

Beyin Tümörü Sınıflandırmada Histogram Eşitleme Yönteminin Bazı Derin Öğrenme Modellerine Etkileri

Effects of Histogram Equalization Method on Some Deep Learning Models in Brain Tumor Classification

Çetin Erçelik¹ , Kazım Hanbay^{*1} 

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

Received:Oct.10,2023

Accepted:Dec.1, 2023

Published:Dec.20, 2023

Özetçe— Beyin tümörü beyinde bulunan hücrelerin yenilenmesi sırasında oluşan hatalardan dolayı kafatası içerisinde anormal kitle büyümesinin genel adıdır. Beyin tümöründen hayatını kaybeden kişi sayısı gün geçtikçe artmaktadır. Kayıpları azaltmak için hastalığın tedavi planlamasında ve sonuç değerlendirilmesinde erken teşhis hayati bir önem taşımaktadır. Beyin tümör teşhisi için yaygın olarak kullanılan ve beyin içerisindeki dokuları gösteren MR (manyetik rezonans) görüntüleme yöntemi kullanılmaktadır. Geleneksel yöntemlerle MR görüntülerini kullanarak beyin tümörünü sınıflandırmak beyin yapısı ve içindeki dokuların karmaşık olmasından dolayı zordur. Beyin tümörü sınıflandırmasında son yıllarda popüler olan ve sınıflandırma konusunda yüksek doğruluk oranları yakalayan derin öğrenme mimarileri kullanılmaktadır. Bu çalışmada VGG16,VGG19 ve MobileNet derin öğrenme mimarileri karşılaştırılarak en yüksek doğruluk oranına sahip olan mimarinin belirlenmesi amaçlanmıştır. Bu mimarilerin başarısını artırmak için veri tabanındaki görüntülere histogram eşitleme işlemi uygulanmıştır. Kullanılan veri seti 3590 MR görüntüsünden oluşup dört beyin tümörü sınıfından (glioma, meningioma, tümörsüz, pituitary) oluşmaktadır. Yapılan test ve eğitim sonucunda en yüksek doğruluk MobileNet tarafından elde edilmiştir. Deneysel çalışmalar histogram eşitleme işleminin görüntülerin kalitesini iyileştirerek derin öğrenme mimarilerinin performanslarına olumlu katkılar sunduğunu göstermiştir.

Anahtar Kelimeler : *Beyin Tümörü, Görüntü Sınıflandırma, Derin öğrenme*

Abstract— Brain tumor is the general name for abnormal mass growth within the skull due to errors that occur during the renewal of cells in the brain. The number of people dying from brain tumors is increasing day by day. In order to reduce losses, early diagnosis is of vital importance in treatment planning and outcome evaluation of the disease. MRI (magnetic resonance) imaging method, which is widely used for brain tumor diagnosis and shows the tissues within the brain, is used. It is difficult to classify brain tumors using MRI images using traditional methods due to the complexity of the brain structure and the tissues within it. Deep learning architectures, which have become popular in recent years and achieve high accuracy rates in classification, are used in brain tumor classification. In this study, it was aimed to determine the architecture with the highest accuracy rate by comparing VGG16, VGG19 and MobileNet deep learning architectures. To increase the success of these architectures, histogram equalization process was applied to the images in the database. The data set used consists of 3590 MR images and consists of four brain tumor classes (glioma, meningioma, non-tumor, pituitary). As a result of the testing and training, the highest accuracy was obtained by MobileNet. Experimental studies have showed that histogram equalization makes positive contributions to the performance of deep learning architectures by improving the quality of images.

Keywords : *Brain Tumor, Image Classification, Deep learning.*

1. Giriş

Kanser vücuttaki hücrelerin kontrolsüz ve doğal olmayan bir yolla büyümesi ve bölünmesi olarak tanımlanabilir. Beyin dokusunda doğal olmayan bir yolla hücrelerin büyümesi ve bölünmesi sonucunda oluşan kitleye beyin tümörü denir (Işın, Direkkoğlu, and Şah 2016). Birincil ve ikincil olarak ayrılan beyin tümörleri hücrelerin yüksek derecede anormal olarak büyümesi ve bölünmesiyle merkezi sinir sistemine hasar verebilir veya işleyişini

bozabilir. Birincil beyin tümörü beynin dokularında yayılma göstermeyip iyi huylu olarak adlandırılırken ikincil beyin tümörü ise meme, akciğer veya vücudun diğer kısımlarındaki kanser hücrelerinin beyine yayılmasıyla oluşur ve kötü huyludur (Aslan et al. 2022). Beyin tümörleri dünya genelinde yaygın olup ciddi sağlık sorunlarına yol açabilirler. Dünyada kadın ve erkeklerde onuncu ve Türkiye de ise sekizinci sırada en yaygın ölüm nedenleri arasında yer almaktadır. Beyin tümörünün doğru bir şekilde segmente edilip sınıflandırılması teşhis ve tedavi için büyük bir öneme sahiptir. Tümörün tespiti için tıbbi görüntüleme teknikleri kullanılmaktadır. Tıbbi görüntüleme teknikleri arasında en yaygın olarak kullanılan yöntem MR (manyetik rezonans) görüntüleme yöntemidir. Bu yöntem beyin dokusunun iç yapısını yüksek çözünürlükte bize sunmaktadır (Polat 2022). MR yöntemi ile elde edilen veriler radyologlar ve hekimler tarafından yorumlanıp bir sonuca gidilmektedir. Ancak bu tür manuel olarak yapılan yorumlamalar gerek uzman kişilerin yoğunluğu, uzmandan uzmana değişen farklılıklar ve uzmanların yorgunluğu göz önüne alındığında elde edilen sonuçlarda hata payının oluşmasına neden olabilmektedir. Bu tür hataların minimize edilmesi için bilgisayar destekli uygulamaların kullanılması gerekmektedir. Beyin tümörünün segmente edilmesi ve sınıflandırılması karmaşık ve zor bir işlem olduğundan dolayı geleneksel makine öğrenmesi yöntemleri yetersiz kalabilmektedir. Yüksek seviyede işlemci ve donanımların gelişmesiyle medikal ve beyin tümörü alanında hastalıkların erken teşhisi ve sınıflandırması için derin öğrenme yöntemleri daha sık kullanılmaktadır (Gül Eker et al. 2021). Tıbbi görüntüleme alanı medikal görüntülerin tespit ve doğru sınıflandırılması için son on yılda derin öğrenme mimarilerinde büyük bir mesafe kaydetmiştir (Siddique et al. 2021).

