

## Sıgdırma & Uyarma Ağı ile Farklı CNN Mimarilerinin Beyin Tümörü Sınıflandırması

İsa Ataş<sup>1\*</sup>, Bashar Alhajahmad<sup>2</sup> ve Musa Ataş<sup>3</sup>

<sup>1</sup>Bilgisayar Teknolojileri / Diyarbakır Teknik Bilimler MYO, Dicle Üniversitesi, Türkiye

<sup>2</sup>Bilgisayar Mühendisliği / Mühendislik Fakültesi, Siirt Üniversitesi, Türkiye

<sup>3</sup>Bilgisayar Mühendisliği / Mühendislik Fakültesi, Siirt Üniversitesi, Türkiye

\*(isa\_atas@dicle.edu.tr)

**Özet** – Beyin tümörleri, tıbbi teşhis ve tedavi süreçlerinde kritik bir rol oynar ve erken tanı, hastaların yaşam kalitesini önemli ölçüde etkileyebilir. Bu nedenle, etkili bir beyin tümörü sınıflandırma yöntemi, hastalığın tanısının konulmasında ve tedavi stratejilerinin belirlenmesinde hayati bir öneme sahiptir. Dikkat mekanizması, bir modelin belirli özelliklere odaklanmasına ve önemli bölgelere daha fazla vurgu yapmasına yardımcı olan özel bir strateji olarak tanımlanabilir. Bu çalışmanın temel hedefi, ImageNet veri seti ile önceden eğitilmiş DenseNet121, EfficientNetB0 ve InceptionV3 Evrişimli Sinir Ağı (ESA) mimarilerini kullanarak dikkat mekanizmasının beyin tümörü sınıflandırma konusundaki etkinliğini incelemektir. Beyin tümör sınıflandırması için Kaggle beyin MR görüntülerinden yararlanılmıştır. Değerlendirme metrikleri olarak kayıp, doğruluk, kesinlik ve geri çağırma ölçütleri referans alınmıştır. Araştırma sonuçları, dikkat mekanizmasını içeren CNN mimarilerinin geleneksel CNN'lerden daha yüksek sınıflandırma doğruluğuna sahip olduğunu göstermektedir. Bu, beyin tümörlerinin daha hassas bir şekilde sınıflandırılmasını ve böylece daha iyi tedavi yöntemlerinin gelişimini sağlayabilir. Ayrıca dikkat mekanizmasının beyin tümörü sınıflandırma alanında nasıl kullanılabileceği konusunda önemli bir yol haritası sunabilir. Dikkat mekanizmaları, gelecekte yapılacak biyomedikal uygulamalı araştırmalarda daha fazla kullanım potansiyeli taşımaktadır. Sonuç olarak yapılacak olan bu çalışmalar, tıbbi teşhis ve tedavi alanındaki önemli bir ilerlemenin kapısını açabilir ve hastaların yaşam kalitesini artırarak sağlık sektöründe önemli bir katkı sağlayabilir.

**Anahtar Kelimeler** – DenseNet, Derin Öğrenme, EfficientNet, Evrişimli Sinir Ağları, Inception, Kanal Dikkat Modülü

### I. GİRİŞ

Beyin tümörleri, insan hayatı için ciddi bir tehdit oluşturmakta ve hastalık olarak yüksek ölüm nedenleri arasında görülmektedir [1]. Beyin tümör türünün erken evrede belirlenmesi hem hastanın yaşaması hem de hekimin tedavi stratejileri açısından hayati önem taşımaktadır. Beyin tümörü tanımlama ve tedavisi, tipik olarak beynin iç yapıları ve yumuşak dokuları hakkında ayrıntılı bilgi sağlayan, yüksek sinyal-gürültü oranına sahip hassas çözünürlüklü görüntüler üreten Manyetik Rezonans (MR) görüntülemenin kullanılmasını içerir [2], [3]. Biyomedikal alanda kullanılan MR görüntüleme, birçok bilim dalında olduğu gibi nörologların beyin tümörlerini tanımlamasında ve


teşhis etmesinde de önemli bir araç haline gelmiştir [4]. Günümüzde beyin tümörlerinin görülme sıklığı arttığından, MR beyin tümör görüntülerinin tanısı, hekimlerin çok fazla zaman ve emeğini almaktadır [5]. Bu problem teşhisin doğruluğunu ciddi şekilde etkilemekte ve daha sonraki tedavi için potansiyel risk oluşturmaktadır. Bilgisayar destekli sistemlerinin gelişmesi ile birlikte hekimlerin üzerindeki yük büyük ölçüde azalmıştır. Fakat her tümörün büyüme hızı, konumu, boyutu ve şekli gibi benzersiz özellikleri nedeniyle, tümör türlerinin sınıflandırılması, bilgisayar destekli teşhis sistemleri için halen önemli bir zorluk olmaya devam etmektedir.

