



**YAPAY ZEKÂ TABANLI GÖRÜNTÜ İŞLEME
YÖNTEMLERİ İLE COVID-19 TAHMİNİ**

Burak YAĞIN

BİYOİSTATİSTİK ve TIP BİLİŞİMİ ANABİLİM DALI

**Tez Danışmanı
Doç. Dr. Emek GÜLDOĞAN**

Yüksek Lisans Tezi – 2022

**T.C.
İNÖNÜ ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ**

**YAPAY ZEKÂ TABANLI GÖRÜNTÜ İŞLEME YÖNTEMLERİ İLE COVID-19
TAHMİNİ**

Burak YAĞIN

**Biyoistatistik ve Tıp Bilişimi Anabilim Dalı
Yüksek Lisans Tezi**

**Tez Danışmanı
Doç. Dr. Emek GÜLDOĞAN**

Bu Araştırma İnönü Üniversitesi Bilimsel Araştırma Projeleri Birimi Tarafından
TYL-2021-2539 Proje numarası ile desteklenmiştir.

**MALATYA
2022**

İÇİNDEKİLER

ÖZET	vii
ABSTRACT.....	viii
SİMGELER ve KISALTMALAR	ix
ŞEKİLLER DİZİNİ	x
TABLolar DİZİNİ	xi
1. GİRİŞ	1
2. GENEL BİLGİLER	3
2.1. Yapay Zekâ Teknolojileri ve Tıpta Güncel Uygulamaları	3
2.2. Makine Öğrenmesi.....	5
2.2.1. Denetimli Öğrenme.....	5
2.2.2. Denetimsiz Öğrenme	6
2.2.3. Takviyeli Öğrenme	6
2.2.4. Çevrimdışı Öğrenme.....	6
2.2.5. Çevrimiçi Öğrenme.....	6
2.3. Derin Öğrenme	7
2.3.1. Derin Öğrenme Mimarileri	8
2.3.2. Evrişimsel Sinir Ağları (CNN)	8
2.3.3. Tekrarlayan Sinir Ağları (RNN).....	9
2.3.4. Uzun Kısa Vadeli Hafıza Ağları (LSTM).....	10
2.3.5. Sınırlı Boltzmann Makineleri (RBM).....	11
2.3.6. Derin İnanç Ağları (DBN)	11
2.4. Görüntü İşleme	12
2.5. Görüntü işlemenin temel adımları	13
2.6. Video İşleme	14
3. MATERYAL VE METOT	16
3.1. Materyal	16
3.1.1. Çalışmada Kullanılan Veri Seti	16
3.2. Metot.....	16
3.2.1. Veri İşleme.....	17
3.2.2. Derin Öğrenme Modelinin Oluşturulması	17
3.2.3. Modelin Eğitimi	18
3.2.4. Web Tabanlı Sistemin Geliştirilmesi.....	19

4. BULGULAR.....	20
4.1. Oluřturulan CNN Modelinin Bulguları	20
4.2. Geliřtirilen Web Tabanlı Sistemin Bulguları.....	23
5. TARTIřMA	25
6. SONUÇ VE ÖNERİLER.....	28
KAYNAKLAR	29
EKLER.....	35
EK-1. Özgeçmiş.....	35
EK-2. Etik Kurul.....	36



TEŐEKKÖR

Gerçekleřtirmiş olduđum tez alıřmasının hayata geirilmesi sűrecinde bilgi ve tecrűbelerinden faydalandıđım, gűrűřleriyle beni destekleyen, samimiyetini her zaman hissettiren ve beni dođru yűnde yűnlendiren danıřman hocam Sayın Do Dr. Emek GÜLDOĖAN'a, akademik eđitimim sűresince desteklerini esirgemeyen ve birikimleriyle bana yol gűsteren deđerli hocalarım Prof. Dr. Saim YOLOĖLU, Prof. Dr. Cemil OLAK ve Do. Dr. Harika Gűzde GűZÜKARA BAĖ'a, űnerileriyle yardımlarını esirgemeyen Anabilim Dalında gűrev yapan ok deđerli asistan hocalarım ile ok deđerli arkadařım Ali KAPLAN'a sonsuz saygı ve teőekkűrlerimi sunarım. Bu zorlu sűrete destekleriyle beni hibir zaman yalnız bırakmayan sevgili eřim Fatma Hilal YAĖIN'a ve hayatımın her dűneminde desteklerini daima kalbimde hissettiren aileme sonsuz teőekkűrlerimi sunarım.

ÖZET

Yapay Zekâ Tabanlı Görüntü İşleme Yöntemleri ile COVID-19 Tahmini

Amaç: Bu çalışmanın amacı, uygun video işleme teknikleri ve yapay zekâ yöntemlerini kullanarak Akciğer Ultrason videoları ile COVID-19'u, Bakteriyel Pnömoni, Viral Pnömoni ve sağlıklı kontrollerden başarılı bir şekilde ayırt ederek sınıflandırmak için yüksek performansa sahip bir modelin ve web tabanlı klinik karar destek sisteminin geliştirilmesidir.

Materyal ve Metot: Bu çalışmada https://github.com/jannisborn/covid19_ultrasound adresindeki açık kaynaklı Akciğer ultrason video veri seti kullanılmıştır. Veri setinde bulunan videoların 32'si sağlıklı kontrol, 24'ü COVID-19, 24'ü Bakteriyel Pnömoni ve 12'si Viral Pnömoni sınıfındandır. Video işleme aşamasında her bir sınıftaki videolardan 300'er görüntü karesi alınmıştır. Bu sayede toplam 1200 görüntü elde edilmiştir. Görüntülerin %80'i (960) eğitim ve %20'si (240) test veri seti olarak bölünmüştür. Modelleme aşamasında keras kütüphanesinde bulunan derin sinir ağları mimarilerinden evrişimli sinir ağları (CNN) yöntemi kullanılmıştır. Oluşturulan modelin performansını değerlendirmek için doğruluk, duyarlılık, seçicilik, kesinlik, Matthews'in korelasyon katsayısı (MCC), F1 skoru ve G-ortalama ölçütleri verilmiştir. Bunlara ek olarak oluşturulan yapay zekâ tabanlı model, Python Flask Kütüphanesi ve JavaScript yardımıyla, HTML5 alt yapısı kullanılarak COVID-19'u başarılı bir şekilde tespit edebilen web tabanlı bir sistem geliştirilmiştir.

Bulgular: Bu çalışmada açık erişimli Akciğer ultrason video veri seti üzerinde oluşturulan model ile test veri setinde doğruluk sağlıklı kontrol, COVID-19 ve viral pnömoni için %93.39 ve bakteriyel pnömoni için ise %95.07 olarak hesaplanmıştır.

Sonuç: Oluşturulan video işleme tabanlı CNN modeli ile elde edilen performans ölçütleri değerlerine göre, geliştirilen sistemin COVID-19, Bakteriyel Pnömoni ve Viral Pnömoni tanısında oldukça başarılı tahminler verdiği söylenebilir.

Anahtar Kelimeler: COVID-19, yapay zekâ, derin öğrenme, video işleme, görüntü işleme, evrişimli sinir ağları.

ABSTRACT

COVID-19 Prediction with Artificial Intelligence Based Image Processing Methods

Aim: The aim of this study is to develop a high-performance model and web-based clinical decision making method to successfully distinguish and classify COVID-19 from Bacterial Pneumonia, Viral Pneumonia and healthy controls with Lung Ultrasound videos using appropriate video processing techniques and artificial intelligence methods development of the support system.

Material and Method: In this study, the open source Lung ultrasound video dataset at https://github.com/jannisborn/covid19_ultrasound was used. The dataset includes 32 healthy controls, 24 COVID-19, 24 Bacterial Pneumonia and 12 Viral Pneumonia class videos. In the video processing stage, 300 image frames were taken from the videos in each class. In this way, a total of 1200 images were obtained. 80% (960) of the images are divided into training datasets and 20% (240) as test datasets. In the modeling phase, the convolutional neural network (CNN) method, one of the deep neural network architectures in the keras library, was used. Accuracy, sensitivity, specificity, precision, Matthews' correlation coefficient (MCC), F1 score and G-ortalama criteria are given to evaluate the performance of the model. In addition to these, a web-based system has been developed that can successfully detect COVID-19 using the HTML5 infrastructure, with the help of the artificial intelligence-based model, Python Flask Library and JavaScript.

Results: In this study, with the model created on the open access Lung ultrasound video dataset, the accuracy in the test dataset was calculated as 93.39% for healthy control, COVID-19 and viral pneumonia, and 95.07% for bacterial pneumonia.

Conclusion: According to the performance criteria values obtained with the video processing-based CNN model, it can be said that the developed system gives very successful predictions in the diagnosis of COVID-19, Bacterial Pneumonia and Viral Pneumonia.

Keywords: COVID-19, artificial intelligence, deep learning, video processing, image processing, convolutional neural networks.

SİMGELER ve KISALTMALAR

AI	: Yapay Zekâ
BT	: Bilgisayarlı Tomografi
CNN	: Evrişimli Sinir Ağları
DBN	: Derin İnanc Ağları
DNA	: Deoksiribo Nükleik Asit
DSÖ	: Dünya Sağlık Örgütü
LSTM	: Uzun Kısa Vadeli Hafıza Ağları
LUS	: Akciğer Ultrasonu
MCC	: Matthews'in Korelasyon Katsayısı
ML	: Makine Öğrenmesi
RBM	: Sınırlı Boltzmann Makineleri
RNN	: Tekrarlayan Sinir Ağları
RT-PCR	: Gerçek Zamanlı Ters Transkripsiyon-Polimeraz Zincir Reaksiyonu
SVM	: Destek Vektör Makineleri

ŞEKİLLER DİZİNİ

Şekil No	Sayfa No
Şekil 2.1. AI, ML ve Derin Öğrenme Arasındaki İlişki	4
Şekil 2.2. Makine Öğrenmesi Süreci	5
Şekil 2.3. CNN Mimarisinin Genel Yapısı	9
Şekil 2.4. RNN Mimarisinin Genel Yapısı	10
Şekil 2.5. LSTM Mimarisinin Genel Yapısı	10
Şekil 2.6. DBN Mimarisinin Genel Yapısı	12
Şekil 2.7. Görüntü işlemedeki temel adımlar	13
Şekil 3.1. Oluşturulan CNN Mimarisi	18
Şekil 3.2. Geliştirilen Web Tabanlı Sistemin Ana Menüsü	19
Şekil 4.1. Sisteme Yüklenen COVID-19 Pozitif Ultrason Videosunun Tahmin Sonucu	23
Şekil 4.2. Sisteme Yüklenen Bakteriyel Pnömoni Ultrason Videosunun Tahmin Sonucu	23
Şekil 4.3. Sisteme Yüklenen Viral Pnömoni Ultrason Videosunun Tahmin Sonucu	24
Şekil 4.4. Sisteme Yüklenen Sağlıklı Kontrol Ultrason Videosunun Tahmin Sonucu ..	24

