



Diagnosing COVID-19 from X-Ray images with using multi-channel CNN architecture

Atınç Yılmaz*^{ID}

Beykent University, Faculty of Engineering and Architecture, Department of Computer Engineering, 34398, Istanbul, Turkey

Highlights:

- Proposed multi-channel CNN deep learning architecture with channel selection formula
- A new method for diagnosing Covid-19
- High performance values

Keywords:

- Covid-19
- Proposed multi-channel CNN method
- Channel selection
- Diagnosis
- Convolutional neural networks
- Deep learning

Article Info:

Research Article
Received: 02.06.2020
Accepted: 10.03.2021

DOI:

10.17341/gazimmfd.746883

Acknowledgement:

The author would like to thank the reviewers and the editors for their valuable comments and contributions that helped to significantly increase the readability and organization of the study.

Correspondence:

Author: Atınç Yılmaz
e-mail: atincyilmaz@beykent.edu.tr
phone: +90 212 444 1997

Graphical/Tabular Abstract

Deep learning has been widely used in a variety of applications to solve a scope of complex problems that require extremely high accuracy and precision, especially in the medical field. In this study, the Covid-19 is diagnosed automatically using a proposed multichannel CNN method. Patients and healthy individuals' Lung X-Ray images data sets were obtained from three separate online databases. Simple recurrent networks (SRN) architecture was also applied for the same problem to compare the results and demonstrate the efficiency of the proposed method. The study proposes a new CNN-based method for early detection of Covid-19, which is a major risk to human life worldwide. Differently from the studies in the literature, the multi-channel CNN architecture with five convolution channels is proposed and the channel selection formulas are presented. It is used for selecting the most distinctive feature filters among the results produced by these channels. The architecture consists of the following components (Figure A).

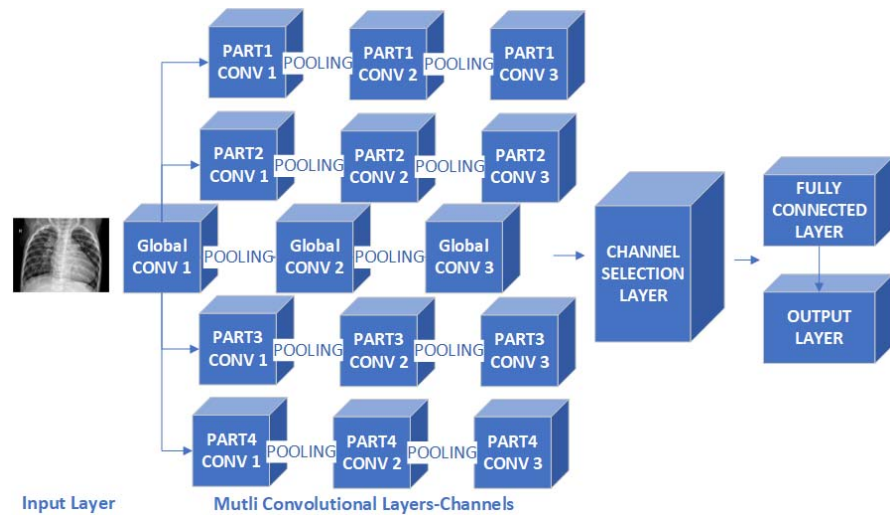


Figure A. Proposed model architecture

Purpose: This study aims to diagnose the Covid-19 with deep learning methods to design an assistive technology system that can be used by doctors and health employee

Theory and Methods:

The proposed multi-channel CNN, and simple recurrent networks (SRN) models were trained on the three different dataset, which was obtained from the Kaggle data repository. The first dataset has 50 images, the second dataset has 1125 images and the third dataset has 5856 images. Their performances were compared with each other.

Results:

It was observed that the proposed multi-channel CNN model is better than other models in diagnosing Covid-19 with %99,41-%97,75-%96,74 accuracy, %99,554-%98,221-%96,923 F₁-score and 0,89-1,13-1,92 RMSE values. The training process took 981546 seconds and the proposed model can also be used in real-time systems.

Conclusion:

In this study; A new method based on CNN is proposed for the early detection of Covid-19 from lung X-Ray images, which is a major risk to human life worldwide. Differently the studies in the literature, the multi-channel CNN architecture with five convolution channels is proposed and the channel selection formulas is presented which are used for selecting the most distinctive feature filters among the results produced by these channels.



Çok kanallı CNN mimarisi ile X-Ray görüntülerinden COVID-19 tanısı

Atınç Yılmaz*^{ID}

Beykent Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, 34398, İstanbul, Türkiye

Ö N E Ç İ K A N L A R

- Kanal seçim formülü ile önerilen çok kanallı CNN derin öğrenme mimarisi
- Covid-19 tanısı için yeni bir yöntem
- Derin öğrenme tabanlı X-Ray görüntüleri üzerinden tanı modeli

Makale Bilgileri

Araştırma Makalesi
Geliş: 02.06.2020
Kabul: 10.03.2021

DOI:

10.17341/gazimmfd.746883

Anahtar Kelimeler:

Covid-19,
Önerilen çok kanallı CNN
mimarisi,
kanal seçimi,
akciğer X-Ray,
tanı,
derin öğrenme

ÖZ

Covid-19, dünyada salgınlaşarak Dünya Sağlık Örgütü tarafından pandemi olarak tanımlanmıştır; insanlar için sonucu ölüme kadar gidebilecek riske sahip virüstür. RT-PCR testi ile Covid-19 tanısının doğrulanması gerekmektedir. Testin sonuçlanması hem uzun zaman almakta hem de yanlış negatif sonuçlar elde edilebilmektedir. Covid-19 tanısı erken ve doğru olursa, hayati risk oranı azalmaktadır. Derin öğrenme, özellikle tıp alanında son derece yüksek doğruluk ve hassasiyet gerektiren çeşitli karmaşık problemleri çözmek için çeşitli uygulamalarda yaygın olarak kullanılmaktadır. Bu çalışmada, akciğer X-Ray görüntülerinden otomatik Covid-19 tanısı, önerilen çok kanallı CNN yöntemi kullanılarak yapılmaktadır. Hasta ve sağlıklı bireylerden elde edilen X-Ray görüntüleri çevrimiçi olarak üç ayrı veri tabanından elde edilmiştir. Sonuçları karşılaştırmak ve önerilen yöntemin verimliliğini ortaya koymak için tekrarlayan derin sinir ağları (SRN) mimarisi de aynı problem için uygulanmıştır. Ayrıca, çalışmanın performansını, doğruluğunu ve verimliliğini ortaya koymak için uygulanan yöntemler için doğruluk, hassasiyet analizi ve işlem sürelerinin ölçümleri yapılmıştır. Önerilen sistem ile PCR testi sonucu beklenmeden kısa sürede Covid-19 tanısı konarak, virüs vücutta etkisini ve hayati riski arttırmadan önlem alınması sağlanmaktadır. Literatürdeki çalışmalardan farklı olarak, beş evrişim kanalına sahip olan çok kanallı CNN mimarisi sunumu ve bu kanalların ürettiği sonuçlar arasında en belirgin özellik filtrelerini seçmek için önerilen çok kanallı CNN mimarisinde kanal seçim formülü ortaya konmaktadır.

Diagnosing COVID -19 from X-Ray images with using multi-channel CNN architecture

H I G H L I G H T S

- Proposed multi-channel CNN deep learning architecture with channel selection formula
- A new method for diagnosing Covid-19
- Deep learning based diagnostic model with using X-Ray images

Article Info

Research Article
Received: 02.06.2020
Accepted: 10.03.2021

DOI:

10.17341/gazimmfd.746883

Keywords:

Covid-19,
Proposed multi-channel CNN
architecture,
channel selection,
lung X-Ray,
diagnosis,
deep learning.

ABSTRACT

Covid-19 has been described as a pandemic by the World Health Organization. It has become an epidemic all over the world and has created a risk for people that may lead to death. To diagnose Covid-19, the diagnosis must be confirmed by RT-PCR test. The test takes a long time and false-negative results can be obtained. If the diagnosis of Covid-19 is made early and correct, the ratio of threats to life is reduced. Deep learning has been widely used in a variety of applications to solve a variety of complex problems that require extremely high accuracy and precision, especially in the medical field. In this study, the Covid-19 is diagnosed automatically using a proposed multi-channel CNN method. Patients and healthy individuals' Lung X-ray images datasets were obtained from three separate online databases. Simple recurrent networks (SRN) architecture was also applied for the same problem to compare the results and demonstrate the efficiency of the proposed method. It is to be noted that to reveal the performance, accuracy and efficiency of the study, accuracy and precision analysis and measurements of processing times for the applied methods were performed. With the proposed system Covid-19 is diagnosed in a short time without waiting for the PCR test and precautions are taken before the virus increases its effect on the body and the risk of individuals' life. Differently from the studies in the literature, the multi-channel CNN architecture with five convolution channels is proposed and the channel selection formulas are presented which are used for selecting the most distinctive feature filters among the results produced by these channels.