2. İlgili Çalışmalar

Makine öğrenmesi ve derin öğrenme mimarileri sayesinde beyin tümörü gibi sağlık alanında devrim yaratacak akıllı ve otomatik çalışmalar yoğun şekilde geliştirilmiştir. Özellikle beyin tümörlerinin tanınması, sınıflandırılması ve MR görüntülerinin segmentasyonu ile ilgili derin öğrenme algoritmaları kullanılarak birçok çalışma yapılmıştır.

Zylfiqar ve diğ. glioma, meningioma ve hipofiz tümörü gibi beyin tümörlerinin üç sınıfta sınıflandırılması için transfer öğrenmesine dayalı bir EfficientNet yaklaşımı geliştirmişlerdir. EfficientNet modelinin önceden eğitilmiş beş farklı modeli kullanılarak Figshare – beyin tümörü veri tabanı üzerinde çalışma yapılmıştır. Yapılan çalışmada önerilen model olan EfficientNetB2'nin temel model olarak kullanılmasıyla toplam test doğruluğu, hassasiyet, duyarlılık ve F1 skoru sırasıyla %98.86, %98.65, %98.77 ve %98.71 elde ederek önemli bir performans gösterilmiştir (Zulfiqar, Ijaz Bajwa, and Mehmood 2023).

Shree ve diğ. beyin tümörlerinin segmentasyonu için ön işleme adımı olarak farklı gürültü giderme tekniklerini kullanmışlardır. Çalışmada Gri-Seviye Eşzamanlı Matris (GLCM) ve DWT tabanlı beyin tümörü özelliklerinin kullanılması ile segmentasyondan sonra oluşabilecek herhangi bir gürültüyü gidermek için morfolojik filtreleme işlemleri uygulanmıştır. Önerilen modelde beyin MRI görüntülerinde tümör yerinin hassas tespiti için olasılıksal sinir ağı sınıflandırıcısı kullanılmıştır. Deneysel sonuçları oldukça başarılı olan bu yöntemde beyin MRI görüntülerinde normal ve anormal dokuları tanımlama konusunda yaklaşık %100 doğruluk elde edilmiştir (Varuna Shree and Kumar 2018).

Asif ve diğ. MRI verilerini kullanarak beyin tümörlerini sınıflandırmak için transfer öğrenme tekniğine dayalı bir yöntem geliştirmişlerdir. Beyin tümör teşhisi için popüler olan Xception, NasNet Large, DenseNet121 ve InceptionResNetV2 gibi önceden eğitilmiş modeller, beyin MRI verisinden derin özellikleri çıkarmak için kullanılmıştır. ADAM optimizasyon metodunu kullanarak Xception mimarisine dayalı geliştirilen CNN modeli önerilen diğer üç modelden daha iyi sonuçlar elde etmiştir (Asif et al. 2022).

Şah ve diğ. derin evrişimli sinir ağı (CNN) EfficientNet-B0 temel modeli ile beyin tümörü görüntülerini verimli bir şekilde sınıflandırmak için önerdikleri katmanlar üzerine fine-tuned (ince ayar) mekanizması eklemişlerdir. Böylece modelin sınıflandırma doğruluğu ve kesinlik konusunda daha iyi bir sonuç elde etmesi sağlanmıştır (Shah et al. 2022).

Musallam ve diğ., MRI görüntülerinin kalitesini artırmak için üç adımlı bir ön işleme yöntemi önererek glioma, meningioma ve hipofiz gibi hastalıkların etkili teşhisi için yeni bir derin öğrenme modeli önermişlerdir. Bu mimari hızlı eğitim için toplu normalleştirme prosedürü kullanırken daha yüksek bir öğrenme hızı ve katman ağırlıklarının kolay başlatılmasını sağlamıştır (Musallam, Sherif, and Hussein 2022).

Sachdera ve ark. beyin tümörü sınıflandırması için bir temel bileşen analizi-yapay sinir ağı (PCA-ANN) önermişlerdir. İçerik tabanlı kontur tarafından bir dizi ilgi alanı elde ederek %91 tümör tespit başarısı elde etmişlerdir (Sachdeva et al. 2013).

Zahraa ve diğ. MRI üzerindeki beyin tümörlerinin otomatik tespiti için çoklu öz değer seçimi temelli bir hibrit yaklaşım önererek %91.02 başarı elde etmişlerdir (Al-Saffar and Yildirim 2021).

Gurkahraman ve Karakiş, T1 ağırlıkları ile MR görüntüleri kullanarak üç farklı sınıfa ait beyin tümörünü (menenjiyom, hipofiz bezesi, gliyom) evrişimsel sinir ağı (ESA) ile sınıflandırmışlardır. Böylece beyin dokusuna ait bazı önemli kısımların (aksiyel, koronel ve sagittal) sınıflandırılmasındaki etkinliklerini başarılı şekilde gerçekleştirmişlerdir (Gurkahraman and Karakiş 2021).

Altun ve Alkan, MRS(Manyetik Rezonans Spektroskopisi) verileri ile beyinde bulunan kolin, kreatin ve N-Asetil Aspartat oluşumlarını ölçerek beyin tümörlerinin teşhis ve sınıflandırılmasını amaçlamışlardır. Toplam 93 kişiden alınan verilerden 49 kişiye beyin tümör teşhisi konmuş ve 44 kişi ise kontrol grubu olarak belirlenmiştir. Sınıflandırma için LSTM (Long Short Term Memory), k-En Yakın komşu, DVM (Destek Vektör Makinesi) ve KA (Karar Ağacı) kullanılmıştır. Sonuç olarak LSTM derin öğrenme modelinin doğruluk performansının diğer klasik modellerden daha iyi olduğu raporlanmıştır (Altun and Alkan 2022).

