



İSTANBUL MEDENİYET ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİYOLOJİK VERİ BİLİMİ ANABİLİM DALI

**Beyin Tümörlerinin Derin Öğrenme, Transfer Öğrenme
ve Topluluk Öğrenme ile Sınıflandırılması**

Yüksek Lisans Tezi

Hakan Kasım Akmaz

Ağustos 2025



İSTANBUL MEDENİYET ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİYOLOJİK VERİ BİLİMİ ANABİLİM DALI

**Beyin Tümörlerinin Derin Öğrenme, Transfer Öğrenme
ve Topluluk Öğrenme ile Sınıflandırılması**

Yüksek Lisans Tezi

Hakan Kasım Akmaz

Danışman

Dr. Öğr. Üyesi Muhammet Sinan Başarslan

Ağustos 2025

TEZ JÜRİSİ ONAYI

Hakan Kasım Akmaz tarafından hazırlanan "Beyin Tümörlerinin Derin Öğrenme, Transfer Öğrenme ve Topluluk Öğrenme ile Sınıflandırılması" başlıklı bu Yüksek Lisans Tezi, Biyolojik Veri Bilimi Anabilim Dalı'nda hazırlanmış ve jürimiz tarafından kabul edilmiştir.

JÜRİ ÜYELERİ

İMZA

Tez Danışmanı:

Dr. Öğr. Üyesi Muhammet Sinan Başarslan

İstanbul Medeniyet Üniversitesi

Üyeler:

Prof. Dr. Ertuğrul Kılıç

İstanbul Medeniyet Üniversitesi

Doç. Dr. Hüseyin Bakır

Doğuş Üniversitesi

Tez Savunma Tarihi: 08/ 08 / 2025

BEYANLAR

Yazım ve Kaynak Gösterme Kılavuzu Beyanı

Danışmanlığımda yazılan bu tezin APA yazım ve kaynak gösterme kılavuzunda belirtilen kurallara uygun olarak yapılandırıldığı ve bu kılavuzun metin içi kaynak gösterme standartlarının bu tezde tutarlı olarak uygulandığı tarafımdan incelenerek teyit edilmiştir.

İmza

Dr. Öğr. Üyesi Muhammet Sinan Başarslan

Etik İlkeler Sadakat Beyanı

Hazırladığım bu tezin tamamen kendi çalışmam olduğunu, akademik ve etik kuralları gözeterek çalıştığımı ve her alıntıya kaynak gösterdiğimi beyan ederim.

İmza

Hakan Kasım Akmaz

ÖZET

Beyin Tümörlerinin Derin Öğrenme, Transfer Öğrenme ve Topluluk Öğrenme ile Sınıflandırılması

Hakan Kasım Akmaz

Yüksek Lisans Tezi, Biyolojik Veri Bilimi Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Muhammet Sinan Başarslan

Ağustos 2025

Beyin tümörlerinde tedavi başarısını artırmak için erken teşhis ve doğru sınıflandırma hayati önem taşımaktadır. Gelişen tıbbi görüntüleme teknikleri ve artan veri miktarıyla birlikte, bu verilerin değerlendirilmesinde bilgisayar destekli tanı sistemlerinin önemi giderek artmaktadır. Bu tez kapsamında, Figshare veri tabanından elde edilen açık kaynaklı manyetik rezonans (MR) görüntüleri kullanılarak, beyin tümörlerinin sınıflandırılmasına yönelik derin öğrenme tabanlı bir çalışma gerçekleştirilmiştir. Sınıflandırma süreci, gliom, meningiom ve hipofiz tümörü olmak üzere üç farklı tümör türünü kapsamaktadır. Çalışmada, sıfırdan model eğitimi yerine transfer öğrenme yöntemi tercih edilerek önceden eğitilmiş derin öğrenme modelleri kullanılmıştır. Bu doğrultuda, Inception, Xception, VGG, ResNet, DenseNet ve ConvNeXtBase gibi evrimsel sinir ağı (CNN) tabanlı modern mimariler uygulanarak sınıflandırma modelleri oluşturulmuş; bu modellerin performansları karşılaştırılmıştır. Ayrıca, farklı modellerin çıktılarını birleştirerek daha yüksek sınıflandırma doğruluğu elde etmek amacıyla topluluk öğrenme yöntemlerinden de yararlanılmıştır. Model geliştirme süreci TensorFlow kütüphanesi kullanılarak yürütülmüştür. Geliştirilen modellerin performansı doğruluk, kesinlik, özgüllük, duyarlılık, F-skoru ve Matthews Korelasyon Katsayısı (MCC) gibi metrikler ile değerlendirilmiş ve elde edilen sonuçlar literatürdeki benzer çalışmalarla karşılaştırılmıştır. VGG16 ve VGG19 modellerinin topluluk öğrenme ile gerçekleştirdiği sınıflandırmada, %99,02 doğruluk ve 0,985 MCC ile en yüksek performans elde edilmiştir.

Anahtar Kelimeler: Beyin tümörü, Sınıflandırma, Derin öğrenme, Transfer öğrenme, Topluluk öğrenme

ABSTRACT

Classification of Brain Tumors Using Deep Learning, Transfer Learning, and Ensemble Learning

Akmaz, Hakan Kasım

Master's Thesis, Department of Biological Data Science

Supervisor: Assistant Professor Dr. Muhammet Sinan Başarslan

August 2025

Early diagnosis and accurate classification play a vital role in improving treatment outcomes for brain tumors. With the advancement of medical imaging techniques and the increasing volume of data, the importance of computer-aided diagnosis systems for analyzing these data has been growing steadily. Within the scope of this thesis, a deep learning-based study was conducted to classify brain tumors using publicly available magnetic resonance (MR) imaging data obtained from the Figshare database. The classification process includes three different tumor types: glioma, meningioma, and pituitary tumor. Instead of training models from scratch, transfer learning was preferred by utilizing pre-trained deep learning models. Accordingly, convolutional neural network (CNN)-based modern architectures such as Inception, Xception, VGG, ResNet, DenseNet, and ConvNeXtBase were implemented to develop classification models, and their performances were compared. Furthermore, ensemble learning methods were employed to combine the outputs of different models in order to achieve higher classification accuracy. The model development process was carried out using the TensorFlow library. The performance of the developed models was evaluated with metrics including accuracy, precision, specificity, recall, F-score, and Matthews Correlation Coefficient (MCC), and the obtained results were compared with similar studies in the literature. The ensemble classification performed by the VGG16 and VGG19 models achieved the highest performance with an accuracy of 99.02% and an MCC of 0.985.

Keywords: Brain Tumor, Classification, Deep Learning, Transfer Learning, Ensemble Learning

TEŞEKKÜR

Yüksek lisans öğrenimim sürecinde ve bu tezin hazırlanmasında gösterdiği her türlü destek ve yardımdan dolayı çok değerli hocam Dr. Öğretim Üyesi Muhammet Sinan BAŞARSLAN'a en içten dileklerimle teşekkür ederim.

Bu çalışma boyunca yardımlarını ve desteklerini esirgemeyen Prof. Dr. Handan ANKARALI, Prof. Dr. Pınar OBAKAN YERLİKAYA, Prof. Dr. Hasan GÜÇLÜ, Dr. Öğretim Üyesi Mahmut Alpertunga KARA, Dr. Öğretim Üyesi Nurgül BULUT hocalarıma, bilgi ve deneyimlerinden faydalandığım için minnettarım.

Ayrıca, bu süreçte bana her zaman destek olan aileme, sabırları ve anlayışları için sonsuz teşekkürlerimi sunarım.

İÇİNDEKİLER

ÖZET.....	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER.....	vii
1. Giriş.....	1
2. Literatür Taraması.....	5
3. Materyal ve Metotlar.....	10
3.1 Veri Seti.....	10
3.2 Evrişimli Sinir Ağları.....	10
3.3 Transfer Öğrenme.....	11
3.4 Topluluk Öğrenme.....	14
3.5 Performans Değerlendirme Metrikleri.....	15
3.6 DeneySEL Kurulum.....	18
4. Bulgular.....	19
5. Sonuç.....	28
Kaynakça.....	30

1. Giriş

Algılama, öğrenme, duygusal tepkilerin işlenmesi ve hareket gibi günlük faaliyetlerin gerçekleşmesini sağlayan beynimiz, özel işlevlerin yürütüldüğü farklı bölümlerden oluşan karmaşık bir yapıya sahiptir. Bireyin iyi bir yaşam sürebilmesi için sağlıklı bir beyin yapısına sahip olması önemlidir. Beyin sağlığı normal beyin işleyişini bozan beyin hastalıklarının olmadığı durumda beynin yapısal bütünlüğünün ve zihinsel ile bilişsel işlevlerinin korunması olarak ifade edilebilir (Wang vd., 2020; Gorelick vd., 2017; Gorelick & Sorond, 2024). Beyin sağlığını tehdit eden durumlardan biri de beyin yapısında hasara yol açan hastalıklar arasında yer alan beyin tümörleridir.

Beyin tümörü, beyinde ya da merkezi sinir sistemi içerisinde, normal hücresel düzenin dışında gelişen ve kontrolsüz biçimde çoğalan hücrelerden oluşan anormal bir kitledir. Beyin tümörleri kökenlerine göre primer (birincil) beyin tümörleri ve metastatik (ikincil) beyin tümörleri olmak üzere iki temel gruba ayrılır. Primer beyin tümörü, beyindeki hücrelerden doğrudan kaynaklanan tümördür. Metastatik beyin tümörü, vücudun başka bir bölgesinde ortaya çıkan bir kanserin genellikle kan dolaşımı yoluyla beyin dokusuna yayılmasıyla oluşan tümördür. Biyolojik davranışlarına göre beyin tümörleri iyi huylu (benign) ve kötü huylu (malignant) olarak iki gruba ayrılır. İyi huylu bir beyin tümörü çok yavaş büyüyen hücrelerden oluşur ve nadiren yayılır. Genellikle belirgin sınırlara sahiptir. Cerrahi tedavi genellikle etkilidir ve tekrarlama olasılıkları düşüktür. Kötü huylu bir beyin tümörü genellikle hızlı büyür ve yayılmacıdır. Tedaviye rağmen tekrar oluşma riski yüksektir. Primer beyin tümörleri iyi veya kötü huylu olabilir. Tüm metastatik beyin tümörleri ise tanım gereği kötü huyludur. Dünya Sağlık Örgütü (WHO), tümörleri kötü huyluluk derecelerine göre Derece I'den Derece IV'e kadar dört gruba ayırmıştır; Derece I en az, Derece IV ise en agresif tümörleri temsil eder (American Brain Tumor Association, 2015). Bu genel sınıflandırmalar doğrultusunda en sık karşılaşılan primer beyin tümörlerinden bazıları meningiomlar, gliomlar ve hipofiz tümörleridir.

