

Manyetik Rezonans (MR) İmgelerinde Beyin Tümörlerinin Tespiti ve Sınıflandırılması

Makbule Hilal Müteveli

YÜKSEK LİSANS TEZİ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Aralık 2020

The Detection and Classification of Brain Tumors on Magnetic Resonance (MR) Images

Makbule Hilal Mütevelli

MASTER OF SCIENCE THESIS

Department of Electrical and Electronics Engineering

December 2020

Manyetik Rezonans (MR) İmgelerinde Beyin Tümörlerinin Tespiti ve Sınıflandırılması

Makbule Hilal Müteveli

Eskişehir Osmangazi Üniversitesi
Fen Bilimleri Enstitüsü
Lisansüstü Yönetmeliği Uyarınca
Elektrik Elektronik Mühendisliği Anabilim Dalı
Telekomünikasyon - Sinyal İşleme Bilim Dalında
YÜKSEK LİSANS TEZİ
Olarak Hazırlanmıştır

Danışman: Doç. Dr. Semih ERGİN

Aralık 2020

ETİK BEYAN

Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre, Doç. Dr. Semih Ergin danışmanlığında hazırlamış olduğum “Manyetik Rezonans (MR) İmgelerinde Beyin Tümörlerinin Tespiti ve Sınıflandırılması” başlıklı YÜKSEK LİSANS tezimin özgün bir çalışma olduğunu; tez çalışmamın tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; tezimde verdiğim bilgileri, verileri akademik ve bilimsel etik ilke ve kurallara uygun olarak elde ettiğimi; tez çalışmamda yararlandığım eserlerin tümüne atıf yaptığımı ve kaynak gösterdiğimi ve bilgi, belge ve sonuçları bilimsel etik ilke ve kurallara göre sunduğumu beyan ederim. 08/12/2020

Makbule Hilal Müteveli

ÖZET

Beyin tümörünün doğru ve otomatik tespiti hayati önem taşımaktadır. Bu tez çalışmasının amacı Manyetik Rezonans (MR) imgelerinde beyin tümörlerini tespit ederek bu tümörleri yüksek doğruluk oranıyla sınıflandırmaktır. Beyin MR imgelerinde kafatası ile beyin dokusunun benzer yoğunluğa sahip olması tümörün yerini belirlemek için yapılan şüpheli bölge tespitini zorlaştırmaktadır. Bu nedenle MR imgelerine, ikilileştirme yöntemi ve çeşitli morfolojik işlemler uygulanarak öncelikle kafatası ortadan kaldırılmıştır. Daha sonra K-means Kümeleme, Lab Renk Uzayında K-means Kümeleme ve Kenarsız Chan-Vese algoritmaları kullanılarak MR imgelerinde şüpheli bölge tespiti yapılmıştır. Bu aşamada üç farklı yöntemin performans değerlendirmesine bakılmış olup en iyi sonucu Kenarsız Chan-Vese algoritmasında ortaya çıktığı görülmüştür. Tespit edilen şüpheli bölgelerden sınıflandırma aşaması için ayırt ediciliği önemli olan Şekil Tabanlı öznitelikler, Gri Seviye Eş-Oluşum Matrisi öznitelikleri, Yönlendirilmiş Gradyanların Histogramı öznitelikleri, Yerel İkili Örüntü öznitelikleri ve İstatistiksel öznitelikler gibi çeşitli öznitelikler çıkarılmıştır. Son olarak şüpheli bölgeler k-En Yakın Komşu, Fisher Doğrusal Ayırtaç Analizi, Rastgele Orman, Karar Ağacı, Destek Vektör Makineleri, Lojistik Regresyon Sınıflandırıcısı ve Naive Bayes sınıflandırma algoritmaları ile sınıflandırılmıştır. Bu tez çalışması sonucunda, Kenarsız Chan-Vese algoritmasından elde edilen tüm şüpheli bölgelerin, iyi huylu tümör, kötü huylu tümör ve normal olarak sınıflandırma işleminde HOG ve LBP öznitelikleri birlikte kullanıldığında Fisher Doğrusal Ayırtaç Analizi sınıflandırıcısı %93,01 doğruluk, %93,46 hassasiyet ve %96,50 özgüllük oranları ile en iyi sonucu sağlamıştır.


Anahtar Kelimeler: Beyin tümörü, bilgisayar destekli teşhis, kafatasının ortadan kaldırılması, şüpheli bölge tespiti, öznitelik çıkarımı, sınıflandırma, MR imgeleri

SUMMARY

Accurate and automatic detection of brain tumor is vital. The aim of this thesis study is to detect brain tumors on Magnetic Resonance (MR) images and to classify these tumors with high accuracy. The similar intensity of skull and brain tissue in the MR images makes it difficult to detect suspicious regions. For this reason, the skull was removed by applying Binarization method and various Morphological operations to MR images. Suspicious regions in the MR images were detected by using K-means Clustering, K-means Clustering in Lab Color Space and Chan-Vese without edges algorithm. At this stage, performance evaluation of three different methods was examined and it was seen that the best result take place in the Chan-Vese without edges algorithm. For the classification stage, various features such as Shape-Based features, Gray Level Co-Occurrence Matrix features, Histogram of Oriented Gradients features, Local Binary Pattern features, and Statistical features were extracted from the detected suspicious regions. Finally, the suspicious regions were classified by k-Nearest Neighbor, Fisher's Linear Discriminant Analysis, Random Forest, Decision Tree, Support Vector Machines, Logistic Linear Classifier and Naive Bayes classification algorithms. As a result of this thesis study, all suspicious regions obtained from the Chan-Vese without edges algorithm were classified as benign tumor, malignant tumor and normal. When the HOG and LBP features are used together, the Fisher's Linear Discriminant Analysis classifier provided the best results with 93.01% accuracy, 93.46% sensitivity and 96.50% specificity rates.

Keywords: Brain tumor, computer aided diagnosis, skull removal, suspicious region detection, feature extraction, classification, MRI

TEŞEKKÜR



İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	vi
SUMMARY	vii
TEŞEKKÜR.....	viii
İÇİNDEKİLER.....	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ.....	xii
SİMGELER VE KISALTMALAR DİZİNİ.....	xiv
1. GİRİŞ VE AMAÇ	1
2. LİTERATÜR ARAŞTIRMASI	3
2.1. Kafatasının MR İmgelerinde Ortadan Kaldırılması Üzerine Yapılan Çalışmalar	3
2.2. MR İmgelerinde Şüpheli Bölge Tespiti Üzerine Yapılan Çalışmalar	5
2.3. Elde Edilen Şüpheli Bölgelerin Sınıflandırılması Üzerine Yapılan Çalışmalar	8
3. MR İMGELERİNDE KAFATASININ ORTADAN KALDIRILMASI	13
3.1. İkileştirme	13
3.2. Açma İşlemi	13
3.3. Delik Doldurma İşlemi	14
3.4. Genişletme İşlemi	14
3.5. Maskeleye	14
4. MR İMGELERİNDE ŞÜPHELİ BÖLGE TESPİTİ.....	16
4.1. K-Means Kümeleme	16
4.2. Lab Renk Uzayında K-Means Kümeleme	17
4.3. Kenarsız Chan-Vese Aktif Kontur Modeli	18
5. MR İMGELERİNDE TESPİT EDİLEN ŞÜPHELİ BÖLGELERDEN	
ÖZİNİTELİK ÇIKARTIMI	22
5.1. Şekil Tabanlı Öznelikler	22
5.2. Gri Seviye Eş-Oluşum Matrisi Öznelikleri	23
5.3. Yönlendirilmiş Gradyanların Histogramı Öznelikleri	28
5.4. Yerel İkili Örüntü Öznelikleri	29

İÇİNDEKİLER (devam)

	<u>Sayfa</u>
5.5. İstatistiksel Öznitelikler	30
6. MR İMGELERİNDEN ELDE EDİLEN ŞÜPHELİ BÖLGELERİN SINIFLANDIRILMASI	32
6.1. k-En Yakın Komşu Sınıflandırıcısı.....	32
6.2. Fisher Doğrusal Ayırtaç Analizi Sınıflandırıcısı	33
6.3. Karar Ağacı Sınıflandırıcısı	33
6.4. Rasgele Orman Sınıflandırıcısı.....	34
6.5. Destek Vektör Makineleri Sınıflandırıcısı	34
6.6. Naive Bayes Sınıflandırıcısı	35
6.7. Lojistik Doğrusal Sınıflandırıcısı.....	36
7. MATERYAL VE YÖNTEM	37
7.1. Kullanılan Veri Tabanı	37
7.2. MR İmgelerinde Kafatasının Ortadan Kaldırılması.....	37
7.3. MR İmgelerinde Şüpheli Bölge Tespiti	39
7.4. MR İmgelerinde Tespit Edilen Şüpheli Bölgelerden Öznitelik Çıkartımı	42
7.5. Şüpheli Bölgelerin Sınıflandırılması	43
8. BULGULAR VE TARTIŞMA	44
9. SONUÇ VE ÖNERİLER	53
KAYNAKLAR DİZİNİ.....	55

ŞEKİLLER DİZİNİ

<u>Sekil</u>	<u>Sayfa</u>
4. 1. Chan-Vese algoritmasının temel çalışma mantığı.....	20
5. 1. GLCM oluşturulurken kullanılan farklı yönler	24
5. 2. GLCM matrisinin oluşum örneği	24
5. 3. LBP oluşumu	29
6. 1. k -NN sınıflandırıcısının çalışma mantığı.....	32
6. 2. SVM çalışma mantığı	35
7. 1. Gri tonlamalı imge.....	37
7. 2. İkili imge	37
7. 3. Birbirine bağlı en büyük bileşeni bulunan imge.....	38
7. 4. Açma işlemi uygulanan imge	38
7. 5. Beyin imgesi	38
7. 6. Delik doldurma işlemi uygulanan imge.....	38
7. 7. Genişletme işlemi uygulanan imge	39
7. 8. Kafatası ortadan kaldırılan imge.....	39
7. 9. K-means kümeleme algoritması ile şüpheli bölge tespiti.....	40
7. 10. Lab renk uzayında K-means kümeleme algoritması ile şüpheli bölge tespiti	41
7. 11. Kenarsız Chan-Vese aktif kontur algoritması ile şüpheli bölge tespiti	41

ÇİZELGELER DİZİNİ

<u>Çizelge</u>	<u>Sayfa</u>
5. 1. Bilinmesi gereken eşitlikler	25
5. 2. GLCM matrisinden çıkartılan doku öznitelikleri ve matematiksel gösterimleri	26
5. 3. İstatistiksel öznitelikler ve matematiksel gösterimleri	31
7. 1. Performans Değerlendirme Kriterleri	39
8. 1. Algoritmaların Karmaşıklık Matrisleri ve Başarı Durumları	44
8. 2. K-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden şekil tabanlı öznitelikler çıkartılarak elde edilen sınıflandırma başarıları (%)	45
8. 3. K-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden GLCM öznitelikleri çıkartılarak elde edilen sınıflandırma başarıları (%)	45
8. 4. K-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden HOG öznitelikleri çıkartılarak elde edilen sınıflandırma başarıları (%)	45
8. 5. K-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden LBP öznitelikleri çıkartılarak elde edilen sınıflandırma başarıları (%)	45
8. 6. K-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden istatistiksel öznitelikler çıkartılarak elde edilen sınıflandırma başarıları (%)	45
8. 7. Lab renk uzayında k-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden şekil tabanlı öznitelikler çıkartılarak elde edilen sınıflandırma başarıları (%)	46
8. 8. Lab renk uzayında k-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden GLCM öznitelikleri çıkartılarak elde edilen sınıflandırma başarıları (%)	46
8. 9. Lab renk uzayında k-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden HOG öznitelikleri çıkartılarak elde edilen sınıflandırma başarıları (%) ..	46
8. 10. Lab renk uzayında k-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden LBP öznitelikleri çıkartılarak elde edilen sınıflandırma başarıları (%)....	46
8. 11. Lab renk uzayında k-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden istatistiksel öznitelikler çıkartılarak elde edilen sınıflandırma başarıları (%)	47
8. 12. Kenarsız Chan-Vese aktif kontur algoritması sonucu ortaya çıkan şüpheli bölgelerden şekil tabanlı öznitelikler çıkartılarak elde edilen sınıflandırma başarıları (%)	47
8. 13. Kenarsız Chan-Vese aktif kontur algoritması sonucu ortaya çıkan şüpheli bölgelerden GLCM öznitelikleri çıkartılarak elde edilen sınıflandırma başarıları (%)	47

ÇİZELGELER DİZİNİ (devam)

<u>Çizelge</u>	<u>Sayfa</u>
8. 14. Kenarsız Chan-Vese aktif kontur algoritması sonucu ortaya çıkan şüpheli bölgelerden HOG öznitelikleri çıkartılarak elde edilen sınıflandırma başarıları (%) ..	47
8. 15. Kenarsız Chan-Vese aktif kontur algoritması sonucu ortaya çıkan şüpheli bölgelerden LBP öznitelikleri çıkartılarak elde edilen sınıflandırma başarıları (%)....	48
8. 16. Kenarsız Chan-Vese aktif kontur algoritması sonucu ortaya çıkan şüpheli bölgelerden istatistiksel öznitelikler çıkartılarak elde edilen sınıflandırma başarıları (%).....	48
8. 17. Kenarsız Chan-Vese yöntemi sonucu ortaya çıkan şüpheli bölgelerden çıkartılan beş farklı öznitelik vektörünün farklı kombinasyonları kullanılarak elde edilen sınıflandırma doğruluk değerleri (%) ve öznitelik boyutları	48
8. 18. GLCM ve LBP öznitelikleri birlikte kullanılarak elde edilen sınıflandırma başarıları (%).....	50
8. 19. HOG ve LBP öznitelikleri birlikte kullanılarak elde edilen sınıflandırma başarıları (%).....	50
8. 20. Şekil tabanlı, GLCM ve LBP öznitelikleri birlikte kullanılarak elde edilen sınıflandırma başarıları (%).....	50
8. 21. Şekil tabanlı, HOG ve LBP öznitelikleri birlikte kullanılarak elde edilen sınıflandırma başarıları (%).....	50
8. 22. Şekil tabanlı, LBP ve istatistiksel öznitelikleri birlikte kullanılarak elde edilen sınıflandırma başarıları (%).....	50
8. 23. GLCM, LBP ve istatistiksel öznitelikler birlikte kullanılarak elde edilen sınıflandırma başarıları (%).....	51
8. 24. HOG, LBP ve istatistiksel öznitelikler birlikte kullanılarak elde edilen sınıflandırma başarıları (%)	51
8. 25. Şekil tabanlı, GLCM, LBP ve istatistiksel öznitelikler birlikte kullanılarak elde edilen sınıflandırma başarıları (%).....	51
8. 26. Şekil tabanlı, HOG, LBP ve istatistiksel öznitelikler birlikte kullanılarak elde edilen sınıflandırma başarıları (%).....	51
8. 27. HOG ve LBP öznitelikleri birlikte kullanılarak elde edilen sınıf bazında başarımlar oranları (%).....	51
8. 28. Literatürde Harvard veri tabanı kullanılarak elde edilen başarımlar oranları ile bu tezde elde edilen başarımlar oranlarının kıyaslanması.....	52

SİMGELER VE KISALTMALAR DİZİNİ

<u>Simgeler</u>	<u>Açıklama</u>
α_i	Destek Vektör Makineleri Sınıflandırıcısında Lagrange çarpanları
d	GLCM matrisinin oluşumunda kullanılan uzaklık parametresi
D	Şekil tabanlı özniteliklerden çap
Y	Şekil tabanlı özniteliklerden yuvarlaklık
w	Fisher Doğrusal Ayırtaç Analizi Sınıflandırıcısında yansıtılmış vektör
σ	Standart sapma parametresi
μ	Ortalama parametresi
θ	GLCM matrisinin oluşumunda kullanılan yön parametresi
\ominus	Morfolojik işlemlerde aşındırma operatörü
\oplus	Morfolojik işlemlerde genişletme operatörü

SİMGELER VE KISALTMALAR DİZİNİ (devam)

<u>Kısaltmalar</u>	<u>Açıklama</u>
BDT	Bilgisayar Destekli Teşhis
FLDA	Fisher's Linear Discriminant Analysis (Fisher Doğrusal Ayırtaç Analizi)
GLCM	Gray Level Co-Occurrence Matrix (Gri Seviye Eş-Oluşum Matrisi)
HOG	Histogram of Oriented Gradients (Yönlendirilmiş Gradyanların Histogramı)
<i>k</i> -NN	<i>k</i> -Nearest Neighbor (<i>k</i> -En Yakın Komşu)
LBP	Local Binary Pattern (Yerel İkili Örüntü)
LLC	Logistic Linear Classifier (Lojistik Doğrusal Sınıflandırıcısı)
MR	Manyetik Rezonans (Magnetic Resonance)
PCA	Principal Component Analysis (Temel Bileşen Analizi)
RGB	Red, Green, Blue (Kırmızı, Yeşil, Mavi)
ROI	Region of Interest (İlgi Bölge)
SVM	Support Vector Machines (Destek Vektör Makineleri)

1. GİRİŞ VE AMAÇ

Beyin tümörü, çok hızlı çoğalan hücrelerin anormal bir şekilde büyümesinden dolayı ortaya çıkmaktadır. Tümörler, beyin zarının etrafındaki beyin hücrelerinden, bezelerden ve sinirlerden kaynaklanır. Beyin tümörleri doğrudan beyin hücrelerini mahvedebilir veya kafatası içine fazla baskı yaparak hücrelere zarar verebilir (Amin vd., 2017; Sehgal vd., 2016). Beyin tümörleri birincil (primer) ve ikincil (seconder) olmak üzere ikiye ayrılır. Eğer beyin kendi hücrelerinden oluşuyorsa birincil beyin tümörleri olup iyi huylu tümör (benign) ve kötü huylu tümör (malignant) olarak sınıflandırılır. İkincil beyin tümörleri ise, vücudun başka herhangi bir noktasında oluşan kanserli hücrelerin beyne sıçramasıyla meydana gelir. İyi huylu beyin tümörü yavaş büyüme gösterir. Genellikle kafatası içinde fakat beyin dokusu dışında gelişir. Diğer organlardaki iyi huylu tümörlere göre daha tehlikelidir. Kanserli olmasa dahi belirli bir büyüklüğe geldiğinde beyin bazı bölgelerine baskı yaparak ciddi ve hayati sorunlara neden olabilir. Az rastlanılsa da zaman içerisinde kötü huylu tümöre dönüşme olasılığı vardır. Kötü huylu beyin tümörü çok hızlı bir şekilde büyüme sağlayarak etrafındaki sağlıklı yapıların içine uzanır ve bu yapılara ciddi zararlar verir. Kontrolsüz çoğalan hücrelerden oluşmakta olup çoğunlukla kanser olarak adlandırılır (Strickland, 2002).

Beyin tümörü, ölüme en çok yol açan beyin hastalıklarından birisidir. Bu nedenle beyin tümörünün erken tanısı oldukça önemlidir. Beyin tümörlerinin tespitinde en yaygın kullanılan görüntüleme tekniği Manyetik Rezonans (MR) görüntülemedir. MR görüntüleme, güçlü bir manyetik alan ve radyo dalgalarını kullanarak vücuttaki organ ve yumuşak dokuların ayrıntılı görüntülerini oluşturur. Diğer görüntüleme teknikleri ile karşılaştırıldığında radyasyon kullanmadığı için daha etkilidir. Tümör, çeşitli dokulardan oluşmaktadır. Bu nedenle tek bir tip MR görüntüleme, anormal dokularla ilgili tam bir bilgi veremez. Farklı sekanslarda görüntü almak tamamlayıcı ve ayırt edici bilgiye ulaşmamızı sağlar. Bu çalışmada T1, T2 ve Proton yoğunluğu sekansları ile çekilen MR görüntüleri kullanılmıştır ve her bir kesit resmi beyin üstten görünüşü olan aksiyel düzlemedir (Amin vd., 2017).

