

## Fetüs beyin dokularının 3B U-Net ile segmentasyonu ve gestasyonel yaşın segmentasyon performansına etkisi

### Segmentation of fetal brain tissues using 3D U-Net and the effect of gestational age on segmentation performance

Uğurcan Akyüz<sup>1\*</sup> , Tayyip Özcan<sup>2</sup> 

<sup>1,2</sup> Erciyes Üniversitesi, Bilgisayar Mühendisliği Bölümü, 38039, Kayseri, Türkiye

#### Öz

Gebelik esnasında fetüs beyinde, çevresel veya genetik etmenlerden kaynaklanan bozuklukların ilerleyen yaşlarda otizm, hiperaktivite ve bipolar bozukluklar olarak ortaya çıktıgı düşünülmektedir. Fetüs beyin dokularının yapısal analizi, dokuların büyüklükleri ve şekilleri hakkında bilgi sağlayarak bu hastalıkların etiyolojisinin araştırılmasına yardımcı olmaktadır. MR (manyetik rezonans) ve ultrason fetüs beyin dokusu analizi için en sık kullanılan iki görüntüleme tekniğidir. Özellikle MR görüntülemede, fetüs beyin dokuları net bir şekilde görülebilmesine rağmen bu görüntülerin yapısal analizi zaman alıcı bir iştir. Hızla gelişen ve değişen fetüs beyin dokuları, haftalık veya aylık periyotlarla, elle veya yarı-otomatik şekilde gerçekleştirilen MR analizinin yapılmasını zorlaştırmaktadır. Bu araştırmada, 3B U-Net ile MR görüntüleri üzerinde yedi farklı fetüs beyin dokusunun tam otomatik segmentasyonu gerçekleştirilmiştir. FeTA2021 veri seti, erken, orta ve geç gestasyonel yaşı gruplarına bölünerek her bir yaş grubu için farklı 3B U-Net modelleri eğitilmiş ve segmentasyon performansı analiz edilmiştir. Gestasyonel yaşı gruplarına göre sırasıyla ortalama 0.83, 0.91 ve 0.92 Dice skoruna ulaşılmıştır.

**Anahtar kelimeler:** Fetüs beyin dokusu, MR görüntüleme, segmentasyon, U-Net

#### 1 Giriş

Milyarlarca nörondan ve karmaşık bağlantılarından oluşan insan beyninin gelişimi hassas bir süreçtir. Gebelik boyunca fetüs beyinlerinde milyarlarca nöron üretilir bu nöronların beyin içerisindeki pozisyonları şekillenir [1]. Gebelik sırasında fetüs beyinde, genetik mutasyonlardan ve çevresel etmenlerden kaynaklanan yapısal bozukluklar meydana gelerek Arnold-Chiari malformasyonu [2], otizm [3], lizensefali [4], gibi anomalilere sebebiyet vermektedir. Bu anomalilerin oluşumunun ve gelişiminin araştırılması amacıyla fetüs beyinlerinin gelişim sürecinin takip edilmesi ve bu oluşumların analizinin yapılması gerekmektedir. Fetüs beyninin analizinin ilk adımı gri madde, beyaz madde, beyincik gibi beyin dokularının segmentasyonunun yapılmasıdır. Fetüs beyin dokularının segmentasyonu, araştırmacıların nicel analizlerine ve dokulardaki anormal

#### Abstract

Environmental and genetic factors are thought to cause diseases in the fetal brain that may later manifest as autism, hyperactivity, and bipolar disorder. Structural analysis of fetal brain tissue helps to explore the etiology of these diseases by providing information about the size and shape of the tissues. MR (magnetic resonance) imaging and ultrasound are the two imaging modalities most used to analyze fetal brain tissue. Especially in MR imaging, brain tissues can be seen clearly. However, structural analysis of MR images is a time-consuming process. Because fetal brain tissues develop and change rapidly, it is difficult to perform manual or semi-automated MR analysis weekly or monthly. In this study, seven different fetal brain tissues were segmented fully-automated with 3D U-Net. The FeTA2021 dataset was divided into the early, middle, and late gestational age groups, different 3D U-Net models were trained for each age group, and segmentation performance was analyzed. Average Dice scores of 0.83, 0.91, and 0.92 were achieved for the gestational-age groups, respectively.

**Keywords:** Fetal brain tissue, MR imaging, segmentation, U-Net

büyümelerin ve şekil bozuklarının tespit edilebilmesine olanak sağlamaktadır. Günümüzde beyin dokularının segmentasyonu, atlas-tabanlı yöntemler kullanılarak MR görüntüleri üzerinde yapılmaktadır. Ancak gelişen fetüs beyin yapısı çok kısa sürede değiştiği için her bir gebelik haftasına ait beyin atlası bulmak veya oluşturmak maliyetli bir iştir. Ayrıca Arnold-Chiari malformasyonu [2] gibi patolojik vakaların da olması ve farklı şekil ve büyülüklükteki beyin dokularının oluşumu, atlas-tabanlı segmentasyonun başarısını düşürmektedir. Bu gibi problemlere çözüm üretmesi ve tam otomatik segmentasyon araçlarının geliştirilmesi için Payette vd. [5] tarafından FeTA2021 (Fetal Brain Tissue Annotation and Segmentation Challenge 2021) veri seti yayınlanmıştır. FeTA2021 veri setinin ilk versiyonunda 20-35 haftalık, patolojik ve nörotipik olan 50 fetüse ait MR görüntüsü bulunmaktadır. Daha sonra