Meningiomlar, beynin zarlarını oluşturan tabakalardan biri olan araknoid materden kaynaklanan genellikle iyi huylu tümörlerdir. En sık serebral hemisferler arasında, beyin ve omuriliği çevreleyen koruyucu dokular olan meninkslerin içerisinde, kafatası tabanında ve beynin arka-alt bölgesi olan posterior fossada yer alırlar. Meningiomların

büyük çoğunluğu Derece I olup, iyi huylu, yavaş büyüyen, lokalize ve beyin dokusuna yayılım göstermeyen tümörlerdir. Ancak, atipik (Derece II) ve anaplastik (Derece III) meningiomlar, histolojik ve biyolojik olarak daha agresif davranışlar sergileyerek beyin dokusuna yayılım gösterebilir ve nüks etme riskleri daha yüksektir (American Brain Tumor Association, 2015; Söylemezoğlu, 2011). 2021 Dünya Sağlık Örgütü sınıflamasına göre, meningiomlar artık sadece histolojik özelliklerine göre değil, aynı zamanda genetik ve moleküler özelliklerine göre de sınıflandırılmaktadır. WHO CNS5 sınıflamasına göre, meningiomlar hala tek bir tümör türü olarak kabul edilmekte, ancak morfolojik çeşitliliği 15 alt tipe ayrılmaktadır (Louis vd., 2021).

Gliomlar, nöronların yerinde kalmasını ve işlevlerini sürdürebilmesini sağlayan glia hücrelerinden kaynaklanan tümörler için kullanılan genel bir terimdir. Hücrelerin fenotipik özelliklerine göre sınıflandırılan üç yaygın gliom türü bulunmaktadır. Astrositomlar, beynin destekleyici dokusunu oluşturan astrosit hücrelerinden kaynaklanan tümörlerdir. Dünya Sağlık Örgütü sınıflaması, astrositomları I'den IV'e kadar bir ölçekle derecelendirir. Düşük dereceli tümörler çocuklarda daha yaygınken, yüksek dereceli tümörler ise yetişkinlerde daha sık görülür. Oligodendrogliomlar, miyelin üretimini sağlayan oligodendrosit hücrelerden kaynaklanır. Oligodendrogliomlar en sık genç ve orta yaşlı yetişkinlerde görülür. Düşük dereceli (Derece II) veya yüksek dereceli (Derece III) olabilir. Ependimomlar, beynin içindeki sıvı dolu boşlukları (ventriküller) kaplayan ependimal hücrelerden kaynaklanır. Dünya Sağlık Örgütü sınıflamasına göre, subependimom, miksopapiller ependimom, RELA füzyon pozitif ependimom, klasik ependimom ve anaplastik ependimom olmak üzere beş alt tipi bulunmaktadır. Bu tümörler I, II veya III derecelerinde olabilir (American Brain Tumor Association, 2015; Tufan, 2019). 2021 Dünya Sağlık Örgütü sınıflamasına göre de ependimomlar genetik özellikleri ve bulundukları bölgeye göre üç ana gruba ayrılır: supratentoryal, posterior fossa ve spinal (Louis vd., 2021).

Hipofiz tümörleri, kafa tabanında yer alan sfenoid kemiğin ortasındaki sella turcica adlı kemik yapı içerisinde bulunan hipofiz bezinden köken alan neoplazmlardır ve genellikle iyi huyludurlar. 2022 Dünya Sağlık Örgütü sınıflamasına göre, bu tümörler artık geleneksel olarak kullanılan 'hipofiz adenomları' terimiyle değil, 'hipofiz nöroendokrin tümörleri' (Pituitary Neuroendocrine Tumors – PitNETs) olarak adlandırılmaktadır. PitNET'ler hormon üretilip üretmemelerine bağlı olarak fonksiyonel (hormon salgılayan) ve fonksiyonel olmayan (hormon salgılamayan) olmak üzere iki gruba ayrılır. Çoğu

PitNET, yavaş büyüyen, çevre dokulara invazyon yapmayan ve lokalize kalan iyi huylu tümörlerdir. Ancak bazı agresif tümörler, özellikle kavernöz sinüs veya suprasellar alan gibi komşu yapılara invazyon yapabilir (Casar-Borota vd., 2025; Hatipoglu, 2022; Lenders vd., 2023; Raverot vd., 2018).

Beyindeki anormallikler, erken evrelerde genellikle kemoterapi veya cerrahi gibi tedavi yaklaşımlarına daha duyarlıdır. Bu nedenle, daha etkili bir tedavi süreci için beyin tümörlerinin erken tanısı büyük önem taşır. Ayrıca, tedaviye verilen yanıtın ve tümörün nüks etme durumunun değerlendirilmesi de tedavi sürecinin başarısı açısından kritik öneme sahiptir. Klinik gereksinimlere paralel olarak gelişen ileri düzey nörogörüntüleme tekniklerinin, beyin tümörlerinin hücresel, metabolik ve fonksiyonel özelliklerini ayrıntılı bir şekilde ortaya koyabilmesi, tanı doğruluğunu artırmakta ve bireye özgü tedavi yaklaşımlarının planlanmasına olanak sağlamaktadır. İleri görüntüleme tekniklerinin temelini ise manyetik rezonans görüntüleme oluşturmaktadır. Beyin tümörü incelemelerinde en temel yöntem olan MR'nin diğer tanı yöntemlerine kıyasla çeşitli avantajları vardır. Yumuşak doku kontrastı ile beyin dokuları arasındaki ayrımı net bir şekilde yapar. Yüksek çözünürlüklü ve çok yönlü düzlemlerde görüntüleme sayesinde tümörlerin boyutu, konumu ve şekli daha kapsamlı olarak analiz edilebilir. Ayrıca, MR, küçük veya düşük dereceli beyin tümörlerinin saptanmasında bilgisayarlı tomografiye kıyasla daha yüksek duyarlılığa sahiptir (Villanueva-Meyer vd., 2017; Martucci vd., 2023; Musthafa vd., 2025).

Tıbbi görüntüleme alanındaki teknolojik gelişmeler ve sağlık sektöründeki dijitalleşme süreci, günümüzde tıbbi veri miktarında kayda değer bir artışa neden olmuştur. Bu gelişmelere paralel olarak bilgisayarların işlem gücünde yaşanan ilerlemeler, tıbbi görüntülerden oluşan büyük ve karmaşık veri setlerinin yapay zeka tabanlı yöntemler aracılığıyla daha hızlı ve yüksek doğrulukla analiz edilmesini mümkün kılmıştır. İnsan beynindeki sinir ağlarından esinlenerek geliştirilen derin öğrenme yaklaşımı, makine öğrenmesinin bir alt dalı olarak öne çıkmaktadır. Derin öğrenme modelleri, büyük miktarda tıbbi görüntüyle eğitildiklerinde karmaşık örüntüleri ve özellikleri tanıyabilmektedir. Bu yetenekleri sayesinde söz konusu modeller, farklı tıbbi görüntü işleme görevlerinde etkin bir şekilde kullanılmaktadır. Derin öğrenme modelleri, temelde birbirine bağlı çok katmanlı yapılardan oluşur. Her bir katman, düğüm veya yapay nöron olarak adlandırılan birimleri içerir. Bu katmanlar, kendisinden önceki katmandaki nöronların çıktılarının belirli ağırlıklarla çarpılıp üzerine sapma değeri eklenmesi ve

ardından doğrusal olmayan bir aktivasyon fonksiyonundan geçirilmesiyle çıktı üretir. Modelin ilk katmanı veriyi, son katmanı ise tahmin veya sınıflandırma gibi görevler için çıktıyı temsil eder. Katmanlar arasındaki bu ardışık bilgi işleme süreci, modelin çok boyutlu verilerdeki karmaşık ilişkileri öğrenmesini ve yüksek doğrulukla tahmin yapmasını sağlar (Cai vd., 2020; Kumar vd., 2023; Litjens vd., 2017).

Bu tezde, Figshare veri tabanından elde edilen açık kaynaklı MR görüntüleri kullanılarak, gliom, meningiom ve hipofiz tümörü olmak üzere üç farklı beyin tümörünün sınıflandırılması için derin öğrenme tabanlı bir analiz gerçekleştirilmiştir. Çalışmada, transfer öğrenme yöntemi benimsenmiş ve önceden eğitilmiş derin öğrenme modelleriyle sınıflandırma yapılmıştır. Inception, Xception, VGG, ResNet, DenseNet ve ConvNeXtBase gibi derin sinir ağı mimarileriyle sınıflandırma modelleri geliştirilmiş ve başarıları karşılaştırılmıştır. Ayrıca, daha yüksek doğruluk oranları elde etmek amacıyla, topluluk öğrenme (ensemble learning) tekniklerinden yararlanılarak farklı modellerin tahmin sonuçları birleştirilmiştir. Python programlama dili ve TensorFlow kütüphanesi kullanılarak geliştirilen bu modellerin performansı, doğruluk, hassasiyet, kesinlik ve F-skoru gibi metriklerle değerlendirilmiş ve sonuçlar mevcut literatürle karşılaştırılmıştır.

2. Literatür Taraması

Beyin tümörlerinin sınıflandırılmasına yönelik literatürde, farklı evrişimli sinir ağı mimarileri geliştirilmiş ve bu modeller çeşitli veri kümeleri üzerinde yüksek doğruluk oranlarıyla test edilmiştir. Bu kapsamda yapılan bazı çalışmalar aşağıda özetlenmiştir.

Badža & Barjaktarović (2020) çalışmasında, gliom, meningiom ve hipofiz tümörlerini sınıflandırmak için, Figshare veritabanında yer alan 3.064 T1-kontrastlı MR görüntüsünden oluşan bir veri seti kullanmıştır. Veri artırma yöntemleriyle görüntü sayısı 9.192'ye çıkarılmış ve önerilen 22 katmanlı yeni CNN mimarisi ile %96,56 doğruluk elde edilmiştir. Kibriya vd. (2022), aynı sınıflandırmaya yönelik, 13 katmandan oluşan yeni bir CNN tabanlı yöntem önermiştir. Önerilen yöntem Figshare veri kümesi üzerinde %97,2 doğruluk oranına ulaşırken, çapraz veri kümesi senaryosunda %96,9 doğruluk elde edilmiştir.

Sultan vd. (2019), özel olarak tasarlanmış 16 katmanlı bir CNN mimarisi kullanarak iki farklı sınıflandırma görevi gerçekleştirmiştir. Figshare veritabanından alınan görüntüler veri artırma teknikleriyle 5 katına çıkarılarak 15.320 görüntüye ulaştırılmış ve gliom, meningiom ve hipofiz tümörü sınıflandırmasında %96,13 doğruluk oranına ulaşılmıştır. İkinci olarak, gliomun farklı derecelerini sınıflandırmak amacıyla REMBRANDT (Repository of Molecular Brain Neoplasia Data) veritabanından elde edilen Derece II, Derece III ve Derece IV olmak üzere üç seviyeye ayrılmış toplam 516 MR görüntüsü kullanılmış ve bu görevde %98,7 doğruluk elde edilmiştir.

