

Meme Ultrason Görüntülerinde Kanserli Hücre Segmentasyonu İçin Yeni Bir FCN Modeli

Cüneyt ÖZDEMİR¹

¹Siirt Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Siirt

e-posta: cozdemir@siirt.edu.tr. ORCID ID: <http://orcid.org/0000-0002-9252-5888>

Geliş Tarihi: 02.03.2023

Kabul Tarihi: 18.09.2023

Öz

Meme kanseri kadınlar arasında yaygın bir hastalıktır. Zamanında teşhis ve uygun müdahale, iyileşme beklentilerini önemli ölçüde artırır ve hastalığın ilerlemesini engeller. Meme kanserinin görsel görüntüleri, meme dokusunu kötü huylu ve kötü huylu olmayan alanlara ayırmaya hizmet ederek, kötü huylu hücrelerin ayırt edilmesi, tümör boyutlarının değerlendirilmesi ve neoplazmın evrelendirilmesi dahil olmak üzere çok önemli bilgiler sağlar. Meme kanseri taramaları, özellikle genç ve hamile kadınlar grubundaki hassasiyetleri iyileştirmek için yürürlüğe konmuştur. Bununla birlikte, radyografik tasvirlerin incelenmesinin yanlışlıkla bazı incelikleri gözden kaçırabileceği durumlar da vardır. Gelişmiş yapay zeka paradigmaları, sofistike hesaplama metodolojileri ile birleştiğinde, daha yüksek hassasiyette sonuçlar elde etmek için kullanılmaktadır. Bu bağlamda, ultrason teknolojisi tarafından kolaylaştırılan segmentasyon metodolojisi çok önemli bir müdahale olarak ortaya çıkmaktadır. Mevcut araştırmada, sapmaların tanımlanması ve kanserojen bölgelerin belirlenmesi için U-Net ve yenilikçi bir Fully Convolutional Network mimarisinden yararlanılmıştır. Bu çalışma kapsamında önerilen Fully Convolutional Network mimarisi, test görüntülerinde %77,2 MeanIoU, %71,6 precision, %77,7 recall ve %74,5 F1 skoru elde edilmiştir. U-Net modeli ile %76,4 MeanIoU, %67,6 precision, %80,4 recall ve %73 F1 skoru elde edilmiştir. Bulgular, önerilen Fully Convolutional Network mimarisinin U-Net modeline göre daha iyi performans sergilediğini ortaya koymuştur. Bu sonuçlar, meme kanseri teşhisi ve tedavisi için segmentasyon işleminin önemini vurgulamakta ve önerilen Fully Convolutional Network mimarisinin U-Net mimarisinden daha başarılı olduğunu ortaya koymaktadır.

Anahtar kelimeler

Fully Convolutional Network; U-Net; Meme görüntüsü; Kanserli hücre; Segmentasyon

A New FCN Model for Cancer Cell Segmentation in Breast Ultrasound Images

Abstract

Breast cancer stands as a widespread ailment among women. Timely diagnosis and appropriate intervention significantly enhance prospects of recovery and thwart disease progression. Visual representations of breast cancer serve to delineate breast tissue into malignant and non-malignant regions, offering crucial insights, including the discernment of malignant cells, assessment of tumor dimensions, and staging of the neoplasm. Breast cancer screenings are implemented to ameliorate sensitivities, especially within the cohort of young and pregnant women. However, instances exist wherein the examination of radiographic portrayals may inadvertently overlook certain intricacies. Advanced artificial intelligence paradigms, coupled with sophisticated computational methodologies, are harnessed to attain outcomes of heightened precision. In this context, the segmentation methodology facilitated by ultrasound technology emerges as a pivotal intervention. In the present study, U-Net and an innovative Fully Convolutional Network architecture are utilized to identify deviations and demarcate carcinogenic zones. Within the scope of this research, the proposed Fully Convolutional Network architecture achieves a MeanIoU of 77.2%, precision rates of 71.6%, recall rates of 77.7%, and an F1 score of 74.5% in testing images. Conversely, the U-Net model yields comparable performance metrics, manifesting a MeanIoU of 76.4%, precision of 67.6%, recall of 80.4%, and an F1 score of 73%. Notably, the findings underscore the superiority of the proposed Fully Convolutional Network paradigm over the U-Net architecture. These results accentuate the significance of segmentation methodologies in the realm of breast cancer diagnosis and treatment, thus affirming the

Keywords

Fully Convolutional Network ; U-Net; Breast image; Cancer cell; Segmentation

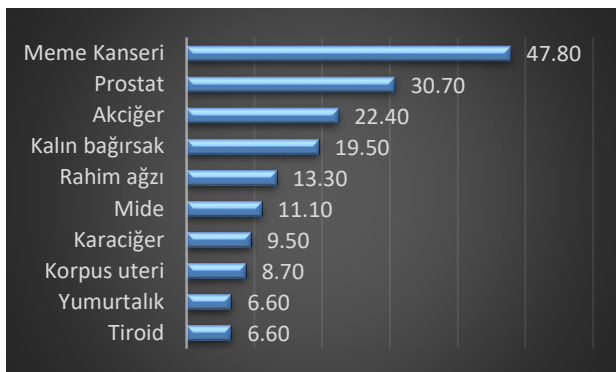
1. Giriş

Kanser, vücudun herhangi bir dokusunda anormal hücrelerin kontrolsüz bir şekilde çoğalması sonucu oluşan bir hastalık olarak tanımlanır. Bu hastalık, genellikle başlangıçta vücutta meydana gelen hücre anormalliklerin çevre dokulara yayılması veya diğer organlara sıçramasıyla karakterizedir. Kanser, tıpta neoplazma veya kötü huylu tümör olarak da adlandırılır.


