



W+-Net: Derin Öğrenme Tabanlı Görüntü Segmentasyonu ile Covid19 Tespiti

W+-Net: Covid19 Detection with Deep Learning-Based Image Segmentation

Lütfü BAYRAK¹, Kenan KOÇKAYA², Ahmet ÇINAR³

^{1,2} Divriği Nuri Demirağ Meslek Yüksekokulu, Cumhuriyet Üniversitesi, Sivas, TÜRKİYE

³ Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, TÜRKİYE

lbayrak@cumhuriyet.edu.tr—ORCID> [0000-0002-2154-7270](https://orcid.org/0000-0002-2154-7270)

kkockaya@cumhuriyet.edu.tr—ORCID> [0000-0002-5253-1511](https://orcid.org/0000-0002-5253-1511)

acinar@firat.edu.tr—ORCID> [0000-0001-5528-2226](https://orcid.org/0000-0001-5528-2226)

Makale Bilgisi / Article Information

Makale Türü / Article Types	Araştırma Makalesi / Research Article
Alınış Tarihi / Received	11 Mart / March 2025
Kabul Tarihi / Accepted	19 Nisan / April 2025

Yıl / Year: 2025 | **Cilt / Volume:** 2 | **Sayı / Issue:** 1 | **Sayfa / Pages:** 20-25

Atıf Formatı / Cite as: Bayrak, L., Koçkaya, K., Çınar, A., "W+-Net: Derin Öğrenme Tabanlı Görüntü Segmentasyonu ile Covid19 Tespiti", Hendese, Vol. 2, Issue 1, Pages 20-25, 2025.

Sorumlu Yazar / Corresponding Author: Kenan KOÇKAYA

W+-Net: Derin Öğrenme Tabanlı Görüntü Segmentasyonu ile Covid19 Tespiti**Lütfü BAYRAK¹**, **Kenan KOÇKAYA^{*2}**, **Ahmet ÇINAR³**^{1,2*}Divriği Nuri Demirağ Meslek Yüksekokulu, Cumhuriyet Üniversitesi, Sivas, TÜRKİYE³Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, TÜRKİYE

(Alınış / Received: 11.03.2025, Kabul / Accepted: 19.04.2025, Online Yayınlanma / Published Online: 25.04.2025)

Anahtar KelimelerGörüntü Segmentasyonu,
Derin Öğrenme,
U-Net,
W-Net**ÖZ**

2019 yılında Çin'in Wuhan kentinde ortaya çıkan Covid19 hastalığı kısa sürede tüm dünyayı etkisi altına almış ve pandemi olarak nitelendirilmiştir. Hastalığın akciğerde ortaya çıkarak yakalanan kişilerde ölümcül etkiler oluşturması nedeniyle tüm dünyada ciddi tedbirlerin alınmasına sebep olmuştur. Tüm dünyayı kısa sürede etkisine alması ve ölümlerin hızla artması tedavinin de hızlı bir şekilde bulunmasına neden olmuştur. Hastalık tespitinde yapay zekâ destekli çalışmaların artması enfekte olan kişilerdeki anomalilerin tespitinde derin öğrenme tabanlı görüntü segmentasyonunun teşhis işlemlerinde önemli bir çözüm oluşturabileceğini göstermiştir. Yapılan bu çalışmada W+-Net olarak nitelendirilen uyarlanmış bir mimari önerilmektedir. Önerilen bu mimari U-Net ve W-Net mimarileriyle kıyaslanmış ve başarımları deneysel sonuçlarla gösterilmiştir. Kaggle'dan alınan 820 akciğer görüntüsünden oluşan bir veri seti üzerinde yapılan test işleminde zar (dice) benzerlik katsayı değerleri U-Net 0,81; W-Net 0,85 ve W+-Net 0,87 olarak elde edilmiştir. Yapılan bu çalışmada Covid 19 anomalilerin tespitinde önerdiğimiz yöntemin diğer yöntemlere göre daha başarılı olduğu açık bir biçimde görülmektedir.

