

**BEYİN MR GÖRÜNTÜLERİNİN DALGACIK DÖNÜŞÜMÜ VE
ÖZÖRGÜTLEMELİ HARİTA AĞLARI KULLANILARAK
BÖLÜTLENMESİ**

Ayşe DEMİRHAN

**DOKTORA TEZİ
ELEKTRONİK-BİLGİSAYAR EĞİTİMİ**

**GAZİ ÜNİVERSİTESİ
BİLİŞİM ENSTİTÜSÜ**

**Ocak 2012
ANKARA**

Ayşe DEMİRHAN tarafından hazırlanan BEYİN MR GÖRÜNTÜLERİNİN DALGACIK DÖNÜŞÜMÜ VE ÖZÖRGÜTLEMELİ HARİTA AĞLARI KULLANILARAK BÖLÜTLENMESİ adlı bu tezin Doktora tezi olarak uygun olduğunu onaylarım.


Prof. Dr. İnan GÜLER

Tez Yöneticisi

Bu çalışma, jürimiz tarafından oy birliği ile Elektronik-Bilgisayar Eğitimi Anabilim Dalında Doktora tezi olarak kabul edilmiştir.

Başkan : Prof. Dr. Ömer Faruk BAY

Üye : Prof. Dr. İnan GÜLER

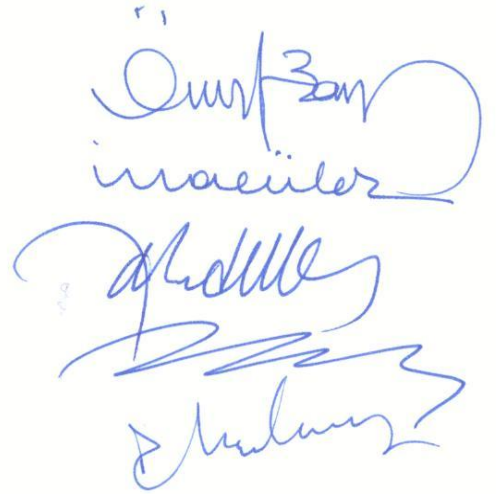
Üye : Doç. Dr. O. Ayhan ERDEM

Üye : Yrd. Doç. Dr. Hasan Şakir BİLGE

Üye : Yrd. Doç. Dr. Derya YILMAZ

Tarih : 12.01.2012

Bu tez, Gazi Üniversitesi Bilişim Enstitüsü tez yazım kurallarına uygundur.



TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada orijinal olmayan her türlü kaynağa eksiksiz atıf yapıldığını bildiririm.

Ayşe DEMİRHAN

**BEYİN MR GÖRÜNTÜLERİNİN DALGACIK DÖNÜŞÜMÜ VE
ÖZÖRGÜTLEMELİ HARİTA AĞLARI KULLANILARAK
BÖLÜTLENMESİ**

(Doktora Tezi)

Ayşe DEMİRHAN

GAZİ ÜNİVERSİTESİ

BİLİŞİM ENSTİTÜSÜ

Ocak 2012

ÖZET

MR görüntüleme tekniği ağrısız ve hasta vücuduna zarar vermeden uygulanan, özel bir makine ile kemiklerin ve diğer dokuların görüntülerinin alındığı bir tıbbi görüntüleme metodudur. Yüksek kalitede tıbbi görüntüler elde etmek amacıyla geniş ölçüde kullanılmaktadır. Beyin MR görüntülerinin bölütlenmesi, ilgilenilen dokuların diğer dokulardan ayrılarak belirgin hale getirilmesi, beyin tümörleri ve diğer nörolojik hastalıkların teşhisi amacıyla gerekli olan çok önemli ve zor bir işlemdir. Bu çalışmada, beyin MR görüntüleri gri cevher, beyaz cevher ve beyin-omurilik sıvısı sağlıklı dokuları ile varsa tümör ve ödem hastalıklı dokularına bölütlenmektedir. Literatürde bu tez çalışmasındaki yöntemleri kullanarak tümör ve ödem ile birlikte sağlıklı beyin dokuları bir arada bölütleyen bir çalışma bulunmamaktadır.

Bu çalışmada, beyin dokularının bölütlenmesi işlemi, gerçek beyin görüntüleri kullanılarak oluşturulmuş beyin modeli, sağlıklı kişilere ait beyin MR görüntüleri ve beyninde tümör bulunan kişilere ait hastaneden toplanan beyin MR görüntüleri üzerinde gerçekleştirilmiştir. Eşyönsüz yayılım filtresi ile

filtrelenen görüntüler çakıştırılarak aynı koordinat sisteminde gösterilmiştir. Beyin dokusu dışındaki alanları görüntülerden çıkartmak için eşikleme ve morfolojik işlemleri bir arada kullanan bir algoritma geliştirilmiştir. Görüntülerden özellik çıkartmak için dalgacık dönüşümü yöntemi kullanılmıştır. Bölütleme işlemi için danışmansız bir yapay sinir ağı olan özörgütlemeli harita ağı kullanılmıştır. Özörgütlemeli harita ağı, el ile etiketlenmiş görüntü bölgeleri ve çıkış nöronlarının isabet histogramına dayanarak geliştirilen algoritma ile etiketlenmiştir. Nöronların en iyi konumunu ayarlamak için danışmanlı bir yöntem olan öğrenmeli vektör nicemleme algoritması kullanılmıştır. Sonuçlar, duyarlılık, belirlilik ve elle yapılan bölütleme ile sistemden elde edilen bölütleme sonuçlarının örtüşme oranlarını gösteren Jaccard ve Dice benzerlik indekslerine göre değerlendirilmiştir. Bölütleme işleminin adımlarını sonuçlarını görerek gerçekleştirebilmek üzere MATLAB ortamında bir grafik ara yüz geliştirilmiştir. Bölütleme sonuçları, beyin MR görüntülerinin bölütlenmesinin dalgacık dönüşümü ve özörgütlemeli yapay sinir ağları ile mümkün olduğunu göstermiştir.

Bilim Kodu : 702.1.021
Anahtar Kelimeler : MR görüntüleme, beyin tümörü, görüntü bölütleme, dalgacık dönüşümü, özörgütlemeli yapay sinir ağları, öğrenmeli vektör nicemleme
Sayfa Adedi : 159
Tez Yöneticisi : Prof. Dr. İnan GÜLER

**SEGMENTATION OF BRAIN MR IMAGES USING WAVELET
TRANSFORM AND SELF ORGANIZING MAPS NEURAL NETWORK**

(Ph.D. Thesis)

Ayşe DEMİRHAN

GAZİ UNIVERSITY

INFORMATICS INSTITUTE

January 2012

ABSTRACT

MR is a painless and noninvasive medical imaging technique in which images of bones and other tissues are taken with a special machine. It is widely used in order to obtain high quality medical images. Segmentation of brain MR images, i.e. separation of tissues of interest from other tissues, and making them clear is a very important and difficult task that is required for the detection of brain tumors and other neurological diseases. In this study, brain MR images are segmented into healthy tissues as white matter, grey matter and cerebrospinal fluid, and if any tumor and edema. In the literature, there are no studies that segments healthy brain tissues together with tumor and edema utilizing the methods used in this study.

In this study, tissue segmentation of brain MR images is performed on a brain model that is generated using real brain MR images, brain MR images of healthy people and brain MR images of patients with tumor that are obtained

from the hospital. Images that are filtered using anisotropic diffusion filter are aligned to the same coordinate system by registration. An algorithm that combines thresholding and morphological processes is developed to remove the areas other than the brain tissues from the images. Wavelet transform is used to obtain features from the images. Self-organizing map which is an unsupervised neural network is used for the segmentation process. Self-organizing map is labeled using the developed algorithm that is based on manually labeled image regions and hit histograms of the output neurons. Supervised learning vector quantization algorithm is used to adjust the best settlements of the neurons. Results are evaluated by sensitivity, specificity, Jaccard and Dice similarity indexes that show the overlap of the manual segmentation and the segmentation results obtained from the system. A graphical user interface is developed in MATLAB environment to perform the steps of the segmentation process by seeing the results of each step. Segmentation results indicate that segmentation of the brain MR images was feasible by wavelet transform and self-organizing maps neural networks.

Science Code : 702.1.021
Key Words : MR imaging, brain tumor, image segmentation,
wavelet transform, self-organizing maps, learning vector
quantization
Page Numbers : 159
Adviser : Prof. Dr. İnan GÜLER

TEŐEKKÖR

Çalıőmalarım boyunca deęerli yardım ve katkılarıyla beni yönlendiren Sayın Hocam Prof. Dr. İnan GÖLER'e, çalıőmalarımda kullandığım verilerin elde edilmesinde bana yardımcı olan Dr. Mustafa TÖRÖ'ye, destekleriyle beni hiçbir zaman yalnız bırakmayan eőim Gökhan DEMİRHAN'a ve aileme teőekkürü bir borç bilirim.

İÇİNDEKİLER

ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ÇİZELGELERİN LİSTESİ.....	xi
ŞEKİLLERİN LİSTESİ	xii
SİMGELER VE KISALTMALAR.....	xix
1. GİRİŞ	1
2. MALZEME ve YÖNTEM	15
2.1. Beyin Modeli	15
2.2. Sağlıklı Beyin MR Görüntüleri	17
2.3. Tümörlü Beyin MR Görüntüleri.....	20
2.4. MR Görüntüleme Yöntemi.....	22
2.5. Görüntü Bölütleme	26
2.6. Görüntü Çakıştırma	27
2.7. Eşyönsüz Yayınım Filtresi	31
2.8. Dalgacık Dönüşümü	32
2.8.1. İki boyutlu dalgacık dönüşümü.....	34
2.8.2. Hızlı dalgacık dönüşümü	35
2.8.3. Dalgacık paketleri	38
2.8.4. Durağan dalgacık dönüşümü.....	41
2.9. Desen Özelliklerinin Çıkarılması	42
2.10. Özörgütlemeli Harita Ağları.....	45

2.11. Öğrenmeli Vektör Nicemleme.....	52
2.11.1. Vektör nicemleme	52
2.11.2. Öğrenmeli vektör nicemleme.....	53
2.12. Performans Değerlendirme Ölçütleri	57
2.13. Yazılım Geliştirme Ortamı	59
3. GELİŞTİRİLEN ALGORİTMALAR	60
3.1. Görüntülerde Beyin Bölgesinin Bulunması.....	60
3.2. Özöğütlemeli Harita Ağının Kümelenmesi ve Etiketlenmesi	69
4. BULGULAR VE İRDELEME.....	72
4.1. Beyin Modeli Bulguları ve İrdeleme	72
4.2. Sağlıklı Beyin MR Görüntüleri Bulguları ve İrdeleme	81
4.3. Tümörlü Beyin MR Görüntüleri Bulguları ve İrdeleme.....	92
4.4. Sistem Grafik Arayüzü	122
5. SONUÇLAR VE DEĞERLENDİRME	138
KAYNAKLAR	144
ÖZGEÇMİŞ	158

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Geliştirilen algoritma ile diğer yöntemlerin performanslarının karşılaştırması.....	68
Çizelge 4.1. Beyin modeli kesin referans doku değerleri	73
Çizelge 4.2. Çeşitli dalgacıklar ile farklı ayrıştırma seviyelerinden elde edilen bölütleme performansı	79
Çizelge 4.3. Jaccard ve Dice benzerlik indeksleri.....	80
Çizelge 4.4. Eğitim ve test işlemlerinde kullanılan IBSR veri kümeleri	81
Çizelge 4.5. SOM ağıının eğitiminde kullanılan parametreler.....	85
Çizelge 4.6. Jaccard, Dice, duyarlılık ve belirlilik benzerlik indeksleri	87
Çizelge 4.7. 20 beyin taraması için elle yönlendirilmiş bölütlemeler ile çeşitli metotlar arasındaki ortalama örtüşme için Jaccard benzerlik indeksi değerleri.....	87
Çizelge 4.8. Test veri kümelerinde farklı yöntemlerden beyaz ve gri cevher için elde edilen bölütleme sonuçları.....	88
Çizelge 4.9. Bölütleme sonuçları	109
Çizelge 4.10. Karışıklık matrisi	111

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. BrainWeb veritabanı benzetim görüntüleri (a) T1-ağırlıklı MR görüntüsü, (b) T2-ağırlıklı MR görüntüsü, (c) PD-ağırlıklı MR görüntüsü, (d) Kesin referans görüntüsü.....	16
Şekil 2.2. IBSR veritabanından bir beyin MR görüntüsü	17
Şekil 2.3. 1_24 numaralı hastaya ait (a) T1-ağırlıklı beyin MR görüntüsü (b) sadece beyin bölgesini gösteren görüntü ve (c) elle bölütlenmiş görüntü.....	19
Şekil 2.4. 12_3 numaralı hastaya ait (a) T1-ağırlıklı beyin MR görüntüsü (b) sadece beyin bölgesini gösteren görüntü ve (c) elle bölütlenmiş görüntü.....	19
Şekil 2.5. A1 numaralı hastaya ait (a) T1-ağırlıklı, (b) T2-ağırlıklı ve (c) FLAIR MR görüntüleri.....	21
Şekil 2.6. A9 numaralı hastaya ait (a) T1-ağırlıklı, (b) T2-ağırlıklı ve (c) FLAIR MR görüntüleri.....	21
Şekil 2.7. MR görüntüleme sisteminin (a) fotoğrafı ve (b) diyagramı	23
Şekil 2.8. (a) Tek yankılı T1-ağırlıklı ve (b) Çift yankılı T2-ağırlıklı MR darbe dizileri	25
Şekil 2.9. 2 boyutlu dönüşüm örnekleri	28
Şekil 2.10. İki boyutlu HDD	35
Şekil 2.11. $f(x, y)$ görüntüsünün iki ölçekli HDD ayrıştırması sonucu elde edilen W_{φ} , W_{ψ}^H , W_{ψ}^V ve W_{ψ}^D alt görüntüleri.....	36
Şekil 2.12. Sentez filtre bankası.....	36
Şekil 2.13. Üç ölçekli bir HDD (a) orijinal görüntü, (b) 1 seviyeli, (c) 2 seviyeli, (d) 3 seviyeli ayrıştırma sonucu elde edilen yaklaşım, yatay, dikey ve köşegen alt görüntüler.....	37
Şekil 2.14. Üç ölçekli bir HDD filtre bankası.....	38
Şekil 2.15. Üç ölçekli bir dalgacık paket analizinin filtre bankası.....	39

Şekil	Sayfa
Şekil 2.16. Üç ölçekli HDD analiz bankasının frekans bölme karakteristiği.....	40
Şekil 2.17. Üç ölçekli bir dalgacık paket analizinin frekans bölme karakteristiği.....	40
Şekil 2.18. Üç ölçekli bir dalgacık paket analiz ağacı	41
Şekil 2.19. Uzaysal filtreleme işlemi. Büyütülmüş görüntü 3×3 büyüklüğündeki bir pencereyi ve görüntüde buna karşılık gelen komşulukları göstermektedir.....	43
Şekil 2.20. SOM ağının yapısı	46
Şekil 2.21. Bir nöronun yapısal komşuluğu ($c1 < c2 < c3$).....	47
Şekil 2.22. BMU ve komşularının ağırlık vektörlerinin güncellenmesi	48
Şekil 2.23. U-matris yapısı.....	50
Şekil 2.24. (a) Kabarcık (b) Gauss komşuluk fonksiyonu	51
Şekil 2.25. İki boyutlu desen uzayını (ζ_1, ζ_2) koordinat sistemindeki noktalar olarak gösterilen, referans vektörler etrafındaki bölgeler şeklinde parçalara ayıran bir Voronoi gösterimi. Aynı bölümdeki tüm vektörler (ζ_1, ζ_2) en yakın komşuları olarak aynı referans vektörünü gösterirler. ..	53
Şekil 2.26. Sonuçların kesin referans ile örtüşme durumu.....	57
Şekil 3.1. Beyin bölgesini bulan algoritmanın işlem adımları	61
Şekil 3.2. (a) Bozuk karakterler içeren düşük çözünürlükteki örnek metin ve büyütülmüş görünüm, (b) yapısal eleman, (c) (a)'nın (b) ile genişletilmesi hali ve büyütülmüş görünüm.	63
Şekil 3.3. (a) Orijinal görüntü, (b) 10 yarıçapındaki bir disk ile aşındırma, (c) 5 yarıçapındaki bir disk ile aşındırma, (d) 20 yarıçapındaki bir disk ile aşındırma	64

Şekil	Sayfa
Şekil 3.4. A6 numaralı hasta için (a) eksik bölütlenmiş, (b) doğru bölütlenmiş beyin bölgesi	66
Şekil 3.5. B7 numaralı hasta için (a) aşırı bölütlenmiş, (b) doğru bölütlenmiş beyin bölgesi	67
Şekil 3.6. IBSR veritabanı (205_3) için bölütleme sonuçları (a) orijinal görüntü, (b) elle bölütlenmiş kesin referans görüntüsü, (c) BrainVisa sonucu, (d) BET sonucu, (e) FreeSurfer sonucu ve (f) geliştirilen algoritma ile elde edilen sonuç	69
Şekil 3.7. SOM ağını kümelemek ve etiketlemek için geliştirilen algoritmanın işlem adımları.....	71
Şekil 4.1. (a) T1-ağırlıklı, (b) T2-ağırlıklı ve (c) PD MR görüntüleri ile (d), (e) ve (f) bu görüntülerin sadece beyin bölgesini içeren halleri.....	74
Şekil 4.2. Daubechies 2 (db2) dalgacığı.....	75
Şekil 4.3. Daubechies 4 (db4) dalgacığı.....	76
Şekil 4.4. (a) Başlangıç dalgacık paketi analiz ağacı, (b) T1-ağırlıklı, (c) T2-ağırlıklı ve (d) PD MR görüntüleri için en iyi alt ağaç görüntüsü ..	78
Şekil 4.5. (a) Kafatası çıkarılmış kesin referans görüntüsü, (b) (a)'nın renklendirilmiş hali, (c) Bölütlenmiş görüntü, (d) (c)'nin renklendirilmiş hali.....	80
Şekil 4.6. 1_24 eğitim veri kümesinden 30. dilime ait (a) ham, (b) sadece beyin bölgesini gösteren ve (c) elle bölütlenmiş görüntüler	82
Şekil 4.7. 4_8 eğitim veri kümesinden 30. dilime ait (a) ham, (b) sadece beyin bölgesini gösteren ve (c) elle bölütlenmiş görüntüler	82
Şekil 4.8. 2_4 test veri kümesinden 30. dilime ait (a) ham, (b) sadece beyin bölgesini gösteren ve (c) elle bölütlenmiş görüntüler	82
Şekil 4.9. (a) 1_24 numaralı hastanın MR görüntüsü, (b) 2_4 numaralı hastanın MR görüntüsü, (c) (a)'daki görüntüye ve (d) (b)'deki görüntüye eşyönsüz yayılım filtresi uygulandıktan sonra elde edilen görüntüler	83
Şekil 4.10. Farklı yöntemlerin bölütleme işleminde gösterdiği performans	89

Şekil	Sayfa
Şekil 4.11. Test veri kümesindeki hastalar için gri cevherin bölütlenmesinde farklı yöntemlerden elde edilen sonuçlar.....	89
Şekil 4.12. 11_3 numaralı test verisindeki (a) 30. dilim görüntüsü, (b) görüntünün elle bölütlenmiş hali, (c) Sistemden elde edilen bölütleme sonucu	90
Şekil 4.13. 111_2 numaralı test verisindeki (a) 30. dilim görüntüsü, (b) görüntünün elle bölütlenmiş hali, (c) Sistemden elde edilen bölütleme sonucu	90
Şekil 4.14. 191_3 numaralı test verisindeki (a) 30. dilim görüntüsü, (b) görüntünün elle bölütlenmiş hali, (c) Sistemden elde edilen bölütleme sonucu	91
Şekil 4.15. 205_3 numaralı test verisindeki (a) 30. dilim görüntüsü, (b) görüntünün elle bölütlenmiş hali, (c) Sistemden elde edilen bölütleme sonucu	91
Şekil 4.16. A1 numaralı hasta için (a) T1-ağırlıklı, (b) T2-ağırlıklı ve (c) FLAIR MR üzerinde el ile işaretlenmiş doku alanları.....	93
Şekil 4.17. A2 numaralı hasta için (a) T1-ağırlıklı, (b) T2-ağırlıklı ve (c) FLAIR MR üzerinde el ile işaretlenmiş doku alanları.....	94
Şekil 4.18. A3 numaralı hasta için (a) T1-ağırlıklı, (b) T2-ağırlıklı ve (c) FLAIR MR üzerinde el ile işaretlenmiş doku alanları.....	95
Şekil 4.19. Beyin MR görüntülerini bölütleyen sistemin akış diyagramı	96
Şekil 4.20. A2 hastasına ait (a) orijinal ve (b) çakıştırılmış MR görüntüleri, soldan sağa T1-ağırlıklı, T2-ağırlıklı ve FLAIR	98
Şekil 4.21. A9 hastasına ait (a) orijinal ve (b) çakıştırılmış MR görüntüleri, soldan sağa T1-ağırlıklı, T2-ağırlıklı ve FLAIR	98
Şekil 4.22. B2 hastasına ait (a) orijinal ve (b) çakıştırılmış MR görüntüleri, soldan sağa T1-ağırlıklı, T2-ağırlıklı ve FLAIR	99
Şekil 4.23. B9 hastasına ait (a) orijinal ve (b) çakıştırılmış MR görüntüleri, soldan sağa T1-ağırlıklı, T2-ağırlıklı ve FLAIR	99
Şekil 4.24. A10 hastasına ait (a) orijinal görüntüler, (b) beyin bölgesini gösteren MR görüntüleri ve (c) filtreleme sonuçları, soldan sağa T1-ağırlıklı, T2-ağırlıklı ve FLAIR	101

Şekil	Sayfa
Şekil 4.25. B3 hastasına ait (a) orijinal görüntüler, (b) beyin bölgesini gösteren MR görüntüleri ve (c) filtreleme sonuçları, soldan sağa T1-ağırlıklı, T2-ağırlıklı ve FLAIR	102
Şekil 4.26. B6 hastasına ait (a) orijinal görüntüler, (b) beyin bölgesini gösteren MR görüntüleri ve (c) filtreleme sonuçları, soldan sağa T1-ağırlıklı, T2-ağırlıklı ve FLAIR	103
Şekil 4.27. B7 hastasına ait (a) orijinal görüntüler, (b) beyin bölgesini gösteren MR görüntüleri ve (c) filtreleme sonuçları, soldan sağa T1-ağırlıklı, T2-ağırlıklı ve FLAIR	104
Şekil 4.28. A10 numaralı hastanın (a) T1-ağırlıklı, (b) T2-ağırlıklı ve (c) FLAIR MR görüntülerinden elde edilen DDD katsayıları, soldan sağa yaklaşım, yatay, dikey ve köşegen katsayıları	105
Şekil 4.29. A10 hastasına ait (a) T1-ağırlıklı, (b) T2-ağırlıklı ve (c) FLAIR MR görüntülerinden elde edilen özellik görüntüleri, soldan sağa yaklaşım katsayıları, entropi, enerji ve standart sapma	107
Şekil 4.30. Eğitim hastaları bölütleme performansı	111
Şekil 4.31. Test hastaları bölütleme performansı	112
Şekil 4.32. (a) Renk kodu, (b) temel bileşen izdüşümü	113
Şekil 4.33. A2 numaralı hasta için (a) el ile işaretlenmiş T1-ağırlıklı MR, (b) gri düzey ve (c) renkli bölütleme sonucu	114
Şekil 4.34. A7 numaralı hasta için (a) el ile işaretlenmiş T1-ağırlıklı MR, (b) gri düzey ve (c) renkli bölütleme sonucu	115
Şekil 4.35. A9 numaralı hasta için (a) el ile işaretlenmiş T1-ağırlıklı MR, (b) gri düzey ve (c) renkli bölütleme sonucu	116
Şekil 4.36. A10 numaralı hasta için (a) el ile işaretlenmiş T1-ağırlıklı MR, (b) gri düzey ve (c) renkli bölütleme sonucu	117
Şekil 4.37. B2 numaralı hasta için (a) el ile işaretlenmiş T1-ağırlıklı MR, (b) gri düzey ve (c) renkli bölütleme sonucu	118
Şekil 4.38. B3 numaralı hasta için (a) el ile işaretlenmiş T1-ağırlıklı MR, (b) gri düzey ve (c) renkli bölütleme sonucu	119

Şekil	Sayfa
Şekil 4.39. B7 numaralı hasta için (a) el ile işaretlenmiş T1-ağırlıklı MR, (b) gri düzey ve (c) renkli bölütleme sonucu	120
Şekil 4.40. B9 numaralı hasta için (a) el ile işaretlenmiş T1-ağırlıklı MR, (b) gri düzey ve (c) renkli bölütleme sonucu	121
Şekil 4.41. Grafik ara yüz açılış ekranı	122
Şekil 4.42. Görüntü seçme ekranı	123
Şekil 4.43. İşaretli alanları incele ekranı	124
Şekil 4.44. T1 MR üzerinde işaretli alanlarının gösterilmesi.....	125
Şekil 4.45. Önışlemler ekranı.....	125
Şekil 4.46. Görüntüleri hizala ekranı	126
Şekil 4.47. Örnek görüntü hizalama ekranı.....	127
Şekil 4.48. Kafatası alanı çıkarma işleminin gerçekleştirildiği ekran.....	128
Şekil 4.49. Sadece beyin dokusu içeren MR görüntülerini gösteren ekran	128
Şekil 4.50. Filtreleme işlemi ekranı	129
Şekil 4.51. Dalgacık dönüşümü uygulama ekranı.....	130
Şekil 4.52. Özellik çıkartma ekranı	131
Şekil 4.53. Bölütleme ekranı	132
Şekil 4.54. Bölütleme sonucunun renkli olarak görüntülenmesi	132
Şekil 4.55. Bölütleme performansı değerlendirme ekranı	133
Şekil 4.56. Bölütlenmiş dokular.....	134

Şekil	Sayfa
Şekil 4.57. SOM ağını inceleme ekranı	135
Şekil 4.58. (a) U-Matrix isabet histogramı, (b) SOM ağındaki birimlerin etiketleri.....	136
Şekil 4.59. Benzerlik renklendirme.....	137

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
F	Yalpalayarak dönme frekansı
B_0	Manyetik alan gücü
γ	Manyetik moment
T	Tesla
G	Gauss
$\phi(x, y)$	Ölçekleme fonksiyonu
$\psi^H(x, y)$	Yatay dalgacık fonksiyonu
$\psi^V(x, y)$	Dikey dalgacık fonksiyonu
$\psi^D(x, y)$	Köşegen dalgacık fonksiyonu
ψ^H	Yatay kenarlar
ψ^V	Dikey kenarlar
ψ^D	Köşegen kenarlar
W_ϕ	Yaklaşım katsayıları
W_ψ^H	Yatay detay katsayıları
W_ψ^V	Dikey detay katsayıları
W_ψ^D	Köşegen detay katsayıları
$h_\phi(-n)$	Ölçekleme vektörü
$h_\psi(-n)$	Detay vektörü
O	Hesapsal karmaşıklık
A	Yaklaşım filtrelemesi
D	Detay filtrelemesi
$\uparrow 2$	Üst örnekleme

$\downarrow 2$	Alt örnekleme
$\lceil \cdot \rceil_m$	m ile üst örnekleme
$\alpha(t)$	Zamanla değişen öğrenme oranı
$N_c(n)$	Zamanla değişen komşuluk kümesi
$\sigma(t)$	Zamanla değişen komşuluk yarıçapı
ε	Görelî öğrenme parametresi

Kısaltmalar**Açıklama**

MR	Manyetik Rezonans
PD	Proton Density (Proton yoğunluk)
FLAIR	Fluid Attenuated Inversion Recovery
BOS	Beyin-Omurilik Sıvısı
YSA	Yapay Sinir Ağları
SOM	Self-Organizing Maps (Özörgütlemeli harita)
VQ	Vector Quantization (Vektör nicemleme)
LVQ	Learning Vector Quantization (Öğrenmeli vektör nicemleme)
ADD	Ayrık Dalgacık Dönüşümü
DDD	Durağan Dalgacık Dönüşümü
HDD	Hızlı Dalgacık Dönüşümü
ADC	Apparent Diffusion Coefficient
BMU	Best Matching Unit (En iyi uyan birim)
IBSR	The Internet Brain Segmentation Repository
FLASH	Fast Low Angle SHot
RF	Radyo Frekans

TE	Echo Time (Yankı zamanı)
DP	Doğru Pozitif
YN	Yanlış Negatif
YP	Yanlış Pozitif
DN	Doğru Negatif
NetCDF	Network Common Data Form
MINC	Medical Image NetCDF
EMMA	Extensible Matlab Medical Image Analysis
db	Daubechies
MAP	Maksimum Aposteriori Probability (En büyük sonsal olasılık)
Ö/Y	Ödem Yok
MHz	MegaHertz

1. GİRİŞ

Manyetik Rezonans (MR), radyolojik görüntüleme yöntemlerinin hızla gelişmekte olduğu günümüzde icat edildiği 1970'lerin başından bugüne dünyada üzerinde en çok çalışma ve araştırmaların yapıldığı, hızlı bir biçimde gelişmelerin elde edildiği ve rutin radyolojik incelemeler arasında en çok ilgi çeken yöntemdir [1]. MR ağrısız ve hasta vücuduna zarar vermeden uygulanan bir görüntüleme tekniğidir. Yüksek kalitede tıbbi görüntüler elde etmek amacıyla geniş ölçüde faydalanılan bir metod olan MR kullanılarak kemiklerin ve diğer dokuların görüntüleri alınır. Özellikle beyin görüntülemesinde MR yöntemi sağladığı uzaysal çözünürlük ve kontrast çözünürlüğü ile yumuşak dokuların görüntülenmesinde çok iyi bir görünüm ortaya çıkarır. Hastaya hiçbir zarar vermeden uygulanabilen bir yöntem olması büyük avantaj sağlamaktadır. MR görüntülemenin diğer görüntüleme yöntemlerine göre avantajı farklı MR parametreleri ile dokuların çeşitli kontrastlara sahip T1-ağırlıklı, T2-ağırlıklı, PD (Proton Density) ve FLAIR (Fluid Attenuated Inversion Recovery) gibi multispektral görüntülerinin elde edilebilmesine olanak sağlamasıdır [2, 3].

Yetişkinlerde beyinde en sık görülen, kansere yol açan ve ölüm oranı yüksek tümör türü glial tümörlerdir. Bunların beyin tümörleri içinde, 20 yaşın üzerindeki kişilerde, görülme sıklığı %90'dır [4]. Bu tür tümör hücreleri kontrolsüz bir şekilde çoğalır, hızlı bir büyüme gösterip çevrelerinde bulunan sağlıklı beyin dokularının içlerine uzanarak yayılırlar ve nadiren omurilik ya da vücudun diğer organlarına yayılma eğiliminde olurlar. Ortaya çıktıkları glial hücrelerin türüne göre çeşitleri vardır [5, 6].

Görüntü bölütleme bir görüntünün bir ya da daha fazla karakteristiğe veya özelliğe göre sınıf ya da altkümü denilen bölgelerine ayrılması, aynı karakteristiğe sahip, ilgilenilen alanların arka plandan ve diğer alanlardan ayırt edilmesi, belirgin hale getirilmesidir [7]. Beyin MR görüntülerinin bölütlenmesi beyin tümörleri ve diğer nörolojik hastalıkların teşhisi amacıyla gerekli olan çok önemli ve zor bir görevdir [1, 2, 7, 8]. Buradaki amaç görüntüyü basitleştirerek analiz için daha anlamlı ve kolay bir format haline getirmektir. Beyin tümörleri şekil, boyut, yerleşim ve görüntü yoğunluğu gibi farklı karakteristiklere sahip olduğundan ve komşu oldukları diğer

beyin yapılarını da deforme edebildiklerinden bölütlenmeleri oldukça zordur. Ayrıca tümör ile birlikte ödem de mevcutsa komşu bölgelerin yoğunluk özellikleri de değişmektedir.

Pek çok klinik uygulamada beyin MR görüntülerinin gri cevher, beyaz cevher ve beyin-omurilik sıvısı (BOS) gibi doku sınıflarına bölütlenmesi klasik bir problemdir ve beyin dokularının bu üç sınıfa ayrılması yeterlidir [9-13]. Ancak beyinde tümör, lezyon, ödem gibi hastalıklı bölümler bulunan kişilerde bu bölgelerin yerlerini ve hastalıklı dokuların büyüklüklerini tespit etmek tanı koyulmasında yardımcı olmakta, uygulanacak cerrahi operasyon öncesinde doktorlara yol göstermekte ve cerrahi operasyonun planlanması aşamasında oldukça faydalı olmaktadır. Aynı zamanda radyasyon tedavisini planlamada, tedavi sonunda ödem, kangren, yaralı dokular gibi bölgeleri ayırt ederek tedavi edici yöntemlerin başarısının izlenmesinde beyin normal dokuları ile birlikte hastalıklı dokularının da bölütlenmesi gerekmektedir. Beynin bölütlenmesi, yapı bilgisini haritalama, benzetim, eğitim ve araştırma amaçlı da kullanılmaktadır. Beyindeki deri, kafatası, yağ, kas ve bağ doku gibi diğer yapılar ek bölütleme sınıfları olarak ortaya koyulabilir. Fakat bu ek sınıflar toplam beyin hacmi içinde yalnızca küçük bir bölümü oluştururlar ve klinik uygulamalarda görüntüleme yöntemleri kullanılarak ilgilenilen bölgeler değildir [14-21].

Tıbbi görüntü bölütleme genellikle el ile yapılmaktadır. İlgilenilen bölgeler bir radyoloji uzmanı ya da doktor tarafından çizilmektedir. Bu durumun dört dezavantajı vardır; (1) Çok vakit alan ve yorucu bir işlemdir. 512×512 piksel boyutunda 1 500 - 2 000 enine görüntü serisinin bölütlenmesi iyi eğitilmiş bir operatör için bile yaklaşık 2 ila 4 saat sürmektedir, (2) Elle yapılan bölütleme nesnel değildir. Farklı uzmanlar tarafından yapılan bölütlemeler birbirinden çok farklı olabilmektedir. Örneğin farklı uzmanlar tarafından gerçekleştirilen beyin tümörü bölütlemesinde yaklaşık %14-%22 arası farklılık tespit edilmiştir, (3) Aynı uzman tarafından farklı zamanlarda yapılan bölütlemeler de birbirinden farklı olabilmektedir, (4) Görüntüleme ekranının parlaklık ve zıtlık değerleri bölütleme doğruluğunu ve takip eden analizlerin güvenilirliğini etkilemektedir [22-24].

Bölütleme işleminde bilgisayarların kullanılması bu problemlerin üstesinden gelinmesine yardımcı olmaktadır. Güvenilir bilgisayarlı bölütleme algoritmaları doktorlara doku ve yapıları nicel olarak inceleme imkânı vererek beyin ile ilgili hastalıkları teşhis ve analiz etmede yardımcı olabilir. Fakat beyin dokularının bölütlenmesi iç içe ve karışık şekli, bulanık sınırları, homojen olmayan yoğunluk dağılımı, arka plan gürültüsü ve komşu beyin dokuları arasındaki düşük kontrast nedeniyle çok zor bir görevdir [25]. Glial tümörler söz konusu olduğunda nekrotik (ölü) ve aktif bölümler içeren tümörün heterojen yapısından dolayı bölütleme işlemi daha da karmaşıklaşmaktadır. Tüm glial tümörlerde nekrotik ve aktif bölümler arasında belirgin bir sınırın olmaması ile bazı tümörlerde nekrotik bölümler mevcutken diğerlerinde bulunmaması da bölütlemeyi güçleştirmektedir [14].

Beyin MR görüntülerinin bölütlenmesi için önerilmiş pek çok farklı metot vardır [9-21]. Beyin dokularını beyaz cevher, gri cevher ve BOS olarak bölütleyen çalışmaların [9-13] yanında sadece tümör [15-20] ve tümör ile ödem dokularını beraber bölütleyen çalışmalar [14, 21] da mevcuttur. Glial tümörlü hastalar üzerinde bölütleme yapan çalışmalar yalnızca tümör [16, 17, 19] ya da tümör ile birlikte yalnızca ödem dokularını bölütlemişlerdir [14].

Beyin tümörleri sağlıklı beyin dokularını tahrip ettiği, işgal ederek hasar verdiği için beyin tümörleri ile birlikte tümörün neden olduğu ödem ve sağlıklı dokuların bir arada incelenmesi gerekir. Bu tez çalışmasındaki yöntemleri kullanarak tümör ve ödem ile birlikte sağlıklı beyin dokularını bir arada bölütleyen bir çalışma literatürde bulunmamaktadır.

Bu tez çalışmasında literatürdeki çalışmalardan farklı olarak glial tümörlü hastalarla çalışılarak tümör ve ödem dokularının yanında beyaz cevher, gri cevher ve BOS dokuları da bölütlenmiştir.

MR görüntülerinin bölütlenmesinde kullanılan yöntemler uygulamaya, görüntülemenin türüne ve diğer faktörlere göre değişmekle birlikte; (1) eşikleme [8, 26-29], (2) model-tabanlı bölütleme [9, 14, 19], (3) bölge-tabanlı bölütleme [23, 30-

36], (4) kenar-tabanlı bölütleme [37, 38], (5) bilgi tabanlı bölütleme [39-42] ve (6) sınıflama tabanlı bölütleme [10, 12, 13, 20, 43-49] olarak sıralanabilir.

Eşikleme temel bölütleme tekniklerinden biridir. Eşik seçim yöntemine göre genel eşikleme ve yerel eşikleme olarak iki grupta incelenebilir. Genel eşikleme görüntü yoğunluğunun çift doruklu dağıldığını varsayar [26]. Bu problemin üstesinden gelmek için histogram tabanlı eşikleme algoritmaları önerilmiştir [27]. Entropi tabanlı eşikleme algoritmaları eşiklenmiş görüntüdeki dağıntıyı maksimize etmeye çalışır [28]. Genel eşiklemeye alternatif olarak görüntüyü pek çok alt görüntüye bölerek her alt görüntü için bir eşik seçilmesi şeklinde çalışan yerel eşikleme gösterilebilir [29]. Eşikleme hızlıdır fakat görüntüyü çift doruklu varsayarak yalnızca iki farklı sınıf oluşturabilir ve bölütlenmiş bölgeler orijinal görüntüdeki nesnelere karşılık gelmeyebilir. Multispektral görüntülere uygulanamaz ve görüntünün uzaysal özelliklerini dikkate almaz. Bu durum eşikleme yöntemini MR görüntülerinde sıklıkla meydana gelen gürültü ve görüntü yoğunluğundaki homojen olmayan dağılımlara karşı hassas yapmaktadır. Ayrıca beyin görüntülerindeki doku yoğunluklarının dağılımı çok karmaşık olduğundan farklı doku türlerini birbirinden ayırt edebilecek eşik değerinin belirlenmesinde zorluklarla karşılaşılır. Bu nedenle tıbbi görüntü bölütleme uygulamaları için klasik eşikleme metodunun yerel yoğunluk ve bağlantıya dayalı bilgileri birleştiren varyasyonları önerilmektedir [8, 26-29]. Tüm bu dezavantajları nedeniyle bu çalışmada eşikleme yöntemi kullanılmamıştır.

Model tabanlı yöntemler beyin MR görüntülerinin bölütlenmesinde sıklıkla kullanılmaktadır [9, 14, 19]. Bu yöntemler anatomik bir şablon (beyin modeli) ve bir vokselin (3 boyutlu piksel) belirli bir beyin yapısına ait olma olasılığının uzaysal dağılımı ile ilgili önsel bilgiden faydalanmaktadır. Model tabanlı yaklaşım güçlü bir yöntem olmasına rağmen çözümler eğitim verisinden öğrenilen istatistiksel dağılımlardan elde edilmektedir. Bu istatistiksel tahminleri elde eden algoritmalar çok yavaştır ve model seçimi zordur. Model tabanlı yöntemlerin sayılan dezavantajları bu çalışmada kullanılmamalarına neden olmuştur.