Bulut ve diğ. MRI verileri ile beyin tümörünü segmente ederek tespit etmişlerdir. MRI verilerinde daha önceden belirlenmiş bölgelerde Markov Random Field, Kapur, Kittler ve Otsu algoritmalarını kullanarak beyin tümör tespitinde doğruluk oranı en yüksek algoritmayı belirlemeye odaklanmışlardır. Bu çalışmanın sonucunda diğer algoritmalarla kıyaslandığında en yüksek doğruluk oranına sahip olan algoritmanın Markov Random Field olduğu bildirilmiştir (Bulut, Kiliç, and İnce 2018).

Gökçe ve diğ. MRI görüntülerini kullanarak uzmanlara yardımcı olabilecek yapay zeka tekniklerinden faydalanarak yeni bir ESA modeli eğitmişlerdir. Model geliştirilirken U-Net ağından faydalanılarak Brast veri kümesinin %80'i kullanılmıştır. Eğitimin sonucunda modelin tümörün belli kısımlarını başarılı bir şekilde işaretlediği görülmüştür (Gökçe et al. 2022).

Salah ve diğ. yapay zeka algoritması ve derin öğrenme modelleri kullanarak MRI verilerinin beyin tümörlerini sınıflandırmak ve türlerini belirlemekteki etkinliğini araştırmayı amaçlamışlardır. Beyin tümör veri kümesi üzerinde önceden eğitilmiş beş derin öğrenme modeli olan Xception, Resnet50, InceptionV3, VGG16, ve MobileNet kullanılmıştır. F1 skorlarının doğruluk oranına göre en başarılı modelin Xception modeli olduğu görülmüştür (Saleh, Sukaik, and Abu-Naser 2020).

Raza ve diğ. glioma, meningioma ve hipofiz beyin tümörlerini sınıflandırmak için DeepTumorNet adlı bir hibrit derin öğrenme modeli geliştirdiler. Bu model, GoogleNet mimarisi temel alınarak özelleştirildi ve yüksek doğruluk seviyeleri elde edildi. Bu çalışma, beyin tümörlerinin doğru teşhisi için önemli bir gelişme olarak kabul ediliyor (Raza et al. 2022).

Rasool ve diğ. MRI görüntüleri kullanılarak üç farklı beyin tümörünü sınıflandırmak için CNN tabanlı yeni hibrit derin öğrenme modeli önermişlerdir. Önerilen model iki farklı yöntem ele alınmıştır. İlk yöntem Google-Net modelini örüntü sınıflandırması için SVM ile birleştirmeye dayanmaktadır. İkinci yöntem ise hassas bir şekilde ayarlanmış bir Google-Net modelini softmax sınıflandırıcı ile birleştirir. Çalışmada en yüksek doğruluk oranı ilk yöntemde kullanılan Google-Net + SVM ile %98,1 olarak elde edilmiştir (Rasool et al. 2022).

Diaz-Pernas ve diğ. çok ölçekli bir yaklaşım içeren bir ESA ile tam otomatik bir beyin tümör segmentasyonu ve sınıflandırma modeli geliştirmişlerdir. Üç farklı beyin tümörü sınıfı olan meningioma, glioma ve hipofiz tümörünün MRI verilerinin sagittal, koronal ve ekstenel kısımlarını önceden çıkarmak için giriş görüntülerinin ön işlenmesine ihtiyaç duyulmadan çalışmayı yürütmüşlerdir. Daha önce yapılmış klasik makine öğrenmesi yöntemleri ile kıyaslandığında %97.3'lük doğruluk oranı elde edilmiştir (Díaz-Pernas et al. 2021).

3. Materyal ve Yöntemler

Bu çalışmada beyin tümörü tespitinde histogram eşitleme metodunun derin öğrenme modelleri üzerindeki etkileri ve sınıflandırma performansına olan olumlu/olumsuz katkıları irdelenmiştir (Lecun, Bengio, and Hinton 2015). Beyin MR görüntülerinin doğasında bulunan kontrast eksikliği ve gürültü gibi bileşenlerin derin öğrenme modellerinin öğrenme performansına olan etkileri gözlemlenmiştir. Histogram eşitleme sayesinde özellikle beyin görüntülerinde kontrast eksikliği azaltılarak tümörlü bölge ile sağlıklı beyin dokusunun olduğu bölgelerin ayırt edilmesi amaçlanmıştır. Böylece öğrenme modellerinin özellik çıkarma kapasitelerine katkı sunulmuştur. Yapılan literatür araştırmalarından bilindiği kadarıyla, ele alınan veri seti özelinde histogram eşitleme yöntemi bu veri setine ilk defa uygulanmıştır. Görüntülerde yapılan iyileştirmenin üç farklı derin öğrenme modelinin performansını

olumlu/olumsuz şekilde nasıl etkileyeceği bu çalışmanın ana motivasyonudur. Bu bölümde öncelikle bu çalışmada kullanılan 3 derin öğrenme modeli kısaca tanıtmıştır. Daha sonra kullanılan histogram eşitleme yöntemi ve elde edilen bazı görsel sonuçlar tartışılmıştır.


Derin öğrenme modelleri aşağıda verilen standart yapıları içermektedir. Bununla birlikte farklı mimari yapıları ve katman mimarileri kullanılarak modeller birbirlerinden ayrılmaktadır. Standart derin öğrenme modelleri aşağıdaki bileşenleri içermektedirler:

Evrişim Katmanları: Evrişim katmanları, genellikle görüntü işleme gibi konularda kullanılır. Bir evrişim işlemi bir giriş görüntüsünün üzerinde bir "filtre" veya "çekirdek" kaydırarak gerçekleştirilir ve bu, özgün görüntüdeki yerel özelliklerin (kenarlar, doku vb.) algılanmasına yardımcı olur. Sonuçta elde edilen evrişimsel özellik haritası bir sonraki katmana iletilir.