TABLÖLAR DİZİNİ

Tablo No	Sayfa No
Tablo 3.1. Veri seti özellikleri.....	16
Tablo 4.1. CNN Modeline ilişkin Karışıklık Matrisi	20
Tablo 4.2. Kontrol Sınıfına İlişkin Performans Ölçütleri	21
Tablo 4.3. COVID-19 Sınıfına İlişkin Performans Ölçütleri	21
Tablo 4.4. Viral Pnömoni Sınıfına İlişkin Performans Ölçütleri	22
Tablo 4.5. Bakteriyel Pnömoni Sınıfına İlişkin Performans Ölçütleri.....	22

1. GİRİŞ

COVID-19 ilk olarak 31 Aralık 2019'da Çin'in Hubei Eyaleti, Wuhan şehrinde tespit edildi. Hızla bulaşan hastalık ilk olarak SARS-CoV-2 olarak tanımlandı ve daha sonra bu hastalık Dünya Sağlık Örgütü (DSÖ) tarafından COVID-19 olarak adlandırıldı. Virüs hayvanlarda oldukça yaygın olup, virüsün zoonotik varlığı nedeniyle hayvanlardan insanlara bulaşmış ve daha sonra temas yoluyla tüm dünyaya hızla yayılmıştır. Bu yeni ve hızla yayılan virüsün Wuhan kentinden Çin'in diğer bölgelerine yayılması 30 gün sürdü. COVID-19, 30 Ocak 2020'de Uluslararası Önemli Halk Sağlığı Acil Durumu ilan edildi ve daha sonra 11 Mart 2020'de DSÖ tarafından pandemi olarak ilan edildi. Ocak 2021 sonu itibariyle dünya çapında 100 milyondan fazla onaylanmış yeni koronavirüs (SARS-Cov-2) vakası ile 200 milyondan fazla kümülatif ölümlerle dünya çapında çok sayıda ölüme neden oldu ve insanların yaşamlarını oldukça olumsuz etkiledi. Hastalığın ateş, kuru öksürük, yorgunluk, nefes almada zorluk gibi grip benzeri semptomları bulunmaktadır. Daha ciddi vakalarda, COVID-19 sıklıkla ölümcül pnömoniye neden olmaktadır (1, 2).

Gerçek zamanlı ters transkripsiyon-polimeraz zincir reaksiyonu (RT-PCR), COVID-19 hastalığını tespit etmek için dünya çapında en yaygın kullanılan yöntemdir, ancak birçok ülkede bu hastalığı teşhis etmek için immünolojik testler de bulunmaktadır. Hızlı sonuç veren testlerin kolayca bulaşabilen COVID-19 hastalığının yayılmasını sınırlamak için en etkili yöntem olduğu kanıtlanmıştır ve bu durum araştırmacıları hızlı bir teşhis yöntemi aramaya yönlendirmektedir (3, 4). Bundan dolayı literatürde çalışmaların çoğunda COVID-19 tespiti için bilgisayarlı tomografi (BT), X-ışını ve akciğer ultrasonu (LUS) olmak üzere temel olarak üç tip radyolojik görüntüleme yöntemi kullanılmaktadır. Bu üç yöntemin dışında, fizyolojik sinyallerin çıkarılması için giyilebilir tıbbi sensörlerin bir kombinasyonunun kullanıldığı başka çalışmalar da vardır (5). Radyolojik görüntüleme yöntemleri arasında, BT taraması akciğerlerin üç boyutlu bir görünümünü sağlar ve hastalığın ilerlemesinin çeşitli aşamalarında COVID-19'u tespit edebilir (6, 7). Ancak, BT taraması maliyetlidir ve hastaları gelecekte bir dereceye kadar zararlı olabilecek radyasyona maruz bırakır (8). X-ışını taramaları esnekliği, düşük maliyeti ve nispeten daha hızlı yaklaşımı nedeniyle hastalığın teşhisinde kullanılan diğer bir yöntemdir (9, 10). Ancak, hastalığın özellikleri ve çeşitli evrelerdeki pulmoner

konsolidasyonları, doğası gereği düşük çözünürlüklü olması ve örtüşen projeksiyonlar içermesi nedeniyle X-ışını taramalarında net olarak görülmemektedir (10). Akciğer Ultrasonu (LUS) ise akciğerlerin net ve gerçek zamanlı görünümlerini sağlar ve yatak başında tedavi ve günlük kontrollerdeki etkili işlevselliği nedeniyle daha yararlıdır. LUS uzun süredir solunum sendromlarını saptamak için kullanılmaktadır ve pnömoni teşhisi için ilgili alanlardaki uzmanların görsel incelemesine göre X-ışınlarına göre daha iyi sonuç vermektedir (11).

Derin Öğrenme yöntemlerinden biri olan Evrişimli Sinir Ağları (CNN'ler) hem sınıflandırma hem de segmentasyon problemleri için yapay zekâ (AI) tabanlı çalışmalarda sıklıkla kullanılmaktadır. CNN; X-ışını, BT, LUS gibi tıbbi görüntü veya videoları kullanarak klinik kararlara destek olmak için etkin bir yöntemdir. COVID-19 dünya çapında bir pandemi olduğundan beri, CNN modellerini kullanmak COVID-19 tahmini için olağanüstü bir araştırma tekniği olmuştur. Farklı LUS veri kümelerini kullanarak COVID-19'u sınıflandırmak ve tanımlamak için CNN tabanlı oldukça iyi araştırmalar mevcuttur (12, 13). COVID-19'u tahmin etmek için oluşturulan CNN modelleri ile umut verici sonuçlar elde edilmiştir. Ancak bu çalışmalarda hastalığı hızlı teşhis edebilmek için web tabanlı klinik karar destek sistemlerinin geliştirilmesi yetersiz kalmıştır.


Bilgisayar destekli bir sistem, doktorlara ve radyologlara hastalık hakkında klinik kararlar vermede ve hastalık teşhisini, takibini ve prognozunu desteklemede yardımcı olabilmektedir. Bu çalışmada, COVID-19'u sağlıklı kontrol, bakteriyel pnömoni ve viral pnömoni'den doğru bir şekilde ayırt ederek tespit edebilmek için LUS videolarına dayalı oldukça başarılı bir derin öğrenme modeli oluşturulmuş ve bilgisayar destekli, hızlı, ücretsiz ve web tabanlı bilgisayar destekli bir tanı aracı geliştirilmiştir. Geliştirilen web tabanlı klinik karar destek sistemine <http://biostatapps.inonu.edu.tr/CVSY/> adresinden ücretsiz olarak erişilebilmektedir.

2. GENEL BİLGİLER

2.1. Yapay Zekâ Teknolojileri ve Tıpta Güncel Uygulamaları

Yapay zekâ (AI), bilgisayar ve makinelerin insan zihninin algılama, öğrenme, problem çözme ve karar verme yeteneklerini taklit etmesini sağlar. Popüler kullanımda AI, bir bilgisayarın veya makinenin örneklerden ve deneyimlerden öğrenme, nesneleri tanıma, dili anlama ve yanıt verme, karar verme, problem çözme gibi insan zihninin yeteneklerini taklit etme olarak ifade edilebilir. Uzun yıllardır yalnızca bilim kurguyla birlikte adı anılan AI, günlük yaşamın bir parçası haline gelmektedir. Verilerin artan hacmi ve buna bağlı olarak bu verileri insanlardan daha hızlı ve daha doğru işleyebilen bilgisayar sistemlerinin geliştirilmesi AI alanında önemli ilerlemelere olanak sağlamaktadır (14, 15).

Yapay zekâ makine öğrenmesi ile doğrudan ilişkilidir. Makine öğrenmesi (ML), bir bilgisayarın belirli talimatlar olmadan belirli görevleri (tipik olarak sınıflandırma veya regresyon) gerçekleştirmesini sağlayan, bunun yerine verilerden kalıplar çıkaran algoritmaların çalışmasına odaklanan bir AI alt kümesidir. Hem AI hem de ML, yüksek boyutlu verilerden tahmin ve sınıflandırmaya odaklandıkları için geleneksel istatistiksel yöntemlerden farklıdır. Başarılı ML modelleri, öğrenebileceği sağlam veriler gerektirir. Bu veriler, modelin tahmin performansı için ve bilinmeyen verilere genellenebilir olmasını sağlamak için oldukça önemlidir. Derin öğrenme modelleri ise AI ve ML’de yeni bir öğrenme biçimini temsil etmektedir. Görüntü işleme ve konuşma tanıma çalışmalarında çığır açan sonuçlar, bu alanda büyük bir ilgi yarattı, çünkü büyük veri sağlayan diğer birçok alandaki farklı uygulamalar da bu sayede mümkün görünmeye başladı (16, 17).



Şekil 2.1. AI, ML ve Derin Öğrenme Arasındaki İlişki


AI; epidemiyoloji, klinik karar verme, moleküler araştırmalar, ilaç geliştirme, tıbbi teşhis ve tedavi de dâhil olmak üzere sağlık sisteminin çeşitli seviyelerinde yaygın olarak kullanılmaktadır (12, 13). Özellikle AI algoritmaları, mevcut pandemi sırasında COVID-19 hastalarının hızlı tespitinde önemli bir rol oynamaktadır. COVID-19'u teşhis etmek için AI tekniklerini kullanan çalışmaların sayısı 2020 yılında hızla artmıştır. AI, teşhis doğruluğunu iyileştirebilir, sağlayıcı iş akışında ve klinik operasyonlarda verimliliği artırabilir, terapötik izlemeyi kolaylaştırabilir, prosedür doğruluğunu ve erken teşhis ile hastalık sürecini iyileştirebilir (18).

Örneğin; Tıpta AI lezyonları tespit etmek, ayırıcı tanıları oluşturmak ve otomatik tıbbi raporlar oluşturmak için uygulanmaktadır. 2017'de Gargeya ve Leng, diyabetik retinopatiyi taramak için AI kullanmıştır ve 5 kat çapraz doğrulama ile %94 duyarlılık ve %98 özgüllük elde edilmiştir. Benzer şekilde, Esteva ve arkadaşları, uzmanlarla karşılaştırılabilir sonuçlarla sağlıklı kontrol ve melanom cilt kanserlerini tanımlamak için bir CNN modeli eğitilmiştir. Weng ve arkadaşları, bir kohort popülasyonunda kardiyovasküler riski tahmin etmek için bir CNN'nin nasıl kullanılabileceğini gösterilmiştir. AI'nin, Amerikan Kardiyoloji Koleji yönergeleri tarafından tanımlanan yerleşik algoritma ile karşılaştırıldığında kardiyovasküler risk tahmininde doğruluğu artırdığı gösterilmiştir. AI ayrıca, amiloid görüntüleme verilerini analiz ederek ve bu hastalıkta ilaç tedavisi yanıtını doğru bir şekilde tahmin ederek Alzheimer hastalığının ilerlemesini güvenilir bir şekilde tahmin etmek için de uygulanmıştır (19-22).