Bölge tabanlı bölütlemelerde kullanılan yöntemler; bölge büyütme [23, 32], böl ve birleştir [30] ve watershed (havza) algoritmalarıdır [35]. Histogram tabanlı bölge bölütlemenin temel sakıncası histogramın uzaysal bir bilgi sağlamamasıdır. Bölge büyütme algoritmasının en önemli dezavantajı bölütlenecek her bölge için bir başlangıç noktasına ihtiyaç duyması ve bu başlangıç noktalarını belirlemek için el ile etkileşim gerektirmesidir. Ayrıca bölge büyütme yöntemi gürültüye karşı hassas olduğundan delikli ya da birbiriyle bağlantısı olmayan bölgeler ortaya çıkabilmektedir. Böl ve birleştir, bölge büyütme ile ilişkili bir algoritmadır. Bir başlangıç noktasına gereksinim duymamakla birlikte benzer dezavantajlara sahiptir [8]. Havza dönüşümü matematiksel morfolojinin sağladığı en güçlü bölütleme araçlarından oluşmaktadır. Fakat havza dönüşümü algoritmasının iki sakıncası vardır. İlk olarak klasik havza dönüşümü algoritması gri düzey görüntülerde aşırı bölütlemeye neden olmaktadır. İkincisi, özellikle gri cevher ve beyaz cevher ya da beyin omurilik sıvısı ve gri cevher geçiş bölgelerinde tamamen bölünmemiş bazı bölgeler vardır [36]. Bölge tabanlı yöntemler bu dezavantajları nedeniyle tercih edilmemiştir.

Kenar tabanlı metotlar, geleneksel Sobel ve Laplace gibi kenar bulucu algoritmalar ile çalışırlar [38]. Kenar tespiti, bölgeleri arasında belirgin kontrast farkı bulunan görüntüler üzerinde iyi sonuçlar verir. Fakat düşük kontrastlı bölgelerde kenar tespiti sınırlıdır. Ayrıca ilgilenilen bölgelerin tespit edilen kenarları arasındaki ilişkiyi bulmak zordur [37]. Bu nedenle kenar tabanlı yöntemler bu çalışmada kullanılmamıştır.

Bilgi tabanlı uzman sistemler görüntü bölütlemelerde kullanılan bir başka yöntemdir [40, 42]. Bilgi tabanı hazırlanırken en önemli işlem, uzman bilgisinin ifade edilmesini sağlayacak olan kural tabanının hazırlanmasıdır. Kural tabanı içinde görüntünün bölütlenmesi için gereken bilgiler kurallarla ifade edilmektedir. Bu sistemler, kurallar ve sistemin oluşturulabilmesi ve sürdürülebilmesi için bilgi mühendisliği ve alan uzmanları gerektirir. Beyin MR görüntülerinin karmaşık yapıları gereği, kurallar kullanarak etkin bir biçimde tanımlanmaları ve

bölütlenmeleri zordur. Bu özelliklerinden dolayı bilgi tabanlı uzman sistemler ile çalışılmamıştır.

Sınıflama tabanlı yöntemler örüntü tanıma teknikleri olarak değerlendirilir. Görüntüden elde edilen ve etiketleri bilinen veri kullanılarak oluşturulan bir özellik uzayını ayırtmaya çalışırlar. Sınıflayıcılar danışmanlı metotlardır. Yeni veriyi otomatik olarak bölütlemek için el ile bölütlenmiş eğitim verisini kullanırlar [8]. Parlaklık benzerliği, çevresel enerji ve eğrisel sürekliliğe göre inşa edilebilirler. Sınıflama tabanlı yöntemler; YSA [43, 50-54], bulanık kümeleme yöntemleri olan k-en yakın komşu [12, 20, 48] ve bulanık c-ortalamlar [55-57] ile destek vektör makineleri [49] olarak sayılabilir. Üyelik fonksiyonlarının sezgisel şekli bulanık c-ortalamlar yönteminin kullanımını sınırlar. Bu yöntem tek başına verimli değildir çünkü komşu piksellerin birbirleriyle olan güçlü ilişkileri ile ilgilenmekte başarısızdır. Sasikala ve Kumaravel beyin MR görüntülerindeki sağlıklı beyin dokusu ile iyi huylu ve habis beyin tümörlerini birbirinden ayırt etmek üzere bulanık c-ortalamlar yöntemini kullanmışlardır [58]. Dalgacık dönüşümü katsayılarından eş oluşum matrislerini kullanarak çıkardıkları istatistiksel özelliklerin en iyi alt kümesini genetik algoritma ile seçmişler ve görüntüleri otomatik olarak bölütlemek için bulanık c-ortalamlar algoritmasında giriş olarak kullanmışlardır [58]. K-en yakın komşu sınıflandırıcı istatistiksel veri yapısı hakkında hiçbir temel varsayım yapmadığından parametrik olmayan bir sınıflandırıcı olarak kabul edilir [20]. Vrooman ve arkadaşları yaptıkları çalışmada beyaz cevher, gri cevher ve BOS dokularını bölütlemek için k-en yakın komşu ve beyin atlasını birleştirerek sınıflayıcı sistemin eğitiminde kullanılacak girdi örneklerini otomatik olarak seçmişlerdir [12]. Khotanlou yaptığı doktora çalışmasında bölütlemenin başlangıç ve ayrıntılandırma aşamalarında rehberlik etmesi için değiştirilmiş olasılıksal bulanık c-ortalamlar ile uzaysal ilişkilerin füzyonunu kullanan bir bölütleme metodu önermiştir [20]. Önerilen metot ardışıldır ve bölütlenmek istenen her bir yapı için kullanıcının belirleyeceği bir sırada tekrar edilmesi gerekmektedir. Ayrıca bu yöntemin kontrastsız görüntülerdeki tümörleri bölütleme performansı düşüktür.

MR görüntülerinin doğrusal olmayan karakteri klasik istatistiksel yöntemlerin bölütleme işlemi için kullanılmasını özellikle uygunsuz kılar. Klasik istatistiksel örüntü tanıma tekniklerine kıyasla sinir ağlarının başlıca avantajı eğitim veri kümesi seçimine karşı olan görelî duyarlılıklarıdır. Bu özelliğın tek bir dilim ve çoklu dilim sınıflandırması için önemli olduđu kanıtlanmıştır. YSA veri dağılımlarının olasılık yoğunluk fonksiyonları hakkında herhangi bir varsayıma bel bağlamadan işlem yapar [60].

YSA'lar sınıflama işlemini belirli bir kural kümesini kullanmak yerine veriden öğrenen bir metotla gerçekleştirirler ve veriye dayalı bir şekilde organize olurlar. Kendi kendilerine öğrenebilmeleri, hata toleransları ve en uygunu arama yeteneklerinden dolayı her geçen gün daha fazla ilgi çekmektedirler. YSA'lar paralel çalışan, lineer olmayan ve biyolojik sinir ağlarına benzer bir desende düzenlenmiş çok sayıda hesaplama elemanından oluşurlar. Tepkilerini buldukları ortam koşullarına göre değiştirir, deneyimlerinden öğrenir ve daha önceki örneklerden yenilerine genelleme yaparlar. YSA'lar karar ağaçları ya da kural tabanlı sistemleri kullanmanın zor olduđu beyin dokusu bölütleme gibi zor, çok değışkenli ve doğrusal olmayan alanlarda iyi performans sergilerler [45, 59]. Tüm bu olumlu özelliklerinden dolayı beyin MR görüntülerinin bölütlenmesi işleminde YSA kullanılmıştır.

Özörgütlemeli harita (Self Organizing Maps-SOM) ağları yarışmacı öğrenme algoritmasını kullanan danışmansız bir YSA türüdür. Sinir ağları alanındaki en popüler ağlardan biridir. SOM ağlarının diğere YSA türlerine göre otomatik olarak benzerlik diyagramları oluşturabilme gibi avantajları vardır [49, 59-61]. SOM ağlarının, yüksek boyutlu girdileri bir ya da iki boyutlu, nöronlardan oluşan ayrık bir kafes üzerine haritalama özelliğı vardır. Girdi verisini Öklid uzaklığı gibi benzerlik ölçütlerine göre çeşitli kalıplar biçiminde organize eder. SOM ağı girdi verisinin hem dağılımını hem de topolojisini öğrenir. Diğere bir deyişle, ağ girişindeki topolojik ilişkileri korur ve komşu girdileri komşu nöronlara haritalar. SOM ağları danışmansız öğrenme işlemi tamamlandıktan sonra, genellikle bir vektör nicemleme metodu olan öğrenmeli vektör nicemleme (Learning Vector Quantization-LVQ) kullanılarak ağdaki nöronların en iyi yerleşimi bulmak için kalibre edilirler [61].

SOM ağını kullanan çalışmaların eğitim işleminin ardından ağın çıkışını kümelemesi gerekir. Çünkü SOM ağının çıkışında bölütlenmek istenen doku türünden daha fazla sayıda çıkış nöronu vardır. Benzer çıkış nöronlarını kümelemek için genellikle ek bir YSA kullanılır. Bu YSA'nın girişinde SOM ağının çıkışındaki nöronların ağırlık vektörleri giriş olarak kullanılmaktadır [10, 11, 16].

Beyin MR görüntülerini bölütlemek için SOM ağlarını kullanan pek çok çalışma yapılmıştır [10, 11, 13, 16, 43, 50-52, 54, 62, 63]. Örneğin Alirezaie ve arkadaşları SOM ağları ile sağlıklı kişilere ait T1-ağırlıklı, T2-ağırlıklı ve PD beyin MR görüntülerini beyaz cevher, gri cevher ve BOS şeklinde bölütlemişlerdir [13]. Öncelikle kafatası içinden beyni gösteren bölgeyi çıkarmışlar ve multispektral veri kümesini ağda giriş olarak kullanmışlardır. Elde ettikleri sonuçları görsel olarak değerlendirmişlerdir [13]. Zizzari ve arkadaşları beyin MR görüntülerinden tümörü tespit edebilmek için gri düzey eş oluşum matrisleri kullanarak görüntüden desen özellikleri çıkarmışlar ve bu özellikleri SOM ağında giriş olarak kullanmışlardır [62]. Ahmed ve Farag yaptıkları çalışmada SOM ağında giriş olarak görüntünün farklı ölçeklerde yumuşatılmış tekrarlarını kullanmışlar ve 3-boyutlu MR görüntülerini bölütlemişlerdir [63]. Reddick ve arkadaşları beyin MR görüntülerini bölütlemek için SOM ağı ve SOM ağının çıkışını sınıflandırmak için çok katmanlı geri yayımlı YSA kullanmışlardır [10]. Çalışmalarında T1-ağırlıklı, T2-ağırlıklı ve PD MR görüntülerini kullanmışlar ve görüntüleri sağlıklı beyin dokuları olan beyaz cevher, gri cevher ve BOS olarak bölütlemişlerdir. Toplam 14 kişilik veri kümesiyle gerçekleştirdikleri çalışmalarında yedi kişiye ait etiketli görüntüleri eğitim amacıyla kullanırken geri kalan yedi kişinin görüntülerini ikinci YSA'yı test etmek için kullanmışlardır. Sınıflayıcı ağdaki her girdi vektörü, ilişkili olduğu ve beyin dokusuna ya da arka plana karşılık gelen bir elle sınıflandırma değerine sahiptir [10]. Song ve arkadaşları SOM ağı ile olasılıksal ağırlıklı YSA'yı birleştirerek bölütleme gerçekleştirmişlerdir [11]. Uyguladıkları metotta SOM ağını kullanarak T1-ağırlıklı ve T2-ağırlıklı MR görüntülerini aşırı bölütlemişlerdir. Farklı hedef sınıfları için her referans vektörünün kısmi katkılarını tahmin etmiş ve Bayes teoremi ile nihai hedef sınıfların her birine ait referans vektörlerinin olasılıklarını hesaplamak için uzman

tarafından seçilen eğitim setlerini kullanmışlardır. Kullandıkları bu parametrik yaklaşım dokuların bir olasılık yoğunluk fonksiyonu olduğunu varsaydığı için sistemin doğruluk oranı düşüktür ve gerçek veri dağılımları ile uyuşmamaktadır [11]. Iftekharuddin ve arkadaşları SOM ağı ile kümelemenin ardından ileri beslemeli YSA ile otomatik Bayes düzenleme yöntemlerini kullanmışlardır [16].

Multispektral görüntü analizi ilgilenilen nesnenin analizinde farklı görüntüleme teknikleri kullanılarak elde edilmiş birden fazla görüntünün kullanılmasıdır. Beynin multispektral analizi için T1-ağırlıklı, T2-ağırlıklı ve FLAIR MR görüntüleri gibi aynı yapıyı gösteren çeşitli görüntülere ihtiyaç vardır. Multispektral görüntü bölütleme, veri kümesindeki her pikselin sınıflandırılmasını ve bu şekilde yapı ve doku sınıfının hacmi hakkında bilgi elde etmeyi amaçlamaktadır. Bu işlemin yapılabilmesi için veri kümesini oluşturan görüntülerin anatomik olarak aynı koordinat sisteminde bulunacak şekilde çakıştırılmaları gerekmektedir. Beyin MR görüntüleri için bu işlem veri elde etme sırasında kişinin kafa pozisyonu sabitleştirerek ve bu sabit alanın görünümünde farklı MR dizilerini uygulayarak başarılabılır. Fakat uygulamada, hareketten kaynaklanan olguların önüne geçilememektedir. Bu durum, görüntü çakıştırma tekniklerinin uygulanmasını gerektirmektedir [64].

Düşük sinyal-gürültü ya da kontrast-gürültü oranları, kullanılan bölütleme yöntemi ne olursa olsun doğruluk oranını düşürmektedir [65]. Bu problemin üstesinden gelebilmek için görüntülere genellikle alçak geçiren filtreleme ya da komşuluk ortalaması gibi geleneksel uzaysal olarak değişmeyen filtreleme teknikleri uygulanmaktadır. Geleneksel filtreleme metotlarının temel sakıncası nesne sınırları ve önemli özellikleri bulanıklaştırmaları ile görüntüdeki yapısal ince detayları, özellikle küçük lezyonları bastırmalarıdır [66]. Uzaysal olarak değişen filtreleme teknikleri, bu kısıtlamanın üstesinden yerel özelliklere bağlı stratejiler kullanarak gelmeyi amaçlamaktadır. Uyarlamalı katsayılarla çalışan özyinelemeli alçak geçiren filtreleme, doğrusal en küçük kareler hata filtreleme, yerel şekil uyarlamalı şablon filtreleme ve eşyönsüz yayılım filtreleme uzaysal olarak değişen filtreleme yöntemlerindedir.

Gerig ve arkadaşları, MR görüntülerindeki rastgele gürültüyü ortadan kaldırmak için Perona ve Malik [67] tarafından önerilen doğrusal olmayan eşyönsüz yayılım filtresi ile geniş bir yelpazedeki diğer filtreleri karşılaştırmışlardır [65]. Çalışmalarında eşyönsüz yayılım filtresinin sinyal-gürültü oranını geliştirdiğini, homojen bölgeleri bulanıklaştırdığını ve nesne sınırlarını keskinleştirdiğini göstermişlerdir. Bu filtre aynı zamanda gürültüyü ve kısmi hacim etkilerini azaltmaktadır. Dolayısıyla yanlış sınıflandırılmış eğitim noktalarının sebep olduğu ve sonraki işlem adımlarını etkileyen operatöre bağlı hatalar da azalmaktadır [66]. Eşyönsüz yayılım filtresi, MR tarayıcısının manyetik alanındaki değişimler nedeniyle ortaya çıkan etki alanı ya da tekbiçimsizlik olarak adlandırılan homojensizlikleri de düzeltmektedir. Homojensizlik görüntünün uzaysal olarak yavaşça değişen bir etki değeri ile çarpılmasıdır. Bu durum görüntülerin çakıştırılması ve bölütlenmesi gibi görevler için problemlere yol açmaktadır [65-67].

Görüntülerin bölütlenmesi işleminin doğru ve güvenilir bir şekilde başarılabilmesi için bölütleme işleminde giriş olarak kullanılacak ve bölütlenecek dokuları en iyi şekilde temsil eden özelliklerin seçilmesi büyük önem arz etmektedir. Görüntü bölütlemeye kullanılan özellikler genellikle yoğunluk, desen, şekil vb.dir [1, 2, 7]. Görüntüde bulunan doku özelliklerini çıkarmak için kullanılacak yöntemler; (1) ortalama, varyans gibi birinci dereceden istatistikler [2], (2) eş oluşum matrisleri [68], (3) momentler [69], (4) lineer ölçek uzayında hesaplanan uzaysal türevler gibi ikinci dereceden istatistikler [70] ve (5) dalgacık dönüşümü [52, 71] olarak sayılabilir. Desen analizinde kullanılan geleneksel istatistiksel yaklaşımlar, görelilik olarak küçük komşuluklar üzerinden hesaplanan uzaysal etkileşimlerin analizleri ile sınırlıdır [72]. Bunun bir sonucu olarak mikro desenler denilen sınıfların analizi ve bölütlenmesinde iyi performans gösterirler. İnsan görmesi ile ilgili modeller hem yerel hem de genel bilgiyi koruma yeteneğine sahip dâhili uzaysal/frekans temsiliğini önermektedirler. Bu bulgular farklı ölçek ve uyumlaştırma ayarlamaları ile çeşitli dalgacıklar kullanan dalgacık dönüşümünün desen analizinde kullanılmasının temelini oluşturmaktadır [71, 73].

Çok çözünürlüklü dalgacık analizi bir görüntünün farklı uzaysal frekanslarda yerleştirilmiş alt görüntülerinin temsilini sağlamaktadır [38]. Görüntünün 2-boyutlu frekans spektrumunu bir alçak geçiren yaklaşım görüntüsü ve üç yüksek geçiren detay görüntüsüne bölmektedir. Fourier dönüşümü ile karşılaştırıldığında dalgacık dönüşümü bir sinyali çeşitli zaman penceresi ve frekans bantlarında tanımlayan bir zaman-frekans fonksiyonudur. Durağan olmayan veya yerel olarak düzensiz sinyallerin analizi için özellikle faydalıdır. Farklı ölçeklerdeki ve frekanslardaki görüntüler bir dokunun görünümü için çeşitli karakteristiklere sahip olduklarından dalgacıkların çok çözünürlüklü, çok kanallı modelleme kapasitesi doku analizi için oldukça uygundur [74].

Dalgacık dönüşümü beyin MR görüntülerinin bölütlenmesinde hem uzay hem de frekans düzleminde sağladığı iyi lokalizasyon nedeniyle sıklıkla kullanılmaktadır [16, 75]. Geleneksel ayrık dalgacık dönüşümü (ADD) aynı konuya ait hafifçe farklı hizalanmış iki görüntüden önemli ölçüde farklı katsayılar çıkaran yani öteleme ile değişen bir karakteristiğe sahiptir [76]. Durağan dalgacık dönüşümü (DDD) ADD'deki alt örnekleme işlemini kaldırarak bu problemin üstesinden gelir ve eksiksiz bir gösterim sağlar [73]. DDD ile ayrıştırılan tüm görüntüler ve orijinal görüntü aynı boyutta olduğundan DDD katsayıları ve onlardan elde edilen desen özellikleri herhangi bir izdüşümüne ihtiyaç duymadan doğrudan bölütleme işleminde kullanılabilir [77].

Dalgacık katsayıları tek başına dokuları tam olarak ifade etmekte yetersizdirler. Dokulu bilgiyi farklı frekans kanallarına bölmekte faydalı olsalar da bir pikselin etrafındaki yerel istatistiksel bilgilerden yoksundurlar. Bu nedenle genellikle dalgacık katsayılarına pencereleme ile uzaysal filtreleme işlemi uygulanmakta ve yerel istatistikler hesaplanmaktadır. Bu yolla standart sapma, enerji, entropi gibi pek çok desen özelliği elde edilebilmektedir.

Beyin görüntülerinin analizinde SOM ağlarında giriş olarak dalgacık dönüşümü ile filtrelenmiş ya da dalgacık dönüşümden elde edilen alt görüntüleri kullanan çalışmalar büyük başarı göstermiştir [49, 52, 78]. Örneğin Vijayakumar ve

arkadaşları tümör, ödem, nekroz, beyin sıvısı ve normal dokuları bölütlemek ve tümörün habislik durumunu derecelendirmek için dalgacık dönüşümü ile filtrelenmiş ADC (Apparent Diffusion Coefficient), FLAIR ve T2-ağırlıklı MR görüntülerini SOM ağında giriş olarak kullanmışlardır. Elde ettikleri sonuçları elle bölütlenmiş görüntülerle doğrulamışlardır [52]. Chaplot ve arkadaşları beyin MR görüntülerini normal ya da anormal olarak sınıflamak üzere görüntülerin dalgacık dönüşümlerinden elde edilen yaklaşım alt görüntülerini SOM ağında giriş olarak kullanmışlar ve %94 oranında sınıflama başarısı elde etmişlerdir [49]. Zhang ve arkadaşları ise yaptıkları çalışmada 2-boyutlu ayrık dalgacık dönüşümü ve SOM ağlarını kullanarak beyin oylumunu çıkarma, beyin dokularını gri cevher, beyaz cevher ve BOS olarak ayırmak için beyin MR görüntülerini bölütlemişler ve sonuçları görsel olarak değerlendirmişlerdir [78].

Beyin görüntülerinin istenilen doku türlerine otomatik olarak bölütlenmesini başarıyla gerçekleştirecek ve hastanelerde aktif olarak kullanılacak bir sistem doktorlara zaman kazandıracak, doktorların elle yaptıkları bölütleme işlemlerinde oluşabilecek öznelliğin önüne geçecek, görüntüleme ekranının parlaklık ve kontrast ayarı gibi bölütleme işlemi ve bunu takip eden analizleri etkileyecek mekanizmaları devre dışı bırakacak, daha da önemlisi hastalara yanlış veya eksik tanı koyulmasını engelleyecek ve cerrahi operasyonların planlanmasını kolaylaştıracak büyük gelişmeler sağlayacaktır.

Bu tez çalışması kapsamında klinik teşhis ve tedavi amaçları için beyin MR görüntülerini otomatik olarak bölütleyen ve etiketleyen bir yazılım sistemi geliştirilmiştir. Bu amaçla gerçek beyin görüntüleri kullanılarak oluşturulmuş beyin modeli (BrainWeb) [79-81], sağlıklı kişilere ait beyin MR görüntüleri [82] ile beyninde tümör bulunan kişilere ait hastaneden toplanan beyin MR görüntüleri üzerinde beyin dokularının bölütlenmesi işlemi gerçekleştirilmiştir.

Tümörlü hastaların görüntülerini bölütlemek için glial tümörü bulunan hastalara ait T1-ağırlıklı, T2-ağırlıklı ve FLAIR MR görüntüleri kullanılmıştır. Beyin tümörleri içinde en yaygın görülen habis tümör tipi olduğu için glial tümörlü hastalarla

çalışılmıştır. Hasta herhangi bir cerrahi operasyon geçirmeden önce elde edilen görüntüler kullanılmıştır. Geliştirilen sistem beyin MR görüntülerini gri cevher, beyaz cevher ve BOS normal beyin dokuları ile tümör ve ödem hastalıklı dokularına bölütleme yapmaktadır. Literatürde, bu tez çalışmasındaki yöntemleri kullanarak beyaz cevher, gri cevher ve BOS dokularını aynı anda tümör ve ödem ile birlikte bölütleme yapan bir çalışma bulunmamaktadır. Görüntülerdeki etki alanını ve rastgele gürültüyü ortadan kaldırmak için doğrusal olmayan eşyönsüz yayılım filtresi tüm görüntülere uygulanmıştır. Daha sonra görüntüleme işlemi sırasında sıklıkla karşılaşılan bir durum olan kafanın hareket ettirilmesi nedeniyle oluşan aksaklıkların giderilmesi için aynı hastadan elde edilen tüm görüntüler çakıştırılarak aynı koordinat sistemine hizalanmıştır. Bu çalışmada ilgilenilen bölgeler beyin dokuları olduğundan eşikleme ve morfolojik işlemlerin bir arada kullanıldığı bir yöntem ile beyin dokusu dışında kalan alanlar görüntülerden çıkartılmıştır. DDD kullanılarak görüntü alt bantlarına ayrılmış ve dalgacık katsayılarına uzaysal filtreleme metotları uygulanarak özellik vektörleri oluşturulmuştur. Bölütleme işlemi için danışmansız öğrenme algoritmasını kullanan SOM ağı eğitilmiştir. Geliştirilen yöntemde SOM ağının çıkışını kümelemek için ek bir YSA kullanılmasına gerek yoktur. El ile etiketlenmiş görüntü bölgelerini kullanan ve çıkış nöronlarının bölütlenecek doku türleri için en iyi uyan birimlerinin (BMU) isabet histogramına dayanan bir algoritma geliştirilmiştir. Beyaz cevher, gri cevher, BOS, tümör ve ödem bölgelerini gösteren alanlar hastaların her birinde ilgilenilen dilim için el ile işaretlenmiştir. El ile bölütleme sayesinde eğitim işleminde kullanılan her girdi vektörünün beyin dokularından hangisine karşılık geldiği bilinmektedir. Geliştirilen algoritma SOM ağının topolojisindeki komşuluk ilişkilerinden faydalanmaktadır. Eğitim ve etiketleme işlemlerinin ardından ağın çıkış nöronlarının en iyi konumunu ayarlamak için danışmanlı LVQ algoritması kullanılmıştır. Elde edilen sonuçlar, elle yapılan bölütleme ile sistemden elde edilen bölütleme sonuçlarının örtüşme oranlarını gösteren Dice benzerlik indeksi [83-85] ile duyarlılık ve belirlilik ölçütlerine göre değerlendirilmiştir.

Tezin ikinci bölümünde tez çalışmasında kullanılan malzeme ve yöntemler verilmiştir. Bölütleme işlemlerinde kullanılan beyin modeli, sağlıklı beyin MR

görüntüleri ve tümörlü beyin MR görüntüleri anlatılmıştır. MR görüntüleme yönteminin temel prensipleri ile görüntü bölütleme yöntemleri verilmiştir. Bölütleme öncesinde bir ön işlem olarak uygulanan görüntü çakıştırma ile yine bir ön işlem olarak gerçekleştirilen eşyönsüz yayılım filtresi bu bölümde anlatılmıştır. Görüntülerden özellik çıkarmada kullanılan dalgacık dönüşümü yöntemi ile görüntülerin bölütlenmesinde kullanılan YSA olan SOM ağırları anlatılmıştır. SOM ağı ile yapılan bölütlemeyi takiben kullanılan LVQ yöntemi ile sistemden elde edilen sonuçların değerlendirilmesinde faydalanılan performans değerlendirme ölçütleri verilmiştir. Yazılım geliştirme ortamı da yine bu bölümde anlatılmıştır.

Üçüncü bölümde bu tez çalışması kapsamında geliştirilen görüntülerde beyin bölgesinin bulunması ve SOM ağının kümelenmesi ve etiketlenmesi algoritmaları verilmiştir.

Dördüncü bölümde beyin modeli, sağlıklı beyin MR görüntüleri ve tümörlü beyin MR görüntüleri üzerinde gerçekleştirilen bölütleme işlemlerinin adımları parametreleriyle birlikte verilmiştir. Bölütleme işlemlerinin başarısı performans değerlendirme ölçütlerine göre değerlendirilerek sistemden elde edilen bölütlenmiş sonuç görüntüleri sunulmuştur. Bu bölümde ayrıca bölütleme işlem adımlarını rahat ve kolay bir şekilde, sonuçları görerek gerçekleştirebilmek üzere geliştirilen grafik ara yüz anlatılmıştır.

Beşinci bölümde ise tezle ilgili genel sonuçlar ve değerlendirme verilmiştir.

2. MALZEME ve YÖNTEM


Bu bölümde öncelikle tez çalışması kapsamında üzerinde beyin dokularının bölütlenmesi işleminin gerçekleştirildiği veri kümeleri olan beyin modeli, sağlıklı kişilere ait beyin MR görüntüleri ve beyinde tümör bulunan kişilere ait hastaneden toplanan beyin MR görüntüleri hakkında bilgiler verilmiştir. Takip eden alt başlıklarda ise bölütleme işleminde kullanılan yöntemler ve algoritmalar anlatılmıştır.

2.1. Beyin Modeli

Benzetim yöntemi ile oluşturulan MR görüntüleri tıbbi görüntü analizi algoritmalarının geliştirilmesinde, özellikle bölütleme algoritmalarında, önemli bir rol oynarlar. Görüntü analizi metotları kontrollü bir ortamda test edilmeli ve değerlendirilmelidir. Benzetim görüntüleri doğrulama için son derece yararlı araçlardır, çünkü kesin referans bilinmektedir. Mutlak bölütleme doğruluğu benzetim görüntüleri ile karşılaştırma yaparak değerlendirilebilir [86].

BrainWeb veritabanı gerçek beyin MR görüntüleri kullanılarak oluşturulmuş benzetim görüntüleri içermektedir [79-81]. Bu veritabanı farklı görüntü işleme metotlarının doğrulanmasında yüzün üzerinde, bağımsız uzman değerlendirmesinden geçmiş yayında kullanılmıştır ve son yıllarda tıbbi görüntü analizlerinin doğrulanmasında fiilen bir standart haline gelmiştir. Veritabanında bulunan benzetim görüntüleri bir kişiden elde edilmiş yüksek çözünürlüklü, düşük gürültülü 27 adet T1-ağırlıklı, 12 adet PD-ağırlıklı ve 12 adet T2-ağırlıklı MR görüntü taramalarının karşılaştırılarak birbirine göre hizalanması ve ortalamalarının alınması sonucu oluşturulmuştur. Görüntü daha sonra uzman bir nöro anatomi uzmanı tarafından bölütlenmiştir. Saf dokular içindeki noktalar belirlenmiştir. Daha sonra her vokseldeki doku içeriğini belirlemek üzere bulanık minimum uzaklık sınıflayıcısı uygulanmıştır. Bu işlemin ardından doku benzetimlerinin nihai kümesini üretmek üzere elle düzeltmeler yapılmış ve maskelemeler uygulanmıştır. Benzetim görüntülerinde beyne ait 181 dilim bulunmaktadır [80, 81, 86-89].

Şekil 2.1 BrainWeb veritabanında bulunan T1-ağırlıklı, T2-ağırlıklı ve PD MR görüntüleri ile bu görüntülerin el ile bölütlenmesi sonucu oluşturulmuş kesin referans görüntülerine birer örnek göstermektedir.




Şekil 2.1. BrainWeb veritabanı benzetim görüntüleri (a) T1-ağırlıklı MR görüntüsü, (b) T2-ağırlıklı MR görüntüsü, (c) PD-ağırlıklı MR görüntüsü, (d) Kesin referans görüntüsü

2.2. Sađlıklı Beyin MR G6r6nt6leri

Tıbbi g6r6nt6 iřleme alanı hızla b6y6mektedir. B6l6tleme, sınıflama ve řekil analizi ile ilgili pek ok yeni yaklařım geliřtirilmekte ve yayınlanmaktadır. Bu durum belirli bir analiz g6revi belirlendiđinde en uygun metodun tanınması ve seilmesinde bir problem oluřturmaktadır. Yayınlanan t6m metotları uygulamak iyi donanımlı bir g6r6nt6 iřleme laboratuvarı iin bile neredeyse imk6nsızdır. Her metodu yerel olarak uygulamak yerine g6r6nt6 verilerini ieren bir yerel havuz oluřturmak ve bu g6r6nt6lere uygulanan her t6rl6 analiz sonularının paylařılması daha faydalıdır. Bu řekilde yeni analiz algoritmaları ortak g6r6nt6ler 6zerinde test edilebilir. Elde edilen sonular aynı g6r6nt6ler 6zerinde daha 6nce uygulanmıř eřitli metotlar ve uzman yorumları ile dođrudan karřılařtırılabilir.

IBSR (The Internet Brain Segmentation Repository), sađlıklı kiřilere ait beyin MR g6r6nt6leri ve bu g6r6nt6lerin b6l6tleme sonularını ieren, t6m d6nyadaki arařtırmacıların faydalanarak katkı sađladıkları bir veritabanıdır. Bu veritabanı, beyin MR g6r6nt6s6 verilerinin yanı sıra uzmanlar tarafından elle yapılmıř b6l6tleme sonularını da sađlamaktadır. Buradaki ama b6l6tleme metotlarının deđerlendirilmesi ve geliřtirilmesini teřvik etmektir [82].



řekil 2.2. IBSR veritabanından bir beyin MR g6r6nt6s6


Şekil 2.2’de IBSR veritabanında bulunan bir beyin MR görüntüsü örneği görülmektedir. Bazı veri türlerinde elle yapılan bölütleme sonuçları da (yeşil çizgiler) görüntülerle birlikte verilmiştir. MR görüntü verileri pozisyonları standartlaştırılmış T1-ağırlıklı 3-boyutlu kafatası beyin taramalarıdır. Bölütlenmiş ya da çizilmiş dosyalar eğitilmiş bir uzmanın saatler harcayarak gerçekleştirdiği yarı otomatik bölütleme sonuçlarıdır. Elle yapılan bölütlemeler %100 kesin referans olarak değerlendirilemese de otomatik bölütleme metotlarının karşılaştırılması açısından iyi bir yoldur.

IBSR veritabanı içinden 20 sağlıklı kişiye ait sadece beyin bölgesini içeren T1-ağırlıklı MR görüntüleri ve bu görüntülerin gri cevher/beyaz cevher/diğer şeklindeki uzman bölütlemeleri kullanılmıştır. Her bir MR görüntüsü 3,1 mm kalınlığında bir beyin dilimini göstermektedir. Görüntüler 8 bitlidir.


4 erkek ve 6 kadın üzerinde 10 FLASH (Fast Low Angle SHot) taraması 1,5 T Siemens Magnetom MR System cihazı kullanılarak şu parametreler ile yapılmıştır; TR=40 ms, TE=8 ms, çevirme açısı=50°, görüntüleme alanı=30 cm, dilim kalınlığı=bitişik 3,1 mm, matris=256×256. 6 erkek ve 4 kadın üzerinde 10 3D-CAPRY taraması 1,5 T General Electric Signa MR System (Milwaukee, WI), cihazı kullanılarak şu parametreler ile yapılmıştır; TR=50 ms, TE=9 ms, çevirme açısı=50°, görüntüleme alanı=24 cm, dilim kalınlığı=bitişik 3,0 mm, matris=256×256.

Tüm MR görüntülerinin pozisyonları görüntüler elde edildikten sonra standartlaştırılmıştır. Daha sonra elle bölütleme işlemi gerçekleştirilmiştir. Pozisyonları standartlaştırılmış görüntüler eğitilmiş bir araştırmacı tarafından yarı otomatik bir yoğunluk dış hat haritalama algoritması ile sinyal yoğunluk histogramları kullanılarak bölütlenmiştir. Yoğunluk dış hat haritalama ile dış kenarlar belirlendikten sonra gri ve beyaz cevher sınırları sinyal yoğunluk histogramları ile ayrılmıştır. Bu teknik kullanılarak sınırlar verilen bir yapı ve onun komşu dokusu için çift doruklu histogramın tepe noktalarının orta noktası olarak tanımlanmıştır. Diğer nöroanatomik yapılar benzer şekilde bölütlenmiştir [90].

IBSR veritabanında bulunan orijinal T1-ağırlıklı beyin MR görüntüleri ile bu görüntülerin sadece beyin bölgesini ve elle bölütlenmiş hallerini gösteren görüntüler Şekil 2.3'te veritabanındaki 1_24 numaralı kişi ve Şekil 2.4'te 12_3 numaralı kişi için verilmiştir.



Şekil 2.3. 1_24 numaralı hastaya ait (a) T1-ağırlıklı beyin MR görüntüsü (b) sadece beyin bölgesini gösteren görüntü ve (c) elle bölütlenmiş görüntü



Şekil 2.4. 12_3 numaralı hastaya ait (a) T1-ağırlıklı beyin MR görüntüsü (b) sadece beyin bölgesini gösteren görüntü ve (c) elle bölütlenmiş görüntü

2.3. Tümörlü Beyin MR Görüntüleri

Tümörlü beyin MR görüntüleri beyninde glial tümör bulunan hastalardan elde edilmiştir. Glial tümörler beyindeki glial hücrelerde ortaya çıkmaktadır. Beyinde en sık görülen ve ölüm oranı en yüksek olan tümör türü olduğundan glial tümöre sahip hastaların görüntüleri üzerinde çalışılmıştır.

29 Mayıs Hastanesi Radyoloji Polikliniği arşivinde bulunan tüm beyin MR görüntüleri bir radyoloji uzmanı yardımıyla taranmıştır. MR taraması sırasında radyoloji uzmanları tarafından hazırlanan raporlar incelenerek rapor metninde kitle (tümör) teşhisi koyulmuş ve operasyon geçirmemiş hastalar tespit edilmiştir.


Tümörlü hastaların görüntüleri öncelikle tümörün kafa içerisinde bulunduğu yere göre intraaksiyal ve ekstraaksiyal yerleşimli biçiminde sınıflandırılmıştır. İntraaksiyal tümörler beynin yumuşak dokusu içinden çıkan tümörler iken ekstraaksiyal tümörler beyin dokusunun dışında çıkıp beyne baskı yapan tümörlerdir. Bu çalışmada beynin yumuşak dokusu içinde yer alan tümörlerle ilgilenildiğinden ekstraaksiyal tümörlü görüntüler elenmiştir.

Bu işlemin ardından intraaksiyal tümörlü veri kümesindeki hasta görüntüleri radyoloji uzmanı ile birlikte incelenerek tümör türleri tespit edilmiş ve glial tümörlü hastalar belirlenmiştir. Veri kümesinden diğer hasta görüntüleri çıkartılarak operasyon geçirmemiş 13 erkek ve 7 kadın toplam 20 hastaya ait intraaksiyal glial tümörlü görüntüler ile çalışmaya devam edilmiştir. Bu hastalarda tümör beynin yumuşak dokusu içinde değişik bölgelerde, katı bir kütle veya sıvı içeren dağınık bir formatta bulunmaktadır.


Bu tez çalışmasında kullanılan beyin MR görüntüleri 1,5 T General Electric MR tarayıcısı ile elde edilmiştir. MR taramalarındaki inceleme alanı büyüklüğü 240×240 mm'dir. Kesit kalınlığı 5,5 mm tarama ve 1,5 mm boşluk olmak üzere 7 mm'dir. Görüntülemeye kullanılan matris büyüklüğü 480×480'dir. Görüntüdeki her bir voksel 0,5×0,5×5,5 mm'lik bir alanı göstermektedir. Çalışmada MR görüntülemeye rutin olarak kaydedilen T1-ağırlıklı (TR/TE: 1860/20), T2-ağırlıklı (TR/TE:

5750/130) ve FLAIR (TR/TE: 8800/130) MR görüntüleri kullanılmıştır. Tüm görüntü türlerindeki toplam dilim sayısı 20'dir. Tüm görüntüler 16-bit derinliğinde ve 512×512 piksel boyutlarındadır.

Şekil 2.5 ve Şekil 2.6'da veri kümesinde yer alan A1 ve A9 numaralı iki hastaya ait T1-ağırlıklı, T2-ağırlıklı ve FLAIR MR görüntüleri verilmiştir.



Şekil 2.5. A1 numaralı hastaya ait (a) T1-ağırlıklı, (b) T2-ağırlıklı ve (c) FLAIR MR görüntüleri



Şekil 2.6. A9 numaralı hastaya ait (a) T1-ağırlıklı, (b) T2-ağırlıklı ve (c) FLAIR MR görüntüleri

2.4. MR Görüntüleme Yöntemi

MR görüntüleme yöntemi vücudun %75'ini oluşturan en büyük bileşen olan suya göre çalışır. Manyetik bir alan içerisinde incelenmek istenilen bölgeye radyo dalgaları gönderilir. Temel olarak çok güçlü bir mıknatıs olan MR tarayıcısı içine bir kişi konduğunda, vücudundaki protonlar ya tarayıcının güçlü manyetik alanına doğru ya da ona karşı dizilirler. Radyo dalgalarının uyardığı hücrelerdeki hidrojen atomlarının ürettiği enerji sayılara dönüştürüldükten ve bir bilgisayar tarafından işlendikten sonra görüntüye dönüştürülür. Radyasyon kullanılmadığı için işlem esnasında hastalar ve uygulayan sağlık personelinin radyasyon alma tehlikesi yoktur. Makine çok yönlü hareket edebildiği için elde edilen görüntü sadece yatay kesitlerle sınırlı değildir. Üç boyutlu görüntüleme sağlanabilir. Sağlıklı ve hasta dokudaki su içeriği farklıdır. Hastalıklı ya da hasarlı doku sağlıklı dokuya göre daha fazla su içerir. Doku ne kadar fazla su içerirse, o kadar güçlü MR sinyali alır [1, 2]. Şekil 2.7'de bir MR görüntüleme sisteminin fotoğrafı ve diyagramı verilmiştir.