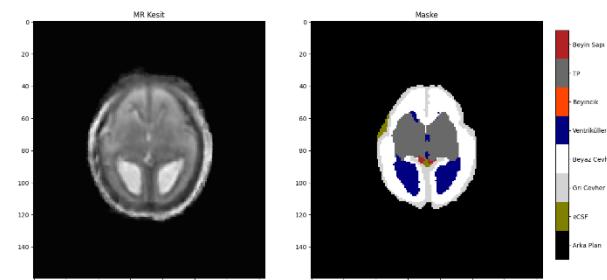
\* Sorumlu yazar / Corresponding author, e-posta / e-mail: 4010930037@erciyes.edu.tr (U. Akyüz)  
Geliş / Received: 03.01.2023 Kabul / Accepted: 17.04.2023 Yayımlanma / Published: 15.07.2023  
doi: 10.28948/ngumuh.1228788

yayınlanan ikinci versiyonu ile veri setindeki toplam fetüs sayısı 80'e çıkarılmıştır.

Payette vd. yayınlanan ilk veri seti ile bu veri seti üzerinde segmentasyon çalışması gerçekleştiren farklı araştırmacı grupların çalışmalarını da tanıtmışlardır. Yapılan çalışmalarla 2B U-Net, 3B U-Net ve Mask R-CNN tabanlı segmentasyon modelleri farklı hiper parametre konfigürasyonları ile eğitilmiştir. IBBM olarak adlandırılan ve üç 2B U-Net modelini içeren segmentasyon yönteminde, aksiyal, koronal ve sagital yönlerden çıkarılan MR görüntülerinin kesitleri üzerinde modeller eğitilmiş ve 3 modelin çıktıları birleştirilerek en iyi segmentasyon sonucuna ulaşılmıştır.

Derin öğrenme yöntemleri veriye aç öğrenme yöntemleridir. Veri sayısının ve çeşitliliğinin artırılması modellerin dayanıklılığını ve başarısını artırmaktadır. Bu yüzden farklı kaynaklardan gelen veriler birleştirilerek büyük veri setleri oluşturulur. Ancak farklı kaynaklardan gelen veriler her zaman aynı sayıda sınıf sayısı veya etiket düzeni içermeyebilir ve bu da veri setlerinin birleştirilmesini zorlaştırabilir. Bu problemin çözümü için Fidon vd. [6] etiket-seti (label-set) kayıp fonksiyonlarını geliştirmiştir. Böylelikle FeTA2021 veri setini farklı kaynaklardan gelen fetüs beyin MR veri setleriyle birleştirip topluluk (ensemble) 3B U-Net modellerini eğittiştir. Farklı kaynaklarından gelen MR görüntüler farklı veri dağılımlarını da içerebilmektedir. Tek bir veri dağılımına sahip homojen veri setleri üzerinde eğitilen modeller ise farklı veri dağılımindaki veri setleri üzerinde çalıştırıldığında performansları düşebilmektedir. Bu problemin çözümü için Dumast vd. [7], FaBiAN (Fetal Brain magnetic resonance) [8] fantom aracını kullanarak fetüslere ait sentetik MR görüntüler oluşturmuştur. Hedef veri dağılımindaki verileri eldeki verilerden türetilmiş ve 2B U-Net eğitiminde kullanılmışlardır. Böylelikle modelin dayanıklılığını artırarak farklı veri dağılımları üzerindeki segmentasyon başarılarını artırmışlardır. Fetüs beyin görüntülerinin toplanmasının yanı sıra yeni oluşmaya başlayan ve sınırları belli olmayan dokuların etiketlenmesi de zorlu bir süreçtir. MR görüntüler için segmentasyon etiketleri oluştururlarken yarı otomatik etiketleme araçlarından yararlanılarak dokuların etiketleri oluşturulur ve oluşturulan etiketler doktorlar tarafından kontrol edilerek hatalı yerler tespit edilir; hatalı etiket sınırları düzenlenir. Ancak bu süreçte de görüntü veya doktor kaynaklı, sınırları iyi belirlenmemiş, gürültülü etiketler oluşabilmektedir. Hem bu gürültülü etiketleri kullanarak hem de yüksek doğrulukta etiketleme işleminin iş yükünü azaltmak amacıyla Karimi vd. [9] gürültülü etiket eğitimi yöntemini kullanarak 3B U-Net modellerini eğitiip testlerini gerçekleştirmiştir. Bu çalışma için 294 fetüse ait beyin görüntüsü toplanmıştır. İlk aşamada, eğitim seti için seçikleri, 272 fetüse ait MR görüntülerini, genel kullanımına açık atlaslarla segmente etmiş ve uzmanlar tarafından hatalı segmentasyonların düzeltmesini sağlamışlardır. Ancak burada sadece önemli hatalar düzeltmiş küçük hatalar çok zaman alacağı için düzeltmemiş ve gürültülü etiketler oluşturulmuştur. Çalışmada önerilen yeni etiket düzleştirme (label smoothing) [9] yöntemi ile modellerin eğitimi yapılmış ve genç fetüsler

icin ortalama 0.89, daha olgun fetüsler için ortalama 0.91 Dice skoru ile beyin dokuları segmente edilmiştir. Segmentasyon modellerinin doğruluğu kadar hızı da önemli bir diğer kriterdir. Özellikle ürüne dönüştürülen çalışmalarla kullanıcının isteklerine kısa sürede cevap vermek kritik önem taşır. Ayrıca hızlı çalışan bir segmentasyon modeli gerçek zamanlı uygulamaların geliştirilebilmesine de olanak sağlar. Salehi vd. [10] yeni geliştirdikleri evrişimsel sinir ağı modeliyle fetüslerde ait beyin bölgelerini ve rahim dokularını bir saniyenin altında bir hızla segmente edebilmişlerdir.



