



Meme Kanseri Segmentasyonu için Topluluk Öğrenmesine Dayalı LinkNet Modeli

Furkan ATLAN^{1*}

¹ Asst. Prof. Dr., Burdur Mehmet Akif Ersoy University, Department of Management Information Systems,
Burdur, Türkiye

Geliş Tarihi/Received: 10.01.2025
Kabul Tarihi/Accepted: 16.03.2025

Doi: 10.31200/makuubd.1617565
Araştırma Makalesi/Research Article

ÖZET

Meme kanseri birçok ülkede kadınlar arasında en sık görülen kanser türüdür. Meme kanserinin tanı ve tedavisinde verilerin analizi büyük bir önem taşımaktadır. Histopatolojik görüntülerdeki kanserli hücre çekirdeklerinin segmentasyonu, uzmanlar için oldukça maliyetli ve zorlu bir iştir. Bu çalışmada, histopatolojik meme kanseri görüntülerinin çekirdek segmentasyonu için topluluk öğrenmesine dayalı LinkNet modeli önerilmektedir. Görüntüler, Kontrast Sınırlı Adaptif Histogram Eşitleme (CLAHE) tekniği ile işlendikten sonra veri artırma uygulanır. LinkNet modelinin kodlayıcı kısmında ResNeXT50 ve Vgg19 modellerinin yerleştirildiği iki ayrı model ile eğitilir. Sonrasında, bu modeller topluluk öğrenmesi ile birleştirilir ve maske tahmini yapılır. Çalışmada elde edilen 0.702 Kümülatif Jaccard İndeks (AJI) metriği sonucu, aynı veri seti ile yapılmış son çalışmalardan daha başarılı bulunmuştur.

Anahtar kelimeler: Meme Kanseri, Segmentasyon, Topluluk Öğrenmesi, LinkNet.

LinkNet Model Based on Ensemble Learning for Breast Cancer Segmentation

ABSTRACT

Breast cancer is the most common type of cancer among women in many countries. Data analysis is of great importance in the diagnosis and treatment of breast cancer. Segmentation of cancer cell nuclei in histopathological images is a very costly and challenging task for experts. In this study, A LinkNet model based on ensemble learning is proposed for kernel segmentation of histopathological breast cancer images. After the images are processed with the Contrast-Limited Adaptive Histogram Equalization (CLAHE) technique, data augmentation is applied. In the encoder part of the LinkNet model, it is trained with two separate models where ResNeXT50 and Vgg19 models are placed. Afterwards, these models are combined with ensemble learning and mask prediction is performed. The 0.702 Aggregated Jaccard Index (AJI) metric result obtained in the study was found to be more successful than recent studies conducted with the same data set.

Keywords: Breast Cancer, Segmentation, Ensemble Learning, LinkNet.

1. GİRİŞ

Histopatolojik görüntüler, genellikle ışık mikroskobu altında incelenen, hücre morfolojisi ve doku yapısı hakkında bilgi sağlayan görüntülerdir (Prabhu vd., 2022). Bu görüntüler tıbbi tanı konulması, kanser malignanti derecelendirmesi ve doku işlenmesi gibi farklı klinik uygulamalarda kullanılmaktadır (Abdelsamea vd., 2022). Bir patolog tarafından histopatolojik görüntülerin değerlendirilmesi oldukça zaman alıcı ve özeldir. Kanser, iyi-huylu kötü huylu tümör ayrımının yapılması ve hücrelerin segmentasyonu gibi görevlerde histopatolojik görüntüler bir altın standart olarak kabul edilmektedir (Bakkouri vd. 2022). İlaveten, histopatolojik görüntüleme hastalar için tanı konulmasında diğer görüntüleme tekniklerine nazaran daha kapsamlı ve güvenilir kanıtlar sunmaktadır (Aswathy & Jagannath, 2017).

Hücrelerin düzensiz çoğalması olarak tanımlanan kanser hastalığı Dünya genelinde her yıl milyonlarca insanın ölümüne neden olmaktadır (Bray vd., 2018). Dünyadaki 185 ülkenin 157'sinde kadınlar arasında en sık görülen hastalık olarak meme kanseri ilk sırada yer almaktadır (Ferlay vd., 2021). Türkiyede'de kadınlar arasında en yaygın kanser türü olarak meme kanseri gösterilmektedir (Türkiye Kanser İstatistikleri, 2018). Meme kanserinin tanı

aşamasında termografi, mamografi, histopatoloji ve dermoskopi gibi farklı görüntüleme tekniklerinden faydalanılsa da en yaygın ve doğru sonuç elde etme açısından histopatolojik görüntüleme tekniği kullanılmaktadır (Abdel-Halim vd., 2021).