Düşük veya orta gelirli birçok ülkede, sağlık sistemlerinin zayıf olması nedeniyle kanser hastaları, doğru zamanda teşhis ve tedaviye erişememektedir. Bu durum, hastalığın ileri aşamalarda teşhis edilmesine ve daha az etkili tedavilere başvurulmasına yol açarak yaşam oranını düşürmektedir. Ancak, güçlü sağlık sistemlerine sahip ülkelerde erken teşhis ve kaliteli tedavi sayesinde kanser hastalarının yaşama oranı daha yüksek olmaktadır (1).

Kanser, dünya genelinde önemli bir halk sağlığı sorunudur. 2018 yılında altı ölümden biri kansere bağlı olarak gerçekleşmiştir. Dünya çapında tahminen 9.6 milyon ölümlerle, kanser en sık görülen ikinci ölüm nedenidir.

Özellikle 2020 yılında Uluslararası Kanser Araştırma Ajansı'na göre, meme kanseri Dünya genelinde en yaygın görülen kanser türüdür (2). Şekil 1'de Uluslararası Kanser Araştırma Ajansı tarafından dünyada görülen kanser türleri gösterilmiştir. Şekil 2'de Dünya sağlık örgütü Uluslararası Kanser Araştırma Ajansı'na (2) göre Türkiye'de 2020 yılında en fazla görülen kanser türleri gösterilmiştir.



Şekil 1. Dünyada 2020 yılında görülen kanser türleri (2)



Şekil 2. 2020 yılında Türkiye'de görülen kanser türleri (2)

Şekil 2'den görüldüğü gibi meme kanseri Türkiye'de en fazla görülen kanser türüdür.

Meme kanserinin teşhisinde mamografi, manyetik rezonans görüntüleme (MR), ultrason ve tomografi gibi medikal görüntüleme yöntemleri kullanılır. Kesin teşhis, meme dokusundan alınan örneklerin patolojik olarak incelenmesiyle elde edilir. Bu test sonucunda kanser hakkında net bir değerlendirme yapılır. Biyopsi dışında mamografi, meme dokularının X ışınlarıyla çekildiği bir yöntem ve meme ultrasonu meme dokularını ses dalgalarıyla görüntülemek için kullanılır. Ultrasonografi, meme kanserinin tanısında önemli bir rol oynar ve meme dokusunun iç yapısını incelemek için kullanılır (Loukas vd. 2013, Joy vd. 2005).

Meme kanserinin erken teşhisi, başarılı tedavi ve iyileşme potansiyelini artırabilir. Zamanında teşhis sadece tedavi sürecinin zorluklarını hafifletmekle kalmaz, aynı zamanda cerrahi gereksinimleri ve yoğun kemoterapi ve radyasyon tedavilerine duyulan ihtiyacı da azaltır. Ayrıca, erken teşhis toplam tedavi maliyetinin azalmasına da katkıda bulunabilir.

Mammografi veya manyetik rezonans (MR) gibi tekniklerle elde edilen radyolojik görüntüler,

kanserli hücrelerin varlığını tespit etmek için incelenir. Bununla birlikte, insan gözüyle yapılan incelemelerde, görüntüleri inceleyen kişilerin yeterli uzmanlık veya tecrübeye sahip olmaması, görüntülerdeki detayların gözden kaçmasına neden olabilir. Bu durum, kanserin doğru şekilde tespit edilememesi ve tedavinin etkinliğinin azalması gibi sonuçlar doğurabilir. Bu nedenle, radyolojik görüntülerin daha doğru bir şekilde analiz edilmesi için gelişmiş görüntü işleme teknikleri ve yapay zeka algoritmaları gibi yöntemler kullanılmaktadır. Bu teknikler sayesinde, görüntüler daha etkili bir şekilde incelenebilir ve kanserli hücrelerin varlığı daha doğru bir şekilde tespit edilebilir. Görüntülerin işlenmesi ve analizinde kullanılan yöntemlerden biri segmentasyon yöntemidir.

Segmentasyon, meme dokusunun kanserli ve kanserli olmayan bölgelerinin ayrıştırılmasıyla kanserli hücrelerin tespit edilmesi, tümör boyutunun ölçülmesi ve kanserin evrelemesi gibi önemli bilgilerin elde edilmesini sağlayan bir yöntemdir. Ayrıca, kanserli dokunun sağlıklı dokudan ayırt edilmesi, kanserin sınırlarının belirlenmesi ve tedavi planlarının oluşturulması açısından büyük bir öneme sahiptir. Görüntü segmentasyonu, radyolojik görüntülerde kanserli hücreleri tanımlamak için kullanılan bir yaklaşımdır. Özellikle derin öğrenme teknikleri ile gerçekleştirilen görüntü segmentasyonu, yüksek hassasiyetli sonuçlar elde edebilir ve meme kanserinin erken teşhisine önemli katkı sağlayabilir. Bu yaklaşım, görüntülerin daha ayrıntılı bir şekilde incelenmesine ve kanserli hücrelerin daha kolay tespit edilmesine olanak tanır. Bu da daha doğru teşhis koymayı mümkün kılar ve hastalığın erken evrelerde teşhis edilmesine yardımcı olur.

