntemi ile otomatik kalça kırık tanımı ve alt sınıflandırma üzerine çalışma yapmışlardır. Çalışmalarında 1118 hastanın radyoloji görüntüleri kullanılmıştır. 3.034 kalça görüntüsü elde edilmiştir. Normal, yerinden çıkmış femur boynu kırığı, yerinden çıkmamış femur boynnu kırığı, intertrokanterik kırık, orif ve artroplasti olarak sınıflandırdılar. DenseNet öğrenme aktarma modeli ile ağın performansı %93,8 olarak gerçekleşmiştir (Krogue et al., 2019).

Matthew Adams ve arkadaşları derin öğrenme yöntemi ile femur boynu kırığı tespiti üzerine çalışma yapmışlardır. 640 adet kalça görüntüsü üzerinde çalışmışlardır. GoogLeNet derin evrişimli sinir ağları ile ağın performansı %90,9 olarak gerçekleşmiştir (Adams et al., 2019).

Yutoku Yamada ve arkdaşları derin evrişimli sinir ağları ile kalça kırıklarını otomatik sınıflandırılması üzerine bir çalışma gerçekleştirmişlerdir. 1.703 adet ön-arka kalça radyografisi ve 1.220 adet yan kaça radyograifisi kullanmışlardır. Xception öğrenme aktarma modeli ile ağın performansı %98 olarak gerçekleşmiştir (Yamada et al., 2020).

Simukayi Mutasa ve arkadaşları derin öğrenme yöntemleri ile femur boyun kırığının otomatik tespit edilmesi üzerine bir çalışma gerçekleştirmişlerdir. Bu çalışmada toplam 550 hastadan 1.063 adet radyografi elde etmişlerdir. Evrişimli sinir ağları ile yapılan eğitimin sonunda ağın performansı %92 olarak gerçekleşmiştir (Mutasa et al., 2020).

3. GENEL KISIMLAR

Bu kısımda yapay zeka, makine öğrenmesi, derin öğrenme, evrişimli sinir ağları ve tıbbi görüntüleme teknikleri hakkında bilgiler verilecektir.

3.1. Yapay Zeka

İlk olarak "Yapay Zeka" (YZ) kavramını ortaya koyan kişi John McCarthy'dir (McCarthy et al., 1955). John McCarthy yapay zekayı şu şekilde tanımlamaktadır. "Zeki makineler, özellikle zeki bilgisayar programları yapma bilimi ve mühendisliğidir." (John McCarthy, 2007). Cahit Arf makalesinde insan gibi düşünebilmesini sağlayabilecek özelliklerin makinelerin de sahip olma imkanı üzerine çalar saat, ev telefonları ve miras meselesini çözen bir hesap makinesi gibi örnekler ile tespitlerde bulunmuştur (Arf, 1959). Arf makinelerin dil kullanabilen, hesap yapabilen, benzerlik kurabilen, mantıksal ve analitik işlemleri yapabilecek şekilde tasarlanabileceğini savunmuştur (Sarı, 2021).

3.2. Makine Öğrenmesi

Makine öğrenmesi (MÖ) YZ'nin bir alt dalıdır. MÖ, matematiksel yöntemler ile verilerden öğrenebilen ve tahmin yapabilen yapay zeka yöntemidir. Makine öğrenmesi algoritmaları ile makinelerin sonuç verebilmesi için öncesinde eğitimini tamamlaması gerekmektedir. Bu eğitim işlemi verilerdeki özellikleri öğrenerek gerçekleşmektedir. Makinenin eğitim sürecinde verilere ait özelliklerin makine öğrenmesi algoritmaları için öncesinde hazırlanması gerekmektedir. MÖ algoritmaları için kullanılacak ham verileri olduğu gibi kullanamamaktadır. Ham verilerden veri özelliklerini kullanabilmesi için belirli teknikler yardımıyla özellik çıkarımı yapılması gerekmektedir (Rende et al., 2016).

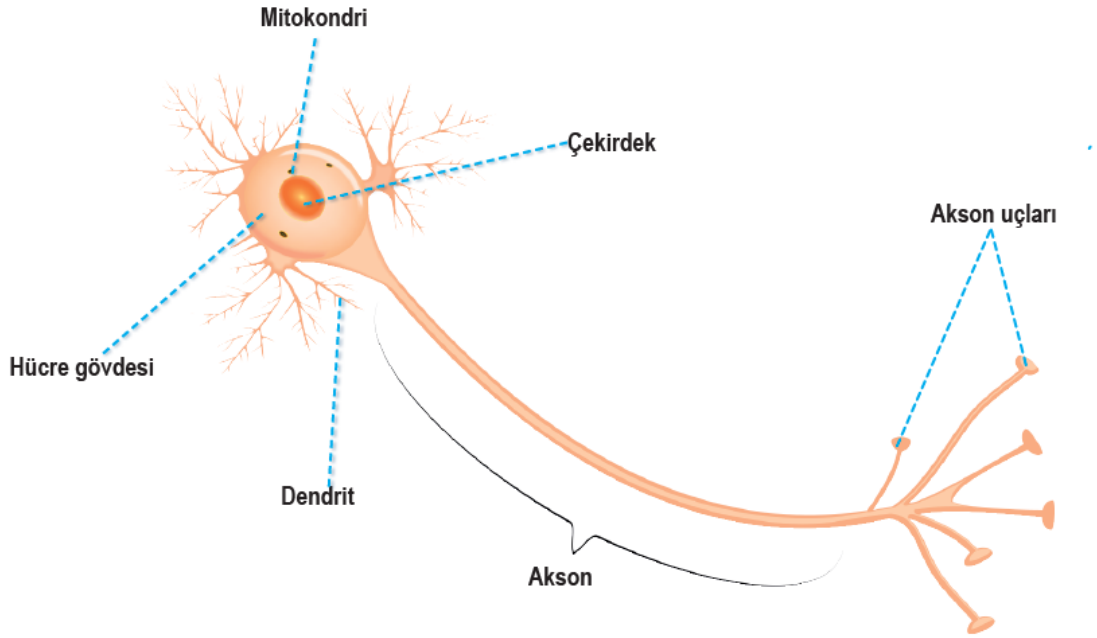
3.3. Derin Öğrenme

Derin öğrenme (DÖ) makine öğrenme sınıflarındandır. Derin öğrenme özellik çıkarma ve dönüştürme işlemleri için doğrusal olmayan katmanları kullanır. Katmanlar bir önceki

katmanın çıktısını girdi olacak şekilde kullanır (Deng & Yu, 2013). Ayrıca derin sinir ağlarının kullanıldığı bir makine öğrenme çeşididir. Derin sinir ağları en az iki veya daha fazla gizli katman kullanan çok katmanlı sinir ağlarıdır (Kim, 2017).

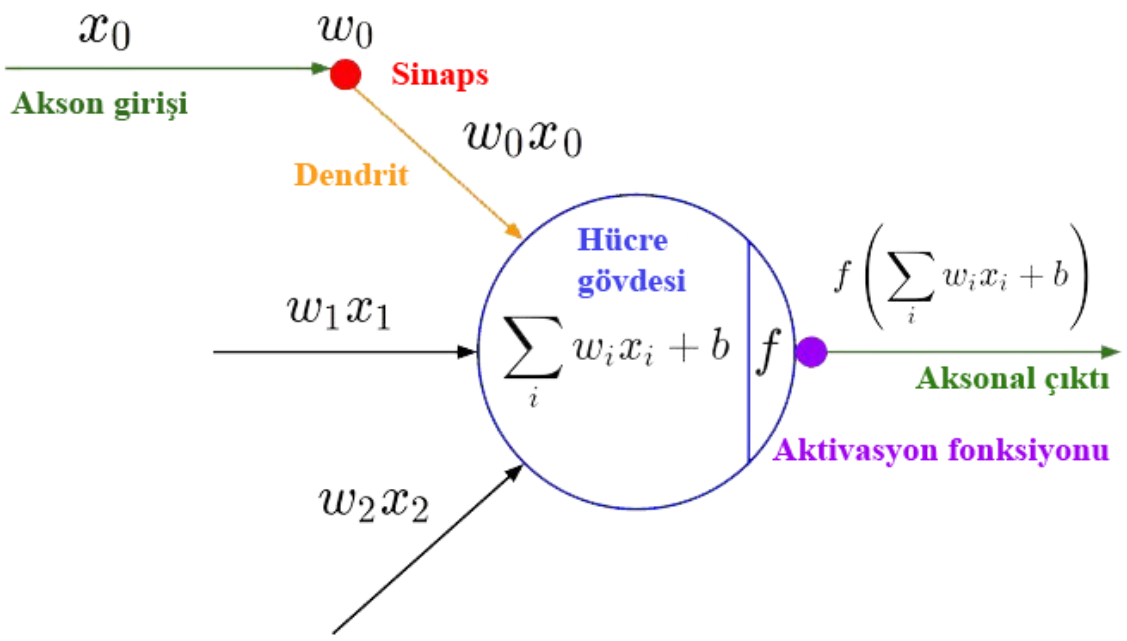
DÖ, MÖ yöntemlerinin eksikliklerini gidermek için geliştirilmiştir. DÖ yöntemleri yapay sinir ağlarına dayanmaktadır. Sinir ağları insan beynindeki nöronların işlevleri taklit edilerek geliştirilmiştir. Yapay sinir ağları kullanımı, eğitim verileriyle birlikte kullanıldığında yüksek bir doğruluk sağlayabilir, ancak gerçek test verileri kullanıldığında doğruluk genellikle düşer (Zhang et al., 2018).

Aşağıda insan beynindeki basitleştirilmiş bir nöron yapısı bulunmaktadır (Şekil 3.1).



Şekil 3.1 Nöron yapısının temel gösterimi (Fikir.gen.tr, n.d.)

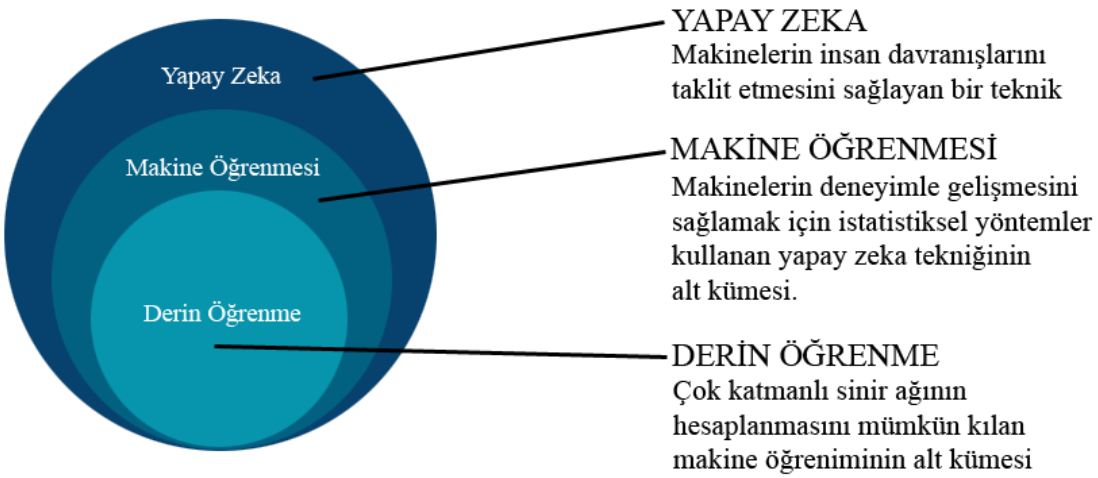
İnsan beynindeki nöronların yapısını taklit ederek modellenen bir nöronun formülleştirilmiş hali (Şekil 3.2) gösterilmiştir.



Şekil 3.2 Nöron yapısının formülleştirilmiş hali (Ayyucekizrak.medium, n.d.)

DÖ yöntemleri, bilgisayarların tecrübelerinden öğrenmesini ve veriye dair özelliklerin algılamasını sağlayan bir yöntemdir. Bilgisayar tecrübelerinden bilgi topladığından, ihtiyaç olan tüm bilgileri belirten bir uzmana gerek yoktur. Veri temelli bu yöntem basit kavramlardan yola çıkarak oluşturduğu karmaşık bir yapıdır. Bu yapıyı grafik olarak anlatsaydık: "Çok sayıda katman içeren derin bir yapı" diyebilirdik (LeCun Y., et al., 2015).

Aşağıda Yapay Zeka, Makine Öğrenmesi ve Derin Öğrenme'nin şema ile gösterimi bulunmaktadır (Şekil 3.3).



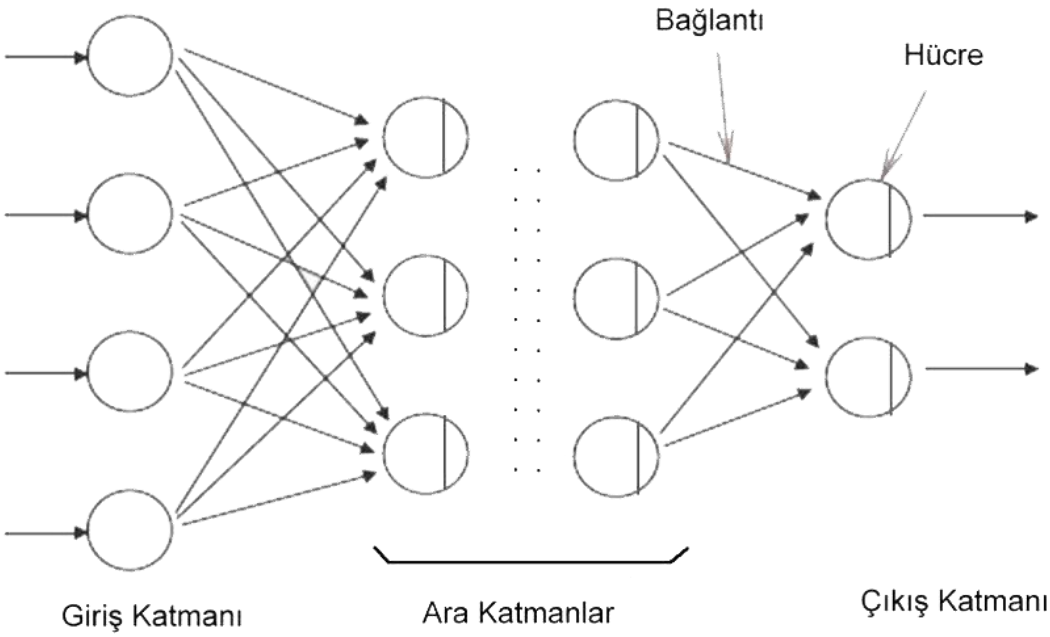
Şekil 3.3 Yapay zeka, makine öğrenmesi ve derin öğrenme'nin şema ile gösterimi

3.3.1. Yapay sinir ağları

Yapay sinir ağları (YSA) nöronlar ile üretilen veriler ile öğrenebilen, eylemleri ilişkilendirebilen, sınıflandırma ve genellemeler yapan makine öğrenmesi sınıflarındandır. YSA'lar nöronlara verilen girdileri işleyip çıktı elde eder ve örneklerden sonuç verebilir, genellemeler yapabilir (Sivari et al., 2020).

YSA'lar paralel programlama yöntemlerini bilgisayar bilimlerine kazandırmıştır. Geleneksel algoritmalardan ayıran bazı temel özellikleri vardır. YSA'lar güncel hayatımızda karşımıza çıkan bazı problemlerde uygulanabilir. Bunlardan birkaçını sıralarsak; endüstride, finansal işlemlerde, askeriyede ve sağlık alanlarında sınıflandırma, veri filtreleme ve teşhis koyma gibi işlemleri yapabilir (Sivari et al., 2020).

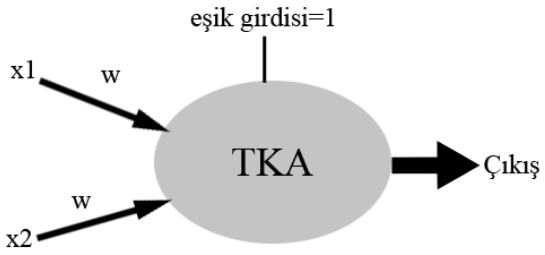
Aşağıda basit bir YSA modeli görülmektedir (Şekil 3.4).



Şekil 3.4 Yapay sinir ağı modeli (Derinogrenme.com, n.d.)

3.3.2. Tek katmanlı algılayıcılar

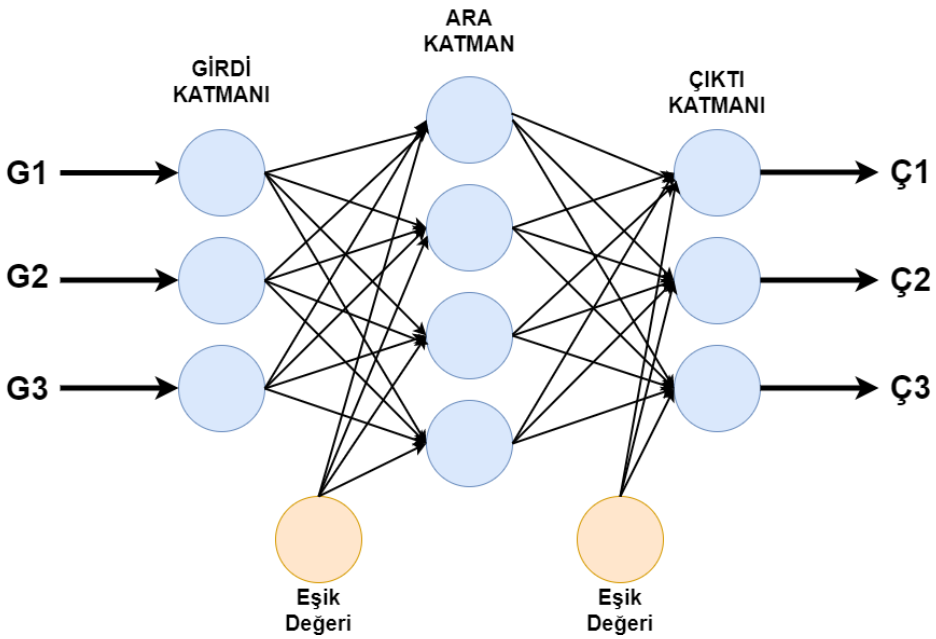
Tek katmanlı algılayıcılar sadece girdi ve çıktı katmanlarından oluşan yapay sinir ağı modelidir. Bu algılayıcılarda çıktı fonksiyonu 1 veya -1 değerini almaktadır. Çıktı 1 olursa birinci sınıf olarak kabul edilir. Çıktı -1 olursa ikinci sınıf olarak kabul edilir (Öztemel E., 2012). Çıkış değerinin 0 almasını engellemek için ağda eşik değeri yer alır. Çıkış fonksiyonu doğrusaldır. Çıkış değerini elde edebilmek için giriş değerleri eşik değerler ile toplanır. Giriş değerlerini eşik değerler ile toplayarak fonksiyondan geçerler ve çıkış değerini elde ederiz. Aşağıda tek katmanlı algılayıcı modelinin yapısı gösterilmektedir (Şekil 3.5).



Şekil 3.5 Tek katmanlı algılayıcı modeli

3.3.3. Çok katmanlı algılayıcılar

XOR problemi ile basit algılayıcıların çözüm üretemediği tespit edilmiştir. Bunun üzerinde Rumelhart ve arkadaşları çok katmanlı algılayıcı modelini üretmişlerdir (Rumelhart et al., 1985). Çok katmanlı algılayıcılar içerisinde doğrusal olmayan aktivasyon fonksiyonu barındırır, birçok nöron bulunur ve bunlar birbirleri ile bağlantılı olduğu bir yapıdır. Çok katmanlı algılayıcılar sınıflandırma ve tanıma problemlerinde başarılı olmuşlardır. Aşağıda çok katmanlı algılayıcı modelinin yapısı gösterilmektedir (Şekil 3.6).



Şekil 3.6 Çok katmanlı algılayıcılar

Çok katmanlı algılayıcılar üç çeşit katmandan oluşur. Bunlar giriş katmanı, ara katmanlar ve çıkış katmanıdır.

Giriş Katmanı: Yapay sinir ağına verilerin girildiği katmandır. Bir tane veya birden çok nöron bulundurabilir. Bu katmandaki her nöron ara katmandaki nöronlara bağlıdır. Bu bağlantı ile tüm veriler ara katmandaki nöronlara iletilir.