2.2. Makine Öğrenmesi

Makine öğrenmesi; açıklayıcı, tahmine dayalı ve anlaşılır modeller ile verilerdeki gizli kalıpların keşfedilmesine yardımcı olan bir dizi yöntem olarak tanımlanabilir. Makine öğrenmesi yöntemleri, veritabanlarındaki kalıpları ve ilişkileri tanımlayabilir ve makine öğrenmesinden geliştirilen modeller, sağlık alanında teşhis ve tedavi planlaması için karar verme süreçlerini destekleyebilir. Keşfedilen modeller, hastane bilgi sistemlerinin karar verme süresini azaltmak için entegre edilebilen tahmine dayalı modeller olarak adlandırılabilir (23, 24).

Makine öğreniminin görevlerinden biri, farklı alanların uygulamalarında sınıflandırma yapmaktır. Sınıflandırma, her gözlemi bir dizi kuralla önceden belirlenmiş bir sınıfa atayan bir tahmin sürecidir. Özellikle sağlık ve tıp alanında, hastalıkların makine öğrenmesi yöntemleriyle risk faktörlerine göre sınıflandırılması ve bu risk faktörlerinin hastalık üzerindeki etki büyüklüklerinin belirlenmesi artmıştır. Sınıflandırma süreci, girdi verilerinden modeller oluşturmak için sistematik bir yaklaşım kullanır. Bu süreçte kullanılan veri seti temel olarak eğitim ve test verisi olarak ikiye ayrılmaktadır. Eğitim verileri sınıflandırma algoritması ile analiz edilir ve bu aşama eğitim aşaması olarak adlandırılır. Öte yandan, sınıflandırmanın doğruluğunu tahmin etmek için test verileri kullanılır. Bu şekilde elde edilen yeni bir kaydın sınıfı tahmin edilir (24, 25).



Şekil 2.2. Makine Öğrenmesi Süreci

2.2.1. Denetimli Öğrenme

Denetimli öğrenme, makine öğrenmesinde birçok araştırmanın odağı olan yöntemleri kapsamaktadır. Bu öğrenme türünde bir eğitim seti ve bir test seti kullanılmaktadır. Test setindeki etiketlenmemiş örnekleri mümkün olan en yüksek doğrulukla tanımlayabilmek için eğitim setindeki bir dizi etiketli örnekten öğrenilmesi olarak tanımlanabilir. Denetimli öğrenmede amaç, sınıf etiketine sahip olan örnekleri analiz ederek yeni örnekleri (test setinde) sınıflandıran bir kural, program veya prosedür geliştirmektir (26).

2.2.2. Denetimsiz Öğrenme

Denetimsiz öğrenme, sistemlerin belirli girdi kalıplarını genel girdi kalıpları koleksiyonunun istatistiksel yapısını yansıtacak şekilde temsil etmeyi nasıl öğrenebileceğini inceler. Denetimli öğrenme veya takviyeli öğrenme'nin aksine, her girdiyle ilişkili açık hedef çıktılar yoktur. Yani denetimsiz öğrenme sınıf etiketi olmayan (çıktısız) öğrenmedir. Bu öğrenmede, kümeler oluşturularak ve bu kümelere veri atanarak veri noktaları birbirine daha çok veya daha az benzeyen özelliklerine göre ayırmak amaçlanmaktadır (27).

2.2.3. Takviyeli Öğrenme

Takviyeli öğrenme, uzun vadeli bir hedefi ifade eden sayısal bir performans ölçüsünü en üst düzeye çıkarmak için bir sistemi kontrol etmeyi öğrenmekle ilgili bir öğrenme türüdür. Takviyeli öğrenmeyi denetimli öğrenmeden ayıran şey, öğrencinin tahminleri hakkında öğrenciye yalnızca kısmi geri bildirim verilmesidir. Ayrıca, tahminlerin kontrollü sistemin gelecekteki durumunu etkilemesinden dolayı uzun vadeli etkileri olabilir. Bu nedenle, zaman önemli bir rol oynar. Takviyeli öğrenmede amaç, verimli öğrenme algoritmaları geliştirmenin yanı sıra algoritmaların yararlarını ve sınırlamalarını anlamaktır. Takviyeli öğrenme, yapay zekadaki problemlerden yöneylem araştırması veya kontrol mühendisliğine kadar çok sayıda pratik uygulama nedeniyle büyük ilgi görmektedir (28).

2.2.4. Çevrimdışı Öğrenme

Bu öğrenme sistemi çevrimdışı bir ortamda eğitilip ve test edilen öğrenme türüdür. Daha sonra eğitilen modeller gerçek bir ortamda uygulanmadan önce değiştirilmemektedir. Bu eğitimden sonra herhangi bir eğitim, çevrimdışı bir ortamda gerçekleştirilir, test edilir ve sonrasında yazılım değişiklik tekniklerini kullanarak dağıtılır. Sistem bir kullanıcıyla etkileşime geçmeden önce sistemin insan tarafından doğrulanması için bir fırsat verir, bu nedenle yaklaşım günümüzde kullanılan makine öğrenmesi uygulamalarında daha yaygındır (29).

2.2.5. Çevrimiçi Öğrenme

Bilgisayar bilimlerinde, çevrimiçi öğrenme bir kerede tüm eğitim veri setinde değilde her adımda gelecek veriler için en iyi tahmin edicinin güncellenmek için kullanıldığı makine öğrenme türüdür. Çevrimiçi öğrenme, tüm veri kümesi üzerinde

eğitim yapmanın hesaplama açısından mümkün olmadığı ve çekirdek dışı algoritmalara ihtiyaç duyulduğu makine öğrenmesi alanlarında kullanılan yaygın bir yöntemdir. Ayrıca, algoritmanın verilerdeki yeni kalıplara dinamik olarak uyum sağlamasının gerekli olduğu durumlarda veya verinin kendisinin zamanın bir fonksiyonu olarak oluşturulduğu durumlarda sıklıkla kullanılır (29, 30).

2.3. Derin Öğrenme

Makine öğrenmesi teknolojisi, web aramalarından sosyal ağlarda içerik filtrelemeye, e-ticaret web sitelerindeki önerilere, kameralar ve akıllı telefonlar gibi tüketici ürünlerine kadar giderek daha fazla yer alarak modern toplumun birçok yönüne güç vermektedir. Makine öğrenmesi sistemleri, görüntülerdeki nesneleri tanımlamak, konuşmayı metne dönüştürmek, haber öğelerini, gönderileri veya ürünleri kullanıcıların ilgi alanlarına göre eşleştirmek ve ilgili arama sonuçlarını seçmek için kullanılmaktadır. Ancak son yıllarda, bu uygulamalar derin öğrenme adı verilen yöntemler bütününden yararlanmaktadır. Geleneksel makine öğrenme yöntemleri, doğal verileri ham formlarında işleme yetenekleriyle sınırlıydı ve onlarca yıldır, bir örüntü tanıma veya makine öğrenme sistemi oluşturmak, ham verileri (bir görüntünün piksel değerleri gibi) uygun bir dahili temsile veya özellik vektörüne dönüştüren bir özellik çıkarıcı tasarlamak için dikkatli mühendislik ve önemli alan uzmanlığı gerektiriyordu (31, 32).

Temsil öğrenimi, bir makinenin ham verilerle beslenmesine ve algılama veya sınıflandırma için gereken temsilleri otomatik olarak keşfetmesine olanak tanıyan bir dizi yöntemdir. Derin öğrenme yöntemleri, her biri bir düzeydeki temsili (ham girdiden başlayarak) daha yüksek, biraz daha soyut bir düzeyde temsile dönüştüren basit ancak doğrusal olmayan modüller oluşturarak elde edilen, birden çok temsil düzeyine sahip temsil-öğrenme yöntemleridir. Sınıflandırma görevleri için, daha yüksek temsil katmanları, girdinin ayırma için önemli olan yönlerini güçlendirir ve alakasız varyasyonları bastırır. Örneğin bir görüntü, bir dizi piksel değeri biçiminde gelir ve birinci temsil katmanındaki öğrenilen özellikler tipik olarak görüntüdeki belirli yönlerde ve konumlarda kenarların varlığını veya yokluğunu temsil eder. İkinci katman tipik olarak, kenar konumlarındaki küçük değişikliklerden bağımsız olarak belirli kenar düzenlemelerini tespit ederek motifleri algılar. Üçüncü katman; motifleri, bilinen nesnelerin parçalarına karşılık gelen daha büyük kombinasyonlar halinde birleştirebilir ve sonraki katmanlar, nesneleri bu parçaların birleşimleri olarak algılar. Derin öğrenmenin kilit yönü; bu özellik katmanlarının mühendisler tarafından

tasarlanmamasıdır (33-35).

Derin öğrenme, uzun yıllardır yapay zeka topluluğunun en iyi girişimlerine direnen sorunlarını çözme konusunda büyük ilerlemeler kaydetmektedir. Yüksek boyutlu verilerdeki karmaşık yapıları keşfetmede oldukça iyidir ve bu nedenle birçok bilim, işletme ve hükümet alanına uygulanabilmektedir. Görüntü/Video işleme, konuşma tanıma, potansiyel ilaç moleküllerinin aktivitesini tahmin etme, parçacık hızlandırıcı verilerini analiz etme, beyin devrelerini yeniden yapılandırma ve kodlamayan DNA'daki mutasyonların gen ekspresyonu ve hastalık üzerindeki etkilerini tahmin etme, duygu analizi, soru yanıtlama ve dil çevirisi gibi konularda diğer makine öğrenmesi yöntemlerine göre son derece umut verici sonuçlar elde edilmiştir (36-38).

2.3.1. Derin Öğrenme Mimarileri

Derin öğrenme mimarileri; yüksek boyutlu verilerden özellik dönüştürme ve özellik çıkarma amacıyla birçok doğrusal olmayan işlem katmanını kullanır. Bu mimarilerde her katman, kendinden önceki katmandaki çıktıyı girdi olarak alır ve kullanır. Yapay sinir ağlarındaki farklı katman sayısı ve yapısı nedeniyle çeşitli türlerde derin öğrenme mimarisi oluşturulmuştur. Bu derin öğrenme mimarileri aşağıdaki başlıklar altında gruplandırılmıştır.


2.3.2. Evrimsel Sinir Ağları (CNN)

CNN mimarisi, yüksek boyutlu verileri analiz etmek için denetimli bir makine öğrenme algoritması olan ve algılayıcıları kullanan bir yapay sinir ağı türüdür. Birçok gizli katmanın sırayla üst üste gelmesiyle oluşturulan çok katmanlı bir ileri beslemeli sinir ağıdır. Evrimsel sinir ağlarının hiyerarşik özellikleri öğrenmesini sağlayan bu sıralı tasarıma sahip olmasıdır (39).

