



COVID-19 Tespiti için Akciğer BT Görüntülerinin Bölütlenmesi

Buket Kaya^{1*}, Muhammed Önal²

¹ Fırat Üniversitesi, Elazığ Organize Sanayi Bölgesi MYO, Elektronik ve Otomasyon Bölümü, Elazığ, Türkiye (ORCID: 0000-0001-9505-181X), bkaya@firat.edu.tr

² Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Ekobilişim Bölümü, Elazığ, Türkiye (ORCID: 0000-0001-5335-867X), muhammedonal@hotmail.com.tr.

(1st International Conference on Applied Engineering and Natural Sciences ICAENS 2021, November 1-3, 2021)

(DOI: 10.31590/ejosat.1015061)

ATIF/REFERENCE: Kaya, B. & Önal, M. (2021). Covid-19 Tespiti için Akciğer BT Görüntülerinin Bölütlenmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (28), 1296-1303.

Öz

Günümüzde her alanda olduğu gibi medikal alanda da teknolojinin hızla ilerlemesiyle birlikte teşhis ve tedavi için ulaşılabilir medikal cihazların sayısı artmaktadır. Hastalar açısından, doğru zamanda, doğru medikal yaklaşımlarla alınan sağlık hizmeti oluşabilecek hayati riskleri önlemektedir. Özellikle tıbbi görüntülerdeki gelişmeler ve yapay zekâ ile paralel gelişimi hekimlere yardımcı, karar destek sağlayıcı sistemlerin ortaya çıkmasını sağlamaktadır. Bunun en önemli nedenlerinden biri yapay zekânın çoğu alanda olduğu gibi sağlık hizmetlerinde de insan kaynaklı hataları minimize etmesidir. Medikal görüntülerin hekimler tarafından yorumlanarak teşhis konulması zaman açısından maliyetli işlemlerdir. Medikal görüntülerin yapay zekâ tekniklerinden faydalanılarak teşhisin koyulması, sınıflandırılması ve otomatik hale getirilmesi hekimlere karar destek sağlayarak iş yükünü hafifletecektir. Çalışmamızda, Covid-19 (2019-nCoV) tespiti için BT Toraks (BT Göğüs) görüntülerinden akciğer dokusunun segmente edilerek bu işlemdeki başarısı ele alınan model geliştirilmiştir.

Anahtar Kelimeler: Derin Öğrenme, Covid-19, Bölütleme, U-Net, Bilgisayarlı Tomografi, Medikal Görüntü Bölütleme

Segmentation of Lung CT Images for COVID-19 Detection

Abstract

Today, as in every field, the number of accessible medical devices for diagnosis and treatment is increasing with the rapid advancement of technology in the medical field. Especially the developments in medical images and its parallel development with artificial intelligence enable the emergence of decision support systems that help physicians. One of the most important reasons for this is that artificial intelligence minimizes human-induced errors in health services, as in most areas. Diagnosis by interpreting medical images by physicians is costly in terms of time. Diagnosing, classifying and automating medical images by using artificial intelligence techniques will ease the workload by providing decision support to physicians. In our study, a model was developed for the detection of covid-19 (2019-nCoV) by segmenting the lung tissue from CT Thorax (CT Chest) images, and the success of this procedure is discussed.

Keywords: Deep Learning, Covid-19, Segmantation, U-Net,Computed Tomography, Medical Image Segmantation.

* Sorumlu Yazar: bkaya@firat.edu.tr

1. Giriş

İlk olarak Çin'in Wuhan kentinde ortaya çıkan COVID-19 (SARS-CoV-2) salgını, küresel bir salgın olarak tüm dünyaya yayılmıştır. 12 Ekim 2021 itibariyle, pandemi nedeniyle dünya çapında 4,8 milyon ölüm ve 6,3 milyar aşı dozu dahil olmak üzere 237 milyondan fazla insan enfekte olmuştur [1]. Bilim adamları, bu küresel salgının yayılma hızını azaltmak için tanı ve tahmine yardımcı olacak testler, ilaç ve aşı keşfi ile mücadeleye katkı sağlarken, bilgi teknolojileri de erken teşhis hususunda çalışmalarına devam etmektedir. Çünkü covid-19 hastalarının teşhisini değerlendirmek için etkili araçlara acil bir şekilde ihtiyaç vardır. Günümüzde tıbbi alandaki gelişime paralel olarak mühendislik alanındaki gelişmeler de hastalıkların teşhis ve tedavisine ciddi katkı sağlamaktadır. Bir insanda hastalığın ortaya çıkışı sürecinden önceki evreden başlayarak akabinde hastalığın seyrindeki değişimleri gözleminin en önemli yöntemlerinden biri de görüntüleme yöntemi olduğundan, sağlık hizmetleri alanında görüntü işleme ile ilgili çalışmalar ivme kazanmıştır. Medikal görüntülerin değerlendirilmesi ve yorumlanması oldukça uzmanlık gerektiren kompleks işlemlerdir. Uzman hekimler tarafından görüntüleme alanında yapılacak hatalı raporlamalar yanlış tedaviye yol açabileceği göz önünde bulundurulması gerekmektedir. Bu anlamda geleneksel yöntemlere nazaran insan hatalarını minimize etmek, teşhis ve tanının erken konulmasını sağlamak için tıbbi görüntüleme alanında yapay zekâ tekniklerinden olan derin öğrenmenin oldukça katkı sağladığı görülmüştür. Çünkü derin öğrenme ile çok katmanlı görüntüler üzerinden performansı yüksek sonuçlar alınmaktadır.[2]

