



Kahramanmaraş Sutcu Imam University Journal of Engineering Sciences



Geliş Tarihi : 02.05.2025
Kabul Tarihi : 16.06.2025

Received Date : 02.05.2025
Accepted Date : 16.06.2025

OVER TÜMÖR ULTRASON GÖRÜNTÜLERİ ÜZERİNDE FARKLI BÖLÜTLEME MODELLERİNİN KARŞILAŞTIRMASI

COMPARISON OF DIFFERENT SEGMENTATION MODELS ON OVARIAN TUMOUR ULTRASOUND IMAGES

*İbrahim ARUK*¹* (ORCID: 0009-0003-7483-4542)

¹ Kahramanmaraş İstiklal Üniversitesi, Yazılım Mühendisliği Bölümü, Kahramanmaraş, Türkiye

*Sorumlu Yazar / Corresponding Author: İbrahim ARUK, ibrahim.aruk@istiklal.edu.tr

ÖZET

Kanser, dünya genelinde başlıca ölüm nedenlerinden biri olup, erken teşhis ve etkin tedavi edilmesi, hastalığın kontrol altına alınmasında hayati bir rol oynamaktadır. Over kanseri, kadınlarda en ölümcül jinekolojik kanser türlerinden biri olarak öne çıkmaktadır. Erken evrelerde genellikle açık bir belirti göstermemesi, teşhisin ileri evrelere geçmesine ve tedavi olanağının azalmasına neden olmaktadır. Bu çalışmada, düşük kaliteli ultrason görüntüleri kullanılarak over tümörlerinin otomatik bölütlenmesi için derin öğrenme tabanlı modellerin performansı kapsamlı bir şekilde değerlendirilmiştir. U-Net, Nested U-Net, DeepLabv3+, SegNet ve FCN modelleri, OTU_2D veri seti üzerinde karşılaştırmalı olarak analiz edilmiştir. DeepLabv3+, %96,37 DSC ve %93,76 IoU skorlarıyla en yüksek bölütleme doğruluğu sağlarken, FCN modeli %96,34 DSC ve %93,82 IoU skorlarıyla benzer bir başarı sergilemiştir. Nested U-Net ve U-Net modelleri, lezyon sınır hassasiyeti ve küçük yapıların doğru şekilde bölütlenmesinde etkili olmuştur. SegNet mimarisi ise diğer modellere kıyasla daha sınırlı bir performans göstermiştir.

Anahtar Kelimeler: Görüntü bölütleme, over tümör, tıbbi görüntü analizi.

ABSTRACT

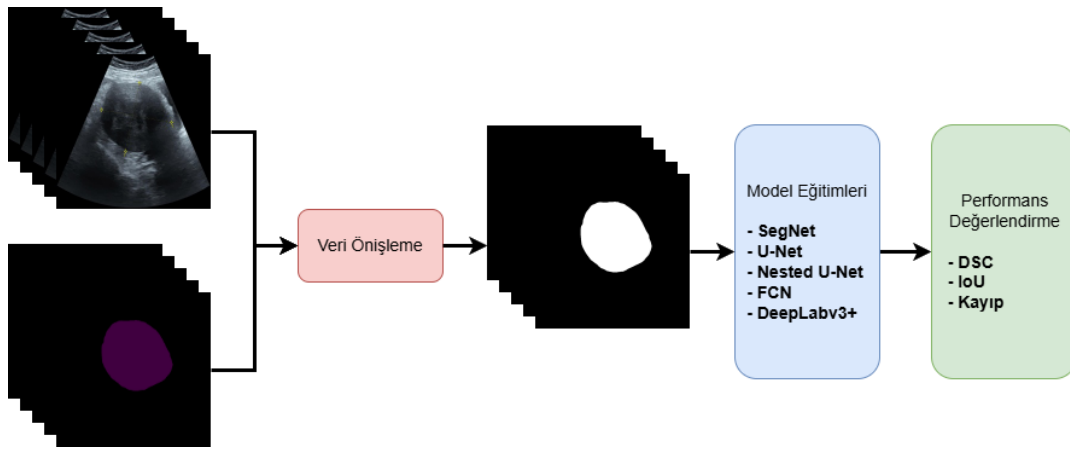
Cancer remains one of the leading causes of mortality worldwide, and early diagnosis along with effective treatment plays a crucial role in controlling the disease. Among gynecological cancers, ovarian cancer stands out as one of the most fatal types for women. The absence of noticeable symptoms in its early stages often delays diagnosis to advanced stages, significantly reducing treatment opportunities. This study comprehensively evaluates the performance of deep learning-based models for the automatic segmentation of ovarian tumors using low-quality ultrasound images. U-Net, Nested U-Net, DeepLabv3+, SegNet, and FCN models were comparatively analyzed on the OTU_2D dataset. DeepLabv3+ demonstrated the highest accuracy with 96.37% DSC and 93.76% IoU scores, while the FCN model achieved comparable performance with 96.34% DSC and 93.82% IoU scores. Nested U-Net and U-Net models were found to be effective in accurately segmenting boundaries and small structures, whereas the SegNet architecture exhibited relatively limited performance compared to the other models.

Keywords: Image segmentation, ovarian tumour, medical image analysis.

GİRİŞ

Kanser hastalığının erken tespiti ve teşhisi, insan sağlığının korunmasında çok önemli bir hale gelmiştir. Over kanseri, kadınlarda görülen ve dünya genelinde önde gelen ölüm nedenlerinden biridir (Pham et al., 2023). Erken evrelerde genellikle belirti göstermemesi, tanının çoğunlukla ileri evrelerde konulmasına neden olmaktadır. Bu da tedavi başarısını ve hastanın yaşam süresini olumsuz yönde etkilemektedir. Siegel ve ark. yaptıkları son çalışmalarındaki istatistiklere göre, 2025 yılında Amerika Birleşim Devletlerinde yaklaşık 20.890 kişi yeni over kanseri tanısı alacak ve over kanserinden yaklaşık 12.730 ölüm gerçekleşecektir (Siegel et al., 2025). Tıbbi tanı koymadaki ilerlemelere rağmen, over kanserinin doğru teşhisi çeşitli karmaşık testler sonucunda ancak mümkün olabilmektedir. Ayrıca over kanseri için belirgin semptomların olmaması nedeniyle yanlış teşhis söz konusu olabilmektedir. Bu nedenle, over tümörlerinin erken ve doğru tespiti büyük önem arz etmektedir. Erken over kanseri tespiti için genellikle ultrason görüntüleri kullanılmaktadır. Ultrason görüntüleme, radyoaktivite içermediği için güvenli bir yöntemdir. Ayrıca, yüksek doğruluk, hassasiyet ve özgüllük sağlamaktadır. Ayrıca, BT ve MRI gibi diğer görüntüleme yöntemlerine kıyasla daha düşük maliyet avantajı sunmaktadır (Bierig & Jones, 2009).

Son yıllarda derin öğrenme temelli görüntü bölütleme işlemi, tıbbi görüntü analizinde oldukça önemli bir konuma ulaşmıştır. Özellikle U-Net mimarisi ve türevleri, sınırlı veriyle yüksek doğrulukta bölütleme sağlayabilmeleri sayesinde medikal bölütleme çalışmalarında yaygın şekilde tercih edilmektedir. Bu kapsamda yapılan değerlendirmede, farklı mimari özelliklere sahip beş model karşılaştırmalı olarak ele alınmıştır. U-Net modeli, simetrik kodlayıcı-kod çözücü yapısı ve atlamalı bağlantılarıyla özellikle biyomedikal bölütleme problemlerinde yüksek başarı sağlamaktadır. Gelişmiş versiyonu olan Nested U-Net modeli ise bu yapıyı daha karmaşık geçiş yolları ve yoğun atlamalı bağlantılarla geliştirerek çoklu ölçekli özelliklerin daha etkili yakalanmasını hedeflemektedir. DeepLabv3+ modeli, boşluklu evrişim ve Atrous Spatial Pyramid Pooling (ASPP) yapısıyla çoklu bağlamdan bilgi toplayarak sınır bölgelerinde daha hassas bölütleme sunmaktadır. SegNet mimarisi, havuzlama indekslerini kodlayıcıdan kod çözücüye taşıyarak daha az parametreyle etkin bir bölütleme gerçekleştirmektedir. Tam Evrişimsel Ağlar (Fully Convolutional Network, FCN) mimarisi ise tam evrişimli katmanları kullanarak klasik sınıflandırma ağlarını piksel düzeyinde bölütleme için yeniden yapılandırmakta ve temel bir derin öğrenme yaklaşımı olarak sıklıkla referans alınmaktadır.