Günümüzde tümörlerin tespiti radyoloji uzmanları ve doktorlar tarafından görüntüleme cihazlarından alınan görüntüler ile yapılmaktadır. Fakat bu her zaman hızlı ve doğru bir tespit sağlayamamaktadır. Bu nedenle görüntüleme teknikleri ve hekimler tarafından kaynaklanan hataların en aza düşürülmesi gibi sebepler, Bilgisayar Destekli Teşhis (BDT) sistemlerinin gelişmesini sağlamıştır (Kawa vd., 2015).

Bu tez çalışmasının amacı, Manyetik Rezonans (MR) imgelerinde beyin tümörlerini tespit ederek bu tümörleri yüksek doğruluk oranıyla sınıflandıracak otomatik bir sistem sunmaktır. Bu sistem genel olarak kafatasının ortadan kaldırılması, şüpheli bölge tespiti, öznitelik çıkartımı ve sınıflandırma gibi dört aşamadan oluşmaktadır. Bu aşamalar için Harvard veri tabanı kullanılmıştır. İlk aşama olan kafatasının ortadan kaldırılması, doğru bir şüpheli bölge tespiti ve sınıflandırma aşaması için önemli bir adımdır. Öncelikle MR imgelerine ikilileştirme yöntemi ve çeşitli morfolojik işlemler uygulanarak kafatası atılmıştır. İkinci aşama olan şüpheli bölge tespiti için üç farklı yöntem (K-means Kümeleme, Lab Renk Uzayında K-means Kümeleme ve Kenarsız Chan-Vese) uygulanmıştır. Bu yöntemlerin performansını değerlendirmek için hedef niteliğe ait tahminlerin ve gerçek değerlerin karşılaştırıldığı karmaşıklık matrisi (confusion matrix) her bir yöntem için bulunmuştur. Bu matrisler incelendiğinde şüpheli bölge tespiti için en iyi sonucu Kenarsız Chan-Vese yönteminin verdiği görülmüştür. Üçüncü aşamada, beyin MR imgelerinde tespit edilen şüpheli bölgelerden doku, şekil ve yoğunluk ile ilgili bilgileri veren farklı öznitelikler çıkartılmıştır. Elde edilen özniteliklerin hangi birleşimlerde tümörü tanımlama açısından daha ayırt edici bir bilgiye sahip olduğu sınıflandırma aşaması için önemli bir ayrıntıdır. Son aşama olan sınıflandırmada çeşitli sınıflandırıcılar kullanılmıştır. Şüpheli bölgeler, rastgele çapraz doğrulama (randomized cross-validation) tekniği ile iyi huylu tümör, kötü huylu tümör ve normal olarak sınıflandırılmıştır. Böylelikle en yüksek doğruluğun HOG ve LBP öznitelikleri birlikte kullanıldığında FLDA sınıflandırıcısı ile elde edildiği tespit edilmiştir.

2. LİTERATÜR ARAŞTIRMASI

Bu bölümde MR imgelerinin işlenerek beyin tümörlerinin tespiti ve beyin tümörlerinin sınıflandırılması konularıyla ilgili geçmişte yapılan çalışmalar incelenmiştir. Literatür araştırması üç ana başlıkta verilmiştir. Bu başlıklar kafatasının MR imgelerinde ortadan kaldırılması üzerine yapılan çalışmalar, MR imgelerinde şüpheli bölge tespiti üzerine yapılan çalışmalar ve elde edilen şüpheli bölgelerin sınıflandırılması üzerine yapılan çalışmalardır.

2.1. Kafatasının MR İmgelerinde Ortadan Kaldırılması Üzerine Yapılan Çalışmalar

Zhuang vd. (2006), yeni bir matematiksel algoritma, model tabanlı bir seviye seti (a model-based level set-MLS) sunmuşlardır. Bu algoritmayı seviye seti fonksiyonuna örtülü olarak yerleştirilmiş sıfır seviye eğrisinin evrimini kontrol etmek için geliştirmişlerdir. Eğrinin evrimi, seviye seti eşitliğinde iki terim kullanılarak kontrol edilmiştir. Seviye seti eşitliğinin değerleri gelişen eğrinin hızını belirleyen kuvvetleri temsil etmektedir. İlk kuvvet eğrinin ortalama eğriliğinden türetilmiş olup ikinci kuvvet ise MR görüntülerinde korteksin yoğunluk özelliklerini modellemek için tasarlanmıştır. Bir seviye seti çerçevesindeki bu kuvvetlerin birleşimi, eğriyi beyin yüzeyine doğru itmekte veya çekmektedir. MLS algoritmasının nitelik değerlendirmesi, MLS algoritmasının sonuçları ile farklı MR görüntülerinde uzman segmentasyonu kullanılarak elde edilenlerle karşılaştırılıp gerçekleştirilmiştir. MLS algoritması kafatasının atılmasında iyi sonuçlar vermiştir.

Paul ve Bandhyopadhyay (2012), MR görüntülerini kullanılarak tümör tespitinde herhangi bir manuel işlemden kaçınmak için kafatasının ortadan kaldırılması gerektiğinin önemini vurgulamışlardır. Öncelikle orijinal görüntüden bir maske oluşturmuşlardır. Maske üretimi için Otsu metodu kullanılmıştır. Otsu metodu görüntü eşikleme yaparak gri bir görüntüyü ikili bir görüntüye dönüştürmeyi otomatik olarak gerçekleştirmek için kullanılır. Başarılı eşiklemede ikili bir görüntü elde etmişlerdir. Elde edilen ikili görüntüdeki delikleri doldurmak için flood fill algoritmasını kullanarak maskeyi oluşturmuşlardır. Daha sonra orijinal görüntüye maskeleme işlemini uygulamışlardır. Böylece orijinal görüntüden kafatasını atmışlardır.

Arakeri ve Reddy (2015), kafatasının, beyin yapısıyla benzer yoğunluğundan dolayı piksellerin yanlış sınıflandırılmasına neden olabileceğini ve bu sebeple MR görüntüsünden beyin kafatasının çıkarılmasının segmentasyonda önemli bir ön adım olduğunu belirtmişlerdir. Bu yüzden önce, Otsu'nun yöntemini uygulayarak otomatik olarak hesaplanan bir eşik değeri ile orijinal T2 ağırlıklı MR görüntüsünü ikili bir görüntüye dönüştürmüşlerdir. Böylece kafatası bölgesini her dilimde ortaya çıkarmışlardır. Ortaya çıkan görüntü, bağlı bileşenlerden oluşmaktadır. Daha sonra, beyne karşılık gelen en büyük bağlantılı bileşen için bir arama yapmışlardır. Sonuç olarak kafatası bölgesini, sadece en büyük bağlı bileşendeki pikselleri tutarak ortadan kaldırmışlardır.

Anitha ve Murugavalli (2016), MR görüntülerinde beyne ait olmayan dokuların segmentasyonunun, homojenlik yoğunlukları nedeniyle kafatası sıyırma işlemi için önemli olduğunu belirtmişlerdir. Kafatasını ortadan kaldırmak için Otsu eşikleme yöntemi ve çeşitli morfolojik işlemler kullanmışlardır. Öncelikle Otsu metodu ile optimal bir eşik değeri belirleyerek orijinal MR görüntülerini ikili görüntü haline getirmişlerdir. Daha sonra ikili görüntüye matematiksel morfoloji işlemleri uygulamışlardır. Bunlar aşındırma (erosion), genişletme (dilation) ve bölge doldurmadır (region filling). Önerilen bu algorithma aşındırma işlemini beyin MR görüntüsünün sınırlarındaki pikselleri yani kafatası gibi beyin dışı bölgeleri kaldırmak için yapmışlardır. Genişletme işlemi ise görüntüdeki tüm dokuları güçlendirmek ve bağlamak için uygulamışlardır.

Bahadure vd. (2017), kafatasını atmak için, görüntü konturu kullanılarak otomatik kafatası sıyırma, segmentasyon ve morfolojik işlemlere dayalı kafatası sıyırma, histogram analizine veya eşik değerine dayalı kafatası sıyırma gibi çeşitli tekniklerin olduğundan bahsetmişlerdir. Bahadure vd. (2017), çalışmalarında kafatası dokularını çıkarmak için bir eşik işlemine dayanan kafatası sıyırma tekniği kullanmışlardır. Öncelikle giriş görüntüsünü gri bir görüntüye dönüştürmüşlerdir. Daha sonra eşikleme yaparak görüntüyü ikili görüntüye dönüştürmüşlerdir. Bağlı nesne sayısını bulup beyin bölgesini gösteren nesnenin içine 1 ve dışına 0 atayarak maskeyi bulmuşlardır. Kafatasından sıyrılmış MR görüntülerini almak için orijinal MR görüntüleri ile maskeleyme işlemi gerçekleştirmişlerdir.

2.2. MR İmgelerinde Şüpheli Bölge Tespiti Üzerine Yapılan Çalışmalar

Raj vd. (2011), beyin tümörünün bilgisayar destekli teşhisi için geliştirdikleri bir çalışma sunmuşlardır. Bu çalışma, hem frekans hem de uzamsal alanın geliştirme yaklaşımlarını kapsayarak MR görüntülerinin iyileştirilmesini içermektedir. Önerdikleri yöntemle, dalgacık alanında imgelerden gürültü gidermeyi ve ardından doğrusal olmayan bir geliştirme fonksiyonu kullanarak imgeleri iyileştirmeyi sağlamışlardır. Ayrıca morfolojik filtre kullanarak kenarların güçlendirilmesi için tekrarlayan bir iyileştirme algoritması uygulamışlardır. Nihayetinde eşikleme yöntemi ile birlikte büyük boyutlu yapı elemanlarını kullanarak beyin tümörünün segmentasyonunu gerçekleştirmişlerdir. Simülasyon sonuçları, önerilen yöntemin diğer yeni geliştirilen yöntemlere kıyasla kontrastı önemli ölçüde iyileştirdiğini ve sınırların tespit edilmesinin yanında kenarları da iyileştirdiğini sergilemiştir.

Deshmukh ve Jadhav (2014), MR görüntülerini kullanarak beyin tümörü tespiti için farklı segmentasyon yöntemlerinin gözden geçirilmesini sunmuşlardır ve farklı segmentasyon yöntemlerinin avantajlarını ve dezavantajlarını incelemişlerdir. Gözden geçirilen bu yöntemler Eşikleme (Thresholding), Bölge büyütme (Region-growing), Kümeleme (Clustering), Esnek hesaplama (Soft-computing), Görüntü / Simetri analizi (Image/Symmetry analysis) yöntemleridir. Kümeleme yöntemini K-Means kümeleme (K-Means clustering) ve Buklanık C-Means kümeleme (Fuzzy C-Means clustering) olmak üzere iki başlık altında incelemişlerdir.

Joseph vd. (2014), MR imgelerinde beyin tümörünün tespiti için bilgisayar destekli bir sistem sunmuşlardır. Bu sistem önışleme, K-means kümeleme ve morfolojik filtreleme olmak üzere üç aşamadan oluşmaktadır. Önışleme aşamasında, RGB giriş görüntüsünü gri seviye bir görüntüye dönüştürmüşlerdir. Medyan filtre kullanarak görüntüdeki gürültüyü gidermişlerdir. Daha sonraki aşamada, K-means kümeleme algoritmasını kullanarak görüntüyü bölümlere ayırmışlardır. Kümeleme algoritmasını uyguladıktan sonra yanlış kümelenmiş bölümlerin ortaya çıkma olasılığı olduğundan, morfolojik filtreleme önermişlerdir. Temel morfoloji işlemlerinden oluşan morfolojik filtrelemede, görüntüye aşındırma ve genişletme işlemi uygulamışlardır. Böylece tümör tespitinin doğruluğunu arttırmışlardır.

Chavan vd. (2015), tümörlü bölge tespiti için çeşitli görüntü işleme tekniklerini kullanarak MR görüntülerinin segmentasyonunu sağlamışlardır. Segmentasyon, ilgi bölgeyi (region of interest – (ROI)) ayırt etmek için bir görüntünün anlamlı bölgelere bölünmesi anlamına gelmektedir. Segmentasyon için görüntü iyileştirme (image enhancement), ikilileştirme (binarization) ve morfolojik işlem (morphological operation) gibi basit görüntü işleme tekniklerini uygulamışlardır. Görüntü ikilileştirmeyi, gri bir görüntüyü belli bir eşik değerinde ikili görüntü (siyah - beyaz) haline dönüştüren bir ön işlemci olarak kullanmışlardır.

Nabizadeh ve Kubat (2015), MR görüntülerinde tümörü içeren dilimleri algılayabilen ve tümör alanını tanımlayabilen tam otomatik bir sistem geliştirmişlerdir. Ayrıca, istatistiksel özniteliklerin Gabor dalgacık özniteliklerinden daha yüksek doğruluk verdiğini çeşitli sınıflandırıcılar kullanarak sunmuşlardır. Tümörü içeren dilimleri bulan algoritma altı adım içermektedir. İlk adımda beyni arka plandan ayırmışlardır. İkincisinde, beynin merkezini bulmak için merkez kütle algoritmasını kullanmışlardır. Üçüncüsünde beynin sınırlarını bulmuşlardır. Dördüncüsünde, olası tüm beyin çaplarının uzunluklarını belirlemişlerdir. Beşinci adımda, beyin orta hattı olarak en uzun çapı belirtirmişlerdir. Altıncı adımda, iki beyin yarım küresinin histogramları arasındaki ortak bilgilere dayanarak tümör dilimini bulmuşlardır. Daha sonra tümör alanını bulmak için segmentasyon işlemini uygulamışlardır. Tüm beyin dokusunda kayan bir pencere kullanarak aday tümör bölgelerine ulaşmışlardır. Gabor dalgacık ve istatistiksel öznitelik kümelerini her bir pencere örneğinden çıkarmışlardır. Tümörlü alan tespiti için her öznitelik setini farklı yaklaşımlar uygulanarak sınıflandırmışlardır.

Mandwe ve Anjum (2016), tümör konumunun saptanması amacıyla beyin MR görüntü segmentasyonu için bilgisayar destekli bir sistem önermişlerdir. Bu sistemde kümeleme tekniklerini kullanmışlardır. Kümeleme, aynı zamanda denetimsiz sınıflandırma tekniği olarak da bilinmektedir çünkü kullanılan algoritma, nesnelere otomatik olarak kullanıcı tarafından verilen ölçütlere göre sınıflandırmaktadır. Sundukları sistemde görüntünün segmentasyonu için K-means kümeleme algoritmasını kullanmışlardır. Daha sonra morfolojik filtreleme yaparak beyin MR görüntülerinde tümör tespitini gerçekleştirmişlerdir. Ayrıca bir diğer kümeleme tekniği olan Bulanık C-Means kümeleme

algoritmasını da uygulamışlardır ve bu algoritmanın görüntü segmentasyonunda önemli bir rol oynadığını belirtmişlerdir.

Sehgal vd. (2016), MR imgelerinde beyin tümörlerini tespit etmek için tam otomatik bir yöntem önermişlerdir. Önerilen bu yöntem beş aşamadan oluşmaktadır. Bunlar, Görüntü elde etme, Önileme, Bulanık C-Means kümeleme algoritması kullanılarak yapılan Segmentasyon, Tümör çıkartımı ve Değerlendirmedir. Önileme aşamasında, matematiksel işlemler veya filtreleme teknikleri kullanarak gürültünün giderilmesini ve MR beyin görüntülerinin geliştirilmesini sağlamışlardır. Daha sonra görüntüleri hızlı ve iyi sonuçlar veren Bulanık C-Means kümeleme algoritmasını kullanarak bölümlere ayırmışlardır. Son olarak bölümlere ayrılan bölgelerin daha büyük alana sahip olanlarını bulduktan sonra ayırıcı özelliği olan daireselliği kullanarak tümörü çıkartmışlardır. Otomatik çıkarılan bölgeyi, manuel olarak çıkarılan gerçek bölgelerle karşılaştırarak sonuçları doğrulamışlardır.

Amin vd. (2017), lezyon ve görüntü seviyelerinde beyin tümörünün saptanması için otomatik bir sistem sunmuşlardır. Önerilen sistemi, MR görüntüleri üzerinde test etmişlerdir. Lezyon ve görüntü seviyelerinde olmak üzere iki farklı algoritma kullanmışlardır. Görüntü seviyesinde beyin tümörü tespiti için kullandıkları birinci algoritmada önce giriş görüntüsünden kafatasını atmışlardır. Kafatası atılan görüntüyü gri seviye bir görüntüye dönüştürmüşlerdir. Görüntüyü iyileştirmek için Gauss filtresi uygulamışlardır. Daha sonra segmentasyon için Eşikleme yöntemi kullanmışlardır. Son olarak morfolojik işlem olan genişletme (dilation) işlemini uygulamışlardır. Lezyon seviyesinde beyin tümörü tespiti için kullandıkları ikinci algoritmada ise yine ilk olarak kafatasını atmışlardır. Kafatasını attıktan sonra giriş görüntüsünü Lab renk uzayına dönüştürmüşlerdir. Daha sonra segmentasyon aşamasında bu görüntüye K-means kümeleme algoritmasını uygulamışlardır. Son olarak sırasıyla aşındırma (erosion) ve genişletme (dilation) morfolojik işlemlerini uygulamışlardır. Önerilen bu otomatik sistem, klinik sonuçların hızlı ve etkili bir şekilde saptanmasına yardımcı olmuştur.

Zawish vd. (2019), tümörleri beyin MR görüntü veri setinden doğru bir şekilde bölümlere ayırmak için tam varyasyon yöntemlerine dayanan gelişmiş bir görüntü segmentasyon tekniği sunmuşlardır. Teknik, kenarsız Chan-Vese aktif konturuna dayanmaktadır. Bu yöntemde bir kuvvet, konturu daraltırken başka bir kuvvet konturu

genişletmektedir. Kontur, ilgi bölgelerin sınırına ulaştığı zaman bu iki kuvvet dengelenmektedir. Böylece bölgenin konturu bulunmaktadır. Bu da doğru bir segmentasyonu sağlamıştır. Zawish vd. (2019) algoritmanın etkililiğini çeşitli beyin MR görüntüleri üzerinde test etmiş ve doğrulamışlardır. Önerdikleri yöntemi, tümörü ve tümörün geometrik boyutlarını tespit etmek için başarıyla uygulamışlardır.

2.3. Elde Edilen Şüpheli Bölgelerin Sınıflandırılması Üzerine Yapılan Çalışmalar

Ain vd. (2010), beyin MR görüntülerinden doku özniteliklerini çıkartmışlardır. Doku özniteliklerinden, birinci derece öznitelikler olarak ortalama, varyans, çarpıklık, basıklık, enerji, entropi özniteliklerini eş-oluşum matrisi öznitelikleri olarak da açısız ikinci moment, korelasyon, eylemsizlik, mutlak değer, ters fark, entropi, maksimum olasılık özniteliklerini çıkartmışlardır. Bu öznitelikleri MR görüntüsündeki önemli bilgileri almak için kullanmışlardır. Çıkartılan öznitelikleri sınıflandırmak için topluluk tabanlı sınıflandırıcı olan Destek Vektör Makinesi sınıflandırıcısını kullanmışlardır. Önerdikleri bu sistemde beyin MR görüntülerini iyi huylu tümör ve kötü huylu tümör olarak sınıflandırarak % 99 ' un üzerinde sınıflandırma doğruluğu elde etmişlerdir.

