



T.C.

SELÇUK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

MR GÖRÜNTÜLERİNDE MS HASTALIĞININ TEŞHİSİNE YENİ BİR YAKLAŞIM

BURAK YILMAZ

DOKTORA TEZİ

Elektrik-Elektronik Müh. Anabilim Dalı

ŞUBAT-2017
KONYA
Her Hakkı Saklıdır

ÖZET

DOKTORA TEZİ

MR GÖRÜNTÜLERİNDE MS HASTALIĞININ TEŞHİSİNE YENİ BİR YAKLAŞIM

Burak YILMAZ

Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Yrd. Doç. Dr. Akif DURDU

Yıl, 2017 Sayfa 165

Jüri

Yrd. Doç. Dr. Akif DURDU
Prof.Dr. Salih GÜNEŞ
Doç.Dr. Ganime Dilek EMLİK
Yrd.Doç.Dr. Rahime CEYLAN
Yrd.Doç.Dr. Hüseyin Oktay ALTUN

MS, hastalığı beynin ve omuriliğin çok farklı yerlerinde meydana gelen inflamatuar bir hastalıktır. Beyindeki nöron hücrelerinde miyelin ve akson hasarı şeklinde görülen hastalık kalıcı etkilere sebep olmaktadır. Karşılaşılan sorunlar her hasta için tutulumun meydana geldiği bölgeye bağlı olarak farklıdır ve başka hastalıklara benzeyen bir şekil alabilir. İlerleyen dönemlerde, meydana gelen atakların ardından düzelici (remisyon) özelliği gözlense de, MS kronik bir hastalıktır.

Hastalığın bu derece geniş belirtiler gösteriyor olması, tanımlamasında bazı karar destek sistemleri ve yardımcı yöntemlerin de kullanılması ihtiyacını doğurmaktadır. Tanıya yardımcı araçların en önemlilerinden biri, beyin ve omuriliğin MRG yöntemleriyle incelenmesidir.

Beyinde oluşan MS plakları, MRG ile açık olarak görülebilir. Plakların etkinlikleri ise damar yoluyla paramanyetik bir madde olan Gadolinyum (Gd) verilerek belirlenir. Akut MS plakları Gd maddesini çekim süresi boyunca bünyesinde tutarken, kronik plaklarda bir tutulum gözlenmemektedir. Kısacası bir plağın Gd tutması aktif olduğunu göstermektedir.

Gerek akut MS plakları, gerek kronik MS plakları beyin MR görüntülerinde görüntü işleme teknikleri ve yapay zekâ teknikleri ile tespit edilebilmektedir. Erken teşhiste doktorlara yardımcı olması açısından bu bölgeleri analiz edebilecek Bilgisayar Destekli Teşhis (BDT) sisteminin ve yazılımların geliştirilmesi, hem sağlık, hem ülke ekonomisi hem de bilim açısından büyük öneme sahiptir. Erken teşhis sayesinde koruyucu yöntemlerle hastalığın insan hayatını kısıtlayıcı bir seyir alması engellenerek, hastalığa yakalanan kişilerin hayat kalitesinin bozulması önlenebilir.

Bu tezde, hızla artan MS vakalarının erken teşhisi ve plakların aktiflik-inaktiflik durumu hakkında, görüntü işleme ve yapay zekâ metotlarını kullanarak uzmanlara yardımcı olacak karar destek sistemi geliştirilmiştir. Yöntemin genelinde Hücresel Yapay Sinir Ağları algoritmasını temel alan yeni algoritma ve yöntemler geliştirilmiştir. Algoritma parametrelerinin tespiti için ise Yapay Arı Koloni algoritması kullanılmıştır.

Anahtar Kelimeler: Arı Koloni Algoritması, Görüntü Güçlendirme, Hücresel Yapay Sinir Ağı (HYSA), MS, Plak.

ABSTRACT

Ph.D. THESIS

A NEW APPROACH TO THE DIAGNOSIS OF MS DISEASE IN MR IMAGES

Burak YILMAZ

THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE
OF SELÇUK UNIVERSITY
DOCTOR OF PHILOSOPHY
IN ELECTRICAL - ELECTRONICS ENGINEERING

Advisor: Assistant Professor Dr. Akif DURDU

Year: 2017, Pages: 165

Jury
Advisor: Assistant Professor Dr. Akif DURDU
Professor Dr. Salih GÜNEŞ
Associate Professor Dr. Ganime Dilek EMLİK
Assistant Professor Dr. Rahime CEYLAN
Assistant Professor Dr. Hüseyin Oktay ALTUN

MS is an inflammatory disease that occurs in many different places in brain and spinal cord. Myelin and axon damage in neurons in the brain causes permanent effects. The problems encountered are different for each patient depending on the region in which the involvement occurs and may take a characteristic similar to other diseases. In the following periods although remission is observed after the episodes, MS is a chronic disease.

The fact that the disease has such a wide range of symptoms indicates that it requires the use of some decision support systems and assistive methods in its definition. One of the most important diagnostic assistants is the examination of the brain and spinal cord with MRI methods.

MS plaques formed in the brain can be seen clearly with MRI. The activities of the plaques are determined by intravenous administration of a paramagnetic substance Gadolinium (Gd). While acute MS plaques hold Gd material throughout the duration of the graft, no involvement is observed in chronic plaques. In short, a flap shows that Gd retention is active.

Both acute MS plaques and chronic MS plaques can be detected by image processing techniques and artificial intelligence techniques in brain MR images. The development of the Computer Aided Diagnostic (CIS) system and software, which can analyze these regions in terms of assisting early diagnosis doctors, has great prominence in terms of health, country economy and science. By early diagnosis, preventive measures prevent the disease from taking a restrictive course of human life, thus preventing the deterioration of the quality of life of the people who have acquired the disease.

In this thesis, a decision support system was developed to assist experts by using image processing and artificial intelligence methods on the early detection of rapidly increasing MS cases and the active-inactivity state of plaques. New algorithms and methods based on the Cellular Artificial Neural Networks algorithm have been developed throughout the method. Artificial Bee Colony algorithm is used to determine the algorithm parameters.

Keywords: Artificial Bee Colony Algorithm, Image Enhancement, Cellular Artificial Neural Network (HYSA), MS, Plak.

ÖNSÖZ

Doktora tez çalışmalarım sürecinde, MS görüntülerinin değerlendirilmesi ve çalışmanın yönlendirilmesinde yardımlarını esirgemeyen Doç. Dr. Ganime Dilek EMLİK'e, bilgi ve deneyimlerini benimle paylaşan danışmanım Yrd. Doç. Dr. Akif DURDU'ya, yardımlarından dolayı Yüksel ÖZBAY'a teşekkür ederim.

Burak YILMAZ

KONYA-2017

İÇİNDEKİLER

TEZ BİLDİRİMİ.....ii

ÖZET.....iii

ABSTRACT.....iv

ÖNSÖZ.....v

İÇİNDEKİLER.....vi

SİMGELER VE KISALTMALAR.....ix

ŞEKİLLER LİSTESİ.....xi

1. GİRİŞ 1

1.1 Tez Konusunun Tanıtılması.....4
1.2 Tezin Amacı ve Önemi.....5
1.3 Bu Konuda Yapılan Çalışmaların Tarihsel Gelişimi.....6

2. MULTİPL SKLEROZ 9

2.1 MS Hastalığının Seyri.....11
2.2 MS Hastalığının Belirtileri 13
2.3 MS Hastalığının Teşhisi.....13
2.4 Tedavi.....14

3.MANYETİK REZONANS GÖRÜNTÜLEME 15

3.1 Manyetik Rezonans Görüntülemenin Temel Prensipleri.....15
3.2 MRG Tekniğinin Diğer Tekniklere Göre Avantaj ve Dezavantajları.....18
3.3 MRG'nin MS Hastalığının Teşhisindeki Yeri.....22

4 GÖRÜNTÜ İŞLEME 23

4.1 Renk Uzayları 24
4.2 Veri Tipi Dönüşümleri.....24
4.3 Görüntü Üzerinde Matematiksel İşlemler.....25
4.4 Noktasal İşlemler.....27
4.4.1 Eşikleme.....27
4.4.2 Adaptif eşikleme.....28
4.4.3 Görüntü kuantalama.....29
4.4.4 Görüntü parlaklığının ayarlanması.....30
4.4.5 Görüntünün karşıtlık değerinin ayarlanması.....30
4.4.6 Görüntünün negatifi.....31
4.4.7 Konvolüsyon 31
4.5 Geometrik İşlemler.....32
4.5.1 Geometrik ölçekleme.....32

4.5.2 Döndürme....32
4.5.3 Eğme....33
4.5.4 Öteleme....33
4.6 Morfolojik Görüntü İşleme....33
4.6.1 Yapısal eleman....34
4.6.2 Genişleme....35
4.6.3 Aşınma işlemi....36
4.6.4 Açma işlemi....36
4.6.5 Kapama işlemi....36
4.7 Süzme....37
4.7.1 Ortalama Süzgeç....37
4.7.2 Ortanca Süzgeç....37
4.7.3 Gaussian Süzgeç....38
4.7.4 Laplacian Süzgeçler....38
4.7.5 Frekans Zemininde Süzgeçler....39
4.8 Görüntü Bölütleme....39
4.9 Görüntü Güçlendirme....40
4.9.1 Histogram Eşitleme (Histogram Equalization)....40
4.9.2 Kontrast Sınırlı Adaptif Histogram Eşitleme (CLAHE)....42

5 HÜCRESEL YAPAY SİNİR AĞLARI....43

5.1 Hücresel Yapay Sinir Ağı Modeli....43
5.2 HYSA Mimarisi....48
5.3 Hücreler Arasındaki Komşuluk İlişkisi....50
5.4 HYSA'larda Konvolüsyon İşlemi....51
5.5 Hücresel yapay sinir ağlarında kararlılık....55
5.6 Hücresel yapay sinir ağlarının sürekli zaman analizi....53
5.7 HYSA'da Eğitim....54
5.7.1 RPLA öğrenme algoritması....54
5.7.2 Yapay Arı Koloni Algoritması ve HYSA Eğitiminde Kullanımı....58
5.8 Çoklu Kararlı Hücresel Yapay Sinir Ağları (ÇK-HYSA)....66

6 METODOLOJİ....69

6.1 Tezde Kullanılan Veri Tabanları ve Atlaslar....71
6.1.1 Halka açık online veri tabanları....71
6.1.2 NEÜ Meram Tıp Fakültesi Veritabanı....72
6.1.3 Beyin Atlasları....72
6.1.4 Beyin Analiz Programları....73
6.2 Görüntü Çakıştırma....74
6.2.1 İlgin Dönüşümü....78
6.2.2 Uygunluk Fonksiyonu....79
6.3 Geliştirilen Doğrusal Harmanlamayla Karşıtlık Güçlendirme Algoritması....80
6.3.1 Metodoloji....82
6.3.2 Doğrusal Harmanlama Katsayılarının Tespiti....85
6.3.3 CEULICA Algortiması ile Beyin Görüntülerinin Güçlendirilmesi....87
6.3.4 CEULICA Algoritması Deneysel Sonuçları....90
6.3.5 Deney 1....93
6.3.6 Deney 2....97

6.3.7 CEULICA Algoritmasının Sınıflama Amacıyla Kullanımı.....102
6.4 Beyinin Kafatasından Ayrılması.....104
6.4.1 Metodoloji.....106
6.4.2 Kafatası Sıyırma Algoritması İçin Katsayı Tespiti.....111
6.4.3 Başarım Ölçümleri 114
6.5 Beyinin Alt Bölgelere Ayrılması 123
6.6 Analiz Yapılacak Bölgenin Seçimi 125
6.7 MS Plaklarının Tespiti 126
6.7.1 Başarım Ölçümleri 130
6.8 Sanal Gadolinyum Tekniği 132
6.8.1 Başarım Ölçümleri 134

7 SONUÇLAR VE ÖNERİLER 138

7.1 Sonuçlar 138
7.2 Öneriler 142
8 KAYNAKLAR 144
EKLER..... 151
ÖZGEÇMİŞ 155
YAYINLAR.....156

SİMGELER VE KISALTMALAR

MR: Manyetik Rezonans

MRG: Manyetik Rezonans Görüntüleme

MS: Multipl Skleroz

NGBC: Normal Görünen Beyaz Cevher

NBC: Normal Beyaz Cevher

NOBC: Normal Olmayan Beyaz Cevher

ROI: Region of Interest

GA: Genetik Algoritma

HYSA: Hücresel Yapay Sinir Ağları

ÇK-HYSA: Çoklu Kararlı Hücresel Yapay Sinir Ağları

RPLA: Recurrent Perceptron Learning Algorithm

w : Ağırlık Katsayıları Vektörü

ABC : Artificial Bee Colony

LoG: Laplacian of Gaussian

CLAHE: Contrast Limited Adaptive Histogram Equalization

HE: Histogram Equalization

US: Unsharp Mask

AHE: Adaptive Histogram Equalization

CEULICA: Contrast Enhancement Using Linear Image Combinations Algorithm

KDS: Karar Destek Sistemi

CNN: Cellular Neural Networks

EME: Enhancement Measure

AMBE: Absolute Mean Brightness Error

UIQI: Universal Image Quality Index

TPF: True Positive Fraction

TNF: True Negative Fraction

ŞEKİLLER LİSTESİ

Şekil 1.1 Periferik sinir kesitinde miyelin kılıf yapısının şematik görünümü 2
Şekil 2.1 İmmün sistem kaynaklı demiyelinizasyonun aşamaları. 10
Şekil 2.2 Hastalık tiplerinin engelliliğe etkisi 12
Şekil 3.1 Presesyon halindeki proton davranışı 16
Şekil 3.2 Protonların enerji kaybının zamana göre grafiği 17
Şekil 3.3 BrainWeb MS database MRG görüntüsünün 86. dilimi. 18
Şekil 4.1 T2 ağırlıklı beyin MRG görüntüsü 25
Şekil 4.2 MIDAS veri tabanından alınmış aksiyel kesitli gri seviye MRG beyin görüntüsü. . 28
Şekil 4.3 MIDAS veri tabanından alınmış aksiyel kesitli gri seviye MRG beyin görüntüsü .. 29
Şekil 4.4 İki boyutlu Konvolüsyon işlemi 31
Şekil 4.5 Yapısal elemanlar. 34
Şekil 4.6 MIDAS veri tabanından alınmış ikili formda MRG beyin görüntüsü 35
Şekil 4.7 MIDAS veri tabanından alınmış ikili formda MRG beyin görüntüsü 36
Şekil 4.8 Aksiyal kesitte elde edilmiş beyin görüntüsü 40
Şekil 4.9 Aksiyal kesitte elde edilmiş beyin görüntüsünün histogram eşitleme işleminden sonraki hali 41
Şekil 4.10 Aksiyal kesitte elde edilmiş beyin görüntüsünün adaptif histogram eşitleme işleminden sonraki hali 42
Şekil 5.1 Chua Devresi 43
Şekil 5.2 Chua diyotunun Akım - Direnç grafiği 44
Şekil 5.3 Chua devresinin osilasyon durumunda kapasitörler arasındaki gerilim ilişkisi 45
Şekil 5.4 HYSA hücresinin eşdeğer devresi 46
Şekil 5.5 Herhangi bir *C(i,j)* hücresinin parça-parça doğrusal çıkış karakteristiği 47
Şekil 5.6 4×4 Boyutunda bir hücresel yapay sinir ağı gösterimi 49
Şekil 5.7 Bir hücrenin dinamik yapısı 49
Şekil 5.8 Hücresel yapay sinir ağlarında hücre ilişkileri 50
Şekil 5.9 Ayrık zamanda HYSA hücresinin modeli 51
Şekil 5.10 ABC algoritmasının genel akış diyagramı 63
Şekil 5.11 HYSA şablonlarının vektörizasyonu 64
Şekil 5.12 Eşikleme eğitim veri seti 65
Şekil 5.13 ÇK-HYSA modeli 67
Şekil 5.14 ÇK-HYSA için vektörizasyon modeli 68
Şekil 5.15 ÇK-HYSA için çıkış fonksiyonu 68

Şekil 6.1 Yöntemin genel akış diyagramı 69
Şekil 6.2 Talairach uzayındaki koordinatların uzaklıklarına dair standartlar 72
Şekil 6.3 MRG görüntülerinde kullanılan düzlemler 73
Şekil 6.4 Geliştirilen görüntü çakıştırma algoritması akış diyagramı 75
Şekil 6.5 Çakıştırılacak olan Atlas görüntüsü ve beyin MRG görüntüsü 76
Şekil 6.6 HYSA sonrası, çakıştırılacak olan Atlas görüntüsü ve beyin MRG görüntüsü 77
Şekil 6.7 Çakıştırma algoritmasının sonucu. 80
Şekil 6.8 CEULICA algoritmasının akış diyagramı 83
Şekil 6.9 Uygunluk fonksiyonunun çıkış grafiği 87
Şekil 6.10 BrainWeb MRG görüntüsünün 86. diliminin T1, T2 ve PD versiyonları ile aynı görüntülerin histogramları 88
Şekil 6.11 BrainWeb MRG görüntüsünün 86. diliminin CEULICA ile güçlendirilmiş hali ile yine aynı görüntülerin histogramları 89
Şekil 6.12 BrainWeb MRG görüntüsünün 86. diliminin CEULICA ile güçlendirilmiş hali ile yine aynı görüntülerin histogramları 97
Şekil 6.13 CEULICA öncesi ve sonrası MRG görüntüleri ve histogramları 101
Şekil 6.14 Sınıflandırılmış BrainWeb 86. görüntü, 163. görüntü,)181. görüntü. 102
Şekil 6.15 Sınıflandırılmış BrainWeb 86. görüntü, 163. görüntü, 181. görüntü. 103
Şekil 6.16 Sınıflandırılmış BrainWeb 86. görüntü, 163. görüntü, 181. görüntü. 103
Şekil 6.17 mCNN-MRI-SS algoritmasının atlas tabanlı çalışma kipi 108
Şekil 6.18 mCNN-MRI-SS algoritmasının paralel HYSA tabanlı çalışma kipi 109
Şekil 6.19 Algoritmadaki her iş akışının çıktıları. 111
Şekil 6.20 Kaynak veri seti 112
Şekil 6.21 Hedef veri setleri 112
Şekil 6.22 ÇK-HYSA'nın çıkış fonksiyonunun grafik gösterimi 114
Şekil 6.23 Subject 49 verisinin veri tabanından elde edilen referans görüntüsü, algoritmanın sonucu ve iki görüntü arasındaki farkı. 118
Şekil 6.24 Case01026-t2w verisinin veritabanından elde edilen referans görüntüsü, algoritmanın sonucu ve iki görüntü arasındaki fark. 120
Şekil 6.25 MRM01 verisinin veritabanından elde edilen referans görüntüsü, algoritmanın sonucu ve iki görüntü arasındaki fark 122
Şekil 6.26 Beyin görüntüsünü alt bölgelere ayıran ÇK-HYSA algoritmasının akış diyagramı 124
Şekil 6.27 ÇK-HYSA ile Bölütleme örneği 124

Şekil 6.28 MS plak tespiti algoritması genel akış diyagramı 129
Şekil 6.29 Eğitimde kullanılan görüntü setleri 130
Şekil 6.30 Bölütleme sonuçları 131
Şekil 6.31 T2w çekim tekniğiyle elde edilmiş MR görüntüsü ve de aynı hastadan elde edilmiş T1 ağırlıklı MR görüntüsünün gadolinyum ile çekilmiş hali 133
Şekil 6.32 Sanal gadolinyum algoritması akış diyagramı. 134
Şekil 6.33 MS_MRM10 görüntüsünün sanal gadolinyum algoritması öncesi ve uygulama sonucunda tutulum oluşan bölgesi 136
Şekil 6.34 Genel başarı ölçümünü gösteren ROC eğrisi..... 137

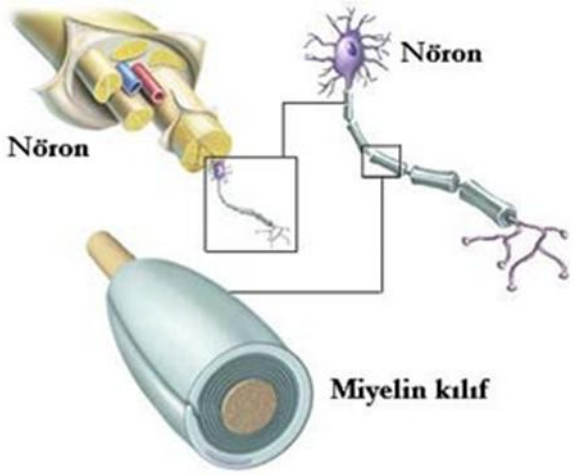
1 GİRİŞ

Bilim ve teknolojideki gelişmeler sayesinde daha önce nasıl meydana geldiği ne olduğu bilinmeyen pek çok hastalık, bugün çok kolay bir şekilde teşhis ve tedavi edilebilmektedir. Merkezi sinir sistemi (MSS) üzerinde yapılan araştırmalar göstermiştir ki özellikle son yüz yetmiş yıldır demiyelinizan hastalıklar adı verilen bir olgu tıpta kendine yer bulmuştur.

Bu hastalıkların hem hücresel seviyede meydana gelmesi, hem de MSS'nde oluşturduğu etkinin tüm yaşam kalitesini etkilemesinden dolayı erken teşhisi ve tedavisi çok büyük önem taşımaktadır. Bu tür hastalıklara, Subakut sklerozan panensefalit (SSPE), Guillain-Barré sendromu (GBS), İnfeksiyöz (progresif multifokal lökoensefalopati) ve vasküler demiyelinizan hastalıklar (Binswanger hastalığı), Multipl Skleroz (MS), Akut Disemine Ensefalomiyelit (ADEM), Akut Hemorajik Lökoensefalopati (AHL) gibi merkezi sinir sisteminin bağışıklık sisteminden etkilenmesiyle ortaya çıkan inflamatuar demiyelinizan hastalıklar ve metabolik miyelin hastalıkları örnek verilebilir. Bu hastalıklardan biri olan Multipl Skleroz (MS), nörolojik fonksiyonlarda ilerleyici ve kalıcı kayıplarla sebep olması bakımından (Kocagül 2012) önemli bir yer tutmaktadır.

Beyin ve omurilikten oluşan merkezi sinir sisteminin, canlının tüm sinirlerinden gelen bilgileri toplayıp analiz etmek, canlının koordinasyonunu sağlamak ve organların çalışma düzenlerini kontrol etmek gibi görevleri vardır. Merkezi sinir sistemi nöronlar adı verilen özelleşmiş bir hücre tipinden oluşur. Bu hücre tipi elektrik sinyallerini alacak ve iletecek şekilde bir yapıya sahiptir. Nöron hücresinde elektrik sinyallerini ileten ana bileşen, akson ve dendritler adı verilen hücre uzantılarıdır. Aksonların dışında elektriksel yalıtımı sağlamak için özelleşmiş, Schwann hücrelerinden oluşan miyelin kılıfı adı verilen bir yapı bulunmaktadır. Bu yapı elektrik sinyallerinin hücre gövdesinden akson uçlarına bozulmadan ulaşmasını sağlamakla görevlidir.

MS hastalığı nöron hücre yapısındaki miyelin kılıfın zarar görmesiyle meydana gelir. Miyelin kılıfının zarar görmesiyle oluşan hasar türüne demiyelinizasyon denir. Demiyelinizasyon, miyelin kılıfın bütünlüğünün bozulmasıdır. MS Hastalığı MSS içerisinde birden çok bölgede ortaya çıkan demiyelinizasyona uğramış plaklar şeklinde görülür. Hastalarda merkezi sinir sisteminin demiyelinize olan bölgesine bağlı olarak motor, somatosensoriyal, görsel, kognitif ve psikiyatrik bozukluklar olmak üzere çok çeşitli belirtiler görülebilmektedir (Şahin ve ark 2009). Şekil 1.1'de periferik sinir kesitinde miyelin kılıf yapısı gösterilmiştir (Healthcentral 2006).



Şekil 1.1 Periferik sinir kesitinde miyelin kılıf yapısının şematik görünümü (Healthcentral 2006).

MS hastalığında, ilerleyen aşamalarda demiyelinizasyonun tamiri mümkün olmamaktadır. Bununla birlikte kalıcı miyelin kaybı ile MSS'de yerleşen lezyonlar ve nörolojik özürlülük meydana gelmektedir. Hastalığın erken dönemlerinde bir miktar miyelin tamiri görülmekte ve bunlar, normalden daha ince miyelin kılıflarına sahip aksonlar şeklindedir (Altıntaş ve Benbir 2005).

MS hastalığının tanılanmasında McDonald ölçütleri (McDonald ve ark 2001) adı verilen bir dizi klinik analiz ve tıbbi görüntüleme tekniklerine başvurulmaktadır. Bu tıbbi görüntüleme yöntemleri içinde, MSS'de demiyelinizan plakları kesin olarak görüntüleyebilen tek tetkik yöntemi manyetik rezonans görüntülemedir (MRG). Son yıllarda geliştirilen yeni MRG teknikleriyle, MS plaklarının patolojik alt yapısı hakkında daha ayrıntılı bilgiler elde edilmiştir (Atalay ve ark 2005).

MS hastalığında hücre seviyesinde ortaya çıkan ve miyelin kılıflarında oluşan dejenerasyonlar, doku seviyesinde bakıldığında bir bozulma olarak görülebilmektedir. Demiyelinizasyona uğramış plaklara tutulma adı da verilmektedir. MS tanısının koyulması için her ne kadar McDonald kriterleri önemli bir yer tutsa da bu kriterler MS etkisini göstermeye başlayınca değerlendirilmektedir. Öte yandan MRG ile incelendiğinde beyin dokularındaki örüntü bozulmalarından yola çıkarak MS'in erken safhalarda tespiti de mümkün olabilmektedir. Bu yüzden MRG ve görüntü analizleri hastalığın erken safhalarda tespit edilmesinde kullanışlı bir araç haline gelmektedir.

Her ne kadar MRG'nin gri ve beyaz cevherdeki yaygın hasara duyarlılığının az olduğu bilinmekteyse de, çeşitli görüntü işleme, örüntü tanıma, yapay zekâ, istatistik ve matematik teknikleriyle MRG'nin güçlendirilmesi, analizi ve MS teşhisindeki etkinliğinin arttırılması mümkündür. McDonald ölçütleri, diğer klinik bulgular ve MRG analizi sonuçlarından faydalanarak MS hastalığının erken teşhisi mümkün olabilmektedir.

MS tanısı ve takibinde birçok MRG yöntemi kullanılmaktadır. Tarihsel olarak tanı kıstasları içerisinde, MRG bulguları yer almamaktadır. Ancak günümüzde kullanılan yenilenmiş McDonald ölçütlerinde MRG önemli rol oynamaktadır. Günümüzde konvansiyonel MRG'nin yanı sıra fonksiyonel MRG (fMRG), difüzyon tensör görüntüleme (DTG) ve manyetizasyon transfer görüntüleme (MTG) gibi yeni yöntemler de MS tanı ve izleminde sıklıkla kullanılmaya başlanmıştır (Akça 2009).

MS lezyonları; ödem, demiyelinasyon veya aksonal kayıp gibi durumları içeren geniş bir spektrumu kapsar. Yaygın etkilenmede, dolaylı olarak atrofi veya MRG ile normal görünen beyaz-gri cevherin biyokimyasal, histopatolojik incelemelerinde ortaya çıkan düşük dereceli inflamasyon, miyelin kaybı, aksonal dejenerasyon gibi bulgulara rastlanabilir (Akça 2009). Bu bulgular MRG sonucunda elde edilen görüntülerde hem görsel hem de sayısal veri olarak elde edilebilmektedir.

MSS hastalıkları içerisinde MS ve özellikle de demiyelizanlar MR görüntüleme teknikleri sayesinde tanılanabilmektedir. MS plakları özellikle beyin beyaz cevherinde görülmektedir. Bu plaklar çeşitli boyutlarda ve değişik yerlerde meydana geldiklerinden dolayı, kesin olarak belirlenmesi önemlidir. Bu amaçla görüntü işleme ve yapay zekâ teknikleri uzmanların hizmetine sunulmuştur.

Hastalıkların ve biyolojik anomalilerin tespitinde genel olarak kullanılan başlıca biyomedikal görüntü işleme yöntemleri şu şekilde sıralanabilir; görüntüler üzerinde ölçüm yapabilme, görüntü dönüştürme, görüntü süzgeçleme ve piksel işleme (LUT değişimleri) yapabilme. Piksel işleme tekniği ile parlaklık ayarlama, kontrast ayarlama, görüntünün değişik formlarını (negatifini, logaritmik, karesel, ters karesel) bulma ve histogram eşitleme, örüntünün formasyonu (istenilen açıda, istenilen yöne döndürülebilmesi), ayna görüntü eldesi gibi işlemler yapılabilmektedir (Honeyman-Buck 2012).

Her ne kadar görüntü işleme yöntemleri sayesinde MR görüntüleri daha yüksek bir kaliteye ulaşarak uzmanlara tanılamada yardımcı olsa da sadece görüntünün güçlendirilmesi ya da netleştirilmesi yeterli değildir. Bir görüntüyü tıbbi tanılamada kullanmak için

görüntüden bilgi çıkartılması gerekmektedir. Bu bilgi lokasyon, yoğunluk, genişlik ve tespit edilen anomali türü gibi çeşitli parametreler içerebilir (Honeyman-Buck 2012).

Görüntü bölütlemede kullanılan algoritmalar sayesinde uzmanlara yardımcı olabilecek, plaklar, tümörler, kitleler ve hastalığa göre özellikli dokular tespit edilebilmektedir (Horsfield ve ark 2007). Günümüzde araştırmacılar özellikle MS tanısı üstünde yeni algoritmalar geliştirme konusunda çalışmaktadır. Bugün bilinen yöntemler arasında k-means, fuzzy c-means, markov zincirleri ve hücresel yapay sinir ağları sayılabilmektedir (Horsfield ve ark 2007).

Bu tez çalışmasında görüntü işleme ve yapay zekâ teknikleri kullanarak bu bölgede hastalığın erken tanılanması ve kontrast madde kullanılmadan, tespit edilen MS plaklarının aktiflik - inaktiflik durumlarının tespiti için yeni bir yöntem geliştirilmesi amaçlanmıştır.

1.1 Tez Konusunun Tanıtılması

Gerçekleştirilen tez çalışmasında, radyolojik olarak MS hastalığının erken tanısı ve plakların aktiflik – inaktiflik durumu incelenerek, doktorların tanı koymalarına yardımcı olabilecek bir karar destek sistemi (KDS) geliştirilmiştir. Yöntem 5 aşamayı içermektedir; görüntü normalizasyonu ile kontrast güçlendirme, inceleme dışında tutulacak bölgelerin beyin görüntüsünden ayrılması, beyin görüntüsünün bölütlenmesi, MS plaklarının bölütlenmesi ve MS plaklarının aktiflik durumunun analizi. Sistem MIDAS – NAMIC ve BrainWeb küresel veritabanlarından alınmış genel veriler ve N.Ü. Meram Tıp Fakültesi'nden alınmış hastane verileriyle test edilerek başarı ölçümleri yapılmıştır.

Doku analizi ve sınıflandırma işlemleri için, HYSA ve ÇK-HYSA algoritmaları kullanılmıştır. Bu algoritmaların eğitimi için Genetik Algoritma (GA) ve Yapay Arı Koloni Algortiması (ABC) tercih edilmiştir (Karaboğa 2014). Sınıflandırma algoritmalarının başarı ölçümünde Jaccard, Dice, TPF ve TNF parametreleri tercih edilmiştir.

Ayrıca biyomedikal görüntülerin ön işlenmesinde kullanılan kontrast güçlendirme işlemi için Contrast Enhancement Using Linear Image Combinations Algorithm (CEULICA) adlı bir algoritma geliştirilmiştir (Yilmaz ve Ozbay 2014). Güçlendirme başarısı CLAHE, HE ve US algoritmalarıyla karşılaştırılmış ve EME, AMBE ve UIQI performans kıstasları ile ölçülmüştür.