W+-Net: Covid19 Detection with Deep Learning-Based Image Segmentation**Keywords**Image Segmentation,
Deep Learning,
U-Net,
W-Net**ABSTRACT**

The Covid19 disease, which emerged in Wuhan, China in 2019, quickly affected the entire world and was described as a pandemic. Since the disease occurs in the lungs and causes fatal effects in those who catch it, it has caused serious precautions to be taken all over the world. The fact that it affected the entire world in a short time and the rapid increase in deaths has also led to the rapid discovery of a treatment. The increase in artificial intelligence-supported studies in disease detection has shown that deep learning-based image segmentation can be an important solution in diagnostic processes in the detection of anomalies in infected people. In this study, an adapted architecture called W+-Net is proposed. This proposed architecture has been compared with U-Net and W-Net architectures and its successes have been demonstrated with experimental results. In the test process performed on a dataset consisting of 820 lung images obtained from Kaggle, the dice similarity coefficient values were obtained as 0.81 for U-Net, 0.85 for W-Net and 0.87 for W+-Net. In this study, it is clearly seen that the method we proposed is more successful than other methods in detecting Covid-19 anomalies.

Published by Muş Alparslan University, Muş, Türkiye
This is an open access article under the CC BY-NC license

Corresponding Author / Sorumlu Yazar: kcockaya@cumhuriyet.edu.tr

Cilt / Volume: 2


Sayı / Issue: 1

Atf Formatı / Cite as: Bayrak, L., Koçkaya, K., Çınar, A., "W+-Net: Derin Öğrenme Tabanlı Görüntü Segmentasyonu ile Covid19 Tespiti", Hendese, Vol. 2, Issue 1, Pages 20-25, 2025.

Doi: 10.5281/zenodo.15278183

1. GİRİŞ

Derin öğrenme tabanlı görüntü segmentasyonu; derin öğrenmenin bileşenlerini kullanarak resimleri veya videoları birden fazla bölüm veya nesneye bölmeyi sağlamaktadır. Segmentasyon çalışmaları, tıp, eğitim, otonom araçlar, kişi veya nesnelerin tespiti, haritalar üzerinde yolların çıkarılması gibi daha birçok alanda yapılmaktadır [1-3]. Görüntü segmentasyonu, görüntüdeki her nesne için piksel bazlı bir maske oluşturur. Bu teknik, görüntüdeki nesnelerin çok daha ayrıntılı bir şekilde anlaşılmasını sağlar. Şekil 1’de derin öğrenme modellerinde kullanılan bazı kütüphaneler, mimarilerin genel yapısı ve derin öğrenme çalışmalarının genel işleyişi gösterilmiştir.



Şekil 1. Derin öğrenme diyagramı.

Covid19 alanında yapılan bazı derin öğrenme tabanlı görüntü segmentasyonu çalışmaları şunlardır;

Wang ve arkadaşları [4] tarafından sınırlı sayıda kamuya açık akciğer BT görüntüleri üzerinde Covid19 tespiti için 3 boyutlu U-Net mimarisi kullanarak dörtlü transfer öğrenme yöntemini değerlendirilmiştir. Yapılan çalışmada akciğer lezyonunu ortaya çıkarmak için özel kodlayıcı ve uyarlanmış kodlayıcı sunulmuştur. Çalışmanın sonuçları; sınırlı verilerle eğitilen, çoklu lezyonlu önceden eğitilmiş modele dayalı önerilen Hibrid Kodlayıcı stratejisinin sırasıyla 0,704; 0,735; 0,682; 0,707; 0,994 ve 0,716'lık ortalama DSC, NSD, Hassasiyet, F1 puanı, Doğruluk ve MCC elde ettiğini, Covid19 enfeksiyonunu segmentlere ayırmak için daha iyi genişletme ve daha düşük aşırı uyum riskleri sağladığını gösterilmiştir.

