



## COVID-19 HASTALIĞININ TEŞHİSİNDE DERİN ÖĞRENME VE VERİ MAHREMİYETİ

Yavuz CANBAY<sup>1\*</sup>, Abdullah İSMETOĞLU<sup>2</sup>, Pelin CANBAY<sup>3</sup>

<sup>1,3</sup> Kahramanmaraş Sütçü İmam Üniversitesi, Bilgisayar Mühendisliği Bölümü Kahramanmaraş, Türkiye

<sup>2</sup> Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, Kahramanmaraş, Türkiye

### Anahtar Kelimeler

### Öz

Yapay Zekâ,  
Derin Öğrenme,  
Veri Mahremiyeti,  
Covid-19,  
Araştırma.

Covid-19 hastalığı, ortaya çıktığı günden bugüne birçok can kaybına yol açmıştır. Dünya Sağlık Örgütü (DSÖ) tarafından pandemi olarak ilan edilen bu hastalığa yakalanan kişilerde ciddi akciğer tahribatları oluşabilmektedir. Hekimlerin bu hastalığın teşhisinde akciğer özelinde çekilen bilgisayarlı tomografi (Computed Tomography - CT) ve X-Ray (Chest X-Ray - CXR) görüntülerini inceleyerek teşhis koydukları bilinmektedir. Bu CXR görüntülerinin çekildiği anda enfekte olduğu değerlendirilen kişilere hekim kontrolü öncesi yapılacak bir erken teşhis ile koruyucu önlemler hızlıca alınabilir ve hekimlerin hastalığı teşhis süreçleri kısaltılabilir. Diğer birçok hastalığın teşhisinde başarılı sonuçlar üreten yapay zekâ yöntemlerinin, Covid-19 hastalığında da başarılı sonuçlar ürettiği güncel çalışmalarda görülebilmektedir. Elde edilen başarılı sonuçların yanında, kullanılan sağlık verileri kişisel veri sınıfına girdiği için bu verilerin işlenmesinde ve analiz edilmesinde mahremiyet koruyucu önlemlere ihtiyaç olduğu açıktır. Gerek Kişisel Verileri Koruma Kanunu (KVKK) gerekse de Genel Veri Koruma Tüzüğü (General Data Protection Rule - GDPR), bu tür verilerin işlenmesinde mahremiyetin korunmasına özen gösterilmesi gerekliliğini ortaya koymaktadır. Bu çalışmada, Covid-19 hastalığını tespit eden yapay zekâ odaklı çalışmalar incelenmiş, kullanılan açık veri kümeleri sunulmuş, Covid-19 hastalığının tespitinde mahremiyeti dikkate alan çalışmalar gözden geçirilerek genel değerlendirmelerde bulunulmuştur.

## DEEP LEARNING AND DATA PRIVACY IN DIAGNOSIS OF COVID-19

### Keywords

### Abstract

Artificial Intelligence,  
Deep Learning,  
Data Privacy,  
Covid-19,  
Review.

Covid-19 disease has caused many mortalities since the day it emerged. People who suffer from this disease, which is announced as a pandemic by World Health Organization (WHO), are more likely to have serious lung damages. It is known that physicians diagnose this disease by examining computed tomography (CT) and X-Ray (Chest X-Ray - CXR) images of the lung. At the moment these CXR images are taken, preventive measures can be taken quickly with an early diagnosis before physician control the people who are considered to be infected, and in addition, physicians' diagnosis processes can be shortened. It can be seen from the literature that artificial intelligence methods have produced successful results in the diagnosis of Covid-19 disease. Besides the successful results, it is a fact that since the health data is classified as personal data, privacy preserving measures are required in the processing and analysis of these data. Both Personal Data Protection Law and General Data Protection Rule (GDPR) reveal the need to focus on preserving privacy in the processing of these data. In this study, studies focusing on artificial intelligence to detect Covid-19 disease were examined, the open data sets used in the literature were presented, studies considering privacy in the detection of Covid-19 were investigated and general evaluations were presented.

### Alıntı / Cite

Canbay, Y., İsmetoğlu A., Canbay, P., (2021). Covid-19 Hastalığının Teşhisinde Derin Öğrenme ve Veri Mahremiyeti, Mühendislik Bilimleri ve Tasarım Dergisi, 9(2), 701-715.

### Yazar Kimliği / Author ID (ORCID Number)

Y. Canbay, 0000-0003-2316-7893  
A. İsmetoğlu, 0000-0002-4291-6450  
P. Canbay, 0000-0002-8067-3365

### Makale Süreci / Article Process

Başvuru Tarihi / Submission Date	28.01.2021
Revizyon Tarihi / Revision Date	23.03.2021
Kabul Tarihi / Accepted Date	04.04.2021
Yayın Tarihi / Published Date	20.06.2021

\* İlgili yazar / Corresponding author, yavuzcanbay@ksu.edu.tr, +90-344-300-1705

## 1. Giriş (Introduction)

Covid-19, insanlara ve hayvanlara bulaşabilen, patojeni olan tek sarmallı bir RNA virüsü olup, 2019 yılında Çin'in Wuhan kentinden dünyaya yayılarak bir pandemi haline gelmiştir (Akkuş, 2020). Bu hastalığın tespitinde PCR testleri kullanılmakla beraber, hekimler ek olarak CT ve CXR grafikleri de isteyerek teşhis koyabilmektedir. Dünya Sağlık Örgütü verilerine göre Covid-19 hastalığında vaka sayısı dünya çapında 120 milyonu geçmiştir ve halen yayılmaya devam etmektedir (World Health Organization, 2021). Söz konusu hastalığın tespitinde kullanılan PCR testlerinin maliyetli olması, bu testlerin sonuçlarının uzun sürede çıkması ve bundan dolayı hekimlerin tedavi aşamalarına kısa sürede başlayamamasından dolayı, hastalığın tespitinde bu süreci iyileştirecek zeki sistemlerin kullanılması kaçınılmaz olmuştur (Narin vd., 2020).

Yapay zekâ yöntemleri, özellikle derin öğrenme algoritmaları son yıllarda sağlık alanında önemli çözümler sunan bir teknoloji haline gelmiştir. Dünyada çoğu hastalığın tespitinde yapay zekâ yöntemlerinden faydalanılmaktadır (Karaküçük ve Eker, 2020). Covid-19 hastalığının teşhisinde de yapay zekâ yöntemlerinin kullanıldığı literatürdeki çeşitli çalışmalarda görülmektedir. Derin öğrenme algoritmaları ile geliştirilmiş birçok başarılı sistem Covid-19 hastalığı ile mücadele sürecinde faydalı olacaktır fakat bu sistemlerin ilgili hastaların mahremiyetini de dikkate alması gerektiği de sürecin bir diğer önemli boyutudur.

Mahremiyet, günümüzde kanunlarla koruma altına alınan temel bir ihtiyaç haline gelmiştir. Özellikle, teknolojinin hızlı bir şekilde gelişerek her alanda varlığını gösterdiği bu dönemde birçok siber saldırıya maruz kalan insanların mahremiyetinin korunması, insanların gerçek ve sanal ortamlarda birey olabilmeye hakkı olarak tanımlanabilir (Canbay vd., 2020). Veri mahremiyeti, toplanan verilerin sistem içerisinde veri sorumluları tarafından hukuka ve etik kurallara uygun olarak işlenmesi ve korunmasıdır (Vural, 2018).

Günlük yaşamımızın ayrılmaz parçası olan bilişim teknolojileri, uygulamalar aracılığıyla her geçen gün büyüklüğü ve çeşitliliği artan veriler toplamakta ve işlenmektedir. Toplanma amaçları farklı olsa da bu veriler içerisinde kişileri doğrudan veya dolaylı olarak tanımlayabilen çeşitli bilgileri içerebilir. Kişisel verilerin işlenmesinde olması gereken idari ve teknik tedbirlerin alınmaması veri ihlallerinin sıklıkla yaşanmasına neden olmaktadır. Veri ihlallerinin zararlarının azaltılması amacıyla mahremiyet koruyucu önlemlerin alınması gerekir. Veri mahremiyeti, veri sahibi ile bu veriyi kullanacak olan paydaşlar arasında verinin nasıl saklanacağı, nerde kullanılacağı ve kimlerle ne düzeyde paylaşılacağı arasında denge kurmaya çalışan önemli bir konudur.

Veri mahremiyeti veri sahibinin mahremiyetini korumada yardımcı olsa da, aynı zamanda, verinin fayda sağlama avantajını da sağlar (Canbay vd., 2020). Mahremiyet odaklı veri ihlallerinin en aza indirgenmesi amacıyla mevcut saldırıların ve eksikliklerin tespit edilmesine ve yeni mahremiyet koruyucu modellere ihtiyaç vardır. Veri mahremiyetinin korunmasına yönelik çalışmalar yapılarak kişisel verilerin kanunlara uygun olarak işlenmesindeki uyumsuzlukların giderilmesi, kişisel verilerin korunması açısından önemlidir (Vural, 2018).

Kişisel Verileri Koruma Kurumu, yayınlamış olduğu kamuoyu duyurusunda, kişisel verilerin pandemi durumunda da hukuka uygun ve temel ilkeler esas alınarak işlenmesi gerektiğine ve veri güvenliğine yönelik gerekli idari ve teknik tedbirlerin alınmasının gerektiğine değinmiştir (Kişisel Verileri Koruma Kurumu, 2020). Bu duyuruda, veri toplayıcıların veya sorumlularının bir kişisel veri olan hastalık ile ilgili verileri paylaşırken hastanın mahremiyetini de dikkate alarak paylaşması gerektiği, aksi takdirde gerekli her türlü idari ve cezai yaptırımların yapılacağı açıkça ifade edilmiştir. Ancak bilgi toplumunda cezalar dâhil tüm yaptırımlar, mahremiyet ihlallerinin tamamının önüne geçememektedir. Gerek veri paylaşımı gerekse de verilerin analiz edilmesi hususunda, Covid-19 verilerinin sahiplerinin mahremiyetini korumak önemli bir problemdir. Covid-19 hastalarına ait CT ve CXR görüntüleri kişisel veri olduğu için bu verilerin analiz edilmesi aşamasında veri mahremiyetinin sağlanması gerekmektedir. Özellikle son zamanlarda CT ve CXR görüntülerinden Covid-19 tespiti yapılan çalışmalar analiz edildiğinde, veri mahremiyeti hususuna gerekli önemin verilmediği görülmüştür.