Zulpe ve Pawar (2012), çalışmalarında, dört farklı beyin tümör sınıfı kullanmışlardır. Bunlar astrositom, menenjiyom, metastatik bronkojenik karsinom ve sarkom gibi tümör tipidir. Her sınıf için gri seviye eş oluşum matrisi tabanlı dokusal öznitelikleri çıkartmışlardır. Bunlar homojenlik, kontrast, ters fark momenti, korelasyon, varyans, toplam ortalama, toplam entropi, fark entropi, eylemsizlik gibi dokusal özniteliklerdir. Sınıflandırma işlemde İleri Beslemeli Sinir Ağı yöntemini uygulamışlardır. Sınıflandırma doğruluğunu % 97,5 olarak bulmuşlardır.

Sachdeva vd. (2013), çok sınıflı beyin tümörü sınıflandırmasını, 55 hastadan alınan MR görüntülerini kullanarak gerçekleştirmişlerdir. Bu görüntüler astrositom, glioblastoma multiforme, çocukluk çağı tümörü medulloblastom, menenjiyom, ikincil tümör-metastatik ve normal bölgelerdir. Sekiz yüz elli altı ilgi bölgesini, içerik tabanlı aktif bir kontur modeli ile çıkartmışlardır. Bu ilgi bölgelerden de iki yüz on sekiz tane yoğunluk ve doku özneliği çıkartmışlardır. Öznitelik alanının boyutluluğunu azaltmak için temel bileşen analizi (principal component analysis - PCA) kullanmışlardır. Bu öznitelik alanını daha sonra yapay

sinir ağı (artificial neural network - YSA) ile altı sınıflı olarak sınıflandırmışlardır. Dolayısıyla bu yaklaşımı PCA-YSA yaklaşımı olarak adlandırmışlardır. İlk deneyde YSA yaklaşımı ile sınıflandırma yapmışlardır. İkinci deneyde, rastgele alt örnekleme PCA-ANN yaklaşımı kullanmışlardır. Sınıflandırma doğruluğunun % 77' den % 91' e yükseldiği görülmüştür.

George vd. (2015), MR görüntülerinde bir beyin tümörünün tespitini yapan ve sınıflandıran bir teknik sunmuşlardır. Beyin MR görüntülerinden şekil tabanlı öznelik çıkarımı yapmışlardır. Şekil öznelik kümesini majör eksen uzunluğu, minör eksen uzunluğu, euler sayısı, katılık, alan ve yuvarlaklık özneliklerini çıkararak oluşturmuşlardır. Önerdikleri yöntemde denetimli tekniklere bağlı olarak iki sınıflandırıcı kullanmışlardır. İlk sınıflandırıcı C4.5 karar ağacı algoritması ve ikinci sınıflandırıcı Çok katmanlı algılayıcı algoritmasıdır. Sınıflandırıcıları, beyin görüntülerini normal veya anormal olarak sınıflandırmak amacıyla ve anormal beyin görüntülerini de iyi huylu tümör ve beş tip kötü huylu tümör olarak sınıflandırmak için kullanmışlardır. Çok katmanlı algılayıcı algoritmasının, C4.5 karar ağacı algoritmasından daha iyi doğruluk sağladığını tespit etmişlerdir ve çok katmanlı algılayıcı algoritmasını kullanarak yaklaşık % 95 özgüllük sağlamışlardır.

Praveen ve Agrawal (2016), manyetik rezonans görüntüleri ile beyin tümörü tespiti ve sınıflandırması için hibrit bir yaklaşım önermişlerdir. Önerilen yaklaşımın ilk aşamasında, gürültü filtreleme, kafatası tespiti gibi işlemleri içeren görüntü ön işlemlerini gerçekleştirmişlerdir. İkinci aşamada, gri seviye eş oluşum matrisini kullanılarak MR beyin görüntülerinden homojenlik, korelasyon, kontrast ve enerji özneliklerini çıkartmışlardır. Üçüncü aşamada, En Küçük Kareler Destek Vektör Makinesi sınıflandırıcısını kullanarak görüntüleri normal veya anormal olarak sınıflandırmışlardır. Deneyleri, beyin MR veri setinden 25 normal ve 75 anormal olmak üzere 100 görüntü üzerinde gerçekleştirmişlerdir. Hem eğitim hem de test görüntüleri üzerindeki sınıflandırma doğruluğunu % 96,63 olarak bulmuşlardır.

Priya vd. (2016), beyin tümörü MR görüntülerini, türlerine ve derecelerine göre sınıflandırmak için Destek Vektör Makinesi (Support Vector Machine - SVM) yöntemini kullanmışlardır. MR görüntülerini temelde dört beyin tümör tipi olan Normal, Gliom,

Meningiyom, Metastaz' a ve yaygın bir Gliom tipi olan dört Astrositom derecesine sınıflandırmışlardır. Destek Vektör Makinesi sınıflandırıcısını, birinci dereceden öznitelikleri içeren (ortalama, varyans, çarpıklık, basıklık, entropi), ikinci dereceden öznitelikleri içeren (korelasyon, kontrast, homojenlik, enerji) ve her ikisi birlikte içeren istatistiksel öznitelik kümesini kullanarak uygulamışlardır. Beyin tümörü tipleri ve derece sınıflandırması için, sadece ikinci dereceden öznitelikleri kullanarak sırasıyla % 85 ve % 78,26' lık bir doğruluk, sadece birinci dereceden öznitelikleri kullanarak sırasıyla % 65,517 ve % 62,31 ve her ikisini birlikte kullanarak sırasıyla % 84,48 ve % 68,1 doğruluk elde etmişlerdir. Deneyleri, farklı SVM türleri, çekirdek türleri ve çekirdek türünün gama değerleri için tekrarlamışlardır. Yanlış sınıflandırma analizini, özgüllük ve hassasiyet ölçümlerini kullanarak her öznitelik kümesi için gerçekleştirmişlerdir. Bu çalışmanın sonunda, SVM sınıflandırma yönteminin beyin tümörü tiplerini tatmin edici bir şekilde sınıflandırdığını fakat tümör derece sınıflandırmasında nispeten eksik olduğunu çıkarmışlardır.

Sachdeva vd. (2016), radyologlara çok sınıflı beyin tümörlerinin sınıflandırılmasında yardımcı olacak etkili bir bilgisayar destekli teşhis sistemi geliştirmeyi amaçlamışlardır. Çalışmalarını, 65 hastanın T1 ağırlıklı MR görüntüsüne sahip halka açık bir veri kümesinde gerçekleştirmişlerdir. İlk veri seti, ikincil tümör-Metastatik ile birlikte Astrositom, Glioblastoma Multiforme, çocukluk çağı tümörü Medulloblastom ve Meningiyom gibi birincil beyin tümörlerini içermektedir. İkinci veri seti Astrositom, Düşük Dereceli Glioma ve Meningiyom' dan oluşmaktadır. Tümör bölgelerini içerik tabanlı aktif kontur modeli ile işaretlemişlerdir. Bölgeleri, daha sonra bölümlere ayrılmış ilgi alanları olarak kaydetmişlerdir. 71 tane öznitelikten oluşan yoğunluk ve doku öznitelik setini bu ilgi alanlardan çıkartmışlardır. Bu setten en uygun öznitelik grubunu seçmek için Genetik Algoritmasını kullanmışlardır. Destek Vektör Makinesi ve Yapay Sinir Ağı tekniği ile genetik algoritmasını kullanarak iki hibrit makine öğrenme modeli uygulanmışlardır ve iki farklı veri seti üzerinde test etmişlerdir. İlk veri kümesinin test sonuçlarında, genetik algoritmasının Destek Vektör Makinesi' nin genel doğruluğunu % 79,3' ten % 91,7' ye ve Yapay Sinir Ağı' nın % 75,6' dan % 94,9' a yükselttiğini elde etmişlerdir. İkinci veri kümesi için de benzer sonuçlara ulaşmışlardır. Destek Vektör Makinesi' nin genel doğruluğu % 80,8' den % 89' a ve Yapay Sinir Ağı' nın % 77,5' ten % 94,1' e yükselttiğini belirtmişlerdir.

Deneysel sonuçlarda Yapay Sinir Ağı sınıflandırıcısının Destek Vektör Makinesinden daha iyi sonuçlar verdiğini gözlemlemişlerdir.

Wasule ve Sonar (2017), MR görüntülerinde, beyin tümörünün kötü huylu ve iyi huylu olarak ya da düşük dereceli ve yüksek dereceli gliom olarak sınıflandırılmasına otomatik bir yaklaşım sunmuşlardır. Önerdikleri yöntemde, görüntülerden doku özneliklerini çıkartmak ve bir öznelik vektörü oluşturmak için Gri Seviye Eş-Oluşum Matrisi tekniğini kullanmışlardır. Çıkarılan öznelikleri, denetimli Destek Vektör Makineleri ve k-En Yakın Komşu algoritmalarını kullanarak sınıflandırmışlardır. Önerilen sistemi, klinik veri tabanının 251 görüntüsüne (85 kötü huylu ve 166 iyi huylu) ve Brats 2012 eğitim veri tabanının 80 görüntüsüne (50 düşük dereceli gliom ve 30 yüksek dereceli gliom) uygulamışlardır. Bu sistemin doğruluğunu klinik veri tabanı için sırasıyla Destek Vektör Makineleri ve k-En Yakın Komşu algoritmaları için % 96 ve % 86, Brats veri tabanı için sırasıyla % 85 ve % 72,50 bulmuşlardır.

Hsieh vd. (2017), merkezi sinir sistemi tümörleri olarak yaygın olan gliomların derece sınıflandırmasını yapmak için nicel manyetik rezonans görüntüleme özneliklerine dayanan bilgisayar destekli tanı sistemi geliştirmişlerdir. Bilgisayar destekli tanı performans değerlendirmesi için 34 glioblastoma ve 73 düşük dereceli gliomdan oluşan görüntü veri tabanını kullanmışlardır. Her durumda, çizili bir tümör alanında bulunan dokuları MR görüntülerindeki gri skala yoğunluklarına göre analiz etmişlerdir. Komşu piksel değerleri arasındaki yerel bağıntıları yorumlamak için 14 tane doku özneliği, gliom dokularının global gri skala dağılımlarını açıklamak için ise 4 tane istatistiksel öznelik çıkarmışlardır. Global görüntü öznelikleri olarak ortalama, varyans, çarpıklık, basıklık ve yerel görüntü öznelikleri olarak da otokorelasyon, kontrast, korelasyon, asimetri, çarpıklık, benzersizlik, enerji, entropi, homojenlik, fark varyansı, fark entropisi, korelasyon bilgi ölçeği, normalize edilmiş homojenlik, ters fark momenti özneliklerini çıkarmışlardır. Tümör derecesi tahmin modelini oluşturarak hem bireysel olarak öznelik setini ve hem de her iki öznelik setinin birleşiminden oluşan öznelik setini sınıflandırmak için Lojistik regresyon sınıflandırıcısını kullanmışlardır. Geliştirdikleri bilgisayar destekli tanı sistemi ile global, yerel ve her iki görüntü öznelik setini birlikte kullandıkları durum için sırasıyla % 76, % 83 ve % 88 doğruluk oranı elde etmişlerdir.

Chowdhury vd. (2018), beyin MR taramalarından tümörün saptanması için optimal ve daha doğru bir sisteme odaklanmışlardır ve eğer tümörün varlığı doğrulanırsa tümörü iyi huylu ve kötü huylu olarak sınıflandırmışlardır. Tüm sistem dört aşamadan oluşur: Anizotropik filtreleme, morfolojik işlemler, öznelik çıkartımı ve sınıflandırma. Önerdikleri sistemde, öncelikle anizotropik difüzyon filtresi kullanarak görüntüyü filtrelemişlerdir. Daha sonra MR görüntüleri üzerinde morfolojik işlemler gerçekleştirerek tümörü tespit etmişlerdir. Dalgacık Dönüşümü Ayırıştırma tekniği kullanarak öznelik çıkartma aşamasını tamamlamışlardır. Son olarak, tümörü iyi huylu veya kötü huylu olarak sınıflandırmak için Destek Vektör Makinesi yöntemini kullanmışlardır. Kötü huylu tümörün saptanması için maksimum doğruluğu % 99,02, iyi huylu tümörün saptanması için ise doğruluğu % 99,67 bulmuşlardır.

Asodekar ve Gore (2019), MR görüntülerinden beyin tümörünün saptanmasını ve sınıflandırmasını yapan bir sistem önermişlerdir. Bu sistem ön işleme, ilgi bölgenin çıkartımı, öznelik çıkarımı ve sınıflandırma aşamalarından oluşmaktadır. İlgi bölgeden şekil özneliklerini çıkarmışlardır. Bu öznelik kümesi ağırlık merkezi, yuvarlaklık oranı ve dikdörtgensellik özneliklerinden oluşmaktadır. MR görüntülerini iyi huylu ve kötü huylu tümör olarak sınıflandırmışlardır. Sınıflandırma aşamasında, Rastgele Orman ve Destek Vektör Makinesi sınıflandırıcı algoritmalarını kullanmışlardır. Rasgele Orman sınıflandırıcısı ile % 81,81 hassasiyet, % 81,90 doğruluk ve % 81,96 özgüllük elde etmişlerdir. Destek Vektör Makinesi sınıflandırıcısı ile ise % 77,01 hassasiyet, % 78,57 doğruluk ve % 79,67 özgüllük elde etmişlerdir. Böylece tümörün sınıflandırılması için Rastgele Orman sınıflandırıcısının, Destek Vektör Makinesinden daha iyi doğruluk sağladığını tespit etmişlerdir.

3. MR İMGELERİNDE KAFATASININ ORTADAN KALDIRILMASI

Kafatasının ortadan kaldırılması, biyomedikal görüntü analizinde önemli bir adımdır ve MR imgelerinde beyin tümörünün etkin olarak incelenmesi için gereklidir. Kafatasının atılması, beyin görüntülerindeki beyin dışı tüm dokuların ortadan kaldırılması işlemidir. Beyin MR imgelerinde kafatası ile beyin dokusunun benzer yoğunluğa sahip olması tümörün yerini belirlemek için yapılan şüpheli bölge tespitini zorlaştırmaktadır. Bu nedenle MR imgelerinde, tümörlü bölgeyi etkili bir şekilde saptayabilmek için kafatasının ortadan kaldırılması gerekir. Bu tezde, ikilileştirme (binarization) yöntemi, çeşitli morfolojik işlemler ve maskeleyme uygulanarak kafatası ortadan kaldırılır.

3.1. İkileştirme (Binarization)

Görüntü ikilileştirme, gri tonlamalı görüntüyü belli bir eşik değerinde ikili görüntü (siyah veya beyaz) tabanına dönüştüren, ön işlemci olarak kullanılan bir yöntemdir. Eşik değeri imgeyi ön plan ve arka plan olarak ikiye böler. Eşik değerinin üzerinde kalan kısım imgenin ön planını oluştururken altında kalan kısım da arka planını oluşturur. Böylece gri tonlamalı görüntülerde belirlenen bir eşik değerine göre, eşik değerinin altındaki piksellere 0 (siyah), üzerindeki piksellere ise 1 (beyaz) değeri atanarak görüntü ikilileştirilir (Chavan vd., 2015).

3.2. Açma İşlemi (Opening)

Açma (opening) işlemi, matematiksel morfoloji işlemidir. Temel olarak imge üzerinde aşındırma (erosion) işlemi takip eden genişletme (dilation) işlemi olarak tanımlanır. \ominus aşındırmayı ifade ederken \oplus genişletmeyi ifade etmektedir. A görüntüsünün B yapısal elemanı ile açılması Eşitlik 3.1' deki gibi gösterilir.

$$A \circ B = (A \ominus B) \oplus B \quad (3.1)$$

Açma işlemi, imge içerisindeki nesnenin dış hatlarını yumuşatarak aradaki dar geçitleri koparır ve küçük çıkıntıları yok eder (Firoz et al., 2016).

3.3. Delik Doldurma İşlemi

Delik doldurma işlemi (hole filling operation) medikal görüntü işlemede yaygın olarak kullanılmaktadır. Hemen hemen tüm tıbbi görüntü işleme işlemleri, herhangi bir aşamada ikili bir görüntü üretmektedir. İkili görüntüler, arka plan alanlarıyla çevrili ön plan nesnelere içerirler. Bir delik, bağlı ön plan piksellerin sınırı ile kaplanmış bir arka plan alanı olarak tanımlanabilir. Delik doldurma işleminde amaç, her bir delikte verilen noktalara 1'ler yerleştirilerek bütün delikleri doldurmaktır.

3.4. Genişletme İşlemi (Dilation)

Matematiksel morfolojinin temel işlemlerinden biridir. A görüntüsünün B yapısal elemanı ile genişletilmesi $A \oplus B$ şeklinde ifade edilmektedir. Bu yapısal eleman görüntü üzerinde gezer ve görüntü pikselleri ile herhangi bir benzerlik gösterdiği anda yapısal elemanın merkez pikselinin olduğu noktaya 1 değeri atanır. Hiçbir benzerlik olmayan noktalara ise 0 değeri atanır.

Bu işlemin temel etkisi görüntüyü kenarlarından genişletmektir. Böylece piksel kümeleri büyür ve aralarındaki boşluklar küçülmüş olur. Genişletme işlemi, ikili imgedeki detayları büyütme ve boşlukları doldurma amacıyla kullanılır (Firoz et al., 2016).

3.5. Maskeleye

Maskeleye (masking), imgenin istenen bölgesinin elde edilmesidir. Tez çalışmasında ikili maske görüntüsü elde edilmiştir. İkili maske görüntüsü, piksel yoğunluğu (intensity) değerlerinin bazılarının bir, bazılarının sıfır olduğu bir görüntüdür. İkili maske görüntüsünde piksel yoğunluğu değeri sıfır olduğunda, elde edilen maskelenmiş görüntünün piksel değeri arka plan değerine atanır.

İkili maske, orijinal görüntünün ilgi bölgesini (Region of Interest - ROI) tanımlar. Maskenin 1 olan piksel değerleri, görüntü pikselinin ROI'ye ait olduğunu gösterir.

Maskenin 0 olan piksel deęerleri ise görüntü pikselinin arka planın bir parçası olduğunu gösterir. İkili görüntünün filtrelenen görüntüyle aynı boyutta olması şartıyla herhangi bir ikili görüntü maske olarak kullanılabilir ve maskeleme yapılabilir.

4. MR İMGELERİNDE ŞÜPHELİ BÖLGE TESPİTİ

MR imgelerinin çeşitli görüntü işleme teknikleriyle analiz edilmesi beyin tümörünün kesin teşhisi için önemlidir. Radyoloji uzmanları MR imgelerinde bulunan tümörlü bölgenin büyüklüğünü, şeklini ve konumunu inceleyerek tümör teşhisini yaparlar ve tedavi şekline karar verirler. Bu nedenle bilgisayar destekli teşhis sistemlerinde tüm imgeyi kullanmak yerine tümörlü alanı içermeye şüphesi olan bölgeleri tespit etmek öznelik çıkartma ve sınıflandırma aşamaları için daha verimlidir. Tez çalışmasında K-means Kümeleme (K-means Clustering), Lab Renk Uzayında K-means Kümeleme (K-means Clustering in Lab Color Space) ve Kenarsız Chan-Vese Aktif Kontur (Chan-Vese Active Contour without edges) yöntemleri ayrı ayrı kullanılarak şüpheli bölge tespiti yapılmıştır. Daha sonra bu üç farklı yöntemin performans değerlendirmesine bakılmıştır. Bu bölümde K-means Kümeleme, Lab Renk Uzayında K-means Kümeleme ve Kenarsız Chan-Vese Aktif Kontur Modeli açıklanmıştır.

