

Gauss Filtreleme ve ResNET50 Modeli Kullanılarak Beyin Tümörlerinin Sınıflandırılması

Classification of Brain Tumors Using Gaussian Filtering and the ResNET50 Model

Çetin Erçelik¹ , Kazım Hanbay*¹ ,

¹Yazılım Mühendisliği Bölümü, İnönü Üniversitesi, Malatya, Türkiye
(kazim.hanbay@inonu.edu.tr, cetin.ercelik@inonu.edu.tr)

Received:Aug.18,2023

Accepted:Oct.17,2023

Published:Oct.18,2023

Özetçe— Beyin tümörleri, dünya genelinde önemli bir halk sağlığı sorunu olarak karşımıza çıkmaktadır. Beyin tümörünün erken teşhisi tedavi süreci için kritik bir öneme sahiptir. Son yıllarda, bilgisayar ortamında derin öğrenme modellerinin kullanımı, beyin tümörü teşhisi ve sınıflandırılmasında önemli bir ilerleme sağlamıştır. Bu modeller farklı görüntüleme modellerinden elde edilen verileri birleştirerek yüksek doğruluk oranları ve güvenilir sonuçlar sağlayabilir. Bu çalışmada beyin tümörlerinin sınıflandırılması için MR (manyetik rezonans) görüntüleri kullanılarak Resnet50 derin öğrenme mimarisi üzerinde çalışma gerçekleştirilmiştir. Beyin görüntülerindeki olumsuzlukları azaltmak için Gauss filtreleme işlemi uygulanmıştır. Böylece yüksek oranda doğruluk değerine ulaşarak hastalığın erken teşhisini sağlayıp yorucu ve zaman alıcı teşhis süreçlerini otomatikleştirilmesine katkı sunulmuştur. Bu sayede tümör teşhisleri daha hızlı ve daha tutarlı bir şekilde yapılabilir.

Anahtar Kelimeler : *Beyin tümörü, Derin Öğrenme Modelleri, Sınıflandırma, Resnet50*

Abstract— Brain tumors are an important public health problem worldwide. Early diagnosis of brain tumor is critical for the treatment process. In recent years, the use of deep learning models in the computer environment has made significant progress in brain tumor diagnosis and classification. These models can combine data from different imaging models, providing high accuracy and reliable results. In this study, a study was carried out on the Resnet50 deep learning architecture using MR (magnetic resonance) images for brain tumor classification. Gaussian filtering is applied to reduce the problems in the brain images. Thus, by achieving a high accuracy value, it provides early diagnosis of the disease and contributes to automating the tedious and time-consuming diagnostic processes. This way, tumor diagnoses can be made faster and more consistently.

Keywords : *Brain tumor, deep learning models, classification, Resnet50*

1. Giriş

Beyin tümörleri, dünya genelinde önemli bir sağlık sorunu olup, ciddi tıbbi müdahale gerektiren karmaşık ve yaşamı tehdit eden hastalıklardan biridir. Beyin tümörlerinin erken teşhisi ve doğru sınıflandırılması hastaların tedavi süreçlerinin yönetimi ve klinik sonuçların iyileştirilmesi açısından hayati bir öneme sahiptir. Gelişen tıp teknolojileri ve yapay zeka uygulamalarının ortaya çıkmasıyla birlikte, beyin tümörü teşhisi ve sınıflandırılmasında bilgisayar görmesi ve derin öğrenme modelleri gibi yenilikçi yöntemler dikkat çekmektedir.

Geethanjali ve diğerleri, İnsan beyni MR görüntülerini içeren veri seti kullanılarak beyin tümörü tespiti ve sınıflandırılması gerçekleştirilmektedir. Veriler, ön işleme ve veri artırma teknikleri ile işlenerek CNN modeline beslenir. Model tümörün varlığını tespit eder ve glioma, meningioma ve hipofiz tümörü gibi farklı kategorilere sınıflandırır. Bu çalışma, beyin tümörlerinin doğru ve hızlı bir şekilde teşhis edilmesine yardımcı olmayı hedeflemektedir (Geethanjali et al., 2023).