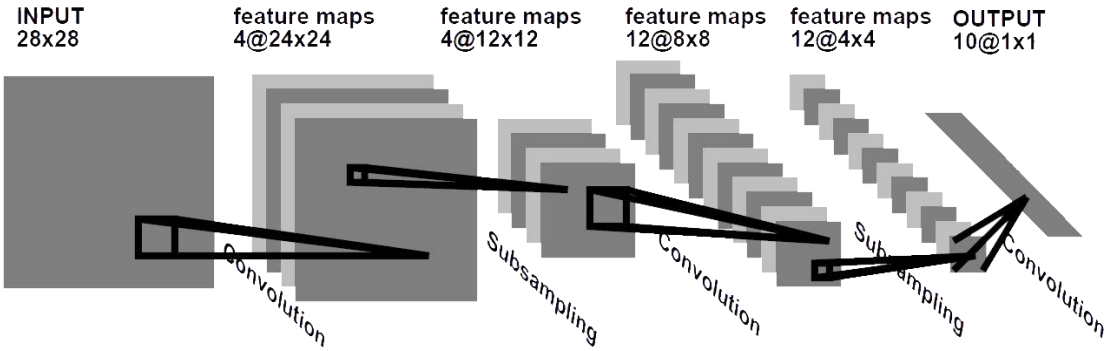
Ara Katman: Giriş katmanına girilen veriler nöronlar ile bu katmana iletilir ve bu katmanda veriler işlenir. Çok katmanlı ağlar bir tane veya birden çok ara katman bulundurabilir. Ara katmandaki işlenmiş bütün veriler çıkış katmanına iletilir.

Çıkış Katmanı: Veriler işlenerek ara katmanlardan çıkış katmanına iletilir. Bu katmanda sonuçlar verilir.

3.3.4. Evrişimli sinir ağları

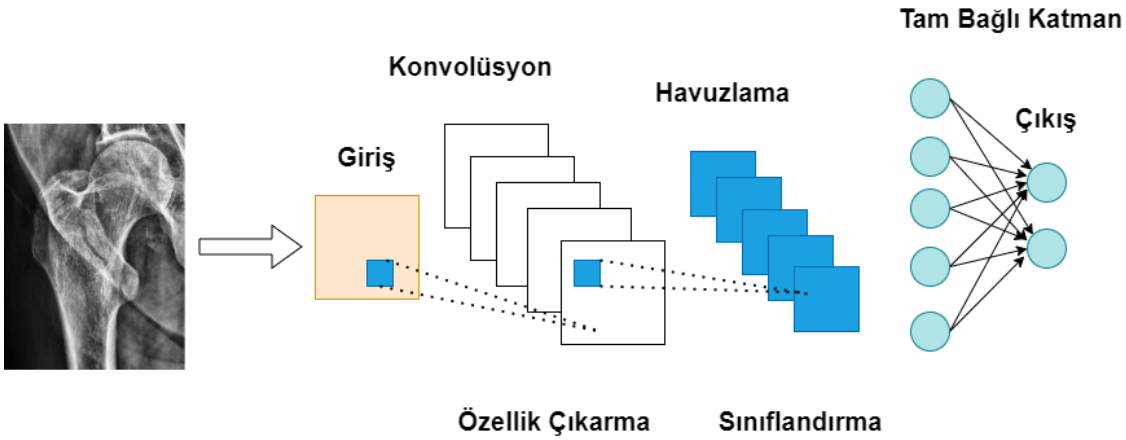
Derin öğrenme tekniklerinde kullanılan sinir ağı çeşidi olan evrişimli sinir ağları (ESA), çoğunlukla görüntü işlemede kullanılır ve içerisinde ileri beslemeli yapay sinir ağları kullanılan güçlü yöntemlerden biridir (Matsugu et al., 2003). Ayrıca veriyi işlemek için yapılandırılmış ızgaraya benzer yapısı olan yapay sinir ağı olarak da açıklanabilir (Goodfellow vd, 2016).

Yann LeCun tarafından ilk ESA ağı olarak tasarlanan 1998'e kadar iyileştirmeleri devam eden LeNet isimli mimarinin görseli aşağıda verilmiştir (Şekil 3.7) (Lecun Y. et al, 1989). İlk defa LeNet mimarisi ile özellik haritaları, düzleştirme adımı ve tam bağlı katman kullanılmıştır. Bu ağda evrişim ve maksimum havuzlama blokları art arda yerleştirilerek alt katmanlar desteklenmiştir. Sonrasında üst katmanlar tam olarak birbirine bağlanmış çok katmanlı ağa karşılık gelmektedir (Şeker et al., 2017).



Şekil 3.7 LeNet mimarisi (Lecun, 1989)

Aşağıda evrişimsel sinir ağı mimarisinin yapısı verilmiştir (Şekil 3.8).



Şekil 3.8 Evrişimsel sinir ağı mimarisi

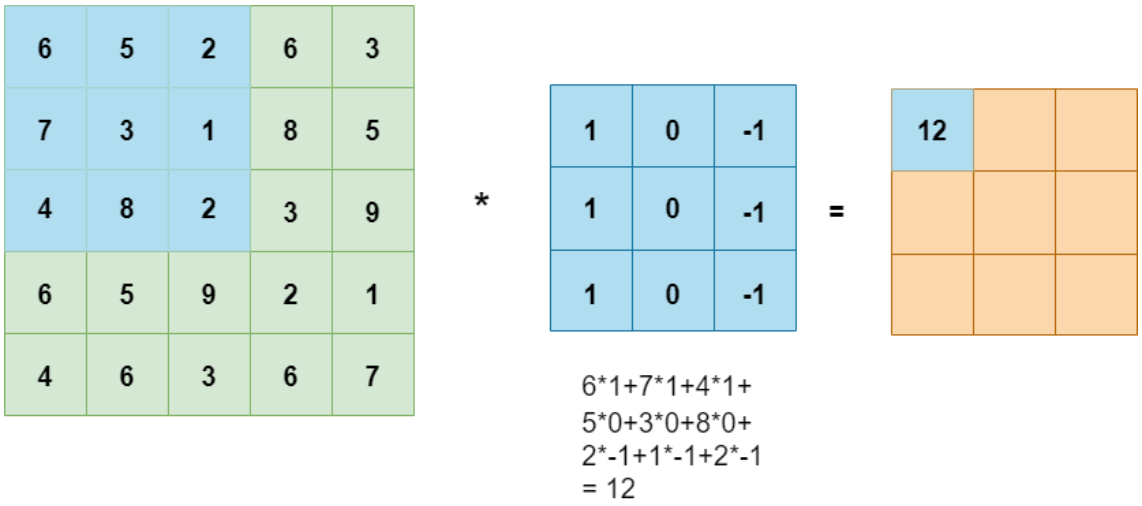
3.3.4.1. Evrişim katmanı

ESA'nın temelinde bu katman bulunur ve bu katmana dönüşüm katmanı da denir. Evrişim katmanı ile görüntülerden özellik çıkarılır.

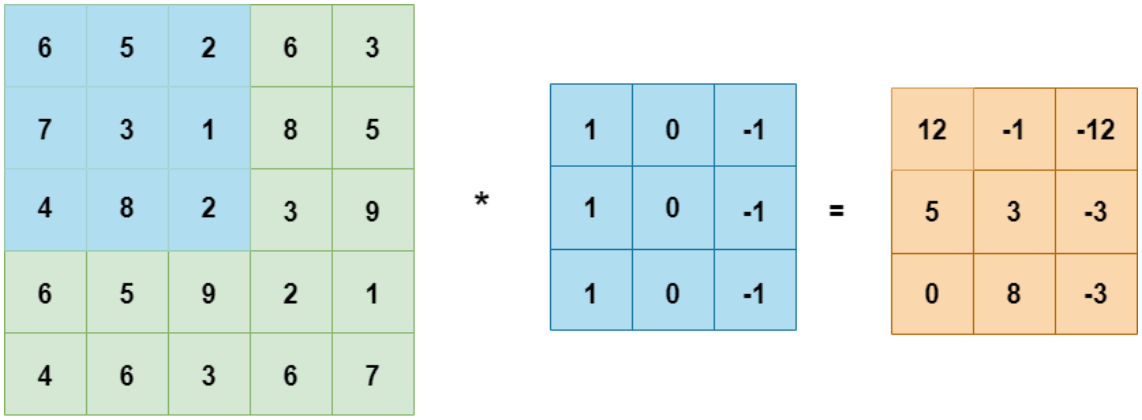
CNN'in evrişim katmanına veriler giriş katmanından gönderilir. Evrişim işlemi bu katmanda uygulanmaya başlar (Wei et al., 2020).

Evrişim işlemi belirlenmiş bir filtrenin bütün görüntü üzerinde belirli adımlarla dolaştırılarak uygulanır. Bu filtreler 2x2, 5x5, 7x7 gibi ölçülerde belirlenebilir. Filtreler ile konvolüsyon işlemi uygulanan görüntüden çıkış verisi elde edilerek sonraki katmana iletilir.

Aşağıda evrişim katmanında yapılan işlem 2 adet görselle verilmiştir (Şekil 3.9) (Şekil 3.10).



Şekil 3.9. Evrişim işlemi 1. adım sonucu

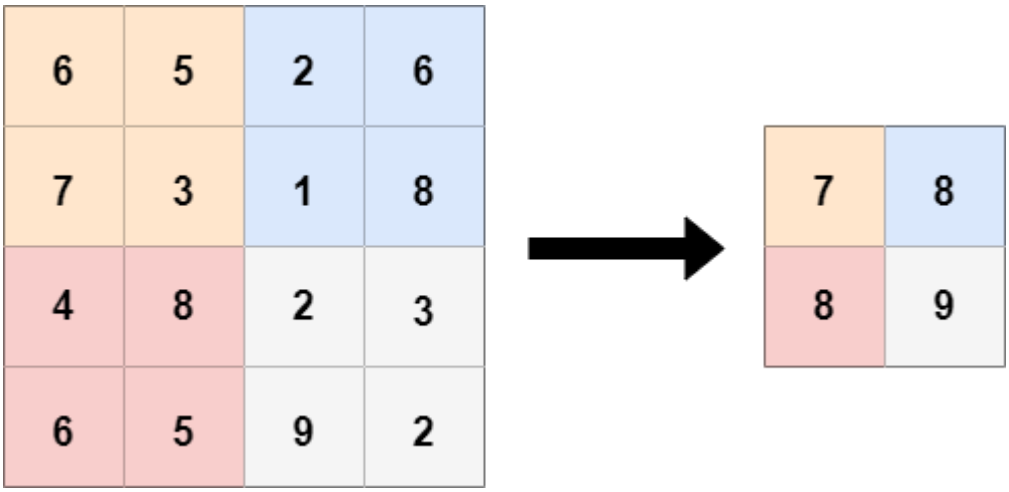


Şekil 3.10 Evrişim işlemi uygulandıktan sonra elde edilen çıktı

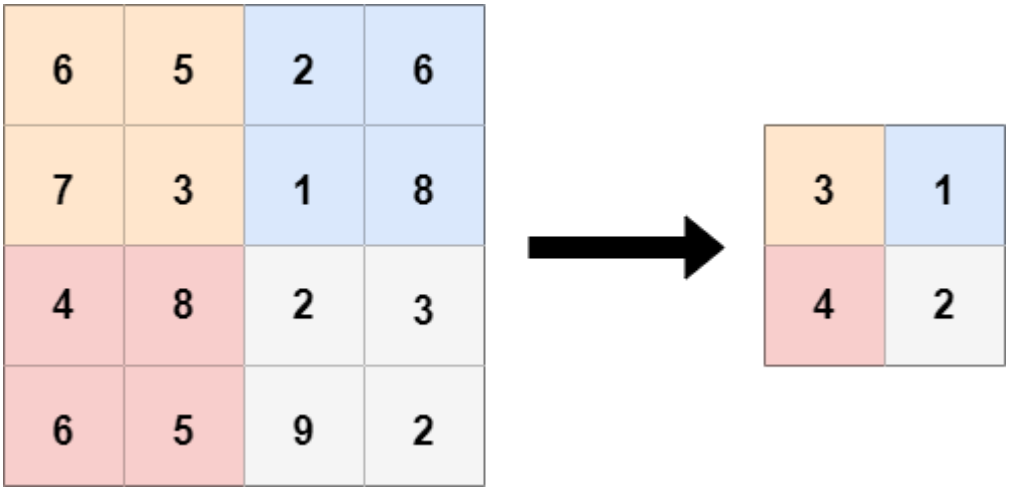
3.3.4.2. Havuzlama katmanı

Havuzlama katmanı genellikle evrişim katmanından sonra kullanılır (Doğan F., 2018). Evrişim katmanına verilen görüntünün çıktısı daha sonra havuzlama katmanına gönderilir. Kendisinden sonra gelecek olan katmana görüntüyü küçülterek verir. Bu işlem maliyeti düşürür ve işlemleri hızlandırır. Parametreler azaltılmış olacağından ağda oluşabilecek olan uyumsuzluk olaylarını minimalize edecektir.

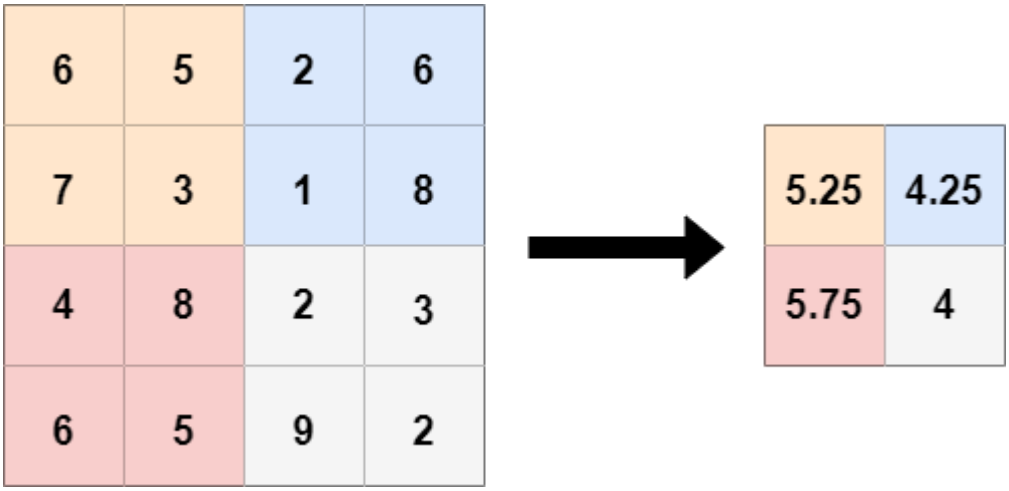
Maksimum havuzlama (Şekil 3.11); Matris bütün pikselleri görüntü içerisinde gezerken matris içerisinde en büyük değeri alıp kullanır. Minimum havuzlama (Şekil 3.12); Matris bütün pikselleri görüntü içerisinde gezerken matris içerisinde en küçük değeri alıp kullanır. Ortalama havuzlama (Şekil 3.13); Matris bütün pikselleri görüntü içerisinde gezerken matris içerisindeki ortalama değeri alıp kullanır.



Şekil 3.11 Maksimum havuzlama



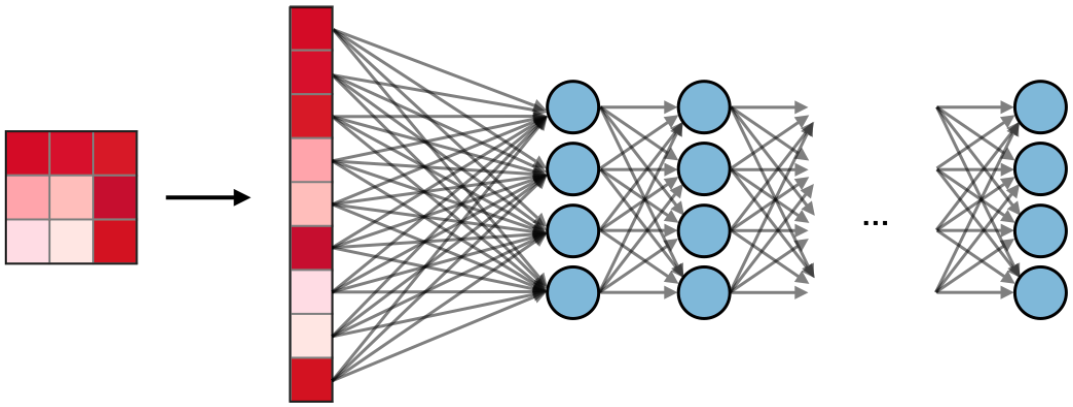
Şekil 3.12 Minimum Havuzlama



Şekil 3.13 Ortalama havuzlama

3.3.4.3. Tam bağlı katman

Bütün nöronlar kendinden sonra gelen nöronla bağlı olarak oluşturdukları bu katmana tam bağlı bağlı katman adı verilmektedir. Bir önceki katmanda yani havuzlama katmanından iletilmiş olan veriler tam bağlı katmanda tek boyutlu matris şekline dönüştürülerek işlenmektedir (Şekil 3.14) (Lin et al., 2014).

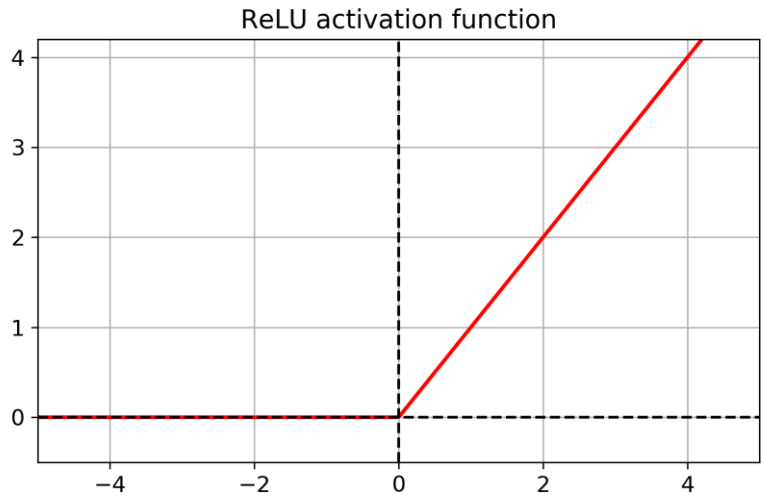


Şekil 3.14 Tam bağlı katman yapısı (Stanford.edu, n.d.)

3.3.4.4. Aktivasyon katmanı

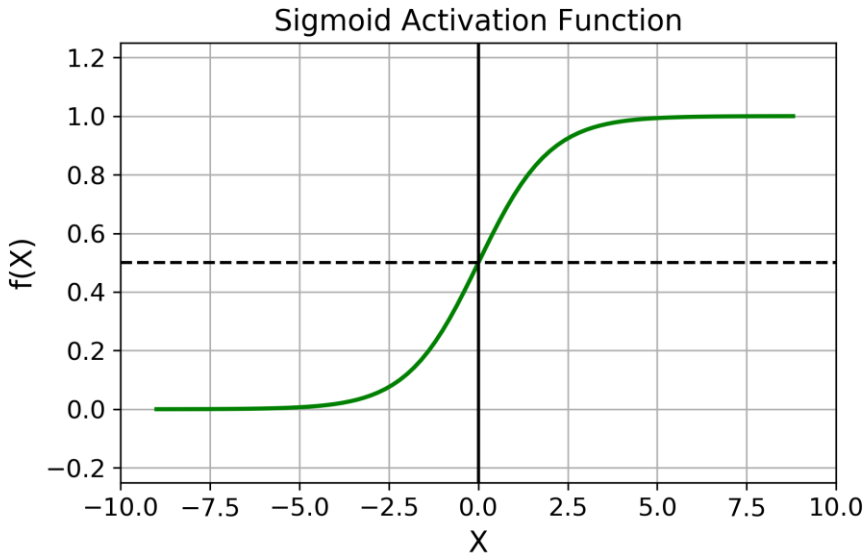
Aktivasyon katmanında elde edilen veriler aktivasyon fonksiyonunda işlenerek yeni veriler üretmektedir. Elde edilen veriler çeşitli aktivasyonlardan probleme göre olan seçilerek işlem yapılır. Aktivasyon fonksiyonu hangi nöronun aktif olacağını belirler. Aşağıda en çok kullanılan aktivasyon fonksiyonları hakkında bilgiler verilmiştir.

Relu aktivasyon fonksiyonu: Negatif bütün değerler 0 (sıfır) değeri alır. Pozitif bütün değerler aynı değeri alır (Şekil 3.15).



Şekil 3.15 Relu aktivasyon fonksiyonu

Sigmoid aktivasyon fonksiyonu: Çıkış değerleri 0 ve 1 aralığındadır. Sigmoid aktivasyon fonksiyonu ikili sınıflandırmalarda kullanılır (Şekil 3.16). Biz de tez çalışmamızda sigmoid aktivasyon fonksiyonunu kullandık.



Şekil 3.16 Sigmoid aktivasyon fonksiyonu

3.4. Görüntü İşleme

Sayısal hale getirilen görüntü üzerinde çeşitli yöntemler uygulanarak projelerimizde kullanabileceğimiz özel görüntülerin elde edilmesi ve elde edilen görüntüden projelerimizde kullanabileceğimiz bilgilerin alınması için kullanılan yöntemdir. Günlük hayatımızın birçok alanında da görüntü işleme yöntemleri yaygın olarak kullanılmaktadır (Gonzalez & Woods, 2008). Ortopedi alanında görüntü işleme ve yapay zeka alanında çalışmalar bulunmaktadır. Kullanılan radyografi görüntülerde bu çalışmalara sıklıkla rastlanmaktadır (Şahin S., 2017).

Biz de tez çalışmamızda radyografi görüntüler üzerinde görüntü işleme yöntemlerinden olan histogram eşitleme işlemi yapmamızı sağlayan CLAHE (Contrast Limited Adaptive Histogram Equalization - Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme) filtresini kullandık.

