

BÖLÜM 5

BEYİN TÜMÖRÜ TANISI İÇİN YAPAY ZEKA STRATEJİLERİ MR'DA SEGMENTASYON VE SINIFLANDIRMA STRATEJİLERİ

Abdulkadir BULDU¹
Dr. Öğr. Üyesi Kaplan KAPLAN²
Doç. Dr. Melih KUNCAN³
Doç. Dr. Fatma KUNCAN⁴
Dr. Erdal AYVAZ⁵

DOI: <https://dx.doi.org/10.5281/zenodo.8364933>

¹ Siirt Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Siirt, Türkiye, abdulkadir.buldu@siirt.edu.tr, Orcid ID: 0000-0002-9161-4862

² Kocaeli Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, Kocaeli, Türkiye, kaplan.kaplan@kocaeli.edu.tr, Orcid ID: 0000-0001-8036-1145

³ Siirt Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Siirt, Türkiye, Orcid ID: 0000-0002-9749-0418

⁴ Siirt Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Siirt, Türkiye, fatmakuncan@siirt.edu.tr, Orcid ID: 0000-0003-0712-6426

⁵ Sağlık Bilimleri Üniversitesi, Tıp Fakültesi, Radyoloji Bölümü, Kocaeli, Türkiye, erayvaz04@gmail.com, Orcid ID: 0000-0002-4630-278X

1. GİRİŞ

Beyin tümörü, toplumda her geçen gün daha yaygın hale gelen en ölümcül hastalıklardan biridir. Yapılan istatistiksel çalışmalarda beyin tümörünün dünyadaki yayılımının her geçen gün daha geniş kitlelere ulaştığı görülmektedir (Kaplan, 2020). GCS (Global Cancer Statistics) tarafından 2020 yılında yapılan araştırmada beyin tümörünün insan hayatını en çok tehlikeye atan hastalıklar arasında 21. sırada yer aldığı belirtilmiştir (Ostrom ve ark., 2021). Bir beyin tümörünün yaşamı tehdit eden risklerine ek olarak, tedavi ve muayene maliyetleri de hafife alınmamalıdır (Goel ve ark., 2021). Yapılan bir araştırmaya göre 3750\$ gibi fiyatlar sadece görüntüleme işlemleri için harcanırken tedavi maliyetlerinin 63000\$'a kadar ulaştığı ortaya çıkmıştır (Dos ve ark., 2022).

Beyin dokusunda oluşan ve tipine göre hayatı büyük ölçüde etkileyebilen bu tümör tipini primer ve sekonder olmak üzere iki ayrı grupta incelemek mümkündür. Primer beyin tümörleri, beyin dokusunda başlayıp yayılmaya devam ederken, metastatik beyin tümörleri olarak da bilinen sekonder, başka bir organda ortaya çıkan ve beyne yayılan bir tümör türüdür. İkincil beyin tümörleri diğer tiplere göre daha öldürücüdür. Oluşum tipine göre sınıflandırmanın yanı sıra beyin tümörlerinin iyi huylu ve kötü huylu olarak derecelendirildiği 4 seviyeden oluşan bir kategorizasyonu da vardır. Bu sıralamaya göre 1. derece tümörler iyi huylu, yayılma hızı yavaş ve hayatı tehdit ediciliği düşükken, 4. dereceye çıktıklarında hayatı tehdit ediciliği artmakta ve yayılma hızı artmaktadır. Bu sıralamaya göre tümör üçüncü dereceden sonra kötü huylu olarak adlandırılır.

Beyin tümörünün bu yaygınlığı, ölüm riski, görüntüleme ve tedavi maliyeti, araştırmacıları konu hakkında yardımcı görüş oluşturmaya sevk etti. Konuyla ilgili çalışmalarda yapay zeka yöntemleri olan makine öğrenmesi ve derin öğrenme yöntemleri yardımıyla tümörlerin sınıflandırılması amaçlanmaktadır.

Unutulmamalıdır ki bu işlemler uygulanmadan önce seçilmesi gereken görüntüleme yöntemi de önemlidir. Araştırmalarda kullanılan görüntüleme tekniğine Manyetik Rezonans Görüntüleme (MRI) adı verilir ve bu yöntemden elde edilen görüntüler günlük hayatta birçok hastalığın teşhisinde kullanılır (Tiwari ve ark., 2019). Sınıflandırma için gerekli özneliklere erişimi sağlayan görüntü çıktıları bu yöntemi tercih edilmesini sağlamıştır.

MR görüntüleme teknikleri yardımı ile yapılacak işlemlerin başında segmentasyon işlemi gelmekte ve bu yöntem sayesinde görüntü üzerinde tümörlü bölge tespit edilmektedir (Menze ve ark., 2015). Daha sonra öznelik çıkarım yöntemleri ile görüntüler sınıflandırma için uygun formata getirilir (Zitova ve ark, 2003). Bu format üzerinde çeşitli ön işlemlerden sonra veri seti sınıflandırmaya hazır hale gelir.

Literatürde yaygın olarak kullanılan makine öğrenmesi yöntemleri, sınıflandırma işlemlerinde kullanılan sınıflandırma teknikleri arasındadır. Derin öğrenme algoritmaları ise her geçen gün popüleritesi artan bir tekniğe sahip olması ve kendi kendine öğrenme yeteneğine sahip olması nedeniyle yüksek doğruluk oranları sağlamaktadır. Ayrıca yapısı gereği büyük veri kümelerinin sınıflandırılmasında da başarılı bir performans sergilemektedir.

Bu çalışmada beyin tümörü bölgesinin segmentasyon teknikleri ile tespiti ve tespit edilen tümörün sınıflandırılması ile ilgili bir literatür çalışması sunulmakta ve bu çalışmalar arasındaki karşılaştırmalara değinilmektedir.


2. BİLGİSAYAR DESTEKLİ SİSTEMLER

Günümüzde beyin tümörü tespiti ve var olan tümörün (benign, malign) yorumlanmasında CAD kullanılmaktadır. Beyin tümörlerinin sınıflandırılmasında kullanılan özellik çıkarım yöntemleri ile elde edilen öznelikler, yorum yapacak uzmanlar (radyolog, nörolog vb.) için öncü niteliğindedir (Saman ve Swathi, 2019). Dokunun homojenliği veya

heterojenliği, tümör sınıflandırmasında kullanılacak özellikler arasındadır. Görüntülerden elde edilen bu özellikler, Bilgisayar Destekli Sistem (CAD) tasarımında kullanılacak parametrelerin seçiminde de bize yol göstericidir. Diğer bir deyişle, CAD radyologlarının karar verme sürecinde yardımcı olabilecek potansiyele sahip olmaları sağlanmaya çalışılmaktadır. Bu kapsamda yapılan çalışmalarda tümörü yorumlayacak uzmanlar, yorgunluk, dalgınlık ve benzeri yanlış yorumlamalara yol açabilecek durumlarda CAD'in başarılı bir yardımcı olduğunu teyit etmektedir. Ancak nihai karar her zaman uzman görüşü olan radyologlara aittir. CAD bunu yaparken makine öğrenmesi yöntemlerinden yararlandığı için tasarlanacak sistemde kullanılan örüntü tanıma yöntemlerinin elde edilen sonucun doğruluğuna etkisi oldukça fazladır. Örüntü tanıma işlemi, mevcut ham verilerden sistemi yorumlamada faydalı olacak özneliklerin çıkarılmasını içerir.

2.1. Görüntü Kaydı

Görüntü kaydı, aynı sahnenin farklı zamanlarda çekilmiş görüntülerinin üst üste bindirilmesi yöntemidir. Görüntüleri birbirinden farklı kılan sebepler ise farklı sensörler tarafından alınması veya farklı perspektifler içermesidir (Jalali ve Dapinder, 2020). Bu nedenle, görüntüler arasındaki farklılıklar doğrudan koşullarla bağlantılıdır. Kayıt yöntemlerinin çoğu 4 adımdan oluşur. Bu yöntemler aşağıda belirtilmiştir. Şekil 1, görüntü kayıt işlemi için bir örnek göstermektedir (Hill ve ark, 2001).



Şekil 2.1 Görüntü kaydı için bir örnek

Görüntü kayıt işlemi, parametrelerin belirlenmesi ve görüntünün kaydedilmesi olmak üzere 2 adımdan oluşmaktadır. Kayıt parametrelerinin belirlenmesi, ikinci görüntünün birinci görüntüye hizalanmasında hangi hareketlerin yapılması gerektiğini belirlemek için gereklidir (Eddy ve ark., 1996). Bu bilgilere dayanarak 1. adımdan 2 boyutlu görüntülere uygulamada 2 öteleme (δ) ve 1 döndürme (θ) olmak üzere toplam 3 parametre belirlemek yeterli olacaktır. Adım 2'yi gerçekleştirmenin birkaç yöntemi vardır.