1.2 Tezin Amacı ve Önemi

MS, öncelikle beynin ve omuriliğin çok farklı yerlerinde meydana gelen inflamatuar bir hastalıktır. Hastalık, lenfositik odaklanmaların içinde infiltrasyonlarla miyelin ve akson hasarı şeklinde görülür. Başlangıçta, inflamasyon geçicidir ve remiyelinizasyon oluşur ama dayanıklı değildir (Compston ve Coles 2008). Karşılaşılan sorunlar her hasta için tutulumun meydana geldiği bölgeye bağlı olarak farklıdır ve başka hastalıklara benzeyen bir şekil alabilir. Belirtiler çok çeşitli varyasyonlara sahip olabilse de genel bazı belirtiler şöyle ifade edilebilir; baş dönmesi, çift görme, tek veya çift gözde görme azalması, dengesizlik ya da kol ve bacaklarda güç kaybı. Her iki bacakta yavaş ilerleyici güç azlığı özellikle tanılaması zor bir durumdur. Bu hastalarda sinir sisteminin diğer bölgelerinde tutulum bulgularının varlığı ve yardımcı laboratuar incelemeleri (manyetik rezonans görüntüleme, uyarılmış yanıtlar) ile tanı konulabilir (Compston ve Coles 2008). Nörolojik açıdan hastanın görünür fonksiyon kayıplarının dışında kalan sistemlerine ait bozukluklar da MS kuşkusu doğurur. İlerleyen dönemlerde, meydana gelen atakların ardından düzelici (remisyon) özelliği de gözlenirse, MS tanısı konulabilir.

Hastalığın bu derece geniş belirtiler gösteriyor olması, tanımlamasında bazı karar destek sistemleri ve yardımcı yöntemlerin de kullanılması ihtiyacını doğurmaktadır. Tanıya yardımcı araçların en önemlilerinden biri, beyin ve omuriliğin MRG yöntemleriyle incelenmesidir.

Beyin MRG görüntüleri incelendiğinde MS hastalığının meydana gelebildiği bölgeler üç isimle adlandırılabilir:

- **Normal Beyaz Cevher (NBC):** Bu bölge işlevsel olarak sağlıklıdır ve MR görüntülerinde beyaz bölge olarak görünür
- **Normal Olmayan Beyaz Cevher (NOBC):** Bu bölge MS plaklarını içerir ve MR görüntüsünde açıkça görünür, algoritmalar tarafından kolayca bölütlenir
- **Normal Görünen Beyaz Cevher (NGBC):** Bu bölge NBC gibi görünür, ilk bakışta fark algılanamaz, yapay zekâ ve görüntü işleme teknikleriyle bu bölgenin tespiti yapılabilir.

Bu bölgelerden en önemlisi aslında NGBC'dir çünkü bu bölgenin erken dönemde algılanması ve bölütlenmesi mümkün olursa MS hastalığı ilerlemeden kontrol altına alınabilir (Lei ve ark 2007)

Hastalık sırasında oluşan tutulumlar da hastalığın durumuna göre farklılıklar gösterebilir. Akut aktif plaklar makrofajların bölgedeki varlığı ile karakterize edilir, lezyon

içerisinde, erken ve geç aşamadaki bozulma ürünlerinin her ikisi de görünür. Kronik aktif plak çok sayıda makrofaj birikimi gösterir, bunların erken olanları plak çeperlerine doğru görülürken geç olanları merkeze doğrudur ve merkezde inaktif bir bölge oluşturur. Yanan plak tipi, az miktarda makrofaj varlığı ile karakterize edilir, erken ve geç bozulma ürünleri plak kenarında görülmektedir. İnaktif plak hiçbir erken veya geç miyelin bozulma ürünü içermemektedir (Lucchinetti 2008).

Beyinde oluşan MS plakları, MRG ile açık olarak görülebilir. Plakların etkinlikleri ise damar yoluyla paramanyetik bir madde olan Gadolinyum (Gd) verilerek belirlenir. Aktif MS plakları Gd maddesini çekim süresi boyunca bünyesinde tutarken, inaktif plaklarda bir tutulum gözlenmemektedir. Kısacası bir plağın Gd tutması aktif olduğunu göstermektedir (Grossman ve ark 1986).

Görüntü işleme teknikleri ve yapay zekâ, bahsedilen bölgelerin analizinde önem kazanmaktadır. Erken teşhiste doktorlara yardımcı olması açısından bu bölgeleri analiz edebilecek Bilgisayar Destekli Teşhis (BDT) sisteminin ve yazılımların geliştirilmesi, hem sağlık, hem ülke ekonomisi hem de bilim açısından büyük öneme sahiptir. Böylece erken teşhis ve koruyucu yöntemlerle hastalığın insan hayatını kısıtlayıcı bir seyir alması engellenerek, hastalığa yakalanan kişilerin hayat kalitesinin bozulması önlenebilir. Bu tezde, hızla artan MS vakalarının erken teşhisi ve plakların aktiflik-inaktiflik durumu hakkında, görüntü işleme ve yapay zekâ metotlarını kullanarak uzmanlara yardımcı olacak karar destek sistemi geliştirilmesi hedeflenmektedir.

1.3 Bu Konuda Yapılan Çalışmaların Tarihsel Gelişimi

MS hastalığının 1868 yılında Jean Martin Charcot tarafından "Histologie de la sclérose en plaques" (Charcot 1868) adlı yayın ile tanımlanmasından sonra hastalığı teşhis ve tedavi yöntemleri hakkında pek çok bilim insanı geniş çaplı çalışmalar yürütmüştür. İlerleyen teknolojiyle beraber 1973 yılında Paul Lauterbur (Lauterbur 1973) tarafından geliştirilen manyetik rezonans görüntüleme tekniği, hızla teşhis yöntemleri arasında yerini almıştır. Sonraki dönemlerde MS hastalığının teşhisinde MRG tekniği kullanılarak pek çok çalışma yapılmıştır.

Multipl Skleroz hastalığının MRG ile tespit edilmesi ilk olarak 1981 yılında İngiltere'de Dr. I.R. Young tarafından gerçekleştirilmiştir (Young ve ark 1981). Çoklu çekim teknikleri ve gelişen teknoloji sayesinde bu konuda özellikle 1990 yılından itibaren önemli çalışmalar ortaya koyulmuştur.

Larsson ve ark. 1992 yılında MS hastaları üstünde yaptıkları çalışmalarla plakların MRG ile tespitindeki hassasiyeti sağlamak için gerekli olan T1 ve T2 relaksiyon sürelerini hesaplamışlardır. Çalışma, yaş ortalamaları 42 olan ve "kesinlikle MS" teşhisi koyulmuş on hasta üzerinde gerçekleştirilmiştir.

Barbosa ve ark. 1993 yılında MRG görüntülerinde normal görünen beyaz madde (NAWM) içerisindeki lezyonları tespit etmek için üzere çalışmalar yapmışlardır (Barbosa ve ark 1994).

Clarke ve ark. 1995 yılında beyin MRG görüntülerinin bölütlenmesi ve analizi için genel bir yöntem tanımlayarak, uygulanma aşamalarını açıklamışlardır (Clarke ve ark 1995).

Barrati ve ark. 1995 yılında FLAIR ve SPIN-ECHO teknikleri ile elde edilen beyin MRG görüntülerinin, MS lezyonlarının yapısını analiz etmedeki etkilerini incelemişlerdir (Baratti ve ark 1995). Çalışma sonucunda bu tekniklerle beyin - omurilik sıvısının (BOS) baskılanarak MS plakları açısından daha belirleyici görüntüler elde edildiği görülmüştür.

Van Waesberghe ve ark. 1997 de MRG görüntülerinden MS teşhisi için dört parametrenin belirleyici olduğunu belirtmişlerdir (van Waesberghe ve ark 1997). Bu parametreler on hastadan alınmış T1 ağırlıklı MRG görüntülerinde 49 lezyonlu bölge incelenerek elde edilmiştir. Parametreler MTR: magnetization transfer ratio, SI: signal intensity, NAWM: normal appearing white matter, CSF: cerebrospinal fluid olarak belirlenmiştir.

Blonda ve ark. 1998'de yaptıkları çalışmada MR görüntülerinin bölütlenmesi için iki fuzzy neural network uygulaması yapmıştır. MS hastalarına ait kalın MR dilimleri içerisinde küçük lezyonların tesbiti için neuro-fuzzy yaklaşımının etkinliğinin araştırılması hedeflenmiştir (Blonda ve ark 1998). Veri kümesi PD, T2, T1, spin-echo T1 3D görüntülerini içermektedir. Dokuların yarı otomatik bölütlenmesi için (Fuzzy Learning Vector Quantization) FLVQ ve (Fully Self Organizing Map) FOSART modelleri kullanılmıştır (Blonda ve ark 1998).

Van Leemput ve ark. tarafından 2001 yılında multi spectral MRG görüntülerinden MS lezyonlarını bölütlemek için tam otomatik bir algoritma sunulmuştur. Bu metot, normal beyin dokuları için rastlantısal model kullanan yoğunluk temelli bir doku sınıflandırması yaparken aynı zamanda modele uymayan MS lezyonlarının dış hatlarını belirleyerek bölütlemektedir. Yöntem MR alanındaki eşitsizlikleri düzelterek verinin kendisinden dokuya özel yoğunluk

değerini tahmin eder ve bir Markov rastgele alanı kullanarak yapısal bilgiyi sınıflandırmaya uygular. Yöntemden elde edilen sınıflandırma sonuçları, uzmanların sınıflandırma sonuçlarıyla karşılaştırılmış, yüksek lezyon yükü korelasyonu göstermiştir. Uzamsal uygunluk göz önüne alındığında ise, hem uzman bölütlemesinde hem de otomatik - uzman bölütlemesi arasında gözle görülür bir uyumsuzluk bulunmuştur (Van Leemput ve ark 2001).

Lei ve ark. 2007 yılında MS hastalığının erken teşhisine yönelik yaptıkları çalışmada T2 ağırlıklı MRG görüntülerinden çeşitli bölgeler seçilmişlerdir. Özellik çıkartım için yeni bir komşuluk fark algoritması kullanılarak dört parametre çıkartılmıştır. Bu parametreler gözlemlenerek iki özdeğer vektörü ile ifade edilebilmiştir. Çalışmada beynin mikrokozmik yapısı tartışılarak çıkartılan doku parametrelerinden, beynin normal beyaz maddesi ile beyaz görünen maddesi arasında gözle görünür bir fark olduğu istatistiksel olarak analiz edilmiştir (Lei ve ark 2007). Araştırmada MR görüntülerindeki NWM, NAWM, AWM bölgeleri T2 ağırlıklı görüntülerden derlenmiştir. Sonuçta istatistik analiz ile NAWM ile NWM arasında gözle görülür farklar olduğu tespit edilmiştir. Çalışmada 26 hasta (9 erkek, 17 kadın) seçilmiştir. Hastalık tespiti LUBLIN – REGINOLD yöntemine göre yapılmıştır. Ortalama yaşları 32'dir. KRUTZKE ismi verilen geliştirilmiş özürlülük testine göre ortalama skorları 2,9 dur (1-5 arasında). Aynı yaş ve cinsiyet değerlerine sahip 26 sağlıklı gönüllü de kontrol grubu olarak seçilmiştir (Lei ve ark 2007).

Khayati ve ark. 2008'de FLAIR metoduyla elde edilmiş beyin MRG görüntüleri ve Markov Rastgelen Alan Modelini kullanarak tam otomatik bir MS lezyon bölütleme metodu geliştirmişlerdir (Khayati ve ark 2008). Cerasa ve ark. Hücresel Yapay Sinir Ağları (HYSA) kullanarak MRG görüntülerinden MS hastalığı tespiti yapan bir uygulama geliştirmişlerdir. Uygulamada kullanılan HYSA, Genetik Algoritmalar (GA) ile eğitilmiştir. Algoritma özel olarak lezyonlardan etkilenmiş beyin bölgelerini tanımlamak için arama yapar. Bu bölgelerin varlığı sağlıklı dokuya göre daha yüksek yoğunluk (intensite) değerleri ile ortaya çıkmaktadır. Algoritma 11 MS hastasından alınan 256 x 256 çözünürlüğündeki beyin MRG görüntüleri üstünde test edilmiş ve ortalama Dice = 0,64 değeri elde edilmiştir (Cerasa ve ark 2012).

2 MULTİPL SKLEROZ

Multipl Skleroz (MS), merkezi sinir sisteminde meydana gelen, şiddetli, kronik, kalıcı inflamatuvar demiyalizan bir hastalık olarak tanımlanır. MS genelde optik sinir, omurilik, beyin sapı ve beyinciğe etki eden, tipik olarak klinik anlamda tek odaklı (monofocal) ya da çok odaklı (multifocal) demiyeline lezyonlar şeklinde görülür (Rovira ve Leon 2008). MS klinik, genetik ve patolojik olarak pek çok belirtiye sahip bir hastalıktır. Klinik bulgular arasında motor kayıplar, duyusal bulgular, koordinasyon sorunları, mesane ve barsak problemleri görülebilmektedir. Denge ile ilgili sorunlar sıkça görülmektedir. MS hastalarında ayrıntılı bir belirti incelemesi yapıldığında bu hastaların %78'inin denge ile ilgili problemlerinin olduğu ve bunun da % 17'sinin baş dönmesi olduğu saptanmıştır (Değirmenci 2006).

MS hastalığı, hücre seviyesinde ortaya çıkan ve miyelin kılıflarında oluşan dejenerasyonlardır. Hastalığın başlangıcı genellikle üçüncü ve dördüncü on yıllardadır ve sadece % 2'si 10 yaşından önce baslarken % 5'i 16 yasından önce başlar. Toplam yaşam süresi beklentisi yaklaşık 25 yıldır (Değirmenci 2006). Multiple Skleroz daha çok genç nüfusta görülmektedir. Hastalık genel olarak 20- 30 yaş civarında görülür. Hastalığın 20 yaş altında ve 60 yaş sonrasında görülmesi nadirdir. Kadınlarda erkeklere nazaran 2-3 kat daha fazla karşılaşılmaktadır (Kurtzke 1977).

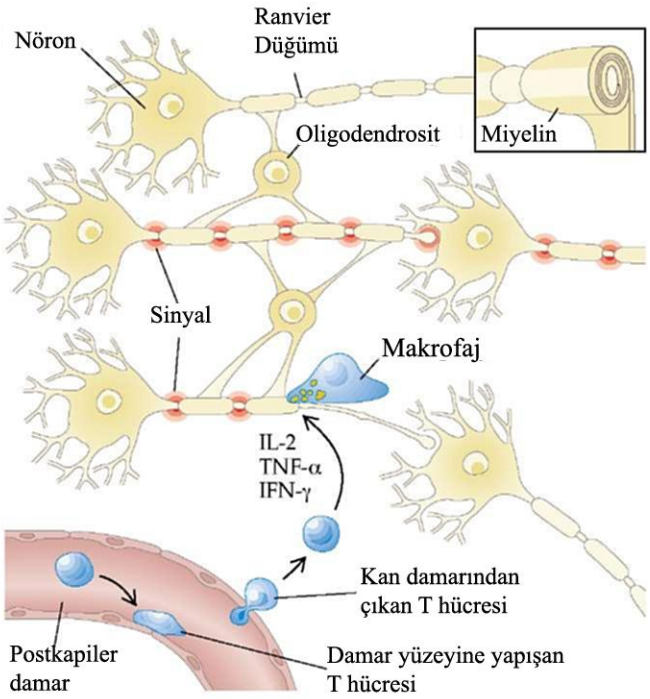
Dünyanın çeşitli coğrafi ve iklimsel bölgelerine göre MS'in görülme sıklığı değişmektedir. En yüksek görünme sıklığı, kuzey ve güney yarım kürelerde 45-65 derece enlemler arasındadır ve görülme oranı 100.000'de 30'un üstündedir. Bahsedilen enlem kuşağının komşusu olan, ülkemizin de içinde bulunduğu bu bölgede prevalans değeri 15-20/100.000 civarındadır. MS'in prevalans değeri tropikal bölgelerde ise 5/ 100.000' civarında gerçekleşmektedir. Bu dağılıma göre MS'un iklim ve coğrafyayla doğrudan bir ilgisi varmış gibi görünebilir, yine de etken bu değildir. Hastalıkta genetik etkilerin olduğunu gösteren bazı bulgular da vardır. Daha detaylı bilgi Geography in multiple sclerosis (Kurtzke 1977) adlı yayında yer almaktadır.

MS genç insanlarda trafik kazaları dışında nörolojik nedenli özürlülüklerde birinci sırayı almaktadır. Hastalık genellikle gençlerde, kadınlarda, sosyo-ekonomik düzeyi yüksek toplumlarda, kentlerde yaşayan eğitim düzeyi yüksek kişilerde görülen bir hastalıktır. Hastalığın ilk belirtileri alevlenmeler ve düzelmelerle seyreder. Başlangıç dönemlerinde hastalık tam bir düzelme gösterebilir bazen de hastalığın ilerlemiş evrelerinde düzelmeler

görülebilir, az sayıda hastada ise baştan itibaren sürekli kötüleşme söz konusu olabilir (Rotstein ve O'Connor 2014).

Hastalık demyelinizasyon adı verilen bir sürecin sonucunda meydana gelir. Demiyelinizasyon mekanizması sinir hücrelerini kaplayan ve yine hücrelerden oluşan, miyelin kılıfın bütünlüğünün bozulmasıdır. Demiyelinazyonun, miyelini oluşturan oligodendroglial hücrelerin ölümü, inflamatuvar hücreler tarafından miyelinin parçalanması, endojen metabolik toksinler, oksidatif hasar, antikor kompleman aracılıklı yıkım gibi çeşitli mekanizmalar ile meydana geldiği düşünülmektedir (Beken ve ark 2013).

Demiyelinazsyon, mekanik, viral akut toksik ya da otoimmün-kökenli olayları takiben ortaya çıkabilmektedir. Erken dönemde erişkin MSS'nin tekrar miyelin kılıfı oluşturma (remiyelinazasyon) kapasitesine sahip olduğu bilinmektedir. Ağır vakalarda, özellikle hasara yol açan olay kronikleşmiş ise remiyelinizasyon kapasitesi azalmaktadır. Örneğin, kuprizon (cuprizone) zehirlenmesi akut demiyelinizasyona neden olurken, toksik ajanla temasın devam etmesi durumunda kronik demiyelinizan lezyonlar gelişmektedir (Altıntaş ve Benbir 2005). Demiyelinazsyon mekanizmasının aşamaları Şekil 2.1'de gösterilmiştir (WebMD 2003).



Şekil 2.1 İmmün sistem kaynaklı demiyelinizasyonun aşamaları (WebMD 2003).

İnsanda en sık görülen demiyelinizan hastalık olan MS'de, oligodendrositler (OG) demiyelinizasyonun tamirinde (remiyelinizasyon) başarısız kalmaktadırlar. Sonuçta kalıcı miyelin ve OG kaybı ile şekillenen lezyonlar ve nörolojik özürlülük gelişmektedir (Altıntaş ve Benbir 2005).

Hastalığın erken dönemlerinde bir miktar miyelin tamiri oluşmaktadır. Bunlar, immatür OG'ler tarafından oluşturulan normalden daha ince miyelinize aksonlar olarak görülmektedir (Altıntaş ve Benbir 2005).

2.1 MS Hastalığının Seyri

MS hastalığının seyir olarak dört tipi vardır.

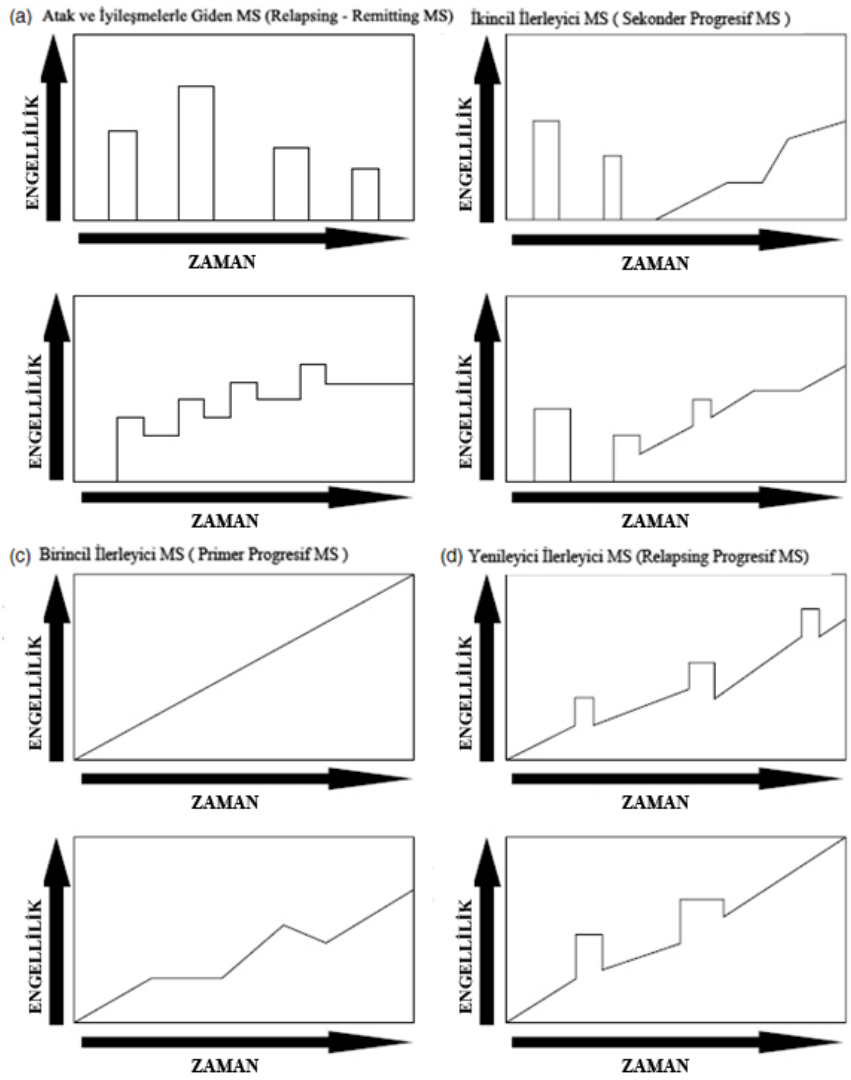
1-İyi Huylu MS (Benign): Bu tipte hafif ataklar vardır ve atakları tam düzelme takip eder. Zamanla biriken bir kötüleşme olmaz ve kalıcı bir hasar bırakmaz. Bu tipte ilk belirti, genellikle el ve ayaklarda uyuşmalardır. Ancak hastalığın başlangıcından 10-15 yıl sonra, bazı olgularda küçük sekeller bırakabilir. MS'li hastaların %10-15'i bu gruba dâhildir (Rotstein ve O'Connor 2014).

2-Tekrarlayan ve Düzelen Tip (Relapsing-Remitting): MS'lilerin yaklaşık %25'i bu gruba girer. Erken dönemde genellikle benign tipe benzer ve ataklardan sonra tam iyileşme olur. Ataklar; gün, hafta veya aylarca sürebilir. Ataklar daha önceki bulguların alevlenmesi veya yeni bir şikâyet şeklinde olabilir. Yine de tekrarlayan ataklar sonrası bazı sekeller kalabilir (Rotstein ve O'Connor 2014).

3-İkincil İlerleyen Tip: Başlangıcı "Tekrarlayan ve Düzelen" tip gibidir. Tekrarlayan ve Düzelen (Relapsing-Remitting) MS'lilerin % 40-50'si ikincil ilerleyen tipe dönüşür. Tekrarlayan ataklar sonrası düzelme daha zorlaşabilir, hatta durabilir. Böylece sekeller artabilir. Bu grup genellikle hastalığın başlangıcının 15-20 yılı içinde ortaya çıkar (Rotstein ve O'Connor 2014).

4-Birincil İlerleyen Tip: Ataklarla birlikte ya da ataksız seyir gösterebilir. Ataklı seyirde hastalığın başlangıcından itibaren giderek artan fonksiyonel kayıplar yani sakatlıklar ataklarla daha da şiddetlenebilir ve kalıcı fonksiyonel bozukluklar meydana gelebilir. MS'lilerin % 10-15'i bu gruba girer (Rotstein ve O'Connor 2014).

Şekil 2.2'de MS tiplerinin engelliliğe etkisi grafik olarak gösterilmiştir.



Şekil 2.2 Hastalık tiplerinin engelliliğe etkisi (Rotstein ve O'Connor 2014).

MS'lilerin üçte biri on yıl sonra da halen fonksiyoneldir ve özürlülük derecesi düşüktür. Bu nedenle yaşam kalitesini etkilese bile genel olarak iyi gidişli bir hastalık olarak kabul edilir. Hastalığın daha başlangıçta nasıl seyredeceğini bilmek olanaksızdır. Çünkü seyir kişiden kişiye değişmektedir. Ancak bazı hastalık özellikleri bir takım ipuçları verebilir. Örneğin; kadın olmak, hastalığın ataklarla seyrediyor olması, birinci ile ikinci atak arasındaki sürenin uzun olması, ilk atakları iyileşerek atlatmak, hastalık başlangıç yaşının genç olması, ilk atakların dengesizlik, ellerde beceriksizlik, titreme gibi bulgularla başlamaması gibi özellikler iyi seyir göstergesidir. Kısa sürede yatağa yahut tekerlekli sandalyeye bağımlı kalmak ya da yaşam süresini kısaltmak gibi klinik tablolar çok azdır (Altıntaş ve Benbir 2005).

2.2 MS Hastalığının Belirtileri

İlk belirtiler baş ağrısı, görme kaybı, çift görme, tek veya çift gözde görme azalması, dengesizlik ya da kol ve bacaklarda güç kaybı gibi belirtiler ortaya çıkabilir. Bazı durumlarda ise hiçbir belirti ortaya çıkmayabilir. Hastalığın beyindeki tutulum bölgesine göre belirtileri değiştiğinden dolayı çok geniş bir belirti yelpazesi vardır, genel olarak belirtiler şu şekilde sıralanabilir. Bulanık ya da çift görme, ataksi, Babinski bulgusu, nistagmus, klonus, beceriksizlik, dizartri (konuşma bozukluğu), duygu durum bozuklukları, yorgunluk, hemiparezi, parestezi, sık idrara çıkma ve idrar kaçırma (inkontinans), inkoordinasyon (koordinasyon bozukluğu), monoparezi, elde sinirlerdeki harabiyet nedeniyle kasların işlev yapamama hali ile karakterize paralizi (felç) durumu, hiperaktif derin tendon refleksleri (dizkapağı refleksi gibi.), erkeklerde iktidarsızlık, denge kusuru ve baş dönmesi (Compston ve Coles 2008).

2.3 MS Hastalığının Teşhisi

MS hastalığı, merkezi sinir sisteminin genelini hedef aldığından, beynin ve omuriliğin çok farklı ve birbirine benzemeyen yerlerinde meydana gelen tutulumlar olarak karşımıza çıkar. Bu yüzden tutulumun yerine göre değişik şikâyetlere neden olur. Ortaya koyduğu sorunlar tablosu her hasta için farklıdır ve diğer hastalıkları çağrıştırabilir. Tanılamada MSS tutulumu ile ilişkili klinik bulguların olması gerekmektedir. Tanıyı desteklemek ve ayırıcı tanı için tetkikler yapılır. Bu tetkiklerde beyin-omurilik sıvısında (BOS) oligoklonal band (OKB) ve IgG indeksinin belirlenmesi MS tanısı için oldukça önemlidir (Yetkin 2014).

Manyetik Rezonans Görüntüleme (MRG) yöntemiyle beyin ve omurilikte yapılan incelenmeler tanıya yardımcı yöntemlerin başında gelir. MRG ile elde edilen görüntülerde plaklar açık olarak görülürler. Plakların etkinlikleri (aktiflik–pasiflik durumu) ise damar yoluyla verilen Gadolinyum (Gd) verilerek belirlenir. Gd paramanyetik bir sıvıdır ve MRG görüntülerinde karşıtlık arttırıcı olarak kullanılır. Bir plağın Gd tutması etkin olduğunu gösterir (Grossman ve ark 1986).

Tanıya yardımcı olarak beyin omurilik sıvısının bazı özellikleri incelenebilir. Olignokal band, miyelin temelli protein, immunoglobulin G indeksi gibi ölçümlerde normal dışı değerler bulunması, beyinde bağışıklık sistemiyle ilgili bir sorun olduğunun habercisidir. Ayrıca görsel, işitsel ve bedensel uyarılmış yanıtlarda anormallikler olması da sırasıyla göz ve kulağın beyin bağlantıları üzerinde ve omurilikte yerleşmiş plağa işaret eder. Dikkatli bir hastalık öyküsü, nörolojik inceleme ve doğru kullanılmış laboratuvar değerlendirmeleri genellikle kesin tanıyı sağlar. MS tanısının olabildiğince çabuk ve doğru konması önemlidir.

Hastaların çoğu gençtir ve tanıya bağlı olarak pek çok önemli yaşam kararları vermeleri (eğitim, evlilik, çocuk...) gerekebilecektir. Bu yüzden tanı netleşmeden hiçbir hastaya MS tanısı yakıştırılmamalıdır (McDonald ve ark 2001).

Jean Martin Charcot'un hastalığı 1868 yılında (Charcot 1868) tanımlamasından sonra bu alanda birçok kez tanı kriterleri oluşturulmuştur. İlk tanı kriterleri 1965 yılında Schumacker tarafından belirlenmiş, daha sonra Poser başkanlığında toplanan komite 1983 yılında nörofizyolojik testleri, MRG ve BOS incelemesini değerlendirerek yeni MS kriterlerini tanımlanmıştır (Yetkin 2014). Tanı aşamasında en belirleyici ve kabul edilmiş yöntem 2001 yılında McDonald ve ark. tarafından öne sürülen McDonald kriterleridir (McDonald ve ark 2001).

Her ne kadar MS tanısı hala klinik bulgulara dayalı olsa da Manyetik Rezonans Görüntüleme (MRG) genel tanılama şemasında yer almıştır (Rovira ve Leon 2008). Bunun sebebi MRG'nin kendine özgü hassasiyetiyle beyin ve omurilikteki demiyelinize olmuş plakların dağılımını gösterebilme yeteneğidir (Rovira ve Leon 2008).

2.4 Tedavi

MS hastalığının bilinen bir kesin geri dönüşü olan bir tedavisi bulunmamaktadır, hastanın yaşam kalitesini yükseltme ve yaşam süresini uzatma yönünde hayat boyu süren tedavi yöntemleri mevcuttur. Bunları şu başlıklar altında toplayabiliriz; destekleyici tedavi, atak tedavisi, semptomatik tedavi ve iyileştirme nöro-koruyucu yöntemlerle hastalık aktivitesini baskılamaya yönelik tedavi. Bu tedaviler içerisinde interferon ve türevleri, tedavide çok önemli bir yer tutmaktadır. İnterferon tedavisine immün sistemin MSS üstüne olan etkisini baskıladığından MS hastalığının erken dönemlerinde başlanması halinde hastalığın seyrinin yavaşlatılması hatta durdurulması söz konusudur. Hastalığın erken teşhisi bu yüzden çok önemlidir ve günümüzde erken teşhis için yoğun çalışmalar devam etmektedir (Compston ve Coles 2008).

3 MANYETİK REZONANS GÖRÜNTÜLEME

Manyetik rezonans görüntüleme atomların manyetik alanla etkileşimlerinden faydalanan bir görüntüleme sistemidir. Manyetizma, elektrik yüklü parçacıkların hareketi sonucu oluşur. Özellikle MRG tekniğinde protonun hareketinden dolayı oluşan manyetik vektörün özelliklerinden faydalanılır. Manyetik rezonans (MR), bu vektör ile dışarıdan uygulanan manyetik alanın etkileşiminden oluşur. Protonun bu hareketine spin adı verilir, Argon ve Cerium atomları hariç tüm atomların spine sahip en az bir izotopları bulunur. Tıbbi amaçlı kullanılan MRG tekniğinde hidrojen atomuna yoğunlaşılmaktadır, çünkü hidrojen atomu canlı vücudunun %99.98'inde bulunmaktadır (Elmalıoğlu ve Çelik 2013).

3.1 Manyetik Rezonans Görüntülemenin Temel Prensipleri

Canlı dokudaki hücre sıvısı ve lipitler içerisindeki hidrojen çekirdeklerinden sinyal elde edebilmek için incelenecek kesimi önce güçlü bir manyetik alana maruz bırakılır. Daha sonra enerjilerine uygun radyofrekans göndererek davranışları incelenmektedir (Elmalıoğlu ve Çelik 2013).