Kaya ve diğerleri, beyin tümörü tespiti için iki öneride bulunmaktadır. İlk olarak, derin öğrenme tabanlı yaklaşımların kullanımını vurgulamışlardır. İkinci olarak, son teknoloji nesne algılama çerçevesi olan YOLO ve derin öğrenme kütüphanesi FastAi'nin sınıflandırma için kullanılması önermektedirler. Çalışmalar 1.992 Beyin

MRI taraması içeren BRATS 2018 veri kümesi üzerinde yapılmıştır. YOLOv5 modeli %85.95 doğruluk elde ederken, FastAI sınıflandırma modeli %95.78 doğruluk sağlamıştır. Bu çalışma bu iki modelin gerçek zamanlı beyin tümörü tespitinde başarılı bir şekilde uygulanabileceğini göstermektedir (KAYA & ÖNAL, 2021).

Kartheeban ve diğerleri, Akıllı Derin Kalıntı Ağ tabanlı Beyin Tümörü Tespiti ve Sınıflandırması (IDRN-BTCC) yaklaşımını vurgulamaktadır. IDRN-BTCC modeli, tıbbi görüntülerde beyin tümörlerini tespit etmek ve sınıflandırmak için tasarlanmıştır. ResNet modeli, özellik çıkarıcı olarak kullanılırken, çok katmanlı algılayıcı (MLP) modülü sınıflandırma işleminde kullanılmaktadır. Yöntemin performansı deneysel bir doğrulama süreci ile değerlendirilmiş ve geliştirilmiş sonuçlar elde edilmiştir (Kartheeban et al., 2022).

Kabir, destek vektör makinesi (SVM) ve yapay sinir ağı temelli bir beyin tümörü tespit algoritması önermektedir. Algoritma, gradyan yoğunluğu yumuşatma tabanlı kenar koruma, görüntü geliştirme, DVM tabanlı segmentasyon, öznelik çıkarma ve sınıflandırmadan oluşmaktadır. BRATS veri seti üzerinde yapılan deneysel sonuçlar, önerilen algoritmanın %97.7 doğrulukla diğer algoritmalarından daha iyi performans gösterdiğini ortaya koymuştur (Kabir, 2020).

Bhanothu ve diğerleri, beyin tümörü tespiti için Faster R-CNN derin öğrenme algoritmasının kullanılmasını önermektedir. Algoritma, MRI görüntülerini değerlendirerek tümörleri tespit etmeyi amaçlamaktadır. Elde edilen sonuçlar, farklı tümör tipleri için ortalama %77.60 kesinlik elde edildiğini göstermektedir (Bhanothu et al., 2020).

Somaya ve diğerleri, beyin tümörü tiplerini sınıflandırmak için önerilen bir evrimsel sinir ağı mimarisi modeli incelemiştir. Ayrıca, mevcut birkaç nesne algılama yöntemi de performans açısından değerlendirilmiştir. Önerilen ağ yapısının genel olarak %96.05'lik yüksek bir doğruluk elde ettiği bulunmuştur. Bu sonuçlar, önerilen modelin beyin tümörlerini farklı amaçlar için sınıflandırma konusunda güçlü bir yeteneğe sahip olduğunu göstermektedir (El-Feshawy et al., 2021).

Poornam ve diğerleri, beyin tümörü tespiti için önerilen sistem, görüntü ön işleme, görüntü büyütme ve sinir ağı eğitimi adımlarını içermektedir. Eğitim için GoogleNet veri seti kullanılmış ve ResNet ile derin öğrenme modeli eğitilmiştir. Önerilen yöntem, beyin tümörü sınıflandırması için etkili sonuçlar elde edebilmektedir (Poornam & Alagarsamy, 2022).