CNN'ler evrim, havuzlama ve tam bağlantılı katmanlar gibi çoklu yapı taşlarını kullanarak geri yayılım yoluyla özelliklerin uzamsal hiyerarşilerini otomatik ve uyarlanabilir bir şekilde öğrenmek için tasarlanmaktadır. Evrim ve havuzlama katmanları, özellik çıkarma işlemini gerçekleştirirken, tam bağlantılı bir katman olan üçüncü katman, çıkarılan özellikleri sınıflandırmak için çıktıyı sağlar. Evrim katmanı, CNN'de önemli bir rol oynar. Bir evrim katmanı, doğrusal ve doğrusal olmayan işlemlerin bir kombinasyonundan yani evrim işlemi ve etkinleştirme işlevinden oluşan özellik çıkarımını gerçekleştiren CNN mimarisinin temel bir bileşenidir. Havuzlama

katmanı, küçük bozulmalara bir öteleme değişmezliği eklemek ve sonraki öğrenilebilir parametrelerin sayısını azaltmak için özellik haritalarının düzlem içi boyutluluğunu azaltan bir altörnekleme işlemi sağlar. Son evrişim veya havuzlama katmanının çıktısı özellik haritaları tipik olarak düzleştirilir ve yoğun katmanlar olarak da bilinen bir veya daha fazla tam bağlantılı katmana bağlanır. Evrişim katmanları tarafından çıkarılan ve havuzlama katmanları tarafından altörneklenen özellikler oluşturulduktan sonra bu özellikler tamamen bağlı katmanların bir alt kümesi tarafından ağın nihai çıktılarına eşlenir. Son tam bağlı katman, sınıf sayısı ile aynı sayıda çıktı düğümüne sahip olmalıdır (40).

CNN'ler görüntü işleme, doğal dil işleme ve diğer bilişsel görevler için sıklıkla kullanılır. Örneğin; dijital görüntülerde, piksel değerleri iki boyutlu bir ızgarada, yani bir dizi sayı içinde depolanır ve çekirdek adı verilen küçük bir parametre ızgarası optimize edilebilir bir özellik çıkarıcı her görüntü pozisyonuna uygulanır ve bu da CNN'leri görüntü işleme için oldukça verimli kılar, çünkü bir özellik görüntünün herhangi bir yerinde ortaya çıkabilir. Literatürde AlexNet, VGGNet, ResNet, GoogLeNet, MobileNet ve DenseNet en iyi bilinen CNN mimarileridir (27).




Şekil 2.3. CNN Mimarisinin Genel Yapısı

2.3.3. Tekrarlayan Sinir Ağları (RNN)

Tekrarlayan Sinir Ağları (RNN), bilgilerin ağ içinde depolanmasına izin veren döngüler içeren bir tür yapay sinir ağıdır. Yöntem yaklaşan olayları bilgilendirmek için önceki deneyimlerinden akıl yürütmeyi kullanır. Bu ağlar, birbirine bağlı bir dizi ağ olarak düşünülebilir. Genellikle zincir benzeri bir mimariye sahiptirler, bu da onları konuşma tanıma, dil çevirisi vb. görevlere uygulanabilir kılmaktadır. RNN, giriş, çıkış veya her ikisindeki vektör dizileri arasında çalışacak şekilde tasarlanabilir. Birden çok zaman dizisi verisi ile başa çıkabilir. Bu nedenle zaman dizisi verileriyle ilgili zaman


ilişkisini yakalamak için oldukça başarılı bir yöntem olduğu söylenebilir. Diğer yapay sinir ağlarında, tüm girdiler birbirinden bağımsız olmasına rağmen, RNN'de, tüm girdiler birbiriyle bağlantılıdır (41, 42).



Şekil 2.4. RNN Mimarisinin Genel Yapısı

2.3.4. Uzun Kısa Vadeli Hafıza Ağları (LSTM)

Uzun Kısa Vadeli Hafıza Ağları (LSTM), dizi tahmin problemlerinde sıra bağımlılığını öğrenebilen bir tekrarlayan sinir ağı türüdür ve karmaşık bir derin öğrenme alanıdır. Yüksek düzeyde bir LSTM, bir Tekrarlayan sinir ağı (RNN) gibi çalışır. LSTM ağının işleyişi üç bölümden oluşur ve her bölüm ayrı bir işlevi yerine getirir. Bir giriş katmanı, bir gizli katman ve bir çıkış katmanı kullanılır. Standart ileri beslemeli sinir ağlarının aksine, LSTM'nin geri bildirim bağlantıları vardır. Yalnızca tek veri noktalarını (görüntüler gibi) değil, aynı zamanda tüm veri dizilerini (konuşma veya video gibi) işleyebilir. LSTM el yazısı tanıma, konuşma tanıma ve saldırı tespit sistemlerinin tahmini gibi görevler için sıklıkla kullanılmaktadır (43, 44).



Şekil 2.5. LSTM Mimarisinin Genel Yapısı

2.3.5. Sınırlı Boltzmann Makineleri (RBM)

Boltzmann makineleri, dahili temsilleri öğrenebilen ve zor problemleri temsil edebilen ve çözebilen stokastik ve üretken sinir ağlarıdır. Boltzmann makineleri, eğitim verilerinde karmaşık düzenlilikleri temsil eden ilginç özellikleri keşfetmeyi sağlayan basit bir öğrenme algoritmasına sahiptir.

Birçok gizli katman, bir sonraki katman için eğitim verisi olarak özellik aktivasyonlarını kullanarak Sınırlı Boltzmann Makineleri (RBM) ile verimli bir şekilde öğrenilebilir. Boyut indirgeme ve sınıflandırma görevlerinde önemli bir rol oynar. Boltzmann, Derin İnanc Ağlarının temel bloğudur. İki katmanlı bir sinir ağıdır. RBM'nin ilk katmanına görünür veya giriş katmanı, ikinci katmanına ise gizli katman denilmektedir. RBM'de görünür birimler ve gizli birimler arasındaki ara bağlantılar simetrik ağırlıklar kullanılarak kurulur (45).


RBM, birbirinden oldukça farklı iki hesaplama problemini çözmek için kullanılır. Bir arama problemi için, bağlantıların ağırlıkları sabittir ve bir maliyet fonksiyonunu temsil etmek için kullanılır. Bir RBM'nin stokastik dinamikleri daha sonra maliyet fonksiyonunun düşük değerlerine sahip ikili durum vektörlerini örneklemesine izin verir. Bir öğrenme problemi için, RBM'ye bir dizi ikili veri vektörü gösterilir ve bu vektörleri yüksek olasılıkla üretmeyi öğrenmesi gerekir. Bunu yapmak için, diğer olası ikili vektörlere göre veri vektörlerinin maliyet fonksiyonunun düşük değerlerine sahip olması için bağlantılar üzerinde ağırlıklar bulması gerekir. Bir öğrenme problemini çözmek için RBM ağırlıklarında birçok küçük güncelleme yapar ve her güncelleme onların birçok farklı arama problemini çözmesini gerektirir (46, 47).

2.3.6. Derin İnanc Ağları (DBN)

Genel olarak derin inanc ağları (DBN), çeşitli denetimsiz sinir ağlarından oluşur. Derin inanc ağının ortak özelliklerinden biri, katmanların aralarında bağlantılar olmasına rağmen, ağı tek bir katmandaki birimler arasındaki bağlantıları içermemesidir. Yöntemin öncülerinden biri olan Geoff Hinton, derin inanc ağlarını "eğitim verilerinin derin bir hiyerarşik temsiliyi çıkaran" modeller olarak tanımlamaktadır (48).

DBN, birden çok stokastik, gizli değişken katmanından oluşan olasılıksal üretken modellerdir. Gizli değişkenler tipik olarak ikili değerlere sahiptir ve genellikle gizli birimler veya özellik algılayıcıları olarak adlandırılır. En üstteki iki katman, yönsüz ve simetrik bağlantılara sahiptir ve bir çağrışımsal bellek oluşturur. Alt katmanlar,

yukarıdaki katmandan yukarıdan aşağıya, yönlendirilmiş bağlantılar alır. En alt katmandaki birimlerin durumları bir veri vektörünü temsil eder. Bir katmandaki değişkenlerin yukarıdaki katmandaki değişkenlere nasıl bağlı olduğunu belirleyen, yukarıdan aşağıya, üretken ağırlıkları öğrenmek için etkili, katman katman bir prosedür vardır. DBM’de her katmandaki gizli değişkenlerin değerleri, alt katmanda gözlenen bir veri vektörü ile başlayan ve üretici ağırlıkları ters yönde kullanan tek bir aşağıdan yukarıya geçişle çıkarılabilir. Çok sayıda gizli katmana sahip ağırlar, görüntüler gibi yüksek düzeyde yapılandırılmış girdi verilerine uygulandığında, gizli katmanlardaki özellik dedektörleri, girdi verilerindeki yapıyı modelleyen derin bir inanç ağı öğrenilerek başlatılırsa, geri yayılım çok daha iyi çalışır (49, 50).




Şekil 2.6. DBN Mimarisinin Genel Yapısı

2.4. Görüntü İşleme

Dijital görüntü işleme, dijital bilgisayarlar kullanılarak görüntülerin işlenmesinden oluşur. Son yıllarda kullanımı katlanarak artmaktadır. Uygulamaların kullanıldığı alanlara sağlık, eğlence dünyası, eğitim ve jeolojik araştırmalar gibi alanlar örnek gösterilebilir. Modern bilgi toplumunun temel direklerinden biri olan multimedya sistemleri, büyük ölçüde dijital görüntü işlemeye dayanmaktadır. Sayısal görüntü işleme disiplini, sayısal sinyal işleme tekniklerinin yanı sıra görüntülere özgü teknikleri de kapsayan çok geniş bir disiplindir. Bir görüntü, iki sürekli değişken x ve y 'nin $f(x, y)$ fonksiyonu olarak kabul edilebilir. Dijital olarak işlenebilmesi için örneklenmesi ve bir sayı matrisine dönüştürülmesi gerekir. Bir bilgisayar sayıları sonlu kesinlik kullanarak

temsil ettiğinden, bu sayıların dijital olarak temsil edilmesi için nicelenmesi gerekir. Dijital görüntü işleme, bu sonlu hassas sayıların işlenmesinden oluşur (51-53).



Şekil 2.7. Görüntü işlemedeki temel adımlar

2.5. Görüntü işlemenin temel adımları

Görüntü elde etmek: Görüntü işlemede genellikle donanımlı bir kaynaktan görüntü elde ederek işleme başlanılır. İş akışı dizisindeki ilk adımdır ve ölçekleme gibi ön işleme yöntemleri kullanılarak yapılır.

Görüntü Zenginleştirme: Sonuçların görüntüleme veya daha fazla görüntü analizi için daha uygun olması için dijital görüntülerin ayarlanması işlemidir. Genellikle görüntülerin keskinleştirilmesi parlaklık ve kontrast ayarı, gürültünün giderilmesi vb. içerir.

Görüntü Restorasyonu: Bozulmuş H fonksiyonu ve ek gürültü terimi ile ilgili bazı bilgiler tarafından bozulmuş bir görüntünün kurtarılması işlemidir. Görüntü iyileştirmenin aksine, görüntü restorasyonu doğası gereği tamamen nesneldir.

Morforlojik İşleme: Görüntünün temsili ve tanımlanmasında yararlı olan görüntü bileşenlerinin çıkarılmasıyla ilgilendir. Erozyon ve genişleme gibi temel morfolojik

işlemleri içerir. Şekil 2.7'deki diyagramdan da görüldüğü gibi morfolojik işleme çıktıları genellikle görüntü öznitelikleridir.

