



Makale / Research Paper

U-Net Mimarisi ile Beyin Tümörü MRI Görüntülerinin Segmentasyonu

Süleyman UZUN^{1a}, Emin GÜNEY^{2a*}, Bünyamin BİNGÖL^{3b}

^{1,2}Sakarya Uygulamalı Bilimler Üniversitesi, Bilgisayar Mühendisliği Bölümü, Sakarya/ Türkiye

³Sakarya Uygulamalı Bilimler Üniversitesi, Elektrik ve Elektronik Mühendisliği Bölümü, Sakarya/ Türkiye
eminguney@subu.edu.tr

Received/Geliş:01.09.2022

Accepted/Kabul: 29.12.2022

Öz: Son yıllarda derin öğrenme yöntemlerinin gelişmesiyle birlikte, sağlık alanında görüntü işleme konusu oldukça önem kazanmıştır. Bu alanda yapılan en yaygın çalışmalardan birisi de kanserli beyin tümörlerinin hızlı ve doğru teşhis edilmesine yöneliktir. Beyin tümörleri başta çocuklar ve yaşlılar olmak üzere kanser hastalarının önde gelen ölüm nedenlerinden biridir. Özellikle son on yılda GPU hesaplama teknolojilerinin gelişmesi ve buna bağlı olarak derin öğrenme alanında yapılan çalışmaların artması da bu alana katkı sağlamıştır. Bu çalışmada MRI görüntüleri üzerinde 512x512 filtre boyutlarına sahip U-Net mimarisi kullanılarak beyin tümör hücrelerinin tespit edilmesini sağlayan bir sistem gerçekleştirilmiştir. Çalışmada literatürde sıkça kullanılan global veri setlerinden BRATS 2020 veri seti kullanılmıştır. Yapılan çalışma sonucunda güvenilirliği kabul edilebilen %91,38'lik bir dice skoru elde edilmiştir.

Anahtar Kelimeler: Beyin tümörü segmentasyonu; derin sinir ağları; görüntü işleme; U-net mimarisi.

Segmentation of Brain Tumor MRI Images with U-Net Architecture

Abstract: With the development of deep learning methods in recent years, image processing has gained importance in health. One of the most common studies in this field is the rapid and accurate diagnosis of cancerous brain tumors. Brain tumors are one of the leading causes of death in cancer patients, especially in children and the elderly. Especially in the last ten years, the development of GPU computing technologies and the increase in studies in deep learning also contributed to this field. In this study, a system that detects brain tumor cells by using U-Net architecture with 512x512 filter sizes on MRI images has been implemented. In the study, the BRATS 2020 dataset, one of the global datasets frequently used in the literature, was used. As a result of the survey, a dice score of 91.38% was obtained, which can be accepted as reliable.

Keywords: Brain tumor segmentation; deep neural networks; image processing; U-net architecture.

1. Giriş

Derin öğrenme yöntemleri son yıllarda görüntü sınıflandırma, nesne algılama ve anlamsal bölütleme gibi çeşitli uygulamalarda başarılı sonuçlar elde etmiştir. Bununla birlikte, sağlık alanında bilgisayarlı görmenin gelişmesi ve hesaplama gücünün artmasıyla beraber Manyetik Rezonans Görüntüleme (MRI) üzerinden beyin tümörü segmentasyon işlemleri sıklıkla uygulanmıştır. Beyin tümörleri ise kanser hastalarının özellikle de çocukların ve yaşlıların önde gelen ölüm nedenlerinden biridir [1]. Sağlık alanında tümörleri tespit etmek için kullanılan MRI görüntüleri, beyin ve kafatası yapılarının ayrıntılı özelliklerini görselleştirmek için nörolojide popüler olarak kullanılmaktadır [2]. Bu görüntüler farklı ışık yoğunluklarında beyin hücrelerinin yapısını segmente ederek görüntüleyebilmeye olanak sağlar. Hastaların kanser tanı süreçlerini hızlandıran ve doğru teşhise


Bu makaleye atıf yapmak için

Uzun, S., Güney, E., Bingöl, B., "U-Net Mimarisi ile Beyin Tümörü MRI Görüntülerinin Segmentasyonu" El-Cezeri Fen ve Mühendislik Dergisi 2022-, 9(4); 1583-1590.