Çeşitli hastalıkların tespiti ve sınıflandırılması için makine öğrenmesi, derin öğrenme ve yapay zekâ tabanlı yaklaşımlar kullanılmaktadır [3]. Bu nedenle tıbbi görüntüleme alanında kullanılan derin öğrenme mimarilerinden biri olan CNN (Evrışimsel Sinir Ağları) oldukça etkili olmuş ve başarılı sonuçlar elde edilen bir çok çalışma geliştirilmiştir. Çalışmamız, iki sınıfa ait (normal ve covid) BT görüntülerini sınıflandırmak için derin öğrenme tabanlı bir model tasarlamış, ardından bu görüntülerden covid-19 enfekte olmuş kişinin akciğer dokusunun segmente edilerek sınıflandırılması sağlanmıştır

2. Materyal ve Metot

2.1. Veri Seti

Veri seti için erişime açık kaynaklara başvurulmuştur. Bu veri seti, Sinir Ağlarını eğitmeyi sağlamış ve ardından sonuçların hesaplanmasında kullanılmak üzere görüntüler manuel olarak segmente edilerek oluşturulan veri setine kaydedilmiştir. Önerilen modelin ve çalışmanın başlıca katkıları şu şekildedir:


1. Veri seti, açık kaynaklı kaynaklardan alınan iki sınıflı BT görüntüleri (covid ve normal) ile hazırlanmıştır.
2. Modelin performansını daha iyi hale getirmek için modelde performans iyileştirme yöntemleri uygulanmıştır.
3. Kullanılan görüntülerin yetersizliğinden dolayı veri artırma teknikleri kullanılmıştır.
4. Modeldeki ezberlemeyi (overfitting) ve dolayısıyla genelleme hatasını en aza indirmek için bazı normalleştirme yapılarak evrişim bloğu eklenmiştir.

Çalışmada kullanılan kaynak ve veri setleri için (Ör:covid-19 makaleleri, BT görüntüleri ve diğer verisetleri) genel kabul görülen Radiopaedia, Kaggle, Google scholar, Github, Science Direct gibi veritabanları taranarak kullanılmıştır.

Bu tür açık kaynaklı veri setlerinin en önemli sorunu genellikle görüntülerin yetersiz sayıda olmasının yanı sıra düzensiz ve kategorize olmamasından dolayı derin öğrenme modellerinin öğrenme ve tahmin yeteneklerini ciddi oranda etkilemektedir.

Çalışmada, .nii (neuroradiology) türünde 20 vakaya ait dosya olmak üzere her biri ayrı gri tonlamalı BT toraks kesit görüntüsünü içeren ve Kaggle veritabanından alınan bir veriseti kullanılmıştır. Bu veri setindeki veriler Brezilya, Sao Paulo'daki hastanelerdeki gerçek hastalardan alınan public bir verisetidir[4]. Verisetindeki toplam kesit sayısı 3520'dir. Veri setindeki vakalardan ağır eğitimi ve testleri için %80 ve %20 oranında kullanılmıştır.

Her iki sınıfta örnek görüntüler Şekil 1'de gösterilmektedir.



Şekil 1 . Önerilen modelinin eğitimi ve değerlendirilmesi için kullanılan örnek BT görüntüleri.

2.2. Yöntem

Pnömoni görüntüleri gibi tıbbi görüntülerden covid-19 teşhisi koyma ve covid-19 tespitinin yapılması temel olarak bir görüntü sınıflandırma problemidir. Bu tür sınıflandırmada ise görüntüye ait özelliklerin yakalanması önem arz ettiğinden görüntü sınıflandırma da bazı problemler sıklıkla yaşanmaktadır. Görüntülerin farklı dokusal özellikler içermesi, görüntünün gürültülü olması, zaman maliyeti vb. problemler görüntünün başarılı bir şekilde sınıflandırmasını olumsuz etkiler. Çalışmamızda, makine öğrenmesi tekniklerinden olan Derin Öğrenme (*Deep Learning*) kullanılmıştır. Bu bağlamda BT toraks görüntülerini (normal, covid) sınıflandırmak için Derin Öğrenme mimarilerinden biri olan Yapay Sinir Ağları (ANN) tabanlı Evrişimli Sinir Ağları (CNN) kullanılmıştır. Yapılan birçok çalışmada CNN'nin, sınıflandırma performansı ile geleneksel makine öğrenmesi yöntemlerinden daha üstün olduğu görülmüştür[5].