2.1.1. Beyin Tümörü Segmentasyonu

MRI görüntülerinde beyin tümörü ve beyin dokusu segmentasyonu literatürde geniş bir çalışma alanına sahiptir (Zhang ve ark., 2008). Görüntü bölütlemenin temel çalışma prensibi, benzer özelliklere sahip piksellerin toplanmasına dayanmaktadır (Duber ve ark., 2011). Bu da başarılı bir bölütlemeye tercih edilen özellik çıkarma yönteminin önemini ortaya koymaktadır. Görüntüdeki nesnelere arasında kesin ayrımlar olduğunda segmentasyon yükü daha hafiftir. Görüntüdeki nesnelere arasındaki benzerlikler arttıkça bölütleme işlemini doğru bir şekilde gerçekleştirmek zorlaşmaktadır. Yoğunluk, beyin MRG görüntülerinde doku tespiti için

kullanılan özelliklerden biridir. Ancak bölütleme işlemi için sadece yoğunluk özelliğinin kullanılması birçok araştırmacı tarafından yetersiz bulunmuştur (İftekharuddin ve ark., 2008). Segmentasyon işleminin başarısı, Zar Benzerlik Katsayısı (DSC) ile ölçülür. Bu katsayı, orijinal ve bölünmüş pikseller arasındaki örtüşmeyi temsil eder. Denklemde, DSC'nin elde edilmesini gösterir.

$$\text{Zar Benzerlik Katsayısı (DSC (A, B))} = \frac{2|A \cap B|}{|A| + |B|}$$

Beyin tümörü segmentasyonu, Foo ve ark.'nın (Foo, 2006) yaptığı araştırma çerçevesinde etkileşim bazında üç gruba ayrılmıştır. Bunlar manuel, yarı otomatik ve tam otomatik segmentasyondur.

2.1.1.1. Manuel Segmentasyon

Bu bölütleme yönteminde beyin ve tümörlü bölgenin sınırları manuel olarak çizilir ve tümörlü bölge boyanır (Yao, 2006). Yani bu yöntemi uygulayan kişiler, tıbbi görüntüleme alanında uzmanlaşmış kişilerden (radyolog vb.) oluşmaktadır. İşlem uzmanlar tarafından yapılırsa da doğruluk oranı yüksek, harcanan zaman açısından dezavantajlıdır.

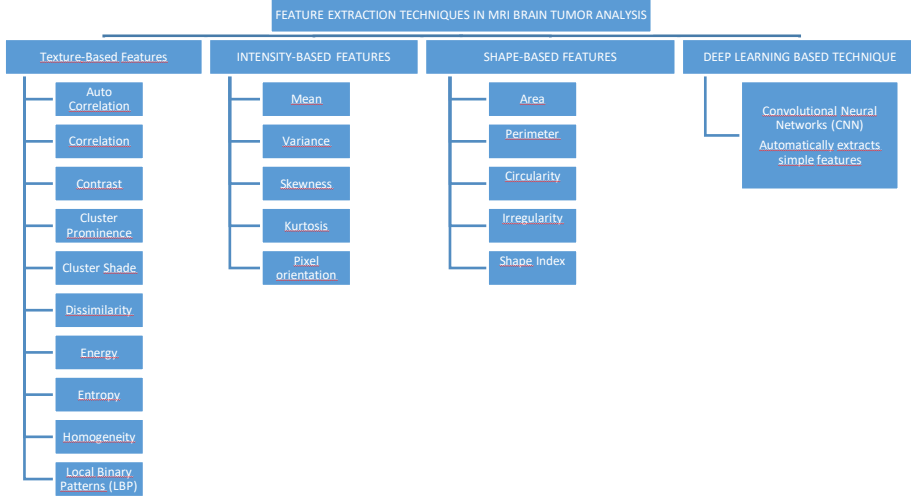
2.1.1.2. Yarı Otomatik Segmentasyon

Yarı otomatik bölütleme işleminde başlangıç, doğruluk kontrolü ve sonucun düzenlenmesi insan tarafından gerçekleştirilir. Ancak segmentasyon işlemlerinden beklenen, olabildiğince insanlardan bağımsız çalışmaktır.

2.1.1.3. Tam Otomatik Segmentasyon

Tam otomatik sistemler, segmentasyon işlemlerini insanlardan bağımsız olarak tamamlama potansiyeline sahiptir. Bu sistemler, makine öğrenimi ve örüntü tanımanın çalışıldığı alanlarda da aktif olarak kullanılmaktadır. Ancak hassas sistem tasarımı aynı zamanda zorlukları da beraberinde getirir. Bunun nedeni, böyle bir sistemi tasarlamak için gereken bilgidir. Bu, tam otomatik

sistemlerin kullanımının neden zor olduğunu açıklar. İnsan bağımlılığına göre sistemlerin sınıflandırılmasının yanı sıra, Şekil 2.2'de gösterildiği gibi segmentasyon işlemleri hakkında genel bir sınıflandırma yapılabilir.



Şekil 2.2. Segmentasyon Yöntemlerinin Genel Sınıflandırılması.

J. amin ve ark. (Amin ve ark., 2017), otomatik bir bölütleme yöntemi sundu. Bu yöntem, tümör bölgesini ayırt etmek için önce görüntüyü üç kritere göre bölütledi. Bunlar sırasıyla yoğunluk, şekil ve dokudur. Daha sonra Destek Vektör Makinesi (SVM) yardımıyla sınıflandırma işlemi gerçekleştirilmiştir. Önerilen yöntemin başarı oranı %97,1 olarak hesaplanmıştır.

Ryo Ito ve ark. (Ito ve ark., 2019), yarı otomatik bir bölütleme yöntemi kullanarak mevcut MRG görüntülerini bölütledi. Sundukları yöntem, görüntü kaydına dayalı Derin Sinir Ağları (DNN) yaklaşımından daha iyi performans gösterdi. Görüntü kaydına dayalı işlemlerde oluşan etiket hatalarını ortadan

kaldırmak için Beklenti Maksimizasyonu (EM) adı verilen gizli etiketleme yönteminden faydalanmıştır. Bu yöntem kapsamında mevcut görüntüye dışarıdan eklenen belirlenen gürültüler yardımıyla etiket kestirimi yapılmıştır. Yöntemin bölütleme başarı oranı Zar Katsayısı (DC) ile hesaplanmış ve %94 olarak elde edilmiştir.

Said ve İbrahim (Said ve İbrahim, 2017) kendi aralarında bölütleme yöntemlerini karşılaştıran bir yaklaşım geliştirmişlerdir. Bu yaklaşım kapsamında karşılaştırma için MATLAB ortamında bir araç kutusu tasarlamışlardır. Çalışma sonunda elde edilen verilere göre k-ortalamar ve Bulanık C ortalamar yöntemleri %96,7 başarı oranı ile doğruluk oranı en yüksek yöntemler olmuştur.

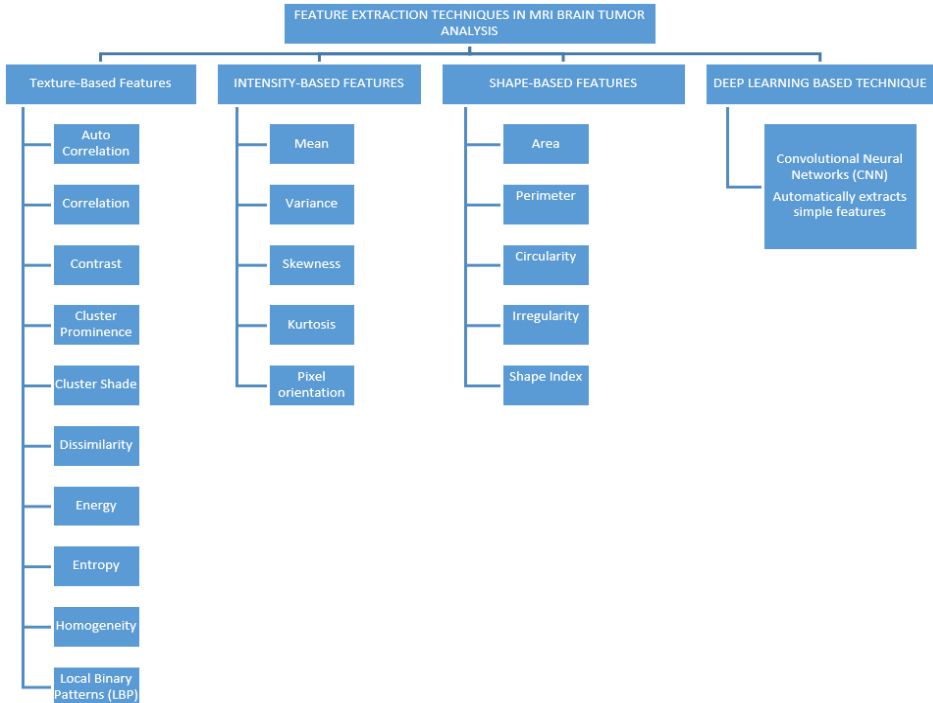
Uma ve ark. (Uma ve ark., 2016) da bölütleme yöntemlerinin karşılaştırılması üzerine bir çalışma yapmışlardır. Araştırma kapsamında karşılaştırılan yöntemler şu şekildedir; Destek Vektör Makinesi (SVM), Bulanık C Means, K-Means, Kümeleme ve Bayes modeli. Yazarlar segmentasyon işleminde en yüksek doğruluğu %99 oranı ile Morfolojik filtreleme yönteminde elde etmişlerdir.

