

**AKCİĞER BİLGİSAYARLI TOMOGRAFİLERİNDEN
GÖRÜNTÜ İŞLEME VE DERİN ÖĞRENME İLE
COVID-19 TESPİTİ**

Feyzanur Banu DEMİR



T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**AKCİĞER BİLGİSAYARLI TOMOGRAFİLERİNDEN GÖRÜNTÜ İŞLEME
VE DERİN ÖĞRENME İLE COVID-19 TESPİTİ**

Feyzanur Banu DEMİR
0000-0001-8921-896X

Doç. Dr. Ersen YILMAZ
(Danışman)

YÜKSEK LİSANS
ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2022
Her Hakkı Saklıdır

TEZ ONAYI

Feyzanur Banu DEMİR tarafından hazırlanan “Akciğer Bilgisayarlı Tomografilerinden Görüntü İşleme ve Derin Öğrenme ile COVID-19 Tespiti ” adlı tez çalışması aşağıdaki jüri tarafından oy birliği ile Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü Elektronik Mühendisliği Anabilim Dalı’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman: Doç. Dr. Ersen YILMAZ

- Başkan** : Doç. Dr. Ersen YILMAZ İmza
0000-0002-6620-655X
Bursa Uludağ Üniversitesi,
Mühendislik Fakültesi,
Elektronik Mühendisliği Anabilim Dalı
- Üye** : Prof. Dr. Hakan GÜRKAN İmza
0000-0002-7008-4778
Bursa Teknik Üniversitesi,
Mühendislik ve Doğa Bilimleri Fakültesi,
Elektrik-Elektronik Mühendisliği Anabilim Dalı
- Üye** : Doç. Dr. Enes YİĞİT İmza
0000-0002-0960-5335
Bursa Uludağ Üniversitesi,
Mühendislik Fakültesi,
Elektronik Mühendisliği Anabilim Dalı

Yukarıdaki sonucu onaylarım

Prof. Dr. Hüseyin Aksel EREN
Enstitü Müdürü
.././....

B.U.Ü. Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

30/05/2022

Feyzanur Banu DEMİR

TEZ YAYINLANMA FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezin/raporun tamamını veya herhangi bir kısmını, basılı (kâğıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma izni Bursa Uludağ Üniversitesi'ne aittir. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet hakları ile tezin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları tarafımıza ait olacaktır. Tezde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alınarak kullandığımızı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederiz.

Yükseköğretim Kurulu tarafından yayınlanan “**Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge**” kapsamında, yönerge tarafından belirtilen kısıtlamalar olmadığı takdirde tezin YÖK Ulusal Tez Merkezi / B.U.Ü. Kütüphanesi Açık Erişim Sistemi ve üye olunan diğer veri tabanlarının (Proquest veri tabanı gibi) erişimine açılması uygundur.

ÖZET

Yüksek Lisans Tezi

AKCIĞER BİLGİSAYARLI TOMOGRAFİLERİNDEN GÖRÜNTÜ İŞLEME VE DERİN ÖĞRENME İLE COVID-19 TESPİTİ

Feyzanur Banu DEMİR

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Ersen YILMAZ

Yeni koronavirüs hastalığı (COVID-19) SARS-CoV-2 virüsünün sebep olduğu bir salgın hastalıktır. Bulaşıcılığının çok yüksek olması sebebiyle hastalığın kontrol altına alınabilmesi için enfekte olmuş bireylerin hızlıca tespit edilip izole edilmesi gerekmektedir. Hastalığın tespit edilmesinde sıklıkla tercih edilen yöntem ters transkripsiyon-polimeraz zincir reaksiyonu (RT-PCR) testleridir. Bu testlerin sonuç verme sürelerinin uzunluğu ve başarımlarının yüzdelere göre hastalığın evrelerine göre farklılık gösterebilmesi önemli dezavantajları olarak öne çıkmaktadır.

Hastalığın erken evrelerinde hızlı ve doğru bir şekilde COVID-19 tanısı koyabilmek için tıbbi radyolojik görüntüleme yöntemleri de kullanılmaktadır. Bu yöntemler, hasta ile daha az temas gerektirdiğinden daha az bulaş riskine sahiptir. Özellikle, X-ışını (X-Ray) ve Bilgisayarlı Tomografi (BT) görüntüleri üzerinden derin öğrenme temelli yaklaşımlar ile COVID-19'un tespit edilmesini hedefleyen çalışmalar literatürde yoğun ilgi görmektedir.

Bu çalışmada, akciğer BT görüntülerini içeren bir veri kümesi oluşturulmuştur. Bu veri kümesi üzerinde derin öğrenme temelli mimariler kullanılarak COVID-19'un tespiti gerçekleştirilmiştir. Derin öğrenme mimarileri kullanılırken iki farklı izlem takip edilmiştir. Birinci izlemde, Basit-CNN ve VGG16 mimarileri kullanılarak ağ derinliğinin başarımlar üzerindeki etkisi incelenmiştir. İkinci izlemde ise öğrenme aktarımı yönteminin derin öğrenme mimarilerinden VGG19, MobileNet ve DenseNet'in başarımları üzerindeki etkisi araştırılmıştır. Çalışmalar sonucunda DenseNet201 mimarisinin 0,99 test doğruluğu ile en yüksek başarıma sahip olduğu gözlemlenmiştir.

Anahtar Kelimeler: COVID-19, Derin Öğrenme, Akciğer Bilgisayarlı Tomografisi, Evrişimsel Sinir Ağları, Öğrenme Aktarımı

2022, xiii + 66 sayfa.

ABSTRACT

MSc Thesis

COVID-19 DETECTION WITH IMAGE PROCESSING AND DEEP LEARNING FROM LUNGS COMPUTED TOMOGRAPHY

Feyzanur Banu DEMİR

Bursa Uludağ University
Graduate School of Natural and Applied Sciences
Department of Electronics Engineering

Supervisor: Assoc. Prof. Dr. Ersen YILMAZ

The novel coronavirus disease (COVID-19) is an epidemic disease caused by the SARS-CoV-2 virus. Due to the high contagiousness of the disease, infected individuals must be identified and isolated quickly to control the disease. The most preferred method for detecting the disease is reverse transcription-polymerase chain reaction (RT-PCR) tests. The length of the results of these tests and the fact that the percentage of success can differ according to the stages of the disease stand out as important disadvantages.

Medical radiological imaging methods are also used to diagnose COVID-19 quickly and accurately in the early stages of the disease. These methods have less risk of infection as they require less contact with the patient. Studies in the literature that target the detection of COVID-19 with deep learning-based approaches, especially through X-Ray (X-Ray) and Computed Tomography (CT) images attract intensive attention.

In this study, a dataset including lung CT images was created. On this dataset, the detection of COVID-19 was carried out using deep learning-based architectures. Two different strategies were followed when using deep learning architectures. In the first strategy, the effect of network depth on performance was examined using Basic-CNN and VGG16 architectures. In the second strategy, the effect of the learning transfer method on the performance was examined using VGG19, MobileNet and DenseNet. As a result of the studies, it has been observed that the DenseNet201 architecture has the highest performance with a test accuracy of 0,99.

Keywords: COVID-19, Deep Learning, Lung Computed Tomography, Convolutional Neural Networks, Transfer Learning
2022, xiii + 66 pages.

ÖNSÖZ ve TEŞEKKÜR

Yüksek lisans eğitimim ve tez çalışmam boyunca sahip olduğu bilgi ve tecrübeleri ile yardımcı olan değerli danışman hocam Doç. Dr. Ersen YILMAZ' a teşekkürlerimi sunarım.

Eğitim hayatım boyunca tecrübeleri ve değerli düşünceleri ile bana her zaman yol gösteren sevgili babam Prof. Dr. İsmail DEMİR' e, maddi ve manevi tüm zorluklarda desteklerini esirgemeyen sevgili annem Melek DEMİR ve canım kardeşlerime teşekkürü bir borç bilirim.

Tez çalışması sürecinde yaşadığım problemlerde yardımlarını esirgemeyen meslektaşlarım Arş. Gör. Ahmet DEMİR ve Arş. Gör. Şule BEKİRYAZICI' ya teşekkürlerimi sunarım.

Bu tez çalışması, COVID-19 hastalığının akciğer bilgisayarlı tomografileri üzerinden görüntü işleme ve derin öğrenme tabanlı yöntemlerle tespit edilmesi amacıyla gerçekleştirilmiştir. Deneysel çalışmalarda kullanılmak üzere yeni bir veri kümesi oluşturulmuştur. Veri kümesinin oluşturulması sürecinde sağladıkları desteklerden dolayı T.C. Sağlık Bakanlığı, Trabzon Valiliği İl Sağlık Müdürlüğü, SBÜ Trabzon Eğitim ve Araştırma Hastanesi Başhekimliği ve Klinik Araştırmalar Etik Kuruluna, Bursa Uludağ Üniversitesi Klinik Araştırmalar Etik Kuruluna teşekkürlerimi sunarım.

Tüm dünyada insanlık için maddi ve manevi açılardan birçok kayıplara uğratan bu süreçte, verilerin elde edilmesinde destekleri bulunan Uzm. Dr. Özlem BAYRAKTAR SARAL, Uzm. Dr. Eser BULUT ve hayatlarımızı borçlu olduğumuz tüm sağlık çalışanlarına teşekkürü bir borç bilirim.

Bu tez çalışmasının COVID-19'un tespiti için yararlı olmasını ve sonraki çalışmalara katkı sağlamasını temenni ederim.

Feyzanur Banu DEMİR
30/05/2022

İÇİNDEKİLER

	Sayfa
ÖZET.....	vi
ABSTRACT.....	vii
ÖNSÖZ ve/veya TEŞEKKÜR.....	viii
SİMGELER ve KISALTMALAR DİZİNİ.....	xi
ŞEKİLLER DİZİNİ.....	xii
ÇİZELGELER DİZİNİ.....	xiii
1. GİRİŞ.....	1
2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI.....	3
2.1. Derin Öğrenme Çalışmaları.....	3
2.2. Tıbbi Görüntüleme.....	5
2.3. Tıbbi Görüntülemelerde Derin Öğrenme Çalışmaları.....	6
2.3.1. Sınıflandırma.....	7
2.3.2. Tespit.....	8
2.3.3. Bölütleme.....	9
2.4. Akciğer Bilgisayarlı Tomografiler Üzerinde Derin Öğrenme Uygulamaları.....	9
2.5. COVID-19'un Arka Planı.....	10
2.5.1. COVID-19'un laboratuvar tabanlı teşhisi.....	11
2.5.2. COVID-19'un tıbbi görüntüleme tabanlı teşhisi.....	12
2.6. Akciğer Bilgisayarlı Tomografiler Üzerinde COVID-19 Tespiti İçin Derin Öğrenme Uygulamaları.....	14
2.6.1. İkili sınıflandırma.....	14
2.6.2. Çoklu sınıflandırma.....	17
3. MATERYAL ve YÖNTEM.....	19
3.1. Kullanılan Veri Kümesi.....	19
3.2. Başarım Ölçütleri Ve İstatistiksel Analiz.....	21
3.3. Derin Öğrenme.....	23
3.4. Evrişimli Sinir Ağları.....	26
3.4.1. Evrişimsel katman.....	27
3.4.2. Aktivasyon katmanı.....	28
3.4.3. Havuzlama katmanı.....	28
3.4.4. Tam normalleştirme (batch normalization) katmanı.....	29
3.4.5. Tam bağlı katman.....	30
3.5. Öğrenme Aktarımı (Transfer Learning).....	30
3.5.1. VGGNet.....	31
3.5.2. DenseNet.....	32
3.5.3. MobileNet.....	32
3.6. Kullanılan Modeller.....	32
3.6.1. Birinci izlem.....	33
3.6.2. İkinci izlem.....	34
3.6.3. Kullanılan modellerin hiper-parametrelerinin seçilmesi.....	36
4. BULGULAR.....	39
4.1. Birinci İzlemde Elde Edilen Sonuçlar.....	39
4.1.1. Basit-CNN mimarisi.....	39
4.1.2. VGG16 mimarisi.....	41
4.2. İkinci İzlemde Elde Edilen Sonuçlar.....	44
4.2.1. VGG19 mimarisi.....	44

4.2.2. MobileNet mimarisi	46
4.2.3. DenseNet mimarisi.....	49
5. TARTIŞMA ve SONUÇ	52
KAYNAKLAR	58
ÖZGEÇMİŞ	66

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

φ	Aktivasyon fonksiyonu
b_k	Kutup değerleri
u_k	k'inci nöronun çıktısı
x_m	Girdi değerleri
y_k	Yapay sinir ağının çıktısı
w_{km}	k'inci nöron için ağırlıklar
$h_{l,k,\dots,t}^{1,2,\dots,N_h}$	Gizli katmanlarda bulunan nöronlar

Kısaltmalar

COVID-19	Yeni koronavirüs hastalığı
RT-PCR	Ters transkripsiyon-polimeraz zincir reaksiyonu
X-Ray	X-ışını
BT	Bilgisayarlı tomografi
MRI	Manyetik rezonans görüntüleme
PET	Pozitron emisyon tomografisi
CNN	Evrişimli sinir ağları
RNN	Tekrarlayan evrişimli sinir ağları
DSÖ	Dünya sağlık örgütü
YSA	Yapay sinir ağlarının
ILSVRC	ImageNet Büyük Ölçekli Görsel Tanıma Yarışması
FDA	ABD Gıda ve İlaç Dairesi
AUC	Eğrinin altında kalan alan değer
ILD	İnterstisyel akciğer hastalığı
SVM	Destek Vektör Makinesi
RF	Rastgele orman
DR	Diyabetik retinopati
MS	Multipl skleroz
ARDS	Akut solunum sıkıntısı
GGO	Buzlu cam opaklığı
SARS	Şiddetli akut solunum sendromu
CGAN	Koşullu üretken düşman ağları
DTL	Derin transfer öğrenme
PNG	Taşınabilir ağ grafiği
VGGNet	Çok derin evrişimli ağlar
DenseNet	Yoğun bağlantılı evrişimli ağlar
MobileNet	Mobil görüntü uygulamaları için verimli evrişimli sinir ağları

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1. COVID-19'lu bir hastanın akciğerlerinin BT' sindeki GGO gibi görsel belirteçler.....	13
Şekil 3.1. COVID-19 bulgularına sahip BT görüntü örnekleri.....	20
Şekil 3.2. COVID-19 bulgularına sahip olmayan BT görüntü örnekleri.....	20
Şekil 3.3. Veri kümesinin sınıflara göre dağılımı.....	21
Şekil 3.4. Biyolojik nöron yapısı.....	23
Şekil 3.5. Yapay sinir ağı yapısı.....	24
Şekil 3.6. Çok katmanlı yapay sinir ağı mimarisi.....	25
Şekil 3.7. Evrişim (filtreleme) işlemi.....	27
Şekil 3.8. Ortalama ve maksimum havuzlama işlemleri.....	29
Şekil 3.9. Temel bir CNN mimarisi.....	30
Şekil 3.10. Bir transfer öğrenme yaklaşım örneği.....	31
Şekil 3.11. Birinci izlemde kullanılan evrişimsel sinir ağı mimarileri A) Basit CNN mimarisi B) VGG16 mimarisi.....	33
Şekil 3.12. Öğrenme aktarımı modeli.....	34
Şekil 3.13. Standart ve derinlemesine ayrılabilir evrişim katmanı blok yapıları A) Derinlemesine ve noktasal evrişim katman blok yapısı B) Standart evrişim katman blok yapısı.....	35
Şekil 3.14. Yoğun blokların iç bağlantı yapısı.....	35
Şekil 3.15. İkinci izlemde kullanılan evrişimsel sinir ağı mimarileri A)VGG19 mimarisi B)MobileNet mimarisi C)DenseNet201 mimarisi.....	36
Şekil 4.1. Basit-CNN mimarisi için doğruluk grafiği (— Eğitim; — Doğrulama).....	40
Şekil 4.2. Basit-CNN mimarisi için kayıp grafiği (— Eğitim; — Doğrulama).....	40
Şekil 4.3. Basit-CNN mimarisine ait karışıklık matrisi.....	41
Şekil 4.5. VGG16 mimarisi için doğruluk grafiği (— Eğitim; — Doğrulama).....	42
Şekil 4.6. VGG16 mimarisi için kayıp grafiği (— Eğitim; — Doğrulama)....	43
Şekil 4.4. VGG16 mimarisine ait karışıklık matrisi.....	43
Şekil 4.8. VGG19 mimarisi için doğruluk grafiği (— Eğitim; — Doğrulama).....	45
Şekil 4.9. VGG19 mimarisine için kayıp grafiği (— Eğitim; — Doğrulama)..	45
Şekil 4.7. VGG19 mimarisine ait karışıklık matrisi.....	46
Şekil 4.11. MobileNet mimarisi doğruluk grafiği (— Eğitim; — Doğrulama)...	47
Şekil 4.12. MobileNet mimarisi için kayıp grafiği (— Eğitim; — Doğrulama).....	48
Şekil 4.10. MobileNet mimarisine ait karışıklık matrisi.....	48
Şekil 4.13. DenseNet201 mimarisi için doğruluk grafiği (— Eğitim; — Doğrulama).....	50
Şekil 4.14. DenseNet201 mimarisi için kayıp grafiği (— Eğitim; — Doğrulama).....	50
Şekil 4.13. DenseNet201 mimarisine ait karışıklık matrisi.....	51

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1. Karışıklık Matrisi.....	22
Çizelge 3.2. Hiper-parametreler.....	37
Çizelge 4.2. Basit-CNN mimarisi eğitim, doğrulama ve test doğrulukları ile kayıpları.....	39
Çizelge 4.3. Basit-CNN mimarisi için başarımları.....	41
Çizelge 4.4. VGG16 mimarisi eğitim, doğrulama ve test doğrulukları ve kayıpları.....	42
Çizelge 4.5. VGG16 mimarisi için başarımları.....	44
Çizelge 4.6. VGG19 mimarisi eğitim, doğrulama ve test doğrulukları ve kayıpları.....	44
Çizelge 4.7. VGG19 mimarisi için başarımları.....	46
Çizelge 4.8. MobileNet mimarisi eğitim, doğrulama ve test doğrulukları ve kayıpları.....	47
Çizelge 4.9. MobileNet mimarisi için başarımları.....	49
Çizelge 4.10. DenseNet201 mimarisi eğitim, doğrulama ve test doğrulukları ve kayıpları.....	49
Çizelge 4.11. DenseNet201 mimarisi için başarımları.....	51
Çizelge 5.1. Birinci izlem başarımları.....	53
Çizelge 5.3. Evrimsel sinir ağları için elde edilen başarımları.....	54
Çizelge 5.4. Literatürde COVID-19 tespiti yapan çalışmaların doğruluk sonuçları.....	55

1. GİRİŞ

Yeni koronavirüs (COVID-19), Aralık 2019'da ilk olarak Çin'de ortaya çıkan ve bulaştığı kişilerde öksürük, nefes darlığı ve ateş gibi bazı belirtilere neden olan bir hastalıktır. Ülkemizde ilk vaka Mart 2020'de ortaya çıkmıştır ve bu tarih itibariyle Dünya Sağlık Örgütü (DSÖ) tarafından pandemi ilan edilmiştir (T.C. Sağlık Bakanlığı, 2022).

Sağlık sistemlerinin yetersizliği ile birlikte günden güne artan yeni vaka, ölüm ve yoğun bakıma yatan hasta sayıları bu yeni salgının tüm dünyayı ciddi bir şekilde tehdit ettiğinin göstergesi olmuştur. Hastalığın yayılmasını kontrol altına alabilmek, uygulanan tıbbi tedavilerin etkinliğini arttırabilmek için hızlı ve doğru bir şekilde virüs taşıyan bireylerin tespit edilmesi gerekmektedir. Bu amaçla kullanılan birincil teşhis yöntemi, bir üst solunum yolu sürüntü örneğinden SARS-CoV-2'ye ait ribonükleik asidin (RNA) tespit edildiği RT-PCR yöntemidir. Sürüntü testleri her yeni kişi için yeni bir test kiti gerektirdiğinden yalnızca ciddi derecede belirti gösteren kişilere yapılmaktadır. Dolayısıyla, maddi olarak bir yük gerektirdiğinden yeterli test kiti sayısının sağlanamadığı ülkeler bulunmaktadır. Bunun yanı sıra test sonucunun çıkma süresi değişken olup hastalığın erken evrelerinde yüksek oranlarda yanlış negatif sonuçlar vermesi söz konusudur.

Daha hızlı ve hastalığın ilk evrelerinde yüksek doğru pozitif oranına sahip teşhis yöntemlerine ihtiyaç duyulmaktadır. Göğüs radyolojik görüntüleri COVID-19 gibi akciğer hastalıkları ile ilgili önemli belirtilere sahiptir. Bu nedenle X-ray ve bilgisayarlı tomografi (BT) gibi tıbbi görüntüleme yöntemleri COVID-19 ile enfekte olmuş bireylerin zamanında teşhis edilip izole edilmesinde yararlı olmaktadır (Singh et al., 2020). Yumuşak dokuların X-ray'lerde doğru bir şekilde ayırt edilememesi ve COVID-19 görsel bulgularının BT görüntülerinde X-ray'lere göre daha net ve anlaşılır olması nedeniyle BT görüntüler tercih edilmektedir.