Kabir Anaraki vd. (2019), gliom tümörlerinin farklı derecelerini sınıflandırmak amacıyla, CNN ile genetik algoritmayı birleştiren bir yöntem önermiştir. Çalışmada, veri artırma teknikleri uygulanarak 8.000 normal MR görüntüsüne ek olarak 4.000 Derece IV, 2.000 Derece III ve 2.000 Derece II olmak üzere toplam 8.000 gliom MR görüntüsü kullanılmıştır. Dört sınıflı sınıflandırma probleminde %93,1 doğruluk elde edilirken, yalnızca gliom derecelerinin sınıflandırılması dikkate alındığında bu oran %90,9 olarak rapor edilmiştir. Ayrıca gerçekleştirilen bir başka vaka çalışmasında, 989 aksiyel MR görüntüsü ve benzer veri artırma teknikleri kullanılarak gliom, meningiom ve hipofiz tümörleri sınıflandırılmış ve %94,2 doğruluk oranına ulaşılmıştır.

Ayadi vd. (2021), 10 evriřim katmanı ieren yeni bir CNN modeli nermiřtir. nerilen model,  farklı aık veri kmesi zerinde deęerlendirilmiřtir. İlk olarak, Figshare veritabanından elde edilen ve meningiom, gliom ile hipofiz tmrlerin sınıflandırılmasını ieren veri kmesi zerinde yapılan deneylerde %94,74 doęruluk oranı elde edilmiřtir. İkinci olarak, tmr derecelerinin sınıflandırılmasındaki performansı deęerlendirmek amacıyla Radiopaedia tabanlı veri kmesi kullanılmış. Derece I–IV olmak zere drt seviyeye ayrılmıř 121 MR grntsnden oluřan veri setindeki grnt sayısı veri artırma teknikleri uygulanarak 2178’e ıkarılmış ve %93,71 doęruluk oranına ulařılmıştır. Son olarak, REMBRANDT kaynaklı veri kmesi kullanılarak astrositom, oligodendrogliom, glioblastom multiforme ve tmr tr bilinmeyen hastaların farklı sınıf sayıları ile sınıflandırması yapılmıřtır.

Tıbbi grnt verilerinin sınırlı olması nedeniyle son dnemlerde derin ęrenme modellerinin etkili eęitimi iin transfer ęrenme teknikleri yoęun řekilde tercih edilmektedir. zellikle, ImageNet gibi byk lekli veri kmeleri zerinde nceden eęitilmiş CNN mimarilerinin, beyin tmr sınıflandırma problemlerine uyarlanması, yksek performans saęlamaktadır. Bu baęlamda, literatrde farklı CNN mimarilerinin transfer ęrenme tabanlı uygulamalarına ynelik alıřmalar gerekleřtirilmiřtir.

Sajjad vd. (2019), Radiopaedia veritabanı kaynaklı Derece I–IV olmak zere drt seviyeye ayrılmıř grntleri ieren veri seti kullanmıřtır. Veri artırma teknikleri uygulanarak her bir MR grntsnden 30 yeni grnt retilmiřtir. nceden eęitilmiş VGG-19 CNN modeli ince ayar (fine-tune) uygulanarak ok dereceli sınıflandırmada %90,67 doęruluk elde edilmiřtir. Ayrıca, nerilen model Figshare kaynaklı MR grntlerinden veri artırma ile elde edilen 91.920 adet gliom, meningiom ve hipofiz tmr grntsnn sınıflandırılmasında kullanılmış ve %94,58 doęruluk oranı elde edilmiřtir.

Rehman vd. (2020), meningiom, gliom ve hipofiz tmrlerini sınıflandırmak amacıyla, Figshare veritabanından elde edilen MR grntlerine transfer ęrenme teknikleri uygulamıřtır. AlexNet, GoogLeNet ve VGG16 olmak zere  farklı CNN mimarisi iin ince ayar ve katman dondurma (layer freezing) yntemleri deęerlendirilmiřtir. Yapılan deneysel alıřmalarda, AlexNet %97,39 ve GoogLeNet %98,04 doęruluk oranlarına ulařırken, en yksek doęruluk oranı %98,69 ile ince ayar yapılan VGG16 mimarisi tarafından elde edilmiřtir. Aamir vd. (2022), aynı kaynaklı veri setine, nceden eęitilmiş

EfficientNet-B0 ve ResNet50 modellerinden elde ettikleri öznitelikleri birleştirerek %98,95 doğruluk oranına ulaşan bir sınıflandırma başarısı elde etmiştir. Deepak ve Ameer (2019), üç tümör tipini sınıflandırmada önceden eğitilmiş GoogLeNet mimarisini kullanmıştır. Önerilen sınıflandırma sistemi, transfer öğrenme yoluyla probleme uyarlanmış ve ortalama %98 doğruluk oranı ile yüksek bir sınıflandırma performansı elde edilmiştir. Raza vd. (2022), aynı sınıflandırma görevi için DeepTumorNet adlı yeni bir model geliştirmiştir. Çalışmada temel olarak GoogLeNet mimarisi esas alınmış; ancak yapı üzerinde çeşitli değişiklikler yapılmıştır. Bu kapsamda, GoogLeNet'in son beş katmanı çıkarılmış ve bunların yerine on beş yeni katman eklenmiştir. Ayrıca modelin ifade gücünü artırmak amacıyla Leaky ReLU aktivasyon fonksiyonu tercih edilmiştir. Geliştirilen model, AlexNet, ResNet50, DarkNet53, ShuffleNet, GoogLeNet, SqueezeNet, ResNet101, ExceptionNet ve MobileNetV2 gibi güncel derin öğrenme tabanlı sınıflandırma modelleriyle karşılaştırıldığında %99,67 doğruluk oranı ile daha yüksek bir başarı elde etmiştir. Babu Vimala vd. (2023), Figshare kaynaklı artırılmış bir veri seti üzerinde, EfficientNetB0'dan EfficientNetB4'e kadar olan önceden eğitilmiş beş farklı EfficientNet modeline, transfer öğrenme tabanlı ince ayar yaklaşımını uygulamış ve modeller üst katmanlar eklenerek yeniden yapılandırılmıştır. Yapılan deneyler sonucunda, ince ayar uygulanmış EfficientNetB2 modeli, %99,06 doğruluk oranı ile en yüksek sınıflandırma performansını göstermiştir. Aziz vd. (2024), aynı sınıflandırma problemi kapsamında önceden eğitilmiş dört derin öğrenme modelini — ResNet, EfficientNet, MobileNet ve DenseNet — transfer öğrenme yöntemiyle değerlendirmiştir. DenseNet, %96 test doğruluğuyla ResNet (%91), EfficientNet (%91) ve MobileNet (%93)'in önünde yer almıştır. DenseNet modelinin genelleme yeteneğini artırmak amacıyla, veri artırımı, nöron atma (dropout), küme normalizasyonu (batch normalization) ve global ortalama havuzlama gibi düzenleme teknikleri ile birlikte hiperparametre optimizasyonu kullanılarak ince ayar uygulanmıştır. Bu geliştirilmiş model %97,1 doğruluk elde etmiştir.

Yang vd. (2018), düşük dereceli gliom (LGG) ve yüksek dereceli gliom (HGG) hastalarını sınıflandırmak amacıyla LGG grubuna ait 368 ve HGG grubuna ait 499 ham MR görüntüsü kullanmıştır. Eğitim verileri veri artırma yöntemiyle 14 kat çoğaltılmıştır. Çalışmada, AlexNet ve GoogLeNet mimarilerine odaklanılmıştır. Her iki model, hem sıfırdan eğitilmiş hem de ImageNet üzerinde önceden eğitilmiş modeller üzerinden transfer öğrenme ve ince ayar uygulanarak MR görüntülerine adapte edilmiştir. Sıfırdan

eđitilen versiyonlar iin AlexNet %85.5 ve GoogLeNet %90.9 dođruluk elde etmiřtir. Transfer renme ve ince ayar yntemleri her iki modelin performansını artırmıř ve sırasıyla %92.7 ve %94.5 dođruluk sađlanmıřtır. Bununla birlikte, GoogLeNet hem sıfırdan eđitildiđinde hem de nceden eđitilmiř model zerinden eđitildiđinde, AlexNet'ten daha yksek performans gstermiřtir.

Tandel vd. (2020), REMBRANDT veritabanından alınan veri setinden beyin tmrlerinin sınıflandırılmasına ynelik beř farklı veri seti tasarlamıřtır. İki sınıflı veri kmesi, MR grntlerini normal ve tmrl olarak ayırmayı hedeflemiřtir.  sınıflı veri kmesinde sınıflandırma normal, dřk dereceli gliom ve yksek dereceli gliom olarak yapılmıřtır. Drt sınıflı veri kmesi, grntleri normal, astrositom (AST), oligodendrogliom (OLI) ve glioblastom multiforme (GBM) olarak ayırmıřtır. Beř sınıflı veri kmesinde, tmrlerin derecelerine gre sınıflandırma yapılmıř olup, veri seti AST (derece 2), AST (derece 3), OLI (derece 2), OLI (derece 3) ve GBM (derece 4) sınıflarından oluřmaktadır. Altı sınıflı veri kmesinde ise beř tmr alt sınıfına ek olarak normal grntler de dahil edilmiřtir. Veri setinin boyutu, veri artırma teknikleri uygulanarak orijinal hacminin  katına ıkarılmıřtır. alıřmada, transfer renme yaklařımı kapsamında nceden eđitilmiř AlexNet mimarisi kullanılmıřtır. Elde edilen sonular, geliřtirilen derin renme modelinin, altı farklı geleneksel makine renmesi modeliyle karřılařtırıldıđında daha yksek performans gsterdiđini ortaya koymuřtur.

Gmez-Guzmn vd. (2023), beyin tmrlerini sınıflandırmak amacıyla hem zgn bir CNN mimarisi hem de eřitli nceden eđitilmiř derin renme modelleri kullanarak kapsamlı bir karřılařtırmalı analiz gerekleřtirmiřtir. alıřmada, gliom, meningiom, hipofiz tmr ve tmr bulunmayan beyin MR grntlerinden oluřan drt sınıflı bir sınıflandırma problemi ele alınmıřtır. MR grntleri, Kaggle zerinde paylařılan ve 7023 grnt ieren bir veri setinden alınmıř, veri artırma teknikleri uygulanarak grnt sayısı 9139'a ıkarılmıřtır. ncelikle 17 katmandan oluřan genel bir CNN mimarisi kullanılmıř, ardından transfer renme yaklařımı kapsamında nceden eđitilmiř derin ađlar ele alınmıřtır. Bu modeller arasında ResNet50, MobileNetV2, Xception, InceptionV3, InceptionResNetV2 ve EfficientNetB0 yer almaktadır. Deneysel sonulara gre, nceden eđitilmiř InceptionV3 modeli, %97,12 ile en yksek dođruluk performansını gstermiřtir. Mathivanan vd. (2024) tarafından gerekleřtirilen alıřmada, aynı sınıflandırma problemi kapsamında kullanılan Kaggle kaynaklı veri setinde model performansını artırmak amacıyla eřitli grnt iyileřtirme teknikleri uygulanmıřtır.

Çalışmada, beyin tümörlerinin MR görüntüleri üzerinden sınıflandırılmasına yönelik transfer öğrenme yöntemlerinin uygulanabilirliği incelenmiştir. Bu kapsamda ResNet152, VGG19, DenseNet169 ve MobileNetV3 olmak üzere dört farklı transfer öğrenme mimarisi değerlendirilmiştir. Elde edilen sonuçlara göre, MobileNetV3 mimarisi %99,75 doğruluk oranı ile en yüksek sınıflandırma başarısını elde etmiştir.