Derin öğrenme, makine öğrenme disiplininin alt dallarından biridir. Makine öğrenmesi, sağlık, gıda, robotik gibi birçok alanda geniş bir kullanım alanına sahip olan bir teknolojidir (Dogan vd. 2022, Atas vd. 2022, Dogan vd. 2023, Kılıç vd. 2021). Derin öğrenme, yapay sinir ağı gibi algoritmaları kullanarak veri setlerindeki karmaşık ilişkileri ve yapıları anlamaya çalışır. Bu sayede öğrenme sürecini gerçekleştirir ve birçok alanda etkili sonuçlar elde ederek yenilikçi çözümler sunar. Özellikle medikal görüntülerin analizinde, derin

öğrenme yöntemlerinin kullanımı oldukça yaygındır. Bu bağlamda, medikal görüntü segmentasyonunda sıklıkla tercih edilen bir derin öğrenme modeli olan "U-Net" bulunmaktadır.

Bu çalışmanın ana amacı, meme kanserinin erken teşhisinde görüntü işleme ve derin öğrenme tekniklerinin etkili bir şekilde kullanılabilirliğini incelemektir. Bu hedefi gerçekleştirmek adına, U-Net ve yeni bir Fully Convolutional Network (FCN) mimarisi gibi derin öğrenme yöntemleri kullanılarak meme kanserinin tespitinde daha etkili sonuçlar elde edilmesi amaçlanmıştır.

Bu araştırma kapsamında, kanserli meme bölgelerindeki anormal hücrelerin teşhisinde önerilen yeni bir FCN mimarisi sunulmuştur. Özellikle meme kanseri görüntülerine yönelik olarak geliştirilen bu FCN mimarisi ile U-Net mimarisi arasındaki performans farklılıkları karşılaştırılmıştır. Bu çalışma, medikal görüntüleme alanında yeni bir makine öğrenimi yöntemi sunma amacı taşımaktadır. Ayrıca, önerilen FCN yönteminin tıbbi görüntüleme pratiğinde daha geniş bir kullanım alanı bulması ve hastalıkların daha hassas ve doğru bir şekilde teşhis edilmesine katkı sağlaması öngörülmektedir.

2. Literatür

Literatürde, farklı veri setleri ve yöntemler ile meme kanseri tespiti için çeşitli çalışmalar yapılmıştır. Bu çalışmalar, meme kanserinin erken teşhisini ve tedavisini iyileştirmeyi amaçlamaktadır. Bu çalışmalardan bazıları şunlardır:

Motta ve vd. (2010), görüntü işleme tekniklerini içeren bir dizi yöntemle birlikte, ilgi alanı (ROI) segmentasyonunu sağlayan bir çalışma geliştirmiştir. Bu çalışmada, öncelikle Otsu eşiklemeyle arka plan temizlenmiş ve ardından morfoloji ve Canny kenar tespitçisi ile istenmeyen bölgeler belirlenerek kaldırılmıştır. Hough dönüşümü ve adaptif iyileştirme ile meme segmentasyonu gerçekleştirilmiştir.

Marques vd. (2012), görüntü işleme tekniklerini kullanarak, meme üst, alt ve yan sınırlarını belirlemeye dayalı bir segmentasyon yöntemi önermişlerdir. Bu yöntem, sınır tespiti, eşikleme,

bölge büyütme ve Least Squares ve B-Splines ile eğri uyumunu içermektedir.

Baffa vd. (2016), uyarlanabilir iyileştirme eşliğine dayalı bir segmentasyon yöntemi geliştirmiştir. Bu yöntemde, meme üst ve alt bölgeleri önce Otsu eşikleme ile tespit edilmiş, ardından arka plan temizlenerek uyarlanabilir eşikleme kullanılarak meme iç bölgeleri belirlenmiştir.

Marques vd. (2016), görüntü işleme tekniklerini içeren bir segmentasyon yöntemi geliştirmiştir. Bu yöntemde eşikleme, kümeleme, kenar algılama ve iyileştirme gibi tekniklerin bir kombinasyonu kullanılmıştır. Yöntem, DMR-UFF veri tabanından alınan 328 IR görüntüsü üzerinde test edilmiştir.

Ancak, ilerleyen teknoloji ile birlikte, Evrimsel Sinir Ağı (ESA), son yıllarda görüntü işleme alanında büyük bir yenilik olarak öne çıkmış ve kanserli hücre tespitinde etkili sonuçlar sunmuştur.

Melo vd. (2017), IR görüntülerinde ROI'yi bölümlere ayırmak için bir ESA geliştirmiştir. Bu yöntem, Görsel Geometrik Grup (VGG-CNN) mimarisi temel alınarak tasarlanmıştır. Eğitim ve test, DMR-UFF veri tabanından yaklaşık 285 görüntü kullanılarak gerçekleştirilmiştir.

Ozan vd. (2018), Attention-UNet modeli ile hedeflenen nesnenin boyutu ve şeklinin değiştiği durumlarda daha iyi özellik gösterimleri elde ettiklerini belirtmiştir. Bu model, önemsiz özellikleri dikkate almayı kısıtlayarak bölütleme görevinde yüksek bir performans sergilemiştir.

Zongwei vd. (2018), geliştirdikleri UNet++ yöntemiyle kodlayıcı ve kod çözücüyü iç içe geçmiş bir evrişim yapısı ile birleştirerek yöntemin performansını artırdıklarını, ancak, ağır karmaşıklığı eğitimi zorlaştırdığını ifade etmiştir.

Mendes vd. (2020), IR görüntüleme ilgi bölgesini belirlemek için Genetik Algoritmalar temelli bir segmentasyon yöntemi önermiştir. Yöntem, ROI algılama sürecinde en iyi uyan bir kardoid işlevi geliştirmeyi içermektedir.