Göğüs radyolojik verilerinden COVID-19'u tespit etmek yeni vaka sayılarının artış hızı nedeniyle zaman alıcı ve oldukça zahmetli bir iş yükü haline gelmektedir. Aynı zamanda çok büyük bir veri yığını içerisinde görsel bulguların değerlendirilmesi insan hatalarına

elverişli bir zemin oluşturmaktadır. Bu nedenlerle, radyologların iş yükünün azaltılması ve teşhislerin yüksek başarımlarıyla gerçekleştirilmesi için makine öğrenmesi yöntemlerine başvurulmaktadır. Özellikle, son yıllarda derin öğrenme mimarilerinden olan evrimsel sinir ağlarındaki (CNN) başarılı çalışmalar, bu mimarinin tıp alanında da yaygın olarak kullanılmasına yol açmıştır (Bakator & Radosav, 2018; Esteva et al., 2021).

Bu kapsamda COVID-19'un göğüs radyolojik verileri üzerinden tespitinde derin öğrenme modellerine dayalı çalışmalar literatürde yoğun ilgi görmektedir. Çünkü bu modellere dayanan yaklaşımlar hızlı, güvenilir ve otomatik analizlere olanak sağlamaktadır (Panwar et al., 2020).

Bu tez çalışmasında COVID-19'un akciğer BT'leri üzerinden hızlı ve güvenilir olarak tespit edilebilmesi için derin öğrenme temelli yaklaşımlar sunulmuştur. Yaklaşımlar iki ana izlemde incelenmiştir. Birinci izlemde; Basit-CNN ve VGG16 mimarileri kullanılarak COVID-19 tespiti gerçekleştirilmiştir. Bu yaklaşımda evrimsel sinir ağlarında katman derinliğinin doğruluğa olan etkisi gözlemlenmiştir. İkinci izlemde ise üç ayrı derin transfer öğrenme mimarisi kullanılarak COVID-19 tespiti yapılmıştır. Her iki izlemdeki mimarilerin başarımlarını incelemesi bu tez kapsamında oluşturulan COVID-19 pozitif ve COVID-19 negatif bireylerin akciğer bilgisayarlı tomografilerini içeren bir veri kümesi üzerinde gerçekleştirilmiştir.

2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI

2.1. Derin Öğrenme Çalışmaları

Düşünme, öğrenme ve karar verme gibi insani özelliklerin mühendislik uygulamalarına aktarımı, makine öğrenmesi adıyla uzun yıllardır ilgi gören ve gittikçe popülerliğini arttıran bir alandır (Goldberg, D. E., & Holland, 1988; Quinlan, 1986). Bir makinenin insan gibi öğrenmesini sağlamak için insan beynindeki sinir hücrelerinin çalışma mantığından faydalanılmaktadır. Bu amaçla 1943 yılında ilk kez biyolojik sinir sistemi fonksiyonlarına karşılık gelen yapay mantıksal bir modelleme gerçekleştirilerek yapay sinir ağlarının (YSA) temelleri oluşturulmuştur (Pitts & McCulloch, 1943). Böylece insanın öğrenmesini sağlayan sinir hücreleri matematiksel olarak modellenmiştir. Sayısallaştırılan hücrelerin beraber çalışması ve nöronların gücünün artırılması gibi bazı ihtiyaçlar ortaya çıkmıştır. 1949 yılında ortaya konulan “Hebbian Öğrenme” bu ihtiyaçları çözümlenmeye yönelik kuralların temelini oluşturmuştur. 1957’de tek bir nörondan oluşan yapay sinir ağının ilk uygulaması olan algılayıcı (perceptron) tasarlanmıştır (Rosenblatt, 1958). Böylece yapay sinir ağlarının tarihsel üç dalgasından birincisi yani temellerinin oluşturulduğu sibernetik (cybernetics) süreç sona ermiştir (Goodfellow et al., 2016; Hebb, 1949). Başlangıçta umut vadeden bu modelin doğrusal olmayan verilerle çalışmaması, örneğin Özel Veya (XOR) işlevini öğrenememesi, yapay sinir ağlarının karanlık döneme girmesine sebep olmuştur (Minsky & Papert, 1969). 10 yıllık duraklama dönemi sonrasında 1980 yılında çağdaş evrimsel sinir ağlarına temel olacak yüksek görsel örüntü tanıma becerisine sahip Neocognitron mimarisi geliştirilmiştir (Fukushima, 1980). 1986’da geriye yayılım (back propagation) algoritması detaylı olarak tanımlanmıştır (Rumelhart et al., 1986). Geriye yayılım algoritmasının uygulanması ile yapay sinir ağlarında çok katmanlı yapılar popülerlik kazanmıştır. 1980’li yıllarda gerçekleşen bu çalışmalar yapay sinir ağlarının ikinci dalgası olan bağlantıcılık (connectionism) dönemini oluşturmaktadır. Bu dalgada gerçekleştirilen çalışmalar ve elde edilen kavramlar derin öğrenmenin temelini oluşturmuştur. 2006 yılında çok katmanlı yapıları içeren çalışmalarla yapay sinir ağlarının üçüncü dalgası olan derin öğrenme başlamıştır (G. E. Hinton & Salakhutdinov, 2006; Geoffrey E. Hinton et al., 2006). Derin öğrenme, görüntü verilerinden nesne tanıma ve algılama, konuşma

tanıma gibi pek çok farklı alanda ve karmaşık problemde başarılı sonuçlar vermektedir (Bengio, 2009; G. E. Hinton & Salakhutdinov, 2006; Lecun et al., 2015).

Evrışimsel sinir ağları, derin öğrenmenin kullanıldığı nesne tanıma, görüntü işleme, dil işleme gibi projelerde sıklıkla kullanılan bir tür sinir ağıdır. Klasik sinir ağlarından en büyük farkı verilerin uzamsal özelliklerini koruması ve görüntülerin özelliklerini çıkartmasıdır. Dolayısıyla karmaşık görüntü gibi zor girdi verilerine karşı dayanıklıdır. Evrışimsel sinir ağlarının ismi ağ katmanları arasında yer alan ve evrişim (convolution) işlevini gerçekleştiren katmandan gelmektedir.

Lecun ve diğerleri, ticari amaçla pratikte kullanılan ilk CNN ağı olan LeNet-5'i oluşturmuşlardır. İki boyutlu girdi şekillerinin değişkenliklerine karşı tasarlanmış olan LeNet-5 ile el yazısı karakter tanıma uygulaması gerçekleştirmişlerdir. Çalışmalarında LeNet-5'in klasik makine öğrenmesi algoritmalarına göre daha yüksek başarımlarını göstermişlerdir (LeCun et al., 1998).

Bir sonraki dönüm noktası ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) kapsamında ortaya atılan AlexNet ile gerçekleştirilmiştir. Bu yarışmada büyük ölçekli bir veri tabanı üzerinden nesne algılama ve görüntü sınıflandırma alanında yüksek başarı elde etmek amaçlanmaktadır. AlexNet daha önceki denemelere göre çok küçük hata oranları vererek bu yarışmayı kazanmıştır (Krizhevsky et al., 2012). AlexNet üzerinde hiperparametre ayarı yaparak Zeiler ve Fergus, ZFNet adını verdikleri mimari ile model başarısını arttırmışlardır (Zeiler & Fergus, 2014). Simonyan ve Zisserman, Visual Geometry Group bünyesinde geliştirdikleri VGGNet ile ağ derinliği ve katman yapılarındaki değişikliklerle sınıflandırma başarısını arttırmışlardır (Simonyan & Zisserman, 2015).

Mimari derinliği ile başarımlarını gözlemleyen ve yine yüksek başarımlar elde eden bir diğer çalışma da GoogleNet olmuştur (Szegedy et al., 2015). VGGNet ve GoogleNet ile mimari derinliğinin başarımlar üzerindeki etkisi kanıtlanmıştır. Bununla birlikte, ağın derinleşmesi eğitimin zorlaşmasına sebep olmaktadır. Bu zorluğun giderilmesi amacıyla ResNet mimarisi önerilmiştir. Bu mimari yeni bir öğrenme çerçevesine sahip 152

katmanlı bir derin evrişimli sinir ağı içermektedir (Sangeetha & Prasad, 2006). Tüm bu çalışmalar sonucunda elde edilen yüksek başarılı CNN mimarileri literatürde çok geniş bir yelpazede uygulama alanına sahip olmuştur.

2.2. Tıbbi Görüntüleme

ABD Gıda ve İlaç Dairesinin (FDA) tanımına göre tıbbi görüntüleme “ tıbbi durumları teşhis etmek, izlemek veya tedavi etmek amacıyla insan vücudunu görüntülemek için kullanılan birkaç farklı teknolojiyi ifade eder. Her teknoloji türü, vücudun incelenen veya tedavi edilen alanı hakkında olası hastalık, yaralanma veya tıbbi tedavinin etkinliği ile ilgili farklı bilgiler verir.” şeklinde ifade edilmektedir. Tüm tıbbi görüntüleme yöntemlerinde genel amaç; tümör, hastalıklı doku, kemik dokularında bulunan kırıklar gibi ilgilenilen durumun kontrast yardımı ile görünür hale getirilmesidir. Böylece bir doktor, radyolog tarafından incelenebilmesi ve teşhis edilebilmesi kolaylaşmaktadır. Tıbbi görüntülemenin temeli 1895 yılında CW Röntgen tarafından X-ışınlarının keşfedilmesine dayanmaktadır. X-ışını görüntüleme yönteminde insan vücudundan geçirilen X-ışınının bir kısmı iç dokular tarafından emilir, bir kısmı saçılır geri kalan kısmı ise detektöre iletilir. İlk zamanlarda hassasiyeti oldukça düşük olan tek bir görüntü için bile pozlama süresi çok uzun zaman almaktaydı. Bununla birlikte X-ışınlarının insan vücudu üzerindeki zararlı iyonlaştırıcı radyasyon gibi biyolojik etkileri tam olarak bilinmemekteydi. Tüm bu olumsuzluklara rağmen X-ışını görüntüleme, uzunca bir süre tanı prosedürlerinde insan vücudu içerisinde görüntü sağlamanın tek yolu olarak kullanılmıştır. Tıbbi görüntüleme yöntemlerindeki ilerlemeler, dijital bilgisayarlar ve veri işleme alanlarında gerçekleşen gelişmeler ile birlikte hız kazanmıştır.

Bir sonraki büyük gelişme 1972’de Geoffrey Hounsfield tarafından X-ışını görüntülemeye düzlemsel yerine kesitsel görüntüler alınmasını sağlayabilen bilgisayarlı tomografinin (BT) keşfedilmesi olmuştur. BT, X-ışını yayan dedektörlerin insan vücudu üzerinde hareket ederken organların ve dokuların enine kesit görüntülerini alarak çalışmaktadır. Bu iki önemli gelişmenin ardından bilgisayarlı görüntüleme ve görüntü işleme yöntemleri yardımı ile radyolojik verilerin incelenmesi, teşhis ve tedavi planlanması kolaylaşmıştır. (FDA, 2018, 2019; Haidekker, 2014; Hounsfield, 1973)

2.3. Tıbbi Görüntülemelerde Derin Öğrenme Çalışmaları

Derin öğrenme, X-ray, MRI, PET, BT gibi tıbbi görüntüler üzerinden bilgisayar destekli hastalık tespiti amacıyla kullanılan yöntemlerin başında gelmektedir. Lezyonların görsel analizi gibi hastalığın teşhisine yönelik yardımcı uygulamalar ile radyologların tanı koyma görevini kolaylaştırabilmektedir. Derin öğrenme literatüründe nesne tanıma ve bilgisayarlı görme görevi yürütülen çalışmalarda insan performansı ile yarışabilecek sonuçlar elde edilmiştir (Kim et al., 2019).

Tıbbi görüntülerin elde edilmesi ve bilgisayara aktarılabilmesi ile otomatik analiz yapan sistemlerin oluşturulması popüler bir çalışma alanı olmuştur. Bu alanda ilk tıbbi görüntü analizleri birleşik kural tabanlı bir sistem oluşturmak için düşük seviyeli piksel işlemenin ardından matematiksel modellemenin uygulanması ile gerçekleştirilmiştir. Aynı zamanda yapay zekada da bu kural tabanlı görüntü işleme sistemine benzer bir yapı bulunmaktadır. Eski moda sistemler (GOFAI) olarak adlandırılan bu sistemlerin temelinde if-then-else gibi kurallar mevcuttur (Haugeland, 1985). 1990 yılının sonlarında bölütleme için kullanılan aktif şekil modelleri, bilgisayar destekli algılama ve teşhis için öznitelik çıkarımı ve istatistiksel sınıflandırıcılar gibi denetimli teknikler medikal görüntü analizinde çokça tercih edilmektedir. Bahsedilen tekniklerde en önemli nokta medikal görüntüler üzerinden ayırt edici özelliklerin çıkarılmasıdır. Bilgisayarın verileri en iyi şekilde temsil eden özniteliklerin çıkarımını yapması, görüntü analizlerindeki en önemli gelişmelerden biridir ve derin öğrenme yaklaşımlarının temelini oluşturmuştur. Derin öğrenme, girdi verileri çıkış katmanına doğru ilerlerken her katmanda daha yüksek seviyeli özelliklerin öğrenildiği çok katmanlı ağ yapısından oluşmaktadır. Görüntü analiz çalışmalarında en yüksek başarı gösteren derin öğrenme modeli evrişimli sinir ağları (CNN) olmuştur. CNN modelleri üzerindeki çalışmalar 1970 yıllarının sonlarından beri gerçekleştirilirken 1995 yılında tıbbi görüntüler üzerinde de kullanılmaya başlanmıştır (Fukushima, 1980; Lo et al., 1995; Litjens et al., 2017).

Derin öğrenme yöntemleri, radyolojik görüntüler üzerinde sınıflandırma, tespit, bölütleme, yerleştirme gibi problemlerde yaygın olarak kullanılmaktadır. Sınıflandırma, tespit ve bölütleme literatürde çokça üzerinde çalışılmış tıbbi görüntü

işleme problemleri olarak karşımıza çıkmaktadır (Ker et al., 2017). Bu alanda gerçekleştirilen çalışmalar bölümün devamında sunulmuştur.

2.3.1. Sınıflandırma

Sınıflandırma, derin öğrenmenin tıbbi görüntü analizinde büyük katkılarının bulunduğu alanlardan biridir. Tıbbi görüntüleme X-ray, bilgisayarlı tomografi (BT), manyetik rezonans görüntüleme (MRI) gibi radyolojik görüntüler üzerinden görüntü sınıflandırması; nesne veya lezyon sınıflandırma amacıyla kullanılmaktadır. Tıptaki tüm bilim dallarında yaygın olarak tercih edilmektedir ve tıbbi teşhise destek sağlamaktadır (Ker et al., 2017; Litjens et al., 2017).

Literatürde çok farklı hastalıkların sınıflandırılmasında derin sinir ağlarının kullanıldığı ve başarılı sonuçlara sahip olduğu pek çok çalışma mevcuttur. Örneğin nöroloji alanında Hosseini ve diğerleri, üç boyutlu CNN mimarisi ile beyin MRI görüntüleri üzerinden Alzheimer hastalığını 0,99 doğrulukla tespit etmişlerdir (Hosseini-Asl et al., 2018). Göz hastalıkları alanında ise Pratt ve diğerleri, diyabetik retinopatiye sahip bireyler arasında hastalığın beş farklı şiddet seviyesinin sınıflandırılmasını göz fundusunun dijital fotoğraflarını içeren görüntü kümesi üzerinden 0,75 doğrulukla gerçekleştirmişlerdir (Pratt et al., 2016). Literatürde göğüs hastalıkları alanında gerçekleştirilen çalışmalar tıbbi görüntü türleri açısından BT ve X-ray kullanılan çalışmalar olarak gruplandırılabilir. X-ray kullanılan çalışmalara örnek olarak, Rajpurkar ve diğerleri göğüs röntgenleri üzerinden 14 farklı akciğer hastalığının sınıflandırmasını gerçekleştirmişlerdir. Çalışmada DenseNet mimarisi olan ChexNet kullanılmış ve pnömöni sınıflandırmasını 0,76'lık bir AUC değeri ile elde etmişlerdir (Rajpurkar et al., 2017). BT kullanılan çalışmalara örnek olarak ise, Nardelli ve diğerleri, göğüs BT görüntüleri üzerinden damarlar için arter-ven sınıflandırması yapmışlardır. Çalışmada CNN kullanılmış ve 0,94'lük bir genel başarıya ulaşmışlardır (Nardelli et al., 2018). Patoloji alanında ise derin öğrenme çalışmaları histopatolojik görüntülerin sınıflandırılmasında kullanılmaktadır. Kumar ve diğerleri 20 farklı doku sınıfına ait histopatolojik görüntü üzerinde Alexnet ve VGGNet modelleri ile 0,95 sınıflandırma doğruluğuna ulaşmışlardır (Kumar et al., 2017).

2.3.2. Tespit

Tıbbi görüntüler üzerinden tespit işlemleri organ, nesne, lezyon ve önemli bölge tespiti olarak örneklendirilebilir. Hastalıkların teşhisinde ve tedavisinde bir lezyonun tespitindeki doğruluk ciddi bir öneme sahiptir. Bu nedenle bilgisayar destekli algılama çalışmaları tıbbi görüntüler üzerinde derin öğrenmenin kullanıldığı önemli alanlardan biridir. Literatürdeki çalışmalar birçok tıbbi bilim dalının bu uygulamalardan destek sağladığını göstermektedir.

Esteva ve diğerleri dermoskopik görüntüler üzerinde iyi huylu, kötü huylu veya neoplastik olmayan lezyon tespitinde CNN mimarisi ile 0,72'lik bir doğruluk oranı elde etmişlerdir (Esteva et al., 2017). Cireşan ve diğerleri, göğüs histolojisi görüntülerinde mitotik figür tespit etmek amacıyla 11-13 katmana sahip CNN modeli kullanmışlar ve ICPR 2012 mitoz tespit yarışmasını kazanmışlardır (Cireşan et al., 2013). Sirinukunwattana ve diğerleri, çalışmalarında kolorektal adenokarsinom görüntülerinden çekirdek merkezlerinin tespit edilmesi için uzamsal regresyon ve çevreleyen uzamsal bağlamı kullanan CNN yaklaşımı önermişlerdir ve 0,80'lik F1-skor değeri elde etmişlerdir (Sirinukunwattana et al., 2016). Göğüs hastalıkları alanında gerçekleştirilen çalışmalarda X-rayler ve BT'ler sıklıkla kullanılmaktadır. Literatürde yer alan çalışmalar bu iki tıbbi görüntüleme yönteminin önemini vurgulamaktadır. Lo ve diğerleri göğüs röntgenlerinden nodül tespiti için 2 gizli katmana sahip CNN kullanmışlardır (Lo et al., 1995). Akciğer BT görüntüleri üzerinden kanserli nodül tespiti için düzenlenen Kaggle Data Science Bowl yarışmasında Liao ve diğerleri en iyi başarıya sahip sonuçlarla yarışmayı kazanmışlardır (Liao et al., 2017). Setio ve diğerleri BT akciğer taramalarından pulmoner nodül tespiti için bir CNN modeli önermişlerdir (Setio et al., 2016). Aynı amaçla Dou ve diğerleri çok düzeyli bağlamsal üç boyutlu CNN modeli ile çalışma gerçekleştirmişlerdir (Dou et al., 2017). Her iki çalışmada klasik makine öğrenmesi yöntemlerine göre yüksek doğruluklar elde edilmiştir. Shin ve diğerleri ise iki önemli bilgisayar destekli algılama sorununu ele almışlardır. İnterstisyel akciğer hastalıklarını ve lenf düğümlerini saptamak için AlexNet-CNN, Cifar-CNN ve GoogLeNet-CNN modelleri gibi genişliği ve derinliği değişken olan beş CNN modeli kullanarak yüksek başarımlar elde etmişlerdir (Shin et al., 2016).

2.3.3. Bölütleme

Bölütleme elle yapıldığında zaman alıcı ve zahmetli bir süreçtir. Bu nedenle derin öğrenme yöntemleri ile otomatik olarak bölütleme yapılması iş yükünün azalması açısından önemli gelişmelerden biri olmuştur. Bölütleme çalışmaları BT ve MRI görüntüleri üzerinde sıklıkla kullanılmaktadır. Akciğer, karaciğer, kalp gibi çeşitli organların; tümör, kanama gibi birçok farklı dokuların bölütlenmesi için kullanılmaktadır.

Pek çok biyomedikal bölütleme uygulamasında gösterdiği başarımla tercih edilen U-Net, Ronneberger ve diğerleri tarafından önerilmiştir (Ronneberger et al., 2015). U-Net ile birlikte tekrarlayan evrişimli sinir ağları da (RNN) bölütleme çalışmalarında sıklıkla kullanılmaktadır. Xie ve diğerleri bu yöntemi histopatolojik görüntüler üzerinde kullanmışlardır (Xie et al., 2016). Moeskops ve diğerleri, MRI beyin görüntülerinin beyaz madde, gri madde gibi bir dizi doku sınıflarına bölütlenmesi için paralel olarak çalışan 3 farklı CNN modeli kullanmışlar ve 0,82 ile 0,87 arasında zar benzerlik katsayı değerine ulaşmışlardır (Moeskops et al., 2016). Milletari ve diğerleri MRI prostat görüntülerinin bölütlenmesi için 3-boyutlu CNN kullanarak 0,87 zar benzerlik katsayı değeri elde etmişlerdir (Milletari et al., 2016). Lezyon bölütlemesine örnek olarak Brosch ve diğerleri U-Net benzeri bir mimari ile multipl skleroz (MS) lezyonlarının bölütlenmesini gerçekleştirmişlerdir (Brosch et al., 2016).