3.4.1. Tıbbi görüntüleme teknikleri

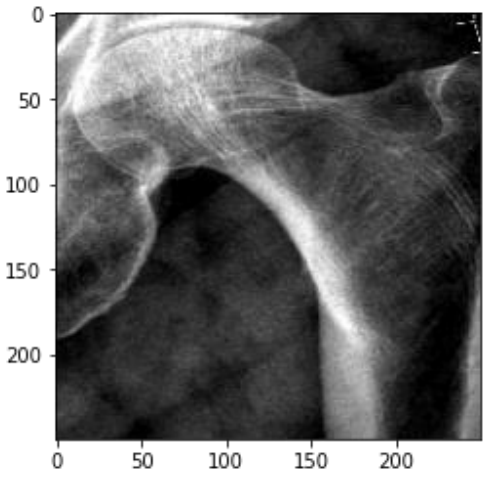
Wilhelm Conrad Röntgen'in 1895 yılında kullanmış olduğu görüntüleme yöntemlerinin temeli olan x ışınını bulmasıyla x-ray görüntüleme kullanılmaya başlanmıştır (Sümer et al., 2018). DICOM (Digital Imaging and Communications in Medicine - Tıpta Dijital Görüntüleme ve İletişim) tıbbi görüntülemede bilgilerin işlenmesinin, depolanmasının, yazıcıdan çıktı alınması ve iletilmesi bilgilerini de kapsayan bir dosyalama standardıdır. Hastadan elde edilen medikal görüntüde adı, soyadı, yaşı, tarama yapılan cihaz gibi bilgileri barındıran belli bir öznitelikten oluşur İçerisinde sistemler arasında TCP/IP protokolünü kullanarak iletişim sağlar (DICOM, n.d.).

Röntgen verilerinin dijital ortama taşınmasıyla veriye ulaşma kolaylığı sağlamıştır. İlgili alanlarla da veri seti hazırlama imkanı olmuştur. Bu veri setleri ile yapay zeka alanlarında çalışılarak günümüz problemlerinin çözümünde kolaylıklar sağlamıştır.

Aşağıda proksimal femur kırığı (Şekil 3.17) ve sağlam proksimal femur (Şekil 3.18) röntgen görüntüsü verilmiştir



Şekil 3.17 Proksimal Femur Kırık

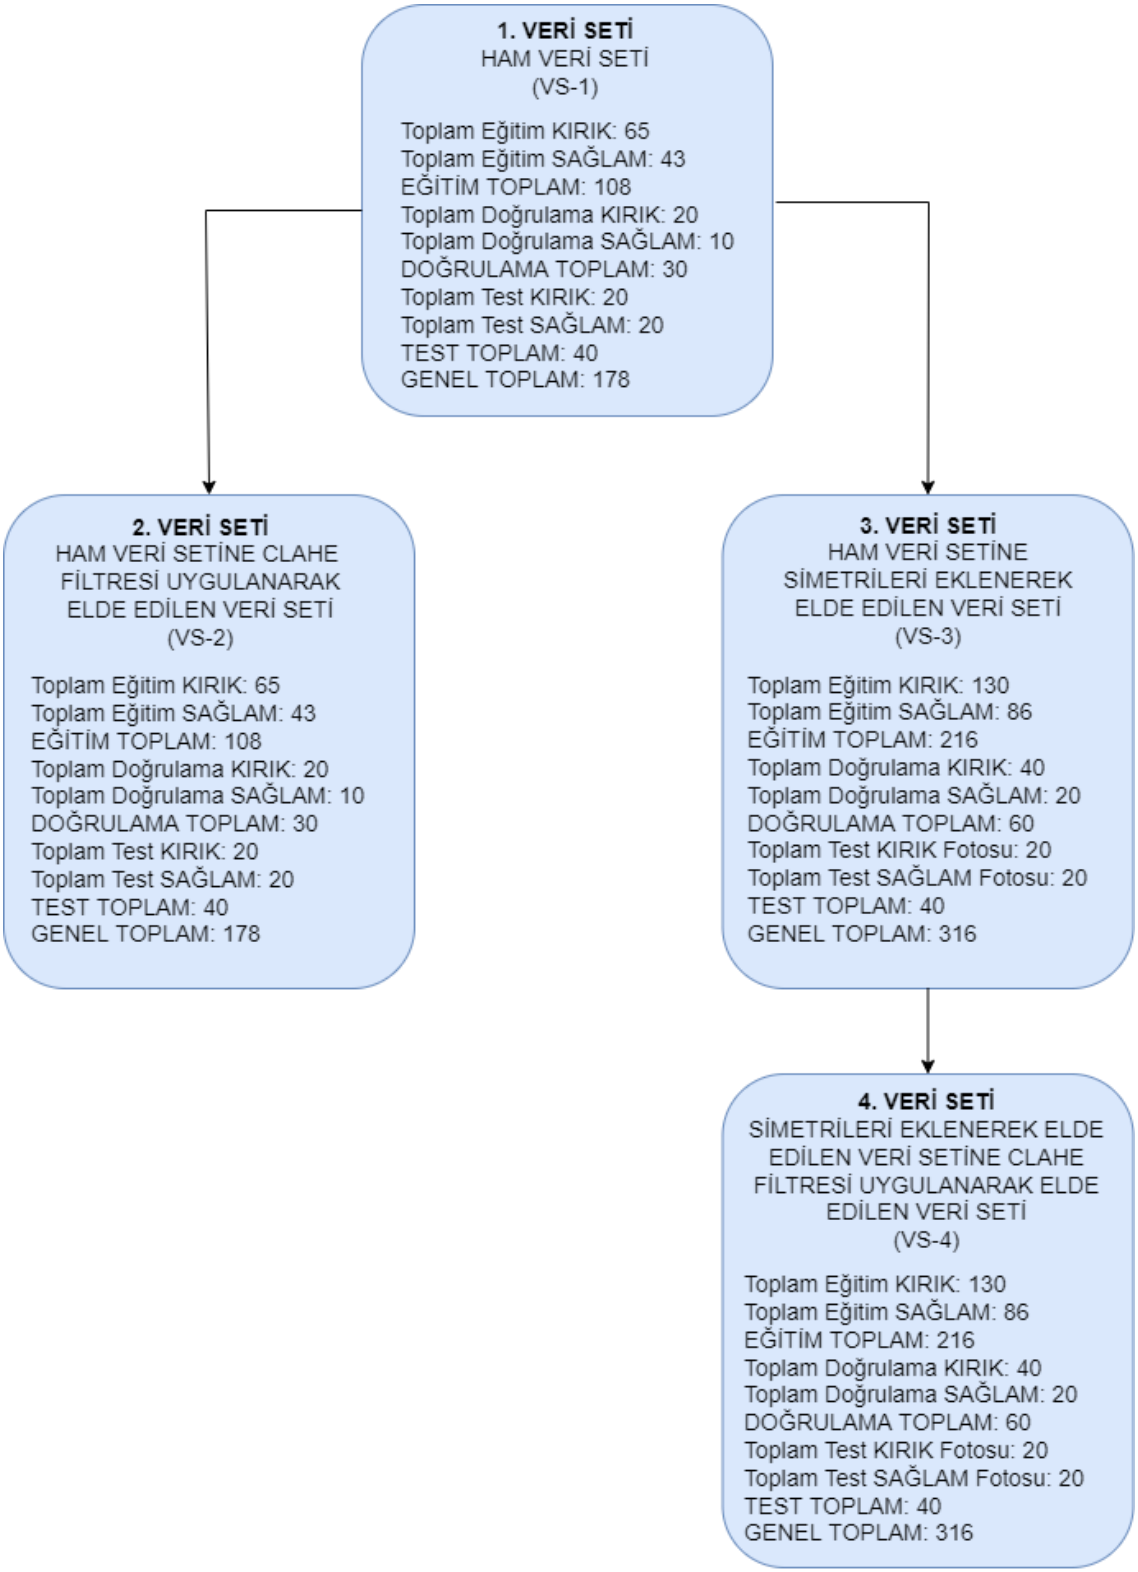


Şekil 3.18 Proksimal Femur Sağlam

4. MATERYAL VE YÖNTEM

4.1. Veri Seti Hakkında Bilgi

Bu çalışmada Sağlık Bilimleri Üniversitesi Gülhane Bilimsel Araştırmalar Etik Kurul Başkanlığı'nın 14.01.2021 tarih ve 2021/04 protokol numaralı protokolü ile Ocak 2011-Kasım 2020 tarihleri arasında 18 yaş üstü 111 hastanın radyoloji görüntüleri proksimal femur kırıkların doğru ve optimize tespiti için kullanılmıştır. Toplam 178 adet x-ray görüntüsü bulunan verilerden 4 adet veri seti oluşturulmuştur. İlk veri setimizde (VS-1) 178 adet x-ray görüntüsünden elde edilmiştir, eğitim için 108, doğrulama için 30, test için 40 adet x-ray görüntüsü kullanılmıştır. İkinci veri setimizde (VS-2) VS-1'e CLAHE filtresi uygulanmış halidir. Üçüncü veri setimizde (VS-3) VS-1'e görüntülerin simetrileri eklenerek veri artırımı yapılmıştır. Böylelikle veri setimizde görüntü sayısı 316 olmuştur. VS-3'te eğitim için 216, doğrulama için 60, test için 40 adet x-ray görüntüsü olarak hazırlanmıştır. Dördüncü veri setimizde (VS-4) VS-3'e CLAHE filtresi uygulanmış halidir. Veri setleri hakkında hazırlamış olduğumuz bilgilendirici görsel (Şekil 4.1) aşağıda verilmiştir.



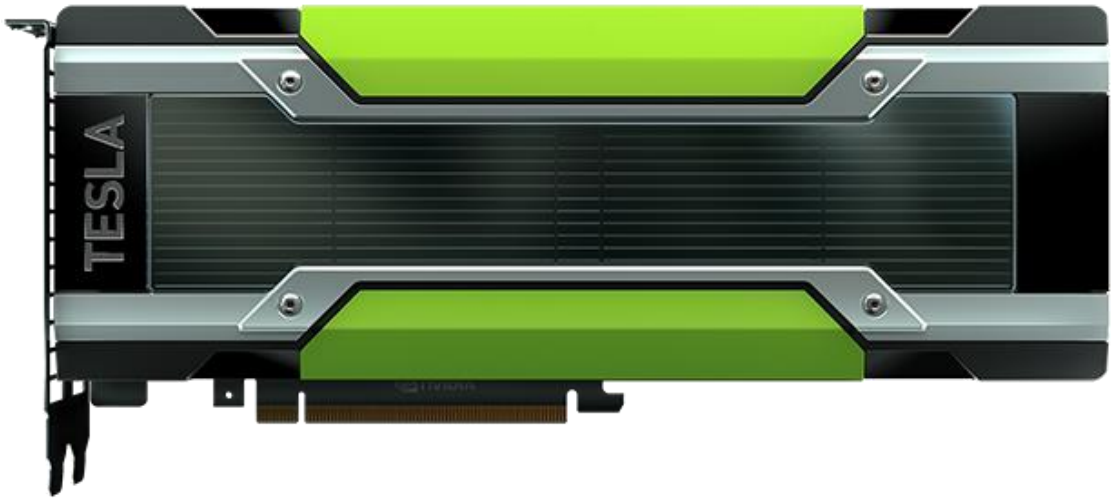
Şekil 4.1 Veri setleri hakkında bilgi

4.2. Kullanılan Yazılım Dili ve Donanım

Tez çalışmamız Google Colaboratory ortamında hazırlanmıştır. Colaboratory ücretsiz olarak Tesla K80 ekran kartını (GPU) (Şekil 4.2) kullanıma sunmuştur. Colaboratory ortamında Keras ve TensorFlow gibi kütüphaneleri kullanarak derin öğrenme çalışmaları yapılabilmektedir. Programlama dili olarak Python 3.7.12 versiyonu kullanılmıştır.

Tesla K80 GPU teknik özellikleri: (Nvidia, n.d.)

- 4992 Nvidia Cuda çekirdeğine sahiptir.
- 24GB belleğe sahiptir.
- Bellek türü GDDR5'tir.
- Bellek bant genişliği 480GB/s'dir.



Şekil 4.2 Tesla K80 GPU (Nvidia, n.d.)

4.3. Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (CLAHE)

En yaygın kullanılan görüntü iyileştirme yöntemlerinden biri de histogram eşitlemedir. Düz bir histogram oluşturduktan sonra görüntüdeki zıtlıklar belirginleştirişmiş olur (S

Erbakan et al., 2015). Histogram eşitleme yöntemi bazı görüntülerde bozulmalara neden olabilmektedir. Pizer ve arkadaşları histogram eşitleme yöntemlerinden kaynaklı aşırı parlaklığı önlemek için görüntüyü bölgelere bölerek komşu pikseldeki değerler baz alınarak bu bölgelere kontrast sınırlı uyarlanabilir histogram eşitleme (Contrast Limited Adaptive Histogram Equalization - CLAHE) yöntemini geliştirmiştir (Öztürk & Öztürk, 2022). CLAHE klasik histogram eşitleme yöntemlerinin aksine, bütün görüntünün yoğunluk seviyesi yerine bölgesel olarak yoğunluk seviyelerine göre işlemektedir (Etta D. Pisano, Shuquan Zong, Bradley M. Hemminger, Marla Deluca, 2016). Görüntüdeki parazitleri, gürültüleri ve bozulmaları azaltır. CLAHE yöntemi medikal görüntülemelerde yaygın bir şekilde kullanılmaktadır (Kurt & Nabİyev, 2010).

4.4. Veri Ön İşleme

Veri setimizdeki görüntüler 500 x 600, 400 x 600 gibi çözünürlüklere sahiptir. Görüntüleri bu çözünürlükle uygulamamızda kullanırsak fazladan işlem yükü ve zaman gerekecektir. Görüntüler ESA mimarilerinin yapısı düşünülerek yeniden boyutlandırılmıştır. Görüntülerin çözünürlüklerini 250 x 250 olarak uyguladık.

4.5. Keras

Google'da derin öğrenme üzerine çalışmakta olan François Chollet tarafından hazırlanmıştır. TensorFlow ve Theano derin öğrenme kütüphanelerinin üzerine kurulmuş modüler bir Python kütüphanesidir (Keras, n.d.). Aynı kodu CPU veya GPU üzerinde sorunsuz çalıştırabilirsiniz. Derin öğrenme modellerini hızlı bir şekilde prototiplemeyi kolaylaştırır. Evrişimli ağlar, tekrarlayan ağlar ve her iki ağın herhangi bir birleştirme ve tertibi için yerleşik desteğe sahiptir. Keras, CERN, Uber, Google, Netflix ve çok farklı alanlarda da kullanılmaktadır (Francois Chollet, 2017).

Basit YSA modelleri oluşturulabilmesi, modüler ve geliştirmeye açık olması, makine öğrenmesi alanında çokça kullanılmasının sebeplerinden bazılarıdır (Keras, n.d.)

Keras bu sektörde çalışanlara büyük kolaylıklar sağlamaktadır. Model mimarisi kolayca değiştirilebilmektedir, aktivasyon ve maliyet fonksiyonları kişiselleştirilebilmektedir. Keras'ın görüntü işleme uygulamalarında oldukça yaygın bir kullanımı vardır.

4.6. Evrişimsel Sinir Ağı Modelleri

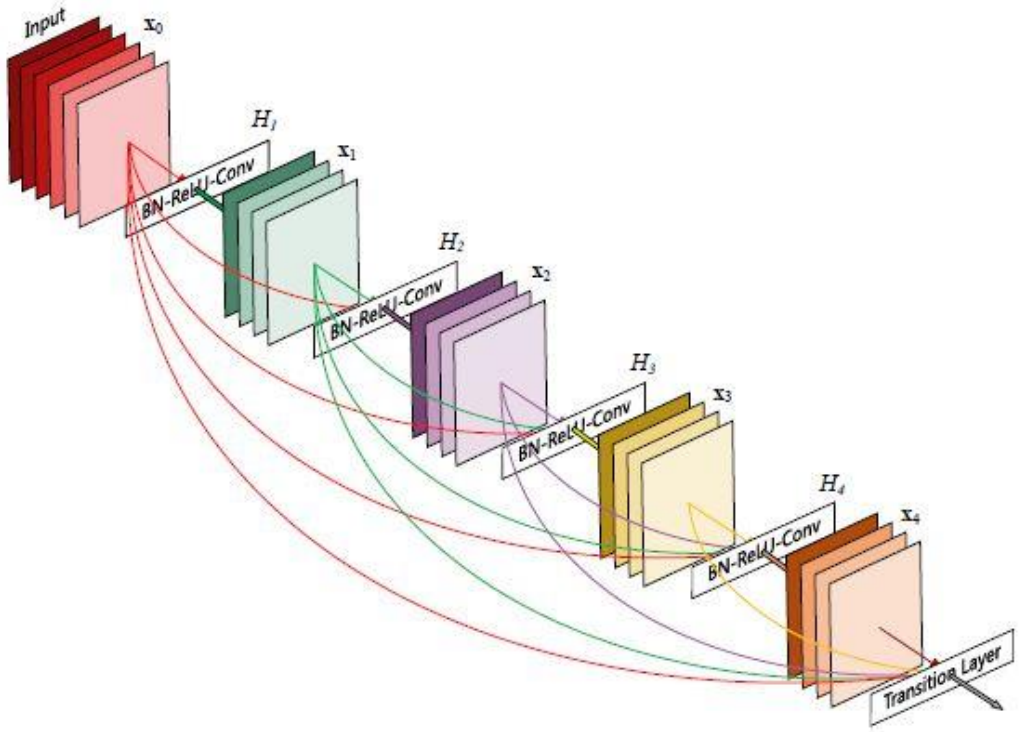
Yapay Sinir Ağları (YSA) hesaplama modelleridir. Çalışma prensipleri insan beynine benzer. YSA nöronların birbirine bağlanması ile oluşur. YSA'nın çalışma prensibini açıklarsak:

- Nöronlar birbirlerine bağlanarak sinyalleri iletirler
- Veri toplar ve veriyi işler
- Ağ yapısında giriş katmanı, ara katman ve çıktı katmanı şeklindedir
- Ağ verinin iler ve geriye doğru gitmesi ile eğitilir
- Sonra ağ test edilir. (El-Shahat, 2018)

4.6.1. Densenet

Huang ve arkadaşları küçük ölçekli olan CIFAR ve SVHN veri setlerinde eğitmiştir. Ayrıca büyük ölçekli olan ImageNet veri seti üzerinde de eğitilerek geliştirilmiş bir modeldir. Evrişimli sinir ağı modellerinden olan DenseNet201 yapısında 201 adet katman bulundurmaktadır (Huang et al., 2017). Bu 201 adet katman 117 döngü, 3 geçiş ve 1 sınıflandırma katmanından oluşmaktadır (Li et al., 2020). DenseNet modellerinin mimarisinin yapısında her katman önceki bütün katmanların özelliklerini girdi olarak kullanmaktadır. Kendisinden sonra gelen katmanlara da kendi özelliklerini girdi olarak verebilmektedir (Kumar, 2019). DenseNet mimarilerini öne çıkaran yapısı ise özellik yayılımını sağlayarak özelliğin yeniden kullanılmasını sağlamasıdır. Bu durum parametre sayısını da azaltmaktadır (Huang et al., 2017). Yoğun blokların sıralı gösterimi aşağıda

(Şekil 4.3) görülmektedir. Sıralı bir şekilde dizilmiş yığın normalizasyonu, relu ve evrişim işlemlerinden oluşmuştur. Ağ girişinde 7x7 boyutunda evrişim blokları ve maksimum havuzlama katmanı bulunmaktadır. Her yoğunluk bloğundan sonra geçiş bloğu gelmektedir. Geçiş bloğunda 1x1 evrişim katmanı, 2x2 ortalama havuzlama katmanı ve 4 adet yoğunluk ve geçiş bloğu bulunmaktadır. Son olarak sınıflandırma katmanında 7x7 boyutunda ortalama havuzlama katmanı bulunmaktadır. Aşağıda (Çizelge 4.1) DenseNet mimarisi gösterilmektedir. Biz de tez çalışmamızda DenseNet201 modelini kullandık.



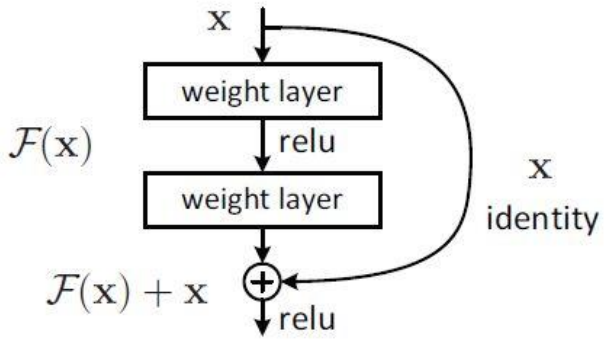
Şekil 4.3 Büyüme oranı k = 4 olan 5 katmanlı yoğun blok. (Huang et al., 2017).