3. Materyal ve Metotlar

Bu bölümde, beyin tümörü sınıflandırmasına yönelik kullanılan yaklaşım sunulmaktadır. İlk olarak, çalışmada kullanılan açık kaynaklı MR görüntülerinden oluşan veri seti tanıtılacaktır. Ardından, meningiom, gliom ve hipofiz tümörlerinin sınıflandırılmasına yönelik olarak kullanılan derin öğrenme tabanlı modeller ele alınacaktır. Bu kapsamda, önceden büyük ölçekli veri kümeleri üzerinde eğitilmiş CNN mimarileri doğrudan transfer öğrenme yöntemiyle, ince ayar yapılmaksızın, yalnızca özellik çıkarımı amacıyla kullanılmıştır. Ayrıca, doğruluk değerlendirme metrikleri ve eğitim süreci de bu bölümde ayrıntılı olarak açıklanacaktır.

3.1 Veri Seti

Bu çalışma kapsamında kullanılan beyin tümörü veri seti, meningiom, gliom ve hipofiz tümörü olmak üzere üç farklı tümör türüne sahip toplam 233 hastadan elde edilen 3064 adet T1-ağırlıklı kontrastlı manyetik rezonans (MR) görüntüsünü içermektedir. Görüntüler, meningiom için 708, gliom için 1426 ve hipofiz tümörü için 930 dilimden oluşmaktadır. Söz konusu veri seti, daha önce Cheng ve arkadaşları tarafından yürütülen çalışmalarda kullanılmıştır (Cheng vd., 2015, 2016). Tüm görüntüler Çin'deki Nanfang Hastanesi (Guangzhou) ve Tianjin Tıp Üniversitesi Genel Hastanesi'nde 2005 ile 2010 yılları arasında elde edilmiştir. Görüntüler, 512×512 piksel çözünürlüğe ve 0.49×0.49 mm² piksel boyutuna sahip iki boyutlu kesitler şeklindedir.

3.2 Evrişimli Sinir Ağları

Evrişimli sinir ağları, görüntü işleme ve bilgisayarla görme (computer vision) alanlarında yaygın olarak kullanılan, güçlü özellik çıkarımı ve sınıflandırma yeteneklerine sahip derin öğrenme mimarileridir. Bu yapılar, genellikle üç temel katmandan oluşur: konvolüsyon katmanı (convolutional layer), havuzlama katmanı (pooling layer) ve tam bağlantılı katman (fully connected layer). Konvolüsyon katmanı, giriş verisine belirli bir deseni tanımaya yönelik çeşitli filtrelerin (çekirdekler) kaydırmalı (sliding) şekilde uygulanmasıyla çalışır. Her bir filtre, girdideki belirli bir özelliği (kenar, doku, şekil gibi) tespit etmeye odaklanır ve bu işlem sonucunda farklı özellik haritaları (feature maps) elde edilir. Parametre paylaşımı ve yerel bağlantılar sayesinde, konvolüsyon katmanları tam bağlantılı yapılara kıyasla çok daha az sayıda öğrenilebilir parametre içerir. Bu özellik,

ağın daha derin ve hesaplama açısından verimli olmasını sağlar (Lecun vd., 1998). Havuzlama katmanı, genellikle konvolüsyon katmanlarının ardından gelir ve özellik haritalarının boyutunu azaltarak hem hesaplama yükünü düşürür hem de modelin özniteliklere karşı daha dayanıklı hale gelmesine katkıda bulunur. En yaygın kullanılan yöntem maksimum havuzlama (max pooling) olup, belirli bir bölgede en yüksek değerin alınması esasına dayanır (Goodfellow vd., 2016). Son aşamada yer alan tam bağlantılı katman, konvolüsyon ve havuzlama katmanlarında çıkarılan öznitelikleri bir araya getirerek sınıflandırma görevini üstlenir. Bu katmanda her nöron, kendisinden önceki katmandaki tüm nöronlarla bağlantılıdır ve genellikle sınıflandırıcı olarak görev yapar. Özellikle softmax aktivasyon fonksiyonu ile birlikte kullanıldığında, çok sınıflı sınıflandırma problemlerinde etkili sonuçlar üretir.

3.3 Transfer Öğrenme

Transfer öğrenme, makine öğrenmesi ve derin öğrenme alanlarında, bir görev veya veri seti üzerinde kazanılan bilginin, ilgili başka bir görevde veya farklı bir veri setinde modelin başarısını artırmak amacıyla kullanılmasıdır. Derin sinir ağlarının büyük miktarda veri gerektirmesi nedeniyle, transfer öğrenme bu modeller için oldukça faydalı bir yaklaşım olarak öne çıkar.

Geleneksel öğrenme yöntemlerinde, her yeni görev için etiketlenmiş veriler kullanılarak sıfırdan yeni bir model oluşturulur. Bu durum, modelin farklı bir veri setine uygulanmasında benzer bir görev bile olsa modelin yeniden eğitilmesini gerektirir. Transfer öğrenme algoritmalarında ise önceden eğitilmiş modellerin veya sinir ağlarının başlangıç noktası olarak kullanılması sayesinde ilk veri setinde kazanılan bilgiler ilgili bir veri setine aktarılır ve yeni görevde daha yüksek başarı sağlanması hedeflenir. Aşağıda, transfer öğrenme alanında yaygın olarak kullanılan ve yüksek performans gösteren bazı önemli sinir ağı mimarileri ele alınacaktır (Géron, 2023).

AlexNet CNN mimarisi, adını geliştiricisi Alex Krizhevsky'den (ve ekip arkadaşları Ilya Sutskever ile Geoffrey Hinton) alır. Bu model, konvolüsyon katmanlarının üzerine havuzlama katmanları eklemek yerine, konvolüsyon katmanlarını doğrudan üst üste dizen ilk yapıdır. Aşırı öğrenmeyi (overfitting) önlemek için eğitim sırasında %50 oranında dropout uygulanmış ve eğitim görüntülerine veri artırımı (data augmentation) yapılmıştır. Ayrıca, ReLU aktivasyon fonksiyonundan sonra yerel yanıt normalizasyonu kullanılarak, en güçlü nöronların çevresindekileri baskılaması sağlanmış; bu sayede farklı özelliklerin

daha iyi öğrenilmesi ve modelin genelleme yeteneğinin artması hedeflenmiştir (Krizhevsky vd., 2012; Géron, 2023).

ResNet (Residual Network), Kaiming He ve çalışma arkadaşları tarafından geliştirilmiştir. 34, 50, 101 ve 152 katmanlı varyantları bulunmaktadır. Bu mimari, derin sinir ağlarının artan katman sayısına rağmen parametre sayısını kontrol altında tutarak yüksek performans elde edebileceğini göstermiştir. ResNet'in temel başarısı, öğrenmeyi derinleştirmeyi mümkün kılan atlama/kısa yol bağlantısı (skip connection) mekanizmasına dayanır. Bu yapıda, bir katmanın girdisi doğrudan daha sonraki katmanın çıktısına eklenir; böylece ağ, doğrudan hedef fonksiyonu öğrenmek yerine, bu fonksiyon ile giriş arasındaki farkı, yani artık (residual) fonksiyonu modellemeye odaklanır. Bu yöntem, özellikle derin ağlarda sıkça karşılaşılan gradyan sönümlenmesi (vanishing gradient) probleminin önüne geçilmesini sağlar ve böylece ağ daha stabil ve hızlı biçimde eğitilebilir. ResNet mimarisi, bu yaklaşımı uygulamak üzere yapılandırılmış artık birim (residual unit) blokları etrafında inşa edilmiştir. Her bir artık birim, küme normalizasyonu, ReLU aktivasyonu ve 3×3 boyutunda filtreler kullanan iki adet konvolüsyon katmanından oluşur. Katmanlar arasında havuzlama yerine adımlı konvolüsyonlar tercih edilir. Girdi ile çıktı boyutları uyuşmadığında ise, boyutsal uyum sağlamak için 1×1 konvolüsyon katmanları kullanılır. ResNet-152, daha derin bir ağ olduğundan, artık birimleri daha verimli hale getirmek için darboğaz katmanı (bottleneck layer) kullanır. Bu yapıda, her artık birim, ilk olarak 64 özellik haritasına sahip bir 1×1 konvolüsyon katmanı, ardından 64 özellik haritası kullanan bir 3×3 konvolüsyon katmanı ve son olarak 256 özellik haritasına sahip bir 1×1 konvolüsyon katmanı içerir (He vd., 2016; Géron, 2023).

VGGNet, Oxford Üniversitesi'ndeki Visual Geometry Group (VGG) araştırma laboratuvarından Karen Simonyan ve Andrew Zisserman tarafından geliştirilmiştir. Mimari, 2 veya 3 konvolüsyon katmanı ile bir havuzlama (pooling) katmanının ardışık olarak tekrarlandığı oldukça basit ve klasik bir yapıya sahiptir. VGG varyantına bağlı olarak toplamda 16 veya 19 konvolüsyon katmanına ulaşılır. Son aşamada ise 2 gizli katmanlı tam bağlı bir ağ ve çıkış katmanı yer alır. Model, çok sayıda küçük boyutlu (3×3) konvolüsyon filtreleri kullanır (Simonyan & Zisserman, 2015; Géron, 2023).

GoogleNet (Inception) mimarisi, Google Research'ten Christian Szegedy ve ekibi tarafından geliştirilmiştir. Önceki CNN'lere kıyasla çok daha derin bir yapıya sahip olan

bu mimari, parametreleri çok daha verimli kullanan inception modülleri içerir. Inception modülleri, farklı boyutlardaki (1×1 , 3×3 , 5×5) konvolüsyon katmanlarını paralel çalıştırarak çok ölçekli özellik çıkarımı sağlar ve 1×1 konvolüsyonlar aracılığıyla kanal boyutunda boyut indirger, böylece hesaplama maliyetini düşürür. Tüm katmanlarda kaydırma değeri 1 ve uygun kenar doldurma (padding) kullanılır; bu sayede çıktıların boyutları girişle eşitlenir. Ağ, yüksek çözünürlüklü girişleri önce birkaç katmanla küçültür, ardından dokuz inception modülü ve aralarındaki havuzlama katmanlarından oluşan derin bir yapıdan geçer. Global ortalama havuzlama katmanı mekânsal bilgiyi azaltarak tam bağlantılı katman ihtiyacını ortadan kaldırır, böylece parametre sayısı ve aşırı öğrenme riski azalır. GoogLeNet'in ardından Google araştırmacıları, Inception-v3 ve Inception-v4 gibi varyantlar geliştirerek inception modüllerini optimize etmiş ve performansı artırmıştır (Szegedy vd., 2015, 2016, 2017; Géron, 2023).