Histopatolojik görüntülerde yer alan çekirdekleri doğru bir şekilde segmente etmek en temel görevdir. Bilhassa iç içe geçmiş hücre çekirdeklerinin birbirinden ayrılması, oldukça zorlu bir iştir. Bu çalışmada, histopatolojik görüntülerle meme kanseri segmentasyonu için topluluk öğrenmesine dayalı bir model önerilmektedir. TNBC (Naylor vd., 2018) veri setindeki histopatolojik görüntülere Kontrast Sınırlı Adaptif Histogram Eşitleme (CLAHE) tekniği uygulanır. Görüntüler daha sonra çevirme (flipping) ve kırpma (cropping) veri artırma teknikleri ile çoğaltılır. Ön işlenen bu histopatolojik görüntüler, meme kanseri segmentasyonu için LinkNet segmentasyon modeline aktarılır. LinkNet modelinin kodlayıcı kısmında, ResNeXt50 ve Vgg19 modelleri kullanılır. İki farklı derin öğrenme modelinin kodlayıcı olarak kullanıldığı önerilen yöntemde, her iki model birleştirilir ve iki modelin tahmininin ortalaması alınır. Meme kanseri segmentasyonu için önerilen yöntemin, aynı veri seti ile yapılan son çalışmalarla karşılaştırıldığında oldukça başarılı sonuçlar elde ettiği görülmektedir.

2. İLGİLİ ÇALIŞMALAR

Lee vd. (2020), ultrason görüntülerindeki meme kanserine ait alanların segmentasyonu için MSGRAP olarak adlandırdıkları bir yöntem önermiştir. Bu yöntem ile klasik evrişim işleminin aksine hem yerel hem de küresel özelliklerin öğrenilmesini sağlayan dikkat mekanizması kullanılmıştır. Çalışmada, doğruluk, F1 skor, kesişimlerin birleşimi (Intersection over Union [IoU]) metrikleri için sırasıyla 0.9779, 0.7658 ve 0.6226 sonucuna ulaşmıştır. Tsochatzidis vd. (2021), U-Net modelinin kodlayıcı kısmında ResNet50 modeli kullandıkları çalışmada DDSM-400 veri setindeki görüntüler için 0.738 Zar Benzerlik Katsayısı (Dice Similarity Coefficient [DSC]) ve 0.585 Jaccard Index (JI) skoruna ulaşmıştır. Qin vd. (2022) U-Net temelli TR-IMUnet adını verdikleri model ile segmentasyondan önce ilgisiz dokuların, segmente edilecek alan ile ilişkisini kesen ve küresel özelliklerin elde edilmesini sağlayan bir model geliştirmiştir. Geliştirilen bu model ile DS ve IoU metrikleri için 0.7741 ve 0.6539 sonucu elde edilmiştir. Huang vd. (2023), SX-Hospital olarak adlandırdıkları ve kendi elde ettikleri veri setindeki görüntüleri hem kontrast öncesi hem de kontrast sonrası özellikleri çıkarmak için ortak faz dikkat ağı modeli önermektedir. Önerdikleri bu model ile 83.03 ± 15.68 DS ve 73.23 ± 17.11 IoU sonucu elde edilmiştir. Samudrala ve Mohan (2024), meme kanseri segmentasyonu için PSPNet segmentasyon modelinin kodlayıcı kısmında DenseNet kullanan

bir model önermiştir. Geliştirdikleri bu model ile 0.9468 doğruluk skoru elde edilmiştir. Dhamale vd. (2025), çift taraflı çok ölçekli ağlar (DMSNet) adını verdikleri segmentasyon modeli ile farklı organlara ait segmentasyon işlevi gören bir model önermiştir. EfficientNetB5 kodlayıcısının hesaplama ve ölçekleme verimliliğinin piramit görüntü dönüştürücüsünün bağlamsal mantığıyla birleşmesine dayanan bu model ile meme kanseri segmentasyonu için oluşturulmuş olan BCSS veri seti üzerinde 0.7977 DS ve 0.7072 IoU sonucuna ulaşılmıştır. Aumente-Maestro vd. (2025), meme kanseri segmentasyonu için, meme kanseri sınıflandırması göreviyle segmentasyon arasındaki korelasyondan yararlanarak uçtan uca çok görevli bir yaklaşım önermiştir. Önerilen bu yaklaşım ile BUSI veri setindeki ultrason görüntülerinden elde edilmiş görüntülerdeki iyi huylu ve kötü huylu tümör segmentasyonunda sırasıyla 0.793 ve 0.72 DSC skoru elde edilmiştir.

