



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 24.11.2023
Kabul Tarihi : 30.11.2023

Received Date : 24.11.2023
Accepted Date : 30.11.2023

DERİN ÖĞRENME TABANLI MODELLERLE AKCİĞER X-RAY GÖRÜNTÜLERİNDEN COVID-19 TESPİTİ

DETECTION OF COVID-19 FROM CHEST X-RAY IMAGES WITH DEEP LEARNING BASED MODELS

*Hacı Ömer DOKUMACI** (ORCID: 0000-0003-4032-0669)

Kahramanmaraş Sütçü İmam Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Kahramanmaraş, Türkiye

*Sorumlu Yazar / Corresponding Author: Hacı Ömer DOKUMACI, omer_dokumaci@ksu.edu.tr

ÖZET

COVID-19 dünya çapında milyonlarca insanı enfekte etmiştir ve önemli hastalık ve ölümlere neden olmuştur. Akciğer röntgeni (CXR), COVID-19 hastalığını izlemek için hızlı ve etkili bir yöntemdir. CXR taramasından COVID-19 teşhisi zor olabilir ve deneyimli radyologlar bile her durumda kesin bir teşhis koyamayabilir. Bu çalışmada, çeşitli CNN tabanlı modellerin performansını değerlendirmek için COVID-19, akciğer opaklığı ve viral pnömonisi olan hastaların X-ışını görüntülerinden oluşan bir veri seti kullanıldı. Değiştirilmiş bir ConvNext'le, 4 yönlü sınıflandırmada COVID-19 görüntülerinde %98,1 doğruluk ve %97,8 kesinlik elde edildi. ConvNext, COVID-19 teşhisi için kullanılan en son tekniklere göre iyi bir performans sergilemektedir. Bu çalışmada ortaya konulan yöntem, klinisyenleri COVID-19 hastalarını taramada destekleyebilir. Böylece bu hastalar için daha hızlı tedavi ve daha iyi sağlık sonuçları mümkün olabilir.

Anahtar Kelimeler: Covid-19, derin öğrenme, CNN.

ABSTRACT

COVID-19 has infected millions of people worldwide and caused significant illness and death. Chest X-rays are a quick and efficient method for monitoring COVID-19 disease. The diagnosis of COVID-19 from a CXR scan can be challenging, and even experienced radiologists may not be able to make a definitive diagnosis in all cases. In this study, we used a dataset of X-ray images of COVID-19, lung opacity, viral pneumonia, and healthy patients to evaluate the performance of several CNN-based models. A modified ConvNext has achieved 98.1% accuracy and 97.8% precision on COVID-19 images in a 4-way classification effort. Our results compare well with state-of-the-art techniques for COVID-19 diagnosis. Our approach could support clinicians in screening patients for COVID-19, thus facilitating faster treatment and better health outcomes for COVID-19 patients.

Keywords: Covid-19, deep learning, CNN.

GİRİŞ

Covid-19 ilk olarak Aralık 2019'da Çin'in Wuhan kentinde gözlemlenmiştir. Hızla dünyadaki diğer ülkelere yayılmış, milyonlarca insana bulaşmış ve ölümlere neden olmuştur (Wang vd., 2020; Gorbalenya vd., 2020; Phelan vd., 2020). Covid-19'un yüksek bulaşıcılığı, hastalığın daha fazla yayılmasını önlemek ve zamanında ve etkili tedavi sağlamak için hastaları hızlı bir şekilde taramayı, tanımlamayı ve izole etmeyi gerekli kılmaktadır.

Ters transkriptaz polimeraz zincir reaksiyonu (RT-PCR) testi, Covid-19 teşhisi için yaygın olarak kullanılan bir yöntemdir (Kucirka vd., 2020; Khan vd., 2020). Bununla birlikte, RT-PCR testi için birtakım limitler vardır. RT-PCR testinin bir limiti, sonuçlar için uzun geri dönüş süresidir. Bu, hastalığın erken evrelerinde veya hastaların ciddi hastalık riskinin yüksek olduğu durumlarda olduğu gibi, hastaların hızlı bir şekilde teşhis edilmesi gereken durumlarda da bir sorun olabilir. RT-PCR testinin bir diğer limiti, yüksek oranda yanlış negatifliğe sahip olmasıdır. Bunun nedeni, viral yükün düşük olması durumunda RT-PCR testinin virüsü tespit edememesidir.