2.4. Akciğer Bilgisayarlı Tomografiler Üzerinde Derin Öğrenme Uygulamaları

Akciğer hastalıklarının tespit ve tedavisinde göğüs radyografisi en önemli muayene aşamalarından biridir. Radyolog tarafından değerlendirilmiş bir tıbbi görüntü doktorlara hastalığın teşhisinde büyük kolaylık sağlamaktadır. Değerlendirilecek tıbbi görüntünün türü akciğerde incelenmesi istenen bulgulara göre değişiklik gösterebilmektedir. Röntgen cihazlarının erişilebilirliğinin kolay olması, çekim süresinin kısa olması ve değerlendirme aşamasının hızlı gerçekleşmesi gibi avantajları dolayısıyla X-ray görüntüleri akciğer hastalıkları tanısında her zaman tipik olarak kullanılan ilk görüntüleme yöntemidir. Fakat üç boyutlu BT görüntüleri kadar hassasiyete sahip değildir. Dolayısıyla literatürde

akciğer hastalıklarının derin öğrenme yaklaşımları ile tespit edilmesi, sınıflandırılması, bölütlenmesi çalışmalarında BT'ler sıklıkla tercih edilmektedir. Özellikle BT'ler üzerinden interstisyel akciğer hastalıklarına işaret eden dokusal örüntülerin tespiti de popüler bir araştırma konusudur.

Charbonnier ve diğerleri tomografilerden hava yolu segmentasyonu ve sızıntı tespiti sınıflandırması yapmışlardır. Çalışmada evrışimsel sinir ağı kullanmışlardır (Charbonnier et al., 2017). Ciompi ve diğerleri pulmoner perifissural nodüller üzerinde sınıflandırma probleminde çözüm olarak önceden eğitilmiş bir CNN mimarisi kullanmışlardır (Ciompi et al., 2015). Tarando ve diğerleri akciğer BT'leri üzerindeki hastalığa ait örüntülerden faydalanarak sınıflandırma yapabilmek için CNN mimarisi ile bilgisayar destekli bir teşhis çalışması gerçekleştirmişlerdir (Tarando et al., 2016). Anthimopoulos ve diğerleri interstisyel akciğer hastalıklarında dokusal sınıflandırma yapabilmek için bir CNN mimarisi önermişlerdir. Tespit edilen dokuları sağlıklı, buzlu cam opaklığı (GGO), mikrolezyon, konsolidasyon, ve GGO/retikülasyon çıktılarına göre sınıflandırmışlardır (Anthimopoulos et al., 2016).

Shen ve diğerleri, BT akciğer taramalarından tanısal akciğer nodülü sınıflandırması için çok ölçekli evrışimli sinir ağlarını (MCNN) kullanmışlardır. Her birinde 2 evrışim katmanı bulunan paralel 3 CNN ile malign ve iyi huylu nodülleri 0,86 doğrulukla sınıflandırmışlardır (Shen et al., 2015).

Akciğer bilgisayarlı tomografileri birçok akciğer hastalığı hakkında önemli görsel bilgiler içermektedir. Literatürde bu görüntüleri kullanarak akciğer hastalıklarının tespitinin yapıldığı pek çok çalışma mevcuttur. 2019 yılında ortaya çıkan ve pandemi haline gelen COVID-19'da bu literatürde yerini almıştır.

2.5. COVID-19'un Arka Planı

Şiddetli akut solunum sendromu (SARS) ilk olarak 2002 yılında ortaya çıkan, bulaşıcılığı ve öldürme oranının yüksekliği ile 21. yüzyılda dünya sağlığını tehdit eden küresel bir salgın hastalıktır. Bu hastalığa sebep olan mikroorganizma; solunum yolu enfeksiyonları,

gastroenterit gibi insanlarda ve hayvanlarda çeşitli hastalıklara sebep olan koronavirüslerin yeni bir türü olarak tanımlanmıştır. Virüsler, öksürme, hapşırma esnasında oluşan damlacıklar ile insandan insana bulaşabilmektedir. (Chan-Yeung et al., 2003; Peiris et al., 2020; WHO, 2003).

Şiddetli akut solunum sendromu koronavirüsü-2 (SARS-CoV-2) olarak adlandırılan yeni tür koronavirüs ise Aralık 2019'da Çin'in Wuhan kentinde ortaya çıkmıştır. Hastalık enfekte damlacıklarla bulaşmaktadır ve 2-14 gün süren kuluçka süresine sahiptir. Semptomları ateş, halsizlik, yorgunluk, nefes darlığı, boğaz ağrısı ve öksürük gibi şikayetlerdir. Hastalık bir kısım insanda asemptomatik olarak seyredebilirken bir kısmında ise pnömoni, akut solunum sıkıntısı (ARDS), çoklu organ yetmezliği ve ölüm gibi çok ciddi durumlara yol açabilmektedir (Singhal, 2020).

COVID-19 virüsüne sahip kişilerle temasta bulunulması, hastalığa ait belirgin semptomların görülmesi, akciğer radyografilerinde COVID-19 belirtilerinin varlığı kişinin COVID-19 şüphelisi olarak değerlendirilmesine sebep olmaktadır. Kişinin enfekte birey olduğunu doğrulamak için teşhis edilmesi gerekmektedir.

2.5.1. COVID-19'un laboratuvar tabanlı teşhisi

COVID-19 ile enfekte olmuş bireyler semptomatik veya asemptomatik olabilmektedir. Bir kişinin enfeksiyon durumunun doğrulanması için moleküler RT-PCR sürüntü testleri, hızlı antijen veya antikör testleri ve serolojik testler gibi laboratuvar tabanlı üç ana test yöntemi kullanılmaktadır.

Gerçek zamanlı polimeraz zincir reaksiyonu testleri (RT-PCR), viral RNA tespiti ile COVID-19 tanı doğrulaması gerçekleştiren standart bir yöntem olarak kabul edilmektedir (Da Silva et al., 2020). RT-PCR testleri genel olarak 4-8 saat aralığında sonuçlanmaktadır, dolayısıyla bir kişinin pozitif veya negatifliğini göreceli olarak kısa bir sürede belirlemektedir. PCR yönteminde boğaz sürüntüsü, nazofaringeal sürüntü gibi solunum yolu numuları ile kişinin koronavirüs taşıyıp taşımadığı belirlenmektedir. Her seviyedeki hastane laboratuvarlarında uygulanabilmesi yani kolay erişilebilirliği

sayesinde Aralık 2019'dan günümüze kadar yaygın olarak kullanılan birincil tespit yöntemidir. Fakat hastalığın erken evrelerinde yanlış-pozitif veya yanlış-negatif sonuçlar vermesi, düşük viral yüke maruz kalmış olan asemptomatik bireylerin negatif çıkması, alınan örneklerin kalitesinin düşük olması, kontaminasyon gibi teknik olumsuzluklara sahiptir.

Kan numuleri üzerinden yapılan diğer spesifik olmayan testlerde bazı önemli kan değerlerinin yüksek veya düşük olması COVID-19 enfeksiyonunun belirtileri olabilmektedir (Singhal, 2020).

2.5.2. COVID-19'un tıbbi görüntüleme tabanlı teşhisi


RT-PCR testi COVID-19 pozitif bireylerin tespitinde standart yöntemlerden biri olmasına rağmen, sahip olduğu teknik yetersizlik ve olumsuzluklardan dolayı bazı destek yöntemlerine ihtiyaç duyulmaktadır. BT ve X-ray gibi tıbbi görüntüleme teknikleri bu nedenle ilk olarak yardımcı yöntemler olarak kullanılmaya başlanmıştır. Gerçekleştirilen çalışmalarda bu yöntemlerin birincil tanı yöntemi olmasını destekleyici duyarlılık seviyeleri elde edilmiştir. Dolayısıyla X-ray ve BT'ler COVID-19'un tespitinde önemli bir kullanım kapasitesine ulaşmıştır (Loddo et al., 2021).

Göğüs X-ray'leri üzerinden COVID-19 tespiti, X-ray cihazlarının her seviyedeki sağlık kuruluşunda bulunması dolayısıyla daha ulaşılabilir ve daha az maliyetlidir. Aynı zamanda düşük radyasyon yüküne sahiptir bu nedenle yüksek kullanılabilirlik avantajı bulunmaktadır (Ghaderzadeh & Asadi, 2021). Akciğer bilgisayarlı tomografileri ise buzlu cam opaklığı ve alt segmental konsolidasyonu gibi daha spesifik görsel göstergeleri çok daha hassas bir şekilde gösterebilmektedir. Hafif veya asemptomatik enfekte bireylerde bile BT görüntüleri anormal olarak gözlemlenmektedir. Bu nedenle negatif test sonucuna sahip kişilerde bile BT yardımı ile COVID-19 teşhisi yapılabilmektedir. Bu durum BT'lerin COVID-19'un akciğer belirtileri üzerinde çok daha hassas olduğunu kanıtlar niteliktedir.

BT'lerde COVID-19 bulguları hasta profiline göre farklılar göstermektedir. Bu farklılıklara rağmen yaygın olarak gözlemlenen ve teşhiste kullanılan bazı görsel özellikler aşağıda verilmiştir (Y. H. Jin et al., 2020).

1. Lezyonların dağılımı (esas olarak bronşiyal vasküler demetler boyunca subplevral) - periferik veya peribronkovasküler varlığı
2. Buzlu cam veya konsolidatif opaklıklardan etkilenen lob sayısı
3. Lezyonların miktarı (genellikle üç veya daha fazla lezyon, ara sıra tek veya çift lezyon)
4. Lezyon şekilleri (düzensiz, büyük blok, nodüler, topaklı, petek benzeri veya ızgara benzeri, vb.)
5. Lezyonların yoğunluğu (çoğunlukla düzensiz, buzlu cam opaklığının (GGO) , konsolidasyonun varlığı)
6. İç yapılar (interlobüler septal kalınlaşmanın , hava bronkogramı varlığı)
7. Fibrotik lezyonların varlığı
8. Nadir plevral efüzyon ve lezyonda vasküler genişlemenin varlığı
9. Amfizem, interstisyel akciğer hastalığı tüberküloz, gibi altta yatan akciğer hastalığının varlığı

Şekil 2.1'de akciğer BT'lerinde ki bazı COVID-19 belirtilerine ait örnekler gösterilmektedir. Bu göstergelerin BT'ler üzerinde gözlemlenmesi doktorların hastalar için teşhiste bulunmasına yardımcı olmaktadır (Da Silva et al., 2020; Falzone et al., 2021; Y. H. Jin et al., 2020; Singhal, 2020).



Şekil 2.1. COVID-19'lu bir hastanın akciğerlerinin BT'sindeki GGO belirteçleri

2.6. Akciğer Bilgisayarlı Tomografiler Üzerinde COVID-19 Tespiti İçin Derin Öğrenme Uygulamaları

Literatürde COVID-19'un tespiti amacıyla BT görüntüler üzerinde derin öğrenme mimarilerinin kullanıldığı pek çok çalışma yer almaktadır. Bu çalışmalar problemi ele alış yaklaşımlarına göre iki grupta toplanabilir; ikili sınıflandırma ve çoklu sınıflandırma. İkili sınıflandırmalarda genellikle COVID-19/Normal veya COVID-19/Bakteriyel Pnömoni şeklinde iki sınıf kullanılmaktadır. Çoklu sınıflandırmada ikili sınıflandırmadaki sınıfların yanına toplum kökenli pnömoni (CAP), influenza A/B gibi diğer hastalık sınıfları eklenerek sayı arttırılmaktadır. Literatür üzerinde gerçekleştirilen incelemeler sınıflandırma yaklaşımları açısından analiz edilerek ikili sınıflandırma ve çoklu sınıflandırma başlıkları altında sunulmuştur.

2.6.1. İkili sınıflandırma

S. Wang ve diğerleri M-Inception V3 modeli ile transfer öğrenme kullanarak harici test veri kümesinde toplam 0,79 doğruluk değeri elde etmişlerdir (S. Wang et al., 2021).

Song ve diğerleri COVID-19'u tespit edebilmek için bir tanı sistemi oluşturmuşlardır. VGG16, DenseNet, ResNet ile DRE-Net adında ResNet50 temelli yeni bir mimari kullanmışlardır. COVID-19 ve bakteriyel pnömoni sınıflandırmasında sırasıyla 0,84; 0,82; 0,86; 0,86 doğruluk değerleri elde etmişlerdir. COVID-19 ve sağlıklı birey sınıflandırmasında ise 0,90; 0,92; 0,92 ve 0,94 doğruluk değerlerine ulaşmışlardır (Song et al., 2021).

Shah ve diğerleri, VGG16, DenseNet-169, ResNet-50, InceptionV3, VGG19 ile ve CTnet-10 adında yeni bir mimari kullanmışlardır. Elde edilen sonuçlarda CTnet-10 mimarisi ile 0,82 doğruluk değeri elde edilirken VGG19 ile 0,94 doğruluk değerine ulaşılmıştır (Shah et al., 2021).

Gifani ve diğerleri, önceden eğitilmiş 15 CNN mimarisi; EfficientNets(B0-B5), NasNetLarge, NasNetMobile, InceptionV3, ResNet-50, SeResnet 50, Xception,

DenseNet121, ResNext50 ve Inception_resnet_v2 kullanmışlardır. Daha iyi sonuçlar elde edebilmek için transfer öğrenme yöntemi ve en iyi mimari kombinasyonu için topluluk öğrenme yöntemini kullanmışlardır. Çalışmalar sonucunda en iyi beş doğruluk değeri, EfficientNets B0 0,82; EfficientNets B3 0,76; EfficientNets B5 0,82; Inception_resnet_v2 0,77; Xception 0,74 biçiminde elde edilmiştir. Bu beş derin transfer öğrenme mimarisi ile gerçekleştirilen topluluk öğrenme yöntemi sonucunda ise 0,85 doğruluk değerine ulaşılmıştır (Gifani et al., 2021).

Harmon ve diğerleri, COVID-19 ve normal birey sınıflandırmasında üç boyutlu derin evrişimsel mimari ile 0,91 doğruluk elde etmişlerdir (Harmon et al., 2020).

Xu ve diğerleri, transfer öğrenme ile önceden eğitilmiş ResNet18 mimarisi kullanarak 0,86 doğruluk değerine ulaşmışlardır (Xu et al., 2020).

B. Wang ve diğerleri, önceden eğitilmiş CNN mimarileri olarak ResNet-50, InceptionV3, DPN-92 (Dual path network), 3D U-Net++ ve Attention ResNet-50 kullanmışlardır. 3D U-Net++ ve ResNet-50 birleşik modeli ile 0,97 doğruluk değeri elde etmişlerdir (B. Wang et al., 2020).

Chen ve diğerleri, U-Net++ mimarisi ile bölütleme yaptıktan sonra önceden eğitilmiş ResNet50 mimarisi ile sınıflandırma yaparak 0,95 doğruluk değerine ulaşmışlardır (Chen et al., 2020).

Polsinelli ve diğerleri, COVID-19 ve sağlıklı birey sınıflandırması için SqueezeNet temelli bir CNN kullanarak 0,83 doğruluk değeri elde etmişlerdir (Polsinelli et al., 2020).

Loey ve diğerleri, BT veri kümesinin boyutlarını arttırmak için klasik veri çoğullama tekniklerinin yanı sıra CGAN kullanmışlardır. AlexNet, VGGNet16, VGGNet19, GoogleNet ve ResNet50 mimarileri ile çalışmışlardır. En iyi başarımları sonucunda 0,83 doğruluk değerine ResNet50 mimarisiyle ulaşmışlardır (Loey et al., 2020).

Rahimzadeh ve diğeri, CNN'lerin sınıflandırma doğruluğunu arttırmak için ResNet50V2 mimarisi ile birlikte değiştirilmiş öznelik seçim piramit ağını kullanmışlardır. Bu yöntem ile 0,98 doğruluk değeri elde etmişlerdir (Rahimzadeh et al., 2021).

Jangam ve diğeri, heterojen önceden eğitilmiş bir topluluk öğrenme yöntemi önermişlerdir. VGG 19, ResNet 101, DenseNet 169 ve WideResNet 502 transfer öğrenme uygulanmış CNN ağlarını kullanarak COVID-CT veri kümesi üzerinde 0,85 doğruluk değerine ulaşmışlardır (Jangam et al., 2022).

Wang ve diğeri, COVID-pozitif ve COVID-negatif sınıflandırması yapmak için üç boyutlu derin evrişimli bir sinir ağı olan DeCoVNet'i önermişler ve 0,90 doğruluk değeri elde etmişlerdir (X. Wang et al., 2020).

Kogilavani ve diğeri, şüpheli BT görüntüleri üzerinde sağlıklı ve COVID-19 ayırımı yapmak için VGG16, DenseNet121, MobileNet, NASNet, Xception ve EfficientNet derin evrişimsel sinir ağlarını kullanmışlardır. Çalışmalar sonucunda sırasıyla 0,98; 0,98; 0,96; 0,90; 0,92; 0,80 doğruluk değerlerine ulaşmışlardır (Kogilavani et al., 2022).

Maghdid ve diğeri, basit tek konvolüsyon katmanlı CNN ile önceden eğitilmiş bir AlexNet mimarisi kullanmışlardır. Basit CNN için 0,94 doğruluk değeri elde edilirken, AlexNet için 0,82 değerine ulaşılmıştır (Maghdid et al., 2021).

X. Yang ve diğeri, DenseNet-169 ve ResNet-50 gibi CNN ağlarını kendi kendini denetleyen öğrenme ve çok görevli öğrenme gibi algoritmalarla eğiterek 0,89'luk bir doğruluk değerine ulaşmışlardır (X. Yang et al., 2020).

Jaiswal ve diğeri, COVID-pozitif ve COVID-negatif sınıflandırması yapabilmek için bir derin transfer öğrenme (DTL) yöntemi önermişlerdir. Yöntemin temelinde DenseNet201 yer almaktadır. Önerilen modelde doğruluk değeri olarak 0,96 elde edilirken VGG16 ve ResNet modellerinde ise 0,95 doğruluk değerine ulaşmışlardır (Jaiswal et al., 2021).

He ve diğeri, en verimli derin öğrenme yöntemini bulabilmek için Self-Trans adlı kendi kendini denetleyen bir transfer öğrenim yaklaşımı kullanmışlardır. DenseNet-121, DenseNet-169, VGG-16, ResNet-18, ResNet-50, EfficientNet-b0, EfficientNet-b1 ağırları ile yapılan deneyler sonucunda DenseNet-169'u omurga olarak kullanarak Self-Trans yöntemi ile 0,86 doğruluk değerine ulaşmışlardır (He et al., 2020).

S. Yang ve diğeri, COVID-19 ve sağlıklı birey ayırımı yapabilmek için DenseNet algoritmasını kullanarak belirli bir eşik değeri seçimi ile 0,92 doğruluk değeri elde etmişlerdir (S. Yang et al., 2020).

Pathak ve diğeri, derin transfer öğrenme yöntemi kullanarak COVID-19 ile enfekte olmuş birey tespiti yapmışlardır. İlk olarak ResNet50 temelli bir öğrenme gerçekleştirmişlerdir. Bu model ile 0,93 doğruluk değeri elde etmişlerdir (Pathak et al., 2020).

Saeedi ve diğeri, DenseNet-121, ResNet, MobileNet mimarileri ile COVID-19 ve sağlıklı birey sınıflandırması yapmışlar ve iyi sonuçlara DenseNet-121 mimarisi ile ulaşmışlardır. Çalışmalar sonucunda 0,91 doğruluk değeri elde edilmiştir (Saeedi et al., 2020).

2.6.2. Çoklu sınıflandırma

Yousefzadeh ve diğeri, DenseNet, ResNet, Xception ve EfficientNetB0 mimarilerini kullanmışlardır. Sınıflandırmayı COVID-19, COVID-19 olmayan anormal (NCA) ve normal olmak üzere üç sınıflı olarak gerçekleştirmişler ve 0,96 doğruluk değerine ulaşmışlardır (Yousefzadeh et al., 2021).

Hu ve diğeri, COVID-19 tespitini, toplum kökenli pnömoni(CAP), pnömoni olmayan(NP) ve COVID-19 sınıflarının ikili, üçlü kombinasyonları biçiminde gerçekleştirmişlerdir. Değiştirilmiş VGG mimarisi kullanmışlardır. İkili sınıflandırmanın üçlü sınıflandırmaya göre daha yüksek doğruluk değerlerine sahip olduğunu

göstermişlerdir. COVID-19/NP sınıflandırmasında ortalama 0,96 doğruluk değeri elde etmişlerdir (Hu et al., 2020).

Jin ve diğerleri, sınıflandırma problemine çok sınıflı olarak yaklaşmışlardır. Veri kümesi COVID-19, CAP, influenza A/B ve pnömoni olmayan olmak üzere dört sınıftan oluşmaktadır. ResNet 152 temelli iki boyutlu derin evrişimli sinir ağı kullanarak COVID-pozitif ve COVID-negatif sınıflandırmasında 0,95 doğruluk değeri elde etmişlerdir (C. Jin et al., 2020).