How to cite this article

Uzun, S., Güney, E., Bingöl, B., "Segmentation of Brain Tumor MRI Images with U-Net Architecture" El-Cezeri Journal of Science and Engineering, 2022, 9(4); 1583-1590.

yardımcı olmayı amaçlayan bu uygulamalar için veri seti en önemli unsurdur. Literatürde bu amaçla kullanılan veri setleri incelendiğinde BRATS veri seti binlerce beyin tümörü için açık kaynaklı olarak sunulan MRI görüntüleriyle öne çıkmaktadır. Bu çalışmada da BRATS 2020 veri seti kullanılmış olup örnek beyin MRI görüntüleri Şekil 1’de gösterilmiştir. Derin öğrenme temelli yapılmış bazı çalışmalardan; Zeineldin ve arkadaşları [3] MRI verileri kullanarak beyin lezyonlarının tam otomatik tespit ve segmentasyonu için DeepSeg adını verdikleri yeni bir genel derin öğrenme mimarisi önermişlerdir. Geliştirilmiş U-Net mimarisine dayalı olarak ResNet, DenseNet ve NASNet gibi farklı Evrimsel Sinir Ağları (ESA) modellerini kullanarak performans karşılaştırması yapmışlardır.



Şekil 1. BRATS veri setinden örnek beyin tümörü MRI görüntüleri

Amin ve arkadaşları [4] beyin tümörlerinin segmentasyon ve sınıflandırılması için otomatik bir yöntem önermiştir. Yoğunluk, şekil ve doku dahil olmak üzere ilgilenilen bölge bölümlere ayrıldıktan sonra kanserli ve kanserli olmayan görüntülerin farklı aşamalarını sınıflandırmak amacıyla Destek Vektör Makinesi (DVM) farklı varyantlarda uygulanmıştır. Önerilen yöntem üç farklı veri setinde (Local, Harvard ve Rider) çapraz şekilde doğrulanmıştır. Sonuçlar, önerilen yaklaşımın tümör tespit prosedürünü hızlandırdığını göstermiştir.

Atban ve arkadaşları [5] yaptıkları çalışmada Alzheimer-MRI veri setini kullanarak geliştirdikleri iki farklı ESA modeli ve bir transfer öğrenme ağı olan AlexNet mimarisi ile beyin MRI görüntüleri üzerinden Alzheimer hastalığının teşhis ve düzeyinin sınıflandırılmasında %96,87’lik bir sınıflandırma başarımları elde etmişlerdir. Öte yandan Deepak ve arkadaşları [6] ise çeşitli beyin tümörlerini sınıflandırmak için transfer öğrenme ağını kullanmışlardır. Softmax düzeyinde farklı tümör sınıflandırma türleri için bazı değişikliklerle birlikte mevcut bir GoogleNet’i kullanmış ve çok sınıflı DVM ile %92,3’lük bir doğruluk seviyesini elde etmişlerdir.