Saeedizadeh ve arkadaşları [5] tarafından yapılan çalışmada 900 görüntüden oluşan akciğer BT veri seti üzerinde TV-UNET adını verdikleri bir görüntü segmentasyon modeli önermişlerdir. Önerilen modelin U-Net'e kıyasla %2'lik bir kazanıma sahip olduğu belirtilmiştir. Yapılan çalışmada %99'un üzerinde bir mIoU oranına ve yaklaşık %86'lık bir zar benzerlik katsayısına ulaşıldığı gösterilmiştir. Fung ve arkadaşları [6] tarafından kendi kendini denetleyen iki aşamalı bir derin öğrenme modeli geliştirilmiştir. Yapılan çalışmada en iyi genel F1 puanı, iki ilgili temel model için sırasıyla 0,55-0,49; kendi kendine denetlenen iki aşamalı segmentasyon modelinde ise 0,63 olarak gözlemlenmiştir.

Tahir ve arkadaşları [7], U-Net, U-Net++ ve Özellik Piramidi Ağları (FPN) kullanılarak kapsamlı bir deney gerçekleştirmişlerdir. Çalışmalarında 11,956 Covid-19 örneği de dâhil olmak üzere 33,920 CXR görüntüsüyle en büyük kıyaslama veri seti oluşturmuştur. Çalışmanın sonucunda %96,11 IoU ve %97,99 zar benzerlik katsayısı performansına ulaşıldığı bulunmuştur.

Wu ve arkadaşları [8] tarafından Covid19 tespiti için ortak Sınıflandırma ve Segmentasyon (Joint Classification and Segmentation- JCS) yapısı önerilmiştir. Çalışma için 400 Covid19 hastasının 44,167 göğüs BT görüntüsü ve 350 enfekte olmayan vakanın bulunduğu büyük ölçekli bir veri kümesi oluşturulmuştur. Çalışmada zar benzerlik katsayısı %78,5 olarak bulunmuştur.

Qi ve arkadaşları [9], sürü zekâsı algoritmasına (swarm intelligence algorithm- SIA) dayalı çok seviyeli görüntü segmentasyonu algoritması önermişlerdir. Çalışmada 0,91 FSIM, 23,09 PSNR ve 0.75 SSIM ortalama değerlendirme sonuçlarına ulaşılmıştır. Jun Ma ve arkadaşları [10] tarafından akciğer ve enfeksiyon segmentasyonunda verimli derin öğrenme yöntemlerinin geliştirilmesi amacıyla üç kıyaslama noktası oluşturmuşlardır. Yapılan çalışmada sol akciğer, sağ akciğer ve enfeksiyon için sırasıyla %97,3; %97,7 ve %67,3 zar benzerlik katsayısı (DSC) ve %90,6; %91,4 ve %70,0 normalleştirilmiş yüzey zar (NSD) puanı elde edildiği gözlemlenmiştir.

Zhang ve arkadaşları [11], az sayıda akciğer görüntüsünden Covid19 tespitinin sağlanabilmesi amacıyla CoSinGAN olarak adlandırdıkları segmentasyon modelini geliştirmişlerdir. Çalışmada elde edilen zar benzerlik katsayı sonuçları $93,0 \pm 6,0$ sol akciğer ve $94,1 \pm 4,0$ sağ akciğer olarak elde edilmiştir. Prabha ve arkadaşları [12], Hibrit Sürü Zekâsı ve Bulanık DPSO algoritmaları kullanılarak önceden işlenmiş görüntülerin kullanıldığı bir segmentasyon modeli önermişlerdir. Çalışmanın zar benzerlik katsayısı 0,981 olarak elde edilmiştir.

Antar ve arkadaşları [13] tarafından, her bir görüntü kanalının (kırmızı, yeşil ve mavi) 128×128 yeniden boyutlandırılmış görüntülerle U-Net ağına bağımsız olarak verildiği bir segmentasyon modeli geliştirilmiştir. Çalışma doğruluk, hassasiyet, kesinlik ve zar katsayısı açısından değerlendirilmiştir. Sonuçlar sırasıyla %99,71; 0,83; 0,87 ve 0,85 olarak elde edilmiştir. Deng-Ping Fan ve arkadaşları [14], Inf-Net olarak adlandırdıkları akciğer enfeksiyonu segmentasyon derin ağını önermişlerdir. Geliştirilen model U-Net gibi segmentasyon mimarileri işe kıyaslanmış ve 0,739 zar benzerlik katsayısına ulaşmıştır.