Bu limitler göz önüne alındığında, RT-PCR testine ek olarak diğer tanı yöntemlerini de dikkate almak önemlidir. Bilgisayarlı tomografi (BT) taramaları ve akciğer röntgeni (CXR) gibi tıbbi görüntüleme yöntemleri, Covid-19'u yüksek derecede doğrulukla teşhis etmek için kullanılabilir. Bu yöntemler, hastaların RT-PCR testinin negatif olduğu ancak yine de enfekte olduğundan şüphelenildiği durumlarda özellikle yararlıdır.

Derin öğrenme (DL) teknikleri, bilgisayarla görü ve biyomedikal görüntüleme alanında, daha üst düzey sistemleri modellemek ve insan benzeri performans elde etmek için başarıyla kullanılmıştır. Bu, CXR görüntülerinden Covid-19 teşhisi için yapay zekâ kullanımına olan ilginin artmasına neden olmuştur. Covid-19 teşhisi için DL tabanlı modellerde tipik olarak evrişimli sinir ağları (CNN) veya transformer kodlayıcı modüller kullanılır. DL yöntemlerinin otomatik özellik öğrenme yeteneği, derin sinir ağlarına dayalı Covid-19 sınıflandırmasını yaygın olarak kullanılan bir yaklaşım haline getirmiştir. DL teknikleri, Covid-19 tanısını otomatikleştirmek için çok sayıda çalışmada kullanılmıştır (Umer vd., 2022; Apostolopoulos vd., 2020; Wang vd., 2020). Bilgisayar destekli tanı (CAD) sistemleri, DL modellerinin yardımıyla radyologların iş yükünü azaltmaya ve tanının doğruluğunu iyileştirmeye yardımcı olabilir. CAD sistemleri, daha yakından izlenebilmeleri için ağır Covid-19 geliştirme riski taşıyan hastaları belirlemek için de kullanılabilir.

ÖNCEKİ ÇALIŞMALAR

Covid-19'un tespiti için CXR görüntülerini otomatik olarak sınıflandırmakta CNN'lerin kullanımı son yıllarda büyük ilgi görmüştür. Öztürk vd. Covid-19'da üç yönlü sınıflandırma için DarkNet'i %87 doğrulukla kullanmıştır. Apostolopoulos vd. önceden eğitilmiş beş CNN'i eğitmiştir ve iki kategorili ve üç kategorili sınıflandırmada sırasıyla %98,75 ve %93,48'lik bir doğruluk elde etmişlerdir. Yoo vd. Covid-19'u %95 doğrulukla tespit etmek için ResNet18 modelini kullanmıştır. Sethy vd. özellik çıkarımı için ResNet50 mimarisini ve sınıflandırma için SVM'i kullanarak %95,33'lük bir doğruluk elde etmiştir. Minaee vd. %95,45'lik bir doğruluk elde etmek için Squeeze Net'i kullanmıştır.

Wang vd. projeksiyon-genişleme-projeksiyon-genişletme (PEPX) mimarisine sahip COVID-Net adlı derin bir CNN ağı tasarlamış ve %93,3'lük bir doğruluk elde etmiştir. Arias-Garzón vd. daha doğru sınıflandırma sonuçları elde etmek için ön işleme aşamasını iyileştirmeye odaklanmıştır. Ön işleme aşaması, verileri frontal veya lateral olarak bölmek için bir filtreleme ağından ve akciğer bölgelerini çıkarmak için bir segmentasyon modelinden oluşuyordu ve bu da daha sonra %97'lik bir sınıflandırma doğruluğu ile sonuçlanmıştır.

MATERYAL VE YÖNTEM

Bu çalışmada, bugüne kadar olan en kapsamlı Covid-19 veri setlerinden birinde, Covid-19'un tespiti için, gelişmiş CNN tabanlı sinir ağı mimarilerinin performansı değerlendirilmiştir. Çalışılan bütün ağlarda sadece sınıflandırma başlığı değiştirilmiştir. Bu sayede transfer öğrenme için en uygun olan ağ mimarisini tespit edilmiştir. Literatürün önemli bir bölümünde, ağların bazı kısımları değiştirilmiştir, ancak eşlik eden kaynak kodu veya hiperparametre değerleri nadiren verildiğinden, bu değişikliklerin ve karşılık gelen sonuçların tekrarlanması zordur. Bu çalışmada standart açık kaynaklı ağların performansı değerlendirildiğinden, sonuçlar alanında uzman kişiler tarafından tekrarlanabilir. Kıyaslanan ağlar şunlardır: ResNet152, ResNext101, EfficientB7 ve ConvNext.