Şekil 1. Çalışmanın Akış Diyagramı

Şekil 1.'de akış diyagramı görülen bu çalışmada, düşük kaliteli ultrason görüntülerinden over tümörlerinin otomatik bölütlenmesine yönelik mevcut yöntemlerin sınırlılıklarını aşmak için, farklı derin öğrenme tabanlı bölütleme modellerinin kapsamlı bir karşılaştırmalı değerlendirmesi yapılmıştır. Bu amaçla, uzmanlar tarafından etiketlenmiş ve geniş örneklem çeşitliliği sunan OTU_2D veri seti kullanılmıştır. Veri setinde bulunan orijinal maskelerden ön işleme sonrasında siyah-beyaz lezyon maskeleri elde edilmiştir. Elde edilen maskeler ile U-Net, Nested U-Net, DeepLabv3+, SegNet ve FCN gibi yaygın olarak kullanılan bölütleme modellerinin performansları nesnel metriklerle analiz edilmiştir. Elde edilen sonuçlar, modellerin güçlü ve zayıf yönlerini ortaya koymakta ve klinik uygulamalar açısından yol gösterici bilgiler sağlamaktadır. Böylece çalışma, over tümör ultrason görüntülerinde bölütleme alanına yeni bir perspektif kazandırarak mevcut bilgi birikimine önemli bir katkı sunmaktadır.

Bu çalışmanın literatüre katkısı şu şekildedir:

- U-Net, Nested U-Net, DeepLabv3+, SegNet ve FCN modelleri aynı veri seti ve koşullarda kapsamlı şekilde karşılaştırılmıştır.
- Modellerin güçlü ve zayıf yönleri belirlenerek uygun model seçimi için rehberlik sağlanmıştır.
- Elde edilen sonuçlar, farklı uygulamalar için model tercihinine yönelik pratik katkılar sunmaktadır.

Çalışmanın bir sonraki bölümünde literatür özeti sunulmaktadır. Üçüncü bölümde materyal ve metotlardan bahsedilmektedir. Dördüncü bölümde bulgular ve tartışma yer almaktadır. Beşinci ve son bölümde ise çalışmanın sonuç kısmı yer almaktadır.

LİTERATÜR ÖZETİ

Over tümörlerinin bölütlenmesi, ultrason görüntüleme gibi düşük kontrastlı ve karmaşık tıbbi görüntülerle çalışmanın zorluklarını barındıran önemli bir araştırma alanıdır. Bu bağlamda, literatürde dikkat çekici ilerlemeler sağlanmış ve birçok farklı yöntem önerilmiştir. U-Net gibi klasik kodlayıcı-kod çözücü mimarilerinin yanı sıra, dikkat mekanizmaları, özel kayıp fonksiyonları ve bağlamsal desenleri yakalayabilen yenilikçi modüller ile güçlendirilmiş modeller geliştirilmiştir. Aynı zamanda, farklı modellerin çıktılarının birleştirilmesi ve toplu öğrenme yaklaşımlarının kullanımı ile bölütleme performansını artırmaya yönelik çalışmalar da literatürde yer edinmiştir. Bu çalışmalar hem model mimarisi hem de kullanılan veri setleri açısından çeşitlilik göstererek, over tümörlerinin boyut, şekil ve hastalık ilişkilerinin daha doğru bir şekilde belirlenmesine katkı sağlamaktadır.

Bu genel çerçevede, Pham ve ark., BKSeg-Net isimli bir bölütleme yöntemi önererek over tümörlerinin bölütlenmesi için yeni bir yaklaşım geliştirmişlerdir. Bu yöntem, U-Net tabanlı bir mimari üzerine kurulmuş ve dikkat kapıları ile güçlendirilmiştir. Modelin başarısını artırmak için yaygın kayıp fonksiyonlarının yanı sıra tümör sınırlarını daha iyi belirlemeyi sağlayan yenilikçi bir Keypoint Loss bileşeni de entegre edilmiştir. Yapılan değerlendirmelerde OTU_2D veri setinde U-Net mimarisi %61,09 Dice Benzerlik Katsayısı (Dice Similarity Coefficient, DSC) ve %51,43 Jaccard Benzerlik İndeksi (Jaccard Similarity Index, IoU) değerlerini sağlarken, önerilen yöntem %88,60 DSC ve %79,61 IoU oranlarını elde etmiştir (Ta et al., 2024).

Bunun yanı sıra, Bui ve ark. yapmış oldukları çalışmada, ultrason görüntülerindeki sembol ve işaretlerin kaldırılması amacıyla bir in-painting yöntemi uyguladıktan sonra, UNet3+ mimarisi ve ResNet50 tabanlı bir kodlayıcı kullanan bir bölütleme modeli geliştirmiştir. OTU_2D veri seti üzerinde yapılan değerlendirmelerde, önerilen model mevcut yöntemlere kıyasla daha iyi performans göstermiştir. Diğer model sonuçlarının değerlendirmesinde U-Net mimarisi %81,02 DSC ve 69,44 IoU, U-Net++ %73,68 DSC ve %59,44 IoU sonuçları elde ederken, önerilen modelin DSC, IoU, Recall ve Precision skorları sırasıyla %86,44, %77,05, %86,31 ve %89,18 olarak elde edilmiştir (Bui et al., 2024). Benzer şekilde, Pham ve ark., ultrason görüntülerinden over tümörlerinin bölütlenmesi üzerine bir çalışma sunmuştur. Çalışmada PSPNet, U-Net, DANet, Deeplabv3 ve PSANet gibi bölütleme modelleri incelenmiş ve OTU_2D veri seti üzerinde değerlendirilmiştir. Çalışmada tümörlerin boyut ve şeklinin yanı sıra, ilişkili hastalıkların da belirlenmesi sağlanmıştır. Deneysel sonuçlarda, U-Net mimarisi %49,70 IoU ve DeepLabv3 mimarisi %59,75 ortalama IoU oranı ile bölütleme gerçekleştirmiştir (Pham et al., 2023).