**Şekil 1.** Fidon vd. tarafından iyileştirilmiş FeTA2021 veri setinden sub-015'e ait bir aksiyal kesit ve ilgili kesite ait 8 segmentasyon sınıfı için etiketler.

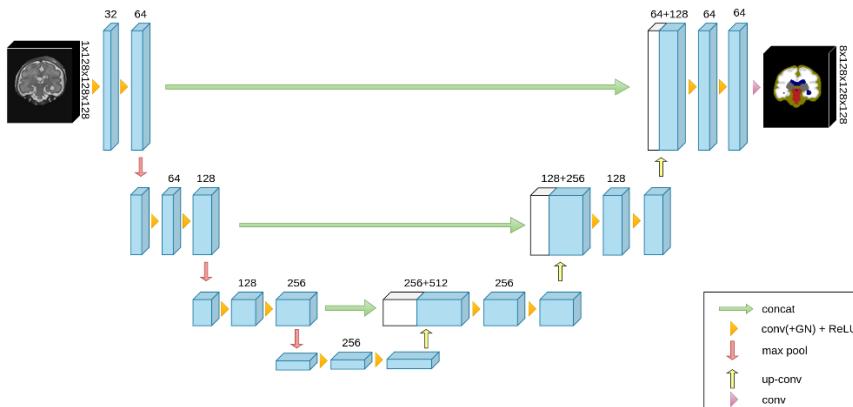
Bu çalışmada, 3B U-Net modelleri ile üç farklı gestasyonel yaş grubuna ayrılan fetüslerin, 7 farklı beyin dokusunun segmentasyonu gerçekleştirilmiştir. Bu dokular dış serebral sıvı (extra-axial cerebrospinal fluid, eCSF), gri cevher (gray matter, GM), beyaz cevher (white matter, WM), ventriküler, beyincik, talamus-putamen (TP), ve beyin sapıdır. Segmentasyon çalışmaları gerçekleştirildiğinde FeTA2021 veri setinden ve dHCP (Developing Human Connectome Project) veri setinden yararlanılmıştır. dHCP veri setinden FeTA2021 veri setiyle uyumlu olabilecek MR görüntülerini seçerek aktarımı öğrenme (transfer learning) için kullanılacak bir veri seti oluşturulmuştur. Temel 3B U-Net modeli, oluşturulan dHCP veri seti üzerinde eğitilmiştir. Daha sonrasında aktarımı öğrenme ile 3 farklı gestasyonel yaş grubuna ayrılmış FeTA2021 alt setleri üzerinde 3 farklı temel 3B U-Net modeli ile eğitimler yapıp modellerin başarıları analiz edilmiştir.

Bu makalenin 2. bölümünde, çalışmada kullanılan veri setleri ve segmentasyon modeli hakkında bilgi verilmiştir. 3. bölümde bulgular tartışılmış, 4. bölümde ise deneyler ve analizlere yer verilmiştir. Son bölümde ise çalışmanın sonucu verilmiştir.

## 2 Materyal ve metot

### 2.1 FeTA2021 Veri Seti

Bu çalışmada, Fetal Brain Tissue Annotation and Segmentation Challenge 2021 yarışması kapsamında yayınlanmış, T2 ağırlıklı,  $0.5\text{mm} \times 0.5\text{mm} \times 0.5\text{mm}$ , izotropik, 80 fetüse ait, super çözünürlüklü MR görüntüler kullanılmıştır [5]. Fetüslerin gestasyonel yaş aralığı 20 hafta ile 35 hafta arasında değişmektedir. Veri seti nörotipik ( sağlıklık ) durumların yanı sıra patolojik durumları da içermektedir. Fetüslerde ait görüntüler 1.5T ve 3T MR cihazları ile toplanmıştır.



**Şekil 1.** Arka plan ve 7 farklı beyin dokusunun segmentasyonu için uyarlamış olduğumuz 3B U-Net modeli.

Yüksek çözünürlüklü fetüs beyin MR görüntüsü elde etmek amacıyla mialSR [11] ve Simple IRTK [12] rekonstrüksiyon yöntemlerinden yararlanılmıştır. Veri setindeki 40 fetüse ait beyin MR görüntüsünün rekonstrüksiyonu mialSR ile geriye kalan fetüslerinki ise Simple IRTK metodu ile yapılmıştır. Simple IRTK ile rekonstrüksiyonu yapılan MR görüntülerine görüntü düzleştirme (image registration) uygulanmıştır. Ayrıca klinik uzmanlar tarafından 7 farklı beyin dokusu için segmentasyon maskeleri (etiketleri) oluşturulmuştur. Bu dokular, eCSF, GM, WM, ventriküler, beyincik, TP ve beyin sapıdır.