Bu çalışmada, meme kanseri için histopatolojik görüntülerde çekirdek segmentasyonunun gerçekleştirilmesinde sadece kodlayıcı değişikliği uygulanmış bir modeli değil, aynı zamanda ön işleme teknikleri ile görüntülerin işlenmesini ve tahminleme aşamasında topluluk öğrenmesi yönteminin dahil edildiği güçlü bir yaklaşım önerilmektedir.

3. MATERYAL VE METOT

Deneyisel çalışmalar, 13. Nesil Intel Core i9 2.6 Ghz işlemci, NVIDIA RTX 4070 8GB ekran kartı ve 64 GB RAM kaynakları kullanılarak yapılmıştır.

3.1. TNBC Veri Seti

TNBC, 512x512 boyutunda 50 adet histopatolojik görüntüden oluşmaktadır. Veri seti içerisindeki görüntülerde toplam 4022 adet çekirdek yer almaktadır. TNBC veri seti, 11 hastadan alınmış üç farklı meme kanser çekirdek tipini içermektedir. TNBC veri seti için eğitim-test verisi ayrımı olarak %80-%20 oranı kullanılmıştır.

Histopatolojik görüntülerde yer alan çekirdeklerin segmente edilmesi görevi için, TNBC veri seti bu alandaki en popüler veri setleri arasında yer almaktadır.

3.2. Veri Ön İşleme

3.2.1. CLAHE

CLAHE, görüntülerin kontrastlarını ayarlamak için kullanılan bir tekniktir. Görüntüler, “tile” adı verilen pencerelere bölündükten sonra yerel olarak her grubun piksel yoğunluğu

artırılarak kontrast iyileştirmesi yapılır. Kontrast sınırlaması sayesinde, belirli piksel değerinin üzerinde olan pikseller kırpılır. Bu işlemlerden sonra, pencerelere bölünmüş görüntüler tekrar birleştirilir (Imtiaz vd., 2023).

3.2.2. Veri Artırma

Veri artırma, kullanılan farklı teknikler ile görüntülerin sayısının artırılmasıdır. Böylelikle, veri seti içerisinde çeşitlilik sağlanmış olur. Bu çalışmada, veri artırma işlemi için çevirme ve kırpma teknikleri kullanılmıştır. Çevirme işleminde görüntü, yatay (x), dikey (y) ve hem yatay hem de dikey (x-y) eksenlerde 180 derece döndürülür. Kırpma işleminde ise, görüntü yatay ve dikey eksenlerde rastgele seçilen piksel değerlerine göre kırpılır.

3.3. LinkNet

LinkNet (Chaurasia & Culurciello, 2017), semantik segmentasyon görevi için geliştirilmiş bir derin öğrenme modelidir. Kodlayıcı-kod çözücü temelli olan LinkNet'in 4 kodlayıcı, 4 kod çözücü blok olmak üzere 8 bloklu bir yapısı vardır.

3.4. Kodlayıcılar

3.4.1. ResNeXt50


ResNeXt50 modeli, 49 adet evrişim katmanı ve ağı sonundaki bir tam bağlı katmandan oluşan yapıya sahip bir derin öğrenme modelidir. ResNet ailesinin öğrenme yapısını baz alan bu modelde “kardinalite” adı verilen bir yenilik mevcuttur. Kardinalite, her bir evrişim bloğunu paralel bir şekilde sıralanmış evrişim grupları ile destekler. Her bir blok için farklı filtreler kullanılır ve bunlar aynı anda çalışır. Bu sayede modelin genişliği artar ve daha fazla özellik öğrenir (Tanwar & Singh, 2023).

3.4.2. Vgg19

Vgg19, Vgg16 (Simonyan & Zisserman, 2014) modelinin genişletilmiş bir versiyonudur. Vgg19 modelinde 16 adet evrişim katmanı, beş adet havuzlama katmanı ve son üç katmanda da tam bağlantı katmanı yer almaktadır. Vgg19 modeli, altı bloktan oluşan bir derin öğrenme modelidir.