Yapay zekâ teknolojisinde makine öğrenme ve derin öğrenme yöntemleri kullanılarak bu zorluğu çözmek için birçok uygulamalar yapılmıştır [6-9]. Derin öğrenme yöntemlerinden Evrişimli Sinir Ağları (ESA'lar), beyin tümörü sınıflandırması [10] dahil olmak üzere birçok biyomedikal görüntü analizinde uygulanmaktadır [11], [12], [13]. Bu çalışmada, beyin tümör sınıflandırması için çok fazla ön işleme gerek duyulmadan güçlü genelleme sağlayan, derin öğrenme modelleri ile kullanılan kanal bazlı Sığdırma ve Uyarma Ağı (SUA) modelini [14] referans aldık. SUA, belirli bir tümör görüntüsünün çoklu temsillerini alır, uçtan uca öğrenir ve tümörün ciddiyet düzeyini etkili bir şekilde tahmin eder. Önceden eğitilmiş modellerden gelen evrişim özelliği tanımlayıcıları ile tümör görüntülerini etkili bir şekilde tanımlar. SUA'nın sığdırma ve uyarma blokları, modelin tümör bölgelerine öncelik vermesine olanak tanırken görüntünün geri kalanına daha az vurgu yaparak modelde bir dikkat mekanizması görevini üstlenir.

## II. MATERYAL VE YÖNTEM

### A. Veri Kümesi ve Veri Ön İşleme


Bu çalışmada deneyler açık erişimli Kaggle Beyin MR görüntü veri seti [15] üzerinde gerçekleştirildi. Şekil 1'de beyin MR örnek görüntüler gösterilmiştir. Kullanılan veri seti farklı formlarını kapsayan 7022 beyin tümörü görüntüsünü içerir: glioma (1621 görüntü), meningioma (1645 görüntü), notumor (2000 görüntü) ve pituitary (1757 görüntü).



Şekil 1. Beyin MR görüntü örnekleri

ESA modelleriyle uyumluluğu sağlamak ve hesaplama yükünü azaltmak için, tüm MR görüntüleri  $512 \times 512$  pikselden  $128 \times 128$  piksele eşit şekilde ölçeklendirildi ve RGB üç kanallı formata dönüştürüldü, ardından veri seti bir eğitim seti ve bir test seti olarak 8:2 oranında bölündü. Ayrıca veri setini artırmak için rastgele yatay çevirme ve rastgele dikey çevirme gibi veri

önişlemeler gerçekleştirildi. Çoğaltılan beyin MR görüntüleri Şekil 2'de gösterilmiştir. Bu işlemler için Açık CEZERI Kütüphanesi (OCL) kullanıldı [16].

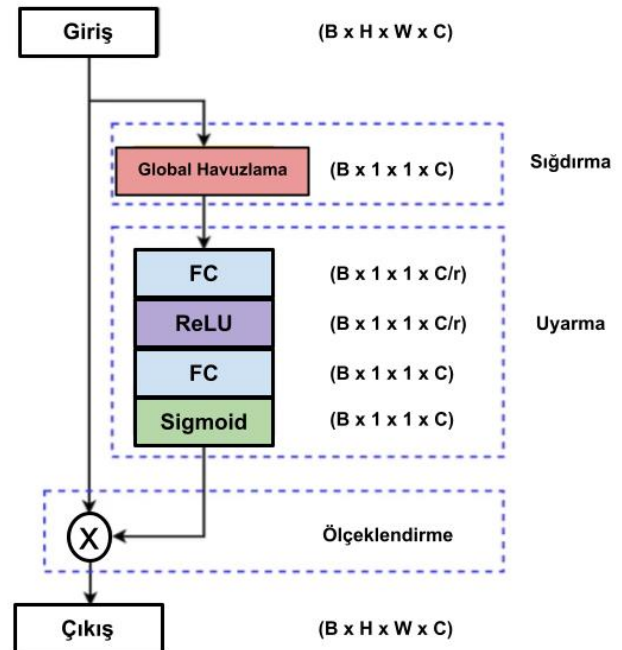


Şekil 2. Yatay ve dikey çevrilmiş MR örnek görüntüler

### B. Sığdırma ve Uyarma Ağı (SUA)

Sığdırma ve Uyarma Ağı, önemli özellikleri geliştirerek daha sağlam bir temsil oluşturmak için her kanalı uygun şekilde yeniden ayarlayan ve ağıın genel performansını artırmak için kullanılan kanal dikkat mekanizmasıdır.