Ito ve arkadaşları [7] ise MRI görüntülerinden beyin tümörü segmentasyonu için yarı denetimli bir öğrenme yöntemi önermişlerdir. Bu yöntemle mevcut kayıt tabanlı ve Derin Sinir Ağı (DSA) tabanlı yöntemlere göre daha iyi bir sonuç elde etmişlerdir. Modelin eğitilmesi için DSA modeli Beklenti-Maksimizasyon algoritması ile birleştirilmiş ve maksimizasyon durumunda, etiket gizli katmanda işlenerek önerilen yöntem iki farklı veri seti üzerinde doğrulanmıştır. Kebir ve arkadaşları [8] MRI görüntülerinden beyin tümörlerinin tespiti için otomatik ve denetimli bir MRI Beyin anomali algılama algoritması geliştirmişlerdir. K-Means algoritması ve ESA kullanan çalışma ham beyin MRI görüntüleri üzerinde %95’lik bir başarı oranına ulaşmıştır. Beyin tümörü segmentasyonu için ESA’nın doğruluğunu geliştirmek amacıyla Mittal ve arkadaşları [9] ise Durağan Dalgacık Dönüşümü (SWT) ve Büyüyen Evrimsel Sinir Ağı (BESA) hibridizasyonu için modeller önermişlerdir. SWT, ayrık veriler için Fourier dönüşümü yönteminden daha iyi sonuçlar veren özellik çıkarımında kullanılmaktadır. Öznitelik çıkarımından sonra, ayırım için Rastgele Ağaç Sınıflandırıcısı (RAS), modeli eğitmede ise BESA kullanılmıştır. Önerilen yöntem, geleneksel ESA’ya göre %2’lik bir

iyileştirme göstermiştir. Talo ve arkadaşları [10] ise beyin MRI görüntülerini sınıflandırmak için otomatik bir derin transfer öğrenme yöntemi önermiştir. Sınıflandırma için önceden eğitilmiş ResNet modeli kullanılarak veri seti genişletilmiştir. Önerilen yaklaşım Harvard Medical School MRI veri setinde %100 oranında bir doğruluk elde etmiştir. Başka bir çalışmada ise Niepceron ve arkadaşları [11] tıbbi görüntü analizi için sinir ağı optimizasyonu ve sıkıştırmasını kullanan çeşitli yöntemleri sınıflandırmış ve gömülü platform üzerinde test etmiştir. Modelin sıkıştırması, mevcut bir ESA mimarisine entegre edilerek hafif bir sinir ağı eğitimi ile geliştirme yapılmıştır. Böylelikle tıbbi görüntü analizi için öğrenme tabanlı uygulamalar bir bilgisayara bağlanmadan gömülü cihaz aracılığıyla gerçekleştirilebilmiştir. Zhang ve arkadaşları [12] tarafından sunulan yenilikçi bir çalışma ise çeşitli anizotropi görüntülerinden çoklu modalitelerin izointens faz segmentasyonu için DSA tercih edilmiştir. Sonuçlar dört farklı algoritma için ESA'nın üstün performansını kanıtlamıştır.

Bu çalışmada ise beyin tümörlerinin teşhisi için bilgisayar ortamında derin öğrenme yöntemlerinden 512x512 filtre boyutlarına sahip U-Net mimarisi kullanılarak otomatik segmentasyon sistemi tasarlanmıştır. Literatürdeki çalışmada kullanılan derin öğrenme yöntemlerinin farklı eğitim görüntüleri üzerinde eğitilerek model oluşturulmuştur. Çalışmadan elde edilen sonuçlar önerilen modelin literatürde kabul edilebilir bir başarıma ulaştığını göstermiştir.

2. Metodoloji

Ronneberger ve diğerleri [13] tarafından önerilen U-Net mimarisi, özellikle tıbbi görüntü segmentasyonu için geliştirilmiş bir ağ modelidir. Bir tür ESA yaklaşımı olan U-Net ilk olarak biyomedikal görüntüler üzerinde bölütleme (segmentasyon) yapma önerisinde bulunmuşlardır. Önerilen mimari iki yola sahip olup mimarinin kodlayıcı ve kod çözücü olmak üzere iki ana bölümü vardır. İlk bölümde kodlayıcı görüntüdeki bağlamı yakalamak için kullanılan daraltma yoludur. İkinci bölümde ise kod çözücü denilen kesin lokalizasyonu sağlamak için simetrik olarak tasarlanmış ve transpoze konvolüsyonları kullanan yoldur.