2. Materyal ve Metotlar

Derin öğrenme yapay sinir ağlarından oluşan bir makine öğrenmesi alt alanıdır. Geleneksel makine öğrenme yöntemlerinden farklı olarak, derin öğrenme verilerdeki karmaşık kalıpları otomatik olarak öğrenerek görevleri gerçekleştirebilen çok katmanlı bir yapay sinir ağı mimarisi kullanır. Derin öğrenme, büyük veri setleri üzerinde eğitildiğinde, daha karmaşık ve yüksek düzeyde soyutlamalar yapabilen, daha yüksek performans elde edebilen ve insan benzeri kararlar alabilen modeller oluşturabilir.

Derin öğrenme modelleri, birbirinden farklı katmanlardan oluşur ve her katman veriyi işlemenin farklı yollarını temsil eder (Zhai & Qiao, 2020). Derin öğrenme modellerinde sıkça kullanılan bazı katmanlar ve açıklamaları şu şekildedir:

Giriş Katmanı: Giriş verilerini alır ve işlemenin başlangıç noktasını oluşturur. Veriler bu katmana beslenerek ağına girer.

Evrşim Katmanı (Convolutional Layer): Görüntü işleme gibi görsel veriler üzerinde etkili olan bu katman, evrşim operasyonlarını gerçekleştirir ve özellik haritaları oluşturur. Bu katman verilerin belirli özelliklerini vurgulamak ve algılamak için kullanılır.


Aktivasyon Katmanı: Evrşim katmanı çıktılarını non-linear bir şekilde aktive eder. Sigmoid, ReLU (Düzeltilmiş Doğrusal Birim) ve tanh gibi aktivasyon fonksiyonları bu katmanda kullanılabilir.

Havuzlama Katmanı (Pooling Layer): Özellik haritalarını örneklemek ve boyutlarını azaltmak için kullanılır. Max Pooling ve Average Pooling gibi yaygın havuzlama teknikleri vardır.

Tam Bağlantılı Katman (Fully Connected Layer): Evrşim katmanlarından elde edilen özellikleri düzleştirir ve çıktı katmanına yönlendirir. Sınıflandırma gibi görevler bu katmanda gerçekleştirilir.

Çıktı Katmanı: Modelin son çıktısını oluşturur ve çıktıları verilen görev için yorumlar. Sınıflandırma için softmax fonksiyonu, regresyon için doğrudan çıktılar kullanılabilir.

Bu katmanlar, birbirleriyle uyumlu bir şekilde birleştirilerek derin öğrenme modeli oluşturulur. Her katman verileri belirli bir şekilde işlemek ve özellikleri çıkarmak için tasarlanmıştır. Bu sayede model verilerdeki karmaşık ilişkileri ve kalıpları otomatik olarak öğrenerek istenilen görevleri gerçekleştirebilir.




Şekil 1: CNN Mimari Yapısı

2.1 Resnet50

Kaiming He ve diğerleri tarafından önerilen ResNet-50, derin öğrenme modellerinde bağlantıların ve artık bağlantıların kullanıldığı bir sinir ağıdır. Artık bağlantılar bir konvolüsyon ağının çıktısını sonraki evrişim katmanının girdisiyle birleştirir. Bu yapı derin ağların eğitimini kolaylaştırır ve özellik haritalarının daha iyi öğrenilmesine yardımcı olur (Kumar et al., 2022).

ResNet-50 toplam beş aşamadan oluşur. İlk aşamada 7x7 boyutunda 64 filtrelili bir evrişim katmanı ve ardından 2 adımlı 3x3 maksimum havuzlama katmanı bulunur. İkinci aşamada üç set halinde 1x1 filtrelili 64 kanallı, ardından 3x3 filtrelili 64 kanallı ve son olarak 1x1 filtrelili 256 kanallı evrişim katmanları yer alır. Sonraki aşamalarda, farklı sayılarda filtrelili evrişim katmanları tekrar edilir. Üçüncü aşamada 128 filtrelili 1x1 evrişim, ardından 128 filtrelili 3x3 evrişim ve son olarak 512 filtrelili 1x1 evrişim katmanları yer alır. Dördüncü aşamada ise 256 filtrelili 1x1 evrişim, ardından 256 filtrelili 3x3 evrişim ve son olarak 1024 filtrelili 1x1 evrişim katmanları yer alır.