Fidon vd. [13] yaptıkları segmentasyon çalışması için FeTA2021 veri setindeki eksik ve hatalı yerleri düzelterek veri setini iyileştirmiştir. Yaptıkları iyileştirmeler kapsamında, mialSR ile elde edilmiş süper çözünürlüklü görüntüler için görüntü düzleştirme gerçekleştirmiştir ve hatalı maske sınırlarını düzeltmişlerdir. Ayrıca klinik uzmanlar tarafından korpus kallozum bölgesi için de maskeler oluşturulmuştur.

Orijinal FeTA2021 veri seti  $256 \times 256 \times 256$ 'lık MR görüntülerini içermektedir. Bazı görüntülerin büyük bir kısmı siyah pikselleri içeren kesitlerinden oluşmaktadır. Fidon vd. tarafından yapılan iyileştirme çalışmalarında bu kesitler temizlenmiştir; fetüs beyinleri MR görüntüsünün ortasında konumlanacak şekilde görüntüler iyileştirilmiştir.

Yaptığımız incelemeler sonucunda Fidon vd. tarafından FeTA2021 veri seti üzerinde yapılan çalışmaların fetüs beyin dokusu sınırlarındaki geçişleri daha net gösterdiği ve kontrastlarını iyileştirdiği görülmüştür. Bu sebeple yaptığımız eğitimlerde Fidon vd. tarafından iyileştirilmiş FeTA2021 fetüs beyin MR görüntülerini kullanılmıştır.

Fidon vd. gerçekleştirdikleri iyileştirme çalışmalarında farklı bir etiket düzeni kullandıkları için yaptığımız çalışmada etiket sıralamasını orijinal FeTA2021 veri setindekine göre yeniden uyarladık. Ayrıca maskelerin ve sınıf sayısının orijinal FeTA2021 veri setiyle uyumlu olması için korpus kallozum sınıfının etiketlerini beyaz cevher etiketleri ile birleştirdik. İyileştirilen veri setinde, görüntü düzleştirme yapılmış görüntülerdeki arka plan etiketleri bozuk piksel değerleri içermekteydi. Etiketlerdeki bozuk piksel değerlerine 0 değerleri atayarak arka plan sınıfının

etiket bütünlüğünü sağladık. Ayrıca Fidon vd. [5] tarafından yapılan çalışmada sub-007 ve sub-009 verilerinin bozuk olduğu ve yaptıkları araştırmada kullanılmadığı belirtilmiştir. Yapılan incelemelerde bu verilerin çok gürültülü olduğu teyit edildi ve yaptığımız çalışmada da sub-007 ve sub-009'a ait veriler kullanılmadı.

Gestasyonel yaşın 3B U-Net modelinin segmentasyon performansına olan etkilerini analiz etmek için iyileştirilmiş FeTA2021 veri seti 3 farklı gestasyonel yaş grubuna bölünmüştür. Bu yaş grupları ve oluşturulan veri setlerine ait fetüs örnek sayısı **Tablo 1**'de görüldüğü gibidir.

## 2.2 dHCP Veri Seti

The Developing Human Connectome Project (dHCP) [14] erken dönem insan beyninin nasıl geliştiğini ve evrildiğini anlamak için başlatılmış bir projedir. Proje kapsamında yeniden doğanlara ait beyin MR görüntülerini ve segmentasyon maskeleri paylaşılmıştır. Bu veri seti aynı zamanda erken doğumlara ait beyin MR görüntülerini de içermektedir. Veri setinin üçüncü versiyonu 787 denekten T1 ve T2 ağırlıklı beyin MR görüntülerini ve maskelerini içermektedir. Yaptığımız bu çalışmada, aktarımı öğrenmede kullanmak için bu veri setinden postmenürel yaşı 26.1 ve 34.9 hafta arasında değişen 89 deneğe ait MR görüntüsü kullanılmıştır.

## 2.3 Segmentasyon Modeli

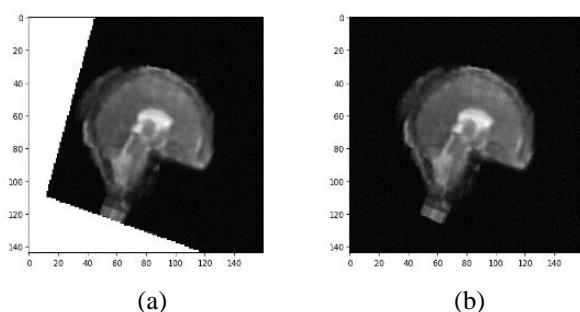
Bu çalışmada Çiçek vd. tarafından geliştirilen 3B U-Net [15] modelinden yararlanıldı. 3B U-Net, medikal görüntülerin segmentasyonu için kullanılan en başarılı derin öğrenme modellerinden birisidir. **Şekil 2**'de 3B U-Net mimarisini görebilmektedir. Daralma ve genişleme bloğundan oluşan 3B U-Net mimarisini, daralma katmanında girdi görüntüsünün özniteliklerini öğrenir ve genişleme katmanında bu öznitelikleri kullanarak ilgili segmentasyon bölgelerinin öğrenilmesini sağlar. Gerçekleştirdiğimiz çalışmada arka plan sınıfı ve 7 farklı fetüs beyin dokusu sınıfı olmak üzere toplamda 8 farklı sınıfın segmentasyonu gerçekleştirildi. MR görüntülerini gri skaladaki tek kanallı 2 boyutlu kesitlerden oluşturmaktadır. Bu yüzden çalışmada orjinal 3B U-Net modelinin girdi katmanı tek kanallı girdileri alacak şekilde ayarlanmıştır ve modelin çıktı