1. GİRİŞ (INTRODUCTION)

Aralık 2019'da Çin'in Vuhan şehrinde insanlarda ateş, nefes darlığı ve öksürük belirtileri ile gelişip sonrasında da tanımı yapılan virüs, yeni tip koronavirüs olarak (Covid-19) isimlendirilmiştir. Salgın şeklinde insandan insana bulaşan Covid-19, önce ülke içinde diğer şehirlere sonrasında da dünyadaki diğer ülkelere yayılmıştır. Covid-19'u anlayabilmek için öncelikle mensup olduğu koronavirüsü iyi bilmek gerekmektedir. Koronavirüs, hem insanlarda hem de diğer hayvanlarda hastalığa sebep olabilecek virüs ailesidir. Tarih boyunca çeşitli şekillerde insanlar için tehlike boyutunda hastalıklara neden olan koronavirüse, orta doğu solunum sendromu (MERS) ve şiddetli akut solunum sendromu (SARS) hastalıkları örnek olarak verilebilir. Yeni koronavirüs hastalığına ise SARS-COV2 virüsünün neden olduğu söylenmektedir [1]. Covid-19 virüsünün insanlara bulaşmasından sonra tam olarak herkes için ortak belirtiler gösterdiği söylenemez. Belirti göstermeden de hastalığın gelişmesinin mümkün olabilmesinin yanında en sık karşılaşılan belirtiler yüksek ateş, nefes darlığı ve kuru öksürüktür. Hastalığın daha şiddetli geliştiği durumlarda ise zatürre, ağır solunum yetmezliği, böbrek yetmezliği ve hatta ölüm vakaları ile sonuçlandığı gözlemlenmiştir. Covid-19 un bulaşma durumu ise hastalık taşıyan bireyin damlacık yolu ile dışarıya aksettirdiği virüs ile olmaktadır. Kişiler, bu parçacıkları soluduğunda veya parçacıklar vasıtası ile kirlenen cisimlere dokunduktan sonra ellerini belirli şekilde yıkamadan yüz, göz, burun veya ağza götürmeleri ile virüsü kapabilmektedir. Yapılan araştırmalarda Covid-19 virüsü bazı durumları taşıyan bireylerde daha fazla risk taşıdığı ortaya konmuştur. Bu durumlar, 60 yaş veya daha ileri bir yaşta olmanın dışında kalp hastalığı, kanser, diyabet, kronik solunum hastalıkları, hipertansiyon gibi hastalık geçmişinin olması şeklinde belirtilebilir.

Bireye tanı konabilmesi için şüpheli vakanın mukozasından gerçek zamanlı polimeraz zincir reaksiyonu (RT-PCR) testi ile tanının doğrulanması gerekmektedir. İlgili test standart olmasına rağmen, Covid-19 tanısı için RT-PCR testinin sonuçlanması zaman alıcıdır ve yüksek yanlış negatif oranları ile sık karşılaşıldığı bildirilmiştir. Öte yandan, Covid-19 tanısı konan hastalara yapılan bilgisayarlı tomografi (BT) taramalarında akciğerin gösterdiği yüksek duyarlılık nedeniyle sıklıkla akciğerde bilateral düzensiz gölgeler veya zemin cam opaklığı (GGO) gözlemlendiğinden dolayı Covid-19 taramasında önemli bir tamamlayıcı gösterge olarak kullanılmıştır.

Teknolojinin gelişmesi ve bilginin getirdiklerinin ortaya çıkması ile işlenmemiş verilerin önemi oldukça artmıştır. Verinin işlenerek analiz edilmesi birçok problemin öngörülmesini sağlamaktadır. Bu durum yapay zeka gibi veriler üzerinden çalışarak yüksek doğruluk ile performans gösteren yöntemlerin de popüleritesini arttırmıştır. Bunun yanında ilgili yöntemlerin sadece doğruluk performansı değil zamansal verimliliği de önem arz etmektedir. İhtiyaç sonucunda geliştirilen işlem gücü yüksek olan ekran kartları

ve bu ekran kartlarını kullanarak daha performanslı çalışmayı mümkün hale getiren kütüphaneler, yöntemlerin verimliliğini artırarak daha kısa sürede doğruluğu yüksek sonuçların alınmasını sağlamıştır. Derin Öğrenme, her katmanında çok katmanlı yapay sinir ağlarının bulunduğu bir mimari olarak tanımlanabilir. Son yıllarda yapay zeka yöntemleri arasında en yaygın olarak kullanılan derin öğrenme yöntemi, tıbbi görüntüler ile akciğer hastalıklarının tespitinde önemli tanısal doğruluklar elde etmiştir [2-4]. Yöntem, 2017'de cilt lezyonlarını sınıflandırma problemi için dermatolog düzeyinde performans göstermiş [5], 2019'da ise akciğer kanseri taraması için çok etkileyici sonuçlar elde etmiştir [2]. Bununla birlikte, hastalık teşhisi için derin öğrenme tabanlı yöntemlerin çoğu, özellikle BT hacimlerinde hastalık tespiti için lezyonlara açıklama eklemeyi gerektirmektedir. Yaşanılan süreçte, Covid-19 tanısı için lezyonlar üzerinde çalışmak radyologlar için çok zaman ayırıp çaba sarf etmesini gerektirmektedir. Tüm dünyada salgının yayılımı hızla sürerken, zamanı verimli kullanabilmek sağlık çalışanları için çok önemlidir. Bu nedenle Covid-19 tespitinin minimum zaman harcanarak ve en az hata ile tespit edilebilmesi oldukça önemlidir. Bu çalışmanın amacı, oldukça kritik bir problem olan Covid-19'un hızlı tanısı için bilgisayarlı tomografi görüntüleri üzerinden otomatik Covid-19 saptaması yapabilecek derin öğrenme tabanlı bir modelin ortaya konmasıdır.

Bu çalışmanın katkısı, önerilen CNN tabanlı çok kanallı derin öğrenme mimarisinin tüm dünyada insan sağlığı için ölümcül sonuçlara kadar büyük risk taşıyan ve pandemi ilan edilen Covid-19 hastalığı için otomatik tanı sisteminin yüksek doğruluk ve etkinlikle ortaya konmasıdır. Çalışmada derin öğrenme yönteminin seçilmesinin nedeni görüntü işleme alanındaki uygulanabilirliğidir. Çalışmada önerilen yöntemin uygulanabilirliğinin gösterilmesi için üç ayrı veri seti kullanılarak modelleme yapılmıştır. Kaggle veritabanı üzerinden erişilebilen ve Github üzerinde de paylaşılan üç farklı akciğer X-Ray görüntü veri setleri sistemin eğitimi ve testi için kullanılmıştır. Bu çalışmada önerilen X-Ray görüntülerinden Covid-19 hastalığı tanı sistemi, risk taşıyan potansiyel hastalara doktorlar tarafından RT-PCR testi gibi zaman kaybetmeden ve daha fazla efor sarf etmeden tanı konulabilmesine yardımcı olmaktadır. Önerilen CNN yönteminde ise, en belirgin özellik filtrelerini seçmek için yeni bir katmanda kanal seçim formülü sunulmaktadır. Önerilen yöntem Evrişimli Sinir Ağı (CNN) mimarisine dayanmakta; yöntemin ve teşhis testinin fizibilitesi sunulmaktadır. Çalışmanın katkıları:

- Dünya için büyük bir problem olan Covid-19 için hızlı tanıya olanak veren derin öğrenme tabanlı bir sistem geliştirilmiştir.
- Gerçekleştirilen çalışmada; CNN mimarisinde yeni bir yöntem önerilmiştir. Önerilen yöntemde, çok kanallı CNN mimarisi üzerinden kanal seçim filtreleri kullanılmıştır.
- Yüksek performans değerlerine sahip yeni bir model geliştirilmiş; modelin uygulanabilirliği ortaya konmuştur.

Çalışma dört bölümden oluşmaktadır. İlk bölümde Covid-19 ile ilgili literatürdeki çalışmalar sunulmuştur. İkinci bölümde veri seti ve önerilen CNN mimarisi ve uygulanan yöntem hakkında bilgi sunulmaktadır. Üçüncü bölümde önerilen CNN yöntemi ile akciğer X-Ray görüntülerinden Covid-19 tespitinin süreçleri sunulmuştur. Dördüncü ve son bölümde ise deneysel çalışmalardan elde edilen sonuçlardan ve katkıdan bahsedilmiştir.

1.1. İlgili Çalışmalar (Related Works)

Ophir vd. [6] BT görüntülerinde Covid-19'u saptamak için derin öğrenme teknolojisini kullanmışlardır. Şüpheli Covid-19 BT özelliklerinin saptanmasında sistemin performansını analiz etmek ve "Corona skoru" oluşturarak her bir hastada zaman içinde hastalığın evrimini değerlendirmek için çoklu retrospektif deneyler yapılmıştır. Çalışmada 157 uluslararası hastadan (Çin ve ABD) oluşan bir test seti kullanılmıştır. Shi vd. [7] büyük ölçekli bir Covid-19 BT veri seti elde ederek bu veri seti kullanımı ile Covid-19 taraması için makine öğrenimi tabanlı bir yöntem önermişlerdir. Çalışmanın dezavantajı, standart X-ışını görüntülemesinden çok daha uzun sürmesidir. Ayrıca, yeterince gelişmiş olmayan yerler için iyi sonuç alınmasını sağlayacak yüksek kaliteli BT tarayıcıları bulunmayabilir. Böyle bir durumda Covid-19 tarama durumu oldukça güç hale gelmektedir. X-ışınları, klinik bakım ve epidemiyolojik çalışmalarda önemli rol oynayan en yaygın ve en yaygın tanısal görüntüleme tekniğidir [8, 9]. Kırsal bölgelerde bile, X-ray üniteleri temel bir tanı görüntüleme olarak kullanılmıştır. Ayrıca, X-ışınlarının gerçek zamanlı görüntülenmesi hastalığın görüntülenmesini önemli ölçüde hızlandıracaktır. Zhang vd. [10], çalışmalarında Covid-19 hastalığında güvenilir tarama için yeni bir derin anomali tespit modeli geliştirmeyi hedeflemişlerdir. Model performansının değerlendirilmesi için Github deposundan Covid-19 tanısı konulan 70 hastanın 100 göğüs röntgeni toplanmıştır. Deneysel sonuçlar, geliştirilen modelin %96 doğrulukla Covid-19 vakalarını güvenilir bir şekilde tespit edebildiğini göstermektedir. Shan vd [11], göğüs BT'si kullanarak akciğerde bulunan enfeksiyon bölgelerinin otomatik segmentasyonu için derin öğrenme tabanlı bir sistem geliştirmişlerdir. Xu vd. [12] akciğer pulmoner BT görüntüleri üzerinde derin öğrenme tekniklerini kullanarak Covid-19 zatürre ve Influenza-A viral zatürre hastalıkları için erken bir tarama modeli oluşturmayı amaçlayarak bir çalışma gerçekleştirmişlerdir. Wang vd. [13], BT görüntülerindeki Covid-19 radyografik değişikliklerine dayanarak, patojenik testten önce klinik tanı sağlamak ve böylece hastalık tanısı için kritik zamandan tasarruf etmek için Covid-19'un grafik özelliklerini çıkarabilen derin öğrenme yöntemi geliştirmişlerdir. Narin vd. [14] çalışmalarında, göğüs röntgeni radyografileri kullanarak koronavirüs zatürresi ile enfekte olmuş hastanın saptanması için üç farklı evrişimli sinir ağı tabanlı model (ResNet50, InceptionV3 ve InceptionResNetV2) önermişlerdir. Bu üç modelin istatistiksel analizleri çalışmada yapılarak kıyaslanmıştır. Elde edilen performans sonuçları göz önüne alındığında, önceden eğitilmiş ResNet50 modelinin önerilen diğer iki model arasında %98