3. MATERYAL ve YÖNTEM

3.1. Kullanılan Veri Kümesi


COVID-19'un BT görüntüleri üzerinden derin öğrenme yöntemleri ile tespit edilmesi pandemi süreci boyunca popülerliğini arttırmıştır. Birçok görüntü analizi uygulamasında olduğu gibi bu çalışmalarda da büyük veri kümelerinin elde edilmesinde zorluklar yaşanmaktadır. Dolayısıyla araştırmacılardan bazıları bu konuda paylaşılmış açık kaynaklı veri kümeleri üzerinde çalışmalarını yürütürken bir grup da kendi veri kümelerini oluşturmuştur. Bu tez çalışması kapsamında yeni bir veri kümesi oluşturularak derin öğrenme mimarileri ile COVID-19'un tespiti yapılmıştır.

Veri kümesi hazırlığı iki kurumun katılımıyla çok merkezli retrospektif bir çalışma olarak yürütülmüştür. Birinci merkez, hastalara ait tomografilerin elde edilmesinin ve etiketlenmesinin gerçekleştirildiği Trabzon Kanuni Eğitim ve Araştırma Hastanesinin Enfeksiyon Hastalıkları ve Radyoloji Kliniğidir. İkinci merkez ise verilerin analiz edilmesi, COVID-19 tespiti için derin öğrenme tabanlı bir sistemin geliştirildiği Bursa Uludağ Üniversitesi Elektrik-Elektronik Mühendisliği Bölümüdür. Bu tez çalışmasındaki tüm aşamalar Bursa Uludağ Üniversitesi Tıp Fakültesi Klinik Araştırmalar Etik Kurulu 11/08/2021 tarih 2021-11/3 karar no'lu etik kurul kararı ve SBÜ Trabzon Kanuni Eğitim ve Araştırma Hastanesi Klinik Araştırmalar Etik Kurulu 10/06/2021 tarih 2021/95 karar no'lu etik kurul kararı çerçevesinde gerçekleştirilmiştir.

Hastane arşivinden COVID-19 pozitif tanısı almış bireyler ve virüs belirtisi bulunmayan normal bireylere ait BT görüntülerini içeren bir veri kümesi oluşturulmuştur. Veriler, Eylül 2020 ve Aralık 2021 ayları arasında hastaneye başvuru yapmış olan erişkin bireylerin BT'lerinden oluşmaktadır. COVID-19 sınıfı için hastanenin pandemi servisine yatışı yapılmış COVID-19 bulgularına sahip 1116 adet akciğer bilgisayarlı tomografisi kullanılmıştır. Bu gruba ait akciğer BT örnekleri Şekil 3.1'de verilmiştir. Normal sınıfı için iç hastalıkları kliniğine başvuruda bulunmuş bireylere ait 998 sağlıklı akciğer bilgisayarlı tomografisi kullanılmıştır. Bu gruba ait BT örnekleri ise Şekil 3.2'de verilmiştir.

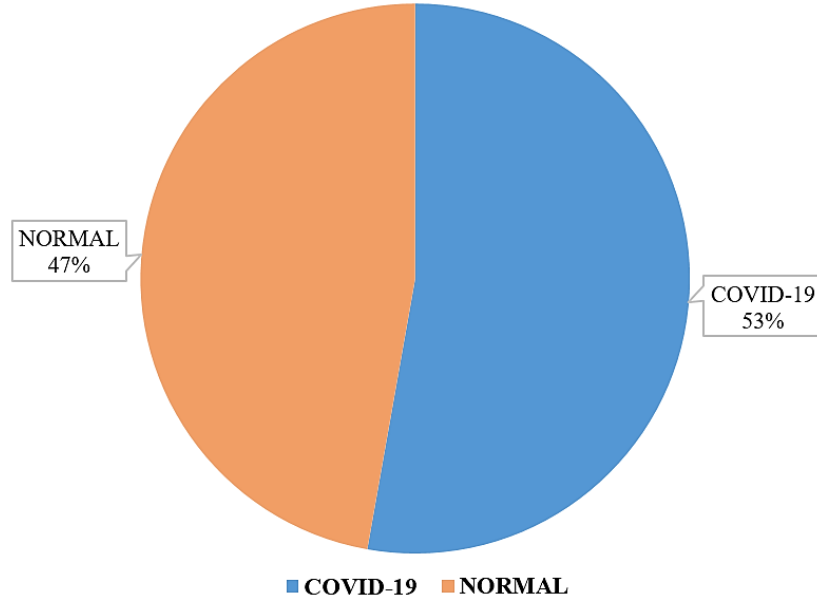


Şekil 3.1. COVID-19 bulgularına sahip BT görüntü örnekleri



Şekil 3.2. COVID-19 bulgularına sahip olmayan BT görüntü örnekleri

Görüntüler 1356x765 piksel boyutlarında PNG (taşınabilir ağ grafiği) formatında düzenlenerek 2114 BT görüntüsü içeren bir veri kümesi hazırlanmıştır. Veri kümesinin sınıflara göre dağılımı Şekil 3.3'te gösterilmiştir.



Şekil 3.3. Veri kümesinin sınıflara göre dağılımı

3.2. Başarım Ölçütleri Ve İstatistiksel Analiz

Kullanılan modellerin başarım değerlendirmesinde ölçüt olarak doğruluk, kesinlik, duyarlılık, özgüllük ve F1-skor kullanılmıştır.

Doğruluk, modelin doğru olarak tahmin ettiği örnek sayısının veri kümesinde yer alan tüm örnek sayısına oranıdır (Denklem 3.1).

Kesinlik, modelin pozitif olarak tahmin ettiği verilerinin doğruluğunu ifade etmektedir. Başka bir deyişle modelin COVID-19 olarak sınıflandırmada ne kadar güvenilir olduğunu yansıtır (Denklem3.2).

Duyarlılık, modelin test verileri üzerinde COVID -19'lu bireyleri doğru olarak tahmin edebilme yeteneği yani doğru pozitif oranıdır (Denklem3.3) .

Özgüllük, modelin test verileri üzerinde sağlıklı bireyleri doğru olarak tahmin edebilme yeteneği yani doğru negatif oranıdır (Denklem3.4).

F1-Skor, kesinlik ve duyarlılığın harmonik ortalamasıdır (Denklem3.5).

Başarım ölçütlerinin hesaplanması için Çizelge 3.1'deki karışıklık matrisi kullanılmaktadır. Çizelgede yer alan Doğru Pozitif (DP), COVID-19'un doğru tahmini; Yanlış Pozitif (YP), COVID-19'un yanlış tahmini; Doğru Negatif (DN), sağlıklı bireylerin doğru tahmini; Yanlış Negatif (YN) ise sağlıklı bireylerin yanlış tahmin sayısıdır. (Kohavi & Provost, 2016; Yılmaz, 2016).

Çizelge 3.1. Karışıklık Matrisi

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

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (3.1)$$

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (3.2)$$

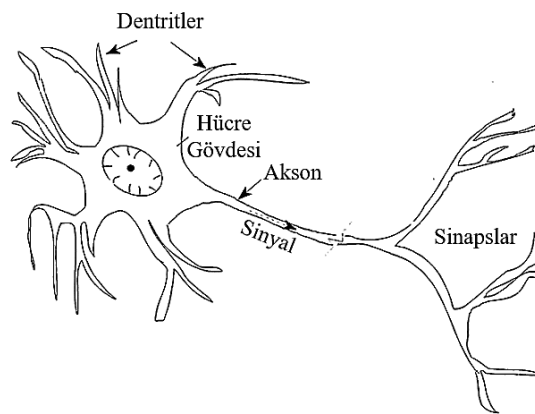
$$Duyarlılık = \frac{DP}{DP + YN} \quad (3.3)$$

$$\text{Özgüllük} = \frac{DN}{DN + YP} \quad (3.4)$$

$$F1 - Skor = \frac{2 * DP}{YN + YP + 2 * DP} \quad (3.5)$$

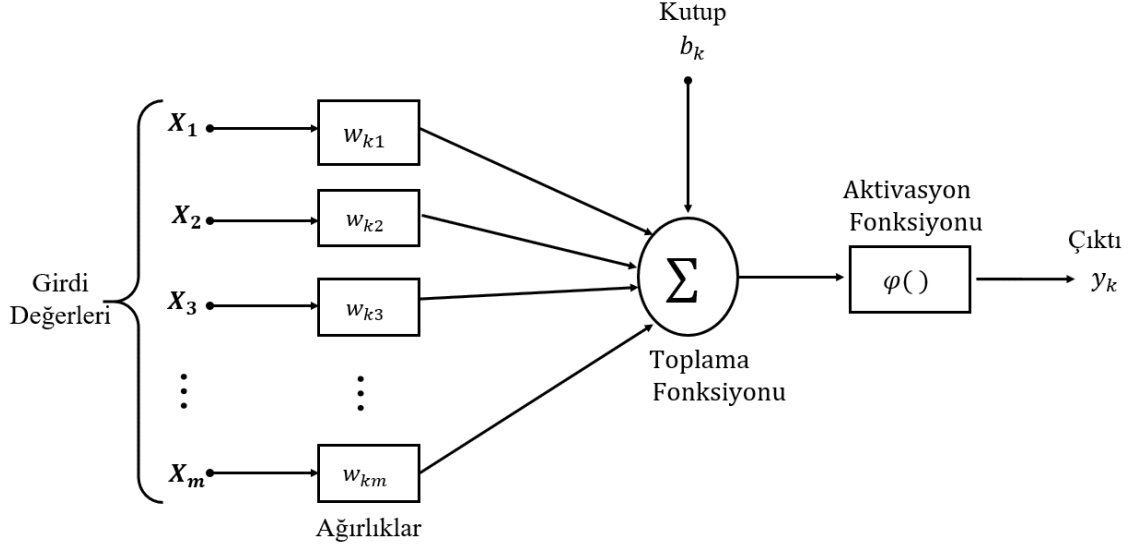
3.3. Derin Öğrenme

Derin öğrenmenin temelinde yapay sinir ağları yer almaktadır. Yapay sinir ağları, biyolojik sinir ağına benzer şekilde çalışan yapay nöronlardan oluşan dijital bir sinir ağı modellemesidir. Biyolojik sinir sisteminin yapı taşı olan nöron Şekil 3.4'te gösterilmiştir (Basheer & Hajmeer, 2001). Bir biyolojik nöron, hücre gövdesi, dentritler ve aksonlar olmak üzere üç ana bölümden oluşmaktadır. YSA'ların oluşum aşamasında bu biyolojik yapıdaki kısımlara karşılık gelen ve aynı işlevi üstlenen yapay birimler oluşturulmuştur. Dentritler, toplama fonksiyonuna; hücre gövdesi, transfer fonksiyonuna; sinapslar, ağırlık değerlerine ve aksonlar yapay sinir ağı çıktısına karşılık gelmektedir. Bahsedilen birimlerin bulunduğu bir yapay sinir ağı örneği Şekil 3.5'te gösterilmektedir.



Şekil. 3.4. Biyolojik nöron yapısı

Şekil 3.5’deki ağ yapısında görüldüğü gibi, girdi değerleri ağırlık değerleri ile çarpılarak nöron çıktısı elde edilmektedir (Denklem 3.6). Ardından yanlılık yani kutup değeri ile toplanır ve elde edilen değer aktivasyon fonksiyonundan geçirilerek sinir ağı çıktısı oluşturulmaktadır (Denklem3.7).



Şekil 3.5. Yapay sinir ağı yapısı

Nöronları k indisi ile gösterdiğimizizi varsayarsak nöron çıktısı ve sinir ağı çıktısı aşağıdaki iki denklem ile elde edilmektedir.

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (3.6)$$


$$y_k = \varphi(u_k + b_k) \quad (3.7)$$

x_1, x_2, \dots, x_m girdi değerleri; $w_{k1}, w_{k2}, \dots, w_{km}$ k 'inci nöron için ağırlıklar; u_k k 'inci nöronun çıktısı; b_k kutup değerleri; $\varphi()$ aktivasyon fonksiyonu ve y_k ise yapay sinir ağının çıktısıdır.

Çok katmanlı sinir ağlarında, giriş ve çıkış arasında gizli katman olarak adlandırılan ek katmanlar yer almaktadır. Gizli katman sayısının artmasıyla ağ mimarisinin derinliği

artmaktadır. Çok katmanlı sinir ağı mimarileri ileri beslemeli ağlardır yani giriş katmanından gelen bilgi ardışık katmanlar boyunca taşınarak çıkış katmanına ulaştırılmaktadır. Katmanlardaki nöronlar bir önceki katmandaki tüm nöronlarla bağlantılıdır, dolayısıyla tam bağlantılı mimari olarak da adlandırılmaktadır.

Son olarak mimariyi optimize edebilmek için kayıp fonksiyonu hesaplanmaktadır. Örnek bir çok katmanlı yapay sinir ağı Şekil 3.6'da gösterilmektedir. (Haykin, 1999).



Şekil 3.6. Çok katmanlı yapay sinir ağı mimarisi

x_1, \dots, x_m , giriş katmanı değerleri; $h_{l,k,\dots,t}^{1,2,\dots,N_h}$, gizli katmanlarda bulunan nöronlar; y_1, y_2, \dots, y_k , çıktı katmanı değerleridir.

İlk gizli katmanda bulunan nöronların çıkış değeri Denklem 3.8 ile hesaplanmaktadır.

$$h_p^1 = a_{f1} \left(\sum_{j=1}^n w_{pj}^1 x_j \right) \quad (3.8)$$

a_{f1} , aktivasyon fonksiyonu; w_{pj}^1 , giriş katmanı ve ilk gizli katman arasındaki ağırlık katsayılarıdır.

İkinci gizli katman çıkış değeri Denklem 3.9 ile hesaplanmaktadır.

$$h_q^2 = a_{f2} \left(\sum_{p=1}^l w_{qp}^2 h_p^1 \right) \quad (3.9)$$

a_{f2} , aktivasyon fonksiyonu; w_{qp}^2 , birinci ve ikinci gizli katman ağırlık katsayılarıdır.

Gizli katmanlar gibi çıkış katmanı değeri de Denklem 3.10 ile hesaplanmaktadır.

$$y_i = a_{f3} \left(\sum_{r=1}^t w_{ir}^{N_h+1} h_r^{N_h} \right) \quad (3.10)$$

a_{f3} , aktivasyon fonksiyonu; $w_{ir}^{N_h+1}$, son gizli katman ve çıkış katmanı arasındaki ağırlık katsayılarıdır.

Tam bağlantılı yapay sinir ağlarında iyi sonuçlar elde edilse de bu bağlantıların budanması ve yerleştirilmesi başarımlar üzerinde olumlu etkiler göstermektedir. Bağlantıların bu şekilde güncellendiği en bilindik ağlar evrimsel sinir ağlarıdır (Aggarwal, 2018; Basheer & Hajmeer, 2001; Haykin, 1999; Ker et al., 2017; Yılmaz, 2016).

3.4. Evrimsel Sinir Ağları

Evrimsel sinir ağları (CNN), görüntüler üzerinde oldukça başarılı performansa sahip ve görüntü analizi uygulamalarında sıklıkla tercih edilen bir derin öğrenme mimarisidir. CNN'lerin temeli filtreleme işlemine dayanmaktadır (Fukushima, 1980; Simard et al., 2003).

CNN mimarilerinde, birden fazla evrimsel katman, aktivasyon katmanı, havuzlama katmanı, tam bağlı katman, sınıflandırıcı katmanı gibi temel katmanların yanı sıra bazı ek katmanlar da bulunmaktadır.

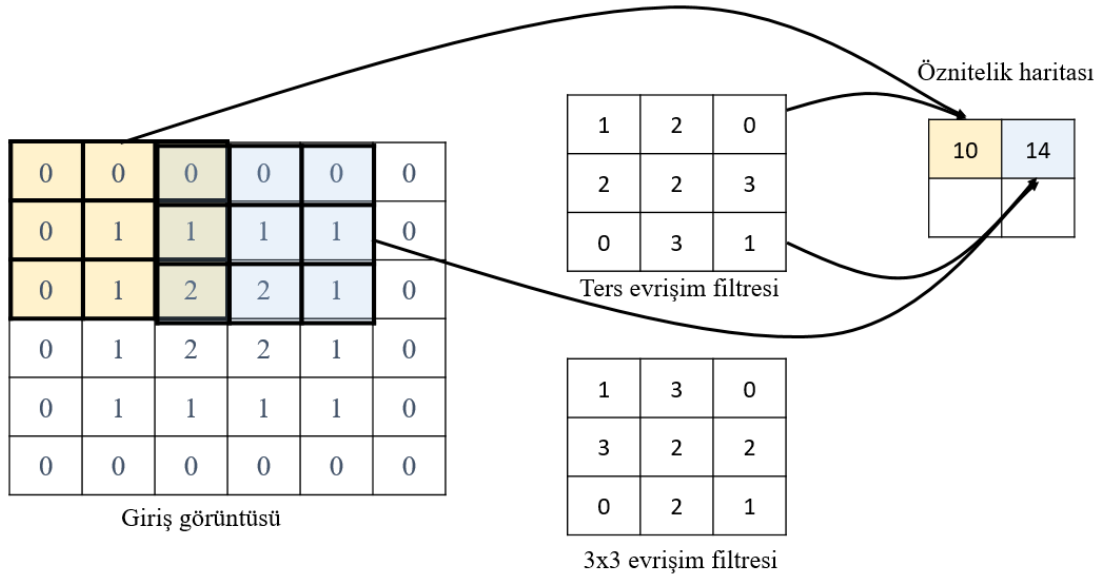
3.4.1. Evrişimsel katman

Evrişimsel katman görüntülerin özniteliklerinin çıkartıldığı temel CNN katmanıdır. Sayısal görüntüler piksel matrisleri biçimindedir. Denklem 3.10'da ifade edilen konvolüsyon (evrişim) işlemi bu matrislere uygulanmaktadır. Evrişim işlemi görüntü üzerinde bir filtrenin gezdirilmesi ile gerçekleşmektedir. İşlem sonucunda elde edilen öznitelik haritası adı verilen yeni matris Denklem 3.11'de verilmiştir. Şekil 3.7'de çekirdek adım büyüklüğü iki olan evrişim işlemine ait bir örnek gösterilmektedir (Cireşan et al., 2011; Demir & Yılmaz, 2021; Jmour et al., 2019; Lecun et al., 2015).

$$(f * g)(t) = \int_{-\infty}^{+\infty} f(T)g(t - T)dT \quad (3.10)$$

$$F_x^r = \frac{F_x^{r-1} - L_x^r}{S_x^r} + 1, F_y^r = \frac{F_y^{r-1} - L_y^r}{S_y^r} + 1 \quad (3.11)$$

(F_x, F_y) özellik haritasının genişliği ve yüksekliğini; (L_x, L_y) çekirdek boyutunu; (S_x, S_y) çekirdek adım büyüklüğünü ve r ise katman sayısını temsil etmektedir.



Şekil 3.7. Evrişim (filtreleme) İşlemi

3.4.2. Aktivasyon katmanı

Katman çıktıları üzerinde bazı fonksiyonlar uygulayarak doğrusal olmayan dönüşümler yapan bir katmandır. Evrişimsel katmanlardan sonra yer alan aktivasyon katmanında genellikle Denklem 3.11’de yer alan Düzleştirilmiş Doğrusal Birim (ReLU) fonksiyonu kullanılmaktadır. Ağın diğer bölümlerinde özellikle son katmanda yer alan aktivasyon fonksiyonları ise softmax (Denklem3.12), sigmoid (Denklem 3.13), hiperbolik tanjant (Denklem 3.14) gibi fonksiyonlardır (Krizhevsky et al., 2012).

$$ReLU(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (3.11)$$

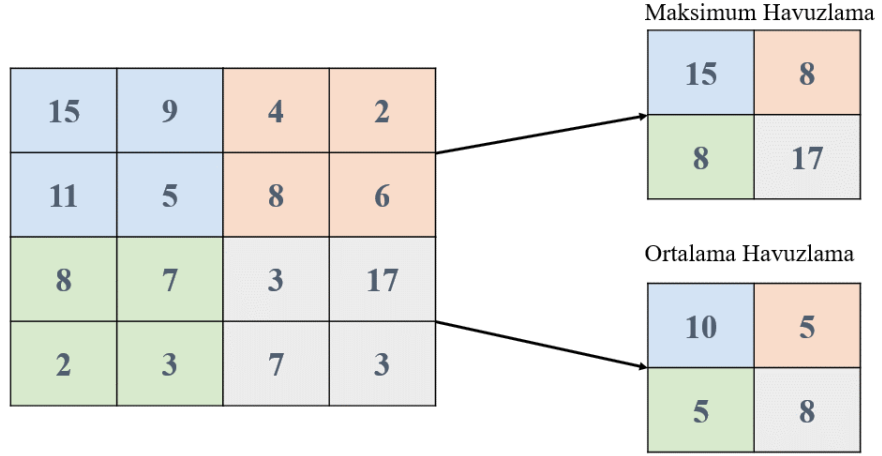
$$Softmax(x) = \frac{e^{x_i}}{\sum_{y=1}^m e^{x_y}} \quad (3.12)$$

$$Sigmoid(x) = \frac{1}{1 + e^{-\alpha x}} \quad (3.13)$$

$$tanh(x) = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (3.14)$$

3.4.3. Havuzlama katmanı

Havuzlama katmanı, evrişimsel katmandan sonra elde edilen öznitelik haritalarının boyutunun azaltıldığı katmandır. Öznitelik haritası üzerinde belirlenen filtre matrisi ile ortalama değer alma (ortalama havuzlama) veya maksimum değer alma (maksimum havuzlama) gibi işlemler gerçekleştirilmektedir. Şekil 3.8’de 2x2 boyutunda filtre ile ortalama ve maksimum havuzlama işlemleri gösterilmektedir. Öznitelik haritasının boyutu azaldığı için bir sonraki katmandaki nöron sayısı ve hesaplama yükü de azalmaktadır. Böylece ağın hızı artmakta ve ihtiyaç duyulan bellek miktarı azalmaktadır.