Bu bölümde önerilen modelin tüm detayları ve çalışma sürecinde atılan adımlar özetlenmektedir. Öncelikle çalışmada kullanılan derin öğrenme yöntemine kısaca değinilmiş, ardından veri setini elde etme süreçlerine ve son olarak da model oluşturma sürecine yer verilmiştir. Modeli oluşturmak için Python açık kaynak yazılımı ve Keras Kütüphanesi kullanılmıştır.

Bu çalışma, 3 ana görevden oluşmaktadır. Bunlar;

- 1- Covid-19 ile enfekte olmuş bölgenin bölütlenmesi


Önerilen Metrik: Dice Coefficient, IoU (Jaccard Index)

- 2- Covid-19'un sınıflandırılması (normal, covid)

Önerilen Metrik: AUROC, F1-Score

3- Akciğer dokusunun bölütlemesi

Önerilen Metrik: *Dice Coefficient, IoU (Jaccard Index)*



Şekil 2. Örnek Veri

Evrişimsel Sinir Ağları teknikleri derin öğrenme yaklaşımıdır. Derin Öğrenme, doğrusal olmayan problemlere birden fazla katman kullanarak çözümler sunan bir yöntemdir. Genellikle video analizi, konuşma tanıma, görüntü sınıflandırma, bilgi alma, nesne tanıma ve doğal dil öğrenme gibi alanlarda kullanılmaktadır [6-7]. Ancak derin öğrenme uygulamaları yaparken belirli bir problem için hangi modelin seçileceğini belirlemede birkaç soru dikkate alınmalıdır. Bunlar;

1. Üretken mi yoksa ayırmacı bir model mi kullanılmalı?
2. Verilerin özellikleri nelerdir?
3. Girilen değerlerin boyutu nedir?

Bu anlamda amaç sınıflandırma ise *ayırt edici* bir model kullanılması uygun olacaktır.

2.2.1. Pre-Processing

Görüntünün kullanıma hazır hale getirilmesi aşamasıdır. Görüntülerde bulunan gereksiz kısımlar kırılarak belirli bir kontrast aralığına getirilmesi sağlanmaktadır. Ardından yoğunluk normalize edilip, gürültülü alanlar temizlenmiştir. Aşağıdaki adımlar izlenmiştir;

1. Eksik ve hatalı görüntüler kaldırılması
2. Boş maske tahmini için ayrı model
3. Görüntü iyileştirme için Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme kullanımı
4. Otsu'nun ikileştirme (*Otsu's binarization*) ve diğer yaklaşımlarını kullanarak enfekte olmuş bölgenin (*ROI*) kırılması
5. Veri Arttırma (*Data Augmentation*)


2.2.2. Veri Arttırma (*Data Augmentation*)

Veri arttırma (*data augmentation*), mevcut veri kümesinden ekstra veri elde etmek için kullanılan bir yöntemdir. Bu durumda mevcut görüntülerin bozuk kopyalarını oluşturur. Temel amaç, sinir ağını çeşitli çeşitliliklerle güçlendirmek, bu da veri setindeki benzer ve alakasız özellikleri ayırt eden bir ağa yol açmaktır. Görüntü arttırma birkaç teknik kullanılarak yapılabilir. Veri mevcudiyeti ve kalitesine göre gerektiğinde büyütme teknikleri verimli bir şekilde kullanılmaktadır. Teklifimiz, farklı koşullar için çok sayıda veri kümesini desteklemek için birden çok tekniği aşağıdaki gibi entegre eder:

- Döndürme (*Rotation*): görüntü -10° ile 10° arasında bir aralık içinde döndürülür.
- Yakınlaştırma (*zoom*): görüntüyü yakınlaştırarak veya uzaklaştırarak ölçeklendirmek de verisini artırır.
- Kesme (*Shear*): görüntü kesme, üç boyutlu imitasyon faktörü ile döndürme kullanılarak gerçekleştirilebilir.

- Gauss bulanıklığı (*Gaussian blur*): Bir Gauss filtresi kullanılarak, görüntünün bulanık bir versiyonuna neden olan yüksek frekans faktörleri ortadan kaldırılabilir.

Bu yöntemler kullanılarak veri seti artırılmış ve eğitim aşamasında kullanılmıştır. Bununla birlikte, test aşamasında, test seti genişletilmeyecektir. Bu, mimarinin sağlamlığını ortaya koyacak ve ezberlemeyi önleyecektir.