CNN Tabanlı Modeller

Residual Network'ün kısaltması olan ResNet, 2015 yılında Microsoft Research'teki araştırmacılar tarafından tanıtılan bir tür sinir ağı mimarisidir (He vd., 2015). Çok derin sinir ağlarını eğitirken ortaya çıkan kaybolan/patlayan

gradyanlar sorununu çözmek için tasarlanmıştır. ResNet, aradaki bazı katmanları atlayarak, bir katmanın aktivasyonlarını diğer katmanlara bağlamak için atlama bağlantılarını kullanan artık bloklar kavramını sunar. Bu, ağın temel eşleme yerine artık bir eşlemeye sığdırılmasına olanak tanır. Bu metot, kaybolan/patlayan gradyanların neden olduğu sorunlar olmadan, çok derin sinir ağlarını eğitime yeteneği ile sonuçlanır.

ResNeXt, Xie vd. tarafından makalelerinde tanıtılan evrişimli bir sinir ağı mimarisidir (Xie vd., 2016). Aynı topolojiye sahip bir dizi dönüşümü bir araya getiren bir yapı taşını tekrarlayan ResNet mimarisinin bir uzantısıdır. Bir ResNet ile karşılaştırıldığında, ResNeXt, derinlik ve genişlik boyutlarına ek olarak önemli bir faktör olarak yeni bir boyut olan kardinalite (dönüşüm kümesinin boyutu) C'yi ortaya çıkarır. Bu, katmanları daha derin ve daha geniş istifleme yerine, ResNeXt'in her bir artık blok içindeki paralel dönüşümlerin sayısını da dikkate aldığı anlamına gelir.

EfficientNet, hem doğruluğu hem de verimliliği artırmak için yeni bir model ölçeklendirme yöntemi kullanan evrişimli bir sinir ağı mimarisidir (Tan vd., 2020). Bileşik ölçeklendirme adı verilen bu yöntem, CNN'leri daha yapılandırılmış bir şekilde ölçeklendirmek için basit ama oldukça etkili bir bileşik katsayı kullanır. Genişlik, derinlik ve çözünürlük gibi ağ boyutlarını rastgele ölçeklendiren geleneksel yaklaşımların aksine, bileşik ölçeklendirme yöntemi, her boyutu sabit bir ölçekleme katsayıları kümesi ile eşit şekilde ölçeklendirir. Bu yaklaşım, modelin farklı boyutlarının ölçeklendirilmesinin etkisi incelenerek geliştirilmiştir. Araştırmacılar ağı tüm boyutlarını (genişlik, derinlik ve görüntü çözünürlüğü) mevcut kaynaklarla dengelemenin genel performansı en iyi şekilde iyileştireceğini bulmuşlardır.

ConvNeXt, tamamen standart evrişim modüllerinden oluşturulmuş saf bir evrişim ağıdır (Liu vd., 2020). ConvNeXt'in arkasındaki motivasyon, CNN ağ yapısının tasarım alanlarını yeniden incelemek ve saf bir evrişim ağının neler başarabileceğinin sınırlarını test etmektir. Araştırmacılar, standart bir ResNet'i bir görüntü transformer tasarımına doğru kademeli olarak modernize ettiler ve yol boyunca performans farkına katkıda bulunan birkaç temel bileşen keşfettiler. Bu keşfin sonucu, ConvNeXt olarak adlandırılan saf evrişimli modellerden oluşan bir ailedir. Tamamen standart evrişimli modüllerden oluşturulan ConvNeXt, standart evrişim ağlarının basitliğini ve verimliliğini korurken, COCO algılama ve ADE20K segmentasyonunda transformer tabanlı modeller ile olumlu bir şekilde rekabet eder.