Baffa vd. (2021), geleneksel U-Net mimarisini temel alan ve meme IR görüntüleri üzerinden DMR için önden görünüm edinimi ile eğitilen basitleştirilmiş bir CNN mimarisi önermiştir.

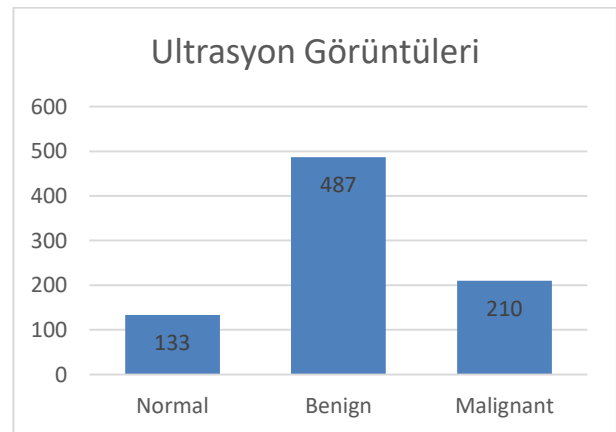
Yang vd. (2021), otomatik göğüs tümörü segmentasyonu için bölge tabanlı evrişimli sinir ağı (R-CNN) adlı bir model tasarlamışlardır. Bu model, segmentasyon görevinde üstün sonuçlar elde etmiştir. Ancak, modelin performansını görüntü kalitesi ve tümör boyutu gibi faktörlerin sınırladığı ifade edilmiştir. Bu sınırlamaların üstesinden gelmek için daha gelişmiş görüntü işleme teknikleri ve daha hassas tümör boyutu tespit yöntemlerine ihtiyaç duyulduğu ifade edilmiştir.

3. Materyal ve Metot

Çalışmada öncelikle, ultrason görüntüleri ve bu görüntülere ait etiketlenen maskeler ön işleme işlemine tabi tutulmuştur. Daha sonra, veri seti bir makine öğrenimi modeline uyacak şekilde hazırlanmış ve görüntüler eğitim, doğrulama ve test kümelerine ayrılmıştır. Eğitim işlemi, denetimli bir öğrenme yaklaşımı kullanılarak maskelerin çıktılarına dayanarak gerçekleştirilmiştir.


3.1 Veri Seti

Görüntüler Dhabyani tarafından erişime açık olarak dağıtılan meme kanseri görüntülerinden oluşmaktadır (Al-Dhabyani vd. 2020). Görüntüler 2018 yılında 600 kadın hastadan toplanmıştır. Görüntüler 25 ile 75 yaş arasındaki kadınlar arasındaki meme ultrason görüntülerinden oluşmaktadır. Veri seti, ortalama görüntü boyutu 500*500 piksel olan 780 görüntüden oluşmaktadır. Görüntüler iyi huylu, normal ve kötü huylu olmak üzere üç kategoriye ayrılmıştır. Şekil 3'te veri setine ait görüntülerin sayısı verilmiştir.




Şekil 3. Veri seti

Şekil 4'te veri setinde yer alan 3 farklı meme kanserine ait görüntü, maskeleme görüntüleri ve görüntü ile maskeleme görüntüsünün birleşiminden olan örnek görüntüler verilmiştir.



Şekil 4. Meme kanseri türleri

Veri setinde yer alan farklı sınıflara ait tüm görüntü maskelerinin ortalamasını alınarak elde edilen görüntüler Şekil 5'te verilmiştir.




Şekil 5. Her sınıftaki maskelerin ortalama görünümü

Veri setinde yer alan görüntüler incelendiğinde normal sınıfında yer alan görüntülere ait maskeleme olmadığı için bu sınıf veri setinden çıkarılmıştır. Veri setinde yer alan görüntüler öncelikle önışleme işlemine tabi tutulmuştur. Önışleme aşamasında görüntüler 128x128 olacak şekilde yeniden boyutlandırılmıştır. Ardından algoritma etkinliğini artırmak ve Makine Öğrenimi işlemi hızlandırmak için görüntüler ölçeklendirilmiştir. Bu işlemler sonunda görüntülerin %90'ı eğitim, %10 test için ayrılmıştır. Eğitim için ayrılan görüntülerin %10'u model validasyonu için ayrılmıştır.

3.2 Metot

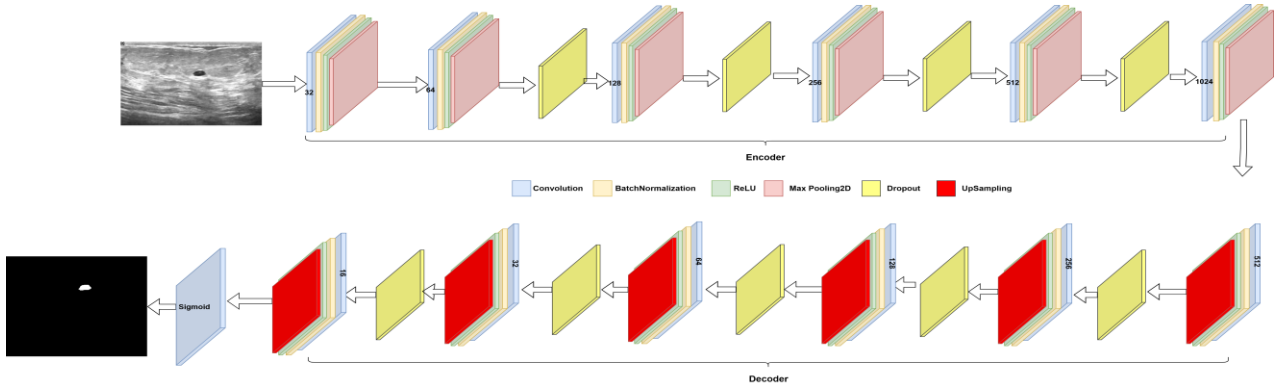
Semantik görüntü bölütlemenin amacı, bir görüntünün her pikselini, temsil edilen bir duruma karşılık gelen bir sınıfla etiketlemektir. Segmentasyon işleminde her piksel için bir tahmin yapılır. Çıktı, her pikselin belirli bir sınıfa sınıflandırıldığı yüksek çözünürlüklü bir görüntüdür. Görüntü segmentasyonu, bir görüntüyü, görüntüdeki farklı nesnelere veya arka planları tanımlamak ve sınıflandırmak için kullanılabilecek farklı bölgelere veya segmentlere bölmeyi içerir. Kanser ultrasonları bağlamında, görüntü segmentasyonu normal doku ve tümörler gibi farklı doku türleri arasında ayırım yapabilir. Bu bilgiler kanserin tanı ve tedavisinde değerlidir.

