



Contents lists available at *Dergipark*

## Journal of Scientific Reports-B

journal homepage: <https://dergipark.org.tr/en/pub/jsrb>



E-ISSN: 2717-8625

Sayı(Number) 8, Aralık(December) 2023

### ARAŞTIRMA MAKALESİ/RESEARCH ARTICLE

Geliş Tarihi(Receive Date): 15.11.2022

Kabul Tarihi(Accepted Date): 23.12.2022

## Beyin tümörü teşhisinde CNN-FL modeli ağ performansının aktivasyon fonksiyonlarına göre karşılaştırılması

Elif Ebru Çakı<sup>1\*</sup>, Tamer Aslan<sup>2</sup>

<sup>1</sup> Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Afyonkarahisar, ORCID: 0000-0002-2225-5675

<sup>2</sup> Afyon Kocatepe Üniversitesi, Afyon Meslek Yüksekokulu, Afyonkarahisar, ORCID: 0000-0003-3068-731X

### ÖZ

Beyin tümörü, hücre bölünmesinin kontrolden çıkarak hücrelerin büyüyerek kitle haline gelmesinden meydana gelmektedir. Kafatası içerisinde sınırlı bir alanda bulunan beyine baskı oluşturan tümör büyüdükçe kişinin beyinin görevlerini gerçekleştirmemesine neden olmaktadır. Her yaş grubunda meydana gelebilen ve oldukça riskli olan bu tümörün teşhisinin doğru olması kişinin hayat fonksiyonlarının da korunmasını sağlamaktadır. MR Çalışmanın nihai hedefi erken ve doğru teşhis ile kişinin yaşam fonksiyonlarına olduğu gibi devamını sağlamaktır. Hastalıkların doğru ve hızlı teşhisi için yapay zeka sistemleri kullanılmaktadır. Brain Tumor veri seti, CNN mimarisini temel alan ancak daha başarılı sonuçlar verebilen CNN-FL mimarisi ile eğitilmiştir. Literatürde yaygın kullanılan 4 aktivasyon ile eğitimler gerçekleştirilerek karşılaştırılmaları yapılmıştır. Kullanılan aktivasyon fonksiyonları ReLU, Leaky ReLU, GELU ve Swish aktivasyon fonksiyonlarıdır. En yüksek %98 sınıflandırma başarısı GELU aktivasyon fonksiyonu ile elde edilmiştir. Çalışmamızın sonunda yapay zeka kullanımı ile gerçekleştirilen model MR görüntülerinden beyin tümörü teşhisine yardımcı bir araç olabileceğini göstermektedir.

*Anahtar kelimeler: CNN-FL, Beyin Tümörü, Yapay Zeka, Derin Öğrenme, Aktivasyon Fonksiyonları.*

## Comparison of CNN-FL model network performance according to activation functions in diagnosis of brain tumor

### ABSTRACT

A brain tumor occurs when cell division goes out of control and the cells grow into a mass. As the tumor grows, it puts pressure on the brain, which is located in a limited area within the skull, causing the person's brain not to perform its functions. The correct diagnosis of this tumor, which can occur in any age group and is quite risky, ensures that the person's life functions are protected. The ultimate goal of the MR Study is to ensure that the person's life functions continue as they are with early and accurate diagnosis. Artificial intelligence systems are used for accurate and rapid diagnosis of diseases. Brain Tumor dataset is

trained with CNN-FL architecture, which is based on CNN architecture but can provide more successful results. Trainings were carried out with 4 activations commonly used in the literature and their comparisons were made. The activation functions used are ReLU, Leaky ReLU, GELU and Swish activation functions. The highest 98% classification success was achieved using the GELU activation function. At the end of our study, we show that this artificial intelligence based model can be a helpful tool for brain tumor diagnosis from MR images.

*Keywords: CNN-FL, Brain Tumor, Artificial Intelligence, Deep Learning, Activation Functions.*

*Corresponding Authors:*

*e-mail: elifebrucaki@gmail.com*

© 2023 DPU All rights reserved.