Çizelge 4.1 DenseNet mimarisinin yapısı. (Huang et al., 2017)

Layers	Output Size	DenseNet-121	DenseNet-169	DenseNet-201	DenseNet-264
Convolution	112 × 112	7 × 7 conv, stride 2			
Pooling	56 × 56	3 × 3 max pool, stride 2			
Dense Block (1)	56 × 56	[1 × 1 conv, 3 × 3 conv] × 6	[1 × 1 conv, 3 × 3 conv] × 6	[1 × 1 conv, 3 × 3 conv] × 6	[1 × 1 conv, 3 × 3 conv] × 6
Transition Layer (1)	56 × 56	1 × 1 conv			
	28 × 28	2 × 2 average pool, stride 2			
Dense Block (2)	28 × 28	[1 × 1 conv, 3 × 3 conv] × 12	[1 × 1 conv, 3 × 3 conv] × 12	[1 × 1 conv, 3 × 3 conv] × 12	[1 × 1 conv, 3 × 3 conv] × 12
Transition Layer (2)	28 × 28	1 × 1 conv			
	14 × 14	2 × 2 average pool, stride 2			
Dense Block (3)	14 × 14	[1 × 1 conv, 3 × 3 conv] × 24	[1 × 1 conv, 3 × 3 conv] × 32	[1 × 1 conv, 3 × 3 conv] × 48	[1 × 1 conv, 3 × 3 conv] × 64
Transition Layer (3)	14 × 14	1 × 1 conv			
	7 × 7	2 × 2 average pool, stride 2			
Dense Block (4)	7 × 7	[1 × 1 conv, 3 × 3 conv] × 16	[1 × 1 conv, 3 × 3 conv] × 32	[1 × 1 conv, 3 × 3 conv] × 32	[1 × 1 conv, 3 × 3 conv] × 48
Classification Layer	1 × 1	7 × 7 global average pool			
		1000D fully-connected, softmax			

4.6.2. Resnet

ResNet mimarisi ilk olarak 2015 yılında Kaiming He ve arkadaşları tarafından tasarlanmış 152 katmanlı bir modeldir. Evrişimsel ağlarda derinlik arttıkça aşırı uydurma problemi ve gradyan kaybı ortaya çıkmaktadır. Bu durumda baştaki katmanların ağırlıkları güncellenememektedir. Bu ağırlıklarında ağa katkısı olmayacaktır. Kaiming ve arkadaşları bu sorunu çözmek için atlama bağlantısı yapmıştır. Her katmandaki giriş bilgilerini sonraki katmana iletmişlerdir bu işlem için artık fonksiyon kullanmışlardır (He et al., 2016a). Derin artık öğrenme yönteminde artık bloklar kullanılmıştır. Bu bloklar ağda değişiklik aralıklarla kullanılabilmektedir (He et al., 2016b) . Biz de tez çalışmamızda ResNet152V2 modelini kullandık. Artık (residual) blokların yapısı aşağıda (Şekil 4.4) verilmiştir. Resnet mimarilerinin yapısı aşağıda (Çizelge 4.2) verilmiştir.



Şekil 4.4 Residual blokların yapısı (He et al., 2016a)

Çizelge 4.2 ResNet mimarisinin yapısı (He et al., 2016a)

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				
		$\begin{bmatrix} 3\times3, 64 \\ 3\times3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3\times3, 64 \\ 3\times3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1\times1, 64 \\ 3\times3, 64 \\ 1\times1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1\times1, 64 \\ 3\times3, 64 \\ 1\times1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1\times1, 64 \\ 3\times3, 64 \\ 1\times1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 3\times3, 128 \\ 3\times3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3\times3, 128 \\ 3\times3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1\times1, 128 \\ 3\times3, 128 \\ 1\times1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1\times1, 128 \\ 3\times3, 128 \\ 1\times1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1\times1, 128 \\ 3\times3, 128 \\ 1\times1, 512 \end{bmatrix} \times 8$
conv4_x	14×14	$\begin{bmatrix} 3\times3, 256 \\ 3\times3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3\times3, 256 \\ 3\times3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1\times1, 256 \\ 3\times3, 256 \\ 1\times1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1\times1, 256 \\ 3\times3, 256 \\ 1\times1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1\times1, 256 \\ 3\times3, 256 \\ 1\times1, 1024 \end{bmatrix} \times 36$
conv5_x	7×7	$\begin{bmatrix} 3\times3, 512 \\ 3\times3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3\times3, 512 \\ 3\times3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1\times1, 512 \\ 3\times3, 512 \\ 1\times1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1\times1, 512 \\ 3\times3, 512 \\ 1\times1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1\times1, 512 \\ 3\times3, 512 \\ 1\times1, 2048 \end{bmatrix} \times 3$
	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

4.6.3. Inceptionresnetv2

InceptionResNetV2 modeli Christian Szegedy ve arkadaşları tarafından 2015 yılında gerçekleştirilen ILSVRC ImageNet yarışması için tasarlanmış bir modeldir (Szegedy et al., 2016). InceptionResNetV2 modeli yapısal olarak Inception-V3 ve ResNet mimarilerinden oluşturulmuştur. InceptionResNetV2, inception mimarisini artık bloklar ile bağlamıştır. Evrişim filtreleri de bu şekilde bağlandığından eğitim süresini azaltmıştır.

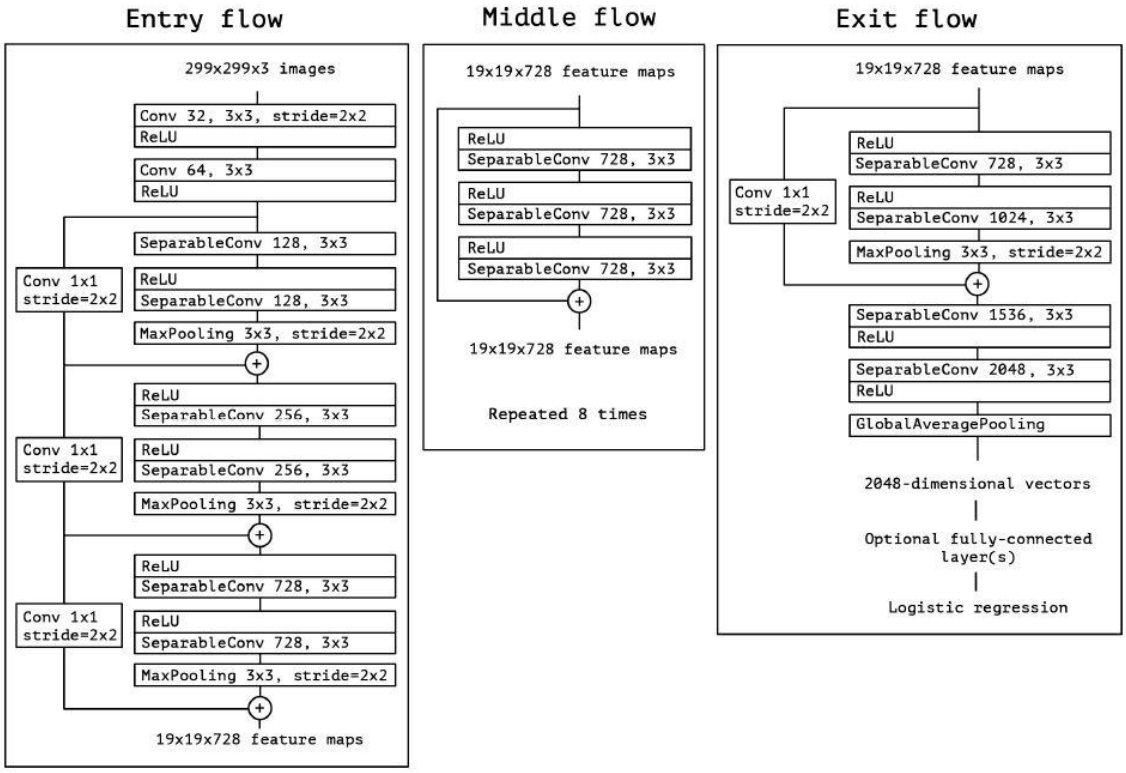
Inception ve ResNet modellerine göre hesaplama maliyeti daha azdır (Alruwaili et al., 2021). InceptionResNetV1'in hesaplama maliyeti yaklaşık InceptionV3'e yakın olmuştur. InceptionResNetV2'nin ham maliyeti InceptionV4 ile aynıdır. InceptionV4'ün mimarisinde artık bloklar ve inception modülleri birbirlerine bağlanmıştır. InceptionResNet modellerinin çeşitlerinde InceptionV4'te kullanılan filtreler kullanılmıştır (Szegedy et al., 2017). InceptionResNetV2 modelinin mimarisi aşağıda (Çizelge 4.3) gösterilmiştir.

Çizelge 4.3 Inception-ResNetV2 mimarisinin yapısı (Alruwaili et al., 2021)

Layer	Patch size	Input size
Conv	3 × 3	224 × 224 × 3
Conv	3 × 3	111 × 111 × 32
Filter contact	3 × 3 pool + 3 × 3 conv	109 × 109 × 64
Filter contact	1 × 1 conv, 3 × 3 conv+ 1 × 1 conv, 7 × 1 conv, 1 × 7 conv, 3 × 3 conv	54 × 54 × 160
Filter contact	3 × 3 conv + max pool	52 × 52 × 128
Inception-ResNet-A × 10	—	26 × 26 × 256
Reduction-A	—	26 × 26 × 256
Inception-ResNet-B × 20	—	13 × 13 × 768
Reduction-B	—	13 × 13 × 768
Inception-ResNet-C × 10	—	6 × 6 × 1534
Average pooling	6 × 6	6 × 6 × 1534
Dropout	Keep = 0.5	1 × 1 × 1534
Fc	1534 × 1000	1534
Fc	1000 × 3	1000
Softmax	Classifier (3 classes)	500

4.6.4. Xception

Xception modeli François Chollet tarafından geliştirilmiştir. Xception mimarisi özellik çıkarma tabanı 36 adet evrişim katmanından oluşmaktadır. 36 adet evrişim katmanı, ilk ve son modüller dışında diğerlerinin çevresinde doğrusal artık bağlantılara sahip olan 14 modül halinde yapılandırılmıştır. Kısaca, Xception mimarisi, artık bağlantılara sahip, derinlemesine ayrılabilir evrişim katmanlarının doğrusal bir yığınıdır. (François Chollet, 2017). Aşağıda Xception mimarisinin katmanlarını gösteren şekil (Şekil 4.5) yer almaktadır.



Şekil 4.5 Xception mimarisinin katmanları (François Chollet, 2017)

4.7. Öğrenim Aktarımı

Öğrenim aktarımı (ÖA) ile Geleneksel olarak oluşturulan yapay zeka modeli yönteminde bir eğitim veri seti ile oluşturmuş olduğunuz yapay zeka modelini eğitiriz. Bu yöntem ile büyük veri setlerine ihtiyacımız olacak ve eğitim süresi de çok uzun olacaktır. Bununla birlikte maliyetlerde artacaktır.

ÖA uygulamaları, insanın öğrenme yöntemini taklit etmektedir. İnsanlar ilk defa karşılaştıkları bir problemi çözerken daha önceki tecrübelerinden yararlanmaktadır (Fırıldak & Talu, 2019).

Her zaman yeni çıkan bir problem ile karşılaştığımızda veri toplamak mümkün olmamaktadır. Öğrenim aktarımı yöntemi; daha önceden eğitilmiş bir modelin başka bir

problem çözümünde kullanılmasıdır. ÖA yöntemi ile az veri ile model performansları artmakta ve eğitim süreleri de kısalmaktadır. Bunun yanında maliyetler de düşmektedir (Pan & Yang, 2010).

ÖA üç adımda uygulanır. Öncelikle neyin aktarılacağına karar verilir. Bilginin hangi parçası aktarılacaktır. Her bilgi her probleme uygulanamaz. Neyin aktarılacağı belirlendikten sonra nasıl aktarılması gerektiği de belirlenmelidir. Son olarak bilginin aktarılma zamanının hangi durumlarda yapılması belirlenmesidir. Önceden eğitilmiş bir model ile transfer edip uygulanacak olan problem çok farklı ise yeni eğitimin performansını olumsuz etkileyecektir. Bunun gibi oluşan durumlara negatif transfer olarak tanımlanır (Pan & Yang, 2010).

ÖA genellikle bir problem için önceden eğitilmiş modelleri yakın problemlerde tekrar kullanılmasıdır. Uygulanacak olan probleme daha önceden eğitilmiş olan model dahil edilir ve yeni problem için düzenlenerek eğitime başlanır. Öğrenim aktarımı sayesinde geleneksel olarak model oluşturmaya göre daha az veri ile kısa sürede çok daha iyi sonuçlar alınmaktadır. Bu yöntem ile karşımıza yeni çıkan problemlerin modellemesinde kolaylık sağlamaktadır. Hayatımızın birçok alanında da başarılı olarak kullanılmaktadır.

4.8. Optimizasyon

Optimizasyon yöntemlerinde gradyan iniş yöntemi kullanılmaktadır. Gradyan iniş yönteminin dezavantajı sabit öğrenme katsayısıdır. Küçük bir katsayı belirlendiğinde öğrenme işlemi uzun sürecektir. Büyük bir katsayı belirlendiğinde ise optimum değere yaklaşamayabilir. Bu yüzden çeşitli optimizasyon yöntemleri geliştirilmiştir (Yazan & Talu, 2017). Modellerin öğrenme aşamasında yaygın olarak kullanılan 6 tane optimizasyon yöntemi bulunmaktadır. Bunlar; SGD, Adadelta, Momentum, Adagrad, RMSProp ve Adam yöntemleridir. Biz tez çalışmamızda RMSporp ve Adam yöntemlerini kullandık (Seyyarer et al., 2020).

4.8.1. Rmsprop

Adagrad yönteminde öğrenme katsayısı zamanla aşırı küçülmeye gitmektedir. Bu soruna çözüm olarak da RMSprop yöntemi geliştirilmiştir (Ser & Bati, 2019).

4.8.2. Adam

Adam yöntemi her iterasyonda öğrenme katsayısını güncellemektedir. Adam yöntemi, Adagrad ve RMSprop yöntemlerinin avantajlı özelliklerini kullanarak tasarlanmıştır (Yazan & Talu, 2017).

5. BULGULAR

5.1. Karışıklık Matrisi (KM)

Çalışmada kullanmış olduğumuz modellerin performanslarını görselleştirmek, tahmin edilen değerin doğruluğunu veya yanlış olduğunu değerlendirmek için kullanılır. Kırık sınıfını pozitif sınıf, sağlam sınıfını ise negatif sınıf olarak değerlendirdik.

Gerçek Pozitif (True Positive): Kırık olan verinin Kırık olarak doğru tahmin edilmesidir.

Gerçek Negatif (True Negative): Sağlam olan verinin Sağlam olarak doğru tahmin edilmesidir.

Yanlış Pozitif (False Positive): Kırık olan verinin Sağlam olarak yanlış tahmin edilmesidir.

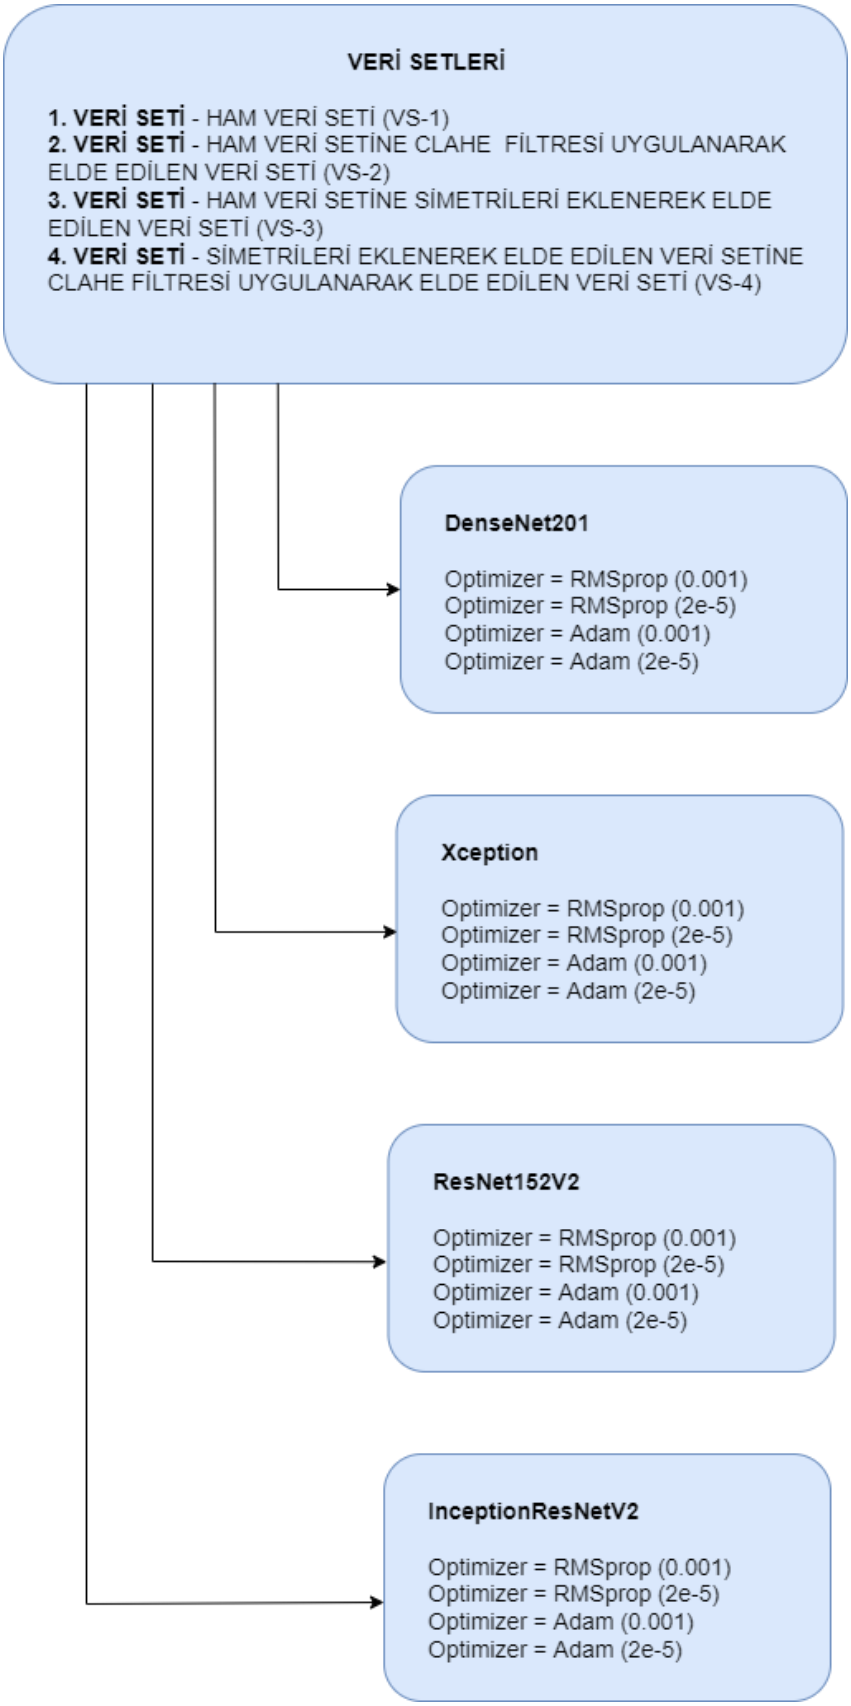
Yanlış Negatif (False Negative): Sağlam olan verinin Kırık olarak yanlış tahmin edilmesidir.

5.2. Veri Setlerinde Yapılan İşlemler

Dört veri setimize uygulanan işlemler sırası ile aşağıdaki gibidir;

Bütün veri setleri sırası ile DenseNet201, Xception, ResNet152V2 ve InceptionResNetV2 öğrenme aktarımı modelleri ile eğitilmiştir.

Aşağıda yapılan işlemleri açıklayıcı görseli (Şekil 5.1) verilmiştir.



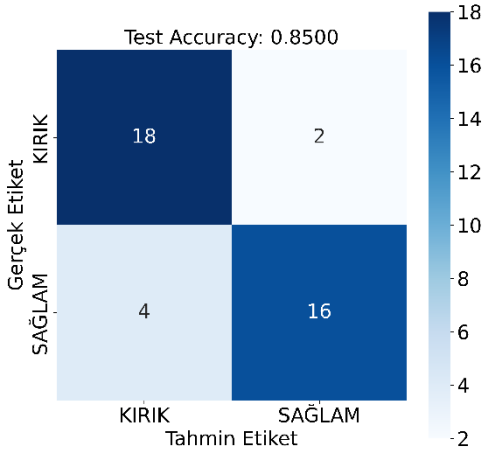
Şekil 5.1 Veri setlerinde yapılan işlemler

Her modelde sırası ile RSMprop ve Adam optimizasyon yöntemleri kullanılmıştır ve verilen öğrenme katsayı değerleri aşağıdaki gibidir;

Bütün modellerde sırası ile RMSprop (0,001), RMSprop (2e-5), Adam (0,001) ve Adam (2e-5) kullanılmıştır.