Bölütleme (Segmentasyon): Dijital bir görüntüyü birden çok segmente ayırma işlemidir. Genellikle nesneleri ve nesnelerdeki sınırları bulmak için kullanılır.

Nesne Tanıma: Nesne tespiti, bilgisayarla görme ve görüntü işlemeden farklı olarak algılanan nesnenin görüntü üzerinde koordinatlarının bulunmasını içerir. Bulunan koordinatlar ile nesnenin bir çerçeve ile içine alınacağı alan da tespit edilmiş olur.

Temsil Etmek ve Açıklamak: Temsil, verilerin bilgisayar işlemesi için uygun bir forma dönüştürülmesiyle ilgilenir. Sınır gösterimi; odak, örneğin köşeler gibi dış şekil özellikleri üzerinde olduğunda kullanılır. Bölgesel temsil ise iç özelliklere (örneğin dokuya) odaklanıldığında kullanılır. Açıklama, özniteliklerin çıkarılmasıyla ilgilidir ve bir nesne sınıfını diğerinden ayırmak için kullanılır (53, 54).

2.6. Video İşleme

Günümüzde tıp alanında görüntüleme teknolojisi doğru teşhis için bilgi sağlamak amacıyla son derece önemlidir. Teşhis için yüksek çözünürlüklü 3D tarayıcılardan gelen artan miktarda grafik bilgi kullanılmaktadır. İyileştirilmiş tıbbi veri kalitesi, araştırmacıların ana amaçlarından biri haline gelmektedir. Bu durum, cerrahi amaçlar için insan vücudunun dâhili videoları ve doğru teşhis için daha fazla bilgi sağlayabilen kameralar tarafından desteklenen çeşitli tıbbi modalitelerin geliştirilmesine yol açmaktadır. Video işleme ve sınıflandırma güvenlik duvarı, canlı akış tahmini, eylem tanıma, şiddet tespiti, karakter tanıma, trafik kontrolü, sosyal medya analizi, duygu analizi, film inceleme, olay tahmini ve hastalık tahmini gibi birçok uygulamada sıklıkla kullanılmaktadır (55, 56).

Görüntülerle karşılaştırıldığında, karmaşık doğası nedeniyle videoları işlemek ve sınıflandırmak daha zordur. Video işleme, her bir kare için yapılan bir dizi işlem olarak görülebilir. Her çerçeve kod çözme, hesaplama ve kodlama işlemlerini içerir. Kod çözme, video karesinin sıkıştırılmış biçimden ham biçime dönüştürülmesidir. Hesaplama, çerçeve ile yapmamız gereken bir işlemdir. Kodlama, işlenmiş çerçevenin sıkıştırılmış duruma geri dönüştürülmesidir (57, 58).

Video sınıflandırma ise, videolardan görüntü çıkarımına dayalı olarak videoyu sınıflandırma tekniğini ifade eder. Video dizilerinde hareket eden nesneleri algılamak ve

saymak için kullanılabilir. İyi bir video sınıflandırıcısı, yalnızca doğru kare etiketleri sağlamakla kalmayıp, videodaki çeşitli karelerin özellikleri ve açıklamaları göz önüne alındığında tüm videoyu en iyi şekilde tanımlayan bir sınıflandırıcıdır. Örneğin, bir video bir karede bir ağaç içerebilir, ancak videonun merkezindeki etiket başka bir şey olabilir (örneğin, "yürüyüş"). Kareleri ve videoyu tanımlamak için gereken etiketlerin ayrıntı düzeyi, göreve bağlıdır. Tipik görevler, videoya bir veya daha fazla global etiket atamayı ve video içindeki her kare için bir veya daha fazla etiket atamayı içerir (59).

Video sınıflandırmanın bazı temel adımları vardır ve bu adımlar sırayla yapılmalıdır. İlk adım veri toplama adımıdır. Bu adım oldukça önemlidir çünkü oluşturulacak sınıflandırma modelinin başarısı veri setinin kalitesine göre değişmektedir. İkinci adım olan veri ön işleme adımında veri için özellik çıkarma, ardından özellik eşleştirme ve sınıflandırma için yöntem yürütme gibi aşamalar bulunmaktadır. Ön işleme bölümü, bir video sınıflandırma sürecinde özellik veya bilgi çıkarmanın yanı sıra video dönüştürme, segmentasyon vb. gibi önemli görevler içerir. Derin öğrenme algoritmaları ile özellik çıkarma, özellik eşleştirme ve özellik sınıflandırma video sınıflandırma sürecinin ana parçalarından biridir (59, 60).



3. MATERYAL VE METOT

3.1. Materyal

3.1.1. Çalışmada Kullanılan Veri Seti

Bu çalışmada COVID-19, viral pnömoni, bakteriyel pnömoni ve sağlıklı kontrolleri içeren ve https://github.com/jannisborn/covid19_ultrasound adresinden elde edilen açık kaynaklı LUS video veri seti kullanılmıştır (61, 62). Kullanılan veri seti ABD uzmanları tarafından kontrol edilmiştir. Veri setinde normalde dışbükey ve doğrusal olmak üzere 200'den fazla LUS videosu bulunmaktadır. Ancak çalışmada 92 dışbükey ultrason video kullanılmıştır. Bu videoların 24'ü COVID-19, 12'si viral pnömoni, 24'ü bakteriyel pnömoni ve 32'si sağlıklı kontrol sınıfındaydı. Veri setinin genel özellikleri Tablo 3.1'de verilmiştir.

Tablo 3.1. Veri seti özellikleri

Dosya Formatı	.avi
Kullanılan Yöntem	Basit Geçerlilik (Hold-out)
Veri Seti Türü	Açık Kaynaklı
Toplam Video Sayısı	92
Her bir sınıf için videolardan elde edilen görüntü sayısı	300
Eğitim Görüntü Sayısı	960
Test Görüntü Sayısı	240
Toplam Görüntü Sayısı	1200
Genişlik	64 piksel
Yükseklik	64 piksel

3.2. Metot

Çalışmadaki tüm analizler Python 3.9 programında yapılmıştır. Python programı <https://www.python.org/> adresinden ücretsiz olarak yüklenebilmektedir. Python programının tercih edilmesindeki sebep ise Açık Kaynak (Open Source) bir dil olması ve birçok geliştirici tarafından kullanılmasıdır. Çalışmada kullanılan yöntemler 4 aşamada incelenebilir.

Bunlar;


1. Veri işleme,
 2. CNN derin öğrenme modelinin oluşturulması,
 3. Oluşturulan modelin eğitimi,
 4. Web tabanlı video işleme yazılımının geliştirilmesi,
- aşamalarını içermektedir.

3.2.1. Veri İşleme

Tüm analizler, akciğeri kapsamlı şekilde görmeyi sağlayan standart bir prob olan dışbükey ultrason problemleri ile kaydedilen veriler (videolar) üzerinde gerçekleştirildi. 92 dışbükey ultrason videosu manuel olarak işlendi ve bunlar her sınıf için 300 kare ile görüntülere bölündü ve 300 COVID-19, 300 bakteriyel pnömoni, 300 viral pnömoni ve 300 sağlıklı kontrol olmak üzere 1200 görüntüden oluşan bir veritabanı oluşturuldu. Görüntülere normalizasyon işlemi yapıldı. Farklı çözünürlüklere sahip olan görüntülerin tümü, 64×64 piksele yeniden boyutlandırıldı. Bu yeniden boyutlandırma işlemi ile standartlaştırılmış görüntüler elde edildi. Derin öğrenme için verideki görüntülerin tümünün aynı boyutlarda olması önemlidir. Çünkü CNN'in giriş katmanı, verideki her görüntü için bir piramit meydana getirir. Bu piramit, herhangi bir boyuttaki bir nesnenin algılanmasına olanak sağlar ve böylece modeli görüntü veri setinde bulunan daha büyük ve/veya daha küçük nesneleri/objeleri algılamayı öğrenir. Tüm sonuçlar Basit Geçerlilik (Hold-out) yöntemi ile görüntülerin %80'i eğitim ve %20'si test seti şeklinde bölünerek elde edildi. Tek bir videonun karelerinin sadece tek bir kıvrımda olması ve sınıf başına örnek sayısının tüm kıvrımlarda benzer olması sağlandı.

3.2.2. Derin Öğrenme Modelinin Oluşturulması

Bu çalışmada Tensorflow Kütüphanesinde bulunan derin sinir ağları mimarilerinden olan Evrişimli Sinir Ağları (CNN) kullanılmaktadır. CNN az miktarda eğitim veri seti ile yüksek performanslı modeller üretmektedir. Böylece binlerce görüntü olmadan çok az veri kullanılarak doğru tahminler elde edilebilmektedir. Derin ve ileri beslemeli yapay sinir ağlarından olan CNN genellikle görsel nesnelerin analiz edilmesinde kullanılmaktadır. Çalışmada kullanılan CNN modelinin yapısı Şekil 3.1'deki gibidir.



Şekil 3.1. Oluşturulan CNN Mimarisi

3.2.3. Modelin Eğitimi


Eğitim görüntü veri seti oluşturulan CNN modeli ile eğitilirken erken durdurma geri araması kullanılmaktadır. Geri aramalar, kodu yürütmek ve eğitim modeli süreciyle otomatik olarak etkileşim kurmak için önemlidir. Keras, erken durdurma adlı bir geri arama yoluyla eğitimin erken durdurulmasını destekler. Bu geri arama, izlenecek performans ölçüsünü, tetikleyiciyi belirlemenize olanak tanır ve bir kez tetiklendiğinde eğitim sürecini durdurur. Oluşturulan modelde eğitim tur (epoch) sayısı 15 olarak ayarlanmıştır. Derin öğrenme uygulamalarında öğrenme işleminin temelde bir optimizasyon problemidir. Doğrusal olmayan problemlerin çözümünde optimum değeri bulmak için optimizasyon yöntemleri kullanılmaktadır. Derin öğrenme uygulamalarında yaygın olarak stochastic gradient descent, adagrad, adadelta, adam, adamax gibi

optimizasyon algoritmaları kullanılmaktadır. Bu algoritmalar arasında başarımlar ve hız bakımından farklılıklar bulunmaktadır.

Çalışmada modelin hiperparametreleri sezgisel olarak seçildi ve analiz sırasında Adam'ın optimizasyon yöntemi ayarlandı. Model performansı Doğruluk, Kesinlik, Duyarlılık, Seçicilik, F1 Skoru, Matthews'in Korelasyon Katsayısı (MCC), G-Ortalama ve Karışıklık (Sınıflandırma) Matrisine göre değerlendirildi.