## 1. Giriş

Beyin tümörü, beyinde bulunan hücrelerin yenilenmesi esnasında hücrelerin büyümesi ve büyüyen hücrelerin kitle haline gelerek beyinde yer edinmesi ile tümörler oluşmaktadır. Her yaş grubunda oluşabilen bu tümörler kafatasında basınca neden olmaktadır. Baskıdan etkilenen beyin görevini yerine getirememektedir. Tümörün erken teşhisi tedavi sürecini hızlandırmakta ve tedaviyi kolaylaştırmaktadır. Tümörün kafatası gibi sınırlı bir alanda büyümesi de erken teşhisi önemli kılmaktadır [1].

Günümüzde görüntü işleme teknolojisi ve yapay zeka tabanlı yöntemlerin tıp alanında da oldukça yaygınlaşması ile MR görüntülerinden tümör tespiti çalışmaları yapılmaktadır. Bazı çalışmalarda sınıflandırma için öznelik çıkarma algoritmaları kullanılırken bazı çalışmalarda ise öznelik çıkarımının yanı sıra sınıflandırma için derin öğrenme yöntemleri kullanılmaktadır.

Prema ve arkadaşları [2] tarafından 2016 yılında yapılan bir çalışmada Otsu algoritması kullanılarak tümörün tespit edilmesine yönelik bir çalışma gerçekleştirilmiştir. Otsu ve Watershed yöntemleri CT(Computed Tomography) görüntülerine uygulanmıştır. Hastalığın tümörlü ve sağlıklı beyin olarak sınıflandırılmasında görüntü işleme yöntemleri kullanılmıştır. Beyin kitle segmentasyonu ve özellik çıkarıma işlemi gerçekleştirilmiştir.


Havaei ve arkadaşları [3] tarafından 2017 yılında yapılan bir başka çalışmada ise derin sinir ağları (DNN, Deep Neural Networks) kullanılmaktadır. Çalışma özgün ve yeni mimari ile gerçekleştirilmekte ve kullanılan 2013 BRATS üzerinde de başarı ile sonuçlanmıştır. Tümörün şekli, boyutu ve görüntü özelliklerinin baz alınmadığı yöntem önerilmekte ve otomatik bir yöntem geliştirdiklerini belirtmektedirler.

Çalışmamızda beyin tümörü teşhisinde MR görüntüleri üzerinden erken teşhis için tanı karar sürecinin en aza indirilerek hastalığın doğru tanısı hedeflenmektedir. Hedeflenen doğru teşhis için CNN-FL mimarisi ile farklı aktivasyon fonksiyonları karşılaştırılmaktadır.

## 2. Materyal Ve Method

### 2.1. Brain Tumor Veriseti

Bu çalışmada farklı boyut ve açılardan elde edilmiş 2.513 tane tümörlü beyin MR görüntüsü ve 2.087 tane sağlıklı beyin MR görüntüsü kullanılmaktadır. Şekil 1'de verisetinde bulunan örnek sağlıklı ve tümörlü beyin MR görüntüsü verilmiştir.

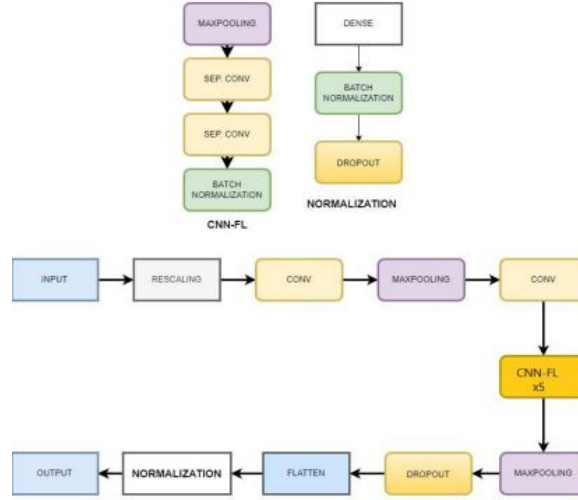


Şekil 1. Sağlıklı ve tümörlü beyin MR görüntüsü.