Şekil 3. Data Augmentation ile artırılan BT görüntüleri

2.2.3. Görüntü Bölütleme (*Image Segmentation*)

Görüntü bölütleme (*image segmentation*), görüntü analizi ile ilgili bir problem olup görüntü işlemenin gösterim ve tanılama aşamalarına görüntüyü hazırlama işlemidir.[12]

Yapılan çalışmalar göz önünde bulundurulduğunda *en iyi* denilebilecek bir görüntü segmentasyon modeli bulunmadığını söyleyebiliriz. Her segmentasyon modelinin başarısı yapılan çalışmanın ve kullanılan görüntünün türüne göre değişiklik gösterebilmektedir. Tıbbi görüntü segmentasyon işlemi de dokuların ölçümü, anormalliklerin tespiti ve bu gibi işlemlerin sınıflandırılmasıdır. Tıbbi görüntü segmentasyonunun amacı, ilgilenilen bölgelerin (*ROI: Region of Interest*) otomatik tanımlanması ve etiketlenmesidir.

Bilgisayarlı Tomografi (BT) görüntülerinden arter veya kemiğin ayrıştırılması işlemi ile görüntü segmentasyonu yapılabilmektedir. Tıbbi görüntüleme segmentasyon işlemi 2 boyutlu ve 3 boyutlu olarak yapılabilmektedir. Akciğer görüntülerinin segmente edilmesi ise covid veya diğer hastalıkların tespit edilmesi mümkün olmaktadır. Bu işlem, covidli dokunun segmentasyon işlemi ile akciğer dokusundan ayırt edilerek yapılabilir.[13]

Herhangi bir Akciğer BT görüntüsü ele alındığında görüntüdeki boşluklu yapıların siyah, içi dolu olan yapıların ise beyaz olarak görüntülediğini görebilirsiniz. Akciğer dokusu boşluklu bir yapıya sahip olduğundan manuel segmente edilecek kısımlar, göğüs kafesinin orta bölgesinde yer alan iki siyah lob şeklinde görüntülenir. Modelimizin otomatik olarak segmentasyon işlemi yapabilmesi için test aşamasında test için ayrılan görüntülerin maskelenmiş akciğer BT görüntülerinden faydalandık. Manuel olarak segmente edilen akciğer BT görüntüleri maske görüntülerinden oluşmaktadır. Bu maske görüntüler binary (ikili) görüntülerdir. Maske görüntülerin oluşması *Uzm.Dr.Abdulkerim Kula*'nın desteği ile sağlanmıştır. Çalışmada, covid-19 ile enfekte olmuş dokunun tespitinin otomatikleştirilmesi için Evrişimli Sinir Ağı tabanlı U-Net mimarisi kullanılarak en yüksek doğruluk ve en düşük hata oranının elde edilmesi amaçlanarak modelimiz oluşturulmuştur.




Şekil 4. Manuel segmente edilen bir akciğer görüntüsü

Çalışmamız, covid-19 ile enfekte olmuş bölgelerin otomatik olarak segmente edilmesi ile hekimler için klinik karar destek sağlayacaktır.

2.2.4. Derin Öğrenme (Deep Learning)

Derin öğrenme, özellik çıkarma ve dönüştürme için birçok doğrusal olmayan işlem birimi katmanını kullanır. Her ardışık katman, önceki katmandaki çıktıyı girdi olarak kullanır. Böylelikle Derin Öğrenme, ham veri kümesinden özellikleri otomatik çıkarabilen yeni bir makine öğrenme tekniğidir. Esasen derin öğrenme, geleneksel makine öğreniminin daha gelişmiş bir sürümüdür diyebiliriz. Denetimli (supervised) ve denetimsiz (unsupervised) olmak üzere iki çeşit derin öğrenme vardır.[8]



Şekil 5. Derin Öğrenme Türleri

2.2.5 Evrişimsel Sinir Ağı (Convolutional Neural Network)


Derin öğrenmenin en başarılı modellerinden biridir. Evrişimsel Sinir Ağı, CNN yada ConvNet olarak da bilinmektedir. CNN, en basit tanımıyla bir girdi görüntüsünü alıp, görüntüde ki çeşitli nesnelere birbirinden ayırabilen derin öğrenme modelidir. Evrişimsel Sinir Ağı, birden fazla katmana sahiptir. Temel bir Evrişimsel Sinir Ağı'nın ilk birkaç evresi Evrişim Katmanı (Convolution Layer) ve Havuzlama Katmanından (Pooling Layer) oluşmaktadır. Son aşamada ise tam bağlı katmandan (Fully Connected Layer) oluşur. Akabinde ise sınıflandırma katmanı bulunmaktadır.[9]

Derin Öğrenme ve bilgisayarlı görü (*computer vision*) konusunu incelediğimizde karşımıza ilk model olan Evrişimli Sinir Ağı çıkacaktır. Bu tür ağları diğer derin öğrenme yöntemlerinden ayıran en büyük özelliği girdi olarak görüntünün kendisini almasıdır. Diğer derin öğrenme modellerinde giriş vektör biçimindedir. CNN, doğrudan giriş verileri olarak 2 boyutlu ve 3 boyutlu görüntüleri kullanır.

