

InceptionResNetV2 ve Sınıf Aktivasyon Haritaları ile Akciğer Kanserinin Tespit Edilmesi

Erdal BAŞARAN*¹ ORCID 0000-0001-8569-2998

¹Ağrı İbrahim Çeçen Üniversitesi, Meslek Yüksek Okulu, Bilgisayar Teknolojileri Bölümü, Ağrı

Geliş tarihi: 11.02.2022

Kabul tarihi: 30.06.2022

Atf şekli/ How to cite: BAŞARAN, E., (2022). InceptionResNetV2 ve Sınıf Aktivasyon Haritaları ile Akciğer Kanserinin Tespit Edilmesi. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 37(2), 341-349.

Öz

Akciğer kanseri, hayati tehlikesi son derecede yüksek olan bir hastalıktır. Dünya Sağlık Örgütü'ne göre kanserden ölüm oranı en yüksek olan hastalıktır. Oldukça sinsi olan bu hastalık erken evrelerde herhangi bir semptom göstermemektedir. İlk evrelerde hastalık doğru teşhis edildiği takdirde tedavisi mümkün olan bir hastalıktır. Bilgisayarlı tomografi ile akciğer bölgesindeki kitleler tespit edilebilmekte ve deneyimli doktorlar tarafından teşhis konulabilmektedir. Derin öğrenme yöntemlerinden biri olan evrişimsel sinir ağı günümüzde birçok hastalığın tespit edilmesinde başarılı bir şekilde uygulanmaktadır. Sınıf aktivasyon haritaları evrişimsel sinir ağı ile eğitilirken görüntünün ayırt edici bölgeleri önemine göre renklendirilmekte ve böylece hedef sınıfa yönelik önemli bölgeler tespit edilebilmektedir. Bu çalışmada bilgisayarlı tomografi ile elde edilen üç sınıftan oluşan toplam 1197 akciğer görüntüsü InceptionResNetV2 evrişimsel sinir ağı ile eğitilmiş sınıf aktivasyon haritaları ve görüntülere ait önemli bölgeler tespit edilerek bu bölgelere ait öznelikler çıkarılmıştır. Elde edilen öznelikler destek vektör makinaları ile sınıflandırılarak %95.44 doğruluk oranı ile sınıflandırılmıştır.

Anahtar Kelimeler: Akciğer kanseri, Inceptionresnetv2, Sınıf aktivasyon haritaları, Destek vektör makinaları

Diagnosis of Lung Cancer with InceptionResNetV2 and Class Activation Maps

Abstract

Lung cancer is a life-threatening disease. According to the World Health Organization, cancer is the disease with the highest mortality rate. This disease, which is quite insidious, does not show any symptoms in the early stages. If the disease is diagnosed correctly in the early stages, it can be treated. With computed tomography, masses in the lung region can be detected and diagnosed by experienced

*Sorumlu yazar (Corresponding author): Erdal BAŞARAN, ebasaran@agri.edu.tr

doctors. Convolutional neural network, which is one of the deep learning methods, is successfully applied in the detection of many diseases today. When class activation maps are trained with a convolutional neural network, distinctive regions of the image are colored according to their importance, so that the important regions for the target class can be determined. In this study, a total of 1197 lung images consisting of three classes obtained by computed tomography, class activation maps were trained with the InceptionResNetV2 convolutional neural network, and the important regions of the images were determined that the features of these regions were obtained. The Obtained features were classified using support vector machines and classified with an accuracy rate of 95.44%.

Keywords: Lung cancer, Inceptionresnetv2, Class activation maps, Support vector machines

1. GİRİŞ

Akciğer kanseri diğer kanser çeşitleri arasında ölüm oranı en yüksek olan kanser çeşididir. Bu hastalığa tanı konulduktan sonra hayatta kalma oranı en düşük olan, ölüm sayısında ise her yıl kademeli bir şekilde artarak dünyadaki en riskli hastalıklardan biridir [1]. Dünya sağlık örgütünün kanserden kaynaklanan ölüm oranlarına bakıldığı zaman en fazla ölümün 1.8 milyon ile akciğerden kaynaklandığı bildirilmiştir [2]. Akciğer kanserinin temel nedeni, dünya çapında akciğer kanseri vakalarının yaklaşık % 80'ini hastaların sigara içmesine bağlanmıştır. Bu hastalığı erken evrede tespit etmek zordur ve akciğer kanseri teşhisi konan kişilerin yaklaşık % 25'i hiçbir semptom göstermemiştir [3]. Bilgisayarlı tomografi (BT), tıpta yaygın olarak kullanılan tanı yöntemlerinden biridir. BT cihazı ile akciğer kanserinin yanı sıra birçok hastalığın erken tanısı kolaylıkla konabilmektedir.