MR değişik amaçlarla uygulanabilir. Kranial MR olarak da adlandırılan beyin MR'ı beyin tümöründen kuşkulanan hastalarda, sebebi bilinmeyen baş ağrılarında, birtakım nörolojik hastalıklarda doktor tarafından istenebilir. Omurga MR'ı disk kaymalarında yararlı olabilir. Omuz, diz gibi eklemlerin ve bağların değerlendirilmesinde kullanılabilir. Kalp, göğüs, karın ve leğen kemiğine ait bazı hastalıklar da MR ile değerlendirilebilir [2].

Farklı anatomik yapılar arasında istenen kontrastı üretmek için MR prosedürleri çeşitli şekillerde değiştirilebilir. MR görüntüleme sistemleri, ölçülen sinyali kontrol etmek için görüntülenen yapıdaki protonların dönüşlerini değiştiren radyo frekans dalga dizilerini ve manyetik alanı modüle eden mekanizmaları kullanır. MR, proton dağılımlarını seçerek görüntüleme yaptığı için yüksek derecede detaylı yapısal görüntüler sağlar ve mükemmel bir yumuşak doku görüntüleme aracıdır. Anatomik çekirdekler, nükleer manyetizmaya sahip olmaları nedeniyle dönüş açısız momenti denilen bir özelliğe sahiptirler. Anatomik çekirdekler şarj edildiklerinde belirli bir ekseninde dönerler. Bir çekirdek dönme eksenini yönünde net bir manyetik moment

üretir. Bu manyetik momentin gücü incelenen çekirdeğin türüne bağlı olarak değişir. MR görüntülemeye hidrojen çekirdekleri (protonlar) güçlü manyetik momentleri ve vücuttaki yumuşak dokudaki yaygınlıkları (su molekülleri) nedeniyle görüntülenirler [1].



(a)



(b)

Şekil 2.7. MR görüntüleme sisteminin (a) fotoğrafı ve (b) diyagramı

Belirli bir bölgedeki çok sayıda proton dikkate alındığında dönüşleri rastgele yönlerde olacaktır. Bu durumda protonların toplamındaki net manyetik moment sıfır olur. Fakat dışarıdan uygulanan bir manyetik alan olduğunda (buna MR görüntüleme de B_0 denir) dönmeler bu alana göre düzenlenir. Dönmelerin kuantum mekanik özelliklerine bağlı olarak pek çok proton alanın paraleline yakın ve her biri manyetik momentine göre aynı yönde hizalanma eğilimi gösterir. Alan eksenine yakın, dönen

ve salınan protonların tümü, dışarıdan uygulanan manyetik alan ile aynı yöndeki bütün dönüşleri için net bir manyetik momente neden olur. Vücudun belli bir bölgesindeki protonlar topluluğunun işte bu net manyetik momenti MR görüntüsünde alınan sinyallerin oluşturulması için temel oluşturur [2].

Belli bir atomik çekirdeğin B_0 alanı eksenindeki yalpalayarak dönme (topaç gibi) frekansı Larmor eşitliği (Eş. 2.1) ile gösterilir;


$$\gamma B_0 = F \quad (2.1)$$

Burada F yalpalayarak dönme frekansı, B_0 dışarıdan uygulanan manyetik alanın gücü ve γ incelenen belirli türdeki çekirdeğin manyetik momentinin bir özelliğidir. MR görüntüleme sistemlerinde (hidrojen çekirdeklerini görüntüleyen) genellikle $\gamma=4\,257$ Hz/G ve $B_0=1,5$ T (= 15 000 G) ortak alan gücü olmaktadır. Bu da verilen alan gücündeki protonların yalpalayarak dönme frekansını $F=(4\,257 \text{ Hz/G}) \times (15\,000 \text{ G})=63\,855\,000 \text{ Hz}=63,855 \text{ MHz}$ olarak verir [1].


Yalpalayarak dönme frekansı, hidrojen çekirdeğine özgü alan gücü, RF (Radyo Frekans) darbeleri uygulayarak protonların seçici olarak uyarıldığı belirli bir frekanstaki rezonansı tanımlar. Bu RF darbeleri protonlara enerji vererek, RF dalgaları uygulandığında enerji emmelerine ve RF darbeleri olmadığında o enerjiyi dağıtmalarına neden olur. RF enerjisi, harici manyetik alan ile hizalanmış protonlara RF darbesi süresince net manyetik momenti B_0 alan düzleminden belirli bir açıya (çevirme açısı) kaydıracak şekilde ulaştırılabilir. Genellikle 180° lik bir darbe uygulanır. RF enerjisi kapatıldığında dönmeler kendilerini tamamı alana göre bir kere daha hizalanana ve net manyetik moment yeniden B_0 boyunca olana kadar harici B_0 alanında yeniden hizalarlar. Bu işleme *dinlenme* denir [2].

MR görüntüsündeki sinyal yoğunluğu dört temel parametre ile belirlenir; (1) Proton Yoğunluğu, (2) T1 dinlenme zamanı, (3) T2 dinlenme zamanı ve (4) Akış. Proton yoğunluğu dokudaki protonların su ve makro moleküller (protein, yağ, vb.) şeklindeki yoğunluğudur. T1 ve T2 dinlenme zamanları protonların başlangıç RF darbesinden sonra yeniden dinlenme durumlarına dönmeleridir. Akışın en önemli

etkisi hızlı akan arter kanından sinyalin kaybedilmesidir. MR görüntüsündeki kontrast, darbe dizi parametreleri değiştirilerek ayarlanabilir. Bir darbe dizisi RF'in ve gradyan darbelerinin sayısını, gücünü ya da zamanını ayarlar. En önemli iki parametre tekrarlama zamanı (TR) ve yankı zamanıdır (TE). TR, ardışık 90°lik RF darbeleri arasındaki zamandır. TE ise başlangıç 90°lik RF darbeleri ve yankı arasındaki zamandır. Şekil 2.8'de tek yankılı T1-ağırlıklı ve çift yankılı T2-ağırlıklı MR darbe dizileri görülmektedir [3].



(a)



(b)

Şekil 2.8. (a) Tek yankılı T1-ağırlıklı ve (b) Çift yankılı T2-ağırlıklı MR darbe dizileri

En yaygın darbe dizileri T1-ağırlıklı ve T2-ağırlıklı spin-yankı dizileridir. T1-ağırlıklı dizi kısa TR ve kısa TE kullanır ($TR < 1000$ ms, $TE < 30$ ms). T2-ağırlıklı dizi uzun TR ve uzun TE kullanır ($TR > 2000$ ms, $TE > 80$ ms). T2-ağırlıklı diziler bir çift yankı dizisi olarak kullanılabilir. İlk veya daha kısa yankı ($TE < 30$ ms) PD ya da T1-ağırlıklı ve T2-ağırlıklı görüntülerin bir karışımıdır. Yakın geçmişte PD görüntüden vazgeçilerek FLAIR görüntü kullanılmaya başlanmıştır [3].

T1-ağırlıklı taramalar beyin hakkında birçok anatomik bilgi sunar. Özellikle eski lezyonların saptanmasında yararlı olan bu tip taramada, anormal alanlar siyah noktalar halinde görülür. T1-ağırlıklı görüntünün arttırılmış versiyonunda, arttırılmamış görüntüde görülemeyen lezyonlar görülür. Kontrast maddenin biriktiği yerler parlak alanlar olarak görülür, eski ve aktif olmayan lezyonlar karanlık kalır. T1-ağırlıklı taramalar sıklıkla gadolinyum içeren bileşikler gibi kontrast maddeler tarama öncesi kan dolaşımına verilerek yapılır. T2-ağırlıklı görüntü T1-ağırlıklı görüntü kadar anatomik ayrıntılara sahip değildir, yeni ve eski lezyonları gösterir. PD eski ve yeni lezyonları saptayabilir ve parlak noktalar halinde gösterir. Özellikle sıvı dolu ventriküllere yakın lezyonların saptanmasında yararlıdır [91].

2.5. Görüntü Bölütleme

Görüntü bölütleme bir görüntünün bir ya da daha fazla karakteristiğe veya özelliğe göre sınıf ya da altküme denilen bölgelerine ayrılması, aynı karakteristiğe sahip, ilgilenilen alanların arka plandan ve diğer alanlardan ayırt edilmesi, belirgin hale getirilmesidir [7].

Görüntü bölütlemenin amacı daha sonraki işlemlerde kullanılmak üzere iki boyutlu piksel dizisi şeklinde temsil edilen görüntüdeki bütün piksellerin ortak özellikleri olan kümelere gruplanmasıdır. Düşük seviyeli görüntü analizinde ilk ve en zor adım görüntü bölütlemidir. Daha sonra yapılacak olan örüntü tanıma, etiketleme gibi yüksek seviyeli uygulamaların ve analizlerin başarısı gerçekleştirilen bölütlenmenin başarısına önemli ölçüde bağlı olacaktır.

Bölütleme tıbbi görüntü işlemede önemli bir araçtır ve pek çok uygulamada faydalı bir yöntem olarak kullanılmaktadır. Bu uygulamalardan bazıları anjiyogramlarda koroner sınırın tespit edilmesi, multipl skleroz lezyonlarının nicelenmesi, cerrahi benzetimler, cerrahi planlama, tümör hacminin ve tedaviye gösterdiği tepkinin ölçülmesi, fonksiyonel haritalama, kan hücrelerinin otomatik sınıflandırılması, beyin gelişiminin incelenmesi, mamogramlardaki mikro kireçlenmelerin tespit edilmesi vb.dir [7].

2.6. Görüntü Çakıştırma

Aynı kişiye ait T1-ağırlıklı, T2-ağırlıklı ve ya FLAIR gibi MR görüntülerin alınması sırasında geçen zamanda hasta kafasını hareket ettirebilmektedir. Kimi zaman normal solunum nedeniyle bile hastanın pozisyonunda değişiklikler olabilmektedir. Bu nedenle görüntülerin içerdikleri ortak nokta ya da bölgelerin kolayca ilişkilendirilebilmesi amacıyla uzaysal olarak birbirilerine göre hizalanması gerekmektedir. Bu işleme *görüntü çakıştırma* ya da *görüntü hizalama* denmektedir [1]. Doğru bir çakıştırma işlemi sonucunda her bir görüntü aynı koordinat sisteminde olacaktır ve bir görüntüdeki belirli bir voksel ile diğer görüntüde buna karşılık gelen voksel aynı fiziksel hacmi temsil edecektir.

Çakıştırma işlemi ile farklı görüntü çeşitlerindeki belirli bir noktanın, bütün görüntülerde aynı fiziksel hacmi göstermesi; $T1(x, y, z) = T2(x, y, z) = FLAIR(x, y, z)$ amaçlanmıştır.

Tüm görüntü çakıştırma yöntemleri genellikle dört ortak adımdan oluşur;

1. Özellik çıkartma,
2. Birbirine karşılık gelen özellikleri eşleştirme,
3. Dönüşüm parametrelerinin hesaplanması,
4. Dönüşümün gerçekleştirilmesi [1].

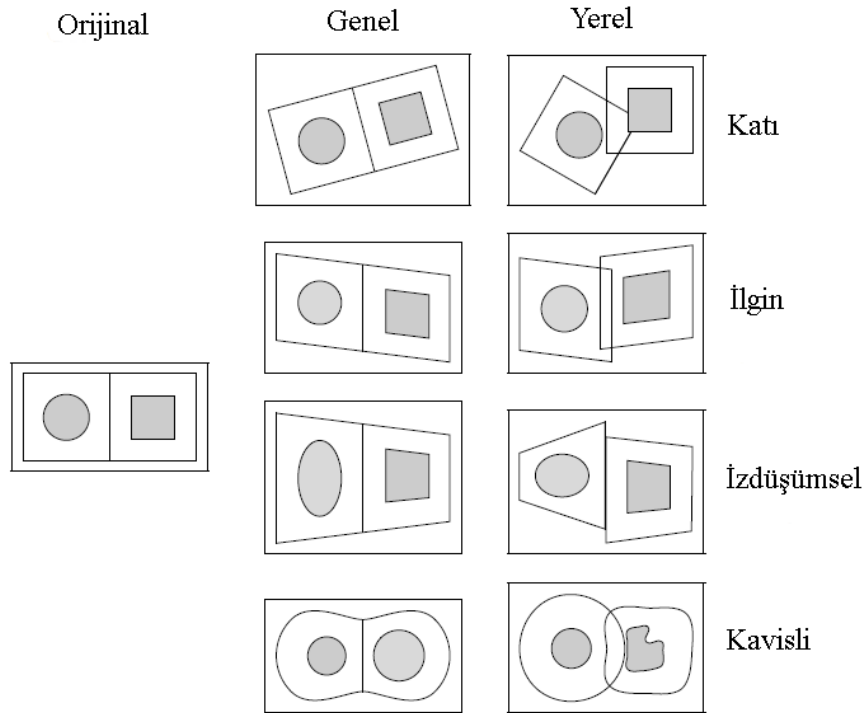
Görüntü çakıştırmada genellikle dört tür dönüşüm uygulanır;

1. *Katı (Rigid) Çakıştırma*: Üzerinde en çok çalışılan yöntemdir. Katı çakıştırma döndürme, öteleme ve yansıtma işlemlerini içerirken ölçekleme işlemini içermez. Bir görüntüdeki paralel düz çizgiler diğer görüntüdeki paralel düz çizgilere haritalanır.
2. *İlgin (Affine) Çakıştırma*: İlgin dönüşümler tüm katı dönüşümleri içerirler. Buna ek olarak hem tek biçimli hem de tek biçimli olmayan ölçekleme ve kırpma işlemlerini de içerirler. Bir görüntüdeki paralel düz çizgiler diğer görüntüdeki paralel düz çizgilere haritalanır fakat paralellik her zaman korunmayabilir. İlgin

dönüşüm aynı düzlemdeki lineer dönüşümlerin bir araya gelmesinden ve buna ek olarak öteleme işleminden oluşur.

3. *İzdüşümsel (Projective) Çakıştırma*: İzdüşümsel dönüşümler özellikle 2 boyutlu bir izdüşümün 3 boyutlu bir hacme çakıştırılması gerektiği durumlarda uygulanırlar. Fakat izdüşümsel dönüşüm ilgin dönüşümü içerdiğinden farklı uygulamalarda da kullanılabilirler. Düz çizgiler düz çizgilere haritalanır ancak paralellik korunmayabilir.
4. *Kavisli (Curved) Çakıştırma*: Kavisli dönüşüm düz çizgileri herhangi bir analitik eğriye haritalar. Bu işlem dönüşümlerdeki en genel durumdur ve izdüşümsel dönüşümü içerdiği görülebilir. Polinomlar, tek biçimli olmayan rasyonel B-splinelar ve ince-plaka (thin-plate) splinelar kavisli dönüşümler için en çok kullanılan yöntemlerdir [1].

Şekil 2.9'da görüntü hizalamada kullanılan dönüşüm yöntemleri örnek bir görüntü üzerinde gösterilmiştir.



Şekil 2.9. 2 boyutlu dönüşüm örnekleri

3-boyutlu bir katı ya da ilgin dönüşüm sabit bir a matrisi kullanılarak $y_i = a_{ij}x_j$ eşitliği ile ifade edilebilir. Burada x ve y eski ve yeni koordinat vektörleridir. Katı dönüşüm Eş. 2.2'deki gibi gerçekleştirilir [92];

$$\begin{pmatrix} y_1 \\ y_2 \\ y_3 \\ 1 \end{pmatrix} = \left(\begin{array}{ccc|c} & & & t \\ & r & & \\ \hline 0 & 0 & 0 & 1 \end{array} \right) \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ 1 \end{pmatrix} \quad (2.2)$$

Burada t bir öteleme vektörü iken r 3×3 'lük dönüştürme matrisidir ve Eş. 2.3 - Eş. 2.6'daki gibi tanımlanır;

$$r_{il} = r_{ij}^{(1)} r_{jk}^{(2)} r_{kl}^{(3)}, \quad (2.3)$$

$$r^{(1)} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos\alpha_1 & -\sin\alpha_1 \\ 0 & \sin\alpha_1 & \cos\alpha_1 \end{pmatrix}, \quad (2.4)$$

$$r^{(2)} = \begin{pmatrix} \cos\alpha_2 & 0 & \sin\alpha_2 \\ 0 & 1 & 0 \\ -\sin\alpha_2 & 0 & \cos\alpha_2 \end{pmatrix}, \quad (2.5)$$

$$r^{(3)} = \begin{pmatrix} \cos\alpha_3 & -\sin\alpha_3 & 0 \\ \sin\alpha_3 & \cos\alpha_3 & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad (2.6)$$

$r^{(i)}$ görüntüyü i ekseninde α_i açısıyla döndürür. İlgin dönüşümde r sınırlanmamıştır. İzdüşümsel dönüşümde eğer homojen koordinatlar kullanılacaksa yalnızca sabit bir matris gösterimi kullanılabilir; $y_i = u_i/u_4$, $u_i = a_{ij}x_j$. Burada a 4×4 'lük sabit bir matristir. Kavisli dönüşümler genel olarak sabit matrisler kullanılarak temsil edilemezler. Pek çok uygulama kavisli dönüşümleri yerel bir *vektör yer değiştirme* olarak; $y_i = x_i + t_i(x)$, veya eski koordinatlar cinsinden polinom dönüşümleri olarak temsil eder [92].

Tüm bu dönüşümler genel olarak tüm görüntüye veya görüntünün sınırlı bir yerel bölgesine uygulanabilir. Çakıştırma işleminde ilk adım olarak genel bir katı dönüşüm uygulandıktan sonra daha elastik genel ya da yerel bir çakıştırma ile devam edilebilir. Yakın zamanda yayınlanan çakıştırma makalelerinde, bir kural olarak, katı ve ilgin

dönüşümler genel, kavisli dönüşümler ise yerel çakıştırmalarda kullanılmaktadır [92].

İlgin dönüşüm tipik olarak görüntü ölçekleme faktörlerinin bilinmediği ya da yanlış olduğundan şüphe edildiği katı vücut hareketi durumunda, özellikle geometrik bozulma nedeniyle MR görüntülerinde, kullanılmaktadır.

Bu çalışmada beyin MR görüntülerinin farklı türlerinin çakıştırılması için yalnızca kafanın genel hareketinden kaynaklanan kaymalar düzeltilmeye çalışıldığından ilgin dönüşüm kullanılmıştır. İlgın dönüşüm, dönüştürme matrisindeki parametreler ile ifade edilen, katı dönüşümde bulunan dönme ve ötelemeyi içeren 6 serbestlik derecesine ek olarak ölçekleme ve kırpmayı içeren 6 serbestlik derecesine daha sahiptir [93].

Bir MR görüntüsünü diğer bir MR görüntüsü ile ilişkilendirirken iki görüntü arasındaki çakışmanın derecesini ölçmek için bir benzerlik ölçütüne ihtiyaç duyulmaktadır. Görüntü yoğunluk değerleri bütün MR türlerinde birbirinden farklı olduğu için farkların kareleri toplamı ya da korelasyon gibi doğrudan görüntü yoğunluklarının karşılaştırıldığı yöntemler kullanılamaz. Voksel tabanlı alternatif bir benzerlik ölçütü olan karşılıklı bilgi (mutual information) Collignon [94] ve Viola [95] tarafından önerilmiştir ve farklı modalitedeki görüntüleri doğru ve güvenilir bir biçimde çakıştırdığı ispat edilmiştir [96]. Karşılıklı bilgi, bilgi kuramına dayanır ve bir A görüntüsünün ikinci bir görüntü olan B ile ilgili içerdiği bilginin miktarını ifade eder (Eş. 2.7) [93].

$$C_{benzerlik}(A, B) = H(A) + H(B) - H(A, B) \quad (2.7)$$

Burada $H(A)$, $H(B)$ ifadeleri A , B 'nin entropilerini ve $H(A, B)$ ise A ile B 'nin bileşik histogramından hesaplanan bileşik entropilerini temsil etmektedir. Eğer iki görüntü çakıştırılmışsa karşılıklı bilgi en üst düzeydedir. Karşılıklı bilgi iki görüntü arasındaki örtüşmeden bağımsız değildir. Görüntü örtüşme miktarına olan bağımlılıkları önlemek için görüntülerdeki çakışmanın bir ölçütü olarak normalleştirilmiş karşılıklı bilgi kullanılmıştır (Eş. 2.8) [93, 97].

$$C_{benzerlik}(A, B) = \frac{H(A)+H(B)}{H(A,B)} \quad (2.8)$$

Görüntülerin karşılaştırılması işleminde T1-ağırlıklı MR görüntüleri statik referans görüntüleri olarak alınmış, T2-ağırlıklı ve FLAIR MR görüntüleri bu görüntü üzerine karşılaştırılmıştır. Bütün hastalar için bu karşılaştırma işlemi bölütleme işleminden önce gerçekleştirilmiştir.

2.7. Eşyönsüz Yayınım Filtresi

Perona ve Malik [67] görüntü işleme için güçlü ve yeni bir kavram olan, eşyönsüz yayınım filtresi adı verilen çok ölçekli bir yumuşatma ve kenar tespiti metodu geliştirmişlerdir. Bu metot matematiksel olarak bir yayınım işlemi şeklinde formüle edilmiştir. Sınırlardaki yumuşatma işlemi yerine bölge içlerindeki yumuşatmaları teşvik etmektedir. Filtreleme işleminde yerel görüntünün yapısı tahmin edilirken, gürültüden kaynaklanan bozulmalar ve kenar kuvveti hakkındaki istatistiksel bilgilerden faydalanılmaktadır [65].

Eşyönsüz yayınım filtresindeki yumuşatma işlemi kenar noktalarda yerel olarak uyarlanabilen bir yayınım katsayısı kullanılarak durdurulmaktadır. Bu işlem herhangi bir boyut için matematiksel olarak Eş. 2.9'daki gibi gösterilebilir;

$$\frac{\partial}{\partial t} u(x, t) = \text{div}(c(x, t) \nabla u(x, t)) \quad (2.9)$$

Yayınımın kuvveti $c(x, t)$ ile kontrol edilir. x vektörü uzaysal koordinatları temsil etmektedir. t değişkeni ise işlem düzenleme parametresidir ve ayrık uygulamalarda iterasyon adımlarının numaralandırılmasında kullanılır. $u(x, t)$ fonksiyonu, görüntü yoğunluğu $I(x, t)$ olarak alınmıştır. $c(x, t)$ yayınım fonksiyonu görüntü yoğunluğundaki eğimin derecesine bağlıdır. Bölgelerin içinde yayılan ve yüksek eğimli yerlerde bulunan bölge sınırlarını etkilemeyen $c(x, t) = f(|\nabla I(x, t)|)$, monoton olarak azalan bir fonksiyondur. Eş. 2.10 ve Eş. 2.11'de verilen iki farklı yayınım fonksiyonu bulunmaktadır;

$$c_1(x, t) = e^{-\left(\frac{|\nabla I(x, t)|}{\kappa}\right)^2} \quad (2.10)$$

$$c_2(x, t) = \frac{1}{1 + \left(\frac{|\nabla I(x, t)|}{\kappa}\right)^{1+\alpha}} \quad \alpha > 0 \quad (2.11)$$

κ parametresi gürültü seviyesine ve kenarların kuvvetine göre seçilir. Bu yayının fonksiyonları κ parametresinden daha büyük yoğunluk eğimine sahip değerler için yayının işlemini zayıflatırken bölgeler arası yerine bölge içindeki yayını teşvik etmektedir [98].

Bu çalışmada, sinyal-gürültü oranını geliştirme, homojen bölgeleri bulanıklaştırarak nesne sınırlarını keskinleştirme, gürültüyü ve kısmi hacim etkilerini azaltma ve etki alanı ya da tekbiçimsizlik olarak adlandırılan homojensizlikleri düzeltme özelliklerinden dolayı eşyönsüz yayının filtresi kullanılmıştır. Eşyönsüz yayının filtresi ile bu olumsuzluklardan arındırılan görüntülerin bölütleme performansları artmaktadır.

2.8. Dalgacık Dönüşümü

Matematiksel dönüşümler ile sinyalin ham halinde bulunmayan daha ileri bilgiler elde edilir. Sinyallerin çoğu zaman düzleminde, zamana bağlı fonksiyonlardır. Zaman düzlemindeki sinyaller çizdirildiğinde sinyalin zaman-genlik temsili yapılmış olur. Pek çok durumda bu temsil yetersizdir. En önemli bilgiler genellikle sinyalin frekans bileşeni içinde gizlidir. Bir sinyalin frekans spektrumu, sinyalin içinde hangi frekans bileşenlerinin bulunduğunu gösterir. Zaman düzleminde kolayca görülemeyen bilgiler frekans düzleminde görülebilir. Frekans, fiziksel ya da matematiksel bir değişkenin oranındaki değişimdir. Eğer değişken hızlı değişirse frekansı yüksektir, yavaş değişirse frekansı düşüktür. Eğer değişken değişmiyorsa frekansı yoktur ya da sıfırdır. Örneğin, günlük bir gazetenin basım frekansı aylık bir dergiden yüksektir [99].

Zaman düzlemindeki bir sinyalin Fourier dönüşümü alınırsa sinyalin frekans-genlik temsili elde edilir. Bir eksenini frekans diğer eksenini genlik olan bu gösterimde sinyalde her frekanstan ne kadar olduğu görülebilir. Frekans eksenini sıfırdan başlar ve sonsuza kadar devam eder. Her frekans için bir genlik değeri vardır.

Fourier dönüşümü 1950'lerin sonlarından beri dönüşüm tabanlı görüntü işlemenin başlıca dayanağı olmuştur. Yakın geçmişte kullanılmaya başlanan dalgacık dönüşümü ise görüntüleri sıkıştırmayı, iletmeyi ve analiz etmeyi çok daha kolaylaştırmaktadır. Temel fonksiyonları sinüs fonksiyonları olan Fourier dönüşümünden farklı olarak, dalgacık dönüşümü “dalgacık” adı verilen, değişken frekanslara ve sınırlı süreye sahip küçük dalgalara dayanır. Bu da bir görüntü için bir partiyon, yalnızca notaları (ya da frekansları) değil aynı zamanda ne zaman çalınacaklarını da gösteren, bir eşdeğer sağlar. Diğer taraftan geleneksel Fourier dönüşümleri yalnızca notaları veya frekans bilgisini sağlar, zamana ait bilgi dönüşüm işlemi içinde kaybolmuştur [38].

Görüntüler genellikle nesnelere oluşturmak için bir araya gelmiş benzer desenler ya da gri seviyesinin bağlantılı bölgeleridir. Eğer nesnelere boyut olarak küçükse veya kontrastı düşükse yüksek çözünürlüklerde incelenir, eğer boyut büyük veya kontrast yüksekse kaba bir bakış yeterli olur. Eğer hem küçük hem de büyük nesnelere, ya da düşük veya yüksek kontrastlı nesnelere aynı anda varsa, bunları birkaç çözünürlükte irdelemek avantajlı olur. Bu yaklaşım çok çözünürlüklü işlemenin temel hareket noktasıdır.

Farklı ölçeklerdeki ve frekanslardaki görüntüler çok çeşitli karakteristiklere sahiptirler. Bu nedenle dalgacık dönüşümü çok çözünürlüklü yapısı nedeniyle doku analizi için oldukça uygundur. Görüntünün 2-boyutlu dalgacık dönüşümü frekans spektrumunu yaklaşım alt görüntüsü ile yatay, dikey ve köşegen detay alt görüntülerine böler. Her bir alt görüntü, orijinal görüntü ile ilgili farklı özellikleri ortaya çıkaracağından, bu alt görüntülerin kendileri ya da alt görüntülerin filtrelenmiş versiyonları görüntü bölütlemeye görüntüyle ilgili çok çeşitli özellikleri ortaya çıkartacaktır.

2.8.1. İki boyutlu dalgacık dönüşümü

İki-boyutlu dalgacık dönüşümünde bir iki-boyutlu ölçekleme fonksiyonu $\varphi(x, y)$ ve üç iki-boyutlu dalgacık fonksiyonu $\psi^H(x, y)$, $\psi^V(x, y)$, $\psi^D(x, y)$ gereklidir. Bu fonksiyonların her biri bir boyutlu ölçekleme fonksiyonu φ ve ona karşılık gelen dalgacık fonksiyonun ψ çarpımıdır. Eş. 2.12 ayrılabilir ölçekleme fonksiyonunu ve Eş. 2.13 – Eş. 2.15 ayrılabilir, yönlere duyarlı dalgacıkları göstermektedir [38, 100, 101].

$$\varphi(x, y) = \varphi(x)\varphi(y) \quad (2.12)$$

$$\psi^H(x, y) = \psi(x)\varphi(y) \quad (2.13)$$

$$\psi^V(x, y) = \varphi(x)\psi(y) \quad (2.14)$$

$$\psi^D(x, y) = \psi(x)\psi(y) \quad (2.15)$$

Bu dalgacıklar fonksiyonel değişimleri – görüntülerdeki yoğunluk veya gri-seviyesi değişimlerini- farklı yönlerde ölçer. ψ^H sütunlardaki değişimleri (yatay kenarlar), ψ^V satırlardaki değişimleri (dikey kenarlar), ψ^D ise köşegensel değişimleri ölçer.

Ayrılabilir iki-boyutlu ölçekleme ve dalgacık fonksiyonları verildiğinde ölçeklenmiş ve ötelenmiş temel fonksiyonlar eşitlik 2.16 ve 2.17'deki gibi yazılır.

$$\varphi_{j,m,n}(x, y) = 2^{j/2} \varphi(2^j x - m, 2^j y - n) \quad (2.16)$$

$$\psi_{j,m,n}^i(x, y) = 2^{j/2} \psi^i(2^j x - m, 2^j y - n) \quad i = \{H, V, D\} \quad (2.17)$$

i indeksi yatay (H), dikey (V) ve köşegen (D) şeklinde dalgacığın yönünü tanımlar. $M \times N$ boyutundaki $f(x, y)$ fonksiyonunun ayrık dalgacık dönüşümü (ADD) Eş. 2.18 ve Eş. 2.19'da verildiği gibidir;

$$W_\varphi(j, m, n) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \varphi_{j_0,m,n}(x, y) \quad (2.18)$$


$$W_{\psi}^i(j, m, n) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \psi_{j,m,n}^i(x, y) \quad i = \{H, V, D\} \quad (2.19)$$

j_0 isteğe bağlı başlangıç ölçeği, $W_{\varphi}(j, m, n)$ $f(x, y)$ 'nin j_0 ölçeğindeki yaklaşımını tanımlayan katsayılardır. $W_{\psi}^i(j, m, n)$, $j \geq j_0$ ölçekleri için yatay, dikey ve köşegen detayları gösteren katsayılardır. Normalde $j_0 = 0$, $N = M = 2^J$ seçilir, böylece $j = 0, 1, 2, \dots, J-1$ ve $m, n = 0, 1, 2, \dots, 2^{j-1}$ değerlerini alır. W_{φ} ve W_{ψ}^i verildiğinde $f(x, y)$ ters ayrık dalgacık dönüşümü kullanılarak elde edilebilir (Eş. 2.20).

$$f(x, y) = \frac{1}{\sqrt{MN}} \sum_m \sum_n W_{\varphi}(j_0, m, n) \varphi_{j_0, m, n}(x, y) + \frac{1}{\sqrt{MN}} \sum_{i=H,V,D} \sum_{j=j_0}^{\infty} \sum_m \sum_n W_{\psi}^i(j, m, n) \psi_{j, m, n}^i(x, y) \quad (2.20)$$


2.8.2. Hızlı dalgacık dönüşümü

İki-boyutlu ADD, dijital filtreler ve alt örnekleycilerle Şekil 2.10'deki gibi Hızlı Dalgacık Dönüşümü (HDD) şeklinde temsil edilebilir.

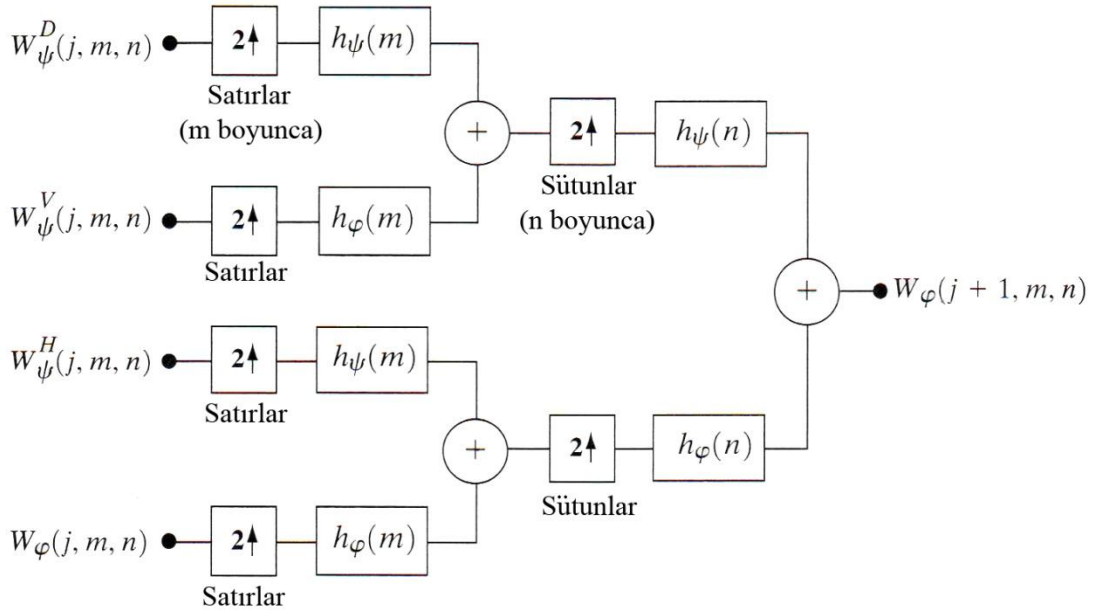


Şekil 2.10. İki boyutlu HDD

Buradaki tek ölçekli filtre bankası tekrarlanarak P ölçekli dönüşüm $j = J - 1, J - 2, \dots, J - P$ ölçeklerinde elde edilebilir. $f(x, y)$, $W_\varphi(J, m, n)$ girdisi gibi kullanılır. Görüntünün satırlarının ölçekleme vektörü $h_\varphi(-n)$ ve detay vektörü $h_\psi(-n)$ ile konvolüsyonu alınıp sütunları alt örneklendiğinde yatay çözünürlükleri 2 katı oranda azaltılmış iki alt görüntü elde edilir. Her iki alt görüntü de sütunlara bağlı olarak filtrelenip alt örneklendiğinde W_φ , W_ψ^H , W_ψ^V ve W_ψ^D şeklinde dört çeyrek-boyutta çıktı alt görüntüsü elde edilir. Bu alt görüntüler Şekil 2.11'de gösterilmektedir [38].




Şekil 2.11. $f(x, y)$ görüntüsünün iki ölçekli HDD ayrıştırması sonucu elde edilen W_φ , W_ψ^H , W_ψ^V ve W_ψ^D alt görüntüleri



Şekil 2.12. Sentez filtre bankası

Şekil 2.12 ayrıştırma işlemini tersine çeviren sentez filtre bankasını göstermektedir. Her tekrarda dört adet j ölçeğindeki yaklaşım ve detay alt görüntüleri üst örneklenir ve biri alt görüntülerin sütunları, diğeri satırları üzerinde işlem yapan iki adet bir-boyutlu filtre ile konvolüsyonu alınır. Sonuçların toplanması $j+1$ ölçeğindeki yaklaşımı verir ve bu işlem orijinal görüntü yeniden oluşturulana kadar devam eder.

Şekil 2.13'te bilgisayar tarafından üretilmiş bir görüntüye üç ölçekli HDD işleminin uygulanması ile elde edilen ayrıştırma sonuçları verilmiştir.




Şekil 2.13. Üç ölçekli bir HDD (a) orijinal görüntü, (b) 1 seviyeli, (c) 2 seviyeli, (d) 3 seviyeli ayrıştırma sonucu elde edilen yaklaşım, yatay, dikey ve köşegen alt görüntüler

2.8.3. Dalgacık paketleri

Zaman-frekans düzleminin parçalara ayrılması üzerinde daha fazla kontrole sahip olmak istendiğinde, örneğin sinyalin yüksek frekanslarında daha küçük bantlar gibi, dalgacık paketleri yöntemi kullanılır. Bu işlem HDD'nin $O(N)$ olan hesapsal karmaşıklığını $O(N \log N)$ 'e çıkarır [38].

Dalgacık paketleri, 2 boyutlu dalgacık dönüşümünden farklı olarak her alt bantta bulunan alçak frekans bileşenleri ile birlikte yüksek frekans bileşenlerini de ayrıştırır [102].


Şekil 2.14'te üç ölçekli bir hızlı HDD filtre bankası görülmektedir [38]. Şekil 2.14'te V alçak geçiren, yaklaşım katsayılarını temsil ederken W , yüksek geçiren, detay katsayıları temsil etmektedir. Ayrıştırma seviyeleri J ile temsil edilmiştir. Dalgacık dönüşümü katsayıları j ölçeğindeki yaklaşım katsayıları $W_\psi(j, k)$, ile j ölçeğindeki detay katsayıları $W_\varphi(j, k)$, $j + 1$ ölçeğindeki yaklaşım katsayılarının $W_\psi(j+1, k)$, ölçekleme vektörü $h_\psi(-n)$ ve detay vektörü $h_\varphi(-n)$ ile konvolüsyonu ve sonuçların alt örnekleme ile hesaplanmaktadır.



Şekil 2.14. Üç ölçekli bir HDD filtre bankası


Dalgacık paketleri dönüşümünde ise filtreleme işlemi yalnızca yaklaşım katsayılarına değil aynı zamanda detay katsayılarına da yapılmaktadır (Şekil 2.15). Böylece frekans bantları üzerinde daha fazla kontrole sahip olunmaktadır [103]. İki adet altsimge içeren gösterimlerde ilk altsimge HDD'deki ebeveyn düğümü

belirtmektedir. Değişik uzunlukta olabilen, A 'lar ve D 'ler oluşan ikinci altsimge ise ebeveyn düğümünden o düğüme kadar izlenen yolu kodlamaktadır. A yaklaşım filtrelemesini ve D detay filtrelemesini temsil etmektedir. Örneğin, $W_{J-1,DA}$ alt uzayı, $J-1$ ölçeğindeki hızlı dalgacık katsayılarının ek bir detay filtre ile filtrelenmesini takiben ortaya çıkan $W_{J-1,D}$ 'nin bir yaklaşım filtresinden geçirilmesi ile elde edilmiştir [38].




Şekil 2.15. Üç ölçekli bir dalgacık paket analizinin filtre bankası

HDD'de W_{J-1} ile temsil edilen alt uzay, frekans spektrumunda en geniş bant genişliğine sahip bölümdür. Üç ölçekli bir HDD'de analiz bankasının frekans bölme karakteristiği Şekil 2.16'da verilmiştir. Dalgacık paketleri, HDD'ye göre daha esnek bir ayrıştırma sağlar. Dalgacık paketleri dönüşümü ile gelişmiş bir ayrıştırma elde edilir ve fonksiyonun spektrumunun ayrıştırılması daha iyi kontrol edilebilir. Bu kontrol gürültü ve sinyalin farklı alt bantlarda birbirinden ayrıştırılabilmesini sağlar [104]. Üç ölçekli bir dalgacık paket analizinin frekans bölme karakteristiği Şekil 2.17'de verilmiştir [38].



Şekil 2.16. Üç ölçekli HDD analiz bankasının frekans bölme karakteristiği




Şekil 2.17. Üç ölçekli bir dalgacık paket analizinin frekans bölme karakteristiği

Dalgacık paketleri ikili ağaç yapısı ile temsil edilebilir. Kök düğüm en yüksek ölçekli yaklaşım katsayıları yani fonksiyonun kendisinin örnekleridir. Yapraklar ise dönüşümün yaklaşım ve detay katsayı çıktılarıdır. İkili ağaç yapısında her alt bant yüksek ya da düşük frekans bileşeni bir sonraki ölçekteki yüksek ve düşük frekans açılım çiftine karşılık gelen iki çocuk düğüme sahiptir [38, 103].