Evrişimsel Sinir Ağı'nın en önemli avantajları şunlardır;

1.Evrişimsel filtre ve havuzlama katmanlarını kullanarak görüntüden daha fazla bilgi alabilir ve eğitilecek ağ parametresini önemli ölçüde azaltabiliriz. 2.CNN'nin bir diğer önemli özelliği de ağırlık paylaşımıdır (*weight sharing*). (*partial addition*)

3.CNN'nin lokal bağlantı (*local connectivity*) özelliğinden bahsedebiliriz. (*partial independence*)




Şekil 6. CNN Genel Mimarisi

Şekil 6'de görüldüğü üzere Evrişimsel Sinir Ağı, ard arda yerleştirilmiş birden fazla eğitilebilir bölümlerden oluşmakta olup ardından eğitici bir sınıflandırıcı ile devam edilmektedir. CNN, giriş verilerini aldıktan sonra katman katman işlemler gerçekleştirerek eğitim süreci tamamlanır. Sonunda doğru sonuç ile karşılaştırma yapmak için bir sonuç çıktısı verir. Oluşan sonuç ile istenen sonucun farkı kadar bir hata oluşmaktadır. Bu hatanın tüm ağırlıklara aktarılması için back propagation (*geriye yayılım*) algoritması kullanılmaktadır. Her bir yineleme ile ağırlıkların güncellemesi yapılarak hatanın azaltılması sağlanmaktadır.

Evrişimsel Sinir Ağı'nı oluşturan katmanlardan **Giriş Katmanı (Input Layer)**; Evrişimsel Sinir Ağı'nın ilk katmanını oluşturmada olup bu katmanda veriler ağa ham veri olarak verilmektedir. Bu katmanın en önemli özelliklerinden biri tasarlanacak modelin başarılı olabilmesi için katmandaki verinin boyutu çok önem arz etmektedir. Çünkü, giriş görüntüsünün boyutu ne kadar yüksek olursa (yüksek bellek ihtiyacı, eğitim süresi ve görüntü başına düşecek test süresinin uzatılması vb.) ağın başarılı olmasıyla birlikte yüksek performans sağlanır. Sonraki katman ise **Evrişim Katmanı (Convolution Layer)**; özellikleri saptamak için kullanılan katmandır. Girdiği birleştirir ve sonucunu bir sonraki katmana iletir. Bu katmana dönüşüm katmanı da denilebilir. Dönüşüm katmanı denilmesinin sebebi, dönüşüm işlemi belirli bir filtrenin tüm görüntü üzerinde dolaştırılmasıdır. Bu filtreler 2x2, 3x3, 5x5 gibi farklı boyutlarda olabilmektedir. Bu filtreler, bir önceki katmandan gelen görüntülere evrişim işlemi uygulayarak çıkış verisini oluşturur. Bu evrişim işlemi sonucunda özellik haritası (feature maps) oluşur. Özellik haritası, her bir filtreye özgü özelliklerin keşfedildiği bölgelerdir. Evrişim katmanından sonra **ReLU** olarak adlandırılan **düzeltilmiş doğrusal birim katmanı** gelmektedir. Evrişimsel Sinir Ağı nöronlarının çıktuları devreye alınan doğrultucu birimdir. Aktifleşme (*activation*) katmanı olarak da bilinmektedir. Bu katman, giriş verisine yapmış olduğu etki ile negatif değerleri sıfıra çekmektedir. Evrişim katmanında belirli matematiksel işlemler uygulandığından ağ doğrusal bir yapıda olup doğrusal olmayan bir yapıya dönüştürmek için ReLU katmanı uygulanır. Bu katmanın kullanılması ile ağın daha hızlı öğrenmesi sağlanmaktadır. Bu katmandan sonra genellikle **havuzlama (pooling) katmanı** gelmektedir. Havuzlama katmanının en temel amacı, sonraki evrişim katmanı için giriş boyutunu azaltmaktır. Boyuttaki azalma ise bilgi kaybına (*loss of information*) neden olmaktadır. Bilgi kaybı ise, bir sonraki ağ katmanları için daha az hesaplama yükü oluşturarak aynı zamanda sistemin ezberlemesini (*overfitting-aşırı öğrenme*) önlediğinden bir avantaja dönüştürmüş olur. Evrişimsel Sinir Ağı'nda havuzlama katmanı zorunlu değildir. Bazı modeller bu katmanı kullanmamaktadır. İlk basamaktaki evrişim işlemi gibi havuzlama katmanında da belli filtreler tanımlanmaktadır. Maksimum havuzlama (*MaxPooling*) genellikle daha iyi performans gösterdiğinden tercih edilirken bu işlemi filtrelerin, görüntü üzerinde belli bir adım atma değerine göre (*stride – adım kaydırma*) gezdirilerek görüntüdeki piksellerin maksimum değerlerini alarak gerçekleştirir. Belirtilen stride değeri artırılıp azaltılabileceği için gerçekleştirilen stride değerine göre çıktı boyutu da değişmektedir. Şekil 2'deki CNN mimarisini incelediğimizde ard arda gelen evrişim (convolution), ReLu ve havuzlama (pooling) katmanından sonra **tam bağlı katman (fully connected layer)** geldiğini görmekteyiz. Ancak tam bağlı katmandan önce **Flatten Layer** katmanı yer almaktadır. Bu katmanın en temel ifadeyle görevi tam bağlı katmanın (fully connected layer) girişindeki verileri hazırlamaktır. Sinir ağları, giriş verilerini tek boyutlu bir diziden almaktadır. Bu sinir