katmanı da **Şekil 2**'de görüleceği üzere 8 farklı sınıfı segmente edecek şekilde  $64 \times 8$  evrişim katmanı ile değiştirilmiştir. Orijinal 3B U-Net modelinde yoğun normalizasyon (batch normalization) katmanları kullanılmaktadır. Yığın normalizasyon katmanları, eğitimlerin daha stabil yapılmasına olanak sağlayarak modellerin daha hızlı sürede veriyi öğrenmesine yardımcı olur ve patlayan veya yok olan gradyan problemlerini de önler. Ancak yoğun normalizasyon yöntemi 8, 16, 32 gibi yoğun büyülüklüklerinde iyi sonuçlar üretmekteyken yoğun büyülüklüğü küçüldükçe yoğun istatistikleri tutarsızlaştığı için etkisini kaybetmektedir. Elimizdeki kısıtlı donanım kaynaklarından ve 3 boyutlu MR görüntülerinin büyük miktarda hafiza maaliyeti getirmesinden dolayı MR görüntülerini yoğunlar halinde modellerimize beslenmemiştir. Bu yüzden çalışmalarımızda kullandığımız 3B U-Net modelinin yoğun normalizasyon katmanlarını grup normalizasyon [16] katmanlarıyla değiştirilmiştir. Grup normalizasyon katmanları ile daha küçük yoğun boyutları üzerinde yoğun normalizasyonun gücünden yararlanılabilir. Grup normalizasyon yaparken evrişim filtrelerinin kaç gruba bölüneceği bilgisinin tanımlanması gereklidir. Bölünecek grup sayısı belirlerken FeTA2021 veri seti üzerinde, 2, 4, 8, 16 grup sayıları ile eğitimler gerçekleştirildik ve grup normalizasyonda 8 grup sayısı kullanılmasının diğer grup sayılarına göre daha başarılı sonuçlar verdieneni gözlemledik. Bu yüzden grup normalizasyon grup hiperparametresini 8 olarak belirledik.

**Tablo 1.** Üç farklı gestasyonel yaş grubuna bölünmüş veri setlerine ait yaş aralıkları ve veri seti örnek sayısı dağılımları.

	Gestasyonel Yaş	Eğitim	Validasyon	Test
Erken Haftalar Veri Seti	$20.0 \leq GY < 24.9$	18	3	3
Orta Haftalar Veri Seti	$24.9 \leq GY < 29.8$	25	6	6
Geç Haftalar Veri Seti	$29.8 \leq GY < 34.8$	11	3	3

GY: Gestasyonel yaş



**Şekil 2.** Fidon vd. tarafından iyileştirilmiş MR görüntülerinden sub-015'e ait arka plan piksel değerleri hatalı olan görüntü (a) ve arka plan piksel değerleri düzeltilmiş görüntü (b).

### 3 Bulgular ve tartışma

#### 3.1 Deneyler

Deneyleşimiz 11 GB NVIDIA GeForce GTX 1080 Ti ekran kartı üzerinde gerçekleştirilmiştir. Yaptığımız eğitimlerde donanım kısıtları sebebiyle her bir MR görüntüsü her epokta  $128 \times 128 \times 128$  boyutlarında, rastgele konumlarda, 8 parçaya bölünmüştür. Optimizasyon algoritması olarak Nesterov Momentum Stochastic Gradient Descent kullanılmıştır. Öğrenme hızı planlayıcısı olarak üçgen2 (triangular2) tipinde döngüsel öğrenme hızı planlayıcı kullanılmıştır [17] ve parametreleri, yukarı 3, aşağı 5, taban  $1e-05$  ve maksimum  $1e-02$  olarak tanımlanmıştır. Eğitimler 100 epok boyunca gerçekleştirilmiştir ve aşırı öğrenme durumunun engellenmesi için erken durdurucu (early stopping) kullanılmıştır. Erken durdurucu ile 10 epok boyunca validasyon kayıp (loss) değeri  $1e-03$  değerinden daha az düşüş eğilimi gösterirse modelin öğrenmeyi bıraktığı varsayılmıştır.

FeTA2021 veri seti Erken, Orta ve Geç Haftalar alt veri setlerine bölündüğü için her bir alt veri seti az miktarda örnek sayısı içermektedir. Bu yüzden segmentasyon performansının sınırlı kalabileceği göz önünde bulunduruldu ve önlem olarak aktarımı öğrenmeden yararlanıldı. Temel 3B U-Net modeli dHCP veri seti üzerinde eğitilip gestasyonel yaş gruplarına bölünmüş FeTA2021 alt veri setleri üzerinde eğitime hazır hale getirildi. Daha sonra her bir alt veri seti üzerinde, temel 3B U-Net modelini baz alan üç farklı 3B U-Net modeli eğitildi ve segmentasyon başarıları test edildi.