Şekil 2.18'de beyin modeli görüntülerinin analizinde kullanılan üç ölçekli bir dalgacık paket analiz ağacı verilmiştir. Ayrıştırma algoritmasının karmaşıklığı ve alt düğümlerin (alt görüntülerin) sayısı ayrıştırma ölçeğinin (seviyesinin) artması ile üstel olarak artmaktadır. Örneğin 3 seviyeli bir ayrıştırma ile 85 alt görüntü elde edilirken 4 seviyeli bir ayrıştırmada alt görüntü sayısı 341 olmaktadır. Bu da takip eden işlem basamaklarını zaman ve bellek açısından uygulanamaz kılmaktadır. Bunun yanında yeterli seviyede ayrıştırılmayan görüntülerden bölütleme işlemi için gerekli desen özellikleri elde edilememektedir. Bu nedenle, algoritmanın

karmaşıklığını azaltmak, özellik boyutunu düşürmek ve gerekli desen özellikleri elde edebilmek için görüntülere 3 seviyeli bir dalgacık paket analizi uygulanmıştır.



Şekil 2.18. Üç ölçekli bir dalgacık paket analiz ağacı

2.8.4. Durağan dalgacık dönüşümü

Geleneksel dalgacık paketi ayrıştırma metodlarında sinyal alt örnekleme ve bir filtre ile konvolüsyonu alınarak bir sonraki seviyenin ayrıştırılmış sinyali elde edilir. Ayrıştırılmış sinyalin uzunluğu orijinal sinyalin $1/2^n$ 'i kadardır. Burada n ayrıştırmanın seviyesini göstermektedir. Ayrıştırılmış sinyaldeki bir piksel orijinal sinyaldeki 2^n piksele karşılık gelmektedir. Bu nedenle ayrıştırılmış sinyalden çıkarılan özellikler ile piksel tabanlı bölütleme yapılamaz [105, 106]. Unser [73], desen özelliklerinin çoklu ölçeklerde karakterize edilebilmesi için DDD olarak tanımlanan yeni bir yaklaşım tanımlamıştır. DDD analizi, öteleme ile değişmeyen bir tam ötesi (overcomplete) dalgacık ayrıştırması kullanır. Bu gösterimin bir sıkı çerçeve oluşturduğu ve hızlı bir tekrarlı algoritma olduğu gösterilmiştir.

Ayrıştırmanın uygulanmasında, geleneksel yöntemde olduğu gibi sinyale alt örnekleme işlemi uygulanmamakta, bunun yerine her tekrarda filtreler Eş. 2.21 kullanılarak üst örnekleme, Eş. 2.22 kullanılarak sinyal ile konvolüsyonu alınmakta ve böylece bir sonraki seviyedeki alt sinyal elde edilmektedir.

$$\begin{aligned}
 h_{i+1}(k) &= [h]_{\uparrow 2^i} * h_i(k) \\
 g_{i+1}(k) &= [g]_{\uparrow 2^i} * h_i(k)
 \end{aligned}
 \tag{2.21}$$

$[\cdot]_{\uparrow m}$ ifadesi m ile üst örnekleme göstermektedir. Bir iterasyonun etkisi, h_i ve g_i filtrelerinin 2 çarpanı ile genişletilmesi anlamına gelmektedir.

$$\begin{aligned} s_{i+1}(k) &= h_{i+1}(k) * s_i(k) \\ d_{i+1}(k) &= g_{i+1} * s_i(k) \end{aligned}, i = 0, 1, \dots, I. \quad (2.22)$$

Her işlem adımı, filtre kademeleri arasında uygun sayıda sıfırlar eklenerek genişletilmiş h ve g temel filtreleri ile bir konvolüsyon içerir. Bu algoritmanın karmaşıklığı tüm iterasyonlar için aynıdır ve örneklerin sayısı ile orantılıdır.


DDD'den elde edilen alt sinyaller orijinal sinyal ile aynı uzunluktadır ve sinyalin ötelenmesinden bağımsızdır. DDD katsayıları ve onlardan elde edilen desen özellikleri herhangi bir izdüşümüne ihtiyaç duymadan doğrudan bölütleme işleminde kullanılabilir. Bununla birlikte görüntülerin bölütlenmesinde yararlı olan orta frekans bölgesine ait bilgileri içermektedirler. Farklı ölçeklerdeki ve frekanslardaki görüntüler bir dokunun görünümü için çeşitli karakteristiklere sahip olduklarından dalgacıkların çok çözünürlüklü, çok kanallı modelleme kapasitesi doku analizi için oldukça uygundur. Bu nedenlerle bu çalışmada görüntülerden özellik çıkartmak için DDD yöntemi kullanılmıştır.

2.9. Desen Özelliklerinin Çıkarılması

Ham dalgacık katsayıları tek başlarına desen işaretlerini tam olarak ifade etmekte yetersizdirler. Dokulu bilgiyi farklı frekans kanallarına bölmekte faydalıdır fakat bir pikselin etrafındaki yerel istatistiksel bilgilerden yoksundurlar. Benzer ortalama parlaklık değerine ya da ikinci dereceden istatistiklere sahip desen çiftlerini ayırt etmek üzere bir doğrusalsızlığa gerek vardır [107].

Görüntülerdeki yerel özellikleri hesaplamak için genellikle uzaysal filtreleme işlemi gerçekleştirilmektedir. Uzaysal filtreleme işlemi 4 adımdan oluşmaktadır; (1) bir merkez nokta (x, y) belirlenir, (2) belirlenen merkez noktanın yalnızca önceden belirlenmiş belirli bir komşuluğunda olan pikseller üzerinde bir işlem gerçekleştirilir, (3) işlem sonucu o noktadaki işlemin tepkisi olarak alınır, (4) görüntüdeki her nokta

için işlem tekrar edilir. Merkez noktanın hareket ettirilmesi her piksel için yeni komşuluklar oluşturur (Şekil 2.19). Bu işleme *pencereleme* ya da *uzaysal filtreleme* denmektedir [101].



Şekil 2.19. Uzaysal filtreleme işlemi. Büyütülmüş görüntü 3×3 büyüklüğündeki bir pencereyi ve görüntüde buna karşılık gelen komşulukları göstermektedir.

Bu çalışmada, dalgacık katsayılarına uzaysal filtreleme işlemi uygulanmış ve sabit boyutlu bir pencere katsayıları üzerinde kaydırılmıştır. Pencerenin yerel istatistikleri

her bir pozisyon için hesaplanmıştır. Elde edilen değerler bu pencerelerin her birinin ortasında bulunan pikselin özellik değerleri olarak ilişkilendirilmiştir.

Geniş çeşitlilikte desen özellikleri mevcuttur. Bu çalışmada, farklı dokuları birbirinden ayırt etmek üzere ortalama mutlak sapma, entropi, enerji ve standart sapma özellikleri kullanılmıştır. Ortalama mutlak sapma bir veri kümesindeki verilerin ortalamadan mutlak sapmasının ortalamasıdır ve desendeki tek düzelikleri gösteren bir enerji ölçөгüdür. N örnek büyüklüğü için ortalama mutlak sapma Eş. 2.23'teki gibi hesaplanır;

$$\text{Ortalama Mutlak Sapma} = \frac{1}{N} \sum_{i=1}^N |x_i - \bar{x}| \quad (2.23)$$

Burada \bar{x} dağılımın ortalamasıdır. Entropi rastgeleliğin istatistiksel bir ölçüsüdür ve görüntüdeki desenleri karakterize etmekte kullanılmaktadır. Entropi Eş. 2.24'teki gibi tanımlanır;

$$\text{Entropi} = -\sum_i x_i^2 \log(x_i^2) \quad (2.24)$$

Desen özelliği olarak kullanılan bir diğer istatistik olan enerji Eş. 2.25'teki gibi hesaplanabilir;

$$\text{Enerji} = \frac{1}{N} \sum_i |x_i|^2 \quad (2.25)$$

Ortalama karışıklığın bir ölçütü olan standart sapma ise Eş. 2.26'daki gibi hesaplanmaktadır;

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (2.26)$$

Dalgacık katsayıları tek başına dokuları tam olarak ifade etmekte yetersiz olduğundan, görüntüdeki yerel istatistiksel bilgileri elde etmek üzere dalgacık

katsayılarına pencereleme ile uzaysal filtreleme işlemi uygulanmış ve yerel istatistikler hesaplanmıştır.

2.10. Özörgütlemeli Harita Ağları


Özörgütlemeli harita (SOM) ağları 1982’de Kohonen tarafından geliştirilmiştir [108]. Danışmansız bir yapay sinir ağıdır. Yarışmacı öğrenme algoritmasını kullanır. Yarışmacı öğrenme algoritmasında ağın çıkış nöronları aktive edilmek için kendi aralarında yarışır. Sonuçta aynı anda yalnızca bir çıkış nöronu kazanarak aktive edilir. Yarışmayı kazanan çıkış nöronuna *kazanan nöron* ya da *en iyi uyan birim* (BMU) denir [59].

Yarışmacı öğrenme işleminde nöronlar çeşitli girdi desenlerine ya da girdi desenlerindeki sınıflara seçilerek ayarlanmış olurlar. Bu şekilde kazanan nöronların bulunduğu yerler, birbirlerine göre farklı girdi özellikleri için ızgara üzerinde anlamlı bir koordinat oluşturacak şekilde ayarlanır [109]. Bu nedenle SOM ağları girdi desenlerinin topografik haritasının oluşumu ile karakterize edilir. Bu topografik haritada, ızgaradaki nöronların uzaysal yerleşimi, girdi desenlerinde bulunan yerleşik istatistiksel özellikleri açığa çıkarır [59].

SOM ağlarının nöral bir model olarak geliştirilmesinde insan beyninin belirgin bir özelliği olan farklı uyarıcı girdilerinin belirli bölgelerde temsil edilmesi özelliğinden esinlenilmiştir. Dokunsal, görsel ve akustik gibi duyuşal girdiler beyin korteksinin farklı alanlarına topografik olarak düzenlenmiş şekilde haritalanırlar. Böylece hesapsal harita, sinir sisteminin bilgi işleme alt yapısı içinde basit bir yapı bloğu oluşturur. Bir hesapsal harita, duyuşal bilgi olan paralel sinyaller üzerinde işlem yapan, birbirinden tamamen farklı ayarlanmış işlemciler ya da filtreler ile temsil edilen nöronların bir dizisi olarak tanımlanır. Bu nedenle nöronlar girdi sinyalini, hesaplanan parametre değerlerinin haritadaki maksimum görece aktivite bölgeleri ile temsil edildiği, yeri-kodlanmış olasılık dağılımına çevirir. SOM ağı, beyindeki hesapsal haritaların temel özelliklerini gösterir ve hesapsal olarak izlenebilirdir [59].

SOM ağının temel hedefi herhangi bir boyuttaki girdi sinyal desenini bir ya da iki-boyutlu bir ayrık haritaya dönüştürmek ve bu dönüşümü topografik olarak düzenli bir biçimde adaptif olarak gerçekleştirmektir.

Görüntü bölütleme teknikleri, görüntüdeki her pikselin yüzey özelliklerine göre bir özellik vektörü ile ilişkilendirilerek, özellik vektörlerinin kümelenmesi temeline dayanır. SOM ağı, giriş görüntüsünü istenen sayıda bölgeden oluşan kümeye haritalamak için kullanılır.




Şekil 2.20. SOM ağının yapısı

Bir SOM ağında nöronlar genellikle bir ya da iki boyutlu bir *ızgaranın* düğümleri olarak yerleştirilmiştir. Yüksek boyutlu haritalar da mümkündür fakat genel değildir. Şekil 2.20’de SOM ağının yapısını görülmektedir. SOM ağı satırlar ve sütunlar şeklinde düzenlenmiş nöronlar içeren tek bir hesapsal katmanı olan ileri beslemeli bir yapıdadır. Basit bir SOM ağı iki katmandan oluşur. İlk katman giriş düğümleridir ve ikinci katman ise çıkış düğümlerini içerir. Çıkış düğümleri Şekil 2.20’de gösterildiği gibi iki boyutlu bir ızgara görüntüsündedir. Her giriş nöronu her çıkış nöronuna ayarlanabilen ağırlıklarla bağlıdır.

Ağırlık vektörünün başlangıç değerleri rastgeledir. Ağırlıklar girişin ağ tarafından öğrenilmesi ile ayarlanır. Girişe en iyi cevabı veren işlem elamanı etrafında bir $N_c(n)$ komşuluk kümesi oluşur. Komşuluk kümesi iki boyutlu, dikdörtgen, altıgen vb. yapılarla oluşabilir. Herhangi bir çıkış işlem elamanının, verilen bir dairesel yarıçap

ile bütün komşulukları belirlenebilir. Ağırlık vektörünün başlangıçtaki keyfi dağılımı, giriş örüntü vektörlerinin ağ tarafından öğrenilmeye başlanması ile kendi kendine ayarlanır. Şekil 2.21’de bir nöronun dikdörtgen ve altıgen olarak yapısal komşuluğu gösterilmektedir [110].



Şekil 2.21. Bir nöronun yapısal komşuluğu ($c1 < c2 < c3$)

Kohonen’in kendi kendini düzenleyen SOM ağı algoritmasının işlem adımları aşağıdaki gibidir;

- 1. adım:** N adet giriş düğümü ile M adet çıkış düğümü arasındaki ağırlıklar küçük rastgele değerlere ayarlanır ve komşuluğun ilk yarıçap değeri belirlenir.
- 2. adım:** Girdi veri kümesi içinden bir x girdi vektörü rastgele seçilerek ağda giriş olarak uygulanır.
- 3. adım:** Girişin, tüm çıkış düğümlerine (sınıflara) olan mesafesi Öklid uzaklık yöntemi kullanılarak Eş. 2.27’deki gibi hesaplanır.

$$d_j = \sum_{i=1}^N (x_i(t) - w_{ij}(t))^2 \quad (2.27)$$

Burada d_j giriş ile j . çıkış düğümü arasındaki mesafeyi, $x_i(t)$ x giriş vektörünün i . elemanının t anındaki değerini ve $w_{ij}(t)$ i . girişten j . çıkış düğümüne olan ağırlığın t anındaki değerini göstermektedir.

4. adım: Minimum mesafeye sahip çıkış düğümü belirlenir. En küçük d_j mesafesine sahip j . çıkış düğümü BMU olarak seçilir.

5. adım: j . çıkış düğümüne ve komşularına ait ağırlıklar yeniden hesaplanır.

Yeni ağırlıklar yarışmayı kazanan çıkış düğümleri için Eş. 2.28 ve yarışmayı kaybeden çıkış düğümleri için Eş. 2.29'daki gibi hesaplanır.

$$w_{ij}(t+1) = w_{ij}(t) + \alpha(t) \cdot (x_i(t) - w_{ij}(t)), \quad (2.28)$$


$$\forall i \in N_c(n)$$

$$w_{ij}(t+1) = w_{ij}(t) \quad (2.29)$$

$$\forall i \notin N_c(n)$$

Burada $\alpha(t)$ zamanla azalan bir öğrenme oranını ($0 < \alpha(t) < 1$) ve $N_c(n)$ zamanla değişen komşuluk kümesini temsil etmektedir.

6. adım: 2. adıma gidilerek işlemler tekrarlanır.



Şekil 2.22. BMU ve komşularının ağırlık vektörlerinin güncellenmesi


SOM ağıının kullandığı nöron topolojisi ve BMU ile birlikte bu nörona komşu nöronların ağırlıklarının yenilenmesi ağıın yapısına dayanıklılık katmaktadır. Bu işlem BMU ve komşularının ağırlık vektörünün girdi vektörüne yaklaşmasını sağlar. Bu adaptasyon işlemi BMU ve komşularının ağırlık vektörlerini x girdi vektörü boyunca gerer. Şekil 2.22’de x ile gösterilen bir girdi örneği için BMU ve komşularının ağırlık vektörlerinin güncellenmesi gösterilmiştir. Düz ve kesikli çizgiler güncellemeden önceki ve sonraki durumları ifade etmektedir [111].

Giriş katmanındaki sinir hücresi sayısı, her piksel için giriş özelliği sayısına bağlı ve çıkış katmanındaki sinir hücresi sayısı küme sayısına eşit veya daha fazladır. Ağıın girişi beyin MR görüntülerinden elde edilen özellik vektörü olacaktır. Sonuçta beyin MR görüntüsü istenilen sayıda bölgeye bölütlenmiş olacaktır.

Ağıdaki her nöron d -boyutlu bir ağırlık vektörüdür. Buradaki d -boyutu giriş vektörünün boyutuna eşittir. Izgaradaki komşu nöronlar benzer ağırlık vektörlerine sahiptirler. SOM ağı, eğitim algoritması olarak girişlerin ağıa teker teker gönderilip, her defasında ağırlıkların güncellendiği *sıralı eğitim* ya da tüm girişler ağıa sunulduktan sonra ağırlıkları güncelleyen *yığın eğitimi* algoritmalarından birini kullanabilir. SOM ağı algoritması vektörler arasındaki uzaklığı ölçmek için *Öklid uzaklık ölçümünü* kullandığından değişkenlerin *normalleştirilmesi* önemlidir. Ağıdaki ağırlık vektörlerinin başlangıç değerleri *lineer* ve ya *rastgele* başlangıç durumuna getirme yöntemleriyle belirlenir. Rastgele başlangıç durumuna getirme yönteminde ağırlık vektörü değerleri değişkenlerin minimum ve maksimum değerleriyle belirlenen d -boyutlu bir küp içinden rastgele seçilir. Lineer başlangıç durumuna getirme yönteminde, eğitim verisinin d -boyutlu minimum-maksimum küpünden ızgara noktaları seçilerek yapılır. Izgara eksenini, eğitim verisindeki m adet en büyük öz (eigen) değere karşılık gelen öz vektörlerdir [112].

Eğitilen SOM ağı komşu harita birimleri arasındaki mesafeleri gösteren *u-matrisi* ile görselleştirilebilir. U-matristeki yüksek değerler küme sınırlarını gösterir. Düşük değerli tekdüze bölgeler ise kümelerin kendisini gösterir. Her bileşen düzlemi, her harita birimindeki bir değişken değerini verir. Bu gösterim en üstünde etiketler gibi

ek bilgiler bulunabilir [112]. Şekil 2.23'te bir u-matris görülmektedir. Şekildeki 1, 2 ve 3, girdi verisindeki üç farklı kümeyi göstermektedir.




Şekil 2.23. U-matris yapısı

SOM ağındaki her nöronun gerçekte biri girdi uzayında ağırlık vektörü olarak, diğeri çıktı uzayında harita ızgarası üzerinde olmak üzere iki pozisyonu vardır. Bu şekilde SOM ağı, girdi uzayından daha düşük boyuttaki çıktı uzayına lineer olmayan bir izdüşümü tanımlayan bir vektör izdüşümü metodudur. Diğer taraftan, eğitim boyunca ağırlık vektörleri girdi verisindeki olasılık yoğunluğunu takip edecek şekilde hareket eder. Bu nedenle SOM ağı aynı zamanda bir vektör nicemleme algoritmasıdır. Vektör nicemleme çok boyutlu verinin daha düşük boyutlarda temsil edilmesidir [111].

SOM ağı algoritmasındaki *komşuluk fonksiyonu* nöronların diğer nöronlarla ne kadar güçlü bağlandığını gösterir. En basit komşuluk fonksiyonu olan *kabarcık komşuluk fonksiyonu* kazanan nöronun tüm komşuluklarında sabit, diğer her yerde sıfırdır. *Gauss komşuluk fonksiyonu* Eş. 2.30'daki gibi uygulanır [112].

$$\exp\left(-\frac{\|r_c - r_i\|^2}{2\sigma^2(t)}\right) \quad (2.30)$$

r_c harita üzerindeki c biriminin yeri, $\sigma(t)$ t anındaki komşuluk yarıçapıdır. Bu eşitlik Şekil 2.23'teki komşuluk kümeleri yerine, harita birimleri arasındaki uzaklığın, $\|r_c - r_i\|$, bir fonksiyonudur. Eğitim fonksiyonları harita üzerindeki uzaklıkları kullanır. Şekil 2.24'te en yaygın kullanılan komşuluk fonksiyonları olan kabarcık ve Gauss görülmektedir. Bu çalışmada Gauss komşuluk fonksiyonu kullanılmıştır.



Şekil 2.24. (a) Kabarcık (b) Gauss komşuluk fonksiyonu

SOM ağlarının diğer YSA türlerine göre otomatik olarak benzerlik diyagramları oluşturabilme avantajı vardır. Orijinal veri kümesi içindeki nesnelere arasındaki ilişkiyi koruyarak yüksek boyutlu girdi verisini daha düşük boyuta (genellikle iki boyut) haritalama özelliğine sahiptir. SOM ağı girdi verisinin hem dağılımını hem de topolojisini öğrenir. Ağ girişindeki topolojik ilişkileri korur ve komşu girdileri komşu nöronlara haritalar. Tüm bu avantajları nedeniyle bu çalışmada beyin MR görüntülerini bölütlemek için SOM ağı kullanılmıştır.

2.11. Öğrenmeli Vektör Nicemleme

Vektör Nicemleme (Vector Quantization-VQ) ve SOM ile yakından ilişkili olan LVQ yönteminin LVQ1, LVQ2, LVQ3 ve OLVQ1 gibi çeşitli algoritmaları mevcuttur.

2.11.1. Vektör nicemleme

VQ giriş veri vektörlerinin $x \in \mathfrak{R}^n$ dağılımının nicelenmiş bir yaklaşımını, sonlu sayıda ağırlık vektörlerini $m_i \in \mathfrak{R}^n, i = 1, 2, \dots, k$ kullanarak oluşturan klasik bir sinyal yaklaştırma metodudur. Ağırlıklar seçildikten sonra x 'in yaklaştırılması, girdi uzayındaki x 'e en yakın ağırlık vektörü m_c 'nin Öklid metriğine göre Eş. 2.31 ve ya Eş. 2.32'deki gibi bulunması demektir;

$$\|x - m_c\| = \min_i \{\|x - m_i\|\} \quad (2.31)$$

$$c = \arg \min_i \{\|x - m_i\|\}. \quad (2.32)$$

Bozunum ölçüsü de denilen niceleme hatasının karesinin beklenen ortalama değerini en aza indirecek m_i 'nin en uygun seçimlerinden biri Eş. 2.33'teki gibi tanımlanır;

$$E = \int \|x - m_c\|^2 p(x) dx \quad (2.33)$$

Burada integral x uzayının tamamı üzerinden alınmaktadır, $p(x)$ ise x 'in olasılık yoğunluk fonksiyonudur [61, 113].


Voronoi Gösterimi

Voronoi Gösterimi, VQ metotlarının desen tanıma ve sinir ağlarındaki gösterimi için kullanılan genel bir kavramdır. Şekil 2.25 sonlu sayıda ağırlık vektörünün koordinatlarının noktalar halinde gösterildiği iki boyutlu uzayı örneklemektedir. Bu uzay bölgelere bölünmüş ve çizgilerle sınırlandırılmıştır. Her bölüm, aynı bölüm içinde bulunan herhangi bir vektörün en yakın komşu olan bir referans vektörü

içermektedir. Noktalar ve çizgiler (komşu referans vektörlerinin sınırları) birlikte Voronoi gösterimini oluşturmaktadır [61].

Voronoi Kümesi

En yakın komşu olarak belirli bir referans vektörüne sahip olan tüm x vektörleri, Voronoi gösterimindeki belirli bir bölgeye denk gelen tüm x vektörleri, Voronoi kümesini oluşturmaktadır.



Şekil 2.25. İki boyutlu desen uzayını (ξ_1, ξ_2) koordinat sistemindeki noktalar olarak gösterilen, referans vektörler etrafındaki bölgeler şeklinde parçalara ayıran bir Voronoi gösterimi. Aynı bölümdeki tüm vektörler (ξ_1, ξ_2) en yakın komşuları olarak aynı referans vektörünü gösterirler.

2.11.2. Öğrenmeli vektör nicemleme

LVQ, VQ ve SOM ağı ile yakından ilişkilidir. VQ ve SOM ağı danışmansız kümeleme ve öğrenme metotlarını kullanırken, LVQ danışmanlı öğrenme yöntemi kullanır. Diğer taraftan SOM ağından farklı olarak LVQ'da öğrenme boyunca "kazanan"ın etrafındaki komşuluklar tanımlanmaz. Bu nedenle ağırlık vektörlerinin herhangi bir uzaysal düzende olması da beklenmez.

LVQ bir istatistiksel sınıflama ve ya tanıma metodu olduğu için tek amacı girdi veri uzayındaki sınıf bölgelerini tanımlamaktır. Bu amaçla, benzer şekilde etiketlenmiş ağırlık vektörlerinin her bir alt kümesi bir sınıf bölgesi içerisine yerleştirilir. Bu algorithmada, giriş örneklerinin sınıf dağılımları sınıf sınırlarında örtüşse bile her

sınıfın ağırlık vektörleri belirli bir sınıf bölgesine yerleştirilebilir. Nicemleme kümeleri, VQ'deki Voronoi kümeleri gibi, komşu ağırlık vektörleri arasındaki sınır ile tanımlanır [61, 113].

LVQ1

Eğer çok sayıda ağırlık vektörü bir x sınıfına atanmışsa, bu durumda x 'in kendisine en yakın m_i ile aynı sınıfta olduğu tespit edilir. x 'e en yakın m_i 'nin indeksi Eş. 2.32'deki gibi tanımlanır;

Burada “kazanan”ın indeksi olan c , x 'e ve tüm m_i 'lere bağlıdır. Eğer x doğal, rastgele, sürekli değerli vektörel bir değişkense çok sayıdaki minimum değeri incelemek gerekmez. Bu durumda $i \neq j$ için $\|x - m_i\| = \|x - m_j\|$ olasılığı sıfırdır.

$x(t)$ bir giriş örneği ve $m_i(t)$ ise m_i 'nin $t = 0, 1, 2, \dots$ ayrık düzlemindeki ardışık değerleri olsun. Uygun şekilde tanımlanmış başlangıç değerleri ile başladığında Eş. 2.34 - Eş. 2.36 temel LVQ işlemini tanımlamaktadır. Eğer x ve m_c aynı sınıfa ait ise Eş. 2.29, farklı sınıflara ait ise Eş. 2.35 ve eğer $i \neq c$ ise Eş. 2.36 kullanılarak ağırlık vektörleri güncellenir. Bu algoritmaya LVQ1 denmektedir.

$$m_c(t+1) = m_c(t) + \alpha(t)[x(t) - m_c(t)] \quad (2.34)$$

$$m_c(t+1) = m_c(t) - \alpha(t)[x(t) - m_c(t)] \quad (2.35)$$

$$m_i(t+1) = m_i(t) \quad (2.36)$$

Burada $0 < \alpha(t) < 1$ 'dir ve $\alpha(t)$ öğrenme oranı genellikle zamanla monotonik olarak azaltılır. α 'nın başlangıçta 0,1'den daha küçük bir değer olması önerilmektedir. Öğrenme adımlarının sayısı yeterli olduğu sürece $\alpha(t)$ lineer olarak sıfıra düşürülebilir. Eğer öğrenme örneklerinin yalnızca sınırlı bir kümesi mevcutsa, döngüsel olarak uygulanabilirler ve örnekler algoritmaya öğrenme örneklerinin temel kümesi içinden rastgele seçilerek sunulabilir [61, 111].

LVQ2

LVQ1 algoritmasına benzer. Ancak öğrenme aşamasında x 'e en yakın komşu olan *iki* ağırlık vektörü, m_i ve m_j , eş zamanlı olarak güncellenir. Bunlardan birinin (m_i) doğru sınıfa değerinin ise (m_j) yanlış sınıfa ait olması gerekmektedir. Bunun da ötesinde x , m_i ve m_j 'nin sınırı civarında tanımlanmış bir “pencere” alanı içerisindeki değerler arasında yer almalıdır.

d_i ve d_j , x 'in m_i ve m_j 'ye olan Öklid uzaklıkları olsun. Bu durumda x , eğer Eş. 2.37 sağlanırsa görece w genişliğindeki bir pencere içerisine denk düşer;

$$s = \frac{1-w}{1+w} \text{ iken, } \min\left(\frac{d_i}{d_j}, \frac{d_j}{d_i}\right) > s \quad (2.37)$$

w pencere genişliği için 0,2 ile 0,3 aralığındaki değerler önerilmektedir.

Orijinal LVQ2 algoritmasının geliştirilmiş bir versiyonu olan LVQ2.1 algoritmasında m_i ya da m_j 'den herhangi birinin x 'e en yakın ağırlık vektörü olmasına izin verilmektedir. Orijinal LVQ2 algoritmasında m_i en yakın olmak zorundadır. LVQ2.1 algoritması Eş. 2.38 ve Eş. 2.39'daki gibi ifade edilebilir;

$$m_i(t+1) = m_i(t) - \alpha(t)[x(t) - m_i(t)] \quad (2.38)$$

$$m_j(t+1) = m_j(t) + \alpha(t)[x(t) - m_j(t)] \quad (2.39)$$

Burada m_i ve m_j , x 'e en yakın iki ağırlık vektörüdür. x ve m_j aynı sınıfa aitken, x ve m_i farklı sınıflara aittir. Bunun da ötesinde x “pencere” içindeki değerlere denk düşmelidir [61, 111].

LVQ3

LVQ2 algoritması karar sınırlarının Bayesian limitleri boyunca diferansiyel olarak kaydırılması fikrine dayanır. Bu işlem devam ettirilirse uzun çalışmalar sonunda m_i 'nin yerine ne olacağı ile ilgilenilmemektedir. Bu nedenle m_i 'nin ya da $f(x)$ 'in sınıf

dağılımlarına yaklaştırılmaya devam ettiğini garanti eden düzeltmeler yapılması gereklidir. LVQ3 algoritması Eş. 2.40 ve Eş. 2.41'deki gibidir.

$$m_i(t+1) = m_i(t) - \alpha(t)[x(t) - m_i(t)] \quad (2.40)$$

$$m_j(t+1) = m_j(t) + \alpha(t)[x(t) - m_j(t)] \quad (2.41)$$

Burada m_i ve m_j , x 'e en yakın iki ağırlık vektörüdür. x ve m_j aynı sınıfa aitken, x ve m_i farklı sınıflara aittir. Bunun da ötesinde x “pencere” içindeki değerlere denk düşmelidir.

Eğer x , m_i ve m_j , aynı sınıfa ait ise $k \in \{i, j\}$ için Eş. 2.42 kullanılır.

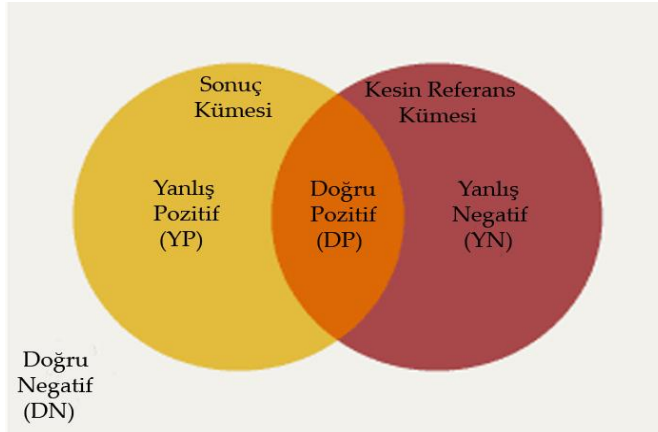
$$m_k(t+1) = m_k(t) + \varepsilon \alpha(t)[x(t) - m_k(t)] \quad (2.42)$$

Çeşitli denemeler sonucunda $w = 0,2$ veya $0,3$ iken ε 'nin uygulanabilir değerleri $0,1$ ile $0,5$ aralığında bulunmuştur. ε için en uygun değer pencere boyutlarına bağlıdır, daha dar pencerelerde daha küçük olmalıdır. Bu algoritma kendini dengede tutmaktadır, yani m_i 'nin en uygun yeri öğrenme devam ettiği sürece değişmeyecektir [61].

Bu çalışmada, SOM ağı danışmansız öğrenme işlemini tamamladıktan sonra, LVQ kullanılarak ağdaki nöronlar problem için en iyi yerleşimi bulmak amacıyla girdi verileri kullanılarak kalibre edilmiştir. LVQ yöntemi ile girdi uzayındaki sınıf bölgelerini tanımlamak için girdi örneklerinin sınıf dağılımlarının sınırlarında çakışmalar olsa bile benzer şekilde etiketlenmiş ağırlık vektörleri sınıflara yerleştirilmektedir. Danışmanlı öğrenme işlemine LVQ1 ile başlanıp sistemin tanıma doğruluğunu arttırmak üzere LVQ3 ile devam edilmiştir.

2.12. Performans Değerlendirme Ölçütleri

Beyin görüntülerinin bölütlenmesinde kullanılan algoritmaların performansını karakterize etmek nöroanatomik yapıların karmaşıklığı, görüntülemenin kalitesi ve doğru bölütleme ihtiyacından dolayı süregelen bir zorluktur. Bölütleme algoritmalarının performansını değerlendirmek için genellikle duyarlılık, belirlilik, *Jaccard* (*Tanimoto* olarak da bilinir) benzerlik indeksi ve *Dice* benzerlik indeksi kullanılmaktadır. Bu indeksler sonuç kümesi ile kesin referans kümesinin uzaysal örtüşmesinin bir ölçüsü olan bölge tabanlı katsayılardır [84].



Şekil 2.26. Sonuçların kesin referans ile örtüşme durumu

A , kesin referans görüntüsünden bilinen ve B bölütleme sonucunda elde edilen bir dokuya ait n adet ikili etiket değerlerini içeren iki küme ise, performans değerlendirme ölçütleri A ve B 'nin örtüşmesini ölçmek için kullanılabilir. A ve B 'deki her bir etiket niteliğinin değeri 0 ve ya 1 olabilir. A ve B 'deki etiket niteliklerinin kombinasyonları ile ilgili elde edilebilecek bilgiler; *Doğru Pozitif (DP)*; A ve B 'nin her ikisinde de değeri 1 olan niteliklerin toplam sayısı, *Yanlış Negatif (YN)*; A 'daki değeri 1 ve B 'deki değeri 0 olan niteliklerin toplam sayısı, *Yanlış Pozitif (YP)*; A 'daki değeri 0 ve B 'deki değeri 1 olan niteliklerin toplam sayısı, *Doğru Negatif (DN)*; A ve B 'nin her ikisinde de değeri 0 olan niteliklerin toplam sayısıdır (Şekil 2.26).

Her bir nitelik bu dört kategoriden birine ait olmak zorundadır (Eş. 2.43)

$$N = DP + YN + YP + DN \quad (2.43)$$

Buna göre Jaccard benzerlik indeksi A ve B kümelerinin kesişim alanının birleşim alanına bölünmesinin oranı olarak Eş. 2.44'deki gibi hesaplanır [85, 114].

$$Jaccard = \frac{|A \cap B|}{|A \cup B|} = \frac{|A \cap B|}{|A| + |B| - |A \cap B|} = \frac{DP}{YN + YP + DP} \quad (2.44)$$

Kappa istatistiği olarak da bilinen bir güvenilirlik ölçütünden türetilen Dice benzerlik indeksi ise kesişim alanının, her bir ayrı alanın ortalama toplamına bölünmesinin oranı olarak hesaplanır (Eş. 2.45) [85, 114].

$$Dice = 2 \frac{|A \cap B|}{|A| + |B|} = \frac{2 \times DP}{(2 \times DP) + YP + YN} \quad (2.45)$$

Duyarlılık (sensitivity) ve belirlilik (specificity) sınıflama işlemlerinde kullanılan istatistiksel performans ölçütleridir. Duyarlılık doğru olarak tanımlanan gerçek pozitif oranını, örneğin el ile beyaz cevher olarak işaretlenmiş bir alanın sistem tarafından da beyaz cevher olarak bulunma oranı ölçer (Eş. 2.46). Bu değer doku bölütlemesinin ne oranda başarı ile gerçekleştirildiğini belirler. Belirlilik ise doğru olarak bulunan negatiflerin oranını vermektedir (Eş. 2.47). Örneğin beyaz cevher olmayan dokuların sistem tarafından da beyaz cevher değil şeklinde bulunmasının oranıdır.

$$Duyarlılık = \frac{DP}{DP + YN} \quad (2.46)$$

$$Belirlilik = \frac{DN}{DN + YP} \quad (2.47)$$

2.13. Yazılım Geliştirme Ortamı

Bu tez çalışması kapsamında beyin MR görüntülerini bölütleyecek yazılım sisteminin geliştirilmesinde yazılım geliştirme ortamı olarak MATLAB kullanılmıştır. Görüntülerden özellik çıkartmak için kullanılan dalgacık dönüşümü yöntemi *Wavelet Toolbox* aracı ve bu özellik vektörüne göre görüntüleri içerdikleri farklı doku türlerine bölütleyecek SOM ağının oluşturulmasında internet üzerinden ücretsiz olarak erişilip kullanılabilen *SOM Toolbox for MATLAB* yazılım paketi [111] kullanılmıştır. Yazılım sistemi için gereken fonksiyonların geliştirilmesinde *MATLAB Compiler*'ın yanında görüntü analizinin çeşitli aşamalarında *Image Processing Toolbox*, *Statistics Toolbox* ve *Signal Processing Toolbox* araçları da kullanılmıştır. Yüksek çalışma hızına sahip 64 bitlik MATLAB yazılım paketi ve kullanılan araçlar Gazi Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından desteklenen “07/2009-04” kodlu ve “Beyin MR Görüntülerinin Dalgacık Dönüşümü ve Özörgütlemeli Harita Ağları Kullanılarak Bölütlenmesi” isimli Bilimsel Araştırma Projesi kapsamında satın alınmıştır.


3. GELİŞTİRİLEN ALGORİTMALAR

3.1. Görüntülerde Beyin Bölgesinin Bulunması

Klinik uygulamalarda, beyin görüntülerinin bölütlenmesinde ilgilenilen bölgeler gri cevher, beyaz cevher, BOS alanları şeklindeki sağlıklı dokular ile tümör, ödem gibi hastalıklı beyin dokularıdır. Beyin görüntülerinin bu doku türlerine sınıflanması klinik uygulamalar için yeterlidir. Beyin görüntülerinde bulunan sağlıklı ve hastalıklı dokular dışında kalan deri, kafatası, yağ, kas, bağ doku gibi bölümler, özel durumlar dışında doktorlar tarafından bölütlenmemekte ve kullanılmamaktadır. Bu nedenle geliştirilen bölütleme sisteminde de bu bölümler ile ilgilenilmemektedir. Bu amaçla beyin bölütleme işlemine geçmeden önce beyin yumuşak dokuları dışında kalan kısımlar beyin görüntülerinden çıkarılmıştır. Bu işleme görüntülerden kafatası alanının çıkartılması (skull stripping) veya tüm beyin bölütleme denmektedir.

J.-M. Lee ve arkadaşları, yaptıkları çalışmada beyin bölgesini bulmak için kullanılan otomatik ve yarı-otomatik metotları, benzetim görüntüleri ve gerçek görüntüler üzerinde gösterdikleri performansa göre karşılaştırarak değerlendirmişlerdir [115]. Otomatik metotlar etkili sonuçlar verse de ek müdahaleler ile düzeltmeler gerektirmektedir. Bunun aksine yarı otomatik yöntemler daha doğru sonuçlar vermektedir, fakat bu yöntemler daha çok zaman almaktadır ve operatörün etkisine bağlıdır. Bu nedenle, yarı-otomatik bir yöntem kullanmak, otomatik bir yöntem kullanarak görüntü üzerinde sonradan işlem yapmaya göre daha pratiktir [115].

Bu çalışmada, görüntülerden beyin dokusu dışındaki alanların çıkartılması için eşikleme ve morfolojik işlemleri birleştiren ve farklı beyin MR görüntü çeşitleri ile birlikte çalışabilen yarı-otomatik bir algoritma geliştirilmiştir. Geliştirilen algoritmanın işlem adımları Şekil 3.1’de verilmiştir.



Şekil 3.1. Beyin bölgesini bulan algoritmanın işlem adımları

Gauss alçak geçiren filtresi yumuşatma filtrelerindedir. Büyük nesnelere ortaya çıkartılması öncesinde küçük detayların kaldırılması ve gürültü bastırma amaçlı kullanılır. Algoritmada kullanılan Gauss filtre parametreleri olan 5×5 filtre boyutu ve 0,7 standart sapma değeri yapılan denemeler sonucunda bulunan en uygun rakamlardır.