Zikiç ve ark. (Zikic ve ark., 2014), CNN tabanlı bir segmentasyon yaklaşımı önerdi. Burada yazarlar, görüntüyü beş farklı parçaya bölmek için CNN yapısını kullandılar. Bunlar sırasıyla tümörsüz, nekroz, ödem, kontrast eksikliği ve büyüyen tümördür.

2.1.3. Özellik Çıkarımı ve Sınıflandırma

Beyin tümörleri sınıflandırılırken beynin özelliklerinden yararlanılarak yorumlar yapılmaktadır. Ancak beyin tümörlerinden elde edilen görüntü verileri doğrudan sınıflandırma için uygun değildir. Bu nedenle öncelikle beyin tümörü MRG görüntülerinin sayısallaştırılması ve sınıflandırmaya uygun hale getirilmesi için çalışmalara ihtiyaç vardır. Bu işlemler literatürde

özellik çıkarma yöntemleri olarak adlandırılmaktadır. Beyin tümörlerinin MRG görüntülerinde özellik çıkarma yöntemlerine dayalı öznelikler sırasıyla yoğunluk, doku, yerel ikili desenler ve şekil olarak sıralanabilir. Bu özellikler tümörlerin etiketlenmesinde kullanılan karakteristik özellikler arasındadır. Şekil 3, belirtilen özelliklerin elde edilmesine yönelik yöntemleri içermektedir. Ancak, her özellik sınıflandırma için kullanılmaya değer değildir. Bu nedenle özellikler arasında bir filtreleme yapmak gerekmektedir. Gereksiz özellikler ortadan kaldırıldıktan sonra makine öğrenmesi yöntemleri yardımıyla tümörün sınıflandırılmasında kullanılmaya hazır olacaktır. Bu işleme özellik seçimi denir ve araştırmalar bunun beyin tümörü sınıflandırma yöntemlerinin doğruluğunu önemli ölçüde artırdığını göstermiştir.



Şekil 2.2. Özellik Çıkarım Yöntemlerinin Sınıflandırılması (Saman ve Jamjala, 2019)

Doku tabanlı özellik çıkarma yöntemlerinde kullanılan analiz yöntemleri, GLCM (Gri Level Oluşum Matrisi) adı verilen bir özellik çıkarma yöntemi altında toplanmıştır. GLCM, korelasyon, homojenlik, LBP (Yerel İkili Örüntüler), kontrast ve enerji gibi kriterlerden oluşur. Bu kriterlerin matematiksel formülasyonu aşağıdaki denklemlerde verilmiştir.

$$\text{Energy} = \sum_i \sum_j p(i, j)^2$$

$$\text{Homogeneity} = - \sum_i \sum_j \frac{1}{1+i-j} p(i, j)$$

$$\text{Contrast} = \sum_n n [\sum_i \sum_j p(i, j)], \quad |i - j| = n$$

$$\text{Correlation} = \frac{\sum_i \sum_j (i - \mu_x)(j - \mu_y) p(i, j)}{\sigma_x \sigma_y}$$

Bir diğer öznelik çıkarma yöntemi olan yoğunluk tabanlı öznelikler varyans, ortalama, basıklık ve çarpıklık gibi öznelikleri içerir. Bu yöntemler, istatistiksel yöntemlerle piksellerin dağılımını inceleyerek görüntünün sayısallaştırılmasını sağlar.

$$\text{Variance} = \frac{1}{N} \sum_{i=1}^N (P_i - \text{mean})^2$$

$$\text{Mean} = \frac{1}{N} \sum_{i=1}^N P_i$$

$$\text{Kurtosis} = \frac{1}{N} \sum_{i=1}^N (P_i - \text{mean})^4$$

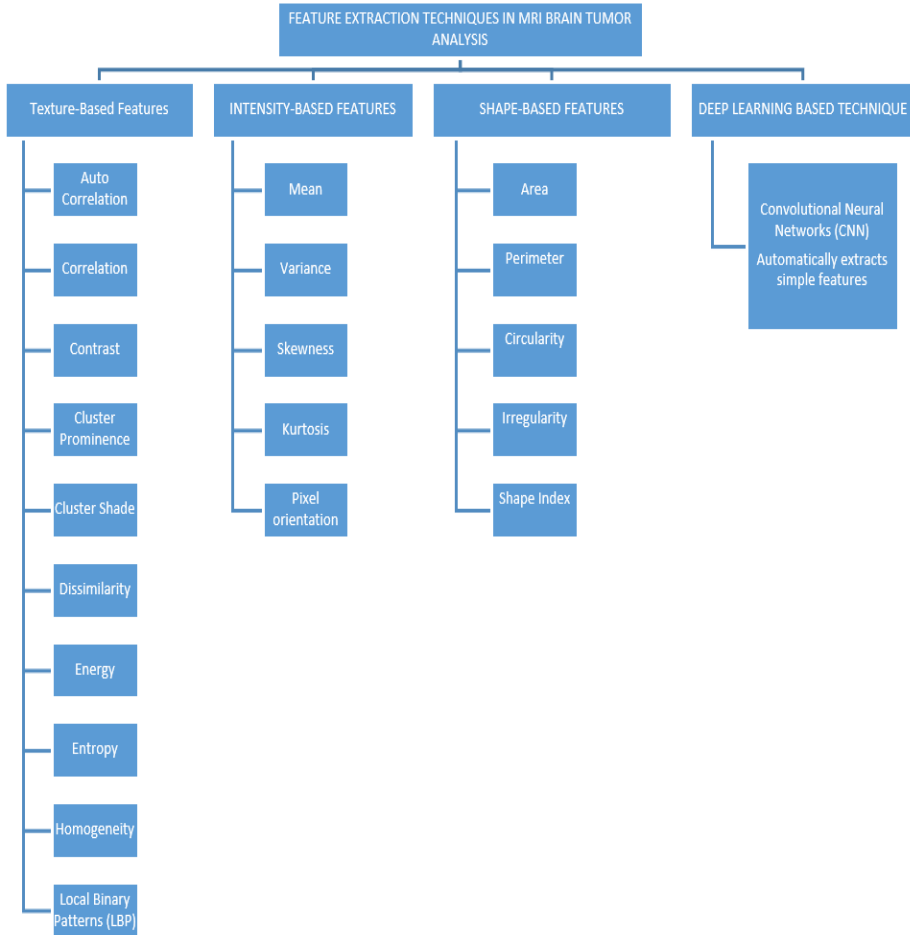
$$\text{Skewness} = \frac{1}{N} \sum_{i=1}^N (P_i - \text{mean})^3$$

Bir diğer öznelik çıkarım yöntemi olan şekil tabanlı yöntemler görüntünün geometrik özelliklerinden yararlanarak sayısallaştırma gerçekleştirirken, CNN tabanlı yöntemler yapısındaki katmanlı ağları kullanarak çeşitli özneliklerin çıkarılmasını sağlar. MRG görüntüsünün sayısallaştırılmış versiyonu, yukarıda açıklanan özellik çıkarma yöntemleri çalışma için uygun hale geldikten sonra kullanılabilir hale gelecektir. Ancak veri setindeki çeşitli

istenmeyen durumların ortadan kaldırılması, sınıflandırma işlemi öncesinde yapılması gerekenler arasındadır. Bu yöntemler arasında sınıflandırma başarısını olumsuz etkileyecek verilerin normalleştirilmesi, eksik ya da hatalı verilerin düzeltilmesi gibi verilerin uygun hale getirilmesini sağlayan yöntemler bulunmaktadır.