Son aşamada modelin 1x1, 3x3 ve 1x1 boyutlarında sırasıyla 512, 512 ve 2048 filtrelili evrişim katmanları bulunur. Tüm evrişim aşamalarından sonra, bir maksimum havuzlama katmanı yer alır ve ardından 1000 nöronlu tam bağlantılı katmanlar kullanılarak sınıflandırma yapılır. ResNet-50, özellikle görüntü sınıflandırma görevlerinde yüksek performans gösterir.



Şekil 2: Resnet50 Modeli(KARADAĞ et al., 2021)


2.2 Önerilen Yöntem

Önerilen yöntem, beyin tümörü teşhisi ve sınıflandırma oranını artırmak için görüntüler üzerinde 3x3'lük bir Gaussian filtresi uygulayarak ResNet50 modeline daha optimal bir giriş verisi vermeyi amaçlamaktadır. Beyin tümörleri tıbbi görüntüleme verileri içinde zorlu bir sınıflandırma sorunudur ve düşük çözünürlüklü, gürültülü görüntüler doğru teşhis ve sınıflandırma süreçlerini zorlaştırabilir. Önerilen yöntemde görüntüler üzerine uygulanan 3x3'lük Gaussian filtresiyle önemli özelliklerin çıkarılması ve gürültünün azaltılması hedeflenmektedir. Bu filtreleme adımı, görüntülerin daha net ve belirgin hale gelmesini sağlamakla birlikte, modelin daha doğru ve güvenilir sonuçlar üretmesine katkı sağlayacaktır. Ayrıca temel ön işlem adımlarından olan Gaussian filtresinin sınıflandırma performansı üzerindeki etkileri gözlemlenmiştir.

ResNet50, başarılı bir derin öğrenme modeli olmasına rağmen, düşük kaliteli görüntülerle eğitildiğinde performansı düşebilmektedir. Bu nedenle, önerilen yöntemde görüntülerin önceden 3×3 'lük Gaussian filtresi ile işlenmesi, ResNet50 modelinin beyin tümörü teşhisi ve sınıflandırmasında daha yüksek doğruluk elde etmesi hedeflenmektedir. Öngörülen deneyler, önerilen modelin ResNet50'ye kıyasla daha iyi performans sergileyebileceğini ve beyin tümörlerinin teşhisinde etkili bir araç olacağını göstermektedir. Bu çalışma, tıbbi görüntüleme alanında veri ön işleme noktasında yeni bir yaklaşım sunarak beyin tümörlerinin tespit ve sınıflandırma süreçlerini daha kesin ve güvenilir hale getirmeyi hedeflemektedir.

Gaussian filtreler bir boyutlu veya iki boyutlu Gauss fonksiyonu kullanılarak tasarlanır. Gauss fonksiyonundaki varyans ve ortalama değeri ayarlanarak dağılımın ölçüsü ayarlanabilir. Bu değerler uygulanacak veri türüne göre deneysel olarak belirlenebilir. Bu filtrenin uygulanması ile beyin MR görüntülerinde özellikle gürültü bileşenlerinin kaldırılması amaçlanmıştır. Ayrıca tıbbi görüntülerde sıklıkla bulunan kontrast eksikliği durumunun en aza indirilmesi sağlanmıştır. Verideki bu iyileştirmeler ile derin öğrenme modelinin özellik çıkartma yeteneğine katkı sunulmuştur. Özellikle tümörlü bölge ile diğer sağlıklı beyin dokusu arasındaki ayırt edicilik artırılmıştır. Böylece ağdaki özellikle havuzlama işleminde karşılaşılan hassas ayırt edicilik yeteneğine katkı sunulmuştur. Yine veride manipülasyona yol açan gürültü piksellerinin baskılanması ve ağ katmanlarının arka plan/ön plan ayırım yeteneğini iyileştirilmiştir.

Sonuç olarak, 3×3 'lük Gaussian filtreli ResNet50 modeli, beyin tümörü teşhisi ve sınıflandırmasında doğruluk açısından önemli bir katkı sunmuştur. Önerilen modelin klinik uygulamalarda beyin tümörlerinin teşhis ve tedavi süreçlerine katkı sağlaması ve bu alandaki araştırmalara yeni bir perspektif sunması beklenmektedir.