Havuzlama Katmanları: Havuzlama katmanı, genellikle evrişimli sinir ağlarında bulunur. Ağın karmaşıklığını ve hesaplama yükünü azaltmaya yardımcı olur. Havuzlama işlemi, bir önceki katmanın çıktısını daha küçük bir boyuta indirirken özelliklerin özetlenmesini sağlar. En yaygın kullanılan havuzlama türleri max pooling ve average pooling havuzlama türleridir.

Aktivasyon Fonksiyonları: Aktivasyon fonksiyonları, sinir ağının çıktısını kontrol eder ve genellikle bir "sıkıştırma" işlemi olarak düşünülebilir. Bu, ağın daha karmaşık ve doğrusal olmayan problemleri çözebilmesini sağlar. En yaygın kullanılan aktivasyon fonksiyonları ReLU (Rectified Linear Unit), sigmoid ve tanh fonksiyonlarıdır.

Yukarıdaki bahsedilen katmanların bulunduğu basit bir CNN Mimarisi Şekil 1'de gösterilmektedir.



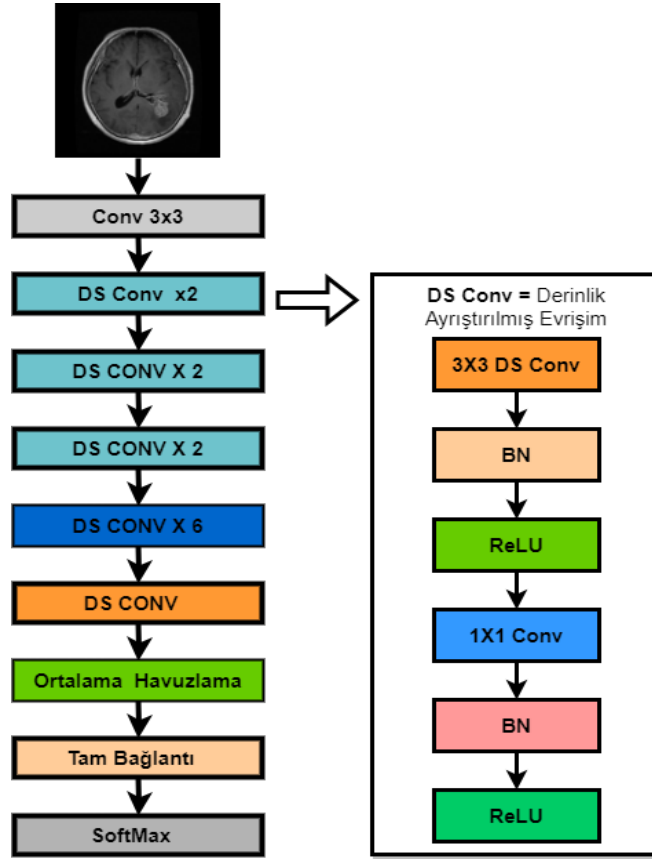
Şekil 1: CNN Mimarisi

3.1 MobileNet Mimarisi

MobileNet görsel işleme için tasarlanmış bir tür ESA modelidir. Bu model hesaplama gücü kısıtlı cihazlar için hafif ve verimli bir çözüm sunar (Mutlu Bilgin, Özdem, and Ali AKCAYOL n.d.). MobileNet derinlemesine evrişim ve noktasal evrişim adlı iki farklı evrişim türünü kullanmasının yanı sıra toplu normalleştirme ve ReLU fonksiyonu kullanmaktadır. Sonuç olarak, MobileNet düşük donanım kaynaklı cihazlarda etkili bir şekilde çalışabilen ve görsel işleme görevlerini başarılı bir şekilde gerçekleştiren hafif ve hızlı bir derin öğrenme modelidir. Şekil 2'de MobileNet mimarisi görülmektedir. MobileNet temelde iki ana bileşenden oluşur:

Derinlik Ayrıştırılmış Evrişim: Geleneksel evrişim katmanlarının daha hafif bir alternatifidir. Evrişim işlemi iki aşamada gerçekleştirir - önce her kanalda ayrı ayrı evrişim yapar ve ardından kanallar arasında paylaşılan bir evrişim gerçekleştirir. Bu derin öğrenme modelinin hesaplama ve bellek ihtiyaçlarını azaltır.

Genişlik Çarpanı: MobileNet'in hafif ve verimli bir model olmasını sağlayan bir parametredir. Genişlik çarpanı, modeldeki kanal sayısını azaltmak için kullanılır. Daha düşük kanal sayısı, daha az parametre ve daha az hesaplama anlamına gelir, böylece daha küçük ve daha hızlı bir model elde edilir. Ancak, kanal sayısındaki azalma, modelin performansını etkileyebilir, bu nedenle genişlik çarpanı dikkatli bir şekilde ayarlanmalıdır.



Şekil 2: MobileNet Mimarisi


3.2. VGG16 ve VGG19 Mimarileri

VGG ağı bir milyondan fazla görüntü içeren ImageNet veri setinden alınan görüntülerle eğitilen evrişimli sinir ağıdır [24]. VGG16 ve VGG19 modelleri Oxford Üniversitesi'nden Visual Geometry Group (VGG) tarafından geliştirilmiştir. Her iki model de evrişimli sinir ağlarına (CNN) dayalıdır ve isimlerini içerdikleri öğrenilebilir katmanların sayısından alırlar: VGG16'da 16 ve VGG19'da ise 19 öğrenilebilir katman bulunmaktadır.