Derin öğrenme yöntemleri son zamanlarda tıbbi görüntüleme cihazları aracılığıyla görüntülerde kitle tespiti yapılabilmekte ve bunlar hastalık tipine göre sınıflandırılabilir [4][5]. BT görüntüleri ile bilgisayar destekli meme kanseri teşhisine yönelik olarak evrişimsel sinir ağı (ESA) ve yığılmış otomatikkodlayıcı (stacked autoencoder) iyi huylu ve kötü huylu görüntüler %84,15 doğruluk oranı ile sınıflandırılmıştır [6]. Görüntü kontrastları maksimum yoğunluk ağırlıkları yaklaşımı ile gama düzeltmesi işleminden sonra görüntü özelliklerinin çıkarılması için çoklu doku, nokta ve geometrik özellikler kullanılmış ve komşuluk bileşen analizi ile özellik


seçiminden sonra topluluk öğrenimi ile sınıflandırma gerçekleştirilmiştir [7]. Akciğer kanserine yönelik olarak yine ESA modeli olan DarkNet-19 mimari ile görüntülere ait özellikler çıkarıldıktan sonra Equilibrium ve Manta Ray Foraging optimizasyon algoritmaları ile özellik seçim işlemi gerçekleştirilmiş ve SVM ile sınıflandırma yapılmıştır. Önerilen model aynı zaman kolon kanseri görüntüleri üzerinde de başarılı bir şekilde test edilmiştir [8].

Bu makalede akciğer kanserinin bilgisayar destekli teşhis edilebilmesi için class activation map algoritmasının SqueezeNet ESA modeli ile eğilerek başarılı bir sınıflandırma işlemi yapmaktır. Çalışmanın ikinci bölümünde kullanılan yöntem ve veri seti açıklandıktan sonra üçüncü bölümde deneysel çalışmaların sonuçlarına yer verilmiştir. Bunu sırasıyla tartışma ve sonuç bölümü izlemiştir.

2. MATERYAL VE METOD

2.1. Veri Seti

Bu veri seti farklı aşamalarda kanser ve sağlıklı tanısı konan hastaların CT taramalarını içerir. BT görüntülerine onkologlar ve radyologlar tarafından etiketleme işlemi gerçekleştirilmiştir. Veri setinde normal durum BT görüntü sayısı 416 iken iyi huylu BT ve kötü huylu BT sınıfına sahip görüntü sayısı sırasıyla 120 ve 561'dir. Veri setinde toplamda 1097 akciğer BT görüntü bulunmaktadır [9]. Veri setinde bulunan her bir sınıfa ait bir görüntü Şekil 1'de verilmiştir.




Şekil 1. Üç sınıflı veri setinden örnek resimler

2.2. Önerilen Yöntem

Bilgisayarlı tomografi (BT) cihazı ile elde edilen ve Normal akciğer BT, iyi huylu ve kötü huylu BT görüntüleri olmak üzere 3 sınıftan oluşan veri setini sınıflandırmak için ilk olarak SqueezeNet ESA modeli ile görüntüler sınıflandırılmıştır. Ardından Class Activation Map tekniği ile ESA modelleri sınıflandırma yapılırken görüntünün hangi bölgesinin sınıf hedefine yönelik olarak ayırt edici olmasına göre renklendirme tekniği

kullanılarak görüntünün önemli bölgeleri tespit edilmiştir. CAM tekniğini akciğer BT görüntüleri üzerinde uygulamak için SqueezeNet ESA modeli kullanılmıştır. Burada renk haritasını ortaya çıkarmak için ağın son konvolüsyon katmanını takip eden ReLu katmanı (relu_conv10) kullanılmıştır. Görüntüler renklendirildikten sonra CAM özellikleri elde edilmiştir ve bu özellikler destek vektör makinalarına giriş olarak verilmiştir. Önerilen modelin akış diyagramı Şekil 2 üzerinde gösterilmiştir.




