

Covid-19 Hastasında Yapay Zeka Destekli Bilgisayarlı Tomografi Sonuçları ile Klinisyen Sonuçlarının Karşılaştırılması

Pınar AYYAT¹

¹ İzmir Demokrasi Üniversitesi, Tıp Fakültesi, Anestezi ve Reanimasyon Anabilim Dalı, Türkiye

(Received: 22 September 2024, Accepted: 01 October 2024)

(6th International Conference on Applied Engineering and Natural Sciences ICAENS 2024, 25-26 September 2024)

ATIF/REFERENCE: Ayvat, P. (2024). Covid-19 Hastasında Yapay Zeka Destekli Bilgisayarlı Tomografi Sonuçları ile Klinisyen Sonuçlarının Karşılaştırılması, *International Journal of Advanced Natural Sciences and Engineering Researches*, 8(9), 34-39.

Özet – Koronavirüs nedeniyle yoğun bakım ünitesine yatırılan hastalar, hastalığın ciddiyetini değerlendirmek için puanlama sistemleriyle takip edilir. APACHE ve SOFA puanlama sistemleri yoğun bakım ünitesindeki hasta takibinde sıklıkla kullanılır. Aralıklı çekilen bilgisayarlı tomografilerinde pulmoner tutulumunu nicelleştirmek için bazı yarı-kantitatif puanlama sistemleri kullanılır. Bunlardan biri beş akciğer lobunun puanlandığı yöntemdir. Bu çalışmada Covid-19 tanısıyla yoğun bakımımızda takip edilen hastalarımızın takibinde klinisyenler olarak kullandığımız skorlar ile, yapay zeka yardımıyla izlenen skorların karşılaştırılmıştır. Klinisyenin takipte kullandığı yoğun bakım skorundaki dolayısıyla mortalitedeki artış ile, evrişimsel sinir ağlarıyla hesaplanan akciğer yoğunluğundaki artış korelasyon göstermiştir. Bu bağlamda, klinisyenlerin bu tür yöntemlerden yararlanabileceği düşüncesindeyiz.

Anahtar kelimeler – Covid-19, evrişimsel sinir ağları, yoğun bakım, bilgisayarlı tomografi, mortalite

I. GİRİŞ

Çin'de başlayan COVID-19, dünya çapında benzeri görülmemiş bir şekilde yayıldı. Hastalığın yayılması bir pandemiye dönüştü ve binlerce kişi enfekte oldu. Bazıları hafif semptomlarla hayatta kalırken, diğerleri yoğun bakım ünitesinde şiddetli semptomlarla tedavi edildi. Hastalar yoğun bakım ünitesinde hayatta kalmak için mücadele ederken, doktorlar da bu yeni bilinmeyen virüsle mücadele ediyordu. Hangi puanlama sisteminin mortaliteyi daha doğru bir şekilde belirleyeceği veya hangi laboratuvar parametrelerinin yatan hasta takibi için daha değerli olduğu araştırıldı [1].

Koronavirüs nedeniyle yoğun bakım ünitesine yatırılan hastalar, hastalığın ciddiyetini değerlendirmek için puanlama sistemleriyle takip edilir. APACHE ve SOFA puanlama sistemleri yoğun bakım ünitesindeki hasta takibinde sıklıkla kullanılır [2,3].

Bilgisayarlı tomografi (BT), COVID-19'u teşhis etmek ve hastalığın kapsamını ve ciddiyetini anlamak için sıklıkla kullanılır [4]. Önemli BT bulguları (Fleischner Society tarafından tanımlanan uluslararası standart terminolojiye göre) buzlu cam opaklığı, parke taşı görünümü ve akciğer segmentlerinde konsolidasyon olarak sayılabilir [5]. Tüm bu anormalliklerin pulmoner tutulumunu nicelleştirmek için bazı yarı-kantitatif puanlama sistemleri kullanılır ve bunlardan biri beş akciğer lobunun puanlandığı yöntemdir. Bu nedenle,

toplam BT skoru bireysel lobar skorları eklenerek bulunur ve 0 (tutum yok) ile 25 (maksimum tutulum) arasında değişir [6].

Akciğerdeki enfeksiyonun yoğunluğunu algılayıp skorlama yapan yöntemler arasında özellikle Evrişimsel sinir ağları (Convolutional Neural Networks, CNNs) ve Automated Lung Scoring Systems öne çıkmaktadır. Bu yöntemler, enfeksiyon yoğunluğunu belirlemede ve skorlama yapmada etkili sonuçlar vermektedir.