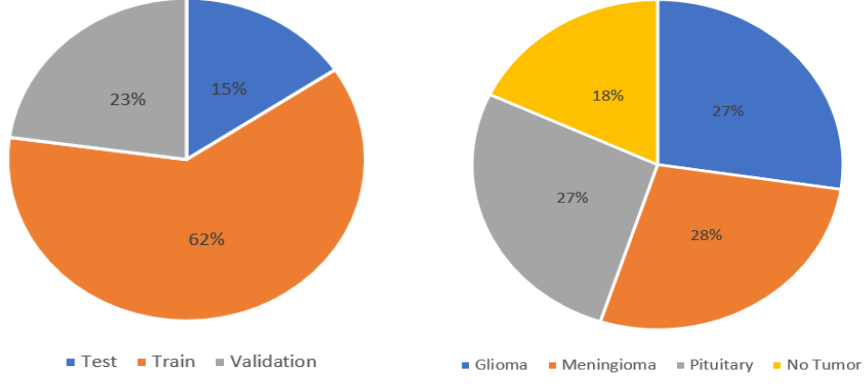
Şekil 3: Önerilen Yöntem Modeli

2.3 Veri Seti

Bu çalışmada beyin tümörlerinin teşhis ve sınıflandırmasında kullanılmak üzere özel olarak oluşturulan veri seti detaylı bir şekilde tanıtılmıştır. Kaggle platformundan alınan bu veri seti, beyin tümörü görüntülerini içermekte olup, toplamda dört ayrı tümör sınıfını temsil etmektedir (*Brain Tumor Mri Classification | Kaggle*, n.d.). Söz konusu sınıflar, glioma tümörü, meningioma tümörü, pituitary tümörü ve tümörsüz görüntülerden oluşmaktadır.

Veri seti doğru sonuçlar elde etmek için önemli bir ön işleme aşaması geçirilerek, test, doğrulama ve eğitim olmak üzere üç ana kısma ayrılmıştır. Test verileri modelin genel performansını değerlendirmek amacıyla toplam veri setinin %15.6'sını içermektedir. Doğrulama verileri modelin eğitim sürecinde hiperparametrelerin ayarlanması ve aşırı öğrenmeyi engellemek için %22.8'lik bir kısmı temsil etmektedir. Eğitim verileri ise derin öğrenme modelinin eğitimi için en büyük kısmı olan %61.6'ını içermektedir.

Bu çalışmada veri setinin detaylı bir analizi yapılarak, beyin tümörlerinin doğru teşhisi ve sınıflandırılmasında kullanılacak etkili bilgisayar destekli teşhis yöntemlerinin geliştirilmesine katkı sunulması hedeflenmiştir. Veri setinin sağladığı değerli bilgiler, gelecekteki tıbbi uygulamalar ve hastalara sunulacak daha iyi tedavi stratejilerinin geliştirilmesine önemli bir katkı sağlayacaktır.