3.2.4. Web Tabanlı Sistemin Geliştirilmesi

Çalışmanın ikinci aşamasında, COVID-19'u viral pnömoni, bakteriyel pnömoni ve sağlıklı kontrollerden ayırt edebilmek için internete bağlı herhangi bir cihazdan (cep telefonu, masaüstü bilgisayar, dizüstü bilgisayar vb.) ücretsiz olarak erişilebilen bilgisayar destekli bir tanı sistemi geliştirildi. Bu web tabanlı sistem Python Flask Kütüphanesi ve JavaScript yardımıyla, HTML5 alt yapısı ile geliştirilmiştir. Sistem İngilizce ve Türkçe olmak üzere iki dil seçeneğine sahiptir. COVID-19 şüphesi olan kişilerin akciğer ultrason videoları yüklendiğinde, geliştirilen sistem birkaç dakika veya daha kısa süre içinde COVID-19 hastalığını tespit edebilmektedir. COVID-19 için ultrason videolarına dayalı bilgisayar destekli tanı sisteminin ana menüsü Şekil 3.2'de gösterilmektedir. Sistem üç bölümden oluşmaktadır. İlk bölüm sistemin kısa bir açıklamasını içerir. İkinci bölümde, kullanıcı akciğer ultrason videosunu sisteme yükleyip “analiz et” düğmesine tıkladığında, üçüncü bölümde COVID-19 teşhisinin tahmini görüntülenir. Sistem, .mov, .mp4, veya .avi uzantılı video dosyalarını desteklemektedir. Geliştirilen bilgisayar destekli tanı aracına <http://biostatapps.inonu.edu.tr/CVSY/> adresinden ulaşılabilir.



Şekil 3.2. Geliştirilen Web Tabanlı Sistemin Ana Menüsü

4. BULGULAR

4.1. Oluşturulan CNN Modelinin Bulguları

Oluşturulan modelin COVID-19, Viral pnömoni ve Bakteriyel pnömoni Ultrason tarama test veri seti için karışıklık matrisi Tablo 4.1’de verilmiştir. Sağlıklı Kontrol, COVID-19, Viral pnömoni ve Bakteriyel pnömoni tespiti için oluşturulan CNN modelinden elde edilen performans metrikleri Tablo 4.2, Tablo 4.3, Tablo 4.4 ve Tablo 4.5’deki gibidir.

Tablo 4.1. CNN Modeline ilişkin Karışıklık Matrisi

	Sağlıklı Kontrol	COVID-19	Viral pnömoni	Bakteriyel pnömoni
Sağlıklı Kontrol	52	3	2	2
COVID-19	3	53	2	3
Viral pnömoni	4	3	55	3
Bakteriyel pnömoni	1	1	1	52

Oluşturulan CNN modeli videolar eğitildikten sonra test seti için sağlıklı kontrol sınıfında 60 örneğin 52’sini doğru tahmin ederken, 8 örneğin sınıfını ise yanlış tahmin etmiştir. COVID-19 sınıfında 60 örneğin 53’sini doğru tahmin ederken, 7 örneğin sınıfını ise yanlış tahmin etmiştir, Viral Pnömoni grubunu içeren 60 örneğin 55’ini doğru tahmin ederken, 5 örneğin sınıfını ise yanlış tahmin etmiştir, Bakteriyel Pnömoni grubunu içeren 60 örneğin 52’sini doğru tahmin ederken, 8 örneğin sınıfını ise yanlış tahmin etmiştir.

Tablo 4.2. Kontrol Sınıfına İlişkin Performans Ölçütleri

Metrik	Tahmin Değeri	%95 Güven Aralığı	
		Alt Sınırı	Üst Sınırı
Doğruluk	0.9339	0.9025	0.9653
Kesinlik	0.8667	0.8237	0.9097
Duyarlılık	0.8814	0.8404	0.9223
Seçicilik	0.9524	0.9254	0.9793
F1-Skoru	0.8739	0.832	0.9159
MCC	0.8292	0.7816	0.8768
G-ortalama	0.9162	0.8811	0.9512

MCC: Matthews'in Korelasyon Katsayısı

Sağlıklı Kontrol Sınıfına ilişkin Performans Ölçütleri dikkate alındığında, doğruluk %93.39 (%90.25-%96.53), kesinlik %86.67 (%82.37-%90.97), duyarlılık %88.14 (%84.04-%92.23), seçicilik %95.24 (%92.54-%97.93), F1-Score %87.39 (%83.2-%91.59), MCC %82.92 (%78.16-%87.68) ve G-ortalama %91.62 (%88.11-%95.12) olarak bulunmuştur.

Tablo 4.3. COVID-19 Sınıfına İlişkin Performans Ölçütleri

Metrik	Tahmin Değeri	%95 Güven Aralığı	
		Alt Sınırı	Üst Sınırı
Doğruluk	0.9339	0.9025	0.9653
Kesinlik	0.8833	0.8427	0.9239
Duyarlılık	0.8689	0.8261	0.9116
Seçicilik	0.9578	0.9324	0.9833
F1-Skoru	0.876	0.8343	0.9177
MCC	0.831	0.7836	0.8785
G-ortalama	0.9123	0.8765	0.9481

MCC: Matthews'in Korelasyon Katsayısı

COVID-19 Sınıfına ilişkin Performans Ölçütleri dikkate alındığında, doğruluk %93.39 (%90.25-%96.53), kesinlik %88.33 (%84.27-%92.39), duyarlılık %86.89 (%82.61-%91.16), seçicilik %95.78 (%93.24-%98.33), F1-Score %87.6 (%83.43-

%91.77), MCC %83.1 (%78.36-%87.85) ve G-ortalama %91.23 (%87.65-%94.81) olarak bulunmuştur.

Tablo 4.4. Viral Pnömoni Sınıfına İlişkin Performans Ölçütleri

Metrik	Tahmin Değeri	%95 Güven Aralığı	
		Alt Sınırı	Üst Sınırı
Doğruluk	0.9339	0.9025	0.9653
Kesinlik	0.9167	0.8817	0.9516
Duyarlılık	0.8462	0.8005	0.8918
Seçicilik	0.9691	0.9473	0.991
F1-Skoru	0.88	0.8389	0.9211
MCC	0.8358	0.7889	0.8827
G-ortalama	0.9056	0.8686	0.9426

MCC: Matthews'in Korelasyon Katsayısı

Viral pnömoni sınıfına ilişkin performans ölçütleri dikkate alındığında, doğruluk %93.39 (%90.25-%96.53), kesinlik %91.67 (%88.17-%95.16), duyarlılık %84.62 (%80.05-%89.18), seçicilik %96.91 (%94.73-%99.1), F1-Score %88 (%83.89-%92.11), MCC %83.58 (%78.89-%88.27) ve G-ortalama %90.56 (%86.86-%94.26) olarak bulunmuştur.

Tablo 4.5. Bakteriyel Pnömoni Sınıfına İlişkin Performans Ölçütleri


Metrik	Tahmin Değeri	%95 Güven Aralığı	
		Alt Sınırı	Üst Sınırı
Doğruluk	0.9507	0.9233	0.9781
Kesinlik	0.8667	0.8237	0.9097
Duyarlılık	0.9455	0.9167	0.9742
Seçicilik	0.9524	0.9254	0.9793
F1-Skoru	0.9043	0.8671	0.9416
MCC	0.8727	0.8305	0.9149
G-ortalama	0.9489	0.9211	0.9768

MCC: Matthews'in Korelasyon Katsayısı


Bakteriyel Pnömoni Sınıfına ilişkin Performans Ölçütleri dikkate alındığında, doğruluk %95.07 (%92.33-%97.81), kesinlik %86.67 (%82.37-%90.97), duyarlılık %94.55 (%91.67-%97.42), seçicilik %95.24 (%92.54-%97.93), F1-Score %90.43 (%86.71-%94.16), MCC %87.27 (%83.05-%91.49) ve G-ortalama %94.89 (%92.11-%97.68) olarak bulunmuştur.

4.2. Geliştirilen Web Tabanlı Sistemin Bulguları


Dışarıdan sisteme rastgele yüklenen COVID-19, bakteriyel pnömoni, viral pnömoni ve sağlıklı kontrollere ilişkin tahmin sonuçları sırasıyla Şekil 4.1, Şekil 4.2, Şekil 4.3 ve Şekil 4.4’de gösterilmektedir. Görüldüğü gibi sistem, yüklenen ultrason videosuna göre COVID-19’u diğer sınıflardan başarılı bir şekilde ayırabilmektedir.




Şekil 4.1. Sisteme Yüklenen COVID-19 Pozitif Ultrason Videosunun Tahmin Sonucu



Şekil 4.2. Sisteme Yüklenen Bakteriyel Pnömoni Ultrason Videosunun Tahmin Sonucu



Şekil 4.3. Sisteme Yüklenen Viral Pnömoni Ultrason Videosunun Tahmin Sonucu



Şekil 4.4. Sisteme Yüklenen Sağlıklı Kontrol Ultrason Videosunun Tahmin Sonucu

5. TARTIŞMA

Yapay zekâ destekli araçlar, işlenmemiş verilerde anlamlı ilişkileri belirleyebilir ve ilaç geliştirme, tedavi kararları, hasta bakımı, mali ve operasyonel kararlar dâhil olmak üzere tıbbın hemen her alanında uygulanabilmektedir. Yapay zekâ sayesinde sağlık hizmetleri uzmanları; kendi başlarına ele almaları zor, zaman alıcı ya da verimsiz olabilecek karmaşık sorunlarla kolay bir şekilde mücadele edebilirler. Uzmanlıklarını daha iyi kullanmalarına ve sağlık sisteminde değer sağlamalarına olanak tanıyarak, yapay zekâ uzmanlar için değerli bir kaynak olabilir (63, 64).

COVID-19 sağlık sistemleri ve ulusların ekonomileri için uzun süredir devam eden bir tehlikedir. Dünyada milyonlarca insan COVID-19 nedeniyle hayatını kaybetti. Ölümünün çoğu, diğer organların kaybına neden olan solunum yetmezliğinden kaynaklanmaktadır. Birçok acil durum olduğu için hastane kapasiteleri doludur ve klinisyenlerin zamanları sınırlıdır. Bu nedenle bilgisayar destekli tanı sistemlerine ihtiyaç duyulmaktadır. COVID-19'un mevcut durumunun klinik teşhisinde hız, erişilebilirlik ve uygulama kolaylığı son derece önemli olduğu için, tıbbi görüntüleme yöntemlerini yapay zekâ teknolojileri ile birleştirmek klinik açıdan oldukça önemlidir (64).

Bu çalışmada, Akciğer Ultrason videolarına dayalı COVID-19, Viral Pnömoni, Bakteriyel Pnömoni ve sağlıklı kontrolleri birbirinden ayırt edebilmek için başarılı bir CNN mimarisi oluşturulmuştur. Oluşturulan model, test setinde COVID-19'u %93.39, Viral Pnömoni'yi %93.39, Bakteriyel Pnömoni'yi %95.07 ve sağlıklı kontrolleri ise %93.39 doğruluk ile sınıflamıştır. Ek olarak oluşturulan CNN modeli Modelin elde edilen performans ölçütleri için bir diğer önemli sonuç, modelden elde edilen duyarlılık ölçütüdür. Daha yüksek bir duyarlılık değeri, daha düşük bir yanlış negatif (FN) değer anlamına gelir ve düşük bir FN değeri, vakalar için cesaret verici bir sonuçtur. Bu sonuç önemlidir çünkü gözden kaçan COVID-19 ve Pnömoni vakalarını (yanlış negatif) en aza indirmek bu araştırmanın ana amaçlarından biridir.