Evrişimsel sinir ağları (CNNs) akciğer enfeksiyonlarını tanımlamak ve yoğunluğunu skorlama amacıyla kullanılır. Özellikle COVID-19 gibi hastalıklarda, akciğer tutulumunun derecesini belirlemek için kullanılırlar. Örnek yöntemler ve modeller olarak U-Net ve V-Net verilebilir. U-Net, Segmentasyon görevlerinde yaygın olarak kullanılan bir CNN modeli. Akciğer enfeksiyon bölgelerini tespit edip yoğunluğunu ölçebilir. V-Net, 3D tıbbi görüntü segmentasyonu için geliştirilmiş bir CNN yapısıdır. Akciğer enfeksiyonlarını üç boyutlu olarak analiz edebilir.

Automated Lung Scoring Systems, özellikle COVID-19 gibi hastalıkların değerlendirilmesi için geliştirilmiş otomatik puanlama sistemleridir ve akciğer enfeksiyonlarının yoğunluğunu otomatik olarak skorlama yeteneğine sahiptir. Örnek yöntemler ve sistemler olarak COVID-19 Severity Scoring Systems ve Infection Detection and Scoring Algorithms verilebilir. COVID-19 Severity Scoring Systems, akciğer tutulumunu otomatik olarak skorlama ve hastalığın ciddiyetini belirleme amacıyla geliştirilmiş sistemlerdir. Infection Detection and Scoring Algorithms, akciğer enfeksiyonlarını algılayan ve yoğunluğunu skorlama yeteneğine sahip algoritmalarıdır.

Bu araştırmada Covid-19 tanısıyla yoğun bakımımızda takip edilen hastalarımızın takibinde klinisyenler olarak kullandığımız skorlar ile, yapay zeka yardımıyla izlenen skorların karşılaştırılmasıdır.

II. MATERYAL ve YÖNTEM

Covid-19 tanısıyla yoğun bakımda takip ettiğimiz 3 hasta bu incelemeye alındı. Hastayı takip eden anestezi doktorunun yaptığı takiplerde yoğun bakım Apache skorlarına göre düşük, orta ve yüksek olarak sıralanan 3 hasta incelemeye alındı. Aynı hastalar radyoloji uzmanı tarafından BT skorlama sistemi ile sınıflandırıldı. Sonrasında BT görüntüleri derin öğrenme yöntemi ile incelenerek bilgisayarlı tomografideki yoğunluk durumuna göre histogram grafilere elde edildi.

Dahil olma kriterleri: 18 yaşından büyük olmak, BT sonuçları ve laboratuvar değerleri mevcut olmak, PCR ile COVID-19 tanısı almış olmak idi.


Dışlama kriterleri: 18 yaşından küçük olmak, BT görüntüleri veya laboratuvar değerleri mevcut olmamak idi.

III. BULGULAR

İncelemeye alınan hastalardan ilki, yoğun bakım hekimi tarafından genel durumu iyi olarak tarif edilen ve APACHE skorlama sisteminde 10 puan almış bir hasta idi. Bu hasta radyoloji uzmanı tarafından yapılan BT skoru 12 olarak tespit edildi. Bu hastanın yapılan yoğunluk histogramında, ortalama yoğunluk -752.53 HU idi (Şekil 1).

Sütun Aralığı(def:50)
Alt Sınır(def:-1000)
Üst Sınır(def:500)
Belirlenen Aralık(%) 99.00999999999999

Hacim 5186.27 cm³
Ortalama yoğunluk -752.53 HU
Minimum -1395.00 HU
Maksimum 1799.00 HU
Standart Sapma 230.99 HU
Pixel Mesafesi 0.72 mm
Kesit Kalınlığı 4.0 mm




Şekil 1. Genel durumu iyi olan hastanın yoğunluk histogramı eğrisi

İkinci hastamız genel durumu orta olarak niteleyebileceğimiz ve APACHE skoru 28 olan bir hasta idi. Bu hastada radyoloji uzmanı tarafından yapılan BT skoru 19 olarak tespit edildi. Bu hastanın yapılan yoğunluk histogramında, ortalama yoğunluk -644.19 HU idi (Şekil 2).