Bu çalışmada, kanserli hücrelerin tespiti için bölütleme işlemlerinde yüksek başarımlar elde eden ve ESA mimarileri arasında tanınan U-Net ve önerilen yeni bir FCN mimarisi kullanılmıştır. U-Net mimarisi (Ronneberger vd. 2015) Biyomedikal Görüntü Segmentasyonu için geliştirilmiştir.



Şekil 6. U-Net Mimarisi (Ronneberger vd. 2015)

Şekil 6'da gösterilen U-Net mimarisi iki aşamadan oluşur: İlk aşama, görüntüdeki bağlamı yakalamak için kullanılan bir kodlayıcı (encoder)dır. Encoder, geleneksel bir evrişimli ve maksimum havuzlama katmanları yığından oluşur. İkinci aşama ise, hassas yerelleştirmeyi mümkün kılmak için simetrik genişleyen bir kod çözücü (decoder) kullanarak evrişim katmanının tersini (transposed convolution) kullanır. U-Net mimarisi gibi, önerdiğimiz FCN mimarisi, encoder ve decoder olmak üzere 2 kısımdan oluşmaktadır.



Şekil 7. Önerilen FCN mimarisi

Encoder bölümü, girdi resmin boyutunu azaltma, özellik haritalarının sayısını artırma ve daha yüksek seviyedeki semantik bilgileri yakalama amacıyla tasarlanmıştır. Şekil 7'den görüldüğü gibi encoder kısmı evrişim, batch normalizasyon, aktivasyon ve havuzlama katmanlarından oluşmaktadır.

Decoder bölümü ise encoder bölümünde üretilen özellik haritalarını girdi resmin orijinal boyutuna tekrar çıkarmak için tasarlanmıştır. Bu amaç için decoder, transpoze evrişim katmanları ve encoder özellikleri ile birleştirme yapmaktadır. Decoder'ın amacı, encoder'da kaybettiği uzamsal ayrıntıyı geri kazanmak ve segmentasyon haritasını veya çıktısını üretmektir.

Önerilen FCN mimarisi içindeki encoder ve decoder bölümleri birlikte çalıştığında, önerilen mimari resimler üzerinde semantik segmentasyon yaparak, her bir pikseli belirli bir kategoriye atama yapmaktadır. Önerilen mimaride çıktı katmanında kullanılan evrişim katmanında aktivasyon fonksiyonu olarak sigmoid aktivasyon fonksiyonu kullanılmıştır.

Bu çalışmanın derin öğrenme modellerinde kullanılan hiper-parametreler, modelin performansını optimize etmek amacıyla dikkatli bir şekilde seçilmiştir. Optimizasyon sürecinde, öncelikle aktivasyon fonksiyonu olarak Adam aktivasyon fonksiyonu tercih edilmiştir. Adam, gradient tabanlı bir optimizasyon algoritmasıdır ve genellikle derin öğrenme modellerinde tercih edilen

bir seçenektir. Öğrenme oranı ise 0.001 olarak varsayılan değeri ile belirlenmiştir.

Hiper-parametrelerin seçiminde kapsamlı bir deneme yanılma süreci gerçekleştirilmiştir. Farklı öğrenme oranları, batch boyutları ve epoch sayıları gibi parametrelerin farklı kombinasyonları denenmiş ve modelin doğruluk oranı, kayıp değeri ve genelleme yeteneği üzerindeki etkileri titizlikle değerlendirilmiştir. Bu denemeler sonucunda, öğrenme oranının başlangıçta 0.001 olarak belirlenmesinin en iyi sonuçları verdiği gözlemlenmiştir.

Modelin eğitiminde, EarlyStopping ve ReduceLRonPlateau teknikleri kullanılmıştır.

EarlyStopping, modelin eğitim sürecinde overfitting'e yatkınlığını önlemek için kullanılan bir tekniktir. Bu teknik sayesinde, modelin performansı belirli bir süre boyunca gelişmiyorsa eğitim durdurulur ve en son iyi performans gösteren model kullanılır.

ReduceLRonPlateau, modelin varsayılan öğrenme oranını dinamik olarak azaltarak eğitim sürecinin daha stabil olmasını ve daha iyi sonuçlar elde edilmesini sağlar. Bu teknik, modelin öğrenme oranının azaltılması gerektiğinde otomatik olarak devreye girer ve eğitim sürecinin daha verimli hale gelmesini sağlar.