SUA temel olarak ESA kanal bağımlılıklarını geliştirmek için kanal bazında yeni bir dikkat mekanizması sunar. Ağ, her kanalı uygun şekilde yeniden ağırlıklandırarak bir parametre ekler, böylece ilgisiz özellikleri göz ardı ederken önemli özelliklere karşı daha duyarlı hale gelir [14]. Şekil 3'de sığdırma ve uyarma ağı mimarisinin akış şeması gösterilmiştir.



Şekil 3. Sığdırma ve Uyarma Ağı (SUA)

Dikkat mekanizmalarından olan bu model iki temel aşamadan oluşur:

**Sığdırma:** İlk adımda, özellik haritasının (feature map) kanal düzlemindeki istatistiksel özetini hesaplar. Özellik haritalarının uzamsal boyutlarını tekil bir değere indirgemek için evrişimli sinir ağlarında kullanılan genel bir yöntem, havuzlamadır. Bu işlem, genellikle global ortalamalı havuzlama ile gerçekleştirilir ve her kanalın ne kadar önemli olduğunu belirlemeye yardımcı olur. Sığdırma aşamasında bir görüntü girilirken sinir ağı, her katmanın farklı boyutlarda bir özellik haritasını çıkaracaktır. Bunlar arasında özellik haritasının ortak matris şekli  $[H, W, C]$ 'dir. Model eğitilirken özellik haritasının matris şekli  $[B, H, W, C]$  olur. **B**, parti boyutunu, **H**, özellik haritasının yüksekliğini **W**, özellik haritasının genişliğini ve **C**, kanal sayısını belirtir [14].

**Uyarma:** Sığdırma aşamasından sonra, her kanal için ağırlıklandırma faktörleri (örneğin, sigmoid veya ReLU aktivasyon fonksiyonları kullanarak) hesaplanır. Giriş şekli  $(B \times 1 \times 1 \times C)$  şeklindedir. Yani giriş katmanında  $C$  nöronları bulunmaktadır. Gizli katman bunu bir azaltma faktörü  $r$  ile azaltır, böylece toplam  $C/r$  nöron sayısına yol açar. Son olarak çıktı, girdiyle aynı boyutlu uzaya yansıtılarak toplamda  $C$  nöronlarına geri döner. Bu ağırlıklandırma faktörleri, her kanalın özgün önemini yansıtır ve bu bilgiler özellik haritasının her bir noktasına uygulanarak özellik haritasının güncellenmesine yol açar. Bu, daha fazla öneme sahip özelliklerin daha fazla dikkat çekmesini sağlar [14].

### C. Evrişimli Sinir Ağları (ESA)

Bu çalışmada popüler bir görüntü sınıflandırma modellerinden DenseNet121, EfficientNetB0 ve InceptionV3 derin evrişimli sinir ağları kullanılmıştır. Bu modeller, geniş bir veri seti olan ImageNet veri seti üzerinde eğitilmiştir.


**DenseNet121:** DenseNet, yoğun bağlantılı bir yapı kullanarak derin ağları oluşturan bir evrişimli sinir ağı mimarisidir. DenseNet121, 121 katman içeren DenseNet'in bir varyasyonudur. Bu model, özellikle transfer öğrenme görevlerinde kullanılmak üzere popülerdir ve çok sayıda görüntü sınıflandırma görevinde iyi sonuçlar vermiştir [17].

**EfficientNetB0:** EfficientNet, evrişimli sinir ağı modellerinin hesaplama açısından daha verimli hale getirilmesi için özel bir strateji kullanır. EfficientNetB0, bu serinin temel modelidir ve Model, düşük hesaplama maliyeti ve yüksek doğruluk arayan uygulamalarda tercih edilir [18].

**InceptionV3:** Inception, Google tarafından geliştirilen bir evrişimli sinir ağı mimarisidir. Görsel tanıma görevlerinde iyi bir performans sergiler. İncelemesi daha geniş görüntü girişleri için tasarlanmıştır ve transfer öğrenme için kullanılır [19].

Bu modeller, önceden eğitilmiş ağırlıklarla kullanılabilirliği için çeşitli görüntü işleme görevlerinde ve transfer öğrenme uygulamalarında kullanılabilir. Özellikle bu modeller, yeni veri setleri üzerinde daha iyi sonuçlar elde etmek veya belirli görsel tanıma görevlerini hızlı bir şekilde çözmek için ince ayar yapmak için kullanışlıdır.