Protonlar, dokularda normalde birbirinin etkisini ortadan kaldıracak şekilde rastlantısal olarak dizildiklerinden dolayı vücudun doğal halinde manyetizasyonu sıfırdır. İncelenecek vücut kesimi güçlü bir manyetik alan etkisine girdiğinde protonlar manyetik alan vektörüne paralel konuma geçerler. Böylece uygulanan manyetik alan vektörü çevresinde topaç gibi bir dönme halini alırlar (presesyon). Protonların presesyonlarının frekansı manyetik alanın gücü ile doğru orantılıdır. Bu hareket Larmor eşitliği (Eşitlik 3.1) ile ifade edilir (Griffiths 1995, Elmalıoğlu ve Çelik 2013)

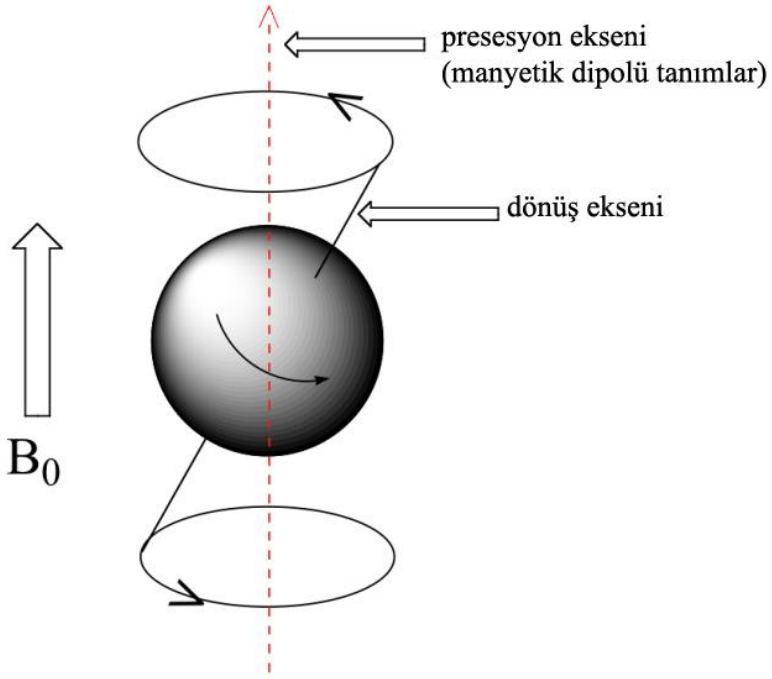
$$w_0 = \gamma \beta_0 \tag{3.1}$$

Burada:

γ : Gyromanyetik orandır ve hidrojen için değeri 42,57 MHz/Tesla dır.

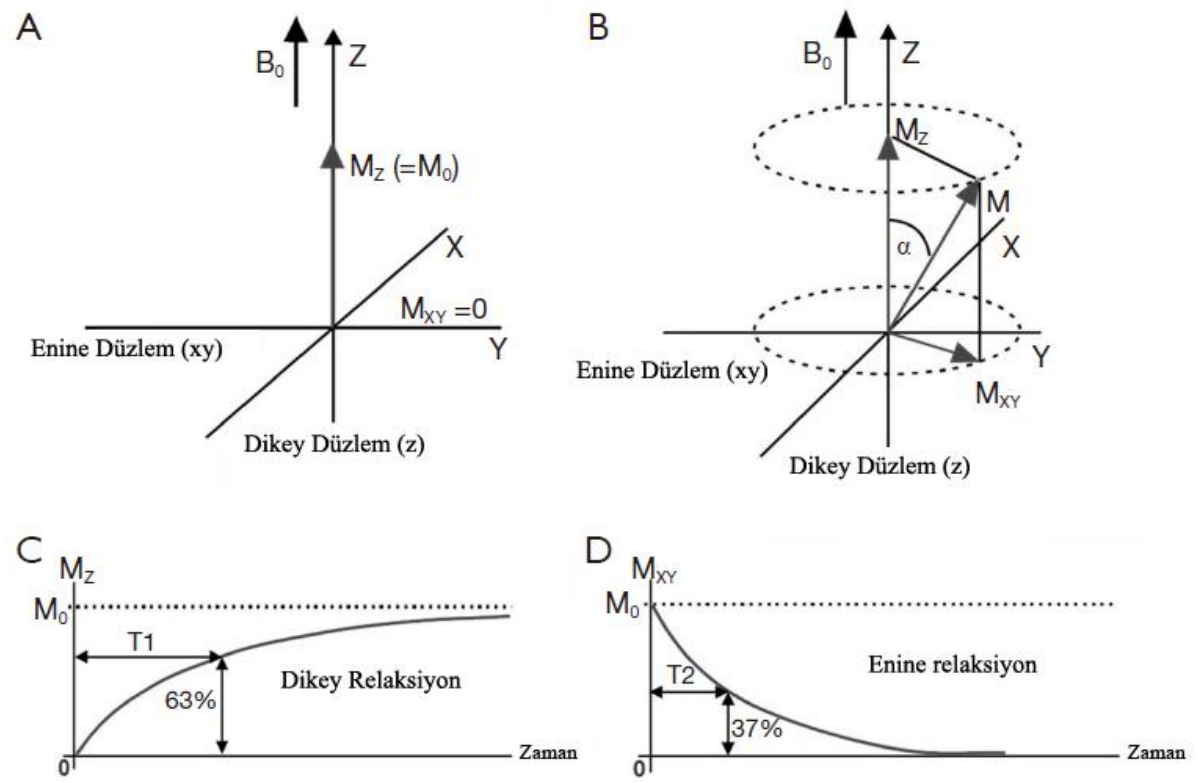
β_0 : Uygulanan dış manyetik alan şiddetidir ve birimi Tesla'dır.

w_0 : Manyetik alandaki protonun dönüş hızıdır, birimi MHz dir. 1,5 Tesla'lık alanda 63,8 MHz'dir (Elmalıoğlu ve Çelik 2013). Şekil 3.1 de presesyon halindeki proton davranışı görülmektedir (http://chemwiki.ucdavis.edu/ 2014).



Şekil 3.1 Presesyon halindeki proton davranışı (http://chemwiki.ucdavis.edu/ 2014)

Protonlar radyo frekansı ile uyarılınca manyetik alan vektörüne paralel olan konumlarından saparak vektörle bir açı yaparlar. Radyofrekans (RF) kesildiğinde ise presesyonel hareketle tekrar eski konumlarına dönerler. Protonların eski konumuna dönmesi işlemine relaksiyon denir. Relaksiyon sırasında radyofrekansın etkisiyle manyetik alana belli bir açı yapan protonlar sinyalin kesilmesiyle eş zamanlı olarak aynı fazla presesyona başlar. Bu sırada protonlar kendilerine uygulanan manyetik enerjiyi kaybederek MRG cihazındaki bobinlerde alternatif akım şeklinde saptanabilecek bir sinyal yayarlar. MR görüntülemede bu sinyal kullanılır. Sinyal başlangıç anında noktadır, çünkü protonlar en yüksek enerji seviyesindedir (özel bir durum yoksa bu açı 90^{o} dir) ve hepsi birden hareket ederek (aynı fazda) çok güçlü bir manyetik alan oluşturur. Bu güçlü manyetik alanın dönmesi ise yüksek bir alternatif akım yaratır. Enerji boşalımı üstel bir yapıya sahiptir. Şekil 3.2 de Protonların enerji kaybının zamana göre grafiği gösterilmiştir (Krishnamurthy ve ark 2014).



Şekil 3.2 Protonların enerji kaybının zamana göre grafiği (Krishnamurthy ve ark 2014)

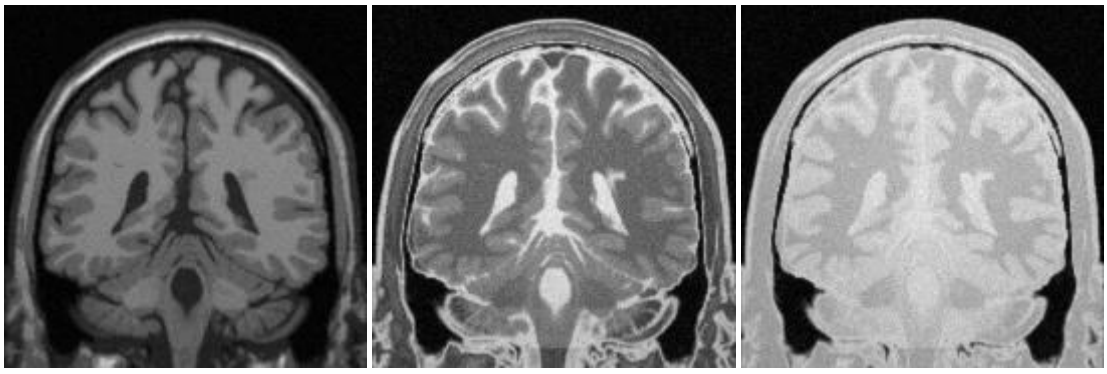
Uygulanan radyofrekans sinyalinin kesilmesiyle, protonlar gittikçe küçülen dairesel bir yol izleyerek başlangıç durumundaki presesyon halini alırlar. Başlangıç konumuna yaklaştıkça protonların x-y düzlemindeki izdüşümü küçüldüğünden dolayı sinyalin gücü azalır. Protonlar başlangıç durumuna ulaştıklarında radyo frekans ile yüklenen enerjiyi tamamen kaybetmiş olurlar böylece sinyal üretmezler. Bu duruma defaze olma adı verilir (Elmalıoğlu ve Çelik 2013).

Protonların, üç boyutlu koordinat sisteminde bulundukları ortama göre defaze olma süreleri farklıdır. Protonların eski konumlarına gelme sürecinde Z eksenine göre bakıldığında protonun eski haline gelişi gözlemlenir. Bu eksende defaze olma süresine T1 süresi adı verilir. X-Y düzleminde defaze olma süresine ise T2 süresi denir. T1 süresi T2'den daima daha uzundur (Elmalıoğlu ve Çelik 2013).

MR görüntüleri oluşturulurken, dokularda bulunan proton miktarı ve T1 - T2 süreleri arasındaki farklılıklardan faydalanılır. Proton yoğunlukları doku ve lezyonların, içerdikleri su miktarına göre farklılıklar gösterir, protonların T1 ve T2 süreleri farklıdır. Örneğin saf suyun ya da BOS'un T1 değeri 2000-3000 ms, yağınki ise 150-250 ms. dir. T2 değeri ise genellikle T1 değerlerinin %10-20'si kadardır. Bu değerler uygulanan manyetik alanın gücüne göre değişir. Görüntü oluşturulurken, proton yoğunluğu (PD), T1 ve T2 parametrelerinin üçü de

kullanılır. Yapılacak olan incelemeye bağlı olarak bu üç parametrelerden her birinin ağırlıklı olarak kullanıldığı farklı türde görüntüler elde edilir. Bu görüntüler T1 ağırlıklı, T2 ağırlıklı ve proton ağırlıklı görüntüler olarak adlandırılır (Elmalıoğlu ve Çelik 2013).

Bu görüntüleme tekniğine spin eko (SE) görüntüleri denir. MRG'nin ana görüntüleme yöntemi SE görüntülemedir. Daha kısa bir inceleme süresi gerektiğinde gradient eko (GE) adlı yöntem de kullanılabilir. İncelenecek doku, bölge ya da baskılanması gereken maddeye göre perfüzyon, diffüzyon gibi değişik amaçlara göre hazırlanmış, farklı puls sekansları da elde edilecek görüntüye göre kullanılır (Elmalıoğlu ve Çelik 2013). Şekil 3.3'de BrainWeb MS database MRG görüntüsünün 86. diliminin PD, T1 ve T2 sekansları ile elde edilmiş halleri görülmektedir. Görüntüler BrainWeb veri tabanından alınmıştır (BrainWeb).



(a) (b) (c)

Şekil 3.3 BrainWeb MS database MRG görüntüsünün 86. diliminin (a) T1, (b) T2 ve (c) PD çekim teknikleri ile elde edilmiş halleri (Görüntüler http://BrainWeb.bic.mni.mcgill.ca/ adresinden alınmıştır).

3.2 MRG Tekniğinin Diğer Tekniklere Göre Avantaj ve Dezavantajları

Biyomedikal görüntüleme sistemlerinin diğer yöntemlere göre avantajlı ve dezavantajlı olduğu yönleri vardır, Çizelge 3.1'de, MRG ve diğer görüntüleme tekniklerinin avantaj ve dezavantajları gösterilmiştir (http://www.nps.org.au/medical-tests/medical-imaging/for-individuals/imaging-compared 2015):

Çizelge 3-1 Radyolojik görüntüleme tekniklerinin karşılaştırması

Görüntüleme Tipi	**Avantaj ve Dezavantajları**
X - Işını Kemikler, bazı tümörler ve diğer katı nesnelerin görüntülenmesi için X-ışınları kullanır.	**Avantajları** Hızlı, non-invaziv ve acısızdır. Kırık kemikler, bazı kanser ve enfeksiyonlara dahil olmak üzere çeşitli hastalıkların ve yaralanmaların teşhis yardımcı olabilir. **Dezavantajları** X-ışını radyasyonuna maruz kalmaktan dolayı gelecekte kanser olma riskinde düşük seviyeli bir artışa sebep olabilir. (Risk çocuklarda daha yüksektir.)
Bilgisayarlı Tomografi (BT) Kemikler, organlar, dokular ve tümörler de dahil olmak üzere vücudun içinde detaylı görüntülerini gösteren kesit tabakaları üretmek için çoklu X-ışınları kullanır.	**Avantajları** • Hızlı ve ağrısız, • Sadece X-ışınına göre daha geniş bir teşhis aralığına sahiptir, • Daha ciddi sorunların varlığını ayırt edebilir veya algılayabilir, •Önceden tedavi edilen hastalığın nüksedip etmediğini kontrol etmek için kullanılabilir. **Dezavantajları** •X-ışını radyasyonuna maruz kalmaktan dolayı gelecekte kanser olma riskinde düşük seviyeli bir artışa sebep olabilir (Risk çocuklarda daha yüksektir), •Sade X-ışınlarına göre daha yüksek dozlarda radyasyon kullanır, bu yüzden riskler (düşük oranda da olsa) diğer görüntüleme türleri için genellikle daha büyüktür, •Bazı kişilerde alerjik ya da enjeksiyon sahası reaksiyonları, böbrek sorunlarına sebep olabilecek kontrast madde (boya) reaksiyonu görülebilir.

	• Bazı prosedürler anestezi gerektirir
Positron-emission tomography (PET) Bir radyoaktif 'izleyici' enjektesi, teneffüs edilmesi veya yutma içerir. Bu malzemenin yaydığı gama-ışınları kemik ve organların görüntüleri göstermek için tarayıcı tarafından kullanılır	**Avantajları** •Genellikle ağrısız, •Geniş bir yelpazedeki durumların teşhis, tedavi, ya da sonuçlarını tahmin yardımcı olabilir, •Diğer görüntüleme türlerinin aksine, vücudun farklı parçalarının nasıl çalıştığını gösterebilir ve çok daha erken sorunları tespit edebilir, •Kanserin ne kadar yayıldığını ve tedavinin ne kadar etkili olduğunu kontrol edebilir, **Dezavantajları** •İyonizan radyasyona maruz kalmayı içerir (gamma-ışınları), •Radyoaktif madde, alerjik reaksiyonlara veya enjeksiyon bölgesindeki reaksiyonlara sebep olabilir. PET tarayıcılar bazı insanların klostrofobik hissetmesine sebep olabilir, bu yüzden yatıştırıcı kullanmak gerekebilir.
Manyetik Rezonans Görüntüleme (MRG) Organların, yumuşak doku, kemik, ligament ve kıkırdak ayrıntılı görüntüleri göstermek için manyetik alanlar ve radyo dalgalarını kullanır	**Avantajları** •Genellikle non-invaziv ve ağrısız, •Hiçbir iyonizan radyasyon kullanmaz, •Geniş bir yelpazedeki durumların teşhis, tedavi, ya da sonuçlarını tahmin yardımcı olabilir, •Bazı teşhis türlerinde BT benzeri bilgiler verebilir. **Dezavantajları** •Uzun ve gürültülü bir prosedür olabilir, •Çekim sırasında hareket, işlemi bozabilir ve yeniden çekim yapmayı gerektirebilir,

	•Bazı insanların klostrofobik hissetmesine sebep olabilir, •Küçük çocuklar ya da hareketsiz kalamayan insanlar için sedasyon veya anestezi gerekli olabilir, •Bazı kişilerde alerjik ya da enjeksiyon sahası reaksiyonları, böbrek sorunlarına sebep olabilecek kontrast madde (boya) reaksiyonu görülebilir, •Bazı durumlarda (örneğin bir kalp pili mevcut olduğunda) işlem gerçekleştirilemez.
Ultrason İç organların, yumuşak doku, kemik dahil olmak üzere vücudun veya doğmamış bebeklerin bir ekran üzerine hareketli görüntülerini üretmek için yüksek frekanslı ses dalgalarını kullanır.	**Avantajları** •Genellikle non-invazif, güvenli ve nispeten ağrısız, •Hiçbir iyonizan radyasyon kullanmaz, •Genellikle kontrast madde enjeksiyonu (boya) gerektirmez, • Karın, pelvis, kan damarları, meme, böbrek, kas, kemik ve eklem gibi vücudun değişik yerlerinde, teşhiste yardımcı olabilir, •Hamilelik sırasında bebeğin sağlığını kontrol etmek için kullanılabilir. **Dezavantajları** •Görüntünün kalitesi ve yorumlanması, tarama yapan kişinin tecrübesine son derece bağlıdır. •Kişinin vücut yapısı, hava ve kalsifiye alanların varlığı (örneğin kemikler, plaklar ve sertleştirilmiş arterler dahil), gibi diğer faktörler görüntü kalitesini etkiler. •Bazı ultrason türleri özel bir prob gerektirebilir

3.3 MRG'nin MS Hastalığının Teşhisindeki Yeri

MRG'nin noninvazif yapısından ve iyonizan ışın kullanmamasından dolayı, MS tanısında en çok kullanılan yöntemlerin başında gelmektedir. MS teşhisinde en önemli parametre plakların belirlenip görüntülenmesidir, MRG sayesinde plaklar kesin bir doğrulukla belirlenebilmektedir (Diren 2000). MS hastalığında MR çekimleri özel bir dikkatle gerçekleştirilmektedir. Özellikle ilaçlı (Gadolinyum) çekimler sayesinde, plakların durumu hakkında detaylı bilgiler elde edilebilmektedir. Yine aynı şekilde hastalığın seyri hakkında bilgi edinmek için çekimler belli aralıklarla tekrarlanır (Elmalıoğlu ve Çelik 2013).

4 GÖRÜNTÜ İŞLEME

Tez çalışması sırasında kullanılan görüntüler, sayısal ortamda kaydedilmiş beyin MRG görüntüleridir. Bu görüntülerin analizden önce hata oranının düşürülüp, analiz hızının arttırılması için verilerin uygun hale getirilmesi gerekmektedir. Bu amaçla görüntü işleme tekniklerinden faydalanılmaktadır. Ayrıca tezde bahsedilen güçlendirme algoritmalarında da yine bu tekniklerden faydalanılmaktadır.

Görüntü işleme, sayısal ya da sayısallaştırılmış görüntüler üzerinde işlem yapan algoritmaların geliştirildiği bir araştırma dalıdır (Pratt 1991, Gonzalez ve Woods 2006). Sayısal ya da sayısallaştırılmış görüntüler piksel (piksel) adı verilen veri parçacıklarından oluşan matrisler şeklinde saklanır. Eğer veriler üç boyutlu olarak tanımlanmışsa her bir veri parçacığı voksel (voksel) olarak adlandırılır. Görüntüler sayısal ortamda matris formunda kaydedildiği için, matrisler üstünde yapılabilen tüm işlemler görüntülere de uygulanabilmektedir. Bu işlemler hem aritmetik işlemler hem de matris işlemleri şeklinde olabilir (Asyalı ve ark 2014).

Görüntü işleme iki ayrı zeminde uygulanabilir, bunlar uzaysal zemin ve frekans zemini olarak adlandırılır. Uzaysal zemin, görüntünün pikseller halinde ifade edildiği ve kesikli koordinat sisteminde gösterildiği halidir. Frekans zemini ise görüntünün alt frekans bantlarına ayrıştırılarak ifade edildiği haldir. Her iki zemin arasındaki dönüşümler, Fourier ve Ters Fourier dönüşümleri ile gerçekleştirilir (Gonzalez ve Woods 2006).

Görüntü işleme, sinyal güçlendirme işlemlerinden görüntü anlamaya kadar geniş bir çalışma alanını kaplar. Genel olarak görüntü işlemede yapılan işlemler; veri önişleme (pre-processing), veri azaltma (data reduction), bölütleme (segmentation), nesne tanıma (object recognition) ve görüntü anlama (image understanding) olarak sıralanabilir. Her bir adımda, giriş ve çıkış verileri, görüntüler (piksel), görüntüden elde edilen ölçüm veya özellikler (feature), önceki aşamalarda yapılmış olan değerlendirmeler ve kararlar (labels) veya nesne ilişki bilgileri (graphs) olabilir (Semmlow 2004).

Görüntü işleme problemlerinde teorik olarak iyi sonuç veren yeterli lineer yöntem mevcuttur, ancak bu çözümler genellikle sadece ideal durumlarda çalışmaktadır. Öte yandan görüntülerin içerdiği bilgilerin lineer olmaması (nonlinear) bu yöntemlerin çok yoğun matematiksel işlemler içermesine, örneğin parça parça doğrusallaştırma işlemi sırasında görüntü üstünde çok fazla lineer parça oluşturulması, ya da çok hassas parametre düzenlemeleri yapılmasına sebep olur. Doğrusal modellerin yeterli olmadığı noktalarda,

doğrusal olmayan modeller kullanılmak zorundadır ki bu durum yoğun bir şekilde üzerinde araştırmaların yapıldığı güncel bir konudur (Gonzalez ve Woods 2006). Bu bölümde MRG görüntüleri üstünde kullanılan bazı görüntü işleme tekniklerinden bahsedilmektedir. Bölüm boyunca aksi belirtilmediği takdirde Q(i,j) işlem sonrası elde edilen çıkış görüntüsünü, P(i,j) ise işleme giren görüntüyü ifade etmektedir.

4.1 Renk Uzayları

Sayısal görüntü işleme, görüntünün bir ortamdan sayısal olarak elde edilmesi ile başlar. Görüntünün dijital verilere dönüştürülmesi aşamasında genel olarak kameralar ve tarayıcılar kullanılmaktadır. Biyomedikal çalışmalarda ise görüntü MRG cihazları, PET tarayıcıları, Mammogram aygıtları, X-Ray cihazları ve CT aletleri gibi çok çeşitli kaynaklardan elde edilebilir. Bu tez çalışmasında kullanılan görüntüler, MRG cihazlarından elde edilmiştir.

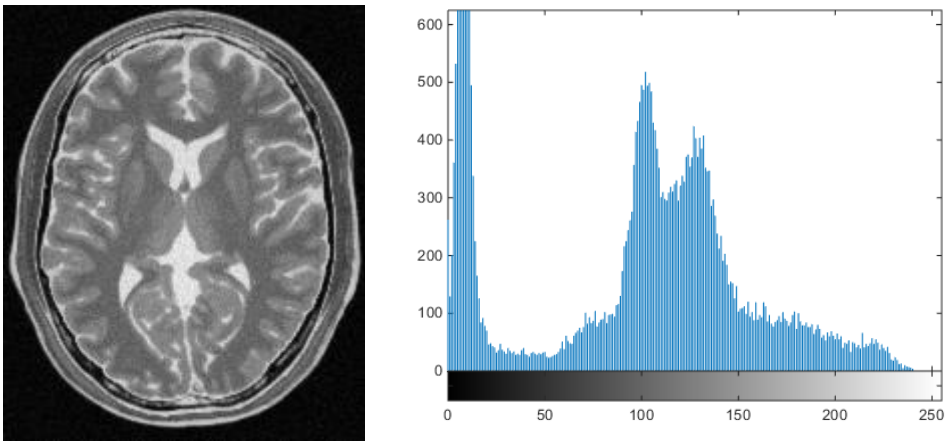
Bu cihazlarla elde edilen görüntüler, renk uzayı adı verilen ve her dijital verinin renk olarak karşılığını içeren bir uzayda tanımlanırlar. Literatürde kullanım amacına göre birden çok renk uzayı tanımlanmıştır. Bunlardan en yaygın olanları; Grayscale, RGB, Lab, HSV, YIQ ve HSI olarak sayılabilir. Bu renk düzlemlerinin yapılan çalışmaya bağlı olarak sağladıkları avantajlar ve dezavantajlar bulunmaktadır. Tüm renk düzlemleri arasında dönüşüm formülleri tanımlanmıştır böylece her uzay bir diğerine dönüştürülebilir (Gonzalez ve Woods 2006).

4.2 Veri Tipi Dönüşümleri

Bu konu her ne kadar görüntü işlemenin temel konularından olmasa da çalışmaya başlamadan önce görüntülerin tanımlandığı sayısal değer aralıklarının çok önemli olduğuna dikkat edilmelidir. Örneğin (0-255) aralığında yoğunluk değerine sahip bir şekilde tanımlanmış görüntü, (-1, +1) aralığında çalışan bir algoritma ile incelenirse, elde edilecek sonuçlar tamamen anlamsız ve yanlış olacaktır. Bu yüzden öncelikle veri tip dönüşümlerine dikkat edilmesi gerekmektedir.

Görüntünün dijital ortama aktarılması sırasında her bir piksel ya da voksel sayısal bir veri tipi sınırları içerisinde tanımlanacaktır. Bu tanımlama n-bit yoğunluk değeri olarak ifade edilir. Örneğin 8-bit yoğunluğu ile tanımlanmış bir görüntü $2^8 = 256$ yoğunluk değeri ile tanımlanır (Seul ve ark 2000, Gonzalez ve Woods 2006). Bit sayısı arttıkça görüntünün histogramının tanım aralığı artacağından görüntünün hassasiyeti de artacaktır. Histogram bir görüntüde hangi piksel değerinden kaç adet olduğunu gösteren bir grafiktir (Seul ve ark

2000). Şekil 4.1'de NEÜ tıp fakültesi radyoloji bölümünden alınan T2 ağırlıklı beyin MRG görüntüsü Şekil 4.1 (a)'da ve aynı görüntünün histogram grafiği Şekil 4.1 (b)'de gösterilmiştir:



(a) (b)

Şekil 4.1 T2 ağırlıklı beyin MRG görüntüsü (a) T2 ağırlıklı MRG görüntüsü (b) Görüntüye ait Histogram

Görüntüde veri tipi dönüşümü, görüntüyü tanımlayan bit sayısını, arttırıp azaltma veyahut tanım aralığını değiştirme işlemidir. Örneğin 8-bit'lik görüntünün $2^8 = 256$ farklı değer alabildiğinden dolayı bilgisayar ortamında integer adı verilen ve (0 - 255) arası değer alan veri tipi ile tanımlanabilir. Eğer veri virgülden sonra hassasiyete sahip olacaksa float adı verilen ve $(1{,}5e^{-45}$, $3{,}4e^{38})$ aralığında tanımlanan veri tipi kullanılması gerekecektir. Çalışmanın içeriğine çeşitli veri tipleri seçilip bunlar arasında dönüşümler yapılması gerekmektedir. Bu konu gözden kaçırıldığında önemli hatalara sebep olabilir.

4.3 Görüntü Üzerinde Matematiksel İşlemler

Görüntüler üstünde uygulanan matematiksel işlemler pikseller üstünde teker teker yapılan işlemlerdir. Piksel değerinin toplanması, çıkarılması, çarpılması, bölünmesi gibi matematiksel işlemler ve VE, VEYA, DEĞİL gibi mantıksal işlemler olabilir. Örnek olarak aşağıdaki işlemler verilebilir (Gonzalez ve Woods 2006):

- **İki görüntünün toplanması:**

$$Q(i, j) = P_1(i, j) + P_2(i, j) \tag{4.1}$$

- **Görüntünün sabit sayıyla toplanması:**

$$Q(i, j) = P_1(i, j) + C \tag{4.2}$$

- **İki görüntünün birbirinden çıkarılması:**

$$Q(i, j) = P_1(i, j) - P_2(i, j) \tag{4.3}$$

- **Görüntüden sabit sayının çıkarılması:**

$$Q(i, j) = P_1(i, j) - C \tag{4.4}$$

- **İki görüntünün çarpılması:**

$$Q(i, j) = P_1(i, j) \times P_2(i, j) \tag{4.5}$$

- **Görüntünün sabit sayıyla çarpılması:**

$$Q(i, j) = P_1(i, j) \times C \tag{4.6}$$

- **İki görüntünün bölünmesi:**

$$Q(i, j) = P_1(i, j) \div P_2(i, j) \tag{4.7}$$

- **Görüntünün sabit sayıyla bölünmesi:**

$$Q(i, j) = P_1(i, j) \div C \tag{4.8}$$

- **Görüntülerin harmanlanması:**

$$Q(i, j) = X \times P_1(i, j) + (1 - X) \times P_2(i, j) \tag{4.9}$$

Bu eşitliklerde Q(i,j) işlem sonunda elde edilen sonuç görüntüsünü P_n (i,j)'ler işleme giren görüntüleri, C sabit sayıyı, i ve j'ler ise üstünde işlem yapılan pikselin satır ve sütun değerlerini ifade eder ve tam sayılar kümesinde tanımlıdırlar. Yapılan işlemlerde dikkat edilmesi gereken önemli bir husus, daha önce bahsedildiği gibi veri tiplerinin sınırlarıyla ilgili sorundur. Örneğin toplama işleminde 8 bit ile ifade edilen bir piksel 255 üstünde bir sonuç çıksa bile 255 üstüne ulaşamayacağı için b değerde kalır, bu durum doyma (saturasyon)

olarak adlandırılır. Ya da negatif değer alamayan bir veri tipi kullanılıyorsa negatif değerli pikseller 0 olacak şekilde düzenlenir. Yapılan işleme göre bu taşma durumlarının nasıl düzenleneceği algoritma geliştiriciye bağlıdır (Gonzalez ve ark 2004).

Mantık operatörleri ise tamsayılı görüntüler yerine mantıksal olarak tanımlı görüntü tipleri üstüne uygulanır. Bu tip görüntülerin bit derinliği sadece 1-bit olduğundan sadece siyah ya da beyaz şeklinde görüntülenirler. Bilinen tüm mantıksal işlemler bit bazında bu görüntülere uygulanabilir (Gonzalez ve ark 2004).

Daha karmaşık sayısal görüntü işleme yöntemleri, gerek sayısal gerek matris operatörlerinin belli bir düzende kullanılmasıyla gerçekleştirilebilir (Gonzalez ve ark 2004).

4.4 Noktasal İşlemler

Uzaysal zeminde tanımlanmış olan görüntülerin üstünde yapılan en basit işlemler, tek bir piksel üstünde yapılan işlemlerdir. Bu işlem giriş görüntüsü ile çıkış görüntüsü arasında tanımlı bir fonksiyon ile ifade edilir. Bu fonksiyon haritalama fonksiyonu olarak adlandırılır, Eşitlik 4.10 da gösterildiği gibidir.

$$Q(i, j) = M(P(i, j)) \tag{4.10}$$

Bu eşitliklerde Q(i,j) işlem sonunda elde edilen sonuç görüntüsünü P(i,j)'ler işleme giren görüntüyü, i ve j'ler ise tamsayı olarak görüntünün satır ve sütun değerlerini ifade eder. M ise harita fonksiyonudur ve uygulanacak olan görüntü işleme tekniğine göre formulasyonu değişir. Genel tekniklerin bazıları takip eden bölümlerde ifade edildiği gibidir.