Sütun Aralığı(def:50)
Alt Sınır(def:-1000)
Üst Sınır(def:500)
Belirlenen Aralık(%) 98.57000000000001

Hacim 4724.29 cm³
Ortalama yoğunluk -644.19 HU
Minimum -1550.00 HU
Maksimum 2071.00 HU
Standart Sapma 261.98 HU
Pixel Mesafesi 0.58 mm
Kesit Kalınlığı 4.0 mm




Şekil 2. Genel durumu orta olan hastanın yoğunluk histogramı eğrisi

Üçüncü hastamız ise genel durumu ağır olan ve APACHE skoru 37 olan bir hasta idi. Bu hastada radyoloji uzmanı tarafından yapılan BT skoru 24 olarak tespit edildi. Bu hastanın yapılan yoğunluk histogramında, ortalama yoğunluk -448.86 HU idi (Şekil 3).

Sütun Aralığı(def:50)
 Alt Sınır(def:-1000)
 Üst Sınır(def:500)
 Belirlenen Aralık(%) 99.78

Hacim 2210.43 cm³
 Ortalama yoğunluk -448.86 HU
 Minimum -1541.00 HU
 Maksimum 1659.00 HU
 Standart Sapma 255.02 HU
 Pixel Mesafesi 0.73 mm
 Kesit Kalınlığı 4.0 mm



Şekil 3. Genel durumu ağır olan hastanın yoğunluk histogramı eğrisi

IV. TARTIŞMA

Sağlık sistemlerindeki yetersizlikler ve her geçen gün artan yeni vaka, ölüm ve yoğun bakıma yatış sayıları, bu yeni salgının dünya genelinde ciddi bir tehdit oluşturduğunu açıkça göstermektedir. Hastalığın yayılımını kontrol altına almak ve uygulanan tıbbi tedavilerin etkinliğini artırmak için virüs taşıyan bireylerin hızlı ve doğru bir şekilde tespit edilmesi gereklidir. Bu amaçla kullanılan birincil teşhis yöntemi, üst solunum yolu sürüntü örneğinden SARS-CoV-2 ribonükleik asidinin (RNA) tespit edildiği RT-PCR yöntemidir.

Bununla birlikte, daha hızlı ve hastalığın erken evrelerinde yüksek doğruluk oranına sahip teşhis yöntemlerine ihtiyaç duyulmaktadır. Göğüs radyolojik görüntüleri, COVID-19 gibi akciğer hastalıklarıyla ilgili önemli belirtiler içermektedir. Bu nedenle, X-ray ve bilgisayarlı tomografi (BT) gibi tıbbi görüntüleme yöntemleri, COVID-19 ile enfekte olmuş bireylerin zamanında teşhis edilip izole edilmesinde etkili olmaktadır [7].

Göğüs radyolojik verilerinden COVID-19 tespiti, artan yeni vaka sayıları nedeniyle zaman alıcı ve oldukça zahmetli bir iş yüküne dönüşmektedir. Ayrıca, büyük veri yığınları arasından görsel bulguların değerlendirilmesi, insan hatalarına açık bir ortam yaratmaktadır. Bu sebeplerden dolayı, radyologların iş yükünü hafifletmek ve teşhislerde yüksek başarı oranları elde edebilmek için makine öğrenmesi yöntemleri kullanılmaktadır. Özellikle, son yıllarda derin öğrenme mimarilerinden biri olan evrişimsel sinir ağları (CNN) ile yapılan başarılı çalışmalar, bu mimarinin tıp alanında yaygın bir şekilde kullanılmasına neden olmuştur [8,9].

Bu bağlamda, COVID-19'un göğüs radyolojik verileri üzerinden tespitine yönelik derin öğrenme modellerine dayalı çalışmalar, literatürde büyük ilgi görmektedir. Çünkü bu modeller, hızlı, güvenilir ve otomatik analizler yapılmasını mümkün kılmaktadır [10].

Evrişimsel sinir ağları (CNN), derin öğrenmenin yaygın olarak kullanıldığı nesne tanıma, görüntü işleme ve dil işleme gibi çeşitli projelerde sıkça tercih edilen bir sinir ağı türüdür. Bu ağların klasik sinir ağlarından en büyük farkı, verilerin uzamsal özelliklerini koruyarak görüntülerin özelliklerini çıkarma yeteneğine sahip olmalarıdır. Bu sayede, karmaşık ve zorlayıcı görüntü verilerine karşı oldukça dayanıklıdır.

Evrişimsel sinir ağları, adını ağ katmanları arasında yer alan ve evrişim (convolution) işlemini gerçekleştiren katmandan almaktadır.