Şekil 4: Veri Seti Dağılım Grafikleri

3. Deneysel Sonuçlar

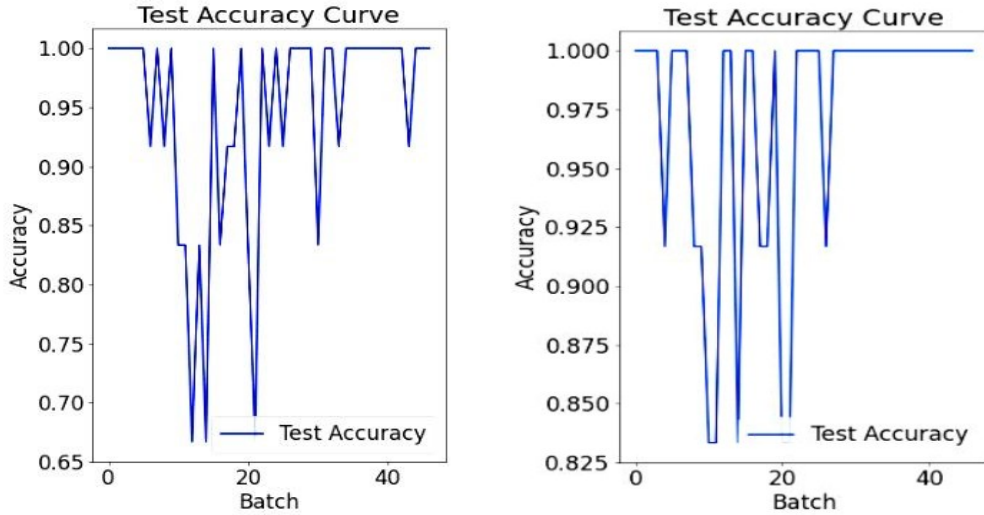
Bu çalışmada, beyin tümörü teşhisi ve tedavisi için iki farklı modelin performansı karşılaştırılmıştır: yalnız haldeki ResNet50 modeli ve önerilen model. Her iki model de aynı beyin tümörü veri seti üzerinde eğitilmiş ve doğruluk, F1 Skoru ve zaman metrikleri kullanılarak değerlendirilmiştir.

Elde edilen sonuçlar önerilen modelin doğruluk, F1 Skoru ve zaman metrikleri açısından yalnız haldeki ResNet50 modeline göre daha iyi performans sergilediğini göstermiştir. Önerilen modelin daha yüksek doğruluk ve F1 Skoru değerleri, beyin tümörü teşhisinde ve sınıflandırmasında daha başarılı olduğunu işaret etmektedir. Şekil 5'te yöntemlerin F1 skor değerleri verilmiştir.



Şekil 5: ResNet50 modeli (soldaki) ve önerilen yöntemin (sağdaki) iteratif olarak F1 skor değerleri

Gauss filtresi ile verilerin ön işlemden geçirilmesi, veri setinin daha iyi ayrıştırılmasını sağlamış ve önerilen modelin tümör sınıflarını daha hassas bir şekilde sınıflandırabilmesine katkıda bulunmuştur. Bu da önerilen modelin beyin tümörü teşhisi konusunda daha iyi bir ayırıcı güce sahip olduğunu ve daha doğru sonuçlar elde ettiğini göstermektedir. Şekil 6'da her iki modelin doğruluk sonuçları verilmiştir.



Şekil 6: Resnet50 modelinin (soldaki) ve önerilen yöntemin (sağdaki) doğruluk sonuçları

Bu çalışma önerilen modelin beyin tümörü teşhisi ve tedavisinde daha etkili bir araç olabileceğini ve klinik uygulamalarda daha yaygın olarak kullanılabilirliğini göstermektedir. Yüksek doğruluk ve F1 Skoru değerleri beyin tümörlerinin erken teşhisi ve uygun tedavi planlarının belirlenmesinde önemli bir rol oynayabileceğini vurgulamaktadır.

Tablo 1. Yöntemlerin sınıflandırma sonuçları

	Resnet50 (%)	Önerilen Yöntem (%)
F1 skor	0.8328	0.8515
Doğruluk	95.8929	97.1429
Zaman	5.8969s	5.3626s

4. Sonuçlar

Bu çalışmada ResNet50 modelinin beyin tümörü sınıflandırmasında başarısını arttırmak için verilere Gauss fonksiyonu ile ön işleme yapmanın katkısı irdelenmiştir. Gauss fonksiyonu ile tasarlanan iki boyutlu filtre ile giriş MR beyin görüntüleri filtrelenmiştir. Böylece görüntülerdeki gürültü bileşenleri temizlenmiştir. Yine kontrast eksikliği azaltılarak tümörlü bölge ile tümör içermeyen bölgelerin ayırt edilmesi sağlanmıştır. Önerilen metodoloji ile görüntü işlemede kullanılan ön işleme adımlarının önem ifade edilmeye çalışılmıştır.