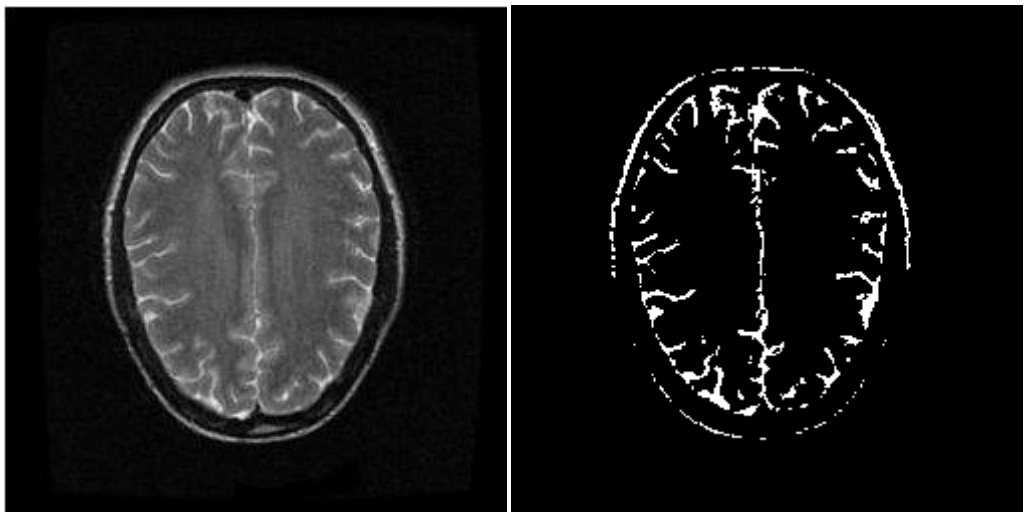
4.4.1 Eşikleme

Eşikleme işlemi 0- 255 arasında ifade edilmiş gri ölçekli görüntünün ikili (binary) değerli görüntüye çevrilmesi işlemidir. Eşiklemede girişi gri değer yoğunlukları çıkışı ise ikili değer olacak şekilde bir haritalama fonksiyonu kullanılarak görüntü belirlenen bir eşik değere göre işlenir. İşlemin haritalama fonksiyonu Eşitlik 4.11 de ifade edildiği gibidir.

$$Q(i, j) = M(P(i, j)) = \begin{cases} 0 & \text{eğer } \mathbf{r} < T \text{ ise} \\ 1 & \text{eğer } \mathrm{r} \geq T \text{ ise} \end{cases} \tag{4.11}$$

Burada T eşik değerini r ise giriş görüntüsündeki eşiklemeye tabi tutulan piksel değerini ifade eder. Eğer renkli bir görüntüye eşikleme işlemi uygulanacaksa, işlem görüntünün tanımlı olduğu renk uzayının her bir kanalı üstünde ayrı ayrı uygulanır. Bu işlemde her kanal için ayrı eşik değerleri belirlenebilir. Eşik değerinin belirlenmesi için çeşitli

yöntemler geliştirilmiştir. Uygulamanın amacına göre uygun olan metot seçilir (Gonzalez ve Woods 2006). MIDAS veri tabanından alınmış aksiyel kesitli gri seviye MRG beyin görüntüsü Şekil 4.2 (a)'da ve aynı görüntünün T=126 eşik değerine göre eşiklenmiş ikili formdaki hali Şekil 4.2 (b)'de gösterilmiştir .



(a) (b)

Şekil 4.2 MIDAS veri tabanından alınmış aksiyel kesitli gri seviye MRG beyin görüntüsü (a) ve aynı görüntünün T=126 eşik değerine göre eşiklenmiş ikili formdaki hali.

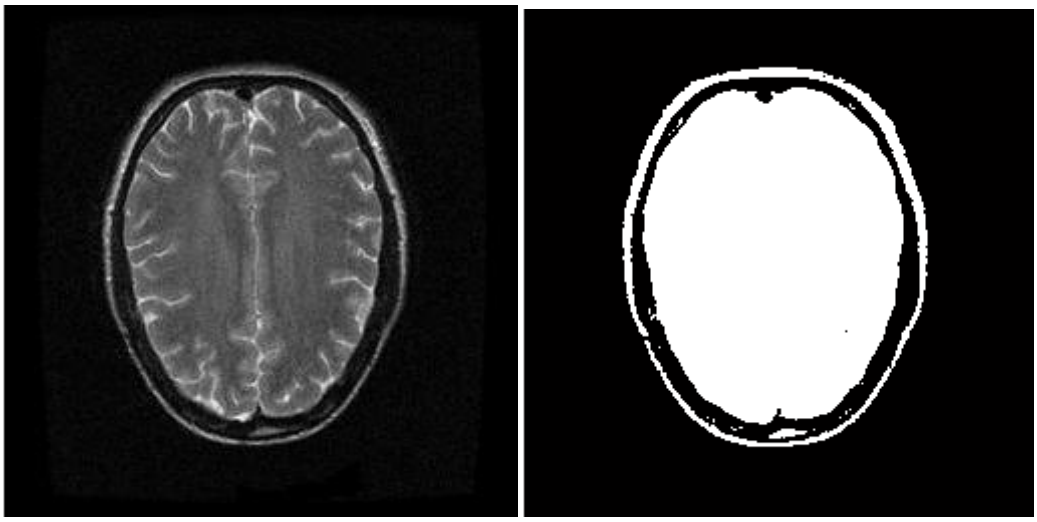
4.4.2 Adaptif eşikleme

Eşikleme işleminin temel halinde bir eşik değeri giriş görüntüsündeki tüm piksellere uygulanarak çıkış görüntüsü elde edilir. Adaptif eşikleme işleminde ise incelenen piksel bulunduğu bölgenin ışık şartlarına göre eşik değeri hesaplanır. Bu algoritmalardan en ünlüsü Otsu'nun gri seviye görüntüler üstünde geliştirdiği algoritmadır ve kısaca kendi ismi ile anılır.

Adaptif eşikleme gri seviye ya da renkli görüntüleri giriş olarak alır ve çıkış olarak ikili değerli görüntüler verir. İşlem sırasında her piksel için bir eşik değeri hesaplanır ve piksel değeri eşik değerinden düşük ise 0, yüksek ise 1 değeri alır (Otsu 1979).

Eşiğin hesaplanmasında genel olarak kullanılan iki metot vardır bunlardan birincisi Chow ve Kaneko'nun yaklaşımı (Chow ve Kaneko 1972) diğeri ise yerel eşikleme (local thresholding) olarak adlandırılır (Sankur 2004). İki metotta da temel yaklaşım görüntünün

daha küçük parçalara ayrılarak her parça için eşik değerinin ayrı ayrı hesaplanmasıdır. MIDAS veri tabanından alınmış aksiyel kesitli gri seviye MRG beyin görüntüsü Şekil 4.3 (a)'da ve aynı görüntünün adaptif eşiklemeyle eşiklenmiş ikili formdaki hali Şekil 4.3 (b)'de gösterilmiştir.



(a) (b)

Şekil 4.3 MIDAS veri tabanından alınmış aksiyel kesitli gri seviye MRG beyin görüntüsü (a) ve aynı görüntünün adaptif eşiklemeyle eşiklenmiş ikili formdaki hali (b)

4.4.3 Görüntü kesikleme

Bu işlemde tüm pikseller mevcut değerlerine uygun olarak tanımlanmış yeni bir değer aralığına göre tekrar tanımlanır. Böylece örneğin (0, 255) aralığında tanımlı görüntü (0-63) gibi daha düşük bir aralıkta tanımlı bir görüntüye indirgenmiş olacaktır. Bu işlem için arama tablosu (lookup table) ya da haritalama fonksiyonları kullanmak mümkündür. Fonksiyonların genel formu Eşitlik 4.12'deki gibidir.

$$Q(i,j) = M(P(i,j)) = \begin{cases} \frac{T_1}{2} & \textbf{eğer } 0 \le r < T_1 \ ise \\ \frac{T_1 + T_2}{2} & \textbf{eğer } T_1 \le r < T_2 \ ise \\ \frac{T_2 + T_3}{2} & \textbf{eğer } T_2 \le r < T_3 \ ise \\ \vdots & \vdots \\ \frac{T_{n-1} + T_n}{2} & \textbf{eğer } T_{n-1} \le r < T_n \ ise \end{cases} \tag{4.12}$$

Burada T eşik değerini r ise giriş görüntüsündeki eşiklemeye tabi tutulan piksel değerini ifade etmektedir.

4.4.4 Görüntü parlaklığının ayarlanması

Pikselin parlaklık değeri, tanımlandığı aralıktaki maksimum değere ne kadar yakın olduğu manasına gelir. Örneğin gri seviye görüntülerde en parlak piksel 255 değerini, en koyu piksel ise 0 değerini alacaktır. Görüntünün genel olarak parlaklık seviyesini arttırmak için her bir pikselin belirlenen bir katsayı ile toplanması, parlaklığı azaltmak için ise çıkartılması işlemi yeterli olacaktır (Gonzalez ve Woods 2006).

4.4.5 Görüntünün karşıtlık değerinin ayarlanması

Görüntünün karşıtlık değeri görüntüdeki en önemli parametrelerden biridir. Görüntünün karşıtlığı yani karşıtlık değeri üstündeki çalışmalar görüntü içerisindeki verinin anlamlı ya da anlamsız olmasına etki edecektir. En basit karşıtlık ayarlama işlemi görüntünün bir sabit değerle çarpılmasıdır (Gonzalez ve Woods 2006).

$$Q(i,\ j) = P_1(i,\ j) \times C \tag{4.13}$$

Burada C > 0 seçildiğinde karşıtlık artar ve C < 0 seçildiğinde karşıtlık azalır. Daha gelişmiş algoritmalar sayesinde karşıtlık ayarlaması hem verinin daha manalı hale gelmesi hem de görünürlüğün artması sağlanabilir (Gonzalez ve Woods 2006). İlerleyen bölümlerde bu konuda daha detaylı bilgi verilecektir.

4.4.6 Görüntünün negatifi

Görüntünün negatifini oluşturma işlemi o görüntünün her bir pikselinin tümleyenini alarak yeni bir görüntü oluşturma işlemidir. Görüntünün tanım aralığındaki maksimum değeri *L* ile ifade edersek negatifi alınan görüntü orijinal görüntünün her bir pikselinin *L* değerinden çıkarılmasıyla elde edilir. Örneğin gri seviye görüntüler için *L= 255'*dir (Gonzalez ve Woods 2006).

$$Q(i,\ j) = L - P_1(i,\ j) \tag{4.14}$$

4.4.7 Konvolüsyon

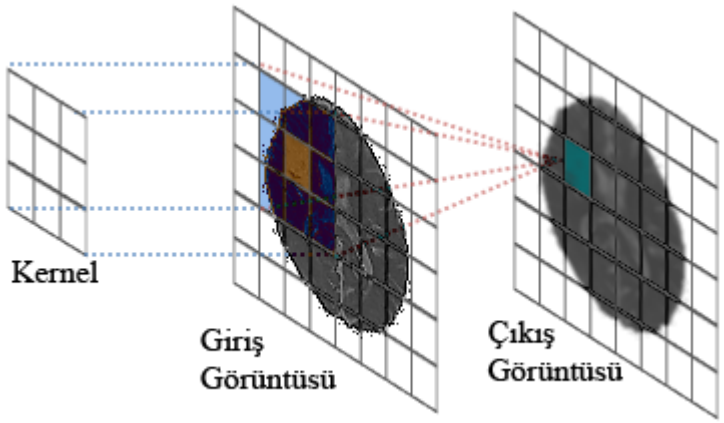
Şimdiye kadar anlatılan işlemler piksellerin üstünde teker teker yapılan işlemlerdir. Oysa pikseller tek başına bilgi taşıdıkları gibi, çevrelerindeki diğer piksellerin bilgilerinden de etkilenmektedirler. Böylece görüntü üstündeki her pikselin diğer piksellerle bir ilişki içerisinde olduğunu söylemek mümkündür. Dolayısıyla bazı algoritmaların bu ilişkiye dayalı

olarak çalışması gerekmektedir. İşte bu amaçla matematikte ve sinyal işleme problemlerinde sıkça kullanılan konvolüsyon işlemi görüntü işlemede de yer bulmuştur (Gonzalez ve Woods 2006).

Temel olarak konvolüsyonu iki matrisin üst üste katlanarak birleştirilip aralarındaki ilişkiyi ifade etmek şeklinde tanımlayabiliriz. Görüntü işleme uygulamalarında ise bu işlem giriş görüntüsünün bir çekirdek matris ile ne kadar uyumlu olduğunu gösteren bir çıkış görüntüsü üretmek şeklinde olur. Konvolüsyon işlemi, filtrelemede, kenarların bulunmasında veya özel şekil ya da dokuların görüntüde aranmasında kullanılırlar (Seul ve ark 2000). Konvolüsyon matematiksel olarak Eşitlik 4.15 eşitliğinde gösterildiği gibidir (Gonzalez ve Woods 2006);

$$Q(i,j) = \frac{1}{mn}\sum_{k=0}^{m}\sum_{l=0}^{n} K(k,l)P(i-k, j-l) \tag{4.15}$$

Burada, Q çıkış görüntüsü, P giriş görüntüsü ve K maske veya çekirdek (kernel) matrisidir. Çekirdek matrisi $m \times n$ boyutludur. Şekil 4.4'de görüntü üzerindeki bir piksel için konvolüsyon işlemi görülmektedir (Seul ve ark 2000).



Şekil 4.4 İki boyutlu Konvolüsyon işlemi

4.5 Geometrik İşlemler

Bazı görüntü işleme uygulamalarında, üstünde çalışılan görüntünün döndürülmesi, çevrilmesi, yansıtılması gibi işlemlere ihtiyaç duyulur. Bu işlemler geometrik işlemler olarak adlandırılır. Geometrik operatörler giriş görüntüsünün (x_1,y_1) konumundaki her bir piksel değeri çıkış görüntüsünde (x_2,y_2) piksel konumuna haritalar. Haritalama fonksiyonunun genel ifadesi Eşitlik 4.16'daki gibi ifade edilebilir (Gonzalez ve ark 2004).

$$(x_2, y_2) = T\{(x_1, y_1)\} \tag{4.16}$$

Eşitlik 4.16'daki T ifadesi dönüşüm matrisini ifade eder ve matrisin elemanları dönüşüm işleminin türüne göre değişir (Gonzalez ve ark 2004).

4.5.1 Geometrik ölçekleme

Üstünde çalışılan görüntünün boyutlarının büyütülmesi veya küçültülmesi için geometrik bir dönüşüm kullanılır. Bu dönüşüm sırasında dikkat edilmesi gereken önemli nokta görüntü boyutu değiştiğinde örnekleme özellikleri de değişeceğinden yeni oluşturulan görüntüde piksel değerlerinin yeniden hesaplanması için bazı yaklaşımlar kullanılması gerektiğidir. Örneğin küçültme sırasında bir grup pikselin yerine seçilen grubu temsil edecek bir piksel hesaplanması veya komşuluk ilişkilerine dayalı bir enterpolasyon işlemi yapılması gerekir. Görüntü büyütülmesi (zumlama) işleminde ise yeni oluşturulacak görüntünün eksik kalan pikselleri, ya piksel tekrarı ya da interpolasyon ile hesaplanır. Görüntünün geometrik ölçeklemesinde kullanılan T matrisi Eşitlik 4.17'deki gibidir (Gonzalez ve Woods 2006):

$$T = \begin{pmatrix} c_x & 0 & 0 \\ 0 & c_y & 0 \\ 0 & 0 & 1 \end{pmatrix} \tag{4.17}$$

4.5.2 Döndürme

Döndürme işlemi, giriş görüntüsündeki (x_1,y_1) piksel pozisyonundaki değerin yeni oluşturulan görüntüde, 0 orijini etrafında belirli bir açı kadar döndürerek, (x_2,y_2) pozisyonunda tekrar tanımlama işlemidir. Döndürme esnasında meydana gelen taşmalar ya ihmal edilir ya da giriş görüntüsü tüm pikselleri kapsayabilecek şekilde genişletilir. Döndürme operatörü sayesinde örneğin beyin MRG görüntülerinin çekimi sırasında olan kayma giderilerek daha başarılı analiz sonuçları elde etmek mümkündür Döndürme operatörünün matris formu Eşitlik 4.18'deki gibidir (Gonzalez ve Woods 2006):

$$T = \begin{pmatrix} \cos\theta & \sin\theta & 0 \\ -\sin\theta & \cos\theta & 0 \\ 0 & 0 & 1 \end{pmatrix} \tag{4.18}$$

burada θ döndürme açısıdır.

4.5.3 Eğme

Eğme işleminde giriş görüntüsündeki pikseller görüntüde eğilmiş şekilde gösterilerek çıkış görüntüsü oluşturulur, örnek olarak görüntüye perspektif etkisi verme veya normal yazıyı italik hale getirme, verilebilir. Görüntünün eğilmesi dikeyde ve yatayda istenilen oranda gerçekleştirilebilir. Dikey eğme işlemi için operatörün matris formu Eşitlik 4.19'daki gibidir (Gonzalez ve Woods 2006).

$$T = \begin{pmatrix} 1 & 0 & 0 \\ s_v & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \tag{4.19}$$

Yatay eğme operatörü ise Eşitlik 4.20'deki gibidir.

$$T = \begin{pmatrix} 1 & s_h & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \tag{4.20}$$

4.5.4 Öteleme

Öteleme işleminde giriş görüntüsü istenilen bir miktarda yatay ve/veya dikey yönde kaydırılarak çıkış görüntüsü elde edilir. Burada amaç görüntüdeki piksellerin yerini değiştirirken açısını ve değerlerini korumaktır. Örneğin iki resmin üst üste bindirilmesinde veya yan yana gösterilmesinde kullanılır. Yeni oluşturulan görüntüde taşma olması durumunda ya görüntü büyütülür ya da taşan pikseller ihmal edilir. Aynı durumda eğer boşluklar oluşursa genelde bu boşluklar siyah piksellerle doldurulur. Operatörün matris formu Eşitlik 4.21'deki gibidir.

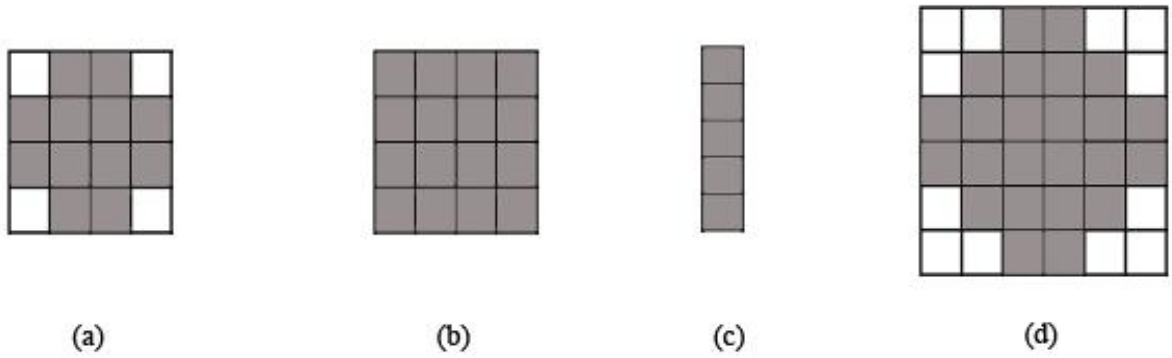
$$T = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ t_x & t_y & 1 \end{pmatrix} \tag{4.21}$$

4.6 Morfolojik Görüntü İşleme

Morfolojik görüntü işlemede amaç görüntü üstündeki şekillerin tanınması ve gösterimidir. Morfolojik görüntü işlemede matematikteki küme teorisini kullanarak analiz işlemleri yapılır. İşlemler gri seviye görüntülerde yapılabilse de genelde ikili görüntüler üstünde işlem yapılması tercih edilir (Gonzalez ve Woods 2006).

4.6.1 Yapısal eleman

Morfolojik görüntü işlemenin en önemli nesnesi, yapısal eleman adı verilen bir matristir. Yapısal eleman içerisinde her bir pikselin nasıl etkileneceği, kesişim veya birleşim gibi işlemlerin hangi kümeye göre yapılacağı tanımlanır. Böylece piksel morfolojik işleme tabii tutulduğunda yeni oluşacak görüntü bu yapısal elemana bağlı olarak oluşur. Şekil 4.5'de bazı yapısal eleman örnekleri verilmiştir; Artı (a), kare (b), çizgi (c), elmas(d) şeklinde yapısal elemanlar.



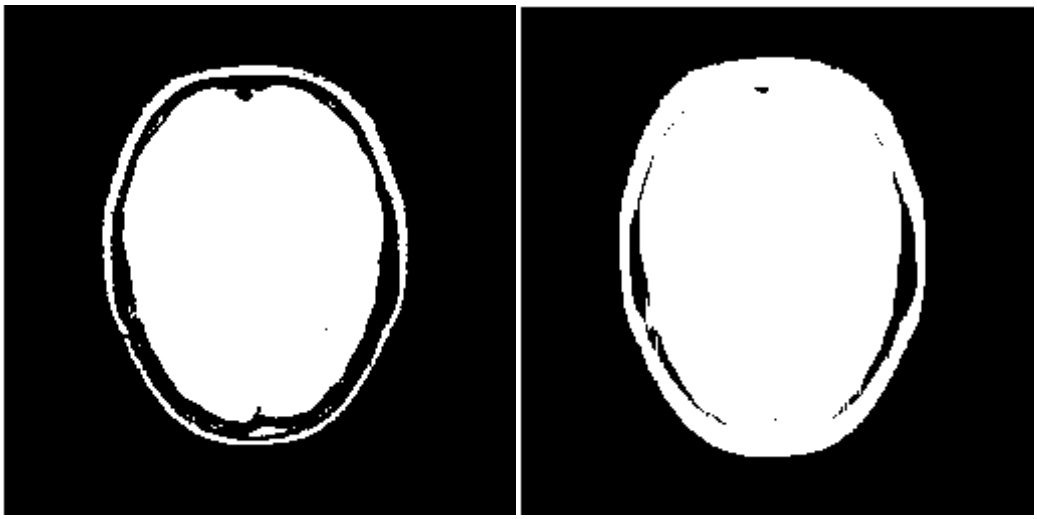
Şekil 4.5 Yapısal elemanlar (a) artı, (b) kare, (c) çizgi, (d) elmas

4.6.2 Genişleme

Genişleme işlemi görüntüdeki nesnenin büyütülmesi ya da kalınlaştırılması için kullanılır. İşlem sırasında kullanıcı tarafından belirlenmiş olan yapısal elemanın ortasına denk gelecek şekilde görüntüdeki her bir piksel işleme sokulur ve genişleme işlemi yapılır. Genişleme, yapısal elemanın şekline göre gerçekleşir. Genişleme işlemi sayesinde görüntü içindeki nesnelerin delik ve boşluklarının dolması, köşelerin yumuşaması mümkündür (Serra 1983, Gonzalez ve Woods 2006). Genişleme işlemi Eşitlik 4.22 ve Eşitlik 4.23'deki gibi ifade edilir. MIDAS veri tabanından alınmış aksiyel kesitli ikili formda MRG beyin görüntüsü Şekil 4.6 (a)'da ve aynı görüntünün genişleme işleminden sonraki hali Şekil 4.6 (b)'de gösterilmiştir.

$$A \oplus B = \left\{ z \in Z^2 \mid z = a + b, a \in A \text{ ve } b \in B \right\} \tag{4.22}$$

$$A \oplus B = \bigcup_{b \in B} (A)_b \tag{4.23}$$



(a) (b)

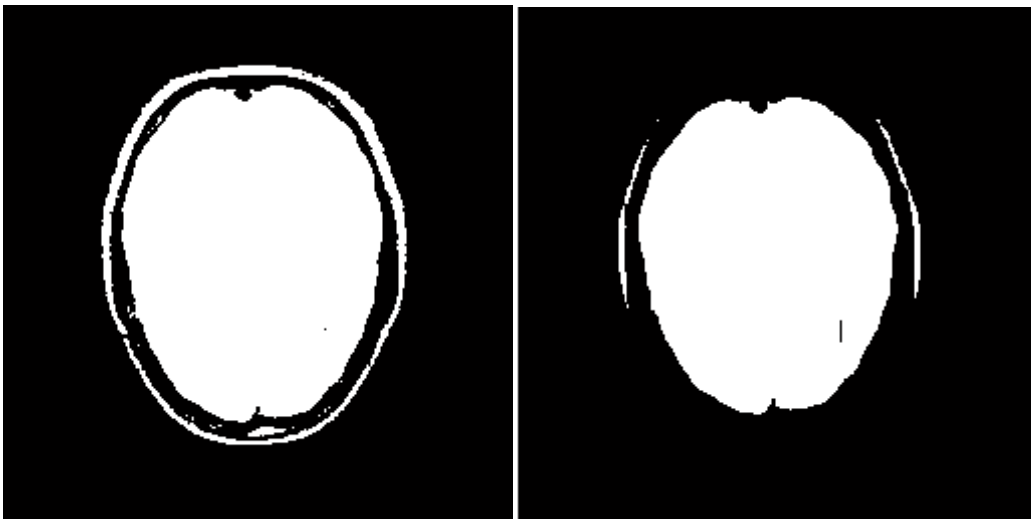
Şekil 4.6 MIDAS veri tabanından alınmış (a) aksiyel kesitli ikili formda MRG beyin görüntüsü (b) aynı görüntünün genişleme işleminden sonraki hali

4.6.3 Aşınma işlemi

Aşınma işlemi genişleme işlemiyle aynı prensiplere dayalı olarak çalışır ancak burada işlem sırasında yapısal elemanın birleşim kümesi değil kesişim kümesi ile sonuç görüntüsü elde edilir. Böylece görüntüdeki nesne küçülür, incelir, delikler genişler veya bitişik olan nesneler ayrılır. Aşınma işlemi Eşitlik 4.24 ve Eşitlik 4.25'deki gibi ifade edilir. MIDAS veri tabanından alınmış aksiyel kesitli ikili formda MRG beyin görüntüsü Şekil 4.7 (a)'da ve aynı görüntünün genişleme işleminden sonraki hali Şekil 4.7 (b)'de gösterilmiştir.

$$A\Theta B = \{z \mid z + b \in A, \forall b \in B\} \tag{4.24}$$

$$A\Theta B = \bigcap_{b \in B} (A)_{-b} \tag{4.25}$$



(a) (b)

Şekil 4.7 (a) MIDAS veri tabanından alınmış aksiyel kesitli ikili formda MRG beyin görüntüsü (b) aynı görüntünün genişleme işleminden sonraki hali

4.6.4 Açma işlemi

Açma işlemi üzerinde çalışılan görüntüye önce aşınma ardından genleşme işlemi uygulanarak gerçekleştirilir. Böylece görüntüdeki küçük fazlalık ve nesneler yok olurken boşluklar temizlenmiş olur. Seçilen yapısal elemanın şekline göre nesnelerin şekillerinde küçük bozulmalar veya küçülmeler meydana gelebilir. Açma işlemi Eşitlik 4.26'daki gibidir (Gonzalez ve Woods 2006).

$$A \circ B = (A \Theta B) \oplus B \tag{4.26}$$

4.6.5 Kapama işlemi

Kapama işlemi üzerinde çalışılan görüntüye önce genişleme ardından aşındırma işlemi uygulanarak gerçekleştirilir. Böylece birbirinden ayrı duran nesneler veya kopukluklar birleştirilmiş olur, görüntüdeki nesnelerin ana hatları belirginleşir. Açma işlemi Eşitlik 4.27'deki gibidir (Gonzalez ve Woods 2006).

$$A \bullet B = (A \oplus B) \Theta B \tag{4.27}$$

4.7 Süzme

Görüntü işlemedeki en işlevsel uygulamalardan biri filtreleme teknikleridir. Filtreleme teknikleri sayesinde görüntü üstünde bulanıklaştırma, keskinleştirme, alçak ya da yüksek frekans bileşenlerini bastırma, kenarları bulma ya da belirginleştirme gibi pekçok işlem gerçekleştirilebilir. Filtreleme işlemi hem uzaysal zeminde hem de frekans zemininde gerçekleştirilebilir. Filtreleme işleminde genellikle bir filtre matrisi işlenecek görüntü ile konvolüsyon işlemine sokulur, filtre matrisinin yapısına göre sonuç görüntüsü elde edilir (Seul ve ark 2000).

4.7.1 Ortalama süzgeç

Ortalama süzgeç $m \times m$ boyutlu bir alandaki piksel değerlerinin ortalamasını alıp ortada bulunan piksele yeni değer olarak atar. Bu süzgeç sayesinde yüksek frekanslı bileşenler bastırılır, yani alçak geçiren süzgeç olarak da ifade edilebilir. Süzgeçte kullanılan konvolüsyon çekirdeği Eşitlik 4.28'deki gibidir (Yılmaz 2005).

$$K = \begin{pmatrix} \frac{1}{9} & \frac{1}{9} & \frac{1}{9} \\ \frac{1}{9} & \frac{1}{9} & \frac{1}{9} \\ \frac{1}{9} & \frac{1}{9} & \frac{1}{9} \end{pmatrix} \tag{4.28}$$

4.7.2 Ortanca süzgeç

Ortanca (median) süzgeç de yine alçak geçiren süzgeç sınıfındadır. Filtrede $m \times m$ boyutlu bir alan içerisinde kalan tüm piksel değerleri küçükten büyüğe (veya tersi şekilde) sıralanır ortadaki değer alınarak çıkış görüntüsündeki piksel değeri olarak atanır. Ortanca süzgeç için herhangi bir konvolüsyon işlemi tanımlı değildir (Yılmaz 2005).

4.7.3 Gaussian süzgeç

Alçak geçiren filtre kategorisindeki bu süzgeç Gaussian fonksiyonundan faydalanır. Direkt olarak fonksiyon kullanılabildiği gibi aynı zamanda yine Gauss fonksiyonuyla elde edilen konvolüsyon çekirdeği kullanılarak da gerçekleştirilebilir. Gaussian fonksiyonu Eşitlik 4.29'daki gibidir (Yılmaz 2005).

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \tag{4.29}$$

Gaussian süzgeci sayesinde görüntü içindeki pikseller arasındaki keskin geçişler yumuşatılır. İki boyutlu Gaussian fonksiyonu kullanılarak elde edilen konvolüsyon çekirdeği Eşitlik 4.30'daki gibidir.

$$K = \begin{pmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{pmatrix} \tag{4.30}$$

4.7.4 Laplacian süzgeçler

Laplacian işlemi matematiksel olarak ikinci türevin alınması manasına gelir. Yüksek geçiren süzgeç tipinde bir süzgeçtir matematiksel formülü 4.31'deki gibidir. Konvolusyon çekirdeği yapısında birçok çeşidi bulunabilir, kullanıcıya ve uygulamaya bağlı olarak uygun olan tercih edilir. Örnek olarak Eşitlik 4.32'deki çekirdek verilebilir (Yılmaz 2005).

$$L = \frac{\partial^2 P(x, y)}{\partial x \partial y} \tag{4.31}$$

$$K = \begin{pmatrix} -1 & 2 & -1 \\ 2 & -4 & 2 \\ -1 & 2 & -1 \end{pmatrix} \tag{4.32}$$

4.7.5 Frekans zemininde süzgeçler

Süzgeç işlemlerinin hem uzaysal hem de frekans zeminlerinde uygulanması mümkündür. Filtrelerin frekans zemininde uygulanabilmesi için öncelikle görüntüye Fourier dönüşümü uygulanır, ardından süzme işlemi uygulanır ardından ters Fourier dönüşümü ile uzaysal zemine geri dönülür (Yılmaz 2005, Gonzalez ve Woods 2006).

Süzme işleminde yüksek frekanslar azaltılarak daha yumuşak bir görüntü elde edilebilir. Düşük frekansların azaltılması ise görüntüdeki kenarların belirginleşmesine sebep olacaktır. İşlemler frekans zemininde gerçekleştiği için ve bu zeminde çarpma ile uzaysal zemindeki konvülüsyon işlemi birbirlerinin özdeşi olduklarından işlem Eşitlik 5.33'deki gibi ifade edilebilir (Yılmaz 2005, Gonzalez ve Woods 2006).

$$G(k,l) = F(k,l)H(k,l) \tag{4.33}$$

Burada F(k,l) Fourier dönüşümü sonrası elde edilen giriş görüntüsü, H(k,l) ise süzgeç fonksiyonu ve G(k,l) ise filtre edilen çıkış görüntüsüdür. Uzaysal zemine dönüş için ise G(k,l)'ye ters Fourier dönüşümü uygulanır (Yılmaz 2005).

Frekans zeminindeki süzgeç fonksiyonları da temel olarak üç tiptedir. Bunlar; alçak geçiren (lowpass), yüksek geçiren (highpass) ve bant geçiren (bandpass) süzgeçlerdir (Yılmaz 2005).