3.5. Önerilen Yöntem

Şekil 1’de önerilen yöntem görsel olarak anlatılmaktadır.



Şekil 1: Önerilen yöntem

Histopatolojik görüntülerdeki meme kanseri segmentasyonu için önerilen yöntemde, görüntülere sırasıyla CLAHE ve veri artırma işlemi uygulanır. Daha sonra bu görüntüler LinkNet modelinin kodlayıcı tarafında ResNeXt50 ve Vgg19 modellerinin kullanıldığı iki modelle eğitilir. Sonrasında bu iki model topluluk öğrenmesi yöntemi ile birleştirilir. Topluluk öğrenmesi işleminde her iki model birleştirildikten sonra bu modellerin ortalaması alınarak maske görüntüleri tahmin edilir.

3.6. Metrikler

Önerilen yöntemin performansının değerlendirilmesi için doğruluk, DS, F1 skor ve kümülatif Jaccard İndeks (AJI) metrikleri kullanılmıştır. Denklem 1-4'te metriklerin formülleri sırayla verilmektedir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+FP+TN+FN} \quad (1)$$

Denklem (1)'de verilen DP, Doğru Pozitif; TN, Doğru Negatif; YP, Yanlış Pozitif; YN, Yanlış Negatif değerlerinin kısaltmasıdır.

$$DS = \frac{2*|g \cap \hat{g}|}{|g + \hat{g}|} \quad (2)$$

Denklem (2)'de verilen g segmente edilmiş temel gerçek çekirdek, $\hat{g}$ tahmin sonucunda elde edilmiş olan çekirdektir.

$$F1 \text{ Skor} = 2 * \frac{\text{Hatırlama} * \text{Hassasiyet}}{\text{Hatırlama} + \text{Hassasiyet}} \quad (3)$$

F1 Skor metriği, sınıflandırmada sıklıkla kullanılan iki metriğin ölçümüyle ilişkilidir. Buna göre, Hassasiyet, doğru sınıflandırılmış pozitif örneklerin sayısının, sınıflandırılmış pozitif örneklerin toplam sayısına oranıdır ve Hatırlama, doğru sınıflandırılmış pozitif örneklerin sayısının, gerçek sınıftaki toplam örnek sayısına oranıdır.

$$AJI = \frac{\sum_{i=1}^{nq} |G_i \cap S(G_i)|}{\sum_{i=1}^{nq} |G_i \cup S(G_i)| + \sum_{k \in K} |S_k|} \quad (4)$$

Denklem (4)'te verilen AJI formülünde nq segmente edilmiş çekirdeklerin sayısını, G_i segmente edilmiş çekirdeklerin kümesini, $S(G_i)$ eşleşen parçalı çekirdeklerin kümesini ve S_k segmente edilmiş çekirdekler ile eşleşmeyen parçalı çekirdeklerin kümesini temsil etmektedir (Zhang vd., 2021). AJI, yanlış örtüşen tahminleri cezalandırmada diğer metriklerle göre daha kararlı ve acımasız olduğundan dolayı segmentasyon çalışmalarında başarıyı belirleyen çok kritik bir ölçüttür (Hançer vd., 2023). Bu nedenden dolayı bu çalışmada da topluluk öğrenmesinde en çok üzerinde durulan metrik AJI olmuştur.

4. BULGULAR VE TARTIŞMA

Tablo 1'de LinkNet modelinin kodlayıcı kısmında kullanılan modellere (LinkNet-ResNeXt50 ve LinkNet-Vgg19) ve bu iki modelin birleştirilmesiyle geliştirilen önerilen yönteme ait sonuçlar verilmektedir. En başarılı sonuçlar kalın punto ile belirtilmiştir.

Tablo 1. Segmentasyon modellerine ait sonuçlar


Model	Doğruluk	DSC	F1 Skor	AJI
LinkNet-ResNeXt50	0.9706	0.822	0.8255	0.6893
LinkNet-Vgg19	0.9691	0.8239	0.8273	0.6851
Önerilen yöntem	0.9717	0.8249	0.8282	0.702

Deneyisel sonuçların yürütülmesinde Tensorflow kütüphanesi (2.9.0 sürümü) kullanılmıştır. Adam optimize edicisi (optimizer), 0.0001 öğrenme hızı (learning rate) ile 20 devir (epochs) boyunca çalıştırılmıştır.