4.1. K-Means Kümeleme

Kümeleme yöntemleri, nesnelere bazı özellik, nitelik ve karakteristiklere göre gruplar haline getirirler. Bu nedenle bir küme, benzer nesne gruplarından oluşur. Sonuç olarak benzer nesnelere aynı gruba, farklı nesnelere ise farklı gruplara yerleştirilir. K-means kümeleme imgeyi bölütleme için en sık kullanılan kümeleme yöntemlerinde biridir.

K-means kümeleme, karesel hatayı en aza düşürerek imgeleri K tane kümeyle bölümlenmeyi hedefler (Jain ve Dubes, 1988). MR resimlerinde küme, birbirine yakın piksel değerlerini içeren bölgelere karşılık gelmektedir. K-means algoritmasında başlangıçta görüntü kaç bölgeye ayrılmak isteniyorsa o kadar K tane küme sayısı tanımlanır. Daha sonra küme sayısı kadar küme merkezi rastgele seçilir. Her bir veri ile her küme merkezi arasındaki mesafe hesaplanır. Bu mesafe hesaplanırken öklit ölçüm yöntemi kullanılmaktadır. Tek bir verinin her küme merkezi için hesaplanan uzaklıkları karşılaştırılır ve bu veri K tane kümeden en kısa uzaklığa sahip olan kümeyle taşınır. Sonra her küme merkezi yeniden tahmin edilir ve her küme merkezi için mesafeler yeniden hesaplanarak karşılaştırılır. Veriler

kendine en yakın kümeye taşınıp tekrar bir küme merkezine ihtiyaç duyulmayana kadar bu işlem tekrarlanır. Kümelerin yeni merkezleri hesaplanırken ortalamaları alınmaktadır.

Genel olarak K-means kümeleme algoritmasının aşamaları aşağıdaki gibi özetlenebilir.

- K tane küme kadar rastgele küme merkezi seçin.
- Her bir verinin her küme merkezine olan mesafesini hesaplayın.
- K tane kümeden en yakın olana veriyi taşıyın.
- Her küme merkezini yeniden hesaplayın.
- Küme merkez değerlerinde değişiklik olmayana kadar işlemi tekrarlayın.

K-means kümeleme algoritmasında verilerin küme merkezleriyle arasındaki mesafe Eşitlik 4.1' deki gibi hesaplanır. Hata kareler toplamı (error sum of squares - SSE), x merkezine verilerin öklit mesafesini, c_i i ' inci merkezi, K ise küme merkez sayısını göstermektedir.

$$SSE = \sum_{i=1}^K \sum_{x \in c_i} dist^2(c_i, x) \quad (4.1)$$

4.2. Lab Renk Uzayında K-means Kümeleme

Renk uzayı, belirli bir renk organizasyonundaki olası renkler kümesi olarak tanımlanır. Renk uzayları, renk bileşenlerini sayı kümeleri olarak tanımlayan matematiksel modellerdir. Temel olarak, koordinat sisteminin ve alt uzayın detaylandırılmasıdır. Renk uzayları doğada bulunan bütün renkleri temsil ederler. Genel olarak üç temel renk (kırmızı, yeşil, mavi) kullanılmaktadır. Bu temel renkler farklı oranlarda değiştirildiğinde renk çeşitliliği sağlanır (Bhatia, 2004).

Lab renk uzayı, ayrı parlaklık ve renk kanallarına sahip olan renk uzaylarından biridir. Lab renk uzayının bileşenleri L (lightness - ışıklılık), a (tonlama) ve b (doygunluk) olarak gösterilir. Bu renk uzayı üç koordinata sahiptir. L, görüntüdeki rengin açıklığını ya da parlaklığını temsil eder. Değerler $[0, 100]$ aralığındadır. Burada 0, en koyu siyahı ve 100, en parlak beyazı belirtir. L arttıkça renkler daha parlak hale gelmektedir. a, görüntüdeki kırmızı veya yeşil tonların miktarını belirtir. Büyük bir pozitif a değeri kırmızıya karşılık gelir. Büyük bir negatif a değeri yeşile karşılık gelir. Değerler genellikle -128 ve 127

arasında deęişir. b ise görüntüdeki sarı veya mavi tonların miktarını belirtir. Büyük bir pozitif b deęeri sarıya karşılık gelir. Büyük bir negatif b deęeri maviye karşılık gelir. Deęerler genellikle -128 ve 127 arasında deęişir (Aldus, 1992).

Lab renk uzayında k-means kümeleme yöntemi uygulanırken önce tüm imgeler, doğru renk dengesi düzeltilmesi sağladığı düşüldüğünden Lab renk uzayında ifade edilir. Daha sonra bu imgeye k-means kümeleme algoritması uygulanarak imge bölütlenir. Lab renk uzayı algısal yönden düzgün dağılım gösteren bir renk uzayı olması sebebiyle birçok görüntü analizi işleminde tercih edilmektedir (Amin vd., 2017; Bhatia, 2004).

4.3. Kenarsız Chan-Vese Aktif Kontur Modeli

Kenarsız aktif konturlar olarak da bilinen Chan-Vese modeli, bölge tabanlı bir bölütleme (segmentasyon) yöntemidir. İmgedeki ilgi bölgeyi ve arka planı birbirinden ayırır. Bu model, kontur (çevre biçimi) deęişimini ve düzey kümesi yöntemini kullanır. Chan-Vese modelinin klasik aktif kontur modellerinden temel farklılıkları, ilgi bölgenin sınırları üzerindeki kontur deęişimini sonlandırmak için imgenin gradyanına baęlı olmaması ve kontrol noktaları kullanmamasıdır (Chan ve Vese, 2001). Başka bir ifadeyle, kenarları yok sayar ve sadece sınırlardaki verileri deęil bölgelerdeki verileri de hesaba katar. Chan-Vese modelinin temeli, Mumford-Shah fonksiyonuna dayanmaktadır. Mumford-Shah modeli, imgenin bölütlenmesi için enerji fonksiyonu kullanan enerji tabanlı bir modeldir. Mumford-Shah modeline göre C , konturu u_0 , giriş imgesini ifade etmektedir ve $F^{MS}(u, C)$ enerji fonksiyonu Eşitlik 4.2' deki gibi hesaplanmaktadır (Mumford ve Shah, 1989).

$$\inf \left\{ F^{MS}(u, C) = \int_{\Omega} (u - u_0)^2 dx dy + \mu \int_{\Omega/C} |\nabla u|^2 dx dy + \nu |C| \right\} \quad (4.2)$$

Yukarıdaki eşitlikte her Ω_i alanı içinde $u = \text{sabit } c_i$ alındığında, $F^{MS}(u, C)$ enerji fonksiyonu Eşitlik 4.3' te gösterildiği gibi minimize edilmektedir (Mumford ve Shah, 1989). u_0 imgesinde bulunan piksellerin ortalaması c_i ile ifade edilmektedir ve ν , sabit bir parametredir.

$$E^{MS}(u, C) = \sum_i \int_{\Omega} (u - c_i)^2 dx dy + v|C| \quad (4.3)$$

$$c_i = \text{ortalama}(u_0), u_0 \subset c_i$$

Mumford ve Shah tarafından formüle edilen bölütleme problemine dayanan Chan-Vese aktif kontur algoritmasında, C başlangıç konturu tarafından iki bölgeye ayrılan u_0 imgesi için oluşturulan enerji fonksiyonu Eşitlik 4.4' de gösterilmektedir. Bu enerji fonksiyonunda C konturunun uzunluğu ve C konturu içindeki bölgenin alanı gibi bazı düzenleyici terimler de bulunmaktadır (Chan ve Vese, 2001).

$$\begin{aligned} F(c_1, c_2, C) = & \mu. \text{Uzunluk}(C) + v. \text{Alan}(i\check{c}(C)) \\ & + \lambda_1 \int_{i\check{c}(C)} |u_0(x, y) - c_1|^2 dx dy \\ & + \lambda_2 \int_{dış(C)} |u_0(x, y) - c_2|^2 dx dy \end{aligned} \quad (4.4)$$

Eşitlik 4.4' de $\mu \geq 0$, $v \geq 0$, $\lambda_1, \lambda_2 > 0$ olarak sabit parametrelerdir. Chan ve Vese (2001), algoritmalarında $\lambda_1 = \lambda_2 = 1$ ve $v = 0$ olarak almaktadırlar. Böylece enerji fonksiyonu Eşitlik 4.5' de gösterildiği gibi minimize edilmektedir. c_1 , C konturunun içindeki bölgenin ortalama değeri ve c_2 , C konturunun dışındaki bölgenin ortalama değeridir. $F_1(C)$ ve $F_2(C)$ ise kuvvet terimleri olarak tanımlanır.

$$\begin{aligned} F(c_1, c_2, C) = & \mu. \text{Uzunluk}(C) + \int_{i\check{c}(C)} |u_0(x, y) - c_1|^2 dx dy + \int_{dış(C)} |u_0(x, y) - c_2|^2 dx dy \\ = & \mu. \text{Uzunluk}(C) + F_1(C) + F_2(C) \end{aligned} \quad (4.5)$$

Kenarsız Chan-Vese modelinde kontur değerlerini gösteren düzey kümesi fonksiyonu, $\phi(x, y)$ ile ifade edilmektedir. C konturunun matematiksel formülü Eşitlik 4.6' da ve bu konturun $\phi(x, y)$ fonksiyonuna göre zamanla değişimi de Eşitlik 4.7' de gösterilmiştir.

$$C = \{(x, y): \phi(x, y) = 0\}, \forall (x, y) \in u_0 \quad (4.6)$$

$$\frac{\partial C}{\partial t} = \frac{\partial \phi(x,y)}{\partial t} \quad (4.7)$$

Eşitlik 4.5' de gösterilen $F(c_1, c_2, C)$ enerji fonksiyonunda $F_1(C)$ kuvvet terimi, konturu daraltırken $F_2(C)$ kuvvet terimi, konturu genişletmektedir. Kontur, ilgili şüpheli bölgelerin sınırına ulaştığında bu iki kuvvet dengelenir ve böylece bölgenin konturunu bulmaya izin verir. Kontur ile ilgili şüpheli bölgenin birbirine göre konum durumları vardır ve bu düzey kümesi fonksiyonunu ifade etmektedir. Bu durumlar, eğer C konturu ilgili şüpheli bölgenin sınırında ise $\phi(x,y) = 0$, C konturu ilgili şüpheli bölgenin içinde ise $\phi(x,y) < 0$, C konturu ilgili şüpheli bölgenin dışında ise $\phi(x,y) > 0$ 'dır. Chan-Vese algoritmasının temel çalışma mantığı Şekil 4.1' de verilmiştir.

$$F_1(C) > 0, F_2(C) \approx 0 \quad F_1(C) \approx 0, F_2(C) > 0$$



1. durum



2. durum

$$F_1(C) > 0, F_2(C) > 0 \quad F_1(C) \approx 0, F_2(C) \approx 0$$



3. durum



4. durum

Şekil 4.1. Chan-Vese algoritmasının temel çalışma mantığı (Chan ve Vese, 2001)

Şekil 4.1’ de ilgili şüpheli bölgeyi gösteren siyah yerler -1 değeri ile belirtilir ve ilgili şüpheli bölgenin dışındaki yerleri gösteren gri yerler ise +1 değeri ile belirtilir. c_1 , konturun içindeki yerlerin ortalama değeri ve c_2 , konturun dışındaki yerlerin ortalama değeridir. Beyaz eğri, konturu temsil etmektedir. 1. duruma bakıldığında beyaz kontur tüm ilgili şüpheli bölgeyi (-1) ve bazı gri yerleri (+1) içermektedir. Bu durumda $c_1 \cong 0$ ve $c_2 = 1$ dir. Eşitlik 4.5’ deki enerji fonksiyonuna göre kontur içindeki imgeden c_1 çıkartılıp karesi alındığında pozitif bir sayıya ulaşılmakta ve kontur dışındaki imgeden c_2 çıkartıldığında ise 0’ a ulaşılmaktadır. Sonuç olarak $F_1 > 0$ ve $F_2 \approx 0$ olarak bulunmaktadır. Bu nedenle algoritma konturu daraltmaya zorlamaktadır. 2. Durumda benzer işlemler uygulandığında $F_1 \approx 0$ ve $F_2 > 0$ olarak hesaplanmakta ve kontur genişlemeye zorlanmaktadır. 3. durumda beyaz kontur hem ilgili şüpheli bölgeyi hem de dışını içerdiği için $F_1 > 0$ ve $F_2 > 0$ olarak hesaplanmaktadır. Bu defa algoritma konturu hem daraltmaya hem de genişletmeye zorlamaktadır. 4. durumda artık beyaz kontur ilgili şüpheli bölgenin sınırındadır ve $F_1 \approx 0$ ve $F_2 \approx 0$ olarak elde edilmektedir. Bu durumda bu iki kuvvet dengelendiğinden algoritma sonlanmaktadır. Böylece ilgili şüpheli bölgenin konturu bulunmaktadır.

5. MR İMGELERİNDE TESPİT EDİLEN ŞÜPHELİ BÖLGELERDEN ÖZİNİTELİK ÇIKARTIMI

Sınıflandırma doğruluğunun yüksek olması için imgede tespit edilen şüpheli bölgelerden çıkartılan, benzerlik ve farklılıkları içeren öznelik bilgisine ulaşmak çok önemli bir işlemdir. Çıkartılan özneliklerden öznelik vektörleri oluşturulmaktadır ve bu vektörlerin hangi sınıfa ait olduğunun tespiti için özneliklerin ayırt edici olması oldukça önemlidir. Tez çalışmasında beyin MR imgelerinde tespit edilen şüpheli bölgelerden doku, şekil ve yoğunluk ile ilgili bilgileri veren farklı öznelikler çıkartılmıştır. Bu öznelikler Şekil Tabanlı (Shape-Based) öznelikler, Gri Seviye Eş-Oluşum Matrisi (Gray Level Co-Occurrence Matrix - GLCM) öznelikleri, Yönlendirilmiş Gradyanların Histogramı (Histogram of Oriented Gradients - HOG) öznelikleri, Yerel İkili Örüntü (Local Binary Pattern - LBP) öznelikleri ve İstatistiksel (Statistical) özneliklerdir.

5.1. Şekil Tabanlı Öznelikler

Beyin tümörleri karmaşık bir yapıya sahiptir. Bu yapılar, boyutları, ödemle birlikte olabirliği, sınırlarının çeşitliliği, düzenli ya da düzensiz olmaları açısından farklılıklar gösterebilir (Wu vd., 2012). Tümörlü yapıların analizinde şekil tabanlı öznelikler ayırt edici özelliğe sahiptirler.

Tez çalışmasında MR imgelerinde şüpheli bölge tespit aşaması tamamlandıktan sonra bu bölgelerden farklı şekil tabanlı öznelikler çıkartılmıştır. Bu aşamada Matlab regionprops işlevi kullanılarak bölgelerin özellikleri elde edilir. İkileştirilen şüpheli bölgelerden birbirine bağlı en büyük bileşen bulunur. Her bir imge için bulunan en büyük bileşeni ilgi bölge (Region of Interest - ROI) olarak tanımlayabiliriz ve bu ilgi bölgeden şekil tabanlı öznelikler çıkartılır. Bu öznelikler alan, konveks alan, eksantriklik, çap, doluluk oranı, major eksen uzunluğu, minor eksen uzunluğu, oryantasyon, çevre, katılık ve yuvarlaklıktır.

- Çevre, ilgi bölgenin sınırında bulunan toplam piksel sayısı ile hesaplanır.
- Alan, ilgi bölgenin içinde bulunan toplam piksel sayısı ile hesaplanır.

- Konveks alan, ilgi bölgeyi içine alan en küçük konveksin içinde bulunan toplam piksel sayısı ile hesaplanır.
- Katılık, *Alan / Konveks alan* olarak hesaplanır.
- Doluluk oranı, ilgi bölge içinde bulunan toplam piksel sayısının (alan), ilgi bölgeyi içine alan en küçük dikdörtgenin içinde bulunan toplam piksel sayısına oranı ile hesaplanır.
- Major eksen uzunluğu, ilgi bölgeyi içine alan elipsin en uzun çapındaki piksel sayısı ile hesaplanır.
- Minor eksen uzunluğu, ilgi bölgeyi içine alan elipsin en kısa çapındaki piksel sayısı ile hesaplanır.
- Eksantriklik, elipsin odak noktaları ve major eksen uzunluğu arasındaki mesafenin oranı ile hesaplanır.
- Oryantasyon, elipsin major eksenini ile x eksenini arasındaki açı ile hesaplanır.
- Çap, ilgi bölgenin alanı ile eşit alana sahip bir dairenin çapı ile hesaplanır ve Eşitlik 5.1' deki gibi bulunur.

$$D = \sqrt{\frac{4 * Alan}{\pi}} \quad (5.1)$$

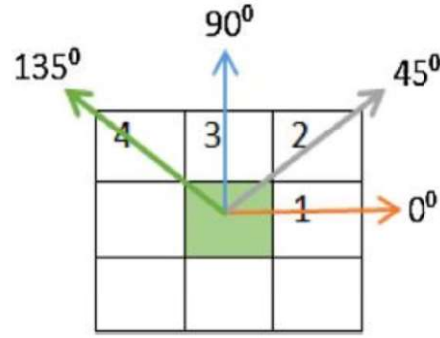
- Yuvarlaklık, ilgi bölgenin dairesel şekle benzerlik derecesini temsil eder. Mükemmel bir daire için yuvarlaklık değeri 1' dir. Yuvarlaklık, Eşitlik 5.2' deki gibi bulunur. r , major eksen uzunluğunun minor eksen uzunluğuna bölünmesidir (Esener, 2017).

$$Y = \frac{Alan}{\pi r^2} \quad (5.2)$$

5.2. Gri Seviye Eş-Oluşum Matrisi Öznitelikleri


MR imgelerinin bileşimleri gri seviye değerlere sahip yoğunluklar olduğu için yerel istatistikleri sunan gri seviye eş-oluşum matrisi, hesaplanabilir ve ayırt edici özelliklere sahiptir. Gri Seviye Eş-oluşum Matrisi (GLCM) kullanılarak çıkartılan ikinci derece istatistiksel öznitelikler doku öznitelikleri olarak tanımlanmaktadır (Haralick vd., 1973).

Doku özneliklerini çıkartmak için oluşturulan GLCM matrisi, rastgele mesafelerde ve tüm görüntü yönelimlerinde gri düzeylerin olasılığını ifade eden $P(i, j | d, \theta)$ fonksiyonuna dayanmaktadır. i ve j imgedeki yeşinlik (intensity) değerleridir. d , uzaklığı θ , yönü temsil etmektedir. Şekil 5. 1’ de $d = 1$ için gösterilen farklı yön açıları verilmiştir.



Şekil 5.1. GLCM oluşturulurken kullanılan farklı yönler (Amin vd., 2017)

GLCM, farklı gri seviyelerine sahip pikseller arasındaki uzamsal ilişkiyi tanımlar. Belirli bir yeşinlikte i olan bir pikselin, belirli bir d uzaklığı ve θ yönündeki başka bir piksel j ile ilişkili olarak ne kadar farklı olduğunu hesaplar. GLCM matrisindeki her eleman (i, j) , i değerine sahip pikselin, j değerine sahip komşu bir piksel ile belirtilen ilişkide gerçekleşme sayısının toplamıdır (Mali ve Pawar, 2016). GLCM matrisin oluşum mantığı Şekil 5.2’ de gösterilmiştir.