doğrulukla en yüksek sınıflandırma performansı sağladığı görülmektedir. Xie vd. [15], çalışmasında X-ışını görüntülerine dayalı olarak SARS ve tipik zatürre hastalıklarını ayırt etmek için veri madenciliği tekniklerini kullanmışlardır. X-ışını makineleri, kırıklar, kemik çıkıkları, akciğer enfeksiyonları, zatürre ve tümörler gibi etkilenen vücudu taramak için kullanılır. BT taraması, aktif vücut kısmının çok yumuşak yapısını ve iç yumuşak doku ve organların daha net görüntülerini inceleyen bir tür gelişmiş röntgen makinesidir [16]. X-ışını kullanmak BT'den daha hızlı, daha kolay, daha ucuz ve daha az zararlı bir yöntemdir.

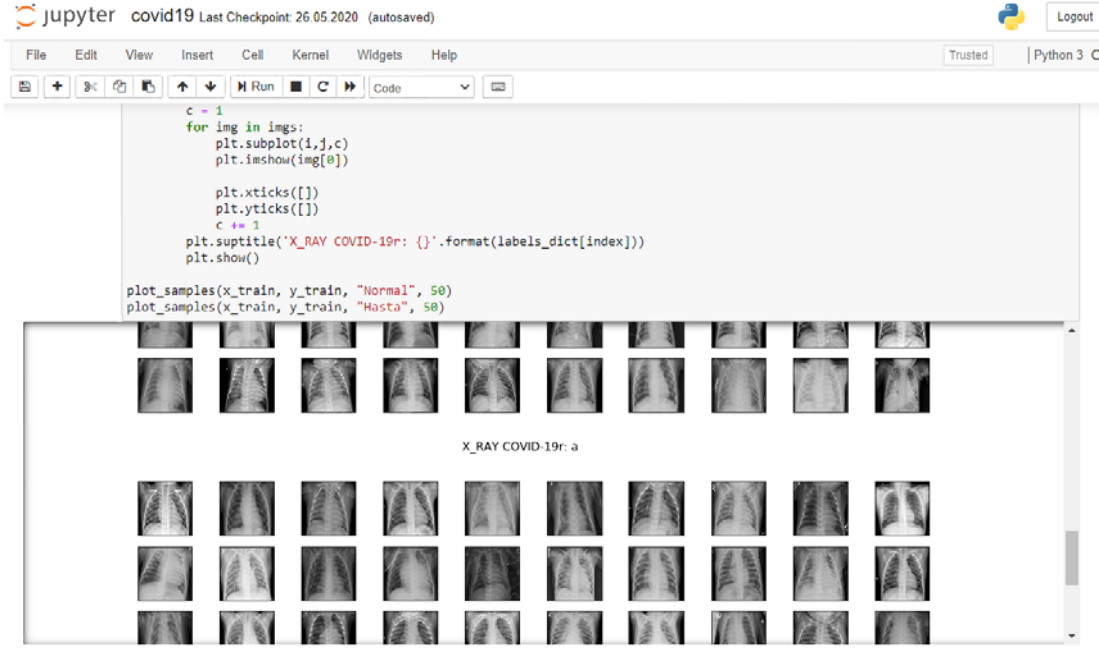
Fang vd. [17], endemik bölgelerde seyahat veya yerleşim öyküsü olan, ateşi veya nedeni bilinmeyen akut solunum semptomları olan 51 hastanın incelendiği bir çalışma gerçekleştirmişlerdir. Çalışmada, ilgili veri setini kullanarak göğüs BT'nin duyarlılığı RT-PCR ile karşılaştırılmıştır. Uygulama sonucunda %71'lik RT-PCR duyarlılığına karşın %98'lik göğüs BT duyarlılığı elde edilmiştir. Hamimi'nin [18] MERS CoV ile ilgili yaptığı çalışmada göğüs röntgeni ve BT'de zatürre belirtileri gibi özellikler olduğunu göstermiştir. Xie vd. [19], RT-PCR testinde duyarlılık eksikliği üzerine bir çalışma gerçekleştirmişlerdir. 167 hastanın %3'ünde göğüs BT bulgularına rağmen RT-PCR test sonucu negatif sonucu çıkmıştır. Bernheim vd. [20], Çin'deki dört merkezden alınan 121 göğüs BT si ile Covid-19 enfeksiyonunun erken, orta ve geç evrelerindeki durumu incelemişlerdir. Çalışmada erken evrenin %28'inde, orta evrenin % 76'sında ve hastalığın geç evrelerin (6-12 gün) %88'inde bilateral akciğer tutulumu olduğu ortaya konmuştur. Bu çalışmada, akciğer X-Ray görüntülerinden Covid-19 tanısının konabilmesi ve tanısal doğruluğu artırmak için CNN tabanlı derin sinir ağı mimarisi önerilmiş ve uygulanmıştır. Önerilen sistem ile PCR testinin sonuçlanması beklenmeden uzmanların ön tanı yapabilmelerini ve bu sayede hastanın sağlık durumunun riskini azaltma imkanı sağlanmaktadır. Çalışmada literatürdeki diğer çalışmalardan farklı olarak çok kanallı yeni bir CNN mimarisi önerilmiştir. Önerilen yöntemde, çok kanallı evrişim kanallarının tam bağlantılı katmanlarından gelen sonuçların en belirgin özellik filtrelerini seçmek için yeni bir katmanda kanal seçim formülü sunulmaktadır. Önerilen sistemin fizibilitesi ve teşhis testi çalışmada sunulmaktadır.

2. MATERYAL VE METOT (MATERIAL AND METHOD)

2.1. Veri Hazırlama ve Önleme

(Data preparation and preprocessing)

Çalışmada X-Ray görüntülerinden Covid-19 tanısının uygulanabilirliğinin gösterilebilmesi için üç farklı veri seti kullanılmıştır. Üç veri seti de Kaggle veri deposundan elde edilmiştir [21-23]. Birinci veri setinde 25 Covid-19 tanısı konulmuş, 25 sağlıklı toplam 50 akciğer X-Ray görüntüsü bulunmaktadır. Modelleme için kullanılan ikinci veri setinde ise üç etikete sahip X-Ray görüntüleri mevcuttur. Veri setinde toplam 1125 akciğer X-Ray görüntüsü varken bunların 125'i Covid-19 tanı etiketli, 500'ü zatürre tanı



Şekil 1. Veri seti örnek X-Ray görüntüleri (Sample X-Ray images)

etiketli, 500'ü ise sağlıklı etiketine sahiptir. Çalışmada kullanılan son veri seti ise Covid-19 virüsünün neden olduğu zatürre ile ilgili hazırlanmıştır. Bu veri setinde 4273 zatürre tanı etiketli, 1583 sağlıklı etiketli toplam 5856 akciğer X-Ray görüntüsü bulunmaktadır. Veri setlerine ait örnek görüntüler Şekil 1'de gösterilmektedir.

Veri hazırlama ve ön işleme evresinde, veri setlerinde bulunan görüntüler belirli işlemlerden geçirilerek etiketli bir veri seti haline getirilmiştir. Görüntülerin sistemde daha adaptasyonlu ve daha hızlı bir şekilde işlemek için görüntüler yeniden boyutlandırılma işlemi yapılarak eş boyuta getirilmiştir. Ön işlemler tamamlandıktan sonra her üç veri setinde bulunan görüntülerin %80'i eğitim seti %20'si ise test seti olarak gelişigüzel şekilde ayrılmıştır.

Veri setleri, çalışmada önerilen çok kanallı CNN mimarisi dışında tekrarlayan derin sinir ağları (SRN) yöntemleri olmak üzere iki farklı modele uygulanmıştır. Modellerin konfigürasyonu, kullanılan mimariler, önerilen CNN mimarisi ve algoritması alt başlıklarda anlatılmıştır.