Bu çalışmada, Covid-19 hastalığının tespitinde yapay zekâ yöntemlerinden derin öğrenme yaklaşımlarını kullanan çalışmalar irdelenmiş, literatürde bu alanda kullanılan veri kümeleri gözden geçirilmiş, bu hastalığının tespitinde veri mahremiyetini dikkate alan çalışmalar derlenerek mevcut durum analizi yapılmıştır.


Bu çalışma beş bölümden oluşmaktadır. Bölüm 2'de konu kapsamında ilgili çeşitli tanımlara yer verilmiştir. Bölüm 3'de detaylı literatür incelemesi yapılarak bu alandaki çalışmalar gözden geçirilmiştir. Bölüm 4'te bu çalışma kapsamında elde edilen araştırma bulgularına yer verilmiştir. Son olarak Bölüm 5'te ise çalışma kapsamında elde edilen sonuçlar sunulmuştur.

## 2. Tanımlar (Definitions)

Bu bölümde, Covid-19 hastalığı, yapay zekâ, derin öğrenme ve veri mahremiyeti kavramları için tanımlar sunulmuştur.

### 2.1 Covid-19 Hastalığı (Covid-19 Disease)

Covid-19 hastalığı, 2019 yılında Çin'in Wuhan kentinde başlamış olup bugün DSÖ tarafından pandemi olarak kabul edilmiştir. Covid-19 virüsü, insanlara ve hayvanlara bulaşabilen, patojeni olan tek sarmallı bir RNA virüsüdür. Toplam vaka sayısı tüm dünyada 120 milyonu geçmiş ve ülkemizde ise 2,9 milyon rakamını aşmış olup halen hızlı bir şekilde artmaya da devam etmektedir. Covid-19 hastalığı sebebiyle hayatını kaybedenlerin sayısı ise dünyada 2.5 milyonu geçmiş olup ülkemizde otuz bin rakamına ulaşmıştır ( World Health Organization, 2021). Covid-19 virüsü solunum yoluyla insan vücuduna girerek kişinin akciğerinde kalıcı hasarlar bırakabilmektedir. Şekil 1'de Covid-19 hastası 3 kişi için çekilen CXR görüntüleri verilmiştir. Daire içine alınan kısımlar Covid-19 virüsünün sebep olduğu akciğerdeki tahribatları göstermektedir.




Şekil 1. Üç farklı hastadan Covid-19 için çekilen CXR görüntüleri (CXR images taken from three different Covid-19 patients) (Minaee vd., 2020)

Covid-19 hastalık teşhisinde patojenik laboratuvar testleri vazgeçilmez bir standart olmasına rağmen test sonuçları ciddi zaman almaktadır. Bu nedenle, hastalığın hızlıca tespiti için yapay zekâ destekli sistemlere ihtiyaç vardır. CT ve CXR görüntülerindeki Covid-19 temelli radyografik değişikliklere dayanarak, yapay zekânın derin öğrenme yöntemlerinin Covid-19'un spesifik grafik özelliklerini çıkarabileceğini, patojenik testten önce klinik bir tanı sağlayabileceğini ve böylece hastalığın kontrolü için kritik bir öneme sahip olan zamandan tasarruf edilebileceği değerlendirilmektedir.

### 2.2 Derin Öğrenme (Deep Learning)

Yapay zekâ literatürde genel olarak, insan zekâsının çalışma yapısını bilgisayarlara aktararak bilgisayarların insana özgü davranışlarından olan, sonuç çıkarma, çözüm bulma, genelleme yapabilme, problemi anlama ve geçmişteki deneyimlerinden yararlanarak öğrenme gibi mantık gerektiren görevlerini yerine getirme kabiliyeti olarak tanımlanmıştır (Nabiyev, 2012). Yapay zekâ, bilgisayar sisteminde insan zekâsını kopyalamaya veya taklit etmeye çalışan bir bilim dalıdır. Şekil 2'den de görüleceği üzere, yapay zekâ genel olarak makine öğrenmesi ve derin öğrenme alt alanlarını içermektedir.



Şekil 2. Yapay zekâ, makine öğrenmesi ve derin öğrenme bağlantısı (The relationship between artificial intelligence, machine learning and deep learning) (Alafi, 2019)

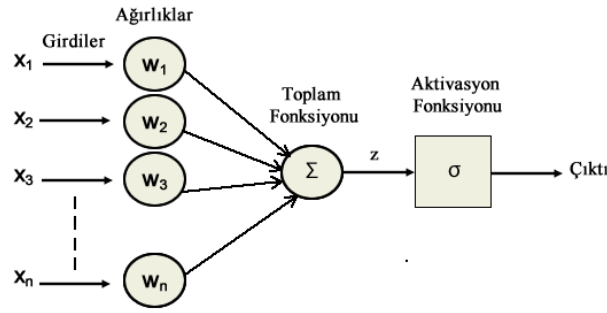
Derin öğrenme, yapay sinir ağları aracılığıyla tanınan ve beyin nöronlarının çalışma prensibinden esinlenen bir makine öğrenimi tekniğidir (Alafi, 2019). Karmaşık derin sinir ağları ilk defa (Lecun vd., 2015) çalışmasında

başarılı bir şekilde eğitilmiştir. Derin öğrenme, belirli bir göreve özgü algoritmaların aksine, veri temsillerine dayalı makine öğrenimi yöntemi olup çok büyük miktarda yapısal olmayan veya etiketlenmemiş veriden de öğrenebildiği için, pek çok uygulamada avantajlar sağlamaktadır. Diğer makine öğrenmesi yaklaşımları ile karşılaştırıldığında derin öğrenme, daha soyut bilgiler öğrenmek için derin mimariler inşa etme avantajına sahiptir. Derin öğrenme yöntemlerinin en önemli özelliği, öznitelik temsillerini otomatik olarak öğrenebilmesi ve böylece çok fazla zaman alan işlemlerden kaçınmasıdır (Coşkun vd., 2017).

Bu başlıkta, derin öğrenmedeki temel mimarilerden olan Derin Sinir Ağları (Deep Neural Network - DNN), Evrişimli Sinir Ağları (Convolutional Neural Network - CNN), Tekrarlayan Sinir Ağları (Recurrent Neural Network - RNN) ve son olarak Uzun Kısa Süreli Bellek (Long Short Term Memory - LSTM) açıklanmıştır.


### 2.2.1. DNN mimarisi (Architecture of DNN)

DNN, insanın beyin fonksiyonlarının makineler tarafından taklit edilebilmesi amacıyla geliştirilmiş işlem birimleridir. Katmanlı yapılarda nöron adı verilen temel işlem birimleri, katmanlar arasındaki bağlantılar sayesinde birbiri ile iletişimde bulunur (P. Canbay, 2020). Bilgi, DNN sistemi ve mimarisi tarafından, makinenin kendi kendine öğrenme yetenekleri olarak adlandırılan bir öğrenme süreci aracılığıyla edinilir (Goodfellow vd., 2016). Şekil 3'te tek katmanlı ve tek sinir hücreli en temel sinir ağı gösterimi verilmiştir.



Şekil 3. Bir yapay sinir hücresi örneği (An example for an artificial neuron) (P. Canbay, 2020)

Derin öğrenmenin ana ilham kaynağı, süregelen bilgi, gözlem ve deneyimdir. Genel olarak bir girdi katmanı, çok sayıda gizli katman ve bir tane çıktı katmanından oluşur. Günümüzde pek çok alanda kullanılmakla beraber özellikle ses işleme, doğal dil işleme, makine çevirisi ve görüntü işleme alanlarında sıklıkla tercih edilmektedir (Canbay ve Sağıroğlu, 2020). Şekil 4'te içinde üç nöron bulunan bir giriş katmanı, her biri 4 dört nörondan oluşan iki gizli katman ve tek bir nöron içeren çıkış katmanı için bir DNN mimari yapısı örneği verilmiştir.



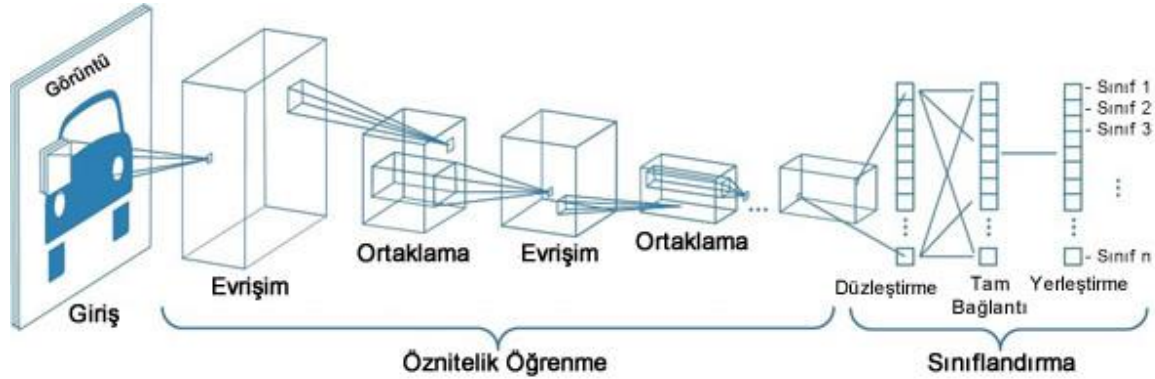
Şekil 4. Bir DNN mimarisi örneği (An example of DNN architecture) (Kimanuka ve Büyük, 2018)

DNN, birbirine bağlı nöronlardan oluşmakta olup bu nöronlar katmanlar halinde yapılandırılmıştır. DNN mimarisi 3 katmandan oluşur. Bunlar; giriş katmanı (veri özelliklerinden oluşur), gizli katman (birden fazla gizli birimden oluşur) ve son olarak çıktı katmanıdır. DNN mimarisinin birden fazla gizli katmana sahip olduğu için derin sinir ağı olarak ifade edilmesinin temel sebebi budur (Kimanuka ve Büyük, 2018). DNN mimarisinde bulunan gizli katmanlardaki nöronların sayısı, sınıflandırma doğruluğunda hayati bir rol oynamaktadır. DNN mimarisini klasik yapay sinir ağlarından ayıran en önemli özelliği, bu mimarinin çok katmanlı ve her katmanında da çok sayıda nöron içermesidir (Aydoğan ve Karci, 2020).