LinkNet modelinin kodlayıcı tarafında kullanılan ResNeXt50 ve Vgg19 modelleri karşılaştırıldığında her iki kodlayıcının da birbirine yakın başarılı sonuçlar elde ettiği görülmektedir. DS, F1 skor gibi segmentasyon çalışmalarındaki önemli metriklerde Vgg19 kodlayıcısı ResNeXt50 kodlayıcısına göre daha başarılı sonuç elde etmişken AJI metriğinde ise daha düşük bir sonuç elde etmiştir. Bunun nedeni olarak, DS ve F1 skor metriklerinin

değerlendirme yaptığında piksel bazında değerlendirme yaparken, AJI metriği ise gerçek görüntü ile tahmin edilen maske görüntüsünün ne kadar örtüştüğüne dikkat etmektedir. Şekil 2’de çalışmada kullanılan üç farklı modele ait tahmin görüntüleri verilmektedir.

ResNeXt50 ve Vgg19 modellerinin topluluk öğrenmesi yöntemiyle birleştirilip tahminlerin ortalamasının alınmasını sağlayan ve çalışmada önerilen yöntemle ait sonuçlara bakıldığında ise tüm metrikler açısından bir artış olduğu görülmektedir. Özellikle, AJI metriğindeki artış oldukça dikkat çekici ve çalışmada önerilen yöntem açısından ümit vericidir. Diğer metriklere nazaran AJI metriğindeki bu artışın sebebi olarak, her iki modelin birleştirilerek tahminlerinin ortalamasının alınmasının hataları dengelediği düşünülmektedir. Her iki modeldeki eksiklikler model birleştirmesi ile giderilmiştir ve bu sayede daha başarılı ve birbiriyle örtüşen, sınırları pek aşılmamış başarılı bir tahmin üretildiği anlaşılmaktadır.



Şekil 2. Modellerle ait tahmin sonuçları (a) CLAHE uygulanmış giriş görüntüsü, b) orijinal maske, c) ResNeXt50 kodlayıcısı, d) Vgg19 kodlayıcısı, e) önerilen yöntem)

Şekil 2’de verilen orijinal maske ve farklı kodlayıcılarla tahmin edilen maskeler göz önüne alındığında görsel olarak çok bir fark görülmeyebilir. Ancak, önerilen yöntem ile tahmin edilen maske görüntülerinin Tablo 1’deki performans değerlendirme metrikleri sonuçları incelendiğinde daha başarılı sonuçlar verdiği ortadadır.

Çalışmada kullanılan topluluk öğrenmesi yöntemi, toplama kuralı (sum rule) tekniğine bağlı olan yumuşak oylama (soft voting) yaklaşımıdır.

Bu yöntemde, her bir modelin ilgili görüntü için ürettiği olasılık haritaları elde edilerek aynı boyutlarda olacak şekilde toplanmış ve ortaya çıkan toplam tahmin maskesi üzerinde belirlenen bir eşik değeri aracılığıyla ikili sınıflandırma gerçekleştirilmiştir. Belirlenen eşik değeri, toplam tahmin skorlarının model sayısına oranla belirli bir güven seviyesini aşmasını gerektirecek şekilde yapılandırılmıştır. Böylece, her pikselin pozitif sınıfa atanabilmesi için modellerin en az yarısının bu piksel üzerinde yüksek olasılık değeri üretmesi sağlanmıştır. Bu yaklaşım, her bir modelin kararına eşit ağırlık vererek ortak bir sonuca ulaşmayı hedefleyen yumuşak oylama tabanlı bir toplama kuralı olup, bireysel model hatalarını minimize ederek genel performansı artırmayı amaçlamaktadır.

TNBC veri seti yapılmış son çalışmalara ait sonuçlar incelendiğinde bu çalışmada önerilen yöntem ile elde edilen sonuçların literatürdeki son çalışmalardan daha başarılı olduğu görülmektedir. Özellikle AJI metriği için elde edilen sonuca en yakın skor Chanchal vd. (2022) tarafından elde edilmiştir. Chanchal vd. (2022) tarafından elde edilen skor ise bu çalışmada sadece ResNeXt50 kodlayıcısı ile elde edilen sonuçtan daha düşüktür. Bu durum hem seçilen kodlayıcıların tercihindeki başarıyı hem de topluluk öğrenmesi ile elde edilen ve iyileştirilen sonuçların başarısını göstermektedir. Tablo 2’de TNBC veri seti ile yapılmış son çalışmalar ile bu çalışmada önerilen yöntemin karşılaştırması verilmektedir. En iyi sonuçlar kalın punto ile belirtilmiştir.