2.2. Derin Öğrenme (Deep Learning)

Yapay sinir ağları, insan beyni gibi öğrenme ve uyum sağlama yeteneğini kazanmayı amaçlayan yapay bir istihbarat yöntemidir [24]. Derin Öğrenme, her katmanında çok katmanlı yapay sinir ağlarının bulunduğu bir mimari olarak tanımlanabilir [25]. Derin Öğrenme yönteminin literatürdeki diğer yapay zeka ve makine öğrenme yöntemlerinden farkı, kendi içinde çok fazla işlem birimi olması nedeniyle verilere ve karmaşık problemlere cevap verebilmesidir. Diğer makine öğrenmesi yöntemlerinde öznitelik bilgisi sisteme önceden verilmesi gerekirken; derin öğrenme öznitelikleri kendisi çıkartmaktadır. Mimari olarak

karmaşık yapısı ve çok sayıda hesaplama yeteneği nedeniyle, yapay sinir ağları çok yüksek hesaplama gücüne sahip donanım gerektirmektedir. Bu ihtiyaç, bilgisayarların GPU'ları (Grafik İşlem Birimi) kullanılarak karşılanmaktadır. Günümüzde, en son teknolojik gelişmeler göz önüne alındığında, sağlık alanındaki veri miktarı Büyük Veri kavramı ile tanımlanabilir. Yapay zeka ve makine öğrenimi yöntemleri uzun bir süredir kullanılmasına rağmen, yapay sinir ağının büyük verileri işleme yeteneği ile birlikte GPU işlemeyle elde edilen performansı artıran güçlü eşzamanlı hesaplama diğer yöntemlerden oldukça farklı kılacaktır. GPU'lar ile, modelin öğrenimi daha fazla eğitim veri seti ile daha kısa sürede tamamlanabilmektedir. Derin öğrenme kullanılarak literatürde birçok çalışma yapılmıştır. Derin öğrenme uygulamaları, sağlık teşhis destek sistemleri ile birlikte doğal dil işleme, görüntü işleme, sinyal işleme, örüntü tanıma, robotik, finans, biyomedikal, reklam, SEO arama motoru optimizasyonları, otonom araç sistemleri gibi çok çeşitli konularda geliştirilmiştir. Derin öğrenme, verinin temsilinden öğrenmeye dayanmaktadır.

2.2.1. Evrişimli sinir ağları (Convolutional neural networks)

Evrişimli Sinir Ağları (CNN), yapay sinir ağlarının aksine, özniteliklerin çıkarılmasına izin veren katmanlara sahip derin öğrenme yaklaşımıdır [26-28]. Görüntü işlemede performans sonuçları için iyi değerler üreten CNN'ler, çok katmanlı yapay sinir ağı tabanlıdır ve özelleştirilmiş derin öğrenme mimarisi yapısına sahiptir [29,30]. CNN'lerin ilk katmanlarında, yerel özellikler görüntüden çıkarılır. Ancak, diğer katmanlarda, geometrik şekilleri veya özellik sembollerini algılamak için özellikler birleştirilir. İşlem adımları, tamamen giriş görüntüsü oluşturulana kadar tekrarlanır. CNN mimarisi aşağıdaki katmanlardan oluşur [25].

Konvolüsyon Katmanı: Bu katman, filtreler kullanarak görüntülerden özelliklerin çıkarılmasını sağlamaktadır. Giriş görüntüsünün ve görüntü filtresinin (başlangıçta rastgele değerleri olan) evrişiminin gerçekleştirildiği katmandır. Bu CNN tabakası yapay sinir ağlarından farklıdır. Katmanlardaki nöronların birbirine bağlı olması yerine, konveksiyon küçük boyutlarda gerçekleştirilir. Çıktı özellik haritası şu şekilde tanımlanır (Eş. 1).

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

Eş. 1'de (F_x, F_y), son katmanın çıktı özellik haritasının genişliği ve yüksekliğidir; (L_x, L_y), çekirdek boyutudur; (S_x, S_y), çekirdeğin yatay ve dikey yönlerde atladığı piksel sayısını tanımlar ve r katmanı göstermektedir. x 'in evrişim sonucu, her bir görüntü için l-1 katmanındaki y piksel değerinin sonuçları Eş. 2'de gösterilmektedir. Evrişim için, n * n boyutundaki filtre olan w rastgele seçilmektedir. Bu filtre eğitim sırasında giriş-çıkış ilişkisine göre ayarlanmaktadır. Eğitimin sonunda, problemi modelleyen katsayılar elde edilir.

$$\sum_a^n \sum_b^n w_{ab} y_{(i+a)(j+b)}^{(l-1)} \quad (2)$$

Önerilen modelde, giriş çerçevelerinden maksimum özellik haritalarını çıkararak veri kümesini maksimum doğrulukla eğitmek için normalizasyon katmanı ve doğrusal birim katmanı (ReLU katmanı) ile beş konvülyasyon katmanı kullanılmıştır.

Aktivasyon Fonksiyonu: Aktivasyon fonksiyonları, derin öğrenme ağının içerisindeki belirlenen katsayıların ve ağırlıkların değişimi için erişimi sağladığından dolayı ağırlık doğruluk oranına direkt olarak etki etmektedir. Ek olarak aktivasyon fonksiyonu, aşırı veri değerleri olmaksızın sonraki katmanda bulunan nöronların bağımsızlığını artıran, böylece tüm ağırlık stabilitesini arttıran bir özellik haritası üretir. Aktivasyon fonksiyonu olarak kullanılan sigmoid fonksiyonu aktivasyon işlemi esnasında piksel değerlerini 0 ile 1 arasında bir değere baskılar. Baskılama evresinde büyük negatif değerler 0, büyük pozitif değerler ise 1 olma eğilimindedir. Benzer olarak hiperbolik teğet fonksiyonu ise piksel değerlerini [-1, 1] aralığında gerçek bir değere baskılar. Doğrusal Birim (ReLU) aktivasyonu, CNN mimarisinde en yaygın kullanılan aktivasyon fonksiyonudur.

Doğrusal Birim Katmanı (ReLU): ReLU aktivasyon fonksiyonu ağırlık güçlendirmek için konvülyasyonel katmanlardan üretilen özellik haritasına uygulanmaktadır. Eş. 3'te tan ve ReLU aktivasyon fonksiyonları gösterilmiştir.

$$\tan(x_1(m, n)) = \frac{\sin(x_1(m, n))}{\cos(x_1(m, n))} = 1 + \frac{1 - e^{-2x_1(m, n)}}{1 + e^{-2x_1(m, n)}} \quad (3)$$

ReLU fonksiyonunu uyguladıktan sonra, son özellik haritasındaki değerler elde edilir (Eş. 4):

$$x(m, n) = \begin{cases} 0 & \text{eğer } x_2(m, n) < 0 \\ \tan(x_1(m, n)) & \text{eğer } x_2(m, n) \geq 0 \end{cases} \quad (4)$$

Havuzlama Katmanı: Bu katman art arda gelen konvülyasyon katmanları arasında kullanılır. Bu katman ağırlık ve işlem sayısını azaltarak hesaplama karmaşıklığı da azaltır. Bu katmanda kullanılan filtreler ortalama veya maksimum değeri işler. Ortalama değer, filtre boyutundaki piksel değerlerinin toplamının filtre penceresi boyutuna bölünmesiyle bulunur. Öte yandan, maksimum değer, filtrenin piksel boyutunun maksimum değeri belirlenerek bulunur. $X * Y * Z$ boyutlu giriş verileri, filtre boyutu F ve adım S için, aktivasyon haritası çıkışı Eş. 5'te gösterilmektedir.

$$X \sim = \frac{X - F + S}{S}, Y \sim = \frac{Y - F + S}{S}, Z \sim = Z \quad (5)$$

Tam Bağlantılı Katman: Bu katman, sınıflandırma işlemini gerçekleştirir ve çıktıyı üretir.