Müller ve arkadaşları [15] tarafından yapılan çalışmada küçük veri kümelerinde başarımla elde edebilmek için otomatik segmentasyon boru hattı adını verdikleri uyarlanmış 3 boyutlu U-Net segmentasyon modeli geliştirilmiştir. Geliştirilen model akciğerler için 0,956 ve enfeksiyon için 0,761 zar benzerlik katsayılarına ulaşmıştır. Yan ve arkadaşları [16] tarafından, farklı şekil ve görünümde hastalık bilgilerini tespit etmek için Progresif Atro Mekansal Piramit Havuzlamayı öneren bir segmentasyon modeli geliştirmişlerdir. Geliştirilen modelin zar benzerlik katsayısı akciğer için 0,987 ve Covid19 için 0,726 olarak elde edilmiştir.

Rahman ve arkadaşları [17] tarafından yapılan çalışmada 18,479 CXR görüntüsünden oluşan büyük bir X-ışını veri seti (COVQU) derlenmiş ve yeni bir U-Net segmentasyon modeli geliştirilerek standart U-Net modelleriyle kıyaslanmıştır.

Geliştirilen modelde %98,63 doğruluk, %94,3 IoU ve %96,94 zar benzerlik katsayısı performansına ulaştığı görülmüştür. Aggarwal ve arkadaşları [18] tarafından Covid19 alanında yapılmış yapay zekâ çalışmalarını ve bu alanda kullanılan veri setlerini derleyen bir araştırma gerçekleştirilmiş ve yüksek bir başarıma sahip olduğu görülmüştür.


Saood ve arkadaşları [19], Covid19 tespiti için SegNet ve U-Net mimarilerini incelemişlerdir. Yapılan çalışmada ortalama doğruluk değerleri SegNet için 0,95 ve U-Net için 0,91 olarak gözlemlenmiştir. Amyar ve arkadaşları [20], küçük veri kümelerinde başarılı sonuçların elde edilmesi için üç görevle ayrıştırılmış bir segmentasyon modeli önermişlerdir. Geliştirilen model 1369 hastadan oluşan bir veri seti üzerinde değerlendirilerek segmentasyon için 0,88 zar benzerlik oranı elde edilmiştir.

Khalifa ve arkadaşları [21] tarafından üç kat evrişim ve havuzlama içeren kodlayıcı bileşeni ve üç kat ters evrişim ve yukarı örnekleme içeren kod çözücü bileşenine sahip bir segmentasyon modeli önerilmiştir. Geliştirilen model %70 eğitim ve %30 test verisi olmak üzere, 3520 görüntüden oluşan bir veri seti üzerinde değerlendirilerek 0,993 küresel doğruluk değerine ulaşıldığı gözlemlenmiştir.

Bu çalışmada covid19 tespiti için yeni bir mimari olan W+-Net mimarisi önerilmiştir. Önerilen mimari 820 Covid19 akciğer görüntüsü üzerinde test edilmiş ve başarımları U-Net ve W-Net mimarileriyle karşılaştırılmalı olarak sunulmuştur.


2. MATERYAL VE YÖNTEM

Bu çalışmada Covid19 vakalarının erken teşhisi için uyarlanabilir bir W+-Net mimari yapısı geliştirilmiştir. Önerilen yöntemi başarımları U-Net ve W-Net mimarileriyle karşılaştırılmalı olarak sunulmuştur. Eğitim işlemlerinde Kaggle'dan alınan Covid19 veri seti kullanılmıştır [22]. Kullanılan Covid19 veri setinde akciğer görüntüleri ve bu görüntülere ait hastalıklı bölgeyi belirten maske görüntüler bulunmaktadır. Mimarilerin eğitim aşamalarında veri setindeki görüntüler 128x128 olarak ölçeklendirilmiştir. Farklı akciğer kesitlerinden 820 veriden oluşan bu sette hastalığın dağılımı Şekil 2'de sunulmuştur. Şekilde görüldüğü üzere veri setinde hastalığın farklı dağılımlara sahip olduğu görülmektedir. Bu sayede eğitim işlemleri sırasında erken Covid19 ve yayılmış Covid19 hastalığının model tarafından tanınması hedeflenmiştir.