### 2.2.2. CNN mimarisi (Architecture of CNN)

Görüntü tanıma problemlerinde yoğun olarak kullanılan CNN mimarisi ilk olarak (Fukushima, 1980) çalışmasında tanıtılmış, kullanımı ise ilk olarak (LeCun vd., 1998) çalışmasında önerilmiştir. CNN mimarisi genel olarak evrişim ve ortaklama katmanlarını içerir. Evrişim katmanı ile öznitelik haritaları oluşturulur. Her evrişim katmanında


farklı filtreler uygulanabilir (Coşkun vd., 2017). Matematiksel olarak bir öznetelik haritası tarafından gerçekleştirilen her filtreleme işlemi, ayrı bir evrişimdir. Evrişim katmanlarında gerçekleşen filtreleme işlemi sonucunda, ortaklama katmanları anlamsal olarak benzer özellikleri tekrar bir araya getirmektedir. En son gerçekleşen ortaklama işleminden sonra, görüntünün düzeltilmesi ve tespit edilen özelliklere göre sınıflandırılması yapılmaktadır (Lecun vd., 2015). Şekil 5'te CNN mimarisinin çalışma prensibi ve içerdiği katmanlar verilmiştir.



Şekil 5. CNN mimarisi çalışma prensibi (The working principle of CNN architecture) (Tan, 2019)


### 2.2.3. RNN mimarisi (Architecture of RNN)

Sıralı bir şekilde bulunan verileri işlemek için kullanılan bir derin öğrenme mimarisidir (Onan, 2020). RNN'de mevcut giriş bilgileri önceki giriş bilgileri ile birlikte değerlendirilir. Yani RNN'ler önceki bilgileri ile yeni öğrendiği bilgileri birlikte değerlendirirler. Örneğin; bir konuşma esnasında genellikle  $t-1$  anında kullanılan kelime  $t$  anında kullanılan kelimeyle,  $t$  anında kullanılan kelime ise  $t+1$  anında kullanılan kelimeyle bağlantılıdır (P. Canbay, 2020). RNN'de önceki işlemin çıktısı sonraki işlemin girdisi olarak kullanıldığı için, RNN'ler iletir beslemeli sinir ağlarından farklı bir yapıya sahiptir. RNN mimarisinde giriş verileri ağdan geçirilerek bir çıkış değeri elde edilir. Elde edilen bu çıkış değeri olması gereken değerler ile karşılaştırılarak değerlerde farklılık olup olmadığı kontrol edilir ve varsa hata ölçümü yapılır. Ağ üzerindeki ağırlık değerleri hataya bağlı olarak değiştirilir ve bu şekilde en doğru sonuca ulaşılarak çıktı verebilen bir model oluşturulmuş olur. RNN mimarisi girdi verilerini işleme alırken kendi hafızalarını kullanmaktadır (Metin ve Karasulu, 2015). Şekil 6'da tekrarlayan sinir ağı mimarisi ve mimarinin hesaplamasına ait yapı verilmiştir.



Şekil 6. Tekrarlayan sinir ağı mimarisi örneği (An example of recurrent neural network architecture) (Zheng vd., 2017)

RNN mimarisinin yapısında, bir giriş katmanı, iki gizli katman ve bir çıkış katmanı bulunur. Bu katmanların hepsi birbirinden bağımsız bir şekilde çalışmaktadır. Dolayısıyla her katmanın kendine göre bir işlevi vardır ve her katman farklı bir görevi yerine getirir. Bu sayede sistemin daha geçerli sonuçlar vermesi amaçlanmaktadır (Britz, 2015). Tekrarlanan bu aşamalar sonucunda bir önceki giriş durumu depolanır ve yeni elde edilen giriş değeriyle birleştirilir. Bu sayede yeni elde edilen girişin bir önceki girişle olan ilişkisi sağlanır. Bu yaklaşım, ses tanıma, doğal dil işleme gibi önceki girdiler hakkında bilgi gerektiren çeşitli görevler için faydalıdır.




Şekil 7. (a) İleri doğru bilgi işleme yapan sinir ağı yapısı (Neural network structure with feed forward processing), (b) Tekrarlayan sinir ağı yapısı (Recurrent neural network structure) (De Campos, 2017)

Şekil 7’de ileri doğru bilgi işleme yapan sinir ağı ile yinelemeli sinir ağı yapısının çalışma prensibi verilmiştir. İleri doğru bilgi işleme yapan sinir ağındaki sonuç o andaki girişe bağlıdır. Çünkü bilgi işleme sürekli ileriye doğrudur. Yinelemeli sinir ağı yapısındaki sonuç ise sadece o andaki girişe göre değil, diğer girişlere de bağlı olarak elde edilir. Bu ağlarda çıkışlar, hem o anda gelen hem de daha önce gelmiş olan bilgilerin birleştirilmesi ile üretilir.

#### 2.2.4. LSTM mimarisi (Architecture of LSTM)

RNN mimarisinin bir türü olan LSTM ilk olarak (Hochreiter ve Schmidhuber, 1997) çalışmasında yeni, verimli ve gradyan tabanlı bir yöntem olarak tanıtılmıştır RNN mimarisinden farklı olarak LSTM mimarisinde, uzun süre önceki herhangi bir girdiyi hatırlamak için kullanılan ve hafıza hücreleri olarak adlandırılan özel katmanlar bulunmaktadır (Latifoğlu ve Nuralan, 2020). Şekil 8’de standart bir RNN’deki modül ile LSTM’deki tekrar eden modülün yapısı verilmiştir.



Şekil 8. (a) RNN’deki tekrar eden modül yapısı (Recurring module structure in RNN), (b) LSTM’deki tekrar eden modül yapısı (Recurring module in LSTM) (Olah, 2015)

Standart RNN’de tek bir *tanh* sinir ağı katmanı bulunurken, LSTM ise çok özel bir şekilde etkileşime giren 4 adet *tanh* sinir ağı katmanı bulunmaktadır. Bu katmanlar sayesinde uzun veya kısa zaman periyotları hatırlanmaktadır. LSTM mimari yapısının temeli RNN mimarisi ile aynıdır. Ancak LSTM yapısında gizli durumları hesaplamak için farklı bir fonksiyon kullanılır. LSTM mimari yapısında bulunan hafızalara hücre denir. Bu hücreler önceki durumu  $h_{t-1}$  ve geçerli girişi  $x_t$  girdi olarak alan bilgi işlem merkezleridir. Hücreler, bu merkezler sayesinde hafızada neler silineceğine ve nelerin tutulacağına karar verir. Sonuç olarak bu hücreler, mevcut belleği, önceki durumu ve girdiyi birleştirir. Bu tür birimlerin, uzun vadeli bağımlılıkları yakalamada çok etkili oldukları anlaşılmaktadır (Metin ve Karasulu, 2015).

Derin öğrenme algoritmaları, sundukları yüksek başarıma rağmen, sağlık verilerine uygulandığında kişisel veri mahremiyetini ihlal edilebileceği için bu tür çözümlerde veri mahremiyetinin dikkate alınması gerekir (Sun vd., 2019).

#### 2.3 Veri Mahremiyeti (Data Privacy)

Mahremiyet, kişinin bağımsız ve özgür olarak var oluşunun temelini oluşturmakla beraber birey olmanın temel gereksinimlerinden de biridir (Dülger, 2015). Veri mahremiyeti, veri sorumluları tarafından toplanan kişisel verilerin yaşam döngüsü içerisinde hukuka ve etik kurallara uygun olarak işlenmesi ve bireyin kendisine ait bilgilerin nasıl toplandığı ve kullanıldığı üzerinde kontrol sahibi olması olarak tanımlanmıştır (Jain vd., 2016). Verilerin toplanması ve paylaşılması sürecinde kontrolün verinin sahibinde kalması veri mahremiyeti açısından önemli bir gereksinimdir. Bu süreçte verilerin kimlerle paylaşılacağı, nerelere aktarılacağı ve hangi amaçla

işleneceği şeffaf ve kontrol edilebilir düzeyde olmalı ve bu süreç verinin sahibi tarafından kontrol edilebilmelidir (Vural, 2018). Türkiye’de, kişisel verilerin işlenmesinde başta özel hayatın gizliliği olmak üzere kişilerin temel hak ve özgürlüklerini korunması, kişisel verileri işleyen gerçek ve tüzel kişilerin yükümlülükleri ile uyacakları usul ve esasların belirlenmesi KVKK ile belirlenmektedir (Kişisel Verileri Koruma Kurumu, 2020).

Bir bireyi, doğrudan veya dolaylı olarak tanımlayabilecek her türlü veri kişisel veri olarak kabul edilmektedir. Demografik veriler, sağlık verileri, maaş verileri, ticari veriler, epostalar, konum verileri, fotoğraflar ve videolar kişisel verilere örnek olarak verilebilir. Günümüzde kişisel verilerin mahremiyetinin korunmasında büyük zorluklar yaşanmaktadır. Bunun sebebi, teknolojinin hayatımızın her alanına girmesiyle beraber kişisel verilerin, bilgimiz olmadan ve kontrolümüz dışında üçüncü taraflarca ele geçirilmesi veya üçüncü taraflarla paylaşılmasıdır (Geambasu vd., 2009). Sahip olunan verilerden yüksek seviyede değer üretmek için veriler yayıncılar tarafından yayınlanabilir. Yayınlanan bu veriler içerisinde kişisel verilerin olması halinde, dikkat edilmesi gereken husus, veriye yayınlamadan önce mahremiyet koruyucu önlemlerin uygulanması gerektiğidir (Xu vd., 2014).