Şekil 2. U-Net mimarisinin genel yapısı

U-Net mimarisi daha az veriyi kullanarak geleneksel makine öğrenmesi yöntemlerinden çok daha iyi bir performans göstermektedir. Yapısı basit, genişletilebilir ve yüksek kaliteli segmentasyon sonuçları üretmeye uygundur. Bu nedenle mimari uçtan uca tam evrişimli bir ESA olup yalnızca evrişim katmanları içermektedir. Farklı filtre boyutlarıyla çeşitli ağ tasarımları ile özellik çıkarım katmanında derin öğrenme ağ modelleri kullanılarak oluşturulmuş farklı hibrit yapıda U-Net mimarileri de bulunmaktadır. Bu çalışmada U-Net mimarisinin 512×512 'lik görüntü segmentasyonu uygulanmış olup önerilen modelin genel mimarisi Şekil 2'de gösterilmiştir.


3. Deneysel Çalışma ve Sonuçlar

Beyin tümör hücrelerinin bilgisayar destekli otomatik segmentasyonu için derin öğrenme ağ modelini eğitmek, başarımlı sonuçlarını çıkarmak amacıyla literatürde sıklıkla kullanılan global veri setlerinden BRATS 2020 kullanılmıştır. BRATS 2020 veri seti içerisinde 369 hastadan alınan 2250 adet farklı MRI görüntüsünü içermektedir. Çalışmada kullanılan veri setinin U-Net modeli ile eğitimi ve eğitim sonuçlarının elde edilmesi amacıyla %80'i (1800 adet görüntü) eğitim ve eğitim sonuçlarının elde edilmesi amacıyla %20'si (450 adet görüntü) ise test aşamasında kullanılmak üzere veri seti ayrılmıştır. Eğitime başlamadan önce elde edilen veriler ile ön işleme çalışması yapılmıştır. MRI görüntüleri, flair ve segmented olmak üzere Şekil 3a'da görüldüğü gibi ham görüntü ve Şekil 3b'de ise tümör hücrelerini gösterecek şekilde iki adet sınıfa ayrılmıştır. Eğitim sürecinin başarılı olması amacıyla tümörlü görüntülerin çoğunlukta olduğu bir eğitim veri seti oluşturulmuştur. Bununla birlikte, diğer veriler ise eğitim başarımlını ölçmek amacıyla test veri setine dahil edilmiştir.




Şekil 3. BRATS 2020 veri setinden alınan MRI görüntü örnekleri, a) ham flair görüntüleri, b) segmented görüntüleri

Yapılan deneysel çalışma, Kaggle ortamında NVIDIA K80 GPU ve 16 GB RAM kullanılarak U-Net modeli için 50 epoch boyunca çalıştırılmış olup toplam eğitim süresi 35 dakika sürmüştür. Modelin performansının ölçülmesi için tahmin edilen segmente alanla veri setindeki mevcut segmente alan karşılaştırılarak doğruluk oranları çıkartılmıştır. Şekil 4a model tarafından elde edilen beyin tümörü segmentasyonu için parçalı görüntü örneklerini göstermektedir. Şekil 4b'de verilen görüntülerde ise sarı pikseller, bölümlere ayrılarak segmente edilmiş kanser hücrelerini temsil ederken mor pikseller ise arka planı temsil etmektedir. Son aşamada ise Şekil 4c'de kanser hücrelerinin MRI görüntüleri ile tespit edilen beyin tümör hücrelerinin birleştirilerek tek bir resimde görüntülenmesi sağlanmıştır.