Şekil 2. Kullanılan veri setinde Covid19 dağılımı.


Ronneberger ve arkadaşları [23] tarafından mikroskopi görüntüleri analiz edilmiştir. Bu çalışmada görüntülerin bölümlere ayrılması için tam bağlamı katmanı bulunmayan U-Net mimarisi önerilmiştir. U-Net az sayıda açıklamalı olarak verilen görüntüden etkili bir biçimde öğrenmek için ağ ve eğitim stratejisi geliştirilmiştir. U-Net ismini görünümünden almaktadır. Bu durum Şekil 3'te açık bir şekilde görülmektedir. U-Net mimarisi üzerinden modellenen yeni mimarinin en temel karakteristiği birbirine bağlı olan katman yapılarından meydana gelmesidir. Geliştirilen U-Net mimarisi daraltma yolu ve simetrik genişleme yolu olmak üzere iki kısımdan oluşmaktadır. Daraltma yolu bağlamı yakalamak için kullanılırken simetrik bir genişleme yolu hassas yerleştirme için kullanılmıştır. Az sayıda örnek verinin kullanılmasına dayalı olarak geliştirilen mimarinin başarımları analiz sonuçlarından açık bir biçimde görülmektedir.



Şekil 3. U-Net Mimarisi.

Xide Xia ve arkadaşları [24] tarafından Berkeley segmentasyon veri kümesinde W-Net mimarisini geliştirmiştir. Geliştirilen mimarinin temeli U-Net mimarisine dayanmaktadır. Yapılan çalışmada U-Net mimarisi peş peşe iki kere çalıştırılmıştır. İlk olarak $UNet_{enc}$ ’ten alınan veri sonuçları ikinci $UNet_{dec}$ kısmına aktarılarak yeni sonuçlar elde edilmiştir. W-Net ve W+-Net UCM olarak tanımlanan iki yeni mimarinin başarımları karşılaştırılmalı olarak bu çalışmada sunulmuştur. Yapılan başarımlar analizlerinde önerilen yöntemim başarımlarının daha yüksek doğrulukta olduğu gözlemlenmiştir. Şekil 4’te geliştirilen W-Net mimarisi gösterilmektedir.

Gerçekleştirdiğimiz çalışmada W-Net mimarisinde bulunan kodlayıcı ve kod çözücü U-Net aşamaları birleştirilmiş ve V modeline uyarlanmıştır. Modelin U simetrisinden çıkarılıp V simetrisine dönüştürülmesi için W-Net modelinin kodlayıcı bölümünde bulunan evrişim işlemleri ilk katmanda bir, ikinci katmanda iki ve alt katmanlarda üç ve kod çözücü bölümünde bulunan ters evrişim işlemleri ilk katmanda bir, ikinci katmanda iki ve alt katmanlarda üç olacak şekilde yeniden düzenlenmiştir. W-Net modelinin U_{enc} bölümünün çıkış fonksiyonu geliştirilen modelde W-Net modelinin U_{dec} kısmıyla birleştirilmiş ve modelde bir bütünlük sağlanmıştır. Bu sayede daha az evrişim ve ters evrişim işlemiyle daha başarılı sonuçların elde edilmesi hedeflenmiştir.



Şekil 4. W-Net Mimarisi [24].

Şekil 5'te yer alan geliştirilen mimaride her seviyede denklem 1'de yer alan ReLU aktivasyon fonksiyonu, 3x3 evrişim işlemi ve 2x2 maksimum havuzlama kullanılmıştır.

$$ReLU = \begin{cases} x & x \leq 0; 0 \\ x & x > 0; x \end{cases} \quad (1)$$

Modelin çıkış işleminde Denklem (2)'de yer alan Sigmoid aktivasyon fonksiyonunu kullanan 1x1 evrişim fonksiyonu kullanılmıştır.

$$sigmoid(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

Şekil 6'da akciğer görüntüsü ve maskesinin U-Net, W-Net ve W+-Net mimarilerindeki tahmin sonuçları gösterilmiştir.