Şekil 3.8. Ortalama ve maksimum havuzlama işlemleri

Evrişimsel katmandan sonra gelen havuzlama katmanlarının yanı sıra ağın son katmanlarında matrisin tamamı üzerinde işlem yapan küresel ortalama havuzlama katmanları da kullanılabilir.

Bir ara adım olarak tam bağlı katmanından önce verilerin tek boyuta indirgenmesini sağlamak için düzleştirme işlemi gerçekleştirilmektedir. Böylece iki boyutlu matris formundaki veri tek boyutlu bir vektör haline gelmektedir. Diğer bir ara katman ise ağın aşırı öğrenmesini engellemek için kullanılan, seyreltme katmanıdır (Narin et al., 2020; Srivastava et al., 2014).

3.4.4. Tam normalleştirme katmanı

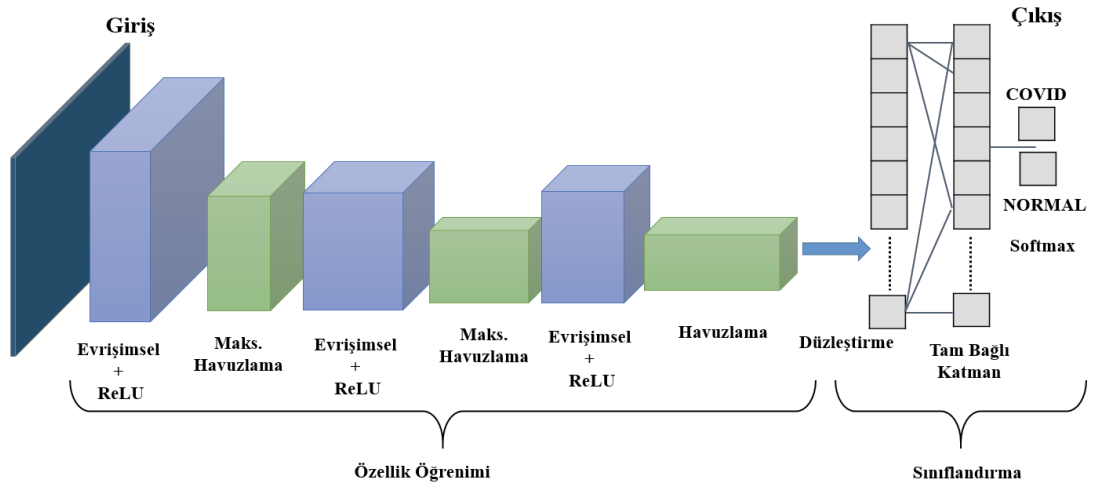
Bu katmanda girdilerin ortalamaları ve varyansları sabitlenerek yeniden ölçekleme ile normalleştirme işlemi gerçekleştirilmektedir. Böylece sistem daha hızlı ve kararlı hale getirilmektedir. Aynı zamanda daha yüksek öğrenme oranlarının kullanımı sağlanırken ağın seyreltme ihtiyacını azaltmaktadır (Ioffe & Szegedy, 2015).

3.4.5. Tam bağı katman

Tam bağı katman mimarinin son katmanıdır ve çok katmanlı algılayıcı olarak çalışmaktadır. Tam bağı katmandaki nöronlar bir önceki katmanın nöronlarına tamamen bağlantılıdır.

Tam bağı katmandan sonra sınıflandırma tahmini gerçekleştirilmektedir. Bu aşamada aktivasyon fonksiyonu sınıflandırma problemine özgü olarak seçilmektedir ve sıklıkla Denklem 3.12’de verilen Softmax aktivasyon fonksiyonu kullanılmaktadır (Narin et al., 2020).

Temel bir CNN mimarisi Şekil 3.9’da verilmiştir.

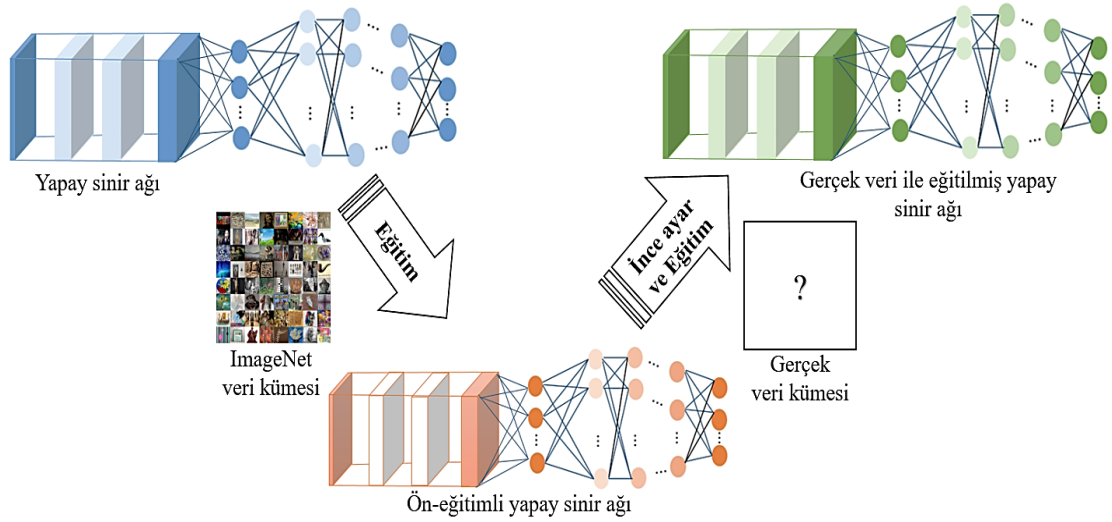


Şekil 3.9. Temel bir CNN mimarisi

3.5. Öğrenme Aktarımı (Transfer Learning)

Evrışimli sinir ağlarında ağ derinliği artması daha karmaşık hesaplamaları ve daha büyük veri ihtiyacını beraberinde getirmektedir. Sınırlı sayıda veri ile CNN eğitimi gerçekleştirilirken transfer öğrenme yönteminden yararlanılmaktadır. Transfer öğrenme başka bir deyişle öğrenme aktarımı, bir görevi gerçekleştirirken başka bir görevi yapmak üzere eğitilmiş derin öğrenme modeli kullanan bir stratejidir. Bir transfer öğrenme yaklaşımı örneği Şekil 3.10’da verilmiştir. Bu yaklaşımda ImageNet gibi büyük ölçekli

bir veri kümesi ile derin sinir ağı eğitilmektedir. ImageNet nesnelere kadar uzanan 20.000’den fazla kategoride 14 milyon görüntü içeren bir veri kümesidir. Başlangıç eğitiminin ardından, ağı, elde ettiği bilgiler ile asıl veriler üzerinde gerçek problem için kullanılmaktadır. Bu sayede daha az veri ile daha kısa eğitim süresinde daha yüksek başarı elde edilebilmektedir. Model, önceki eğitimden sahip olduğu ağırlıklar sayesinde rastgele ağırlıklar ile eğitilmez bu sebeple çok daha hızlı çalışmaktadır. CNN modellerinde daha iyi sonuçlar elde edilebilmesi için parametrelerin çok sayıda veri ile eğitilmesi gerekmektedir. Önceden eğitilmiş bir modelde eğitim görmüş parametreler ince ayar yapılarak yeni modele aktarılacağından daha iyi başarımlar elde edilebilmektedir. VGGNet, DenseNet, MobileNet, ResNet, Inception, EfficientNet gibi birçok önceden eğitilmiş popüler CNN mimarileri mevcuttur. Bu çalışmada VGGNet, DenseNet ve Mobile.Net mimarileri kullanılmıştır. (Gifani et al., 2021; Huh et al., 2016; Pandit et al., 2021).



Şekil 3.10. Bir transfer öğrenme yaklaşım örneği

3.5.1. VGGNet

Çok derin evrişimli ağlar (Very Deep Convolutional Networks), Oxford Visual Geometry Group tarafından ILSVR2014’ü kazanmak için ortaya atılan ve yüksek başarı gösteren temel mimarilerden birisidir. Evrişimsel katmanlarda 3x3 filtre boyutu ve ReLU aktivasyon fonksiyonu kullanılmaktadır. Son katmanda ise sınıflandırma için softmax yer

almaktadır. Katman sayılarına göre farklılık gösteren altı farklı VGGNet mimarisi mevcuttur (Simonyan & Zisserman, 2015). Bu çalışmada 19 katmanlı VGG19 kullanılmıştır.

3.5.2. DenseNet

Yoğun bağlantılı evrişimli ağlar (Densely Connected Convolutional Network), katmanlar arasında yoğun bloklar ile doğrudan bağlantıların bulunduğu evrişimli sinir ağlarıdır. Katmanlar diğer tüm katmanlara ileri beslemeli olarak bağlantılıdır. N katmanlı bir DenseNet'te her katman $N(N+1)/2$ doğrudan bağlantıya sahiptir ve önceki katmanların özellik haritalarını girdi olarak alırken kendi özellik haritasını da sonraki katmanlara girdi olarak vermektedir. DenseNet'ler daha az hesaplama karmaşıklığına sahip olduğundan daha az belleğe ihtiyaç duyar ve sahip oldukları katman sayılarına göre adlandırılmaktadır (Huang et al., 2017). Bu çalışmada DenseNet201 kullanılmıştır.

3.5.3. MobileNet

Mobil görüntü uygulamaları için verimli evrişimli sinir ağları (Efficient Convolutional Neural Networks for Mobile Vision Applications) modelleri, derinlemesine ayrılabilir evrişimsel katmanlar kullanılan evrişimli sinir ağlarıdır. Evrişimsel katmanlarda, iki boyutlu filtre iki ayrı evrişim filtresi halinde görüntüye uygulanmaktadır. Böylece parametreler normal bir evrişim işlemine göre daha azdır. Bu derinlemesine ayrılabilir evrişimsel katmanların mimarideki konumları ve durumlarına göre MobileNetV1, MobileNetV2, MobileNetV3 olmak üzere üç farklı model oluşturulmuştur (Howard et al., 2017). Bu çalışmada MobileNetV1 kullanılmıştır.

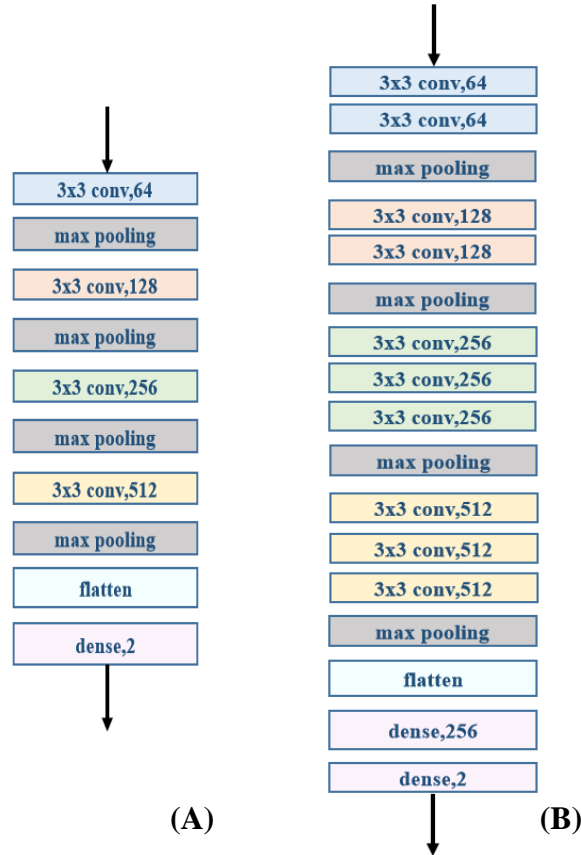
3.6. Kullanılan Modeller

COVID-19 ve normal bireylerin akciğer BT görüntülerinin bulunduğu bir veri kümesi üzerinde COVID-19'un tespiti için evrişimli sinir ağı mimarileri kullanılan iki izlem takip edilmiştir. Birinci izlemde, Basit-CNN ve VGG16 mimarileri kullanılarak ağ derinliğinin başarımlar üzerindeki etkisi incelenmiştir. İkinci izlemde ise öğrenme aktarımı yönteminin

derin öğrenme mimarilerinden VGG19, MobileNet ve DenseNet'in başarımları üzerindeki etkisi araştırılmıştır.

3.6.1. Birinci izlem

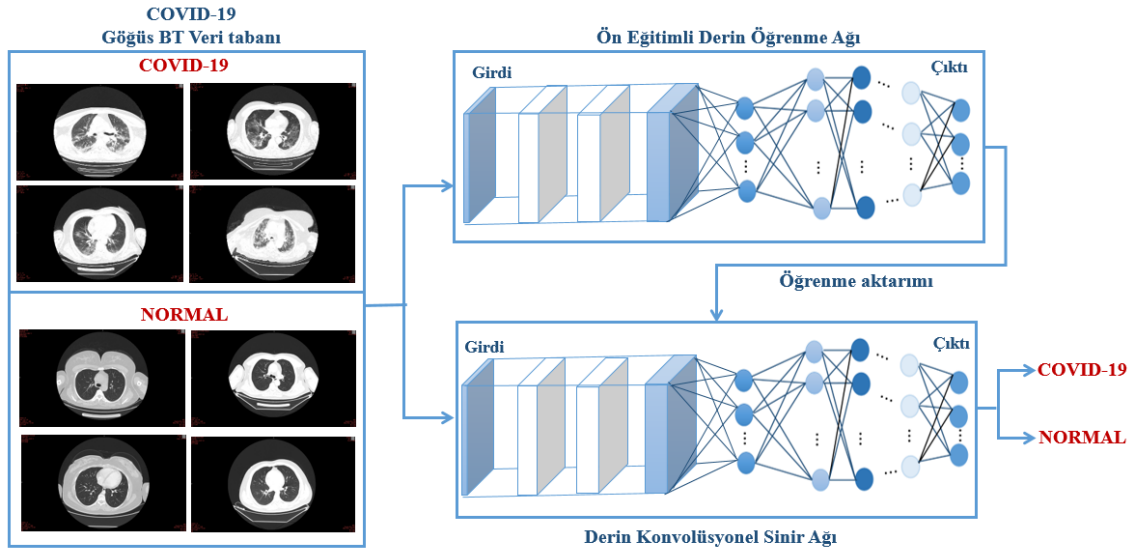
Birinci izlemde, iki mimari kullanılmıştır. İlk mimari Şekil 3.11.A'da yer alan Krizhevsky ve diğerlerinin literatüre kazandırdığı Alexnet'e benzer olarak oluşturulan Basit-CNN mimarisidir (Krizhevsky et al., 2012). Verilerin sınıflandırılmasında daha az evrimsel katman içeren ve derinliği az olan bir mimari tercih edilmiştir. Modelde dört evrimsel katman mevcuttur. Her evrimsel katmandan sonra maksimum havuzlama işlemi gerçekleştirilmektedir. Ardından düzleştirme yapılarak yoğun katmanla iki sınıflı çıkış kararı oluşturulmaktadır. İkinci mimari ise Şekil 3.11.B'de yer alan, Simonyan ve Zisserman tarafından oluşturulan VGG16 evrimsel sinir ağıdır (Simonyan & Zisserman, 2015). Bu mimaride basit CNN'den farklı olarak her konvolüsyon bloğunda bir evrimsel katman yerine ikili veya üçlü evrimsel katman yığınları bulunmaktadır.



Şekil 3.11. Birinci izlemde kullanılan evrimsel sinir ağı mimarileri
A) Basit CNN mimarisi B) VGG16 mimarisi

3.6.2. İkinci izlem

İkinci izlemde popüler CNN mimarileri ImageNet veri kümesi üzerinde eğitilmiştir. Bu sayede CNN'lerin görüntü işleme uygulamalarında iyi performans göstermesine olanak sağlayan parametreleri büyük veri kümesi ile önceden eğitilmiş ve optimize edilmiştir. Uygulanan öğrenme aktarımı modeline ait adımlar Şekil 3.12'de gösterilmektedir.

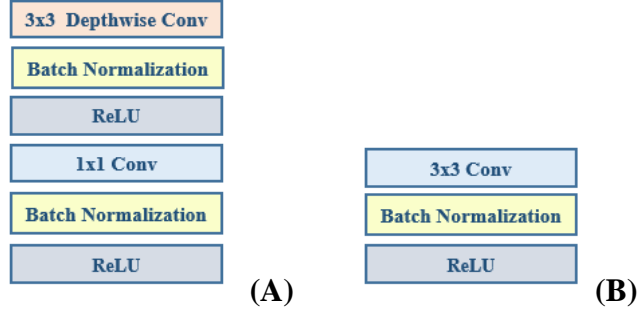


Şekil 3.12. Öğrenme aktarımı modeli

Kullanılan ağlardan birincisi Şekil 3.15.A'da gösterilen VGG19 mimarisidir. Modelde evrişim işlemleri ikili ve dörtlü evrişimsel katman bloklarıyla gerçekleştirilmektedir. Katman blokları çıkışlarında maksimum havuzlama işlemi yapılmaktadır. Global havuzlama katmanından sonra iki yoğun katman arasında tam normalleştirme ve seyreltme işlemleri gerçekleştirilmektedir.

İkinci ağ Şekil 3.15.B'de yer alan MobileNet mimarisidir. Bu mimarinin en önemli özelliği farklı evrişimsel katman yapısı içermesidir. Bu yapıda derinlemesine evrişimsel katman ve noktasal evrişimsel katman bulunmaktadır. Dolayısıyla evrişimsel katmanlar blok bir yapı oluşturmaktadır. Şekil 3.13.A'da derinlemesine ve noktasal evrişimsel katman blok yapıları gösterilmektedir. MobileNet mimarisinde tüm evrişimsel katman

bloklarında bu yapı bulunmaktadır. Şekil 3.13.B’de ise standart bir evrişimsel katman gösterilmektedir.




Şekil 3.13. Standart ve derinlemesine ayrılabilir evrişim katman blok yapıları

A) Derinlemesine ve noktasal evrişim katman blok yapısı

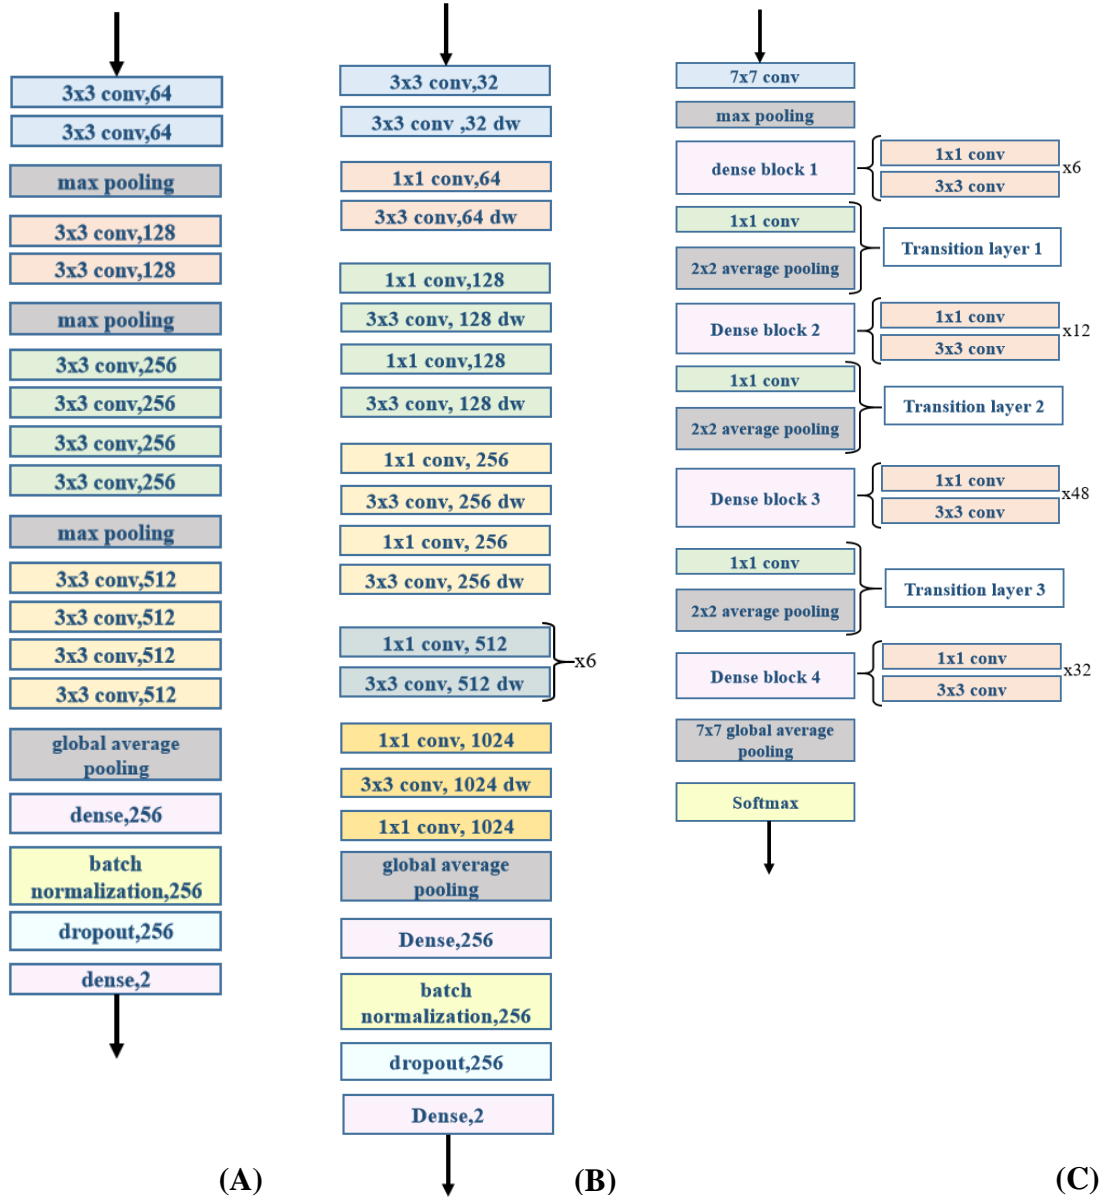
B) Standart evrişim katman blok yapısı

Mimarideki son derinlemesine ayrılabilir konvolüsyon bloklarının çıkışında global ortalama havuzlama işlemi gerçekleştirilmektedir. Son olarak normalizasyon ve seyreltme işlemleri ardından yoğun katman ile çıkış elde edilmektedir.