5.3. Ham Veri Setinde (VS-1) Yapılan Test Sonuçları

178 adet x-ray görüntünün bulunduğu veri setimizin detaylı bilgileri şu şekildedir. Eğitim 108 (kırık:65, sağlam:43), doğrulama 30 (kırık:20, sağlam:10), test için ise 40 (kırık:20, sağlam:20) adet x-ray görüntümüz bulunmaktadır.
Modellerimizi denerken ise optimizer olarak "Adam" ve "RMSprop" kullanılmıştır. Optimizerlere "0,001" ve "2e-5" değerleri girilerek ayrı ayrı test edilmiştir. Metrik değeri olarak "metrics = ['accuracy'])" kullanılmıştır.
Bu veri setimizde;
Aşağıda VS-1 DenseNet201 KM görseli (Şekil 5.2) ve VS-1 DenseNet201 sonuç tablosu (Çizelge 5.1) verilmiştir.



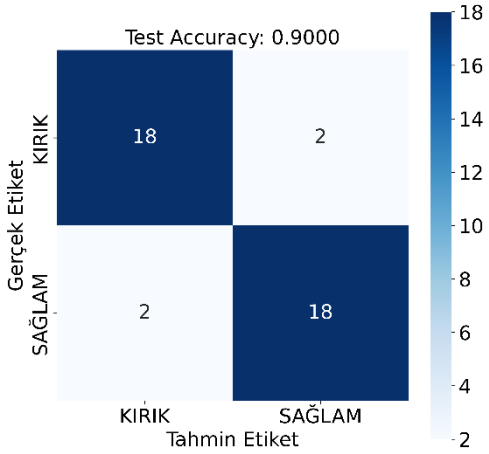
DenseNet201 (optimizer = Adam(2e-5)) ile kırık verilerde %90, sağlam verilerde %80 başarı elde edilmiştir. F1-Score: 0,8500.

Şekil 5.2 VS-1 DenseNet201 KM görseli

Çizelge 5.1 VS-1 DenseNet201 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,8182	0,9000	0,8571
SAĞLAM	0,8889	0,8000	0,8421

Aşağıda VS-1 Xception KM görseli (Şekil 5.3) ve VS-1 Xception sonuç tablosu (Çizelge 5.2) verilmiştir.



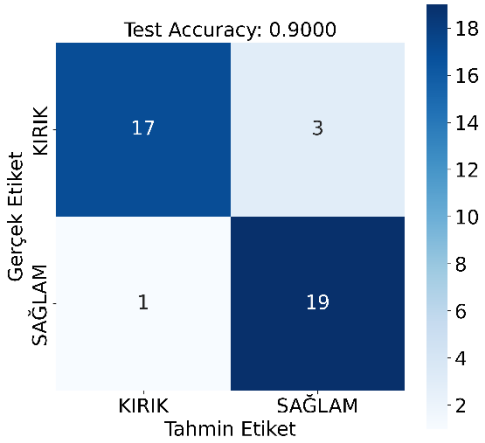
Xception (optimizer = RMSprop(2e-5)) ile ile kırık verilerde %90, sağlam verilerde %90 başarı elde edilmiştir. F1-Score: 0,9000.

Şekil 5.3 VS-1 Xception KM görseli

Çizelge 5.2 VS-1 Xception sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,9000	0,9000	0,9000
SAĞLAM	0,9000	0,9000	0,9000

Aşağıda ResNet152V2 KM görseli (Şekil 5.4) ve VS-1 ResNet152V2 sonuç tablosu (Çizelge 5.3) verilmiştir.



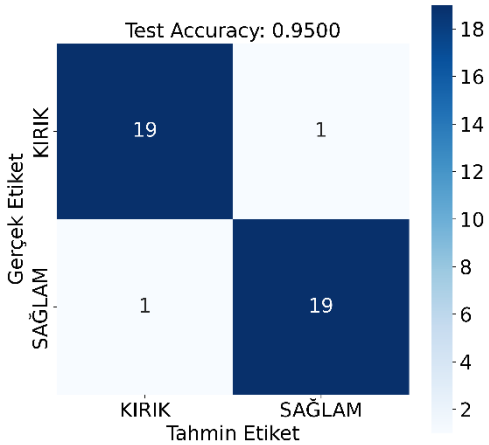
ResNet152V2 (optimizer = RMSprop(2e-5)) ile kırık verilerde %85, sağlam verilerde %95 başarı elde edilmiştir. F1-Score: 0,9000.

Şekil 5.4 VS-1 ResNet152V2 KM görseli

Çizelge 5.3 VS-1 ResNet152V2 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0.9444	0.8500	0.8947
SAĞLAM	0.8636	0.9500	0.9048

Aşağıda VS-1 InceptionResNetV2 KM görseli (Şekil 5.5) ve VS-1 InceptionResNetV2 sonuç tablosu (Çizelge 5.4) verilmiştir.



InceptionResNetV2 (optimizer = Adam(0,001)) ile kırık verilerde %95, sağlam verilerde %95 başarı elde edilmiştir. F1-Score: 0,9500.

Şekil 5.5 VS-1 InceptionResNetV2 KM görseli

Çizelge 5.4 VS-1 InceptionResNetV2 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,9500	0,9500	0,9500
SAĞLAM	0,9500	0,9500	0,9500

5.4. Ham Veri Setine CLAHE Filtresi Uygulanarak Elde Edilen Veri Setinde (VS-2) Yapılan Test Sonuçları

178 adet x-ray görüntüsünün bulunduğu veri setimize görüntü işleme tekniklerinden CLAHE filtresi uygulayarak eğitim ve test işlemlerimizi yapacağız. Varsayılan filtre parametresi olarak aşağıdaki değerleri uyguladık.

```
clahe = cv2.createCLAHE(clipLimit=2.0, tileGridSize=(8,8))
```

Aşağıda normal x-ray (Şekil 5.6) ve CLAHE filtresi uygulanmış x-ray (Şekil 5.7) röntgenini görebilirsiniz.

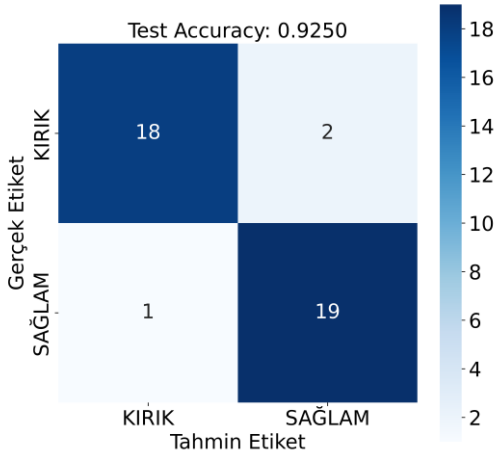


Şekil 5.6 Normal x-ray



Şekil 5.7 CLAHE uygulanmış x-ray

Aşağıda VS-2 DenseNet201 KM görseli (Şekil 5.8) ve VS-2 DenseNet201 sonuç tablosu (Çizelge 5.5) verilmiştir.



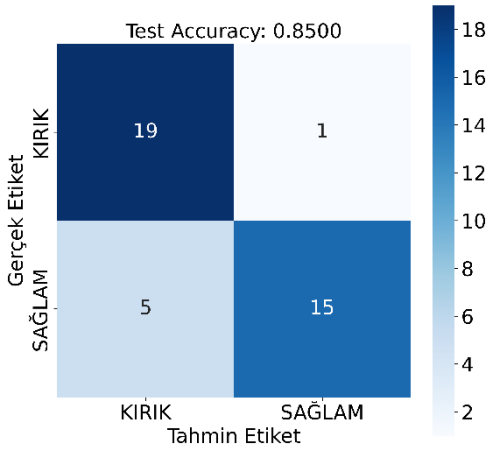
DenseNet201 (optimizer = Adam(0,001)) ile kırık verilerde %90, sağlam verilerde %95 başarı elde edilmiştir. F1-Score: 0,9250.

Şekil 5.8 VS-2 DenseNet201 KM görseli

Çizelge 5.5 VS-2 DenseNet201 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,9474	0,9000	0,9231
SAĞLAM	0,9048	0,9500	0,9268

Aşağıda VS-2 Xception KM görseli (Şekil 5.9) ve VS-2 Xception sonuç tablosu (Çizelge 5.6) verilmiştir.



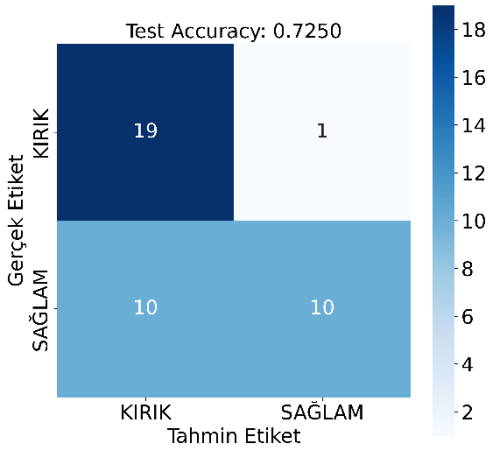
Xception (optimizer = RMSprop(0,001)) ile kırık verilerde %95, sağlam verilerde %75 başarı elde edilmiştir. F1-Score: 0,8500.

Şekil 5.9 VS-2 Xception KM görseli

Çizelge 5.6 VS-2 Xception sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,7917	0,9500	0,8636
SAĞLAM	0,9375	0,7500	0,8333

Aşağıda VS-2 ResNet152V2 KM görseli (Şekil 5.19) ve VS-2 ResNet152V2 sonuç tablosu (Çizelge 5.7) verilmiştir.



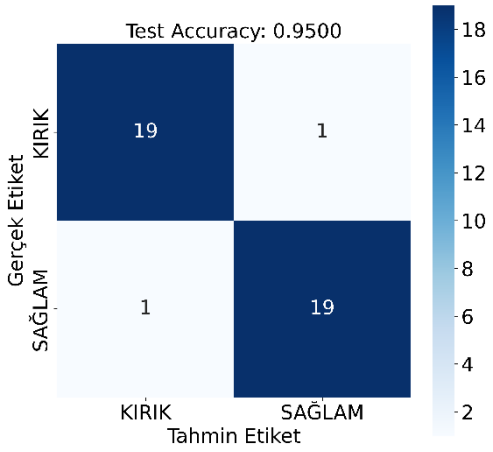
ResNet152V2 (optimizer = Adam(2e-5)) ile kırık verilerde %95, sağlam verilerde %50 başarı elde edilmiştir. F1-Score: 0,7250.

Şekil 5.10 VS-2 ResNet152V2 KM görseli

Çizelge 5.7 VS-2 ResNet152V2 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,6552	0,9500	0,7755
SAĞLAM	0,9091	0,5000	0,6452

Aşağıda VS-2 InceptionResNetV2 KM görseli (Şekil 5.11) ve VS-2 InceptionResNetV2 sonuç tablosu (Çizelge 5.8) verilmiştir.



InceptionResNetV2 (optimizer = Adam(0.001)) ile kırık verilerde %95, sağlam verilerde %95 başarı elde edilmiştir. F1-Score: 0,9500.

Şekil 5.51 VS-2 InceptionResNetV2 KM

Çizelge 5.8 VS-2 InceptionResNetV2 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,9500	0,9500	0,9500
SAĞLAM	0,9500	0,9500	0,9500

5.5. Ham Veri Setine Simetrileri Eklenerek Elde Edilen Veri Setinde (VS-3) Yapılan Test Sonuçları

178 adet x-ray görüntünün bulunduğu ham veri setimize başarı durumunu iyileştirmek için simetri görüntüler ekleyerek görüntü artırımına gidilmiştir. Son durumda 316 adet x-ray görüntünün bulunduğu veri setimizin detaylı bilgileri şu şekildedir. . Eğitim 216 (kırık:130, sağlam:86), doğrulama 60 (kırık:40, sağlam:20), test için ise 40 (kırık:20, sağlam:20) adet x-ray görüntümüz bulunmaktadır.

Aşağıda normal x-ray (Şekil 5.12) ve simetrisi oluşturulmuş x-ray (Şekil 5.13) röntgenini görebilirsiniz.

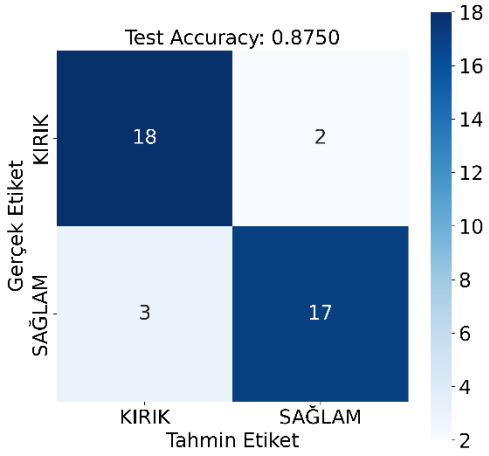


Şekil 5.12 Normal x-ray görüntüsü



Şekil 5.63 Simetrisi oluşturulmuş x-ray

Aşağıda VS-3 DenseNet201 KM görseli (Şekil 5.14) ve VS-3 DenseNet201 sonuç tablosu (Çizelge 5.9) verilmiştir.



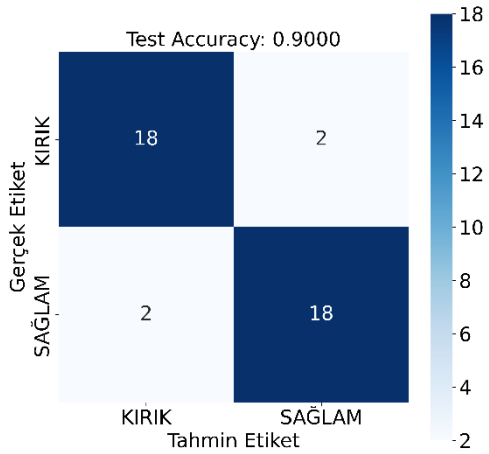
DenseNet201 (optimizer = Adam(0,001))ile kırık verilerde %90, sağlam verilerde %85 başarı elde edilmiştir. F1-Score: 0,8750.

Şekil 5.7 VS-3 DenseNet201 KM görseli

Çizelge 5.9 VS-3 DenseNet201 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,8571	0,9000	0,8780
SAĞLAM	0,8947	0,8500	0,8718

Aşağıda VS-3 Xception KM görseli (Şekil 5.15) ve VS-3 Xception sonuç tablosu (Çizelge 5.10) verilmiştir.



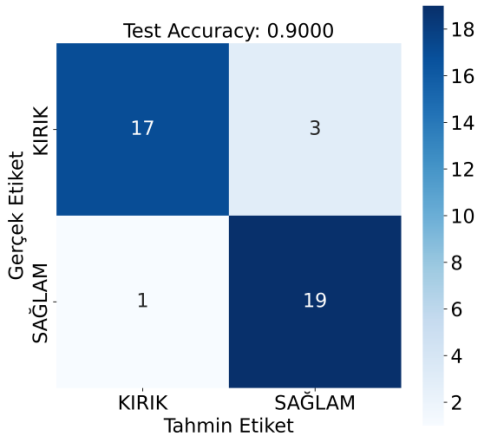
Xception (optimizer = RMSprop(2e-5)) ile ile kırık verilerde %90, sağlam verilerde %90 başarı elde edilmiştir. F1-Score: 0,9000.

Şekil 5.8 VS-3 Xception KM görseli

Çizelge 5.10 VS-3 Xception sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,9000	0,9000	0,9000
SAĞLAM	0,9000	0,9000	0,9000

Aşağıda VS-3 ResNet152V2 KM görseli (Şekil 5.16) ve VS-3 ResNet152V2 sonuç tablosu (Çizelge 5.11) verilmiştir.



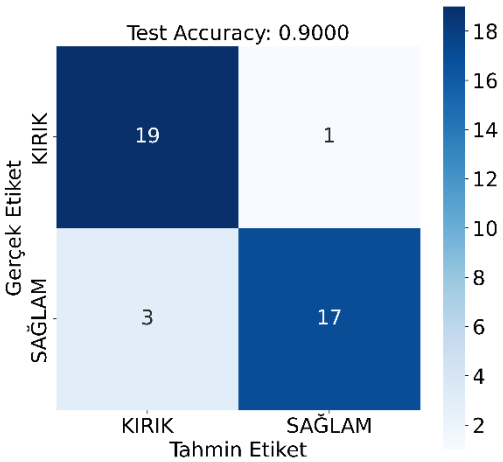
ResNet152V2 (optimizer = RMSprop(2e-5)) ile kırık verilerde %85, sağlam verilerde %95 başarı elde edilmiştir. F1-Score: 0,9000.

Şekil 5.16 VS-3 ResNet152V2 KM görseli

Çizelge 5.81 VS-3 ResNet152V2 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,9444	0,8500	0,8947
SAĞLAM	0,8636	0,9500	0,9048

Aşağıda VS-3 InceptionResNetV2 KM görseli (Şekil 5.17) ve VS-3 InceptionResNetV2 sonuç tablosu (Çizelge 5.12) verilmiştir.



InceptionResNetV2 (optimizer = Adam(0,001)) ile kırık verilerde %95, sağlam verilerde %85 başarı elde edilmiştir. F1-Score: 0,9000.

Şekil 5.97 VS-3 InceptionResNetV2 KM

Çizelge 5.12 VS-3 InceptionResNetV2 sonuç tablosu

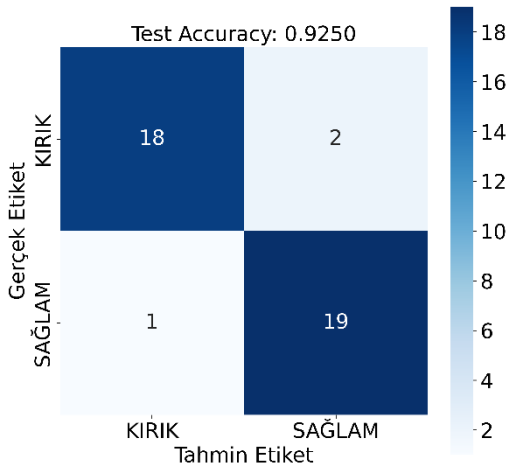
SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,8636	0,9500	0,9048
SAĞLAM	0,9444	0,8500	0,8947

5.6. Simetrileri Eklenerek Elde Edilen Veri Setine CLAHE Filtresi Uygulanarak Elde Edilen Veri Setinde (VS-4) Yapılan Test Sonuçları

Son olarak 316 adet x-ray görüntümüzün bulunduğu veri setimize görüntü işleme tekniklerinden CLAHE filtresi uygulayarak eğitim ve test işlemlerimizi yapacağız. Varsayılan fltre parametresi olarak aşağıdaki değerleri uyguladık.

```
clahe = cv2.createCLAHE(clipLimit=2.0, tileGridSize=(8,8))
```

Bu veri setimizde;
Aşağıda VS-4 DenseNet201 KM görseli (Şekil 5.18) ve VS-4 DenseNet201 sonuç tablosu (Çizelge 5.13) verilmiştir.



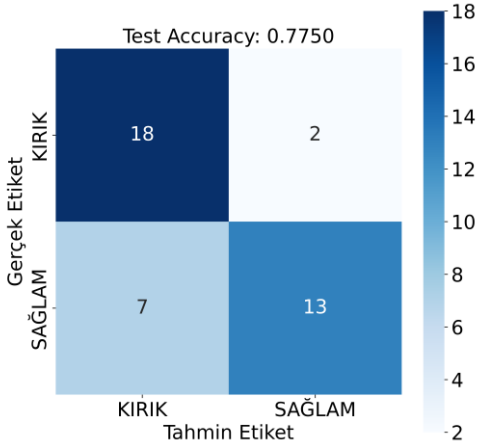
DenseNet201 (optimizer = Adam(0.001)) ve (optimizer = Adam(2e-5)) ile sonuçlar aynı çıkmıştır. Kırık verilerde %90, sağlam verilerde %95 başarı elde edilmiştir. F1-Score: 0,9250.

Şekil 5.108 VS-4 DenseNet201 KM görseli

Çizelge 5.13 VS-4 DenseNet201 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,9474	0,9000	0,9231
SAĞLAM	0,9048	0,9500	0,9268

Aşağıda VS-4 Xception KM görseli (Şekil 5.19) ve VS-4 Xception sonuç tablosu (Çizelge 5.14) verilmiştir.



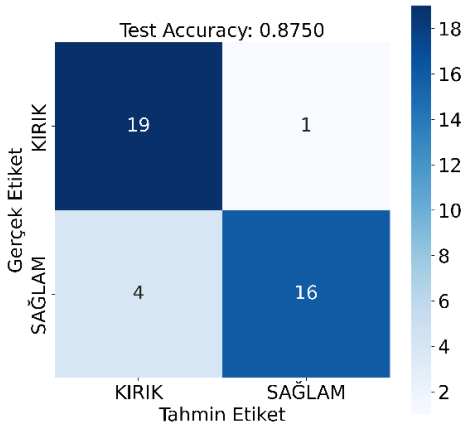
Xception (optimizer = RMSprop(2e-5)) ile kırık verilerde %90, sağlam verilerde %65 başarı elde edilmiştir. F1-Score: 0,7750.