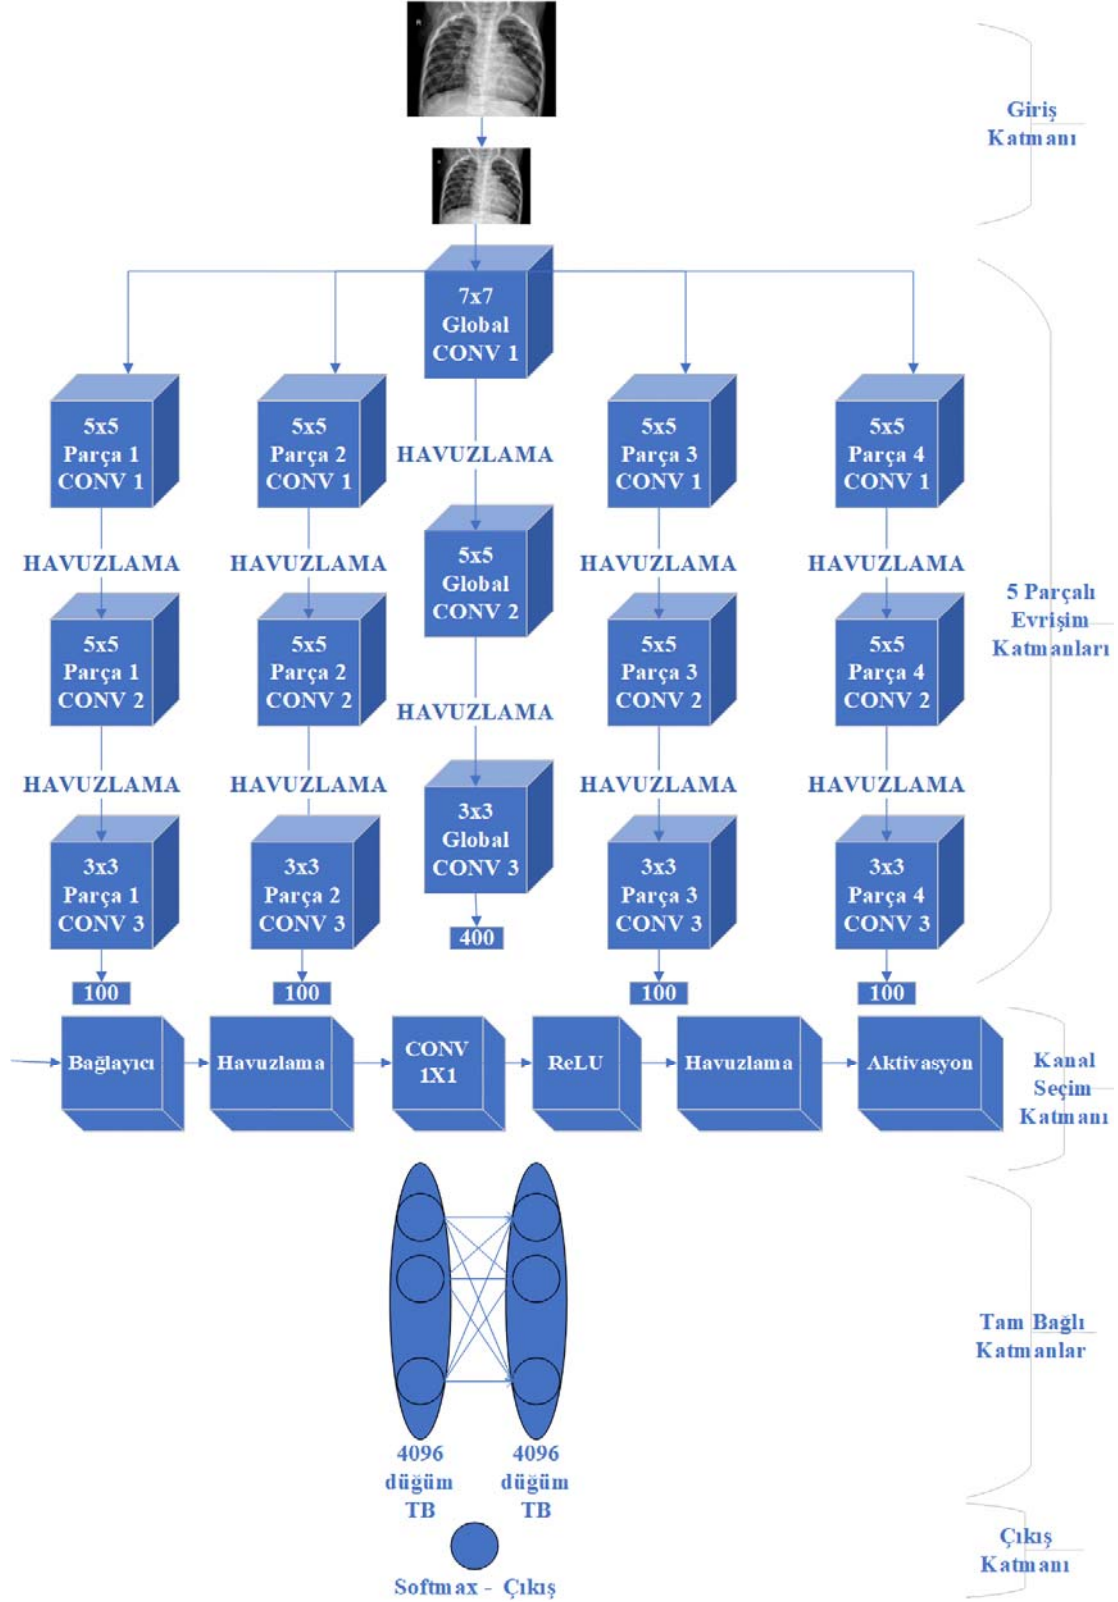
Evrişimli sinir ağları modelleri: AlexNet, LeNet, ZFNet, VGG-16, GoogLeNet, Microsoft ResNet gibi mimariler literatürde en yaygın kullanılan CNN modelleridir. Bu modeller derin öğrenmenin geliştirilmesinde önemli bir rol oynadığından ötürü çok önemlidirler [31].

2.2.2. Önerilen CNN yöntemi (Proposed CNN method)

Bu bölümde, akciğer X-Ray görüntülerinden Covid-19 tanısı için uygulanacak önerilen çok kanallı CNN yöntemi anlatılmaktadır. Yılmaz çalışmasında [32], Üç kanallı özellik seçim katmanı ile derin öğrenme mimarisi kullanarak omuz implantı marka ve modelinin tespitini sağlamıştır. Bu çalışmada ise, önerilen mimarinin 5 kanallı özellik seçim katmanına sahip olması, en yüksek olasılık seçimi yapılırken sigmoid aktivasyon fonksiyonları kullanılması ve ek olarak her bir sınıf olasılığının hesaplanması için tüm özellik haritalarındaki skorların çarpılarak elde edilmesi ile farklılıklar bulunmaktadır. Önerilen çok kanallı CNN modeli 5 parçalı şekilde modellenmiştir. Modelde ilk olarak bir global evrişimsel katman bulunmaktadır. Daha sonra bu katmandan 4 farklı evrişim katmanının beslenmesi sağlanarak dört evrişimsel katman daha modele eklenmektedir. Önerilen çok kanallı CNN yönteminin ilk katmanı olan global evrişimsel katmanı 32 özellik haritası için $7 \times 7 \times 3$ evrişim çekirdeğine sahiptir. Daha sonra global evrişim katmanı dört eşit parçaya bölünerek ilgili görüntü için özellikleri öğrenmeyi amaçlayan bağımsız evrişim katmanlarını oluşturmaktadır. Global evrişim katmanı üzerinden oluşturulan dört bağımsız evrişim katmanları ilk adımında 5×5 çekirdek boyutlu evrişim çekirdeğine sahiptir. Ayrıca mimaride kullanılan tüm parçalarda maksimum havuzlama, tam bağlantılı evrişimsel katmanlar bulunmaktadır. Mimarinin sonraki adımında ise beş katman için de ikinci evrişim katmanı için 5×5 son evrişim katmanı için ise 3×3 lük çekirdek boyutu kullanılmıştır. Bu durum görüntünün daha ayrıntılı lokal özelliklerinin öğrenilmesi için düşünülmüştür. Global evrişim katmanı mimarisinin tam bağlantı katmanı 400 boyutunda bir çıktı oluştururken; parçalanarak oluşturulan diğer dört evrişim katmanı mimarilerinin tam bağlantı katmanı 100 boyutunda bir çıktı oluşturmaktadır. Ayrıca önerilen çok kanallı CNN mimarisinde tüm evrişim katmanlarının çıktılarını üretmek için bir ReLU katmanı bulunmaktadır.

Beş kanallı evrişimsel katman sonuçları arasında en baskın sonucun elde edilmesi için kanal seçim işlemleri yapılmaktadır. Önerilen çok kanallı yönteminin mimari

yapısı Şekil 2’de gösterilmektedir. Önerilen çok kanallı CNN modelinde en baskın özellik filtrelerinin seçilmesi için kanal seçim formülü tanıtılmaktadır. Önerilen mimaride, bir



Şekil 2. Önerilen çok kanallı CNN yöntemi mimarisi (Architecture of proposed CNN method.)

evrişim operatörü, her pikseldeki her sınıfın olasılığını verir. Eş. 6'da, final skoru elde edilmesi için özellik haritalarının tüm kanalları üzerinden çarpılır.

$$F_{Score_k} = \sum_{i=1, j=1}^P x_{i,j} * w_{i,j} \quad (6)$$

Denklem 6'da x, ağız çıkış özelliğini, w, evrişim çekirdeğini ve P ise piksel pozisyonlarının kümesini temsil etmektedir. Hesaplama için sadece standart sapma değerini değerlendirmek doğru değildir. Çünkü standart sapma değeri mevcut tüm skorların dağılımını vermektedir. Standart sapma ve elde edilen skor değerleri kullanılarak ortalama skorun standart sapmanın kaç kez altında veya üstünde olduğunu hesaplamak düşünülmüştür. Bu şekilde, başlangıçta eşdeğer olan ham skorlar eşdeğer hale getirilir. Sonuç olarak, her bir skorun tüm skorlara göreli konumu (performans) matematiksel olarak ifade edilebilir ve bu skorlar birbirleri ile karşılaştırılabilir. Final skorunun mutlak notu, tüm final skorlarının mutlak not ortalamasının ve standart sapmanın bir fonksiyonudur. Fonksiyon bu son puanın başarısını vermektedir (Eş. 7).

$$Avg = \frac{\sum_{k=1}^N F_{Score_k}}{N}$$

$$Std = \sqrt{\frac{1}{N} \sum_{k=1}^N (F_{Score_k} - Avg)^2} \quad (7)$$

$$S_{F_{Score_k}} = \frac{F_{Score_k} - Avg}{Std}$$

Bu denklemde K, kanal sayısını, $S_{F_{Score_k}}$ ise tahmin olasılığını (nihai skorun başarısı) ifade etmektedir. Kanal seçim bloğu formülü ile özellik seçimini ifade eden F_{Score} , denklem 8'de gösterilmektedir. Eş. 8'de gösterildiği gibi, gerçek etikete doğru en yüksek olasılık değerini değiştirmek için bir parametre eklenmiştir.