Tablo 2. TNBC veri seti ile yapılmış son çalışmaların karşılaştırması

Model	Doğruluk	DS	F1 Skor	AJI
SPN (Liu vd., 2022)	-	0.7492	0.76	0.5854
DSREDN (Chanchal vd., 2022)	-	-	0.7653	0.6854
MFFNet (Li vd., 2023)	0.954	-	0.813	0.642
BAWGNet (Imtiaz vd., 2023b)	0.8294	0.7857	-	-
Robust Nuclei Segmentation (Gour vd., 2024)	-	-	0.8376	0.611
ANet (Kadaskar vd., 2024)	-	0.753	-	0.559
Önerilen yöntem	0.9717	0.8249	0.8282	0.702

5. SONUÇLAR

Meme kanserinin farklı görüntüleme teknikleri ile elde edilen görüntülerinin analizi oldukça zor bir iştir. Kanserli görüntülerdeki hücre çekirdeklerinin segmentasyonu için derin öğrenme modelleri kullanılmaktadır. Bu çalışmada TNBC veri setinde yer alan görüntüler ile topluluk öğrenmesine dayalı segmentasyon modeli geliştirilmiştir. Çalışmada, histopatolojik meme kanseri görüntülerinin segmentasyonu için önerilen model, aynı veri seti ile yapılan son çalışmalarla karşılaştırıldığında başarılı bulunmuştur. Elde edilen sonuçların literatürdeki sonuçlardan daha iyi olduğu görülmektedir. Segmentasyon görevlerinde yanlış tahmin edilen ve çerçeve sınırlarını aşan pikselleri ağır şekilde cezalandıran AJI metriği için topluluk öğrenmesiyle birleştirilen modellerden elde edilen sonuçlarda iyileştirme görülmüştür. Sonraki yapılacak çalışmalarda topluluk öğrenmesi için farklı tekniklerin kullanılması, kodlayıcı ve segmentasyon modeli olarak farklı modeller ile optimizasyon yapılması düşünülebilir.

ARAŞTIRMACILARIN KATKI ORANI BEYANI

Araştırmacıların çalışmaya katkı oranları eşittir.

ÇATIŞMA BEYANI

Çalışma kapsamında herhangi bir kurum veya kişi ile çıkar çatışması bulunmamaktadır.

REFERENCES / KAYNAKLAR

Prabhu, S., Prasad, K., Robels-Kelly, A., & Lu, X. (2022). AI-based carcinoma detection and classification using histopathological images: A systematic review. *Computers in Biology and Medicine*, 142, 105209.

Abdelsamea, M. M., Zidan, U., Senousy, Z., Gaber, M. M., Rakha, E., & Ilyas, M. (2022). A survey on artificial intelligence in histopathology image analysis. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 12(6), e1474.

Bakkouri, I., Afdel, K., Benois-Pineau, J., & Initiative, G. C. F. T. A. S. D. N. (2022). BG-3DM2F: Bidirectional gated 3D multi-scale feature fusion for Alzheimer's disease diagnosis. *Multimedia Tools and Applications*, 81(8), 10743-10776.

Aswathy, M. A., & Jagannath, M., (2017). Detection of breast cancer on digital histopathology images: Present status and future possibilities. *Informatics in Medicine Unlocked*, 8, 74-79.

Bray, F., Ferlay, J., Soerjomataram, I., Siegel, R. L., Torre, L. A., & Jemal, A. (2018). Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: A Cancer Journal for Clinicians*, 68(6), 394-424.

Ferlay, J., Colombet, M., Soerjomataram, I., Parkin, D. M., Piñeros, M., Znaor, A., & Bray, F. (2021). Cancer statistics for the year 2020: An overview. *International Journal of Cancer*, 149(4), 778-789.

T.C. Sağlık Bakanlığı Halk Sağlığı Genel Müdürlüğü. Türkiye Kanser İstatistikleri 2018. Erişim adresi: <https://hsgm.saglik.gov.tr/tr/kanser-istatistikleri.html>, 2024.

Abdel-Halim, C. N., Rosenberg, T., Dyrvig, A. K., Høilund-Carlsen, P. F., Sørensen, J. A., Rohde, M., & Godballe, C. (2021). Diagnostic accuracy of imaging modalities in detection of histopathological extranodal extension: A systematic review and meta-analysis. *Oral Oncology*, 114, 105169.