3. Bulgular ve Tartışma


Mimariler arası benzerlik oranının kıyaslanmasında Denklem (3)'te yer alan iki küme veya veri dizisi arasındaki benzerliği ölçen istatistiksel bir metrik olan zar (dice) benzerlik oranı kullanılmıştır. Zar benzerlik oranı segmentasyon


çalışmalarında yaygın olarak kullanılan bir metriktir. Zar benzerlik oranı Denklem (3)'te belirtildiği gibi tanımlanır.

$$Dice(X, Y) = \frac{2|X \cap Y|}{|X| + |Y|} \quad (3)$$

Denklem (3)'te yer alan X ve Y ifadeleri sırasıyla orijinal veri kümesini ve eğitim işlemi sonucunda elde edilen tahmin veri kümesini tanımlamaktadır.

Geliştirilen modelde evrişim işlemleri indirgenerek yeni bir W+-Net mimarisi oluşturulmuştur. Önerilen mimarinin Covid19 algılama başarımı farklı tur sayısı ve doğrulama bölünmesi değerleri için Kaggle'dan alınan Covid19 veri seti üzerinde analiz edilerek araştırılmıştır. Yapılan analiz sonucunda elde edilen bilgiler Tablo 1'de karşılaştırmalı olarak sunulmuştur.





Şekil 6. (a) Akciğer görüntüsü, (b) Enfeksiyon bölgesi, (c) U-Net tahmini, (d) W-Net tahmini, (e) W+-Net Tahmini.

Çizelge 1. Zar Başarım Katsayıları

Doğrulama Bölünmesi	Tur Sayısı	U-Net	W-Net	W+-Net
0,1	25	0,68	0,75	0,76
	30	0,75	0,77	0,80
	35	0,78	0,80	0,81
	40	0,80	0,81	0,84
	45	0,82	0,84	0,85
0,2	50	0,81	0,82	0,83
	25	0,73	0,76	0,78
	30	0,74	0,78	0,82
	35	0,79	0,81	0,82
	40	0,78	0,82	0,83
0,3	45	0,83	0,84	0,85
	50	0,84	0,84	0,86
	25	0,74	0,77	0,80
	30	0,78	0,79	0,79
	35	0,78	0,81	0,81
0,3	40	0,81	0,82	0,85
	45	0,82	0,83	0,85
	50	0,81	0,85	0,87

Yapılan bu çalışmada doğrulama bölünmesi değerleri sırasıyla literatürle uyumlu olması ve verilerin karşılaştırılması için 0,1; 0,2 ve 0,3 alınmıştır. Çizelge 1’de gözlemlenen zar başarımlarına ilişkin veriler incelendiğinde geliştirilen W+-Net modelinin Covid19 veri seti üzerinde

yapılan analizlerde U-Net ve W-Net modellerine kıyasla daha başarılı olduğu açık bir biçimde görülmektedir.

SONUÇLAR ve ÖNERİLER

Görüntü segmentasyonu alanında son yıllarda birçok çalışma gerçekleştirilmiştir. Bu çalışmalar incelendiğinde yüksek algılama başarımına sahip olan derin öğrenme tabanlı yaklaşımlara olan ilginin her geçen gün arttığı görülmektedir. Görüntü segmentasyonunun en önemli uygulama alanlarından birisi hastalıkların teşhis edilmesidir. Sağlık alanında hastalıkların teşhis edilmesi ile ilgili olarak yapay zekâ ve derin öğrenme algoritmaları kullanılmakta ve geleneksel yöntemlere göre hastalık teşhis başarımının yüksek olduğu görülmektedir.