VGG modelleri evrişim ve havuzlama işlemlerini bir dizi 3x3 çekirdekli evrişim katmanı, ReLU aktivasyon fonksiyonu ve ardından bir 2x2 havuzlama katmanı şeklinde takip eden basit ve tekrarlanabilir bir yapıya sahip olmasıyla bilinir. Her evrişim işlemi sonrası çıkış derinliği (kanal sayısı) iki katına çıkar. Bu yapının sonunda ise tam bağlantılı katmanlar ve son çıktıyı üretmek için bir softmax aktivasyon fonksiyonu bulunur.


VGG16 ve VGG19 modelleri özellikle görüntü tanıma ve sınıflandırma görevlerinde mükemmel performans gösterir ve bu nedenle birçok bilgisayarlı görü uygulamasında yaygın olarak kullanılır. Ancak bu modellerin karmaşıklığı ve yüksek sayıda parametre içermesi nedeniyle, büyük miktarda hesaplama kapasitesi gerektirirler ve bu da onların kullanımını bazı durumlarda zorlaştırabilir.

VGG16 mimarisi, evrişim katmanı, reLu, maksimum havuzlama, tam bağlı katman ve softmax katmanları ile toplamda 41 katmandan oluşmaktadır. Son katmanı sınıflandırma katmanı olup giriş katmanında olan görüntü 224x224x3 boyutundadır. VGG16 mimarisi Şekil 3'te görülebilir.



Şekil 3: VGG16 Mimarisi (Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması Ferdi DOĞAN 2018)

VGG19 mimarisinin katman sayısı 47 olup VGG16 tek farkı katman sayısının fazla olmasıdır. ImageNet veri setinde %88'lik başarımlarını yakalamıştır. VGG19 mimarisi Şekil 4'te görülebilir.



Şekil 4: VGG19 Mimarisi (BÜYÜKARIKAN and ÜLKER 2020)

3.3. Histogram Eşitleme

Histogram eşitleme, görüntü işleme alanında sıkça kullanılan bir yöntemdir ve bir görüntünün kontrastını artırmak veya görüntüdeki parlaklık dağılımını düzeltmek için kullanılır (Üniversitesi et al. 2014). Temel amaç bir görüntünün piksel değerlerinin dağılımını, olası değerlerin daha eşit bir şekilde dağıldığı bir hale getirmektir. Histogram eşitleme işlemi aşağıdaki adımlarla gerçekleştirilir:

Görüntünün histogramını hesaplama: Görüntüdeki piksel değerlerinin hangi aralıklarda ne kadar sıklıkta bulunduğunu gösteren bir histogram oluşturulur. Histogram bir grafik olarak görüntülenir ve genellikle piksel değerleri (0 ile 255 arasında olabilir) x-eksenine ve piksel sayısı veya yoğunluk frekansı y-eksenine yerleştirilir.


Kümülatif dağılım fonksiyonu (CDF): Histogramın kümülatif dağılım fonksiyonu, her piksel değeri için o değere kadar olan tüm piksellerin sayısını toplar. Bu, CDF'nin 0'dan 1'e kadar olan değerlerle normalize edilmiş bir histogram olduğu anlamına gelir.

Histogram eşitleme dönüşümü: CDF'yi kullanarak, her piksel değerini yeni bir değere dönüştüren bir işlem elde edilir. Bu işlem görüntüdeki piksel değerlerini dağılımı eşitlemek için yeniden düzenler.

Yeni görüntü oluşturma: Piksel değerlerini dönüştürerek yeni ve daha optimal bir kontrast dağılımına sahip görüntü oluşturulur.

Histogram eşitlemenin sonucu görüntünün kontrastını artırır ve görüntüdeki daha fazla ayrıntının görünür ve birbirinden ayrılabilir hale gelmesini sağlar. Özellikle eşikleme gibi işlemler öncesinde uygulanarak optimal eşik değerin daha kolay tespit edilmesine olanak sağlar. Şekil 5'te Histogram eşitleme uygulanan beyin tümörü görüntüsü bulunmaktadır. Elde edilen görüntü incelendiğinde orijinal görüntüye göre beyin bölgelerinin daha net ve anlaşılır hale geldiği görülmektedir. Böylece özellik çıkarımı yapılırken tümürlü ve tümörsüz bölgeler arasındaki ayrım özellik çıkarma işlemi öncesinde belirginleştirilmiştir. Farklı beyin dokusu bölgelerinin hem arka

plandan hem de diğer beyin gölgelerinden ayırt edilmesine olanak tanınmıştır. Böylece evrişim gibi işlemlerin performansı iyileştirilerek özellik çıkarma kapasitesi artırılmıştır.



Şekil 5: Histogram uygulanan beyin tümör görüntüsü: orijinal görüntü (soldaki), histogram eşitleme sonucu (sağdaki)

3.4. Kullanılan veri tabanı

Bu çalışmada kullanılan veri kümesi beyin MR görüntülerini içermekte olup, dört farklı kategoriye ayrılmıştır: glioma, pituitary, meningioma ve tümörsüz görüntüler (Anon n.d.). Bu geniş ve çeşitli veri kümesi, toplamda 3590 görüntüden oluşmaktadır ve geniş bir spektrumda beyin tümörü vakalarını kapsamaktadır. Bu veri kümesi beyin tümörlerinin derin öğrenme yöntemleri ile sınıflandırılmasına yönelik kapsamlı bir analiz sağlar ve beyin tümörlerinin otomatik tanı ve sınıflandırılması konusunda yeni araştırmalara ışık tutabilir.

Veri kümesindeki her bir görüntü çeşitli ön işleme adımlarından geçirilmiştir. Bu işlemler görüntülerin standartlaştırılmasını, gürültünün azaltılmasını ve uygun görüntü boyutunun belirlenmesini içerir. Ön işlemler derin öğrenme modelinin eğitim sürecini daha etkili hale getirmekte ve algoritmanın genelleme yeteneğini geliştirmektedir.