4.8 Görüntü Bölütleme

Bölütleme ya da ayıklama (segmentasyon) işlemi incelenen görüntünün içindeki parçaların arka plandan veya diğer nesnelerden ayrılması işlemidir. Görüntüdeki nesnenin tespiti için nesnenin görüntü içerisindeki diğer parçalarından ayırt edilebilir bir özelliğinin olması ve bunun nesnenin tümü için geçerli olması gerekir (Pratt 1991, Gonzalez ve Woods 2006).

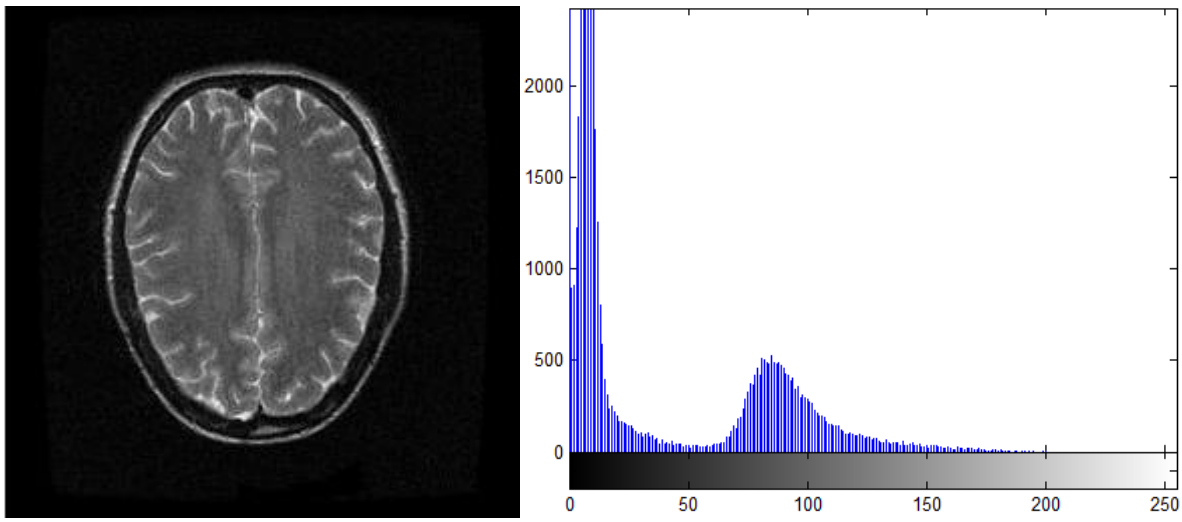
Örneğin görüntüdeki parlaklığı göz önüne alıp bir eşikleme işlemi yaparak aranan nesne için bir maske oluşturmak mümkündür. Yine de sadece parlaklık değerine dayalı bir nesne tanımlama işlemi yeterli olmayacaktır, bu yüzden renklerde veya desenlerde olan farklılıkları analiz eden daha kompleks algoritmalar kullanılmaktadır. Renk farklılıklarına dayalı bölütlemede, renk uzayları arasındaki dönüşümlerden faydalanılır. Desen tespitine yönelik bölütlemelerde ise daha karmaşık algoritmalar gerekebilir. Örneğin FFT, Wavelet gibi dönüşümler ya da istatistiki analiz gibi (Seul ve ark 2000). Bu tez çalışmasında beyinin, beyindeki bölgelerin ve MS plaklarının tespiti de yine böyle algoritmalar kullanılarak gerçekleştirilmiştir.

4.9 Görüntü Güçlendirme

Görüntü işleme sürecinde, eşikleme, bölütleme analiz gibi çeşitli işlem adımları takip edilmekltedir. Bu analizlerin kalitesinin artması için, örneğin bir nesnenin daha belirgin hale gelmesi için, görüntü güçlendirme algoritmalarından faydalanılır. Görüntü güçlendirme algoritmaları sayesinde gürültü bastırma, keskinleştirme, karşıtlık ayarlama gibi işlemler gerçekleştirilir. Biyomedikal görüntülerinde güçlendirme işlemi özellikle arka plan parlaklığı ayarlamak ve görüntüdeki nesnelerin sınırlarını belirginleştirmek amacıyla kullanılır (Quintanilla-Dominguez ve ark 2010). Literatürde birçok görüntü güçlendirme algoritması vardır ve sürekli olarak yenileri geliştirilmektedir.

4.9.1 Histogram eşitleme (histogram equalization)

Görüntü elde edilirken, gerek ortam gerekse görüntüyü sayısallaştıran aygıtlar yüzünden görüntü tanım aralığının dar bir bölgesini kullanacak şekilde sayısallaştırılmış olabilir. Örneğin 0-255 aralığında tanımlı gri seviyeli görüntü tanımlanırken maksimum değeri 126 olacak şekilde sayısallaştırılmış olabilir. Görüntünün histogramı incelendiğinde bu durum görülebilir. Şekil 4.8 (a)'da aksiyel kesitte elde edilmiş beyin görüntüsü ve Şekil 4.8 (b)'de aynı görüntünün histogramını göstermektedir.



(a) (b)

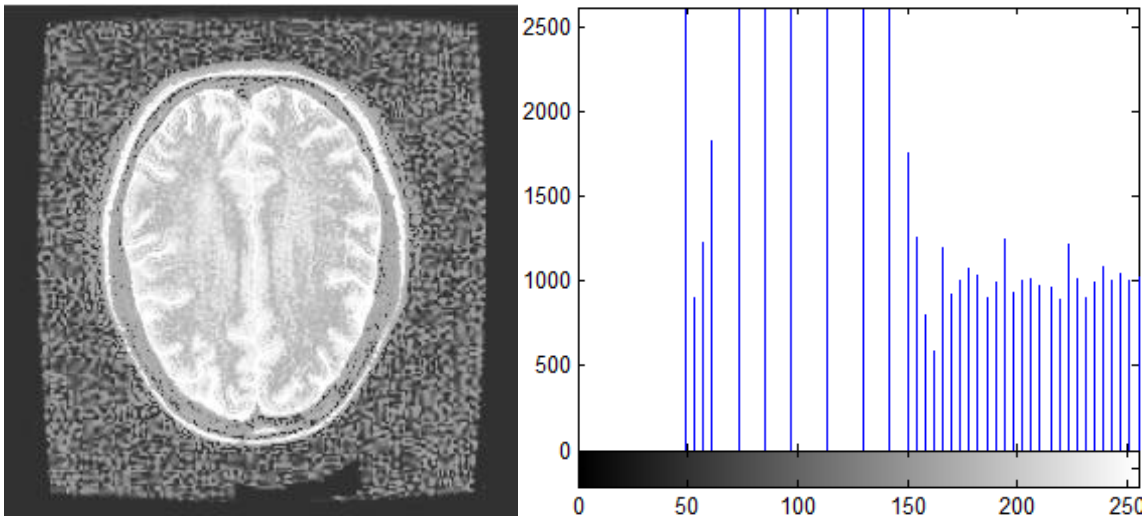
Şekil 4.8 Aksiyal kesitte elde edilmiş beyin görüntüsü (a) görüntü,
(b) aynı görüntünün histogramı

Görüntünün detaylarının belirginleşmesi ve 0 ile 255 aralığına dağıtılması için histogram eşitleme işlemi uygulanabilir. Histogram eşitleme işlemi her bir piksele Eşitlik4.34 ve 4.35'deki işlemler uygulanarak gerçekleştirilir (Pratt 1991, Gonzalez ve Woods 2006).

$$p_n = \frac{yoğunluk \quad değerindeki \quad piksel \quad sayısı}{toplam \quad piksel \quad sayısı} \qquad \boldsymbol{n = 0, 1, ..., L - 1.} \tag{4.34}$$

$$g(i,j) = floor((L-1)\sum_{n=0}^{f(i,j)} p_n) \tag{4.35}$$

Şekil 4.8 (a)'daki görüntüye histogram eşitleme işlemi uygulandıktan sonra elde edilen görüntü Şekil 4.9 (a)'da ve histogramı Şekil 4.9 (b)'de gösterilmiştir.



(a) (b)

Şekil 4.9 Aksiyal kesitte elde edilmiş beyin görüntüsünün (a) histogram eşitleme işleminden sonraki hali (b) aynı görüntünün histogramı

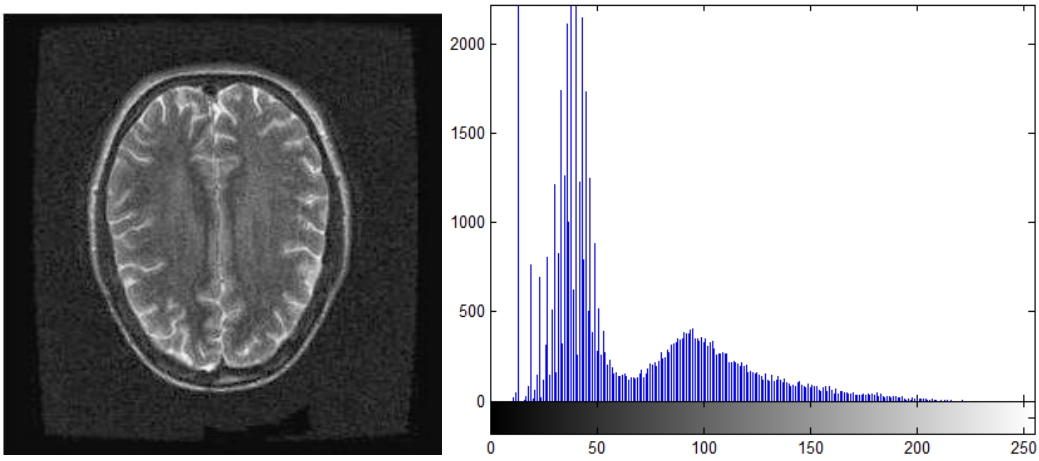
4.9.2 Kontrast sınırlı adaptif histogram eşitleme (CLAHE)

Görüntüdeki pikseller bulundukları bölgeden etkilenmektedirler, örneğin Şekil 4.8'de beyin bölgesi içinde yer alan bir piksel ya da arka plan bölgesinde yer alan piksel, komşusu olduğu diğer piksellere yakın değerlere sahiptir. Dolayısıyla her ikisine de aynı oranda güçlendirme işlemi uygulamak Şekil 4.9'da görüldüğü gibi istenmeye sonuçlar doğurabilir. Özellikle gürültü sinyali Şekil 4.9'da görüldüğü gibi aşırı güçlenmiştir.

Bu gibi sorunların üstesinden gelmek için adaptif histogram eşitleme tekniği geliştirilmiştir. İşlem yapılırken, fonksiyon tüm piksellere genel uygulanması yerine ilgilenilen pikselin bulunduğu bölge sabitlenerek, pikselin yerel histogramı pencerelenen bölgenin merkezindeki pikselle atanır. Böylece sadece yerel alan içindeki pikseller değerlendirilmeye alınmış olur. Algoritma, Eşitlik 4.36'da gösterildiği gibidir.

$$g = [g_{\max} - g_{\min}]\, p(f) + g_{\min} \tag{4.36}$$

Burada g_{max} maksimum piksel değeri, g_{min} minimum piksel değeri, g hesaplanan piksel değeridir. $p(f)$ ise kümülatif olasılık dağılım fonksiyonudur (Yılmaz 2005). Şekil 4.10'da, Şekil 4.8'deki görüntünün adaptif histogram eşitleme işleminden sonraki hali (a) ve aynı görüntünün histogramı (b) gösterilmiştir. Burada olasılık dağılım fonksiyonu Rayleigh fonksiyonudur.



(a) (b)

Şekil 4.10 Aksiyal kesitte elde edilmiş beyin görüntüsünün (a) adaptif histogram eşitleme işleminden sonraki hali (b) aynı görüntünün histogramı

Bu tez çalışmasında, görüntü güçlendirme amacıyla, Doğrusal Harmanlama İle Kontrast Güçlendirme Algoritması (Contrast Enhancement Using Linear Image Combinations Algorithm (CEULICA)) (Yilmaz ve Ozbay 2014) geliştirilmiştir.

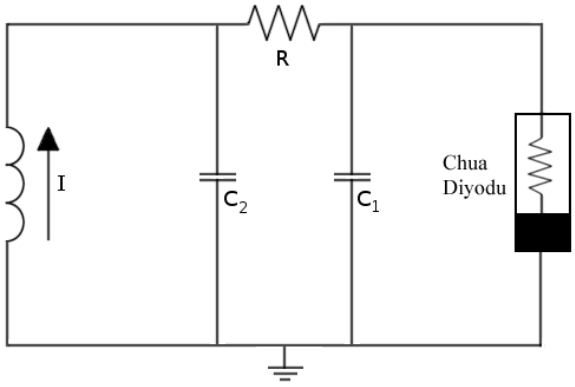
5 HÜCRESEL YAPAY SİNİR AĞLARI

Biyomedikal görüntülerin içerdiği bilgilerin doğrusal olmaması, görüntü işleme tekniklerinin bazı durumlarda daha gelişmiş işlemler içermesini ya da çok hassas parametre düzenlemeleri yapılmasını gerektirmektedir. Her görüntü işleme probleminin kendine has işlem ve süreçlere ihtiyacı olmasından dolayı, görüntü işleme problemini çözecek yöntemin eğitilebilir ve olabildiğince geniş bir kullanım esnekliğine sahip olması istenen bir durumdur. Bu çalışmada, bahsedilen esnek kullanım yeteneklerine ve gelişmiş görüntü işleme özelliklerine sahip Hücresel Yapay Sinir Ağları (HYSA) tercih edilmiştir.

HYSA'nın en dikkat çekici özelliği, tek bir algoritmanın, sadece parametre değişiklikleri ile neredeyse her görüntü işleme görevini yerine getirebilir olmasıdır. Bu bölümde, HYSA'nın genel özellikleri, parametre tespiti ile eğitimi ve gelişmiş bir modeli olan Çoklu Kararlı Hücresel Yapay Sinir Ağı (ÇK-HYSA) anlatılacaktır.

5.1 Hücresel Yapay Sinir Ağı Modeli

HYSA modeli Chua tarafından bulunan, nonlineer, kaotik devre modelini temel olarak almaktadır (Chua ve Yang 1988, 1988, Chua 1989). Devre genel olarak bir osilatör devresi yapısında olmasına rağmen, içerisinde barındırdığı özel bir eleman olan Chua Diyotu sayesinde, kaotik davranış gösterebilmektedir. Şekil 5.1'de Chua devresi gösterilmiştir (http://www.chuacircuits.com/ 2015).



Şekil 5.1 Chua Devresi

Devre genel olarak Eşitlik 5.1, 5.2 ve 5.3 ile ifade edilen diferansiyel eşitlik takımı ile modellenebilir:

$$\dot{x} = \propto (y - x - g(x)) \tag{5.1}$$

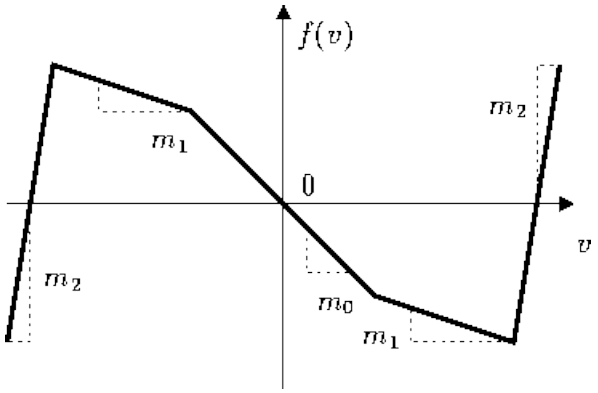
$$\dot{y} = x - y + z \tag{5.2}$$

$$\dot{z} = -\beta y \tag{5.3}$$

Bu eşitliklere Chua eşitlikleri adı verilir, eşitlikler sırasıyla C_1ve C_2 kapasitörleri ile L bobinindeki gerilim değişimini göstermektedir. Burada α ve β devre elemanlarına göre değişen parametrelerdir. Eşitlik 5.1'deki g(x), akıma göre Chua diyotunun değişen gerilimini temsil eden parçalı lineer eşitlik olup şu şekilde ifade edilir:

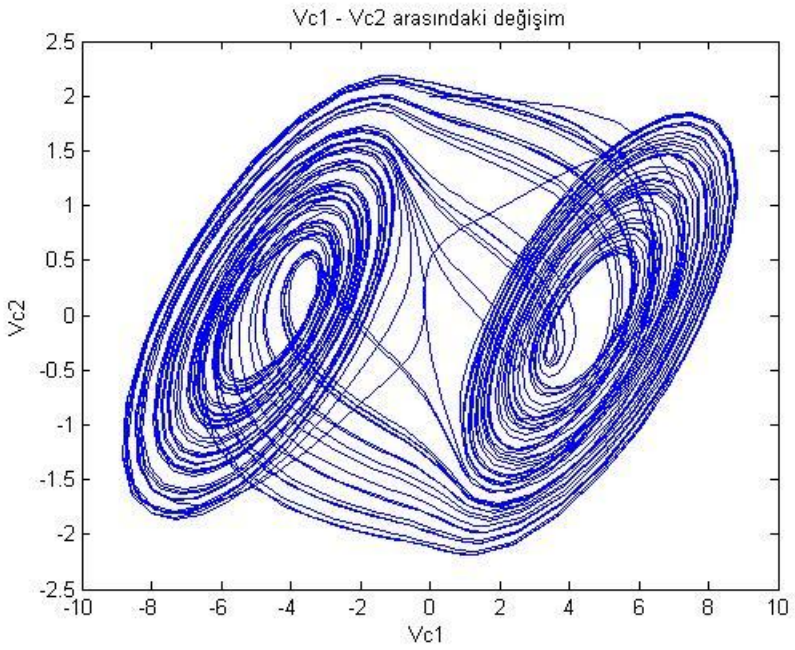
$$g(x) = \begin{cases} m_0 x + m_0 - m_1, & | x \leq -1 \\ m_1 x, & | -1 \leq x \leq 1 \\ m_0 x + m_1 - m_0 & | 1 \leq x \end{cases} \tag{5.4}$$

Burada m_0, m_1 ve m_2 diyotun akım - direnç fonksiyonundaki eğimleri temsil etmektedir. Şekil 5.2'de Chua Diyotunun Akım-Direnç grafiği gösterilmiştir (http://www.chuacircuits.com/ 2015).



Şekil 5.2 Chua diyotunun akım - direnç grafiği

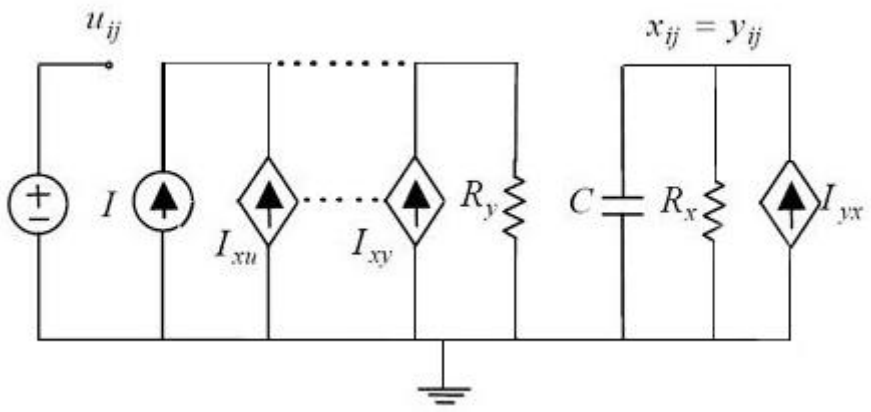
Devre başlangıç şartlarına ve diyotun akım - direnç karakteristiğine göre, sönümlü, doyumlu veya kaotik osilasyonlu davranış şekilleri gösterebilir. Devrenin kaotik osilasyon durumunda kapasitörler arasındaki gerilim ilişkisi Şekil 5.3'de gösterilmiştir:



Şekil 5.3 Chua devresinin kaotik osilasyon durumunda kapasitörler arasındaki gerilim ilişkisi

Chua devresinin davranışının akıma bağlı bir diyot ile belirlenebiliyor olması, devrenin çok önemli bir yeteneğe sahip olmasına yol açmaktadır. Devre; istenen şartlar sağlandığında osilasyona girebilir, istenen şartlar sağlanmadığında sönümlü davranışa veya doyuma gidebilir. Bu da devrenin özel durumların tespiti için kullanılabilecek bir yapıda olduğunu göstermektedir. İşte HYSA modeli, bu devreyi temel alan geliştirilmiş bir sinir ağı modelidir (Chua 1989).

HYSA modeli her biri Chua devresi olacak şekilde tasarlanmış ve aralarındaki ilişki tanımlanmış hücrelerden oluşur. Burada hücrelerin her birinin özelliği, akıma bağlı olan Chua diyotunun sadece hücrenin kendi akımı ile değil, komşuluk ilişkisi içerisinde bulunduğu diğer hücrelerden gelen akım bilgisine de bağımlı olmasıdır. Modeldeki her bir hücrenin eşdeğer devresi Şekil 5.4'deki gibi gösterilebilir (Chua 1989).



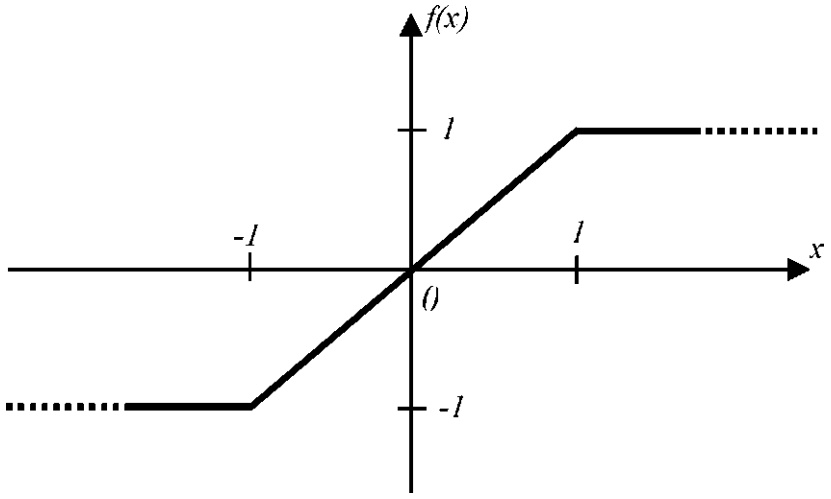
Şekil 5.4 HYSA hücresinin eşdeğer devresi

Hücresel yapay sinir ağının herhangi bir *C(i,j)* hücresine karşılık gelen bu devrede *u* giriş, x durum ve *y* çıkışa karşılık gelmektedir. Bu *C(i,j)* hücresine ait v_{xij} durum geriliminin başlangıç koşulu ile giriş gerilimi olan v_{uij} 'nin 1 den küçük veya eşit olduğu kabul edilmiştir. v_{yij} ise çıkış gerilimidir (Chua 1989).

C(i,j) hücresi E_{ij} gerilim kaynağı, I akım kaynağı, C kapasite, R_x ve R_y dirençleri, giriş kontrol gerilimi v_{ukl} ile çıkış kontrol gerilimi v_{ykl} tarafından geri besleme olarak kontrol edilen lineer gerilim kontrollü akım kaynaklarından meydana geldiği görülür.

Burada $I_{xy}(i,j;k,l)$ ve $I_{xu}(i,j;k,l)$ gerilim kontrollü akım kaynaklarının karakteristikleri $C(k,l) \in N_r(i,j)$ komşuluğu altında $I_{xy}(i,j;k,l)=A(i,j;k,l)v_{ykl}$ ve $I_{xu}(i,j;k,l)=B(i,j;k,l)v_{uki}$ olarak ifade edilirler (Chua ve Yang 1988, Chua 1989).

Her hücre içerisindeki tek lineer olmayan eleman parça-parça lineer $I_{yx}=(1/R_y)f(v_{xij})$ karakteristiğine sahip olan gerilim kontrollü akım kaynağıdır. *f(.)* fonksiyonu Şekil 5.5'de gösterilmiştir.



Şekil 5.5 Herhangi bir *C(i,j)* hücresinin parça-parça doğrusal çıkış karakteristiği

Kirchoff gerilimler ve akımlar yasaları uygulanarak bu hücresel devrenin eşitliği aşağıda gösterildiği gibi ifade edilebilir (Chua ve Yang 1988, Chua 1989)

Durum eşitliği Eşitlik 5.5'deki gibidir:

$$C\frac{dv_{xij}(t)}{dt} = -\frac{1}{R_x}v_{xij}(t) + \sum_{C(k,l)\in N_r(i,j)} A(i,j;k,l)v_{ykl}(t) + B(i,j;k,l)v_{ukl}(t) + I \qquad (5.5)$$

Çıkış eşitliği Eşitlik 5.6'daki gibidir:

$$v_{yij}(t) = \frac{1}{2}(|v_{xij}(t)+1| - |v_{xij}(t)-1|) \qquad 1 \le i \le M; 1 \le j \le N \qquad (5.6)$$

Giriş eşitliği Eşitlik 5.7'deki gibidir:

$$v_{uij}(t) = E_{ij}\ , \qquad 1 \le i \le M; 1 \le j \le N \qquad (5.7)$$

Kısıtlama durumları Eşitlik 5.8 ve 5.9'daki gibidir:

$$|v_{xij}(0)| \le 1\ , \qquad 1 \le i \le M; 1 \le j \le N \qquad (5.8)$$

$$|v_{uij}| \le 1 \qquad 1 \le i \le M; 1 \le j \le N \qquad (5.9)$$

Parametrik kabuller Eşitlik 5.10 ve 5.11'deki gibidir:

$$A(i, j; k, l) = A(k, l; i, j), \qquad 1 \le i \le M; 1 \le j \le N \tag{5.10}$$

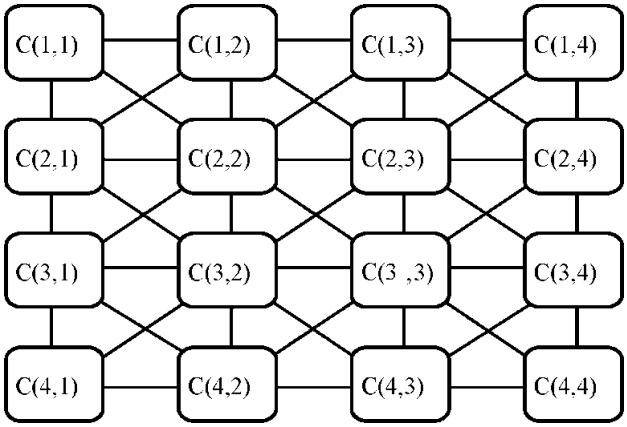
$$C > 0, R_x > 0. \tag{5.11}$$

Bir hücresel yapay sinir ağındaki tüm hücreler aynı devre yapısı ve değerlerine sahiptirler. Bir merkezi hücre, tanımlanan *r* komşuluğunda $(2r+1)^2$ kadar komşu hücreye sahip olan hücredir. Bunun dışında kalan hücreler ise sınır hücreleridir. Bu şekilde tanımlanan hücresel yapay sinir ağ yapıları doğrusal olmayan bir eşitlik takımı ile karakterize edilirler. Hücresel yapay sinir ağındaki bir hücrenin dinamiklerini çıkış geri beslemesinin etkisini belirleyen $A(i, j; k, l)$ parametresi ile girişin kontrol etkisini belirleyen $B(i, j; k, l)$ parametreleri oluşturur (Chua ve Yang 1988, Chua 1989).

Bu ifadeleri özetleyecek olursak; HYSA modeli, hücrelerin komşuluk ilişkilerine bağlı olarak çıkış fonksiyonu davranışını değiştirebilme yeteneğine sahiptir. Her bir hücrenin diğer hücreye olan etkisi eğitim yöntemleri ile belirlenebilir. Bu özellik sayesinde görüntü işleme uygulamalarında her bir piksele denk gelecek bir hücre tanımlayarak ve hücreler arası ilişkileri belirleyerek kullanılması mümkündür. Ayrıca yine verilerin doğru bir şekilde yerleştirilmesi ile sınıflandırma, eksik veri tamamlama, veri setindeki yanlış verilerin düzeltilmesi gibi pek çok işlemde kullanılması mümkündür.

5.2 HYSA Mimarisi

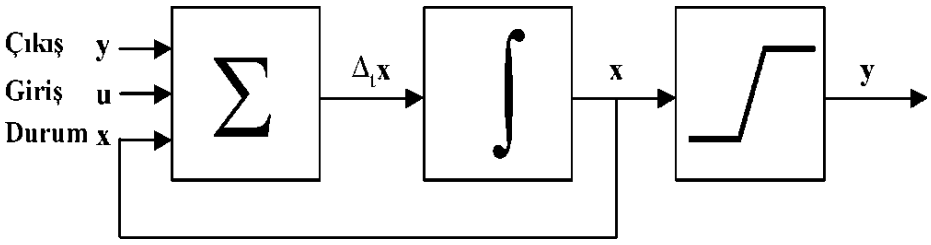
HYSA'nın, komşuluk ilişkileri tanımlanmış olan hücrelerden meydana geldiği daha önce belirtilmişti. Şekil 5.6'da 4x4 boyutunda bir HYSA gösterilmektedir (Chua 1989). M×N boyutundaki bir HYSA içerisindeki her bir hücreyi tanımlamak için i. satır ve j. sütun indisleri kullanılır ve hücreler C (i, j) ile gösterilir (Chua 1989).



Şekil 5.6 4×4 Boyutunda bir hücresel yapay sinir ağı gösterimi

HYSA'lar girişine uygulanan veriyi, tanımlanmış olan hücreler arası ilişki modeline göre sınıflandırarak bir çıkış verisi elde eder. Çıkışta elde edilen veri -1 veya +1 olacak şekilde sınırlandırılır. HYSA eğer görüntü işleme amacıyla kullanılıyorsa girişe uygulanan görüntü renkli, gri seviyeli veya bit eşlenik resim gibi çeşitli formatlarda olabilir. Burada en hassas nokta giriş verisinin -1 ve +1 aralığında tanımlanmış olmasıdır. Sistem parametreleri doğru tanımlanmışsa, veri analizi sonrasında kararlı duruma ulaşıp istenen görevi yerine getirecektir.

HYSA'nın hücre yapısını bir blok diyagramı olarak gösterecek olursak, her bir hücreyi, ağırlıklı toplama yapan doğrusal bir giriş birimi, doğrusal dinamik bir ara birim ve n parçalı (genellikle üç parçalı) orijine göre simetrik bir çıkış birimi olmak üzere dinamik bir devre şeklinde ifade etmek mümkündür. Şekil 5.7'de bir hücrenin dinamik yapısı gösterilmiştir (Uçan ve ark 2006).



Şekil 5.7 Bir hücrenin dinamik yapısı

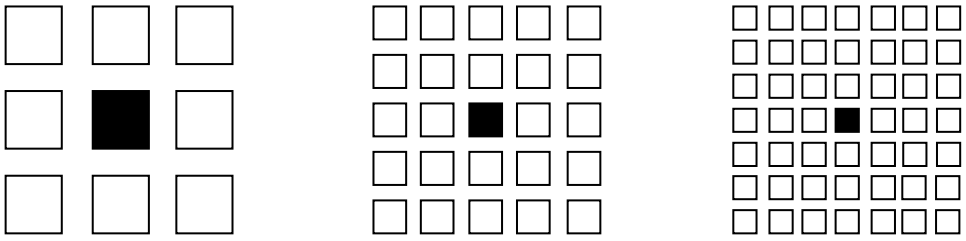
HYSA'ların çok boyutlu olarak tanımlanarak kullanılması mümkündür, bu tez çalışmasında görüntü temelli işlemler yapıldığı için iki boyutlu olarak kullanılacaklardır.