Ayrıca, Ta ve ark., over ultrason görüntülerinde ikili bölütleme geliştirmek için ağırlıklı birleştirme yaklaşımını temel alan bir yöntem sunmuşlardır. Bu strateji, farklı modellerden elde edilen bölütleme haritalarını birleştirmek için ağırlıkları optimize eden bir grid arama algoritması kullanarak daha yüksek duyarlılık ve kesinlik oranlarına ulaşmayı hedeflemiştir. Çalışmada, UNet mimari çerçevesinde Inceptionv3, DenseNet121 ve MobileNet gibi üç farklı omurga mimarisi incelenmiş ve birleştirilmiş bir ısı haritası oluşturulmuştur. Ayrıca, MobileNet'in verimliliği ve yüksek performansı nedeniyle FPN ve PSPNet gibi iki farklı bölütleme modelinde de omurga olarak kullanılmış ve bu modellerde de UNet ile benzer bir ağırlıklı birleştirme yaklaşımı uygulanmıştır. Yapılan bölütleme değerlendirmelerinde en yüksek başarıyı U-Net mimarisi MobileNet omurgası ile %73,48 IoU oranında elde etmiştir (Ta et al., 2024). Buna ek olarak, Siahpoosh ve ark., over tümörlerinin bölütlenmesi için PCU-Net adını verdikleri, U-Net mimari tabanlı bir model geliştirmiştir. Bu modelde, büyük boyutlu çekirdekler kullanarak global bağlam bilgilerini yakalamaya olanak tanıyan ConvMixer modülü bulunmaktadır. Ayrıca, farklı genişleme oranlarına sahip paralel genişletilmiş evrişimler aracılığıyla yerel ve global bağlamsal desenleri entegre eden Pyramid Dilated Convolution (PDC) modülü de bu yapıya entegre edilmiştir. OTU_2D veri seti üzerinde gerçekleştirilen

değerlendirmelerde, U-Net mimarisi %69,82 IoU ve %76,96 DSC skoru elde etmiştir. Geliştirilen yeni model olan PCU-Net ise IoU değerinde %74,05 ve DSC değerinde %79,95'lik bir oran sağlamıştır (Siahpoosh et al., 2024).

Son olarak, El-Khatib ve ark. yaptıkları çalışmada, üç ana aşamadan oluşan bir yöntem sunarak over tümörlerinin semantik bölütlenmesini gerçekleştirmiştir. İlk aşamada, ResNet-18, ResNet-50, MobileNet-V2, InceptionResNet-V2 ve Xception omurgalarına sahip beş farklı DeepLabv3+ ağı kullanılarak bireysel ağlar önerilmiştir. İkinci aşamada, birden fazla bireysel bölütleme ağını birleştirmek için özel bir algoritma geliştirilmiştir. Son aşamada ise en doğru topluluğu oluşturmak amacıyla bireysel ağların seçimini optimize eden yinelemeli bir seçim yaklaşımı tanımlanmıştır. Deneysel çalışmalarda, U-Net, DeepLabv3+ ve önerilen model sırasıyla %76,06, %83,99 ve %91,18 IoU değeri elde etmişlerdir (El-khatib et al., 2024).


Tüm bu çalışmaların ortak noktası olarak, bu bölümde incelenen araştırmaların, over tümörlerinin bölütlenmesinde farklı yaklaşımların etkinliğini gösterdiği söylenebilir. Özel kayıp fonksiyonları ve modül entegrasyonları sayesinde model performansındaki artışlar dikkat çekerken, toplu öğrenme yöntemleri ile bireysel ağların sınırlamaları aşılmıştır. Literatürdeki modeller, kullanılan veri setlerine göre değişen sonuçlar elde etse de özellikle IoU ve DSC gibi metriklerde kayda değer iyileşmeler sağlamıştır.

MATERYAL VE METOT

Veri Seti

Bu çalışmada, toplamda 1.469 adet 2D ultrason görüntüsü içeren Çok Modaliteli Over Tümörü Ultrason Görüntüleri (Multi Modality Ovarian Tumor Ultrasound Images, MMOTU) (Zhao et al., 2022) veri seti kullanılmıştır. Görüntü anotasyonları, yüksek kaliteyi sağlamak için önce bir uzman tarafından yapılmış ve ardından başka bir uzman tarafından doğrulanmıştır. Veri setindeki ilk altı kategori, iyi huylu over tümörlerini temsil ederken, son iki kategori kötü huylu tümörlere işaret etmektedir (Pham et al., 2024). Ancak, bu çalışma kapsamında görüntüler, bireysel kategoriler yerine yalnızca bölütleme işlemi için değerlendirilmiştir. Değerlendirme süreci, MMOTU veri setinin OTU_2D alt kümesine odaklanmıştır. Bu alt küme, hem piksel düzeyinde semantik anotasyonlar hem de genel kategori sınıflamaları içermekte olup, lezyon bölütlenmesi gibi belirli görevler için ideal bir veri seti niteliğindedir.

Şekil 2.'de OTU_2D veri setinde bulunan over tümörü ultrason görüntüleri ve gerçek maske örneklerinden bazı örnekler gösterilmektedir.



Şekil 2. OTU_2D Veri Setindeki Over Tümörü Ultrason Görüntüleri ve Gerçek Maske Örnekleri.

Bölütleme Modelleri

Tıbbi görüntü bölütlemesi, özellikle düşük kontrast ve karmaşık yapıya sahip görüntülerde, doğru tanı ve tedavi süreçlerini desteklemek için kritik bir öneme sahiptir. Bu kapsamda, derin öğrenme tabanlı görüntü bölütleme modelleri, sundukları yüksek doğruluk ve esneklik ile alandaki en popüler yaklaşımlar arasında yer almaktadır. Bunlar arasında U-Net ve Nested U-Net gibi kodlayıcı-kod çözücü tabanlı modeller, semantik bölütlemenin temel

taşları olarak öne çıkmaktadır. Ayrıca, DeepLabv3+, SegNet ve FCN gibi yöntemler, farklı mimari tasarımlar ve bağlamsal bilgi işleme yetenekleri sayesinde çeşitli tıbbi görüntüleme senaryolarında yaygın olarak kullanılmaktadır. Bu bölümde, her bir modelin temel yapısı, özellikleri ve tıbbi görüntü bölütlenmesindeki katkıları ele alınacaktır.

U-Net Mimarisi

U-Net, tıbbi görüntü bölütleme alanında yüksek doğruluk ve etkinlik sunan, tam evrimsel bir ağ mimarisi olarak öne çıkmaktadır. Ronneberger ve ark. tarafından geliştirilen bu yapı, özellikle sınırlı etiketli veriyle çalışmanın zorluklarını aşmak amacıyla veri artırma stratejilerini etkin biçimde kullanmaktadır (Ronneberger et al., 2015). Model, tipik olarak bir sıkıştırma yolu (kodlayıcı) ve bir genişletme yolu (kod çözücü) olmak üzere iki ana bölümden oluşmaktadır. Kodlayıcı aşamasında, ardışık 3×3 evrişim katmanları ve 2×2 ortaklama işlemleriyle giriş görüntüsünün soyut ve yoğun temsilleri elde edilmektedir. Kod çözücü bölümünde ise, 2×2 yukarı evrişimler ve 3×3 evrişimler ile bu öznelikler orijinal boyuta ölçeklendirilir. Atlama bağlantılarıyla kodlayıcı ve kod çözücülere karşılık gelen katmanları arasında yüksek çözünürlüklü uzamsal bilgi doğrudan aktarılır. Bu da özellikle sınırların hassas bir şekilde belirlenmesini ve bölütleme doğruluğunun artmasını sağlamaktadır (Siahpoosh et al., 2024).

Nested U-Net (U-Net++) Mimarisi

Zhou ve ark. tarafından geliştirilen Nested U-Net mimarisi, klasik U-Net mimarisinin bir varyasyonu olarak geliştirilmiş olup, uzun mesafeli ve yoğun atlamalı bağlantıları sayesinde bölütleme performansını artırmayı hedeflemektedir (Zhou et al., 2018). Orijinal U-Net'te, kodlayıcı ve kod çözücü arasında gevşek atlamalı bağlantılar kullanılırken, Nested U-Net'te bu bağlantılar yoğunlaştırılarak, semantik açıdan farklı katmanlar arasında doğrudan ve çok katmanlı bilgi aktarımı sağlanmaktadır. Bu mimaride, kodlayıcı ve kod çözücü mimarileri arasında kurulan atlamalı yollar, birden fazla evrişim katmanından oluşan yoğun bloklar aracılığıyla birbirine bağlanmaktadır. Her evrişim katmanından önce yer alan birleştirme katmanları, ağırlıklı farklı aşamalarında üretilen özellik haritalarının etkin şekilde bütünleştirilmesine olanak tanımaktadır. Bu yapı, özellikle ince detayların korunmasını ve farklı ölçeklerdeki nesnelere daha başarılı şekilde bölütlenmesini mümkün kılmaktadır (Zhang et al., 2023).