Naylor, P., Laé, M., Reyat, F., & Walter, T. (2018). Segmentation of nuclei in histopathology images by deep regression of the distance map. *IEEE Transactions on Medical Imaging*, 38(2), 448-459.

Lee, H., Park, J., & Hwang, J. Y., (2020). Channel attention module with multiscale grid average pooling for breast cancer segmentation in an ultrasound image. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, 67(7), 1344-1353.

Tsochatzidis, L., Koutla, P., Costaridou, L., & Pratikakis, I. (2021). Integrating segmentation information into CNN for breast cancer diagnosis of mammographic masses. *Computer Methods and Programs in Biomedicine*, vol. 200, pp. 105913.

Qin, C., Wu, Y., Zeng, J., Tian, L., Zhai, Y., Li, F., & Zhang, X. (2022). Joint transformer and multi-scale CNN for DCE-MRI breast cancer segmentation. *Soft Computing*, 26(17), 8317-8334.

Huang, R., Xu, Z., Xie, Y., Wu, H., Li, Z., Cui, Y., ... & Wang, Y., (2023). Joint-phase attention network for breast cancer segmentation in DCE-MRI. *Expert Systems with Applications*, 224, 119962.

Samudrala, S., & Mohan, C. K. (2024). Semantic segmentation of breast cancer images using DenseNet with proposed PSPNet. *Multimedia Tools and Applications*, 83(15), 46037-46063.

Imtiaz, T., Fattah, S. A., & Saquib, M., (2023). ConDANet: Contourlet driven attention network for automatic nuclei segmentation in histopathology images. *IEEE Access*.

Chaurasia, A., & Culurciello, E., (2017). Linknet: Exploiting encoder representations for efficient semantic segmentation. In *2017 IEEE Visual Communications and Image Processing (VCIP)*, 1-4, IEEE.

Tanwar, S., & Singh, J. (2023). ResNext50 based convolution neural network-long short term memory model for plant disease classification. *Multimedia Tools and Applications*, vol. 82(19), 29527-29545.

Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.

Zhang, J., Li, C., Kosov, S., Grzegorzec, M., Shirahama, K., Jiang, T., ... & Li, H. (2021). LCU-Net: A novel low-cost U-Net for environmental microorganism image segmentation. *Pattern Recognition*, 115, 107885.

Hancer, E., Traore, M., Samet, R., Yıldırım, Z., & Nemati, N. (2023). An imbalance-aware nuclei segmentation methodology for H&E stained histopathology images. *Biomedical Signal Processing and Control*, 83, 104720.

Liu, W., He, Q., & He, X. (2022). Weakly supervised nuclei segmentation via instance learning. In *2022 IEEE 19th International Symposium on Biomedical Imaging (ISBI)*, 1-5, IEEE.

Chanchal, A. K., Lal, S., & Kini, J. (2022). Deep structured residual encoder-decoder network with a novel loss function for nuclei segmentation of kidney and breast histopathology images. *Multimedia Tools and Applications*, 81(7), 9201-9224.

Li, X., Pi, J., Lou, M., Qi, Y., Li, S., Meng, J., & Ma, Y. (2023). Multi-level feature fusion network for nuclei segmentation in digital histopathological images. *The Visual Computer*, 39(4), 1307-1322.

Imtiaz, T., Fattah, S. A., & Kung, S. Y. (2023). BAWGNet: Boundary aware wavelet guided network for the nuclei segmentation in histopathology images. *Computers in Biology and Medicine*, 165, 107378.

Gour, M., Jain, S., & Kumar, T. S. (2024). Robust nuclei segmentation with encoder-decoder network from the histopathological images. *International Journal of Imaging Systems and Technology*, 34(4), e23111.

Kadaskar, M., & Patil, N. (2024). ANet: Nuclei instance segmentation and classification with attention-based network. *SN Computer Science*, 5(4), 348.

Dhamale, A., Rajalakshmi, R., & Balasundaram, A. (2025). Dual multi scale networks for medical image segmentation using contrastive learning. *Image and Vision Computing*, 154, 105371.

Aumente-Maestro, C., Díez, J., & Remeseiro, B. (2025). A multi-task framework for breast cancer segmentation and classification in ultrasound imaging. *Computer Methods and Programs in Biomedicine*, 260, 108540.