5.3 Hücreler Arasındaki Komşuluk İlişkisi

Her bir HYSA hücresi, diğer hücreler ile belli bir komşuluk ilişkisi ile bağlanmıştır. *M* satır ve *N* sütundan oluşan bir *MxN* 'lik hücresel yapay sinir ağı için herhangi bir *C(i,j)* hücresinin r komşuluğu Eşitlik 5.12'deki gibi tanımlanır (Chua ve Yang 1988)

$$N_r(i,j) = \left\{ C(k,l) \middle| \max(|i-k|,|j-l|) \le r, \quad 1 \le i \le M; 1 \le j \le N \right\} \tag{5.12}$$

Burada r, pozitif bir tamsayıdır, her bir hücrenin kendisinden ne kadar uzaklıktaki hücreler tarafından doğrudan etkileneceğine işaret eder. Şekil 5.8.'de görüleceği gibi r=1 komşuluğunda her bir hücre sadece çevresindeki hücrelerle etkileşim içindeyken, r=2 ve r=3 komşuluklarında hücreler kendilerinden iki ve üç hücre uzaklıklarındaki hücrelerle de ilişki içerisindedir (Chua 1989, Chua ve Roska 2002).



r=1 *r=2* *r=3*

(a) (b) (c)

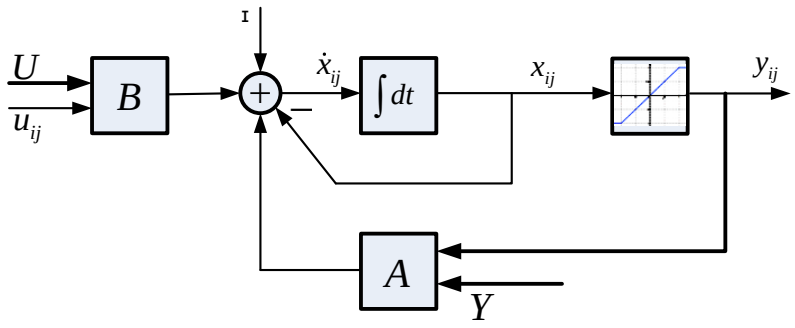
Şekil 5.8 Hücresel yapay sinir ağlarında (HYSA) (a) *r=1,* (b) *r=2,* (c) *r=3* komşuluğu için hücre ilişkileri

Şekil 7.7'de de görüldüğü gibi; genellikle r = 1, r = 2 ve r = 3 komşuluklarına sırasıyla 3×3, 5×5 ve 7×7 komşulukları da denir. Bir r komşuluğu içerisinde (2r+1) x (2r+1) tane hücre bulunur. Komşuluk, eğer özel bir işlem durumu söz konusu değilse simetri özelliğine de sahiptir. Bu durum Eşitlik 5.13'le ifade edilir.

$$C(i,j) \in Nr(k,l) \text{ ise } \qquad C(k,l) \in Nr(i,j) \tag{5.13}$$

5.4 HYSA'larda Konvolüsyon İşlemi

HYSA'lar sayısal ortamda kullanıldığında ayrık zamanlı işlemler içereceği için fark eşitlikleri ve konvolüsyon işlemleri ile ifade edilebilir. Bu yüzden sistemi ayrık zamanlı olarak ifade ettiğimizde, sistem Şekil 5.9'daki gibi düzenlenebilir. Bu modelde girişin diğer hücrelerle olan ilişkisini belirleyen B matrisi, diğer hücrelerden gelen bilgilerin ilişkilerini belirleyen A geri besleme matrisi ve sabit olarak etki eden "I" bias değeri sistem tanımına dâhil olmaktadır.



Şekil 5.9 Ayrık zamanda HYSA hücresinin modeli

Bu parametrelerden $A(i,j;k,l)$ Geri Besleme Ağırlık Katsayı Matrisi, $B(i,j;k,l)$ Giriş Ağırlık Katsayı Matrisi olarak da adlandırılır. Örneğin (r=1) komşuluk için A ve B parametrelerinin matris formu Eşitlik 5.14'deki gibi ifade edilebilirler;

$$A=\begin{pmatrix} A_{-1,-1} & A_{-1,0} & A_{-1,1} \\ A_{0,-1} & A_{0,0} & A_{0,1} \\ A_{1,-1} & A_{1,0} & A_{1,1} \end{pmatrix} \qquad B=\begin{pmatrix} B_{-1,-1} & B_{-1,0} & B_{-1,1} \\ B_{0,-1} & B_{0,0} & B_{0,1} \\ B_{1,-1} & B_{1,0} & B_{1,1} \end{pmatrix} \tag{5.14}$$

Eşitlik 5.14'deki matris formundan şu tanımlamalar yapılabilir;

$$A_{-1,-1} = A_{1,1} = a_1,\ A_{-1,0} = A_{1,0} = a_2,\ A_{-1,1} = A_{1,-1} = a_3,\ A_{0,1} = A_{0,-1} = a_4,\ A_{0,0} = a_5 \tag{5.15}$$

$$B_{-1,-1} = B_{1,1} = b_1,\ B_{-1,0} = B_{1,0} = b_2,\ B_{-1,1} = B_{1,-1} = b_3,\ B_{0,1} = B_{0,-1} = b_4,\ B_{0,0} = b_5 \tag{5.16}$$

A ve B matrislerini yeniden düzenlersek, Eşitlik 5.17'deki simetrik matrisler elde edilir:

$$A=\begin{pmatrix} a_1 & a_2 & a_3 \\ a_4 & a_5 & a_4 \\ a_3 & a_2 & a_1 \end{pmatrix} \qquad B=\begin{pmatrix} b_1 & b_2 & b_3 \\ b_4 & b_5 & b_4 \\ b_3 & b_2 & b_1 \end{pmatrix} \tag{5.17}$$

Eğer özel bir durum söz konusu değilse A ve B matrisleri kararlı durumu sağlamak için simetrik seçilir.

Konvolüsyon işlemi sayesinde çıkış, geri beslemenin etkisini belirleyen A ve giriş kontrol etkisini belirleyen B sayesinde tüm hücrelere etki etmiş olacaktır. Ayrık zamanlı hücresel yapay sinir ağını ifade eden formülde **A** ve **y** arasındaki ilişki ile **B** ve **u** arasındaki ilişki aynı olup iki boyutlu bir konvolüsyon ilişkisidir ve Eşitlik 5.18 ve 5.19'daki gibi ifade edilir. Burada, konvolüsyon " $\otimes$ " ile gösterilecektir.

$$x_{ij}(n+1) = \sum_{(k,l)\in N_r(i,j)} A_{i,j;k,l} \cdot y_{k,l}(n) + \sum_{(k,l)\in N_r(i,j)} B_{i,j;k,l} \cdot u_{k,l}(n) + I_{i,j} \tag{5.18}$$

$$x(n+1) = A \otimes y(n) + B \otimes u(n) + I \tag{5.19}$$

Buna göre Eşitlik 5.20'deki gibi yeniden düzenlenirse;

$$x_{ij}(n+1) = \sum_{k\in N_r(i,j)} \sum_{l\in N_r(i,j)} \hat{A}_{i,j} \cdot y_{i-k,j-l}(n) + \sum_{k\in N_r(i,j)} \sum_{l\in N_r(i,j)} \hat{B}_{i,j} \cdot u_{i-k,j-l}(n) + I \tag{5.20}$$

Burada konvolüsyon toplamının yazılabilmesi için; HYSA'nın uygulanacağı görüntülerin sınır değerleri tamamen sıfır olarak seçilmelidir. Ayrıca $\hat{A}$ ve $\hat{B}$ değerlerinin $\hat{A}_{i,j} = A_{-i,-j}$ ve $\hat{B}_{i,j} = B_{-i,-j}$ şeklinde olması gereklidir. Sınır değerlerinin bu etkisine göre yeniden yazılacak olursa Eşitlik 5.21 elde edilir.

$$x_{ij}(n+1) = \sum_{k\in N_r(i,j)} \sum_{l\in N_r(i,j)} \hat{A}_{-i,-j} \cdot y_{i-k,j-l}(n) + \sum_{k\in N_r(i,j)} \sum_{l\in N_r(i,j)} \hat{B}_{-i,-j} \cdot u_{i-k,j-l} + I \tag{5.21}$$

5.5 Hücresel yapay sinir ağlarında kararlılık

Hücresel yapay sinir ağlarının çıkışlarının geçici rejimden sonra sabit kararlı çıkış değerlerine ulaşması durumuna kararlılık adı verilir. Daha önce de belirtildiği gibi HYSA hücreleri kaotik osilasyona girebilen Chua devrelerinden oluşmuştur dolayısıyla hücrelerarasındaki etkileri belirleyen şablon parametreleri doğru seçilmezse HYSA'nın kaotik

osilasyona girme durumu söz konusudur (Chua ve Roska 2002). HYSA'nın kararlılık durumunu Eşitlik 5.22'deki gibi ve ya geçici rejim sonrasında durum görüntüsünün sabit bir değere ulaşması durumunu göz önüne alarak, Eşitlik 5.23'deki gibi ifade edebiliriz (Manganaro ve ark 2012).

$$\lim_{x\to\infty} v_{xij}(t) = sabit\,,\ 1 < i < M;1 < j < N \tag{5.22}$$

$$\lim_{x\to\infty} \frac{dv_{xij}(t)}{dt} = 0\,,\ 1 < \mathrm{i} < \mathrm{M};1 < \mathrm{j} < \mathrm{N} \tag{5.23}$$

Bu konuda yapılan çalışmalara göre; A geri besleme matrisinin simetrik olması ve aksi ispat edilemediği için devre parametrelerinin $A(i,j;i,j) > \frac{1}{R_x}$ koşulunu sağlaması durumunda Eşitlik 5.24'deki veya eşdeğeri olan Eşitlik 5.25'deki koşulları sağlanmış olur.

$$\lim_{x\to\infty} \left| v_{xij}(t) \geq 1 \right|,\ 1 < \mathrm{i} < \mathrm{M};1 < \mathrm{j} < \mathrm{N}. \tag{5.24}$$

$$\lim_{x\to\infty} v_{yij}(t) = \pm 1,\ 1 < \mathrm{i} < \mathrm{M};1 < \mathrm{j} < \mathrm{N}. \tag{5.25}$$

Bu da HYSA'nın osilasyon durumuna girmeyeceğini göstermesi açısından oldukça önem taşımaktadır. Bu durum hücresel sinir ağının çıkışlarının sadece ikili değerlerden oluşacağını garanti etmektedir.

5.6 Hücresel yapay sinir ağlarının sürekli zaman analizi

Hücresel yapay sinir ağlarının sürekli zamanda integral formundaki ifadesini tekrar yazarsak Eşitlik 5.26 elde edilir (Chua 1989, Chua ve Roska 2002).

$$v_{xij}(t) = v_{xij}(0) + \frac{1}{C}\int_0^t \left[-\frac{1}{R_x} v_{xij}(\tau) + f_{ij}(\tau) + g_{ij}(u) + I \right] d\tau\,,\ 1 < \mathrm{i} < \mathrm{M};1 < \mathrm{j} < \mathrm{N} \tag{5.26}$$

Burada, yeniden düzenleme yapılarak Eşitlik 5.27 ve 5.28 elde edilir.

$$f_{ij}(t) = \sum_{C(k,l)\in N_r(i,j)} A(i,j;k,l) v_{ykl}(t) \tag{5.27}$$

$$g_{ij}(u) = \sum_{C(k,l)\in N_r(i,j)} B(i,j;k,l) v_{ukl}(t) \tag{5.28}$$

Eşitlik 5.28'de $vx_{ij}(t)$ görüntünün herhangi bir t anındaki durumunu temsil etmektedir. Bu durum başlangıç koşulu olarak verilen görüntü v_{xij} (0) ve hücresel yapay sinir ağının

dinamik kurallarına bağlıdır. Dolayısıyla bu eşitliklerden hücresel yapay sinir ağları, bir başlangıç görüntüsünün herhangi bir *t* anındaki dinamik dönüşümünü elde etmek için kullanılabilir sonucu çıkarılabilir. Burada $t \to \infty$ ulaştığında durum değişkeni tam kararlı durumda v_{xij} bir sabite ve çıkış v_{yij} ise +1 ve-1 değerlerinden herhangi birisine gitmektedir. Kararlılık koşullarının sağlanmaması durumunda ise osilasyon ve kaotik durumları ortaya çıkmaktadır (Chua 1989, Chua ve Roska 2002).

5.7 HYSA'da Eğitim

HYSA'nın eğitimi, örüntü tanıma görevinde kullanılacak olan geri besleme (A), kontrol (B) şablonları ile eşik değerlerinin (I) hesaplanması demektir. Bu işleme şablon bulma adı verilir. Şablon bulma, tecrübeye dayalı tahminlerden, çok gelişmiş algoritmalara kadar pek çok şekilde gerçekleştirilebilir. Bu amaçla faydalanılan algoritmalardan birisi Güzeliş ve Karamahmut tarafından geliştirilen "Dinamik Ardışıl Algılayıcı Öğrenme Algoritması" (Recurrent Perceptron Learning Algorithm) (Guzelis ve Karamahmut 1994) ve bu tez çalışmasında kullanılan Karaboğa ve arkadaşları tarafından geliştirilen yapay arı koloni algoritması (ABC) (Karaboga ve ark 2012) bunlara örnek olarak verilebilir.

5.7.1 RPLA öğrenme algoritması

RPLA algoritması, özellikle kararlı bir HYSA modeli oluşturacak şablonlarının belirlenmesi için geliştirilmiş gözetimli bir öğrenme algoritmasıdır. Algoritma temel olarak Perceptron Öğrenme Algoritmasına benzer. Algoritma şu adımları takip ederek koşturulur:

1. Adım: Başlangıç koşulları için **w**(0) başlangıç ağırlık vektörüne bir değer atanır.

2. Adım: Her bir adımda, verilen başlangıç durum **(x)** vektörü ve başlangıç giriş **(u)** vektörü ile o anki bağlantı ağırlık vektörleri **w**(n) için kalıcı durum çıkışları (y) hesaplanır.

3. Adım: Bir sonraki bağlantı ağırlık vektörleri hesaplanırken $w(n+1) = \left[w(n) - \varepsilon(n) \cdot \gamma \left[w(n) \right]^{+} \right]$ tanımlaması kabul edilerek bağlantı ağırlık katsayıları güncellenir.

4. Adım: İstenen çıkış ve elde edilen HYSA çıkışları arasında hesaplanan hata istenen seviyeye gelinceye kadar n'yi 1 arttırarak 2. adımdan sonraki adımlar tekrar edilir.

RPLA algoritması ile eğitim işlemine geçmeden önce HYSA'yı tanımlayan şablonlarda bazı düzenlemelerin yapılması ve eğitim işlemine uygun hale getirilmesi gerekmektedir. Örneğin 3x3 boyutundaki bağlantı ağırlık katsayıları şablonu için düşünürsek Eşitlik 5.29'da gösterildiği gibi şablon matrisleri ifade edilebilir.

$$A=\begin{pmatrix} A_{-1,-1} & A_{-1,0} & A_{-1,1} \\ A_{0,-1} & A_{0,0} & A_{0,1} \\ A_{1,-1} & A_{1,0} & A_{1,1} \end{pmatrix} \qquad B=\begin{pmatrix} B_{-1,-1} & B_{-1,0} & B_{-1,1} \\ B_{0,-1} & B_{0,0} & B_{0,1} \\ B_{1,-1} & B_{1,0} & B_{1,1} \end{pmatrix} \tag{5.29}$$

A ve B şablonları simetrik olma kuralına uyacaksa Eşitlik 5.30 ve 5.31'deki gibi ifade edilebilir:

$$A_{-1,-1} = A_{1,1}= a_1,\ A_{-1,0} = A_{1,0} = a_2,\ A_{-1,1} = A_{1,-1} = a_3,\ A_{0,1} = A_{0,-1} = a_4,\ A_{0,0}=a_5 \tag{5.30}$$

$$B_{-1,-1} = B_{1,1} = b_1,\ B_{-1,0} = B_{1,0} = b_2,\ B_{-1,1} = B_{1,-1} = b_3,\ B_{0,1} = B_{0,-1} = b_4,\ B_{0,0}=b_5 \tag{5.31}$$

A ve B matrislerini Eşitlik 5.32'deki gibi yeniden düzenlersek (Cerasa ve ark 2012) :

$$A=\begin{pmatrix} a_1 & a_2 & a_3 \\ a_4 & a_5 & a_4 \\ a_3 & a_2 & a_1 \end{pmatrix} \qquad B=\begin{pmatrix} b_1 & b_2 & b_3 \\ b_4 & b_5 & b_4 \\ b_3 & b_2 & b_1 \end{pmatrix} \tag{5.32}$$

Şablonlara bir de I eşik seviyesini ekledikten sonra, uygun değerleri bulmak için, tüm şablonları tek bir vektöre indirgeyerek Eşitlik 5.33'deki gibi tanımlamak mümkündür (Cerasa ve ark 2012):

$$w \cong \left[a^T b^T I \right]^T \cong \left[a_1 a_2 a_3 a_4 a_5 b_1 b_2 b_3 b_4 b_5 I \right]^T \tag{5.33}$$

Perceptron öğrenme algoritmasının aksine bu algoritmada hata fonksiyonunun türevi kullanılmaz, giriş ise iki kısımdan oluşur. Bunlar, HYSA giriş değerleri ve başlangıç durum değerleridir. Giriş vektörü $v_u = \left[..., u_{i,j}, ... \right]^T \in R^m$ ve başlangıç durum vektörü $v_x = \left[..., x_{i,j}(0), ... \right]^T \in R^m$ olmak üzere, sistemin giriş vektörü $v = \left[v_u{}^T v_x{}^T \right]^T \in R^m$ olarak tanımlanabilir. Hücresel yapay sinir ağı bu giriş vektöründen **w** ağırlık katsayı değerlerini

kullanarak $v_x = \left[..., y_{i,j}(t), ...\right]^T \in R^m$ çıkış vektörünü üretecektir. Burada HYSA giriş vektör uzayıyla çıkış vektör uzayı arasında bir cebirsel dönüşüm tanımlar.

Algoritmanın gözetimli yani eğiticili bir öğrenme algoritması olmasından dolayı, bir de eğitim sonuçlarının uygunluğunu test etmek için istenen çıkış değerlerini içeren bir d vektörü de tanımlanmalıdır:

$$d = P(v) : \left\{(v_1, d_1), (v_2, d_2), ...(v_n, d_n)\right\} \tag{5.34}$$

Gözetimli eğitim algoritmaları, çıkış ve istenen çıkış değerleri arasındaki farkı ölçmek için hatayı ifade eden eşitlik ya da eşitliklere ihtiyaç duymaktadır. Bu yüzden $\varepsilon[w]$ ile ifade edilen bir hata fonksiyonu bu algoritmada kullanılır. Hata fonksiyonu Eşitlik 5.35'deki gibi tanımlanabilir:

$$\varepsilon[w] \cong \sum_{s=1}^{N} \varepsilon^s[w] = \sum_s \sum_{i,l} \left(y^s{}_{i,l}(\infty) - d^s{}_{i,l}\right)^2 \tag{5.35}$$

Burada istenen çıkış ile $y_{i,j}(\infty)$ olarak gösterilen gerçek çıkış (kararlı durum çıkışı) arasındaki farkın ölçüsüdür. v_s ve d_s eğitim setlerinden s. örneğe ait giriş ve istenen çıkış çiftlerine karşılık gelmektedir. Amaç, bu hata fonksiyonunu minimize edecek olan w ağırlık katsayılarının elde edilmesidir.

Hata fonksiyonunun ifadesi incelenirse problemi, kısıtlamalı bir optimizasyon problemi şeklinde ele almak mümkündür. Buna göre $\varepsilon[w]$'daki sabit terimler ihmal edilip yeniden düzenlenirse Eşitlik 5.36 elde edilir.

$$\varepsilon[w] \cong \sum_{i,l} (y^s{}_{i,l}(\infty) \cdot (y^s{}_{i,l}(\infty) - d^s{}_{i,l}) = \sum_{(i,j,s)\in D^+} y^s{}_{i,l}(\infty) - \sum_{(i,j,s)\in D^-} y^s{}_{i,l}(\infty) \tag{5.36}$$

Hata fonksiyonu 5.36'daki Eşitlik haline gelir. Bu Eşitlik RPLA algoritmasının oluşturulmasını daha anlaşılır kılmaktadır. Çıkışların +1 ve -1 değerlerini alabildiği göz önünde bulundurularak, bu Eşitlikte iki ayrı bölgede sonuç elde edilebildiğini söyleyebiliriz. Bu bölgeler $D^+ \cong \left\{(i,j,s) \middle| y^s{}_{i,l}(\infty) = -d^s{}_{i,j} = 1\right\}$ ve $D^- \cong \left\{(i,j,s) \middle| y^s{}_{i,l}(\infty) = -d^s{}_{i,j} = -1\right\}$

şeklindedir. Yani buradaki D^+ ve D^- bölgeleri gerçek çıkışlar ile istenen çıkışlar arasındaki uyuşmanın ölçütünün birer karşılığıdır.

HYSA çıkışındaki fonksiyonun parça parça doğrusal olmasından dolayı türevlenebilir bir fonksiyon değildir dolayısıyla hata fonksiyonunda düşüm (gradient) yöntemleri kullanılamaz.

RPLA yöntemi ile eğitime uygun hale getirmek için HYSA tanım Eşitliklerini hatayı da içerecek şekilde tekrar ifade edersek:

$$x_{i,j} = -S \cdot x_{i,j} + \sum_{(k,l)\in(-1,0,1)} A_{k,l} \cdot y_{(i+k),(j+l)} + \sum_{(k,l)\in(-1,0,1)} B_{k,l} \cdot u_{(i+k),(j+l)} + I \tag{5.37}$$

$$y_{i,j}(t) = \frac{1}{2}\left(\left|x_{i,j}+1\right| - \left|x_{i,j}-1\right|\right) \tag{5.38}$$

$S \cdot x_{i,j}$ ifadesi eşitliğin sol tarafına alınıp yeniden yazılırsa,

$$S \cdot x_{i,j}(\infty) = w \cong \sum_{(k,l)\in(-1,0,1)} A_{k,l} \cdot y_{(i+k),(j+l)}(\infty) + \sum_{(k,l)\in(-1,0,1)} B_{k,l} \cdot u_{(i+k),(j+l)} + I \tag{5.39}$$

elde edilir. Burada $Ys_{i,j}C(i,j)$ $Ys_{i,j}C(i,j)$ $Ys_{i,j}C(i,j)$ hücresini süren toplam giriş olarak ifade edilebilir ve şu şekilde gösterilir.

$$Ys_{i,j} = \left[\left[y^s{}_{i,j}\right]^T \left[u^s{}_{i,j}\right]^T I\right]^T \tag{5.40}$$

A ve B matrislerinin tam simetrik oldukları için $y^s{}_{i,j}$ ve $u^s{}_{i,j}$ matrisleri Eşitlik 5.41 ve 5.42'deki şekilde tanımlanabilirler:

$$y^s{}_{i,j} \cong \left[y^s{}_{i-1,j-1}(\infty) + y^s{}_{i+1,j+1}(\infty) y^s{}_{i-1,j}(\infty) + y^s{}_{i+1,j}(\infty) y^s{}_{i-1,j+1}(\infty) + y^s{}_{i+1,j-1}(\infty) y^s{}_{i,j-1}(\infty) + y^s{}_{i,j+1}(\infty) y^s{}_{i,j}(\infty)\right]^T \tag{5.41}$$

$$u^s{}_{i,j} \cong \left[u^s{}_{i-1,j-1} + u^s{}_{i+1,j+1} u^s{}_{i-1,j} + u^s{}_{i+1,j} u^s{}_{i-1,j+1} + u^s{}_{i+1,j-1} u^s{}_{i,j-1} + u^s{}_{i,j+1} u^s{}_{i,j}\right] \tag{5.42}$$

Burada $Y^s{}_{i,j}$ vektörünün ilk beş teriminin geri besleme ağırlık katsayı matris değerlerinin türevlenebilir bir fonksiyon olmadığına dikkat edilmesi gerekir. Ayrıca **w** ağırlık katsayıları vektörü ile girişlere bağlı olarak istenilen işlevi yerine getirecek birden fazla çözümü olabilir. Eşitliğin denge noktalarındaki bu çözümler seçilen başlangıç durum değerlerine bağlıdır.

Sonuç olarak fark Eşitliği ile ağırlık katsayı vektörü w istenilen değere ulaşıncaya kadar adım adım uyarlanır. Bir sonraki adımdaki ağırlık değerleri ile mevcut adımdaki ağırlıklar arasındaki ilişki Eşitlik 5.43 ve 5.44 ile tanımlanır:

$$w(n+1) = \left[w(n) - \varepsilon(n) \cdot \gamma\left[w(n)\right] \right] \tag{5.43}$$

Burada $\gamma\left[w(n)\right]$ vektörü şu şekilde tanımlanır:

$$\gamma\left[w(n)\right] \cong \left(\sum_{(i,j,s)\in D^{+}} Y^{s}{}_{i,j}(n) - \sum_{(i,j,s)\in D^{-}} Y^{s}{}_{i,j}(n) \right) \tag{5.44}$$

Eşitlik 5.36'da $\varepsilon(n)$ öğrenme hızını belirleyen bir parametredir ve zamana bağlı bir fonksiyon seçilebileceği gibi genellikle zamandan bağımsız çok küçük pozitif bir sayı olarak seçilir.

RPLA başlangıç şartları, çıkışların +1 ve -1 değerlerine yakınsaması için *a5>S* koşulu ile başlatılır. Her adımda $y^{s}{}_{i,j}(\infty)$ kararlı durum vektörü, diferansiyel Eşitlikler giriş vektörü $v^{s}{}_{u}$ ve uyarlanmış bağlantı ağırlık katsayıları vektörü için seçilen başlangıç durum vektörü $v^{s}{}_{x}$ 'e bağlı olarak çözülür. **[w]+, w** bağlantı ağırlık katsayı vektörünün $A = \left\{ w \in R \middle| a_5 > S \right\}$ kümesinin bir elemanı olduğunu gösterir. Bu da kararlı durum çıkışlarının +1 ve -1 değerlerine gideceklerini garanti eder.

$$w(n) \in A \text{ ise } \left[w(n)\right]^{+} = w(n) \text{ ve } w(n) \notin A \text{ ise } \left[w(n)\right]^{+} = K_n \cdot w(n) \tag{5.45}$$

Burada $K_n \cong \mu \cdot \dfrac{A}{a_5(n)}$ olarak ifade edilir. *u*> 1 olan ve genellikle 1.5 olarak seçilen bir sabittir.

5.7.2 Yapay Arı Koloni Algoritması ve HYSA Eğitiminde Kullanımı

Önceki bölümde HYSA'nın eğitimine kısıtlamalı bir optimizasyon problemi şeklinde yaklaşmanın mümkün olduğu ifade edilmişti. Bu durumda HYSA'nın kararlılığını sağlayacak uygun şablon parametrelerinin tespitini bir tanım uzayında optimum sonucu bulma işlemi olarak ele almak mümkündür. RPLA algoritması ile uygun şablonların bulunması işlemine bu açıdan yaklaştığımızda, algoritmanın başlangıç şartlarına göre aynı sonucu verecek farklı şablonlar oluşturabildiği görülmektedir fakat bu durum tanım uzayında uygun değeri arama

işlemi yerel minimumlara takılma tehlikesini de beraber getirmektedir. Bu yüzden parametreleri tanımlayacak uzayda daha geniş arama yeteneklerine sahip algoritmalara ihtiyaç doğmaktadır.

Bu tez çalışmasında Karaboğa ve arkadaşları tarafından geliştirilen Yapay Arı Koloni Algoritması kullanılmıştır (Karaboga ve Akay 2009, Karaboğa 2014). Bu bölümde Algoritmanın genel çalışma mantığı ve HYSA eğitiminde kullanımı anlatılacaktır.

5.7.2.1 Yapay arı koloni algoritması

Yapılan araştırma ve gözlemler sonucunda bal arılarının yiyecek bulma süreçlerinde, sürü zekâsı kavramı ile ifade edilebilecek bazı davranışlar gözlemlenmiştir. Bu davranışlar yiyecek arama, öğrenme, bilgi paylaşımı ve ezberlemedir. Konu ile ilgili detaylı çalışmalardan biri "A Survey: Algorithms Simulating Bee Swarm Intelligence" (Karaboga ve Akay 2009) makalesidir.

Yapılan bu çalışmalara göre bir arı kolonisindeki arılar arasında, merkezi bir yönlendirme birimine ihtiyaç duymadan yapılacak işlere göre bir görev paylaşımı vardır. Yiyecek arama sürecinde temel olarak üç bileşen vardır. Bunlar yiyecek kaynakları, görevli işçi arılar ve görevsiz işçi arılardır. Arılar yiyecek (nektar, polen veya bal olarak adlandırılabilir) bulmak için yiyecek kaynaklarına giderler. Bir yiyecek kaynağının değeri, yoğunluk, yakınlık, erişim kolaylığı birçok etkene bağlıdır. Ayrıca kolaylık açısından kaynağının zenginliği gibi tek bir etken de kullanılabilir (Karaboğa 2014, Akay ve Karaboga 2015).

Arı kolonisinin davranış modelinde, Tereshko'ya göre, arılar arasında bir görev paylaşımı vardır ve bu iş paylaşımı otonom, yani kendi kendine meydana gelen bir mekanizmadır. Görev paylaşımının ve kendi kendine organize olabilme yeteneğinin varlığı sürü zekâsının varlığını göstermektedir. Bu modeldeki temel bileşenler şöyle ifade edilebilir; yiyecek kaynakları, görevli işçi arılar ve görevsiz işçi arılardır. Modeldeki bu bileşenlerin davranışında yiyecek kaynağına yönelme ve yiyecek kaynağını bırakma hareketleri de mevcuttur (Tereshko 2000).

Görevli olan işçi arılar, önceden keşfedilmiş kaynaklardan kovana yiyecek getirilmesinden sorumludurlar ve kaynağın kalitesi, konumu gibi bilgileri kovandaki diğer arılarla paylaşırlar. Görevsiz işçi arılar ise yeni yiyecek kaynaklarını aramaktadırlar.

Yiyecek taşımak dışında görevi belirsiz iki tür arı vardır, bunlar içsel bir dürtüye veya dış bir etmene bağlı olarak gelişigüzel kaynak arayan kaşif arılar ve kovanda bekleyip görevli arıları izleyerek bu arıların paylaştığı bilgiyi kullanarak yeni kaynağa yönelen gözcü arılardır. Bu arıların kovandaki sayısal oranı %5-10 civarındadır (Karaboğa 2014).

Arıların bilgi ve görev paylaşımı özellikleri sürü davranışı olarak nitelendirilebilir. Bu davranış modelindeki en önemli etmen arılar arasındaki bilgi paylaşımıdır. Kaynağın yeri, cinsi ve kalitesi gibi bilgilerin paylaşımı kovandaki dans adı verilen işlemle yapılır. Bilgi paylaşan arı dans hareketiyle kaynağın kovana uzaklığı ve güneşe olan açısını bildirirken aynı zamanda diğer arılar da antenleri aracılığıyla dans eden arıya dokunarak kaynağın tadı ve kokusu hakkında da bilgi alırlar (Karaboğa 2014).

İşte bu arıların sürü davranışını modelleyen algoritma Yapay Arı Koloni Algoritması (Artificial Bee Colony Algorithm (ABC)) olarak adlandırılmıştır (Karaboga ve Akay 2009, Karaboğa 2014). Algoritmada model tanımını kolaylaştırmak için bazı temel kabuller yapılmaktadır. Buna göre: (kaynak sayısı = görevli arı sayısı = işçi arıların sayısı) olarak belirlenmektedir ve nektarı tükenmiş kaynağın görevli arısı kaşif arıya dönüşmektedir. Kaynaklardaki nektar miktarı, kaynaklarla ilgili çözümlerin uygunluğuna ve bu kaynakların yerleri ise optimizasyon problemine ait olası çözümlere karşılık gelmektedir. ABC algoritması en fazla nektara sahip yiyecek kaynağının yerini bulmaya çalışarak uzaydaki çözümlerden problemin minimumunu veya maksimumunu veren çözümü bulmaya çalışmaktadır. ABC algoritmasının temel adımlarını anlatacak sözde kod şu şekildedir (Karaboğa 2014):

Adım 1: Başlangıç yiyecek kaynağı bölgelerinin üretilmesi.