## 2.2. CNN-FL

CNN-FL (Convolutional Neural Networks- Federated Learning) başarısız ağ çıktılarının başarısızlığı ile ilişkisini öğrenerek tahmin için bir model oluşturmaktadır. Modelin oluşumunda evrişimli sinir ağını temel almaktadır [4]. Mimaride 10 adet evrişim katmanı mevcuttur. İki adet standart evrişim katmanının ardından ayrılabilir evrişim katmanları kullanılmaktadır. Eğitim için az veriye ihtiyaç duymasından dolayı ayrılabilir (Separable) evrişim kullanılmaktadır. Ayrılabilir evrişim öğrenmeyi iki adıma ayırarak çalışmaktadır. CNN-FL mimarisinde ise 8 katmanda yer almakta sonrasında ise havuzlama katmanı ile devam etmektedir [5]. Mimari modeli Şekil 2’de verilmektedir.


CNN-FL hata için evrişimli bir sinir ağı oluşturur ve ağı test durumlarıyla eğitir. Son olarak sanal bir test seti kullanarak eğitilen modeli test ederek her bir ifadenin şüpheliliğini değerlendirir. Çalışmamızdaki veri setinin sanal veri seti ile de test edilmesi ile doğru tanı oranının artması hedeflenmektedir.



Şekil 2. CNN-FL mimarisi [5].


Çalışmada MR görüntülerinin sınıflandırılarak tümörün tanımlanmasında CNN-FL mimarisi kullanılmıştır. Model 32 batch size, 0.01 öğrenme hızı, 10 epoch ile eğitim gerçekleştirilmiştir. Çalışmamızda evrişim katmanlarındaki aktivasyon fonksiyonları değiştirilmiştir. ReLU, Leaky ReLU, GELU ve Swish aktivasyon fonksiyonları kullanılarak analiz gerçekleştirilmiştir. Bu fonksiyonların karşılaştırılması yapılarak başarıları analiz edilmiştir. Analizlere ait grafikler verilmiştir.

Aktivasyon fonksiyonları, nöron içerisindeki değerlerin normalleştirilmesinde kullanılmaktadır. ReLU (Rectified Linear Unit) aktivasyon fonksiyonu en çok kullanılan aktivasyon fonksiyonlarından biridir. Bir diğer adı ile doğrutulmuş lineer birim fonksiyonudur. Bu fonksiyon nöron çıkışı 0'dan büyük olduğunda çıkış değerine, küçük olduğunda ise çıkışı 0'a eşitlemektedir [6]. Koordinat sisteminde gösterimi Şekil 3'de verilmiştir. Fonksiyonun matematiksel formülü Eş. 1'de aşağıda verilmektedir. Şekil 4 ve Şekil 5'de eğitimin başarı ve kayıp grafikleri yer almaktadır.




Şekil 3. ReLU aktivasyon fonksiyon grafiği [7].

$$ReLU(x) = \max(0, x) = \begin{cases} x, & \text{if } x > 0 \text{ (active state)} \\ 0, & \text{if } x \leq 0 \text{ (inactive state)} \end{cases} \quad (1)$$




Şekil 4. ReLU accuracy (Doğruluk) grafiği.



Şekil 5. ReLU loss (Kayıp) grafiği.


Leaky ReLU, sızdırılan veya sızdıran ReLU olarak da bilinmektedir. Eksi sonsuza kadar giden bu aktivasyon fonksiyonu negatif değerlerin öğrenilmesinde kullanılmaktadır [8]. Koordinat sisteminde gösterimi Şekil 6 'de verilmiştir. Fonksiyonun matematiksel formülü Eş. 2'de de aşağıda verilmektedir. Şekil 7 ve Şekil 8'de eğitimin başarı ve kayıp grafikleri verilmiştir.