### 2.3.1. Veri mahremiyetinin korunması (Preserving of data privacy)

Verinin bir değer kaynağı olarak üçüncü taraflara paylaşımı, veri ihlalleri konusunda kaygıları da beraberinde getirmektedir. Verinin yayınlanmasında dikkat edilmesi gereken en önemli husus saldırganlar tarafından elde edilen arka plan bilgileri ile yapacakları çıkarımlar sonucunda veri mahremiyeti ihlallerinin yaşanmasıdır. Veri mahremiyeti ihlalleri, doğrudan bireyleri hedef aldığı için mağduriyet ve ayrımcılık yaşanmasına sebep olmakta ve bu durum saldırganların ilgisini sıklıkla çekmektedir. Saldırgan, sahip olduğu arka plan bilgisini yayınlanan veri kümeleri ile belirli öznitelikler üzerinde eşleştirme işlemi yaparak veri sahibinin kimlik ve hassas bilgilerini, bilgisi dışında elde ederek ifşa edebilir. Böylesi ihlallerin yaşanmaması için saldırılara karşı yeterli önlemlerin alınması, veri mahremiyetini hedef alan tehditlerin ve mahremiyet koruyucu yaklaşımların bilinmesi gerekir (Canbay, 2019).

### 2.3.2. Mahremiyet korumalı veri yayınlama (Privacy preserving data publishing)

Veri yayınlama, mevcut verinin sahibinin izni ve bilgisi dâhilinde, çeşitli kişi, kurum veya kuruluşlarla ilgili politika ve stratejilere göre çeşitli platformlarda paylaşılmasıdır. Bu paylaşımın temel amacı kişilerin ve kurumların bu veriden yüksek düzeyde fayda elde etmelerini sağlamaktır. Mahremiyet korumalı veri yayınlama ise içerisinde kişisel veri barındıran veri kümelerini yayınlarken aynı zamanda mahremiyet koruyucu çeşitli önlemleri alarak hassas bilgilerin ifşa edilmesini mümkün olduğu kadar engellenmesini sağlamaktır (Canbay vd., 2020).

Veri yayınlama yöntemi, veri paylaşımında kolay ve ekonomik bir yöntem olduğu için veri işleyen kişi, kurum ve kuruluşlar tarafından yaygın olarak kullanılır. Ancak içerisinde kişisel veri barındıran veri kümelerinin herhangi bir mahremiyet önlemi alınmadan paylaşılması veya yayınlanması ciddi ifşaları da beraberinde getirir. Bu amaçla literatürde veri yayınlamada yaygın olarak kullanılan mahremiyet koruma modelleri aşağıda verilmiştir (Vural, 2018).

*k*-Anonimlik modeli; Sweeney tarafından önerilen en temel mahremiyet koruma modelidir. Genel çalışma mantığı, herhangi bir kaydın *k*-1 adet kayıttan ayırt edilemeyecek şekilde grupların oluşturulmasıdır. Kimlik ifşa saldırısına karşı geliştirilmiştir (Sweeney, 2002).

*l*-Çeşitlilik modeli; *k*-Anonimlik modelinin hassas öznitelikleri koruyamaması problemini gidermek geliştirilmiş olup, eşlenik sınıfların homojen değerlerden oluşmasını engeller. Bu model her eşlenik sınıfındaki hassas özniteliklerin en az *l* sayıda olmasını garanti eder ve homojenite saldırısına bir çözüm sunar (Machanavajhala vd., 2007).

*t*-Yakınlık modeli; Li ve arkadaşları tarafından önerilen bu model, *l*-Çeşitlilik modelinin çarpık veri dağılımından kaynaklı saldırıları minimize etmek için bir koruma sağlar ve herhangi bir eşlenik sınıfındaki hassas özniteliklerin dağılımının genel tablodaki dağılımına yakın olmasını sağlar (Li vd., 2007).

## 2.4. Diferansiyel Mahremiyet (Differential Privacy)

Diferansiyel mahremiyet, günümüzde sıklıkla kullanılan ve verilere gürültü ekleme yaklaşımına dayanan bir veri mahremiyeti koruma modelidir (Dwork, 2006). Bu modelin amacı verinin bulunduğu veri tabanı sistemine doğrudan erişim sağlanması yerine, veri tabanı üzerinde yapılacak istatistiksel bir sorgulama için gürültülü sonuçlar döndürmektir (Var ve İnan, 2018). Diferansiyel mahremiyet, veri tabanları üzerinde çalışan algoritmalar için güçlü bir mahremiyet sağlayarak bir standart oluşturur (Abadi vd., 2016).

$k$ -Anonimlik,  $l$ -Çeşitlilik,  $t$ -Yakınlık gibi modellerin en büyük problemi arka plan saldırılarına karşı tam olarak çözüm sunamamalarıdır. Diferansiyel mahremiyet modeli bu korumayı sağlayarak yüksek seviyede mahremiyet garantisi verir (Canbay ve Sağıroğlu, 2020). Diferansiyel mahremiyet için literatürde bulunan iki tanım aşağıda verilmiştir.

$\epsilon$ -Diferansiyel Mahremiyet;  $A$  mekanizmasının herhangi  $S_1$  ve  $S_2$  komşuluk veri tabanları üzerinde her  $D$  çıktı kümesi için; Denklem 1'de verilen şartı sağlaması halinde  $\epsilon$ -diferansiyel mahremiyeti sağlamaktadır.

$$\Pr[A(S_1) \in D] \leq e^\epsilon \Pr[A(S_2) \in D] \quad (1)$$

$(\epsilon, \delta)$ -Diferansiyel Mahremiyet;  $A$  mekanizmasının herhangi  $S_1$  ve  $S_2$  komşuluk veri tabanları üzerinde her  $D$  çıktı kümesi için; Denklem 2'de verilen şartı sağlaması halinde  $(\epsilon, \delta)$ -diferansiyel mahremiyeti sağlamaktadır.

$$\Pr[A(S_1) \in D] \leq e^\epsilon \Pr[A(S_2) \in D] + \delta \quad (2)$$

Yukarıda sunulan bilgiler ışığında;  $\epsilon$ -Diferansiyel Mahremiyet temel diferansiyel mahremiyet olarak tanımlanırken,  $(\epsilon, \delta)$ -Diferansiyel Mahremiyet ise  $\delta > 0$  değeri için yaklaşık diferansiyel mahremiyet olarak tanımlanır (Beimel vd., 2013).

Diferansiyel mahremiyet mekanizmasının kullanıldığı sistemlerde, istatistiksel olmayan veya cevabı belirli bir kayıt kümesi olan sorgular dikkate alınmayıp, bu sorgulara cevap verilmemektedir. Veri tabanında bulunan kayıtlara doğrudan erişim bu şekilde engellenmektedir. Şekil 9'da diferansiyel mahremiyetin uygulanmasına dair süreç verilmiştir. Bu süreçte veri üzerinde analiz işlemi yapmak isteyen araştırmacı, veri tabanına istatistiksel bir sorgu gönderir. Bu sorgunun gerçek cevabı diferansiyel mahremiyet mekanizmasına gönderilir ve bu mekanizma gerçek cevaba gürültü ekleyerek geri döndürür. Bu şekilde araştırmacının gerçek veriye ulaşması engellenerek onun yerine yaklaşık cevaplara ulaşması sağlanır (Canbay ve Sağıroğlu, 2020). Veri tabanına yapılan sorguların cevaplarına eklenecek gürültü miktarı, sorgunun hassasiyet değeri ile ilgilidir. Bir sorgunun hassasiyeti, sorgunun yapısına göre iki komşu veri tabanı üzerinden hesaplanır (Var ve İnan, 2018).



Şekil 9. Diferansiyel mahremiyet süreci (The process of differential privacy) (Canbay ve Sağıroğlu, 2020)

Diferansiyel mahremiyet, bireylerin mahremiyetini klasik yaklaşımlara göre önemli ölçüde korumaktadır. Örneğin, bir şirkette çalışanların hepatit test sonuçlarının kayıt altına alınıp takip edildiğini varsayalım. Teste giren 100 kişiden 30 kişinin test sonucunun pozitif, 70 kişinin test sonucunun ise negatif olsun. Bir saldırganın, şirket çalışanı Arda'nın test sonucunun pozitif olup olmadığını öğrenmek istediğini varsayalım. Saldırgan, teste katılan 99 kişi hakkında arka plan bilgisi elde etmiş olup, 70 kişinin test sonucunun negatif 29 kişinin test sonucunun pozitif olduğunu öğrenmiştir. Bu nedenle, veri tabanındaki 100. kişi olan Arda'nın test sonucunun pozitif olduğu sonucuna ulaşabilir. Bu tür saldırıları engellemek, saldırganın hedefi hakkında ne kadar arka plan bilgisine sahip olduğu bilinmediği için oldukça güçtür. Diferansiyel mahremiyet, bu tür arka plan saldırılarına karşı mahremiyeti korumayı amaçlar. Saldırganın, bir veri kümesindeki 100 kişiden 99'u hakkında tam bilgiye sahip olsa bile, yine de son kişi hakkındaki bilgileri elde edemeyeceğini garanti eder (Erçin, 2018).

### 3. Literatür Taraması (Literature Survey)

Bu bölümün temel amacı; Covid-19 tespitinde derin öğrenmeyi kullanan çalışmaları ve Covid-19 tespitinde mahremiyeti dikkate alan çalışmaları inceleyerek özetlemek, ayrıca literatürde kullanılan Covid-19 açık veri kümelerini karşılaştırarak sonraki yapılacak çalışmalara bir ön bilgi sunmaktır.

#### 3.1. Covid-19 Tespitinde Derin Öğrenme Tekniklerini Kullanan Çalışmalar (Studies Using Deep Learning Techniques to Detect Covid-19)

Literatürde, Covid-19 tespitinde derin öğrenmeyi dikkate alan çalışmalar aşağıda özetlenmiştir.