Şekil 4'te çalışmamızın özetini gösteren ESA+SUA modeli gösterilmiştir.



Şekil 4. ESA+SUA Modeli

### III. BULGULAR

Deneyler Python dilinde Google Colab bulut platformunda (Colab) Tesla K80 GPU – NVIDIA T4 GPU Kartı ile gerçekleştirildi. Yapılan deneylerde başlangıçta önceden eğitilmiş derin öğrenme modelleri kanal dikkat mekanizması kullanılmadan eğitim seti ile eğitilerek modelin performansı karşılaştırıldı. Daha sonra derin öğrenme modellerine kanal dikkat mekanizması dahil edilerek eğitim adımları tekrarlandı. Deney sonuçlarında elde edilen metrik değerler Tablo 1 ve Tablo 2 verilmiştir.


Tablo 1. ESA çıkış performans dağılımı

Model	Metrikler			
	Loss	Accuracy	Precision	Recall
DenseNet 121	0.052	0.988	0.987	0.988
EfficientNet B0	0.067	0.970	0.971	0.970
Inception V3	0.176	0.933	0.930	0.933

Tablo 2. ESA+SUA çıkış performans dağılımı


Model	Metrikler			
	Loss	Accuracy	Precision	Recall
DenseNet121	0.036	0.994	0.994	0.992
EfficientNetB0	0.047	0.984	0.984	0.984
InceptionV3	0.103	0.942	0.942	0.942

DenseNet121 modelinin kanal dikkat mekanizması ile birlikte elde edilen kayıp ve doğruluk grafiği Şekil 5’de gösterilmiştir.




Şekil 5. DenseNet121+SUA Modeli

EfficientNetB0 modelinin kanal dikkat mekanizması ile birlikte elde edilen kayıp ve doğruluk grafiği Şekil 6’da gösterilmiştir.



Şekil 6. EfficientNetB0+SUA Modeli


InceptionV3 modelinin kanal dikkat mekanizması ile birlikte elde edilen kayıp ve doğruluk grafiği Şekil 7’de gösterilmiştir.



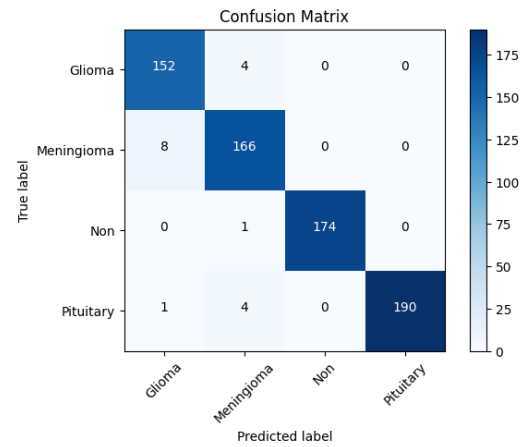
Şekil 7. InceptionV3+SUA Modeli

Bulunan sonuçlar analiz edildiğinde; model doğruluğu, kesinliği ve hatırlatma oranı en yüksek olan DenseNet121 modeli çıkmıştır. Aynı zamanda çalışmanın bir diğer ölçüt metriği olan karışıklık matrisi de analiz edilmiştir. DenseNet121+SUA


modeli hem doğruluk oranı olarak hem de karışıklık matris sonuçları yönünde diğer modellere göre daha yüksek çıkmasından dolayı bu çalışmada en başarılı model olarak söylenebilir. DenseNet121, EfficientNetB0 ve InceptionV3 mimarilerinin kanal dikkat mekanizması ile oluşturduğu modellerin karışıklık matrisleri sırasıyla; Şekil 8, Şekil 9 ve Şekil 10’da gösterilmiştir.



Şekil 8. DenseNet121+SUA Modelinin Karışıklık Matrisi



Şekil 9. EfficientNetB0+SUA Modelinin Karışıklık Matrisi



Şekil 10. InceptionV3+SUA Modelinin Karışıklık Matrisi

#### IV. SONUÇLAR

Sonuç olarak bu çalışmada hızlı eğitim süresine sahip InceptionV3, DenseNet121 ve EffientNetB0 derin öğrenme modelleri ile sığdırma ve uyarma ağ modeli birlikte kullanılarak; glioma, meningioma ve pituitary beyin tümörü tiplerinin sınıflandırılması yapılmış ve performansları karşılaştırılmıştır. Modellerden doğruluk, kesinlik ve geri çağırma oranı en yüksek olan DenseNet121 modeli başarılı olarak gözlemlenmiştir. Gelecek çalışmalarda, mevcut kullanılan üç model dışında başka modeller veya farklı bir dikkat mekanizması birleştirilerek yeni modeller çıkartılabilir. Oluşturulacak bu modeller ile beyin tümörü çeşitlerinin yanı sıra farklı hastalık tipine ait MR görüntüleri ile de sınıflandırma ve tespit çalışmaları yapılabilir.