CNN modellerinin farklı yapıları kullanılarak COVID-19 tahminine ilişkin yayınlanmış birçok çalışma rapor edilmiştir. Literatürde X-ışını görüntü veri seti kullanılarak yapılan bir çalışmada CNN, CNN / Random Forest ve CNN-destek vektör makinesi (SVM) yöntemleri kullanılmış ve en yüksek doğruluk oranı %95.2 ile CNN modelinden elde edilmiştir (65). Başka bir çalışmada MobileNet, ResNet50, InceptionV3

ve InceptionV3 ve MobileNet modelleri kombinasyonu kullanılarak sırasıyla %95.18, %94.39, %95.75 ve %96.49 doğruluk oranları elde edilmiştir (66). COVID-19 X-Ray tarama görüntü veri setlerinde ResNet18, ResNet50, ResNet101, VGG16 ve VGG19 modelleri kullanılan bir çalışmada özelliklerin sınıflandırılması için bazı çekirdek fonksiyonları ile Destek Vektör Makineleri (SVM) sınıflandırıcısı oluşturulmuştur. ResNet50 modeli ve SVM sınıflandırıcı, tüm sonuçlar arasında en yüksek değer olan %94,7'lik bir doğruluk puanı elde edilmiştir (67). Farklı bir COVID-19 X-ışını görüntü veri setinde DeTraC olarak adlandırılan aktarım - öğrenme için farklı CNN modelleri (AlexNet, VGG19, ResNet ve SqueezeNet) oluşturulmuştur. COVID-19'u tespit etmek için DeTraC ile %93.1'lik bir doğruluk oranı elde edilmiştir (68).

Yapılan bir çalışmada ultrason görüntülerine dayalı olarak oluşturulan ResNeXt (MCRFNet) modeli ile %94.39 doğruluk, %82.28 kesinlik, %76,27 duyarlılık değerleri elde edilmiştir (69). Akciğer ultrason görüntüleme veri setinden COVID-19'un otomatik tespiti için yapılan bir diğer çalışmada; derin bir evrimsel sinir ağı (POCOVID-Net) eğitilmiş ve %89 doğruluk elde edilmiştir (70).

Literatürde birçok çalışmada COVID-19 tahmini için olağanüstü sonuçlar elde edilmiştir. Ancak bu çalışmaların çoğu COVID pozitif ve COVID negatif örnekleri sınıflandırılmıştır ve oluşturulan modeller için web tabanlı klinik karar destek sistemlerinin geliştirilmesi de sınırlı kalmıştır. Literatürdeki benzer çalışmalara kıyasla mevcut çalışmanın diğer çalışmalardan önemli bir farkı, COVID-19'u, Viral Pnömoni'yi ve Bakteriyel Pnömoni'yi hızlı bir şekilde tahmin edebilen bir modelin geliştirilmesi ve dünya çapında kullanılmak üzere geliştirilen ücretsiz ve web tabanlı klinik karar destek sisteminin geliştirilmesidir.

Bu çalışmanın ikinci aşamasında geliştirilen web tabanlı sistem, ultrason videolarından COVID-19, Viral Pnömoni, Bakteriyel Pnömoni ve sağlıklı kontrolleri birbirinden ayırt edebilen ve tahmin sonuçlarını birkaç dakika veya saniye içinde verebilen nadir çalışmalardan biridir. Bu nedenle geliştirilen sistemin klinik değerlendirmelerde klinisyenlere ve diğer sağlık çalışanlarına yardımcı olacağı düşünülmektedir. COVID-19, Viral Pnömoni ve Bakteriyel Pnömoni şüphesi olan bireyleri teşhis etmek için kullanılan tıbbi yöntemlere yardımcı olabilecek bir sistemin geliştirilmesi ile hastalığın teşhis ve tedavi süreçlerinin daha etkin bir şekilde yürütülmesi öngörülmektedir. Ayrıca önerilen yapay zekâ tabanlı sistemin etkin kullanımı ile hastalığın teşhis süreçlerini desteklemesi, olası mali yükü ve uygun olmayan tıbbi

prosedürleri azaltması beklenmektedir. Önerilen model ve geliştirilen sistem, radyolojiye odaklanan mevcut yaklaşımı önemli ölçüde etkilemektedir ve sağlık çalışanları ve radyologların COVID-19, Viral Pnömoni ve Bakteriyel Pnömoni vakalarını tespit etmelerine, teşhis etmelerine ve takip etmelerine yardımcı olacak yararlı bir araç olabilir. Bu bilgisayar destekli sistem ile COVID-19, Viral Pnömoni ve Bakteriyel Pnömoni için teşhis süresini kısaltacağı ve teşhis doğruluğunu önemli ölçüde arttıracığı öngörülmektedir.



6. SONUÇ VE ÖNERİLER

Bu çalışmada, COVID-19'u sağlıklı kontrol, bakteriyel pnömoni ve viral pnömoni'den doğru bir şekilde ayırt ederek tespit edebilmek için Akciğer Ultrasonu (LUS) videolarına dayalı oldukça başarılı bir derin öğrenme modeli oluşturulmuş ve bilgisayar destekli, hızlı, ücretsiz ve web tabanlı bilgisayar destekli bir tanı aracı geliştirilmiştir. Çalışmada geliştirilen web tabanlı sistemin; COVID-19, Viral Pnömoni ve Bakteriyel Pnömoni teşhisi için klinik karar verme sürecinde hekimlere destek sağlayabileceği tahmin edilmektedir.

Çalışmanın birincil katkıları aşağıdaki gibidir:

1. COVID-19 sınıflandırması için CNN mimarisi ile oluşturulan model, test setinde oldukça başarılı performansa sahiptir.
2. CNN modeline dayalı olarak geliştirilen sistem, COVID-19'u doğru ve etkin bir şekilde tahmin edebilmektedir. Ayrıca birkaç dakika veya saniye içinde tahmin işlemini gerçekleştirmektedir.
3. Geliştirilen web tabanlı sistemin <http://biostatapps.inonu.edu.tr/CVSY/> adresinden interneti olan herhangi bir cihaz aracılığıyla kullanılabilmesi hastalıkların tespiti için hızlı bir araç olabileceği ve bu sayede hastalıkların prevalansını düşürebileceği düşünülmektedir.
4. Sistemin çift dil seçeneğine sahip olması erişim kolaylığı sağlamaktadır.

Birlikte ele alındığında, mevcut çalışmanın ön sonuçları oldukça iyidir ve eğitim için daha fazla veri elde edildikçe sonuçlar daha da geliştirilebilir. Gelecekteki çalışmalar için, sistemin daha fazla eğitim veri setini kullanarak daha yüksek performans ölçütlerine sahip bir model oluşturmak planlanmaktadır.

KAYNAKLAR

1. Dastider AG, Sadik F, Fattah SA. An integrated autoencoder-based hybrid CNN-LSTM model for COVID-19 severity prediction from lung ultrasound. *Comput Biol Med* 2021,132: 104296: 150-8.
2. Muhammad G, Hossain MS. COVID-19 and non-COVID-19 classification using multi-layers fusion from lung ultrasound images. *Inf Fusion* 2021, 72: 80-8.
3. Wang C, Horby PW, Hayden FG, Gao GF. A novel coronavirus outbreak of global health concern. *The lancet* 2020, 395: 470-3.
4. Ahmadi M, Sharifi A, Dorosti S, Ghouschi SJ, Ghanbari N. Investigation of effective climatology parameters on COVID-19 outbreak in Iran. *Sci. Total Environ* 2020, 729: 138705: 180-7.
5. Hassantabar S, Stefano N, Ghanakota V, Ferrari A, Nicola GN, Bruno R, Marino IR, Hamidouche K, Jha NK. Coviddeep: Sars-cov-2/covid-19 test based on wearable medical sensors and efficient neural networks. *arXiv* 2020, 200710497: 1-11.
6. Ai T, Yang Z, Hou H, Zhan C, Chen C, Lv W, Tao Q, Sun Z, Xia L. Correlation of chest CT and RT-PCR testing for coronavirus disease 2019 (COVID-19) in China: a report of 1014 cases. *Radiology* 2020, 296: 32-8.
7. Chung M, Bernheim A, Mei X, Zhang N, Huang M, Zeng X, Cui J, Xu W, Yang Y, Fayad ZA, Jacobi A, Li K, Li S, Shan H. CT imaging features of 2019 novel coronavirus (2019-nCoV). *Radiology* 2020, 295: 202-7.
8. Roy S, Menapace W, Oei S, Luijten B, Fini E, Saltori C, Huijben I, Chennakeshava N, Mento F, Sentelli A, Peschiera E, Trevisan R, Maschietto G, Torri E, Inchingolo R, Smargiassi A, Soldati G, Rota P, Passerini A, van Sloun Ruud JG, Ricci E, Demi L. Deep learning for classification and localization of COVID-19 markers in point-of-care lung ultrasound. *IEEE Trans Med Imaging* 2020, 39 :2676-87.
9. Mahmud T, Rahman MA, Fattah SA. CovXNet: A multi-dilation convolutional neural network for automatic COVID-19 and other pneumonia detection from chest X-ray images with transferable multi-receptive feature optimization. *Comput Biol Med* 2020, 122: 103869: 580-9.

10. Fan L, Li D, Xue H, Zhang L, Liu Z, Zhang B, Zhang L, Yang W, Xie B, Duan X, Hu X, Cheng K, Peng L, Yu N, Song L, Chen H, Sui X, Zheng N, Liu S, Jin Z. Progress and prospect on imaging diagnosis of COVID-19. *Chin J Acad Radiol* 2020, 3 : 4-13.
11. Amatya Y, Rupp J, Russell FM, Saunders J, Bales B, House DR. Diagnostic use of lung ultrasound compared to chest radiograph for suspected pneumonia in a resource-limited setting. *Int J Emerg Med* 2018, 11(1): 1-9.
12. Polsinelli M, Cinque L, Placidi G. A light CNN for detecting COVID-19 from CT scans of the chest. *Pattern Recognit Lett* 2020, 140: 95-5.
13. Huang S, Yang J, Fong S, Zhao Q. Artificial intelligence in the diagnosis of COVID-19: challenges and perspectives. *Int J Biol Sci* 2021, 17: 95-5.
14. Hamet P, Tremblay J. Artificial intelligence in medicine. *Metab* 2017, 69: 36-40.
15. Amisha PM., Pathania M, Rathaur VK. Overview of artificial intelligence in medicine. *Fam. Med. Prim. Care Rev* 2019, 8: 2328–2331.
16. Jackson PC. *Introduction to artificial intelligence*, 5th ed. Mineola, Newyork, Dover Publications, 2019: 40-48.
17. Ertel W. *Introduction to artificial intelligence*, 2th ed. Springer, 2018: 10-15.
18. Hamet P, Tremblay J. Artificial intelligence in medicine. *Metabolism* 2017, 69: 36-40.
19. Mintz Y, Brodie R. Introduction to artificial intelligence in medicine. *MITAT* 2019, 28: 73-81.
20. Amisha PM, Pathania M, Rathaur VK. Overview of artificial intelligence in medicine. *JFMPC* 2019, 8: 2328.
21. Kaul V, Enslin S, Gross SA. History of artificial intelligence in medicine. *GIE* 2020, 92: 807-12.
22. Lorkowski J, Grzegorowska O, Pokorski M. Artificial Intelligence in the Healthcare System: An Overview. *Adv Exp Med Biol* 2021, 2: 1-10.