## Leaky ReLU




Şekil 6. Leaky ReLU aktivasyon fonksiyon grafiği[7].

$$Leaky ReLU(x) = \max(kx, x) = \begin{cases} x, & \text{if } x > 0 \\ kx, & \text{if } x \leq 0 \end{cases} \quad (2)$$




Şekil 7. Leaky ReLU accuracy (Doğruluk) grafiği.




Şekil 8. Leaky ReLU loss (Kayıp) grafiği.

Yüksek performansı ile kullanılan GELU aktivasyon fonksiyonu gauss hatasının doğrusal birimi olarak bilinmektedir. ReLU aktivasyon fonksiyonundan gelen özellikleri birleştirerek işler [9]. Koordinat sisteminde gösterimi Şekil 9’da verilmiştir. Fonksiyonun matematiksel formülü Eş. 3’de aşağıda verilmektedir. Şekil 10 ve Şekil 11’de eğitim sonundaki accuracy (başarı) ve loss (kayıp) grafikleri verilmiştir.




Şekil 9. GELU aktivasyon fonksiyon grafiği[7].

$$GELU(x) = xP(X \leq x) = x\Phi(x) = x \cdot \frac{1}{2} \left[ 1 + \operatorname{erf}\left(\frac{x}{\sqrt{2}}\right) \right] \quad (3)$$



Şekil 10. GELU accuracy (Doğruluk) grafiği.




Şekil 11. GELU loss (Kayıp) grafiği.

Google tarafından geliştirilmiş olan ve zor veri setlerindeki çalışma başarısı ile bilinen Swish aktivasyon fonksiyonu görüntü işleme alanlarında oldukça iyi performans göstermektedir. Fonksiyonda  $x$  negatif sonsuza yaklaşırken  $y$  sabitlenir.  $x$  sonsuza yaklaştığında ise  $y$  de sonsuza yaklaşmaktadır. ReLU'da  $x=0$  anında anlık yön değişimi varken Swish aktivasyon fonksiyonunda bu yön değişimi bulunmamaktadır [10]. Koordinat sisteminde gösterimi Şekil 12'de verilmiştir. Fonksiyonun matematiksel formülü Eş. 4'de aşağıda verilmektedir. Şekil 13 ve Şekil 14'de eğitimin başarı ve kayıp grafikleri verilmiştir.




### Swish




Şekil 12. Swish aktivasyon fonksiyon grafiği [7].

$$f(x) = \frac{x}{1+e^{-x}}$$

(4)



Şekil 13. Swish accuracy (doğruluk) grafiği.



Şekil 14. Swish loss (kayıp) grafiği.

Çalışmamızda CNN-FL mimarisi farklı aktivasyon fonksiyonları ile test edilerek ağırlık eğitim başarıları ve eğitim kayıpları karşılaştırıldı. Literatürde yaygın kullanılan 4 aktivasyon fonksiyonları kullanılarak gerçekleştirilen eğitimlerin performans sonuçları sonuçlar kısmında yer alan Tablo 1, Tablo 2, Tablo 3, Tablo 4 ve Tablo 5 de verilmektedir.

### 3. Sonuçlar

Beyin tümörünün erken ve doğru teşhisi hayati fonksiyonların devamı için oldukça önem arz etmektedir. Çalışmamızda MR görüntülerinden tümörün teşhisini farklı aktivasyon fonksiyonları ve parametreleri kullanılarak gerçekleştirildi. Literatürde yeni yer edinen CNN-FL mimarisi ile eğitim gerçekleştirilmiştir. Tablo 1, Tablo 2, Tablo 3 ve Tablo 4'de kullanılan aktivasyon fonksiyonlarının tümörlü ve sağlıklı beyinin teşhisinde elde edilen başarı sonuçları verilmektedir. Tablolardaki sonuçlar çalışmamızda tümörlü ve sağlıklı olarak doğru sınıflandırmanın gerçekleştiğini göstermektedir.

Tablo 5'de aktivasyon fonksiyonlarının performans sonuçları verilmektedir. Eğitim sırasında yalnızca aktivasyon fonksiyonlarının değişimi ile sonuçlar elde edilmiş ve %98.2608 model başarıları GELU aktivasyon fonksiyonu ile elde edilmiştir.