3.2.1 Değerlendirme Ölçütleri

Deneysel çalışmalarda kullanılan modellerin segmentasyon performans değerlendirmesi için birkaç farklı metrik kullanılmıştır. Bunlar;

Mean Intersection over Union (MeanIoU), segmentasyonun doğruluğunu ölçmek için kullanılan bir metriktir. Tahmin edilen bir görüntü ile referans bir görüntü arasındaki kesişmenin büyüklüğünün, tahmin edilen görüntü ile referans görüntüsü arasındaki birleşimin büyüklüğüne bölünmesiyle hesaplanır. Her sınıf için ayrı ayrı hesaplanan IoU değerlerinin ortalaması alınarak, ortalama IoU değeri elde edilir.

Precision, segmentasyon sırasında tanımlanan nesnelerin ne kadarının gerçekten doğru şekilde belirlendiğini ölçmek için kullanılan bir metriktir. Precision, belirlenen nesnelerin gerçek sınırlarına ne kadar yakın olduğunu belirler. Precision, modelin yanlış pozitif örneklerinin oranını azaltarak, modelin daha az yanlış pozitif örnek ürettiğini gösterir.

Recall metriği, gerçek pozitif (true positive) örneklerin tespit edilme oranını ifade eder. Bir modelin, tüm gerçek pozitif örneklerin ne kadarını doğru bir şekilde tespit edebildiğini ölçmek için kullanılır. U-Net modelinin daha yüksek bir Recall performansı göstermesi, modelin daha fazla gerçek pozitif örneğini doğru bir şekilde tespit

edebilmesinden kaynaklanabilir. Bu, modelin daha fazla hücre bölgesini tespit ettiği anlamına gelir. Ancak, aynı zamanda yanlış pozitif örneklerin sayısını artırabilir ve dolayısıyla Precision metriği düşük çıkabilir. Bu nedenle, model seçimi ve performans ölçümü için tek başına yeterli değildir.

F1 score, Precision ve Recall metriklerinin birleşimidir ve segmentasyonun doğruluğunu ölçmek için kullanılır. F1 score, Precision ve Recall'ın harmonik ortalamasını ifade eder. F1 score, Precision ve Recall'ın bir denge noktasıdır ve nesnelerin doğru şekilde tanımlanması için hem Precision hem de Recall'ın yüksek olması gerektiğini gösterir. F1 score, modelin Precision ve Recall metriklerindeki performansını dengeler.

4. Bulgular

Veri seti içerisinde meme kanseri hücrelerinin bölütlenmesi için U-Net ve önerilen FCN mimarisi kullanılarak deneysel çalışmalar yapılmıştır. Veri setinde yer alan giriş ve maske görüntülerinin boyutları tek kanallı ve 128x128 piksel olarak yeniden yapılandırılmıştır. U-Net ve önerilen FCN mimarisi ile yapılan deneysel çalışma sonuçları, Çizelge 1'de sunulmuştur.


Çizelge 1. Model Performansları

FCN						
Metrik	1. Deneş	2. Deneş	3. Deneş	4. Deneş	5. Deneş	Ortalama
Mean IoU	0,793	0,747	0,753	0,793	0,771	0,772
Precision Score	0,771	0,706	0,681	0,733	0,688	0,716
Recall Score	0,785	0,712	0,767	0,816	0,807	0,777
F1 Score	0,778	0,709	0,721	0,773	0,743	0,745
U-Net						
Mean IoU	0,788	0,735	0,744	0,825	0,728	0,764
Precision Score	0,692	0,582	0,706	0,826	0,575	0,676
Recall Score	0,86	0,82	0,717	0,805	0,818	0,804
F1 Score	0,767	0,681	0,712	0,816	0,676	0,730

Çizelge 1'den görülebileceği üzere, önerilen FCN modeli ve U-Net modeli ile farklı deneysel çalışmalar yapılmış ve bu sonuçların ortalaması alınarak performans değerleri gösterilmiştir. Çizelge 1'den görülebileceği üzere FCN mimarisi, U-Net mimarisine kıyasla MeanIoU, Precision ve F1 score


metriklerinde daha yüksek performans sergilemiştir. Bununla birlikte, Recall metriği açısından U-Net modeli daha iyi bir performans göstermiştir. FCN modelinin MeanIoU, Precision ve F1 score metriklerinde daha yüksek bir performans sergilemesi, modelin daha doğru ve tutarlı bir

şekilde bölütlenmiş bölgeleri tespit ettiğini ve daha az yanlış pozitif örnek ürettiğini gösterir. Bu da, modelin daha iyi bir performans sergilediği anlamına gelir ve bölütlenme işleminde daha güvenilir sonuçlar elde ettiğini göstermektedir. Önerilen FCN modeli ile yapılan deneysel çalışmalardan en yüksek skoru alan eğitilmiş FCN modeli ile birkaç görüntü üzerinde yapılan tahminleme sonuçları Şekil 8’de gösterilmiştir.




Şekil 8. FCN modeline ait tahminleme sonuçları

Önerilen FCN modeline ait doğruluk ve kayıp grafiği şekil 9’da gösterilmiştir.



Şekil 9. FCN mimarisine ait kayıp ve doğruluk grafiği

U-Net modeli ile yapılan deneysel çalışmalarda en yüksek skorun alındığı eğitilmiş modele ait doğruluk ve kayıp fonksiyon grafiği şekil 10’da gösterilmiştir.



Şekil 10. U-Net mimarisine ait kayıp ve doğruluk grafiği

Şekil 9 ve Şekil 10, FCN ve U-Net mimarilerinin kayıp (loss) ve doğruluk (accuracy) grafiğini göstermektedir. Bu grafikler, model performansını anlamak ve eğitimin ilerlemesini takip etmek için önemlidir.