Şekil 5.119 VS-4 Xception KM görseli

Çizelge 5.14 VS-4 Xception sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,7200	0,9000	0,8000
SAĞLAM	0,8667	0,6500	0,7429

Aşağıda VS-4 Xception KM görseli – 2 (Şekil 5.20) ve VS-4 Xception sonuç tablosu – 2 (Çizelge 5.15) verilmiştir.



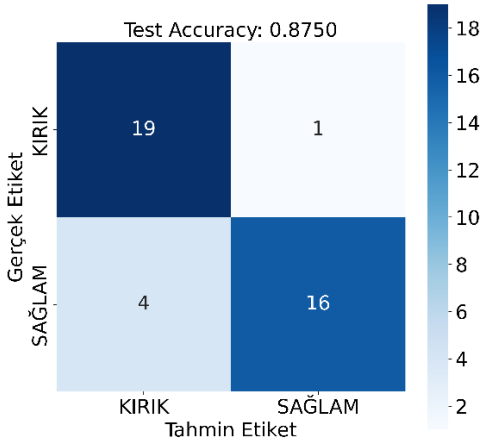
Xception (optimizer = Adam(2e-5)) ile kırık verilerde %95, sağlam verilerde %60 başarı elde edilmiştir. F1-Score: 0,8750.

Şekil 5.20 VS-4 Xception KM görseli - 2

Çizelge 5.15 VS-4 Xception sonuç tablosu - 2

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,7037	0,9500	0,8085
SAĞLAM	0,9231	0,6000	0,7273

Aşağıda VS-4 ResNet152V2 KM görseli (Şekil 5.21) ve VS-4 ResNet152V sonuç tablosu (Çizelge 5.16) verilmiştir.



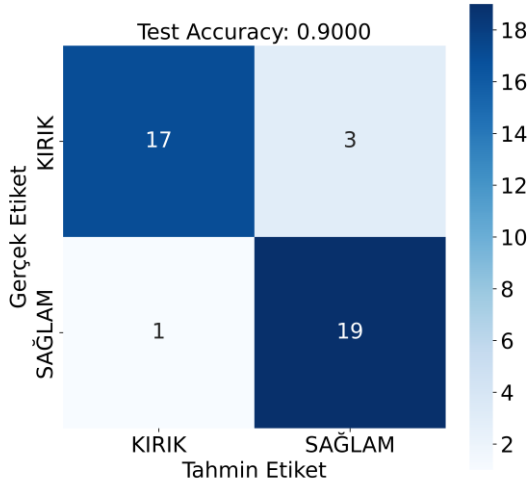
ResNet152V2 (optimizer = RMSprop(2e-5)) ile kırık verilerde %95, sağlam verilerde %80 başarı elde edilmiştir. F1-Score: 0,8750.

Şekil 5.121 VS-4 ResNet152V2 KM görseli

Çizelge 5.16 VS-4 ResNet152V sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,8261	0,9500	0,8837
SAĞLAM	0,9412	0,8000	0,8649

Aşağıda VS-4 InceptionResNetV2 KM görseli (Şekil 5.22) ve VS-4 InceptionResNetV2 sonuç tablosu (Çizelge 5.17) verilmiştir.



InceptionResNetV2 (Adam = Adam(2e-5)) ile kırık verilerde %85, sağlam verilerde %95 başarı elde edilmiştir. F1-Score: 0,9000.

Şekil 5.132 VS-4 InceptionResNetV2 KM görseli

Çizelge 5.17 VS-4 InceptionResNetV2 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,9444	0,8500	0,8947
SAĞLAM	0,8636	0,9500	0,9048

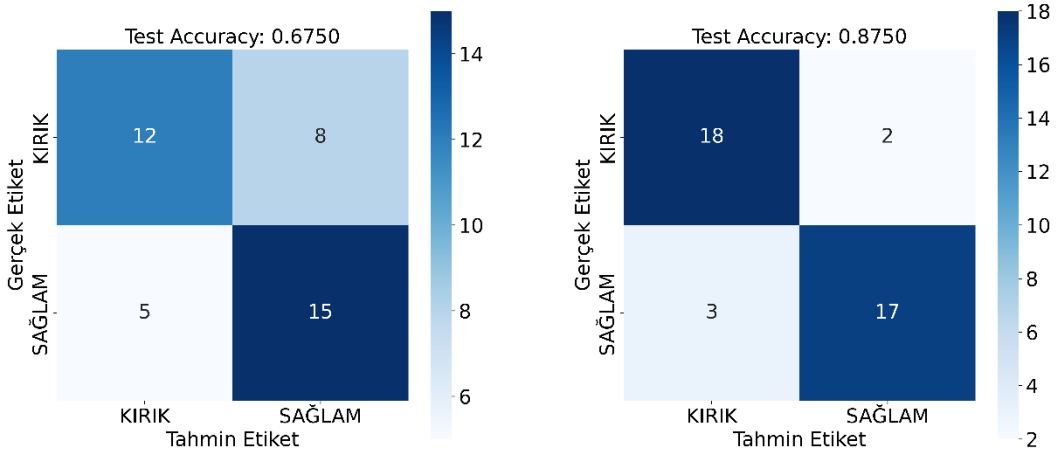
5.7. Veri Setlerinin Başarı Kıyaslamaları

Kullanmış olduğumuz dört ayrı veri setlinin başarı kıyaslamalarını aşağıda listeledik.

5.7.1. VS-1 ile VS-3'ün aynı modeldeki başarı kıyaslamaları

VS-1 ile VS-3'ün aynı modeldeki başarı kıyaslamaları aşağıdaki gibidir.

Aşağıda VS-1 ve VS-3 DenseNet201 (optimizer = Adam(0,001)) KM görseli (Şekil 5.23) ve VS-1 DenseNet201 sonuç tablosu (Çizelge 5.18) ve VS-3 DenseNet201 sonuç tablosu (Çizelge 5.19) verilmiştir.



Şekil 5.143 VS-1 ve VS-3 DenseNet201 (optimizer = Adam(0,001)) KM görseli

Çizelge 5.18 VS-1 DenseNet201 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,7059	0,6000	0,6486
SAĞLAM	0,6522	0,7500	0,6977

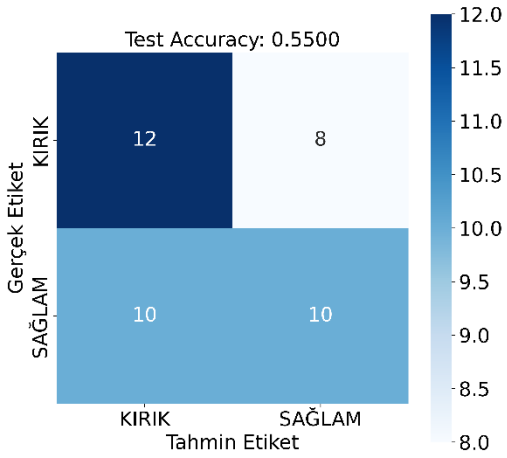
Çizelge 5.19 VS-3 DenseNet201 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,8571	0,9000	0,8780
SAĞLAM	0,8947	0,8500	0,8718

DenseNet201; VS-1'de yapılan testlerde kırık verilerde %60, sağlam verilerde %75 (F1-Score: 0,6750) başarı elde edilmiştir. VS-3'de yapılan testlerde kırık verilerde %90, sağlam verilerde %85 (F1-Score: 0,8750) başarı elde edilmiştir. Bu modelde veri artırımı yapıldığında başarının arttığı görülmüştür.

Aşağıda VS-1 ve VS-3 ResNet152V2 (optimizer = RMSprop(0.001)) KM görseli (Şekil 5.24) ve VS-3 ResNet152V2 sonuç tablosu (Çizelge 5.20) verilmiştir.

VS-1'de aşırı uydurma olmuştur.



Şekil 5.154 VS-1 ve VS-3 ResNet152V2 (optimizer = RMSprop(0,001)) KM görseli

Çizelge 5.20 VS-3 ResNet152V2 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,5455	0,6000	0,5714
SAĞLAM	0,5556	0,5000	0,5263

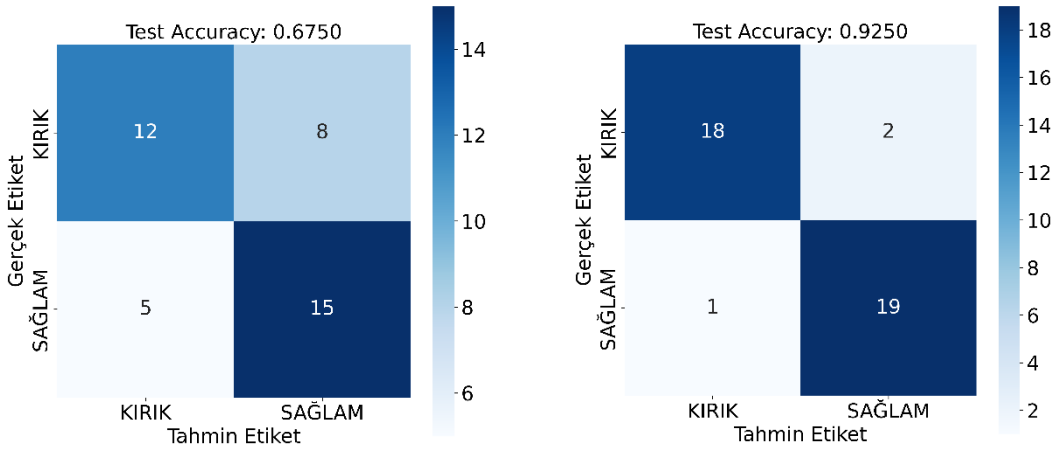
ResNet152V2; VS-1'de aşırı uydurma gerçekleşmiştir, VS-3'de yapılan testlerde kırık verilerde %60, sağlam verilerde %50 (F1-Score: 0,5500) başarı elde edilmiştir. Bu modelde veri artırımı yapıldığında başarının arttığı görülmüştür.

Veri setimizde veriyi artırdığımızda başarının da arttığı görülmüştür.

5.7.2. VS-1 ile VS-2'nin aynı modeldeki başarı kıyaslamaları

VS-1 ile VS-2'nin başarı kıyaslamaları aşağıdaki gibidir.

Aşağıda VS-1 ve VS-2 DenseNet201 (optimizer = Adam(0,001)) KM görseli (Şekil 5.25) ve VS-1 DenseNet201 sonuç tablosu (Çizelge 5.21) ve VS-2 DenseNet201 sonuç tablosu (Çizelge 5.22) verilmiştir.



Şekil 5.165 VS-1 ve VS-2 DenseNet201 (optimizer = Adam(0,001)) KM görseli

Çizelge 5.210 VS-1 DenseNet201 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,7059	0,6000	0,6486
SAĞLAM	0,6522	0,7500	0,6977

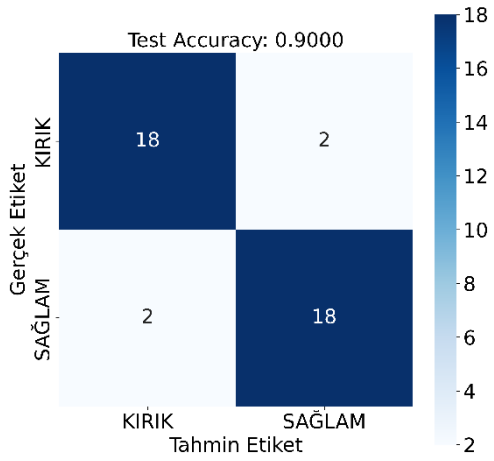
Çizelge 5.22 VS-2 DenseNet201 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,9474	0,9000	0,9231
SAĞLAM	0,9048	0,9500	0,9268

DenseNet201; VS-1'de yapılan testlerde kırık verilerde %60, sağlam verilerde %75 (F1-Score: 0,6750) başarı elde edilmiştir. VS-2'de yapılan testlerde kırık verilerde %90, sağlam verilerde %95 (F1-Score: 0,9250) başarı elde edilmiştir. Bu modelde CLAHE filtresi uygulandığında başarının arttığı görülmüştür.

Aşağıda VS-1 ve VS-2 Xception (optimizer = RMSprop(0.001)) KM görseli (Şekil 5.26) ve VS-2 Xception sonuç tablosu (Çizelge 5.23) verilmiştir.

VS-1'de aşırı uydurma olmuştur.



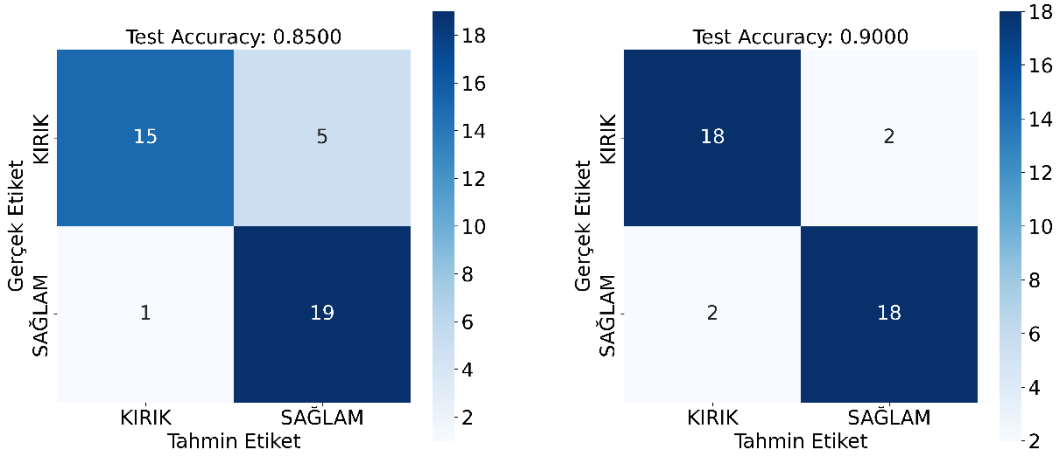
Şekil 5.176 VS-1 ve VS-2 Xception (optimizer = RMSprop(0,001)) KM görseli

Çizelge 5.23 VS-2 Xception sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,7917	0,9500	0,8636
SAĞLAM	0,9375	0,7500	0,8333

Xception; VS-1'de aşırı uydurma olmuştur. VS-2'de yapılan testlerde kırık verilerde %95, sağlam verilerde %75 (F1-Score: 0,9000) başarı elde edilmiştir. Bu modelde CLAHE filtresi uygulandığında başarının arttığı görülmüştür.

Aşağıda VS-1 ve VS-2 InceptionResNetV2 (optimizer = RMSprop(2e-5)) KM görseli (Çizelge 5.27) ve VS-1 InceptionResNetV2 sonuç tablosu (Çizelge 5.24) ve VS-2 InceptionResNetV2 sonuç tablosu (Çizelge 5.25) verilmiştir.



Şekil 5.187 VS-1 ve VS-2 InceptionResNetV2 (optimizer = RMSprop(2e-5)) KM

Çizelge 5.11 VS-1 InceptionResNetV2 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,9375	0,7500	0,8333
SAĞLAM	0,7917	0,9500	0,8636

Çizelge 5.12 VS-2 InceptionResNetV2 sonuç tablosu

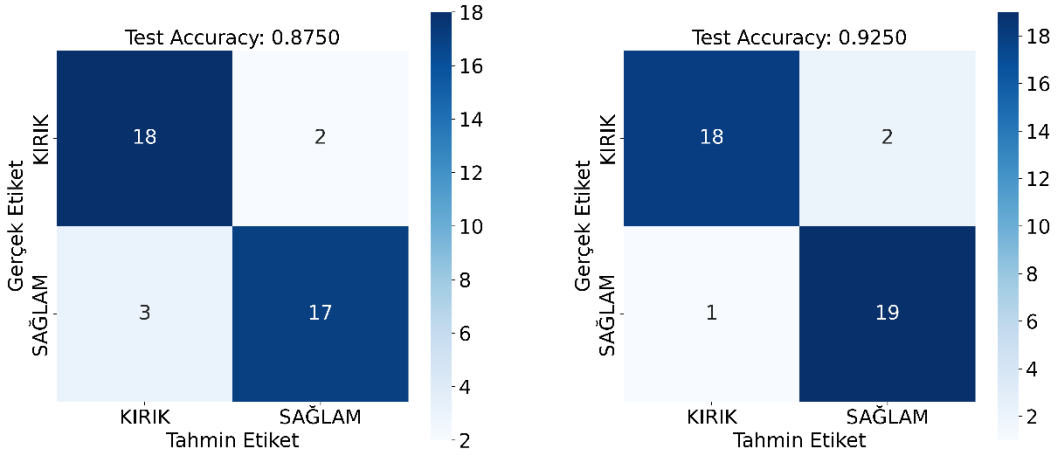
SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,9000	0,9000	0,9000
SAĞLAM	0,9000	0,9000	0,9000

InceptionResNetV2; VS-1'de yapılan testlerde kırık verilerde %75, sağlam verilerde %95 (F1-Score: 0,8500) başarı elde edilmiştir. VS-2'de yapılan testlerde kırık verilerde %90, sağlam verilerde %90 (F1-Score: 0,9000) başarı elde edilmiştir. Bu modelde CLAHE filtresi uygulandığında başarının arttığı görülmüştür.

5.7.3. VS-3 ile VS-4'ün aynı modeldeki başarı kıyaslaması

VS-3 ile VS-4'ün aynı modeldeki başarı kıyaslaması aşağıdaki gibidir.

Aşağıda VS-3 ve VS-4 DenseNet201 (optimizer = Adam(0,001)) KM görseli (Şekil 5.28) ve VS-3 DenseNet201 sonuç tablosu (Çizelge 5.26) ve VS-4 DenseNet201 sonuç tablosu (Çizelge 5.27) verilmiştir.



Şekil 5.198 VS-3 ve VS-4 DenseNet201 (optimizer = Adam(0,001)) KM görseli

Çizelge 5.13 VS-3 DenseNet201 sonuç tablosu

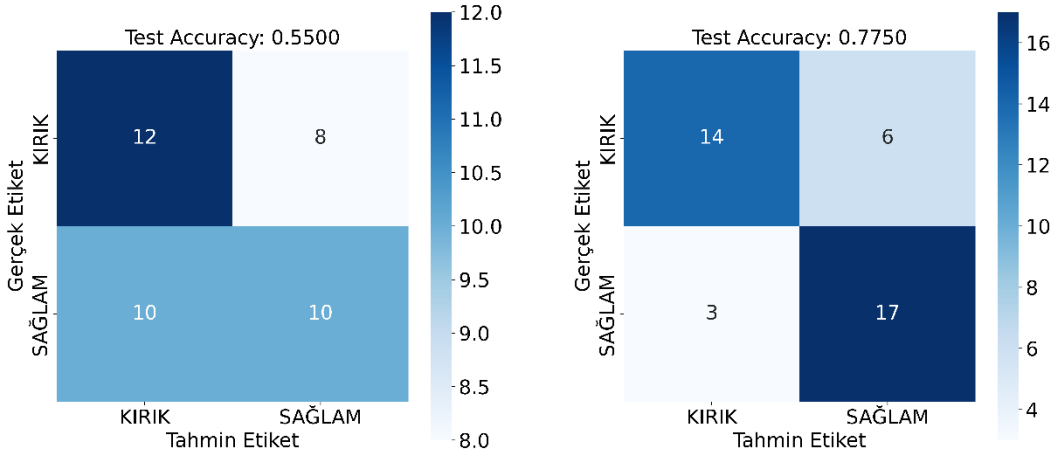
SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,8571	0,9000	0,8780
SAĞLAM	0,8947	0,8500	0,8718

Çizelge 5.14 VS-4 DenseNet201 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,9474	0,9000	0,9231
SAĞLAM	0,9048	0,9500	0,9268

DenseNet201; VS-3'de yapılan testlerde kırık verilerde %90, sağlam verilerde %85 (F1-Score: 0,8750) başarı elde edilmiştir. VS-4'te yapılan testlerde kırık verilerde %90, sağlam verilerde %95 (F1-Score: 0,9250) başarı elde edilmiştir. Bu modelde CLAHE filtresi uygulanan veri setinde başarının arttığı görülmüştür.

Aşağıda VS-3 ve VS-4 ResNet152V2 (optimizer = RMSprop(0,001)) KM görseli (Şekil 5.29) ve VS-3 ResNet152V2 sonuç tablosu (Çizelge 5.28) ve VS-4 ResNet152V2 sonuç tablosu (Çizelge 5.29) verilmiştir.