DeepLabv3+ Mimarisi

DeepLabv3+ mimarisi (Chen et al., 2018), derin evrimsel sinir ağı (CNN) ve ASPP modüllerinin avantajlarını bir araya getiren, gelişmiş bir kodlayıcı-kod çözücü yapısı sunmaktadır. Bu yapı, hem küresel hem de yerel bağlamsal bilgiyi yakalayabilmekte ve bu sayede semantik bölütleme görevlerinde üstün performans sergilemektedir. DeepLabv3+ mimarisi, ayrıca kodlayıcı ve kod çözücü arasında atlamalı bağlantı, çok ölçekli girişler ve nihai bölütleme haritasının üretilmesi için son bir yeniden örnekleme adımı gibi çeşitli iyileştirmeler de içermektedir. Atrous evrişim, uzamsal piramit havuzlama ve derinlik-ayrık evrişim gibi teknikler, nesne tespiti ve lokalizasyonunda modelin başarısını artırmaktadır. Özellikle ResNet gibi artık bağlantılara sahip güçlü bir omurga ağının kullanılması, derin katmanlarda görülen kaybolan gradyan sorununu azaltmakta ve öznelik çıkarımını güçlendirmektedir (Maheswari et al., 2025; Nguyen et al., 2024).

SegNet Mimarisi

SegNet (Badrinarayanan et al., 2017), tam evrimsel bir kodlayıcı-kod çözücü mimarisiyle tasarlanmış olup, semantik görüntü bölütlemesi görevlerinde yüksek verimlilik sağlamaktadır. Bu mimari, VGG-16 veya VGG-19 tabanlı bir kodlayıcı ve buna karşılık gelen simetrik bir kod çözücü ağı içermektedir. Kodlayıcı ağında, girdi görüntüsünün öznelikleri çıkarılmakta, ardından uzamsal boyutlar kademeli olarak azaltılmaktadır. Kod çözücü katmanlarında tam bağlantılı katmanlar bulunmamakta ve böylece daha yüksek çözünürlükte öznelik haritaları ve daha az parametre elde edilmektedir. Bu yöntem, bellek kullanımını minimize ederek, düşük doğruluk kaybı ile pratik uygulamalara uygunluk sağlamaktadır. Kod çözücü ağı ise, kodlayıcıdan aktarılan havuzlama indekslerini kullanarak giriş öznelik haritalarını yeniden örnekleme ve ardından yoğun öznelik haritaları üretmektedir. Nihai olarak, elde edilen öznelik haritaları piksel düzeyinde sınıflandırma yapan bir Softmax katmanına aktarılmakta ve her piksel için sınıf olasılıkları üretilmektedir (Afify et al., 2021).

FCN Mimarisi

Long ve ark. (Shelhamer et al., 2017) tarafından, evrimsel sinir ağlarının tam bağlantılı katmanlarını evrim katmanları ile değiştirerek, semantik bölütleme için uçtan uca öğrenilebilen ilk sinir ağı olan FCN mimarisi geliştirilmiştir. FCN yapısı, temel olarak bir aşağı örnekleme ve bir yukarı örnekleme bölümünden oluşmaktadır. Aşağı örnekleme bölümünde, ardışık evrim katmanları, derin seviyelerde zengin semantik bilgi çıkarırken, sıg seviyelerde ise sınır detaylarını içeren öznitelik haritaları üretmektedir. Yukarı örnekleme kısmında ise transpoze evrim katmanları kullanılarak, elde edilen öznitelik haritaları orijinal görüntü boyutuna yeniden ölçeklendirilmektedir. FCN'de, kodlayıcı özelliklerinin tekrarlı şekilde kullanılması, yukarı örnekleme sırasında doğruluk ve sağlamlığı artırmaktadır (Bi et al., 2018; Wang et al., 2022).

BULGULAR VE TARTIŞMA

Deney Ortamı ve Hiper Parametreler

Değerlendirme süreçlerimiz, Windows 11 işletim sistemine sahip bir bilgisayar üzerinde gerçekleştirilmiştir. Bu bilgisayar, 2.10 GHz hızında çalışan Intel Core i7 14700K işlemci, 32 GB DDR5 RAM ve NVIDIA RTX 4060 GPU bileşenlerini içermektedir. Tüm deneyler, NVIDIA CUDA desteğiyle optimize edilmiş PyTorch çerçevesi kullanılarak uygulanmıştır. Model performanslarının karşılaştırılabilir ve tutarlı olması adına, eğitim ve test verilerinde tüm modeller aynı parametrelerle test edilmiştir.

Çalışmada kullanılan tüm deneysel hiper parametreler Tablo 1.'de özetlenmiştir. Model eğitim süreçlerinde, giriş çözünürlüğü, yığın boyutu, epok sayısı, epok öğrenme oranı, kayıp fonksiyonu ve optimizasyon algoritması gibi temel parametreler standartlaştırılmış ve sabit tutularak tüm deneylerde tutarlılık sağlanmıştır. Bu yaklaşım, elde edilen sonuçların karşılaştırılabilirliğini ve tekrar edilebilirliğini güvence altına almakta; ayrıca parametre kaynaklı belirsizlikleri en aza indirerek model performansının daha güvenilir şekilde değerlendirilmesine olanak tanımaktadır.


Tablo 1. Deneysel Hiper Parametreler

Parametre	Değer
Varsayılan giriş çözünürlüğü	256 × 256
Yığın boyutu	16
Epok Sayısı	30
Epok öğrenme oranı	0.001
Kayıp fonksiyonu	Çapraz entropi kaybı
Optimizasyon algoritması	Adam

Veri Önışleme

Bu çalışmada, veri önışleme aşamasında görüntülerin ve maskelerin analiz süreçlerine uygun hale getirilmesi için bazı işlemler yapılmıştır. İlk adım olarak, tüm görüntü ve maske verileri, modelin girdi boyutlarıyla uyumlu olması amacıyla 256 × 256 piksel boyutuna yeniden boyutlandırılmıştır. Ayrıca Şekil 3.'de görüldüğü gibi, maskelerde bulunan lezyon bölgelerindeki renk çeşitliliği ortadan kaldırılmış ve farklı renk tonlarına sahip tüm lezyon bölgeleri beyaz renge dönüştürülmüştür. Bu işlem, bölütleme görevinde hedef bölgelerin net bir şekilde belirlenmesine ve modelin tutarlı sonuçlar üretebilmesine olanak tanımıştır.

Tablo 2.'de OTU_2D veri setinde yer alan ultrason görüntüleri ve karşılık gelen maske sayılarının dağılımı özetlenmektedir. Veri seti, toplamda 1.469 ultrason görüntüsü ve bu görüntülere ait 1.469 gerçek maske içermektedir. Çalışmada, modelin eğitimi için veri setinin %80'i (1.175 görüntü ve maske) eğitim verisi olarak, kalan %20'si ise (294 görüntü ve maske) test verisi olarak ayrılmıştır. Bu dengeli dağılım, modelin hem öğrenme sürecinde yeterli çeşitliliğe ulaşmasını hem de performansının bağımsız bir test kümesi üzerinde güvenilir biçimde değerlendirilmesini sağlamaktadır. Ayrıca, her ultrason görüntüsüne karşılık bir gerçek maske bulunması, bölütleme algoritmalarının doğruluğunun nesnel olarak ölçülmesine olanak tanımaktadır.