3. SINIFLANDIRMA YÖNTEMLERİ

Sınıflandırma teknikleri geniş bir yelpazeye sahiptir. Temel olarak denetimli ve denetimsiz olarak 2 grupta incelenir. Denetimli yöntemlerde, sınıflandırmanın doğruluğunu sağlamak için uzman radyologların görüntü üzerinde tespitinden yararlanılır. Denetimsiz sınıflandırma yöntemlerinde uzman görüşü mekanizması yoktur. Şekil, beyin tümörü sınıflandırmasında kullanılan tekniklerin kategorizasyonunu göstermektedir. Şekil 3, özellik çıkarma yöntemlerinin genel sınıflandırmasını göstermektedir.



Şekil 3.1. Makine Öğrenimi Sınıflandırma Yöntemlerinin Sınıflandırılması

Literatürde geniş bir çalışma alanına sahip olan beyin tümörü sınıflandırmasının kullanımı ve makine öğrenmesi yöntemleri ile yeni yaklaşım girişimleri gün geçtikçe yaygınlaşmaktadır. Naomi Joseph ve ark. (Joseph ve ark., 2017), BRATS veri setinde k-ortalamlar sınıflandırma yöntemini uygulamıştır. Yazarlar görüntüler için yarı otomatik bölütleme yöntemlerinden biri olan k-means have algoritmasını kullanmışlardır. Bu algoritma sayesinde model daha hızlı hale geldi. Uygulanan bölütleme sonrasında K-means kümeleme sınıflandırma yönteminin uygulandığı veri setinden elde edilen doğruluk oranı %82 olarak belirlenmiştir.

Bu konuda çalışma yapan Amin ve Mageed (Amin ve Mageed, 2012). yaklaşımları ile beyin tümörünü otomatik olarak saptamayı amaçlamışlardır. Görüntüler Ain Shams Üniversitesi'nin web sitesindeki 'beyin atlası'ndan alınmıştır ve 30 farklı beyin MR görüntüsü içermektedir. Yazarlar, Temel bileşen analizi (PCA) öznelik çıkarma yöntemi yardımıyla Çok Katmanlı Perceptron yöntemini kullanarak %88,2 ile %96,7 arasında değişen bir başarı oranı elde etmişlerdir.

Cheng ve ark. (Cheng ve ark., 2015), SVM ve Knn yardımıyla bir sınıflandırma yaklaşımı yapmıştır. Bu çalışmada 2 boyutlu görüntüler üzerinde operasyonlar gerçekleştirilmiş olup, veriler Nanfang Hastanesi ve General Hospital'da 2005-2010 yılları arasında elde edilen görüntülerden oluşmaktadır. Bu sınıflandırma sürecinde öznelik olarak GLCM, kelime torbası ve yoğunluk histogramını kullanmışlardır. Yazarlar, çalışma kapsamında BoW özneliğine dayalı olarak Destek Vektör Makineleri (DVM) yönteminin %91,14 oranında başarı elde ettiğini ortaya koymuşlardır.

Çınarer ve Emiroğlu (Çınarer ve Emiroğlu, 2019) Ulusal Kanser Enstitüsü tarafından Kanser Görüntüleme Arşivi veri tabanından alınan Rembrandt veri seti üzerinde DVM, Knn, RF (Rastgele Ağaçlar) ve LDA (Lineer Diskriminant Analiz) yöntemlerini uygulayarak bir sınıflandırma işlemi gerçekleştirmiştir. Bu çalışma sonucunda yazarların elde ettiği sonuçlara göre DVM yöntemi bu veri setinde diğer 3 yöntemi geride bırakarak %90 doğruluk sağlamıştır.

Pratondo ve ark. (Pratondo ve ark., 2017), segmentasyon süreci için bir yaklaşım sundu. Bu yaklaşımı takiben, Knn ve SVM makine öğrenmesi yöntemlerini kullanarak sınıflandırma işlemi gerçekleştirdiler. Yazarlar, homojen olmayan sınırların tespiti yoluyla beyin tümörlerini tespit etmeyi amaçladılar. Literatürde Chan-ve-se segmentasyonu olarak bilinen bu sınır

belirleme yöntemini makine öğrenmesi yöntemleriyle birleştirerek %90 oranında başarılı bir sonuç elde ettiler.

Abbas ve ark. (Abbas ve ark., 2019), beyin tümörünün segmentasyonu ve sınıflandırılması için yeni bir yöntem geliştirme konusunda bir çalışma yürüttüler. Yerel Bağımsız Projeksiyona Dayalı Sınıflandırma (LIPC) adını verdikleri bu yöntemle tümörü yenileme sürecinde tümörden çıkan buharı kullandılar. Yazarlar, yöntemi MICCAI Beyin Tümörü Segmentasyonu veri setine uyguladılar. İşlem sonucunda bölütleme başarısının kriteri olan dice skoru 0,95'tir. Ayrıca sınıflandırma başarısı %89 olarak belirlenmiştir.

Sachdeva ve ark. (Sachdeva ve ark., 2011) literatürdeki yaklaşımları birleştiren bir çalışma sundu. Yazarlar, Genetik Algoritma (GA) ve DVM algoritmasını harmanlayarak standart DVM yönteminden daha yüksek performans elde ettiklerini bulmuşlardır. PGIMER veri seti üzerinde sınıflandırma işlemini gerçekleştiren yazarlar, bu çalışma kapsamında GADVM yöntemi ile %91,7 başarı oranına ulaşmıştır. Yazarlar, aynı veri seti üzerinde standart DVM yöntemini kullandıklarında %56,3 başarı elde ettiklerini belirtmişlerdir.

Selvaraj ve ark. (Selvaraj ve ark., 2009), 1100 tümörlü ve tümörsüz MRG görüntüsünü sınıflandırmak için bir yaklaşım sundu. Bu yaklaşımda, yazarlar en küçük kareler destek vektör makinesi sınıflandırma yöntemini kullanmışlardır. Yazarlar, %96-98 arasında değişen bir doğruluk ölçeği elde ettiler.

Chander ve ark. (Chander ve ark., 2018), beyin tümörü tespiti için geliştirilmiş bir yöntemi literatüre sunmayı amaçlamıştır. Bu doğrultuda yazarlar, GLCM özneliklerini çıkardıkları veri setine makine öğrenmesi sınıflandırma yöntemi olan SVM'yi uygulamışlardır. Tümörün iyi mi yoksa

kötü mü olduğunu belirlemeyi amaçlayan yazarlar %93'lük bir sınıflandırma başarısı elde ettiler.

Devkota ve ark. (Devkota ve ark., 2018), beyin tümörünün doğasının belirlenmesi konusunda da bir çalışma yürütmüştür. Bu bağlamda sundukları yöntemin performansını iyileştirmek için gürültüyü en aza indirmeyi amaçlamışlardır. Yazarlar bu süreç için bir medyan filtre tasarlayarak sınıflandırma doğruluğunu arttırmayı amaçlamışlardır. Ardından, doku özelliklerinin yanı sıra istatistiksel özellikleri de çıkaran yazarlar, SVM yöntemini mevcut MRI görüntülerine uyguladılar. Önerilen yöntemin sınıflandırma başarısı %86.6 idi.

Abbasi ve Tajeripour. (Abbasi ve Tajeripour, 2017), beyin tümörü tespiti için yaptıkları çalışmada, önce BRATS 2013 veri setine 3D MRI görüntüleri bias alan korelasyonu ve histogram eşleştirme uygulayarak mevcut verileri kullanıma hazır hale getirmiştir. Bu işlemin ardından görüntüleri segmentlere ayırmışlar ve sınıflandırmaya hazır hale getirmişlerdir. Daha sonra yazarlar, Histograms of Oriented Gradient (HOG) ve Local Binary Pattern (LBP) yardımıyla özellik çıkarımı yapmış ve mevcut verilere Random Forest (RF) sınıflandırma yöntemini uygulamıştır. Bu prosedürlerin bir sonucu olarak, yazarlar %93'lük bir doğruluk elde edildiğini paylaşmıştır.

Soltaninejad ve ark. (Soltaninejad ve ark., 2014), 4 farklı beyin tümörü tipinin sınıflandırılması üzerine bir çalışma yapmışlardır. Yazarlar ilk önce BRATS 2013 veri kümesine girdap akımı efektini uygulayarak görüntüyü kullanım için daha verimli hale getirmişlerdir. Daha sonra görüntüleri bölütleyen yazarlar, bölütlenen görüntüleri SVM ile sınıflandırmışlar ve %80 başarı oranı elde etmişlerdir.

Anjali ve ark. (Anjali ve Priya, 2017), MRI görüntülerine dayalı makine öğrenmesi yöntemlerinden biri olan SVM yardımıyla beyin tümörünün

saptanması üzerine yaptıkları çalışmada doku özelliklerinden yararlanarak Particle Swarm Optimization yöntemini kullanarak özellik seçimini yapmışlardır. Görüntüyü daha saf hale getirmek için medyan filtreden de yararlanan yazarlar, The World Brain Atlas'tan aldıkları veri setinde çalışmanın başarısını %92.31 olarak elde etmişlerdir.