Problemin önerilen çok kanallı CNN yöntemi ve diğer yöntemler ile modellenmesi için ilk olarak veri seti ön işleme adımlarının ardından eğitim ve test seti olarak gelişigüzel olarak ayrılacaktır. Daha sonrasında öğrenme parametrelerinin başlangıç değerleri atanacak; modellerin eğitim sürecinin ardından ise sonuç olarak optimum ağırlık ve parametre değerleri belirlenecektir.

$$\overline{F_{Score}} = \begin{bmatrix} maks(S_{F_{Score}}) * sigmoid(x_1, w_1) \\ maks(S_{F_{Score}}) * sigmoid(x_2, w_2) \\ \dots \\ maks(S_{F_{Score}}) * sigmoid(x_N, w_N) \end{bmatrix} \begin{bmatrix} F_{Score1} \\ F_{Score2} \\ \dots \\ F_{ScoreN} \end{bmatrix} \quad (8)$$

$$\overline{F_{Score}} = \begin{bmatrix} maks(S_{F_{Score}}) * sigmoid(x_1, w_1) * w_1 \\ maks(S_{F_{Score}}) * sigmoid(x_2, w_2) * w_2 \\ \dots \\ maks(S_{F_{Score}}) * sigmoid(x_N, w_N) * w_N \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \dots \\ x_N \end{bmatrix}$$

3. DENEYSEL ÇALIŞMALAR-UYGULAMA (EXPERIMENTAL STUDIES)

Çalışmada uygulanan tüm modeller 3.50GHz işlemci, 16 GB Ram, NVIDIA GeForce 8GB ekran kartına sahip bilgisayar üzerinde gerçekleştirilmiştir. Uygulama Python kodlama dili ile 'Jupyter Notebook' geliştirme ortamında geliştirilmiştir (Şekil 3). Uygulanan tüm modeller için Keras, Tensorflow ve matplotlib kütüphaneleri kullanılmıştır. Modellerde başlangıç parametreleri standart olarak alınmıştır. X-Ray görüntülerinden Covid-19 tanısı yapılan model için önerilen CNN mimarisi sınıflandırma için AlexNet derin öğrenme algoritmasını kullanmaktadır. Çalışmada 3 farklı veri seti modellerine önerilen CNN mimarisi dışında tekrarlayan derin sinir ağırları (SRN) yöntemi de kıyaslamak için uygulanmıştır. 'Jupyter Notebook' geliştirme ortamı üzerinde önerilen yöntemin test setindeki X-Ray görüntüsü için Covid-19 tanısı koyma durumu Şekil 4'te gösterilmiştir.

```

In [21]: model.compile(loss='categorical_crossentropy', optimizer='adam',
metrics=['accuracy'])

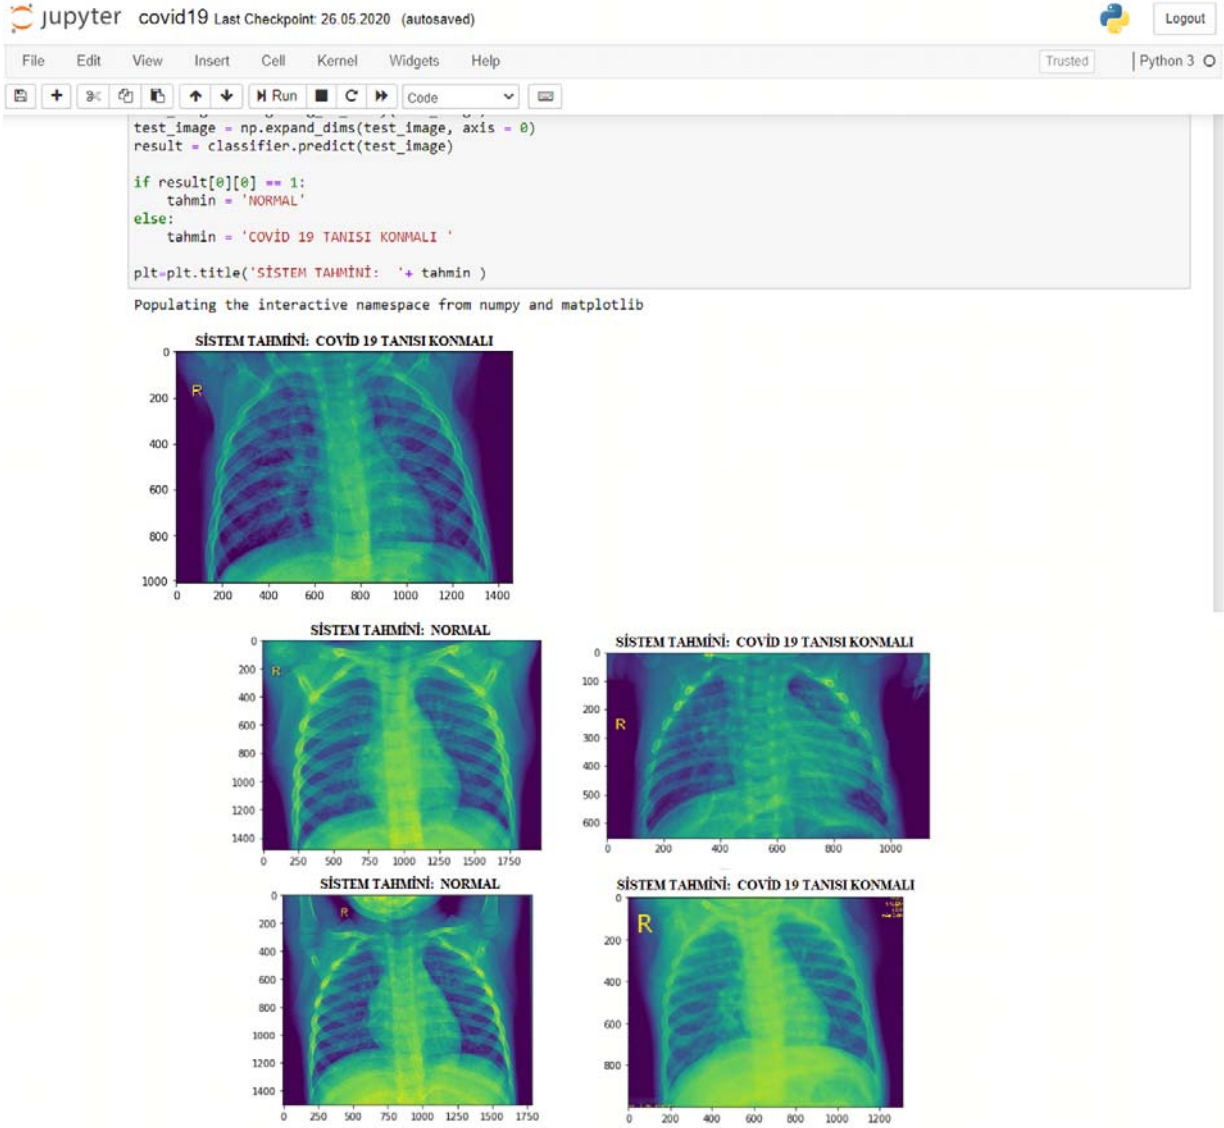
###
model.add(Dense(2, activation='softmax'))
model.fit(x_train,y_train ,batch_size=60,epochs=10000,verbose=1, validation_data = (x_test,y_test))

###
score = model.evaluate(x_test, y_test, verbose=1)
print('\n', 'Test accuracy:', score[1])

Train on 4685 samples, validate on 1171 samples
Epoch 1/10000
4685/4685 [=====] - 139s 30ms/step - loss: 0.6930 - accuracy: 0.5144 - val_loss: 0.6515 - val_accurac
y: 0.7199
Epoch 2/10000
4685/4685 [=====] - 150s 32ms/step - loss: 0.6231 - accuracy: 0.7321 - val_loss: 0.6100 - val_accurac
y: 0.7199
Epoch 3/10000
4685/4685 [=====] - 148s 32ms/step - loss: 0.5939 - accuracy: 0.7321 - val_loss: 0.5963 - val_accurac
y: 0.7199
Epoch 4/10000
4685/4685 [=====] - 152s 33ms/step - loss: 0.5840 - accuracy: 0.7321 - val_loss: 0.5933 - val_accurac
y: 0.7199
Epoch 5/10000
4685/4685 [=====] - 178s 38ms/step - loss: 0.5817 - accuracy: 0.7321 - val_loss: 0.5931 - val_accurac
y: 0.7199
Epoch 6/10000
4685/4685 [=====] - 176s 38ms/step - loss: 0.5812 - accuracy: 0.7321 - val_loss: 0.5933 - val_accurac
y: 0.7199

```

Şekil 3. Jupyter Notebook geliştirme ortamında modelin geliştirilmesi (Development of the model in Jupyter Notebook.)



Şekil 4. Sistemin Covid-19 tanı sonucu (Tumor detection of the system)

Önerilen çok kanallı CNN modelinde, 5 kanallı evrişim katmanı bulunmaktadır. İlk olarak global evrişim katmanı ile başlayan mimari; bu katmanın 4 farklı evrişim katmanını beslemesi ile toplam beş kanal olarak tasarlanmıştır. Tüm kanalların mimarisinde 3'er evrişim katmanı, 2'şer havuzlama katmanı, ReLU doğrusal birim ve tam bağlantılı katman bulunmaktadır. Global kanaldaki ilk evrişim katmanında $7 \times 7 \times 3$ evrişim çekirdeğine sahipken; ikinci evrişim katmanında 5×5 son evrişim katmanında ise 3×3 evrişim çekirdeğine sahiptir. Mimaride kullanılan diğer dört evrişim kanalının ilk iki evrişim katmanında 5×5 son evrişim katmanında ise 3×3 evrişim çekirdeği bulunmaktadır. Global evrişim kanalının tam bağlantı katmanı 400 boyutunda çıktı üretirken diğer dört evrişim kanallarının tam bağlantı katmanı ise 100 boyutunda çıktı üretmektedirler. Tüm kanallardan gelen çıktılar önerilen çok kanallı CNN mimarisinin en iyi sonucu üretmesi için kanal seçim katmanı üzerinden hesaplama yapılır. Bu özellik haritaları tam bağlantılı katmanlara bağlandıktan sonra sınıflandırma olasılıklarını belirlemek için Softmax aktivasyonu

gerçekleştirilmiştir. Global evrişim kanalında 8228220, diğer evrişim kanallarının her birinde 2109852 olmak üzere modeldeki toplam parametre sayısı 16667628'dir. Modellerin eğitimleri yaklaşık 980000 saniyeye yakın ve 7000 iterasyon sürmüştür. İlk veri setinde 40. iterasyona kadar ikinci veri setinde 900. iterasyona kadar son veri setinde ise 6500. iterasyona kadar hata değeri azalırken bu iterasyondan sonraki eğitim sürecinde azalım gözlenmemiştir.