Xception mimarisi, François Chollet tarafından 2016 yılında geliştirilen ve GoogLeNet ile ResNet yaklaşımlarını birleştiren derin öğrenme modelidir. Inception modülleri yerine derinlik ayrılabilir (depthwise separable) konvolüsyon katmanları kullanarak mekânsal ve kanal arası özellik çıkarımını ayrı ayrı gerçekleştirir. Normal konvolüsyon katmanlarının mekânsal ve kanal arası desenleri aynı anda yakalamasının yerine, Xception önce her bir girdi özellik haritasına tek bir mekânsal filtre uygular, ardından 1×1 konvolüsyonla kanal arası ilişkileri modeller. Mimari, girişte iki standart konvolüsyon katmanı ile başlar ve devamında ayrılabilir konvolüsyonlar ile havuzlama katmanları kullanır. Bu yöntem, Inception modüllerinin mekânsal ve kanal arası desenleri birlikte işleme yaklaşımına kıyasla daha üstün performans gösterir (Chollet, 2017; Géron, 2023).

EfficientNet, Google Brain araştırmacıları Mingxing Tan ve Quoc V. Le tarafından geliştirilmiştir. Evrişimli sinir ağlarının performansını artırmak amacıyla, modeli daha derin, daha geniş ve daha yüksek çözünürlüklü girişlerle dengeli biçimde ölçeklendirmeyi hedefleyen yenilikçi bir mimaridir. Bu yapı, hesaplama kaynaklarının daha verimli kullanılmasını sağlayan bileşik ölçeklendirme yöntemi ile öne çıkar. Araştırmacılar, küçük ölçekli bir temel model olan EfficientNetB0 üzerinde sinirsel mimari arama yöntemiyle en uygun yapılandırmayı belirlemiş, ardından bu yapı temel alınarak farklı hesaplama kapasitelerine göre optimize edilmiş daha büyük versiyonlar geliştirilmiştir. Bu süreç sonucunda EfficientNetB1'den EfficientNetB7'ye kadar uzanan ve giderek artan kapasiteye sahip modeller oluşturulmuştur (Tan & Le, 2020; Géron, 2023). Ayrıca, EfficientNet'in bir sonraki nesli olan EfficientNetV2, daha hızlı eğitim süreleri ve daha

düşük parametre sayıları ile daha yüksek performans elde etmeye yönelik geliştirilmiştir (Tan & Le, 2021).

DenseNet, 2017 yılında Gao Huang, Zhuang Liu, Laurens van der Maaten ve Kilian Q. Weinberger tarafından geliştirilen, derin sinir ağlarında bilgi akışını ve gradyan yayılımını iyileştirmeyi amaçlayan yenilikçi bir evrişimli sinir ağı mimarisidir. Bu mimarinin temel özelliği, her katmanın çıktısını kendisinden sonraki tüm katmanlara doğrudan girdi olarak sağlamasıdır. Böylece, modelde veri ve gradyan akışı güçlendirilirken, parametre verimliliği de artar. DenseNet, birkaç yoğun bağlantılı konvolüsyon katmanından oluşan birden fazla yoğun bloktan meydana gelir. “Yoğun bağlantılı” teriminden kasıt, her katmanın çıktısının, aynı blok içindeki kendisinden sonraki tüm katmanlara doğrudan iletilmesidir; bu sayede, bir bloktaki herhangi bir katman, kendisinden önceki katmanların çıktılarının derinlemesine birleştirilmiş haliyle beslenir. Yoğun bloklar arasında yer alan geçiş katmanları modelin boyutunu ve karmaşıklığını kontrol altında tutar (Huang vd., 2017; Géron, 2023).

ConvNeXt, 2022 yılında Liu ve arkadaşları tarafından önerilen, klasik CNN mimarilerinin optimize edilmesini amaçlayan bir modeldir. Bu mimari, özellikle ResNet yapısının temel bileşenlerinden faydalanarak geliştirilmiş ve Vision Transformer (ViT) tabanlı mimarilerden alınan yapısal iyileştirmelerle güçlendirilmiştir. ConvNeXt, geleneksel CNN'lerin verimli özellik çıkarımı ve yerel öğrenme kapasitelerini korurken, Transformer tabanlı yapılarla yaygın olarak kullanılan katman normalizasyonu (Layer Normalization), GELU aktivasyon fonksiyonu, genişletilmiş çekirdek boyutları, derinlik bazlı konvolüsyon yapıları ve tersine çevrilmiş darboğaz (inverted bottleneck) gibi bileşenlerle performans artışı sağlamaktadır. Ayrıca, modelin giriş aşamasında kullanılan yama (patch) temelli giriş katmanı stratejisi, Transformer tabanlı mimarilerde sıklıkla görülen yama temelli işleme yaklaşımını CNN yapısına entegre etmektedir (Liu vd., 2022).

3.4 Topluluk Öğrenme

Bireysel makine öğrenmesi modellerinin farklı hata yapma eğiliminde olması, bu modellerin çıktılarının doğru bir şekilde birleştirilmesi durumunda genel tahmin doğruluğunun artırılabilceğini göstermektedir. Bu temel yaklaşıma dayanan topluluk öğrenmesi, birden fazla makine öğrenmesi algoritmasının bir araya getirilerek daha güçlü

ve kararlı modellerin oluşturulmasını amaçlayan bir yaklaşımdır (Dietterich, 2000; Géron, 2023).

En yaygın kullanılan topluluk öğrenme teknikleri arasında Torbalama (bagging), Güçlendirme (boosting) ve Yığınlama (stacking) yer almaktadır. Torbalama yöntemi, eğitim verisinden yerine koyarak rastgele alt kümeler oluşturulması ve her bir alt küme üzerinde modellerin ayrı ayrı eğitilmesi prensibine dayanır. Güçlendirme, birden fazla modelin sıralı şekilde eğitilerek, her yeni modelin önceki modellerin hatalarını dikkate alması prensibine dayanan bir topluluk öğrenme yöntemidir. Bu yaklaşımda, ilk model veriler üzerinde eğitildikten sonra, her yeni model, önceki modelin hata yaptığı örnekler üzerinde daha fazla odaklanarak eğitilir. Yığınlama yönteminde ise farklı türden makine öğrenmesi algoritmaları bir araya getirilerek daha yüksek doğruluk sağlayan bir model oluşturulur. Bu yöntemde, farklı temel modeller aynı eğitim verisi üzerinde bağımsız olarak eğitilir ve bu modellerin tahminleri, bir üst düzey modele giriş olarak verilir. Üst model, bu tahminleri kullanarak eğitilir ve nihai tahmini üretir (Géron, 2023).

Topluluk öğrenmesinde, birden fazla modelin tahmin çıktılarının birleştirilmesi için çeşitli oylama stratejileri kullanılmaktadır. Bu stratejilerden biri olan çoğunluk oylaması (hard voting), her modelin tahminini bir oy olarak kabul eder ve tüm modeller arasından en fazla oyu alan sınıfı son tahmin olarak belirler. Alternatif bir oylama stratejisi ise olasılıksal oylama (soft voting) yöntemidir. Olasılıksal oylamada, her modelin sınıflara ilişkin tahmin ettiği olasılık değerleri dikkate alınır. Modellerin verdiği olasılıklar ortalanarak, en yüksek ortalama olasılığa sahip sınıf son karar olarak seçilir. Bu yöntem, modellerin güvenini ve belirsizliğini dikkate alarak daha hassas tahminler elde edilmesini sağlar (Géron, 2023).

3.5 Performans Değerlendirme Metrikleri

Sınıflandırma modellerinin performansını değerlendirmek amacıyla, modelin tahmin sonuçları ile gerçek değerler arasındaki ilişki dört temel kategori altında incelenmektedir (Başarslan, 2025).

Gerçek Pozitif (True Positive, TP): Modelin pozitif olarak tahmin ettiği ve gerçekte de pozitif olan örneklerin sayısıdır.

Gerçek Negatif (True Negative, TN): Modelin negatif olarak tahmin ettiği ve gerçekte de negatif olan örneklerin sayısıdır.

Yanlış Pozitif (False Positive, FP): Modelin pozitif olarak tahmin ettiği ancak gerçekte negatif olan örneklerin sayısıdır. Bu durum, Tip I hata olarak da adlandırılır.

Yanlış Negatif (False Negative, FN): Modelin negatif olarak tahmin ettiği ancak gerçekte pozitif olan örneklerin sayısıdır. Bu durum, Tip II hata olarak da bilinir.

Bu dört temel kategoriye dayanarak, sınıflandırma modelinin performansını ölçmek amacıyla çeşitli metrikler hesaplanmaktadır.

Doğruluk (Accuracy): Modelin tüm sınıflandırmalar içerisindeki doğruluk oranını ifade eden bu metrik, modelin doğru tahmin ettiği örneklerin toplam örnek sayısına oranı şeklinde hesaplanır (Başarslan, 2025):

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN}$$

Kesinlik (Precision): Modelin pozitif tahminlerin ne kadarının doğru olduğunu gösteren metrik, gerçekten pozitif olan tahminlerin tüm pozitif olarak tahmin edilen örneklerle oranı şeklinde ifade edilir (Başarslan, 2025):

$$\text{Kesinlik} = \frac{TP}{TP + FP}$$

Özgüllük (Specificity): Modelin negatif örnekleri hangi oranda doğru tanıdığını gösteren metrik, gerçek negatiflerin toplam negatif örnekler içindeki oranı olarak hesaplanır (Başarslan, 2025):

$$\text{Özgüllük} = \frac{TN}{TN + FP}$$

Duyarlılık (Sensitivity) / Recall (Geri Çağırma): Modelin gerçek pozitif örnekleri ne ölçüde doğru tespit ettiğini gösteren metrik, doğru tahmin edilen pozitif örneklerin pozitif sınıfa ait toplam gerçek örneklerle oranı şeklinde ifade edilir (Başarslan, 2025):

$$\text{Duyarlılık} = \frac{TP}{TP + FN}$$

F1 skoru: Sınıflandırma modellerinde kesinlik ve duyarlılık metriklerini birlikte dikkate alan dengeleyici bir performans ölçütüdür. F1 skoru, kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır (Tharwat, 2021):

$$F_1 = \frac{2 \cdot TP}{2 \cdot TP + FP + FN}$$

Hem yanlış pozitifler hem de yanlış negatifler dikkate alınarak modelin sınıflandırma başarısı daha kapsamlı bir şekilde değerlendirilebilir. Özellikle sınıflar arasında dengesizlik olduğunda F1 skoru, tek başına doğruluk gibi metriklere göre daha anlamlı sonuçlar sunar. Çok sınıflı sınıflandırma problemlerinde F1 skoru her bir sınıf için ayrı ayrı hesaplanır ve sonuçlar makro ortalama, mikro ortalama veya ağırlıklı ortalama yöntemleriyle birleştirilerek genel bir skor elde edilir.

F2 skoru: Sınıflandırma problemlerinde modelin kesinlik ve duyarlılık metriklerini birlikte değerlendiren, ancak duyarlılık değerine daha fazla ağırlık veren bir ölçüttür. Özellikle yanlış negatiflerin daha kritik olduğu uygulamalarda daha hassas bir değerlendirme sunar. Aşağıdaki formül ile hesaplanır (Tharwat, 2021):

$$F_2 = \frac{5 \cdot TP}{5 \cdot TP + 4 \cdot FN + FP}$$

Çok sınıflı sınıflandırma problemlerinde F2 skoru her bir sınıf için ayrı ayrı hesaplanır ve elde edilen skorlar, genel bir performans değeri elde etmek amacıyla makro ortalama, mikro ortalama veya ağırlıklı ortalama yöntemlerinden biri kullanılarak birleştirilir.