Şekil 3. OTU_2D Veri Setindeki Orijinal Gerçek Maske ile Ön İşleme Sonrası Elde Edilen Gerçek Maske Örnekleri

Tablo 2. OTU_2D Veri Setinde Bulunan Ultrason Görüntü ve Maske Sayıları

Veri seti bölümleri	Ultrason görüntüsü	Gerçek maske
Eğitim verisi (%80)	1.175	1.175
Test verisi (%20)	294	294
Toplam veri (%100)	1.469	1.469

Deneysel Sonuçlar

Bu çalışmada, Tablo 3.'de, OTU_2D veri seti üzerinde beş farklı derin öğrenme tabanlı bölütleme modelinin performansları kapsamlı bir şekilde değerlendirilmiştir. Modellerin başarımı, DSC, IoU ve Çapraz Entropi Kaybı (Cross-Entropy Loss) metrikleriyle karşılaştırılmıştır. Elde edilen bulgular, tıbbi görüntü bölütleme alanında güncel mimarilerin güçlü ve zayıf yönlerini ortaya koymaktadır.

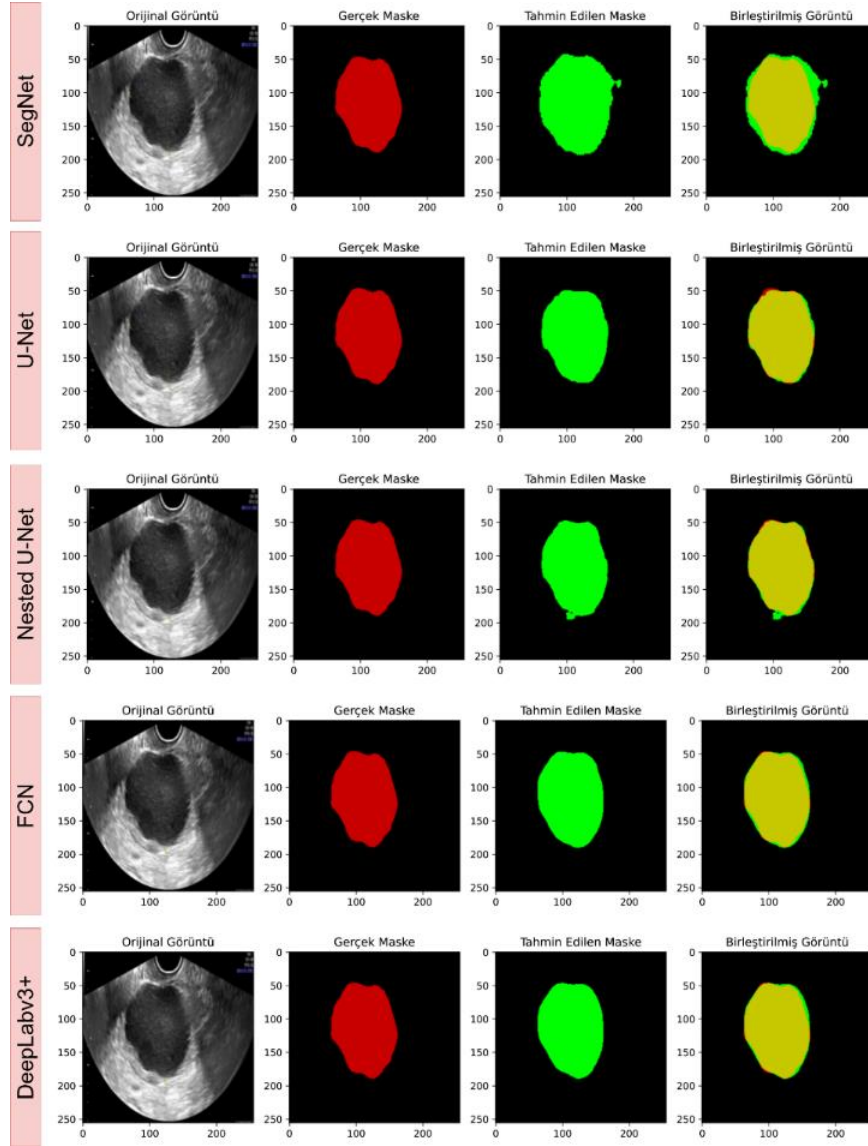
Tablo 3. OTU_2D Veri Seti için Bölütleme Modellerinin Performansları

Model ismi	DSC (%)	IoU (%)	Kayıp
SegNet	90,15	86,06	2.0163
U-Net	94,41	90,74	0.2067
Nested U-Net	95,13	91,86	0.1921
FCN	96,34	93,82	0.1871
DeepLabv3+	96,37	93,76	0.1724

Ayrıca bölütleme modellerinin başarılarının nitel olarak desteklenmesi amacıyla, test kümesinden seçilen temsili bir ultrason görüntüsü üzerinde elde edilen görsel sonuçlar Şekil 3.'te sunulmuştur. Her bir model için orijinal görüntü, uzman tarafından işaretlenen gerçek maske (kırmızı), model tarafından üretilen tahmin maskesi (yeşil) ve doğru/yanlış sınıflandırmaların (sarı: doğru pozitif, yeşil: yanlış pozitif, kırmızı: yanlış negatif) bir arada gösterildiği birleşik görüntüler yer almaktadır. Bu görselleştirme, her bir mimarinin bölütleme doğruluğunu, sınır keskinliği ve bölgesel tutarlılık açısından karşılaştırmalı olarak değerlendirme olanağı sunmaktadır.

Tablo 3.'de görüldüğü gibi, SegNet mimarisi, %90,15 DSC ve %86,06 IoU skorlarıyla diğer mimarilere kıyasla daha düşük bir bölütleme başarımı ortaya koymaktadır. Eğitim sürecindeki 2,0163'lük yüksek kayıp değeri, modelin istikrarsız öğrenme davranışını ve sınırlı genelleme kapasitesini yansıtmaktadır. Görsel analiz bulguları da bu nicel sonuçları desteklemektedir. Şekil 4.'te görülen SegNet mimarisinin ürettiği maskelerde sınır düzensizlikleri ve hedef dışı yanlış pozitif alanlar dikkat çekmekte, bu da modelin yerel doku farklılıklarını ayırt etmedeki yetersizliğini

göstermektedir. Bu kapsamda SegNet mimarisi, temel bölütleme görevlerinde sınırlı başarı gösteren bir mimari olarak öne çıkmaktadır.



Şekil 4. OTU_2D Veri Setinde Bulunan Orijinal Görüntü ve Gerçek Maske Görüntüleri ile Bölütleme Modellerinden Tahmin Edilen Maske ile Birleştirilmiş Görüntü Örnekleri.

U-Net modeli, %94,41 DSC ve %90,74 IoU değerleri ile daha kararlı bir öğrenme süreci sergilemiş ve 0,2067 kayıp değeriyle de eğitim etkinliğini ortaya koymuştur. Atlamalı bağlantıların sağladığı bilgi akışı sayesinde, özellikle sınır bölgelerinde daha net ve sürekli maskeler üretilebilmiştir. Şekil 4.'te görülen görsel çıktılar, doğru pozitif alanların artışı ve yanlış sınıflandırmaların azalışı ile bu nicel başarıyı doğrulamaktadır. Ancak, bazı küçük yapılar üzerindeki bölütleme duyarlılığı hâlâ iyileştirme gereksinimi taşımaktadır. Nested U-Net mimarisi, %95,13 DSC ve %91,86 IoU skorlarıyla klasik U-Net yapısını daha da ileri taşıyarak yüksek doğrulukta bölütleme sağlamaktadır. 0,1921 kayıp değeri, bu modelin eğitim sürecinde daha verimli olduğunu göstermektedir. Şekil 4'te yapılan değerlendirmelerde, yanlış pozitif ve negatif alanların azaldığı, tahmin edilen maskenin morfolojik olarak gerçek maskeye daha yakın olduğu gözlemlenmiştir. Özellikle küçük yapılar ve sınır bölgelerinde sağlanan yüksek duyarlılık, modelin çok ölçekli öznelik çıkarımındaki başarısını göstermektedir.