Probleme uygulanan tüm yöntemlere ait modellerin performans ölçümleri için doğruluk, hassasiyet, duyarlılık, özgüllük, F_1 skoru, ve RMSE gibi değerler ölçülmüştür. Oluşturulan karışıklık matrisinden dört istatistiksel endeks hesaplanarak önerilen sınıflandırma sisteminin performansının değerlendirilmesi için kullanılmıştır (Eş. 9) [33]. Eş. 9'da verilen denklemde GP gerçek pozitif, GN gerçek negatif, YP yanlış pozitif ve YN yanlış negatif ifade etmektedir.

$$\begin{aligned}
\text{Doğruluk} &= \frac{GP + GN}{GP + GN + YP + YN} \\
\text{Duyarlılık} &= \frac{GN}{GP + YN} \\
\text{Özgüllük} &= \frac{GN}{GN + YP} \\
\text{Hassasiyet} &= \frac{GN}{GP + YP} \\
F_1 &= 2 * \frac{\text{Hassasiyet} * \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}}
\end{aligned} \quad (9)$$

4. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

Bu çalışmada; insan yaşamı için büyük bir risk olan olası beyin tümörünün erken tespiti için CNN'ye dayalı yeni bir yöntem önerilmektedir. Kaggle veritabanında yer alan üç ayrı Covid-19 ile ilintili X-Ray akciğer görüntülerine ait veri setleri, 3 farklı model ile akciğer X-Ray görüntüsü üzerinden Covid-19 tanısı konması için uygulanmıştır. Dünya için oldukça önemli bir problem olan ve pandemi olarak tanımlanan Covid-19 tanısı için uygulanan PT-PCR testinin sonuçlanması uzun zaman aldığından ve sonuçlandığında yüksek yanlış negatif durumu ile çok sık karşılaşıldığından ötürü çalışmada önerilen şekilde bir tanı sistemi ile sağlık çalışanlarının işleri daha kolaylaşacaktır. Ayrıca erken tanı sayesinde doktorların müdahalesi ile kişinin hastalığının ilerlemeden ölümcül riski azaltmak da mümkün olacaktır.

Çalışmada akciğer X-Ray görüntülerinden Covid-19 tanısı için farklı sınıflandırıcıların ve öznelik gruplarının sınıflandırma performansları incelenmiştir. Çalışmada ilk veri setinden 50 görüntü, ikinci veri setinde 1125 görüntü ve üçüncü veri setinde ise 5856 görüntü ile, üç farklı sınıflandırıcı ve veri dengeleme yaklaşımı içeren bir desen oluşturulmuştur. Önerilen çok kanallı CNN mimarisine ek olarak, SRN mimarisi de sayısal olarak test edilmiş ve

değerlendirilmiştir. Covid-19 tanı problemi için uygulanan yöntemlerin 1. veri setindeki Covid-19 tanı değerlendirme istatistikleri Tablo 1'de, 2. veri setine uygulanan modeller için değerlendirme istatistikleri ise Tablo 2'de ve 3. veri setine uygulanan modeller için performans karşılaştırılması Tablo 3'te sunulmaktadır. Mimarilerin problem için doğruluk performansları 1. 2. ve 3. veri setlerine ait modeller için sırasıyla; önerilen çok kanallı CNN derin öğrenme yöntemi için %99,41-%97,5-%96,74 ve SRN yöntemi için %97,28-%94,92-%93,72 şeklindedir. En fazla veriye sahip olan 3. Veri seti için doğruluk ve hata azalımı grafiği Şekil 5'te gösterilmektedir. Bu sonuçlar, önerilen CNN mimarisinin diğer mimarilerden daha başarılı olduğunu göstermektedir. Önerilen çok kanallı CNN yönteminin diğer mimarilerden daha iyi olmasının nedeni, görüntülerin 5 farklı evrişim kanalı üzerinde işlenmesi ve ardından en belirgin özellik vektörünün belirlenmesi için kanal seçim katmanı ile desteklenmesidir. Önerilen yöntemin çalışmada üç farklı veri seti için elde edilen performansı literatürde aynı problem üzerinde yapılan çalışmalarla karşılaştırılmış ve önerilen yöntemin performansı daha yüksek bulunmuştur (Tablo 4).

Önerilen çok kanallı CNN yöntemi uygulanan her üç veri seti için SRN mimarisine göre tüm performans değerlendirme kriterleri açısından daha iyi sonuçlar elde etmiştir. Tablo 1, Tablo 2, Tablo 3 ve Tablo 4'te sunulan performans kriteri sonuçları ve uygulanan mimarilerin işlem süresi, önerilen mimarinin uygulanacak sorunun geçici kritikliğine göre uygulanabilir olduğunu göstermektedir.

Bu çalışmada literatürdeki çalışmalardan farklı olarak, çok kanallı evrişim katmanları ile en belirgin özellik filtrelerini seçmek için önerilen çok kanallı CNN modelinde kanal seçim formülü sunulmuştur. Önerilen çok kanallı CNN modelinin çok kanallı evrişim katmanlarının tam bağlantı

Tablo 1. 1. Veri seti için uygulanan modellerin performanslarının karşılaştırılması
(Comparison of applied models's performance for 1st dataset)

1. Veri Seti	Önerilen CNN Mimarisi	SRN Mimarisi
Doğruluk	99,41	97,28
Duyarlılık	99,73	97,94
Özgüllük	99,16	96,72
Hassasiyet	99,38	97,07
RMSE	0,89	1,11
F ₁	99,554	97,503
Eğitim Süresi (sn)	1210	1150
Test Süresi (sn)	556	541

Tablo 2. 2. Veri seti için uygulanan modellerin performanslarının karşılaştırılması
(Comparison of applied models's performance for 2nd dataset)

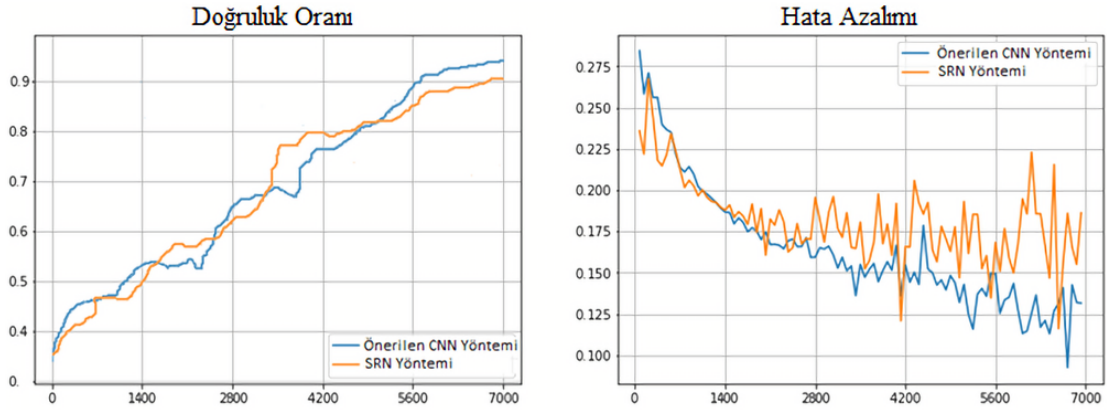
2. Veri Seti	Önerilen CNN Mimarisi	SRN Mimarisi
Doğruluk	97,75	94,92
Duyarlılık	98,84	95,36
Özgüllük	96,44	93,17
Hassasiyet	97,61	94,53
RMSE	1,13	1,79
F ₁	98,221	94,94
Eğitim Süresi (sn)	762132	760981
Test Süresi (sn)	362920	360326

Tablo 3. 3. Veri seti için uygulanan modellerin performanslarının karşılaştırılması
(Comparison of applied models's performance for 3rd dataset)

3. Veri Seti	Önerilen CNN Mimarisi	SRN Mimarisi
Doğruluk	96,74	93,72
Duyarlılık	97,32	95,12
Özgüllük	95,96	91,39
Hassasiyet	96,53	93,56
RMSE	1,92	4,87
F ₁	96,923	94,333
Eğitim Süresi (sn)	981546	980213
Test Süresi (sn)	446157	445562

Tablo 4. Literatürdeki benzer çalışmalar ile önerilen yöntemin performanslarının karşılaştırılması
(Comparing the performance of the proposed method with similar studies in the literature)

Referans Çalışma	Sınıflandırıcı	Doğruluk Oranı (En İyi %)
Ophir vd. [6]	CNN	95
Shi vd. [7]	iSARF	90,7
Zhang vd. [10]	CNN	96
Shan vd. [11]	CNN	91,6
Xu vd. [12]	ResNET	86,7
Wang vd. [13]	DL-Inception	82,9
Narin vd. [14]	ResNET	98
Önerilen Yöntem (1. Veriseti)	CNN	99,41
Önerilen Yöntem (2. Veriseti)	CNN	97,75
Önerilen Yöntem (3. Veriseti)	CNN	96,74

**Şekil 5.** Uygulanan modellerin doğruluk performans grafikleri (Accuracy performance graphics of applied models)

katmanlarından çıkarılan her özellik için uygun bir ağırlığın belirlenmesi, formülasyon ile gösterilmiştir. Daha sonra, önerilen yöntemin uygulanabilir olup olmadığını göstermek için akciğer X-Ray görüntülerine ait üç ayrı veri kümesi farklı bir yöntemde uygulanmış ve karşılaştırılmıştır. Bunun yanı sıra literatürde aynı tip probleme uygulanmış benzer yöntemlerin sonuçları da ayrı olarak kıyaslanmıştır. Sonuçlar incelendiğinde hem başarımların performansı hem de zamansal verimlilik açısından, önerilen yöntemin uygulanabilir olduğu gösterilmiştir. Buna ek olarak, bu çalışmada, derin öğrenme yöntemi ile tüm dünyada pandemi olarak tanımlanan Covid-19 için hızlı bir tanı sistemi önerilmiştir. İleride Covid-19 hastalığının tüm süreçleri ve belirtileri daha net anlaşıldığında önerilen yöntem ile farklı bir tanı sistemi de uygulanabilir.