Üçüncü ağ Şekil 3.15.C’de gösterilen DenseNet201 mimarisidir. Model evrişimsel katman ve maksimum havuzlama ile başlamaktadır. Devamında dört tane yoğun blok ve üç geçiş katmanı bulunmaktadır. Yoğun blokların bağlantıları Şekil 3.14’te gösterilmektedir. Yoğun bloklarda 1x1 ve 3x3’lük filtre boyutuna sahip evrişimsel katmanlar yer almaktadır. Yoğun blokların birincisinde 6, ikincisinde 12, üçüncüsünde 48 ve dördüncüsünde ise 32 evrişimsel katman grubu bulunmaktadır. Geçiş katmanları 1x1 filtre boyutlu evrişimsel katman ve ortalama havuzlama katmanından oluşmaktadır. Dördüncü yoğun bloktan sonra global havuzlama gerçekleştirilir ve son olarak softmax fonksiyonu ile çıkış elde edilmektedir.



Şekil 3.14. Yoğun blokların iç bağlantı yapısı



Şekil 3.15. İkinci izlemde kullanılan evrişimsel sinir ağı mimarileri
A) VGG19 mimarisi **B)** MobileNet mimarisi **C)** DenseNet201 mimarisi

3.6.3. Kullanılan modellerin hiper-parametrelerinin seçilmesi

Tüm mimarilerde Çizelge 3.2’de verilen hiper-parametreler kullanılmıştır.

Çizelge 3.2. Hiper-parametreler

Parametreler:	Değerler:
Alfa	0,00001
Beta 1	0,9
Beta 2	0,999
Epsilon	1e-08
Devir sayısı	30
Devirlerdeki adım sayısı	20

Modellerin optimize edilmesinde Çizelge 3.2’de yer alan alfa, Beta 1, Beta 2 ve epsilon değerlerine sahip Adam optimizasyon algoritması kullanılmıştır. Alfa, mimarinin öğrenme oranıdır. Eğitim aşamasında ağırlıkların güncellenmesindeki adım büyüklüğünü belirtmektedir. Beta 1 ilk an tahminleri, Beta 2 ise ikinci an tahminleri için üstel azalma oranını ifade etmektedir. Epsilon, sıfıra bölünmeyi önlemek için belirlenen çok küçük bir sayı değeridir.

Kayıp fonksiyonu olarak Seyrek Kategorik Çapraz Entropi başka bir deyişle ikili çapraz entropi tercih edilmiştir. Eğitim aşamasında modelin başarı oranını görebilmek için her bir devir sonunda doğruluk ve kayıp değerleri takip edilmiştir.

Sinir ağlarında eğitim devir sayısını seçmek önemli bir adımdır. Fazla veya az seçilmesi durumlarında model yetersiz veya aşırı öğrenecektir. Bu nedenle belirlenen devir sayısının performansı düşürmemesi için erken durdurma yöntemi kullanılmıştır. Modelin doğrulama veri kümesindeki gelişimi doğrulama kayıp fonksiyonu ile takip edilmekte ve gelişim durduğunda eğitim işlemi sonlanmaktadır. Bu çalışmada kullanılan modellerde tercih edilen devir ve adım sayısı Çizelge 3.2’de verilmiştir.

Veri kümesi tüm mimariler için aynı oranda bölünmüştür. Aşırı öğrenmeyi engellemek için eğitim veri kümesi içerisinde 0,13 oranında doğrulama için ayrılmıştır. Toplamda 2114 veri; 1656 eğitim, 246 doğrulama, 212 test olarak bölünmüştür. Eğitim verilerinde

rastgele yatay, dikey çevirme ve ölçeklendirme işlemleri gerçekleştirilerek modelin ezberlemeden öğrenmesi sağlanmıştır.

4. BULGULAR

4.1. Birinci İzlemede Elde Edilen Sonuçlar

Birinci izlem kapsamında Basit-CNN mimarisi ve VGG16 mimarileri kullanılmıştır. Bu bölümde mimariler için eğitim, doğrulama ve test sonuçları verilmektedir.


4.1.1. Basit-CNN mimarisi

Basit-CNN mimarisinde giriş görüntüsü 224x224 boyutlarına indirgenerek kullanılmıştır. Mimariye ait eğitim, doğrulama ve test doğrulukları ile kayıpları Çizelge 4.2’de sunulmuştur. Mimari 1 594 178 eğitilebilir parametreye sahiptir.

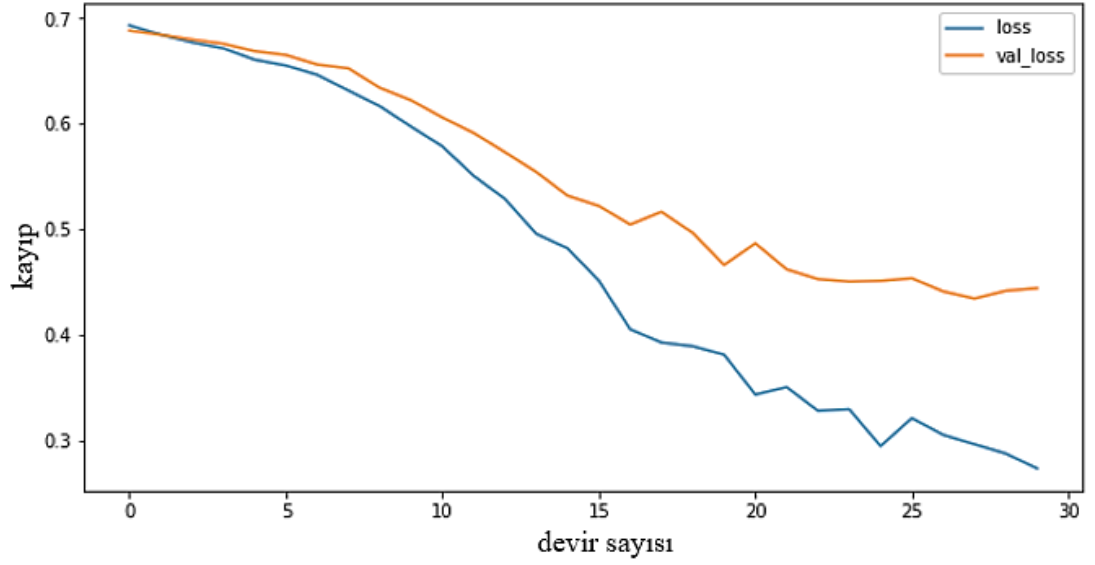
Çizelge 4.2. Basit-CNN mimarisi eğitim, doğrulama ve test doğrulukları ile kayıpları

Sonuçlar Mimari	Eğitim Sonuçları		Doğrulama Sonuçları		Test Sonuçları	
	Doğruluk	Kayıp	Doğruluk	Kayıp	Doğruluk	Kayıp
Basit-CNN	0,8828	0,2729	0,7886	0,4439	0,9103	0,2501

1902 veri kullanılarak gerçekleştirilen eğitim ve doğrulama için doğruluk ve kayıp fonksiyonuna ait grafikler sırasıyla Şekil 4.1 ve Şekil 4.2’de verilmiştir.




Şekil 4.1. Basit-CNN mimarisi için doğruluk grafiği (— Eğitim; — Doğrulama)



Şekil 4.2. Basit-CNN mimarisi için kayıp grafiği (— Eğitim; — Doğrulama)

Test aşamasında kullanılan 212 veri için karışıklık matrisi Şekil 4.3'te gösterilmiştir.



Şekil 4.3. Basit-CNN mimarisine ait karışıklık matrisi

Karışıklık matrisinden hesaplanan doğruluk, kesinlik, duyarlılık, özgüllük ve F1-Skor ölçütleri Çizelge 4.3'te sunulmuştur.

Çizelge 4.3. Basit-CNN mimarisi için başarımlar

Ölçütler Mimari	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skor
Basit-CNN	0,9104	0,9263	0,8800	0,9375	0,9025


4.1.2. VGG16 mimarisi

VGG16 mimarisinde giriş görüntüsü 224x224 boyutlarına indirgenerek kullanılmıştır. Mimariye ait eğitim, doğrulama ve test doğrulukları ile kayıpları Çizelge 4.4'te sunulmuştur. Mimari 134 286 738 eğitilebilir parametreye sahiptir.

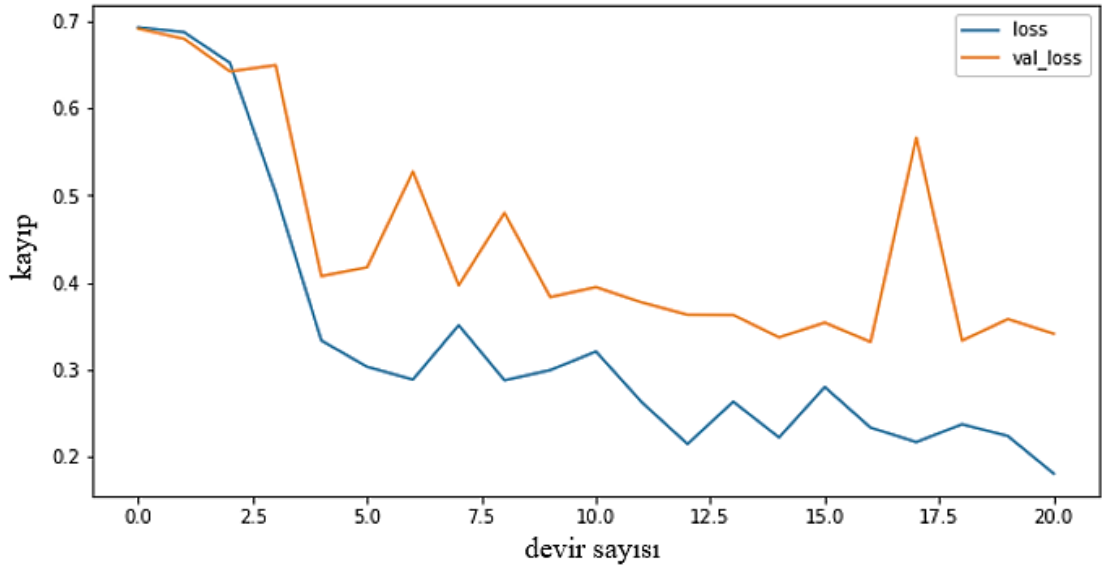
Çizelge 4.4. VGG16 mimarisi eğitim, doğrulama ve test doğrulukları ve kayıpları

Sonuçlar Mimari	Eğitim Sonuçları		Doğrulama Sonuçları		Test Sonuçları	
	Doğruluk	Kayıp	Doğruluk	Kayıp	Doğruluk	Kayıp
VGG16	0,9281	0,1808	0,8537	0,3414	0,9245	0,1954

1902 veri kullanılarak gerçekleştirilen eğitim ve doğrulama için doğruluk ve kayıp fonksiyonuna ait grafikler sırasıyla Şekil 4.5 ve Şekil 4.6’da verilmiştir.

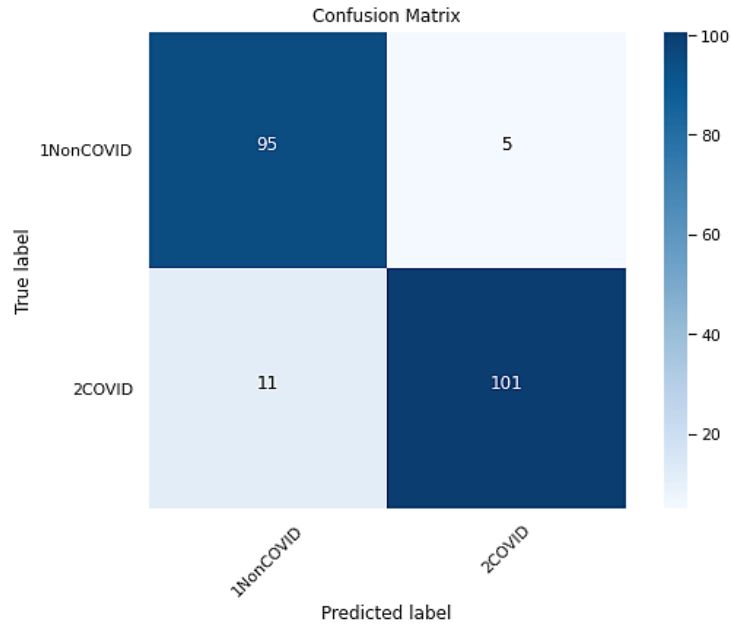


Şekil 4.5. VGG16 mimarisi için doğruluk grafiği (— Eğitim; — Doğrulama)



Şekil 4.6. VGG16 mimarisini için kayıp grafiği (— Eğitim; — Doğrulama)

Test aşamasında kullanılan 212 veri için karışıklık matrisi Şekil 4.4'te gösterilmiştir.



Şekil 4.4. VGG16 mimarisine ait karışıklık matrisi

Karışıklık matrisinden hesaplanan doğruluk, kesinlik, duyarlılık, özgüllük ve F1-Skor ölçütleri Çizelge 4.5'te sunulmuştur.

Çizelge 4.5. VGG16 mimarisi için başarımlar sonuçları

Ölçütler Mimari	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skor
VGG16	0,9245	0,8962	0,9500	0,9017	0,9223

4.2. İkinci İzlemlerde Elde Edilen Sonuçlar

İkinci izlem kapsamında VGG19, MobileNet ve DenseNet mimarileri kullanılmıştır. Bu bölümde mimariler için eğitim, doğrulama ve test sonuçları verilmektedir.

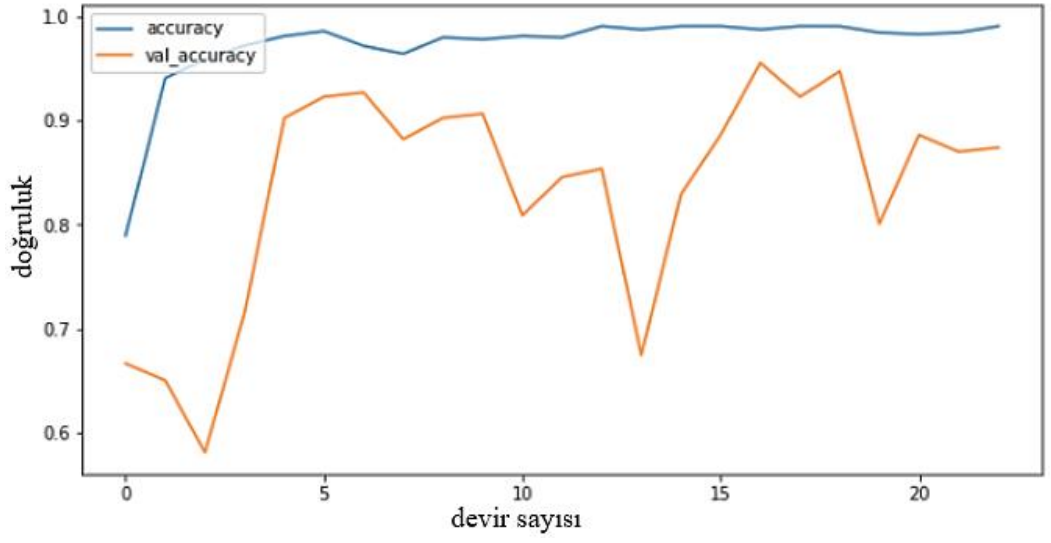
4.2.1. VGG19 mimarisi

VGG19 mimarisinde giriş görüntüsü 224x224 boyutlarına indirgenerek kullanılmıştır. Mimariye ait eğitim, doğrulama ve test doğrulukları ile kayıpları Çizelge 4.6’da sunulmuştur. Mimari 512 eğitilemez, 20 156 738 eğitilebilir toplamda 20 157 250 parametreye sahiptir.


Çizelge 4.6. VGG19 mimarisi eğitim, doğrulama ve test doğrulukları ve kayıpları

Sonuçlar Mimari	<i>Eğitim Sonuçları</i>		<i>Doğrulama Sonuçları</i>		<i>Test Sonuçları</i>	
	Doğruluk	Kayıp	Doğruluk	Kayıp	Doğruluk	Kayıp
VGG19	0,9906	0,0222	0,8740	0,2627	0,9764	0,0556

1902 veri kullanılarak gerçekleştirilen eğitim ve doğrulama için doğruluk ve kayıp fonksiyonuna ait grafikler sırasıyla Şekil 4.8 ve Şekil 4.9’da verilmiştir.




Şekil 4.8. VGG19 mimarisi için doğruluk grafiği (— Eğitim; — Doğrulama)



Şekil 4.9. VGG19 mimarisine için kayıp grafiği (— Eğitim; — Doğrulama)

Test aşamasında kullanılan 212 veri için karışıklık matrisi Şekil 4.7'de gösterilmektedir.



Şekil 4.7. VGG19 mimarisine ait karışıklık matrisi

Karışıklık matrisinden hesaplanan doğruluk, kesinlik, duyarlılık, özgüllük ve F1-Skor ölçütleri Çizelge 4.7’de sunulmuştur.

Çizelge 4.7. VGG19 mimarisi için başarımlar sonuçları

Ölçütler \ Mimari	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skor
VGG19	0,9764	0,9784	0,9680	0,9830	0,9732


4.2.2. MobileNet mimarisi

MobileNet mimarisinde giriş görüntüsü 224x224 boyutlarına indirgenerek kullanılmıştır. Mimariye ait eğitim, doğrulama ve test doğrulukları ile kayıpları Çizelge 4.8’de sunulmuştur. Mimari 22 400 eğitilemez, 3 470 402 eğitilebilir toplamda 3 492 802 parametreye sahiptir.

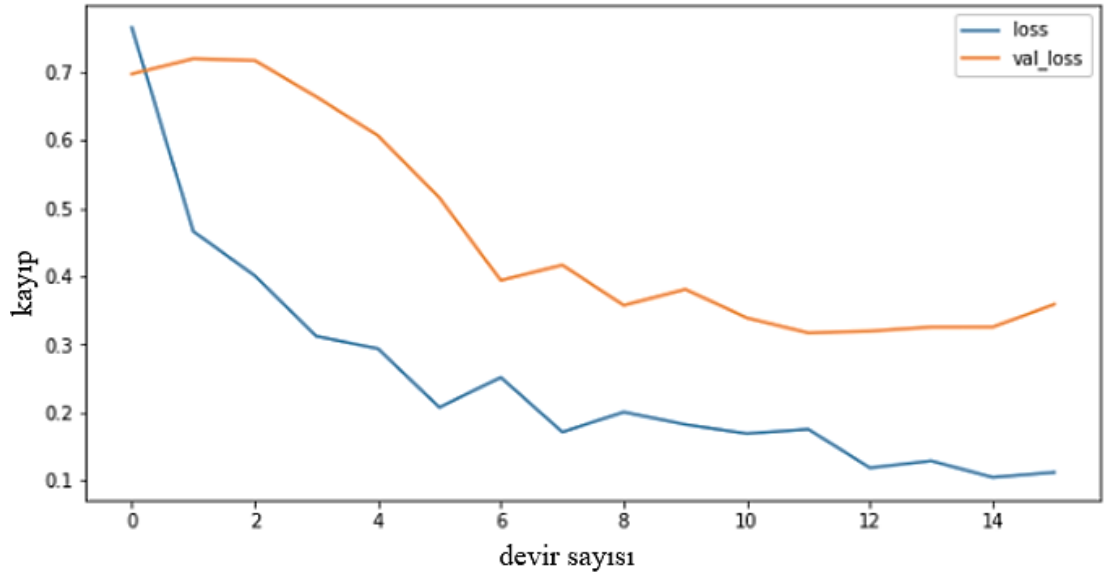
Çizelge 4.8. MobileNet mimarisi eğitim, doğrulama ve test doğrulukları ve kayıpları

Sonuçlar Mimari	Eğitim Sonuçları		Doğrulama Sonuçları		Test Sonuçları	
	Doğruluk	Kayıp	Doğruluk	Kayıp	Doğruluk	Kayıp
MobileNet	0,9609	0,1121	0,8496	0,3589	0,9339	0,1837

1902 veri kullanılarak gerçekleştirilen eğitim ve doğrulama için doğruluk ve kayıp fonksiyonuna ait grafikler sırasıyla Şekil 4.11 ve Şekil 4.12’de verilmiştir.