FCN modeli, %96,34 DSC ve %93,82 IoU gibi yüksek başarımlara ulaşarak, bölütleme doğruluğunda dikkat çekici bir performans sergilemektedir. 0,1871'lik düşük kayıp değeri, modelin hem eğitim sürecinde hem de test aşamasında kararlı sonuçlar verdiğini ortaya koymaktadır. Görsel analizde, doğru pozitif piksellerin yoğunluğu ve sınırlı yanlış

sınıflandırmalar modelin uzamsal tutarlılık ve yapısal uyum açısından da güçlü olduğunu göstermektedir. Bu durum, çok katmanlı öznetelik haritalarının etkili biçimde bütünleştirilmesiyle doğrudan ilişkilidir. DeepLabv3+ modeli, %96,37 DSC ve %93,76 IoU ile en yüksek bölütleme performansını sunmakta, 0,1724 kayıp değeri ile de en düşük eğitim kaybını sergilemektedir. Şekil 4.'teki görsel sonuçlar, bu nicel verileri tam anlamıyla desteklemektedir. Modelin tahmin ettiği maske, gerçek maske ile neredeyse tam örtüşmektedir. Bu model, gerek nicel metriklerde gerekse görsel doğrulamada en üstün mimari olarak öne çıkmaktadır.

DeepLabv3+ ve FCN mimarilerinin, özellikle düşük kaliteli ultrason görüntülerinde elde ettikleri yüksek bölütleme performansı dikkat çekicidir. Bu durumun başlıca sebeplerinden biri, her iki mimarinin de çok ölçekli bağlamsal bilgiyi etkin şekilde işleyebilme yetenekleridir. DeepLabv3+, ASPP ve kodlayıcı-kod çözücü yapısı sayesinde, hem küçük hem de büyük ölçekli doku ve sınır detaylarını başarılı biçimde yakalayabilmekte, böylece düşük kontrast ve yüksek gürültü içeren ultrason görüntülerinde dahi anahtar tümör sınırlarını hassas şekilde belirleyebilmektedir. Benzer şekilde, FCN mimarisi tam evrişimli katmanlarıyla, görüntüdeki tüm pikseller için konum bilgisine duyarlı tahminler üretebilmekte ve bu da özellikle bozulmuş veya düşük çözünürlüklü görüntülerde bölütleme başarısını artırmaktadır. Ayrıca, düşük seviyeli detay bilgisini koruyabilmesi, ultrason gibi parazitlerin yoğun olduğu veri setlerinde avantaj sağlamaktadır.

Yapılan değerlendirmeler, DeepLabv3+ ve FCN mimarilerinin OTU_2D veri seti üzerinde üstün bölütleme başarısı sunduğunu ortaya koymaktadır. Nested U-Net ve U-Net modelleri ise özellikle sınır hassasiyeti ve küçük yapıların korunmasında etkili olurken, SegNet modeli bu yönleriyle daha sınırlı bir başarı sergilemiştir. Bu bütünleşik analiz, bölütleme modellerinin performansını yalnızca sayısal metriklerle değil, aynı zamanda görsel kalite ve morfolojik uygunluk bağlamında da değerlendirme gerekliliğini vurgulamaktadır.

İstatistiksel Anlamlılık Testi

Wilcoxon Signed-Rank testi, eşleştirilmiş iki bağımlı grup arasında medyan farkının istatistiksel olarak anlamlı olup olmadığını değerlendiren parametrik olmayan bir testtir. Tablo 4.'te, her bir modelin DSC ve IoU skorları, DeepLabv3+ referans modeli ile Wilcoxon Signed-Rank testi kullanılarak karşılaştırılmış ve elde edilen p-değerleri sunulmuştur.

Tablo 4. Modellerin Dice ve Iou Skorları için Wilcoxon Signed-Rank Testi ile Elde Edilen p-Değerleri

Model ismi	DSC p-Değeri	IoU p-Değeri
SegNet	1.18×10^{-43}	5.99×10^{-42}
U-Net	2.20×10^{-25}	1.87×10^{-26}
Nested U-Net	9.54×10^{-19}	4.44×10^{-19}
FCN	7.49×10^{-1}	8.21×10^{-1}

Tablo 4. incelendiğinde, SegNet, U-Net ve Nested U-Net modellerinin hem DSC hem de IoU skorları için elde edilen p-değerlerinin son derece küçük olduğu ($p < 0.05$), dolayısıyla bu modeller ile referans model arasında istatistiksel olarak anlamlı bir fark bulunduğu görülmektedir. Özellikle SegNet ve U-Net modelleri için p-değerleri 10^{-25} ve daha küçük olup, bu sonuçlar, modellerin performansları arasında güçlü bir farklılık olduğunu göstermektedir.

Öte yandan, FCN modeli ile referans model arasındaki karşılaştırmada elde edilen p-değerleri (DSC için 0.749, IoU için 0.821) 0.05 eşik değerinin oldukça üzerindedir. Bu bulgu, FCN ile referans modelin performansları arasında istatistiksel olarak anlamlı bir fark bulunmadığını, yani her iki modelin benzer bir performans gösterdiğini ortaya koymaktadır.

Tartışma

Yapmış olduğumuz çalışmanın bazı kısıtları bulunmaktadır. Öncelikle, sadece klasik U-Net ve benzeri temel bölütleme mimarilerinin over tümör ultrason görüntülerindeki performansları karşılaştırılmıştır. Son yıllarda

literatürde öne çıkan Attention U-Net ve Transformer tabanlı gibi daha yeni ve gelişmiş derin öğrenme yaklaşımları ise çalışmanın kapsamı dışında bırakılmıştır. Bunun nedeni, temel modellerin mevcut veri seti üzerinde karşılaştırmalı analizinin yapılmasının hedeflenmesidir. Kullanılan veri seti tek merkezli olup, hasta sayısı sınırlı ve yalnızca düşük kaliteli ultrason görüntülerini içermektedir.

Ayrıca bu bölümde, literatürde OTU_2D veri seti kullanılarak gerçekleştirilmiş bölütleme yöntemlerinin, çalışmamızda en yüksek başarıyı elde eden model ile karşılaştırmalı analizi yer almaktadır. Değerlendirilen tüm çalışmaların aynı veri seti üzerinde yapılmış olması, yöntemlerin yalnızca mimari düzeyde değil, aynı zamanda işledikleri ilgi bölgesi (Region of Interest, ROI) kapsamı ve bölütleme yaklaşımları açısından da doğrudan karşılaştırılmasına imkân tanımaktadır. Tablo 5. incelendiğinde, DSC ve IoU metrikleri açısından yöntemler arasında belirgin farklılıklar olduğu görülmekte olup, bu farklar büyük ölçüde model mimarisi ve eğitim parametrelerinden kaynaklanmaktadır.

Tablo 5. Literatürde Yer Alan Çalışmaların Başarılarının Karşılaştırılması

Yazar	Yıl	Veri seti	Yöntem	DSC	IoU
Pham ve ark.	2024	OTU_2D	BKSeg-Net	%88,60	%79,61
Bui ve ark.	2024	OTU_2D	UNet3+ (ResNet50)	%86,44	%77,05
Pham ve ark.	2023	OTU_2D	U-Net	-	%59,75
Ta ve ark.	2024	OTU_2D	U-Net (MobileNet)	-	%73,48
Siahpoosh ve ark.	2024	OTU_2D	PCU-Net	%79,95	%74,05
El-Khatib ve ark.	2024	OTU_2D	DeepLabv3+	-	%91,18
Çalışmamız	2025	OTU_2D	DeepLabv3+	%96,37	%93,76

Pham ve ark. (2024) tarafından geliştirilen BKSeg-Net modeli, %88,60 DSC ve %79,61 IoU skorları ile dikkat çekmektedir. Bu modelde, karmaşık yapılı ROI'leri daha hassas biçimde ele alabilmek için özel bloklar ve kayıp bileşeni kullanılmıştır. Bu durum, modelin özellikle detaylı sınırların bölütlenmesinde iyi performans sergilemesine katkı sağlamıştır. Benzer şekilde, Bui ve ark. (2024) tarafından kullanılan UNet3+ (ResNet50) mimarisi, güçlü bir omurga mimarisi ile ROI alanlarını tespit etmede %86,44 DSC ve %77,05 IoU değerlerine ulaşmıştır.