Bu veri kümesi ayrımı, makine öğrenimi modelinin etkili bir şekilde eğitilmesine ve değerlendirilmesine büyük katkı sağlamaktadır. Bu ayrım, modelin performansını daha doğru bir şekilde değerlendirmeye ve aşırı uyumu önlemeye yardımcı olur. Veri kümesi dört farklı sınıfa ayrılmıştır: Glioma, Meningioma, No Tumor ve Pituitary. Her sınıf altında belirli sayıda görüntü bulunmaktadır: Glioma için 985, Meningioma için 990, No Tumor için 596 ve Pituitary için 999. Bu sınıflandırma, modelin eğitim sürecinde ve sonraki performans değerlendirmesinde çeşitli veri noktaları üzerinde test edilmesine olanak sağlar.

4. Deneysel Sonuçlar

Bu çalışmada derin öğrenme modellerinin uygulanmasında PyTorch kütüphanesinden faydalanılmıştır. PyTorch derin öğrenme algoritmalarının etkili bir şekilde uygulanmasını sağlayan bir açık kaynaklı kütüphanedir. Eğitim sürecinde 100 epoch tamamlanmış ve batch size 12 olarak belirlenmiştir. Batch size, modelin işlediği örneklerin sayısını temsil ederken, öğrenme hızı 0.001 olarak ayarlanmıştır. Bu parametreler modelin eğitim hızını ve performansını etkileyen kritik faktörlerdir. NVIDIA RTX 5000 grafik kartı kullanılarak derin öğrenme modelinin hesaplama gereksinimleri karşılanmıştır.

Bu çalışmada kontrast eksikliği problemini gidermek amacıyla sıklıkla kullanılan histogram eşitleme yönteminin tıbbi görüntü işlemede kullanılabilirliği incelenmiştir. Özellikle beyin tümörü tespiti üzerinde üç farklı derin öğrenme modeli olan VGG16, VGG19 ve MobileNet modelleri kullanılarak bir analiz gerçekleştirilmiştir. Modeller başlangıçta orijinal halleriyle ve veri tabanındaki görüntülere herhangi bir ön işlem yapılmadan kullanılarak sonuçlar alınmıştır. Daha sonra veri tabanındaki MR görüntülerine histogram eşitleme işlemi uygulandıktan sonra belirtilen modeller ile yeniden sonuçlar alınmıştır.

Bu bölümde beyin tümörü teşhis ve tedavisinde kullanılan VGG16, VGG19 ve MobileNet derin öğrenme modellerinin performansı ile histogram eşitleme görüntü işleme sonrası performans değişiklikleri incelenmiştir. Deneysel sonuçlar aşağıdaki şekilde özetlenmektedir:

VGG16 Modeli: VGG16 modeli yalın halinde yüksek performans göstermiş ve beyin tümörü teşhisi ve tedavisinde başarılı sonuçlar elde etmiştir. Ancak histogram eşitleme işlemi uygulandığında, VGG16 modelinin performansının belirgin bir şekilde arttığı gözlemlenmiştir.

VGG19 Modeli: VGG19 modeli yalın haliyle de iyi sonuçlar vermiştir, ancak VGG16'ya kıyasla F1 skor açısından daha düşük doğruluk oranları elde etmiştir. Histogram eşitleme işlemi uygulandığında, VGG19 modelinin hem doğruluk hem de F1 skor performansında belirgin bir iyileşme gözlemlenmemiştir.

MobileNet Modeli: MobileNet modeli yalın haliyle diğer iki modele benzer performans sergilemiştir. Beyin tümörü teşhis ve tedavisi görevlerinde kabul edilebilir doğruluk oranlarına sahiptir. Ancak histogram eşitleme işlemi uygulandığında MobileNet modelinin performansında önemli bir değişiklik gözlemlenmemiştir; yani histogram eşitleme işlemi bu modelin performansına katkı sağlamamıştır. Ancak F1 skor bağlamında bir iyileşme söz konusudur.

Sonuç olarak bu deneyler, VGG16 ve VGG19 modellerinin histogram eşitleme işlemi sonrası performanslarının arttığını göstermektedir. Ancak MobileNet modeli için aynı iyileşme gözlemlenmemiştir. Bu sonuçlar model seçiminin ve görüntü işleme tekniklerinin tıbbi görüntü analizi uygulamalarında dikkatle değerlendirilmesi gerektiğini vurgulamaktadır.

Tablo 1: Derin öğrenme modelleri deneysel sonuçları

Modeller	Doğruluk	F1 skor
VGG16	0.9410	0.9418
Histogram eşitleme + VGG16	0.9589	0.9589
VGG19	0.9464	0.7614
Histogram eşitleme + VGG19	0.9517	0.9519
MobileNet	0.9660	0.8560
Histogram eşitleme + MobileNet	0.9607	0.9607

Elde edilen sonuçlar irdelendiğinde, histogram eşitleme işlemi neticesinde VGG16 ve VGG19 modellerinin doğruluk ve F1 skorlarında belirgin bir artış elde edildiği görülebilir. Bu sonuçlar bu iki derin öğrenme modelinin beyin tümörü tespitinde başarılı bir şekilde kullanılabilmesini göstermektedir.

MobileNet modeli histogram eşitleme işleminden daha az etkilenmiştir. Bu durum daha hafif bir modelin daha karmaşık bir görevde farklı kısıtlılıklarla karşılaşabileceği sonucunu vermektedir. Modelin performansını artırmak için daha fazla optimizasyon çalışması gerekebilir. Bu sonuçlar ışığında gelecekteki araştırmalara yönelik bazı öneriler sunulabilir:

Veri Çeşitliliği: Daha geniş ve farklı türde beyin tümörü görüntü verilerinin kullanılması, modelin daha iyi genelleme yapmasına yardımcı olabilir. Veri çeşitliliği modelin çeşitli klinik senaryolara daha iyi uyum sağlamasını sağlayabilir.

Model Optimizasyonu: MobileNet gibi hafif modellerin performansını artırmak için model optimizasyon tekniklerinin kullanılması değerlendirilmelidir. Daha iyi performans ve hızlı çıkarım süreleri elde etmek için bu önemlidir. Modelin katman yapısı, katmanlardaki evrişim ve aktivasyon fonksiyonlarının çeşitliliğinin irdelenmesi gerekebilir.