TEŞEKKÜR (ACKNOWLEDGEMENT)

Yazar, araştırmanın okunabilirliğini, düzenini ve organizasyonunu önemli ölçüde artırmaya yardımcı olan değerli yorumları ve katkıları için hakemlere ve editörlere teşekkür eder.

KAYNAKLAR (REFERENCES)

1. T.C. Sağlık Bakanlığı Covid-19 Hastalığı, <https://covid19bilgi.saglik.gov.tr/tr/covid-19-yeni-koronavirus-hastaligi-nedir>, Erişim tarihi Mayıs 31, 2020.
2. Ardila, D., Kiraly, A.P., Bharadwaj, S., Choi, B., Reicher, J.J., Peng, L., Tse, D., Etmedi, M., Ye, W.,

- Corrado, G., End-To-End Lung Cancer Screening with Three-Dimensional Deep Learning On Low-Dose Chest Computed Tomography, *Nature Medicine*, 25 (6), 954–961, 2019.
3. Suzuki, K., Overview of Deep Learning in Medical Imaging, *Radiological Physics And Technology*, 10 (3), 257–273, 2017.
 4. Coudray, N., Ocampo, P.S., Sakellaropoulos, T., Narula, N., Snuderl, M., David, F., Moreira, A.L., Razavian, N., Tsirigos, A., Classification and Mutation Prediction From Non-Small Cell Lung Cancer Histopathology Images Using Deep Learning, *Nature Medicine*, 24 (10), 1559–1567, 2018.
 5. Esteva, A., Kuprel, B., Novoa, R.A., Ko, J., Swetter, S.M., Blau, H.M., Thrun, S., Dermatologist-Level Classification of Skin Cancer With Deep Neural Networks, *Nature*, 542 (7639), 115–118, 2017.
 6. Ophir, G., Maayan, F.A., Hayit, G., Patrick D.B., Huangqi Z., Wenbin, J., Bernheim, A., Siegel, E., Rapid AI development Cycle For The Coronavirus (COVID-19) Pandemic: Initial Results For Automated Detection & Patient Monitoring Using Deep Learning CT Image Analysis, *Radiology*, 2020. arXiv:2003.05037v3
 7. Shi, F., Xia, L., Shan, F., Wu, D., Wei, Y., Yuan, H., Jiang, H., Gao, Y., Sui, H., Shen, D., Large-scale Screening of Covid-19 From Community Acquired Pneumonia Using Infection Size-Aware Classification, 2020. arXiv:2003.09860v1
 8. Franquet, T., Imaging of Pneumonia: Trends and Algorithms, *European Respiratory Journal*, 18 (1), 196–208, 2001.
 9. [9] Cherian, T., Mulholland, E.K., Carlin, J.B., Ostensen, H., Amin, R., Campo, M., Greenberg, D., Lagos, R., Lucero, M., Madhi, S.A., Standardized Interpretation Of Paediatric Chest Radiographs for The Diagnosis of Pneumonia in Epidemiological Studies, *Bulletin of the World Health Organization*, 83, 353–359, 2005.
 10. Zhang, J., Xie, Y., Li, Y., Shen, C., Covid-19 Screening on Chest X-ray Images Using Deep Learning Based Anomaly Detection, arXiv:2003.12338v1, 2020.
 11. Shan, F., Gao, Y., Wang, J., Shi, W., Shi, N., Han, M., Xue, Z., Shi, Y., Lung Infection Quantification of Covid-19 in CT Images with Deep Learning, 1-19, arXiv:2003.04655, 2020.
 12. Xu, X., Jiang, X., Ma, C., Du, P., Li, X., Lv, S., Yu, L., Chen, Y., Su, J., Lang, G., Li, Y., Zhao, H., Xu, K., Ruan, L., Wu, W., Deep Learning System to Screen Coronavirus Disease, Pneumonia, *Applied Intelligence*, 1-29, 2020. arXiv:2002.09334, 2019
 13. Wang, S., Kang, B., Ma, J., Zeng, X., Xiao, M., Guo, J., Cai, M., Yang, J., Li, Y., Meng, X., Xu, B., A Deep Learning Algorithm Using CT Images To Screen For Corona Virus Disease (Covid-19), DOI: 10.1101/2020.02.14.20023028, 2020.
 14. Narin, A., Kaya, C., Pamuk, Z., Automatic Detection of Coronavirus Disease (COVID-19) Using X-ray Images and Deep Convolutional Neural Networks, *Computers in Biology and Medicine*, arXiv:2003.10849v1, DOI: 10.1016/j.compbiomed.2020.103792, 2020.
 15. Xie, X., Li, X., Wan, S., Gong, Y., Mining X-ray Images of SARS Patients, *Data Mining: Theory, Methodology, Techniques, and Applications*, 282-294, Springer-Verlag, Berlin, Heidelberg, ISBN: 3540325476, 2006.
 16. Difference Between X-ray and CT Scan, <https://biodifferences.com/difference-between-x-ray-and-ct-scan.html>, Erişim tarihi Mayıs 31, 2020.
 17. Fang, Y., Zhang, H., Xie, J., Lin, M., Ying, L., Pang, P., Ji, W., Sensitivity of chest CT for Covid-19: Comparison to RT-PCR, *Radiology*, 200432, DOI: 10.1148/radiol.2020200432, 2020.
 18. Hamimi, A. MERS-CoV: Middle East Respiratory Syndrome Corona Virus: Can Radiology be Of Help? Initial Single Center Experience, *The Egyptian Journal of Radiology and Nuclear Medicine*, 47 (1), 95-106, 2016.
 19. Xie, X., Zhong, Z., Zhao, W., Zheng, C., Wang, F., Liu, J., Chest CT for Typical 2019-nCoV Pneumonia: Relationship to Negative RT-PCR Testing, *Radiology*, DOI: <https://pubs.rsna.org/doi/10.1148/radiol.2020200343>, 2020.
 20. Bernheim, A., Mei, X., Huang, M., Chest CT Findings in Coronavirus Disease-19 (Covid-19): Relationship to Duration of Infection, *Radiology*, DOI: <https://pubs.rsna.org/doi/10.1148/radiol.2020200463>. 2020.
 21. Kaggle Covid-19 Chest X-Ray, <https://www.kaggle.com/bachrr/covid-chest-xray>, Erişim tarihi Mayıs 31, 2020.
 22. Kaggle Lung Image Mini Project, <https://www.kaggle.com/hnchinmaya/lung-image-mini-project-covid19-xray>, Erişim tarihi Mayıs 31, 2020.
 23. Kaggle Chest X-Ray Images, <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia>, Erişim tarihi Mayıs 31, 2020.
 24. Yılmaz A., Yapay Zeka, Kodlab Yayınevi, Türkiye, 2017.
 25. Yılmaz A., Kaya, U., Derin Öğrenme. Kodlab Yayınevi, Türkiye, 2019.
 26. Çelik, A., Arıca, N., Enhancing Face Pose Normalization With Deep Learning, *Turkish Journal of Electrical Engineering & Computer Sciences*, 27, 3699-3712, 2019.
 27. Yan, Z., Xu, Z., Dai, J., The Big Data Analysis on The Camera-Based Face Image in Surveillance Cameras, *Autosoft Journal - Intelligent Automation & Soft Computing*, 24 (1), 123-132, 2019.
 28. Adem, K., Közkurt, C., Defect Detection of Seals in Multilayer Aseptic Packages Using Deep Learning, *Turkish Journal of Electrical Engineering & Computer Sciences*, 27, 4220-4230, 2019.
 29. Arı A., Hanbay D., Tumor Detection in MR Images of Regional Convolutional Neural Networks, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (3), 1395-1408, 2019.
 30. Kaya A., Keçeli S., Can A.B., Examination of Various Classification Strategies in Classification of Lung Nodule Characteristics, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (2), 709-725, 2019.

31. Dođan, F., Türkođlu, İ., Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme, DÜMF Mühendislik Dergisi, 10 (2), 409-445, 2019.
32. Yılmaz, A., Shoulder Implant Manufacturer Detection by Using Deep Learning: Proposed Channel Selection Layer, Coatings, 11 (3), 346, 2021.
33. Quek, M., Chin, N., Yusof, Y., Law, C., Tan, S. Pattern Recognition Analysis on Nutritional Profile and Chemical Composition of Edible Bird's Nest for its Origin and Authentication, International Journal of Food Properties, 21 (1), 1680–1696, 2018.