TEKRAR ET {

Adım 2: *Görevli arıların yiyecek kaynağı bölgelerine gönderilmesi.*

Adım 3: *Olasılık değerlerine göre yapılan seçimde kullanılacak olasılık değerlerinin görevli arılardan gelen bilgiye göre hesaplanması.*

Adım 4: *Gözcü arıların olasılık değerine göre yiyecek kaynağı bölgesi seçmeleri.*

Adım 5: *Bırakılacak kaynakların bırakılışı ve kâşif arı üretimi.*

} KADAR (çevrim sayısı=Maksimum çevrim sayısı)

Takip edilen adımların detaylı açıklaması şu şekilde ifade edilebilir:

Adım 1. Başlangıç yiyecek kaynağı bölgelerinin üretilmesi. Arama uzayı, kovan çevresindeki alan olarak varsayılarak, muhtemel çözümlerin bulunduğu yerleri yiyecek kaynağı olarak adlandırılabilir. Bu durumda algoritmanın başlangıç anında yiyecek kaynaklarının rastgele olarak arama uzayına yerleştirilmesi gerekmektedir. Bu işlemi

yaparken Eşitlik 5.46 da gösterildiği gibi, her parametre için alt ve üst sınırlar arasında, rastgele değerler üretilerek gerçekleştirilir. Burada X_{ij}, i=1, …, SN, j=1, …, D, ve $hata_i$ başlangıçta sıfır olarak ayarlanır ve uygunluk değeri hesaplanır. SN (Source Number), yiyecek sayısı ve D (Dimension) ise optimize edilecek parametre sayısıdır (Karaboğa 2014).

$$X_{ij} = X_j^{min} + rand(0,1)(X_j^{maks} - X_j^{min}) \tag{5.46}$$

Adım 2. Görevli arıların yiyecek kaynağı bölgelerine gönderilmesi. Her yiyecek kaynağında görevli bir arı vardır, işçi arı görevli olduğu yiyecek kaynağına komşu olan yeni bir kaynağa yönlenir ve bunun kalitesini inceleyerek eğer daha iyi bir kaynak bulmuşsa hafızaya alır. İşlem i=1 den SN'ye kadar X_i'nin görevli arısı için gerçekleştirilir, Bu işlem için Eşitlik 5.47 kullanılır (Karaboğa 2014).

$$V_{ij} = X_{ij} + \varphi_{ij}(X_{ij} - X_{kj}) \tag{5.47}$$

Burada V_{ij}, X_{ij} 'nin komşuluğundaki yeni bir kaynaktır. φ [-1,1] aralığında rastgele bir değerdir bu sayede komşular arasında arama rastgele yapılabilmektedir (Karaboğa 2014).

Komşuluğun uyması gereken bazı sınırlar söz konusudur, yeni komşu değerinin başlangıçta verilen alt ve üst sınır içerisinde kalması gerekmektedir. Komşuluk sınırlarının aşılması durumunda uyulacak kurallar Eşitlik 5.48'deki gibidir (Karaboğa 2014):

$$V_{ij} = \begin{cases} X_j^{min} & , V_{ij} < X_j^{min} \\ V_{ij} & , X_j^{min} \leq V_{ij} \leq X_j^{max} \\ X_j^{max} & , V_{ij} > X_j^{max} \end{cases} \tag{5.48}$$

Belirtilen kurallara uygun olarak üretilen yeni kaynağın maliyet fonksiyonu ile elde edilen değerini kullanarak, kaynağın uygunluk değeri (fitness) hesaplanır ve incelenen kaynaklar arasında en iyisi seçilir. Eğer uygunluk değerine göre bir gelişme olmamışsa $hata_i$ bir birim arttırılır. Eşitlik 5.49, bu uygunluk değerini ifade etmektedir (Karaboğa 2014).

$$Uygunluk = \begin{cases} \frac{1}{(1+f_i)} & , f_i \geq 0 \\ 1 + abs(f_i) & , f_i < 0 \end{cases} \tag{5.49}$$

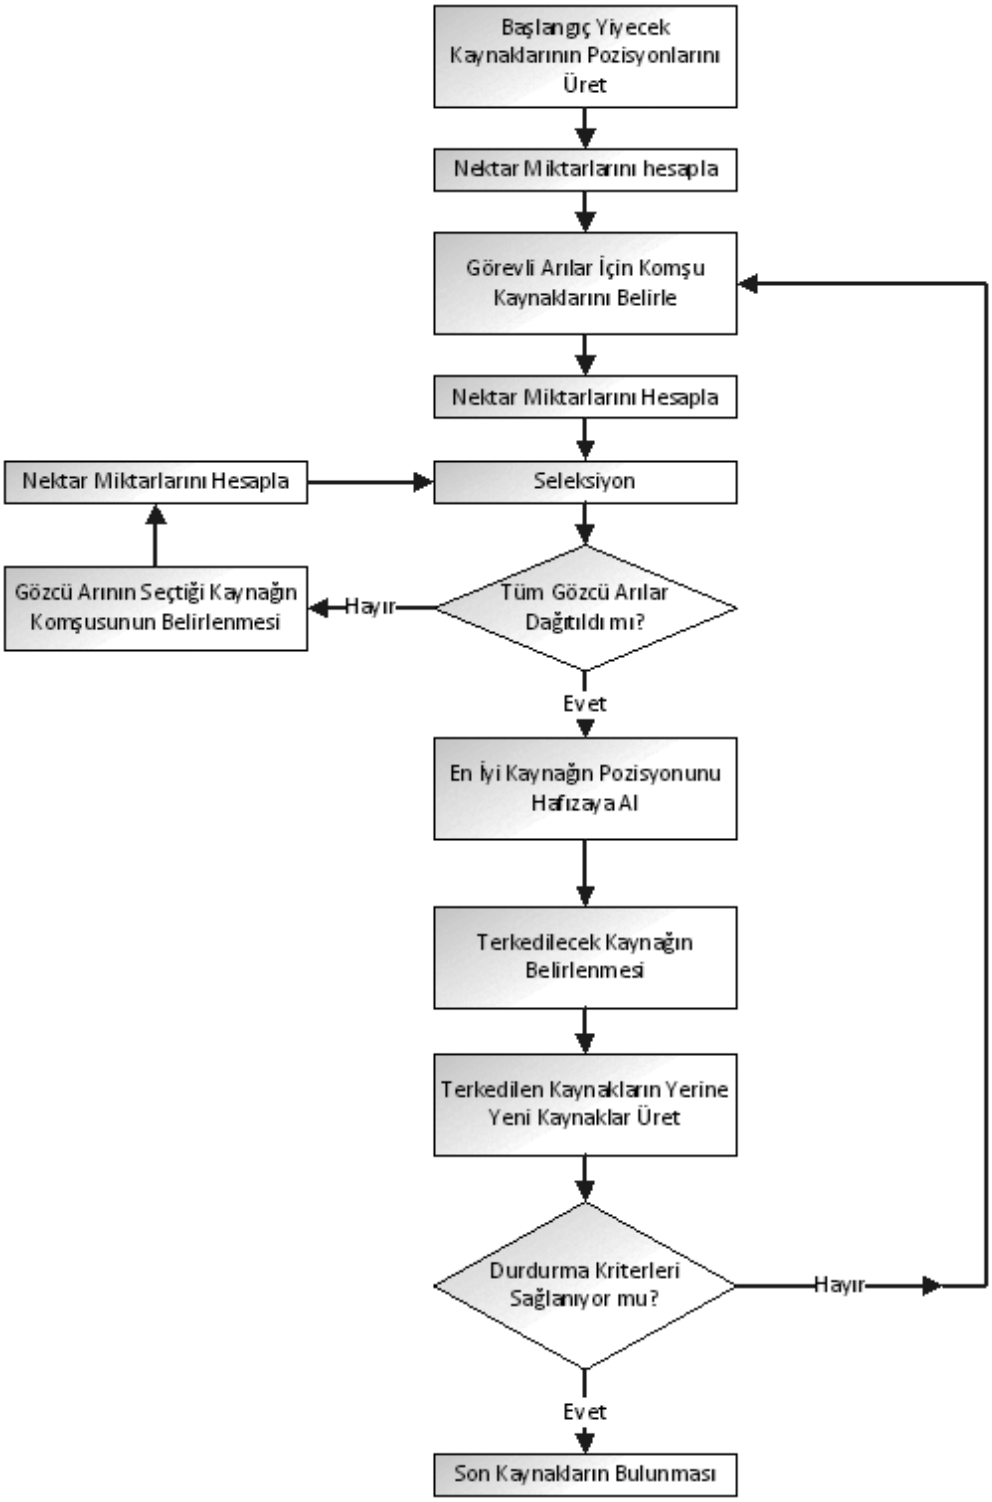
Burada f_i maliyet fonksiyonunun sonucudur ve elde edilen maliyet değerine göre çözümün uygunluğu hesaplanmaktadır (Karaboğa 2014).

Adım 3. Olasılık değerlerine göre yapılan seçimde kullanılacak olasılık değerlerinin görevli arılardan gelen bilgiye göre hesaplanması. Gözcü arılar işçi arılardan elde edilen nektar bilgilerine göre olasılığa bağlı olarak yiyecek kaynaklarını seçerler. Seçim işlemi rulet tekeri, turnuva, stokastik örnekleme gibi seçim yöntemleriyle olabilir. ABC eğer herhangi bir değişiklik yapılmamışsa rulet tekeri algoritmasını kullanır. Olasılık değeri Eşitlik 5.50'deki gibi hesaplanır (Karaboğa 2014):

$$P_i = \frac{uygunluk}{\sum_{j=1}^{N} uygunluk_i} \tag{5.50}$$

Adım 4. Gözcü arıların olasılık değerine göre yiyecek kaynağı bölgesi seçmeleri. Her bir kaynak için, [0,1] aralığında bir P_i değeri üretildikten sonra eğer bu değer rastgele üretilen bir değerden büyükse, gözcü arı için yeni bir kaynak üretilir ve üretilen V_i ile X_i karşılaştırılarak içlerinden daha iyi olan seçilir. Eğer önceki çözüm ile bulunan çözüm arasında fark yoksa yani $f_i = f_{i+1}$ olmuş ise $hata_i = 0$ yapılır. Bu işlem bütün gözcü arılar yiyecek kaynağı bölgelerine dağılıncaya kadar tekrar edilir.

Adım 5. Bırakılacak kaynakların bırakılışı ve kâşif arı üretimi. Bir çevrim sonucunda her bir arının çözüm geliştirme durumları $hata_i$ katsayılarına bakılarak değerlendirilir, böylece kaynaktaki yiyeceğin tükenip tükenmediği belirlenir. Kaynak tükenmişse rastgele yeni bir çözüm üretilir ve en iyi çözüm hafızada tutulur. Sonlandırma koşulları sağlanmıyorsa, Adım 2'den Adım 6'ya kadar devam edilir. Burada sonlandırma koşulları maksimum çevrim sayısı veya, maksimum kâşif arı sayısı da olabilir (Karaboğa 2014) Algoritmanın genel akış diyagramı Şekil 5.10'da görüldüğü gibidir.

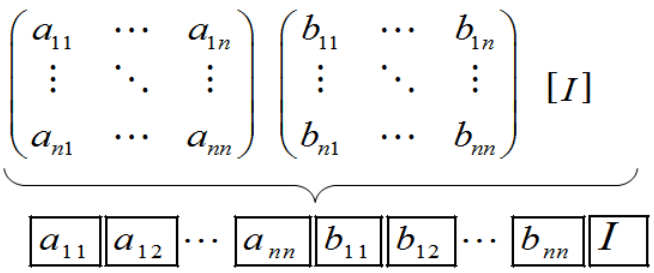


Şekil 5.10 ABC algoritmasının genel akış diyagramı

5.7.2.2 Yapay arı koloni algoritmasıyla HYSA eğitimi

Bu tez çalışmasında HYSA eğitiminde ABC algoritması kullanılmıştır. Bunun en temel sebepleri algoritmanın, çoğu sürü zekâsına dayalı algoritmadan daha başarılı sonuçlar ürettiği ve basit yapısına rağmen karmaşık yapıdaki problemler üzerinde de başarılı performans sergiliyor olmasıdır (Yiğitbaşı 2014).

Daha önce de bahsedildiği gibi HYSA algoritmasının eğitimini, kısıtlamalı bir optimizasyon problemi şeklinde ele almak da mümkündür. Bunun için izlenmesi gereken adımlar RPLA algoritmasına benzemekle beraber, şablonların bir eğitim vektörü olarak tanımlanmasından sonra değişiklik gösterir. HYSA şablonları Şekil 5.11'daki gibi düzenlenerek RPLA'da olduğu gibi bir w vektörü haline getirilir. Vektör, Eşitlik 5.51'deki gibidir.



Şekil 5.11 HYSA şablonlarının vektörizasyonu

$$w \cong \left[a^T b^T I \right]^T \cong \left[a_1 a_2 a_3 a_4 a_5 b_1 b_2 b_3 b_4 b_5 I \right]^T \tag{5.51}$$

Bu aşamadan sonra işlem yine aynı RPLA'da olduğu gibi bir giriş veri setine ve bir hedef veri setine ihtiyaç duyar. Ayrıca ABC tarafından üretilen şablon parametrelerinin doğruluğunu test etmek için bir de uygunluk fonksiyonu gerekmektedir. Uygunluk fonksiyonu pek çok şekilde tasarlanabilir. Bu tez çalışmasında uygunluk fonksiyonu olarak, Eşitlik 5.52'deki iki boyutlu korelasyon fonksiyonu kullanılmıştır (Sutton ve ark 2009). Korelasyon fonksiyonu iki görüntünün birbirine benzerliğini ölçerek [0 - 1] aralığında sayısal bir değer üretir.

$$r = \frac{\sum_m \sum_n (A_{mn} - \bar{A})(B_{mn} - \bar{B})}{\sqrt{(\sum_m \sum_n (A_{mn} - \bar{A})^2)(\sum_m \sum_n (B_{mn} - \bar{B})^2)}} \tag{5.52}$$

Bu Eşitlikde A ve B karşılaştırılacak görüntüler, $\bar{A}$ A görüntüsünün 2B ortalama değeri, $\bar{B}$ ise B görüntüsünün 2 boyutlu ortalama değeridir.

$$x_{ij}(n+1) = \sum_{(k,l)\in N_r(i,j)} A_{i,j;k,l} \cdot y_{k,l}(n) + \sum_{(k,l)\in N_r(i,j)} B_{i,j;k,l} \cdot u_{k,l}(n) + I_{i,j} \tag{5.53}$$

$$x(n+1) = A \otimes y(n) + B \otimes u(n) + I \tag{5.54}$$

HYSA'nın tanım eşitliklerinin ayrık zamanda Eşitlik 5.18 ve 5.19' daki gibi olduğu daha önce ifade edilmişti, bu Eşitlikleri ABC'de maliyet fonksiyonu olarak kullanarak Eşitlik 5.53 ve 5.54'dekigibi ifade edildikten sonra aşağıdaki adımlar takip edilir:

1.Adım: Başlangıç koşulları için **w**(0) başlangıç ağırlık vektörüne bir değer atanır.

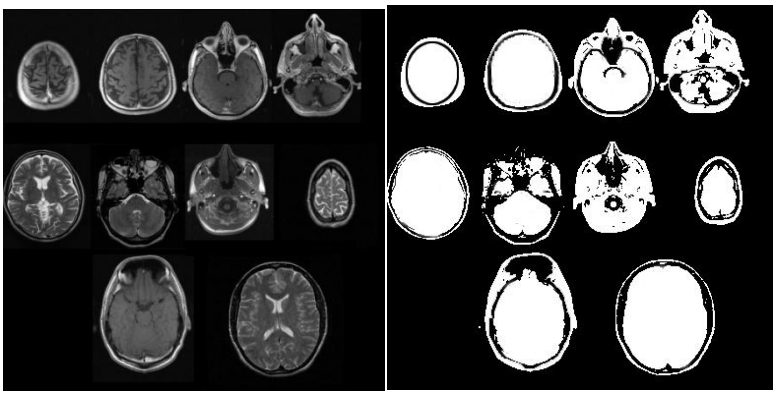
2.Adım: ABC kolonisinde tanımlı her bir arı için verilen başlangıç durum **(x)** vektörü ve başlangıç giriş **(u)** vektörü ile o anki bağlantı ağırlık vektörleri **w**(n) için kalıcı durum çıkışları (y) hesaplanır.

3.Adım: Üretilen her bir sonuç için uygunluk fonksiyonu değerleri analiz edilerek ABC algoritması tarafından bir sonraki aşama için yeni değerler oluşturulur.

4.Adım: İstenen çıkış ve elde edilen HYSA çıkışları arasında hesaplanan hata istenen seviyeye gelinceye kadar veya ABC algoritması hedef iterasyon sayısına ulaşıncaya kadar 2. adımdan sonraki adımlar tekrar edilir.

Algoritmada her bir şablon parametresi arama uzayındaki bir boyut olarak ele alınır. ABC algoritması ile eğitimde en önemli nokta, parametrelerin değişiminde her seferinde hata fonksiyon hesaplaması yaparak güncelleme yapmak yerine arama uzayı içerisinde yeni değerler üretilir. Hata hesabının yapılmamasının sebebi zaten ABC algoritmasının doğasında var olan komşuluk ile yeni parametre tespit özelliğidir.

Hedef ve kaynak veri setleri çok çeşitli yapıda tasarlanabilir, örneğin Şekil 5.12'deki veri seti, beyin MRG görüntüsü içerisinde eşikleme yaparak beyin bölgesini işaretleme amacıyla kullanılan eğitim veri setidir.



(a) (b)

Şekil 5.12 Eşikleme eğitim veri seti (a) Kaynak görüntüleri (b) Hedef görüntüleri.

Eğitimde ABC algoritmasının getirdiği avantaj, daha geniş bir uzayda daha hassas aramalar yaparak yerel minimum çözümlerine takılmadan en uygun şablon parametrelerinin bulunmasını mümkün kılmasıdır.

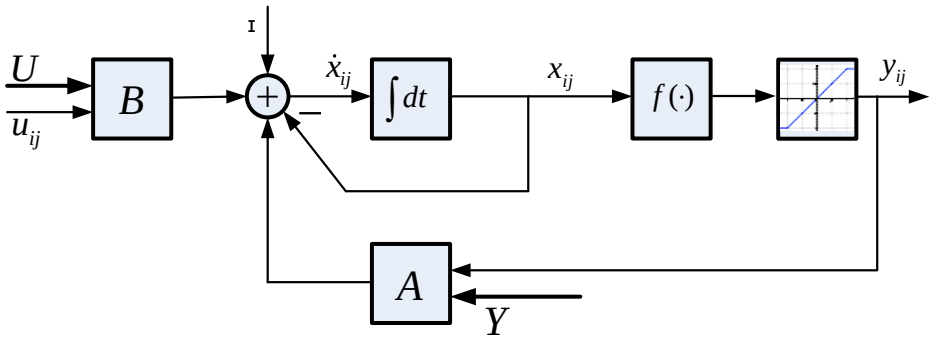
5.8 Çoklu Kararlı Hücresel Yapay Sinir Ağları (ÇK-HYSA)

HYSA modeli A,B ve I matrisleri ile verilen tanımlar sayesinde, girişine verilen verilerden aranan özel bir örüntüyü bulma yeteneğine sahiptir. Sistem kararlı hale ulaştığında aranan örüntü bulunmuşsa çıkış örüntünün bulunduğu bölgelerde +1, diğer bölgelerde -1 değerine ulaşır. Sistem bu haliyle sınıflandırma işlemini başarıyla yapabilmektedir. Özel bir durum olarak birden fazla örüntünün sınıflandırılması gerektiğinde, bazı alternatifler mümkündür.

Bu alternatiflerden biri, birkaç HYSA'yı beraber kullanarak aranan her bir örüntü için ayrı ayrı iterasyonlar yapmaktır. Bu durumda zaman tüketimi eklenen her yeni HYSA ile orantılı olarak artacaktır. İkinci bir alternatif iterasyonları HYSA kararlı duruma ulaşmadan önce sonlandırmaktır ki bu doğru bir yaklaşım değildir, bu yöntem sistemin kararsız olmasına sebep olacaktır ve birden fazla sınıflama yapmış gibi görünse de hiçbir zaman doğru sonuç veremeyecektir.

Son alternatif ise HYSA'nın çıkışındaki fonksiyonun, birden fazla sınıfı belirleyecek şekilde tasarlanmasıdır. Bu modele Çoklu Kararlı Hücresel Yapay Sinir Ağı (ÇK-HYSA) modeli adı verilir (Hernández ve ark 2009). ÇK-HYSA modeli geleneksel HYSA'dan farklı olarak çıkış fonksiyonun tanımındaki değişiklik sayesinde birden fazla dokuyu sınıflayabilir. Geleneksel HYSA modelinde çıkış, [-1, +1] aralığında sınırlandırılmış, tek bir eğime sahip nonlineer bir fonksiyonken ÇK-HYSA modelinde çıkış fonksiyonu birden fazla eğime ve kırılma noktasına sahiptir (Hernández ve ark 2009).

ÇK-HYSA'nın çıkış fonksiyonundaki bu çoklu kırılma noktaları sayesinde ağ sürekli duruma ulaştığında [-1, +1] aralığında doyuma ulaştığı noktalara göre farklı çıkışlar vererek birden fazla dokuyu sınıflandırması mümkündür. ÇK-HYSA modeli Şekil 5.13'deki gibidir.



Şekil 5.13 ÇK-HYSA modeli

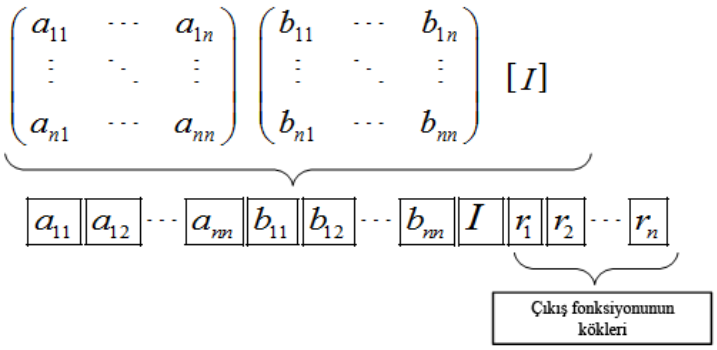
Bu modelde U giriş görüntüsünü, u_{ij} girişin diğer hücrelerden gelen başlangıç şartlarını, x_{ij} hücrenin başlangıç şartlarındaki değerini, y_{ij} hücrenin çıkış değerini, Y ise diğer hücrelerden gelen başlangıç değeri bilgisini ifade eder.

ÇK-HYSA çıkış fonksiyonunun doğru bir şekilde tanımlanması buradaki en önemli konudur. Çıkış fonksiyonu birden çok eğime ve kırılma noktasına sahip parçalı bir fonksiyon olabileceği gibi, bir polinomla ifadesi de mümkündür. Uygun bir çıkış fonksiyonunun belirlenmesinde uyulması gereken bazı basit kurallar vardır. Bu kurallar, fonksiyonun sürekli olması, reel köklerinin olması ve simetrik olmasıdır (Hernández ve ark 2009). Bu kurallara göre incelendiğinde fonksiyonun bir polinom olarak tanımlanmasının kolaylığı görülmektedir. Faktör formunda yazılmış örnek bir çıkış fonksiyonu Eşitlik 5.55'deki gibidir (Hernández ve ark 2009).

$$f(x) = a(x - r_1)(x - r_2) \dots (x - r_n)(x - r_{n+1}) \dots (x - r_{2n+1}) \tag{5.55}$$

Burada $a < 0$ ve $r_1 < r_2 < \cdots < r_{2n+1}$ reel sayılar kümesinde tanımlı olan, $r_1, r_2 \dots, r_n$ negatif $r_{n+1} = 0$ ve $r_{n+2}, r_{n+3} \dots, r_{2n+1}$ sayıları da pozitif olmalıdır. Bu genel fonksiyon tanımı istenen temel özellikleri sağlamaktadır. Fonksiyonun faktör formunda tanımlanmış olması parametrelerin optimizasyon algoritmaları ile tespitini de kolaylaştırmaktadır. Bu tez çalışmasında da a, $[r_1, r_2, r_3 \dots, r_n]$ parmetreleri ABC algoritması kullanılarak belirlenmiştir.

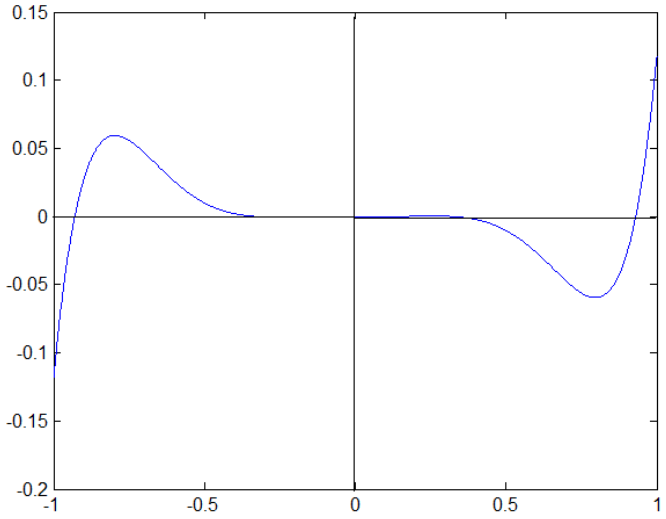
ÇK-HYSA'nın eğitimi de normal HYSA ile aynı yöntemlerle gerçekleştirilebilir, burada ekstradan çıkış fonksiyon parametreleri de eğitim ile bulunmaktadır. ÇK-HYSA parametrelerinin vektörizasyonu Şekil 5.14'de ve Eşitlik 5.56'daki gibidir.



Şekil 5.14 ÇK-HYSA için vektörizasyon modeli

$$w \cong \left[a^T b^T I r^T \right]^T \cong \left[a_1 a_2 a_3 a_4 a_5 b_1 b_2 b_3 b_4 b_5 I r_1 r_2 \cdots r_n \right]^T \tag{5.56}$$

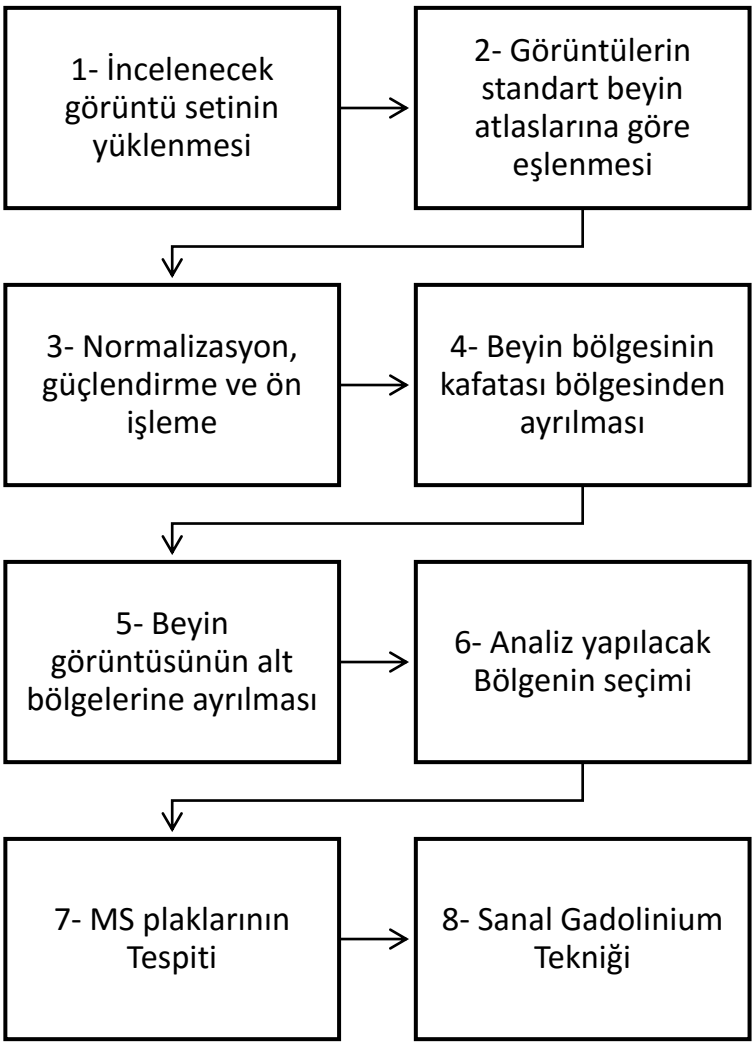
Eğitim sonrası elde edilen parametrelere göre üretilebilecek çıkış fonksiyonlarına örnek olarak Şekil 5.15'deki grafik verilebilir. Şekilde ifade edilen grafik yatay eksendeki x_{ij} değerlerine karşı çıkışta verilecek y_{ij}değerlerini dikey eksende ifade etmektedir. Görüldüğü gibi grafiğin ifade ettiği polinom birden fazla köke sahiptir y_{ij}çıkış değerleri bu kökler civarında oluşacağı için her kök görüntüdeki belli özellikleri sınıflandırabilmektedir.



Şekil 5.15 ÇK-HYSA için çıkış fonksiyonu

6 METODOLOJİ

Bu tez çalışmasında MS hastalığının teşhisinde doktorlara yardımcı olacak bir BDT sisteminin ve yazılımların geliştirilmesi amaçlanmıştır. Böylece erken teşhis ve koruyucu yöntemlerle hastalığın insan hayatını kısıtlayıcı bir seyir alması engellenerek, hastalığa yakalanan kişilerin hayat kalitesinin bozulması önlenebilir. Tezde sunulan MS vakalarının analizi ve plakların aktiflik-inaktiflik durumunu analiz eden KDS literatürdeki benzer çalışmalardan yola çıkarak geliştirilmiş çeşitli önişleme ve analiz tekniklerini kullanarak çalışılmıştır. Yöntem Şekil 6.1'deki adımları takip etmektedir. Yapılan literatür araştırmalarında görülmüştür ki, beyin MRG görüntülerinin analizinde belli başlı bazı adımların izlenmesi önemlidir. Literatürde bu konuda yapılan çalışmalar sayesinde genel bir iskelet belirlenmiştir (Prastawa ve ark 2004, Friston 2007, Despotovic ve ark 2015).



Şekil 6.1 Yöntemin genel akış diyagramı

Akış diyagramında da görüldüğü gibi verilerin elde edilip işleme başlanmasından sonra takip edilen adım, görüntülerin standart beyin atlaslarına uygun olarak eşlenmesi işlemidir (Xu ve Nowinski 2001, Wyawahare ve ark 2009). Bu tez çalışmasında da optimizasyon algoritmalarına dayalı bir görüntü çakıştırma fonksiyonu geliştirilmiş ve bu amaç için kullanılmıştır. Algoritma detaylı olarak Bölüm 6.2' de anlatılmaktadır.

Akış diyagramındaki üçüncü adım, görüntünün, ön işlemden geçirilerek normalize edilmesi ve güçlendirilmesidir. Tıbbi görüntülerde güçlendirmenin ana amacı görüntü kalitesinin insan gözünün hassasiyetine uygun hale getirmek (Majumder ve Irani 2006) ya da otomatik ve yarı otomatik sınıflandırıcı sistemlerde bölütleme başarısını arttırmaktır. Tez çalışması sırasında, Doğrusal harmanlamayla karşıtlık güçlendirme algoritması (CEULICA) özellikle başta beyin görüntüleri olmak üzere MRG görüntülerinde karşıtlık güçlendirme işlemi yaparak daha net bir görsel sonuç elde etmek amacıyla geliştirilmiştir (Yilmaz ve Ozbay 2014). Algoritma Bölüm 6.3' de tanıtılmaktadır.

Dördüncü adımda, beyin ile beyin dışı bölgelerin birbirinden ayrılması işlemi gerçekleştirilmektedir, çünkü beyin dışı bölgelerden gelen veriler, asıl incelenen bölgedeki verileri bozarak anlaşılırlık seviyesini düşürmektedir. Özellikle yağ dokusunun MS plaklarına benzer gri seviye yoğunluğuna sahip olması bu duruma sebep olmaktadır. Bu yüzden literatürde Kafatası Soyma (Skull Stripping) adı verilen yöntemler kullanılmaktadır (El-Dahshan ve ark 2014). Tez çalışmasında bu amaçla, beyin atlasları, çoklu kararlı hücresel yapay sinir ağları ve görüntü işleme teknikleri kullanan bir yöntem geliştirilmiştir. Yöntem Bölüm 6.4'de detaylı olarak verilmiştir.

Beşinci adımda istenmeyen bölgelerin ayrılması ve görüntü düzeltmesinden sonra elde kalan saf beyin görüntüsü Beyaz Cevher (WM), Gri Cevher (GM) ve Beyin-Omurilik Sıvısı (CSF) adlı alt bölgelere ayrılmıştır. Bu işlem için çoklu kararlı hücresel yapay sinir ağı temelli bir algoritma geliştirilmiştir. Yöntem Bölüm 6.5'de tanıtılmıştır.