Lecun ve ekibi, ticari olarak uygulamada kullanılan ilk CNN ağı olan LeNet-5'i geliştirmişlerdir. LeNet-5, iki boyutlu girdi şekillerindeki değişkenliklere karşı dayanıklı olacak şekilde tasarlanmış olup, el yazısı karakter tanıma uygulamalarında kullanılmıştır. Bu çalışmada, LeNet-5'in klasik makine öğrenmesi algoritmalarına kıyasla daha yüksek bir performans sergilediği gösterilmiştir [11].

Bir diğer önemli dönüm noktası, ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) kapsamında geliştirilen AlexNet ile yaşanmıştır. Bu yarışma, büyük ölçekli bir veri tabanını kullanarak nesne algılama ve görüntü sınıflandırma alanında yüksek başarı elde etmeyi hedeflemiştir. AlexNet, önceki denemelere kıyasla çok daha düşük hata oranları sunarak bu yarışmada birinciliği kazanmıştır [12]. Benzer şekilde, mimari derinlikle başarı arasındaki ilişkiyi inceleyen ve yine yüksek performans elde eden bir diğer çalışma ise GoogleNet olmuştur [13]. Bu ve benzeri çalışmaların sonucunda elde edilen yüksek performanslı CNN mimarileri, literatürde geniş bir uygulama yelpazesi bulmuştur.

Derin öğrenme, X-ray, MRI, PET ve BT gibi tıbbi görüntülerin bilgisayar destekli hastalık tespitinde kullanılan en önemli yöntemlerden biri olarak öne çıkmaktadır. Lezyonların görsel analizini içeren yardımcı uygulamalar, hastalıkların teşhisinde radyologlara destek sağlayarak tanı sürecini kolaylaştırmaktadır. Derin öğrenme alanındaki çalışmalar, nesne tanıma ve bilgisayarlı görme gibi görevlerde, insan performansına yakın sonuçlar elde ederek dikkat çekmiştir [14].

Charbonnier ve ekibi, tomografilerde hava yolu segmentasyonu ve sızıntı tespiti sınıflandırması yapmak için evrişimsel sinir ağlarını kullanmıştır [15]. Benzer şekilde, Ciompi ve çalışma arkadaşları, pulmoner periferik nodüllerin sınıflandırılması için önceden eğitilmiş bir CNN mimarisine başvurmuşlardır [16]. Tarando ve ekibi ise, akciğer BT görüntülerinde hastalığa ait örüntüleri sınıflandırmak amacıyla CNN mimarisi tabanlı bir bilgisayar destekli teşhis sistemi geliştirmiştir [17]. Ayrıca, Anthimopoulos ve meslektaşları, interstisyel akciğer hastalıklarının dokusal sınıflandırması için bir CNN mimarisi önermiş ve tespit ettikleri dokuları sağlıklı, buzlu cam opaklığı (GGO), mikrolezyon, konsolidasyon ve GGO/retikülasyon gibi kategorilere ayırmışlardır [18].

Akciğer bilgisayarlı tomografileri, pek çok akciğer hastalığına dair önemli görsel veriler sunmaktadır. Literatürde, bu görüntülerin kullanımıyla akciğer hastalıklarının tespiti üzerine birçok çalışma yapılmıştır. 2019 yılında ortaya çıkan ve pandemi haline gelen COVID-19 da bu literatürde kendine yer bulmuştur.

V. SONUÇLAR

Literatürde, COVID-19 tespiti amacıyla BT görüntüleri üzerinde derin öğrenme mimarilerinin kullanıldığı birçok çalışma bulunmaktadır. Bu çalışmalar, problemi ele alış biçimlerine göre iki ana gruba ayrılabilir: ikili sınıflandırma ve çoklu sınıflandırma. İkili sınıflandırma yaklaşımlarında, genellikle COVID-19/Normal veya COVID-19/Bakteriyel Pnömoni gibi iki sınıf kullanılır. Çoklu sınıflandırmada ise, bu sınıflara ek olarak toplum kökenli pnömoni (CAP), influenza A/B gibi diğer hastalık sınıfları dahil edilerek sınıf sayısı artırılır. Literatürde yapılan incelemeler, sınıflandırma yaklaşımları açısından analiz edilerek, ikili sınıflandırma ve çoklu sınıflandırma başlıkları altında ele alınmıştır. Bu yöntemlerle yapılan analizler, klinisyenlerin deneyimleri sonucu elde edilen analizlerle karşılaştırılmıştır. Ağır hasta olarak tanımlanan COVID-19 vakalarında, akciğer görüntülemelerinde yoğunluğun yüksek olduğu tespit edilmiştir. Bu bağlamda, klinisyenlerin bu tür yöntemlerden yararlanabileceği düşüncesindeyiz.