Sonuç tablolarından da görüldüğü üzere CNN-FL modeli ile eğitimler sonucunda doğru tanı başarıları oldukça yüksektir.

Çizelge 1. ReLU aktivasyon fonksiyonunun teşhis başarıları.

	Kesinlik	Duyarlılık	F1-Score	Support
<b>Tümörlü</b>	0.96	0.99	0.98	779
<b>Sağlıklı</b>	0.98	0.95	0.97	601

Çizelge 2. Leaky ReLU aktivasyon fonksiyonunun teşhis başarıları.

	Kesinlik	Duyarlılık	F1-Score	Support
<b>Tümörlü</b>	0.98	0.99	0.98	779
<b>Sağlıklı</b>	0.98	0.98	0.98	601

**Çizelge 3.** GELU aktivasyon fonksiyonunun teşhis başarısı.

	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>F1-Score</b>	<b>Support</b>
<b>Tümörlü</b>	0.98	0.99	0.98	779
<b>Sağlıklı</b>	0.99	0.97	0.98	601

**Çizelge 4.** Swish aktivasyon fonksiyonunun teşhis başarısı.

	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>F1-Score</b>	<b>Support</b>
<b>Tümörlü</b>	0.97	0.98	0.98	779
<b>Sağlıklı</b>	0.98	0.97	0.97	601

**Çizelge 5.** Aktivasyon fonksiyonlarının model başarısı (%).

	<b>Doğruluk</b>
<b>ReLU</b>	97.2463
<b>Leaky ReLU</b>	98.1884
<b>GELU</b>	98.2608
<b>Swish</b>	97.6811

## **Teşekkür**

Yazarların teşekkür etmesi gereken herhangi bir kişi ya da kuruluş yoktur.

## **Kaynakça**

- [1] Bulut, F., Kiliç, İ., and İnce, İ. F. (2018), Beyin Tümörü Tespitinde Görüntü Bölütleme Yöntemlerine Ait Başarımların Karşılaştırılması ve Analizi, Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi, 20(58), 173-186.
- [2] Prema, V., Sivasubramanian, M., and Meenakshi, S. (2016), Brain cancer feature extraction using Otsu's thresholding segmentation. *Brain*, 6(3).
- [3] Havaei, M., Davy, A., Warde-Farley, D., Biard, A., Courville, A., Bengio, Y., ... and Larochelle, H., (2016), Brain Tumor Segmentation with Deep Neural Networks. Cornell University Library, arXiv preprint arXiv:1505.03540.
- [4] Zhang, Z., Lei, Y., Mao, X., and Li, P., (2019), CNN-FL: Evrişimli sinir ağlarını kullanarak hataların yerini tespit etmek için etkili bir yaklaşım, IEEE 26th International Conference on Software Analysis, Evolution and Reengineering (SANER), 445-455.
- [5] Çaki, E. E., and Bayram, F., (2022), Cnn-F1 Modeli Ile Pnömoni Tespitinin Aktivasyon Fonksiyonlarına Göre Karşılaştırılması.
- [6] Ozkaya, U., Melgani, F., Bejiga, M. B., Seyfi, L., and Donelli, M. (2020), GPR B scan image analysis with deep learning methods. *Measurement*, 165, 107770.
- [7] The AI website. [Online], (2022), Available: <https://www.v7labs.com/blog/neural-networks-activation-functions>
- [8] Xu, J., Li, Z., Du, B., Zhang, M., & Liu, J. (2020, July). Reluplex made more practical: Leaky ReLU. In 2020 IEEE Symposium on Computers and communications (ISCC), 1-7.

- [9] Hendrycks, D. and Gimpel, K. (2016). Gauss hata doğrusal birimleri (gelus). arXiv ön baskı arXiv:1606.08415 .
- [10] Ramachandran, P., Zoph, B. and Le, QV (2017). Aktivasyon fonksiyonları arıyor. arXiv ön baskı arXiv:1710.05941 .