Algoritmada gerekli olan genel eşik değerinin tespit edilmesi aşamasında tek bir sabit eşik değeri tespit etmek mümkün olmamaktadır. Hastanın MR görüntüsü içinde göz gibi parlak alanlar olup olmamasına göre eşik değeri büyük farklılıklar gösterebilmektedir. Bu nedenle görüntü içinden beyin bölgesini gösteren alanın bulunabilmesi için farklı görüntü çeşitleri ile çalışabilen ve eşik değeri değiştirildiğinde elde edilecek sonucun önizlemesini veren bir grafik arayüz hazırlanmıştır. Bu grafik arayüz içerisinde orijinal MR görüntüsü ile birlikte görüntünün histogram dağılımı görülmektedir. Histogram üzerine yerleştirilen bir ibre hareket ettirilerek eşik değeri seçilebilmektedir. Görüntüde seçilen eşik değerinden büyük gri seviyesine sahip piksellere 0 değeri atanmakta, daha sonra görüntüye Otsu yöntemi ile eşikleme uygulanmaktadır. Otsu metodunda, görüntünün normalleştirilmiş histogramı üzerinden sınıflar arasındaki varyans en fazla olacak şekilde bir eşik değeri seçilir. Eşik değeri $[0 \ 1]$ aralığında normalleştirilmiş bir değerdir. Eşikleme işleminin ardından görüntü eşik değeri kullanılarak siyah-beyaz formata getirilmektedir.

Algoritmada beyin ve diğer dokular arasındaki bağlantıları kaldırmak için morfolojik görüntü işleme yöntemleri kullanılmıştır. Morfolojik görüntü analizi işlemlerinden biri olan *genişleme* (dilation), görüntüdeki nesnelere kalınlaştıran ya da büyüten bir işlemdir. Bu kalınlaştırma işlemi *yapı elemanı* (structuring element) adı verilen dikdörtgen, yuvarlak ya da altıgen gibi farklı geometrilerde olabilen bir şekil ile kontrol edilir. *Aşınma* (erosion) işlemi ise görüntüde bulunan nesnelere inceltmesi ya da küçültülmesidir. Aşınma işlemi de bir yapı elemanı ile kontrol edilmektedir. Genişleme ve aşınma işlemlerinin birleştirilmesi ve aynı ya da farklı yapı elemanları kullanılarak bu işlemlerin arka arkaya uygulanması ile görüntüler üzerinde çeşitli dönüşüm işlemleri gerçekleştirilmektedir. Görüntü A ve yapısal eleman B ile temsil

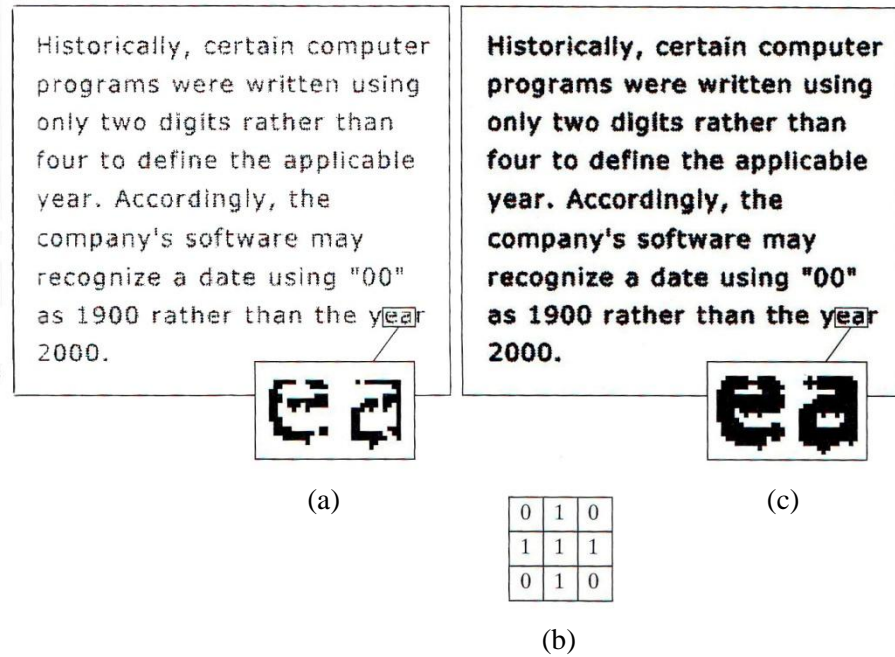
edilirse genişleme işlemi Eş. 3.1 ve aşınma işlemi ise Eş. 3.2'deki gibi ifade edilir [38, 101].

$$A \oplus B = \{z | (\hat{B})_z \cap A \neq \emptyset\} \quad (3.1)$$

$$A \ominus B = \{z | (\hat{B})_z \cap A^c \neq \emptyset\} \quad (3.2)$$

Burada \emptyset boş kümeyi ve A^c A görüntüsünün tümleyenini temsil etmektedir. A ve B kümelerinin genişlemesi, yansıması alınan ve z kadar ötelenen B 'nin A ile en az bir noktada örtüştüğü yerlerdeki yapısal eleman merkez noktası konumlarının tümünü içeren kümedir.


Şekil 3.2'de genişleme işlemine bir örnek verilmiştir.



Şekil 3.2. (a) Bozuk karakterler içeren düşük çözünürlükteki örnek metin ve büyütülmüş görünüm, (b) yapısal eleman, (c) (a)'nın (b) ile genişletilmesi hali ve büyütülmüş görünüm.

A kümesinin B kümesi ile aşındırılması ise ötelenmiş B 'nin A görüntüsünün arka planı ile hiçbir örtüşmesinin bulunmadığı yerlerdeki yapısal eleman merkez noktası

konumlarının tümünü içeren kümedir. Şekil 3.3'te aşınma işlemine bir örnek verilmiştir.



Şekil 3.3. (a) Orijinal görüntü, (b) 10 yarıçapındaki bir disk ile aşındırma, (c) 5 yarıçapındaki bir disk ile aşındırma, (d) 20 yarıçapındaki bir disk ile aşındırma


Aşınma işlemi takiben genişleme işleminin uygulanmasına *morfolojik açma* (opening), genişleme işlemi takiben aşınma işleminin uygulanmasına ise *morfolojik kapatma* (closing) denmektedir. Morfolojik açma, bir nesnenin yapı elemanını tamamen içine alamayan bölgelerini çıkarır, nesnelerin dış hatlarını yumuşatır, zayıf bağlantıların arasını açar ve zayıf çıkıntıları görüntüden çıkarır. Morfolojik kapama, açma işleminde olduğu gibi nesnelerin dış hatlarını yumuşatma eğilimindedir. Fakat açma işleminden farklı olarak dar açıklıkları birleştirir, uzun, ince körfezleri doldurur ve yapı elemanından küçük olan boşlukları doldurur. Morfolojik olarak açılmış bir görüntü orijinal görüntüden çıkarılırsa *top-hat dönüşüm* elde edilir. Benzer şekilde

görüntünün morfolojik kapanışından orijinal görüntü çıkarıldığında *bottom-hat dönüşüm* elde edilmiş olur. Bu iki dönüşüm bir arada kullanılarak kontrast iyileştirmesi gerçekleştirilir [38, 101].


Morfolojik işlemlerin ardından görüntüde bulunan nesnelerin tanınması işlemine geçilmiştir. Burada nesnelerin dış hat sınırları taranarak sınır piksellerine ait koordinatlar tespit edilmiştir. Bulunan nesneler içinde kafatası alanı en büyük çevreye sahip nesnedir. Fakat morfolojik işlemler ile kafatası ve beyin arasındaki bağlantılar açıldığından arada bir boşluk oluşmuştur. Bu nedenle içinde boşluk bulundurmayan en büyük çevreye sahip nesne beyin bölgesi olmaktadır. Beyin bölgesi içi bir ve dışı sıfır değeri ile doldurularak bir maske görüntüsü elde edilmiştir. Maske görüntüsünün T1-ağırlıklı, T2-ağırlıklı ve FLAIR MR görüntüleri ile çarpılması sonucunda görüntülerde sadece beyin bölgesi bırakılmıştır.

Algoritmadan elde edilen sonuç görüntüsü eşik değeri seçimi ile aynı anda ekranda görülebilmektedir. Şekil 3.4 ve Şekil 3.5'te bu grafik arayüz kullanılarak A6 ve B7 numaralı iki farklı hastanın görüntüsü üzerinden farklı eşik değerleri ile elde edilen sonuçlar gösterilmektedir.

Algoritmada genel bir eşik değerinin tespit edilmesi aşamasında tek bir sabit eşik değeri tespit etmek mümkün olmamaktadır. Hastanın MR görüntüsü içinde göz gibi parlak alanlar olup olmadığına göre eşik değeri büyük farklılıklar gösterebilmektedir. Seçilen eşik değerine göre hastalardan elde edilen sonuçlar Şekil 3.4 ve Şekil 3.5'te verilmiştir.




(a)




(b)

Şekil 3.4. A6 numaralı hasta için (a) eksik bölütlenmiş, (b) doğru bölütlenmiş beyin bölgesi



(a)



(b)


Şekil 3.5. B7 numaralı hasta için (a) aşırı bölütlenmiş, (b) doğru bölütlenmiş beyin bölgesi

Bu çalışmada geliştirilen, beyin MR görüntülerinde beyin bölgesini bularak kafatası alanını görüntülerden çıkararak algoritma, daha önce geliştirilmiş tanınmış algoritmalar olan Brain Surface Extractor (BSE) [116], Brain Extraction Tool (BET) [117], BET2, BrainVisa [118] ve FreeSurfer [119] ile duyarlılık, belirlilik ve Jaccard benzerlik indeksine göre karşılaştırılmıştır [120, 121]. Tüm yöntemler T1-ağırlıklı MR görüntüleri ile bu görüntülerin elle bölütlenmiş hallerini içeren ve Bölüm 2.2’de ayrıntıları verilen IBSR veritabanı [82] üzerinde gösterdikleri performansa göre değerlendirilmiştir. Çizelge 3.1’de geliştirilen algoritmanın performansı diğer yöntemlerin performansları ile IBSR veritabanındaki 205_3 numaralı hasta için karşılaştırılmıştır. Çizelgedeki rakamlar incelendiğinde geliştirilen algoritmanın BSE ile yakın sonuçlar gösterirken diğer yöntemlere göre daha başarılı olduğu görülmektedir.

Çizelge 3.1. Geliştirilen algoritma ile diğer yöntemlerin performanslarının karşılaştırması

	BSE	BET	BET2	BrainVisa	FreeSurfer	Geliştirilen algoritma
Jaccard	0,9256	0,7107	0,9219	0,8217	0,8974	0,9252
Duyarlılık	-	-	0,9894	0,8252	1,00	0,9877
Belirlilik	-	-	0,9916	0,9995	0,9869	0,9917

Şekil 3.6’da IBSR veritabanındaki 205_3 numaralı hastanın verileri üzerinde geliştirilen yöntem ve diğer yöntemler ile elde edilen sonuçlar görsel olarak verilmiştir [121]. Şekil 3.6’dan görülebileceği gibi BrainVisa yöntemiyle elde edilen bölütlemelerde beyin bölgesinde pek çok boşluk oluşmuştur. BET ve FreeSurfer yöntemleri ise beyin bölgesine ait olmayan alanları da görüntü içinde bırakmıştır. Çizelge 3.1 ve Şekil 3.6 incelendiğinde geliştirilen algoritmanın beyin MR görüntülerinde beyin bölgesinin bulunmasında başarılı olduğu görülmektedir.



Şekil 3.6. IBSR veritabanı (205_3) için bölütleme sonuçları (a) orijinal görüntü, (b) elle bölütlenmiş kesin referans görüntüsü, (c) BrainVisa sonucu, (d) BET sonucu, (e) FreeSurfer sonucu ve (f) geliştirilen algoritma ile elde edilen sonuç

3.2. Özörgütlemeli Harita Ağının Kümelenmesi ve Etiketlenmesi

SOM ağlarını kullanarak görüntü bölütlemesi yapan çalışmalarda iki aşamalı bir yaklaşım uygulanmaktadır. İlk aşamada SOM ağı ile eğitim yapıldıktan sonra ikinci aşamada SOM ağına dayalı olarak verinin kümelenmesi gerçekleştirilir. İlk aşamada çıkış nöronlarının sayısının, verinin nicel analizini kolaylaştırmak için arzu edilen küme sayısından daha fazla olması gerekmektedir. İkinci aşamada SOM ağı tarafından gerçekleştirilen eğitimin ardından çıkış nöronları kümelenir. Bu yaklaşımın en önemli faydası işlem yükünü önemli ölçüde azaltması ve büyük veri kümelerini kümelemeyi mümkün kılmasıdır [122, 123].

SOM ağının çıkışını kümelemek için pek çok farklı yöntem kullanılmakla birlikte beyin MR görüntülerini bölütleyen çalışmalar benzer çıkış nöronlarını kümelemek

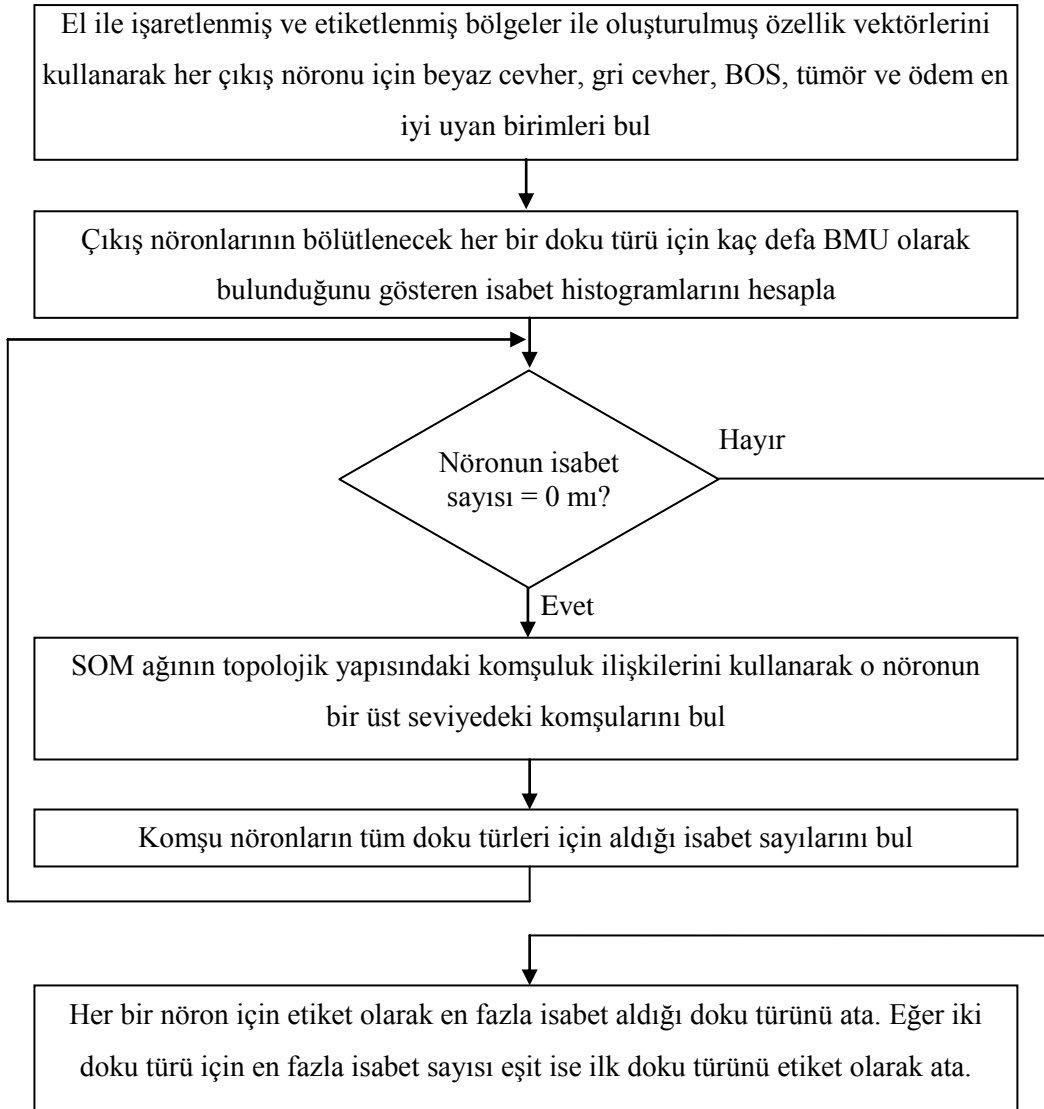
için genellikle ek bir YSA kullanılmışlardır [10, 11, 16]. Bu YSA'da SOM ağının çıkışındaki nöronların ağırlık vektörleri giriş olarak kullanılmaktadır.

Bu çalışmada, SOM ağının çıkışını kümelemek için yeni bir algoritma geliştirilmiştir. Geliştirilen bu algoritma ile ek bir YSA kullanmaya gerek kalmamaktadır. Algoritma SOM ağının eğitim işlemi tamamlandıktan sonra ikinci aşama olarak çalıştırılmaktadır. SOM ağı bölütlenecek doku sayısından daha fazla sayıda çıkış nöronuna sahip olacak şekilde girdi verisine haritalandıktan sonra, ağın çıkış nöronlarının kümelenmesi ve etiketlenmesi için geliştirilen algoritma kullanılmaktadır.

Algoritma danışmanlı bir yol izlemekte, el ile işaretlenmiş ve etiketlenmiş görüntü bölgelerini kullanmaktadır. Beyaz cevher, gri cevher, BOS, tümör ve ödem bölgelerini gösteren alanlar hastaların her birinde ilgilenilen dilim için el ile işaretlenmiştir. El ile bölütleme sayesinde bütün girdi vektörlerinin hangi beyin dokusuna ait olduğu bilinmektedir. Geliştirilen algoritma çıkış nöronlarının bölütlenecek her bir doku türü için kaç defa BMU olarak bulunduğunu gösteren isabet histogramlarına dayanmaktadır.

Algoritma geliştirilirken SOM ağının en önemli özelliklerinden biri olan nöronlar arasındaki komşuluklardan da faydalanılmıştır. Eğer iki özellik vektörü girdi uzayında birbirine yakınsa bunlara karşılık gelen çıkış nöronları da çıkış uzayında birbirine yakın olacaktır ve bunun tersi de geçerlidir. Bu nedenle isabet histogramlarından elde edilen bilgi ağın topolojik yapısında birbirine komşu olan nöronların bilgisiyle birleştirilerek çıkış nöronlarının hangi doku türünü temsil ettiği tespit edilmiştir.

Şekil 3.7'de SOM ağını kümelemek ve etiketlemek için geliştirilen algoritmanın işlem adımları verilmiştir.



Şekil 3.7. SOM ağını kümelemek ve etiketlemek için geliştirilen algoritmanın işlem adımları

4. BULGULAR VE İRDELEME

Bu çalışmada, beyin modeli, sağlıklı kişilere ait beyin MR görüntüleri ve tümörlü hastalara ait beyin MR görüntüleri üzerinde beyin dokularının bölütlenmesi işlemi gerçekleştirilmiştir. Bunun sonucunda beyin modeli ve sağlıklı kişilerin görüntüleri beyaz cevher, gri cevher ve BOS, tümörlü hastalara ait görüntüler ise beyaz cevher, gri cevher, BOS, ödem ve tümör bölgelerine sınıflandırılmıştır. Böylece beyin MR görüntüleri daha kolay anlaşılır ve yorumlanabilir hale getirilerek hekimlere beyin MR görüntülerinin analizinde ve beyinde bulunan tümör ve ödemin teşhisinde yardımcı olabilecek bir sistem geliştirilmiştir.

4.1. Beyin Modeli Bulguları ve İrdeleme

Görüntü analizinden elde edilen sonuçların doğrulanmasında kullanılan ve Bölüm 2.1’de verilen Brainweb veritabanındaki görüntüler beyni 181 dilim halinde göstermektedir. Her bir beyin dilimi için T1-ağırlıklı, T2-ağırlıklı ve PD MR görüntüleri bulunmaktadır. Veritabanı aynı zamanda beynin her dilimi için, bu 3 modalitedeki görüntüler kullanılarak uzman nöro anatomistler tarafından bölütlenmiş kesin referans (ground truth) görüntülerini de içermektedir. Kesin referans görüntüleri kullanılarak, geliştirilen sistemden elde edilen bölütleme sonuçları kolaylıkla değerlendirilebilir.

BrainWeb görüntüleri MINC (Medical Image NetCDF) görüntü formatındadır. NetCDF (Network Common Data Form) dosya formatı isimlendirilmiş, çok boyutlu değişkenlerin makineden bağımsız olarak depolanmasını sağlayan bir yazılım arayüzü sağlar. MINC görüntü formatı, BrainWeb veritabanının geliştirildiği Montreal Nöroloji Enstitüsü’ndeki McConnell Beyin Görüntüleme Merkezi’nde geliştirilmiştir. Bu görüntü formatı MATLAB tarafından doğrudan algılanıp kullanılamamaktadır. Bu nedenle MINC formatının MATLAB içinde kullanılabilmesini sağlayan EMMA (Extensible Matlab Medical Image Analysis) isimli bir araç geliştirilmiştir. Bu araçta bulunan komutlar kullanılarak beynin 181 dilimi için her biri 181 farklı görüntü içeren MINC formatındaki T1-ağırlıklı, T2-


ağırlıklı, PD MR görüntüleri ile birlikte kesin referans görüntüsü MATLAB ortamında okunmuştur. Daha sonra bu dilimler içinden doku yönünden en zengin olanı ve ilgilenilen tüm doku türlerini içeren bir dilim seçilmiş ve çalışmanın bundan sonraki kısmına beynin bu dilimine ait görüntüler kullanılarak devam edilmiştir.

BrainWeb kesin referans görüntüsünde her piksel değeri farklı bir doku türünü temsil etmektedir (Çizelge 4.1). Kesin referans görüntüsünde arka plan, BOS, gri cevher, beyaz cevher ve glial cevher dışındaki kalan dokuların, yani intrakraniyal yapı dışındaki dokuların, piksel değerlerine sıfır atanırsa ilgilenilmeyen dokuların değeri sıfırlanmış olur. Bu işlem ile devam eden işlem aşamalarında ilgilenilmeyen dokulara arka plan muamelesi yapılmaktadır. Kesin referans görüntüsü ile simüle edilmiş T1-ağırlıklı, T2-ağırlıklı ve PD MR görüntüleri aynı koordinatlardaki pikselleri aynı doku türünü göstermektedir. Kesin referans görüntüsünde sıfır değeri atanan piksellere benzetim görüntülerinde de sıfır değeri atanarak ilgilenilmeyen dokuların benzetim görüntülerinde arka plan olarak değerlendirilmesi sağlanmaktadır. Şekil 4.1'de benzetim görüntüleri ve bu görüntülerin beyin bölgesini gösteren halleri verilmiştir.

Çizelge 4.1. Beyin modeli kesin referans doku değerleri

Piksel değeri	Doku türü
0	Arka plan
1	CSF
2	Gri cevher
3	Beyaz cevher
4	Yağ
5	Kas/Deri
6	Deri
7	Kafatası
8	Glial cevher
9	Bağ doku

Brainweb simülatörü, beyinde bulunan glial cevheri ayrı bir sınıf olarak içermektedir. Glial cevher, benzetim görüntülerinde karıncıkların içinde yer alan ince bir yüzey olarak görülmektedir. Yapılan çalışmalarda glial cevher ayrı bir sınıf olarak değerlendirilmeyip beyaz cevher olarak değerlendirilmekte ve bölütlenmektedir [124]. Bu nedenle benzetim görüntülerinde bulunan glial cevher içeren ve değeri 8 olan piksellere 3 değeri atanarak bu bölgelerin beyaz cevher olarak değerlendirilmesi sağlanmıştır.




Şekil 4.1. (a) T1-ağırlıklı, (b) T2-ağırlıklı ve (c) PD MR görüntüleri ile (d), (e) ve (f) bu görüntülerin sadece beyin bölgesini içeren halleri


Özellik çıkartma, görüntü verisine dayalı bilgilendirici değişkenler kümesinin bulunmasıdır. Beyin MR görüntülerinin analizi için doğru ve güvenilir bir bölütleme ancak farklı beyin dokularını en iyi temsil eden özelliklerin seçilmesi ile mümkündür. Dalgacık dönüşümünün genişletilmiş bir sürümü olan dalgacık paketleri yöntemi ile uzay-frekans düzleminin parçalara ayrılması üzerinde daha fazla esneklik sağlanmıştır. Pek çok tıbbi görüntü modalitesi için geliştirilen pratik uygulamalarda

ilgilenilen özellikler ile gürültü özellikleri birbirinden oldukça farklı karakterlere sahiptir ve dalgacık paketleri analizi ile birbirlerinden verimli bir şekilde ayrılabilirler. BrainWeb görüntülerinin bölütlenmesi işleminde özellik çıkarma yöntemi olarak dalgacık paket analizi yöntemi kullanılmıştır.

Dalgacık dönüşümü işlemi için kullanılacak dalgacığın seçilmesi ya da dönüşümün uygulanacağı seviye sayısı standart kurullarla belirlenemediğinden kullanılacak dalgacığı seçmek üzere öncelikle farklı dalgacıklar kullanılarak çeşitli ayrıştırma seviyelerinde dönüşüm uygulanmış ve sonuçlar benzetim görüntüsünde gösterdiği başarı ile değerlendirilmiştir. Yapılan denemeler sonucunda erişilen en yüksek bölütleme doğruluk oranlarına göre bu çalışmada db2 ve db4 dalgacıkları kullanılmışlardır. Şekil 4.2’de db2 ve Şekil 4.3’te db4 dalgacıklarının ölçekleme ve dalgacık fonksiyonları ile bu fonksiyonlara ait ayrıştırma ve yeniden oluşturma filtrelerinin katsayıları verilmiştir. Fonksiyonlar ve katsayıları ait görüntüler MATLAB ortamında üretilmiştir.



Şekil 4.2. Daubechies 2 (db2) dalgacığı



Şekil 4.3. Daubechies 4 (db4) dalgacı

Dalgacık paketi dönüşümü metodu kullanılarak özellik çıkarımı için T1-ağırlıklı, T2-ağırlıklı ve PD MR görüntülerine uygulanan işlem adımları şunlardır;

1. MR görüntülerine farklı dalgacıklar ile çeşitli seviyelerde dalgacık paket dönüşümü uygulanarak dalgacık paket ağacı ve katsayılarının bulunması,
2. Dalgacık paketi ağacı içinden “Shannon”, “logarithm of the "energy" (log energy)”, “threshold” gibi farklı entropi türlerini kullanarak en iyi entropi değerine göre en iyi alt ağacın tespit edilmesi,
3. MR görüntülerinin en iyi dalgacık paketi alt ağacına göre yeniden oluşturulması.

Dalgacık paketi dönüşümünden elde edilen alt görüntüler içinden görüntü özelliklerini en iyi temsil edenleri tespit etmek üzere dönüşümün başlangıç ağacı üzerinden en iyi dalgacık paketi alt ağacı tespit edilmiştir.

Dalgacık dönüşümünden sonra en iyi dalgacık paketi alt ağacı en iyi entropi değerine göre bulunmuştur. Bu çalışmada kullanılan Shannon ve log energy entropi

değerlerinin Eş. 4.1 ve Eş. 4.2'deki gibi hesaplanmaktadır [125]. Burada s sinyalin kendini ve i ise sinyal örneklerini temsil etmektedir.


$$Shannon(s) = - \sum_i s_i \log (s_i^2) \quad (4.1)$$

$$log \ energy(s) = \sum_i \log (s_i^2) \quad (4.2)$$

Bu yöntemle göre ağaç içerisinde bulunan bir N düğümünün $N1$ ve $N2$ şeklinde alt düğümlere ayrılması için $N1$ ve $N2$ alt düğümlerinin toplam entropi değerinin N düğümünün entropi değerinden daha düşük olması gerekmektedir [126]. Bu yalnızca N düğümünden erişilebilen bilgiye bağlı yerel bir kriterdir. Başlangıç T ağacından başlayarak ve bu algoritmanın birleştirme tarafını kullanarak T ağacından elde edilebilecek tüm ikili ağaçlar arasında en iyi ağaç elde edilir.

Şekil 4.4 bir başlangıç dalgacık paketi ağacını ve bu ağaç üzerinden Shannon entropi kullanılarak en iyi entropi değerine göre elde edilen en iyi alt ağaç görüntülerini göstermektedir. BrainWeb benzetim görüntülerini bölütlemeye kullanılan T1-ağırlıklı, T2-ağırlıklı ve PD MR görüntüleri için db2 dalgacığı kullanılarak gerçekleştirilen 3 seviyeli dalgacık paket dönüşümü sonucunda Shannon entropi kullanılarak en iyi entropi değerine göre elde edilmiş en iyi alt ağaç görüntüleri Şekil 4.4 (b, c, d)'de verilmiştir.

Dalgacık paketi alt ağacında bulunan görüntüler kullanılarak görüntüler yeniden oluşturulmuştur. Bu görüntüler ile birlikte orijinal MR görüntüleri bir araya getirilerek özellik vektörü elde edilmiştir. SOM ağında bu özellik vektörü giriş olarak kullanılmıştır. Benzetim görüntülerinde her pikselin hangi doku türüne ait olduğu bilindiğinden etiket olarak bu doku türlerinin isimleri kullanılmıştır. SOM ağı MATLAB için geliştirilmiş olan *SOM Toolbox* kullanılarak oluşturulmuştur [111].



Şekil 4.4. (a) Başlangıç dalgacık paketi analiz ağacı, (b) T1-ağırlıklı, (c) T2-ağırlıklı ve (d) PD MR görüntüleri için en iyi alt ağaç görüntüsü


SOM ağı oluşturulurken öncelikle ağdaki birim sayısının belirlenmesi gerekmektedir. SOM ağındaki çıkış nöronlarının sayısı verideki sapmaları tespit edebilmek için önemlidir. SOM ağındaki çıkış nöronlarının sayısı Vesanto ve diğerleri tarafından önerilen sezgisel kural kullanılarak seçilmiştir [112]. Bu kurala göre harita birimlerinin en uygun sayısı $5\sqrt{n}$ 'dir. Burada n , eğitim örneklerinin sayısıdır. Ağın boyutlarının belirlenmesi için eğitim verisinde bulunan en büyük iki öz değer

arasındaki oran hesaplanmıştır ve ağı kenar uzunlukları olarak atanmıştır. SOM ağı rastgele başlangıç durumuna getirme yöntemine göre, ağırlık vektörü değerleri değişkenlerin minimum ve maksimum değerleriyle belirlenen d -boyutlu bir küp içinden rastgele seçilerek başlangıç durumuna getirilmiştir. Ağ başlangıç durumuna getirildikten sonra eğitim kaba ve ince ayar olmak üzere iki aşamada gerçekleştirilmiştir. Ağın eğitilmesi için ardışık eğitime göre daha hızlı çalışan toplu eğitim yöntemi tercih edilmiştir. Ağ, dokuların ait olduğu farklı sınıf kimlikleri dikkate alınarak eğitilmiştir. SOM ağından alınan sonuçlar kesin referans görüntüsü ile karşılaştırılmış ve doku türlerini ait olduğu sınıflara bölütleme hatası hesaplanmıştır. Bölütlenmiş MR görüntüsü SOM ağı tarafından otomatik olarak etiketlenen veri kullanılarak oluşturulmuştur.

Çizelge 4.2. Çeşitli dalgacıklar ile farklı ayırıştırma seviyelerinden elde edilen bölütleme performansı

Dalgacık Türü	Ayırıştırma Seviyesi	Entropi Türü	Doğruluk (%)
db2	2	Shannon	98,27
db2	3	Shannon	98,64
db2	4	Shannon	98,29
db2	2	log energy	98,39
db2	3	log energy	98,40
db2	4	log energy	98,49
db4	2	Shannon	98,42
db4	3	Shannon	98,40
db4	4	Shannon	98,41
db4	2	log energy	98,28
db4	3	log energy	98,56
db4	4	log energy	98,32

Farklı dalgacık fonksiyonları, ayırıştırma seviyeleri ve entropi türleri için sistemden elde edilen bölütleme sonuçları Çizelge 4.2’de verilmiştir. Tablodaki rakamlar kesin referans görüntüsü ile sistemden elde edilen bölütlenmiş görüntünün piksellerinin birebir karşılaştırılması ile bulunan doğruluk değerinin yüzde olarak verilmiş halidir.



Şekil 4.5. (a) Kafatası çıkarılmış kesin referans görüntüsü, (b) (a)'nın renklendirilmiş hali, (c) Bölütlenmiş görüntü, (d) (c)'nin renklendirilmiş hali

Çizelge 4.2'den de görüldüğü üzere en iyi bölütleme performansları db2 dalgacığı ile 3 seviyede gerçekleştirilen ve Shannon entropi metodunun kullanıldığı durumda elde edilmiştir. Şekil 4.5'de kesin referans görüntüsü ile %98,64 oranında doğru bölütlenmiş görüntü verilmiştir. Çizelge 4.3'te arka plan, beyaz cevher, gri cevher ve BOS için elde edilen Jaccard ve Dice benzerlik indeksleri verilmiştir.

Çizelge 4.3. Jaccard ve Dice benzerlik indeksleri

Doku Türü	Jaccard	Dice
Arka plan	99,92	99,96
BOS	92,96	96,35
Gri cevher	91,88	95,77
Beyaz cevher	96,95	98,45

4.2. Sağlıklı Beyin MR Görüntüleri Bulguları ve İrdeleme

Eğitim ve Test Verisinin Oluşturulması


Sağlıklı kişilere ait beyin MR görüntülerini bölütleme için Bölüm 2.2’de ayrıntıları verilen IBSR veritabanı kullanılmıştır. IBSR veritabanındaki veri kümeleri çeşitli zorluk seviyelerindedir ve düşük kontrastlı taramalar içermektedir. Görüntüler büyük oranda homojen değildir. Çizelge 4.4’te IBSR veritabanında bulunan eğitim ve test işlemlerinde kullanılan görüntüler ve içerdikleri dilim sayıları verilmiştir.

Çizelge 4.4. Eğitim ve test işlemlerinde kullanılan IBSR veri kümeleri


Eğitim işleminde kullanılan IBSR veri kümesi	İçerdiği dilim sayısı	Test işleminde kullanılan IBSR veri kümesi	İçerdiği dilim sayısı
1_24	65	2_4	65
4_8	61	5_8	60
6_10	63	7_8	60
8_4	63	11_3	63
12_3	63	13_3	63
15_3	60	16_3	60
17_3	63	100_23	63
110_3	64	111_2	63
112_2	63	191_3	63
202_3	63	205_3	63

IBSR veritabanındaki 10 kişiye ait görüntüler eğitim amaçlı kullanılırken kalan 10 kişi ise sistemin test edilmesinde kullanılmıştır. Çizelge 4.4’ten de görülebileceği gibi IBSR görüntüleri ortalama yaklaşık 60 dilim içermektedir. Bu nedenle eğitim ve test verileri oluşturulurken bu dilimlerden her kişiye ait ortada bulunan 30. dilim seçilmiştir. Veritabanı beyin görüntülerinin sadece ilgilenilen kısımlarını içeren ve diğer kısımları atılmış hallerini ve bu görüntülerin elle bölütlenmiş hallerini içermektedir. Bölütleme işleminde sadece beyin bölgesini gösteren ve elle


bölütlenmiş bu görüntüler kullanılmıştır. Şekil 4.6 ve Şekil 4.8’de eğitim veri kümesi verilerinin ve Şekil 4.8’de test verilerinin örnekleri gösterilmiştir.



Şekil 4.6. 1_24 eğitim veri kümesinden 30. dilime ait (a) ham, (b) sadece beyin bölgesini gösteren ve (c) elle bölütlenmiş görüntüler




Şekil 4.7. 4_8 eğitim veri kümesinden 30. dilime ait (a) ham, (b) sadece beyin bölgesini gösteren ve (c) elle bölütlenmiş görüntüler



Şekil 4.8. 2_4 test veri kümesinden 30. dilime ait (a) ham, (b) sadece beyin bölgesini gösteren ve (c) elle bölütlenmiş görüntüler

Eşyönsüz Yayınım Filtresi İle Filtreleme

Eğitim ve test için ayrılan görüntüler bölütleme işleminde kullanılmadan önce bölge içlerini yumuşatıp kenarları belirginleştiren eşyönsüz yayınım filtresinden geçirilmiştir. Filtrenin yayınım kuvvetini belirlemek üzere Eş. 2.11'deki formül kullanılmıştır. Filtreleme işlemindeki diğer parametreler olan κ değeri 5 ve iterasyon sayısı ise 10 olarak alınmıştır. Şekil 4.9'de 1_24 ve 2_4 numaralı hastalara ait MR görüntüleri ile bu görüntülere eşyönsüz yayınım filtresi uygulanması ile elde edilen görüntüler verilmiştir.



Şekil 4.9. (a) 1_24 numaralı hastanın MR görüntüsü, (b) 2_4 numaralı hastanın MR görüntüsü, (c) (a)'daki görüntüye ve (d) (b)'deki görüntüye eşyönsüz yayınım filtresi uygulandıktan sonra elde edilen görüntüler

Özellik Vektörünün Oluşturulması

Farklı dokuları birbirinden ayırt etmekte kullanılacak özellikleri görüntülerden çıkarmak için DDD yöntemi uygulanmıştır. DDD yönteminde diğer dalgacık dönüşümü yöntemlerinden farklı olarak, dönüşüm sırasında alt örnekleme işlemi yapılmamaktadır. Bunun sonucunda, dönüşüm sonucunda elde edilen alt görüntüler ile orijinal görüntünün boyutları aynı olmaktadır. Bu sayede her piksel için tanımlayıcı özellikler dönüşüm sonucunda elde edilen katsayılardan pencereleme yöntemi ile çıkarılabilmektedir. DDD yönteminin bir diğer avantajı ise sinyal ötelemelerinden etkilenmemesidir.

Daubechies dalgacık serisinden db2 dalgacığı kullanılarak görüntülere 1 seviyeli DDD uygulanmıştır. Dönüşüm sonucunda 1 adet yatay ve 3 adet dikey ve köşegen detay alt görüntüleri elde edilmiştir. Yatay, dikey ve köşegen detay alt görüntülerinin ortalaması alınarak görüntüye ait detayları gösteren tek bir görüntü oluşturulmuştur. Sonuçta DDD ile orijinal görüntüye ait bir yatay ve bir de detay görüntüsü elde edilmiştir.

Görüntülerin bölütlenmesi işleminde sadece DDD ile elde edilen ham katsayıları kullanmak yeterli değildir. Bu katsayılara ek olarak yerel istatistiksel bilgiyi ifade edecek özellikler görüntü üzerinde 3×3 boyutunda bir pencere gezdirilerek elde edilmiştir. Bu özellikler Eş. 2.23–Eş. 2.26’da verilen ortalama mutlak sapma, entropi, enerji ve standart sapmadır.

DDD ile elde edilen katsayılar ve bu katsayılardan pencereleme ile elde edilen özellikler bir araya getirilerek özellik vektörü oluşturulmuştur.

SOM Ağının Eğitimi

Eğitim ve test işlemlerinde kullanılacak her görüntü için oluşturulan özellik vektöründe etiket olarak doku türlerinin isimleri kullanılmıştır. IBSR veri tabanında orijinal görüntülerle birlikte bu görüntülerin elle bölütlenmiş halleri de verildiğinden etiket bilgisi bölütlenmiş görüntülerden elde edilmiştir. Özellik vektörü SOM ağında

giriş olarak kullanılmadan önce normalleştirilerek [0 1] aralığına getirilmiştir. SOM ağı danışmansız olarak Çizelge 4.5'teki parametreler kullanılarak eğitilmiştir. Çizelgedeki n değeri girdi verisinin sayısıdır.

Çizelge 4.5. SOM ağıının eğitiminde kullanılan parametreler

Parametre	Değer
Eğitim algoritması	Ardışık
Nöron sayısı	$5 \times n^{0.54321}$
Başlangıç durumuna getirme	Rastgele
Kafes şekli	Altıgen
Öğrenme oranı [kaba_ eğitim ince_ ayar]	[0.5 0.05]
Komşuluk fonksiyonu	Gauss
Öğrenme oranı fonksiyonu	Üs

Ağın Etiketlenmesi

Girdi örnekleri ağa sunulup, ağın ağırlıkları danışmansız eğitim ile ayarlandıktan sonra, gerçekleştirilecek işlem adımı farklı girdi desenlerini ağ üzerine yerleştirebilmek için ağın etiketlenmesidir. Bu amaçla elle analiz edilmiş veri kümeleri girdi olarak kullanılıp, verilerin ağdaki en iyi uyduğu birim tespit edilerek ağdaki birimler buna göre etiketlenir.