Şekil 4.11. MobileNet mimarisi doğruluk grafiği (— Eğitim; — Doğrulama)



Şekil 4.12. MobileNet mimarisi için kayıp grafiği (— Eğitim; — Doğrulama)

Test aşamasında kullanılan 212 veri için karışıklık matrisi Şekil 4.10’da gösterilmektedir.



Şekil 4.10. MobileNet mimarisine ait karışıklık matrisi

Karışıklık matrisinden hesaplanan doğruluk, kesinlik, duyarlılık, özgüllük ve F1-Skor ölçütleri Çizelge 4.9’da sunulmuştur.

Çizelge 4.9. MobileNet mimarisi için başarıml sonuçları

Ölçütler Mimari	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skor
MobileNet	0,9339	0,8909	0,9800	0,8928	0,9333

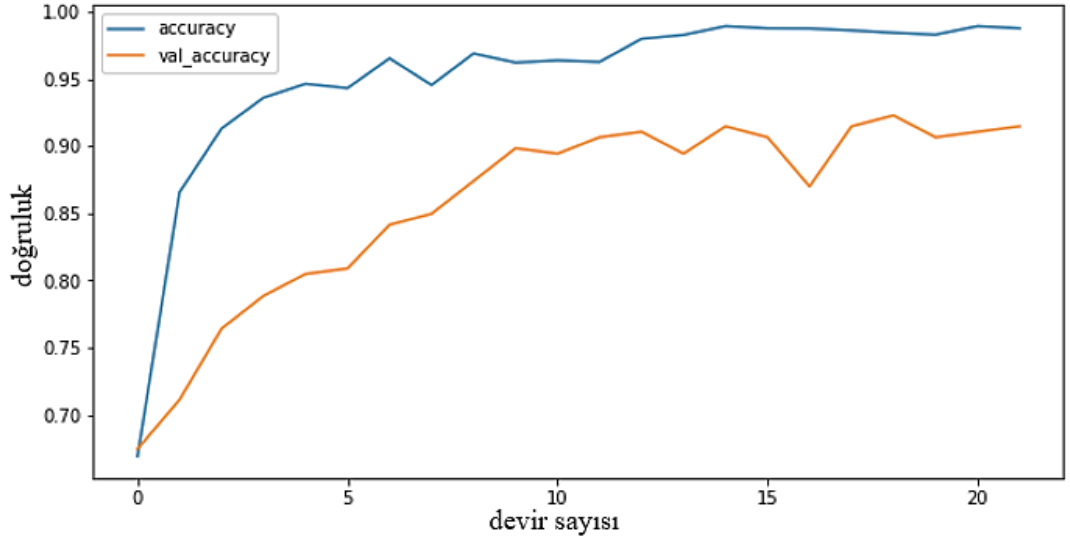
4.2.3. DenseNet201 mimarisi

DenseNet201 mimarisinde giriş görüntüsü 224x224 boyutlarına indirgenerek kullanılmıştır. Mimariye ait eğitim, doğrulama ve test doğrulukları ve kayıpları Çizelge 4.10’da sunulmuştur. Mimari 229 568 eğitilemez, 18 585 730 eğitilebilir toplamda 18 815 298 parametreye sahiptir.


Çizelge 4.10. DenseNet201 mimarisi eğitim, doğrulama ve test doğrulukları ve kayıpları

Sonuçlar Mimari	Eğitim Sonuçları		Doğrulama Sonuçları		Test Sonuçları	
	Doğruluk	Kayıp	Doğruluk	Kayıp	Doğruluk	Kayıp
DenseNet201	0,9875	0,0387	0,9146	0,2239	0,9858	0,0542

1902 veri kullanılarak gerçekleştirilen eğitim ve doğrulama için doğruluk ve kayıp fonksiyonuna ait grafikler sırasıyla Şekil 4.13 ve Şekil 4.14’te verilmiştir.




Şekil 4.13. DenseNet201 mimarisi için doğruluk grafiği (— Eğitim; — Doğrulama)



Şekil 4.14. DenseNet201 mimarisi için kayıp grafiği (— Eğitim; — Doğrulama)

Test aşamasında kullanılan 212 veri için karışıklık matrisi Şekil 4.13'te gösterilmektedir.



Şekil 4.13. DenseNet201 mimarisine ait karışıklık matrisi

Karışıklık matrisinden hesaplanan doğruluk, kesinlik, duyarlılık, özgüllük ve F1-Skor ölçütleri Çizelge 4.11’de sunulmuştur.

Çizelge 4.11. DenseNet201 mimarisi için başarımlar sonuçları

Ölçütler \ Mimari	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skor
DenseNet201	0,9858	0,9791	0,9894	0,9829	0,9842

5. TARTIŞMA ve SONUÇ

COVID-19 hastalığının teşhisinde yaygın olarak kullanılan yöntem RT-PCR testleridir. Yöntemin önemli dezavantajı hastalığın erken evrelerinde yüksek oranda yanlış negatif sonuç vermesidir. Bu durum enfekte ve yoğun bakım vaka sayıları ile sağlık çalışanlarının çalışma sürelerinin artmasına ve dolayısıyla hastanelerin hizmet kalitesinin azalmasına sebep olmaktadır. Bu nedenler COVID-19'un teşhisinde yeni ve yardımcı teşhis yöntemlerine ihtiyaç doğurmuştur.

Çözüm yöntemleri arasında derin öğrenme temelli yaklaşımlar öne çıkmaktadır. Bu yaklaşımlar kullanılarak hızlı, güvenilir ve otomatik analizler yapılabilmektedir.

Bu tez çalışmasında COVID-19'un akciğer BT'leri üzerinden tespit edilebilmesi için iki ayrı izlemde evrimsel sinir ağları kullanılmıştır. Birinci izlemde, Basit-CNN ve VGG16 mimarileri; ikinci izlemde ise VGG19, MobileNet ve DenseNet mimarileri kullanılmıştır.

Deneysel çalışmalar sonucunda birinci izlemdeki mimarilere ait test başarımları Çizelge 5.1'de sunulmuştur. VGG16'nın doğruluk, duyarlılık ve F1-Skor ölçütlerinde Basit-CNN mimarisinden daha iyi sonuçlar verdiğini göstermektedir. Kesinlik ve özgüllük ölçütlerinde ise Basit-CNN mimarisinin başarımları daha yüksektir.

VGG16 mimarisinde, küçük boyutlu evrişim filtreleri kullanıldığından çok fazla ağırlık katmanına sahiptir. Katman sayısının artması, mimarinin derinliğini ve daha karmaşık fonksiyonlara uyum sağlama yeteneğini arttırmaktadır. Böylece Basit-CNN'e kıyasla daha yüksek bir başarımlar göstermektedir. Evrişim katmanlarının sayısı ile artan ReLU birimi sayısı da karar işlevini daha ayırt edici hale getirmektedir. Çizelge 5.1'de yer alan sonuçlar, aynı zamanda, COVID-19'un tespitinde ağ mimarileri derinliğinin ve evrişim katmanları yapısının başarımlar ölçütleri üzerindeki etkisini göstermektedir.

Çizelge 5.1. Birinci izlem başarımları sonuçları

Ölçütler Mimari	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skor
Basit-CNN	0,9104	0,9263	0,8800	0,9375	0,9025
VGG16	0,9245	0,8962	0,9500	0,9017	0,9223

Deneysel çalışmalar sonucunda ikinci izlemdeki mimarilere ait test başarımları sonuçları Çizelge 5.2’de sunulmuştur. Özgüllük hariç diğer tüm başarımlar ölçütleri için DenseNet en iyi değerleri vermiştir. Özgüllük değerinde ise VGG19 ile benzer (çok yakın) sonuç vermiştir.

DenseNet mimarisinde her evrişim katmanı sonraki tüm katmana bağlandığından daha derin bir yapıya sahiptir. Önceki katmanlardan gelen özellik haritaları tekrar tekrar kullanılarak derin bir denetim sağlanmaktadır. Kaybolan gradyan sorununda ise yine katmanlar arasındaki atlama bağlantıları ile her katmandaki gradyanlar erişilir hale getirilmektedir. Bağlantı yapısı sayesinde sahip olduğu avantajlar güçlü bir ağ mimarisinin temelini oluşturmaktadır.

Çizelge 5.2. İkinci izlem başarımları sonuçları

Ölçütler Mimari	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skor
MobileNet	0,9339	0,8909	0,9800	0,8928	0,9333
DenseNet201	0,9858	0,9791	0,9894	0,9829	0,9842
VGG19	0,9764	0,9784	0,9680	0,9830	0,9732

Deneysel çalışmalar sonucunda iki ayrı izlem için elde edilen sonuçlar Çizelge 5.3’te birlikte sunulmuştur. Tüm mimariler açısından en yüksek değerli sonuçların öğrenme aktarımı yöntemi kullanılan DenseNet201 mimarisine ait olduğu görülmektedir.

Öğrenme aktarımı yönteminde örnek aktarımı, özellik aktarımı, parametre aktarımı ve ilişki kurma tecrübesi aktarımı gerçekleştirilir. Bu sayede daha kısa eğitim süresi ile daha az veri kullanılarak daha yüksek başarımlar elde edilebilmektedir. Çizelge 5.3'te yer alan sonuçlar ile öğrenme aktarımının başarımlar ölçütleri üzerindeki etkisi gözlemlenebilmektedir.

Çizelge 5.3. Evrişimsel sinir ağları için elde edilen başarımlar sonuçları

	Ölçütler Mimari	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1- Skor
Birinci İzlem	Basit-CNN	0,9104	0,9263	0,8800	0,9375	0,9025
	VGG16	0,9245	0,8962	0,9500	0,9017	0,9223
İkinci İzlem	MobileNet	0,9339	0,8909	0,9800	0,8928	0,9333
	DenseNet201	0,9858	0,9791	0,9894	0,9829	0,9842
	VGG19	0,9764	0,9784	0,9680	0,9830	0,9732

COVID-19'un tespiti için pek çok farklı yaklaşım mevcuttur. Bu tez çalışmasında evrişimsel sinir ağları kullanılarak akciğer BT'leri üzerinden COVID-19 tespiti yapan literatür çalışmaları incelenmiştir. Bu tez çalışmasında elde edilen sonuçlar ile literatürde yer alan çalışmaların sonuçları karşılaştırmak amacıyla doğruluk ölçütü bazında Çizelge 5.4'te birlikte sunulmuştur. DenseNet201 mimarisinin 0.9858 test doğruluğu ile en yüksek başarıma sahip olduğu görülmektedir.

Çizelge 5.4. Literatürde COVID-19 tespiti yapan çalışmaların doğruluk sonuçları

Gerçekleştirilen Çalışma	Veri Tipi	Mimari	Sınıf Sayısı	Sonuç
S. Wang ve diğerleri	BT	(TL) M-Inception V3	CxN	0,793
Song ve diğerleri	BT	DRE-Net	CxBP CxN	0,86 0,94
Shah ve diğerleri	BT	CTnet-10 VGG19	CxN	0,82 0,94
Gifani ve diğerleri	BT	(ETL) EfficientNets B0 EfficientNets B3 EfficientNets B5 Inception_resnet_v2 Xception 0.74	CxN	0,85
Harmon ve diğerleri	BT	3D-CNN	CxN	0,908
Xu ve diğerleri	BT	(TL) ResNet18	CxN	0,86
B. Wang ve diğerleri	BT	(TL) “3DUnet++&ResNet-50”	CxN	0,974
Chen ve diğerleri	BT	(TL) ResNet50	CxN	0,95
Loey ve diğerleri	BT	ResNet50	CxN	0,8291
Polsinelli ve diğerleri	BT	SqueezeNet	CxN	0,83
Rahimzadeh	BT	ResNet50V2	CxN	0,9849
Jangam ve diğerleri	BT	(SEM) VGG 19 DenseNet 169	CxN	0,8473
X. Wang ve diğerleri	BT	DeCoVNet	CxN	0,901

Çizelge 5.4. Literatürde COVID-19 tespiti yapan çalışmaların doğruluk sonuçları (devam)

Kogilavani ve diğerleri	BT	VGG16 DenseNet121 MobileNet NASNet Xception EfficientNet	CxN	0,9768 0,9753 0,9638 0,8951 0,9247 0,8019
Maghdid ve diğerleri	BT	(TL) Basit CNN	CxN	0,941
X. Yang ve diğerleri	BT	(MTL) DenseNet-169 ResNet-50	CxN	0,89
Jaiswal ve diğerleri	BT	(DTL-SSL) DenseNet201 temelli model	CxN	0,962
He ve diğerleri	BT	DenseNet-169'i omurgalı Self-Trans modeli	CxN	0,86
S. Yang ve diğerleri	BT	DenseNet	CxN	0,92
Pathak ve diğerleri	BT	(DTL) ResNet50	CxN	0,930
Saedi ve diğerleri	BT	DenseNet-121	CxN	0,908
Youdefzadeh ve diğerleri	BT	DenseNet ResNet Xception EfficientNetB0	CxNxNCA	0,964
Hu ve diğerleri	BT	Değiştirilmiş VGG	CxN	0,962
Jin ve diğerleri	BT	ResNet 152	NxCxCAP NxCAP CxCAP CxN	0,874 0,940 0,891 0,949
Bu çalışma	BT	(DTL) DenseNet201	CxN	0,9858

COVID olmayan anormal (NCA); Toplum kökenli pnönomi (CAP); derin transfer öğrenme yöntemi (DTL); çok görevli öğrenme (MTL); kendi kendini denetleyen öğrenme (SSL); yığılmış topluluk öğrenme modeli (SEM); transfer öğrenme topluluğu (ETL)

KAYNAKLAR

- Aggarwal, C. C. (2018). *Neural Networks and Deep Learning*. Springer.
- Anthimopoulos, M., Christodoulidis, S., Ebner, L., Christe, A., & Mougiakakou, S. (2016). Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network. *IEEE Transactions on Medical Imaging*, 35(5), 1207–1216. <https://doi.org/10.1109/TMI.2016.2535865>
- Bakator, M., & Radosav, D. (2018). Deep Learning and Medical Diagnosis : A Review of Literature. *Multimodal Technologies and Interaction*, 2(3), 47. <https://doi.org/10.3390/mti2030047>
- Basheer, I. A., & Hajmeer, M. (2001). Artificial Neural Networks: Fundamentals, Computing, Design, and Application. *Journal of Microbiological Methods*, 43(43(1)), 3–31. [https://doi.org/10.1016/S0167-7012\(00\)00201-3](https://doi.org/10.1016/S0167-7012(00)00201-3)
- Bengio, Y. (2009). Learning deep architectures for AI. In *Foundations and Trends in Machine Learning* (Vol. 2, Issue 1). <https://doi.org/10.1561/22000000006>
- Brosch, T., Tang, L. Y. W., Yoo, Y., Li, D. K. B., Traboulsee, A., & Tam, R. (2016). Deep 3D Convolutional Encoder Networks With Shortcuts for Multiscale Feature Integration Applied to Multiple Sclerosis Lesion Segmentation. *IEEE Transactions on Medical Imaging*, 35(5), 1229–1239. <https://doi.org/10.1109/TMI.2016.2528821>
- Chan-Yeung, M., Xu, R., Sinha, M., Pande, B., Sinha, R., Zhou, Y., Macgeorge, E. L., Myrick, J. G., Morin, C. M., Carrier, J., Bastien, C., Godbout, R., Choi, E. P. H., Hui, B. P. H., Wan, E. Y. F., O'Connor, R. C., Wetherall, K., Cleare, S., McClelland, H., ... Hand, C. J. (2003). SARS : epidemiology CUMULATIVE NUMBER OF CASES AND DEATHS IN VARIOUS COUNTRIES IN. *Respirology*, 8, S9–S14.
- Charbonnier, J. P., Rikxoort, E. M. van, Setio, A. A. A., Schaefer-Prokop, C. M., Ginneken, B. van, & Ciompi, F. (2017). Improving airway segmentation in computed tomography using leak detection with convolutional networks. *Medical Image Analysis*, 36, 52–60. <https://doi.org/10.1016/j.media.2016.11.001>
- Chen, J., Wu, L., Zhang, J., Zhang, L., Gong, D., Zhao, Y., Chen, Q., Huang, S., Yang, M., Yang, X., Hu, S., Wang, Y., Hu, X., Zheng, B., Zhang, K., Wu, H., Dong, Z., Xu, Y., Zhu, Y., ... Yu, H. (2020). Deep learning-based model for detecting 2019 novel coronavirus pneumonia on high-resolution computed tomography. *Scientific Reports*, 10(1), 1–11. <https://doi.org/10.1038/s41598-020-76282-0>
- Ciompi, F., de Hoop, B., van Riel, S. J., Chung, K., Scholten, E. T., Oudkerk, M., de Jong, P. A., Prokop, M., & van Ginneken, B. (2015). Automatic classification of pulmonary peri-fissural nodules in computed tomography using an ensemble of 2D views and a convolutional neural network out-of-the-box. *Medical Image Analysis*, 26(1), 195–202. <https://doi.org/10.1016/j.media.2015.08.001>
- Cireşan, D. C., Giusti, A., Gambardella, L. M., & Schmidhuber, J. (2013). Mitosis detection in breast cancer histology images with deep neural networks. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 8150 LNCS(PART 2), 411–418. https://doi.org/10.1007/978-3-642-40763-5_51
- Cireşan, D. C., Meier, U., Masci, J., & Gambardella, L. M. (2011). Flexible, High Performance Convolutional Neural Networks for Image Classification. *Proceedings of the Twenty-Second International Joint Conference on Artificial Intelligence Flexible*, 1237–1242. <https://www.aaai.org/ocs/index.php/IJCAI/IJCAI11/paper/viewFile/3098/3425>

- Da Silva, S. J. R., Silva, C. T. A. Da, Guarines, K. M., Mendes, R. P. G., Pardee, K., Kohl, A., & Pena, L. (2020). Clinical and Laboratory Diagnosis of SARS-CoV-2, the Virus Causing COVID-19. *ACS Infectious Diseases*, 6(9), 2319–2336. <https://doi.org/10.1021/acscinfecdis.0c00274>
- Demir, F. B., & Yılmaz, E. (2021). X-Ray Görüntülerinden COVID-19 Tespiti için Derin Öğrenme Temelli Bir Yaklaşım. *European Journal of Science and Technology*, 32, 627–632. <https://doi.org/10.31590/ejosat.1039522>
- Dou, Q., Chen, H., Yu, L., Qin, J., & Heng, P. A. (2017). Multilevel Contextual 3-D CNNs for False Positive Reduction in Pulmonary Nodule Detection. *IEEE Transactions on Biomedical Engineering*, 64(7), 1558–1567. <https://doi.org/10.1109/TBME.2016.2613502>
- Esteva, A., Chou, K., Yeung, S., Naik, N., Dean, J., & Socher, R. (2021). Deep learning-enabled medical computer vision. *Npj Digital Medicine*, 4(5), 1–9. <https://doi.org/10.1038/s41746-020-00376-2>
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115–118. <https://doi.org/10.1038/nature21056>
- Falzone, L., Gattuso, G., Tsatsakis, A., Spandidos, D. A., & Libra, M. (2021). Current and innovative methods for the diagnosis of COVID-19 infection (Review). *International Journal of Molecular Medicine*, 47(6), 1–23. <https://doi.org/10.3892/ijmm.2021.4933>
- FDA. (2018). *Food and Drug Administration-Medical Imaging*. <https://www.fda.gov/radiation-emitting-products/radiation-emitting-products-and-procedures/medical-imaging>
- FDA. (2019). *Food and Drug Administration- Computed Tomography (CT)*.
- Fukushima, K. (1980). Neocognitron: A Self-Organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position. *Biological Cybernetics*, 36, 193–202.
- Ghaderzadeh, M., & Asadi, F. (2021). Deep Learning in the Detection and Diagnosis of COVID-19 Using Radiology Modalities: A Systematic Review. *Journal of Healthcare Engineering*, 2021. <https://doi.org/10.1155/2021/6677314>
- Gifani, P., Shalbaf, A., & Vafaezadeh, M. (2021). Automated detection of COVID-19 using ensemble of transfer learning with deep convolutional neural network based on CT scans. *International Journal of Computer Assisted Radiology and Surgery*, 16(1), 115–123. <https://doi.org/10.1007/s11548-020-02286-w>
- Goldberg, D. E., & Holland, J. H. (1988). (1988). Genetic algorithms and machine learning. *Machine Learning*, 3, 95–99. <https://link.springer.com/article/10.1023/A:1022602019183#citeas>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>
- Haidekker, M. A. (2014). Medical Imaging Technology (Springer Briefs in Physics). In *Medical Physics* (Vol. 41, Issue 10). <https://doi.org/10.1118/1.4895957>
- Harmon, S. A., Sanford, T. H., Xu, S., Turkbey, E. B., Roth, H., Xu, Z., Yang, D., Myronenko, A., Anderson, V., Amalou, A., Blain, M., Kassin, M., Long, D., Varble, N., Walker, S. M., Bagci, U., Ierardi, A. M., Stellato, E., Plensich, G. G., ... Turkbey, B. (2020). Harmon Artificial intelligence for the detection of COVID-19 pneumonia on chest CT using multinational datasets _ Enhanced Reader.pdf. *Nature Communications*, 11.