Şekil 5.2. GLCM matrisinin oluşum örneği

Şekil, $d = 1$ uzaklığı ve $\theta = 0^\circ$ yönü için hesaplanan eş-oluşum matrisini ifade etmektedir. İmgedeki $i=1$ ve $j=1$ piksel değerleri, sadece bir kez bu şekilde tekrarladığı için GLCM matrisinin (1,1) elemanının değeri 1 olarak hesaplanmaktadır. Bu durumda matriste 1. satır 1. sütuna 1 yazılmaktadır. Diğer durum olan imgedeki $i=1$ ve $j=2$ piksel değerlerine bakıldığında iki kez bu şekilde tekrar olduğu için GLCM matrisinin (1,2) elemanının değeri 2 olarak hesaplanmaktadır. Bu durumda matriste 1. satır 2. sütuna 2 yazılmaktadır.

Tez çalışmasında MR imgelerinden bulunan GLCM matrislerinden önerilen 22 çeşit doku özneliği çıkartılmıştır (Haralick vd., 1973; Soh ve Tsatsoulis, 1999; Clausi, 2002). Bu özneliklerin çıkartılması için bilinmesi gereken eşitlikler Çizelge 5.1’ de gösterilmiştir. Burada $P(i, j)$ gri seviye eş-oluşum matrisini, μ_x ve μ_y sırasıyla GLCM’ nin satırlarının ve sütunlarının ortalamasını, σ_x ve σ_y sırasıyla GLCM’ nin satırlarının ve sütunlarının standart sapmasını temsil etmektedir. Çıkartılan doku öznelikleri ve matematiksel gösterimleri ise Çizelge 5.2’ de verilmiştir.

Çizelge 5.1. Bilinmesi gereken eşitlikler

$P(i, j): GLCM = \begin{bmatrix} P(1,1) & \dots & P(1, N_g) \\ \vdots & \ddots & \vdots \\ P(N_g, 1) & \dots & P(N_g, N_g) \end{bmatrix}$
$P_x(i) = \sum_{j=1}^{N_g} P(i, j) \quad , \quad P_y(i) = \sum_{i=1}^{N_g} P(i, j)$
$P_{x+y}(k) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P_{i+j=k}(i, j) \quad , \quad k = 2, 3, \dots, 2N_g$
$P_{x-y}(k) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P_{ i-j =k}(i, j) \quad , \quad k = 0, 1, \dots, N_g - 1$
$\mu_x = \sum_i \sum_j i \cdot P(i, j) \quad , \quad \mu_y = \sum_i \sum_j j \cdot P(i, j)$
$\sigma_x = \sum_i \sum_j (i - \mu_x)^2 \cdot P(i, j) \quad , \quad \sigma_y = \sum_i \sum_j (j - \mu_y)^2 \cdot P(i, j)$

Çizelge 5.2. GLCM matrisinden çıkartılan doku öznitelikleri ve matematiksel gösterimleri

GLCM Matrisinden Çıkartılan Doku Öznitelikleri	Matematiksel Gösterimleri
Otokorelasyon (Soh ve Tsatsoulis, 1999)	$\sum_i \sum_j (i \cdot j) \cdot P(i, j)$
Kontrast (Haralick vd., 1973; Soh ve Tsatsoulis, 1999)	$\sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{\substack{j=1 \\ i-j =n}}^{N_g} P(i, j) \right\}$
Korelasyon (MATLAB R2016a)	$\frac{\sum_i \sum_j (i - \mu_x) \cdot (j - \mu_y) \cdot (P(i, j))}{\sigma_x \cdot \sigma_y}$
Korelasyon (Haralick vd., 1973; Soh ve Tsatsoulis, 1999)	$\frac{\sum_i \sum_j (i \cdot j) \cdot P(i, j) - \mu_x \cdot \mu_y}{\sigma_x \cdot \sigma_y}$
Asimetri (Soh ve Tsatsoulis, 1999)	$\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \{i + j - \mu_x - \mu_y\}^4 \cdot P(i, j)$
Çarpıklık (Soh ve Tsatsoulis, 1999)	$\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \{i + j - \mu_x - \mu_y\}^3 \cdot P(i, j)$
Benzersizlik (Soh ve Tsatsoulis, 1999)	$\sum_i \sum_j i - j \cdot P(i, j)$
Enerji (Haralick vd., 1973 ; Soh ve Tsatsoulis, 1999)	$\sum_i \sum_j \{P(i, j)\}^2$
Entropi (Soh ve Tsatsoulis, 1999)	$- \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P(i, j) \cdot \log\{P(i, j)\}$
Homojenlik (MATLAB R2016a)	$\sum_i \sum_j \frac{1}{1 + i - j ^2} \cdot P(i, j)$
Homojenlik (Soh ve Tsatsoulis, 1999)	$\sum_i \sum_j \frac{1}{1 + (i - j)^2} \cdot P(i, j)$
Maksimum Olasılık (Soh ve Tsatsoulis, 1999)	$\max_{i,j} P(i, j)$

Varyans (Haralick vd., 1973)	$\sum_i \sum_j (i - \mu)^2 \cdot P(i, j)$
Toplam Ortalaması (Haralick vd., 1973)	$\sum_{i=2}^{2N_g} i \cdot P_{x+y}(i)$
Toplam Varyansı (Haralick vd., 1973)	$\sum_{i=2}^{2N_g} (i - \text{Toplam Ortalaması})^2 \cdot P_{x+y}(i)$
Toplam Entropisi (Haralick vd., 1973)	$-\sum_{i=2}^{2N_g} P_{x+y}(i) \cdot \log\{P_{x+y}(i)\}$
Fark Varyansı (Haralick vd., 1973)	<i>variance of P_{x-y}</i>
Fark Entropisi (Haralick vd., 1973)	$-\sum_{i=2}^{2N_g} P_{x-y}(i) \cdot \log\{P_{x-y}(i)\}$
Korelasyon Bilgi Ölçeği 1 (Haralick vd., 1973)	$\frac{HXY - HXY1}{\max\{HX, HY\}}$ $HXY = -\sum_i \sum_j P(i, j) \cdot \log(P(i, j))$ $HXY1 = -\sum_i \sum_j P(i, j) \cdot \log(p_x(i) \cdot p_y(j))$ <p><i>HX ve HY p_x ve p_y'nin entropi değerleridir.</i></p>
Korelasyon Bilgi Ölçeği 2 (Haralick vd., 1973)	$(1 - \exp[-2 \cdot (HXY2 - HXY)])^{1/2}$ $HXY2 = -\sum_i \sum_j P_x(i) \cdot P_y(j) \cdot \log\{P_x(i) \cdot P_y(j)\}$
Inverse Difference Normalized (Clausi, 2002)	$\sum_i \sum_j \frac{1}{1 + i - j ^2 / N_g^2} \cdot P(i, j)$
Inverse Difference Moment Normalized (Clausi, 2002)	$\sum_i \sum_j \frac{1}{1 + (i - j)^2 / N_g^2} \cdot P(i, j)$

5.3. Yönlendirilmiş Gradyanların Histogramı Öznitelikleri

Yönlendirilmiş Gradyanların Histogramı (HOG), ilk olarak nesne tespiti amacıyla önerilerek kullanılmıştır (Dalal ve Triggs, 2005). Daha sonra HOG, bilgisayarla görü ve görüntü işlemede öznitelik çıkartmak için de kullanılmaya başlamıştır (Yin vd., 2008). Tez çalışmasında, MR imgelerinde tespit edilen şüpheli bölgelerden öznitelik çıkartımı için HOG kullanılmıştır.

HOG öznitelikleri imgelerin kenar yönelimleri ve gradyan değerleri dikkate alınarak çıkartılmaktadır. Burada temel amaç, imgenin yerel histogramlarını elde etmektir. Yerel histogramlar, gradyan yönelimlerinden oluşmaktadır. HOG algoritması genel olarak, öncelikle, imgenin gradyan değerinin hesaplanması, daha sonra ise belirlenen hücrelerde yönelim histogramlarının hesaplanması ve oluşturulan blok gruplarında histogramların normalize edilmesi adımlarını içermektedir. HOG öznitelikleri elde edilirken ilk olarak imgenin yatay ve dikey gradyan değerleri sırasıyla Eşitlik 5.3 ve Eşitlik 5.4' deki gibi hesaplanır. Bu değerler hesaplanırken x ve y yönlerinde çeşitli kenar algılama maskeleri kullanılmaktadır. Burada $f_x(x, y)$ yatay eksenindeki parlaklık değişimini, $f_y(x, y)$ dikey eksenindeki parlaklık değişimini ifade etmektedir. $I(x, y)$ ise (x, y) noktasındaki parlaklığı temsil etmektedir.

$$f_x(x, y) = I(x + 1, y) - I(x - 1, y) \quad (5.3)$$

$$f_y(x, y) = I(x, y + 1) - I(x, y - 1) \quad (5.4)$$

Daha sonra hesaplanan gradyan değerleri kullanılarak Eşitlik 5.5' te gösterildiği gibi gradyan büyüklüğü ve Eşitlik 5.6'da gösterildiği gibi gradyan yönelimi hesaplanmaktadır. Burada $m(x, y)$, gradyan büyüklüğünü $\theta(x, y)$, gradyan yönelimini temsil etmektedir. İşaretsiz yönelim değerlerini elde etmek için Eşitlik 5.7 kullanılmaktadır.

$$m(x, y) = \sqrt{f_x(x, y)^2 + f_y(x, y)^2} \quad (5.5)$$


$$\theta(x, y) = \tan^{-1} \frac{f_x(x, y)}{f_y(x, y)} \quad (5.6)$$

$$\theta(x, y) = \begin{cases} \theta(x, y) + \pi & \text{eğer } \theta < 0 \\ \theta(x, y) & \text{değilse} \end{cases} \quad (5.7)$$

Sonraki aşamada imge hücre olarak adlandırılan küçük, bağlı bölgelere bölünerek her hücre için gradyan değerleri ve yönelimleri hesaplanmaktadır. Belli sayıda hücreler birleştirilerek blok adı verilen daha büyük bir bölge oluşturulmaktadır. Her bir bloktaki yerel histogramlar hesaplanarak normalize edilmektedir ve bu bölgelerden öznelikler çıkartılmaktadır.

5.4. Yerel İkili Örüntü Öznelikleri

Yerel İkili Örüntü (LBP) yönteminin temelini imgedeki yerel doku yönünü temsil eden doku birimlerine dayanan doku analizi oluşturmaktadır (Wang ve He, 1990). LBP yöntemi ile doku öznelikleri elde edilmektedir. Bilgisayarlı görü uygulamalarında doku tanımlaması için gri seviye görüntülerde LBP kullanılmaktadır ve güçlü bir doku sınıflandırma yöntemi olarak bilinmektedir. LBP, her pikseli çevreleyen yerel doku komşularının bilgisini kullanarak bir tanımlayıcı veya doku modeli oluşturmaktadır (Ojala vd., 2002).



Şekil 5.3. LBP oluşumu (Abbasi ve Tajeripour, 2017)

LBP, her pikseli etrafındaki komşu pikseller ile karşılaştırarak ikili bir kod üretmektedir ve yeni bir piksel değeri oluşturmaktadır. Şekil 5.3' de yarıçapı 1 ve 8 komşuluğa sahip olan bir LBP' nin oluşum örneği gösterilmiştir. LBP merkez pikseli 3x3 komşuluğunda 8 komşusu ile karşılaştırmaktadır. Merkez pikselin komşusu, merkez pikselden daha büyük veya eşit bir değere sahipse komşu piksel 1 değerini almaktadır ama merkez pikselin komşusu, merkez pikselden küçükse komşu piksel 0 değerini almaktadır. Merkez pikselin sekiz komşusu, 8 bitlik bir sayı ile temsil edilmektedir ve bu sayının onluk karşılığı merkez pikselin yeni değeri olmaktadır.

LBP' nin matematiksel gösterimi Eşitlik 5.8' de verilmiştir. Burada P dairesel komşuluktaki piksel sayısını ve R dairenin yarıçapını temsil etmektedir. s birim basamak fonksiyonunu, g_p ($p = 0, \dots, P - 1$) dairesel komşuluktaki p . komşu pikselin yeğlilik değerini ve g_c merkez pikselin yeğlilik değerini ifade etmektedir.

$$x = g_p - g_c$$

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$$
(5.8)

$$LBP(P, R) = \sum_{p=0}^{P-1} s(g_p - g_c) \cdot 2^p$$

5.5. İstatistiksel Öznitelikler

İstatistiksel öznitelikler, yoğunluğa dayalı özniteliklerdir. Doğruluğu yüksek bir sınıflandırma için kullanışlı olan istatistiksel öznitelikler birçok çalışmada tercih edilmektedir. İstatistiksel özniteliklerden enerji, ilgi bölgedeki piksel değerlerinin karelerinin toplamını ifade etmektedir. Ortalama, bir imgede ilgi bölgedeki piksellerin yeğlilik değerlerinin toplamının o bölgedeki toplam piksel sayısına bölünmesiyle tanımlanmaktadır. Varyans, ortalama etrafındaki yeğlilik değişimlerini göstermektedir. Çarpıklık (skewness), ortalama etrafındaki gri seviye değerlerin asimetrisinin ölçüsüdür ve ortalama etrafındaki üçüncü momenti göstermektedir. Basıklık (kurtosis), yeğlilik dağılımının normal dağılıma yakınlık ölçüsüdür ve ortalama etrafındaki dördüncü momenti göstermektedir. Entropi, bir imgenin gri seviye yeğlilik dağılımındaki rastgeleliğin miktarını temsil etmektedir (Sachdeva vd., 2016).

Tez çalışmasında, MR imgelerinde tespit edilen şüpheli bölgelerden 8 farklı istatistiksel öznitelik çıkartılmıştır. Bu öznitelikler ve matematiksel gösterimleri Çizelge 5.3' de verilmiştir.

Çizelge 5.3. İstatistiksel öznitelikler ve matematiksel gösterimleri


İstatistiksel Öznitelikler	Matematiksel Gösterimleri
Enerji	$\sum_{i=1}^N x_i^2$
Ortalama	$\mu = \frac{1}{N} \sum_{i=1}^N x_i$
Varyans	$\frac{1}{N-1} \sum_{i=1}^N (x_i - \mu)^2$
Çarpıklık	$\sigma = \text{standart sapma} = \sqrt{\mu}$ $\frac{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^3}{\sigma^3}$
Basıklık	$\frac{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^4}{\sigma^4}$
Entropi	$\sum_{i=1}^N p(x_i) \log_2 p(x_i)$
Ortalama Enerji	$\mu_{\text{Energy}} = \frac{1}{N} \sum_{i=1}^N x_i^2$
Enerji Varyansı	$\frac{1}{N-1} \sum_{i=1}^N (x_i^2 - \mu_{\text{Energy}})^2$

6. MR İMGELERİNDEN ELDE EDİLEN ŞÜPHELİ BÖLGELERİN SINIFLANDIRILMASI

Beyin tümörünün sınıflandırma süreci, tespit edilen şüpheli bölgelerden öznitelikler çıkartıldıktan sonra sınıflandırma aşaması ile son bulmaktadır. Bu aşama için k -En Yakın Komşu (k -Nearest Neighbor - k -NN), Fisher Doğrusal Ayırtaç Analizi (Fisher's Linear Discriminant Analysis - FLDA), Karar Ağacı, Rastgele Orman, Destek Vektör Makineleri (Support Vector Machines - SVM), Naive Bayes ve Lojistik Doğrusal Sınıflandırıcısı (Logistic Linear Classifier - LLC) kullanılmıştır.

6.1. k -En Yakın Komşu Sınıflandırıcısı

En yakın komşu algoritması parametrik olmayan basit ve etkili bir sınıflandırma algoritmasıdır (Cover ve Hart, 1967). Genel olarak bir nesne, en yakın k tane komşuları ile durumuna bakılarak komşularının çoğunluk oyu ile sınıflandırılmaktadır. k -en yakın komşu sınıflandırıcısı öznitelik vektörlerine uygulanmaktadır. k -NN sınıflandırıcısında, sınıfı belli olan vektörlerdeki öznitelikler ile test vektöründeki öznitelikler arasındaki mesafe Öklid uzaklığı ile ölçülmektedir. Mesafe ölçüldükten sonra k tane öznitelik en az mesafe farkına göre seçilmektedir ve bu k tane özniteliğin çoğunlukta olduğu sınıf seçilerek test vektörü o sınıfa atanmaktadır. k sayısı, sınıf sayısının herhangi bir tamsayı katı olamaz. Şekil 6.1' de k -NN sınıflandırıcısının çalışma mantığı gösterilmektedir.



Şekil 6.1. k -NN sınıflandırıcısının çalışma mantığı

6.2. Fisher Doğrusal Ayırtaç Analizi Sınıflandırıcısı

Doğrusal ayırtaç analizi ile ilgili çalışma Fisher (1936), tarafından yayınlanan makale ile başlamaktadır. FLDA, verileri iki ya da daha fazla sınıfa sınıflandırmayı hedefleyen istatistiksel bir yöntemdir. Fisher doğrusal ayırtaç sınıflandırıcısı, verileri sınıflardan birine sınıflandırmak için sınıf içi farklılığı minimum ve sınıflar arası farklılığı maksimum yapacak şekilde doğrusal fonksiyonlar oluşturmaktadır. Bu doğrultuda FLDA' nın amacı Eşitlik 6.1' de gösterilen fonksiyonu en büyükmektir.

$$J(w) = \frac{w^T S_B w}{w^T S_W w} \quad (6.1)$$

Eşitlik 6.1' de S_B sınıflar arası dağılım matrisini, S_W sınıf içi dağılım matrisini ve w yansıtılmış vektörü ifade etmektedir. S_B ve S_W matrisleri sırasıyla Eşitlik 6.2 ve Eşitlik 6.3' te gösterilmiştir. Bu eşitliklerde m sınıf sayısını, N_c c . sınıftaki veri sayısını, μ vektör ortalamasını, \bar{x} veri durumlarının genel ortalamasını ifade etmektedir.

$$S_B = \sum_{c=1}^m [N_c (\mu_c - \bar{x})(\mu_c - \bar{x})^T] \quad (6.2)$$

$$S_W = \sum_{c=1}^m \{ \sum_{i=1}^{N_c} [(x_i - \mu_c)(x_i - \mu_c)^T] \} \quad (6.3)$$

FLDA ölçütünün maksimizasyonu, S_W ' nin tersi ve S_B arasındaki matris çarpımının özdeğer ve özvektör ayrışımı yoluyla çözülmektedir. Böylece, $J(w)$ fonksiyonunu en büyükmek amacıyla, en büyük özdeğerlere karşılık gelen özvektörler alınmaktadır.

6.3. Karar Ağacı Sınıflandırıcısı

Karar ağacı sınıflandırıcısı, bilinmeyen bir veriyi art arda bir veya daha fazla karar fonksiyonu kullanarak bir sınıfa sınıflandırmayı amaçlamaktadır (Swain ve Hauska, 1977). Karar ağacı, bir ağaç yapısı ile açıklanmaktadır ve en yukarıdan en aşağı inen bir sistemden oluşmaktadır. Genel olarak ağaç, bir kök düğümünden, iç düğümlerden ve yaprak düğümlerinden oluşmaktadır. Ağacın en yukarısındaki ilk düğüm kök düğümüdür ve bu düğüme karar düğümü de denilmektedir. Bir karar düğümü birden fazla dallanma içerebilmektedir. Ağacın yaprakları sınıf etiketlerini ve bu yapraklara giden dallar ise karar

kurallarını ifade etmektedir. Sonuç olarak karar ağacı sınıflandırıcısı, çok sayıda özellik içeren bir veri kümesini, bir takım karar kuralları uygulayarak sınıflandırma işlemi için daha küçük kümelere bölmektedir. Bu işlem yaprak düğümü oluşup bütün örnekler aynı sınıfa ait olduğunda durmaktadır.