#### 3.2 Deney Sonuçları

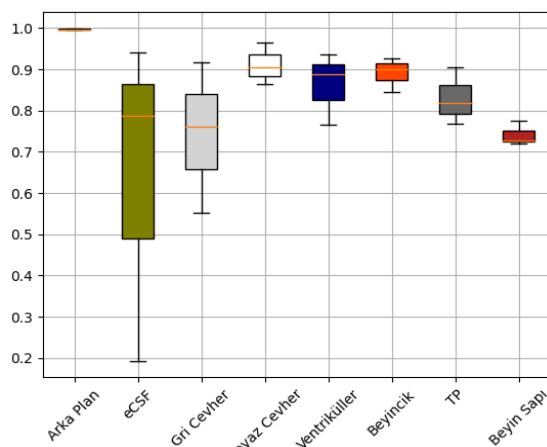
Gebeliğin erken dönemlerinde fetüs beyin dokuları yeni oluşmaya başladığı için bu haftalardaki dokuların ayırt edilebilirliği daha düşüktür ancak ilerleyen haftalarda beyin dokuları daha fazla belirginleşmeye başlar ve ayırt edilebilirliği artar. **Tablo 2**'de gestasyonel yaş gruplarına göre beyin dokusu başına elde edilmiş ortalama Dice skorları verilmiştir. **Şekil 4**'te Erken Haftalar Veri Seti, **Şekil 5**'te Orta Haftalar Veri Seti ve **Şekil 6**'da Geç Haftalar Veri Seti için elde edilen segmentasyon test sonuçlarına ait kutu grafikleri ve hata matrisleri verilmiştir. **Şekil 4, 5 ve 6**'daki grafikler incelendiğinde daha genç fetüslerin eCSF ve GM beyin dokularının segmentasyonunda yetişkin fetüs beyin dokularına göre daha düşük Dice skoru elde edildiği görülmektedir. **Şekil 4.a**'daki kutu büyük grafiği incelendiğinde eCSF ve GM sınıfı için ortanca değerin 0.79 ve 0.77 Dice skoru civarında olduğu görülmektedir. **Tablo 2**'deki Erken Haftalar veri setinde eCSF ve GM sınıfı için segmentasyon sonuçları incelendiğinde ise bu sınıflara ait ortalama Dice skoru değerlerinin daha düşük olduğu görülmektedir. Veri setlerinde sınırlı sayıda örnek bulunduğu da göz önüne alındığında, iyi segmente edilememiş bir görüntünün buna sebebiyet verdiği anlaşılmaktadır. **Şekil 4.b**'deki Erken Haftalar veri setine ait hata matrisi incelendiğinde, Erken Haftalar veri seti üzerinde eğitilen 3B U-Net modelinin, özellikle arka plan sınıfı ve eCSF sınıfına ait segmentasyon bölgelerini karıştırdığı görülmektedir. İyi oluşturulamayan eCSF sınıfı etiketleri ve

arka plan sınıfı ile eCSF sınıfı arasındaki belirsiz geçişler bu probleme sebebiyet vermiştir. **Şekil 5** ve **6**'daki kutu büyük grafikleri incelediğinde Geç Haftalar veri seti üzerinde eğitilen 3B U-Net modelinin daha başarılı segmentasyon performansı gösterdiği görülmektedir. Gebeliğin ilerleyen

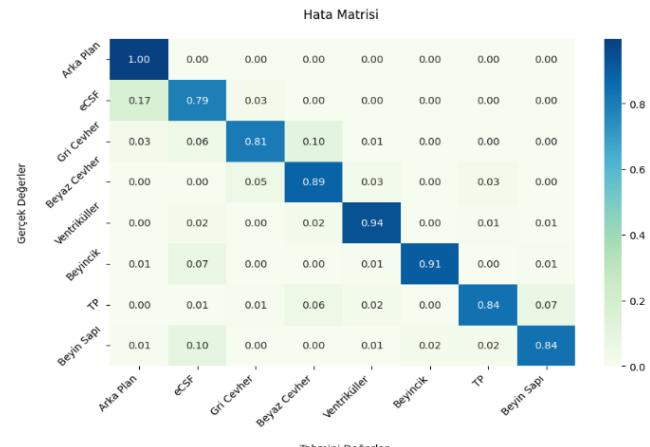
haftalarında olgunlaşan ve belirginleşen fetüs beyin dokularının segmentasyonunun daha başarılı bir şekilde gerçekleştirildiği gözlemlenmiştir

**Tablo 2.** Gestayonel yaş gruplarına göre bölünmüş veri setlerinden elde edilmiş ortalama Dice skorları.

	Arka plan	eCSF	GM	WM	Ventriküler	Beyincik	TP	Beyin sapi
Erken Haftalar veri seti	0.9965	0.6397	0.7434	0.9111	0.8621	0.8909	0.8295	0.7407
Orta Haftalar veri seti	0.9979	0.9175	0.8539	0.9480	0.9142	0.9265	0.8872	0.8578
Geç Haftalar veri seti	0.9976	0.9167	0.8455	0.9525	0.9160	0.9450	0.9233	0.8955