Şekil 5.209 VS-3 ve VS-4 ResNet152V2 (optimizer = RMSprop(0,001)) KM görseli

Çizelge 5.28 VS-3 ResNet152V2 sonuç tablosu

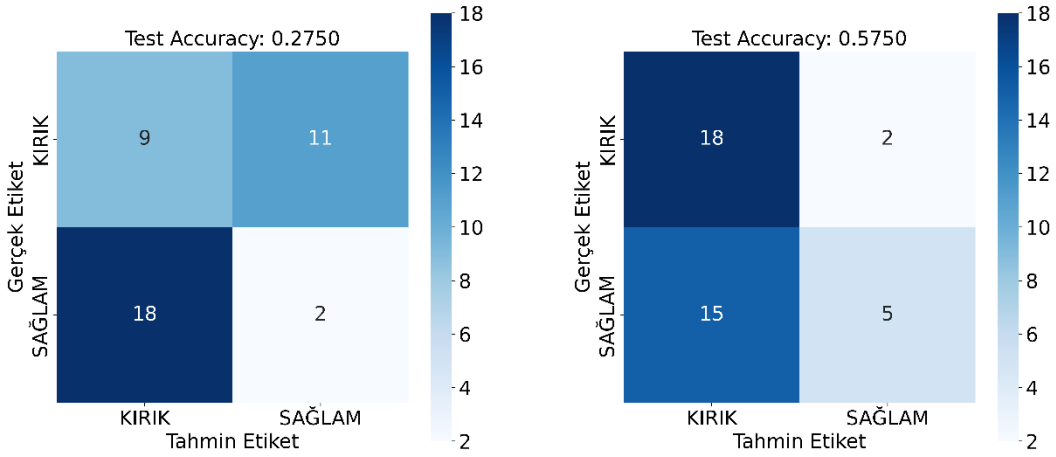
SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,5455	0,6000	0,5714
SAĞLAM	0,5556	0,5000	0,5263

Çizelge 5.29 VS-4 ResNet152V2 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,8235	0,7000	0,7568
SAĞLAM	0,7391	0,8500	0,7907

ResNet152V2; VS-3'de yapılan testlerde kırık verilerde %60, sağlam verilerde %50 (F1-Score: 0,5500) başarı elde edilmiştir. VS-4'te yapılan testlerde kırık verilerde %70, sağlam verilerde %85 (F1-Score: 0,7750) başarı elde edilmiştir. Bu modelde CLAHE filtresi uygulanan veri setinde başarının arttığı görülmüştür.

Aşağıda VS-3 ve VS-4 InceptionResNetV2 (optimizer = RMSprop(0,001)) KM görseli (Şekil 5.30) ve VS-3 InceptionResNetV2 sonuç tablosu (Çizelge 5.30) ve VS-4 InceptionResNetV2 sonuç tablosu (Çizelge 5.31) verilmiştir.



Şekil 5.30 VS-3 ve VS-4 InceptionResNetV2 (optimizer = RMSprop(0,001)) KM

Çizelge 5.30 VS-3 InceptionResNetV2 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,3333	0,4500	0,3830
SAĞLAM	0,1538	0,1000	0,1212

Çizelge 5.31 VS-4 InceptionResNetV2 sonuç tablosu

SINIF	PRECISION	RECALL	F1-SCORE
KIRIK	0,5455	0,9000	0,6792
SAĞLAM	0,7143	0,2500	0,3704

InceptionResNetV2;VS-3'de yapılan testlerde kırık verilerde %45, sağlam verilerde %10 (F1-Score: 0,2750) başarı elde edilmiştir. VS-4'te yapılan testlerde kırık verilerde %90, sağlam verilerde %25 (F1-Score: 0,5750) başarı elde edilmiştir. Bu modelde CLAHE filtresi uygulanmış veri setinde başarının arttığı görülmüştür.

Yaptığımız derin öğrenme tez çalışmamızda görüntü işleme yöntemlerinden CLAHE filtresi uygulandığında başarı oranın düşük olduğu bazı modellerde başarı oranının arttığı tespit edilmiştir.

6. SONUÇ

Tez çalışmamızda 4 ayrı veri seti üzerinde çalışmalar yaptık. Her veri setimiz öğrenme aktarma modellerinden sırası ile DenseNet201, Xception, ResNet152V2 ve InceptionResNetV2 modelleri ile eğitilmiştir. Her model 4 ayrı optimizer değeri ile eğitildi. Sırası ile kullandığımız optimizer değerleri; RMSprop: 0,001, RMSprop: 2e-5, Adam: 0,001 ve Adam: 2e-5 olarak bu şekildedir.

VS-1'de eğitim için 108 (Kırık: 65, Sağlam: 43) adet x-ray görüntüsü, doğrulama için 30 (Kırık: 20, Sağlam: 10) adet x-ray görüntüsü ve test için 40 (Kırık: 20, Sağlam: 20) adet, toplamda 178 adet x-ray görüntüsü kullandık.

Bu veri setimizde en başarılı model F1-Score: 0,9500 ile InceptionResNetV2 (optimizer = Adam(2e-5)) kırık verilerde %95, sağlam verilerde %95 başarı elde edilmiştir. Diğer modellerin sonuçları da aşağıda belirtilmiştir;

DenseNet201 (optimizer = Adam(2e-5)) ile kırık verilerde %90, sağlam verilerde %80 başarı elde edilmiştir (F1-Score: 0,8500).

Xception (optimizer = RMSprop(2e-5)) ile ile kırık verilerde %90, sağlam verilerde %90 başarı elde edilmiştir (F1-Score: 0,9000).

ResNet152V2 (optimizer = RMSprop(2e-5)) ile kırık verilerde %85, sağlam verilerde %95 başarı elde edilmiştir (F1-Score: 0,9000).

VS-2'de eğitim için 108 (Kırık: 65, Sağlam: 43) adet x-ray görüntüsü, doğrulama için 30 (Kırık: 20, Sağlam: 10) adet x-ray görüntüsü ve test için 40 (Kırık: 20, Sağlam: 20) adet, toplamda 178 adet CLAHE filtresi uygulanmış x-ray görüntüsü kullandık.

Bu veri setimizde en başarılı model F1-Score: 0,9500 ile InceptionResNetV2 (optimizer = Adam(2e-5)) kırık verilerde %95, sağlam verilerde %95 başarı elde edilmiştir. Diğer modellerin sonuçları da aşağıda belirtilmiştir;

DenseNet201 (optimizer = Adam(0,001)) ile kırık verilerde %90, sağlam verilerde %95 başarı elde edilmiştir (F1-Score: 0,9250).

Xception (optimizer = RMSprop(0,001)) ile ile kırık verilerde %95, sağlam verilerde %75 başarı elde edilmiştir (F1-Score: 0,8500).

ResNet152V2 (optimizer = Adam(2e-5)) ile kırık verilerde %95, sağlam verilerde %50 başarı elde edilmiştir (F1-Score: 0,7250).

VS-3'de x-ray görüntülerin simetrilerini ekleyerek veri artırımına gidilmiştir. Bu veri setimizde eğitim için 216 (Kırık: 130, Sağlam: 86) adet x-ray görüntüsü, doğruma için 60 (Kırık: 40, Sağlam: 20) adet z-ray görüntüsü ve test için 40 (Kırık: 20, Sağlam: 20) adet, toplamda 316 adet x-ray görüntüsü kullandık.

Bu veri setimizde en başarılı modeller F1-Score: 0,9000 ile Xception (optimizer = RMSprop(2e-5)) ile kırık verilerde %90, sağlam verilerde %90 ve diğer model ise InceptionResNetV2 (optimizer = Adam(0,001)) ile kırık verilerde %95, sağlam verilerde %85 başarı elde edilmiştir. Diğer modellerin sonuçları da aşağıda belirtilmiştir;

DenseNet201 (optimizer = Adam(0,001))ile kırık verilerde %90, sağlam verilerde %85 başarı elde edilmiştir (F1-Score: 0,8750).

ResNet152V2 (optimizer = Adam(2e-5)) ile kırık verilerde %95, sağlam verilerde %80 başarı elde edilmiştir (F1-Score: 0,8750).

VS-4'te eğitim için 216 (Kırık: 130, Sağlam: 86) adet x-ray görüntüsü, doğruma için 60 (Kırık: 40, Sağlam: 20) adet x-ray görüntüsü ve test için 40 (Kırık: 20, Sağlam: 20) adet, toplamda 316 adet CLAHE filtresi uygulanmış x-ray görüntüsü kullandık.

Bu veri setimizde en başarılı model F1-Score: 0,9250 ile DenseNet201 (optimizer = Adam(0.001)) ve (optimizer = Adam(2e-5)) ile sonuçlar aynı çıkmıştır. Kırık verilerde %90, sağlam verilerde %95 başarı elde edilmiştir. Diğer modellerin sonuçları da aşağıda belirtilmiştir;

ResNet152V (optimizer = RMSprop(2e-5)) ile kırık verilerde %95, sağlam verilerde %80 başarı elde edilmiştir (F1-Score: 0,8750).

InceptionResNetV2 (optimizer = Adam(0.001)) ile kırık verilerde %95, sağlam verilerde %60 başarı elde edilmiştir (F1-Score: 0,7750).

Aynı modelde aldıkları F1-Score'ları da inceleyip kıyas edersek;

DenseNet201 (optimizer = Adam(0,001)) modelinde VS-1'de F1-Score 0,6750 iken VS-3'te F1-Score 0,8750, VS-2 ve VS-4'te ise F1-Score 0,9250 ye yükselmiştir.

Xception (optimizer = RMSprop(0,001) modelinde VS-2'de F1-Score 0,8500 olmuştur. Diğer modellerde aşırı uydurma olmuştur.

ResNet152V2 (optimizer = RMSprop(0,001)) modelinde VS-1 ve VS-2'de aşırı uydurmaya geçmiştir. VS-3'te F1-Score 0,5500, VS-4'te ise F1-Score 0,7750 ye yükselmiştir.

InceptionResNetV2 (optimizer = RMSprop(0,001)) modelinde VS-3'te F1-Score 0,2750 iken VS-4'te ise F1-Score 0,5750 ye yükselmiştir.

Genel olarak baktığımızda veri seti artırıldığında ve görüntü işleme yöntemlerinden CLAHE filtresi uygulandığında başarısı düşük olan modellerde başarı oranları artmaktadır. Test için kullandığımız veri setimiz daha büyük olabilseydi test sonuçlarını daha net bir şekilde alabilirdik.

Kırık değerlendirmesi ve tedavisinde özellikle tanı amaçlı olarak yapay zeka uygulamaları faydalı olabilmektedir. Tez çalışmamız kapsamında geliştirdiğimiz 'Yapay Zeka Modeli' ile proksimal femur kırıklarına otomatik olarak ve güvenilir bir tanı konulabilmesi, ayrıca hekimlere destek sağlayacak bu teknoloji ile maliyet ve zaman kazancı elde edilebilmesi sağlanmaktadır. Şu anda devam eden çalışmalarımızda daha fazla veri ile hatasız ve mükemmel sonuçlar elde etmek için çalışmaktayız. Ayrıca daha güçlü bilgisayarlar ile modelin eğitim süresi kısaltılabilir. Bu çalışmada edindiğimiz bilgiler doğrultusunda kompleks kırıklarda ve tanısı zor olgularda tanı ve karar desteği sağlayıcı modeller geliştirmeyi amaçlamaktayız.

Bu çalışmamızda yeterli miktarda veri olduğunda ve görüntü işleme teknikleri ile desteklendiğinde proksimal femur kırıklarının optimize tespiti için kullanılabilir ve ayrıca klinisyenlerin çalışmalarını kolaylaştırabilir olduğunu gördük.

KAYNAKLAR

Adams, M., Chen, W., Holcdorf, D., McCusker, M. W., Howe, P. D. L., & Gaillard, F. 2019. Computer vs human: Deep learning versus perceptual training for the detection of neck of femur fractures. Journal of Medical Imaging and Radiation Oncology, 63(1), 27–32. https://doi.org/10.1111/1754-9485.12828

Alruwaili, M., Shehab, A., & Abd El-Ghany, S. (2021). COVID-19 Diagnosis Using an Enhanced Inception-ResNetV2 Deep Learning Model in CXR Images. Journal of Healthcare Engineering, 2021(Dl). https://doi.org/10.1155/2021/6658058

Arf, C. 1959. Cahit Arf - makine düşünebilir mi ve nasıl düşünebilir.pdf. I.

Ayyucekizrak.medium. (n.d.). Nöron Formül. https://ayyucekizrak.medium.com/şu-kara-kutuyu-açalim-yapay-sinir-ağları-7b65c6a5264a

Benetos, I. S., Babis, G. C., Zoubos, A. B., Benetou, V., & Soucacos, P. N. 2007. Factors affecting the risk of hip fractures. Injury, 38(7), 735–744. https://doi.org/10.1016/J.INJURY.2007.01.001

Briot, K., Cortet, B., Trémollières, F., Sutter, B., Thomas, T., Roux, C., Audran, M., & le Comité Scientifique du GRIO, pour. 2009. Male osteoporosis: Diagnosis and fracture risk evaluation. Joint Bone Spine, 76, 129–133. https://doi.org/10.1016/j.jbspin.2008.07.014

Chollet, Francois. 2017. Fundamentals of Machine Learning. In Keras. https://doi.org/10.1201/9780429330131-1

Chollet, François. 2017. Xception: Deep learning with depthwise separable convolutions. Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, 2017-Janua, 1800–1807. https://doi.org/10.1109/CVPR.2017.195

Deng, L., & Yu, D. 2013. Deep learning: Methods and applications. Foundations and Trends in Signal Processing, 7(3–4), 197–387. https://doi.org/10.1561/2000000039

Derinogrenme.com. (n.d.). YSA. https://www.derinogrenme.com/2017/03/04/yapay-sinir-aglari/

DICOM. (n.d.). Dicom. https://www.dicomlibrary.com/dicom/

El-Shahat, A. 2018. Introductory Chapter: Artificial Neural Networks. Advanced Applications for Artificial Neural Networks. https://doi.org/10.5772/intechopen.73530

Etta D. Pisano, Shuquan Zong, Bradley M. Hemminger, Marla Deluca, R. E. J. 2016. Fast search of a similar patch for self-similarity based image super resolution. IEICE Transactions on Information and Systems, E99D(8), 2194–2198. https://doi.org/10.1587/transinf.2016EDL8049

Fikir.gen.tr. (n.d.). Nöron. https://www.fikir.gen.tr/sinir-sisteminin-yapisi-gorevi-ve-isleyisi-noron-nedir-noron-kaca-ayrilir/

Fırıldak, K., & Talu, M. F. 2019. Evrişimsel Sinir Ağlarında Kullanılan Transfer Öğrenme Yaklaşımlarının İncelenmesi. Anatolian Journal of Computer Science, 4(2), 88–95. https://dergipark.org.tr/tr/download/article-file/833620

Gonzalez, R. C., & Woods, R. E. 2008. Digital Image Processing Third Edition Pearson. 954.

Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. 2017. Densely connected convolutional networks. Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, 2017-Janua, 2261–2269. https://doi.org/10.1109/CVPR.2017.243

John McCarthy. 2007. What Is Artificial Intelligence? American Scientist, 73(3), 258.

Keras, W. (n.d.). Keras. https://tr.wikipedia.org/wiki/Keras

Kim, P. (2017). MATLAB Deep Learning. In MATLAB Deep Learning. https://doi.org/10.1007/978-1-4842-2845-6

Kirazlı, Y. (n.d.). Osteoporotik Kalça Kırıklı Hastada Medikal Tedavi Medical Treatment in Patients with Osteoporotic Hip Fracture.

Krogue, J. D., Cheng, K., Hwang, K. M., Toogood, P., Meinberg, E. G., Geiger, E. J., Zaid, M., McGill, K. C., Patel, R., Sohn, J. H., Wright, A., Darger, B. F., Padrez, K. A., Ozhinsky, E., Majumdar, S., & Pedoia, V. 2019. Automatic hip fracture identification and functional subclassification with deep learning. ArXiv, 1, 1–14. https://doi.org/10.1148/ryai.2020190023

Kumar, R. 2019. Adding binary search connections to improve DenseNet performance. https://ssrn.com/abstract=3545071

Kurt, B., & Nabİyev, V. V. 2010. Dijital Mamografi Görüntülerinin Kontrast Sınırlı Adaptif Histogram Eşitleme ile İyileştirilmesi. VII. Ulusal Tıp Bilişimi Kongresi, 67–78.

Lecun, Y. 1989. Handwritten Digit Recognition. Handwritten Digit Recognition: Applications of Neural Network Chips and Automatic Learning, 461–478. https://doi.org/10.1007/978-1-4842-3357-3_12

Lecun, Y., Bengio, Y., & Hinton, G. 2015. Deep learning. Nature, 521(7553), 436–444. https://doi.org/10.1038/nature14539

Li, X., Shen, X., Zhou, Y., Wang, X., & Li, T.-Q. 2020. Classification of breast cancer histopathological images using interleaved DenseNet with SENet (IDSNet). https://doi.org/10.1371/journal.pone.0232127

Lin, M., Chen, Q., & Yan, S. 2014. Network in network. 2nd International Conference on Learning Representations, ICLR 2014 - Conference Track Proceedings, 1–10.

Lüthje, P., Nurmi-Lüthje, I., Kaukonen, J. P., Kuurne, S., Naboulsi, H., & Kataja, M. 2009. Undertreatment of osteoporosis following hip fracture in the elderly. Archives of Gerontology and Geriatrics, 49(1), 153–157. https://doi.org/10.1016/J.ARCHGER.2008.06.007

Matsugu, M., Mori, K., Mitari, Y., & Kaneda, Y. 2003. Subject independent facial expression recognition with robust face detection using a convolutional neural network. Neural Networks, 16(5–6), 555–559. https://doi.org/10.1016/S0893-6080(03)00115-1

McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. 1955. A proposal for the Dartmouth summer research project on artificial intelligence. AI Magazine, 27(4), 12–14.

Morita, S., Jinno, T., Nakamura, H., Kumei, Y., Shinomiya, K., & Yamamoto, H. 2005. Bone mineral density and walking ability of elderly patients with hip fracture: A strategy for prevention of hip fracture. Injury, 36(9), 1075–1079. https://doi.org/10.1016/J.INJURY.2005.02.028

Mutasa, S., Varada, S., Goel, A., Wong, T. T., & Rasiej, M. J. 2020. Advanced Deep Learning Techniques Applied to Automated Femoral Neck Fracture Detection and Classification. Journal of Digital Imaging, 33(5), 1209–1217. https://doi.org/10.1007/s10278-020-00364-8

Nvidia. (n.d.). Nvidia. https://www.nvidia.com/en-gb/data-center/tesla-k80/

Öztemel E., P. D. E. 2012. Yapay Sinir Ağlari. In Papatya Yayincilik. http://papatyabilim.com.tr/PDF/yapay_sinir_aglari.pdf

Öztürk, N., & Öztürk, S. 2022. Bölütleme Tabanlı Yeni Görüntü İyileştirme Yöntemi. European Journal of Science and Technology, 32, 675–681. https://doi.org/10.31590/ejosat.1041197

Pan, S. J., & Yang, Q. 2010. A Survey on Transfer Learning. Smart Innovation, Systems and Technologies, 194(10), 781–789. https://doi.org/10.1007/978-981-15-5971-6_83

Rende, F. Ş., Bütün, G., & Karahan, Ş. 2016. Derin Öğrenme Algoritmalarinda Model Testleri: Derin Testler. CEUR Workshop Proceedings, 1721, 54–59.

Rumelhart, D. E., Hinton, G. E., & Williams, R. J. 1985. Learning Internal Representations by Error Propagation. Readings in Cognitive Science: A Perspective from Psychology and Artificial Intelligence, V, 399–421. https://doi.org/10.1016/B978-1-4832-1446-7.50035-2

S Erbakan, S., Bakar, İ. S., Engin, E. Z., Şeker, K., & Akkaya, İ. 2015. Image Processing Based Vascular Network Analysis Görüntü İş leme Tabanl ı Görüntü İşleme Tabanlı Damar Şebekesi Analizi Image Processing Based Vascular Network Analysis. May 2016.

Sarı, F. 2021. Cahit Arf'ın "Makine Düşünebilir mi ve Nasıl Düşünebilir?" Adlı Makalesi Üzerine Bir Çalışma. TRT Akademi, 6, 812–833. https://doi.org/10.37679/trta.962940

Ser, G., & Bati, C. T. 2019. Determining the best model with deep neural networks: Keras application on mushroom data. Yuzuncu Yil University Journal of Agricultural Sciences, 29(3), 406–417. https://doi.org/10.29133/yyutbd.505086

Seyyarer, E., Ayata, F., Uçkan, T., & Karci, A. 2020. Derin Öğrenmede Kullanilan Optimizasyon Algoritmalarinin Uygulanmasi Ve Kiyaslanmasi APPLICATIONS AND COMPARISON OF OPTIMIZATION ALGORITHMS USED IN DEEP. 2, 90–98.

Sivari, E., Civelek, Z., & Kahraman, G. 2020. Artificial neural network model estimating the initial dose of propofol used in general anesthesia. El-Cezeri Journal of Science and Engineering, 7(3), 1482–1495. https://doi.org/10.31202/ecjse.764719

Soydemir, R., & Kuran, B. 2010. Osteoporotik Kalça Kırığı ile İlişkili Risk Faktörlerinin Değerlendirilmesi. 31–34.

Stanford.edu. (n.d.). Tam Bağlı Katman. https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-convolutional-neural-networks

Sümer, E., Engin, M., Ağıldere, M., & Oğul, H. 2018. Monitoring Nodule Progression in Chest X-ray Images. Pamukkale University Journal of Engineering Sciences, 24(5), 934–941. https://doi.org/10.5505/pajes.2018.89166

Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. A. 2017. Inception-v4, inception-ResNet and the impact of residual connections on learning. 31st AAAI Conference on Artificial Intelligence, AAAI 2017, 4278–4284.