Ağdaki birimlerin etiketlenmesi aşamasında bir birimin belirli bir doku türü olarak kaç adet isabet aldığı tespit edilmiştir. Ve bir birimin etiketi olarak en çok isabet aldığı doku türü atanmıştır. Eğer bir ağ birimi hiç isabet almamışsa ya da farklı doku türleri için eşit sayıda isabet almışsa bu durumda o birimin komşuluğundaki birimlere bakılarak etiketleme yapılmıştır. SOM ağını etiketlemede kullanılan algoritma Bölüm 3.2'de ayrıntılı olarak verilmiştir.

LVQ 1 ve LVQ3 Eğitimi

Pek çok pratik uygulamada SOM ve LVQ metotları birleştirilmiştir. SOM ağı oluşturulup danışmansız eğitim işleminden geçirildikten ve etiketlendikten sonra, nöronların problem için en uygun yerleşimini sağlamak amacıyla, girdi verileri kullanılarak danışmanlı eğitim gerçekleştirilmiştir. Bu aşamada çeşitli sınıfların ve ya kümelerin ağırlık vektörlerine LVQ kullanılarak ince ayar yapılmıştır. Danışmanlı öğrenme işlemine LVQ1 ile başlanıp sistemin tanıma doğruluğunu arttırmak üzere LVQ3 ile devam edilmiştir. Yapılan deneysel çalışmalar sonucunda LVQ algoritmalarında kullanılan iterasyon sayısı 1 000 ve $\alpha(t)$ öğrenme oranı 0,5 olarak seçilmiştir. LVQ3 algoritması için pencere genişliği parametresi 0,2 alınırken göreceli öğrenme parametresi ϵ için 0,3 değeri kullanılmıştır.

Sonuçların Jaccard ve Dice Benzerlik İndeksleri ile Değerlendirilmesi

Danışmansız eğitim ile eğitilen ve LVQ ile kalibre edilen SOM ağına performansı test görüntüleri kullanılarak test edilmiştir. Elde edilen sonuçlar ortalama örtüşme metriği de denilen Jaccard ve Dice benzerlik indekslerine göre değerlendirilmiştir. Bu metriklerin değeri eğer sonuçlar çok benzerse 1,0'a ve eğer hiç benzer şekilde sınıflandırılmış piksel paylaşılmıyorsa 0,0'a yaklaşır.

10 adet veri kümesi ile eğitilen sistemin performansı 10 adet test veri kümesi kullanılarak test edilmiştir. IBSR veritabanındaki yalnızca beyin içeren 20 veri kümesi kullanılmıştır. Sonuçlar gri cevher ve beyaz cevher için elle yapılan bölütlemelerle karşılaştırılmış ve Jaccard, Dice, duyarlılık ve belirlilik benzerlik indeksleri ile değerlendirilmiştir (Çizelge 4.6).

Çizelge 4.6. Jaccard, Dice, duyarlılık ve belirlilik benzerlik indeksleri

Hasta No	Jaccard		Dice		Duyarlılık		Belirlilik	
	Beyaz Cevher	Gri Cevher	Beyaz Cevher	Gri Cevher	Beyaz Cevher	Gri Cevher	Beyaz Cevher	Gri Cevher
2_4	0,2989	0,4534	0,4602	0,6239	0,3352	0,7391	0,9922	0,9558
5_8	0,5639	0,6911	0,7211	0,8173	0,6832	0,8383	0,9898	0,9835
7_8	0,3538	0,5356	0,5227	0,6976	0,4938	0,6999	0,9832	0,9757
11_3	0,6295	0,6979	0,7726	0,8221	0,7730	0,8268	0,9785	0,9741
13_3	0,6035	0,7119	0,7527	0,8317	0,6645	0,8881	0,9912	0,9686
16_3	0,5544	0,6905	0,7133	0,8169	0,6303	0,8676	0,9943	0,9817
100_23	0,5865	0,7210	0,7394	0,8379	0,6037	0,9402	0,9978	0,9662
111_2	0,6544	0,6775	0,7911	0,8078	0,6990	0,9024	0,9937	0,9697
191_3	0,6031	0,6633	0,7524	0,7976	0,7299	0,8111	0,9857	0,9786
205_3	0,6334	0,7054	0,7756	0,8273	0,6762	0,9024	0,9944	0,9716
Ortalama	0,5481	0,6548	0,7001	0,7880	0,6289	0,8416	0,9901	0,9726

IBSR veritabanının resmi sitesinden duyurulan, çeşitli bölütleme metotlarının IBSR veri kümeleri üzerinde gösterdikleri performans Çizelge 4.7’de verilmiştir. Çizelgedeki rakamlar, yöntemlerin bölütleme performansını gösteren Jaccard benzerlik indeksi değerleridir. Bu sonuçlar IBSR veritabanındaki yalnızca beyin içeren 20 veri kümesi kullanılarak elde edilmiştir.

Çizelge 4.7. 20 beyin taraması için elle yönlendirilmiş bölütlemeler ile çeşitli metotlar arasındaki ortalama örtüşme için Jaccard benzerlik indeksi değerleri


Gri Cevher	Beyaz Cevher	Kullanılan Metot
0,564	0,567	Adaptif MAP
0,558	0,562	Eğilimli MAP
0,473	0,567	Bulanık c-ortalamar
0,550	0,554	En Büyük Sonsal Olasılık (MAP)
0,535	0,551	Maximum-Likelihood
0,477	0,571	Ağaç-yapılı k-ortalamar
0,876	0,832	El ile (2 uzmanın ortalaması)

Çizelge 4.8’de Çizelge 4.7’de verilen yöntemlerin ve geliştirilen yöntemin test veri kümeleri üzerinde gösterdiği bölütleme performansı Jaccard benzerlik indeksine göre beyaz ve gri cevher için verilmiştir. Sistemden elde edilen sonuçlar IBSR veritabanının sitesinde duyurduğu farklı metotların sonuçlarıyla karşılaştırıldığında geliştirilen sistemin gri cevher alanları ayırt etmede diğer yöntemlere göre üstünlük sağladığı görülmektedir. Gri cevherin bölütlenmesinde farklı metotlardan elde edilen ortalama sonuç 0,53 iken geliştirilen sistemde bu değer 0,13 arttırılarak 0,66 doğruluğa ulaşılmıştır. Sistem beyaz cevherin bölütlenmesinde ise ortalama bir başarı göstermiştir.

Çizelge 4.8. Test veri kümelerinde farklı yöntemlerden beyaz ve gri cevher için elde edilen bölütleme sonuçları


Veri Kümesi	MAP		Adaptif MAP		Eğilimli MAP		Bulanık c-ortalamalar		Maximum-Likelihood		k-ortalamalar		Geliştirilen Yöntem	
	Gri	Beyaz	Gri	Beyaz	Gri	Beyaz	Gri	Beyaz	Gri	Beyaz	Gri	Beyaz	Gri	Beyaz
2_4	0,31	0,19	0,36	0,28	0,30	0,18	0,31	0,29	0,31	0,19	0,31	0,29	0,45	0,30
5_8	0,15	0,07	0,27	0,13	0,15	0,08	0,20	0,08	0,17	0,07	0,18	0,07	0,69	0,56
7_8	0,60	0,64	0,62	0,64	0,61	0,65	0,53	0,65	0,55	0,67	0,52	0,66	0,54	0,35
11_3	0,68	0,72	0,66	0,71	0,69	0,74	0,58	0,72	0,71	0,70	0,59	0,72	0,70	0,63
13_3	0,66	0,70	0,65	0,68	0,66	0,67	0,52	0,71	0,70	0,67	0,53	0,72	0,71	0,60
16_3	0,58	0,56	0,58	0,57	0,59	0,57	0,46	0,55	0,51	0,56	0,48	0,56	0,69	0,55
100_23	0,67	0,66	0,66	0,66	0,68	0,67	0,55	0,67	0,65	0,67	0,55	0,67	0,72	0,59
111_2	0,56	0,64	0,57	0,65	0,61	0,68	0,48	0,64	0,56	0,65	0,50	0,65	0,68	0,65
191_3	0,65	0,72	0,66	0,69	0,66	0,72	0,57	0,72	0,61	0,66	0,57	0,72	0,66	0,60
205_3	0,67	0,71	0,67	0,70	0,66	0,71	0,59	0,72	0,64	0,71	0,58	0,71	0,71	0,63
Ortalama	0,55	0,56	0,57	0,57	0,56	0,57	0,48	0,57	0,54	0,55	0,48	0,58	0,66	0,55

Farklı yöntemlerin IBSR veritabanındaki beyin MR görüntülerini bölütlemeye gösterdiği başarının grafiği Şekil 4.10’da verilmiştir.




Şekil 4.10. Farklı yöntemlerin bölütleme işleminde gösterdiği performans

Test veri kümesindeki hastalar için gri cevherin bölütlenmesinde farklı yöntemlerden elde edilen sonuçlar Şekil 4.11’de grafik olarak verilmiştir.




Şekil 4.11. Test veri kümesindeki hastalar için gri cevherin bölütlenmesinde farklı yöntemlerden elde edilen sonuçlar


Şekil 4.12-Şekil 4.15'te 11_3, 111_2, 191_3 ve 205_3 numaralı test veri kümelerindeki görüntüler, bu görüntülerin elle bölütlenmiş halleri ve bu görüntüler için sistemden elde edilen bölütleme sonuçları verilmiştir.




Şekil 4.12. 11_3 numaralı test verisindeki (a) 30. dilim görüntüsü, (b) görüntünün elle bölütlenmiş hali, (c) Sistemden elde edilen bölütleme sonucu



Şekil 4.13. 111_2 numaralı test verisindeki (a) 30. dilim görüntüsü, (b) görüntünün elle bölütlenmiş hali, (c) Sistemden elde edilen bölütleme sonucu



Şekil 4.14. 191_3 numaralı test verisindeki (a) 30. dilim görüntüsü, (b) görüntünün elle bölütlenmiş hali, (c) Sistemden elde edilen bölütleme sonucu



Şekil 4.15. 205_3 numaralı test verisindeki (a) 30. dilim görüntüsü, (b) görüntünün elle bölütlenmiş hali, (c) Sistemden elde edilen bölütleme sonucu

4.3. Tümörlü Beyin MR Görüntüleri Bulguları ve İrdeleme


Beyninde tümör bulunan kişilere ait beyin MR görüntülerini bölütleme için Bölüm 2.3'te ayrıntıları verilen, 29 Mayıs Hastanesi Radyoloji Polikliniği'nden elde edilen 20 hastanın görüntüsü kullanılmıştır. Bölütleme işlemine geçilmeden önce veri kümesindeki tüm hastalar için MR görüntülerindeki tüm dilimler gözden geçirilerek sağlık beyin dokularının yanında tümör ve ödem bölgelerinin en net görülebildiği dilim seçilmiştir. Görüntülerde beyaz cevher, gri cevher, BOS, tümör ve ödem alanlarını gösteren bölgeler, bir radyoloji uzmanı ile birlikte, elle seçilmiş ve etiketlenmiştir. YSA'da giriş olarak kullanılacak eğitim ve test verilerine ait etiket bilgisini oluşturmak için gerekli bir işlem olan el ile işaretleme, bölütlenecek doku türlerine ait örnek alanların seçilmesi işlemidir. İşaretlenen bu alanlar YSA'nın eğitilmesinde etiket bilgisi olarak, test aşamasında ise bölütleme doğruluğunun tespit edilmesinde kullanılmaktadır.

Görüntülerde elle seçim yapma işlemi çok dikkat gerektiren, vakit alan, sıkıcı ve zor bir işlemdir. Bu işlem adımı yapılacak herhangi bir hatanın tüm sistemin sonucunu olumsuz etkileyeceği düşünüldüğünde büyük önem arz etmektedir.

Elle bölütleme işlemi için öncelikle hangi dokunun hangi görüntü türünde net olarak görüldüğü tespit edilmektedir. Beyaz cevher ve gri cevherin işaretlenmesi için T1-ağırlıklı MR görüntüsü, BOS alanlarının işaretlenmesi içinse T2-ağırlıklı MR görüntüleri kullanılmıştır. Tümör için T1-ağırlıklı ve T2-ağırlıklı MR görüntüleri incelenerek tümör hangisinde daha net görülüyorsa işaretleme o görüntüde yapılmıştır. Ödemin işaretlenmesi için de genellikle T2-ağırlıklı ya da FLAIR MR görüntüleri kullanılmıştır.


İşaretleme işleminde her doku türü için seçim yapılan görüntü üzerinde kapalı bir alan oluşturulmaktadır. Bu alan seçilen doku bölgesi içinde 1 dışında 0 değeri olacak şekilde görüntü ile aynı boyutta bir maske haline getirilmektedir. Eğitim ve test veri kümelerinin oluşturulması adımı, bu maske görüntüleri tüm görüntü türleri ile çarpılıp tüm doku türleri için her görüntü türünden değerler elde edilmektedir.

Şekil 4.16 - Şekil 4.18’de A1-A3 numaralı hastalar için T1-ağırlıklı, T2-ağırlıklı ve FLAIR MR görüntüleri üzerinde el ile işaretlenmiş doku alanları gösterilmektedir.




(a)

(b)




(c)

Şekil 4.16. A1 numaralı hasta için (a) T1-ağırlıklı, (b) T2-ağırlıklı ve (c) FLAIR MR üzerinde el ile işaretlenmiş doku alanları




(a)

(b)




(c)

Şekil 4.17. A2 numaralı hasta için (a) T1-ağırlıklı, (b) T2-ağırlıklı ve (c) FLAIR MR üzerinde el ile işaretlenmiş doku alanları



Şekil 4.18. A3 numaralı hasta için (a) T1-ağırlıklı, (b) T2-ağırlıklı ve (c) FLAIR MR üzerinde el ile işaretlenmiş doku alanları

Görüntülerin bölütlenmesi için eğitim aşamasında ve sistemden elde edilen sonuçların değerlendirilmesi için test aşamasında gerçekleştirilen işlem adımları Şekil 4.19'da verilmiştir.




Şekil 4.19. Beyin MR görüntülerini bölütleyen sistemin işlem adımları

El ile işaretleme işleminin ardından 20 hasta içinden rastgele seçilen 10 tanesi eğitim geri kalan 10 tanesi ise test veri kümesi olarak ayrılmıştır. Eğitim hastaları A1-A10 ve test hastaları ise B1-B10 olarak numaralandırılmıştır.


Tüm görüntüler double formata çevrilerek, yoğunluk değerleri [0 1] aralığında normalleştirilmiştir.

T1-ağırlıklı, T2-ağırlıklı ve FLAIR MR görüntülerinin alınması arasında geçen zamanda hasta kafasını hareket ettirebilmektedir. Görüntülerin içerdikleri ortak nokta ya da bölgelerin kolayca ilişkilendirilebilmesi amacıyla uzaysal olarak birbirilerine göre hizalanması işlemi gerçekleştirilmiştir. Bu işleme *görüntü hizalama* ya da *görüntü çakıştırma* denmektedir [93]. Doğru bir çakıştırma işlemi sonucunda her bir görüntü aynı koordinat sisteminde olmaktadır ve bir görüntüdeki belirli bir piksel ile diğer görüntüde buna karşılık gelen piksel aynı fiziksel alanı temsil etmektedir.

Görüntülerin çakıştırılması işleminde T1-ağırlıklı görüntüler statik referans görüntüleri, T2-ağırlıklı ve FLAIR MR görüntüleri ise hareket eden görüntüler olarak alınmıştır. Her hasta için T2-ağırlıklı ve FLAIR MR görüntüleri T1-ağırlıklı görüntüye göre hizalanmıştır. Şekil 4.20 - Şekil 4.23'de A2, A9, B2 ve B9 numaralı hastaların T1-ağırlıklı, T2-ağırlıklı ve FLAIR MR görüntülerinin tarayıcıdan elde edilen orijinal halleri ile birbirlerine göre çakıştırılmış halleri verilmiştir.




(a)




(b)

Şekil 4.20. A2 hastasına ait (a) orijinal ve (b) çakıştırılmış MR görüntüleri, soldan sağa T1-ağırlıklı, T2-ağırlıklı ve FLAIR




(a)




(b)

Şekil 4.21. A9 hastasına ait (a) orijinal ve (b) çakıştırılmış MR görüntüleri, soldan sağa T1-ağırlıklı, T2-ağırlıklı ve FLAIR




(a)




(b)

Şekil 4.22. B2 hastasına ait (a) orijinal ve (b) çakıştırılmış MR görüntüleri, soldan sağa T1-ağırlıklı, T2-ağırlıklı ve FLAIR



(a)




(b)

Şekil 4.23. B9 hastasına ait (a) orijinal ve (b) çakıştırılmış MR görüntüleri, soldan sağa T1-ağırlıklı, T2-ağırlıklı ve FLAIR


Beyin görüntülerinde bulunan sağlıklı ve hastalıklı dokular dışında kalan deri, kafatası, yağ, kas, bağ doku gibi bölümler, özel durumlar dışında doktorlar tarafından bölütlenmemekte ve kullanılmamaktadır. Geliştirilen sistemde de beyin görüntüsünde bulunan gri cevher, beyaz cevher, BOS, tümör ve ödem dışında kalan bölümler ile ilgilenilmemektedir. Bu nedenle Bölüm 3.1’de verilen algoritma kullanılarak eğitim ve test veri kümelerinde görüntülerden kafatası ve diğer ilgilenilmeyen bölgeler çıkartılmıştır.

MR tarayıcısının manyetik alanındaki değişimler görüntü yoğunluğunda etki alanı (bias field) ya da tekbiçimsizlik (non-uniformity) olarak adlandırılan homojensizliklere neden olmaktadır. Sonuç, görüntü yoğunluklarının uzaysal olarak yavaşça değişen bir etki değeri ile çarpımıdır. Bu durum görüntülerin analizi ve bölütlenmesi gibi görevler için problemlere yol açmaktadır. Bu nedenle bu çalışmada, etki alanını ve rastgele gürültüyü ortadan kaldırmak için eşyönsüz yayılım filtresi tüm görüntülere uygulanmıştır. Filtreleme işleminde kullanılan parametrelerin belirlenmesi ile ilgili standart kurallar olmadığı için deneysel olarak en iyi sonucu veren değerler seçilmiştir. Filtrenin yayılım kuvvetini belirlemek üzere Eş. 2.11’deki formül kullanılmıştır. Filtreleme işlemindeki parametreler olan κ değeri 1 ve iterasyon sayısı 15 olarak alınmıştır.


Şekil 4.24 - Şekil 4.27’de A10, B3, B6 ve B7 numaralı hastaların MR görüntüleri, bu görüntülerin yalnızca beyin bölgesini içeren halleri ve beyin bölgesini gösteren görüntülerin filtreleme sonuçları verilmiştir.




Şekil 4.24. A10 hastasına ait (a) orijinal görüntüler, (b) beyin bölgesini gösteren MR görüntüleri ve (c) filtreleme sonuçları, soldan sağa T1-ağırlıklı, T2-ağırlıklı ve FLAIR



Şekil 4.25. B3 hastasına ait (a) orijinal görüntüler, (b) beyin bölgesini gösteren MR görüntüleri ve (c) filtreleme sonuçları, soldan sağa T1-ağırlıklı, T2-ağırlıklı ve FLAIR




Şekil 4.26. B6 hastasına ait (a) orijinal görüntüler, (b) beyin bölgesini gösteren MR görüntüleri ve (c) filtreleme sonuçları, soldan sağa T1-ağırlıklı, T2-ağırlıklı ve FLAIR



Şekil 4.27. B7 hastasına ait (a) orijinal görüntüler, (b) beyin bölgesini gösteren MR görüntüleri ve (c) filtreleme sonuçları, soldan sağa T1-ağırlıklı, T2-ağırlıklı ve FLAIR

YSA'da giriş olarak kullanılacak görüntü özelliklerini ortaya çıkarmak için görüntüye Daubechies dalgacık serisinden db2 dalgacığı kullanılarak 1 seviyeli DDD ayrıştırması uygulanmıştır. Desen özelliklerinin çoklu ölçeklerde karakterize edilebilmesi için DDD kullanılarak öteleme ile değişmeyen bir tam ötesi (overcomplete) ayrıştırma elde edilmiştir.

Şekil 4.28’de A10 numaralı hastanın MR görüntülerine DDD uygulanması ile elde edilen dalgacık katsayıları verilmiştir.



Şekil 4.28. A10 numaralı hastanın (a) T1-ağırlıklı, (b) T2-ağırlıklı ve (c) FLAIR MR görüntülerinden elde edilen DDD katsayıları, soldan sağa yaklaşım, yatay, dikey ve köşegen katsayıları

Ham dalgacık katsayıları tek başlarına desen özelliklerini tam olarak ifade etmekte yetersizdirler. Dokulu bilgiyi farklı frekans kanallarına bölmekte faydalıdır fakat bir pikselin etrafındaki yerel istatistiksel bilgilerden yoksundurlar. Benzer ortalama parlaklık değerine ya da ikinci dereceden istatistiklere sahip desen çiftlerini ayırt etmek üzere bir doğrusalsızlığa gerek vardır. Bu nedenle dalgacık katsayılarına uzaysal filtreleme işlemi uygulanmış ve 3×3 boyutunda bir pencere katsayılar üzerinde kaydırılmıştır. Pencerenin yerel istatistikleri her bir pozisyon için


hesaplanmıştır. Elde edilen değerler bu pencerenin ortasında bulunan pikselin değeri olarak atanmıştır. Filtreleme işlemi ile elde edilen ve yerel istatistiksel bilgiyi ifade etmek üzere hesaplanan özellikler Eş. 2.24 - Eş. 2.26'da verilen entropi, enerji ve standart sapmadır.

T1-ağırlıklı, T2-ağırlıklı ve FLAIR MR görüntüleri ile bu görüntülere uygulanan dalgacık dönüşümü sonucunda elde edilen yaklaşım dalgacık katsayıları, bu katsayı görüntülerinden pencereleme ile elde edilen entropi, enerji ve standart sapma özellik görüntüleri bir araya getirilerek YSA'da giriş olarak kullanılacak özellik vektörü elde edilmiştir.

Yapay sinir ağını eğitirken görüntülerin ve görüntülerden elde edilen özellik görüntülerinin tamamı kullanılmamıştır. Özellik görüntüleri içinden hangi girdi vektörünün hangi doku türüne karşılık geldiğini ifade edebilmek amacıyla elle işaretleme yoluyla her doku türü için seçilmiş alanlar kullanılmıştır. Örneğin, görüntülerin beyaz cevher için işaretlenmiş bölgesi içinde kalan pikselleri ağ girişinde beyaz cevheri temsilen kullanılmıştır. Tüm doku türlerinin eşit oranda temsil edilebilmesi ve hiçbirinin ağırlık eğitiminde baskın olmaması için, her doku türüne ait ortalama örnek sayısına eşit, aynı sayıda örnek rastgele seçilip bir araya getirilerek özellik vektörü oluşturulmuştur. Ağdaki nöronlar da bu bilgiye göre etiketlenmiştir.

Özellik vektörü SOM ağında giriş olarak kullanılmadan önce histogram eşitleme yöntemi uygulanmış ve değerler $[0 \ 1]$ aralığında normalleştirilmiştir.

Şekil 4.29'da A10 numaralı hastanın T1-ağırlıklı, T2-ağırlıklı ve FLAIR MR görüntülerinden elde edilen, yaklaşım katsayıları, entropi, enerji ve standart sapmadan oluşan özellik görüntüleri verilmiştir.



Şekil 4.29. A10 hastasına ait (a) T1-ağırlıklı, (b) T2-ağırlıklı ve (c) FLAIR MR görüntülerinden elde edilen özellik görüntüleri, soldan sağa yaklaşım katsayıları, entropi, enerji ve standart sapma

SOM ağı danışmansız olarak Çizelge 4.5'teki parametreler kullanılarak eğitilmiştir. SOM ağının eğitimi ile MR görüntüleri beyaz cevher, gri cevher, BOS, ödem ve tümör olarak beş farklı bölgeye kümelenebilir. Girdi örnekleri ağa sunulup, ağın ağırlıkları danışmansız eğitim ile ayarlandıktan sonra, elle seçilmiş veri kümeleri girdi olarak kullanılıp, verilerin ağıdaki en iyi uyduğu birim tespit edilerek ağıdaki birimler buna göre etiketlenmiştir. Bu işlem için Bölüm 3.2'de verilen Özörgütlemeli Harita Ağının Kümelenebilirliği ve Etiketlenebilirliği algoritması kullanılmıştır.

SOM ağı oluşturulup danışmansız eğitim işleminden geçirildikten ve etiklendikten sonra nöronların problem için en uygun yerleşimini sağlamak amacıyla girdi verileri

kullanılarak danışmanlı eğitim gerçekleştirilmiştir. Bu aşamada ağdaki nöronların ağırlıklarına LVQ kullanılarak ince ayar yapılmıştır. LVQ yönteminin amacı girdi uzayındaki sınıf bölgelerini tanımlamak için girdi örneklerinin sınıf dağılımlarının sınırlarında çakışmalar olsa bile benzer şekilde etiketlenmiş ağırlık vektörlerini sınıflara yerleştirmektir. Danışmanlı öğrenme işlemine LVQ1 ile başlanıp sistemin tanıma doğruluğunu arttırmak üzere LVQ3 ile devam edilmiştir. Her iki algoritmada da çalışma uzunluğu 100 ve öğrenme oranı 0,5 olarak seçilmiştir. LVQ3 algoritmasında pencere genişliği 0,2 ve görelî öğrenme parametresi 0,3 alınmıştır.

Danışmansız eğitim ile eğitilen ve LVQ ile kalibre edilen SOM ağının performansı test görüntüleri kullanılarak test edilmiştir. Elde edilen sonuçlar ortalama örtüşme metriği de denilen Dice benzerlik indeksi ile duyarlılık ve belirlilik analiziyle değerlendirilmiştir.

Çizelge 4.9’da beyaz cevher, gri cevher, BOS, ödem ve tümör için sistemden elde edilen bölütleme performansları Dice benzerlik indeksi, duyarlılık ve belirlilik olarak verilmiştir. Hastalar numaralandırılırken eğitim veri kümesinde bulunan hastalar *A*, test veri kümesinde bulunan hastalar ise *B* ile gösterilmiştir. Ödem için verilen sonuçlarda ödemi bulunmayan hastalar için *Ö/Y* (*Ödem Yok*) ifadesi kullanılmıştır.

Çizelge 4.9. Bölütleme sonuçları

Hasta No	Beyaz Cevher Doğruluk (%)			Gri Cevher Doğruluk (%)			BOS Doğruluk (%)			Ödem Doğruluk (%)			Tümör Doğruluk (%)		
	Dice	Duyarlılık	Belirlilik	Dice	Duyarlılık	Belirlilik	Dice	Duyarlılık	Belirlilik	Dice	Duyarlılık	Belirlilik	Dice	Duyarlılık	Belirlilik
A1	87,07	99,00	92,90	94,80	94,80	98,70	98,00	98,00	99,50	51,15	48,80	89,50	37,84	34,40	88,15
A2	82,79	93,80	91,80	86,91	89,60	95,85	87,25	99,20	92,95	75,99	61,40	99,95	78,11	69,60	97,85
A3	88,19	97,80	92	89,04	91	95,53	99,60	99,40	99,93	Ö/Y	Ö/Y	Ö/Y	36,72	24,20	97,47
A4	95,24	100	97,50	91,46	87,80	98,95	99,60	100	99,80	65,37	77,60	85,05	45,31	36,20	94,10
A5	84,67	100	87,93	74,53	59,40	100	100	100	100	Ö/Y	Ö/Y	Ö/Y	51,62	35	99,80
A6	76,99	71,60	96,40	75,67	82,40	91,15	95,97	100	97,90	95,36	92,60	99,60	83,06	80,40	96,70
A7	96,76	98,40	98,33	94,06	93,40	98,27	95,21	91,40	99,80	Ö/Y	Ö/Y	Ö/Y	60,34	45,80	98
A8	75,48	78,20	90,33	67,27	66,60	89,53	96,99	100	97,93	Ö/Y	Ö/Y	Ö/Y	59,35	49,20	94,47
A9	76,23	99,40	84,65	80,69	93,60	90,40	100	100	100	72,88	60,20	98,75	2,54	1,80	89,95
A10	99,90	99,80	100	99,90	100	99,95	100	100	100	96,93	94,80	99,80	97,06	99,20	98,70
B1	93,55	100	96,55	93,85	93,00	98,70	88,73	100	93,65	92,64	86,80	99,85	77,85	68,20	98,25
B2	84,40	86,00	95,55	85,25	95,40	92,90	99,40	99,20	99,90	77,49	65,40	99,15	69,80	71,20	91,80
B3	98,62	99,80	99,13	97,97	96,40	99,87	99,70	100	99,80	Ö/Y	Ö/Y	Ö/Y	91,59	85	99,80
B4	96,13	99,40	97,53	83,43	72	99,80	100	100	100	Ö/Y	Ö/Y	Ö/Y	27,14	16,81	97,67
B5	95,60	100	97,70	91,18	92	97,55	99,90	100	99,95	72,51	89,40	85,70	43,60	31	97,20
B6	96,62	100	98,25	97,02	97,80	99,05	97,09	100	98,50	66,21	58,00	95,70	63,75	67	89,20
B7	98,23	99,80	99,15	98,58	97,40	99,95	68,36	99,80	76,95	83,31	71,40	100	11,49	7,80	93
B8	96,15	99,80	97,40	68,16	51,80	99,93	99,70	100	99,80	Ö/Y	Ö/Y	Ö/Y	22,63	16,20	91
B9	96,38	98,40	98,07	85,07	75,20	99,47	97,66	100	98,40	Ö/Y	Ö/Y	Ö/Y	79,35	77,60	94
B10	97,55	99,40	98,53	94,11	89,40	99,80	99,90	100	99,93	Ö/Y	Ö/Y	Ö/Y	71,50	56,20	99,67

Çizelge 4.9’da verilen doğruluk oranları incelendiğinde sistemin beyaz cevher, gri cevher ve BOS dokularını bölütlemekte oldukça yüksek performans sergilediği görülmektedir. Çoğu hasta için BOS bölütleme doğruluğunda %100 değerine ulaşılmıştır. Beyaz cevher ve gri cevher dokuları için bölütleme doğruluğunun ortalaması sırasıyla %95 ve %98 olmuştur. Diğer taraftan ödem ve tümör dokuları için bazı hastalardan elde edilen doğruluk oranları görece olarak düşük olmuştur. Bunun nedenleri olarak;


- 1) Bölütlenen tümör türü olan glial tümörlerin homojen bir yapıda olmaması aksine oldukça heterojen bir yapıda olması,
- 2) Tümör alanını oluşturan dokuların nekrotik (ölü ya da çürüyen) ve aktif kısımlar ile şişkinlik gibi farklı özelliklerde alanlar içermesi,
- 3) Nekrotik alanlar ve aktif bölgeler arasında belirgin bir sınır olmaması ve tümörlerin bazıları nekrotik alan içerirken bazılarının içermemesi,
- 4) Ödem ve tümör alanlarının MR görüntülerinde birbirine çok benzer yoğunluklarda görünmesi,
- 5) Tümörün içindeki protein ve kan içeriği yoğun olduğunda ödem ya da sıvı gibi görünmesi sayılabilir.

Bu durum tümörün en çok ödem veya BOS ile karıştırıldığını gösteren ve Çizelge 4.10’te verilen karışıklık matrisinden de (confusion matrix) görülebilir. Çizelge 4.10’te verilen karışıklık matrisi eğitim ve test kümelerini oluşturan 20 hastanın tamamının bölütleme sonuçları üzerinden otomatik bölütleme ve el ile bölütlemenin örtüşmesini nicel olarak karşılaştırabilmek için hesaplanmıştır. Çizelgeden en çok ödem ve tümör dokularının birbirleriyle karıştırıldığı ve ödem örtüşmesinin tümörden daha iyi olduğu görülebilir. Çizelgeye göre beyaz cevher, gri cevher ve BOS örtüşmeleri sırasıyla %96, %86 ve %99’dur.


Çizelge 4.10. Karışıklık matrisi

Çıkış/İstenen	Beyaz Cevher	Gri Cevher	BOS	Ödem	Tümör
Beyaz Cevher	96,03	3,97	0	0	0
Gri Cevher	5,89	85,95	0,37	3,1	4,69
BOS	0	0,18	99,35	0	0,47
Ödem	3,65	0,83	0,03	73,38	22,1
Tümör	8,05	5,39	8,45	29,47	48,64

Şekil 4.30 ve Şekil 4.31’de eğitim ve test hastalarından elde edilen Dice benzerlik indeksi olarak bölütleme performansları grafik olarak gösterilmiştir. Ödemi olmayan hastalarda ödem için Dice benzerlik indeksi 1 olarak gösterilmiştir.



Şekil 4.30. Eğitim hastaları bölütleme performansı

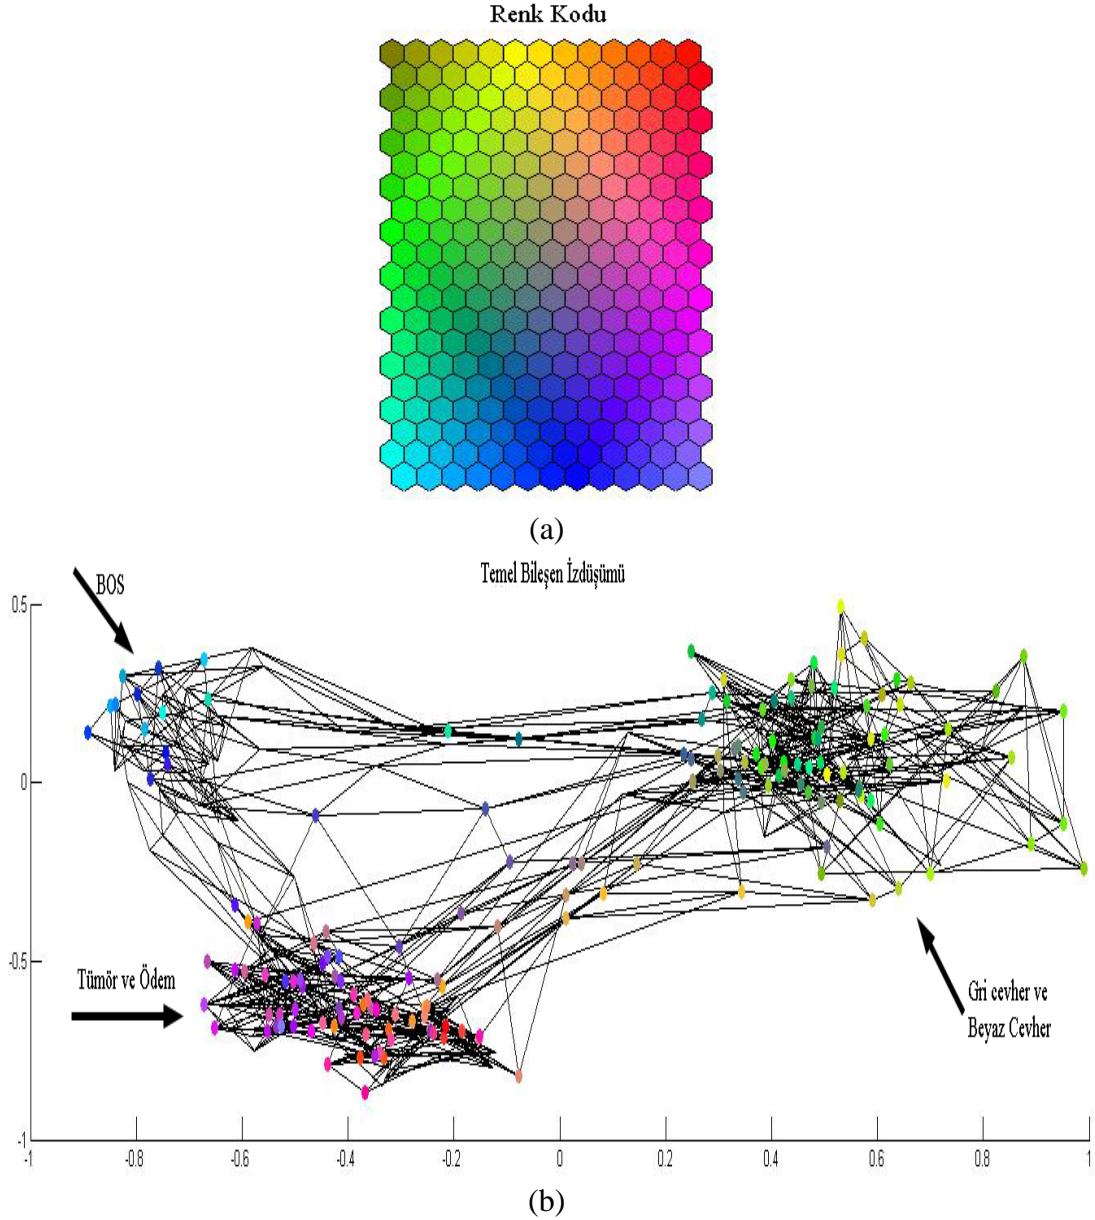


Şekil 4.31. Test hastaları bölütleme performansı


Vektör izdüşümünde yüksek boyutlu bir veri örneği kümesi, veri örnek çiftleri arasındaki mesafe mümkün olduğunca korunarak daha düşük boyuta yansıtılır. Ağ ağırlık vektörlerinin yansıtılması ve komşu ağ birimlerinin çizgilerle birleştirilmesi SOM ağına kendi karakteristik ağ-benzeri görünümünü verir. İzdüşüm görüntüleri ağ düzlemleri ile renk kodlaması ile ilişkilendirilebilir.

Şekil 4.32’de eğitilmiş SOM ağının ağırlık vektörlerini temel bileşen analizi kullanarak yansıtan temel bileşen izdüşümü verilmiştir. Bu izdüşüm başlangıçta 20×13 büyüklüğünde 2 boyutlu bir ızgara olan SOM ağının eğitim işleminin ardından girdi verisine yakınsaması sonucu elde edilen son halini temsil etmektedir. Renk haritası, izdüşüm üzerinde renklerin yayılması ile oluşturulmuştur. Renk haritasında kullanılan renkler rastgeledir ve farklı bölge sınıflarını temsil etmektedir. İzdüşüm incelendiğinde SOM ağının ağırlık vektörlerinin üç sınıfa ayrıldığı görülebilir. BOS dokusunu temsil eden ağırlık vektörleri birbirine yakın ve diğer ağırlık vektörlerinden uzak olacak şekilde gruplanmıştır. Bu nedenle BOS dokuları mükemmel bir şekilde ayırt edilebilmektedir. Bunun yanında beyaz cevher-gri

cevher ağırlık vektörleri ile ödem-tümör ağırlık vektörleri iki grup halinde ayrılmıştır. Bu durum Çizelge 4.10'te verilen karışıklık matrisindeki sonuçları desteklemektedir. Bu gruplardan beyaz cevher ve gri cevher kendi grupları içindeki ayrımsamayı tümör ve ödem grubuna göre daha iyi başarmaktadır.



Bölütleme işleminin hesaplama süresi tüm denemelerde hastada ödem olup olmamasından bağımsız olarak 2.83 GHz Core 2 Quad CPU ve 4 GB RAM bilgisayar ile yaklaşık 18-20 s olmaktadır.




Şekil 4.33. A2 numaralı hasta için (a) el ile işaretlenmiş T1-ağırlıklı MR, (b) gri düzey ve (c) renkli bölütleme sonucu

Şekil 4.33'te A2 numaralı eğitim hastası için elle işaretlenmiş MR görüntüsünün yanında sistemden elde edilen bölütleme sonuçları gri düzey ve renkli olarak verilmiştir. Sistem beyaz cevher, gri cevher ve BOS dokularının bölütlenmesinde iyi performans sergilemiştir. Tümör ve ödemin yerlerini doğru tespit etmiştir. Tümör


içindeki sıvı içeriği yoğun bazı bölgelerin BOS olarak sınıflandırıldığı görülmektedir.