Narin ve arkadaşları çalışmalarında (Narin vd., 2020), CT ve CXR görüntülerini kullanarak Covid-19 hastalığını tespit etmek için CNN tabanlı bir yaklaşım önermiştir. Çalışma kapsamında görüntüler beş evrişimli sinir ağı tabanlı modeller olan ResNet50, ResNet101, ResNet152, InceptionV3 ve Inception-ResNetV2 ile eğitilmiştir. Hastalık teşhisinde, en yüksek başarı %99,7 ile ResNet50 modelinde elde edilmiştir.

Toğaçar ve arkadaşları (Toğaçar vd., 2020), Covid-19 tespitinde derin öğrenme tekniklerinden faydalandılar. Veri setleri; koronavirüs, pnömoni ve normal CXR görüntüleri olmak üzere üç sınıftan oluşmaktadır. Bu çalışmada veri sınıfları, ön işleme adımı olarak bulanık renk tekniği kullanılarak yeniden yapılandırılmış ve orijinal görüntülerle yapılandırılan görüntüler MobileNetV2 ve SqueezeNet derin öğrenme modelleriyle eğitilmiştir. SVM algoritması kullanılarak yapılan sınıflandırma ile %99,27 başarı oranı elde edilmiştir.

Covid-19 virüsünü, diğer grip ve zatürre türlerinden doğru bir şekilde ayırmak isteyen Farooq ve Hafeez çalışmalarında (Farooq ve Hafeez, 2020), CovidResNet50 olarak adlandırdıkları CNN tabanlı yeni bir yaklaşım önermiştir. Çalışmaya özgü oluşturulan veri setlerindeki CT ve CXR görüntüleri ResNet-50 modeli ile eğitilmiştir. Çalışma ile ResNet50 modelinin eğitim süresi azaltılarak çalışma performansı iyileştirilmiştir. Önerilen yeni yaklaşım ile hastalık teşhisinde %96,23 başarı oranı elde edilmiştir.

Wang ve arkadaşları çalışmalarında (Wang vd., 2020), Covidx veri setinde yer alan 13.870 hastaya ait 13.975 CXR görüntülerinden Covid-19 hastalığını tespit etmek için derin evrişimli sinir ağı tasarımı olan COVID-Net'i tasarlamıştır. Makine-İnsan işbirliği stratejisi ile tasarlanan bu veri seti modeli ile hasta olmayanların sınıflandırmasında %90,5, Covid-19 harici hasta olanların sınıflandırmasında %91,3, Covid-19 hastalarının sınıflandırılmasında ise %98,9 başarı oranı elde etmişlerdir.

Ko ve arkadaşları (Ko vd., 2020), CT görüntülerinden Covid-19 hastalığını teşhis ederek, bu hastalığı diğer solunum yolu hastalıklarından ayrılması için CNN tabanlı bir yapay zekâ sistemi geliştirmiştir. Çalışmada kullanılan veri seti, Wonkwang Üniversite Hastanesi, Chonnam Ulusal Üniversite Hastanesi ve İtalyan Tıbbi ve Girişimsel Radyoloji Derneğinin veri tabanından alınan CT görüntülerinden oluşmaktadır. Tasarlanan sistemin eğitimi VGG16, ResNet-50, Inception-v3 veya Xception derin öğrenme modelleri ile gerçekleştirilmiş olup FCONet sınıflandırma ağı ile görüntüler sınıflandırılmıştır. Çalışmada, ResNet-50 modeli ile %99,58 duyarlılık, %100,00 özgüllük ve %99,87 başarı oranları elde edilmiştir.

X-Viral ve xCovid veri setinden alınan 43.370 CT ve CXR görüntülerini kullanarak Covid-19 hastalığını, diğer solunum yolu ve akciğer rahatsızlığı olan zatürre hastalığından ayırmak isteyen Zhang ve arkadaşları çalışmalarında (Zhang vd., 2020) CNN tabanlı, Güvene Duyarlı Anormallik Algılama Modeli geliştirmiştir. Geliştirdikleri bu model ile hastalık teşhisinde %71,70 duyarlılık ve %83,30 doğruluk oranı elde etmiştir.

Hu ve arkadaşları çalışmalarında (Hu vd., 2020), Çin'de bulunan hastanelerdeki 588 hastaya ait CT görüntülerinden Covid-19 virüsünü tespit eden ve onu diğer solunum yolu hastalıklarından ayırarak bu görüntüleri sınıflandıran CNN mimarisini kullanan bir yöntem önermiştir. Çalışma kapsamında görüntüler, hasta olmayanlar, zatürre hastaları ve Covid-19 hastaları olarak sınıflandırılmıştır. Bu çalışma ile büyük ölçekli klinik çalışmalarında Covid-19 hastalığını diğer hastalıklardan ayırarak, Covid-19 hastalık teşhisinde hatayı en aza indirmek amaçlanmıştır.

Sürüntü testinden önce klinik bir teşhis sağlamayı amaçlayan Wang ve arkadaşları (Shuai Wang vd., 2020), 1065 CT görüntüsü ile oluşturdukları veri seti üzerinde çalışıp geliştirmiş oldukları model ile hastanın sağlığını ve Covid-19 virüsünün bulaş riskini kontrol edebilmek için kritik bir öneme sahip olan zamandan tasarruf etmeyi hedeflemiştir. CNN tabanlı bu model ile Covid-19 hastalık teşhisinde %88 özgüllük ve %87 duyarlılık ve %89,5 doğruluk oranı elde etmiştir.

Hall ve arkadaşları (Hall vd., 2020), CT görüntülerinin Covid-19 hastalık teşhisinde ne kadar yararlı olduğunu göstermek için 4000'den fazla CXR görüntüsü ile 122 CT görüntüsünü kullanarak CNN tabanlı derin öğrenme modeli geliştirmiştir. Yapılan çalışmada görüntüleri kullanılan 102 hastanın tamamının hastalık teşhisi doğru yapılmıştır. Ayrıca, Covid-19 harici solunum yolu hastalıklarının teşhisinde ise %95 başarı oranı elde etmişlerdir.

Hemdan ve arkadaşları (Hemdan vd., 2020), 25 doğrulanmış pozitif Covid-19 vakasına ait 50 CT görüntüsü üzerinde çalışarak CNN tabanlı bir model geliştirmiştir. Çalışma kapsamında, COVIDX-Net, DenseNet, VGG19 ve Google Mobile Net'in derin öğrenme modellerinden faydalanılmıştır. Önerilen çerçeve model ile normal hastaların sınıflandırmasında %89, Covid-19 hastalarının sınıflandırılmasında ise %91 başarı oranı elde edilmiştir.

Wang ve arkadaşları (Shuo Wang vd., 2020), 4106 hastadan alınan 5372 CT görüntüsü ile oluşturulan CT-EGFR veri seti ile Covid-19 hastalığının teşhisini gerçekleştiren CNN tabanlı otomatik derin öğrenme sistemi önermiştir.

Veri setindeki görüntüler kullanılarak DenseNet121-FPN ve Covid-19Net modelleri eğitilmiştir. Geliştirdikleri sistem, Covid-19 hastalığını, zatürre ve diğer solunum yolu hastalıklarından ayırt edilebilmek için sınıflandırma işlemi yapmaktadır. Çalışma ile Covid-19 hastalık teşhisinde %90, Covid-19 hastalığını diğer solunum yolu hastalıklarından ayırt etmede %87, normal zatürre hastalığından ayırt etmede ise %88 başarı oranı elde edilmiştir.

Bu bölümde, Covid-19 hastalık teşhisinde derin öğrenme algoritmaları kullanılan, literatürdeki güncel bazı çalışmalara yer verilmiştir. Gün geçtikçe bu çalışmaların sayıları artmaktadır. Bunun en önemli sebebi ise Covid-19 hastalığının teşhisinde hayati öneme sahip CT ve CXR görüntülerinin analizinde derin öğrenme yaklaşımlarının başarılı sonuçlar üretmesidir. Bu çalışmalardan en yüksek başarı %99,27 ile Toğaçar ve arkadaşları tarafından elde edilmiştir. Genel olarak bu çalışmalarda elde edilen başarılar yüksek olsa da, bunların hiçbirinde veri mahremiyetine değinilmediği görülmektedir. CT ve CXR görüntüleri sağlık verisi olduğu için bu verilerin işlenmesinde mahremiyet koruyucu önlemlere gerek duyulmaktadır. Yukarıda verilen çalışmalar, sadece hastalığın teşhisine odaklanmış veri mahremiyetini dikkate almamıştır. Devam eden bölümde literatürde konu kapsamında veri mahremiyetini dikkate alan çalışma özetlenmiştir.

### 3.2. Covid-19 Tespitinde Veri Mahremiyetini Dikkate Alan Derin Öğrenme Çalışmaları (Deep Learning Studies Considering Data Privacy in Detection of Covid-19)

Bu bölümde ise Covid-19 hastalığını tespit etmede veri mahremiyetine odaklanan derin öğrenme temelli çalışmalar gözden geçirilmiştir.

Müftüoğlu ve arkadaşları çalışmalarında (Müftüoğlu vd., 2020), Covid-19 ile enfekte olmuş 139 hastaya ait toplam 373 CXR görüntüsü kullanarak Covid-19 hastalığının teşhisini gerçekleştirmişlerdir. Çalışmalarında Covid-19 tespiti için ilk olarak EfficientNet-B0 modeli ile %94 başarı elde etmiş ancak diferansiyel mahremiyeti uyguladıklarında ise bu başarının %71'e kadar düştüğü belirtilmiştir.