Şekil 2. Önerilen modelin akış diyagramı

2.3. SqueezeNet

Indola ve diğerleri tarafından önerilen bu sinir ağı mimarisi AlexNet mimarisine göre 50 kat daha az parametreye sahip olmasına rağmen AlexNet mimarisinin doğruluk oranına yaklaşılmaktadır [10]. 18 katmandan oluşan SqueezeNet mimarisi tek bir evrişim katmanı (conv1), ardından sekiz Fire modülü (fire2-9) ve son olarak bir son evrişim katmanı (conv10) ile başlar [11]. SqueezeNet, giriş kanallarının sayısını azaltmak için sıkıştırma katmanları kullanılır [12]. SqueezeNet evrişim ağı kullanılır ve daha küçük ve daha etkili bir CNN mimarisi oluşturmak için yangın modüllerinin sıkıştırma ve genişletme katmanlarını kullanır [13]. Bu çalışmada akciğer BT görüntüleri SqueezeNet ESA modeli ile sınıflandırılırken aynı anda işlenen veri sayısı değeri olan mini-batch size 32 olarak seçilmiştir. Tüm eğitim verilerinin bir sefer ağı ile eğitilme değeri olan epoch ise 16 olarak seçilirken öğrenme oranı ise 1×10^{-4} seçilmiştir.

2.4. Class Activation Map

Evrişimsel sinir ağlarında evrişim katmanı ile özellik haritaları elde edilir ve istenen çıktının elde edilmesi için bu özellikler tam bağlantılı katmanda kullanılır. Çıktı katmanının ağırlıkları özellik haritalarına geri yansıtılarak görüntüye ait önemli bölgeler belirlenmektedir bu işlem sınıf aktivasyon eşleşmesi olarak tanımlanan bir tekniktir [14]. Tam bağlantılı katmanları, küresel ortalama havuzlama ve 1×1 evrişim katmanı ile değiştirir. Bu yapı, derin evrişim katmanlarından özellik haritaları oluşturmak için sınıflandırıcıdaki kategori ağırlıklarını çarparak sınıflandırma ağındaki ayırt edilen bölge görselleştirilmektedir [15]. Kırmızı olan bölgeler ayırt ediciliği en yüksek olan bölge olarak renklendirilmektedir. Veri setinde bulunan görüntüye ait class aktivasyon haritası belirlenmiş olan örnek görüntü Şekil 3'de verilmiştir.



Şekil 3. Class activation map ile Akciğer BT görüntüsüne ait önemli bölgelerinin tespit edilmesi

Evrişimsel sinir ağında, belirli bir sınıf c için, softmax katmanının girişini (S_c) belirtirsek, softmax'ın çıkışı $\exp S_c / \sum \exp S_c$ ile hesaplanabilir. S_c ise Eşitlik 1'deki hesaplanmaktadır:

$$S_c = \sum_k w_k^c \sum_{x,y} f_k(x,y) = \sum_{x,y} \sum_k w_k^c f_k(x,y) \quad (1)$$

Eşitlik 1'de $f_k(x,y)$; uzamsal konumdaki (x, y) son evrişim katmanında k biriminin aktivasyon

değerini temsil ettiğinde w_k , f_k sınıfı için f_k 'nin önemini göstermektedir. Ağ eğitilirken w değerini almak için geri yayılımı kullanırsak, o zaman M_c olarak belirtilen c sınıfının class activation map'i Eşitlik 2 ile hesaplanır:

$$M_c = \sum_k w_k^c f_k(x,y) \quad (2)$$

2.5. Destek Vektör Makinaları

DVM, denetimli bir makine öğrenme yöntemidir. Vapnik [16] tarafından geliştirilen bu makine öğrenme algoritması sınıflandırma ve regresyon problemlerinde kullanılmaktadır. Veriler hiper düzlem üzerinde başarılı bir şekilde sınıflandırılmaktadır. Veri setinin doğrusal olarak ayrılmadığı durumlarda doğrusal olmayan bir çekirdek işlevleri kullanılır [17]. Bu çalışmada akciğer BT görüntülerinden çıkarılan özellikler DVM ile sınıflandırılırken Cubik kernel kullanılmıştır. Kernel boyutu otomatik olarak seçilirken kutu sınırlama değeri 1 olarak seçilmiştir.