Şekil 4.34'te A7 numaralı eğitim hastası için elle işaretlenmiş MR görüntüsü ile sistemden elde edilen bölütleme sonuçları gri düzey ve renkli olarak verilmiştir. Sağlıklı dokuların bölütlenmesinde iyi sonuç alınırken sistemin bazı tümör bölgelerini ödem olarak sınıflandırdığı görülmektedir.




Şekil 4.34. A7 numaralı hasta için (a) el ile işaretlenmiş T1-ağırlıklı MR, (b) gri düzey ve (c) renkli bölütleme sonucu

Şekil 4.33'te A9 numaralı eğitim hastası için elle işaretlenmiş MR görüntüsünün yanında sistemden elde edilen bölütleme sonuçları gri düzey ve renkli olarak verilmiştir. Sistemin özellikle BOS bölgelerinin tespitinde oldukça iyi sonuç verdiği görülmektedir. Tümör ve ödemin birbirine karıştırıldığı bazı noktalar da mevcuttur.




Şekil 4.35. A9 numaralı hasta için (a) el ile işaretlenmiş T1-ağırlıklı MR, (b) gri düzey ve (c) renkli bölütleme sonucu

Şekil 4.36’da A10 numaralı eğitim hastası için elle işaretlenmiş MR görüntüsü ile sistemden elde edilen bölütleme sonuçları gri düzey ve renkli olarak verilmiştir. Sistemin hem beyaz cevher, gri cevher ve BOS için hem de tümör ve ödem için dokuların yerlerini ve büyüklüklerini doğru olarak bulduğu ve iyi bir bölütleme performansı sergilediği görülmektedir.




Şekil 4.36. A10 numaralı hasta için (a) el ile işaretlenmiş T1-ağırlıklı MR, (b) gri düzey ve (c) renkli bölütleme sonucu

Şekil 4.37’de B2 numaralı test hastası için elle işaretlenmiş MR görüntüsü ile sistemden elde edilen bölütleme sonuçları gri düzey ve renkli olarak verilmiştir. Sistemin dokuların yerlerini ve büyüklüklerini doğru olarak bulduğu görülmektedir. Bunun yanında bazı BOS ve ödem bölgeleri tümör olarak tespit edilmiştir.




Şekil 4.37. B2 numaralı hasta için (a) el ile işaretlenmiş T1-ağırlıklı MR, (b) gri düzey ve (c) renkli bölütleme sonucu

Şekil 4.38’de B3 numaralı test hastası için elle işaretlenmiş MR görüntüsü ile sistemden elde edilen bölütleme sonuçları gri düzey ve renkli olarak verilmiştir. Tüm dokular için elde edilen bölütleme doğruluk oranları oldukça yüksektir. Fakat BOS dokusu içerisindeki bazı bölgeler tümör olarak algılanmıştır.




Şekil 4.38. B3 numaralı hasta için (a) el ile işaretlenmiş T1-ağırlıklı MR, (b) gri düzey ve (c) renkli bölütleme sonucu

Şekil 4.39’da B7 numaralı test hastası için elle işaretlenmiş MR görüntüsü ile sistemden elde edilen bölütleme sonuçları gri düzey ve renkli olarak verilmiştir. Sistemden tümör için elde edilen en kötü bölütleme sonuçlarından biri bu hastaya aittir. Bu hastada tümör yoğun biçimde sıvı içerdiğinden sistem tarafından BOS olarak değerlendirilmiştir. Ödem ve diğer dokular için elde edilen bölütleme doğruluğu ise oldukça yüksektir.



Şekil 4.39. B7 numaralı hasta için (a) el ile işaretlenmiş T1-ağırlıklı MR, (b) gri düzey ve (c) renkli bölütleme sonucu


Şekil 4.40'ta B9 numaralı test hastası için elle işaretlenmiş MR görüntüsü ile sistemden elde edilen bölütleme sonuçları gri düzey ve renkli olarak verilmiştir. Ödemi olmayan bu hastada sistemin ödem alanları bulduğu görülmektedir. Bunun yanında gri cevher, beyaz cevher ve BOS'un bölütlenmesinde yüksek başarı oranlarına erişilmiştir.



Şekil 4.40. B9 numaralı hasta için (a) el ile işaretlenmiş T1-ağırlıklı MR, (b) gri düzey ve (c) renkli bölütleme sonucu

4.4. Sistem Grafik Arayüzü

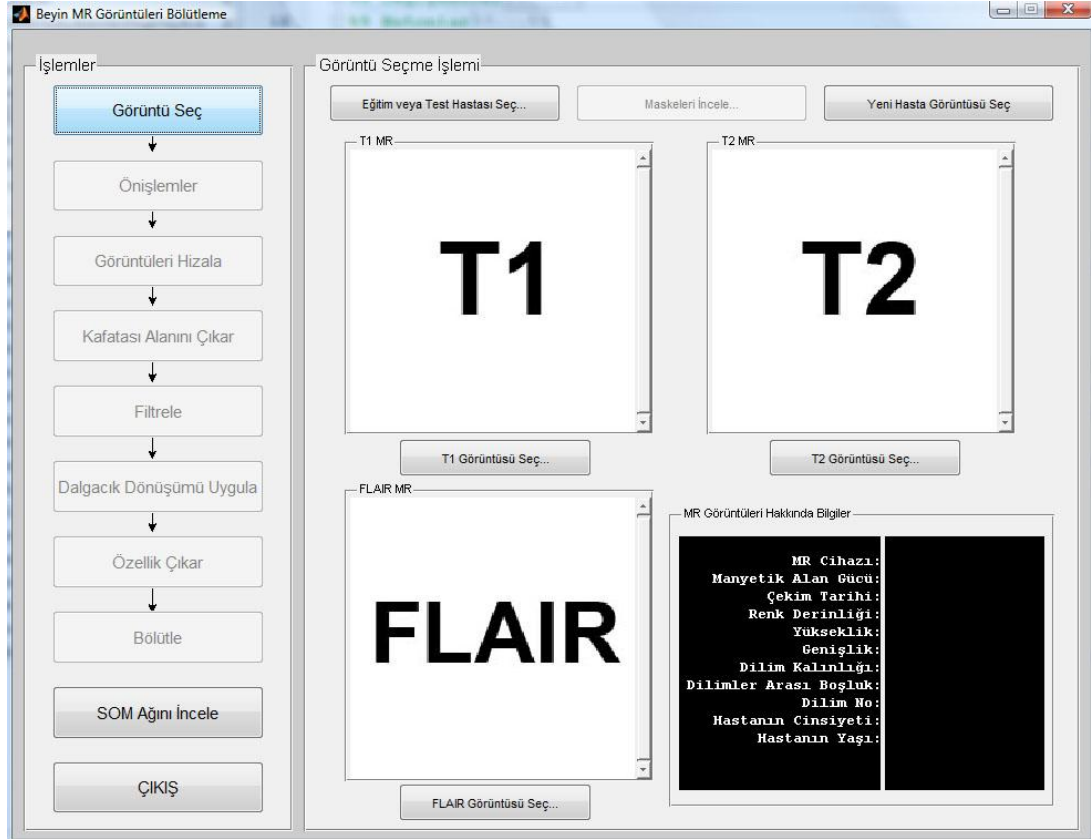
Geliştirilen sistemde bölütleme işlemini gerçekleştirmek için ardı ardına çeşitli işlem adımları çalıştırılmakta ve bu adımların tamamı bitirdikten sonra sonuca ulaşılabilir. Bu işlem adımlarını rahat ve kolay bir şekilde her adımdan elde edilen sonuçları görerek ve takip ederek gerçekleştirebilmek üzere bir grafik ara yüz geliştirilmiştir. Bu grafik ara yüz sayesinde sistemi geliştirirken kullanılan eğitim ve test veri kümeleri veya herhangi bir hastaya ait T1-ağırlıklı, T2-ağırlıklı ve FLAIR MR görüntüleri giriş olarak seçildiği takdirde bölütleme işlemi yapılabilmektedir. Şekil 4.41’de bu grafik ara yüzün açılış ekranı görülmektedir.



Şekil 4.41. Grafik ara yüz açılış ekranı

Sistemde işlem adımlarının sırasıyla gerçekleştirilmesi gerekmektedir. Bir işlem adımı gerçekleştirilmeden diğerine geçilmemesi gerektiğinden program ilk çalıştırıldığında yalnızca “Görüntü Seç”, “SOM Ağını İncele” ve “ÇIKIŞ”

seçenekleri aktif, diğer seçenekler pasiftir. Görüntüleri seçme işlemini gerçekleştirmek üzere “Görüntü Seç” butonuna tıkladığında ekran görüntüsü Şekil 4.42’deki gibi olmaktadır.



Şekil 4.42. Görüntü seçme ekranı

Burada kullanıcı sistemi eğitmekte ve ya test etmekte kullanılan veri kümelerinden birini veya yeni bir hastaya ait T1-ağırlıklı, T2-ağırlıklı ve FLAIR MR görüntülerini seçebilir. Seçilen görüntüler ekrandaki ilgili panellerde gösterilecektir. Eğer hazır veri setlerinden biri seçilirse “Maskeleri İncele” butonu aktifleşecektir. Görüntülere ait el ile işaretlenmiş alanları gösteren maskeler bu buton yardımıyla görüntülenebilir. Herhangi bir hastaya ait MR görüntüleri seçildikten sonra bu hastanın bilgileri sağ altta görülen “MR Görüntüleri Hakkında Bilgiler” kısmında görülecektir. Bir hasta ile işlem yaptıktan sonra ya da işlemi yarıda bırakarak başka bir hastaya ile işlem yapmak üzere “Yeni Hasta Görüntüsü Seç” butonu


kullanılabilir. Bu durumda daha önceki hastaya ait tüm bilgiler ve yapılmış tüm işlemler kaybolacaktır.

Hazır veri kümelerinde bulunan bir hasta seçildikten sonra “Maskeleri İncele” butonuna basıldığında Şekil 4.43’teki ekran görüntüsü elde edilir.




Şekil 4.43. İşaretli alanları incele ekranı

Burada T1-ağırlıklı, T2-ağırlıklı ya da FLAIR MR görüntülerinden herhangi biri üzerinde işaretli alanları inceleyebilmek için örneğin “T1 MR Üzerinde Seçili Alanlar...” butonuna basıldığında Şekil 4.44’teki ekran görüntüsü elde edilir.




Şekil 4.44. T1 MR üzerinde işaretli alanlarının gösterilmesi

Görüntü seçme işlemi tamamlandıktan sonra “Önişlemler” butonu aktifleşmektedir. Şekil 4.45’te önişlemler ekranı verilmiştir. Ön işlemler gerçekleştirildikten sonra “T1 Görüntüsü İncele”, “T2 Görüntüsü İncele” ve “FLAIR Görüntüsü İncele” butonları ilgili görüntülerin ayrı bir pencerede açılarak daha detaylı bir şekilde incelenebilmesine olanak tanınmaktadır. Tüm işlem adımlarında elde edilen sonuçlar grafik arayüz ile benzer şekilde incelenebilmektedir.




Şekil 4.45. Önişlemler ekranı

Önişlemler gerçekleştirildikten sonra “Görüntüleri Hizala” adımına geçilmektedir. Şekil 4.46’da bu işlemin gerçekleştirildiği ekranın görüntüsü verilmiştir. Üstteki panelde görüntülerin orijinal halleri, alttaki panelde ise “Görüntüleri Hizala” butonuna basıldıktan sonra elde edilen hizalanmış görüntüler görülmektedir. Hizalama işlemindeki değişiklikler oldukça küçük olduğunda gözle fark edilemeyebilir. Bu nedenle MR görüntüleri üzerinde gerçekleştirilen hizalama işlemi örnek bir görüntü olan Lena üzerinde de ayrıca gösterilmiştir (Şekil 4.47). “Hizalama Örneği...” butonuna basıldığında açılan yeni pencerede orijinal Lena görüntüsü ile birlikte döndürülmüş hali yan yana verilmiştir. “Görüntüyü Hizala” butonuna basıldığında eğri duran görüntü orijinal görüntü temel alınarak hizalanmaktadır.




Şekil 4.46. Görüntüleri hizala ekranı




Şekil 4.47. Örnek görüntü hizalama ekranı

Bir sonraki işlem adımı olan “Kafatası Alanını Çıkar” bölümünde görüntü içerisinde yalnızca ilgilenilen beyin dokuları bırakarak ilgilenilmeyen kafatası ve diğer bölgelerin görüntülerden çıkartılması işlemi gerçekleştirilmektedir (Şekil 4.48). Burada solda MR görüntüsü, sağda kafatası alanı çıkarılmış görüntü ve altta ise görüntüye ait yoğunluk dağılımı gösterilmektedir. Yoğunluk dağılımı üzerindeki ibre hareket ettirildiğinde eşik değeri değişmekte ve bu eşik değerine göre geliştirilen kafatası alanı çıkarma algoritmasından elde edilen sonuç sağda gösterilmektedir. İbreyi hareket ettirerek doğru sonuca ulaştıktan sonra Tamam butonuna basıldığında tüm MR görüntülerine aynı işlem uygulanmakta ve kafatası bölgesi çıkartılmış görüntüler ekranda görülmektedir (Şekil 4.49).



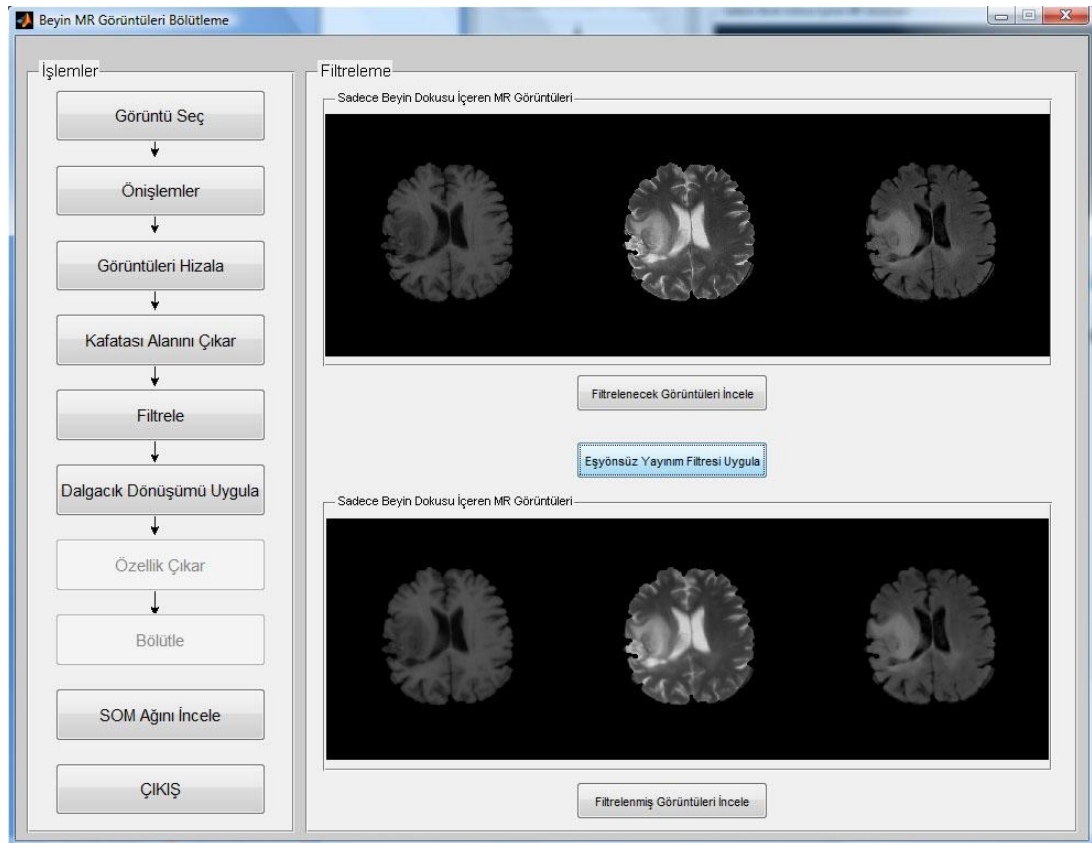
Şekil 4.48. Kafatası alanı çıkarma işleminin gerçekleştirildiği ekran




Şekil 4.49. Sadece beyin dokusu içeren MR görüntülerini gösteren ekran

Görüntülerden kafatası bölgesi çıkarıldıktan sonra filtreleme işlemine geçilmektedir. Bu adımda görüntüye eş yönsüz yayılım filtresi uygulanmaktadır. Şekil 4.50’de üstte kafatası alanı çıkarılmış görüntüler, altta ise bu görüntülerin filtrelenmiş halleri görülmektedir. İşlem öncesi ve sonrası görüntüleri “Görüntüleri İncele” butonları ile ayrıntılı olarak incelenebilmektedir.

Filtrelenmiş görüntülere bir sonraki adımda DDD uygulanmaktadır. Dönüşüme ait parametreleri gösteren, dönüşüm işlemi gerçekleştiren ve dönüşümün ardından T1-ağırlıklı, T2-ağırlıklı ve FLAIR MR görüntülerine ait dönüşüm katsayılarının incelenebildiği ekranın görüntüsü Şekil 4.51’de verilmiştir.




Şekil 4.50. Filtreleme işlemi ekranı



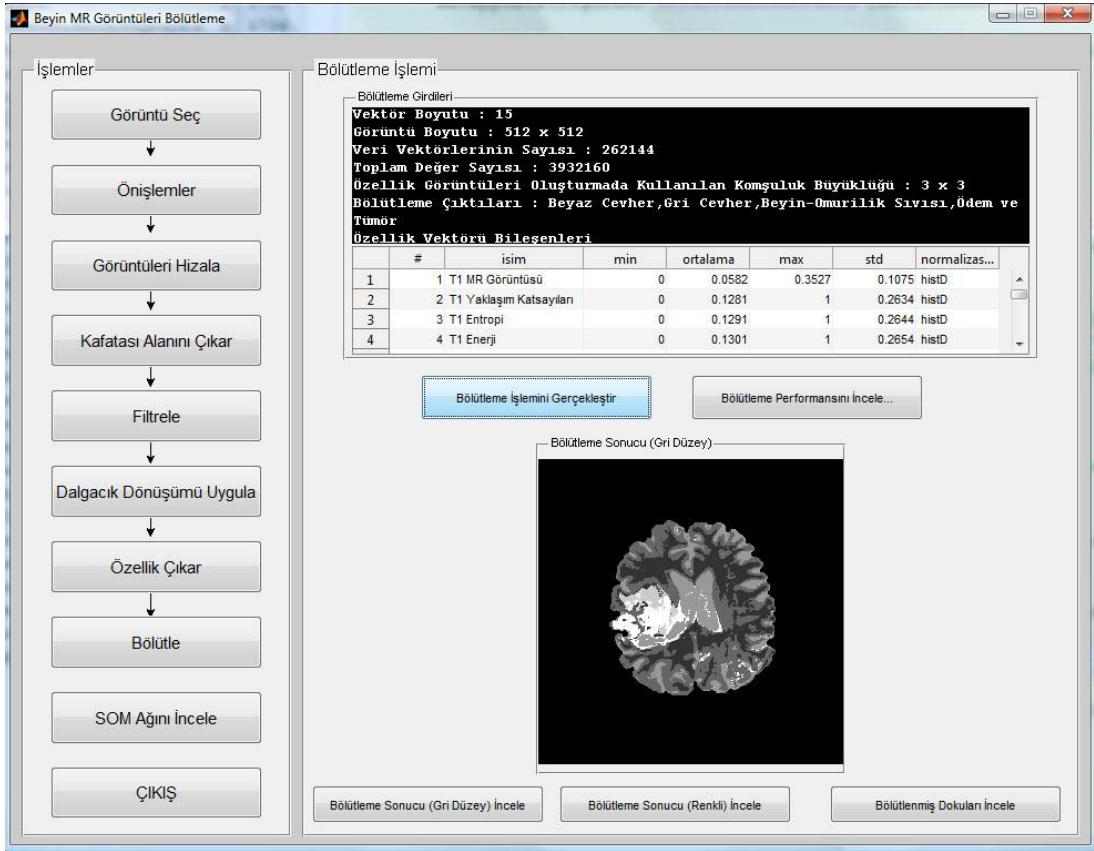
Şekil 4.51. Dalgacık dönüşümü uygulama ekranı

Dalgacık dönüşümü işlemini görüntülerden özellik çıkarma adımı takip etmektedir. Bu adımda yaklaşım dalgacık katsayılarından 3×3 boyutunda bir pencere ile pencereleme yöntemi kullanılarak entropi, enerji ve standart sapma özellikleri çıkarılmaktadır. Daha sonra elde edilen bu özellik görüntüleri histogram eşitlemesi yapılarak normalleştirilmektedir. Şekil 4.52'deki "Özellik Çıkar" ekranında T1-ağırlıklı, T2-ağırlıklı ve FLAIR MR görüntülerine bu işlem adımları uygulanmaktadır. Özellik görüntüleri soldan sağa sırasıyla; görüntüye ait yaklaşım katsayıları, entropi, enerji ve standart sapmadır. Ancak tüm görüntülerden özellik çıkarımı tamamlandığında bir sonraki aşama olan bölütleme işlemine geçilebilmektedir.




Şekil 4.52. Özellik çıkartma ekranı

“Bölütleme” ekranında öncelikle bölütleme işleminin girdilerine ait özellikler verilmiştir (Şekil 4.53). Seçilen hastadan elde edilen özellik vektörüne ait istatistiksel bilgiler de aynı ekranda bir tablo halinde görülebilmektedir. Bölütleme işlemi gerçekleştirildiğinde elde edilen bölütlenmiş görüntü pencerenin en altında yer alan “Bölütleme Sonucu (Gri Düzey) İncele” ve “Bölütleme Sonucu (Renkli) İncele” butonları yardımıyla ayrıntılı olarak incelenebilmektedir (Şekil 4.54).

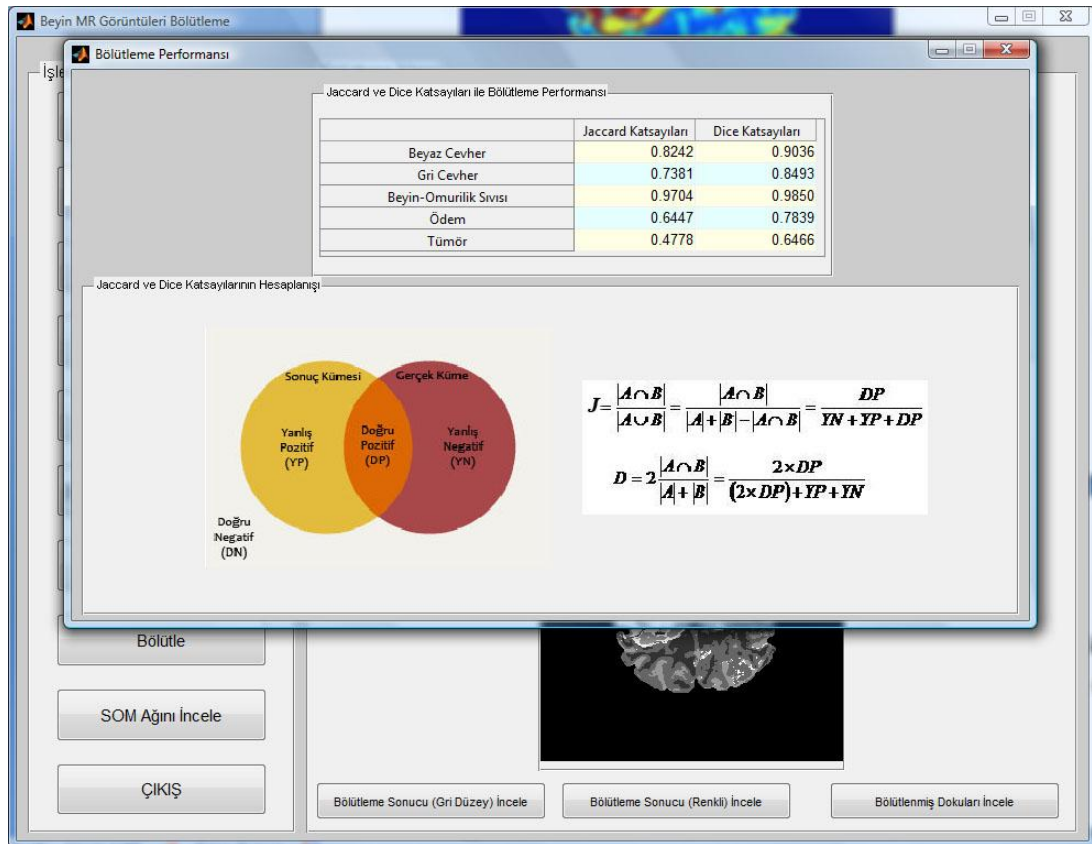


Şekil 4.53. Bölütleme ekranı




Şekil 4.54. Bölütleme sonucunun renkli olarak görüntülenmesi

Bölütleme işleminin ardından eğer üzerinde çalışılan hasta eğitim veya test veri kümelerinden birine aitse “Bölütleme Performansını İncele” butonu ile yeni bir pencere içinde Dice ve Jaccard benzerlik indeksleri ile performans değerlendirmesi yapılabilmektedir (Şekil 4.55). Eğer yeni bir hastaya ait görüntüler seçildiyse bölütleme sonucunu karşılaştırmak üzere elde gerçek küme değerleri olmadığından bu değerlendirme yapılamaz.



Şekil 4.55. Bölütleme performansı değerlendirme ekranı

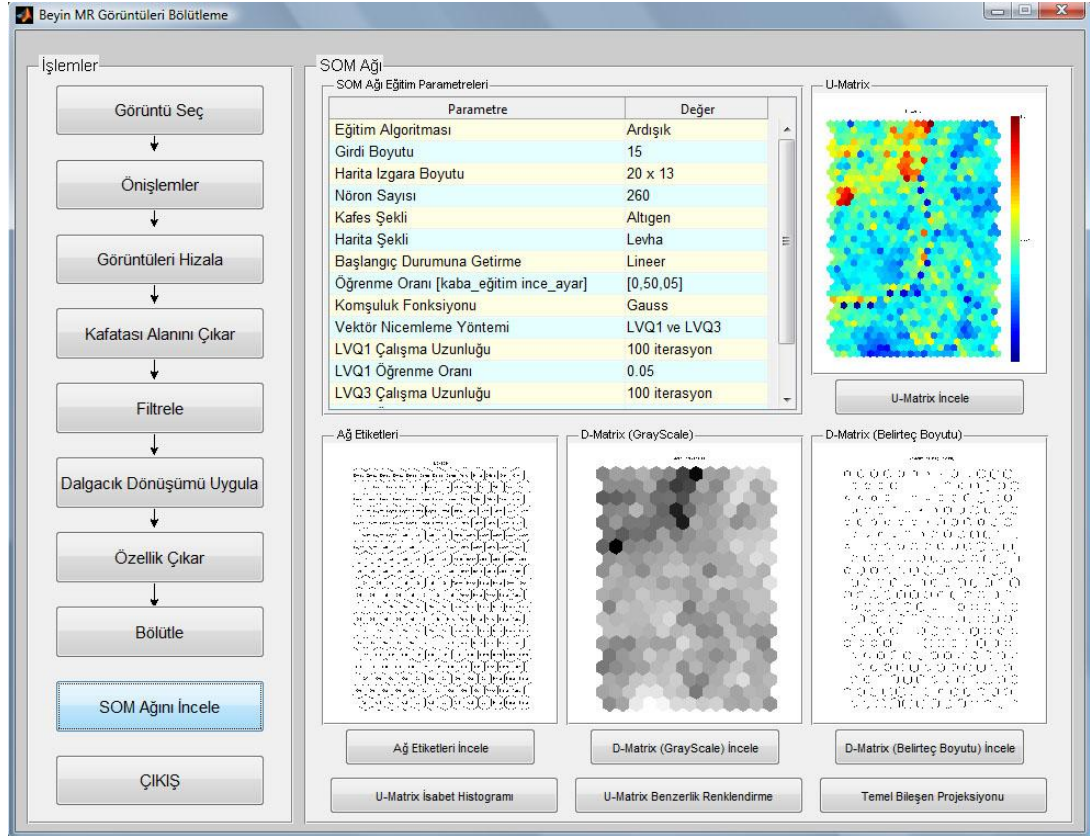
Bölütleme sonucunda “Bölütlenmiş Dokuları İncele” seçeneği ile bölütlemekten elde edilen tüm doku çeşitleri ayrı ayrı incelenebilmektedir (Şekil 4.56).



Şekil 4.56. Bölütlenmiş dokular

Bölütme işleminde kullanılan ve eğitim veri kümesindeki hasta görüntüleriyle eğitilmiş ağı incelemek ve ağı analizini yapmak için “SOM Ağını İncele” paneli geliştirilmiştir (Şekil 4.57). Bu ekranda öncelikle ağı eğitiminde kullanılan parametreler verilmiştir. U-matrisi SOM ağı için birleşik mesafe matrisidir. Bu matris ağıdaki nöronların ağılık vektörlerinin birbirlerine olan uzaklığını ifade etmektedir. Örneğin 5×1 boyutunda $m(1) \ m(2) \ m(3) \ m(4) \ m(5)$ şeklindeki bir ağda, $m(i)$ bir ağ birimini (nöron) temsil etmektedir. Bu ağ için u-matrisi 9×1 boyutunda bir vektör olacaktır; $u(1) \ u(1,2) \ u(2) \ u(2,3) \ u(3) \ u(3,4) \ u(4) \ u(4,5) \ u(5)$. Burada $u(i,j)$, $m(i)$ ve $m(j)$ ağ birimleri arasındaki mesafedir. $u(k)$ ise çevre değerlerin ortalamasıdır. Örneğin; $u(3) = (u(2,3) + u(3,4)) / 2$. D-matrisi, uzaklık matrisi demektir. U-matristen farklı olarak sadece ağ biriminin çevresindeki ağ birimlerinden uzaklığını vermektedir. “D-matrisi (GrayScale)” bu uzaklık değerini gri düzey renklerle, “D-matrisi (Belirteç Boyutu)” ise ağ biriminin büyüklüğünü değiştirerek ifade


etmektedir. “SOM Ağını İncele” paneli ile ağa ait U-matrisi, ağdaki birimlerin etiketleri ve D-matrisleri incelenebilmektedir.



Şekil 4.57. SOM ağını inceleme ekranı


SOM ağının girişinde kullanılan veriye verdiği tepki hesaplanabilmekte ve isabet histogramları olarak ifade edilebilmektedir. İsbet histogramı, her bir ağ biriminin girdi veri kümesi için kaç defa BMU olduğunu gösterir. Bu işlem tüm veri kümesinin geneli için uygulanabilir. Ayrıca girdi veri türlerinin her biri için ağın hangi biriminin en çok BMU olduğu ayrı ayrı tespit edilebilmektedir. Bu tez çalışmasında beyaz cevher, gri cevher, BOS, ödem ve tümör için ayrı ayrı ağın hangi biriminin en çok BMU olduğu tespit edilmiştir. Ağın etiketlenmesi işleminde de bu bilgidan faydalanılmıştır. İsbet histogramlarında hangi girdinin hangi veri türünü tespit ettiğinin bilinmesi gerektiğinden ancak eğitim ve test veri kümelerinde hesaplanabilmektedir. “SOM Ağını İncele” panelindeki “U-Matrix İsbet Histogramı” butonuna basıldığında Şekil 4.58 (a)’da verilen isbet histogramı ve

Şekil 4.58 (b)'de SOM ağındaki birimlerin etiketleri incelenebilir. İsalet histogramında beyaz renk beyaz cevheri, siyah gri cevheri, turuncu BOS'u, kırmızı ödemi ve pembe renk tümörü temsil etmektedir. İsalet sayısına ne kadar fazlaysa renkli alanların büyüklüğü de o kadar fazla olmaktadır.



Şekil 4.58. (a) U-Matrix isabet histogramı, (b) SOM ağındaki birimlerin etiketleri

Benzerlik renklendirme, nöronların ağırlık vektörlerinin temel bileşen izdüşümü üzerine bir renk haritasının yayılması ile üretilir. “SOM Ağını İncele” panelindeki “U-Matrix Benzerlik Renklendirme” butonu ile bu işlem gerçekleştirilebilir (Şekil 4.59).



Şekil 4.59. Benzerlik renklendirme

Vektör izdüşümünde yüksek boyutlu bir veri örnekleri kümesi veri örnek çiftleri arasındaki mesafe mümkün olduğunca korunarak daha düşük boyuta yansıtılır. Ağın ağırlık vektörlerinin yansıtılması ve komşu ağ birimlerinin çizgilerle birleştirilmesi SOM ağına kendi karakteristik ağ-benzeri görünümünü verir. İzdüşüm görüntüleri ağ düzlemleri ile renk kodlaması ile ilişkilendirilebilir. “SOM Ağını İncele” panelindeki “Temel Bileşen Projeksiyonu” ile bu işlem gerçekleştirilebilir. Bu işlem ile elde edilecek sonuç görüntüsü Şekil 4.32’de verilmiştir.

5. SONUÇLAR VE DEĞERLENDİRME

Bu tez çalışması kapsamında klinik teşhis ve tedavi amaçları için beyin MR görüntülerini otomatik olarak bölütleyen bir yazılım sistemi geliştirilmiştir. Beyin MR görüntülerinin bölütlenmesi beyin tümörleri ve diğer nörolojik hastalıkların teşhisi amacıyla gerekli olan çok önemli ve zor bir görevdir. Beyin MR görüntülerinin gri cevher, beyaz cevher ve BOS gibi doku sınıflarına bölütlenmesi klasik bir problemdir. Ancak beyinde tümör, lezyon, ödem gibi hastalıklı bölümler bulunan kişilerde bu bölgelerin yerlerini ve hastalıklı dokuların büyüklüklerini tespit etmek tanı koyulmasında yardımcı olmakta, uygulanacak cerrahi operasyon öncesinde doktorlara yol göstermekte ve cerrahi operasyonun planlanması aşamasında oldukça faydalı olmaktadır. Aynı zamanda radyasyon tedavisini planlamada, tedavi sonunda ödem, kangren, yaralı dokular gibi bölgeleri ayırt ederek tedavi edici yöntemlerin başarısının izlenmesinde beyin normal dokuları ile birlikte hastalıklı dokularının da bölütlenmesi gerekmektedir.

Literatürde beyin dokularını beyaz cevher, gri cevher ve BOS olarak bölütleyen çalışmaların yanında, tümörlü hastalar üzerinde yapılan ve yalnızca tümör ya da tümör ile birlikte yalnızca ödem dokularını bölütleyen çalışmalar da mevcuttur. Beyin tümörleri sağlıklı beyin dokularını tahrip eder. Beyindeki basıncı artırır, beyni kaydırarak ve kafatasına doğru iterek işgal eder ve hasar verir. Bu nedenle, beyin tümörleri ile birlikte tümörün neden olduğu ödem ve sağlıklı dokuların bir arada incelenmesi gerekir. Literatürde bu tez çalışmasındaki yöntemleri kullanarak tümör ve ödem ile birlikte sağlıklı beyin dokularını bir arada bölütleyen bir çalışma bulunmamaktadır. Bu çalışmada, beyin MR görüntüleri gri cevher, beyaz cevher ve BOS sağlıklı beyin dokuları ile varsa tümör ve ödem hastalıklı dokularına bölütlenmektedir.

Bu çalışmada, gerçek beyin görüntüleri kullanılarak oluşturulmuş benzetim görüntülerinden oluşan beyin modeli, sağlıklı kişilere ait beyin MR görüntüleri ile beyinde tümör bulunan kişilere ait hastaneden toplanan beyin MR görüntüleri üzerinde beyin dokularının bölütlenmesi işlemi gerçekleştirilmiştir.

Bu çalışmada, benzetim görüntüleri içeren ve son yıllarda tıbbi görüntü analizlerinin doğrulanmasında fiilen bir standart haline gelmiş BrainWeb veritabanı üzerinde beyni gri cevher, beyaz cevher ve BOS şeklinde bölütleyen bir sistem geliştirilmiştir. BrainWeb veritabanı gerçek kişilerin beyin MR görüntüleri kullanılarak oluşturulmuştur. T1-ağırlıklı, T2-ağırlıklı ve PD MR görüntüler ile birlikte uzman nöro-anatomistler tarafından bölütlenmiş kesin referans görüntülerini de içermektedir. Bu nedenle geliştirilen sistemden elde edilen bölütleme sonuçlarının doğruluğu kesin referans görüntüsü ile yapılan karşılaştırmalar ile kolaylıkla tespit edilebilmiştir. Görüntülerde kafanın beyin dokusu dışındaki kısımları hariç tutulmuş ve görüntü içinde yalnızca tez konusu kapsamında ilgilenilen dokular bırakılmıştır. BrainWeb benzetim görüntülerinde kesin referans görüntüsünün her piksel değeri farklı bir doku türünü temsil ettiğinden ilgilenilmeyen dokulara ait piksel değerleri sıfırlanarak arka plan haline getirilmiştir. Görüntülerden özellik çıkarma yöntemi olarak dalgacık paket dönüşümü kullanılmıştır. Dalgacık dönüşümü işlemi için kullanılacak dalgacığın seçilmesi ya da dönüşümün uygulanacağı seviye sayısı standart kurullarla belirlenmemektedir. Bu nedenle MR görüntülerine farklı dalgacıklar kullanarak farklı seviyelerde dalgacık paket dönüşümü uygulanarak dalgacık paket ağacı ve katsayıları bulunmuş, dalgacık paketi ağacı içinden en iyi entropi değerine göre en iyi alt ağaç tespit edilmiş ve MR görüntüleri en iyi dalgacık paketi alt ağacına göre yeniden oluşturulmuştur. Yeniden oluşturulan bu görüntüler SOM ağında kullanılarak benzetim görüntülerinin bölütlenmesi sağlanmıştır. Sonuçlar elle bölütlenmiş kesin referans görüntüsü ile karşılaştırılarak değerlendirilmiştir.

BrainWeb veritabanından Dice benzerlik indeksine göre arka plan için %99,96, BOS için %96,35, gri cevher için %95,77 ve beyaz cevher için ise %98,45 bölütleme doğruluğu elde edilmiştir. Jaccard benzerlik indeksine göre elde edilen bölütleme doğruluk oranları ise arka plan için %99,92, BOS için %92,96, gri cevher için %91,88 ve beyaz cevher için ise %96,95 olmuştur. Bu değerler aynı veritabanı üzerinde yapılan diğer çalışmalarla karşılaştırıldığında tüm doku türleri için daha iyi sonuçlar alındığı görülmektedir [35, 116]. Örneğin, Shattuck ve arkadaşları en büyük

sonsal (maximum a posteriori) sınıflandırıcı ile yaptıkları çalışmada Jaccard benzerlik indeksine göre gri cevher için %80,8 ve beyaz cevher için %86,7 doğru bölütleme oranlarına erişmişlerdir [116]. Grau ve arkadaşlarının havza dönüşümü (watershed transform) ve atlas çakıştırma yöntemlerini bir arada kullandıkları çalışmalarında Dice benzerlik ölçütüne göre elde ettikleri doğru bölütleme oranları beyaz cevherde %94,56, gri cevherde ise %89,02 olmuştur [35].