Jayachandran ve Dhanasekaran (Jayachandran ve Dhanasekaran, 2013) beyin tümörlerinin tespiti üzerine yaptıkları çalışmada, mevcut veri setine 4 adımlı Fuzzy-SVM yöntemini uygulamışlardır. Gürültünün azaltılması ile başlayan bu yöntem, doku özelliklerinin çıkarılması ile devam etmiştir. Daha sonra yazarlar, elde edilen özneliklerin sınıflandırma etkilerini seçmiş ve mevcut öznelikler üzerinde Fuzzy-DVM yöntemini uygulamışlardır. Bu süreç sonunda yazarlar sınıflandırma işleminin başarısını %95,80 olarak belirlemişlerdir.

Son yıllarda makine öğrenimi yöntemlerinin karmaşıklığı ve bir problemi çözmek için kullanılan düğüm sayısının fazla olması nedeniyle araştırmacılar derin öğrenme tabanlı sınıflandırma süreçlerine odaklanmaya başladılar. Derin öğrenme yöntemi, sistemi karmaşıklıktan uzak tutar ve daha basit bir öğrenme yapısı ile araştırmacılara kolaylık sağlar. Sınıflandırma işlemini gerçekleştirirken yapısındaki ağırlar yardımıyla transfer öğrenme yöntemi ile özellikleri sınıflandırma sürecine dahil eder ve makine öğrenmesi yöntemlerine göre daha başarılı sonuçlar elde etmeyi amaçlar. Bu, görüntü sınıflandırması ile ilgili çalışmalarda yaygın olarak kullanılmasını da sağlamıştır. MRI görüntüleri aracılığıyla elde edilen beyin tümörü verilerinin sınıflandırılması konusunda literatürde derin öğrenme yöntemleri ile ilgili birçok çalışma yayınlanmıştır.

Khan ve ark. (Khan ve ark., 2020), derin öğrenmeye dayalı beyin tümörü sınıflandırması için Aşırı Öğrenme Makinesi (ELM) yöntemini kullanmıştır. Sınıflandırma işlemi uygulanmadan önce modele VGG16 ve VGG19

uygulanarak özellik çıkarımı yapılmıştır. Bu özelliklerden sınıflandırma performansına etkisi yüksek olanlar seçilerek sınıflandırma işlemine tabi tutulmuştur. Yazarlar yöntemi sınıflandırma problemlerinde literatürde yaygın olarak kullanılan BRATS2018 veri setine uyguladığında %92,5 doğruluk elde etmiştir. Sınıflandırıcının başarısını karşılaştırmak için aynı veri seti üzerinde çeşitli derin öğrenme yöntemleri ile sınıflandırma yapan yazarlar, çalışmalarında önerilen yöntemin en yüksek doğruluğa sahip olduğunu göstermişlerdir.

Sachdeva ve ark. (Sachdeva ve ark., 2013), T1 ağırlıklı MRG görüntüleri üzerinde astrositom, menenjiyom, sekonder metastatik tümör gibi tümör tiplerinin sınıflandırılması üzerine bir çalışma yapmışlardır. Bu çalışmada 428 adet beyin tümörü kesiti bulunmaktadır ve bu kesitler 2010-2011 yılları arasında Lisansüstü Tıp Eğitimi ve Araştırma Enstitüsü'nde (PGIMER) elde edilen MRG görüntülerinden oluşmaktadır. Yapay Sinir Ağları (YSA) sınıflandırma yöntemini kullanarak yazarlar %91 oranında sınıflandırma başarısı elde ettiklerini paylaşmışlardır.

Deepak ve Ameer (Deepak ve Ameer, 2019) beyin belirli bölgelerinde (glioma, meningioma, hipofiz) meydana gelen tümörlerin sınıflandırılmasına ilişkin bir çalışma yürüttüler. Çalışmada kullanılan 233 hastaya ait 3064 adet beyin MR görüntüsü Figshare veri tabanından alınmış olup, bu veri seti literatürde modellerin test edilmesinde sıklıkla kullanılan veri setleri arasında yer almaktadır. Yazarların yaklaşımına göre, beyinden çıkarılan özelliklerin benzerliği nedeniyle makine öğrenmesi sınıflandırma süreci kesintiye uğramaktadır. Bunun üstesinden gelmek için yazarlar, sınıflandırma sürecine bir transfer öğrenme adımı dahil ederek ve veri kümesinin boyutunu azaltarak modellerini %92,3 başarı oranıyla GoogleNet ile birleştirdiler.

Derin öğrenme ile sınıflandırma süreçlerinde kullanılan yöntemler, farklı katmanları otomatik olarak sürece dahil ederek özellik çıkarmayı makine

öğrenmesinden daha kolay hale getirir. Widhiarso ve ark. (Widhiarso ve ark., 2018), derin öğrenmenin bu avantajına dayanarak, Biyomedikal Mühendisliği Okulu'ndan alınan 233 hastadan alınan 3064 beyin MRI görüntüsünden GLCM özelliklerini çıkardı. Bu çıkarımın geleneksel makine öğrenimi yöntemlerine göre %20 daha başarılı olduğunu buldular. Bu sayede yazarlar %82'lik bir başarı oranına ulaştılar.

Beyin tümörlerini sınıflandırmak için Mohsen ve ark. (Mohsen ve ark., 2018) Harvard Tıp Fakültesi'nden topladıkları 66 görüntüyü Derin Sinir Ağı (DNN) yöntemini kullanarak tümörsüz, glioblastoma, metastaz ve sarkom olarak gruplandırdılar. Çalışma sonucunda elde ettikleri doğruluk oranı literatüre %96,97 olarak kaydedilmiştir.

Anilkumar ve Rajesh (Anilkumar ve Rajesh, 2020) çalışmaları kapsamında derin öğrenme süreci yardımıyla sınıflandırma işlemini gerçekleştirmişlerdir. Yazarlar yeni bir algoritma önermişler ve VGGnet yapısını biraz daha karmaşık hale getirerek, küçük veri kümeleri üzerinde sınıflandırma sürecinde uygulanan transfer öğrenme yönteminin başarısını arttırmayı amaçlamışlardır. Beyin tümörleri üzerine yapılan çalışmalarda sıklıkla kullanılan BRATS ve CE-MRI veri setlerini kullanan yazarlar, sınıflandırma işlemi sonucunda sırasıyla %97,28 ve %98,69 doğruluk oranlarına ulaşmışlardır.

Sarhan (Sarhan, 2020) bir makine öğrenme yöntemi olan SVM ile derin öğrenme yöntemi olan SVM'yi karşılaştırmak için bir çalışma yürütmüştür. Çalışmasında özellik çıkarma yöntemi olarak Haar dalgacık dönüşümünü kullanan Sarhan, girdi verilerini yaklaşım katsayıları ve detay katsayıları olarak ikiye ayırmıştır. Çalışmada Figshare (Cheng) veri setini kullanan yazar, bu özellik yardımıyla sınıflandırma işlemini gerçekleştirmiş ve CNN modelinin, SVM'nin %98 doğruluğuna kıyasla %99,3 doğruluk oranıyla daha iyi sonuçlar verdiğini belirtmiştir.

Raj ve ark. (Raj ve ark., 2020) literatüre yeni bir yaklaşım getirmek amacıyla BRAINnet adını verdikleri bir yöntem geliştirmişlerdir. Yazarların önerdiği yöntem iki aşamada çalışmaktadır. İlk olarak algoritma tümör kontrolünü gerçekleştirir. İkinci aşamada, inceleme sonucu tümör hücresinin mevcut olduğunu tespit ederse görüntüye segmentasyon uygulayarak tümörü etiketler. Bu doğrultuda yazarlar, çalışmanın tümör tespitinde %98, tümör etiketlemesinde ise %99 doğruluk oranına sahip olduğunu ortaya koydu.

D. Zikic ve ark. (Zikic ve ark., 2014) CNN modeli yardımıyla sınıflandırma yapmıştır. Yazarlar, 5 katmanlı modeli kullanarak BRATS 2013 veri setine uyguladıkları segmentasyon sonrasında sınıflandırma sürecinde %83,7 doğruluk elde etmişlerdir.