Yapılan bu çalışmada W-Net mimarisinin yeniden uyarlanmasıyla yeni bir W+-Net modeli oluşturulmuştur. Modelin başarımı Kaggle’den alınan Covid19 veri seti üzerinde analiz edilmiştir. Gözlemlerin başarımı tahmin sonuçlarının enfeksiyon bölgelerine olan benzerliğiyle desteklenmiştir. Geliştirilen W+-Net mimarisinin başarımı farklı doğrulama bölünmesi ve tur sayısı seviyelerinde, U-Net ve W-Net modelleri ile karşılaştırılmıştır. Başarım analiz sonuçlarına göre geliştirilen W+-Net mimari modelinin U-Net ve W-Net modellerine göre daha yüksek bir algılama başarımına sahip olduğunu gösterilmiştir.

Ayrıca, yapılan bu çalışma göstermiştir ki geliştirilen bir modelin nihai model olarak nitelendirilmesi tam olarak mümkün değildir. Geliştirilen modeller farklı veri setleri üzerinde farklı sonuçlar sergileyebilmektedir. Bu sebeple görüntü segmentasyonu alanında gelecek çalışmalarımızda farklı veri setleri üzerinde mimarimizi geliştirerek tahmin oranını daha da arttırmayı hedeflemekteyiz.