Bu çalışmada, tüm dünyadaki araştırmacıların faydalanarak katkı sağladıkları bir veritabanı olan IBSR veritabanında bulunan 20 sağlıklı kişiye ait T1-ağırlıklı MR görüntüleri ve bu görüntülerin gri cevher, beyaz cevher ve diğer şeklinde uzmanlar tarafından bölütlenmiş halleri bölütleme işleminin eğitiminde ve test edilmesinde kullanılmıştır. Veritabanında beyin görüntülerinin sadece ilgilenilen kısımları olan beyin bölgesini içeren görüntüler ve bu görüntülerin elle bölütlenmiş halleri bulunmaktadır. Bölütleme işleminde bu görüntüler kullanılmıştır. Eğitim ve test için ayrılan görüntüler bölütleme işleminde kullanılmadan önce bölge içlerini yumuşatıp kenarları belirginleştiren eşyönsüz yayılım filtresinden geçirilmiştir. Farklı dokuları birbirinden ayırt etmekte kullanılacak özellikleri görüntülerden çıkarmak için DDD yöntemi uygulanmıştır. DDD yönteminde diğer dalgacık dönüşümü yöntemlerinden farklı olarak, dönüşüm sırasında alt örnekleme işlemi yapılmamaktadır. Bu nedenle dönüşüm sonucunda elde edilen alt görüntüler ile orijinal görüntünün boyutları aynıdır. Bu sayede her piksel için tanımlayıcı özellikler dönüşüm sonucunda elde edilen katsayılardan pencereleme yöntemi ile çıkarılabilir. Görüntülerin bölütlenmesi işleminde sadece DDD ile elde edilen ham katsayıları kullanmak yeterli değildir. Bu katsayılara ek olarak yerel istatistiksel bilgiyi ifade edecek özellikler görüntü üzerinde 3×3 boyutunda bir pencere gezdirilerek elde edilmiştir. Bu özellikler ortalama mutlak sapma, entropi, enerji ve standart sapmadır. DDD ile elde edilen katsayılar ve bu katsayılardan pencereleme ile elde edilen özellikler bir araya getirilerek özellik vektörü oluşturulmuştur. Eğitim ve test işlemlerinde kullanılacak her görüntü için, oluşturulan özellik vektöründe etiket olarak doku türlerinin isimleri kullanılmıştır. SOM ağı oluşturulup, danışmansız eğitim işleminden geçirildikten ve etiketlendikten sonra nöronların problem için en uygun yerleşimini sağlamak için

girdi verileri kullanılarak danışmanlı eğitim gerçekleştirilmiştir. Bu aşamada çeşitli sınıfların ve ya kümelerin ağırlık vektörlerine LVQ kullanılarak ince ayar yapılmıştır. Danışmanlı öğrenme işlemine LVQ1 ile başlanıp sistemin tanıma doğruluğunu arttırmak üzere LVQ3 ile devam edilmiştir. Danışmansız eğitim ile eğitilen ve LVQ ile kalibre edilen SOM ağıının performansı test görüntüleri kullanılarak değerlendirilmiştir. Elde edilen sonuçlar ortalama örtüşme metriği de denilen Jaccard ve Dice benzerlik indekslerine göre değerlendirilmiştir.

Sistemden elde edilen sonuçlar IBSR veritabanının resmi sitesinde duyurulan farklı metotların sonuçlarıyla Jaccard benzerlik indeksi göre karşılaştırıldığında geliştirilen sistemin gri cevher alanları ayırt etmede diğer yöntemlere göre üstünlük sağladığı görülmektedir. Gri cevherin bölütlenmesinde 6 farklı metottan (MAP, Adaptif MAP, Eğilimli MAP, Bulanık c-ortalamlar, Maximum-Likelihood) elde edilen ortalama bölütleme doğruluğu %53 iken [82] geliştirilen sistemde bu değer %13 arttırılarak %66 doğruluğa ulaşılmıştır. Beyaz cevher için 6 farklı metottan elde edilen ortalama bölütleme başarısı %56 iken geliştirilen sistem %55 doğruluk oranına ulaşmıştır.

Bu çalışmada, tümörlü hastaların görüntülerini bölütlemek için yetişkinlerde beyinde en sık görülen, kansere yol açan ve ölüm oranı yüksek tümör türü olan glial tümörlü hastalar ile çalışılmıştır. Glial tümörü bulunan 20 adet hastaya ait T1-ağırlıklı, T2-ağırlıklı ve FLAIR MR görüntüleri kullanılarak beyin MR görüntülerini gri cevher, beyaz cevher ve BOS normal beyin dokuları ile tümör ve ödem hastalıklı dokularına bölütlenmiştir. Görüntülerdeki etki alanını ve rastgele gürültüyü ortadan kaldırmak için eşyönsüz yayılımı filtresi tüm görüntülere uygulanmıştır. MR çekimi sırasında kafanın hareket ettirilmesi nedeniyle oluşan kaymaların düzeltilmesi için görüntüler çakıştırılarak aynı koordinat sistemine hizalanmıştır. Beyin dokusu dışındaki alanlar eşikleme ve morfolojik işlemlerin bir arada kullanıldığı bir yöntem ile görüntülerden çıkartılmıştır. DDD ile elde edilen katsayı görüntüleri ve bu görüntülerden uzaysal filtreleme metotları ile elde edilen özellikler bir arada kullanılarak özellik vektörü oluşturulmuştur. Bölütleme işlemi için SOM ağı danışmansız öğrenme algoritması ile eğitilmiştir. Beyaz cevher, gri cevher, BOS, tümör ve ödem bölgelerini gösteren alanlar hastaların her birinde ilgilenilen dilim için el ile işaretlenmiştir. SOM ağıının

çıkışı el ile işaretlenmiş görüntü bölgeleri ve çıkış nöronlarının isabet histogramına dayanarak geliştirilen algoritma ile etiketlenmiştir. SOM ağının eğitimi ve etiketlenmesi işleminin ardından ağın çıkış nöronlarının en iyi konumunu ayarlamak için danışmanlı LVQ algoritması kullanılmıştır.

Sistemden elde edilen sonuçlar elle yapılan bölütleme ile örtüşme oranlarını gösteren Dice benzerlik indeksinin yanında duyarlılık ve belirlilik ölçütlerine göre değerlendirilmiştir. Dice benzerlik indeksine göre beyaz cevher %91, gri cevher %87, BOS %96, tümör %56 ve ödem %77 oranında doğru bölütlenmiştir. Sistemden elde edilen duyarlılık ve belirlilik değerleri ise sırasıyla beyaz cevher için %96 ve %96, gri cevher için %90 ve %97, BOS için %99 ve %98, tümör için %49 ve %95, ödem için ise %96 ve %56 olmuştur.

Elde edilen değerler glial tümörlü hastalar ile yapılan diğer çalışmalarla, bu çalışmalarda yalnızca tümör ve ya tümör ve ödem bölütlendiği için bu dokular için karşılaştırılabilmektedir. Corso ve arkadaşları glial tümörün bir alt türü olan glioblastoma multiforme hastası 20 kişi ile yaptıkları çalışmada Bayes model tabanlı sınıflama yöntemini kullanmışlar ve Jaccard benzerlik indeksine göre tümörde %69, ödemde %62 bölütleme doğruluğuna erişmişlerdir [14]. Iftekharuddin ve arkadaşları 3'ü glial tümörlü olmak üzere toplam 9 pediatrik hasta ile yaptıkları çalışmada SOM ağını kullanmışlar ve yalnızca tümörü bölütlemişlerdir. Çalışmalarında %90 duyarlılık değerine ulaşmışlardır [16]. Dou ve arkadaşları bulanık bilgi füzyonunu kullandıkları çalışmalarında glial tümörlü 4 hasta ile çalışmışlardır. Yalnızca tümör dokusunun bölütlendiği çalışmada (doğru pozitif sayısı) / (toplam voksel sayısı) şeklinde hesapladıkları %96 doğru bölütleme oranına erişmişlerdir [17].

Sonuç olarak, DDD ve SOM ağlarının beyaz cevher, gri cevher ve BOS dokularını bölütlemekte oldukça yüksek performans sergilediği bunun yanında ödem ve tümör dokuları için elde edilen doğruluk oranlarının görece olarak daha düşük olduğu görülmektedir.

Üzerinde çalışılan tümör türünün homojen olmayan yapısı, sınırları ayırt edilemeyen nekrotik ve aktif kısımlar ile şişkinlik gibi farklı özellikte alanlar içermesi ve tümörün kan içeriği yoğun olduğunda ödem ya da sıvı gibi görünmesi olarak sayılabilecek nedenlerle daha düşük olan ödem ve tümör bölütleme doğruluk oranlarını arttırmak üzere ek yöntemler uygulanabileceği tespit edilmiştir.

Sistemden elde edilen sonuçların başarımını arttırmak üzere görüntülere model ya da şekil tabanlı yöntemler işlem sonrasında uygulanabilir. Daha fazla hasta verisine ulaşılabilmesi durumunda sistemin başarısı artırılabilir. Geliştirilen sistem MR tarayıcı cihazı yazılımına gömülerek MR görüntüleri kaydedildiği anda analizi otomatik olarak yapılabilir. Geliştirilen görüntü bölütleme sistemi yalnızca beyin MR görüntülerinin bölütlenmesi amacıyla kullanılmıştır. Bu sistem vücudun herhangi bir bölgesine ait görüntülerin bölütlenmesi amacıyla kullanılabilir şekilde çalışmaya uygundur. Sistem yalnızca sağlıklı beyin dokularını bölütleyecek şekilde düzenlenirse multipl skleroz, Alzheimer vb. gibi sağlıklı beyin dokularını etkileyen hastalıkların teşhisinde de kullanılabilir.

KAYNAKLAR

1. Robb, R. A., “Biomedical Imaging, Visualization and Analysis”, *Wiley-Liss, Inc.*, U.S.A., 34-42 (2000).
2. Rangayyan, R. M., “Biomedical Image Analysis”, *CRC Press*, U.S.A., 47-53, 583-638 (2005).
3. İnternet: University of California, Center for Functional MRI, Hesselink, J. R., “Basic Principles of MR Imaging” <http://spinwarp.ucsd.edu/neuroweb/Text/br-100.htm> (2008).
4. Langleben, D. D. ve Segall, G. M., “PET in Differentiation of Recurrent Brain Tumor from Radiation Injury”, *J. Nucl. Med.*, 41: 1861–1867 (2000).
5. İnternet: University of Maryland Medical Center, “Brain Tumors – Primary – Introduction”, http://www.umm.edu/patiented/articles/what_brain_tumors_000089_1.htm (2011).
6. İnternet: UCLA Neurosurgery “Glioma”, <http://neurosurgery.ucla.edu/body.cfm?id=159> (2011).
7. Rogowska, J., “Overview and Fundamentals of Medical Image Segmentation”, *Handbook of Medical Imaging: Processing and Analysis*, Editör: Bankman, I., *Academic Press*, Orlando, 69-85 (2000).
8. Pham, D. L., Xu, C. ve Prince, J. L., “Current Methods in Medical Image Segmentation”, *Annu. Rev. Biomed. Eng.*, 2: 315–337 (2000).
9. Jiménez-Alaniz, J. R., Medina-Bañuelos, V. ve Yáñez-Suárez, O., “Data-Driven Brain MRI Segmentation Supported on Edge Confidence and A Priori Tissue Information”, *IEEE Trans. Med. Imag.*, 25 (1): 74-83 (2006).

10. Reddick, W. E., Glass, J. O., Cook, E. N., Elkin, T. D. ve Deaton, R. J., “Automated Segmentation and Classification of Multispectral Magnetic Resonance Images of Brain Using Artificial Neural Networks”, *IEEE Trans. Med. Imag.*, 16 (6): 911-918 (1997).
11. Song, T., Jamshidi, M. M., Lee, R. R. ve Huang, M., “A Modified Probabilistic Neural Network for Partial Volume Segmentation in Brain MR Image”, *IEEE Trans. Neural Netw.*, 18 (5): 1424-1432 (2007).
12. Vrooman, H. A., Cocosco, C. A., Lijn, F., Stokking, R., Ikram, M. A., Vernooij, M. W., Breteler, M. B. ve Niessen, W. J., “Multi-Spectral Brain Tissue Segmentation Using Automatically Trained k-Nearest-Neighbor Classification”, *NeuroImage*, 37: 71–81 (2007).
13. Alirezaie, J., Jernigan, M. E. ve Nahmias, C., “Automatic Segmentation of Cerebral MR Images Using Artificial Neural Networks”, *IEEE Trans. Nucl. Sci.*, 45 (4): 2174-2182 (1998).
14. Corso, J. J., Sharon, E., Dube, S., El-Saden, S., Sinha, U. ve Yuille, A., “Efficient Multilevel Brain Tumor Segmentation with Integrated Bayesian Model Classification,” *IEEE Trans. Med. Imag.*, 27 (5): 629-640 (2008).
15. Ahmed, S., Iftekharuddin, K. M. ve Vossough, A., “Efficacy of Texture, Shape, and Intensity Feature Fusion for Posterior-Fossa Tumor Segmentation in MRI,” *IEEE Trans. Inf. Technol. Biomed.*, 15 (2): 206-213 (2011).
16. Iftekharuddin, K. M., Zheng, J., Islam, M. A., Ogg, R. J., “Fractal-Based Brain Tumor Detection in Multimodal MRI,” *Appl. Math. Comput.*, 207: 23–41 (2009).
17. Dou, W., Ruan, S., Chen, Y., Bloyet, D., Constans, J.-M., “A Framework of Fuzzy Information Fusion for the Segmentation of Brain Tumor Tissues on MR Images”, *Image Vision Comput.*, 25: 164–171 (2007).

18. Zhang, N., Ruan, S., Lebonvallet, S., Liao, Q., Zhu, Y., “Kernel Feature Selection to Fuse Multi-Spectral MRI Images for Brain Tumor Segmentation,” *Comput. Vis. Image Und.*, 115: 256–269 (2011).
19. Kaus, M. R., Warfield, S. K., Nabavi, A., Black, P. M., Jolesz, F. A., Kikinis, R., “Automated Segmentation of MR Images of Brain Tumors,” *Radiology*, 218: 586–591 (2001).
20. Khotanlou, H., “3D Brain Tumors and Internal Brain Structures Segmentation in MR Images”, Doktora Tezi, *Informatique, Telecommunications et Electronique, Telecom ParisTech*, Paris, 65-129 (2008).
21. Prastawa, M., Bullitt, E., Ho, S., Gerig, G., “A Brain Tumor Segmentation Framework Based on Outlier Detection”, *Med. Imag. Anal.*, 8: 275–283 (2004).
22. Straka, M., Cruz, A. L., Köchl, A., Sramek, M., Gröller, M. E., Fleischmann, D., “3D Watershed Transform Combined with a Probabilistic Atlas for Medical Image Segmentation”, *J. Med. Inform. & Technol.*, 6: IT 69-78 (2003).
23. Kaus, M., Warfield, S. K., Jolesz F. A. ve Kikinis, R., “Adaptive Template Moderated Brain Tumor Segmentation in MRI”, *Bildverarbeitung in der Medizin*, Springer, 102–106 (1999).
24. Brown, M. S., Mcnitt-Gray, M. F., Nicholas, J. G. G., Mankovich, J., Hiller, J., Wilson, L. S. ve Aberle, D. R., “Method for Segmenting Chest CT Image Data Using an Anatomical Model: Preliminary Results”, *IEEE Trans. Med. Imag.*, 16 (6): 828-839 (1997).
25. Chang, H.-H., Valentino, D. J., Duckwiler, G. R. ve Toga, A. W., “Segmentation of Brain MR Images Using a Charged Fluid Model,” *IEEE Trans. Biomed. Eng.*, 54 (10): 1798-1813 (2007).
26. Sezgin, M., Sankur, B., “Survey Over Image Thresholding Techniques and Quantitative Performance Evaluation”, *J. Electron. Imaging*, 13 (1):146-165 (2004).

27. Cai, J. ve Liu, Z.-Q., “A New Thresholding Algorithm Based on All-Pole Model”, *14th Int. Conf. Pattern Recogn.*, 1: 34-36 (1998).
28. Sahho, P., Wilkins, C. ve Yeager, J., “Threshold Selection Using Renyi's Entropy”, *Pattern Recogn.*, 30 (1):71-84 (1997).
29. Shapiro, V. A., Veleva, P. K. ve Sgurev, V. S., “An Adaptive Method for Image Thresholding”, *11th Int. Conf. Pattern Recogn.*, The Hague, Netherlands, 3: 696-699 (1992).
30. Chen, P. ve Pavlidis, T., “Image Segmentation as an Estimation Problem”, *Comput. Vision Graph.*, 12:153-172, (1980).
31. Adams, R. ve Bischof, L., “Seeded Region Growing”, *IEEE T. Pattern Anal.*, 16 (6): 641-647 (1994).
32. Yu, X., Yla-Jaaski, J., Huttunen, O., Vehkomaki, T., Sipila, O. ve Katila, T., “Image Segmentation Combining Region Growing and Edge Detection”, *11th Int. Conf. Pattern Recogn.*, The Hague, Netherlands, 3: 481-484 (1992).
33. Roerdink, J. ve Meijster, A., “The Watershed Transform: Definitions, Algorithms and Parallelization Strategies”, *Fund. Inform.*, 41: 187-228 (2001).
34. Najman, L. ve Schmitt, M., “Geodesic Saliency of Watershed Contours and Hierarchical Segmentation”, *IEEE T. Pattern Anal.*, 18 (12): 1163-1173 (1996).
35. Grau, V., Mewes, A. U. J., Alcaniz, M., Kikinis, R. ve Warfield, S. K., “Improved Watershed Transform for Medical Image Segmentation Using Prior Information”, *IEEE Trans. Med. Imag.*, 23 (4): 447-458 (2004).
36. Kong, J., Wang, J., Lu, Y., Zhang, J., Li, Y., Zhang, B., “A Novel Approach for Segmentation of MRI Brain Images”, *13th IEEE Mediterr. Electrotech. Conf.*, Malaga, Spain, 525-528 (2006).

37. Boudraa, A., Zaidi, H., “Image Segmentation Techniques in Nuclear Medicine Imaging”, *Quantitative Analysis in Nuclear Medicine Imaging*, Editör: Zaidi, H., **Springer**, New York, 308– 357 (2005).
38. Gonzalez, R. C., Woods, R. E., “Digital Image Processing”, **Prentice Hall**, New Jersey, 116-119, 349-402, 519-560 (2002).
39. Clark, M. C., Hall, L. O., “Automatic Tumor Segmentation Using Knowledge-Based Techniques”, **IEEE Trans. Med. Imag.**, 17 (2): 187-201 (1998).
40. Li, C., Goldgof, D. ve Hall, L., “Knowledge-Based Classification and Tissue Labeling of MR Images of Human Brain”, **IEEE Trans. Med. Imag.**, 12 (4): 740-750 (1993).
41. Loncaric, S., Kovacevic, D., Cosic, D., “Fuzzy Expert System for Edema Segmentation”, **9th IEEE Mediterr. Electrotech. Conf.**, 2: 1476-1479 (1998).
42. Matesin, M., Loncaric, S., Petracic, D., “A Rule-Based Approach to Stroke Lesion Analysis from CT Brain Images”, **2nd Int. Sym. Imag. Signal Process. Anal.**, Croatia, 219–223 (2001).
43. Tian, D., Fan, L., “A Brain MR Images Segmentation Method Based on SOM Neural Network”, **1st Int. Conf. Bioinform. Biomed. Eng.**, Wuhan, 686-689 (2007).
44. Morra, L., Lamberti, F., Demartini, C, “A Neural Network Approach to Unsupervised Segmentation of Single-Channel MRI Images”, **1st Int. IEEE EMBS Conf. Neural Eng.**, Italy, 515-518 (2003).
45. Murino, V., Vernazza, G., “Artificial Neural Networks for Image Analysis and Computer Vision”, **Image Vision Comput.**, 19 (9): 583-584 (2001).
46. Dokur, Z. ve Ölmez, T., “Segmentation of MR and CT Images by Using a Quantiser Neural Network”, **Neural Comput. Appl.**, 11:168–177 (2003).

47. Egmont-Petersen, M., Ridder, D., Handels, H., “Image Processing with Neural Networks – a Review”, *Pattern Recogn.* 35: 2279-2301 (2002).
48. Boer, R., Vrooman, H. A., Ikram, M. A., Vernooij, M. W., Breteler, M. M. B., Lugt, A., Niessen, W. J., “Accuracy and Reproducibility Study of Automatic MRI Brain Tissue Segmentation Methods”, *NeuroImage*, 51: 1047–1056 (2010).
49. Chaplot, S., Patnaik, L. M., Jagannathan, N., “Classification of Magnetic Resonance Brain Images Using Wavelets as Input to Support Vector Machine and Neural Network”, *Biomed. Signal Proces.*, 1 (1): 86-92 (2006).
50. Güler, İ., Demirhan, A., Karakiş, R., “Interpretation of MR Images Using Self-Organizing Maps and Knowledge-Based Expert Systems”, *Digit. Signal Process.*, 19: 668-677 (2009).
51. Glass, J. O., Reddick, W. E., Reeves, C. ve Pui, C.-H., “Improving the Segmentation of Therapy-Induced Leukoencephalopathy in Children with Acute Lymphoblastic Leukemia Using a Priori Information and a Gradient Magnitude Threshold”, *Magn. Reson. Med.*, 52: 1336–1341 (2004).
52. Vijayakumar, C., Damayanti, G., Pant, R., Sreedhar, C. M., “Segmentation and Grading of Brain Tumors on Apparent Diffusion Coefficient Images Using Self-Organizing Maps”, *Comput. Med. Imag. Grap.*, 31: 473–484 (2007).
53. Demirhan, A., Güler, İ., “Image Segmentation Using Self-Organizing Maps and Gray Level Co-Occurrence Matrices”, *J. Fac. Eng. Arch. Gazi Univ.*, 25 (2): 285-291 (2010).
54. Demirhan, A., Güler, İ., “Using Wavelet Transform and Neural Networks for the Analysis of Brain MR Images”, *IEEE 18th Signal Proc. Commun. Appl. Conf.* , Diyarbakır, 933-936 (2010).
55. Sutton, M. A., Bezdek, J. C., Cahoon, T. C., “Image Segmentation by Fuzzy Clustering: Methods and Issues”, *Handbook of Medical Imaging: Processing and Analysis*, Editör: Bankman, I., *Academic Press*, Orlando, 87-106 (2000).

56. Liew A. W.-C, Yan, H., “An Adaptive Fuzzy Clustering Algorithm for Medical Image Segmentation”, *Int. Worksh. Med. Imag. Aug. Real.*, Shatin, Hong Kong , China, 272-277 (2001).
57. Selvathi, D., Arulmurgan, A., Selvi, S. T., Alagappan, S., “MRI Image Segmentation Using Unsupervised Clustering Techniques”, *6th Int. Conf. Comput. Int. Multimed. Appl.*, Las Vegas, Nevada, 105-110, (2005).
58. Sasikala, M. ve Kumaravel, N., “Wavelet Based Automatic Segmentation of Brain Tumors Using Optimal Texture Features”, *4th Kuala Lumpur Int. Conf. Biomed. Eng.*, Glasgow, UK, 21: 637-640 (2008).
59. Haykin, S., “Neural Networks: A Comprehensive Foundation”, *Prentice-Hall*, New Jersey, 443-484 (1999).
60. Ozkan, M., Dawant, B. M. ve Maciunas, R. J., “Neural-Network Based Segmentation of Multi-Modal Medical Images: A Comparative and Prospective Study”, *IEEE Trans. Med. Imag.*, 12: 534–544 (1993).
61. Kohonen, T., “The Self-Organizing Maps 3rd Edition”, Springer, Germany, 105-176, 245-261 (2002).
62. Zizzari, A., Seiffert, U., Michaelis, B., Gademann, G., Swiderski, S., “Detection of Tumor in Digital Images of the Brain”, *Int. Conf. Signal Process., Pattern Recogn. & Appl.*, Greece, 132-137 (2001).
63. Ahmed, M. N., Farag, A. A., “Two-Stage Neural Network for Volume Segmentation of Medical Images”, *Pattern Recogn. Lett.*, 18: 1143-1151 (1997).
64. Wismüller, A., Vietze, F., Dersch, D., “Segmentation with Neural Networks”, *Handbook of Medical Imaging: Processing and Analysis*, Editör: Bankman, I., *Academic Press*, Orlando, 107-126, (2000).
65. Gerig, G., Kubler, O., Kikinis, R. ve Jolesz, F. A., “Nonlinear Anisotropic Filtering of MRI Data”, *IEEE Trans. Med. Imag.*, 11 (2): 221-232 (1992).

66. Mohamed, F. B., Vinitiski, S., Faro, S. H., Gonzalez, C. F., Mack, J. ve Iwanaga, T., “Optimization of Tissue Segmentation of Brain MR Images Based on Multispectral 3D Feature Maps,” *Magn. Reson. Imaging*, 17 (3): 403–409 (1999).
67. Perona, P. ve Malik, J., “Scale-Space and Edge Detection Using Anisotropic Diffusion”, *IEEE Trans. Pattern Anal. Mach. Intell.*, 12 (7): 629-639 (1990).
68. Haralick, R. M., Shanmugam, K. ve Dinstein, I., “Textural Features for Image Classification”, *IEEE Trans. Syst., Man, Cybern.*, SMC-3 (6): 610-621 (1973).
69. Hu, M.-K., “Visual Pattern Recognition by Moment Invariants”, *IEEE Trans. Inf. Theory*, 8 (2): 179-187 (1962).
70. Witkin, A. P., “Scale-Space Filtering”, *8th Int. Joint Conf. Art. Intell.*, Karlsruhe, Germany, 1019-1022 (1983).
71. Mallat, S. G., “A Theory for Multiresolution Signal Decomposition: The Wavelet Representation”, *IEEE Trans. Pattern Anal. Mach. Intell.*, 11 (7): 674-693 (1989).
72. Haralick, R. M., “Statistical and Structural Approaches to Texture”, *Proc. IEEE*, 67 (5): 786-804 (1979).
73. Unser, M., “Texture Classification and Segmentation Using Wavelet Frames”, *IEEE Trans. Image Process.*, 4 (11): 1549-1560 (1995).
74. Tsai, D.-M., Hsiao, B., “Automatic Surface Inspection Using Wavelet Reconstruction”, *Pattern Recogn.*, 34: 1285-1305 (2001).
75. Zhou, Z., Ruan, Z., “Multicontext Wavelet-Based Thresholding Segmentation of Brain Tissues in Magnetic Resonance Images”, *Magnetic Resonance Imaging*, 25: 381-385 (2007).

76. Zhang, Y., Dong, Z., Wu, L., Wang, S., Zhou, Z., “Feature Extraction of Brain MRI by Stationary Wavelet Transform”, *Int. Conf. Biomed. Eng. Comput. Sci.*, Wuhan, 1-4 (2010).
77. Demirhan, A., Güler, İ., “Combining Stationary Wavelet Transform and Self-Organizing Maps for Brain MR Image Segmentation”, *Eng. Appl. Artif. Intel.*, 24: 358–367 (2011).
78. Zhang, J., Liu, Q., Chen, Z., “A Medical Image Segmentation Method Based on SOM and Wavelet Transforms”, *J. Commun. Comp.*, 2 (5): 46-50 (2005).
79. İnternet: McConnell Brain Imaging Centre (BIC) of the Montreal Neurological Institute, McGill University, “*BrainWeb: Simulated Brain Database*”, <http://www.bic.mni.mcgill.ca/brainweb/> (2006).
80. Cocosco, C. A., Kollokian, V., Kwan, R., K.-S. ve Evans, A. C., “Brainweb: Online Interface to a 3D MRI Simulated Brain Database”, *NeuroImage*, 5 (3): 425 (1997).
81. Aubert-Broche, B., Griffin, M., Pike, G. B., Evans, A. C. ve Collins, D. L., “Twenty New Digital Brain Phantoms for Creation of Validation Image Data Bases”, *IEEE Trans. Med. Imag.*, 25 (11): 1410-1416 (2006).
82. İnternet: The Internet Brain Segmentation Repository (IBSR), Center for Morphometric Analysis Neuroscience Center, Harvard Medical School, <http://www.cma.mgh.harvard.edu/ibsr/> (2009).
83. Dice, L. R., “Measures of the amount of ecologic association between species”, *Ecology*, 26: 297-302 (1945).
84. Chang, H.-H., Zhuang, A. H., Valentino, D. J., Chu, W.-C., “Performance Measure Characterization for Evaluating Neuroimage Segmentation Algorithms”, *NeuroImage*, 47 (1): 122–135 (2009).

85. Berkhin, P., "A Survey of Clustering Data Mining Techniques", Grouping Multidimensional Data: Recent Advances in Clustering, Editörler: Kogan, J., Teboulle, M., Nicholas, C., *Springer*, The Netherlands, 25-73 (2006).
86. Aubert-Broche, B., Evans, A. C. ve Collins, L., "A New Improved Version of the Realistic Digital Brain Phantom", *NeuroImage*, 32: 138-145 (2006).
87. Kwan, R. K., Evans, A. C. ve Pike, G. B., "MRI Simulation-Based Evaluation of Image-Processing and Classification Methods", *IEEE Trans. Med. Imag.*, 18 (11): 1085–1097 (1999).
88. Kwan, R., K.S., Evans, A. C. ve Pike, G. B., "An Extensible MRI Simulator for Post-Processing Evaluation", *Proc. VBC'96*, Hamburg, Germany, 1131:135–140 (1996).
89. Collins, D. L., Zijdenbos, A. P., Kollokian, V., Sled, J. G., Kabani, N. J., Holmes, C. J. ve Evans, A. C., "Design and Construction of a Realistic Digital Brain Phantom", *IEEE Trans. Med. Imag.*, 17(3):463–468, 1998.
90. Filipek, P. A., Richelme, C., Kennedy, D. N. ve Caviness Jr., V. S., "The Young Adult Human Brain: An MRI-Based Morphometric Analysis", *Cereb. Cortex*, 4 (4): 344–360 (1994).
91. Fletcher-Heath, L. M., Hall, L. O., Goldgof, D. B., Murtagh, F. R., "Automatic Segmentation of Non-Enhancing Brain Tumors in Magnetic Resonance Images", *Artif. Intell. Med.*, 21: 43-63 (2001).
92. Maintz, J. B. A. ve Viergever, M. A., "A Survey of Medical Image Registration", *Med. Image Anal.*, 2 (1): 1–37 (1998).
93. Rueckert, D., Sonoda, L. I., Hayes, C., Hill, D. L. G., Leach, M. O. ve Hawkes, D. J., Nonrigid Registration Using Free-Form Deformations: Application to Breast MR Images, *IEEE Trans. Med. Imag.*, 18(8): 712-721 (1999).

94. Collignon, A., Maes, F., Delaere, D., Vandermeulen, D., Seutens, P. ve Maral, G., “Automated Multimodality Image Registration Using Information Theory”, *14th Int. Conf. Inform. Process. Med. Imag.*, Ile de Berder, France, 263–274 (1995).
95. Viola, P., “Alignment by Maximization of Mutual Information”, Doktora Tezi, *Massachusetts Inst. Technol.*, Cambridge, MA, 76-135 (1995).
96. West, J., Fitzpatrick, J. M., Wang, M. Y., Dawant, B. M., Maurer, C. R. Jr, Kessler, R. M., Maciunas, R. J., Barillot, C., Lemoine, D., Collignon, A., Maes, F., Suetens, P., Vandermeulen, D., van den Elsen, P. A., Napel, S., Sumanaweera. T. S., Harkness, B., Hemler, P. F., Hill, D. L., Hawkes, D. J., Studholme, C., Maintz, J. B., Viergever, M. A., Malandain, G., Woods, R. P., “Comparison and Evaluation of Retrospective Intermodality Image Registration Techniques”, *J. Comput. Assisted Tomogr.*, 21: 554–566 (1997).
97. Studholme, C., Hill, D. L. G. ve Hawkes, D. J., “An Overlap Invariant Entropy Measure of 3D Medical Image Alignment”, *Pattern Recognit.*, 32 (1): 71–86 (1998).
98. Bayram, E., Ge, Y., Wyatt, C. L., “Confidence Based Anisotropic Filtering of Magnetic Resonance Images”, *23th Int. Conf. IEEE Eng. Med. Biol. Soc.*, Istanbul, Turkey, 2526-2529 (2001).
99. İnternet: *Rowan University, College of Engineering*, Polikar, R., “The Engineer's Ultimate Guide to Wavelet Analysis, The Wavelet Tutorial”, <http://users.rowan.edu/~polikar/WAVELETS/WTtutorial.html> (2008).
100. Meyer-Bäse, A., “Pattern Recognition in Medical Imaging”, *Elsevier Academic Press*, USA, 97-120 (2004).
101. Gonzales, R. C., Woods, R. E., Eddins, S. L., “Digital Image Processing Using Matlab”, *Prentice Hall*, New Jersey, 242-276, 334-377 (2004).

102. Coifman, R. R., Meyer, Y. ve Wickerhauser, M. V., “Wavelet Analysis and Signal Processing”, Wavelets and Their Applications, Editör: Ruskai, B., **Jones & Bartlett Pub**, Boston, 153-178 (1992).
103. Jin, Y., Angelini, E. ve Laine, A., “Wavelets in Medical Image Processing: Denoising, Segmentation, and Registration”, Handbook of Biomedical Image Analysis, Editörler: Suri, J. S., Wilson, D. L., Laxminarayan, S., **Kluwer Academic / Plenum Publishers**, New York, 305-358 (2005).
104. Coifman, R. R. ve Woog, L. J., “Adapted Waveform Analysis, Wavelet Packets, and Local Cosine Libraries as a Tool for Image Processing”, **Proc. SPIE 2567**, San Diego, California, 2567: 31-39 (1995).
105. Jiang, X.-Y., Zhao, R.-C., “Texture Segmentation Based on Incomplete Wavelet Packet Frame”, **2nd Int. Conf. Mach. Learn. Cybern.**, Wan, 5: 3172-3177 (2003).
106. Kim, S. C., Kang, T. J., “Texture Classification and Segmentation Using Wavelet Packet Frame and Gaussian Mixture Model”, **Pattern Recogn.**, 40: 1207-1221 (2007).
107. Acharyya, M., De, R. K. and Kundu, M.K., “Extraction of Features Using M-Band Wavelet Packet Frame and Their Neuro-Fuzzy Evaluation for Multitexture Segmentation”, **IEEE Trans. Pattern Anal. Mach. Intell.**, 25 (12): 1639-1644 (2003).
108. Kohonen, T., “Self-Organizing Formation of Topologically Correct Feature Maps”, **Biol. Cybern.**, 43(1): 59-69 (1982).
109. Kohonen, T., “The Self-Organizing Map”, **Proc. Inst. Elec. Electron. Eng.**, 78: 1464-1480 (1990).

110. Kotropoulos, C. ve Pitas, I., “Self-Organizing Maps and Their Applications in Image Processing, Information Organization, and Retrieval”, *Nonlinear Signal and Image Processing*, Editörler: Barner, K. E, Arce, G. E., **CRC Press**, 387-444 (2004).
111. İnternet: **Helsinki University of Technology, Department of Computer Science and Engineering**, Vesanto, J., “SOM Implementation in SOM Toolbox” <http://www.cis.hut.fi/projects/somtoolbox/documentation/somalg.shtml> (2008).
112. Vesanto, J., Himberg, J., Alhoniemi, E. ve Parhankangas, J., “Self-Organizing Map in Matlab: The SOM Toolbox”, **Proc. Matlab DSP Conf.**, Espoo, Finland, 35-40 (1999).
113. Kohonen, T., Kangas, J., Laaksonen, J., Torkkola, K., “LVQ_PAK: A Program Package for the Correct Application of Learning Vector Quantization Algorithms”, **IEEE IJCNN'92**, Piscataway, NJ, I: 725-730 (1992).
114. Duda R. O., Hart P. E., Stork D. G. “Pattern Classification 2nd ed.”, **Wiley-Interscience**, New York, 537-542 (2000).
115. Lee, J.-M., Yoon, U., Nam, S. H., Kim, J.-H., Kim, I.-Y., Kim, S. I., “Evaluation of Automated and Semi-Automated Skull-Stripping Algorithms Using Similarity Index and Segmentation Error”, **Comput. Biol. Med.**, 33: 495–507 (2003).
116. Shattuck, D. W., Sandor-Leahy, S. R., Schaper, K. A., Rottenberg, D. A., Leahy, R. M., “Magnetic Resonance Image Tissue Classification Using A Partial Volume Model”, **NeuroImage**, 13: 856–876 (2001).
117. Smith, S. M., “Fast Robust Automated Brain Extraction”, **Hum. Brain. Mapp.**, 17: 143–155 (2002).
118. Cointepas, Y., Mangin, J. F., Garnero, L., Poline, J. B., Benali, H., “Brain-VISA: Software Platform for Visualization and Analysis of Multimodality Brain Data”, **Neuroimage**, 13 (6): S98 (2001).

119. Rex, D. E., Shattuck, D. W., Woods, R. P. , Narr, K. L., Luders, E., Rehm, K., Stoltzner, S. E., Rottenberg, D. A., Toga, A. W., “A Meta-Algorithm for Brain Extraction in MRI”, *NeuroImage*, 23: 625–637 (2004).
120. Park, J. G., Lee, C., “Skull Stripping Based on Region Growing for Magnetic Resonance Brain Images”, *NeuroImage*, 47: 1394–1407 (2009).
121. Hwang, J., Han, Y. ve Park, H., “Skull-Stripping Method for Brain MRI Using a 3D Level Set with a Speedup Operator”, *J. Magn. Reson. Imaging*, 34: 445–456 (2011).
122. Vesanto, J., Alhoniemi, E., “Clustering of the Self-Organizing Map”, *IEEE Trans. Neural Netw.*, 11 (3): 586–600 (2000).
123. Wu, S., Chow, T. W. S., “Clustering of the Self-Organizing Map Using a Clustering Validity Index Based on Inter-Cluster and Intra-Cluster Density”, *Pattern Recogn.*, 37 (2): 175-188 (2004).
124. Bromiley, P. A., ve Thacker, N. A., “Improving the Accuracy of MR Image Segmentation Through the Use of Local Gradient Information”, *Proc. MIUA 2008*, Dundee, Scotland, 84-88 (2008).
125. Misiti, M., Misiti, Y., Oppenheim, G., “Matlab Wavelet Toolbox User's Guide”, *The MathWorks, Inc., Natick, MA*, 6-45 – 6-51, 6-143 – 6-168 (2011).
126. Coifman, R. R., Wickerhauser, M. V., “Entropy-Based Algorithms for Best Basis Selection”, *IEEE Trans. Inf. Theory*, 38 (2): 713-718 (1992).

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : DEMİRHAN, Ayşe
 Uyuğu : T.C.
 Doğum tarihi ve yeri : 26.01.1980 Ankara
 Medeni hali : Evli
 Telefon : 0 (312) 212 68 20
 Faks : 0 (312) 212 00 59
 e-mail : ayseoguz@gazi.edu.tr

Eğitim

<u>Derece</u>	<u>Eğitim Birimi</u>	<u>Mezuniyet tarihi</u>
Yüksek lisans	Gazi Üniversitesi / Elektronik-Bilgisayar Eğitimi	2006
Lisans	Gazi Üniversitesi / Bilgisayar Sistemleri Öğretmenliği	2002
Lise	Yıldırım Beyazıt Anadolu Kız Meslek Lisesi / Bilgisayar	1998

İş Deneyimi

<u>Yıl</u>	<u>Yer</u>	<u>Görev</u>
Eylül-Aralık 2002	Yavuz Selim İlköğretim Okulu	Bilgisayar Öğretmeni
Aralık 2002- ...	Gazi Üniversitesi	Araştırma Görevlisi

Yabancı Dil

İngilizce

Yayınlar

1. Güler, İ., Toprak, A., **Demirhan, A.**, Karakış, R., “MR Images Restoration with the Use of Fuzzy Filter Having Adaptive Membership Parameters”, *Journal of Medical Systems*, 32 (3): 229-234 (2008).
2. Güler, İ., **Demirhan, A.**, Karakış, R., “Interpretation of MR Images Using Self-Organizing Maps and Knowledge-Based Expert Systems”, *Digital Signal Processing*, 19 (4): 668-677 (2009).
3. **Demirhan, A.**, Güler, İ., “Image Segmentation Using Self-Organizing Maps and Gray Level Co-Occurrence Matrices”, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 25 (2): 285-291 (2010).
4. **Demirhan, A.**, Kaymaz, M., Ahıska, R., Güler, İ., “A Survey on Application of Quantitative Methods on Analysis of Brain Parameters Changing with Temperature”, *Journal of Medical Systems*, 34: 1059-1071 (2010).
5. **Demirhan, A.**, Kılıç, Y. A., Güler, İ., “Tıpta Yapay Zekâ Uygulamaları”, *Yoğun Bakım Dergisi*, 9 (1): 31-41 (2010).
6. **Demirhan, A.**, Güler, İ., “Beyin MR Görüntülerinin Analizi için Dalgacık Dönüşümü ve Sinir Ağlarının Kullanılması”, *IEEE 18. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, SIU2010*, Diyarbakır, 933-936 (2010).
7. **Demirhan, A.**, Güler, İ., “Combining Stationary Wavelet Transform and Self-Organizing Maps for Brain MR Image Segmentation”, *Engineering Applications of Artificial Intelligence*, 24 (2) :358-367 (2011).
8. **Demirhan, A.**, Güler, İ., “Bilişim ve Sağlık”, *Gazi Üniversitesi Bilişim Enstitüsü Bilişim Teknolojileri Dergisi*, 4 (3): 13-20 (2011).
9. **Demirhan, A.**, Törü, M., Güler, İ., “Brain MR Tissue Segmentation Using Wavelets and Neural Networks”, Under Review.