Veri Seti


Bu çalışmada kullanılan Covid-19 veri seti, aşağıdaki hastalıkların CXR görüntülerinden oluşmaktadır: Normal, Covid-19, Akciğer Opaklığı ve Viral Pnömoni (Rahman vd., 2021; Chowdhury vd., 2020). Akciğer opaklığı, Covid dışı akciğer enfeksiyonu anlamına gelmektedir. Veri tabanında 3616 Covid-19 pozitif vakanın yanı sıra 10,192 Normal, 6012 Akciğer Opaklığı ve 1345 Viral Pnömoni görüntüsü ile toplam 21,165 CXR görüntüsü bulunmaktadır. Görüntülerin tümü 299×299 çözünürlüğe normalleştirilmiştir. Banco digital de Imagen Médica de la Comunidad Valenciana (BIMCV), Alman Tıp Okulu (GMS), Società Italiana di Radiologia Medica e Interventistica (SIRM), Kuzey Amerika Radyoloji Derneği (RSNA) ve Guangzhou Kadın ve Çocuk Tıp Merkezi (GWCMC) gibi çeşitli tıbbi kurumlardan toplanmıştır. Örnek resimler etiketleriyle birlikte Şekil 1'de gösterilmiştir.

Veri seti rastgele olarak üç kategoriye ayrılmıştır: eğitim, doğrulama ve test. Test veri seti, toplam veri setinin %10'unu oluştururken, geri kalanın %80'i eğitim veri setine, %20'si ise doğrulama veri setine atanmıştır.

Veri artırma, yeni veriler toplanmadan, eğitim modelleri için mevcut veri çeşitliliğinin önemli ölçüde artırılmasını sağlayan bir stratejidir. Döndürme ve yatay çevirme gibi veri artırma teknikleri, büyük sinir ağlarını eğitmek için yaygın olarak kullanılır. Bu teknikler tek tek veya kombinasyon halinde uygulanabilir. Amaç, eğitim verileri içinde daha geniş bir örnek çeşitliliği sunarak daha sağlam bir model oluşturmaktır. Bu çalışmada da görüntüler eğitim sırasında rasgele olarak döndürülmüş ve yatay olarak çevrilmiştir. Döndürme açısı maksimum 10 derece olarak sınırlanmıştır. Görüntüler veri artırımından önce ağların giriş çözünürlüğüne göre ölçeklendirilmiştir.

Transfer Öğrenme

Transfer öğrenme, bir görev için geliştirilen bir modelin, ikinci bir görevdeki bir model için başlangıç noktası olarak yeniden kullanıldığı bir makine öğrenimi yöntemidir. Sinir ağı modelleri geliştirmek için gereken geniş bilgi işlem ve zaman kaynakları göz önüne alındığında, önceden eğitilmiş modellerin bilgisayarla görü ve doğal dil işleme görevlerinde başlangıç noktası olarak kullanılması derin öğrenmede popüler bir yaklaşımdır.



Şekil 1. Veri Seti İçindeki Örnek Görüntüler

Bu çalışmada, önceden eğitilmiş modellerin çıktı katmanları atılmıştır. Sınıf sayısı ile eşleşen yeni bir sınıflandırma başlığı eklenmiştir. Model, veri seti üzerinden yeniden eğitilerek, önceden eğitilmiş ağırlıkların değiştirilmesiyle yeni sınıflandırmayı öğrenir. Sınıflandırma başlığı, çıktı boyutu 512 olan tam bağlı (FC) bir katmandan, bir bırakma (dropout) katmanından ve 4 sınıf çıktısı olan son bir sınıflandırma katmanından oluşur.

Model eğitimi, $1e-5$ başlangıç öğrenme hızı, 32 batch size ve 25 iterasyon sayısı (epoch) ile gerçekleştirildi. Optimize edici olarak AdamW metodu kullanıldı. Her 10 iterasyon sonrası öğrenme hızı onda birine düşürüldü. AdamW, Adam metodundaki ağırlık azalması yöntemini değiştiren stokastik bir optimizasyon yöntemidir. Adam metodunun yakınsamasını ve performansını iyileştirmek için ayrıştırılmış bir ağırlık azalması formülü ve bir AMSGrad varyantı kullanır.

BULGULAR VE TARTIŞMA

Bu çalışmada, modellerin performansını değerlendirmek için dört metrik kullanılmıştır. Bu göstergelerden kesinlik (precision), geri çağırma (recall) ve doğruluk (accuracy) aşağıdaki denklemler ile ifade edilir.

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (1)$$

$$\text{Geri çağırma} = \frac{TP}{TP+FN} \quad (2)$$

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

Bu denklemlerde TP gerçek pozitiflerin, TN gerçek negatiflerin, FP yanlış pozitiflerin ve FN yanlış negatiflerin sayısını gösterir.