#### KAYNAKLAR

- [1] A. Hossain et al., *A Lightweight Deep Learning-Based Microwave Brain Image Network Model for Brain Tumor Classification Using Reconstructed Microwave Brain (RMB) Images*, Biosensors, vol. 13, no. 2 H. 238, 2023.
- [2] Z. N. K. Swati et al., *Context-based brain tumor retrieval for MR images using transfer learning*, IEEE Access, vol. 7, p. 17809-17822, 2019.
- [3] F. Zulfiqar, UI Bajwa and Y. Mehmood, *Multi-class classification of brain tumor types from MR images using EfficientNets*, Biomedical Signal Processing and Control, vol. 84, p. 104777, 2023.
- [4] N. Chetih, Z. Messali, A. Serir and N. Ramou, *Robust fuzzy c - means clustering algorithm using non-parametric Bayesian estimation in wavelet transform domain for noisy MR brain image segmentation*, IET Image Processing, vol. 12, no. 5, p. 652-660, 2018.
- [5] J. Kakarla, BV Isunuri, KS Doppalapudi and KSR Bylapudi, *Three-class classification of brain magnetic resonance images using mean-pooling convolutional neural network*, International Journal of Imaging Systems and Technology, vol. 31, no. 3, p. 1731-1740, 2021.
- [6] A. Musa, *Fıstık sınıflandırma sistemi için Siirt fıstığı imgelerinden gürbüz özneliklerin çıkarılması*. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi 7.1 (2016): 93-102.
- [7] K. Cenk. *Modeling student behaviours in a virtual classroom with incorporation of social learning theory into belief-desire-intention model*. MS thesis. Middle East Technical University, 2015.
- [8] A. Musa, and T. Ayhan, *Development of automatic tree counting software from uav based aerial images with machine learning*. arXiv preprint arXiv:2201.02698 (2022).
- [9] A. İsa, *Comparison of deep convolution and least squares GANs for diabetic retinopathy image synthesis*. Neural Computing and Applications, 14431–14448, 2023. <https://doi.org/10.1007/s00521-023-08482-4>
- [10] H. Shi, X. Wu and X. Li, *Brain Tumor Classification Based on Multi-Level Attention*, 2023 IEEE 6th International Conference on Electronic Information and Communication Technology (ICEICT), Qingdao, China, 2023, pp. 264-269, doi: 10.1109/ICEICT57916.2023.10245579.
- [11] N. Abiwinanda, M. Hanif, S. T. Hesaputra, A. Handayani and T. R. Mengko, *Brain tumor classification using convolutional neural network*, in World Congress on Medical Physics and Biomedical Engineering, Prague, Czech Republic:Springer, pp. 183-189, June 2018.
- [12] R. L. Kumar, J. Kakarla, B. V. Isunuri and M. Singh, *Multi-class brain tumor classification using residual network and global average pooling*, Multimedia Tools and Applications, vol. 80, pp. 13429-13438, 2021.
- [13] J. D. Bodapati, S. N. Shareef, V. Naralasetti and N. B. Mundukur, *Msenet: Multi-modal squeeze-and-excitation network for brain tumor severity prediction*, International Journal of Pattern Recognition and Artificial Intelligence, vol. 35, no. 07, pp. 2157005, 2021.
- [14] J. Hu, L. Shen, S. Albanie, G. Sun and E. Wu, *Squeeze-and-Excitation Networks*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 42 (8), 2011–2023, arXiv:1709.01507, 2017.
- [15] M. Nickparvar, Brain Tumor MRI Dataset. Retrieved from Kaggle website: <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset/metadata> (2021).
- [16] A. Musa, *Open Cezeri Library: A novel Java based matrix and computer vision framework*. Computer Applications in Engineering Education, 24(5): 736-743. (2016). <https://doi.org/10.1002/cae.21745>
- [17] G. Huang, Z. Liu, L. van der Maaten, K.Q. Weinberger: *Densely Connected Convolutional Networks* (2018). <https://doi.org/10.48550/arXiv.1608.06993>
- [18] M. Tan, Q.V. Le, *EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks* (2020). <https://doi.org/10.48550/arXiv.1905.11946>
- [19] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, Z. Wojna, *Rethinking the Inception Architecture for Computer Vision* (2015). <https://doi.org/10.48550/arXiv.1512.00567>