23. Yağın FH. Gen İfade Veri Setlerinde Boyut İndirgeme Yöntemlerinin Sınıflama Performansına Etkilerinin Karşılaştırılması. Sağlık Bilimleri Enstitüsü, Biyoistatistik ve Tıp Bişimi Anabilim Dalı. Yüksek Lisans tezi, Malatya: İnönü Üniversitesi, 2020.
24. Sarker IH. Machine learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science* 2021, 2: 1-21.
25. BalıkcıCicek İ, Kucukakcalı Z, Colak C. Associative Classification Approach Can Predict Prostate Cancer Based On The Extracted Association Rules. *The Journal of Cognitive Systems* 2020, 2: 51-4.
26. Batista GE, Monard MC. An Analysis Of Four Missing Data Treatment Methods for Supervised Learning. *Appl Artif Intell* 2003, 17: 519-33.
27. Ucuzal H. Yapay Zekâya Dayalı Anlamsal Video İşleme Yöntemlerinin Tıpta Kullanılabilirliğinin Araştırılması. Sağlık Bilimleri Enstitüsü, Biyoistatistik ve Tıp Bişimi Anabilim Dalı. Yüksek Lisans tezi, Malatya: İnönü Üniversitesi, 2020.
28. Szepesvári C. Algorithms for Reinforcement Learning. *Synth Lect Artif Intell Mach Learn* 2010, 4: 99-103.
29. Ng MF, Zhao J, Yan Q, Conduit GJ, She ZW. Predicting The State Of Charge And Health Of Batteries Using Data-Driven Machine Learning. *Nat Mach* 2020, 2: 161-170.
30. Fatima M, Pasha M. Survey of Machine Learning Algorithms for Disease Diagnostic. *JILSA* 2017, 9: 1-5.
31. Shorten C, Khoshgoftaar TM, Furht B. Deep Learning applications for COVID-19. *J. Big Data* 2021, 8:1-54.
32. Janiesch C, Zschech P, Heinrich K. Machine learning and deep learning. *Electron. Mark* 2021, 31:1-11.
33. Işın A, Direkoğlu C, Şah M. Review of MRI-based brain tumor image segmentation using deep learning methods. *Procedia Comput. Sci* 2016,102: 317-24.
34. Lauriola I, Lavelli A, Aiolfi F. An Introduction to Deep Learning in Natural Language Processing: Models, Techniques, and Tools. *Neurocomputing* 2022, 470:443-56.

35. Mahmud M, Kaiser MS, McGinnity TM, Hussain A. Deep learning in mining biological data. *Cognit Comput* 2021,13:1-33.
36. Jin S, Zeng X, Xia F, Huang W, Liu X. Application of deep learning methods in biological networks. *Brief. Bioinformatics* 2021,22:1902-17.
37. Ma M, Sun C, Mao Z, Chen, X. Ensemble deep learning with multi-objective optimization for prognosis of rotating machinery. *ISA Trans.* 2021,113:166-74.
38. Dolezal JM, Trzcinska A, Liao C-Y, Kochanny S, Blair E, Agrawal N, Keutgen XM, Angelos P, Cipriani NA. Deep learning prediction of BRAF-RAS gene expression signature identifies noninvasive follicular thyroid neoplasms with papillary-like nuclear features. *Mod. Pathol* 2021, 34:862-74.
39. Yan LC, Yoshua B, Geoffrey H. Deep learning. *Nature* 2015, 521:436-44.
40. Yamashita R, Nishio M, Do RKG, Togashi K. Convolutional neural networks: an overview and application in radiology. *Insights into imaging* 2018,9:611-29.
41. Wang J, Zhang C. Software reliability prediction using a deep learning model based on the RNN encoder–decoder. *Reliab. Eng. Syst* 2018,170: 73-82.
42. Sheikhan M, Jadidi Z, Farrokhi A. Intrusion detection using reduced-size RNN based on feature grouping. *Neural. Comput. Appl.* 2012,21:1185-90.
43. Qing L, Linhong W, Xuehai D. A novel neural network-based method for medical text classification. *Future Internet* 2019, 11:255-59.
44. Sherstinsky A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *Physica D: Nonlinear Phenomena* 2020, 404:132306.
45. Hinton GE. Boltzmann machine. *Scholarpedia* 2007, 2(5):1668.
46. Fiore U, Palmieri F, Castiglione A, De Santis A. Network anomaly detection with the restricted Boltzmann machine. *Neurocomputing.* 2013,122:13-23.
47. Larochelle H, Mandel M, Pascanu R, Bengio Y. Learning algorithms for the classification restricted boltzmann machine. *J Mach Learn Res.* 2012, 13(1): 643-669.
48. Hinton GE. Deep belief networks. *Scholarpedia J* 2009,4(5):5947.

49. Roder M, Passos LA, de Rosa GH, de Albuquerque VHC, Papa JP. (). Reinforcing learning in Deep Belief Networks through nature-inspired optimization. *Appl. Soft Comput.* 2021,108: 107466.
50. Qiao C, Yang L, Shi Y, Fang H, Kang Y. Deep belief networks with self-adaptive sparsity. *Appl. Intell.* 2021, 1-17.
51. Arashpour M, Ngo T, Li H. Scene understanding in construction and buildings using image processing methods: A comprehensive review and a case study. *J. Build. Eng* 2021, 33: 101672.
52. Van der Walt S, Schönberger JL, Nunez-Iglesias J, Boulogne F, Warner JD, Yager N, Gouillart E, Tony Y. scikit-image: image processing in Python. *PeerJ* 2014, 2: 453.
53. Dey N, Borra S, Ashour AS, Shi, F. Machine learning in bio-signal analysis and diagnostic imaging. *Academic Press* 2018
54. Maier A, Syben C, Lasser T, Riess, C. A gentle introduction to deep learning in medical image processing. *Z Med Phys*, 2019, 29(2): 86-101.
55. Jena B., Saxena S, Nayak GK, Saba L, Sharma N, Suri J. S. Artificial intelligence-based hybrid deep learning models for image classification: The first narrative review. *Comput. Biol. Med* 2021, 137: 104803.
56. Xie S, Sun C, Huang J, Tu Z, Murphy K. Rethinking spatiotemporal feature learning: Speed-accuracy trade-offs in video classification. *ECCV* 2018, 305-321.
57. Pandeya YR, Lee, J. Deep learning-based late fusion of multimodal information for emotion classification of music video. *Multimed. Tools Appl* 2021, 80(2): 2887-2905.
58. Stringari CE, Guimarães PV, Filipot JF, Leckler F, Duarte R. Deep neural networks for active wave breaking classification. *Sci Rep* 2021, 11(1): 1-12.
59. Gao M, Cai W, Liu R. AGTH-Net: attention-based graph convolution-guided third-order hourglass network for sports video classification. *J. Healthc. Eng* 2021, 2021: 1-10
60. Nie X, Zhou X, Shi Y, Sun J, Yin Y. Classification-enhancement deep hashing for large-scale video retrieval. *Appl. Soft Comput* 2021, 109: 107467.
61. Born J, Weidemann N, Cossio M, Buhre C, Brändle G, Leidermann K, Aujayeb A. L2 Accelerating COVID-19 differential diagnosis with explainable ultrasound image

- analysis: an AI tool. *BMJ Thorax* 2021, 76: 1-256.
62. Born J, Wiedemann N, Cossio M, Buhre C, Brändle G, Leidermann K, Aujayeb A, Moor M, Rieck B, Borgward. Accelerating detection of lung pathologies with explainable ultrasound image analysis. *Appl Sci* 2021,11:672.
 63. Ashok M, Madan R, Joha A, Sivarajah U. Ethical framework for Artificial Intelligence and Digital technologies. *Int J Inf Manage* 2022,62:102433.
 64. Yağın FH, Gündoğan E, Ucuzal H, Çolak C. A Computer-Assisted Diagnosis Tool for Classifying COVID-19 based on Chest X-Ray Images. *Konuralp Medical Journal* 2021, 13:438-45.
 65. Kang Z, Li X, Zhou S. Recommendation of low-dose CT in the detection and management of COVID-2019. *Eur Radiol* 2020, 30:4356-57.
 66. Ahmad F, Farooq A, Ghani MU. Deep ensemble model for classification of novel coronavirus in chest X-ray images. *Comput Intell Neurosci* 2021, 2021: 270-9.
 67. Ismael AM, Şengür A. Deep learning approaches for COVID-19 detection based on chest X-ray images. *Expert Syst Appl* 2021, 164: 150-11.
 68. Abbas A, Abdelsamea MM, Gaber MM. Classification of COVID-19 in chest X-ray images using DeTraC deep convolutional neural network. *Appl Intell (Dordr)* 2021, 51 : 854-64.
 69. Hu Z, Liu Z, Dong Y, Liu J, Huang B, Liu A, Huang J, Pu X, Shi X, Yu J, Xiao Y, Zhang H, Zhou J. Evaluation of lung involvement in COVID-19 pneumonia based on ultrasound images. *Biomed Eng Online* 2021, 20:1-15.
 70. Born J, Brändle G, Cossio M, Disdier M, Goulet J, Roulin J, Wiedemann N. POCOVID-Net: automatic detection of COVID-19 from a new lung ultrasound imaging dataset (POCUS). *arXiv* 2020, 11: 670-13.

EKLER

EK-1. Özgeçmiş



EK-2. Etik Kurul



SAGLIK BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜNE

13 Nisan 2013 tarih ve 28617 sayı ile T.C. Resmi Gazetede yayınlanan " Klinik Araştırmalar Hakkında Yönetmelik'in 1. bölümünün 2. maddesinin 1. fıkrası (Bu yönetmelik biyoyararlanım ve biyoeşdeğerlilik çalışmaları dâhil, ruhsat veya izin alınmış olsa dahi insanlar üzerinde yapılacak olan ilaç, tıbbi ve biyolojik ürünler ile bitkisel ürünlerin klinik araştırmaları, klinik araştırma yerlerini ve bu araştırmaları gerçekleştirecek gerçek veya tüzel kişileri kapsar.) gereğince yüksek lisans öğrencisi Burak YAĞIN'ın tezinin klinik bir çalışma olmaması kullanılacak olan verinin web sitesinde yayınlanmış veri tabanından elde edilecek olması sebebiyle etik kurul kararı alınmamıştır.