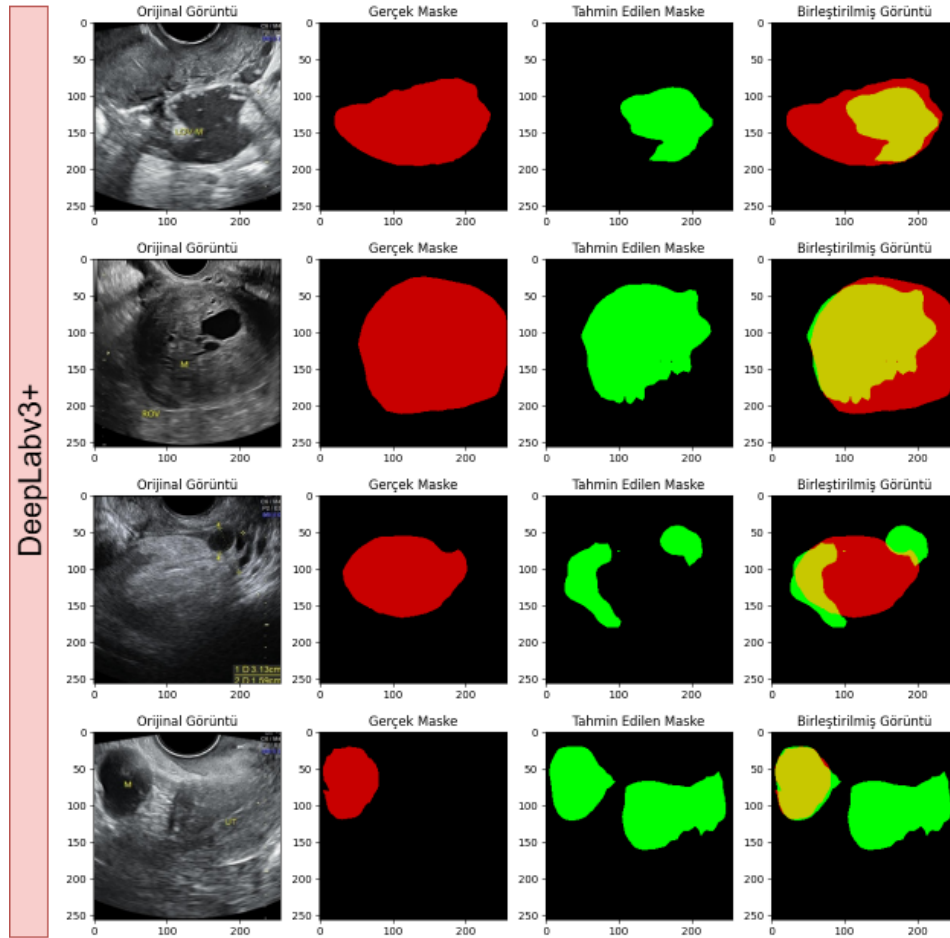
Pham ve ark. (2023) tarafından yürütülen çalışmada ise klasik U-Net modeli kullanılmış ve yalnızca %59,75 IoU değeri hesaplanmış, DSC değeri ifade edilmemiştir. ROI sınırlarını belirlemede sınırlı hassasiyete sahip bu temel mimari, geniş ve kompleks ROI'lerde düşük başarı sergilemiş, bu da modelin genel bölütleme gücünü sınırlamıştır. Ta ve ark. (2024) tarafından geliştirilen U-Net (MobileNet) modeli de daha sınırlı kapasitede ve hafif yapılı bir mimari olup, yalnızca %73,48 IoU değeri bildirilmiştir. ROI içindeki ayrıntıların yakalanmasında yaşanan zorluklar nedeniyle, bu modelin performansı da yüksek çözünürlük isteyen bölütleme problemlerinde yetersiz kalmıştır.

Siahpoosh ve ark. (2024) tarafından önerilen PCU-Net modeli, %79,95 DSC ve %74,05 IoU skorlarıyla düşük başarı elde etmiş, yapısal ayrıntıları yakalamada yetersiz kalmıştır. El-Khatib ve ark. (2024) çalışmasında DeepLabv3+ modeliyle %91,18 gibi oldukça yüksek bir IoU oranı elde edilmiş, ancak DSC değeri raporlanmamıştır. Yalnızca IoU değeri verilmiş olması, modelin bölütleme başarısının diğer çalışmalarla tam anlamıyla karşılaştırılmasını güçleştirmektedir. Yine de, bu yüksek IoU oranı, modelin özellikle ROI sınırlarını hassas biçimde belirlenmesinde başarılı olduğunu göstermektedir.

Bu çalışma kapsamında geliştirilen DeepLabv3+ modeli ise hem geniş hem de detaylı ROI'leri etkin biçimde işleyecek şekilde optimize edilmiş, %96,37 DSC ve %93,76 IoU skorları ile literatürde karşılaştırılan tüm modellere karşı üstünlük sağlamıştır. El-Khatib ve ark. ile kıyaslandığında IoU skorunda yaklaşık 2,5 puanlık bir artış dikkat çekerken, birçok çalışmada ya düşük kalan ya da hiç raporlanmayan DSC değeri göz önüne alındığında, önerilen modelimizin hem yönetsel olarak hem de ROI duyarlılığı bakımından mevcut literatürden anlamlı ölçüde ayrıştığı görülmektedir. Geliştirilen modelin, kullanılan bölütleme mimarisi ve ROI özelliklerine dayalı ayrıntılı bölütleme kabiliyeti sayesinde, OTU_2D veri seti üzerinde başarılı sonuçları sunduğu görülmektedir.

DeepLabv3+ modeli, test verisi üzerinde en yüksek başarıyı gösteren yöntemdir. Ancak, modelin düşük performans sergilediği örneklerde bazı sınırlılıkları olduğu görülmüştür. Şekil 5. incelendiğinde, modelin bazı görüntülerde gerçek bölütlenme maskesini tam olarak yakalayamadığı anlaşılmaktadır. Bu örneklerde model genellikle hedef yapının sadece bir kısmı doğru tespit edilmiştir. Bazı durumlarda ise model, yanlış pozitif bölütlemeler üretmiştir.

Bu başarısızlıkların başlıca nedenleri arasında ultrason görüntülerindeki düşük kontrast, doku homojenliği, sınır belirsizliği ve gürültü yer almaktadır. Ayrıca, yapıların şekil ve boyutlarındaki çeşitlilik ile eğitim veri setindeki dengesizlikler de modelin genelleme kabiliyetini azaltmıştır. DeepLabv3+ modelinin bazı zorlayıcı örneklerde yetersiz kalması, gelecekte daha dengeli ve çeşitli bir veri seti kullanılmasını gerektirmektedir. Ayrıca, gelişmiş veri artırma tekniklerinin uygulanması modelin başarısını artırabilir. Bu bulgular, modelin sınırlarını ortaya koymakta ve gelecek çalışmalar için önemli bir rehber sunmaktadır.



Şekil 5. DeepLabv3+ Modelinin Yeteri Kadar Başarılı Sınıflandıramadığı Görüntülerden Örnekler

SONUÇ

Over kanserinin erken teşhisi ve doğru şekilde bölütlenmesi, düşük kontrastlı ultrason görüntüleme verilerinin karmaşıklığı nedeniyle önemli zorluklar barındırmaktadır. Bu çalışmada, uzman etiketli OTU_2D veri seti kullanılarak U-Net, Nested U-Net, DeepLabv3+, SegNet ve FCN gibi derin öğrenme tabanlı bölütlenme modelleri karşılaştırılmıştır.