göstermektedir. U-Net mimarisi, bir daralma/kodlayıcı (*contracting path/Encoder*) ve bir genişleme/kod çözücü (*expansive path/Decoder*) yolundan meydana gelmektedir. U-Net mimarisindeki *daralma yolu* ise geleneksel bir evrişimsel ağız tipik mimarisini izlemektedir. 3x3'lük bir evrişim (*convolution*) işleminin iki defa tekrarlanmasından oluşmaktadır. Daha sonra bu işlemi, aktivasyon (*activation*) olarak ReLu (*Düzleştirilmiş Doğrusal Birim Katmanı*) ve alt örnekleme (*downsampling*) için iki stride (*ötelemeli/kaydırmalı*) adım ile 2x2'lik bir maksimum havuzlama (*maxpooling*) işlemleri takip eder. Her alt örnekleme (*downsampling*) işleminde özellik kanalları (*feature channel*) sayısı ikiye katlanmaktadır. Mimarideki *genişleme yolu*'ndaki her adım yukarı örnekleme (*upsampling*) işleminden sonra özellik kanalları (*feature channel*) sayısını yarıya indiren 2x2'lik bir evrişim (*convolution*) işleminden, daralma yolundan karşılık gelen kırılmış özellik (*cropped feature*) eşlemesiyle birleştirme işleminden (*concatenate*) ve 3x3'lük bir evrişim (*convolution*) işleminin iki defa uygulanmasıyla oluşmaktadır. Bu evrişim (*convolution*) işlemlerinde aktivasyon olarak *ReLU* fonksiyonu kullanılmaktadır. Son katmanda ise 64 bileşenli özellik vektörü, istenen sayıda sınıfa eşlenmek için 1x1'lik bir *convolution* işlemi yapmaktadır. Bu ağız toplam olarak 23 evrişim (*convolution*) katmanı bulunmaktadır.

Şekil 10'de görüldüğü üzere modelimizin blok diyagramındaki gibi veri seti birkaç aşamadan geçmektedir. İlk olarak, sonraki blokları daha fazla görüntü ile zenginleştirmek ve modelimizin tanınmasını istediğimiz özel özellikleri vurgulamak için veriler artırılır (*Data augmentation*). Bu işlem, veri setindeki görüntüleri döndürerek (*rotating*), kırarak (*shearing*), yakınlaştırarak (*zooming*) ve bulanıklaştırarak (*blurring*) yapılmaktadır. Bir sonraki adımda ise pre-processing (*ön işleme*) tabii tutulur (*shuffle, resize, normalize*). Bu aşamalar, ağa beslenen verileri birleştirmek için gereklidir. Görüntülerdeki anormallikleri belirler ve bölütlenir (*Lesion Segmentation*). Son olarak, covid-19 sınıflandırıcı modelimiz ile covid-19 ve normal görüntüleri sınıflandırmış oluruz.



Şekil 10. Modelin Mimarisi

3. Araştırma Sonuçları ve Tartışma

3.1. Değerlendirme Metrikleri

Görüntü segmentasyonu için en yaygın kullanılan değerlendirme metrikleri IoU (Intersection over Union) ve Dice Coefficient metrikleridir. *Dice Coefficient*, her iki görüntüdeki (doğru görüntü ve tahmin edilen görüntü) toplam piksel sayısına bölünen örtüşme alanının 2 katıdır. *Dice Coefficient*, IoU'ya çok benzer ve her ikisi de 0 ile 1 arasında değişir ve 1, tahmin edilen ile gerçek arasındaki en büyük benzerliği belirtir. *IoU*, *Ground Truth* ile model tahmini arasındaki örtüşme Jaccard indeksi ile ölçülür. Bu sebeple, *IoU* hesaplaması, iki dikdörtgenin

kesiştikleri alanın (*intersection*) bu iki dikdörtgenin bileşiminin (*union*) alanına bölümü olarak hesaplanır.