3. BULGULAR

Bu çalışmada yapılan deneysel çalışmaların başarı kriterlerini değerlendirmek için karmaşıklık

matrisinden yararlanılmıştır. Karmaşıklık matrisinde doğru pozitif (DP), yanlış pozitif (YP), doğru negatif (DN) ve yanlış negatif (YN) olmak üzere dört değer bulunmaktadır. Matematiksel olarak Eşitlik 3-7'de verilmiştir [18]. Bu çalışmada başarı kriterlerinin bir diğer ölçütü olan alıcı işlem karakteristik eğrisinden de yararlanılmıştır. Bu eğrinin altında kalan alan tanı testlerinde

karşılaştırma amacıyla kullanılmaktadır. Yapılan deneysel çalışmalarda veri setinin %70'i eğitim için ayrılmıştır. Test için veri setinin %30'u ayrılmıştır.

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (3)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (4)$$

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (5)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (6)$$

$$\text{F-Skor} = \frac{2DP}{2DP+YP+YN} \quad (7)$$


Akciğer BT görüntülerini sınıflandırmak için CAM algoritması SqueezeNet modeli ile eğitilmiştir. Bu yöntemin SqueezeNet ESA modeline göre başarısına bakmak için ilk olarak veri seti SqueezeNet modeli ile sınıflandırılmıştır. Yapılan sınıflandırma sonucunda BT görüntüleri %92,71 doğruluk oranı ile sınıflandırılmıştır. Sınıflandırma sonucunda elde edilen başarı kriterleri sonuçları Çizelge 1'de karmaşıklık matrisi ve alıcı işlem karakteristiği (AİK) eğrisi sırasıyla Şekil 4 ve Şekil 5'te verilmiştir.

Çizelge 1. SqueezeNet modeli ile akciğer BT görüntülerinin sınıflandırma sonuçları

ESA Modeli	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F-Skor
SqueezeNet	92,71	79,82	96,18	91,02	82,47

İyi Huylu	15	0	21
Kötü Huylu	0	167	1
Normal	2	0	123
	İyi Huylu	Kötü Huylu	Normal

Şekil 4. SqueezeNet modeli ile akciğer BT görüntülerinin sınıflandırma sonucu elde edilen karmaşıklık matrisi



Şekil 5. SqueezeNet modeli ile akciğer BT görüntülerinin sınıflandırma sonucu elde edilen AİK eğrisi

İkinci aşamada CAM algoritması SqueezeNet ESA modeli ile eğitildikten SqueezeNet modeline göre görüntünün ayırt edici bölgeleri renklendirilmiştir ve ardından renklendirilen bölgelere ait özellikler çıkarılmıştır. Son olarak bu özellikler DVM ile


sınıflandırılmıştır. Sınıflandırma sonucunda %95,44 doğruluk oranı elde edilmiştir. DVM algoritması ile elde edilen başarı kriterleri Çizelge 2’de karmaşıklık matrisi ve AİK eğrisi ise Şekil 6 ve Şekil 7’de verilmiştir.

Çizelge 2. CAM algoritması özellikleri ile akciğer BT görüntülerinin SVM sınıflandırma sonuçları

Metod	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F-Skor
DVM	95,44	91,00	97,61	93,85	92,24

İyi Huylu	28	1	7
Kötü Huylu	1	164	3
Normal	2	1	122
	İyi Huylu	Kötü Huylu	Normal

Şekil 6. CAM algoritması özellikleri ile akciğer BT görüntülerinin SVM sınıflandırma sonucu elde edilen karmaşıklık matrisi



Şekil 7. CAM algoritması özellikleri ile akciğer BT görüntülerinin SVM sınıflandırma sonucu elde edilen AİK eğrisi