FCN modelinin kayıp ve doğruluk grafiği incelendiğinde, eğitim sürecinin başından itibaren uyumlu bir şekilde davrandığı görülmektedir. Loss grafiği azalırken, accuracy grafiği artmaktadır. Bu, modelin eğitiminin istikrarlı olduğunu ve veriye daha iyi uyum sağladığını göstermektedir. Ayrıca, FCN modelindeki loss ve accuracy grafiğinin uyumlu bir şekilde artıp azalması, modelin aşırı uyum olmadan genellemeyi başarılı bir şekilde gerçekleştirdiğini göstermektedir.

Öte yandan, U-Net modelinin kayıp ve doğruluk grafiği daha karmaşık bir davranış sergilemektedir. Loss grafiği incelendiğinde, modelin başlangıçta düşen bir trend izlediği fakat yaklaşık 25. epoch'tan sonra düzensiz bir şekilde davrandığı gözlemlenmektedir. Bu noktada, train loss değerlerinin düşmeye devam ettiği halde validasyon loss değerlerinin artmaya başlaması, modelin aşırı uyum (overfitting) durumuna girebileceğini düşündürülebilir. Aynı şekilde, accuracy grafiğindeki durum da dikkat çekicidir. Train accuracy'si artarken, validasyon accuracy'si sabit kalmaktadır. Bu durum, modelin eğitim verilerine aşırı uyum sağlamış olabileceğini ve yeni verilere genelleme yapma yeteneğinin düşük olabileceğini göstermektedir.

Sonuç olarak, FCN modelinin daha istikrarlı bir performans sergilediği ve eğitim sürecinin genellemeyi olumlu bir şekilde etkilediği gözlemlenirken, U-Net modelinin yaklaşık 25.

epoch'tan sonra overfitting eğilimi gösterdiği ve yeni verilere genelleme yeteneğinin azalabileceği görülmektedir. Bu durum, FCN modelinin U-Net modeline göre daha güvenilir sonuçlar üretebileceğini düşündürülebilir.

U-Net modeli ile rastgele görüntüler üzerinde yapılan tahminleme sonuçları şekil 11'de gösterilmiştir.



Şekil 11. U-Net modeline ait tahminleme sonuçları

Şekil 8 ve Şekil 11'de görüldüğü gibi U-Net ve önerilen FCN modeli görüntülere ait kanserli hücreleri yüksek bir doğruluk ile tespit etmektedir.

5. Tartışma ve Sonuç

Kadınlarda yaygın bir şekilde teşhis konulan meme kanseri, Dünya'da tüm kanser vakalarının dörtte birini oluşturmaktadır. Meme kanserinin teşhisinde, kanserli ve kanserli olmayan dokuların ayırt edilmesi, kanserli hücrelerin tespiti, tümör boyutunun ölçülmesi ve kanserin evrelendirilmesi

gibi önemli bilgilerin elde edilmesi kritik bir öneme sahiptir. Ayrıca, kanserli dokunun sağlıklı dokudan ayrıştırılması, kanserin sınırlarının belirlenmesi ve tedavi planlarının hazırlanması için kritik önem taşımaktadır. Bu amaçla, radyolojik görüntülerdeki kanserli hücreleri tespit etmek için görüntüler parçalara ayırmak gerekmektedir. Bu işlem için Segmentasyon yöntemi yaygın bir şekilde kullanılmaktadır.

Bu çalışma, medikal görüntülerin analizi için önemli bir araç olan görüntü segmentasyonunu başarıyla uygulamış ve meme görüntülerindeki kanserli bölgelerin doğru tespitini gerçekleştirmiştir. Çalışmanın temel hedefi, ultrason görüntülerindeki kanserli bölgeleri hassas bir şekilde tespit edebilen güçlü bir görüntü segmentasyon modeli geliştirmek ve böylece kanser tanı ve tedavi süreçlerinin doğruluğunu artırmaktır. Bu amaç doğrultusunda, özgün bir FCN mimarisi tasarlanmış ve uygulanmıştır. Ayrıca, önerilen FCN mimarisi U-Net ile karşılaştırılmış ve elde edilen sonuçların daha üstün olduğu gözlemlenmiştir.

Çalışmada önerilen FCN model mimarisi, kanserli hücrelerin konumunu test görüntülerinde %77,2 Ortalama IoU, %71,6 kesinlik, %77,7 recall ve %74,5 F1 skoru ile tespit etmiştir. U-Net modeli ile %76,4 Ortalama IoU, %67,6 kesinlik, %80,4 recall ve %73 F1 skoru ile kanserli hücreler tespit edilmiştir.

Bu çalışma önerilen özgün FCN mimarisi ile ultrason görüntülerinde kanserli bölgelerin hassas bir şekilde tespit edilmesi başarıyla gerçekleştirilmiştir. Literatürde medikal görüntülerde yaygın olarak kullanılan U-Net modeline kıyasla, önerilen FCN mimarisi daha üstün performans sergilemiştir. Elde edilen sonuçlar, önerilen FCN mimarisinin yüksek doğruluk ve güvenilirlikle kanserli bölgeleri tespit etme konusunda etkili olduğunu açıkça göstermiştir. Bu nedenle, çalışmanın özgün FCN mimarisi sayesinde elde edilen üstün sonuçlar, modelin benzersiz özelliklerini ve üstünlüğünü göstermektedir. Elde edilen sonuçlar, önerilen FCN mimarisinin ultrason görüntülerinde kanserli hücrelerin yerini doğru bir şekilde tespit edebildiğini ve kanser tanı ve tedavi süreçlerinde yararlı bir araç olma potansiyeline sahip olduğunu göstermektedir.