Metrik tanımları ise;


$$\text{Dice}(S) = 2|A \cap B| / (|A| + |B|) = 2TP / (2TP + FP + FN)$$

$$\text{IOU}(J) = (|A \cap B|) / (|A \cup B|) = TP / (TP + FP + FN)$$

$$J = S / (S - 2)$$

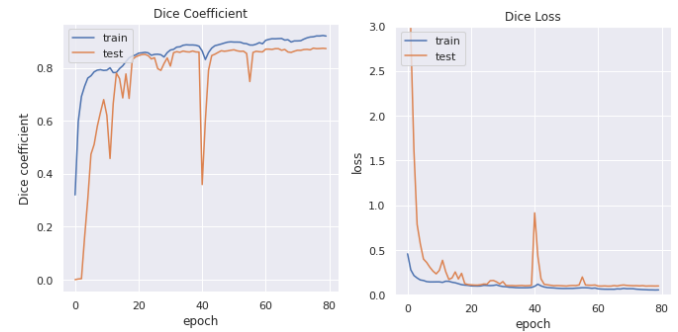
$$\partial J / \partial S = 2 / [(2 - s)]^2$$

(S = 0.586, J = 0.414) için eğim değeri 1'e eşittir.

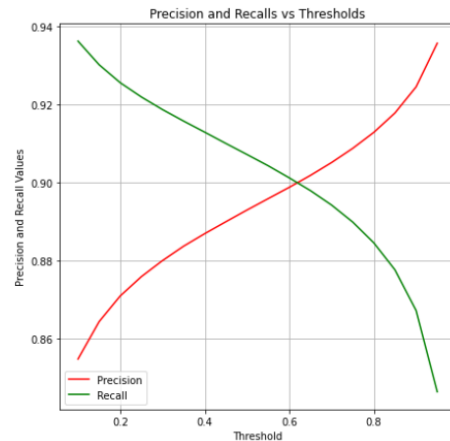


Şekil 11. Dice & IoU ilişkisini gösteren Venn Diyagramı


Şeklindedir.



Şekil 12. Enfekte olan bölgenin segmentasyonu için Dice Coefficient ve Dice Loss için Eğitim Eğrisi



Şekil 13. Precision (Kesinlik) ve Recall (Duyarlılık) Eşikleri




Şekil 14. Sınıflandırma (Classification) Loss Eğrisi

Test verilerinin değerlendirilmesi için evrimsel sinir ağıımızda akciğer bölütlemesi için giriş görüntümüzün boyutunu 128 piksel olarak alarak, 14 katmanlı bir model ile çalıştırdık.

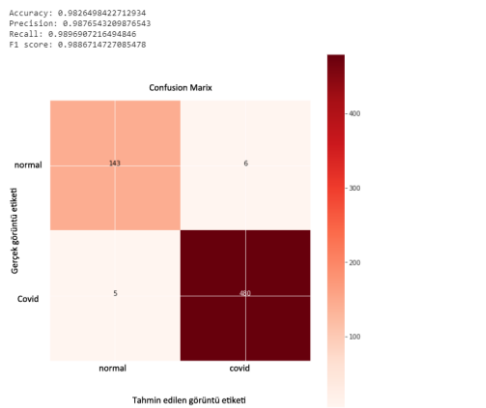
Enfekte olan dokuların bölütlemesi için 39 katmanlı bir model çalıştırdık ve aşağıdaki sonucu elde ettik.

Tablo 1.

	loss	dice coefficient
Akciğer	0.0590	0.9410
Enfekte Bölge	0.4809	0.5191



Şekil 15. Gerçek görüntüler ile tahmin edilen görüntülerin karşılaştırılması



Şekil 16. Gerçek görüntüler ile tahmin edilen görüntülerin karşılaştırılması

Precision (kesinlik) ve recall (duyarlılık) değerleri dice için en iyi eşişe (best threshold) göre dir

	Dice	IoU	Precision (Kesinlik)	Recall (Duyarlılık)	AUCROC	F1 Score	Accuracy (Doğruluk)
Enfekte Dokunun Bölütlenmesi (3-fold)	0.948	0.903	0.947	0.950	-	Dice ile aynı	-
Enfekte Dokunun Bölütlenmesi (4-fold)	0.956	0.917	0.955	0.958	-	Dice ile aynı	-
Sınıflandırma	-	-	0.987	0.989	0.998	0.988	0.982
Akciğer Bölütlenmesi	0.984	0.969	-	-	-	Dice ile aynı	-