4. TARTIŞMA

Sigara içmenin başlıca bir faktörü olarak meydana gelen akciğer kanseri, kansere sebebi ölümde ilk sıralarda yer almaktadır. Erken evrede hastalık tespit edilip tedavi süreci başladığı takdirde bu hastalık ile baş etme oranı artmaktadır. Hastalık şüphesi ile kliniğe başvurulduğunda radyologlar tarafından çekilen akciğer BT görüntülerinin yorumlanması önem arz etmektedir. Bu çalışmada akciğer BT görüntüleri ile hastalığın yüksek doğruluk oranı ile tespit edilebilmesi için class activation map SqueezeNet ESA modeli ile eğitilerek BT görüntülerinde ayırt ediciliği yüksek olan bölgelerin tespit edilerek yapılmıştır. Ancak class activation map algoritması ile BT görüntüleri ile önemli bölgeleri renklendirildiği zaman bazı görüntülerde bazı görüntüler incelendiğinde ilgisiz bölgelerin renklendirildiği fark edilmiştir. Bu problemin ortadan kaldırılması için belki farklı ESA modelleri ile class activation map eğitilerek giderilebilir. Bu çalışmada kullanılan veri seti ile

yapılan çalışmaların önerilen model ile performans sonuçlarının karşılaştırılması Çizelge 3'te verilmiştir.

Çizelge 3. Aynı veri seti ile yapılan çalışmaların karşılaştırılması

Yazar	Yıl	Yöntem	Doğruluk Oranı (%)
Hamdalla ve arkadaşları [19]	2021	Ön işleme, segmentasyon, GLCM, DVM	89,88
G Ashwin ve arkadaşları [20]	2021	Ön işleme, bölge bazlı özellikler, Ensemble sınıflandırıcı	85
Bu çalışma	2022	InceptionResNe tV2, class activation map, DVM	95,44

Hamdalla [19], etkili bir sınıflandırma işlemi gerçekleştirmek için BT görüntülerinin gürültü gidermek için gauss filtresi uygulamışlardır. Ardından açık renkli olan pikseller beyaz renge koyular ise siyah renge dönüştürüldükten sonra otsu segmentasyon ile bölütleme işlemi yapılmıştır. Bölgeye ait öznelikler Gabor filtreleme ve gri seviyeli eş oluşum matrisi ile çıkarılarak DVM ile sınıflandırmıştır. Benzer şekilde G Ashwin [20] ve diğerleri de ön işleme ve segmentasyon işlemi için aynı yöntemi kullanmıştır. Ardından lezyon bölgesine ait geometrik şeklin çevresi, ortalama piksel yoğunluk değeri gibi el-yapımı özellikler çıkarıldıktan sonra en yüksek doğruluk oranı ensemle yöntem ile elde edilmiştir. Çalışmalarda geleneksel modeller yerine ESA modelleri görüntülere ait detaylı özellik öğrenme yeteneklerine sahip olduğundan dolayı görüntüler eğitildikten sonra konvolusyon veya tam bağlı katmana ait öznelikler ile sınıflandırma yapılsaydı daha iyi performans değerine ulaşabilirdi [21].

5. SONUÇ

Bu çalışmada akciğer BT görüntülerinin sınıflandırılması için InceptionResNetV2 modeli ile class activation map algoritmasıyla görüntülerin ayırt edici bölgeler başarılı bir şekilde tespit edilmiştir. Tespit edilen özneliklerin sınıflandırılması için DVM algoritması kullanıldı. Doğrudan InceptionResNetV2 modeli ile görüntüler %92,71 doğruluk oranı ile sınıflandırılırken class activation map ile önemli bölgelere ait özneliklerin DVM ile sınıflandırılması sonucun %95,44 doğruluk oranı elde edilmiştir.

Gelecekte farklı ESA modelleri ile class activation map eğitilerek geniş öznelik elde edildikten sonra sınıflandırma işlemi yapılması planlanmaktadır.