MCC (Matthews Correlation Coefficient): Doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif değerlerini birlikte dikkate alarak modelin tahminleri ile gerçek sınıflar arasındaki korelasyonu ölçer. Hem pozitif hem de negatif sınıflardaki hataları hesaba kattığı için özellikle sınıf dağılımının dengesiz olduğu durumlarda güvenilir sonuçlar verir. -1 ile +1 arasında değer alır; +1 mükemmel sınıflandırmayı, 0 rastgele tahmini, -1 ise tamamen hatalı bir sınıflandırmayı ifade eder (Tharwat, 2021).

ROC (Receiver Operating Characteristic) eğrisi ve AUC (Area Under the Curve) değeri: ROC eğrisi, bir sınıflandırma modelinin farklı eşik değerlerinde pozitif sınıfı ne kadar iyi ayırt ettiğini görselleştiren bir grafikdir. Bu egride yatay eksen FP oranını, dikey eksen ise TP oranını gösterir. Modelin eşik değeri değiştikçe bu iki oran arasındaki ilişki çizilerek modelin genel performansı hakkında fikir edinilir. Eğrinin altında kalan alan ise AUC olarak adlandırılır ve modelin sınıflandırmadaki genel başarısını sayısal bir değerle ifade eder. AUC değerinin 1'e yakın olması modelin mükemmel yakın performans gösterdiği, 0.5'e yakın olması modelin sınıflandırma yeteneğinin zayıf olduğu anlamına gelir (Tharwat, 2021).

Karışıklık Matrisi (Confusion matrix): Modelin her sınıf için ne kadar doğru veya yanlış tahmin yaptığını özetleyen bir matristir. İkili sınıflandırmada TP, TN, FP ve FN

olmak üzere dört bileşenden oluşur. Çok sınıflı problemler için karışıklık matrisi, her sınıf için doğru ve yanlış tahminlerin gösterildiği daha büyük boyutlu bir kare matris şeklinde olur. Satırlar gerçek sınıfları, sütunlar ise modelin tahmin ettiği sınıfları temsil eder. Bu matris sayesinde modelin hangi sınıflarda hata yaptığı açıkça görülebilir ve bu bilgiler doğrultusunda kesinlik, duyarlılık ve F1 skoru gibi detaylı performans metrikleri hesaplanabilir (Tharwat, 2021).

3.6 Deneysel Kurulum

Modelin eğitim süreci Google Colab ortamında gerçekleştirilmiştir. Transfer öğrenme yaklaşımı ile ImageNet üzerinde önceden eğitilmiş ConvNeXtBase, DenseNet169, DenseNet201, InceptionV3, ResNet50V2, ResNet101V2, ResNet152V2, VGG16, VGG19 ve Xception modelleri kullanılmıştır. Modellerin üstüne tam bağlantılı katmanlar eklenerek küme veya katman normalizasyonu uygulanmış, ardından önce taban modeller dondurularak sınıflandırıcı katmanlar eğitilmiş, daha sonra son katmanlar ince ayar ile yeniden eğitilmiştir. Eğitim sırasında erken durdurma ve öğrenme oranı azaltma gibi tekniklerle aşırı öğrenme engellenmeye çalışılmıştır. Veri kümesi, modelin genel performansını değerlendirebilmek amacıyla önce %80 eğitim ve %20 test oranında veri seti ayırma yöntemi ile ikiye ayrılmıştır. Test setinde modellerin doğruluk, kesinlik, duyarlılık, F1 ve F2 skorları, özgüllük ve MCC gibi performans metrikleri hesaplanmıştır. Ayrıca her model için karışıklık matrisi çıkarılarak sınıf bazlı doğru ve yanlış sınıflandırmalar detaylı şekilde analiz edilmiştir. Buna ek olarak, modelin daha sağlam ve güvenilir sonuçlar vermesi amacıyla 5 katlı çapraz doğrulama yöntemi de uygulanmıştır. Bu sayede model, verinin farklı alt kümeleri üzerinde eğitilerek daha istikrarlı ve önyargıdan arındırılmış performans ölçümleri elde edilmiştir.

4. Bulgular

Çalışmada, modellerin performansları hem %80 eğitim ve %20 test oranına sahip veri kümesi üzerinde hem de 5 katlı çapraz doğrulama yöntemi kullanılarak değerlendirilmiştir. 5 katlı çapraz doğrulama, her modelin farklı veri alt kümeleriyle eğitilmesini ve test edilmesini sağlayarak, daha tutarlı ve genellenebilir sonuçlar elde edilmesine olanak tanımaktadır.

Tablo 1: %80 eğitim ve %20 test ayrımında modellerin sınıflandırma performansları

Model	Doğruluk	Kesinlik	Özgüllük	Duyarlılık	F1	F2	MCC
ConvNeXtBase	93.96	93.92	96.83	93.96	93.90	93.96	0.908
DenseNet169	94.78	94.78	97.44	94.78	94.76	94.78	0.920
DenseNet201	93.64	93.77	97.09	93.64	93.66	93.66	0.903
InceptionV3	90.38	90.20	94.83	90.38	90.24	90.34	0.852
ResNET50V2	94.94	94.90	97.16	94.94	94.91	94.93	0.922
ResNET101V2	95.76	95.86	98.10	95.76	95.78	95.78	0.935
ResNET152V2	92.66	92.59	95.91	92.66	92.61	92.65	0.887
VGG16	98.86	98.86	99.32	98.86	98.85	98.86	0.983
VGG19	98.21	98.21	99.14	98.21	98.21	98.21	0.973
Xception	92.82	92.79	95.90	92.82	92.78	92.82	0.890


Tablo 1, %80 eğitim ve %20 test oranı ile ayrılmış veri seti üzerinde farklı transfer öğrenme tabanlı modellerin beyin tümörü sınıflandırma performanslarını kapsamlı bir şekilde ortaya koymaktadır. Genel olarak modeller yüksek doğruluk ve dengeli performans metriklerine ulaşmış olsa da, aralarında performans farkları gözlemlenmiştir. Elde edilen sonuçlara göre, VGG16 modeli %98.86 doğruluk, %98.86 duyarlılık, %99.32 özgüllük ve 0.983 MCC değeri ile en yüksek ve dengeli performansı sergilemiştir. Benzer şekilde, VGG19 modeli %98.21 doğruluk ve 0.973 MCC değeriyle yüksek bir başarı elde etmiştir. Bu bulgular, VGG16 ve VGG19 modellerinin medikal görüntü sınıflandırmasında güçlü bir genelleme kapasitesine sahip olduğunu göstermektedir. ResNet mimarilerinden ResNet101V2 ve ResNet50V2, sırasıyla %95.76 ve %94.94 doğruluk ile 0.935 ve 0.922 MCC değerlerine ulaşarak üç sınıf arasında dengeli bir

performans ortaya koymuştur. Bununla birlikte, aynı mimari ailesine ait olan ResNet152V2 modeli, %92.66 doğruluk ve 0.887 MCC değeri ile diğer ResNet varyantlarına kıyasla daha düşük performans sergilemiştir. Bu sonuçlar, ResNet152V2'nin dengesiz veri setinde özellikle azınlık sınıflarını ayırt etme konusunda diğer varyantlara göre daha az etkili olduğunu ortaya koymaktadır. DenseNet169 ve DenseNet201 modellerinde ise sırasıyla %94.78 ve %93.64 doğruluk ile 0.920 ve 0.903 MCC değerleri elde edilmiştir. Bu sonuçlar, mimarilerin dengesiz ve çok sınıflı veri setlerinde istikrarlı ve tatmin edici bir performans sergilediğini işaret etmektedir. ConvNeXtBase modeli, %93.96 doğruluk ve 0.908 MCC değeriyle rekabetçi bir performans sunmakla birlikte, VGG ve ResNet ailesine kıyasla bir miktar geride kalmıştır. Öte yandan, InceptionV3 ve Xception modelleri daha düşük doğruluk (%90.38 ve %92.82) ve MCC değerleriyle (0.852 ve 0.890) mevcut veri setinde sınıflar arası ayrımı yeterince etkili yapamadığını ve diğer modellere kıyasla genel performans açısından geride kaldığını ortaya koymaktadır.


Şekil 1, %80 eğitim ve %20 test ayırımında modellerin beyin tümörü sınıflandırması için elde edilen karışıklık matrislerini göstermektedir. Bu veriler, modellerin sınıflar arasındaki ayırım yeteneklerinin anlaşılmasını sağlar. VGG16 ve VGG19 modelleri, tümör sınıflarını ayırt etmede en başarılı performansı göstermektedir. Hem TP sayıları yüksek hem de FP ve FN değerleri oldukça düşüktür. ResNet101V2 ve ResNet50V2 modelleri de güçlü performans sergilemektedir. TP değerleri yüksek olup, FP ve FN sayıları VGG modellerine kıyasla biraz daha fazla olsa da, genel olarak sınıflar arası ayrımı etkili yapabilmektedir. DenseNet169 ve DenseNet201 modellerinin ise TP değerleri yüksek olmakla beraber, FP ve FN sayıları VGG ve ResNet modellerine göre biraz daha fazladır.

Tablo 2, %80 eğitim ve %20 test ayırımıyla oluşturulan veri setinde farklı topluluk öğrenme yöntemlerinin beyin tümörü sınıflandırma performanslarını göstermektedir. Burada, bireysel modellerin performanslarını aşan çeşitli model kombinasyonları ve iki farklı oylama stratejisi (çoğunluk oylama ve olasılıksal oylama) karşılaştırılmıştır. VGG16 ve VGG19 ikilisi her iki oylama yönteminde de en yüksek performansa ulaşmıştır. Çoğunluk oylamada %99.02 doğruluk ve 0.985 MCC, olasılıksal oylamada ise %98.86 doğruluk ve 0.983 MCC ile güçlü ve tutarlı sonuçlar elde edilmiştir. Bu, benzer mimarilerin topluluk içinde birbirini tamamlayarak hataları azaltabildiğine işaret etmektedir. ResNet101V2 ve VGG16 ikilisi olasılıksal oylama ile %98.53 doğruluk ve 0.978 MCC'ye ulaşarak ResNet101V2'den iyi performans sergilemiştir.

Şekil 1: %80 eğitim ve %20 test ayırımında modellerin karışıklık matrisleri



Şekil 1: %80 eğitim ve %20 test ayırımında modellerin karışıklık matrisleri (devamı)




Üçlü model kombinasyonlarında ise, VGG16, DenseNet169 ve ResNet101V2 ile yapılan topluluk öğrenme hem çoğunluk hem de olasılıksal oylamada yaklaşık %98.5 doğruluk ve 0.978 MCC ile benzer performanslar göstermiştir. Buna karşın, VGG16, VGG19 ve ResNet101V2 üçlüsünde çoğunluk oylama %99.02 doğruluk ve 0.985 MCC ile en yüksek değeri yakalarken, olasılıksal oylama biraz daha düşük (%98.37 doğruluk, 0.975 MCC) sonuç vermiştir.