Das ve ark. (Das ve ark., 2019) derin öğrenme tabanlı beyin tümörü tespiti kapsamında önerdikleri yöntemde 2 aşamalı bir yol izlemişlerdir. Bu yöntem doğrultusunda, ön işleme tabi tutulan MR görüntüleri öncelikle yeniden boyutlandırılmış ve filtrelenmiştir. Daha sonra sınıflandırma başarısını arttırmak için kontrast değeri optimal değere getirilmiştir. Bu ön işlemlerden sonra yazarlar, 233 hastadan alınan 3064 beyin tümörü görüntüsüne CNN yöntemini uygulamış ve sonuç olarak %94,39 doğruluk elde etmişlerdir.

Özyurt ve ark. (Özyurt ve ark., 2019), TCGA-GBM veri seti üzerinde yaptıkları çalışmada, derin öğrenme yöntemlerinden biri olan CNN yardımıyla beyin tümörünü (iyi huylu ve kötü huylu) etiketlemeyi amaçlamışlardır. Bu bağlamda yazarlar, görüntüleri bölütlemek için ilk olarak Neutrosophic Set–Expert Maximum Fuzzy Sure Entropy (NS-EMFSE) yöntemini kullanmışlar ve CNN yardımıyla bölütlenen görüntülerden özellik çıkarımı gerçekleştirmişlerdir. Daha sonra yazarlar, özellik çıkarımı yaptıkları MR görüntülerine NS-EMFSE CNN yöntemini uygulamış ve %95,62 doğruluk elde etmişlerdir.

Çınar ve Yıldırım (Çınar ve Yıldırım, 2020) yaptıkları çalışmada derin öğrenme yöntemlerinden biri olan Resnet50'nin geliştirilmiş versiyonunu kullanarak MR görüntülerinde tümör tespiti yapmayı amaçlamışlardır. Yazarlar, Resnet50'nin mevcut sürümüne 8 katman daha ekleyerek Kaggle'dan elde edilen beyin tümörü görüntülerine uygulayarak sonuçları diğer derin öğrenme yöntemleriyle karşılaştırmış ve %97 oranında doğruluk elde etmiştir.

Raja ve Viswasa (Raja ve Viswasa, 2021) yaptıkları çalışmada BRATS 2015'ten elde edilen görüntülerin çeşitli ön işleme tabi tutulmasından sonra derin öğrenme yöntemleri yardımıyla tümör hücrelerinin tespit edilmesini amaçlayan bir yaklaşım sunmuşlardır. Bu yaklaşıma göre yazarlar önce görüntülerdeki gürültüyü gidermek için medyan filtresi kullanmış, ardından gürültünün azaltıldığı görüntüye Bayesian Bulanık C-ortalama bölütleme yöntemini uygulayarak görüntü bölütleme işlemini gerçekleştirmişlerdir. Daha sonra yazarlar WPTE ve ST özellik çıkarma yöntemlerini kullanarak elde edilen özellikleri kullanarak verileri sınıflandırmışlardır. JOA ve SoftMax regresyonu ile sınıflandırma işlemini gerçekleştiren yazarlar, yaklaşım sonucunda %98,5 doğruluk elde etmişlerdir.

Seetha ve Raja (Seetha ve Raja, 2018) çalışmalarında beyin tümörünü tespit etmeyi amaçlamışlardır. Bu doğrultuda yazarlar öncelikle ImageNet'ten aldıkları beyin tümörü MR görüntülerini Fuzzy C Means segmentasyon yöntemini kullanarak sınıflandırmaya hazır hale getirmişlerdir. Daha sonra sınıflandırma sürecinde DNN ve DVM yöntemlerini birleştiren yazarlar %97,5 sınıflandırma başarısı elde etmişlerdir.

Tablo 1. Beyin tümörü sınıflandırmasına ilişkin karşılaştırmalı çalışmalar

Yazar/lar	Yıl	Veri Seti	Özellikler	Sınıflandırma Yöntemi	Doğruluk (%)
Naomi Joseph ve ark.	2017	BRATS		Yarı Otomatik Segmentasyon ve K-Mean sınıflandırma	% 82
Amin and Mageed	2012	Şam Üniversitesine ait 'Brain Atlas'		Özellik çıkarımı için kullanılan Temel Bileşen Analizi (PCA). Sınıflandırma için uygulanan Çok Katmanlı Perceptron	% 88.2- % 96.7
Cheng ve ark.	2015	Nanfeng Hastanesi and General Hastanesi	GLCM, kelime çantası ve yoğunluk histogramı	Knn and DVM	% 91.14 (SVM)
Cinärer ve ark.	2019	Kanser Görüntüleme Arşiv Veritabanı	Her MR görüntüsünden 30 özellik çıkarıldı.	SVM, Knn, RF, LDA	% 90 (SVM)
A. Pratondo ve ark.	2016	Bahsedilmedi	Bahsedilmedi	Chan vese yöntemiyle segmentasyon ardından DVM ile sınıflandırma.	%90
Khizar Abbas ve ark.	2019	MICCAI Beyin Tümörü Segmentasyon Veri Seti	Standart sapma, histogram, basıklık, çarpıklık	Otomatik Segmentasyon ve Yerel Bağımsız Projeksiyon Tabanlı Sınıflandırma (LIPC)	%89
J. Sachdeva ve ark.	2011	Radyodiagnoz Anabilim Dalı, Lisansüstü Tıp Eğitimi ve Araştırma Enstitüsü (PGIMER)	71 yoğunluk ve doku özelliği	GADVM (Genetik Algoritma ile birleştirilmiş DVM)	%91.7
Selveraj ve ark.	2013	Bahsedilmedi	Bahsedilmedi	En Küçük Kareler Destek Vektör Makineleri (LS-DVM)	% 96 - 98
Chander ve ark.	2019	Bahsedilmedi	GLCM özellikler	DVM	%93
Devkota ve ark.	2018	Bahsedilmedi	Doku özellikleri	DVM	%86.6
Abbasi ve ark.	2017	BRATS 2013	HOG ve LBP	Random Forest (RF)	%93
Soltaninejad ve ark.	2014	BRATS 2013	Bahsedilmedi	DVM	%80
Anjali ve ark.	2017	The World Brain Atlas	Parçacık Sürü Optimizasyonu	DVM	%92.31
A. Jayachandran	2013	Bahsedilmedi	Doku özellikleri	Fuzzy-SVM	

ve ark.					
Khan ve ark.	2020	BRATS 2018	VGG16 ve VGG19 uygulanarak öznelikler çıkartılır ve Correntropy tabanlı eklem öznelikleri seçilir.	Aşırı Öğrenme Makinesi (ELM)	% 92.5
Sachdeva ve ark.	2013	PGIMER'den alınan 428 Beyin Tümörü dilimi	LoG, GLCM, RILBP, DGTF, RICGF	Yapay Sinir Ağları (ANN)	% 91
S. Deepak, and P.M Ameer	2019	Figshare beyin tümörü veri seti	Bahsedilmedi	GoogleNet	% 92.3
Widhiarso ve ark.	2018	Biyomedikal Mühendisliği Okulu (Güney Tıp Üniversitesi, Guangzhou, Çin)	GLCM	Evrşimsel Sinir Ağının (CNN) makine öğrenimi yöntemleriyle karşılaştırılması	% 82
Mohsen ve ark.	2017	Harvard Tıp Fakültesi	DWT kullanılarak çıkarılan özellikler. Çıkarılan özelliklerden bahsedilmiyor	Derin Sinir Ağı (DNN)	%96.97
Anilkumar and Rajesh	2020	BRATS ve CE-MRI	Transfer öğrenme	VGGnet	% 97.28 and % 98.69
Sarhan	2020	Figshare (Cheng)	Haar dalgacık dönüşümü	CNN	% 99.3
Raj et al.	2020		Transfer öğrenme	BrainNET	% 99
D. Zikic ve ark.	2014	BRATS 2013	Transfer öğrenme	CNN	%83.7
Das ve ark.	2019	BRATS 2013	Transfer öğrenme	CNN	%94.39
Özyurt ve ark.	2019	TCGA-GBM	Özellik çıkarımı için CNN	NS-EMFSE (nötrosofik küme – uzman maksimum bulanık kesin entropi) CNN	%95.62
Cinar and Yildirim	2020	Kaggle	Bahsedilmedi	ResNet50	%97
Raja and Viswasa	2021	BRATS 2015	Dalgacık Paket Dönüşüm Enerjisi (WPTE) ve ST	Softmax regresyonu	%98.5
Seetha and Raja	2018	ImageNet	Bahsedilmedi	DNN'li DVM (Derin Sinir Ağları)	%97.5

4. PERFORMANS KRİTERLERİ

Segmentasyon ve sınıflandırma süreçlerinde yöntemin başarısının ölçülmesi araştırmalar için oldukça önemlidir. Makine öğrenimi yöntemleri her performans ölçümüne karşı olumlu sonuçlar vermeyebilir. Bu nedenle değerlendirme kriterleri için farklı yollar izlenebilir (Biratu ve ark., 2021). Sınıflandırma kriterlerinde temel olarak kullanılan kavramlardan birkaçı Gerçek Negatif (TN), Gerçek Pozitif (TP), Yanlış Pozitif (FP) ve Yanlış Negatif (FN)'dir. Bunların yardımıyla Doğruluk, Özgüllük, Hassasiyet, Geri Çağırma, F1-Score, Zar Benzerlik Katsayısı (DSC) performans kriterlerinin hesaplanmasını gerçekleştirebilmektedir.