- Haugeland, J. (1985). *Artificial intelligence: the very idea* (Print book). Cambridge, Mass. : MIT Press.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation Subsequent Edition*.
- He, X., Yang, X., Zhang, S., Zhao, J., Zhang, Y., & Xing, E. (2020). *Sample-Efficient Deep Learning for COVID-19 Diagnosis Based on CT Scans*. XX(Xx).
- Hebb, D. O. (1949). *The Organization of Behavior: A NEUROPSYCHOLOGICAL THEORY*. Wiley.
- Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the Dimensionality of Data with Neural Networks. *Science*, 313(5786), 504–507.
- Hinton, Geoffrey E., Osindero, S., & Teh, Y.-W. (2006). A Fast Learning Algorithm for Deep Belief Nets Geoffrey. *Neural Computation*, 18, 1527–1554. <https://doi.org/10.7763/ijesd.2010.v1.67>
- Hosseini-Asl, E., Ghazal, M., Mahmoud, A., Aslantas, A., Shalaby, A., Casanova, M., Barnes, G., Gimel'farb, G., Keynton, R., & Baz, A. El. (2018). Alzheimer's disease diagnostics by a 3D deeply supervised adaptable convolutional network. *Frontiers in Bioscience - Landmark*, 23(3), 584–596. <https://doi.org/10.2741/4606>
- Hounsfield, G. N. (1973). Computerized transverse axial scanning (tomography): Part I. Description of system. *British Journal of Radiology*, 4, 1016–1022. [https://doi.org/10.1016/0360-3016\(94\)E0127-6](https://doi.org/10.1016/0360-3016(94)E0127-6)
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. *Computer Vision and Pattern Recognition (Cs.CV)*.
- Hu, S., Gao, Y., Niu, Z., Jiang, Y., Li, L., Xiao, X., Wang, M., Fang, E. F., Menpes-Smith, W., Xia, J., Ye, H., & Yang, G. (2020). Weakly Supervised Deep Learning for COVID-19 Infection Detection and Classification from CT Images. *IEEE Access*, 8, 118869–118883. <https://doi.org/10.1109/ACCESS.2020.3005510>
- Huang, G., Liu, Z., Maaten, L. Van Der, & Weinberger, K. Q. (2017). Densely Connected Convolutional Networks. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2261–2269.
- Huh, M., Agrawal, P., & Efros, A. A. (2016). *What makes ImageNet good for transfer learning?* 1–10. <http://arxiv.org/abs/1608.08614>
- Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *32nd International Conference on Machine Learning, ICML 2015*, 1, 448–456.
- Jaiswal, A., Gianchandani, N., Singh, D., Kumar, V., & Kaur, M. (2021). Classification of the COVID-19 infected patients using DenseNet201 based deep transfer learning. *Journal of Biomolecular Structure and Dynamics*, 39(15), 5682–5689. <https://doi.org/10.1080/07391102.2020.1788642>
- Jangam, E., Barreto, A. A. D., & Annavarapu, C. S. R. (2022). Automatic detection of COVID-19 from chest CT scan and chest X-Rays images using deep learning, transfer learning and stacking. *Applied Intelligence*, 52(2), 2243–2259. <https://doi.org/10.1007/s10489-021-02393-4>
- Jin, C., Chen, W., Cao, Y., Xu, Z., Tan, Z., Zhang, X., Deng, L., Zheng, C., Zhou, J., Shi, H., & Feng, J. (2020). Development and evaluation of an artificial intelligence system for COVID-19 diagnosis. *Nature Communications*, 11(1). <https://doi.org/10.1038/s41467-020-18685-1>
- Jin, Y. H., Cai, L., Cheng, Z. S., Cheng, H., Deng, T., Fan, Y. P., Fang, C., Huang, D., Huang, L. Q., Huang, Q., Han, Y., Hu, B., Hu, F., Li, B. H., Li, Y. R., Liang, K.,

- Lin, L. K., Luo, L. S., Ma, J., ... Wang, X. H. (2020). A rapid advice guideline for the diagnosis and treatment of 2019 novel coronavirus (2019-nCoV) infected pneumonia (standard version). *Medical Journal of Chinese People's Liberation Army*, 45(1), 1–20. <https://doi.org/10.11855/j.issn.0577-7402.2020.01.01>
- Jmour, N., Zayen, S., & Abdelkrim, A. (2019). Convolutional neural networks for image classification. *CEUR Workshop Proceedings*, 2546, 101–114.
- Ker, J., Wang, L., Rao, J., & Lim, T. (2017). Deep Learning Applications in Medical Image Analysis. *IEEE Access*, 6, 9375–9379. <https://doi.org/10.1109/ACCESS.2017.2788044>
- Kim, M., Yun, J., Cho, Y., Shin, K., Jang, R., Bae, H., & Kim, N. (2019). Deep Learning in Medical Imaging. *Neurospine* 2019, 16(4), 657–668.
- Kogilavani, S. V., Prabhu, J., Sandhiya, R., Kumar, M. S., Subramaniam, U. S., Karthick, A., Muhibbullah, M., & Imam, S. B. S. (2022). COVID-19 Detection Based on Lung Ct Scan Using Deep Learning Techniques. *Computational and Mathematical Methods in Medicine*, 2022. <https://doi.org/10.1155/2022/7672196>
- Kohavi, R., & Provost, F. (2016). *Glossary of Terms*. November. <https://doi.org/10.1023/A>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *NIPS'12: Proceedings of the 25th International Conference on Neural Information Processing Systems*, 1097–1105.
- Kumar, M. D., Babaie, M., Zhu, S., Kalra, S., & H.R.Tizhoosh. (2017). A Comparative Study of CNN, BoVW and LBP for Classification of Histopathological Images. *IEEE Symposium Series on Computational Intelligence (IEEE SSCI 2017)*, 1–7.
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2323. <https://doi.org/10.1109/5.726791>
- Liao, F., Liang, M., Li, Z., Hu, X., & Song, S. (2017). Evaluate the Malignancy of Pulmonary Nodules Using the 3-D Deep Leaky Noisy-OR Network. *IEEE Transactions on Neural Networks and Learning Systems*, 30(11), 3484–3495. <https://doi.org/10.1109/TNNLS.2019.2892409>
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42(December 2012), 60–88. <https://doi.org/10.1016/j.media.2017.07.005>
- Lo, S.-C. B., Lou, S.-L. A., Lin, J.-S., Freedman, M. T., Chien, M. V, & Mun, S. K. (1995). Artificial Convolution Neural Network Techniques and Applications for Lung Nodule Detection. *Ieee Transactions on Medical Imaging*, 14(4), 711–718. https://www.researchgate.net/profile/Seong_Mun/publication/3220638_Artificial_Convolution_Neural_Network_Techniques_and_Applications_for_Lung_Nodule_Detection/links/59cd2a09a6fdcc0333ebcd74/Artificial-Convolution-Neural-Network-Techniques-and-Applications
- Loddo, A., Pili, F., & Di Ruberto, C. (2021). Deep learning for covid-19 diagnosis from ct images. *Applied Sciences (Switzerland)*, 11(17). <https://doi.org/10.3390/app11178227>
- Loey, M., Manogaran, G., & Khalifa, N. E. M. (2020). A deep transfer learning model with classical data augmentation and CGAN to detect COVID-19 from chest CT

- radiography digital images. *Neural Computing and Applications*, 0123456789. <https://doi.org/10.1007/s00521-020-05437-x>
- Maghdid, H., Asaad, A. T., Ghafoor, K. Z. G., Sadiq, A. S., Mirjalili, S., & Khan, M. K. (2021). *Diagnosing COVID-19 pneumonia from x-ray and CT images using deep learning and transfer learning algorithms*. 26. <https://doi.org/10.1117/12.2588672>
- Milletari, F., Navab, N., & Ahmadi, S. A. (2016). V-Net: Fully convolutional neural networks for volumetric medical image segmentation. *Proceedings - 2016 4th International Conference on 3D Vision, 3DV 2016*, 565–571. <https://doi.org/10.1109/3DV.2016.79>
- Minsky, M., & Papert, S. (1969). *Perceptrons: An introduction to computational geometry* (1st ed.). MIT Press.
- Moeskops, P., Viergever, M. A., Mendrik, A. M., De Vries, L. S., Benders, M. J. N. L., & Isgum, I. (2016). Automatic Segmentation of MR Brain Images with a Convolutional Neural Network. *IEEE Transactions on Medical Imaging*, 35(5), 1252–1261. <https://doi.org/10.1109/TMI.2016.2548501>
- Nardelli, P., Jimenez-Carretero, D., Bermejo-Pelaez, D., Washko, G. R., Rahaghi, F. N., Ledesma-Carbayo, M. J., & San Jose Estepar, R. (2018). Pulmonary Artery-Vein Classification in CT Images Using Deep Learning. *IEEE Transactions on Medical Imaging*, 37(11), 2428–2440. <https://doi.org/10.1109/TMI.2018.2833385>
- Narin, A., Kaya, C., & Pamuk, Z. (2020). Automatic Detection of Coronavirus Disease (COVID-19) Using X-ray Images and Deep Convolutional Neural Networks. *ArXiv Preprint ArXiv:2003.10849*. <https://arxiv.org/abs/2003.10849>
- Pandit, M. K., Banday, S. A., Naaz, R., & Chishti, M. A. (2021). Automatic detection of COVID-19 from chest radiographs using deep learning. *Radiography*, 27(2), 483–489. <https://doi.org/10.1016/j.radi.2020.10.018>
- Panwar, H., Gupta, P. K., Siddiqui, M. K., Morales-Menendez, R., & Singh, V. (2020). Chaos , Solitons and Fractals Application of deep learning for fast detection of COVID-19 in X-Rays using nCOVnet. *Chaos, Solitons and Fractals: The Interdisciplinary Journal of Nonlinear Science, and Nonequilibrium and Complex Phenomena*, 138, 109944. <https://doi.org/10.1016/j.chaos.2020.109944>
- Pathak, Y., Shukla, P. K., Tiwari, A., Stalin, S., & Singh, S. (2020). Deep Transfer Learning Based Classification Model for COVID-19 Disease. *Irbm*, 1, 1–6. <https://doi.org/10.1016/j.irbm.2020.05.003>
- Peiris, J. S. M., Lai, S. T., Poon, L. L. M., Guan, Y., Yam, L. Y. C., Lim, W., Nicholls, J., Yee, W. K. S., Yan, W. W., Cheung, M. T., Cheng, V. C. C., Chan, K. H., Tsang, D. N. C., Yung, R. W. H., Ng, T. K., & Yuen, K. Y. (2020). *Coronavirus as a possible cause of severe acute respiratory syndrome*. January.
- Pitts, W., & McCulloch, W. S. (1943). A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, Volume 5. https://doi.org/10.1007/978-3-030-01370-7_61
- Polsinelli, M., Cinque, L., & Placidi, G. (2020). A light CNN for detecting COVID-19 from CT scans of the chest. *Pattern Recognition Letters*, 140, 95–100. <https://doi.org/10.1016/j.patrec.2020.10.001>
- Pratt, H., Coenen, F., Broadbent, D. M., Harding, S. P., & Zheng, Y. (2016). Convolutional Neural Networks for Diabetic Retinopathy. *Procedia Computer Science*, 90(July), 200–205. <https://doi.org/10.1016/j.procs.2016.07.014>
- Quinlan, J. R. (1986). Induction of decision trees. *Machine Learning*, 1(1), 81–106. <https://doi.org/10.1007/bf00116251>

- Rahimzadeh, M., Attar, A., & Sakhaei, S. M. (2021). A fully automated deep learning-based network for detecting COVID-19 from a new and large lung CT scan dataset. *Biomedical Signal Processing and Control*, 68(February), 102588. <https://doi.org/10.1016/j.bspc.2021.102588>
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Langlotz, C., Shpanskaya, K., Lungren, M. P., & Ng, A. Y. (2017). *CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning*. 3–9. <http://arxiv.org/abs/1711.05225>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *Lecture Notes in Computer Science*, 9351(Cvd), 12–20. <https://doi.org/10.1007/978-3-319-24574-4>
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. <https://doi.org/10.1037/h0042519>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323, pages533–536. <https://www.nature.com/articles/323533a0>
- Saeedi, A., Saeedi, M., & Maghsoudi, A. (2020). *A Novel and Reliable Deep Learning Web-Based Tool to Detect COVID-19 Infection from Chest CT-Scan*. July. <http://arxiv.org/abs/2006.14419>
- Sangeetha, V., & Prasad, K. J. R. (2006). Syntheses of novel derivatives of 2-acetylfuro[2,3-a]carbazoles, benzo[1,2-b]-1,4-thiazepino[2,3-a]carbazoles and 1-acetyloxycarbazole-2- carbaldehydes. *Indian Journal of Chemistry - Section B Organic and Medicinal Chemistry*, 45(8), 1951–1954. <https://doi.org/10.1002/chin.200650130>
- Setio, A. A. A., Ciompi, F., Litjens, G., Gerke, P., Jacobs, C., Van Riel, S. J., Wille, M. M. W., Naqibullah, M., Sanchez, C. I., & Van Ginneken, B. (2016). Pulmonary Nodule Detection in CT Images: False Positive Reduction Using Multi-View Convolutional Networks. *IEEE Transactions on Medical Imaging*, 35(5), 1160–1169. <https://doi.org/10.1109/TMI.2016.2536809>
- Shah, V., Keniya, R., Shridharani, A., Punjabi, M., Shah, J., & Mehendale, N. (2021). Diagnosis of COVID-19 using CT scan images and deep learning techniques. *Emergency Radiology*, 28(3), 497–505. <https://doi.org/10.1007/s10140-020-01886-y>
- Shen, W., Zhou, M., Yang, F., Yang, C., & Tian, J. (2015). Multi-scale Convolutional Neural Networks for Lung Nodule Classification. *International Conference on Information Processing in Medical Imaging*. https://link.springer.com/chapter/10.1007/978-3-319-19992-4_46#citeas
- Shin, H.-C., Roth, H. R., Gao, M., Lu, L., Xu, Z., Nogues, I., Yao, J., Mollura, D., & Summers, R. M. (2016). Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning. *IEEE Transactions on Medical Imaging*, 35(5), 1285–1298.
- Simard, P. Y., Steinkraus, D., & Platt, J. C. (2003). Best practices for convolutional neural networks applied to visual document analysis. *Proceedings of the International Conference on Document Analysis and Recognition, ICDAR, 2003-Janua*(January), 958–963. <https://doi.org/10.1109/ICDAR.2003.1227801>
- Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *3rd International Conference on Learning Representations*,

- ICLR 2015 - Conference Track Proceedings*, 1–14.
- Singh, D., Kumar, V., & Kaur, M. (2020). Classification of COVID-19 patients from chest CT images using multi-objective differential evolution – based convolutional neural networks. *European Journal of Clinical Microbiology & Infectious Diseases*, 39, 1379–1389.
- Singhal, T. (2020). A Review of Coronavirus Disease-2019 (COVID-19). *The Indian Journal of Pediatrics*, 87(April), 281–286.
- Sirinukunwattana, K., Raza, S. E. A., Tsang, Y. W., Snead, D. R. J., Cree, I. A., & Rajpoot, N. M. (2016). Locality Sensitive Deep Learning for Detection and Classification of Nuclei in Routine Colon Cancer Histology Images. *IEEE Transactions on Medical Imaging*, 35(5), 1196–1206. <https://doi.org/10.1109/TMI.2016.2525803>
- Song, Y., Zheng, S., Li, L., Zhang, X., Zhang, X., Huang, Z., Chen, J., Wang, R., Zhao, H., Chong, Y., Shen, J., Zha, Y., & Yang, Y. (2021). Deep Learning Enables Accurate Diagnosis of Novel Coronavirus (COVID-19) With CT Images. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 18(6), 2775–2780.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15, 1929–1958. [https://doi.org/10.1016/0370-2693\(93\)90272-J](https://doi.org/10.1016/0370-2693(93)90272-J)
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 07-12-June, 1–9. <https://doi.org/10.1109/CVPR.2015.7298594>
- T.C. Sağlık Bakanlığı. (2022). *T.C. Sağlık Bakanlığı COVID-19 Bilgilendirme Platformu*.
- Tarando, S. R., Fetita, C., Faccineto, A., & Brillet, P.-Y. (2016). Increasing CAD system efficacy for lung texture analysis using a convolutional network. *Medical Imaging 2016: Computer-Aided Diagnosis*.
- Wang, B., Jin, S., Yan, Q., Xu, H., Luo, C., & Wei, L. (2020). AI-assisted CT imaging analysis for COVID-19 screening: Building and deploying a medical AI system. *Applied Soft Computing Journal*, 98(January).
- Wang, S., Kang, B., Ma, J., Zeng, X., Xiao, M., Guo, J., Cai, M., Yang, J., Li, Y., Meng, X., & Xu, B. (2021). A deep learning algorithm using CT images to screen for Corona virus disease (COVID-19). *European Radiology*, 31(8), 6096–6104. <https://doi.org/10.1007/s00330-021-07715-1>
- Wang, X., Deng, X., Fu, Q., Zhou, Q., Feng, J., Ma, H., Liu, W., & Zheng, C. (2020). A Weakly-Supervised Framework for COVID-19 Classification and Lesion Localization From Chest CT. *Ieee Transactions on Medical Imaging*, 39(8), 2615–2625.
- WHO. (2003). *World Health Organization-Severe acute respiratory syndrome (SARS)*. World Health Organization.
- Xie, Y., Zhang, Z., Sapkota, M., & B, L. Y. (2016). Spatial Clockwork Recurrent Neural Network for Muscle Perimysium Segmentation Yuanpu. *MICCAI 2016. Lecture Notes in Computer Science*, 9901. <https://doi.org/10.1007/978-3-319-46723-8>
- Xu, X., Jiang, X., Ma, C., Du, P., Li, X., Lv, S., Yu, L., Ni, Q., Chen, Y., Su, J., Lang, G., Li, Y., Zhao, H., Liu, J., Xu, K., Ruan, L., Sheng, J., Qiu, Y., Wu, W., ... Li, L. (2020). A Deep Learning System to Screen Novel Coronavirus Disease 2019

- Pneumonia. In *Engineering* (Vol. 6, Issue 10, pp. 1122–1129). <https://doi.org/10.1016/j.eng.2020.04.010>
- Yang, S., Jiang, L., Cao, Z., Wang, L., Cao, J., Feng, R., Zhang, Z., Xue, X., Shi, Y., & Shan, F. (2020). Deep learning for detecting corona virus disease 2019 (COVID-19) on high-resolution computed tomography: a pilot study. *Annals of Translational Medicine*, 8(7), 450–450. <https://doi.org/10.21037/atm.2020.03.132>
- Yang, X., He, X., Zhao, J., Zhang, Y., Zhang, S., & Xie, P. (2020). *COVID-CT-Dataset: A CT Scan Dataset about COVID-19. December*. <http://arxiv.org/abs/2003.13865>
- Yilmaz, E. (2016). Fetal State Assessment from Cardiotocogram Data Using Artificial Neural Networks. *Journal of Medical and Biological Engineering*, 36(6), 820–832. <https://doi.org/10.1007/s40846-016-0191-3>
- Yousefzadeh, M., Esfahanian, P., Movahed, S. M. S., Gorgin, S., Rahmati, D., Abedini, A., Nadji, S. A., Haseli, S., Karam, M. B., Kiani, A., Hoseinyazdi, M., Roshandel, J., & Lashgari, R. (2021). Ai-corona: Radiologist-assistant deep learning framework for COVID-19 diagnosis in chest CT scans. In *PLoS ONE* (Vol. 16, Issue 5 May). <https://doi.org/10.1371/journal.pone.0250952>
- Zeiler, M. D., & Fergus, R. (2014). Visualizing and Understanding Convolutional Networks. In *European Conference on Computer Vision–ECCV 2014. ECCV 2014. Lecture Notes in Computer Science* (Vol. 8689). <https://doi.org/10.1016/j.ancr.2017.02.001>

ÖZGEÇMİŞ

Adı Soyadı : Feyzanur Banu DEMİR
Doğum Yeri ve Tarihi : Trabzon / 1997
Yabancı Dil : İngilizce

Eğitim Durumu
Lise : Trabzon Kanuni Anadolu Lisesi
Lisans : Karadeniz Teknik Üniversitesi
Yüksek Lisans : Bursa Uludağ Üniversitesi

Çalıştığı Kurum/Kurumlar : Bursa Uludağ Üniversitesi- Elektrik-Elektronik Müh.

İletişim (e-posta) : feyzanurdemir@uludag.edu.tr

Yayınları : Demir, F. B. & Yılmaz, E. (2021). X-Ray Görüntülerinden COVID-19 Tespiti için Derin Öğrenme Temelli Bir Yaklaşım. Avrupa Bilim ve Teknoloji Dergisi , Ejosat Özel Sayı 2021 (RDCONF) , 627-632 . DOI: 10.31590/ejosat.1039522