Tablo 2: %80 eğitim ve %20 test ayırımında topluluk öğrenme performansları

Model	Doğruluk	Kesinlik	Özgüllük	Duyarlılık	F1	F2	MCC
Çoğunluk oylama (ResNet101V2+ VGG16)	97.23	97.49	99.03	97.23	97.26	97.28	0.959
Olasılıksal oylama (ResNet101V2+ VGG16)	98.53	98.55	99.37	98.53	98.53	98.53	0.978
Çoğunluk oylama (VGG16+VGG19)	99.02	99.06	99.66	99.02	99.02	99.03	0.985
Olasılıksal oylama (VGG16+VGG19)	98.86	98.86	99.50	98.86	98.86	98.86	0.983
Çoğunluk oylama (VGG16+ DenseNet169+ ResNet101V2)	98.53	98.53	99.30	98.53	98.53	98.53	0.978
Olasılıksal oylama (VGG16+ DenseNet169+ ResNet101V2)	98.53	98.54	99.27	98.53	98.53	98.53	0.978
Çoğunluk oylama (VGG16+ VGG19+ ResNet101V2)	99.02	99.02	99.51	99.02	99.02	99.02	0.985
Olasılıksal oylama (VGG16+ VGG19+ ResNet101V2)	98.37	98.38	99.25	98.37	98.37	98.37	0.975

Şekil 2: %80 eğitim ve %20 test ayırımında topluluk öğrenme karışıklık matrisleri



Şekil 2: %80 eğitim ve %20 test ayırımında topluluk öğrenme karışıklık matrisleri (devamı)



Şekil 2, topluluk öğrenme yöntemlerine ait karışıklık matrislerini göstermektedir. VGG16 ve VGG19 modellerinin çoğunluk oylama ile oluşturduğu yapı, üç tümör türü için neredeyse hatasız sınıflandırma yaparak en iyi performansı sergilemiştir. Bu yapı, Meningiom ve Hipofiz sınıflarında sıfır FN değeri ve Gliom sınıfında yalnızca altı FN değeriyle duyarlılık açısından oldukça güçlü bir sonuç ortaya koymuştur. Bununla birlikte, VGG16, VGG19 ve ResNet101V2 modellerinden oluşan çoğunluk oylama yapısı da benzer şekilde yüksek başarı göstermiş, tüm sınıflarda düşük FN ve FP değerleriyle dengeli bir sınıflandırma sağlamıştır.

Tablo 3, 5 katlı çapraz doğrulama sonuçlarına göre hem bireysel modellerin hem de topluluk öğrenme yöntemlerinin sınıflandırma performanslarını göstermektedir. VGG16 ve VGG19 modelleri, ResNet101V2 ve DenseNet169 gibi diğer güçlü transfer öğrenme tabanlı mimarilere kıyasla daha yüksek sınıflandırma performansları sergilemiştir. Özellikle VGG19 modeli, %97.62 doğruluk ve 0.963 MCC değeri ile en başarılı bireysel model olmuştur. VGG16 da %96.90 doğruluk ve 0.952 MCC değeriyle yüksek sonuçlar vermiştir. Bu iki modelin çoğunluk oylaması ile birleşiminde %97.00 doğruluk ve 0.954 MCC, olasılıksal oylama ile ise %97.58 doğruluk ve 0.962 MCC elde edilmiştir. Üçlü yapı olan VGG16, VGG19 ve ResNet101V2'nin olasılıksal oylama yöntemiyle oluşturulan birleşiminde %97.81 doğruluk ve 0.966 MCC değeri ile en yüksek

performans kaydedilmiştir. Bu bulgular, olasılıksal oylama yöntemlerinin genellikle daha yüksek doğruluk ve MCC gibi dengeli metriklerde üstünlük sağladığını göstermektedir.

Tablo 3: 5 katlı çapraz doğrulama ile sınıflandırma performansları

Model	Doğruluk	Kesinlik	Özgüllük	Duyarlılık	F1	F2	MCC
DenseNet169	93.31	93.51	97.03	93.31	93.36	93.35	0.896
ResNet101V2	94.52	94.53	97.12	94.52	94.51	94.52	0.914
VGG16	96.90	96.92	98.42	96.90	96.90	96.90	0.952
VGG19	97.62	97.65	98.91	97.62	97.62	97.62	0.963
Çoğunluk oylama (VGG16+VGG19)	97.00	97.14	98.82	97.00	97.03	97.03	0.954
Olasılıksal oylama (VGG16+VGG19)	97.58	97.60	98.90	97.58	97.59	97.59	0.962
Çoğunluk oylama (VGG16+ VGG19+ ResNet101V2)	97.68	97.71	98.98	97.68	97.69	97.69	0.964
Olasılıksal oylama (VGG16+ VGG19+ ResNet101V2)	97.81	97.84	99.04	97.81	97.82	97.82	0.966

Tablo 4’de, literatürde önerilmiş çeşitli sınıflandırma modellerinin performans metrikleri ile bu tez kapsamında geliştirilen modelin sonuçları karşılaştırmalı olarak sunulmuştur. Geliştirilen model, hem %80 eğitim - %20 test bölünmesiyle hem de 5 katlı çapraz doğrulama yöntemiyle değerlendirildiğinde literatürdeki pek çok çalışmadan daha yüksek performans sergilemiştir.

Tablo 4 : Literatürdeki yöntemlerle önerilen yöntemin performans karşılaştırması

Model	Doğruluk	Kesinlik	Özgüllük	Duyarlılık	F1
Badža & Barjaktarović (2020)	97.39	95.44		96.94	96.11
Kibriya vd. (2022)	97.2	0.97		0.96	
Ayadi vd. (2021)	94.74				
Sajjad vd. (2019)	94.58		96.12	88.41	
Rehman vd. (2020)	98.69				
Aamir vd. (2022)	98.95				
Deepak ve Ameer (2019)	97.1				
Raza vd. (2022)	99.67	99.6		100	99.66
Babu Vimala vd. (2023)	99.06	98.73		99.13	98.79
Aziz vd. (2024)	97.10	0.97		0.97	0.97
Önerilen	99.02	99.06	99.66	99.02	99.02

5. Sonuç

Bu tez kapsamında gerçekleştirilen çalışma, beyin tümörlerinin sınıflandırılmasında derin öğrenme tabanlı yöntemlerin etkinliğini incelemeyi amaçlamıştır. Figshare veri tabanından elde edilen manyetik rezonans görüntüleri kullanılarak gliom, meningiom ve hipofiz tümörü olmak üzere üç farklı tümör türü sınıflandırılmıştır. Çalışmada, transfer öğrenme tabanlı modellerin performansları, hem %80 eğitim - %20 test veri oranı ile yapılan değerlendirme ile hem de 5 katlı çapraz doğrulama yöntemiyle analiz edilmiştir. Elde edilen sonuçlar şöyledir:

- %80 eğitim - %20 test veri ayırımında, VGG16 modeli %98,86 doğruluk, %98,85 F1-skoru ve 0,983 MCC ile, VGG19 modeli ise %98,21 doğruluk, %98,21 F1-skoru ve 0,973 MCC ile en yüksek performansları göstermiştir.
- Aynı veri ayırımında, çoğunluk oylama yöntemi ile yapılan topluluk öğrenmede VGG16+VGG19 ve VGG16+VGG19+ResNet101V2 modelleri %99,02 doğruluk, %99,02 F1-skoru ve yaklaşık 0,98 MCC ile yüksek performans sergilemiştir.
- 5 katlı çapraz doğrulama sonuçlarına göre, VGG16+VGG19+ResNet101V2 topluluk öğrenme yöntemi, olasılıksal oylama ile %97,81 doğruluk, %97,82 F1-skoru ve 0,966 MCC ile en yüksek performansı göstermiştir.

Çalışmada elde edilen bulgular, topluluk öğrenme yöntemlerinin bireysel modellere kıyasla performans artışı sağladığını ortaya koymuştur. Elde edilen sonuçlar, özellikle sınıf dengesizliği içeren veri kümelerinde ve hata toleransının düşük olduğu tıbbi görüntüleme gibi alanlarda topluluk yaklaşımlarının tercih edilmesini desteklemektedir.

Gelecekteki çalışmalarda, bu çalışmada uygulanan oylama tabanlı topluluk öğrenme yöntemine ek olarak, torbalama ve yığınlama gibi diğer topluluk öğrenme stratejilerinin de uygulanması planlanmaktadır. Ayrıca, geliştirilen modellerin açıklanabilirliğini artırmak amacıyla Açıklanabilir Yapay Zeka (XAI) yaklaşımlarının entegrasyonu hedeflenmektedir. Bu bağlamda, özellikle kullanıcı güvenini pekiştirmek ve karar verme süreçlerini daha şeffaf hale getirmek için SHAP ve LIME gibi model açıklama tekniklerinin kullanılması amaçlanmaktadır. Böylece hem sınıflandırma performansı hem

de model yorumlanabilirliđi aısından daha gl ve kullanıcı dostu yapay zeka sistemlerinin geliřtirilmesine katkı sađlanması hedeflenmektedir.

Kaynakça

- Aamir, M., Rahman, Z., Dayo, Z. A., Abro, W. A., Uddin, M. I., Khan, I., Imran, A. S., Ali, Z., Ishfaq, M., Guan, Y., & Hu, Z. (2022). A deep learning approach for brain tumor classification using MRI images. *Computers and Electrical Engineering*, 101, 108105. <https://doi.org/10.1016/j.compeleceng.2022.108105>
- American Brain Tumor Association. (2015). *About Brain Tumours: A Primer for Patients and Caregivers*. American Brain Tumor Association (ABTA).
- Ayadi, W., Elhamzi, W., Charfi, I., & Atri, M. (2021). Deep CNN for Brain Tumor Classification. *Neural Processing Letters*, 53(1), 671-700. <https://doi.org/10.1007/s11063-020-10398-2>
- Aziz, N., Minallah, N., Frnda, J., Sher, M., Zeeshan, M., & Durrani, A. H. (2024). Precision meets generalization: Enhancing brain tumor classification via pretrained DenseNet with global average pooling and hyperparameter tuning. *PLOS ONE*, 19(9), e0307825. <https://doi.org/10.1371/journal.pone.0307825>
- Babu Vimala, B., Srinivasan, S., Mathivanan, S. K., Mahalakshmi, Jayagopal, P., & Dalu, G. T. (2023). Detection and classification of brain tumor using hybrid deep learning models. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-50505-6>
- Badža, M. M., & Barjaktarović, M. Č. (2020). Classification of Brain Tumors from MRI Images Using a Convolutional Neural Network. *Applied Sciences*, 10(6), 1999. <https://doi.org/10.3390/app10061999>
- Başarslan, M. S. (2025). MC &M-BL: a novel classification model for brain tumor classification: multi-CNN and multi-BiLSTM. *The Journal of Supercomputing*, 81(3), 1-25.
- Cai, L., Gao, J., & Zhao, D. (2020). A review of the application of deep learning in medical image classification and segmentation. *Annals of Translational Medicine*, 8(11), 713. <https://doi.org/10.21037/atm.2020.02.44>