F_1 puanı, kesinlik ve geri çağırma arasındaki harmonik ortalamadır. Kesinlik ve geri çağırma arasında bir denge bulunması gerekiyorsa veya eşit olmayan bir sınıf dağılımı varsa, o zaman F_1 puanı önemlidir (Denklem 4).

$$F_1 = \frac{2 \cdot \text{Geri Çağırma} \cdot \text{Kesinlik}}{\text{Geri Çağırma} + \text{Kesinlik}} \quad (4)$$

Tablo 1. Makro Ortalama Metrikleri (%)

Model	Doğruluk	Kesinlik	Geri Çağırma	F1 Puanı
EfficientNet B7	94,7	96,0	94,4	95,2
Resnet152	93,8	94,0	94,6	94,3
ResNext101	94,4	95,6	93,7	94,6
ConvNext	96,0	96,9	96,1	96,4

Tablo 2. Covid-19 Tespit Metrikleri (%)

Model	Doğruluk	Kesinlik	Geri Çağırma	F1 Puanı
EfficientNet B7	95,3	97,5	95,3	96,4
Resnet152	97,2	92,9	97,2	95,0
ResNext101	97,5	95,9	97,5	96,7
ConvNext	98,1	97,8	98,1	97,9

Tablo 3. Her sınıf için F₁ Puanları (%)

Model	Covid-19	Normal	Opaklık	Viral
EfficientNet B7	96,4	95,1	92,7	96,6
Resnet152	95,0	94,3	91,8	95,9
ResNext101	96,7	94,6	92,5	94,6
ConvNext	97,9	96,2	94,2	97,4

Makro ortalama metrikleri için elde edilen sonuçlar Tablo 1'de gösterilmektedir. Makro ortalama metrikleri, bütün sınıfların metriklerinin ortalamasının alınmasıyla oluşturulur. Modellerin hepsi, %94 ila %97 arasında metriklere sahiptir. Bu da genel tespit için iyi performansın işaretidir. ConvNext, bu dört CNN varyantının içindeki en iyi model olarak ortaya çıkmıştır. ConvNext'in genel olarak geri çağırma ve kesinliği %96'nın üzerindedir, bu nedenle yalnızca gerçek pozitifleri yakalamak için değil, aynı zamanda yanlış pozitifleri en aza indirmek için de iyidir. EfficientNet B7 ikinci en iyi modelken, ResNet152 genel olarak en kötü performansı göstermiştir.

Tablo 2, Covid-19 tespit metriklerini göstermektedir. Bu metrikler yalnızca Covid-19 sınıflandırma performansı üzerinden hesaplanmıştır. Gene bütün modeller yüksek doğruluklar göstermektedir. ConvNext, bu dört CNN mimarisi içinde yine en iyi modeldir ve bu da onu Covid-19 teşhisi için en iyi aday yapar. ConvNext için bütün metrikler %98 civarındadır, bu nedenle hem Covid-19 pozitiflerini hem de negatiflerini tespit etmek için iyi bir modeldir. F₁ puanına bakılırsa, EfficientNet B7 ve ResNext101 benzer performans göstermektedir. ResNet152 en kötü F₁ puanına sahiptir.

Tablo 3, her sınıf ve her model için F₁ puanlarını gösterir. ConvNext, %97,9 ile Covid-19 görüntüleri için en yüksek puana sahiptir. EfficientNet B7 ve ResNext101, Covid-19 için benzer F₁ puanlarına sahipken, en düşük puanı ResNet152 almıştır. Tüm modeller, Opaklık sınıfı için en düşük puana sahiptir. Bu yüzden Opaklık sınıfı dört sınıf arasından tespit edilmesi en zor sınıftır.


Şekil 2, en iyi CNN modeli olan ConvNext için karışıklık matrisini göstermektedir. Opaklık sınıfı, dört sınıf arasında en küçük geri çağırma sahiptir. Opaklık sınıfı ile normal sınıf arasında yanlış sınıflandırılma olmuştur. Normal ve viral sınıflar arasında da karışıklık vardır. Bazı covid görüntüleri de normal olarak değerlendirilmiştir. Bunların dışında sınıflar arasında yanlış negatifler veya pozitifler çok azdır.