Görüntü Ön İşleme: Görüntü iyileştirme teknikleri üzerinde daha fazla çalışma yapılabilir. Histogram eşitleme gibi yöntemlerin yanı sıra, log dönüşümü ve frekans temelli dönüşüm yöntemleri gibi daha gelişmiş ve özelleştirilmiş görüntü işleme algoritmalarının kullanılması düşünülmelidir.

Bu çalışma ile tıbbi görüntü analizi ve beyin tümörü tespiti gibi önemli sağlık uygulamaları için derin öğrenme ve görüntü işleme yöntemlerinin etkili bir şekilde kullanılabilirliğini göstermektedir. Gelecekteki araştırmalarda bu önerilere dayanarak bu alandaki ilerlemeleri hızlandırabilir ve daha iyi teşhis ve tedavi yöntemleri geliştirebilir. Ayrıca derin öğrenme modellerinin performanslarının farklı ön işleme yöntemleri ile iyileştirilebileceğini

göstermiştir. Böylece karmaşık derin öğrenme mimarileri geliştirmeden önce veri üzerinde gerçek zamanlı olmayan bazı ön işlemler yapılarak donanım gereksinimi düşük güçlü yöntemler geliştirilebilir.

5. Sonuçlar

Bu çalışmada VGG16, VGG19 ve MobileNet derin öğrenme modellerinin sınıflandırma performanslarını görüntü ön işleme bağlamında değerlendirilmiştir. Belirli bir veri kümesi üzerinde modeller öncelikle doğrudan çalıştırılarak sınıflandırma sonuçları elde edilmiştir. Daha sonra tüm görüntülere histogram eşitleme yöntemi uygulanarak kontrast eksikliği içeren görüntülerin iyileştirilmesi sağlanmıştır. Elde edilen iyileştirilmiş veri kümesi ile üç model bağımsız şekilde yeniden çalıştırılarak elde edilen sonuçlar analiz edilmiştir.

Yürütülen deneysel çalışmalarda derin öğrenme tabanlı CNN modellerinin görüntü sınıflandırma problemindeki performansını iyileştirmek için görüntü ön işleme metodlarından faydalanılabileceği anlaşılmıştır. Elde edilen sonuçlar farklı model yapılarının ve görüntü ön işleme yöntemlerinin tıbbi görüntü analizi ve diğer uygulama alanlarında nasıl etkili olabileceği konusunda önemli bir anlayış sağlamıştır. Gelecekteki çalışmalarda daha fazla model ve görüntü iyileştirme yöntemi karşılaştırması yapılarak donanım ihtiyacını en aza indiren derin öğrenme tabanlı sınıflandırma çalışmalarına katkı sunulmaya devam edilecektir.

Kaynaklar

- Al-Saffar, Zahraa A., and Tülay Yıldırım. 2021. "A Hybrid Approach Based on Multiple Eigenvalues Selection (MES) for the Automated Grading of a Brain Tumor Using MRI." *Computer Methods and Programs in Biomedicine* 201:105945. doi: 10.1016/J.CMPB.2021.105945.
- Altun, Sinan, and Ahmet Alkan. 2022. "MR Spektroskopisi Kullanılarak Beyin Tümörü Tespitinde LSTM Tabanlı Derin Öğrenme Uygulaması." *Journal of the Faculty of Engineering and Architecture of Gazi University* 38(2):1193–1202. doi: 10.17341/GAZIMMFD.1069632.
- Anon. n.d. "Brain Tumor Mri Classification." Retrieved October 3, 2023 (<https://www.kaggle.com/datasets/mohammedhamdy98/brain-tumor-mri-classification/>).
- Asif, Sohaib, Wenhui Yi, Qurrat Ul Ain, Jin Hou, Tao Yi, and Jinhai Si. 2022. "Improving Effectiveness of Different Deep Transfer Learning-Based Models for Detecting Brain Tumors From MR Images." *IEEE Access* 10:34716–30. doi: 10.1109/ACCESS.2022.3153306.
- Aslan, Muzaffer, Elektrik Elektronik Mühendisliği Bölümü, Mühendislik ve Mimarlık Fakültesi, and Bingöl Üniversitesi. 2022. "Derin Öğrenme Tabanlı Otomatik Beyin Tümör Tespiti." *Firat University Journal of Engineering Science* 34(1):399–407. doi: 10.35234/FUMBD.1039825.
- Bulut, Faruk, İlker Kiliç, and İbrahim Furkan İnce. 2018. "Beyin Tümörü Tespitinde Görüntü Bölütleme Yöntemlerine Ait Başarımların Karşılaştırılması ve Analizi." *Dokuz Eylül University-Faculty of Engineering Journal of Science and Engineering* 20. doi: 10.21205/deufmd.
- BÜYÜKARIKAN, Birkan, and Erkan ÜLKER. 2020. "AYDINLATMA ÖZNİTELİĞİ KULLANILARAK EVRİŞİMSEL SİNİR AĞI MODELLERİ İLE MEYVE SINIFLANDIRMA." *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi* 25(1):81–100. doi: 10.17482/UUMFD.628166.
- Díaz-Pernas, Francisco Javier, Mario Martínez-Zarzuola, David González-Ortega, and Míriam Antón-Rodríguez. 2021. "A Deep Learning Approach for Brain Tumor Classification and Segmentation Using a Multiscale Convolutional Neural Network." *Healthcare* 2021, Vol. 9, Page 153 9(2):153. doi: 10.3390/HEALTHCARE9020153.
- Gökçe, Emin, Mehmet Fatih Demiral, Ali Hakan Işık, and Mehmet Bilen. 2022. "Evrışimli Sinir Ağlarında Beyin Tümörü Segmentasyonu." *El-Cezeri* 9(4):1518–28. doi: 10.31202/ECJSE.1141335.
- Gül Eker, Ayşe, Nevcihan Duru, Kocaeli Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Havacılık ve Uzay Bilimleri Fakültesi, Havacılık Elektrik Elektronik Bölümü, and Ayşe Gül EKER Kocaeli Üniversitesi. 2021. "Medikal Görüntü İşlemede Derin Öğrenme Uygulamaları." *Acta Infologica* 5(2):459–74. doi: 10.26650/ACIN.927561.
- Gürkahraman, Kali, and Rukiye Karakiş. 2021. "Veri Çoğaltma Kullanılarak Derin Öğrenme İle Beyin Tümörlerinin Sınıflandırılması." *Journal of the Faculty of Engineering and Architecture of Gazi University* 36(2):997–1012. doi: 10.17341/GAZIMMFD.762056.
- Işın, Ali, Cem Direkoğlu, and Melike Şah. 2016. "Review of MRI-Based Brain Tumor Image Segmentation Using Deep Learning Methods." *Procedia Computer Science* 102:317–24. doi: 10.1016/J.PROCS.2016.09.407.
- Lecun, Yann, Yoshua Bengio, and Geoffrey Hinton. 2015. "Deep Learning." *Nature* 2015 521:7553 521(7553):436–44. doi: 10.1038/nature14539.
- Musallam, Ahmed S., Ahmed S. Sherif, and Mohamed K. Hussein. 2022. "A New Convolutional Neural Network Architecture for Automatic Detection of Brain Tumors in Magnetic Resonance Imaging Images." *IEEE Access* 10:2775–82. doi: 10.1109/ACCESS.2022.3140289.