Doğruluk, sistemin sınıflandırma işlemini gerçekleştirme yeteneğini test eder ve buna göre bir çıktı verir. Doğruluk kriteri, modelin matematiksel işaretinin yönünden bağımsız bir parametredir. Doğruluk parametresinin hesaplanması denklemde gösterilmektedir.

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

Özgüllük, N ve TN verilerine ilişkin tahminlerin gerçekten negatif olma oranını temsil eder. Özgüllük kriterinin türetilmesi denklemde gösterilmektedir.

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

Kesinlik, önerilen yöntemin doğru tahmin oranını gösteren kriterdir.

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

Duyarlılık, modelin pozitif örneklere ilişkin tahminlerini inceler. Model üzerindeki tahminlerin doğruluk oranının sıklığını ifade eder. Aşağıdaki denklemdeki gibi ifade edilir.

$$\text{Duyarlılık} = \frac{TP}{FP + TN}$$

Bahsedilen diğer performans ölçütleri gibi temel kriterlere (TN, TP, FP ve FN) bağlı olan Recall, denklemdeki gibi hesaplanır.

$$\text{Recall} = \frac{TN}{FN + TP}$$

Geri çağırma ve kesinlik yardımıyla elde edilen F1-Score kriteri, harmonik ortalamasının hesaplanması yöntemi olarak bilinmektedir. Kriterin Hassasiyet (PR) ve Geri Çağırma (RE) değişkenlerine bağlı olarak türetilmesi denklem (12)'de gösterilmektedir.

$$F1 - \text{Score} = 2 ((RE) * (PR)) / (RE + PR)$$

5. SONUÇLAR VE GELECEK ÇALIŞMALAR

Hayatımız boyunca göz ardı edilemeyecek hastalıklardan biri olan beyin tümörünün tespiti ve yorumlanmasına odaklanan bu çalışma, araştırmacılara ışık tutacak kapsamlı bir literatür desteği sağlamayı amaçlamaktadır. Bu literatür taraması kapsamında, beyin tümörü segmentasyonu ve sınıflandırması konusunda akademik olarak geliştirilen yöntem ve çalışmalar tartışılarak, konuyla ilgilenen araştırmacıların beyin tümörleri ile ilgili çalışmalarına daha hızlı ulaşabilmesi sağlanarak yaklaşımlar sunulmuştur.

Çalışma kapsamında elde edilen bulgulara göre beyin tümörü tespit sürecinde izlenen segmentasyon yöntemlerinin sınıflandırma sürecinin önemli bir parçası olduğu görülmektedir. Tümör bölgesinin tespit edilmesini, çalışma alanının daraltılmasını ve daha doğru sonuçların elde edilmesini sağlayan bu yöntemler topluluğu, bir sonraki adım olan özellik çıkarımına da ışık tutmaktadır.

Özellik çıkarma yöntemleri, sınıflandırma işlemlerine uygun olmayan görüntüyü dijital veriye dönüştürerek sınıflandırma için kullanıma sunar. Başka bir deyişle özellik çıkarma yöntemleri, sınıflandırma yöntemleri için mevcut görüntü verilerinin anlamlandırılmasına hizmet eder. Ayrıca özellik çıkarma yöntemleri bazen doğrudan kullanılamayabilir. Bu, veri setine çeşitli ön işlemlerin uygulanmasını gerektirir. Araştırmada bahsedilen ve literatürde geniş bir yere sahip olan GLCM özellikleri, beyin tümörlerinin makine öğrenmesi teknikleri ile sınıflandırılmasında kullanılan en yaygın özellikleri oluşturmaktadır. Verdiği dokusal özellikler sayesinde sınıflandırma yöntemleriyle tümör tipinin belirlenmesine olanak sağlar.

Çalışmada yukarıda anlatılan işlemler sonrasında sınıflandırmaya hazır hale gelen veri setine uygulanan makine öğrenmesi yöntemleri ve sonuçları ele alınmaktadır. Makine öğrenmesi yöntemleri, veri setini eğitim ve test olarak ikiye böldükten sonra eğitilen tekniği test veri seti üzerinde test ederek bir doğruluk oranı sağlar.

Makine öğrenmesi yöntemlerinden farklı olarak öğrenme sürecini katmanlı bir yapıda gerçekleştiren derin öğrenme yöntemleri, özellikle büyük veri setlerinde makine öğrenmesi yöntemlerine göre avantajlıdır. Ayrıca bu öğrenme sürecinin farklılığı, derin öğrenme yöntemlerini dinamik veri setlerinde kullanıma uygun hale getirmektedir. Bu çalışmada incelenen yöntemler dikkate alındığında makine öğrenmesi yöntemleriyle elde edilen doğruluk oranlarının genel olarak derin öğrenmenin gerisinde kaldığı görülmektedir. Bunun en büyük nedeni derin öğrenme yöntemlerinin öğrenme tekniği olan transfer öğrenme yöntemidir.

Manuel segmentasyon ve sınıflandırma, MR tabanlı sınıflandırma ve segmentasyon yöntemlerinin günlük klinik işlemlere uyarlanması için yeterli değildir. Geliştirilmiş CNN mimarileri otomatik segmentasyon ve sınıflandırma görevine yardımcı olabilir. Ayrıca otomatik modeller sadece

MR tekniklerini değil diğer görüntüleme tekniklerini de destekleyebilmektedir. MR cihazlarının standardizasyonunun iyileştirilmesi de otomatik segmentasyon ve sınıflandırma sürecinin geliştirilmesine yardımcı olabilir.

KAYNAKÇA

- Abbas, K., Khan, P. W., Ahmed, K. T., & Song, W. C. (2019, October). Automatic brain tumor detection in medical imaging using machine learning. In 2019 International conference on information and communication technology convergence (ICTC) (pp. 531-536). IEEE.
- Abbasi, S., & Tajeripour, F. (2017). Detection of brain tumor in 3D MRI images using local binary patterns and histogram orientation gradient. *Neurocomputing*, 219, 526-535.
- Amin, J., Sharif, M., Yasmin, M., & Fernandes, S. L. (2020). A distinctive approach in brain tumor detection and classification using MRI. *Pattern Recognition Letters*, 139, 118-127.
- Amin, S. E., & Megeed, M. A. (2012, May). Brain tumor diagnosis systems based on artificial neural networks and segmentation using MRI. In 2012 8th International Conference on Informatics and Systems (INFOS) (pp. MM-119). IEEE.
- Anilkumar, B., & Kumar, P. R. (2020). Tumor classification using block wise fine tuning and transfer learning of deep neural network and KNN classifier on MR brain images. *Int. J. Emerg. Trends Eng. Res*, 8(2), 574-583.
- Anjali, R., & Priya, S. (2017). An efficient classifier for brain tumor classification. *Int J Comput Sci Mob Comput*, 6(8), 40-48.
- Cheng, J., Huang, W., Cao, S., Yang, R., Yang, W., Yun, Z., ... & Feng, Q. (2015). Enhanced performance of brain tumor classification via tumor region augmentation and partition. *PloS one*, 10(10), e0140381.
- Çınarar, G., & Emiroğlu, B. G. (2019, October). Classification of brain tumors by machine learning algorithms. In 2019 3rd international symposium on multidisciplinary studies and innovative technologies (ISMSIT) (pp. 1-4). IEEE.
- Çınar, A., & Yildirim, M. (2020). Detection of tumors on brain MRI images