Szegedy, C., Zeng, G., He, Y., Yu, Z., Yang, X., Yang, R., & Zhang, L. 2016. Preparation of novel high copper ions removal membranes by embedding organosilane-functionalized multi-walled carbon nanotube. Journal of Chemical Technology and Biotechnology, 91(8), 2322–2330. https://doi.org/10.1002/jctb.4820

Şahin, S. 2017. Başkent Üniversitesi Fen Bilimleri Enstitüsü Pelvik Kemik Yapılarının Bölütlenmesi ve Pelvik Açılarının Otomatik Ölçümü - Doktora Tezi.

Şeker, A., Diri, B., & Balık, H. 2017. Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. Gazi Journal of Engineering Sciences, 3(3), 47–64. http://dergipark.gov.tr/gmbd/issue/31064/372661

Tanrıover, M. D., Oz, S. G., Tanrıover, A., Kilicarslan, A., Turkmen, E., Guven, G. S., Saracbasi, O., Tokgozoglu, M., & Sozen, T. 2010. Hip fractures in a developing country: Osteoporosis frequency, predisposing factors and treatment costs. Archives of Gerontology and Geriatrics, 50(3), e13–e18. https://doi.org/10.1016/J.ARCHGER.2009.04.010

Urakawa, T., Tanaka, Y., Goto, S., Matsuzawa, H., Watanabe, K., & Endo, N. 2019. Detecting intertrochanteric hip fractures with orthopedist-level accuracy using a deep convolutional neural network. Skeletal Radiology, 48(2), 239–244. https://doi.org/10.1007/s00256-018-3016-3

Wei, L., Cai, J., Nguyen, V., Chu, J., & Wen, K. 2020. P-SFA: Probability based Sigmoid Function Approximation for Low-complexity Hardware Implementation. Microprocessors and Microsystems, 76. https://doi.org/10.1016/j.micpro.2020.103105

White, S. C., Atchison, K. A., Gornbein, J. A., Nattiv, A., Paganini-Hill, A., & Service, S. K. 2006. Risk factors for fractures in older men and women: The Leisure World

Cohort Study. Gender Medicine, 3(2), 110–123. https://doi.org/10.1016/S1550-8579(06)80200-7

Yamada, Y., Maki, S., Kishida, S., Nagai, H., Arima, J., Yamakawa, N., Iijima, Y., Shiko, Y., Kawasaki, Y., Kotani, T., Shiga, Y., Inage, K., Orita, S., Eguchi, Y., Takahashi, H., Yamashita, T., Minami, S., & Ohtori, S. 2020. Automated classification of hip fractures using deep convolutional neural networks with orthopedic surgeon-level accuracy: ensemble decision-making with antero-posterior and lateral radiographs. Acta Orthopaedica, 3674. https://doi.org/10.1080/17453674.2020.1803664

Yazan, E., & Talu, M. F. 2017. Stokastik dereceli alçalma yöntemi temelli optimizasyon tekniklerinin karşilaştirilmasi. IDAP 2017 - International Artificial Intelligence and Data Processing Symposium, September 2017. https://doi.org/10.1109/IDAP.2017.8090299

Zhang, Q., Yang, L. T., Chen, Z., & Li, P. 2018. A survey on deep learning for big data. Information Fusion, 42(October 2017), 146–157. https://doi.org/10.1016/j.inffus.2017.10.006

EKLER

EK 1. Veri setlerinin DenseNet201 modelinde test sonuçları

EK 2. Veri setlerinin Xception modelinde test sonuçları

EK 3. Veri setlerinin ResNet152V2 modelinde test sonuçları

EK 4. Veri setlerinin InceptionResNetV2 modelinde test sonuçları

EK - 1

HAM VERİ SETİ (clahe(8,8)) (VS-2)	HAM VERİ SETİ (VS-1)	VERİ ARTIRIMI YAPILAN VERİ SETİ (VS-3)	CLAHE FİLTRELİ VERİ SETİ (clahe (8,8)) (VS-4)
Toplam Eğitim KIRIK: 65 Toplam Eğitim SAĞLAM: 43 **EĞİTİM TOPLAM: 108** Toplam Doğrulama KIRIK: 20 Toplam Doğrulama SAĞLAM: 10 **DOĞRULAMA TOPLAM: 30** Toplam Test KIRIK: 20 Toplam Test SAĞLAM: 20 **TEST TOPLAM: 40** **GENEL TOPLAM: 178**	Toplam Eğitim KIRIK: 65 Toplam Eğitim SAĞLAM: 43 **EĞİTİM TOPLAM: 108** Toplam Doğrulama KIRIK: 20 Toplam Doğrulama SAĞLAM: 10 **DOĞRULAMA TOPLAM: 30** Toplam Test KIRIK: 20 Toplam Test SAĞLAM: 20 **TEST TOPLAM: 40** **GENEL TOPLAM: 178**	Toplam Eğitim KIRIK: 130 Toplam Eğitim SAĞLAM: 86 **EĞİTİM TOPLAM: 216** Toplam Doğrulama KIRIK: 40 Toplam Doğrulama SAĞLAM: 20 **DOĞRULAMA TOPLAM: 60** Toplam Test KIRIK Fotosu: 20 Toplam Test SAĞLAM Fotosu: 20 **TEST TOPLAM: 40** **GENEL TOPLAM: 316**	Toplam Eğitim KIRIK: 130 Toplam Eğitim SAĞLAM: 86 **EĞİTİM TOPLAM: 216** Toplam Doğrulama KIRIK: 40 Toplam Doğrulama SAĞLAM: 20 **DOĞRULAMA TOPLAM: 60** Toplam Test KIRIK: 20 Toplam Test SAĞLAM: 20 **TEST TOPLAM: 40** **GENEL TOPLAM: 316**

DenseNet201_01.h5 - optimizer = RMSprop(0.001)			
Over fitting (aşırı uydurma)	Over fitting (aşırı uydurma)	Over fitting (aşırı uydurma)	Over fitting (aşırı uydurma)

DenseNet201_02.h5 - optimizer = RMSprop(2e-5)			
KIRIK VERİLERDE : %95 SAĞLAM VERİLERDE: %85 F1-Score: 0.9000	KIRIK VERİLERDE : %90 SAĞLAM VERİLERDE: %100 F1-Score: 0.9500	KIRIK VERİLERDE : %95 SAĞLAM VERİLERDE: %20 F1-Score: 0.5750	KIRIK VERİLERDE : %95 SAĞLAM VERİLERDE: %55 F1-Score: 0.7500

DenseNet201_03.h5 - optimizer = Adam(0.001)			
KIRIK VERİLERDE : %90 SAĞLAM VERİLERDE: %95 F1-Score: 0.9250 *** TEZ - (Clahe veri seti test sonucu)**	KIRIK VERİLERDE : %60 SAĞLAM VERİLERDE: %75 F1-Score: 0.6750	KIRIK VERİLERDE : %90 SAĞLAM VERİLERDE: %85 F1-Score: 0.8750 *** TEZ - (4.3- Artırılmış veri seti test sonucu)**	KIRIK VERİLERDE : %90 SAĞLAM VERİLERDE: %95 F1-Score: 0.9250 *** TEZ - (4.4- Clahe veri seti test sonucu)**

DenseNet201_04.h5 - optimizer = Adam(2e-5)			
KIRIK VERİLERDE : %90 SAĞLAM VERİLERDE: %100 F1-Score: 0.9500	KIRIK VERİLERDE : %90 SAĞLAM VERİLERDE: %80 F1-Score: 0.8500 *** TEZ - (4.2-Ham veri seti test sonucu)**	KIRIK VERİLERDE : %95 SAĞLAM VERİLERDE: %55 F1-Score: 0.7500	KIRIK VERİLERDE : %90 SAĞLAM VERİLERDE: %95 F1-Score: 0.9250 *** TEZ - (4.4- Clahe veri seti test sonucu)**

EK - 2

HAM VERİ SETİ (clahe(8,8)) (VS-2)	HAM VERİ SETİ (VS-1)	VERİ ARTIRIMI YAPILAN VERİ SETİ (VS-3)	CLAHE FİLTRELİ VERİ SETİ (clahe (8,8)) (VS-4)
Toplam Eğitim KIRIK: 65 Toplam Eğitim SAĞLAM: 43 **EĞİTİM TOPLAM: 108** Toplam Doğrulama KIRIK: 20 Toplam Doğrulama SAĞLAM: 10 **DOĞRULAMA TOPLAM: 30** Toplam Test KIRIK: 20 Toplam Test SAĞLAM: 20 **TEST TOPLAM: 40** **GENEL TOPLAM: 178**	Toplam Eğitim KIRIK: 65 Toplam Eğitim SAĞLAM: 43 **EĞİTİM TOPLAM: 108** Toplam Doğrulama KIRIK: 20 Toplam Doğrulama SAĞLAM: 10 **DOĞRULAMA TOPLAM: 30** Toplam Test KIRIK: 20 Toplam Test SAĞLAM: 20 **TEST TOPLAM: 40** **GENEL TOPLAM: 178**	Toplam Eğitim KIRIK: 130 Toplam Eğitim SAĞLAM: 86 **EĞİTİM TOPLAM: 216** Toplam Doğrulama KIRIK: 40 Toplam Doğrulama SAĞLAM: 20 **DOĞRULAMA TOPLAM: 60** Toplam Test KIRIK Fotosu: 20 Toplam Test SAĞLAM Fotosu: 20 **TEST TOPLAM: 40** **GENEL TOPLAM: 316**	Toplam Eğitim KIRIK: 130 Toplam Eğitim SAĞLAM: 86 **EĞİTİM TOPLAM: 216** Toplam Doğrulama KIRIK: 40 Toplam Doğrulama SAĞLAM: 20 **DOĞRULAMA TOPLAM: 60** Toplam Test KIRIK: 20 Toplam Test SAĞLAM: 20 **TEST TOPLAM: 40** **GENEL TOPLAM: 316**

Xception_01.h5 - optimizer = RMSprop(0.001)			
KIRIK VERİLERDE : %95 SAĞLAM VERİLERDE: %75 F1-Score: 0.8500 *** TEZ - (Clahe veri seti test sonucu)**	Over fitting (aşırı uydurma)	Over fitting (aşırı uydurma)	Over fitting (aşırı uydurma)

Xception_02.h5 - optimizer = RMSprop(2e-5)			
KIRIK VERİLERDE : %95 SAĞLAM VERİLERDE: %35 F1-Score: 0.6500	KIRIK VERİLERDE : %90 SAĞLAM VERİLERDE: %90 F1-Score: 0.9000 *** TEZ - (4.2-Ham veri test sonucu)**	KIRIK VERİLERDE : %90 SAĞLAM VERİLERDE: %90 F1-Score: 0.9000 *** TEZ - (4.3- Artırılmış veri seti test sonucu)**	KIRIK VERİLERDE : %90 SAĞLAM VERİLERDE: %65 F1-Score: 0.7750 *** TEZ - (4.4- Clahe veri seti test sonucu)**

Xception_03.h5 - optimizer = Adam(0.001)			
Over fitting (aşırı uydurma)	KIRIK VERİLERDE : %90 SAĞLAM VERİLERDE: %75 F1-Score: 0.8250	Over fitting (aşırı uydurma)	KIRIK VERİLERDE : %45 SAĞLAM VERİLERDE: %100 F1-Score: 0.7250

Xception_04.h5 - optimizer = Adam(2e-5)			
KIRIK VERİLERDE : %90 SAĞLAM VERİLERDE: %75 F1-Score: 0.8250	KIRIK VERİLERDE : %85 SAĞLAM VERİLERDE: %95 F1-Score: 0.9000	KIRIK VERİLERDE : %90 SAĞLAM VERİLERDE: %85 F1-Score: 0.8750	KIRIK VERİLERDE : %95 SAĞLAM VERİLERDE: %60 F1-Score: 0.7750 *** TEZ - (4.4- Clahe veri seti test sonucu)**

EK - 3

HAM VERİ SETİ (clahe(8,8)) (VS-2)	HAM VERİ SETİ (VS-1)	VERİ ARTIRIMI YAPILAN VERİ SETİ (VS-3)	CLAHE FİLTRELİ VERİ SETİ (clahe (8,8)) (VS-4)
Toplam Eğitim KIRIK: 65 Toplam Eğitim SAĞLAM: 43 **EĞİTİM TOPLAM: 108** Toplam Doğrulama KIRIK: 20 Toplam Doğrulama SAĞLAM: 10 **DOĞRULAMA TOPLAM: 30** Toplam Test KIRIK: 20 Toplam Test SAĞLAM: 20 **TEST TOPLAM: 40** **GENEL TOPLAM: 178**	Toplam Eğitim KIRIK: 65 Toplam Eğitim SAĞLAM: 43 **EĞİTİM TOPLAM: 108** Toplam Doğrulama KIRIK: 20 Toplam Doğrulama SAĞLAM: 10 **DOĞRULAMA TOPLAM: 30** Toplam Test KIRIK: 20 Toplam Test SAĞLAM: 20 **TEST TOPLAM: 40** **GENEL TOPLAM: 178**	Toplam Eğitim KIRIK: 130 Toplam Eğitim SAĞLAM: 86 **EĞİTİM TOPLAM: 216** Toplam Doğrulama KIRIK: 40 Toplam Doğrulama SAĞLAM: 20 **DOĞRULAMA TOPLAM: 60** Toplam Test KIRIK Fotosu: 20 Toplam Test SAĞLAM Fotosu: 20 **TEST TOPLAM: 40** **GENEL TOPLAM: 316**	Toplam Eğitim KIRIK: 130 Toplam Eğitim SAĞLAM: 86 **EĞİTİM TOPLAM: 216** Toplam Doğrulama KIRIK: 40 Toplam Doğrulama SAĞLAM: 20 **DOĞRULAMA TOPLAM: 60** Toplam Test KIRIK: 20 Toplam Test SAĞLAM: 20 **TEST TOPLAM: 40** **GENEL TOPLAM: 316**

ResNet152V2_01.h5 - optimizer = RMSprop(0.001)			
Over fitting (aşırı uydurma)	Over fitting (aşırı uydurma)	KIRIK VERİLERDE : %60 SAĞLAM VERİLERDE: %50 F1-Score: 0.5500	KIRIK VERİLERDE : %70 SAĞLAM VERİLERDE: %85 F1-Score: 0.7750

ResNet152V2_02.h5 - optimizer = RMSprop(2e-5)			
KIRIK VERİLERDE : %95 SAĞLAM VERİLERDE: %40 F1-Score: 0.6750	KIRIK VERİLERDE : %85 SAĞLAM VERİLERDE: %95 F1-Score: 0.9000 *** TEZ - (4.2-Ham veri seti test sonucu)**	KIRIK VERİLERDE : %85 SAĞLAM VERİLERDE: %95 F1-Score: 0.9000 ***TEZ - (4.3- Artırılmış veri seti test sonucu)**	KIRIK VERİLERDE : %95 SAĞLAM VERİLERDE: %80 F1-Score: 0.8750 ***TEZ - (4.4- Clahe veri seti test sonucu)**

ResNet152V2_03.h5 - optimizer = Adam(0.001)			
Over fitting (aşırı uydurma)	Over fitting (aşırı uydurma)	Over fitting (aşırı uydurma)	Over fitting (aşırı uydurma)

ResNet152V2_04.h5 - optimizer = Adam(2e-5)			
KIRIK VERİLERDE : %95 SAĞLAM VERİLERDE: %50 F1-Score: 0.7250 *** TEZ - (Clahe veri seti test sonucu)**	KIRIK VERİLERDE : %95 SAĞLAM VERİLERDE: %60 F1-Score: 0.7750	KIRIK VERİLERDE : %95 SAĞLAM VERİLERDE: %80 F1-Score: 0.8750	KIRIK VERİLERDE : %85 SAĞLAM VERİLERDE: %80 F1-Score: 0.8250

EK - 4

HAM VERİ SETİ (clahe(8,8)) (VS-2)	HAM VERİ SETİ (VS-1)	VERİ ARTIRIMI YAPILAN VERİ SETİ (VS-3)	CLAHE FİLTRELİ VERİ SETİ (clahe (8,8)) (VS-4)
Toplam Eğitim KIRIK: 65 Toplam Eğitim SAĞLAM: 43 **EĞİTİM TOPLAM: 108** Toplam Doğrulama KIRIK: 20 Toplam Doğrulama SAĞLAM: 10 **DOĞRULAMA TOPLAM: 30** Toplam Test KIRIK: 20 Toplam Test SAĞLAM: 20 **TEST TOPLAM: 40** **GENEL TOPLAM: 178**	Toplam Eğitim KIRIK: 65 Toplam Eğitim SAĞLAM: 43 **EĞİTİM TOPLAM: 108** Toplam Doğrulama KIRIK: 20 Toplam Doğrulama SAĞLAM: 10 **DOĞRULAMA TOPLAM: 30** Toplam Test KIRIK: 20 Toplam Test SAĞLAM: 20 **TEST TOPLAM: 40** **GENEL TOPLAM: 178**	Toplam Eğitim KIRIK: 130 Toplam Eğitim SAĞLAM: 86 **EĞİTİM TOPLAM: 216** Toplam Doğrulama KIRIK: 40 Toplam Doğrulama SAĞLAM: 20 **DOĞRULAMA TOPLAM: 60** Toplam Test KIRIK Fotosu: 20 Toplam Test SAĞLAM Fotosu: 20 **TEST TOPLAM: 40** **GENEL TOPLAM: 316**	Toplam Eğitim KIRIK: 130 Toplam Eğitim SAĞLAM: 86 **EĞİTİM TOPLAM: 216** Toplam Doğrulama KIRIK: 40 Toplam Doğrulama SAĞLAM: 20 **DOĞRULAMA TOPLAM: 60** Toplam Test KIRIK: 20 Toplam Test SAĞLAM: 20 **TEST TOPLAM: 40** **GENEL TOPLAM: 316**

InceptionResNetV2_01.h5 - optimizer = RMSprop(0.001)			
KIRIK VERİLERDE : %95 SAĞLAM VERİLERDE: %60 F1-Score: 0.7750	KIRIK VERİLERDE : %95 SAĞLAM VERİLERDE: %75 F1-Score: 0.8500	KIRIK VERİLERDE : %45 SAĞLAM VERİLERDE: %10 F1-Score: 0.2750	KIRIK VERİLERDE : %90 SAĞLAM VERİLERDE: %25 F1-Score: 0.5750

InceptionResNetV2_02.h5 - optimizer = RMSprop(2e-5)			
KIRIK VERİLERDE : %90 SAĞLAM VERİLERDE: %90 F1-Score: 0.9000 *** Kıyaslamada kullandım**	KIRIK VERİLERDE : %75 SAĞLAM VERİLERDE: %95 F1-Score: 0.8500	KIRIK VERİLERDE : %90 SAĞLAM VERİLERDE: %85 F1-Score: 0.8750	KIRIK VERİLERDE : %90 SAĞLAM VERİLERDE: %80 F1-Score: 0.8500

InceptionResNetV2_03.h5 - optimizer = Adam(0.001)			
KIRIK VERİLERDE : %95 SAĞLAM VERİLERDE: %95 F1-Score: 0.9500 *** TEZ - (Clahe veri seti test sonucu)**	KIRIK VERİLERDE : %95 SAĞLAM VERİLERDE: %95 F1-Score: 0.9500 *** TEZ - (4.2-Ham veri seti test sonucu)**	KIRIK VERİLERDE : %95 SAĞLAM VERİLERDE: %85 F1-Score: 0.9000 *** TEZ - (4.3- Artırılmış veri seti test sonucu)**	KIRIK VERİLERDE : %95 SAĞLAM VERİLERDE: %60 F1-Score: 0.7750

InceptionResNetV2_04.h5 - optimizer = Adam(2e-5)			
KIRIK VERİLERDE : %85 SAĞLAM VERİLERDE: %90 F1-Score:0.8750	KIRIK VERİLERDE : %85 SAĞLAM VERİLERDE: %95 F1-Score:0.9000	KIRIK VERİLERDE : %90 SAĞLAM VERİLERDE: %90 F1-Score: 0.9000	KIRIK VERİLERDE : %85 SAĞLAM VERİLERDE: %95 F1-Score: 0.9000 *** TEZ - (4.4- Clahe veri seti test sonucu)**

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı ve Soyadı : Hasan ERSÖNMEZ

Eğitim

Yüksek Lisans	Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği ABD	2018 - Halen
Lisans	Hoca Ahmet Yesevi Uluslararası Türk-Kazak Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü	2012-2016
Lisans	Anadolu Üniversitesi İşletme Fakültesi İşletme Bölümü	2009-2012
Önlisans	Samsun 19 Mayıs Üniversitesi Meslek Yüksekokulu Bilgisayar Programcılığı	2001-2004

İş Deneyimi

Yıl	**Kurum**	**Görev**
2009-Halen	Çankırı Karatekin Üniversitesi Bilgi İşlem Daire Başkanlığı	Bilgisayar Teknikeri