6.4. Rastgele Orman Sınıflandırıcısı

Rastgele orman, birçok ağaç sınıflandırıcısının birleşimidir. Ormandaki her ağaç, bağımsız olarak örneklenen rastgele bir vektörün değerlerine bağlıdır (Breiman, 2001). Rastgele orman sınıflandırıcısı birden çok karar ağacı kullanmaktadır. Karar ağacı, tahminleri yapmak için karar kuralları uygulamaktadır fakat rastgele orman, çeşitli karar ağaçları oluşturmak için özellikleri rastgele seçmektedir ve sonuçların ortalamasını almaktadır. Buradaki parametreler algoritmanın tahmin gücünü arttırmak ya da algoritmayı daha hızlı hale getirmek için kullanılmaktadır. Genel olarak, geliştirilecek ağaçların sayısını ifade eden parametrenin yüksek olması performansı artırmaktadır ve tahminleri daha kararlı hale getirmektedir fakat hesaplamayı yavaşlatmaktadır.

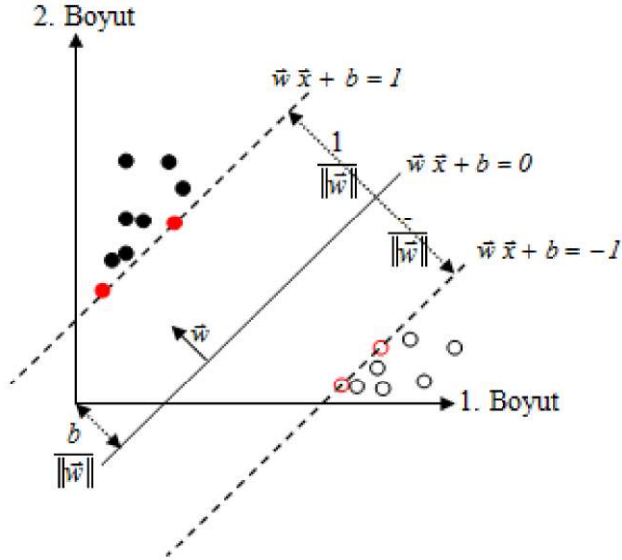
6.5. Destek Vektör Makineleri Sınıflandırıcısı

Destek vektör makineleri sınıflandırıcısının amacı, sınıfları birbirinden en uygun bir biçimde ayırabilen hiperdüzlemi bulmaktır (Cortes ve Vapnik, 1995). SVM sınıflandırıcısı eğitim verisindeki farklı sınıflara ait, kendisine en yakın vektörler arasındaki mesafeyi maksimum yapan bir hiperdüzlem tanımlamaktadır. Sınırlandırmayı sağlayan bu en yakın vektörler destek vektörleridir. Destek vektörleri hiperdüzleme paralel bulunan düzlemler üzerinde bulunmaktadırlar ve iki sınıfın sınırını belirlemektedirler (Ayhan ve Erdoğan, 2014). Bu hiperdüzlemi elde etmek için gerekli olan karar fonksiyonu Eşitlik 6.4' de gösterilmektedir.

$$f(\vec{x}_{test}) = \sum_{i=1}^M \{\alpha_i \cdot L_i \cdot (\vec{x}_i^T \cdot \vec{x}_{test}) + b\} \quad (6.4)$$

Burada doğrusal ayrılabilen iki sınıflı veriler için eğitim verisi (\vec{x}_i, L_i) , $i = 1, \dots, M$ olmaktadır ve M sayıda örnekten oluşmaktadır. \vec{x}_i vektörleri, L_i sınıf etiketlerini, \vec{x}_{test} test vektörünü ve α_i sıfırdan farklı Lagrange çarpanlarını temsil etmektedir. SVM' nin çalışma

mantığı Şekil 6.2’ de verilmiştir. Şekildeki hiperdüzlem \vec{w} normaline ve $\frac{b}{\|\vec{w}\|}$ orijinden dik uzaklığına sahiptir.



Şekil 6.2. SVM çalışma mantığı (Esener, 2017)

6.6. Naive Bayes Sınıflandırıcısı

Naive Bayes sınıflandırıcısı, güçlü ve bağımsız varsayımlarla Bayes’ in teoremine dayanan basit olasılıklı bir sınıflandırıcıdır. Bayes teoremine göre sınıflandırılacak bir test örneği verildiğinde, tahmin niteliği taşıyan öznelikler kullanılarak her sınıfın olasılığı hesaplanmaktadır ve test örneği olasılık değeri en büyük olana sınıflandırılmaktadır (John ve Langley, 1995). Eşitlik 6.5’ de Bayes teoremi gösterilmektedir.

$$P(c_i | x) = \frac{p(x|c_i)P(c_i)}{p(x)} \quad (6.5)$$

Bu teoremden $P(c_i | x)$ x örneğinin c_i sınıfından olma olasılığı, $p(x | c_i)$ sınıf c_i ’ den bir örneğin x örneği olma olasılığı, $P(c_i)$ sınıf c_i ’ nin ilk olasılığı ve $p(x)$ herhangi bir örneğin x örneği olma olasılığıdır. Naive Bayes sınıflandırıcısı, her örneğin n boyutlu uzayda $X = x_1, x_2, \dots, x_n$ tanımlı olduğu ve $c = c_1, c_2, \dots, c_m$ olmak üzere m tane sınıf bulunan veri kümesinde sınıflandırma işlemi için $P(c_i | X)$ olasılığını en büyüklemeyi aramaktadır. $p(X)$ olasılığı bütün sınıflar için sabit olduğundan $P(c_i | X) = p(X | c_i)P(c_i)$ olasılığı için

en büyük değer elde edilmektedir. Sonuç olarak sınıflandırma kuralı Eşitlik 6.6' daki gibi ifade edilmektedir. Eşitlikteki V_{NB} ise hedef değerini temsil etmektedir.

$$V_{NB} = \operatorname{argmax}(P(c_i) \prod_{j=1}^n p(x_j | c_i)) \quad (6.6)$$

6.7. Lojistik Doğrusal Sınıflandırıcısı

Lojistik doğrusal sınıflandırıcısının amacı, bağımlı değişken ile bir dizi öngörücü bağımsız değişken arasındaki ilişkiyi tanımlamak için en uygun doğrusal modeli bulmaktır (Pohar vd., 2004). Bağımlı değişkenler ile bağımsız değişkenler arasındaki ilişkiyi tanımlamak için lojistik regresyon analizi kullanılmaktadır. Lojistik regresyonda bağımlı değişkenlerin içinden bir değişkenin seçilme olasılığı tahmin edilmektedir. LLC' de parametreler ve bağımsız değişkenler için doğrusal bir model oluşturulmaktadır. Eşitlik 6.7' de \vec{x} örneği kullanılarak iki sınıf için elde edilen LLC modeli gösterilmektedir (Webb, 2002).

$$\log \left(\frac{p(\vec{x}|w_1)}{p(\vec{x}|w_2)} \right) = \vec{\beta}^T \cdot \vec{x} + \beta_0 \quad (6.7)$$

Lojistik doğrusal sınıflandırma yönteminde, değişkenler ortak kovaryans matrisine sahiptir ve sınıf olasılıkları eşittir. Bağımlı değişkenler logit fonksiyonuna dönüştürülmektedir. Bunun sonucundaki lojistik dağılım fonksiyonları Eşitlik 6.8' de gösterilmektedir. Eşitliklerdeki β_0 sabittir ve β regresyon katsayılarını temsil etmektedir. LLC karar kuralı ise Eşitlik 6.9' da verilmektedir.

$$p(w_1 | \vec{x}) = \frac{\exp(\vec{\beta}^T \cdot \vec{x} + \beta_0)}{1 + \exp(\vec{\beta}^T \cdot \vec{x} + \beta_0)} \quad (6.8)$$

$$p(w_2 | \vec{x}) = \frac{1}{1 + \exp(\vec{\beta}^T \cdot \vec{x} + \beta_0)}$$

$$\vec{x} \in \begin{cases} w_1, & \frac{p(w_1|\vec{x})}{p(w_2|\vec{x})} > 1 \\ w_2, & \frac{p(w_1|\vec{x})}{p(w_2|\vec{x})} < 1 \end{cases} \quad (6.9)$$


7. MATERYAL VE YÖNTEM

7.1. Kullanılan Veri Tabanı

Tez çalışmasında Harvard veri tabanı kullanılmıştır (Summers, 2003). Harvard veri tabanı, 41 tanesi normal (sağlıklı) ve 100 tanesi tümörlü olmak üzere toplam 141 tane beyin MR imgesinden oluşmaktadır. Bu 100 tane tümörlü imgelerin 59 tanesi iyi huylu ve 41 tanesi kötü huylu imgelerdir. Kullanılan beyin MR imgeleri 256×256 piksel boyutlarına ve 8 bit derinliğine sahiptir.

7.2. MR İmgelerinde Kafatasının Ortadan Kaldırılması

MR imgelerinde kafatasını ortadan kaldırmak için öncelikle RGB formatındaki giriş imgesi Şekil 7.1’ de gösterilen gri tonlamalı bir imgeye dönüştürülmüştür. Daha sonra imgeye ikilileştirme yöntemi uygulanmıştır. Bu işlem için en uygun eşik değeri 55 olarak belirlenmiştir. Belirlenen eşik değerinin altındaki piksellere 0 (siyah), üzerindeki piksellere 1 (beyaz) değeri atanmıştır. Böylece imge ön plan ve arka plan olarak ikiye bölütlenmiştir. Elde edilen ikili imge Şekil 7.2’ de gösterilmiştir.



Şekil 7.1. Gri tonlamalı imge




Şekil 7.2. İkili imge

Daha sonra ikili görüntüde birbirine bağlı en büyük bileşen bulunmuştur ve elde edilen imge Şekil 7.3’ te gösterilmiştir. Şekil 7.3’ te görüldüğü gibi kafatası ve beyin

birbirine küçük bileşenlerle bağlıdır. Bu bağlantıyı koparmak için imgeye morfolojik bir işlem olan açma işlemi uygulanmıştır. Bu işlemin sonucunda oluşan imge Şekil 7.4’ de verilmiştir.




Şekil 7.3. Birbirine bağlı en büyük bileşeni bulunan imge




Şekil 7.4. Açma işlemi uygulanan imge

Açma işlemi uygulandıktan sonra Şekil 7.4’ te görüldüğü gibi kafatası ve beyin arasındaki bağlantı kesilmiştir. En büyük bağlı bileşen olan beyin Şekil 7.5’ te gösterildiği gibi çıkartılmıştır. Böylece kafatası beyinden ayrılmıştır. Daha sonra elde edilen imgeye delik doldurma işlemi uygulanmıştır ve Şekil 7.6’ da gösterildiği gibi delikler doldurulmuştur.




Şekil 7.5. Beyin imgesi




Şekil 7.6. Delik doldurma işlemi uygulanan imge

Detayları büyütmek amacıyla Şekil 7.6’ da elde edilen imgeye genişletme işlemi uygulanmıştır ve Şekil 7.7’ de gösterilmiştir. Böylece kafatasını atmak için gerekli maske elde edilmiştir. Son olarak, elde edilen maske ile gri tonlamalı imgeye maskeleme yapılarak kafatası ortadan kaldırılmıştır. Kafatası atılan beyin MR imgesi Şekil 7.8’ de verilmiştir.



Şekil 7.7. Genişletme işlemi uygulanan imge



Şekil 7.8. Kafatası ortadan kaldırılan imge


7.3. MR İmgelerinde Şüpheli Bölge Tespiti

Kafatası atıldıktan sonra K-means Kümeleme, Lab Renk Uzayında K-means Kümeleme ve Kenarsız Chan-Vese Aktif Kontur algoritmaları kullanılarak bütün MR imgelerinde şüpheli bölge tespiti yapılmıştır. Bu üç farklı yöntemin performans değerlendirmesine bakılmıştır. Tez çalışması kapsamında şüpheli bölge tespiti ve sınıflandırma aşamalarında başarı durumlarını ölçmek için Çizelge 7.1’ de gösterilen değerlendirme kriterleri kullanılmıştır.

Çizelge 7.1. Performans değerlendirme kriterleri


TP: Doğru Pozitif (True Positive)	FP: Yanlış Pozitif (False Positive)
FN: Yanlış Negatif (False Negative)	TN: Doğru Negatif (True Negative)
Hassasiyet (Sensitivity – SNS) = $\frac{TP}{(TP+FN)}$	
Özgüllük (Specificity – SPC) = $\frac{TN}{(TN+FP)}$	
Doğruluk (Accuracy – ACC) = $\frac{TP+TN}{(TP+TN+FP+FN)}$	

K-means kümeleme yönteminde, $k=3$ tane küme tanımlanmıştır, çünkü en iyi sonuçta 3 kümelemede ulaşılmıştır. Şekil 7.9 a)' da kafatası atılan örnek bir imgeye K-means kümeleme algoritması uygulanmıştır ve bu algoritma ile yapılan şüpheli bölge tespiti Şekil 7.9' da gösterilmiştir. Şekil 7.9 b)' deki beyaz yerler algoritmanın bulduğu şüpheli bölgeyi ifade etmektedir.



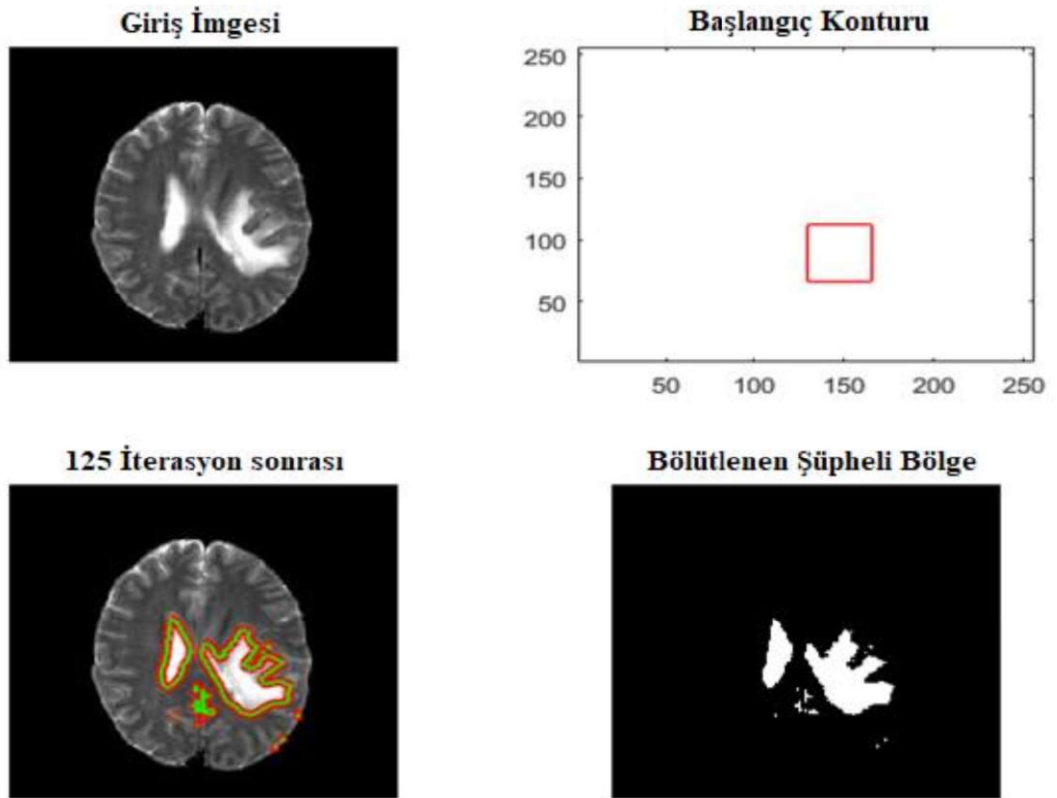
Şekil 7.9. K-means kümeleme algoritması ile şüpheli bölge tespiti: a) Kafatası atılan örnek bir imge, b) Bölütlenen şüpheli bölge.

Lab renk uzayında K-means kümeleme yönteminde, örnek bir giriş imgesi Şekil 7.10 a)' da gösterildiği gibi Lab renk uzayına dönüştürülmüştür. Lab renk uzayı algısal yönden düzgün dağılım gösteren bir renk uzayı olması sebebiyle kullanılmıştır. Daha sonra bu imgeye $k=3$ olarak tanımlanan K-means kümeleme algoritması uygulanmıştır. Lab renk uzayında K-means kümeleme algoritması ile yapılan şüpheli bölge tespiti Şekil 7.10' da gösterilmiştir. Şekil 7.10 b)' deki kırmızı yerler algoritmanın bulduğu şüpheli bölgeyi ifade etmektedir.



Şekil 7.10. Lab renk uzayında K-means kümeleme algoritması ile şüpheli bölge tespiti: a) Lab renk uzayına dönüştürülen imge, b) Bölütlenen şüpheli bölge.

Kenarsız Chan-Vese aktif kontur yönteminde, başlangıç konturu ve iterasyon sayısı belirlenmiştir. Kafatası atılan giriş imgesine kenarsız Chan-Vese algoritması uygulanmıştır. İterasyon sayısı 125 alınmıştır. Kenarsız Chan-Vese aktif kontur algoritması ile yapılan şüpheli bölge tespiti Şekil 7.11’ da gösterilmiştir.



Şekil 7.11. Kenarsız Chan-Vese aktif kontur algoritması ile şüpheli bölge tespiti

7.4. MR İmgelerinde Tespit Edilen Şüpheli Bölgelerden Öznitelik Çıkartımı

Üç farklı yöntem ile şüpheli bölge tespiti yapılan her MR imgesinden 64x64 boyutunda bölgeler alınmıştır ve bu bölgelerden öznitelik çıkartımı yapılmıştır. 5. Bölümde anlatılan beş farklı özneliğin hepsi ayrı ayrı çıkartılıp öznitelik vektörleri oluşturulmuştur. Bu öznitelik vektörlerinin sınıflandırma başarıları bulunmuştur. Ayrıca kenarsız Chan-Vese aktif kontur algoritması ile bulunan şüpheli bölgelerden elde edilen öznitelik vektörleri farklı durumlarda birleştirilerek yeni oluşan öznitelik vektörlerinin de sınıflandırma başarılarına bakılmıştır.

Şekil tabanlı öznitelikleri elde etmek için 64x64 boyutundaki bölgeden, konveks alan, alan, eksantriklik, çap, doluluk oranı, major eksen uzunluğu, minor eksen uzunluğu, oryantasyon, çevre, katılık, yuvarlaklık öznitelikleri çıkartılmıştır ve her üç şüpheli bölge tespit algoritması için oluşturulan şekil tabanlı öznitelik vektörü 1x11 boyutludur.

Gri seviye eş-oluşum matrisi özniteliklerini elde etmek için 64x64 boyutundaki bölgeden $d = 2$ uzaklığı ve $\theta = 0^\circ$ yönü için GLCM matrisi hesaplanmıştır. Daha sonra GLCM matrisinden Çizelge 5.2 de gösterilen 22 tane doku özneliği çıkartılmıştır. Her üç şüpheli bölge tespit algoritması için oluşturulan GLCM öznitelik vektörü 1x22 boyutludur.