Şekil 3, bu çalışmadaki en kötü CNN modeli olan Resnet152 için karışıklık matrisini göstermektedir. Normal ve opaklık sınıfları arasında önemli bir karışıklık vardır. Şekilde viral-normal sınıflar arasındaki karışıklık da görülebilir. Covid-19 için yanlış negatifler ve pozitifler çoğunlukla opaklık ve normal sınıflarından gelmektedir.

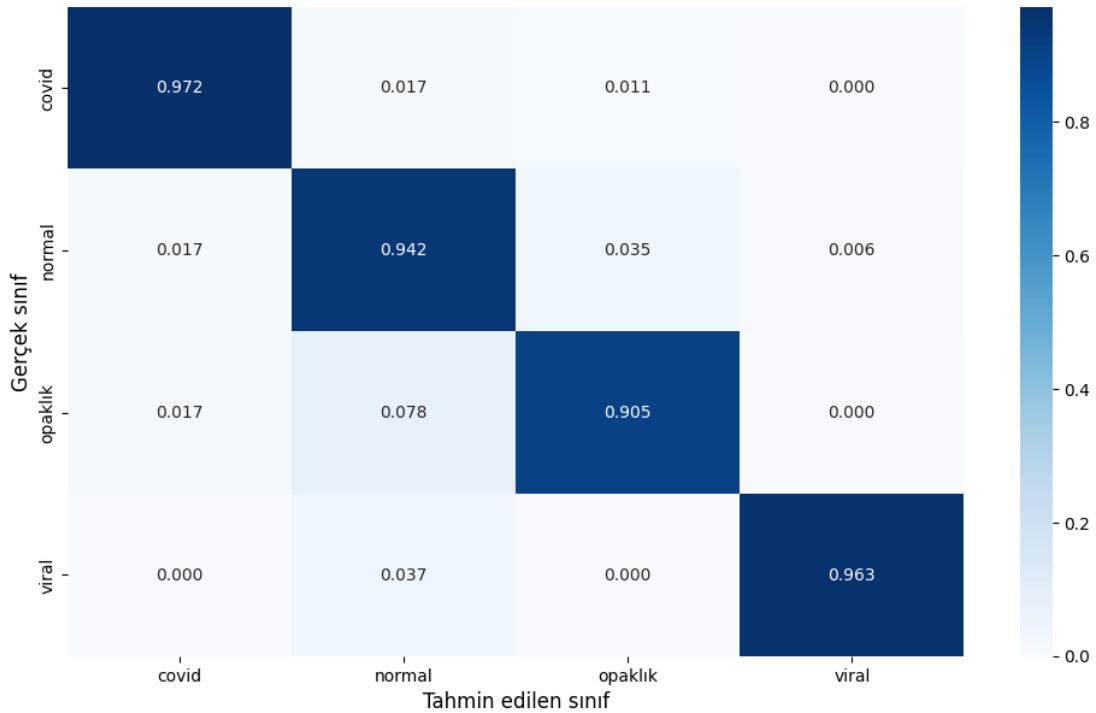
SONUÇLAR

Bu çalışmada, en kapsamlı halka açık Covid-19 veri setlerinden biriyle, Covid-19'un tespiti için en gelişmiş CNN tabanlı sinir ağı mimarilerinin performansı değerlendirilmiş ve karşılaştırılmıştır. Kıyaslanan ağlar şunlardır:

ResNet152, ResNext101, EfficientB7 ve ConvNext. Tüm modellerin makro ortalaması %94 ila %97 arasındadır ve bu da genel algılama için modellerin iyi performansı olduğunu gösterir.



Şekil 2. ConvNext Karışıklık Matrisi



Şekil 3. ResNet152 Karışıklık Matrisi

ConvNext, bu dört CNN varyantı içindeki en iyi modeldir ve bu da onu tanı için iyi bir seçim haline getirir. ConvNext'in genel doğruluk ve kesinliği %96'nın üzerindedir, bu nedenle yalnızca gerçek pozitifleri yakalamak için değil, aynı zamanda yanlış pozitifleri en aza indirmek için de iyidir. Covid-19 için ConvNext doğruluğu %98,1'dir. Bu da dörtlü sınıflandırma için yapılan CNN çalışmalarının üst sıralarında yer alan bir performanstır.