6. KAYNAKLAR

1. Chaudhary, A., Singh, S.S., 2012. Lung Cancer Detection on CT Images by Using Image Processing. International Conference on Computing Sciences (ICCS 2012), 142–146,

- Phagwara, India.
2. “Cancer,” 2020. <https://www.who.int/news-room/fact-sheets/detail/cancer>, Erişim Tarihi: 07.02.2022.
 3. Singh, G.A.P., Gupta, P.K., 2019. Performance Analysis of Various Machine Learning-based Approaches for Detection and Classification of Lung Cancer in Humans. *Neural Computing and Applications*, 31(10), 6863–6877.
 4. Toğaçar, M., Ergen, B., 2019. Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(1), 109–121.
 5. Gao, F., 2018. SD-CNN: A Shallow-Deep CNN for Improved Breast Cancer Diagnosis. *Computerized Medical Imaging and Graphics*, 70, 53–62.
 6. Song, Q., Zhao, L., Luo, X., Dou, X., 2017. Using Deep Learning for Classification of Lung Nodules on Computed Tomography Images. *Journal of Healthcare Engineering*, 1-7.
 7. Khan, M.A., 2020. Lungs Cancer Classification from CT Images: An Integrated Design of Contrast Based Classical Features Fusion and Selection. *Pattern Recognition Letter*, 129, 77–85.
 8. Toğaçar, M., 2021. Disease Type Detection in Lung and Colon Cancer Images Using the Complement Approach of Inefficient Sets. *Computers in Biology and Medicine*, 137, 104827.
 9. “The IQ-OTHNCCD Lung Cancer Dataset,” 2020, [Online]. Available: <https://www.kaggle.com/antonixx/the-iqothnccd-lung-cancer-dataset>. Erişim Tarihi: 01.02.2022.
 10. Iandola, F.N., Han, S., Moskewicz, M.W., Ashraf, K., Dally, W.J., Keutzer, K., 2016. SqueezeNet: AlexNet-Level Accuracy with 50x Fewer Parameters and < 0.5 MB Model Size. *arXiv Prepr. arXiv1602.07360*.
 11. Sayed, G.I., Soliman, M.M., Hassanien, A. E., 2021. A Novel Melanoma Prediction Model for Imbalanced Data Using Optimized Squeezenet by Bald Eagle Search Optimization. *Computers in Biology and Medicine*, 136, 104712.
 12. Fan, J., Bi, S., Xu, R., Wang, L., Zhang, L., 2022. Hybrid Lightweight Deep-Learning

- Model for Sensor-Fusion Basketball Shooting-Posture Recognition. *Measurement*, 189, 110595.
13. Ucar, F., Korkmaz, D., 2020. COVIDiagnosis-Net: Deep Bayes-SqueezeNet Based Diagnosis of the Coronavirus Disease 2019 (COVID-19) from X-ray Images. *Medical Hypotheses*, 140, 109761.
 14. Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., Torralba, A., 2016. Learning Deep Features for Discriminative Localization. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2016)*, 2921–2929. Las Vegas, USA.
 15. Zhang, R., Meng, F., Li, H., Wu, Q., Ngan, K.N., 2022. Category Boundary Re-Decision By Component Labels to Improve Generation of Class Activation Map. *Neurocomputing*, 469, 105–118.
 16. Cortes, C., Vapnik, V., 1995. Support-Vector Networks. *20(3)*, 273–297.
 17. Sonmez, M.E., Eczacıoglu, N., Gumuş, N.E., Aslan, M.F., Sabanci, K., Aşikkutlu, B., 2022. Convolutional Neural Network-support Vector Machine Based Approach for Classification of Cyanobacteria and Chlorophyta Microalgae Groups. *Algal Research*, 61, 102568.
 18. Toğaçar, M., Ergen, B., Sertkaya, M. E., 2019. Zatiürre Hastalığının Derin Öğrenme Modeli ile Tespiti. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31,1.
 19. Kareem, H.F., AL-Husieny, M.S., Mohsen, F.Y., Khalil, E.A., Hassan, Z.S., 2021. Evaluation of SVM Performance in the Detection of Lung Cancer in Marked CT Scan Dataset. *Indonesian Journal of Electrical Engineering and Computer Science*, 21(3), 1731–1738.
 20. Ashwin, S.G., Anurag, P.K., Reddy, N.V.S., Ashwath, R.B., 2022. Prediction of Lung Cancer Using Ensemble Classifiers. *Journal of Physics: Conference Series*. 2161, 1,12007.
 21. Kim, H., Jung, W.K., Park, Y.C., Lee, J.W., Ahn, S.H., 2022. Broken Stitch Detection Method for Sewing Operation Using CNN Feature Map and Image-processing Techniques. *Expert Systems with Applications*, 188, 116014.