Gerçekleştirilen analizlerde, DeepLabv3+ modeli %96,37 DSC ve %93,76 IoU skorlarıyla en yüksek performansı göstermiş ve özellikle sınır bölgelerindeki hassasiyetiyle öne çıkmıştır. Benzer şekilde, FCN modeli %96,34 DSC ve %93,82 IoU skorlarıyla dikkat çekici bir doğruluk sağlamıştır. Nested U-Net ve U-Net modelleri, sınır hassasiyeti

ile küçük yapıları doğru şekilde bölütlemeye etkili bulunurken, SegNet modeli diğer modellere kıyasla daha sınırlı bir başarı sergilemiştir.

Elde edilen bulgular, çok ölçekli öznelik çıkarımı ve bağlamsal bilgi işleme gibi mimari yeniliklerin, medikal görüntü bölütleme alanındaki başarının artırılmasında kritik bir rol oynadığını ortaya koymaktadır. Bu çalışma, farklı klinik ihtiyaçlara uygun model seçimi için pratik bir rehber sunarken, gelecekteki araştırmalar için toplu öğrenme stratejilerinin veya hibrit mimarilerin entegrasyonu ile bölütleme doğruluğunun daha da artırılacağı yönünde bir perspektif sunmaktadır.

Gelecekteki çalışmalarda, literatürde son dönemde öne çıkan Attention U-Net ve Transformer tabanlı modeller gibi yeni mimarilerin de değerlendirmeye alınması, over tümör ultrason görüntülerinde bölütleme performansının daha kapsamlı ve güncel bir şekilde analiz edilmesine olanak sağlayacaktır. Ayrıca çok merkezli ve daha geniş veri setlerinin karşılaştırılması, bölütleme başarısının daha kapsamlı bir şekilde analiz edilmesine katkı sağlayacaktır. Bu sayede, elde edilecek bulguların alana katkısının daha da artırılması amaçlanmaktadır.

KAYNAKLAR

- Afify, H. M., Mohammed, K. K., & Hassanien, A. E. (2021). An improved framework for polyp image segmentation based on SegNet architecture. *International Journal of Imaging Systems and Technology*, 31(3), 1741-1751. <https://doi.org/10.1002/ima.22568>.
- Badrinarayanan, V., Kendall, A., & Cipolla, R. (2017). SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(12), 2481-2495. <https://doi.org/10.1109/TPAMI.2016.2644615>.
- Bi, L., Feng, D., & Kim, J. (2018). Dual-Path Adversarial Learning for Fully Convolutional Network (FCN)-Based Medical Image Segmentation. *The Visual Computer*, 34(6), 1043-1052. <https://doi.org/10.1007/s00371-018-1519-5>.
- Bierig, S. M., & Jones, A. (2009). Accuracy and cost comparison of ultrasound versus alternative imaging modalities, including CT, MR, PET, and angiography. *Journal of Diagnostic Medical Sonography*, 25(3), 138-144. <https://doi.org/10.1177/8756479309336240>.
- Bui, H. S., Tran, S. H., Nguyen, T. B., Tran, T. H., Vu, H., & Le, T. L. (2024, 3-6 Dec. 2024). Marker-Aware Ovarian Tumor Segmentation from Ultrasound Images. 2024 Asia Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC), <https://doi.org/10.1109/APSIPAASC63619.2025.10848960>.
- Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. *Proceedings of the European conference on computer vision (ECCV)*, <https://doi.org/10.48550/arXiv.1802.02611>.
- El-khatib, M., Popescu, D., Teodor, O., & Ichim, L. (2024). Intelligent system based on multiple networks for accurate ovarian tumor semantic segmentation. *Heliyon*, 10(17). <https://doi.org/10.1016/j.heliyon.2024.e37386>.
- Maheswari, P., Raja, P., Karkee, M., Raja, M., Baig, R. U., Trung, K. T., & Hoang, V. T. (2025). Performance analysis of modified DeepLabv3+ architecture for fruit detection and localization in apple orchards. *Smart Agricultural Technology*, 10, 100729. <https://doi.org/10.1016/j.atech.2024.100729>.
- Nguyen, T.-N., Tran, T. D., & Cuong, P. V. (2024). Segmentation of Concrete Surface Cracks Using DeeplabV3+ Architecture. *Proceedings of the Third International Conference on Sustainable Civil Engineering and Architecture*, Singapore, <https://doi.org/10.1007/978-981-99-7434-4>.
- Pham, T.-L., Le, V.-H., Tran, T.-H., & Vu, D. H. (2023). Comprehensive Study on Semantic Segmentation of Ovarian Tumors from Ultrasound Images. *The 12th Conference on Information Technology and Its Applications*, Cham, https://doi.org/10.1007/978-3-031-36886-8_22.
- Pham, T.-L., Pham, G.-M., Nguyen, T.-D., Le, V.-H., Le, T.-L., Vu, D.-H.,... Tran, T.-H. (2024). Data Augmentation and Assessment for Enhanced Ovarian Tumor Classification. 2024 Asia Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC), <https://doi.org/10.1109/APSIPAASC63619.2025.10848688>.

- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, Cham, https://doi.org/10.1007/978-3-319-24574-4_28.
- Shelhamer, E., Long, J., & Darrell, T. (2017). Fully Convolutional Networks for Semantic Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(4), 640-651. <https://doi.org/10.1109/TPAMI.2016.2572683>.
- Siahpoosh, M., Imani, M., & Ghassemian, H. (2024, 6-7 March 2024). Ovarian Tumor Ultrasound Image Segmentation with Deep Neural Networks. *2024 13th Iranian/3rd International Machine Vision and Image Processing Conference (MVIP)*, <https://doi.org/10.1109/MVIP62238.2024.10491156>.
- Siegel, R. L., Kratzer, T. B., Giaquinto, A. N., Sung, H., & Jemal, A. (2025). Cancer statistics, 2025. *Ca*, 75(1), 10. <https://doi.org/10.3322/caac.21871>.
- Ta, N. A., Ngo, V. A., Pham, T. L., Vu, D. H., Le, T. L., Vu, H.,...Tran, T. H. (2024, 31 July-2 Aug. 2024). Weighted Fusion Architecture for Improved Ovarian Tumor Segmentation from Ultrasound Images. *2024 Tenth International Conference on Communications and Electronics (ICCE)*, <http://doi.org/10.1109/ICCE62051.2024.10634737>.
- Wang, Z., Gao, X., Wu, R., Kang, J., & Zhang, Y. (2022). Fully automatic image segmentation based on FCN and graph cuts. *Multimedia Systems*, 28(5), 1753-1765. <https://doi.org/10.1007/s00530-022-00945-3>.
- Zhang, H., Zhu, C., Lian, X., & Hua, F. (2023). A Nested Attention Guided UNet++ Architecture for White Matter Hyperintensity Segmentation. *IEEE Access*, 11, 66910-66920. <https://doi.org/10.1109/ACCESS.2023.3281201>.
- Zhao, Q., Lyu, S., Bai, W., Cai, L., Liu, B., Cheng, G.,...Chen, L. (2022). MMOTU: a multi-modality ovarian tumor ultrasound image dataset for unsupervised cross-domain semantic segmentation. *arXiv preprint arXiv:2207.06799*. <https://doi.org/10.48550/arXiv.2207.06799>.
- Zhou, Z., Rahman Siddiquee, M. M., Tajbakhsh, N., & Liang, J. (2018). Unet++: A nested u-net architecture for medical image segmentation. *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*, https://doi.org/10.1007/978-3-030-00889-5_1.