Şekil 17. Sonuçlar

Çalışmada günümüzün en büyük salgını olan covid-19 enfeksiyonunun neden olduğu hastalığa dair çalışma gerçekleştirilmiştir. Çalışma, özellikle hekimlere zaman ve maliyet açısından covid-19 tespiti için kaynakların daha etkin kullanılması açısından bir karar destek sağlamaktadır. Çalışmanın her aşamasında uzman desteği alınarak mesafe katedilmiştir. Tıbbi görüntüleme de yapay zekâ tekniklerinden faydalanarak sadece covid-19 bulgularının tespitinde değil diğer tüm hastalıkların tespitinde de etkin kullanılarak erken teşhis, ön görü ve tahmin, radyologlar yada hekimlerin iş yükünü azaltmak, hata payı düşük sistemler ortaya çıkarmak, acil ve öncelikli hastaların sınıflandırılması vb. sağlanabilir.

4. Sonuç

Kullanılan public veri setindeki görüntülerin standardize ve kategorize olmamasından kaynaklı modelin başarısı etkilenmiştir. Çünkü, Medikal görüntülerde, gri seviye (gray level) kontrast değerlerindeki yetersizlik, yüksek gürültü ve tanımsız doku sınırları gibi sorunlarla karşılaşmaktadır. Modelin başarılı olması için, medikal görüntülerdeki gürültülerin minimize edilmesi yada ortadan kaldırılması gerekmektedir. Çalışma kapsamında hala çalışılacak alanları mevcuttur. Bunların iyileştirilmesi ile medikal görüntüleme alanında diğer hastalıkların tespitinde de kullanılabilmesine ön ayak olacaktır.

5. Teşekkür

Eğitimde kullanılan ve manuel olarak segmente edilmiş maske görüntülerini oluşturan sn.Uzm.Dr.Abdulkerim Kula'ya katkılarından ve desteklerinden, ayrıca github'da paylaşmış olduğu çalışmadan dolayı sn.Rohit Verma'ya teşekkür ederiz.

Kaynakça

- [1] <https://covid19.who.int/>, last accessed on 12 Sep 21.
- [2] M. Toğaçar, B. Ergen, "Biyomedikal Görüntülerde derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması," Fırat Üniversitesi Müh.Bilimleri Dergisi 2019; 31(1): 109-121.
- [3] Fraiwan L, Hassanin O, Fraiwan M, Khassawneh B, Ibnian AM, Alkhodari M. Automatic identification of respiratory diseases from stethoscopic lung sound signals using ensemble classifiers. Biocybern Biomed Eng. 2021;41(1):1-14. <https://doi.org/10.1016/j.bbe.2020.11.003>.
- [4] CT scan images: URL: <https://www.kaggle.com/plameneduardo/sarscov2-ctscan-dataset>, last accessed on 15 Sep 2020.
- [5] Chen, X., Xiang, S., Liu, C. L., & Pan, C. H., Vehicle detection in satellite images by hybrid deep convolutional neural networks, IEEE Geoscience and remote sensing letters, 11 (10), 1797-1801, 2014.
- [6] L. Deng and D. Yu, "Deep Learning: Methods and Applications," Found. Trends® Signal Process., vol. 7, no. 3-4, pp. 197-387, 2014.
- [7] Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Chen, T., Recent advances in convolutional neural networks. Pattern Recognition, 2017.
- [8] L. Deng and D. Yu, "Deep Learning: Methods and Applications," Found. Trends® Signal Process., vol. 7, no. 3-4, pp. 197-387, 2014. FLEXChip Signal Processor (MC68175/D), Motorola, 1996.

- [9] Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Chen, T., Recent advances in convolutional neural networks. *Pattern Recognition*, 2017.
- [10] İnik, Ö., Ülker E., Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin öğrenme Modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi (GBAD)*, 85-104, 2017.
- [11] Frid-Adar, M., Diamant, I., Klang E., Amitai, M., Goldberger J., Greenspan H., GAN-based synthetic medical image augmentation for increased CNN performance in liver lesion classification. *Neurocomputing*. 321-331, 2018.
- [12] *Computer Graphics Companion, Image Segmentation*, 2003.
- [13] Memon, N.A., Mirza, A.M. ve Gilani, S.A.M., Segmentation of Lungs from CT Scan Images for Early Diagnosis of Lung Cancer, *Transactions on Engineering, Computing and Technology*, 14, (2006) 228-233.
- [14] J. Padhye, V. Firoiu, and D. Towsley, "A stochastic model of TCP Reno congestion avoidance and control," Univ. of Massachusetts, Amherst, MA, CMPSCI Tech. Rep. 99-02, 1999.