Literatür incelendiğinde, Covid-19 tespitinde veri mahremiyetini dikkate alan tek çalışmanın Müftüoğlu ve arkadaşları tarafından gerçekleştirildiği, ilgili çalışmada %71 doğruluk oranı sağlanmasına rağmen bu başarının daha yüksek seviyelere çıkarılması gerektiği ve yenilikçi farklı çözümlere ihtiyaç olduğu görülmektedir. Başarı oranının daha da yükseltilmesi için, daha fazla CT veya CXR görüntüsü kullanılarak, farklı parametrelerle diferansiyel mahremiyeti uygulamak bu kapsamda bir çözüm olabilir.

## 4. Araştırma Bulguları (Results)

Covid-19 hastalığını yapay zekâ sistemleri kullanarak tespit eden çeşitli çalışmalar literatürde mevcuttur. Bu çalışmalarda CXR görüntüleriyle derin öğrenme yöntemleri kullanılarak yüksek başarı oranları elde edildiği Tablo 1'de görülmektedir. Bunun sebebi görüntünün işlenmesi, görüntüden özelliklerin çıkarılması ve çıkarılan özelliklere göre görüntünün sınıflandırılmasında CNN mimarisinin, diğer mimarilere göre yüksek başarı oranı sağlamasıdır. Tablo 1'de derin öğrenme mimarileri kullanılarak Covid-19 hastalık teşhisi yapılan çalışmaların karşılaştırılması gösterilmektedir.

**Tablo 1.** Derin öğrenme ile Covid-19 teşhisi yapan çalışmaların karşılaştırılması (Comparison of the studies diagnosing Covid-19 by deep learning)

Çalışma	Görüntü türü	Mimari	Veri Seti	Veri Sayısı(Adet)	Mahremiyet Odaklı	Doğruluk/Başarı Oranı
(Narin vd., 2020)	CT ve CXR	CNN	Kaggle Chest X-Ray	7406 adet görüntü	Hayır	%98,43
(Toğaçar vd., 2020)	CT ve CXR	CNN	IEEE 8023	590 adet görüntü	Hayır	%99,27
(Farooq ve Hafeez, 2020)	CT ve CXR	CNN	COVIDx	2839 adet görüntü	Hayır	%96,23
(Linda Wang vd., 2020)	CT ve CXR	CNN	COVID-19 Open Research Dataset	13975 adet görüntü	Hayır	%98,90
(Shuai Wang vd., 2020)	CT ve CXR	CNN	Çalışmaya Özgü	274 adet görüntü	Hayır	%89,50
(Hall vd., 2020)	CT ve CXR	CNN	IEEE 8023	557 adet görüntü	Hayır	%91,24
(Hemdan vd., 2020)	CT ve CXR	CNN	IEEE 8023	50 adet görüntü	Hayır	%91,00
(Shuo Wang vd., 2020)	CT ve CXR	CNN	CT-EGFR	5372 adet görüntü	Hayır	%90,00
(Müftüoğlu vd., 2020)	CT ve CXR	CNN	Çalışmaya Özgü	373 adet görüntü	Evet	%71,00

Tablo 1'de sunulan çalışmalar incelendiğinde, CT ve CXR görüntülerinin kullanıldığı, hepsinde genel olarak CNN derin öğrenme mimarisinden faydalandığı, açık olarak yayınlanan veri kümelerinin kullanıldığı, mahremiyet odaklı sadece bir çalışmanın olduğu görülmektedir. Ayrıca, Tablo 1'deki veriler karşılaştırıldığında, Toğaçar ve arkadaşlarının IEEE 8023 veri seti ile CNN mimarisi kullanarak %99,27 ile en yüksek başarı oranını elde ettikleri

görülmektedir. Bu çalışmalardan veri mahremiyetini dikkate alan tek çalışma olarak Müftüoğlu ve arkadaşlarının yaptıkları çalışma olduğu, ancak yine de bu çalışmadaki başarının %71 olarak elde edildiği ve bu başarının daha da yükseltilmesi gerektiği değerlendirilmektedir.

#### 4.1. Covid-19 Çalışmaları İçin Sunulan Açık Veri Kümeleri (Open Datasets for Covid-19 Studies)

Günümüzde derin öğrenme yöntemi uygulanarak tıp alanında yürütülen çalışmalar, açık veri kümelerinin araştırmacıların kullanımına sunulmasıyla birlikte büyük bir hız kazanmıştır. Bu çalışmaların bir kolu da hastalıkların erken tanı ve teşhisi ile ilgili çalışmalardır. Bu çalışmada incelenen literatür ele alındığında, bir kısmı mevcut açık veri setlerini kullanırken bir kısmı da CT ve CXR görüntülerinden kendi veri setlerini oluşturmuşlardır. Yayınlanan bazı veri setlerini kullanmak için ise araştırma fikrinin detaylarını ve çalışmanın gizliliğini içeren imzalı kullanım izin belgesi alınması gerekmektedir.

Yapılan literatür taramasında, ilgili çalışmalarda genellikle, Kaggle Chest X-ray, Covidx, IEEE8023 Covid-19 Chest X-ray veri setleri ile araştırmacıların çeşitli sağlık kuruluşlarından temin ettikleri veri setlerini kullandıkları görülmüş olup Tablo 2'de bu veri setleri ile ilgili çeşitli bilgiler verilmiştir.

**Tablo 2.** Literatürde yaygın olarak kullanılan Covid-19 açık veri kümeleri (Covid-19 open datasets widely used in the literatüre)

Referans	Veri seti	Veri Türü	Yayımlandığı Platform	Kullanan Çalışma
(Mooney, 2020a)	Kaggle, Pneumonia Sample X-Rays	Görüntü	Kaggle	(Rabbah vd., 2020)
(IEEE, 2020)	IEEE8023 Covid-19 Chest X-ray	Görüntü	Github	(Hemdan vd., 2020)
(Rodrigues, 2020)	COVID-19 – Kaggle: Chest X-ray	Görüntü	Data.mendeley	(Narin vd., 2020)
(Pengtao Xie, 2020)	GitHub UCSD-AI4H / Covid-CT	Tablo	Github.	(Sharma, 2020)
(Chung, 2020)	Figure1-Covid-Chestxray-Dataset	Görüntü	Github.com	(Wong vd., 2020)
(Lisphilar, 2020)	Covid-19 Dataset In Japan	Tablo	Kaggle.com	(Kobayashi vd., 2020)
(Tails, 2020)	Covid-19 Tracking Germany Dataset	Tablo	Kaggle.com	(Mavragani, 2020)
(Mooney, 2020b)	San Francisco Covid-19 Dataset	Tablo	Kaggle.com	(Gianfrancesco vd., 2020)
(Institute, 2020)	COVID-19 Open Research Dataset Challenge (CORD-19)	Görüntü ve Tablo	Kaggle.com	(Linda Wang vd., 2020)
(Rajkumar, 2020b)	Novel Coronavirus 2019 Dataset	Tablo	Kaggle.com	(Levitt vd., 2020)
(Albert Sun, 2020)	NY-TIMES Covid-19 USA Dataset	Tablo	Github.com	(Alamo vd., 2020)
(Goldbloom, 2020)	Covid-19 Data From John Hopkins University Dataset	Tablo	Kaggle.com	(Zarikasvd., 2020)
(Rajkumar, 2020a)	Covid-19 India Dataset	Tablo	Kaggle.com	(Prakash vd., 2020)
(Union, 2020)	European Union Open Covid-19 Dataset	Tablo	Data.europa.eu	(Di Pietro vd., 2020)
(Badr, 2020)	COVID-19_Unified-Dataset	Tablo	Github.com	(Kerr vd., 2021)
(Lira, 2020)	Covid-19 Mexico Dataset	Tablo	Kaggle.com	(Medel-Ramírez ve Medel-Lopez, 2020)

#### 5. Sonuçlar ve Tartışma (Conclusions and Discussion)

Derin öğrenme yaklaşımları kullanılarak CT ve CXR görüntülerinden Covid-19 hastalığının teşhisi yaygın bir yaklaşım olup, bu alandaki çalışmaların sayısı gün geçtikçe artmaktadır. Bunun sebebi ise derin öğrenme teknikleri ile yapılan hastalık teşhisinde yüksek başarı oranlarının elde edilmesidir. Literatürde Covid-19 hastalığının teşhis edilmesinde en çok kullanılan derin öğrenme mimarisinin CNN olduğu görülmüştür. Bunun sebebi ise CNN mimarisinin görüntünün işlenmesi, görüntüden özelliklerin çıkarılması ve çıkarılan özelliklere göre görüntünün sınıflandırılmasında yüksek başarılı sonuçlar üretmesidir.

Hastalık teşhisi kadar hastalara ait verilerin mahremiyetinin korunması, özellikle KVKK ve GDPR açısından çok önemlidir. Veri mahremiyetinin korunması, verinin yayınlanmasında veya verilerin analiz edilerek işlenmesi sürecinde sağlanabilmektedir. Mahremiyet korumalı veri yayınlamada *k*-Anonimlik, *l*-Çeşitlilik ve *t*-Yakınlık modelleri yaygın olarak kullanılırken, mahremiyet korumalı veri analizinde diferansiyel mahremiyet tabanlı çözümlerden faydalanılmaktadır.

Bu çalışmada Covid-19 teşhisinde derin öğrenmeyi kullanan ve veri mahremiyetini dikkate alan güncel çalışmalar incelenmiş, bu çalışmalarda kullanılan derin öğrenme mimarileri, veri setleri ve çalışma sonunda elde edilen başarı oranları tablo halinde verilerek karşılaştırmalar yapılmıştır.

Bu çalışma sonucu yapılan değerlendirmeler şu şekilde sıralanabilir;

- Covid-19 ve diğer hastalıkların tespitinde ve analizinde, veri mahremiyetine yeterince önem verilmesi ve uygulanması gerektiği,
- Covid-19 tespitinde mahremiyeti dikkate alırken aynı zamanda elde edilecek başarının mümkün olduğu kadar kabul edilebilir seviyelerde olması gerektiği,
- Diferansiyel mahremiyetin bu alandaki çalışmalara uygulanmasında farklı  $\epsilon$  değerlerinin dikkate alınarak sonuçlarının irdelenmesi gerektiği,
- Covid-19 tespitini sağlayan çalışmaların başarı oranlarını arttırabilmek için daha çok sayıda açık CT ve CXR veri kümelerinin yayınlanması gerektiği,
- Ülkemizde Covid-19 için açık CT ve CXR veri kümelerinin mevcut olmadığı bundan dolayı ülkemiz özelinde yeterli çalışmaların yapılamadığı,
- Bu tür verilerin yayınlanmasında bir endişe duyulması halinde güncel konulardan olan Federe Öğrenme modelinin uygulanabileceği,
- KVKK ve GDPR gibi yasal mevzuatlara uygun bir şekilde veri işleme ve analizlerin yapılması gerektiği,

değerlendirilmektedir.