- using the hybrid convolutional neural network architecture. *Medical hypotheses*, 139, 109684.
- Das, S., Aranya, O. R. R., & Labiba, N. N. (2019, May). Brain tumor classification using convolutional neural network. In 2019 1st International Conference on Advances in Science, Engineering and Robotics Technology (ICASERT) (pp. 1-5). IEEE.
- Das, S., Nayak, G. K., Saba, L., Kalra, M., Suri, J. S., & Saxena, S. (2022). An artificial intelligence framework and its bias for brain tumor segmentation: A narrative review. *Computers in biology and medicine*, 143, 105273.
- Deepak, S., & Ameer, P. M. (2019). Brain tumor classification using deep CNN features via transfer learning. *Computers in biology and medicine*, 111, 103345.
- Devkota, B., Alsadoon, A., Prasad, P. W. C., Singh, A. K., & Elchouemi, A. (2018). Image segmentation for early stage brain tumor detection using mathematical morphological reconstruction. *Procedia Computer Science*, 125, 115-123.
- Dubey, R. B., Hanmandlu, M., & Vasikarla, S. (2011, April). Evaluation of three methods for MRI brain tumor segmentation. In 2011 eighth international conference on information technology: new generations (pp. 494-499). IEEE.
- Eddy, W. F., Fitzgerald, M., & Noll, D. C. (1996). Improved image registration by using Fourier interpolation. *Magnetic resonance in medicine*, 36(6), 923-931.
- Foo, J. L. (2006). A survey of user interaction and automation in medical image segmentation methods. Iowa State University Human Computer Interaction Technical Report ISU-HCI-2006-02.
- Goel, N. J., Bird, C. E., Hicks, W. H., & Abdullah, K. G. (2021). Economic implications of the modern treatment paradigm of glioblastoma: an

- analysis of global cost estimates and their utility for cost assessment. *Journal of Medical Economics*, 24(1), 1018-1024.
- Hill, D. L. G., Batchelor, P. G., Holden, M., & Hawkes, D. J. (2001). Medical image registration *Physics in Medicine and Biology*, Vol. 46, pp. R1–R45.
- Iftekharuddin, K. M., Zheng, J., Islam, M. A., & Ogg, R. J. (2009). Fractal-based brain tumor detection in multimodal MRI. *Applied Mathematics and Computation*, 207(1), 23-41.
- Ito, R., Nakae, K., Hata, J., Okano, H., & Ishii, S. (2019). Semi-supervised deep learning of brain tissue segmentation. *Neural Networks*, 116, 25-34.
- Jalali, V., & Kaur, D. (2020). A study of classification and feature extraction techniques for brain tumor detection. *International Journal of Multimedia Information Retrieval*, 9(4), 271-290.
- Jayachandran, A., & Dhanasekaran, R. (2013). Brain tumor detection and classification of MR images using texture features and fuzzy SVM classifier. *Research Journal of Applied Sciences, Engineering and Technology*, 6(12), 2264-2269.
- Joseph, N., Sanghani, P., & Ren, H. (2017, December). Semi-automated segmentation of glioblastomas in brain MRI using machine learning techniques. In *2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA)* (pp. 1149-1152). IEEE.
- Kaplan, K., Kaya, Y., Kuncan, M., & Ertunç, H. M. (2020). Brain tumor classification using modified local binary patterns (LBP) feature extraction methods. *Medical hypotheses*, 139, 109696.
- Burton, T., Jenkins, N., Sharpe, D., & Bossanyi, E. (2011). *Wind Energy Handbook, Second Edition. Wind Energy Handbook, Second Edition.*
- Khan, M. A., Ashraf, I., Alhaisoni, M., Damaševičius, R., Scherer, R., Rehman, A., & Bukhari, S. A. C. (2020). Multimodal brain tumor

- classification using deep learning and robust feature selection: A machine learning application for radiologists. *Diagnostics*, 10(8), 565.
- Menze, B. H., Jakab, A., Bauer, S., Kalpathy-Cramer, J., Farahani, K., Kirby, J., ... & Van Leemput, K. (2014). The multimodal brain tumor image segmentation benchmark (BRATS). *IEEE transactions on medical imaging*, 34(10), 1993-2024.
- Mohsen, H., El-Dahshan, E. S. A., El-Horbaty, E. S. M., & Salem, A. B. M. (2018). Classification using deep learning neural networks for brain tumors. *Future Computing and Informatics Journal*, 3(1), 68-71.
- Ostrom, Q. T., Krebs, H. L., Patil, N., Cioffi, G., & Barnholtz-Sloan, J. S. (2021). Racial/ethnic disparities in treatment pattern and time to treatment for adults with glioblastoma in the US. *Journal of Neuro-Oncology*, 152, 603-615.
- Özyurt, F., Sert, E., Avci, E., & Dogantekin, E. (2019). Brain tumor detection based on Convolutional Neural Network with neutrosophic expert maximum fuzzy sure entropy. *Measurement*, 147, 106830.
- Pratondo, A., Chui, C. K., & Ong, S. H. (2017). Integrating machine learning with region-based active contour models in medical image segmentation. *Journal of Visual Communication and Image Representation*, 43, 1-9.
- Raj, A., Anil, A., Deepa, P. L., Aravind Sarma, H., & Naveen Chandran, R. (2020). BrainNET: A Deep Learning Network for Brain Tumor Detection and Classification. In *Advances in Communication Systems and Networks: Select Proceedings of ComNet 2019* (pp. 577-589). Springer Singapore.
- Raja, P. S. (2020). Brain tumor classification using a hybrid deep autoencoder with Bayesian fuzzy clustering-based segmentation approach. *Biocybernetics and Biomedical Engineering*, 40(1), 440-453.
- Sachdeva, J., Kumar, V., Gupta, I., Khandelwal, N., & Ahuja, C. K. (2011, December). Multiclass brain tumor classification using GA-SVM. In

- 2011 Developments in E-systems Engineering (pp. 182-187). IEEE.
- Sachdeva, J., Kumar, V., Gupta, I., Khandelwal, N., & Ahuja, C. K. (2013). Segmentation, feature extraction, and multiclass brain tumor classification. *Journal of digital imaging*, 26, 1141-1150.
- Said, A. M., & Ibrahim, F. S. (2017). Comparative study of segmentation techniques for detection of tumors based on MRI brain images. *Int. J. Biosci. Biochem. Bioinform*, 8, 1-1.
- Saman, S., & Jamjala Narayanan, S. (2019). Survey on brain tumor segmentation and feature extraction of MR images. *International journal of multimedia information retrieval*, 8, 79-99.
- Sarhan, A. M. (2020). Brain tumor classification in magnetic resonance images using deep learning and wavelet transform. *Journal of Biomedical Science and Engineering*, 13(06), 102.
- Seetha, J., & Raja, S. S. (2018). Brain tumor classification using convolutional neural networks. *Biomedical & Pharmacology Journal*, 11(3), 1457.
- Selvaraj, H., Selvi, S. T., Selvathi, D., & Gewali, L. (2007). Brain MRI slices classification using least squares support vector machine. *International journal of intelligent computing in medical sciences & image processing*, 1(1), 21-33.
- Sharath Chander, P., Soundarya, J., & Priyadharsini, R. (2020). Brain tumour detection and classification using K-means clustering and SVM classifier. In *RITA 2018: Proceedings of the 6th International Conference on Robot Intelligence Technology and Applications* (pp. 49-63). Springer Singapore.
- Soltaninejad, M., Ye, X., Yang, G., Allinson, N., & Lambrou, T. (2014). Brain tumour grading in different MRI protocols using SVM on statistical features.
- Tiwari, A., Srivastava, S., & Pant, M. (2020). Brain tumor segmentation and

- classification from magnetic resonance images: Review of selected methods from 2014 to 2019. *Pattern recognition letters*, 131, 244-260.
- Uma, K., Suhasini, K., & Vijayakumar, M. (2016). A comparative analysis of brain tumor segmentation techniques. *Indian Journal of Science and Technology*, 9(48).
- Widhiarso, W., Yohannes, Y., & Prakarsah, C. (2018). Brain tumor classification using gray level co-occurrence matrix and convolutional neural network. *IJEIS (Indonesian Journal of Electronics and Instrumentation Systems)*, 8(2), 179-190.
- Yao, J. (2006). *Image Processing in Tumor Imaging, New Techniques in Oncologic Imaging*. Zhang, F., & Hancock, ER Zhang.(2010). New Riemannian techniques for directional and tensorial image data. *Pattern Recognition*, 43(4), 1590-1606.
- Zhang, Y., Zou, P., Mulhern, R. K., Butler, R. W., Laningham, F. H., & Ogg, R. J. (2008). Brain structural abnormalities in survivors of pediatric posterior fossa brain tumors: a voxel-based morphometry study using free-form deformation. *NeuroImage*, 42(1), 218-229.
- Zikic, D., Ioannou, Y., Brown, M., & Criminisi, A. (2014). Segmentation of brain tumor tissues with convolutional neural networks. *Proceedings MICCAI-BRATS*, 36(2014), 36-39.
- Zikic, D., Ioannou, Y., Brown, M., & Criminisi, A. (2014). Segmentation of brain tumor tissues with convolutional neural networks. *Proceedings MICCAI-BRATS*, 36(2014), 36-39.
- Zitova, B., & Flusser, J. (2003). Image registration methods: a survey. *Image and vision computing*, 21(11), 977-1000.