- Casar-Borota, O., Burman, P., & Lopes, M. B. (2025). The 2022 WHO classification of tumors of the pituitary gland: An update on aggressive and metastatic pituitary neuroendocrine tumors. *Brain Pathology*, 35(1).
<https://doi.org/10.1111/bpa.13302>
- Cheng, J., Huang, W., Cao, S., Yang, R., Yang, W., Yun, Z., Wang, Z., & Feng, Q. (2015). Enhanced Performance of Brain Tumor Classification via Tumor Region Augmentation and Partition. *PLOS ONE*, 10(10), e0140381.
<https://doi.org/10.1371/journal.pone.0140381>
- Cheng, J., Yang, W., Huang, M., Huang, W., Jiang, J., Zhou, Y., Yang, R., Zhao, J., Feng, Y., Feng, Q., & Chen, W. (2016). Retrieval of Brain Tumors by Adaptive Spatial Pooling and Fisher Vector Representation. *PLOS ONE*, 11(6), e0157112.
<https://doi.org/10.1371/journal.pone.0157112>
- Chollet, F. (2017). Xception: Deep Learning with Depthwise Separable Convolutions. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1800-1807. <https://doi.org/10.1109/cvpr.2017.195>
- Deepak, S., & Ameer, P. M. (2019). Brain tumor classification using deep CNN features via transfer learning. *Computers in Biology and Medicine*, 111, 103345.
<https://doi.org/10.1016/j.combiomed.2019.103345>
- Dietterich, T. G. (2000). Ensemble Methods in Machine Learning. İçinde *Multiple Classifier Systems* (C. 1857, ss. 1-15). Springer.
- Géron, A. (2023). *Hands-on machine learning with Scikit-Learn, Keras and TensorFlow: Concepts, tools, and techniques to build intelligent systems* (Third edition). O'Reilly Media, Inc.
- Gómez-Guzmán, M. A., Jiménez-Beristáin, L., García-Guerrero, E. E., López-Bonilla, O. R., Tamayo-Perez, U. J., Esqueda-Elizondo, J. J., Palomino-Vizcaino, K., & Inzunza-González, E. (2023). Classifying Brain Tumors on Magnetic Resonance Imaging by Using Convolutional Neural Networks. *Electronics*, 12(4), 955.
<https://doi.org/10.3390/electronics12040955>

- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. The MIT Press.
- Gorelick, P. B., Furie, K. L., Iadecola, C., Smith, E. E., Waddy, S. P., Lloyd-Jones, D. M., Bae, H.-J., Bauman, M. A., Dichgans, M., Duncan, P. W., Girgus, M., Howard, V. J., Lazar, R. M., Seshadri, S., Testai, F. D., Van Gaal, S., Yaffe, K., Wasiak, H., & Zerna, C. (2017). Defining Optimal Brain Health in Adults: A Presidential Advisory From the American Heart Association/American Stroke Association. *Stroke*, 48(10). <https://doi.org/10.1161/str.0000000000000148>
- Gorelick, P. B., & Sorond, F. A. (2024). What is brain health? *Cerebral Circulation - Cognition and Behavior*, 6, 100190. <https://doi.org/10.1016/j.cccb.2023.100190>
- Hatipoglu, G. (2022). Hipofiz Adenomlarının Görüntülenmesi. *Türk Radyoloji Seminerleri*, 10(2), 183-197. <https://doi.org/10.5152/trs.2022.221865>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778. <https://doi.org/10.1109/cvpr.2016.90>
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017, Temmuz). Densely Connected Convolutional Networks. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI. <https://doi.org/10.1109/cvpr.2017.243>
- Kabir Anaraki, A., Ayati, M., & Kazemi, F. (2019). Magnetic resonance imaging-based brain tumor grades classification and grading via convolutional neural networks and genetic algorithms. *Biocybernetics and Biomedical Engineering*, 39(1), 63-74. <https://doi.org/10.1016/j.bbe.2018.10.004>
- Kibriya, H., Masood, M., Nawaz, M., & Nazir, T. (2022). Multiclass classification of brain tumors using a novel CNN architecture. *Multimedia Tools and Applications*, 81(21), 29847-29863. <https://doi.org/10.1007/s11042-022-12977-y>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing*

Systems 25, 1097-1105.

- Kumar, R., Kumbharkar, P., Vanam, S., & Sharma, S. (2023). Medical images classification using deep learning: A survey. *Multimedia Tools and Applications*, 83(7), 19683-19728. <https://doi.org/10.1007/s11042-023-15576-7>
- Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324. <https://doi.org/10.1109/5.726791>
- Lenders, N. F., Earls, P. E., Inder, W. J., & McCormack, A. I. (2023). The evolution in pituitary tumour classification: A clinical perspective. *Endocrine Oncology*, 3(1). <https://doi.org/10.1530/eo-22-0079>
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., Van Der Laak, J. A. W. M., Van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88. <https://doi.org/10.1016/j.media.2017.07.005>
- Liu, Z., Mao, H., Wu, C.-Y., Feichtenhofer, C., Darrell, T., & Xie, S. (2022). *A ConvNet for the 2020s* (No. arXiv:2201.03545). arXiv. <https://doi.org/10.48550/arXiv.2201.03545>
- Louis, D. N., Perry, A., Wesseling, P., Brat, D. J., Cree, I. A., Figarella-Branger, D., Hawkins, C., Ng, H. K., Pfister, S. M., Reifenberger, G., Soffietti, R., Von Deimling, A., & Ellison, D. W. (2021). The 2021 WHO Classification of Tumors of the Central Nervous System: A summary. *Neuro-Oncology*, 23(8), 1231-1251. <https://doi.org/10.1093/neuonc/noab106>
- Martucci, M., Russo, R., Schimperna, F., D'Apolito, G., Panfili, M., Grimaldi, A., Perna, A., Ferranti, A. M., Varcasia, G., Giordano, C., & Gaudino, S. (2023). Magnetic Resonance Imaging of Primary Adult Brain Tumors: State of the Art and Future Perspectives. *Biomedicines*, 11(2), 364. <https://doi.org/10.3390/biomedicines11020364>

- Mathivanan, S. K., Sonaimuthu, S., Murugesan, S., Rajadurai, H., Shivahare, B. D., & Shah, M. A. (2024). Employing deep learning and transfer learning for accurate brain tumor detection. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-57970-7>
- Musthafa, N., Memon, Q. A., & Masud, M. M. (2025). Advancing Brain Tumor Analysis: Current Trends, Key Challenges, and Perspectives in Deep Learning-Based Brain MRI Tumor Diagnosis. *Eng*, 6(5), 82. <https://doi.org/10.3390/eng6050082>
- Raverot, G., Burman, P., McCormack, A., Heaney, A., Petersenn, S., Popovic, V., Trouillas, J., & Dekkers, O. M. (2018). European Society of Endocrinology Clinical Practice Guidelines for the management of aggressive pituitary tumours and carcinomas. *European Journal of Endocrinology*, 178(1), G1-G24. <https://doi.org/10.1530/eje-17-0796>
- Raza, A., Ayub, H., Khan, J. A., Ahmad, I., S. Salama, A., Daradkeh, Y. I., Javeed, D., Ur Rehman, A., & Hamam, H. (2022). A Hybrid Deep Learning-Based Approach for Brain Tumor Classification. *Electronics*, 11(7), 1146. <https://doi.org/10.3390/electronics11071146>
- Rehman, A., Naz, S., Razzak, M. I., Akram, F., & Imran, M. (2020). A Deep Learning-Based Framework for Automatic Brain Tumors Classification Using Transfer Learning. *Circuits, Systems, and Signal Processing*, 39(2), 757-775. <https://doi.org/10.1007/s00034-019-01246-3>
- Sajjad, M., Khan, S., Muhammad, K., Wu, W., Ullah, A., & Baik, S. W. (2019). Multi-grade brain tumor classification using deep CNN with extensive data augmentation. *Journal of Computational Science*, 30, 174-182. <https://doi.org/10.1016/j.jocs.2018.12.003>
- Simonyan, K., & Zisserman, A. (2015). *Very Deep Convolutional Networks for Large-Scale Image Recognition* (No. arXiv:1409.1556). arXiv. <https://doi.org/10.48550/arXiv.1409.1556>

- Söylemezoğlu, F. (2011). Meningiom Sınıflaması ve Histopatolojik Özellikleri. *Türk Nöroşirürji Dergisi*, 21(2), 84-90.
- Sultan, H. H., Salem, N. M., & Al-Atabany, W. (2019). Multi-Classification of Brain Tumor Images Using Deep Neural Network. *IEEE Access*, 7, 69215-69225.
<https://doi.org/10.1109/access.2019.2919122>
- Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. (2017). Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning. *Proceedings of the AAAI Conference on Artificial Intelligence*, 31(1).
<https://doi.org/10.1609/aaai.v31i1.11231>
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the Inception Architecture for Computer Vision. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2818-2826.
<https://doi.org/10.1109/cvpr.2016.308>
- Szegedy, C., Wei Liu, Yangqing Jia, Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1-9.
<https://doi.org/10.1109/cvpr.2015.7298594>
- Tan, M., & Le, Q. V. (2020). *EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks* (No. arXiv:1905.11946). arXiv.
<https://doi.org/10.48550/arXiv.1905.11946>
- Tan, M., & Le, Q. V. (2021). EfficientNetV2: Smaller Models and Faster Training.
<https://doi.org/10.48550/ARXIV.2104.00298>
- Tandel, G. S., Balestrieri, A., Jujaray, T., Khanna, N. N., Saba, L., & Suri, J. S. (2020). Multiclass magnetic resonance imaging brain tumor classification using artificial intelligence paradigm. *Computers in Biology and Medicine*, 122, 103804.
<https://doi.org/10.1016/j.compbiomed.2020.103804>
- Tharwat, A. (2021). Classification assessment methods. *Applied Computing and Informatics*, 17(1), 168-192. <https://doi.org/10.1016/j.aci.2018.08.003>
- Tufan, K. (2019). Glial Tümörlerde Ayırıcı Tanı. *Türk Nöroşirürji Dergisi*, 29(3), 244-250.

- Villanueva-Meyer, J. E., Mabray, M. C., & Cha, S. (2017). Current Clinical Brain Tumor Imaging. *Neurosurgery*, *81*(3), 397-415.
<https://doi.org/10.1093/neuros/nyx103>
- Wang, Y., Pan, Y., & Li, H. (2020). What is brain health and why is it important? *BMJ*, m3683. <https://doi.org/10.1136/bmj.m3683>
- Yang, Y., Yan, L.-F., Zhang, X., Han, Y., Nan, H.-Y., Hu, Y.-C., Hu, B., Yan, S.-L., Zhang, J., Cheng, D.-L., Ge, X.-W., Cui, G.-B., Zhao, D., & Wang, W. (2018). Glioma Grading on Conventional MR Images: A Deep Learning Study With Transfer Learning. *Frontiers in Neuroscience*, *12*.
<https://doi.org/10.3389/fnins.2018.00804>