Şekil 4. Beyin tümör segmentasyonu, a) Örnek MRI görüntüsü, b) mevcut segmentasyon ve tespit edilen kanserli hücre segmentasyon görüntüsü, c) mevcut segmentasyon görüntüsü ve tespit edilen kanserli hücre segmentasyonunun beyin üzerindeki görünümü



Şekil 5. Çalışmadan çıkartılan örnek segmentasyon görüntüleri a) Ham görüntü, b) Ödemli segment, c) Orjinal segment, d) Tam segment, e) Genişleyen segment, f) Nekroz segment

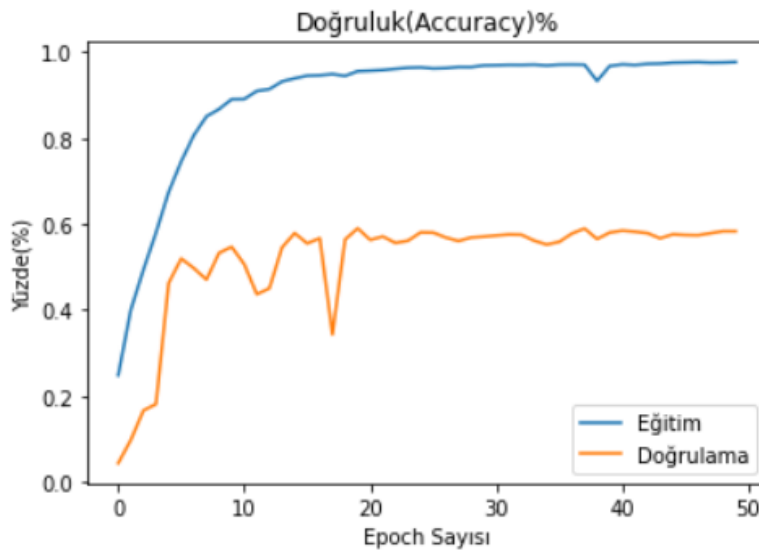
Beyindeki ödemler, tümör etrafında ortaya çıkan sıvı birikmesi olup MRI görüntülerinde net bir şekilde görülmekte olup tümörden ayrılması gerekmektedir. Şekil 5'te geliştirilen U-Net mimarisinin ödemli, ödemli ve nekroz MRI görüntülerini başarılı bir şekilde segmente edildiği açıkça görülmektedir. Eğitilen modelin test sonuçları Tablo 1'de ayrıntılı bir şekilde verilmiştir. Tablodan da görülebileceği gibi beyin tümörlerinin tespitinde önerilen sistem %91,38'lik bir dice skoruna ulaşmış ve %87,41'lik bir doğruluk oranında başarımlı sağlanmıştır. Benzer şekilde modelin kayıp

oranı 0,0862'lik bir orana düşürülmesi yeterli görülmüştür. Bununla beraber IoU parametresi beyin hücrelerindeki tümörün 0,8741 oranında bir doğrulukla bulunduğunu göstermektedir.

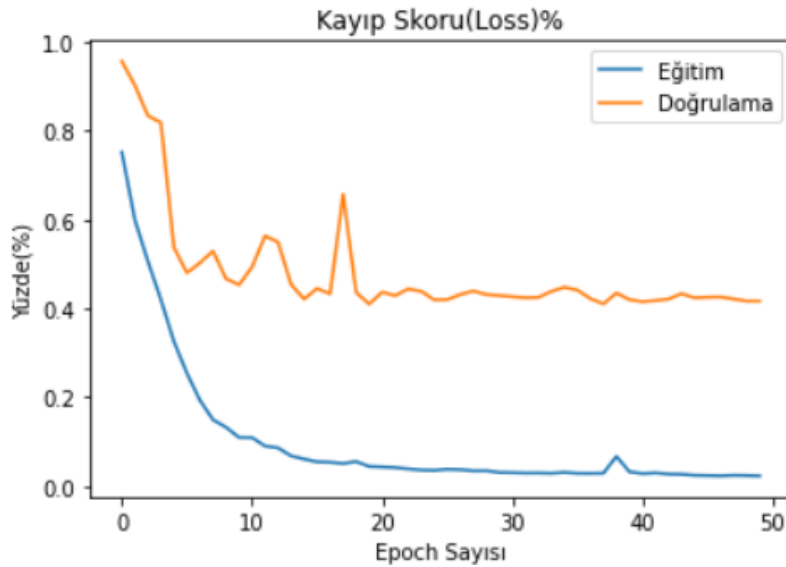
Tablo 1. Çeşitli parametrelerde başarımları sonuçları