Yönlendirilmiş gradyanların histogramı özniteliklerini elde etmek için K-means kümeleme ve Lab renk uzayında k-means kümeleme algoritması kullanılarak elde edilen 64x64 boyutundaki bölgeye hücre boyutu 8x8 ve yönelim sayısı 16 olan HOG uygulanmıştır. Oluşturulan HOG öznitelik vektörü 1x3136 boyutludur. Kenarsız Chan-Vese algoritması kullanılarak elde edilen 64x64 boyutundaki bölgeye hücre boyutu 9x9 ve yönelim sayısı 9 olan HOG uygulanmıştır. Oluşturulan HOG öznitelik vektörü 1x1296 boyutludur.

Yerel ikili örüntü özniteliklerini elde etmek için K-means kümeleme algoritması kullanılarak elde edilen 64x64 boyutundaki bölgeden daire yarıçapı 2 ve komşu sayısı 8 olan LBP oluşturulmuştur. Lab renk uzayında k-means kümeleme ve kenarsız Chan-Vese algoritması kullanılarak elde edilen 64x64 boyutundaki bölgeden ise daire yarıçapı 5 ve komşu sayısı 8 olan LBP oluşturulmuştur. Bu LBP öznitelik vektörleri 1x944 boyutludur.

İstatistiksel öznitelikleri elde etmek için K-means kümeleme algoritması kullanılarak elde edilen 64x64 boyutundaki matris 1x4096 boyutundaki vektör haline getirilmiştir. 1x4096 boyutundaki bölgeden enerji, ortalama, varyans, çarpıklık, basıklık, entropi, ortalama enerji, enerji varyansı öznitelikleri çıkartılmıştır ve oluşturulan istatistiksel öznitelik vektörü 1x8 boyutludur. Lab renk uzayında k-means kümeleme ve kenarsız Chan-Vese algoritması kullanılarak elde edilen 1x4096 boyutundaki bölgeden enerji, ortalama, varyans, çarpıklık, basıklık, entropi öznitelikleri çıkartılmıştır ve oluşturulan istatistiksel öznitelik vektörü 1x6 boyutludur.

7.5. Şüpheli Bölgelerin Sınıflandırılması

Şüpheli bölgeler k -NN ($k=1$), FLDA, Rastgele Orman (ağaç sayısı=100), Karar Ağacı, SVM, LLC ve Naive Bayes sınıflandırıcıları ile sınıflandırılmıştır. Bu sınıflandırma iyi huylu tümör, kötü huylu tümör ve normal (sağlıklı) olmak üzere üç sınıflıdır. Her sınıfın % 66' sını eğitim verisi olarak % 34' ü test verisi olarak belirlenmiştir. Sınıflandırma işlemi 3-katmanlı “rastgele çapraz doğrulama (randomized cross-validation)” tekniği kullanılarak gerçekleştirilmiştir. Bu teknik 3 aşamalıdır ve her aşamada her sınıfın rastgele seçilen farklı % 34'ü test verisi olarak kullanılmıştır. Daha sonra sınıflandırma başarısını bulmak için her aşamada doğruluk, hassasiyet ve özgüllük oranları elde edilmiştir. Hesaplanan bu oranlar toplanıp ortalaması alınmıştır ve genel başarımlar hesaplanmıştır.

8. BULGULAR VE TARTIŞMA

Tez çalışması kapsamında üç farklı algoritma ile şüpheli bölge tespiti yapılmıştır. Kullanılan bu algoritmaların performansını değerlendirmek için hedef niteliğe ait tahminlerin ve gerçek değerlerin karşılaştırıldığı karmaşıklık matrisi her bir algoritma için bulunmuştur. Bu matrisler kullanılarak performans değerlendirmesi yapılmıştır. Algoritmaların karmaşıklık matrisleri ve başarı durumları Çizelge 8.1’ de verilmiştir. Çizelge incelendiğinde şüpheli bölge tespitinde en iyi sonucun kenarsız Chan-Vese aktif kontur algoritmasına ait olduğu görülmüştür.

Çizelge 8.1. Algoritmaların karmaşıklık matrisleri ve başarı durumları

K-means Kümeleme		Lab Renk Uzayında K-means Kümeleme		Kenarsız Chan-Vese Aktif Kontur	
TP=165281	FN=43848	TP=148087	FN=61042	TP=175131	FN=33998
FP=511107	TN=5833364	FP=391016	TN=5953455	FP=291571	TN=6052900
Hassasiyet = 0,79		Hassasiyet = 0,71		Hassasiyet = 0,84	
Özgüllük = 0,92		Özgüllük = 0,94		Özgüllük = 0,95	
Doğruluk = 0,92		Doğruluk = 0,93		Doğruluk = 0,95	

Elde edilen bütün şüpheli bölgelerden 5. Bölümde anlatılan öznitelikler çıkartılmıştır. Bu özniteliklerin sınıflandırma başarıları doğruluk, hassasiyet ve özgüllük oranları hesaplanarak bulunmuştur. 6. Bölümde anlatılan yedi farklı sınıflandırıcı ile 3-sınıflı sınıflandırma aşaması tamamlanmıştır. Elde edilen tüm başarımlar oranları üç sınıftan ayrı ayrı elde edilen başarımlar oranlarının aritmetik ortalaması alınarak bulunmuştur.

K-means kümeleme algoritması kullanılarak elde edilen beş farklı öznitelik vektörünün ayrı ayrı sınıflandırma başarıları ve öznitelik vektör boyutları bulunmuştur. 11-boyutlu şekil tabanlı öznitelikler kullanılarak elde edilen sınıflandırma başarıları Çizelge 8.2’ de, 22-boyutlu GLCM öznitelikleri kullanılarak elde edilen sınıflandırma başarıları Çizelge 8.3’ te, 3136-boyutlu HOG öznitelikleri kullanılarak elde edilen sınıflandırma

başarıları Çizelge 8.4’ te, 944-boyutlu LBP öznitelikleri kullanılarak elde edilen sınıflandırma başarıları Çizelge 8.5’ te, 8-boyutlu istatistiksel öznitelikler kullanılarak elde edilen sınıflandırma başarıları Çizelge 8.6’ da verilmiştir.

Çizelge 8.2. K-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden şekil tabanlı öznitelikler çıkartılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	41,25	57,50	52,55	48,84	34,49	48,94	44,68	
Hassasiyet	41,61	58,84	54,32	48,89	34,75	53,96	48,36	11
Özgüllük	69,55	78,22	75,80	74,06	67,23	74,98	72,26	

Çizelge 8.3. K-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden GLCM öznitelikleri çıkartılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	61,90	82,41	76,67	67,27	72,36	69,72	64,49	
Hassasiyet	60,56	82,71	74,96	66,69	73	69,43	63,99	22
Özgüllük	80,21	91,50	87,91	83,29	86,64	84,71	82,71	

Çizelge 8.4. K-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden HOG öznitelikleri çıkartılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	71,94	67,96	67,50	38,29	66,76	58,80	70,23	
Hassasiyet	69,79	67,55	67,54	38,47	66,14	60,64	68,62	3136
Özgüllük	84,78	83,26	83,07	68,48	82,34	79,64	84,03	

Çizelge 8.5. K-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden LBP öznitelikleri çıkartılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	71,67	82,13	71,48	50,23	70	54,54	67,27	
Hassasiyet	73,49	83,11	72,90	52,17	70,89	58,44	67,95	944
Özgüllük	85,80	91,90	85,37	75,03	84,59	77,75	83,50	

Çizelge 8.6. K-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden istatistiksel öznitelikler çıkartılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	66,76	74,58	66,85	58,56	37,82	65,28	29,07	
Hassasiyet	65,84	75,05	65,49	57,96	34,41	66,13	33,33	8
Özgüllük	83,21	87,52	82,74	78,78	66,95	83,07	66,67	

Lab renk uzayında k-means kümeleme algoritması kullanılarak elde edilen beş farklı öznitelik vektörünün ayrı ayrı sınıflandırma başarıları ve öznitelik vektör boyutları bulunmuştur. 11-boyutlu şekil tabanlı öznitelikler kullanılarak elde edilen sınıflandırma başarıları Çizelge 8.7’ de, 22-boyutlu GLCM öznitelikleri kullanılarak elde edilen sınıflandırma başarıları Çizelge 8.8’ de, 3136-boyutlu HOG öznitelikleri kullanılarak elde edilen sınıflandırma başarıları Çizelge 8.9’ da, 944-boyutlu LBP öznitelikleri kullanılarak elde edilen sınıflandırma başarıları Çizelge 8.10’ da, 6-boyutlu istatistiksel öznitelikler kullanılarak elde edilen sınıflandırma başarıları Çizelge 8.11’ de verilmiştir.

Çizelge 8.7. Lab renk uzayında k-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden şekil tabanlı öznitelikler çıkartılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	47,55	46,11	48,38	46,94	39,58	36,25	41,81	11
Hassasiyet	47,06	45,06	48,51	46,77	37,52	35,81	40,02	
Özgüllük	73,06	72,37	73,67	73,46	69,09	67,51	69,49	

Çizelge 8.8. Lab renk uzayında k-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden GLCM öznitelikleri çıkartılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	59,12	73,15	78,80	71,62	58,84	57,59	60,37	22
Hassasiyet	57,41	71,85	75,94	69,73	55,73	56,56	59,80	
Özgüllük	79,63	86,85	89,05	85,75	79,15	78,64	80,60	

Çizelge 8.9. Lab renk uzayında k-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden HOG öznitelikleri çıkartılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	66,06	65,32	59,44	40,83	63,10	53,70	62,36	3136
Hassasiyet	63,56	63,99	57,81	41,16	61,72	54,27	61,14	
Özgüllük	81,78	82,01	78,45	70,53	80,91	76,79	80,19	

Çizelge 8.10. Lab renk uzayında k-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden LBP öznitelikleri çıkartılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	74,49	65,93	58,52	48,38	58,10	51,67	49,58	944
Hassasiyet	74,96	65,98	57,79	47,26	59,18	54,15	51,44	
Özgüllük	87,28	82,41	78,23	73,48	78,91	76,35	74,77	

Çizelge 8.11. Lab renk uzayında k-means kümeleme algoritması sonucu ortaya çıkan şüpheli bölgelerden istatistiksel öznitelikler çıkartılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	51,16	51,90	66,06	67,50	51,81	53,38	41,16	6
Hassasiyet	50,19	49,59	64,10	63,98	49,37	54,45	44,33	
Özgüllük	75,29	74,81	82,58	82,83	75,28	77,41	71,84	

Kenarsız Chan-Vese aktif kontur algoritması kullanılarak elde edilen beş farklı öznitelik vektörünün ayrı ayrı sınıflandırma başarıları ve öznitelik vektör boyutları bulunmuştur. 11-boyutlu şekil tabanlı öznitelikler kullanılarak elde edilen sınıflandırma başarıları Çizelge 8.12’ de, 22-boyutlu GLCM öznitelikleri kullanılarak elde edilen sınıflandırma başarıları Çizelge 8.13’ te, 1296-boyutlu HOG öznitelikleri kullanılarak elde edilen sınıflandırma başarıları Çizelge 8.14’ te, 944-boyutlu LBP öznitelikleri kullanılarak elde edilen sınıflandırma başarıları Çizelge 8.15’ te, 6-boyutlu istatistiksel öznitelikler kullanılarak elde edilen sınıflandırma başarıları Çizelge 8.16’ da verilmiştir.

Çizelge 8.12. Kenarsız Chan-Vese aktif kontur algoritması sonucu ortaya çıkan şüpheli bölgelerden şekil tabanlı öznitelikler çıkartılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	58,80	58,33	67,50	52,87	56,11	44,03	45,65	11
Hassasiyet	58,21	56,50	67,47	52,45	53,93	43,54	44,41	
Özgüllük	78,94	79,18	83,65	76,56	77,85	71,941	71,77	

Çizelge 8.13. Kenarsız Chan-Vese aktif kontur algoritması sonucu ortaya çıkan şüpheli bölgelerden GLCM öznitelikleri çıkartılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	62,41	83,70	88,70	77,18	72,92	54,86	72,55	22
Hassasiyet	61,34	83,46	88,49	76,70	73,88	54,04	73,08	
Özgüllük	80,50	91,43	92,24	88,06	86,31	77,25	86,28	

Çizelge 8.14. Kenarsız Chan-Vese aktif kontur algoritması sonucu ortaya çıkan şüpheli bölgelerden HOG öznitelikleri çıkartılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	92,92	88,61	83,84	51,25	91,48	92,31	90,19	1296
Hassasiyet	92,12	89,21	83,20	52,38	91,96	92,40	89,96	
Özgüllük	96,01	94,28	91,61	76,23	95,63	96,09	94,87	

Çizelge 8.15. Kenarsız Chan-Vese aktif kontur algoritması sonucu ortaya çıkan şüpheli bölgelerden LBP öznitelikleri çıkartılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	85,23	89,44	85,19	68,89	87,45	80,79	88,15	
Hassasiyet	85,57	89,64	85	68,01	88,07	82,09	88,86	944
Özgüllük	92,78	94,89	92,23	84,39	93,89	90,27	91,14	

Çizelge 8.16. Kenarsız Chan-Vese aktif kontur algoritması sonucu ortaya çıkan şüpheli bölgelerden istatistiksel öznitelikler çıkartılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	64,31	73,33	85,79	76,48	59,35	56,99	49,63	
Hassasiyet	63	72,60	84,45	75,90	61,42	54,81	51,96	6
Özgüllük	81,24	87,15	92,45	88,56	80,53	78,74	74,76	

Sınıflandırma başarılarını gösteren çizelgeler incelendiğinde en yüksek doğruluk oranının kenarsız Chan-Vese aktif kontur algoritması kullanılarak bulunan öznitelik vektörlerinden elde edildiği görülmüştür. % 92,92 olan en yüksek sınıflandırma doğruluğunun HOG öznitelikleri kullanılarak k-NN sınıflandırıcısı ile elde edildiği saptanmıştır.

Kenarsız Chan-Vese yönteminin diğer iki yöntemle kıyaslandığında daha iyi sonuçlar verdiği belirlenmiştir. Doğruluk oranını artırmak amacıyla kenarsız Chan-Vese yöntemi ile bulunan şüpheli bölgelerden elde edilen beş farklı öznitelik vektörünün tüm farklı kombinasyonları bulunarak yirmi altı tane yeni öznitelik vektörü oluşturulmuştur. Elde edilen yeni öznitelik vektörlerinin boyutları ve sınıflandırma doğruluk değerleri Çizelge 8.17’ de verilmiştir.

Çizelge 8.17. Kenarsız Chan-Vese yöntemi sonucu ortaya çıkan şüpheli bölgelerden çıkartılan beş farklı öznitelik vektörünün farklı kombinasyonları kullanılarak elde edilen sınıflandırma doğruluk değerleri (%) ve öznitelik boyutları.

Yeni Öznitelik Vektörleri	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Şekil tabanlı+GLCM	70,09	84,49	80,14	69,31	68,98	58,43	50,09	33
Şekil tabanlı+HOG	58,80	88,61	81,71	49,17	56,62	90,23	41,85	1307
Şekil tabanlı+LBP	62,36	88,75	86,06	69,63	78,98	80,79	41,85	955
Şekil tabanlı+İstatistiksel	68,98	62,36	78,70	71,53	46,99	57,59	55,05	17

GLCM+HOG	62,41	87,22	86,53	55,05	84,40	91,62	73,15	1318
GLCM+LBP	72,92	90,93	87,36	63,29	83,80	80,79	83,89	966
GLCM+İstatistiksel	74,44	78,06	87,31	75,09	77,36	56,99	69,12	28
HOG+LBP	85,23	93,01	87,45	57,22	87,45	85	85,37	2240
HOG+İstatistiksel	65	88,61	86,71	71,39	83,75	89,54	45,65	1302
LBP+İstatistiksel	72,31	88,75	86,67	71,67	84,58	80,09	43,52	950
Şekil tabanlı+GLCM+HOG	70,09	87,92	85,19	49,12	43,98	90,23	41,85	1329
Şekil tabanlı+GLCM+LBP	71,53	90,23	83,24	55,93	73,06	80,09	41,85	977
Şekil tabanlı+GLCM+İstatistiksel	71,11	83,29	83,66	72,31	68,33	56,99	53,10	39
Şekil tabanlı+HOG+LBP	62,36	93,01	87,45	51,53	79,72	84,31	41,85	2251
Şekil tabanlı+HOG+İstatistiksel	68,98	88,61	84,58	68,56	63,98	87,45	44,63	1313
Şekil tabanlı+LBP+İstatistiksel	68,98	90,19	88,15	69,68	78,19	80,09	44,63	961
GLCM+HOG+LBP	72,92	92,31	87,27	55,05	83,80	85	83,19	2262
GLCM+HOG+İstatistiksel	74,44	85,83	86,57	80,79	83,01	88,84	44,21	1324
GLCM+LBP+İstatistiksel	74,49	90,93	87,27	76,44	80,97	80,09	45,60	972
HOG+LBP+İstatistiksel	72,31	93,01	88,75	70,93	84,58	84,31	46,30	2246
Şekil tabanlı+GLCM+HOG+LBP	71,53	92,31	88,10	48,43	73,06	85,05	41,85	2273
Şekil tabanlı+GLCM+HOG+İstatistiksel	71,11	87,22	87,96	78,70	64,81	87,45	41,16	1335
Şekil tabanlı+GLCM+LBP+İstatistiksel	71,85	90,23	88,80	72,96	69,40	80,09	38,38	983
Şekil tabanlı+HOG+LBP+İstatistiksel	68,98	93,01	83,19	70,37	78,19	83,61	44,63	2257
GLCM+HOG+LBP+İstatistiksel	74,49	91,62	92,36	75,74	80,97	84,35	45,60	2268
Şekil tabanlı+GLCM+HOG+LBP+İstatistiksel	71,85	91,62	84,58	72,96	69,40	84,35	38,38	2279

Çizelge 8.17 incelendiğinde HOG ve LBP öznitelikleri birlikte kullanıldığında FLDA sınıflandırıcısı ile en yüksek doğruluk oranının % 93,01'e yükseldiği görülmüştür. Ayrıca tek bir çeşit öznitelik vektörü kullanılarak bulunmuş olan doğruluk oranlarını artıran öznitelik vektör kombinasyonları belirlenmiştir. Toplamda dokuz farklı öznitelik vektör kombinasyonunda tek çeşit öznitelik vektör kullanımına göre doğruluk oranları artmıştır. Bu kombinasyonlara ait daha hassas bir analiz yürütmek için hassasiyet ve özgüllük oranları doğruluk oranlarıyla beraber Çizelge 8.18-8.26'da verilmiştir.