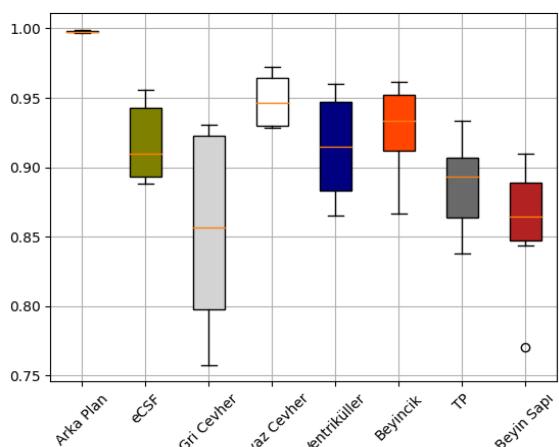


(a) Erken Haftalar Veri Seti Kutu Grafiği

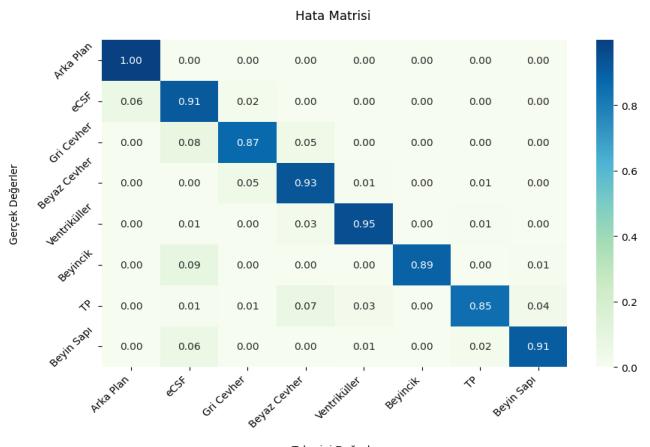


(b) Erken Haftalar Veri Seti Hata Matrisi

**Şekil 4.** Erken Haftalar Veri Setinde her bir doku için elde edilen Dice skorlarının kutu grafiği ve hata matrisi.

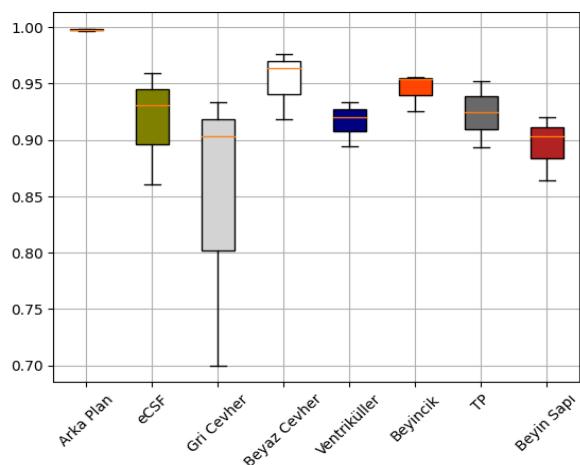


(a) Orta Haftalar Veri Seti Kutu Grafiği

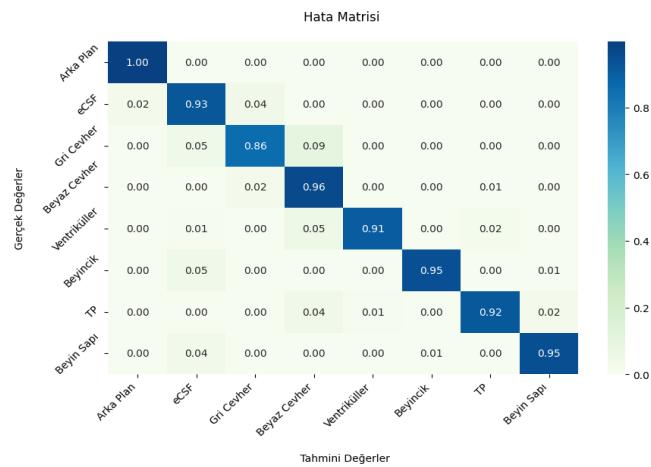


(b) Orta Haftalar Veri Seti Hata Matrisi

**Şekil 3.** Orta Haftalar Veri Setinde her bir doku için elde edilen Dice skorlarının kutu grafiği ve hata matrisi.



(a) Geç Haftalar Veri Seti Kutu Grafiği



(b) Geç Haftalar Veri Seti Hata Matrisi

Şekil 4. Geç Haftalar Veri Setinde her bir doku için elde edilen Dice skorlarının kutu grafiği ve hata matrisi.

#### 4 Sonuçlar

Bu çalışmada 3B U-Net modeli ile, başarılı bir şekilde, tam otomatik, fetüs beyin dokularının segmente edilebileceğini gösterdik ve gestasyonel yaşın segmentasyon performansına olan etkilerini analiz ettik. Yaptığımız bu çalışmada 20-35 haftalık fetüslerin beyinlerini 7 farklı sınıf için segmente edebilen farklı 3B U-Net modelleri geliştirdik. 3 farklı gestasyonel yaş grubuna böldüğümüz FeTA2021 veri seti üzerinde 3 farklı 3B U-Net modelini eğiterek performanslarını incelendik. Erken, Orta ve Geç gestasyonel yaşı grupları için, bütün dokular üzerinde, sırasıyla ortalama 0.83, 0.91 ve 0.92 Dice skorları elde ettik. Özellikle Erken Haftalar Veri Setindeki MR görüntülerinde eCSF ve GM dokularını tespit etmek dokuların belirsizliği yüzünden daha zorlayıcıydı. Ancak ileri haftalardaki dokuların segmentasyonu belirgin doku sınırlarından dolayı daha başarılı şekilde gerçekleştirilebildi. Ancak daha dayanıklı ve başarılı modellerin geliştirilebilmesi için daha fazla sayıda fetüs beyin MR görüntüsü örneğine ve etiketlerine ihtiyaç vardır. İlerleyen yıllarda örnek fetüs beyin MR görüntüsü veri setlerinin çoğalmasıyla, yaş farkı ve patolojik durum gözetmeksizin daha dayanıklı modellerin geliştirilebilmesinin önü açılacaktır.

#### Teşekkür

Bu çalışma finansal olarak; Erciyes Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü (BAP) tarafından (Proje No: FYL-2022-11744) desteklenmiştir.

#### Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

#### Benzerlik oranı: %6

#### Kaynaklar

- [1] S. L. Connors, P. Levitt, S. G. Matthews et al., Fetal mechanisms in neurodevelopmental disorders. *Pediatric Neurology*, 38, 3, 163–176, 2008. <https://doi.org/10.1016/j.pediatrneurol.2007.10.009>

- [2] A. Barry, B.M. Patten, B.H. Stewart., Possible factors in the development of the Arnold-Chiari malformation. *Journal of Neurosurgery*, 14, 3, 285–301, 1957. <https://doi.org/10.3171/jns.1957.14.3.0285>
- [3] N. E. Foster, K. A. Doyle-Thomas, A. Tryfon et al., Structural gray matter differences during childhood development in autism spectrum disorder: A multimetric approach. *Pediatric Neurology*, 53, 4, 350–359, 2015. <https://doi.org/10.1016/j.pediatrneurol.2015.06.013>
- [4] Ghai, S., Fong, K.W., Toi, A., Chitayat, D., Pantazi, S., Blaser, S., Prenatal US and MR imaging findings of lissencephaly: review of fetal cerebral sulcal development. *Radiographics*, 26, 2, 389–405, 2006. <https://doi.org/10.1148/rg.262055059>
- [5] K. Payette, P. de Dumast, H. Kebiri et al., An automatic multi-tissue human fetal brain segmentation benchmark using the fetal tissue annotation dataset. *Scientific Data*, 8, 1, 1–14, 2021. <https://doi.org/10.6084/m9.figshare.14039327>
- [6] L. Fidon, M. Aertsen, S. Shit et al., Partial supervision for the feta challenge 2021. arXiv preprint <https://doi.org/10.48550/arXiv.2111.024> 082111.02408, 2021
- [7] P. de Dumast, H. Kebiri, K. Payette, A. Jakab, H. Lajous and M. B. Cuadra, Synthetic magnetic resonance images for domain adaptation: Application to fetal brain tissue segmentation. 2022 IEEE 19th International Symposium on Biomedical Imaging (ISBI) IEEE, pp. 1–5, Kolkata, India, 2022. <https://doi.org/10.1109/ISBI52829.2022.9761451>
- [8] H. Lajous, C. W. Roy, T. Hilbert et al., A fetal brain magnetic resonance acquisition numerical phantom (fabian). *Scientific Reports*, 12, 1, 1–21, 2022. <https://doi.org/10.1038/s41598-022-10335-4>
- [9] D. Karimi, C. K. Rollins, C. Velasco-Annis, A. Oualam and A. Gholipour, Learning to segment fetal brain tissue from noisy annotations. *Medical Image*

- Analysis, 85, 102731, 2023.  
<https://doi.org/10.1016/j.media.2022.102731>
- [10] S. S. M. Salehi, S. R. Hashemi, C. Velasco-Annis et al., Real-time automatic fetal brain extraction in fetal mri by deep learning. 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018), pp. 720-724, Washington, DC, USA, 2018.  
<https://doi.org/10.1109/ISBI.2018.8363675>
- [11] S. Tourbier, X. Bresson, P. Hagmann, J. P. Thiran, R. Meuli, M.B. Cuadra, An efficient total variation algorithm for super-resolution in fetal brain MRI with adaptive regularization. Neuroimage, 118, 584-97, 2015.  
<https://doi.org/10.1016/j.neuroimage.2015.06.018>
- [12] M. Kuklisova-Murgasova, G. Quaghebeur, M.A. Rutherford, J.V. Hajnal, J.A. Schnabel, Reconstruction of fetal brain MRI with intensity matching and complete outlier removal. Medical Image Analysis, 16, 8, 1550-64, 2012.  
<https://doi.org/10.1016/j.media.2012.07.004>
- [13] L. Fidon, M. Aertsen, D. Emam et al., Label-set loss functions for partial supervision: Application to fetal brain 3d mri parcellation. International Conference on Medical Image Computing and Computer-Assisted Intervention Springer, pp. 647–657, Virtual Event, 2021. [https://doi.org/10.1007/978-3-030-87196-3\\_60](https://doi.org/10.1007/978-3-030-87196-3_60)
- [14] A. Makropoulos, E. C. Robinson, A. Schuh et al., The developing human connectome project: A minimal processing pipeline for neonatal cortical surface reconstruction. Neuroimage, 173, 88–112, 2018.  
<https://doi.org/10.1016/j.neuroimage.2018.01.054>
- [15] Ö. Çiçek, A. Abdulkadir, S.S. Lienkamp, T. Brox, O. Ronneberger, 3D U-Net: Learning dense volumetric segmentation from sparse annotation. Medical Image Computing and Computer-Assisted Intervention -- MICCAI 2016, pp. 424-432, Athens, Greece, 2016.  
[https://doi.org/10.1007/978-3-319-46723-8\\_49](https://doi.org/10.1007/978-3-319-46723-8_49)
- [16] Y. Wu, K. He, Group Normalization. Computer Vision - ECCV 2018, pp. 3-19, Munich, Germany, 2018. [https://doi.org/10.1007/978-3-030-01261-8\\_1](https://doi.org/10.1007/978-3-030-01261-8_1)
- [17] L.N. Smith, Cyclical learning rates for training neural networks. 2017 IEEE Winter Conference on Applications of Computer Vision (WACV), pp. 464-472, Santa Rosa, CA, USA, 2017.  
<https://doi.org/10.1109/WACV.2017.58>