KAYNAKLAR

- [1] Redmon, J., Divvala, S., Girshick, R., Farhadi, A., “You only look once: Unified, real-time object detection”, In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Sayfa 779-788, 2016.
- [2] Sethy, P. K., Behera, S. K., Ratha, P. K., Biswas, P., “Detection of coronavirus disease (COVID-19) based on deep features and support vector machine”, 2020.
- [3] Szegedy, C., Toshev, A., Erhan, D., “Deep neural networks for object detection”, Advances in Neural Information Processing Systems, Cilt 26, Sayfa 779-788, 2013.
- [4] Wang, Y., Zhang, Y., Liu, Y., Tian, J., Zhong, C., Shi, Z., Zhang, Y., He, Z., “Does non-COVID-19 lung lesion help? Investigating transferability in COVID-19 CT image segmentation”, Computer Methods and Programs in Biomedicine, Cilt 202, Sayfa 106004, 2021.
- [5] Saeedizadeh, N., Minaee, S., Kafieh, R., Yazdani, S., Sonka, M., “COVID TV-Unet: Segmenting COVID-19 chest CT images using connectivity imposed Unet”, Computer Methods and Programs in Biomedicine Update, Cilt 1, Sayfa 100007, 2021.
- [6] Fung, D. L., Liu, Q., Zammit, J., Leung, C. K. S., Hu, P., “Self-supervised deep learning model for COVID-19 lung CT image segmentation highlighting putative causal relationship among age, underlying disease and COVID-19”, Journal of Translational Medicine, Cilt 19, Sayfa 1-18, 2021.
- [7] Tahir, A. M., Chowdhury, M. E. H., Khandakar, A., Rahman, T., Qiblawey, Y., Khurshid, U., Kiranyaz, S., Ibtehaz, N., Rahman, M. S., Al-Maadeed, S., Mahmud, S., Ezeddin, M., Hameed, K., Hamid, T., “COVID-19 infection localization and severity grading from chest X-ray images”, Computers in Biology and Medicine, Cilt 139, Sayfa 105002, 2021.
- [8] Wu, Y. H., Gao, S. H., Mei, J., Xu, J., Fan, D. P., Zhang, R. G., Cheng, M. M., “JCS: An explainable COVID-19 diagnosis system by joint classification and segmentation”, IEEE Transactions on Image Processing, Cilt 30, Sayfa 3113-3126, 2021.
- [9] Qi, A., Zhao, D., Yu, F., Heidari, A. A., Wu, Z., Cai, Z., Alenezi, F., Mansour, R. F., Chen, H., Chen, M., “Directional mutation and crossover boosted ant colony optimization with application to COVID-19 X-ray image segmentation”, Computers in Biology and Medicine, Cilt 148, Sayfa 105810, 2022.
- [10] Ma, J., Wang, Y., An, X., Ge, C., Yu, Z., Chen, J., Zhu, Q., Dong, G., He, J., He, Z., Cao, T., Zhu, Y., Nie, Z., Yang, X., “Toward data-efficient learning: A benchmark for COVID-19 CT lung and infection segmentation”, Medical Physics, Cilt 48, Sayfa 1197-1210, 2021.
- [11] Zhang, P., Zhong, Y., Deng, Y., Tang, X., Li, X., “CoSinGAN: learning COVID-19 infection segmentation from a single radiological image”, Diagnostics, Cilt 10, Sayı 11, Sayfa 901, 2020.
- [12] R-Prabha, M., Prabhu, R., Suganthi, S. U., Sridevi, S., Senthil, G. A., Babu, D. V., “Design of hybrid deep learning approach for COVID-19 infected lung image segmentation”, Journal of Physics: Conference Series, Cilt 2040, Sayı 1, Sayfa 012016, 2021.
- [13] Antar, S., Abd El-Sattar, H. K. H., Abdel-Rahman, M. H., Ghaleb, F. M., “COVID-19 infection segmentation using hybrid deep learning and image processing techniques”, Scientific Reports, Cilt 13, Sayı 1, Sayfa 22737, 2023.
- [14] Fan, D.-P., Zhou, T., Ji, G.-P., Zhou, Y., Chen, G., Fu, H., Shen, J., Shao, L., “Inf-Net: Automatic COVID-19 lung infection segmentation from CT images”, IEEE Transactions on Medical Imaging, Cilt 39, Sayı 8, Sayfa 2626-2637, 2020.
- [15] Müller, D., Rey, I. S., Kramer, F., “Automated chest CT image segmentation of COVID-19 lung infection based on 3D U-Net”, arXiv preprint arXiv:2007.04774, 2020.
- [16] Yan, Q., Wang, B., Gong, D., Luo, C., Zhao, W., Shen, J., Shi, Q., Zhang, Y., Zhang, L., You, Z., “COVID-19 chest CT image segmentation network by multi-scale fusion and enhancement operations”, IEEE Transactions on Big Data, Cilt 7, Sayı 1, Sayfa 13-24, 2021.
- [17] Rahman, T., Khandakar, A., Qiblawey, Y., Tahir, A., Kiranyaz, S., Bin Abul Kashem, S., Islam, M. T., Al Maadeed, S., Zughaier, S. M., Khan, M. S., Chowdhury, M. E., “Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images”, Computers in Biology and Medicine, Cilt 132, Sayfa 104319, 2021.
- [18] Aggarwal, P., Mishra, N. K., Fatimah, B., Singh, P., Gupta, A., Joshi, S. D., “COVID-19 image classification using deep learning: Advances, challenges and opportunities”, Computers in Biology and Medicine, Cilt 144, Sayfa 105350, 2022.
- [19] Saood, A., Hatem, I., “COVID-19 lung CT image segmentation using deep learning methods: U-Net versus SegNet”, BMC Medical Imaging, Cilt 21, Sayfa 1-10, 2021.
- [20] Amyar, A., Modzelewski, R., Li, H., Ruan, S., “Multi-task deep learning based CT imaging analysis for COVID-19 pneumonia: Classification and segmentation”, Computers in Biology and Medicine, Cilt 126, Sayfa 104037, 2020.
- [21] Khalifa, N. E. M., Manogaran, G., Taha, M. H. N., Loey, M., “A deep learning semantic segmentation architecture for COVID-19 lesions discovery in limited chest CT datasets”, Expert Systems, Cilt 39, Sayı 6, Sayfa e12742, 2022.
- [22] Kaggle, “COVID-19 Image Dataset”, <https://www.kaggle.com/datasets>.
- [23] Ronneberger, O., Fischer, P. ve Brox, T., “U-net: Convolutional networks for biomedical image segmentation”, Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III, Springer International Publishing, 18, 2015.
- [24] Xia, X. ve Kulis, B., “W-net: A deep model for fully unsupervised image segmentation”, arXiv preprint arXiv:1711.08506, 2017.