Model	Kayıp Oranı	IoU	Dice Skoru	Doğruluk
U-Net	0,0862	0,8741	0,9138	87,41

Ayrıca, doğruluk ve kayıp skorları eğitim boyunca canlı olarak çizdirilerek başarımları izlenmiştir. Doğruluk ve kayıp skorları Şekil 6 ve Şekil 7'de gösterilmektedir. Şekilden eğitim başarımlarının sürekli arttığı ve kayıpların ise zamanla azaldığı gözlemlenmektedir.



Şekil 6. Beyin tümör segmentasyonu için önerilen U-Net mimarisinin doğruluk sonuçlarının gösterilmesi



Şekil 7. Uygulanan U-Net mimarisinin kayıp sonuçlarının gösterilmesi

Çalışmadan elde edilen sonuçların literatür ile karşılaştırılması Tablo 2'te verilmiştir. Karşılaştırılan çalışmalardan ilki Sobhaninia vd. [14] tarafından çalışılan LinkNet mimarisi tabanlı sistemdir. Zeineldin ve diğerleri [3] ise, beyin tümörlerini algılamak için derin segmentasyon (deepSeg) adını verdikleri mimariyi kullanmışlardır. Diğerleri ise Pinto vd. [15] tarafından sunulan Extra-Trees sınıflandırıcı tabanlı sistemdir. Literatürdeki diğer çalışmalara bakıldığında, sunulan çalışmada ödemli, ödemli ve nekroz sınıflı test görüntülerinden, üç sınıflı BRATS 2020 veri seti üzerinde gerçekleştirilen çalışma doğruluk diğerlerine göre %91,38 oranında bir başarı yüzdesi hesaplanmıştır.

Tablo 2. Beyin tümörü MRI segmentasyon sonuçlarının diğer çalışmalarla karşılaştırılması

Çalışmalar	Sobhaninia vd. [14]	Zeineldin vd. [3]	Pinto vd. [15]	Sunulan Çalışma
Dice skoru	79%	81%	83%	91.38%
Veri seti	Özgün veri seti	BRATS 2019	BRATS 2013	BRATS 2020

5. Sonuç ve Öneriler

Sağlık alanında kanserli hücrelerin tespit ve segmentasyonu için yapılan birçok çalışma bulunmaktadır. Segmentasyon modelleri, görüntülerdeki her pikseli bir sınıf etiketine eşleştirme işlemini ifade etmektedir. Bunun için görüntülerdeki sınıfları piksel bazında sınıflandırarak maske üretmektedir. Bu çalışma bilgisayar ortamında beyin tümörlerinin otomatik segmentasyonu için 512x512 filtre boyutlarına sahip U-Net mimarisi kullanan bir sistem önermektedir. U-Net görüntüleri hızlı ve hassas bir şekilde bölümlere ayırmak için kullanılan bir ESA mimarisidir. Çalışmada beyin tümörlerinin tespiti için literatürde sıklıkla kullanılan BRATS 2020 veri seti tercih edilmiştir. Eğitim sürecinden sonra oluşturulan model gerekli konfigürasyonlar yapılarak test ortamında analiz edilmiştir. Elde edilen sonuçlar, %91,38'lik bir dice skoru ile literatürde kabul edilebilir bir başarıyı göstermiştir.

Sonraki yapılacak çalışmalarda ise U-Net modeli üzerinde iyileştirme çalışmaları yapılarak elde edilen dice skorunun daha da artırılması hedeflenmektedir. Ayrıca, bu çalışmada oluşturulan sistemin mobilitesini arttırmak amacıyla gömülü sistem temelli taşınabilir ve gerçek zamanlı segmentasyon sistemleri tasarlanması hedeflenmektedir.

Teşekkür

2021-01-09-039 kodlu bu proje, Sakarya Uygulamalı Bilimler Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından desteklenmiştir. Bu çalışmanın ortaya çıkmasında verdiği destekten ötürü Bilimsel Araştırma Projeleri Birimine teşekkür ederiz.