### Teşekkür (Acknowledgement)

Bu çalışma Kahramanmaraş Sütçü İmam Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından 2020/7-22 M numaralı proje kapsamında desteklenmiştir.

Bu çalışmaya verdikleri destekten dolayı Kahramanmaraş Sütçü İmam Üniversitesi Data Vision Laboratuvarına (datavision.ksu.edu.tr) teşekkür ederiz.

### Yazarların Katkıları (Authors' Contributions)

*Yavuz Canbay*: Araştırma probleminin belirlenmesi, konseptin oluşturulması, kontrol, makalenin yazılması ve gözden geçirilmesi,

*Abdullah İsmetoğlu*: Analiz, konseptin oluşturulması, makalenin yazılması,

*Pelin Canbay*: Araştırma probleminin belirlenmesi, kontrol, makalenin gözden geçirilmesi.

### Çıkar Çatışması (Conflict of Interest)

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir. No conflict of interest was declared by the authors.

### Kaynaklar (References)

- Abadi, M., Chu, A., Goodfellow, I., McMahan, H. B., Mironov, I., Talwar, K., & Zhang, L. (2016). Deep Learning With Differential Privacy. Paper presented at the Proceedings of the 2016 ACM SIGSAC Conference on Computer and Communications Security.
- Akkuş, M. S. (2020). Koronavirüs ve Covid-19. *Aksaray Üniversitesi Tıp Bilimleri Dergisi*, 1(2), 15-20.
- Alafi, B. (2019). Artificial Intelligence And Deep Learning Methodologies. *The Journal of Cognitive Systems*, 4(2), 57-61.
- Alamo, T., Reina, D. G., Mammarella, M., & Abella, A. (2020). Covid-19: Open-data resources for monitoring, modeling, and forecasting the epidemic. *Electronics*, 9(5), 827.
- Albert Sun, N. (2020, Erişim Tarihi: 05.12.2020). NY-Times Covid-19 USA Dataset. İnternet Sayfası: <https://github.com/nytimes/covid-19-data>
- Aydoğan, M., & Karci, A. (2020). Spelling Correction with the Dictionary Method for the Turkish Language Using Word Embeddings. *Avrupa Bilim ve Teknoloji Dergisi*, 57-63.
- Badr, H. S. (2020, Erişim Tarihi: 04.12.2020). Covid-19 Unified-Dataset. İnternet Sayfası: [https://github.com/CSSEGISandData/COVID-19\\_Unified-Dataset](https://github.com/CSSEGISandData/COVID-19_Unified-Dataset)
- Beimel, A., Nissim, K., & Stemmer, U. (2013). Private Learning And Sanitization: Pure vs. Approximate Differential Privacy. In *Approximation, Randomization, and Combinatorial Optimization. Algorithms and Techniques* (pp. 363-378): Springer.
- Britz, D. (2015, Erişim Tarihi: 28.12.2020). Recurrent Neural Networks Tutorial, Part 1 – Introduction To RNNs. İnternet Sayfası: <http://www.wildml.com/2015/09/recurrent-neural-networks-tutorial-part-1-introduction-to-rnns/>
- Canbay, P. (2020). Sağlıkta Yapay Zekâ: Derin Öğrenme Teknikleri ve Uygulamaları. In K. D. Ahmet Rıza Şahin, Süleyman Sivri (Ed.), *Sağlık Bilimlerinde Yapay Zekâ* (pp. 25-39): Akademisyen Kitabevi.
- Canbay, Y. (2019). Aykırı Veri Yönelimli Fayda Temelli Büyük Veri Anonimleştirme Modeli. (Doktora Tezi), Gazi Üniversitesi,

- Canbay, Y., & Sağıroğlu, Ş. (2020). Derin Öğrenmede Diferansiyel Mahremiyet. Uluslararası Bilgi Güvenliği Mühendisliği Dergisi, 6(1), 1-16.
- Canbay, Y., Vural, Y., & Sağıroğlu, Ş. (2020). Mahremiyet Korunmalı Büyük Veri Yayınlama İçin Kavramsal Model Önerileri. Politeknik Dergisi, 23(3), 785-798.
- Chung, A. G. (2020, Erişim Tarihi: 20.12.2020). Figure1-Covid-Chestxray-Dataset. İnternet Sayfası: <https://github.com/agchung/Figure1-COVID-chestxray-dataset>
- Coşkun, M., Yıldırım, Ö., Uçar, A., & Demir, Y. (2017). An Overview Of Popular Deep Learning Methods. European Journal of Technic (EJT), 165-176.
- De Campos, L. M. L. (2017). Time Series Prediction With Direct And Recurrent Neural Networks. Turkish Journal of Forecasting, 1(1), 7-15.
- Di Pietro, G., Biagi, F., Costa, P., Karpiński, Z., & Mazza, J. (2020). The likely impact of COVID-19 on education: Reflections based on the existing literature and recent international datasets (Vol. 30275): Publications Office of the European Union.
- Dülger, M. V. (2015). Sağlık Hukukunda Kişisel Verilerin Korunması Ve Hasta Mahremiyeti. İstanbul Medipol Üniversitesi Hukuk Fakültesi Dergisi, 1(2), 43-80.
- Dwork, C. (2006). Differential Privacy. Paper presented at the International Colloquium on Automata, Languages and Programming, Berlin, Heidelberg.
- Ercin, Ö. (2018, Erişim Tarihi: 23.11.2020). Differential Privacy (Diferansiyel Gizlilik ve Mahremiyet). İnternet Sayfası: <http://ozdenercin.com/2018/09/19/differential-privacy-diferansiyel-gizlilik-ve-mahremiyet/>
- Farooq, M., & Hafeez, A. (2020). Covid-Resnet: A deep Learning Framework For Screening Of Covid19 From Radiographs. arXiv preprint arXiv:2003.14395.
- Fukushima, K. (1980). Neocognitron: A Self-organizing Neural Network Model for a Mechanism. Biol. Cybernetics 36, 193-202.
- Geambasu, R., Kohno, T., Levy, A. A., & Levy, H. M. (2009). Vanish: Increasing Data Privacy with Self-Destructing Data. Paper presented at the 18th USENIX Security Symposium, Washington.
- Gianfrancesco, M. A., Hyrich, K. L., Gossec, L., Strangfeld, A., Carmona, L., Mateus, E. F., . . . Bhana, S. (2020). Rheumatic disease and COVID-19: initial data from the COVID-19 global rheumatology alliance provider registries. The Lancet Rheumatology, 2(5), e250-e253.
- Goldbloom, A. (2020, Erişim Tarihi: 20.12.2020). Covid-19 Data From John Hopkins University Dataset. İnternet Sayfası: <https://www.kaggle.com/antgoldbloom/covid19-data-from-john-hopkins-university>
- Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). Deep learning (Vol. 1): MIT press Cambridge.
- Hall, L. O., Paul, R., Goldgof, D. B., & Goldgof, G. M. (2020). Finding Covid-19 from Chest X-rays using Deep Learning on a Small Dataset. arxiv:2004.02060.
- Hemdan, E. E.-D., Shouman, M. A., & Karar, M. E. (2020). Covidx-Net: A Framework Of Deep Learning Classifiers To Diagnose Covid-19 In X-Ray Images. arXiv preprint arXiv:2003.11055.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. Neural computation, 9(8), 1735-1780.
- Hu, S., Gao, Y., Niu, Z., Jiang, Y., Li, L., Xiao, X., . . . Xia, J. (2020). Weakly Supervised Deep Learning For Covid-19 Infection Detection And Classification From CT Images. IEEE Access, 8, 118869-118883.
- IEEE. (2020, Erişim Tarihi: 05.12.2020). IEEE8023 Covid-19 Chest X-ray. İnternet Sayfası: <https://github.com/ieee8023/covid-chestxray-dataset>
- Institute, A. (2020, Erişim Tarihi: 05.12.2020). Covid-19 Open Research Dataset Challenge (CORD-19). İnternet Sayfası: <https://www.kaggle.com/allen-institute-for-ai/CORD-19-research-challenge?select=metadata.csv>
- Jain, P., Gyanchandani, M., & Khare, N. (2016). Big Data Privacy: A Technological Perspective And Review. Journal of Big Data, 3(1), 25.
- Karaküçük, Y., & Eker, S. (2020). Sağlık Bilimlerinde Yapay Zekâ. In Oftalmolojide Yapay Zeka ve Derin Öğrenme Uygulamaları (pp. 123-143): Akademisyen Kitabevi.
- Kerr, G. H., Badr, H. S., Gardner, L. M., Perez-Saez, J., & Zaitchik, B. F. (2021). Associations between meteorology and COVID-19 in early studies: Inconsistencies, uncertainties, and recommendations. One Health, 12, 100225.
- Kimanuka, U. A., & Büyük, O. (2018). Turkish Speech Recognition Based On Deep Neural Networks. Journal of Natural & Applied Sciences.
- Kişisel Verileri Koruma Kurumu. (2020, Erişim Tarihi: 23.11.2020). Kamuoyu Duyurusu (Covid-19 İle Mücadelede Konum Verisinin İşlenmesi ve Kişilerin Hareketliliklerinin İzlenmesi Hakkında Bilinmesi Gerekenler). İnternet Sayfası: <https://www.kvkk.gov.tr/Icerik/6726/COVID-19-ILE-MUCADELEDE-KONUM-VERISININ-ISLENMESI-VE-KISILERIN-HAREKETLILIKLERININ-IZLENMESI-HAKKINDA-BILINMESI-GEREKENLER-2->
- Ko, H., Chung, H., Kang, W. S., Kim, K. W., Shin, Y., Kang, S. J., . . . Jung, H. (2020). Covid-19 pneumonia Diagnosis Using A Simple 2D Deep Learning Framework With A Single Chest CT Image: Model Development And Validation. Journal of Medical Internet Research, 22(6), e19569.
- Kobayashi, G., Sugawara, S., Tamae, H., & Ozu, T. (2020). Predicting intervention effect for COVID-19 in Japan: state space modeling approach. BioScience Trends.
- Latifoğlu, L., & Nuralan, K. B. (2020). Tekil Spektrum Analizi ve Uzun-Kısa Süreli Bellek Ağları ile Nehir Akım Tahmini. Avrupa Bilim ve Teknoloji Dergisi, 376-381.

- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 2278 - 2324.
- Levitt, M., Scaiewicz, A., & Zonta, F. (2020). Predicting the trajectory of any COVID19 epidemic from the best straight line. *medRxiv*.
- Li, N., Li, T., & Venkatasubramanian, S. (2007). t-Closeness: Privacy Beyond k-Anonymity And l-Diversity. Paper presented at the 2007 IEEE 23rd International Conference on Data Engineering.
- Lira, C. (2020, Erişim Tarihi: 05.12.2020). Covid-19 Mexico Dataset. İnternet Sayfası: <https://www.kaggle.com/carloslira/covid19-mexico>
- Lisphilar. (2020, Erişim Tarihi: 10.12.2020). Covid-19 Dataset In Japan. İnternet Sayfası: <https://www.kaggle.com/lisphilar/covid19-dataset-in-japan>
- Machanavajjhala, A., Kifer, D., Gehrke, J., & Venkatasubramanian, M. (2007). l-Diversity: Privacy Beyond k-Anonymity. *ACM Transactions on Knowledge Discovery from Data (TKDD)*, 1(1), 3-es.
- Mavragani, A. (2020). Tracking COVID-19 in Europe: infodemiology approach. *JMIR public health and surveillance*, 6(2), e18941.
- Medel-Ramírez, C., & Medel-Lopez, H. (2020). Data Mining for the Study of the Epidemic (SARS-CoV-2) COVID-19: Algorithm for the Identification of Patients (SARS-CoV-2) COVID 19 in Mexico. Available at SSRN 3619549.
- Metin, İ. A., & Karasulu, B. (2015). İnsan Aktivitelerinin Sınıflandırılmasında Tekrarlayan Sinir Ağı Kullanan Derin Öğrenme Tabanlı Yaklaşım. *Veri Bilimi*, 2(2), 1-10.
- Minaee, S., Kafieh, R., Sonka, M., Yazdani, S., & Soufi, G. J. (2020). Deep-Covid: Predicting Covid-19 From Chest X-Ray Images Using Deep Transfer Learning. *arXiv preprint arXiv:2004.09363*.
- Mooney, P. (2020a, Erişim Tarihi: 08.12.2020). Kaggle, Pneumonia Sample X-Rays. İnternet Sayfası: <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia>
- Mooney, P. (2020b, Erişim Tarihi: 06.12.2020). San Francisco Covid-19 Data. İnternet Sayfası: <https://www.kaggle.com/paultimothymooney/san-francisco-covid19-data>
- Müftüoğlu, Z., Kizrak, M. A., & Yıldırım, T. (2020). Differential Privacy Practice On Diagnosis of Covid-19 Radiology Imaging Using EfficientNet. Paper presented at the 2020 International Conference on INnovations in Intelligent SysTems and Applications (INISTA).
- Nabiyev, V. V. (2012). *Yapay Zekâ: Seçkin Yayıncılık*.
- 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*.
- Olah, C. (2015, Erişim Tarihi: 06.12.2020). Understanding LSTM Networks. İnternet Sayfası: <http://colah.github.io/posts/2015-08-Understanding-LSTMs>
- Onan, A. (2020). Evrişimli Sinir Ağı Mimarilerine Dayalı Türkçe Duygu Analizi. *Avrupa Bilim ve Teknoloji Dergisi*, 374-380.
- Pengtao Xie, J. S., Jinyu Zhao. (2020, Erişim Tarihi: 28.11.2020). GitHub UCSD-AI4H / Covid-CT. İnternet Sayfası: <https://github.com/UCSD-AI4H/COVID-CT>
- Prakash, K. B., Imambi, S. S., Ismail, M., Kumar, T. P., & Pawan, Y. (2020). Analysis, prediction and evaluation of covid-19 datasets using machine learning algorithms. *International Journal*, 8(5).
- Rabbah, J., Ridouani, M., & Hassouni, L. (2020). A New Classification Model Based on Stacknet and Deep Learning for Fast Detection of COVID 19 Through X Rays Images. Paper presented at the 2020 Fourth International Conference On Intelligent Computing in Data Sciences (ICDS).
- Rajkumar, S. (2020a, Erişim Tarihi: 20.12.2020). Covid-19 India Dataset. İnternet Sayfası: <https://www.kaggle.com/sudalairajkumar/covid19-in-india>
- Rajkumar, S. (2020b, Erişim Tarihi: 05.12.2020). Novel Coronavirus 2019 Dataset. İnternet Sayfası: <https://www.kaggle.com/sudalairajkumar/novel-corona-virus-2019-dataset>
- Rodrigues, P. (2020, Erişim Tarihi: 04.12.2020). Covid-19 - Kaggle: Chest X-Ray (normal). İnternet Sayfası: <https://data.mendeley.com/datasets/rsbjbr9sj/2>
- Sharma, S. (2020). Drawing insights from COVID-19-infected patients using CT scan images and machine learning techniques: a study on 200 patients. *Environmental Science and Pollution Research*, 27(29), 37155-37163.
- Sun, Z., Wang, Y., Shu, M., Liu, R., & Zhao, H. (2019). Differential Privacy for Data and Model Publishing of Medical Data. *IEEE*, 152103-152114.
- Sweeney, L. (2002). k-Anonymity: A Model For Protecting Privacy. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 10(05), 557-570.
- Tails, H. o. (2020, Erişim Tarihi: 06.12.2020). Covid-19 Tracking Germany Dataset. İnternet Sayfası: <https://www.kaggle.com/headsortails/covid19-tracking-germany>
- Tan, Z. (2019). *Derin Öğrenme Yardımıyla Araç Sınıflandırma (Yüksek Lisans Tezi)*, Fırat Üniversitesi,
- Toğaçar, M., Ergen, B., & Cömert, Z. (2020). Covid-19 Detection Using Deep Learning Models To Exploit Social Mimic Optimization And Structured Chest X-Ray Images Using Fuzzy Color And Stacking Approaches. *Computers in Biology and Medicine*, 103805.

- Union, E. (2020, Erişim Tarihi: 20.12.2020). European Union Open Covid-19 Coronavirus Dataset. İnternet Sayfası: <https://data.europa.eu/euodp/en/data/dataset/covid-19-coronavirus-data>
- Var, E., & İnan, A. (2018). Sınıflandırma İçin Diferansiyel Mahremiyete Dayalı Öznitelik Seçimi. *Journal of the Faculty of Engineering & Architecture of Gazi University*, 33(1).
- Vural, Y. (2018). Veri Mahremiyeti: Saldırılar, Korunma ve Yeni bir Çözüm Önerisi *Uluslararası Bilgi Güvenliği Mühendisliği Dergisi*, 4(2), 21-34.
- Wang, L., Lin, Z. Q., & Wong, A. (2020). Covid-Net: A Tailored deep Convolutional Neural Network Design For Detection Of Covid-19 Cases From Chest X-Ray Images. *Scientific Reports*, 10(1), 1-12.
- Wang, L. L., Lo, K., Chandrasekhar, Y., Reas, R., Yang, J., Eide, D., . . . Merrill, W. (2020). Cord-19: The covid-19 open research dataset. *ArXiv*.
- Wang, S., Kang, B., Ma, J., Zeng, X., Xiao, M., Guo, J., . . . Meng, X. (2020). A Deep Learning Algorithm Using CT Images To Screen For Corona Virus Disease (Covid-19). *medRxiv*.
- Wang, S., Zha, Y., Li, W., Wu, Q., Li, X., Niu, M., . . . Yu, H. (2020). A Fully Automatic Deep Learning System For Covid-19 Diagnostic And Prognostic Analysis. *European Respiratory Journal*.
- Wong, A., Qiu Lin, Z., Wang, L., Chung, A. G., Shen, B., Abbasi, A., . . . Duong, T. Q. (2020). COVIDNet-S: Towards computer-aided severity assessment via training and validation of deep neural networks for geographic extent and opacity extent scoring of chest X-rays for SARS-CoV-2 lung disease severity. *arXiv e-prints*, arXiv: 2005.12855.
- World Health Organization. (2021, Erişim Tarihi: 20.03.2021). WHO Coronavirus Disease (COVID-19) Dashboard. İnternet Sayfası: <https://covid19.who.int/>
- Xu, L., Jiang, C., Wang, J., Yuan, J., & Ren, Y. (2014). Information Security in Big Data: Privacy and Data Mining. *IEEE Access*, 1149 - 1176.
- Zarikas, V., Pouloupoulos, S. G., Gareiou, Z., & Zervas, E. (2020). Clustering analysis of countries using the COVID-19 cases dataset. *Data in brief*, 31, 105787.
- Zhang, J., Xie, Y., Liao, Z., Pang, G., Verjans, J., Li, W., . . . Shen, C. (2020). Viral Pneumonia Screening On Chest X-Ray Images Using Confidence-Aware Anomaly Detection. *arXiv preprint arXiv:2003.12338*.
- Zheng, J., Xu, C., Zhang, Z., & Li, X. (2017, March). Electric load forecasting in smart grids using long-short-term-memory based recurrent neural network. In *2017 51st Annual Conference on Information Sciences and Systems (CISS)* (pp. 1-6). IEEE.