Sonuç olarak Gauss ön işlemeli önerilen modelin yalın haldeki ve veri ön işleme içermeyen ResNet50 modeline göre daha iyi performans sergileyerek beyin tümörü teşhis ve tedavisinde etkili bir araç olarak kullanılabilmesi ortaya konulmuştur. Bu bulgular bilgisayar destekli teşhis sistemlerinin tıp alanında önemli bir rol oynayabileceğine ve beyin tümörü hastalarına daha iyi ve hızlı tedavi stratejileri sunmak için değerli bir katkı sağlayabileceğine dair umut vaat etmektedir.

Kaynaklar

- Anon. n.d. "Brain Tumor Mri Classification | Kaggle." Retrieved July 31, 2023 (<https://www.kaggle.com/datasets/mohammedhamdy98/brain-tumor-mri-classification>).
- Bhanothu, Yakub, Anandhanarayanan Kamalakannan, and Govindaraj Rajamanickam. 2020. "Detection and Classification of Brain Tumor in MRI Images Using Deep Convolutional Network." *2020 6th International Conference on Advanced Computing and Communication Systems, ICACCS 2020* 248–52. doi: 10.1109/ICACCS48705.2020.9074375.
- El-Feshawy, Somaya A., Waleed Saad, Mona Shokair, and Moawad Dessouky. 2021. "Brain Tumour Classification Based on Deep Convolutional Neural Networks." *ICEEM 2021 - 2nd IEEE International Conference on Electronic Engineering*. doi: 10.1109/ICEEM52022.2021.9480637.

- Geethanjali, N., V. Pushpalatha, C. Ramya, L. Sandhiya, and S. Subhashri. 2023. "Brain Tumor Detection and Classification Using Deep Learning." *Winter Summit on Smart Computing and Networks, WiSSCoN 2023*. doi: 10.1109/WISSCON56857.2023.10133851.
- Kabir, Md Ahasan. 2020. "Early Stage Brain Tumor Detection on MRI Image Using a Hybrid Technique." *2020 IEEE Region 10 Symposium, TENSYPMP 2020* 1828–31. doi: 10.1109/TENSYPMP50017.2020.9230635.
- KARADAĞ, Batuhan, Ali ARI, and Müge KARADAĞ. 2021. "Derin Öğrenme Modellerinin Sinirsel Stil Aktarımı Performanslarının Karşılaştırılması." *Politeknik Dergisi* 24(4):1611–22. doi: 10.2339/POLITEKNIK.885838.
- Kartheeban, K., Kapula Kalyani, Sai Krishna Bommavaram, Divya Rohatgi, Mathur Nadarajan Kathiravan, and S. Saravanan. 2022. "Intelligent Deep Residual Network Based Brain Tumor Detection and Classification." *International Conference on Automation, Computing and Renewable Systems, ICACRS 2022 - Proceedings* 785–90. doi: 10.1109/ICACRS55517.2022.10029146.
- KAYA, Buket, and Muhammed ÖNAL. 2021. "A CNN Based Method for Detecting Covid-19 from CT Images." *Bilgisayar Bilimleri (Special)*:1–10. doi: 10.53070/BBD.990793.
- Kumar, Raj, Dinesh Singh, Anuradha Chug, and Amit Prakash Singh. 2022. "Evaluation of Deep Learning Based Resnet-50 for Plant Disease Classification with Stability Analysis." *Proceedings - 2022 6th International Conference on Intelligent Computing and Control Systems, ICICCS 2022* 1280–87. doi: 10.1109/ICICCS53718.2022.9788207.
- Poornam, S., and Saravanan Alagarsamy. 2022. "Detection of Brain Tumor in MRI Images Using Deep Learning Method." *3rd International Conference on Electronics and Sustainable Communication Systems, ICESC 2022 - Proceedings* 855–59. doi: 10.1109/ICESC54411.2022.9885583.
- Zhai, Xiaodong, and Fei Qiao. 2020. "A Deep Learning Model with Adaptive Learning Rate for Fault Diagnosis." *Proceedings of 2020 IEEE 9th Data Driven Control and Learning Systems Conference, DDCLS 2020* 668–73. doi: 10.1109/DDCLS49620.2020.9275094.