KAYNAKLAR

- [1] Guan W, Liang W, Zhao Y, Liang H, Chen Z, Li Y, et al. Comorbidity and its impact on 1590 patients with COVID-19 in China: a nationwide analysis. *Eur Respir J* 2020;55(5):640.
- [2] Qiao Q, Lu G, Li M, Shen Y, Xu D. Prediction of outcome in critically ill elderly patients using APACHE II and SOFA scores. *J Int Med Res* 2012;40(3):1114–21.
- [3] Ho KM. Combining Sequential Organ Failure Assessment (SOFA) score with Acute Physiology and Chronic Health Evaluation (APACHE) II score to predict hospital mortality of critically ill patients. *Anaesth Intensive Care*. 2007;35(4):515–21.
- [4] Liu F, Zhang Q, Huang C, Shi C, Wang L, Shi N, et al. CT quantification of pneumonia lesions in early days predicts progression to severe illness in a cohort of COVID-19 patients. *Theranostics* [Internet]. 2020;10(12):5613.
- [5] Hansell DM, Bankier AA, MacMahon H, McLoud TC, Müller NL, Remy J. Fleischner Society: Glossary of Terms for Thoracic Imaging1 2008;246(3):697–722.
- [6] Pan F, Ye T, Sun P, Gui S, Liang B, Li L, et al. Time course of lung changes at chest CT during recovery from Coronavirus disease 2019 (COVID-19). *Radiology* 2020;295(3):715–21.
- [7] Singh, D., Kumar, V., & Kaur, M. (2020). Classification of COVID-19 patients from chest CT images using multi-objective differential evolution – based convolutional neural networks. *European Journal of Clinical Microbiology & Infectious Diseases*, 39, 1379–1389
- [8] Bakator, M., & Radosav, D. (2018). Deep Learning and Medical Diagnosis: A Review of Literature. *Multimodal Technologies and Interaction*, 2(3), 47
- [9] Esteva, A., Chou, K., Yeung, S., Naik, N., Dean, J., & Socher, R. (2021). Deep learning-enabled medical computer vision. *Npj Digital Medicine*, 4(5), 1–9.
- [10] Panwar, H., Gupta, P. K., Siddiqui, M. K., Morales-Menendez, R., & Singh, V. (2020). Chaos , Solitons and Fractals Application of deep learning for fast detection of COVID-19 in X-Rays using nCOVnet. *Chaos, Solitons and Fractals: The Interdisciplinary Journal of Nonlinear Science, and Nonequilibrium and Complex Phenomena*, 138, 109944.
- [11] LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2323.
- [12] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *NIPS'12: Proceedings of the 25th International conference on Neural Information Processing Systems*, 1097–1105
- [13] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 07-12-June, 1–9
- [14] Kim, M., Yun, J., Cho, Y., Shin, K., Jang, R., Bae, H., & Kim, N. (2019). Deep Learning in Medical Imaging. *Neurospine* 2019, 16(4), 657–668
- [15] Charbonnier, J. P., Rikxoort, E. M. va., Setio, A. A. A., Schaefer-Prokop, C. M., Ginneken, B. van, & Ciompi, F. (2017). Improving airway segmentation in computed tomography using leak detection with convolutional networks. *Medical Image Analysis*, 36, 52–60
- [16] Ciompi, F., de Hoop, B., van Riel, S. J., Chung, K., Scholten, E. T., Oudkerk, M., de Jong, P. A., Prokop, M., & van Ginneken, B. (2015). Automatic classification of pulmonary peri-fissural nodules in computed tomography using an ensemble of 2D views and a convolutional neural network out-of-the-box. *Medical Image Analysis*, 26(1), 195–202
- [17] Tarando, S. R., Fetita, C., Faccineto, A., & Brillet, P.-Y. (2016). Increasing CAD system efficacy for lung texture analysis using a convolutional network. *Medical Imaging 2016: Computer-Aided Diagnosis*
- [18] Anthimopoulos, M., Christodoulidis, S., Ebner, L., Christe, A., & Mougiakakou, S. (2016). Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network. *IEEE Transactions on Medical Imaging*, 35(5), 1207–1216