Yazar(lar)ın Katkıları

SU, bilimsel yayın özetleri için literatür araştırması ve eğitim kısmında; EG, makalenin yazımında, bilimsel yayın araştırması ve metodolojinin tanımlanmasında ve oluşturulmasında; ve BB, algoritmaların kodlanmasında ve test kısmında yer almıştır. Her üç yazar da makalenin son halini okudu ve onayladı.

Çıkar Çatışması

Yazarlar, çıkar çatışması olmadığını beyan eder.

Kaynaklar

- [1]. McNeill, K. A. Epidemiology of Brain Tumors, *Neurologic Clinics*, 34(4), 981–998, 2016.
- [2]. Sazzad S., Hoque, M., Rahman M. ve Ahmmed T., Development of Automated Brain Tumor Identification Using MRI Images, 2019, 1-4.
- [3]. Zeineldin R. A., Karar M. E., Coburger J., Wirtz C. R. ve Burgert O., DeepSeg: deep neural network framework for automatic brain tumor segmentation resonance FLAIR images, *International Journal of Computer Assisted Radiology and Surgery*, 2020, 15(6).
- [4]. Amin J., Sharif M., Yasmin M. ve Fernandes S. L., A distinctive approach in tumor detection and classification using MRI, *Pattern Recognition Letters*, 2020, 118–127.
- [5]. Atban F. ve Ilhan H. O., MR görüntüleri üzerinden Alzheimer hastalığının tespiti için Evrişimli Sinir Ağ tasarımı ve performans kıyaslaması, in *ISMSIT 2021 - 5th International Symposium on Multidisciplinary Studies and Innovative Tech*, Proceedings, 2021, 473-477.
- [6]. Deepak S. and Ameer P. M., Brain tumor classification using deep CNN features via transfer learning, *Computers in Biology and Medicine*, 2019, 111(6).
- [7]. Ito R., Nakae K., Hata J., Okano H. Ve Ishii S., Semi-supervised deep learning of brain tissue segmentation, *Neural Networks*, 2019, 116(1), 25-34.
- [8]. Kebir S. T. ve Mekaoui S., An Efficient Methodology of Brain Abnormalities Detection using CNN Deep Learning Network, *Proceedings of the 2018 International Conference on Applied Smart Systems, ICASS 2018*, 2019, 1–5.
- [9]. Mittal M., Goyal L. M., Kaur S., Kaur I., Verma A. ve Hemanth D. J., Deep learning based enhanced tumor segmentation approach for MR brain images, *Applied Soft Computing Journal*, 2019, 78(1), 346–354.
- [10]. Talo M., Baloglu U. B., Yıldırım Ö. ve Acharya U. R., Application of deep transfer learning for automated brain abnormality classification using MR images, *Cognitive Systems Research*, 2019, 54(1), 176–188.
- [11]. Niepceron B., Nait-Sidi-Moh A. ve Grassia F., Moving Medical Image Analysis to GPU Embedded Systems: Application to Brain Tumor Segmentation, *Applied Artificial Intelligence*, 2020, 34(12), 1-14.
- [12]. Zhang W. et al., Deep convolutional neural networks for multi-modality isointense infant brain image segmentation, *NeuroImage*, 2015, 108(1), 214–224.
- [13]. Ronneberger O., Fischer P. ve Brox T., U-Net: Convolutional Networks for Biomedical Image Segmentation, 2015.
- [14]. Sobhaninia Z., Rezaei S., Noroozi A., Ahmadi M., vd., Brain tumor segmentation using deep learning by type specific sorting of images, *arXiv preprint*, 2018.
- [15]. Pinto A., Pereira S., Correia H., vd., Brain tumour segmentation based on extremely randomized forest with high-level features, In *2015 37th annual international conference of the IEEE engineering in medicine and biology society (EMBC)*, 2015.