- Mutlu Bilgin, Mehtap, Kevser Özdem, and M. Ali AKCAYOL. n.d. "POLİTEKNİK DERGİSİ JOURNAL of POLYTECHNIC Derin Öğrenme İle Kuş Türü Sınıflandırma: Karşılaştırmalı Bir Çalışma Bird Species Classification Using Deep Learning: A Comparative Study." doi: 10.2339/politeknik.904933.
- Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması Ferdi DOĞAN, Derin. 2018. "The Comparison Of Leaf Classification Performance Of Deep Learning Algorithms." *SAKARYA UNIVERSITY JOURNAL OF COMPUTER AND INFORMATION SCIENCES* 1.
- Polat, Özlem. 2022. "Sadeleştirilmiş U-Net Mimarisi İle Beyin Tümörü Segmentasyonu Brain Tumor Segmentation with Simplified U-Net Architecture." *Bilim. Derg. / NOHU J. Eng. Sci* 11(4):856–61. doi: 10.28948/ngmuh.1111082.
- Rasool, Mohammed, Norazman Ismail, Wadii Boulila, Adel Ammar, Hussein Samma, Waelm S. Yafooz, and Abdel Hamidm Emara. 2022. "A Hybrid Deep Learning Model for Brain Tumour Classification." *Entropy* 2022, Vol. 24, Page 799 24(6):799. doi: 10.3390/E24060799.
- Raza, Asaf, Huma Ayub, Javed Ali Khan, Ijaz Ahmad, Ahmed S. Salama, Yousef Ibrahim Daradkeh, Danish Javeed, Ateeq Ur Rehman, and Habib Hamam. 2022. "A Hybrid Deep Learning-Based Approach for Brain Tumor Classification." *Electronics* 2022, Vol. 11, Page 1146 11(7):1146. doi: 10.3390/ELECTRONICS11071146.
- Sachdeva, Jainy, Vinod Kumar, Indra Gupta, Niranjana Khandelwal, and Chirag Kamal Ahuja. 2013. "Segmentation, Feature Extraction, and Multiclass Brain Tumor Classification." *Journal of Digital Imaging* 26(6):1141–50. doi: 10.1007/S10278-013-9600-0/METRICS.
- Saleh, Ahmad, Rozana Sukaik, and Samy S. Abu-Naser. 2020. "Brain Tumor Classification Using Deep Learning." *Proceedings - 2020 International Conference on Assistive and Rehabilitation Technologies, ICareTech 2020* 131–36. doi: 10.1109/ICARETECH49914.2020.00032.
- Shah, Hasnain Ali, Faisal Saeed, Sangseok Yun, Jun Hyun Park, Anand Paul, and Jae Mo Kang. 2022. "A Robust Approach for Brain Tumor Detection in Magnetic Resonance Images Using Finetuned EfficientNet." *IEEE Access* 10:65426–38. doi: 10.1109/ACCESS.2022.3184113.
- Siddique, Nahian, Sidike Paheding, Colin P. Elkin, and Vijay Devabhaktuni. 2021. "U-Net and Its Variants for Medical Image Segmentation: A Review of Theory and Applications." *IEEE Access*. doi: 10.1109/ACCESS.2021.3086020.
- Üniversitesi, Hacettepe, Yerbilimleri Uygulama, Araştırma Merkezi Bülteni, Manyetik Belirti, Haritalarının Histogram, Eşitleme Yöntemi, Kullanılarak İyileştirilmesi, Muzaffer Özgü Arisoy, and Ünal Dikmen. 2014. "Manyetik Belirti Haritalarının Histogram Eşitleme Yöntemi Kullanılarak İyileştirilmesi." *Yerbilimleri* 35(2):141–68. doi: 10.17824/HUYUAMD.23614.
- Varuna Shree, N., and T. N. R. Kumar. 2018. "Identification and Classification of Brain Tumor MRI Images with Feature Extraction Using DWT and Probabilistic Neural Network." *Brain Informatics* 5(1):23–30. doi: 10.1007/S40708-017-0075-5/FIGURES/4.
- Zulfiqar, Fatima, Usama Ijaz Bajwa, and Yasar Mehmood. 2023. "Multi-Class Classification of Brain Tumor Types from MR Images Using EfficientNets." *Biomedical Signal Processing and Control* 84:104777. doi: 10.1016/J.BSPC.2023.104777.