Çizelge 8.18. GLCM ve LBP öznitelikleri birlikte kullanılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	72,92	90,93	87,36	63,29	83,80	80,79	83,89	966
Hassasiyet	72,62	90,81	86,96	63,70	84,33	82,09	84,42	
Özgüllük	86,43	95,44	93,54	81,66	91,92	90,41	92,13	

Çizelge 8.19. HOG ve LBP öznitelikleri birlikte kullanılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	85,23	93,01	87,45	57,22	87,45	85	85,37	2240
Hassasiyet	85,57	93,46	86,84	51,78	88,07	85,90	85,92	
Özgüllük	92,78	96,50	93,68	76,11	93,89	92,38	92,70	

Çizelge 8.20. Şekil tabanlı, GLCM ve LBP öznitelikleri birlikte kullanılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	71,53	90,23	83,24	55,93	73,06	80,09	41,85	977
Hassasiyet	71,37	90,02	82,02	55,69	73,55	81,29	33,33	
Özgüllük	85,51	95,11	91,19	78,20	86,61	90,02	66,67	

Çizelge 8.21. Şekil tabanlı, HOG ve LBP öznitelikleri birlikte kullanılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	62,36	93,01	87,45	51,53	79,72	84,31	41,85	2251
Hassasiyet	62,30	93,46	87,08	51,70	80,20	85,10	33,33	
Özgüllük	80,59	96,50	93,25	76	89,89	91,99	66,67	

Çizelge 8.22. Şekil tabanlı, LBP ve istatistiksel öznitelikleri birlikte kullanılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	68,98	90,19	88,15	69,68	78,19	80,09	44,63	961
Hassasiyet	69,39	90,23	87,40	68,15	79	81,53	38,89	
Özgüllük	83,98	95,23	93,92	84,63	89,32	89,95	69,44	

Çizelge 8.23. GLCM, LBP ve istatistiksel öznitelikler birlikte kullanılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	74,49	90,93	87,27	76,44	80,97	80,09	45,60	972
Hassasiyet	73,98	90,81	86,36	74,42	81,33	81,53	46,70	
Özgüllük	86,47	95,44	93,41	87,58	90,46	90,09	74,01	

Çizelge 8.24. HOG, LBP ve istatistiksel öznitelikler birlikte kullanılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	72,31	93,01	88,75	70,93	84,58	84,31	46,30	2246
Hassasiyet	72,43	93,46	88,82	69,92	84,77	85,34	46,78	
Özgüllük	86,34	96,50	94,35	85,37	92,38	92,06	74,19	

Çizelge 8.25. Şekil tabanlı, GLCM, LBP ve istatistiksel öznitelikler birlikte kullanılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	71,85	90,23	88,80	72,96	69,40	80,09	38,38	983
Hassasiyet	71,67	90,02	88,85	71,16	69,82	81,53	31,51	
Özgüllük	85,10	95,11	94,29	85,80	84,91	90,02	65,80	

Çizelge 8.26. Şekil tabanlı, HOG, LBP ve istatistiksel öznitelikler birlikte kullanılarak elde edilen sınıflandırma başarıları (%).

	k-NN	FLDA	Rastgele Orman	Karar Ağacı	SVM	Naive Bayes	LLC	Öznitelik Boyutu
Doğruluk	68,98	93,01	83,19	70,37	78,19	83,61	44,63	2257
Hassasiyet	69,39	93,46	82,47	69,22	79	84,55	38,89	
Özgüllük	83,98	96,50	91,18	85,04	89,32	91,66	69,44	

Ayrıca en iyi sınıflandırma sonucunu veren HOG ve LBP özniteliklerinin birlikte kullanıldığında elde edilen sınıf bazında başarı oranları bulunmuştur ve Çizelge 8.27’de verilmiştir.

Çizelge 8.27. HOG ve LBP öznitelikleri birlikte kullanılarak elde edilen sınıf bazında başarı oranları (%).

	Normal (Sağlıklı)	İyi Huylu Tümör	Kötü Huylu Tümör
Doğruluk	97,56	89,83	92,68
Hassasiyet	97,62	89,91	92,86
Özgüllük	95,10	96,43	97,98

Literatürde Harvard veri tabanını kullanarak beyin tümörü içeren MR imgelerini sınıflandıran çalışmalar incelenmiştir. Bu veri tabanı kullanılarak elde edilen başarımlar oranları ile bu tezde elde edilen başarımlar oranları kıyaslanmıştır ve Çizelge 8.28’de verilmiştir.

Çizelge 8.28. Literatürde Harvard veri tabanı kullanılarak elde edilen başarımlar oranları ile bu tezde elde edilen başarımlar oranlarının kıyaslanması

Referans	Çıkarılan Öznitelikler	Sınıflandırma Metodu	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)
(Amin vd., 2017)	Şekil tabanlı, GLCM, İstatistiksel	SVM	99,4	98,4	100
(Priya vd., 2016)	GLCM	SVM	85	82,73	94,47
(Chavan vd., 2015)	GLCM	k-NN	96,15	Mevcut değil	Mevcut değil
Önerilen Çalışma	HOG + LBP	FLDA	93,01	93,46	96,50

9. SONUÇ VE ÖNERİLER

Ölüme en çok yol açan beyin hastalıklarından birisinin beyin tümörü olduğu bilinmektedir. Bu sebeple beyin tümörünün erken tanısı ve tespiti oldukça önemlidir. Bu çalışmada, beyin tümörlerinin tespitinde en sık kullanılan görüntüleme tekniği olan MR görüntüleme kullanılmıştır. Tez çalışması kapsamında beyin tümörlerinin tespiti ve sınıflandırılması için MR imgeleri çeşitli görüntü işleme yöntemleri ile işlenmiştir. Uzmanlara yardımcı olmak amacıyla otomatik bir sistem sunulmuştur.

Bu tez çalışmasında sunulan sistem, kafatasının ortadan kaldırılması, şüpheli bölge tespiti, öznelik çıkartımı ve sınıflandırma olarak dört farklı aşamada gerçekleştirilmiştir. Bu aşamalarda, 41 tanesi normal (sağlıklı), 59 tanesi iyi huylu tümürlü ve 41 tanesi kötü huylu tümürlü olmak üzere toplam 141 tane beyin MR imgesinden oluşan Harvard veri seti kullanılmıştır. İlk aşamada öncelikle MR imgelerinde İkileştirme yöntemi kullanılmıştır. Elde edilen ikili imgelere Açma, Delik doldurma ve Genişletme işlemleri gibi temel bazı morfolojik işlemler uygulanmıştır. Böylece kafatasını beyin yapısından ayıran maske elde edilmiştir ve kafatası atılmıştır. Bu işlem şüpheli bölge tespitinin doğru bir şekilde yapılması için gerekli bir ön adımdır.

Tez çalışmasının ikinci aşamasında şüpheli bölge tespiti yapılmıştır. K-means kümeleme, Lab renk uzayında k-means kümeleme ve Kenarsız Chan-Vese yöntemleri olmak üzere üç farklı algoritma kullanılmıştır. Bu yöntemlerin performans değerlendirmelerine bakılmıştır. Değerlendirme yapılırken uzman görüşü alınarak gerçek değerler elle tespit edilmiştir. Her bir yöntem için gerçek değerlerin ve algoritmaların bulduğu hedef niteliğe ait tahminlerin karşılaştırıldığı karmaşıklık matrisi bulunmuştur. Karmaşıklık matrisleri kullanılarak bu yöntemlerin şüpheli bölgeyi bulmadaki hassasiyet, özgüllük ve doğruluk oranları elde edilmiştir. Sonuç olarak şüpheli bölge tespitinde en iyi performansı % 84 hassasiyet oranı ile Kenarsız Chan-Vese yöntemi sağlamıştır.

Tez çalışmasının üçüncü aşamasında tespit edilen şüpheli bölgelerden doku, şekil ve yoğunluk ile ilgili bilgileri veren beş farklı öznelik çıkartılmıştır. Bu öznelikler Şekil tabanlı, GLCM, HOG, LBP ve İstatistiksel özneliklerdir. Sınıflandırma başarısının artması

için farklı dokuları en iyi ayırt edebilen özniteliklerin seçilmesi oldukça önemlidir. Bu sebeple ayrı ayrı elde edilen öznitelik vektörleri farklı kombinasyonlarda seçilerek yeni oluşan öznitelik vektörlerinin de sınıflandırma başarılarına bakılmıştır.

Tez çalışmasının son kısmı olan dördüncü aşamada ise şüpheli bölgeler iyi huylu tümör, kötü huylu tümör ve normal olarak sınıflandırılmıştır. Bu işlem için k -NN, FLDA, Rastgele orman, Karar ağacı, SVM, LLC ve Naive bayes sınıflandırıcıları kullanılmıştır. Veri setinin % 66' sı eğitim verisine % 34' ü test verisine ayrılmıştır. Sınıflandırma, 3-katmanlı rastgele çapraz doğrulama tekniği kullanılarak gerçekleştirilmiştir ve her bir çapraz doğrulama adımında her sınıfın farklı % 34' ü test verisi olarak kullanılmıştır. Sınıflandırma sonuçlarına bakıldığında tümörlü ve tümörsüz bölgelerin tanımlanması açısından hangi özniteliklerin daha ayırt edici bir bilgiye sahip olduğu tespit edilmiştir. Beş farklı öznitelikten ayırt ediciliği en yüksek olarak ilk sırada HOG özniteliklerinin ikinci sırada ise LBP özniteliklerinin geldiği görülmüştür. Bu doğrultuda en iyi sınıflandırma sonucu, HOG ve LBP özniteliklerinin birleşiminden oluşan öznitelik vektörü kullanılarak FLDA sınıflandırıcısı ile elde edilmiştir. En iyi sınıflandırma başarısı %93,01 doğruluk oranı, %93,46 hassasiyet oranı ve %96,50 özgülük oranı olarak hesaplanmıştır.

Tez çalışması kapsamında şüpheli bölge tespitinde Chan-Vese yönteminin öne çıktığı ve çok daha iyi sonuçlar verdiği görülmüştür. Farklı dokuları tanımlayıcılığı yüksek olan özniteliklerin seçilmesinin sınıflandırma doğruluğunu artırdığı görülmüştür. Tezde kullanılan sınıflandırıcıların birbirlerine kesin bir üstünlük sağlamadıkları fakat sınıflandırma doğruluğunu temel etkileyen durumun parametre seçimi olduğu tespit edilmiştir.

Çalışmada elde edilen sonuçlar umut vericidir ve ileriki çalışmalara ışık tutarak literatüre katkı sağlayacağı düşünülmektedir. Gelecekteki çalışmalarda daha geniş bir veri tabanı kullanılarak beyin MR imgelerinin tümör derecesine göre sınıflandırma işlemi yapılabilir. Şüpheli bölgelerden elde edilen özniteliklere çeşitli özniteliklerin (özellikle şüpheli bölgelerden doku ve şekil bilgisini daha iyi ortaya koyan) ilave edilmesinin sınıflandırma başarısını artıracacağı düşünülmektedir. Ayrıca daha iyi bir çözünürlüğe sahip olan MR imgelerinin kullanılması sınıflandırma başarısını artıracaktır.

KAYNAKLAR DİZİNİ

- 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.
- Ain, Q., Latif, G., Kazmi, S. B., Jaffar, M. A., Mirza, A. M., 2010, Classification and segmentation of brain tumor using texture analysis, *Recent Advances In Artificial Intelligence, Knowledge Engineering And Data Bases*, 147–155.
- Aldus Corporation, 1992, TIFF Revision 6.0 Final, Seattle, WA., 110–115.
- Amin, J., Sharif, M., Yasmin, M., Fernandes, S. L., 2017, A distinctive approach in brain tumor detection and classification using MRI, *Pattern Recognition Letters*, 1–10.
- Anitha, V., Murugavalli, S., 2016, Brain tumour classification using two-tier classifier with adaptive segmentation technique, *IET Computer Vision*, 10(1), 9–17.
- Arakeri, M. P., Reddy, G. R. M., 2015, Computer-aided diagnosis system for tissue characterization of brain tumor on magnetic resonance images, *Signal, Image and Video Processing*, 9(2), 409–425.
- Asodekar, B., Gore, S. A., 2019, Brain tumor classification using shape analysis of MRI images, *International Conference on Communication and Information Processing (ICCIP-2019)*.
- Ayhan, S., Erdoğan, Ş., 2014, Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi, *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 9(1), 175–198.
- Bahadure, N. B., Ray, A. K., Thethi, H. P., 2017, Image analysis for MRI based brain tumor detection and feature extraction using biologically inspired BWT and SVM, *International Journal of Biomedical Imaging*, 2017, 1–12.
- Bhatia, S. K., 2004, Adaptive k-means clustering, In *Proceedings of Florida Artificial Intelligence Research Symposium*, 695–699.
- Breiman, L., 2001, Random forests, *Machine Learning*, 45, 5–32.
- Chan, T. F., Vese, L. A., 2001, Active contours without edges, *IEEE Transactions on Image Processing*, 10(2), 266–277.
- Chavan, N. V., Jadhav, B. D., Patil, P. M., 2015, Detection and classification of brain tumors. *International Journal of Computer Applications*, 112(8), 0975–8887.
- Chowdhury, A., Chowdhury, A. R., Das, I., Halder, A., 2018, Detection and classification of brain tumor using ML, *International Journal of Advanced Research in Computer Science*, 9(2), 585–591.
- Clausi, D. A., 2002, An analysis of co-occurrence texture statistics as a function of grey level quantization, *Canadian Journal of Remote Sensing*, 28(1), 45–62.
- Cortes, C., Vapnik, V., 1995, Support-vector networks, *Machine Learning*, 20, 273–297.

KAYNAKLAR DİZİNİ (devam)

- Cover T, M., Hart P, E., 1967, Nearest neighbor pattern classification, IEEE Transactions on Information Theory, 13(1), 21–27.
- Dalal, N., Triggs, B., 2005, Histograms of oriented gradients for human detection, IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 886–893.
- Deshmukh, R. D., Jadhav, C., 2014, Study of different brain tumor MRI image segmentation techniques, International Journal of Computer Science Engineering and Technology, 4(4), 133–136.
- Esener, İ. I., 2017, Meme kanseri için şüpheli bölgelerin mamografi imgeleri üzerinde belirlenmesi ve meme kanser türünün sınıflandırılması, Doktora Tezi, Eskişehir Osmangazi Üniversitesi, 150 s.
- Firoz, R., Ali, M. S., Khan, M. N. U., Hossain, M. K., Islam, M. K., Shahinuzzaman, M., 2016, Medical image enhancement using morphological transformation, Journal of Data Analysis and Information Processing, 4(1), 1–12.
- Fisher, R. A., 1936, The use of multiple measurements in taxonomic problems, Annals of Eugenics, 7(2), 179–188.
- George, D. N., Jehlol, H. B., Oleiwi, A. S. A., 2015, Brain tumor detection using shape features and machine learning algorithms, International Journal of Scientific & Engineering Research, 6(12), 454–459.
- Haralick, R. M., Shanmugam, K., Dinstein, I., 1973, Textural features for image classification, IEEE Transactions on Systems, Man and Cybernetics, 3(6), 610–621.
- Hsieh, K. L. C., Lo, C. M., Hsiao, C. J., 2017, Computer-aided grading of gliomas based on local and global MRI features, Computer Methods and Programs in Biomedicine, 139, 31–38.
- Jain, A.K., Dubes, R. C., 1988, Algorithms for clustering data, Prentice Hall College Div, 334,
- John, G. H., Langley, P., 1995, Estimating continuous distributions in bayesian classifiers. Proceedings of the Eleventh Conference on Uncertainty in Artificial Intelligence, 338–345.
- Joseph, R. P., Singh, C. S., Manikandan, M., 2014, Brain tumor Mri image segmentation and detection in image processing, International Journal of Research in Engineering and Technology, 3(1), 1–5.
- Kawa, J., Rudzki, M., Pietka, E., Szwarc, P., 2015, Computer aided diagnosis workstation for brain tumor assessment, 22nd International Conference ‘Mixed Design of Integrated Circuits and Systems’, 98–103.
- Mali, A. A., Pawar, S. R., 2016, Detection & classification of brain tumour, International Journal of Innovative Research in Computer and Communication Engineering, 4(1), 407–411.

KAYNAKLAR DİZİNİ (devam)

- Mandwe, A. A., Anjum, A., 2016, Detection of brain tumor using K-means clustering, *International Journal of Science and Research (IJSR)*, 5(6), 420–423.
- Mumford, D., Shah, J., 1989, Optimal approximations by piecewise smooth functions and associated variational problems, *Communications on Pure and Applied Mathematics*, 42(5), 577–685.
- Nabizadeh, N., Kubat, M., 2015, Brain tumors detection and segmentation in MR images: Gabor wavelet vs. statistical features, *Computers and Electrical Engineering*, 45, 286–301.
- Ojala, T., Pietikäinen, M., Mäenpää, T., 2002, Multiresolution gray-scale and rotation invariant texture classification with local binary patterns, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7), 971–987.
- Paul, T. U., Bandhyopadhyay, S. K., 2012, Segmentation of brain tumor from brain MRI images reintroducing K – means with advanced dual localization method, *International Journal of Engineering Research and Applications (IJERA)*, 2(3), 226–231.
- Pohar, M., Blas, M., Turk, S., 2004, Comparison of logistic regression and linear discriminant analysis: A simulation study, *Metodološki Zvezki*, 1(1), 143–161.
- Praveen, G. B., Agrawal, A., 2016, Hybrid approach for brain tumor detection and classification in magnetic resonance images, *International Conference Communication, Control and Intelligent Systems (CCIS)*, 162–166.
- Priya, K. M., Kavitha, S., Bharathi, B., 2016, Brain tumor types and grades classification based on statistical feature set using support vector machine, *Proceedings of the 10th International Conference on Intelligent Systems and Control, ISCO 2016*.
- Raj, A., Alankrita, A. S., Bhateja, V., 2011, Computer aided detection of brain tumor in magnetic resonance images, *International Journal of Engineering and Technology*, 3(5), 523–532.
- 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(6), 1141–1150.
- Sachdeva, J., Kumar, V., Gupta, I., Khandelwal, N., Ahuja, C. K., 2016, A package-SFERCB-"Segmentation, feature extraction, reduction and classification analysis by both SVM and ANN for brain tumors", *Applied Soft Computing*, 47, 151–167.
- Sehgal, A., Goel, S., Mangipudi, P., Mehra, A., Tyagi, D., 2016, Automatic brain tumor segmentation and extraction in MR images, *Conference on Advances in Signal Processing (CASP)*, 104–107.
- Soh, L. K., Tsatsoulis, C., 1999, Texture analysis of sar sea ice imagery using gray level co-occurrence matrices, *IEEE Transactions on Geoscience and Remote Sensing*, 37(2), 780–795.

KAYNAKLAR DİZİNİ (devam)

- Strickland, R. N., 2002, Image-processing techniques for tumor detection, CRC Press, p.1-27.
- Summers, D., 2003, Harvard whole brain atlas: www.med.harvard.edu/AANLIB/home.html, J Neurol Neurosurg Psychiatry, 74(3), 288–288.
- Swain, P. H., Hauska, H., 1977, Decision tree classifier: Design and potential. IEEE Transactions on Geoscience Electronics, GE-15(3), 142–147.
- Wang, L., He, D. C., 1990, Texture classification using texture spectrum, Pattern Recognition, 23(8), 905–910.
- Wasule, V., Sonar, P., 2017, Classification of brain MRI using SVM and KNN classifier, In Proceedings of 2017 3rd IEEE International Conference on Sensing, Signal Processing and Security (ICSSS), 218–223.
- Webb, A. R., 2002, Linear discriminant analysis. in: Statistical pattern recognition, John Wiley & Sons, New York, p. 158-159.
- Wu, P., Xie, K., Zheng, Y., Wu, C., 2012, Brain tumors classification based on 3D shape. Advances in Intelligent and Soft Computing, 160(2), 277–283.
- Yin, Z., Porikli, F., Collins, R. T., 2008, Likelihood map fusion for visual object tracking, IEEE Workshop on Applications of Computer Vision, WACV, 1–7.
- Zawish, M., Siyal, A. A., Ahmed, K., Khalil, A., Memon, S., 2019, Brain tumor segmentation in MRI images using Chan-veese technique in MATLAB, 2018 International Conference on Computing, Electronic and Electrical Engineering, ICE Cube 2018, 1–6.
- Zhuang, A. H., Valentino, D. J., Toga, A. W., 2006, Skull-stripping magnetic resonance brain images using a model-based level set, NeuroImage, 32(1), 79–92.
- Zulpe, N., Pawar, V., 2012, GLCM textural features for brain tumor classification, International Journal of Computer Science Issues (IJCSI), 9(3), 354–359.