6. Kaynaklar

- Loukas, C., Kostopoulos, S., Tanoglidi, A., Glotsos, D., Sfikas, C., Cavouras, D., 2013. Breast cancer characterization based on image classification of tissue sections visualized under low magnification. *Computational and Mathematical Methods in Medicine*, 2013, 7. doi:10.1155/2013/829461
- Joy, J., Penhoet, E., & Petititti, D., 2005. Saving women's lives: strategies for improving breast cancer detection and diagnosis. National Academies Press.
- Veta, M., Pluim, J. P. W., Diest, P. J., Viergeve, M. A., 2014. Breast cancer histopathology image analysis: A review. *IEEE Transactions on Biomedical Engineering*, 61(5), 1400–1411.
- Irshad, H., Veillard, A., Roux, L., Racoceanu, D., 2014. Methods for nuclei detection, segmentation, and classification in digital histopathology: A review-Current status and future potential. *IEEE Reviews in Biomedical Engineering*, 7, 97–114.
- Ataş, M., Özdemir, C., Ataş, İ., Ak, B., Özeroğlu, E., 2022. Biometric identification using panoramic dental radiographic images with few-shot learning. *TURKISH JOURNAL OF ELECTRICAL ENGINEERING & COMPUTER SCIENCES*, 30(3), 1115–1126. doi:10.55730/1300-0632.3830
- Dogan, Y., Keles, H. Y., 2022. Iterative facial image inpainting based on an encoder-generator architecture. *Neural Computing & Applications*, 34(12), 10001–10021. doi:10.1007/s00521-022-06987-y
- Kılıç, Ş., Kaya, Y., Askerbeyli, İ., 2021. A new approach for human recognition through wearable sensor signals. *Arabian Journal for Science and Engineering*, 46, 4175-4189.
- Dogan, Y., 2023. A New Global Pooling Method for Deep Neural Networks: Global Average of Top-K Max-Pooling. *Traitement du Signal*, 40(2).
- Motta, L. S., 2010. Obtenção automática da região de interesse em termogramas frontais da mama para o auxílio a detecção precoce de doenças. In Federal University Fluminense (UFF). Niterói (RJ, Brazil).
- Marques, R. S., 2012. Segmentação automática das mamas em imagens térmicas. In Federal University Fluminense (UFF). Niterói (RJ, Brazil).
- Baffa, M., Cheloni, D., Lattari, L., 2016. Segmentação Automática de Imagens Térmicas das Mamas Utilizando Limiarização com Refinamento Adaptativo. *Anais Do XVI Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS 2016)*. Presented at the Simpósio Brasileiro de Computação Aplicada à Saúde, Brasil. doi:10.5753/sbcas.2016.9896
- Marques RS, Conci A, Perez MG, Andaluz VH, Mejia TM. 2016. An approach for automatic segmentation of thermal imaging in computer aided diagnosis. *IEEE Latin Am Trans*. 14(4):1856–1865.
- Melo, R., Conci, A., Vasconcelos, C. N., 2017. On the use of fully convolutional networks on evaluation of infrared breast image segmentations. In *Anais do XVII Workshop de Informática Médica*. São Paulo, Brazil: SBC.
- Ozan, O., Jo, S., Le, F. L., Matthew, L., Mattias, H., Kazunari, M., ... Steven, M., 2018. Kainz Bernhard Attention u-net: Learning where to look for the pancreas.
- Zhou, Z., Rahman Siddiquee, M. M., Tajbakhsh, N., Liang, J., 2018. Unet++: A nested u-net architecture for medical image segmentation. In *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop, DLMIA 2018, and 8th International Workshop, ML-CDS 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 20, 2018, Proceedings 4* (pp. 3-11). Springer International Publishing.
- Olaf, R., Philipp, F., Thomas, B., 2015. Convolutional networks for biomedical image segmentation, *International Conference on Medical Image Computing and Computer-Assisted Intervention* (pp. 234–241). Springer.
- Mendes, L. C., Rodrigues, E. O., Izidoro, S. C., Conci, A., & Liatsis, P., 2020. ROI extraction in thermographic breast images using genetic algorithms. *2020 International Conference on Systems, Signals and Image Processing (IWSSIP)*. Presented at the 2020 International Conference on Systems, Signals and

Image Processing (IWSSIP), Niterói, Brazil.
doi:10.1109/iwssip48289.2020.9145346

Baffa, M. de F. O., Coelho, A. M., Conci, A., 2021. Segmentação de Imagens Infravermelhas Para Detecção do Câncer de Mama Utilizando U-NET CNN. Anais Do XXI Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS 2021). Presented at the Simpósio Brasileiro de Computação Aplicada à Saúde, Brasil. doi:10.5753/sbcas.2021.16058

Yang, L., Xiuxiu, H., Jincan, Y., Tonghe, W., Lijing, W., Wei, L., ... Xiaofeng, Y., 2021. Breast tumor segmentation in 3D automatic breast ultrasound using mask scoring R-CNN, Med. Med. Phys, 48(1), 204–214.

Al-Dhabyani, W., Gomaa, M., Khaled, H., & Fahmy, A., 2020. Dataset of breast ultrasound images. Data in Brief, 28(104863), 104863. doi:10.1016/j.dib.2019.

İnternet kaynakları

1-<https://www.who.int/health-topics/cancer#tab=tab>,
(02.02.2023)

2-<https://gco.iarc.fr/today>, (02.02.2023)