KAYNAKLAR

- Apostolopoulos, I. D. & Mpesiana, T. A. (2020). COVID-19: Automatic detection from x-ray images utilizing transfer learning with convolutional neural networks. *Physical and Engineering Sciences in Medicine*, 43(2), 635–640.
- Arias-Garzo'n, D., Alzate-Grisales, J.A., Orozco-Arias, S., Arteaga-Arteaga, H.B., Bravo-Ortiz, M.A., MoraRubio, A., vd. (2021). COVID-19 detection in X-ray images using convolutional neural networks. *Mach Learn Appl*, 6, 100138.
- Chowdhury, M.E., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M.A., Mahbub, Z.B., Islam, K.R., Khan, M.S., Iqbal, A., Emadi, N.A., vd. (2020). Can AI help in screening viral and covid-19 pneumonia?. <https://arxiv.org/abs/2003.13145>.
- Gorbalenya, A. E., Baker, S. C., Baric, R. S., De Groot, R. J., Drosten, C., Gulyaeva, A. A & Ziebuhr, J. (2020). The species severe acute respiratory syndrome-related coronavirus: Classifying 2019-nCoV and naming it SARS-CoV-2. *Nat Microbiol*; 5, 536–44.
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Deep Residual Learning for Image Recognition. <https://arxiv.org/abs/1512.03385>.
- Khan, A. I., Shah, J. L. & Bhat, M. M. (2020). CoroNet: A deep neural network for detection and diagnosis of COVID-19 from chest x-ray images. *Computer Methods & Programs in Biomedicine*, 196(26), 105581.
- Kucirka, L. M., Lauer, S. A., Laeyendecker, O., Boon, D. & Lessler, J. (2020). Variation in false-negative rate of reverse transcriptase polymerase chain reaction-based SARS-CoV-2 tests by time Since exposure. *Annals of Internal Medicine*, 173(4), 262–267.
- Liu, Z., Mao, H., Wu, C., Feichtenhofer, C., Darrell, T., & Xie, S. (2022). A ConvNet for the 2020s. <https://arxiv.org/abs/2201.03545>.
- Minaee, S., Kafieh, R., Sonka, M., Yazdani, S., & Jamalipour Soufi, G. (2020). Deep-COVID: Predicting COVID-19 from chest X-ray images using deep transfer learning. *Med Image Anal*, 65, 101794.
- Ozturk, T., Talo, M., Yildirim, E.A., Baloglu, U.B., Yildirim, O., & Rajendra Acharya, U. (2020). Automated detection of COVID-19 cases using deep neural networks with X-ray images. *Computers in Biology and Medicine*, 121, 103792.
- Phelan, A. L., Katz, R. & Gostin, L. O. (2020). The novel coronavirus originating in Wuhan, China: Challenges for global health governance. *JAMA*, 323(8), 709– 710.
- Rahman, T., Khandakar, A., Qiblawey, Y., Tahir, A., Kiranyaz, S., Kashem, S.B.A., Islam, S.T., Maadeed, S.A., Zughair, S.M., Khan, M.S., & Chowdhury, M.E. (2021). Exploring the Effect of Image Enhancement Techniques on COVID-19 Detection Using Chest X-ray Images. *Computers in Biology and Medicine*, 132, 104319.
- Sethy, P.K., Behera, S.K., Ratha, P.K., & Biswas P. (2020). Detection of coronavirus Disease (COVID-19) based on Deep Features and Support Vector Machine. *Int J Math Eng Manag Sci*, 5(4), 643–651.
- Tan, M., & Le, Q.V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. <https://arxiv.org/abs/1905.11946>.
- Umer, M., Ashraf, I., Ullah, S., Mehmood, A., & Choi, G.S. (2022). Covinet: A convolutional neural network approach for predicting covid-19 from chest x-ray images. *Journal of Ambient Intelligence and Humanized Computing*, 13(1), 535–547.
- Wang, C., Horby, P. W., Hayden, F. G. & Gao, G. F. (2020) A novel coronavirus outbreak of global health concern. *Lancet (London, England)*, 395(10223), 470– 473.
- Wang, L., Lin Z. Q., & Wong, A. (2020). Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images. *Scientific Reports*, 10(1), 1–12.
- Wang, L., Lin, Z.Q., & Wong, A. (2020). COVID-Net: a tailored deep convolutional neural network design for detection of COVID-19 cases from chest X-ray images. *Sci Rep*, 10(1), 19549.
- Xie, S., Girshick, R., Dollár, P., Tu, Z., & He, K. (2016). Aggregated Residual Transformations for Deep Neural Networks. <https://arxiv.org/abs/1611.05431>.