Altıncı adımda, MS plaklarının hangi bölgede aranması gerektiği ve bunun sebepleri anlatılmıştır. Bu bilgilere göre analizi yapılacak bölge seçilmiştir. Bu seçime ait bilgiler Bölüm 6.6'da anlatılmıştır.

Yedinci adımda bölütlenmiş görüntü içerisinde MS plaklarının belirlenmesi ve analizi işlemi yapılır. Bu işlem için gerekli olan matematik modelleri ve HYSA parametreleri ile plakların bölütlenmesinde kullanılan algoritma Bölüm 6.7'de tanıtılmıştır.

Sekizinci aşamada, plakların aktif-inaktif olma durumu incelenip bu konuda geliştirilen yeni bir algoritma olan, Sanal Gadolinium Prosedürü (Virtual Gadolinium) uygulanmıştır. Yöntem, Bölüm 6.8'de tanıtılmıştır.

6.1 Tezde Kullanılan Veri Tabanları ve Atlaslar

Bu çalışma sırasında yapılan analizler, MRG cihazlarından T1, T2, PD, FLAIR, MP-RAGE yöntemleriyle (modality) elde edilen beyin veri kümeleri kullanılmıştır.

6.1.1 Halka açık online veri tabanları

Dünya çapında çeşitli araştırma merkezleri ve girişimler, isteyen araştırmacıların yaralanması için çeşitli veri tabanlarını yayınlamaktadırlar. Bunlardan bazıları ücretli üyelik gerektirirken bazıları ise ücretsiz erişime açıktır. Veri tabanları gerçek verilerden oluşturulmuş olabileceği gibi, çeşitli yazılımlarla benzetim yapılarak da oluşturulmuş olabilirler. Tez çalışmasında kullanılan veri tabanları bu bölümde anlatılmıştır.

6.1.1.1 BrainWeb veritabanı

BrainWeb veritabanı, McGill Üniversitesi Montreal Nörolojik Enstitüsü McConnell Beyin Görüntüleme Merkezi tarafından sağlanan çeşitli yöntemlere sahip üç boyutlu görüntülerden oluşan bir veritabanıdır. Veritabanına http://www.bic.mni.mcgill.ca/BrainWeb/ adresinden ulaşılabilmektedir. BrainWeb veritabanı simule edilmiş, sağlıklı ve MS'li beyin görüntüleri içerir (BrainWeb , Kwan ve ark 1996, Collins ve ark 1998, Kwan ve ark 1999). Bunlardan başka BrainWeb, normal beyin MRG görüntülerinin 20 anatomik modelini sunmaktadır (Aubert-Broche ve ark 2006, Aubert-Broche ve ark 2006). Orijinal MRG T1 ağırlıklı modeldir ve anatomik modellerdeki her voksel Çizelge 6.1'de gösterildiği gibi kodlanmıştır.

Çizelge 6.1 BrainWeb anatomik modelindeki doku kodları

Sayısal Değer	Doku	Sayısal Değer	Doku
0	Arkaplan	6	Kas/Yağ
1	BOS (CSF)	7	Kafatası
2	Gri Madde	8	Damarlar
3	Beyaz Madde	9	Yağ çevresi
4	Yağ	10	Dura Maddesi
5	Kas	11	Kemik İliği

Veritabanındaki orijinal görüntülerin özellikleri şunlardır; 1 mm dilim kalınlığı, T1 ağırlıklı, 181×256×256 vokseller ile 0 ile 4095 arasında kısa tamsayı değerleri. Her orijinal

görüntü de aşağıdaki özelliklere sahip 0.5 mm dilim kalınlığı, 362×434×362 vokselli, tam sayılı 0 ile 255 arasında değerlerle tanımlı bir anatomik modele sahiptir.

6.1.1.2 NAMIC veritabanı

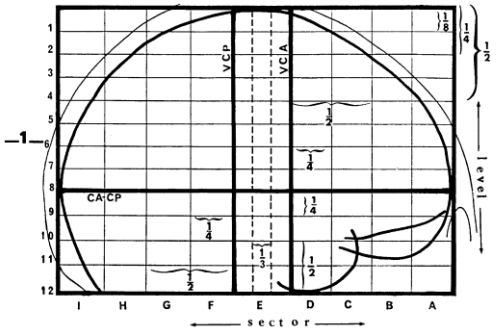
NAMIC (National Alliance for Medical Image Computing) veri tabanı University of North Carolina'da bulunan CASILab tarafından kullanıma sunulmuş ve Kitware, Inc.'nin MIDAS (Multimedia Digital Archiving System) veri sunucuları tarafından yayınlanmaktadır (Bullitt ve ark 2005). MIDAS sunucuları medikal ve medikal olmayan çeşitli veri kümelerini hem sunucu tabanlı hem de tek başına çalışan uygulamalar için yayınlamaktadır (Kitware. 2015). Veritabanına http://www.insight-journal.org/midas/ adresinden ulaşılabilmektedir.

6.1.2 NEÜ Meram Tıp Fakültesi veritabanı

Bu veri seti, Necmettin Erbakan Üniversitesi Meram tıp fakültesinin 2011/235 sayılı kararı ile klinik araştırmaların yerel etik komitesinin izni ile alınan MRG görüntülerinden oluşturulmuştur. Görüntü verileri standart Talairach alanı ile uyumlu değildir. Veritabanındaki her MRG görüntüsü dilimler arasında 3 mm dilim kalınlığı ve 10 mm mesafe olan 24 dilimden oluşur. Görüntüler Siemens Magnetom Symphony A Tim System 1.5 T makinesiyle elde edilmiştir.

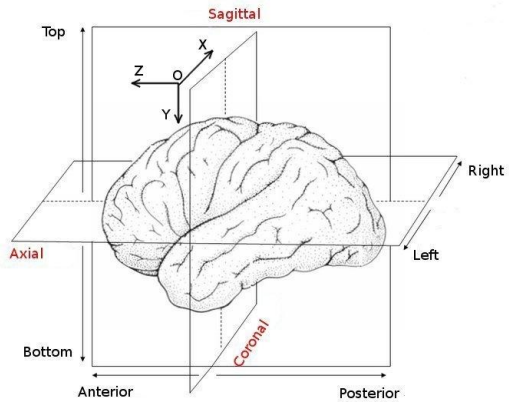
6.1.3 Beyin atlasları

Beyin üstünde yıllar boyu yapılan araştırmalar ve çalışmalar sayesinde beyinin haritalandırılması mümkün olmuştur. Böylece yapılan çalışmaların tüm diğer çalışmalara uygun ve koordineli olmasını sağlamak için beyinin haritasını tanımlayacak koordinat sistemleri geliştirilmiştir. Bunlardan en yaygın olanları Talairach ve Montreal Neurological Institute and Hospital (MNI) koordinat sistemleridir (Chau ve McIntosh 2005). Şekil 6.2'de Talairach uzayındaki koordinatların uzaklıklarına dair standartlar gösterilmiştir.



Şekil 6.2 Talairach uzayındaki koordinatların uzaklıklarına dair standartlar (http://neuro.imm.dtu.dk/services/brededatabase/WOROI_96.html)

Beyin MRG görüntüleri genelde üç boyutlu olarak elde edilir ve belirtilen koordinat sistemlerinden birine göre MRG dilimleri yerleştirilir. Üstünde çalışılmak istenen dilime bu koordinat sistemleri üzerinden ulaşılabilir. Görüntüler genelde aksiyel, koronal ve sagital olarak adlandırılan düzlemler ile görüntülenirler. Şekil 6.3'de bu düzlemler gösterilmiştir.



Şekil 6.3 MRG görüntülerinde kullanılan düzlemler
(http://brainvisa.info/doc/axon/en/processes/ExtractComponentsInOrder.html)

Sunulan görüntü eşleme algoritması, bu atlaslardan seçilen herhangi birine göre, hedef veri setini eşleyecek şekilde geliştirilmiştir.

6.1.4 Beyin analiz programları

Bilimsel araştırmalarda ve biyomedikal endüstrisinde beyin görüntülerinin analizi için kullanılan pekçok algoritma ve paket program mevcuttur. Bu tez çalışması sırasında, bu algoritmalardan bazıları, karşılaştırma ve analiz amacıyla kullanılmıştır.

6.1.4.1 FSL – BET

FSL, Centre for Functional Magnetic Resonance Imaging of the Brain (FMRIB) tarafından geliştirilen bir yazılım paketidir. Yazılım, beyin MRG analizi için çeşitli araçlar içerir (Jenkinson ve ark 2012).

6.1.4.2 BrainSuite – BSE

BrainSuite beyin MRG analizi için geliştirilmiş bir yazılım paketidir. Yazılım klinik çalışmalar için beyin bölütlemeleri üretebilen birçok düşük seviyeli algoritma içerir. Algoritmalar arasında kafatası ve kafa derisi çıkarma, görüntü homejenlik düzeltme, voksel temelli doku sınıflandırması, topolojik düzeltme, işleme ve düzenleme araçları bulunur.

Araçlar, kortikal minimal düzeyde kullanıcı etkileşimi gerektiren şekilde tasarlanmıştır (Shattuck ve Leahy 2002).

6.1.4.3 SPM8

SPM8 Wellcome Trust Centre for Neuroimaging, (University College London, UK) tarafından geliştirilmiş bir yazılım paketidir. SPM yazılım paketi beyin görüntüleme veri dizilerinin analizi için tasarlanmıştır. Diziler, bir dizi resim veya aynı konudan zaman serisi olabilir. Mevcut sürüm, fMRI, PET, SPECT, EEG ve MEG'nin analizi için tasarlanmıştır (Kasiri ve ark 2010).

6.2 Görüntü Çakıştırma

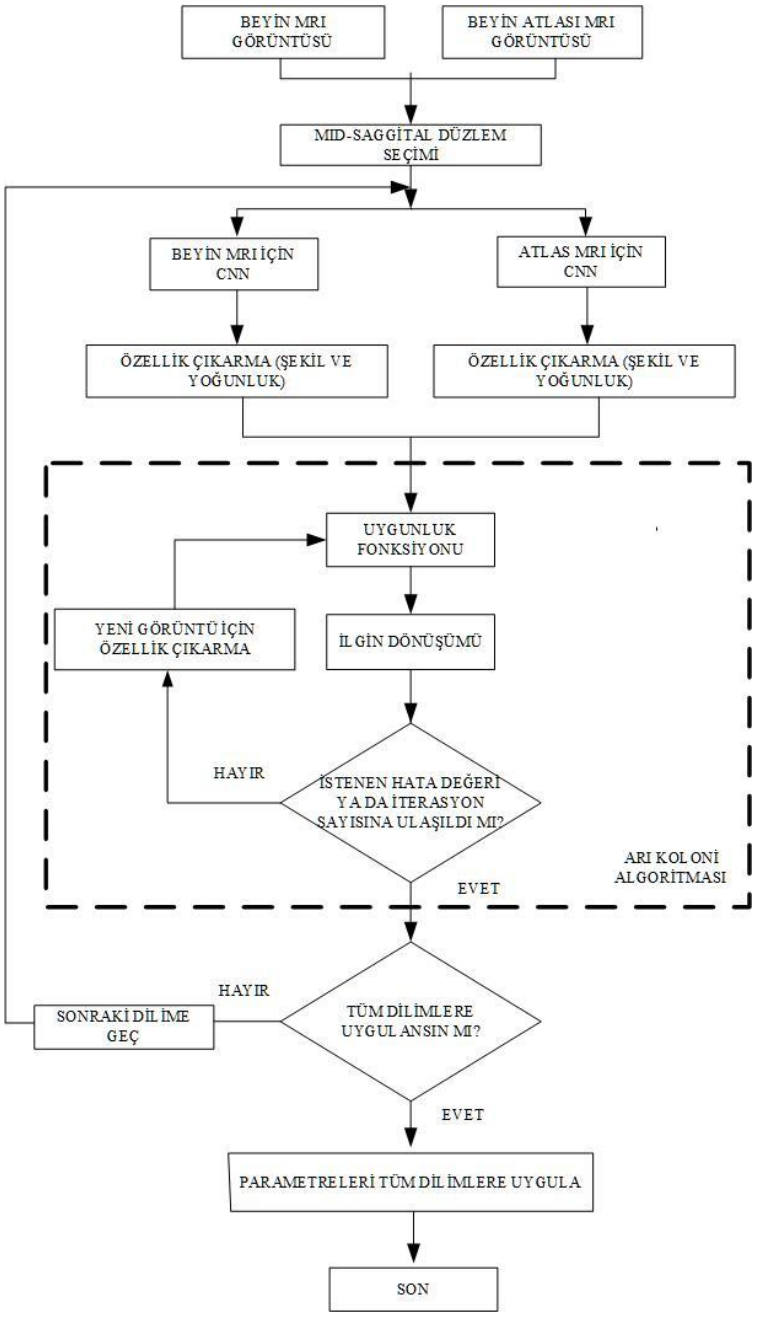
Biyomedikal görüntülerin işlenmesinde ve analizinde hem yoğunluk hem de şekilsel olarak standardizasyonu sağlamak için çeşitli yöntemler geliştirilmiştir. Bu yöntemlerden biri de görüntülerin atlaslara ya da standart modellere çakıştırılmasıdır. Biyomedikal görüntülerin çakıştırılması ile incelenen dokunun anatomik modele ne kadar uyduğu ya da bozulma miktarını tespit etmek mümkündür (Shams ve ark 2010, Glocker ve ark 2011).

Literatürde, çeşitli yöntemlere dayanan farklı görüntü çakıştırma algoritmaları mevcuttur. Algoritmaları karakteristik özelliklerine göre çeşitli şekillerde sınıflandırabiliriz (Viergever ve ark 2016):

- Boyutsallık (uzaysal veya uzay-zamansal, 2D/2D, 2D/3D, 3D/3D)
- Çakıştırma yöntemine göre (dışsal, içsel, görüntüye dayalı olmayan)
- Dönüşüm yöntemine göre (kati, afin, yansıtmalı, eğimli)
- Dönüşüm zeminine göre (genel, yerel)
- Etkileşim derecesine göre (etkileşimli, yarı otomatik, otomatik)
- Optimizasyon yöntemine göre (hesaplanan, aranan)
- Görüntü modalitesine göre (tekli, çoklu, model-modalite, hasta-modalite)
- Konuya göre (içsel, dışsal, atlas tabanlı)
- İlgili nesneye göre (beyin, kalp, v.s.)

Tez çalışmasında geliştirilen algoritma, esnek (non-rigid), afin dönüşümü tabanlı ve dönüşüm parametreleri için optimizasyon yöntemleri kullanacak şekilde tasarlanmıştır. Algoritma aynı anda hem şekil özelliklerini hem yoğunluk özelliklerini kullanacak şekilde geliştirilmiştir. Giriş görüntüsü ve atlas arasında maksimum korelasyonu sağlamak için her iki görüntü de Hücresel Yapay Sinir Ağları ile işlenerek temel şekil özellikleri ortaya çıkarılmıştır.

Elde edilen görüntü ve değerler tasarlanan uygunluk fonksiyonuna sunularak Arı Koloni Algoritması ile ilgin dönüşüm (Affine Transform) (Napadow ve ark 2006) parametreleri hesaplanıştır. Dönüşümü yapılacak olan her görüntü kendine özgü olduğu için Arı Koloni Algoritması her görüntü setinde yeni parametreler üretecek şekilde kullanılmıştır. Yöntemin genel akış diyagramı Şekil 6.4'deki gibidir:



Şekil 6.4 Geliştirilen görüntü çakıştırma algoritması akış diyagramı

Algoritmada ilk aşama, çakıştırılacak MRG görüntüsü ve atlas görüntülerinin seçilmesidir. Algoritma hem, 3B MRG görüntülerinde hem de tek tek her bir görüntü diliminde çalışabilir. Eğer sadece bir görüntü atlasa çakıştırılacaksa, atlasta ve MRG

görüntüsünde aynı dilimin seçilmiş olduğundan emin olunmalıdır. Eğer 3B çakıştırılma yapılacaksa, MRG verisi ile atlas verisinin aynı parametrelerle ve çekim tekniğiyle elde edilmiş olması gerekmektedir. Böylece veri setlerindeki dilim sayıları eşitlenmiş olacaktır.

Bir sonraki aşamada, orijinal görüntü ile çakıştırılacak görüntü manuel olarak seçilir, eğer özel bir işlem yapılmıyorsa çakıştırılacak her iki görüntüde simetriyi yakalayabilmek için, görüntülerin ortası olarak kabul edilen midsaggital düzlem tercih edilir. Aynı zamanda midsagittal düzlem Talairach koordinat sisteminin de başlangıç noktası olarak kabul edilir. (Chau ve McIntosh 2005)

Çakıştırılacak görüntülerin seçiminden sonra görüntülerin işleme uygun hale getirilmesi gerekmektedir. Beyin atlasları birden çok kişiden elde edilmiş beyin MRG görüntüleri kullanılarak elde edilirler (Serag ve ark 2012), bu yüzden her ne kadar anatomik sınırlar sayısal olarak kesin bir şekilde belirlenmiş olsa da, oluşturulan atlas görüntüleri gürültüsüz ve bulanık bir yapıya sahiptir. Çalışmada, bulanıklıktan dolayı oluşan farkın minimuma indirilmesi için her iki görüntü de HYSA algoritmasıyla işlenerek, referans olarak kullanılabilecek görüntü özelliklerinin ortaya çıkarılması sağlanır. Çakıştırılacak olan atlas görüntüsü Şekil 6.5(a)'da ve MRG görüntüsü Şekil 6.5(b)'de gösterilmiştir. Şekil 6.6'da ise aynı görüntülerin HYSA algoritması sonrasında elde edilen halleri görülmektedir.



(a) (b)

Şekil 6.5 Çakıştırılacak olan Atlas görüntüsü (a) ve beyin MRG görüntüsü (b)

Çakıştırılacak her iki görüntünün aynı çekim tekniği ile elde edilmiş olmasının dışında gürültü ve yoğunluk değerleri olarak da birbirlerine yakın olması çakıştırma başarısını arttıracaktır. Bu yüzden bir sonraki aşamada her iki görüntü de HYSA algoritmasından

geçirilerek şekil özelliklerini ortaya çıkaracak şekilde yeni görüntüler elde edilir. Şekil 6.6'da HYSA sonucunda elde edilen görüntüler gösterilmiştir. Görüntü özelliklerini yakınlaştırmak için bir eşikleme işlemi yerine HYSA tercih edilmesinin sebebi görüntünün şekil ve doku özelliklerine bağlı olarak yapıyı koruyarak mümkün olan en yakın şekli elde etmektir.

Algoritmanın karşılaştırması için dört görüntüden oluşan iki ayrı veri seti oluşturulur. Bunlardan ilk veri seti, gri seviye görüntüler, ikinci veri seti ise şekil özellikleri korunmuş ikili görüntülerdir.



(a) (b)

Şekil 6.6 HYSA sonrası, (a) çakıştırılacak olan atlas görüntüsü ve (b) beyin MRG görüntüsü

Görüntülerin şekil özelliklerini belirlemede kullanılan HYSA'nın A,B ve I matrisleri Eşitlik 6.1'deki gibidir

$$A=\begin{bmatrix} -0,372 & 0,656 & 0,090 \\ 0,603 & 0,398 & 0,603 \\ 0,902 & 0,656 & -0,372 \end{bmatrix},\ B=\begin{bmatrix} -0,982 & 0,647 & 0,242 \\ 0,127 & 1,126 & 0,127 \\ 0,242 & 0,647 & -0,982 \end{bmatrix},\ I=\begin{bmatrix} 0,1430 \end{bmatrix} \quad (6.1)$$

Bu işlemlerden sonra şekil ve yoğunluk özelliklerine göre karşılaştırma yapılabilecek iki görüntü seti elde edilir. Sonraki aşama bu görüntüleri kullanarak çakıştırma işleminin gerçekleştirilmesidir. Çakıştırma işlemi için İlgin dönüşümü (Affine Transform) adı verilen yöntem (Napadow ve ark 2006) ve yöntemin parametrelerini belirlemek için yapay arı koloni algoritması kullanılır.

6.2.1 İlgin dönüşümü

İlgin dönüşümü, (x,y) koordinatlarından ölçekleme, öteleme, döndürme ve kaykılma işlemlerini yaparak (x',y') koordinatlarına dönüşüm yapmayı sağlar. Dönüşüm sırasında görüntüdeki nesneler arasındaki ilişki korunmaya devam eder. Örneğin iki paralel doğru dönüşüm sonrasında yine paralel olarak kalacaktır, fakat açılar değişecektir (Zwillinger 2011). İlgin dönüşüm hem 2B hem de 3B gerçekleştirilebilmektedir. İlgin dönüşümü Eşitlik 6.2 – 6.11 ile tarif edilir.

$$\begin{bmatrix} x' \\ y' \end{bmatrix} = s \begin{bmatrix} cos\alpha & sin\alpha \\ -sin\alpha & cos\alpha \end{bmatrix} \begin{bmatrix} x - x_0 \\ y - y_0 \end{bmatrix} \tag{6.2}$$

$$\begin{bmatrix} x' \\ y' \end{bmatrix} = s \begin{bmatrix} cos\alpha(x - x_0) & sin\alpha(y - y_0) \\ -sin\alpha(x - x_0) & cos\alpha(y - y_0) \end{bmatrix} \tag{6.3}$$

Eşitlikleri ayırarak:

$$x' = (s\cos\alpha)x + (s\sin\alpha)y - s(x_0\cos\alpha + y_0\sin\alpha) \tag{6.4}$$

$$y' = (-s\sin\alpha)x + (s\cos\alpha)y + s(x_0\sin\alpha - y_0\cos\alpha) \tag{6.5}$$

Eşitlikler aynı zamanda

$$a = s\cos\alpha \tag{6.6}$$

$$b = -s\sin\alpha \tag{6.7}$$

Kabul edilerek şu şekilde yazılabilir:

$$x' = ax - by + c \tag{6.8}$$

$$y' = bx + ay + d \tag{6.9}$$

Skala değeri s:

$$s = \sqrt{a^2 + b^2} \tag{6.10}$$

Döndürme açısı α:

$$\alpha = \tan^{-1}\left(-\frac{b}{a}\right) \tag{6.11}$$

şeklinde tanımlanır (Zwillinger 2011).

6.2.2 Uygunluk fonksiyonu

Çalıştırma parametrelerinin arı koloni optimizasyonu ile belirlenebilmesi için bir uygunluk fonksiyonuna ihtiyaç duyulur. Uygunluk fonksiyonu, parametre olarak, daha önce üretilmiş olan veri setleri ve ilgin dönüşümü katsayılarını alır. Katsayılar ABC algoritması tarafından her adımda hesaplanarak güncellenir ve parametrelere göre ilgin dönüşümü gerçekleştirilir. Dönüşümden sonra yeni elde edilen görüntüler bir sonraki adım için tekrar parametre olarak kullanılır. Çakıştırma başarısının hesaplanması için uygunluk fonksiyonu görüntü korelasyon fonksiyonunu ve Jaccard katsayısını kullanır.

Korelasyon fonksiyonu iki görüntüyü gri seviye değerlerine göre karşılaştırarak [0,1] aralığında bir değer üretir (Sutton ve ark 2009). "0" iki görüntünün tamamen uyumsuz olduğunu ve "1" ise iki görüntünün birebir aynı olduğunu belirtir. Korelasyon fonksiyonunun matematiksel ifadesi Eşitlik 6.12'deki gibidir.

$$r = \frac{\sum_m \sum_n (A_{mn} - \bar{A})(B_{mn} - \bar{B})}{\sqrt{(\sum_m \sum_n (A_{mn} - \bar{A})^2)(\sum_m \sum_n (B_{mn} - \bar{B})^2)}} \tag{6.12}$$

Bu Eşitlikde A ve B karşılaştırılacak görüntüler, $\bar{A}$, A görüntüsünün 2B ortalama değeri, $\bar{B}$ ise B görüntüsünün 2B ortalama değeridir.

Çakıştırılan iki görüntünün şekil özelliklerinin uyumunu ölçmek için ise Jaccard katsayısı kullanılır. Jaccard katsayısı da yine [0 – 1] arasında değer üretmektedir, "0" iki görüntünün üstü üste binmediğini "1" ise mükemmel bir şekilde iki görüntünün eşlendiğini ifade eder. Jaccard katsayısı Eşitlik 6.13 ve 6.14'e göre hesaplanır.

$$D = \frac{2|S \cap R|}{|S| + |R|} \tag{6.13}$$

$$J = \frac{|S \cap R|}{S \cup R} = \frac{D}{2 - D} \tag{6.14}$$

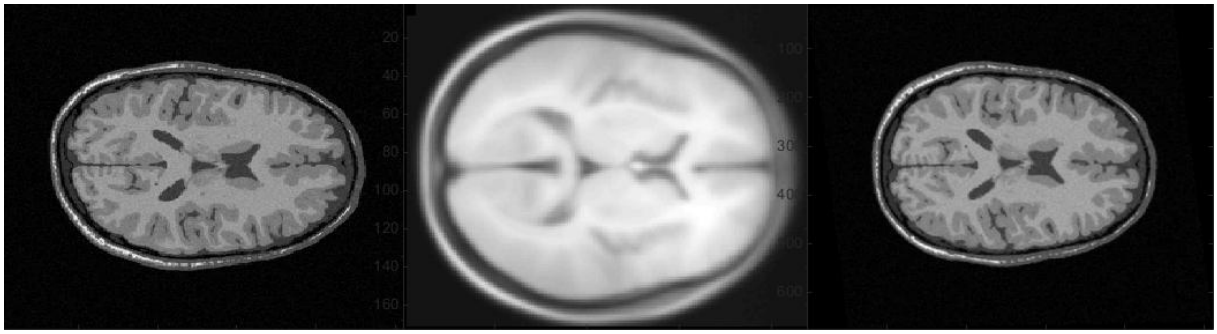
burada S ilgin dönüşümü sonucu elde edilen görüntüyü, R ise atlas görüntüsünü ifade eder. Eşitlik 6.13'de D ile ifade edilen değer ise Dice katsayısı adı verilen bir diğer karşılaştırma katsayısıdır.

Uygunluk fonksiyonu bu iki parametreyi kullanarak, görüntünün ABC'den gelen parametrelere göre çakıştırma başarısını hesaplayarak ABC algoritmasına bir sonraki adım için geri döndürür. Burada uygunluk fonksiyonunun çıkışı Eşitlik 6.15'deki gibi hesaplanmıştır.

$$f = 1 - (\alpha r + \beta J) \tag{6.15}$$

Burada f uygunluğu (fitness), r korelasyonu, α korelasyon katsayısını, J Jaccard değerini ve β Jaccard katsayısını ifade eder. Burada α ve β değerleri [0,1] aralığında olup kullanıcı tarafından belirlenir ve hangi katsayının daha önemli olduğunu ifade eder.

Çakıştırma işlemi, daha önceden belirlenen adım sayısına ya da hata değerine ulaştığında ABC algoritması tarafından sonlandırılır. İşlem sonunda eğer bulunan parametreler tüm dilimlere uygulanacaksa her bir dilime bulunan parametrelere göre ilgin dönüşümü uygulanır, aksi takdirde algoritma sonlandırılır. BrainWeb veritabanından seçilmiş T1 çekim tekniğiyle kaydedilmiş subject52 adlı verinin 90 numaralı dilimi Şekil 6.7 (a)'da, Talairach average 305 T1 atlasının 78 numaralı dilimi Şekil 6.7 (b)'de ve çakıştırma sonucunda elde edilen görüntünün yine 90 numaralı dilimi Şekil 6.7 (c)'de gösterilmektedir.



(a) (b) (c)

Şekil 6.7 Çakıştırma algoritmasının sonucu (a) BrainWeb veritabanından seçilmiş T1 çekim tekniğiyle kaydedilmiş subject52 adlı verinin 90 numaralı dilimi, (b) Talairach average 305 T1 atlasının 78 numaralı dilimi (c) çakıştırma algoritmasının sonucu.

6.3 Geliştirilen Doğrusal Harmanlamayla Karşıtlık Güçlendirme Algoritması

Beyin görüntüleri üstünde çalışırken, hastalığın meydana geldiği bölgeye göre, beynin bölümlerinin ayrılıp daha yoğun incelenmesi gerekir. Beyin görüntüsünün bölgelerine ayrılabilmesi için görüntünün net ve ayırt edilebilir olması büyük bir avantaj sağlar. Daha önceki bölümde görüntünün güçlendirilirken piksel değerlerinin doğru bir şekilde tanımlandığı değer aralığına yayılması gerektiğinden bahsedilmişti. Bu bölümde ise bu amaçla geliştirilmiş bir algoritma tanıtılacaktır.

Karşıtlık (kontrast) güçlendirme, görüntü işleme ve bilgisayar görmesi işlemlerinde sıkça karşılaşılan bir konudur.

Karşıtlık güçlendirme teknikleri uzaysal zemin ve frekans zemini teknikleri olmak üzere iki kategoride incelenebilir (Kabir ve ark 2010). Bu tekniklerin bazıları haritalama ve dönüşüm fonksiyonları şeklinde tanımlanırken diğer bazı teknikler, niceleyici ve niteleyici analizleri de içeren algoritmalar olarak tanımlanırlar. Uzaysal zemin teknikleri görüntü işlemede en çok ilgi gören tekniklerdir. Literatürde çok çeşitli uzaysal zemin tekniği mevcuttur. Kabir ve arkadaşları, global ve yerel dönüşüm fonksiyonlarına dayalı bir teknik geliştirirken Kosheleva ve arkadaşları 1998'de ortalama filtreleme tekniğini değiştirerek seçici ortalama filtreleme metodunu geliştirdiler (Kosheleva ve ark 1998). Panetta ve arkadaşları köşe koruyan karşıtlık güçlendirme tekniğini kullandılar (Panetta ve ark 2008). Chen ve arkadaşları 2006'da optimize edilmiş görüntülü güçlendirme metodunu geliştirdiler (Chen ve ark 2006). Bu çalışmaların dışında ayrıca uzaysal bant geçiren filtre ve keskinleştirme maskeleri de geliştirilen teknikler arasında sayılabilir.

Yukarıda bahsedilen metotlar gayet güçlü ve başarılıdır fakat beyin MRG görüntüleri üstünde çalışılırken tüm teknikler her zaman istenilen başarıyı sağlamayabilir çünkü beyin MRG görüntülerinin bazı özel durumları vardır. Örneğin kemik ve yağ dokusunun yoğunluk seviyeleriyle beyin dokusunun yoğunluk seviyeleri birbirlerine yakın olduğu için kafatası dokusunun etkileri incelenecek olan dokuyu bozabilir bu yüzden, güçlendirme işleminde ekstra dikkat gerektiren durumlar oluşabilir (Vovk ve ark 2007).

Bir başka sorun da MRG görüntülerini elde ederken kullanılan çekim teknikleridir. Örneğin aynı dokunun yoğunluk değerleri T1 T2 ve FLAIR çekim tekniklerinde farklı değerlere sahip olur. Dolayısıyla bir karşıtlık güçlendirme metodu T1 tekniğinde güçlü olurken başka bir metot FLAIR tekniğinde başarılı sonuç verebilir. Bu çeşit sorunların üstesinden gelmek için özelleştirilmiş karşıtlık güçlendirme teknikleri geliştirilmiştir Örneğin Khademi ve arkadaşlarının geliştirdiği otomatik karşıtlık güçlendirme tekniği özellikle görüntülerde kullanılır (Khademi ve ark 2009). Yang ve Arkadaşları yerel histogram eşitleme tekniğini kullanmışlardır (Yang ve ark 2007). Vidaurrazaga ve Arkadaşları dalgacık dönüşümü kat sayılarının doğrusal harmanlaması tekniğini kullanmışlardır (Vidaurrazaga ve ark 2000).

Algoritma geliştirilirken, PD, T1 ve T2 biçimindeki görüntüleri güçlendirebilen bir yöntem ortaya koymak amaçlanmıştır. Yöntem histogramın çeşitli bölgeleri üstüne yoğunlaşır. Yalnızca bir tek kaynak görüntüden yeni görüntüler türeterek, bu görüntüler üstünde uzaysal filtrelemeler yapar. Türetilen yeni görüntüleri doğrusal harmanlama tekniğiyle birleştirerek son görüntüyü elde eder. Yöntemde kullanılan doğrusal harmanlama

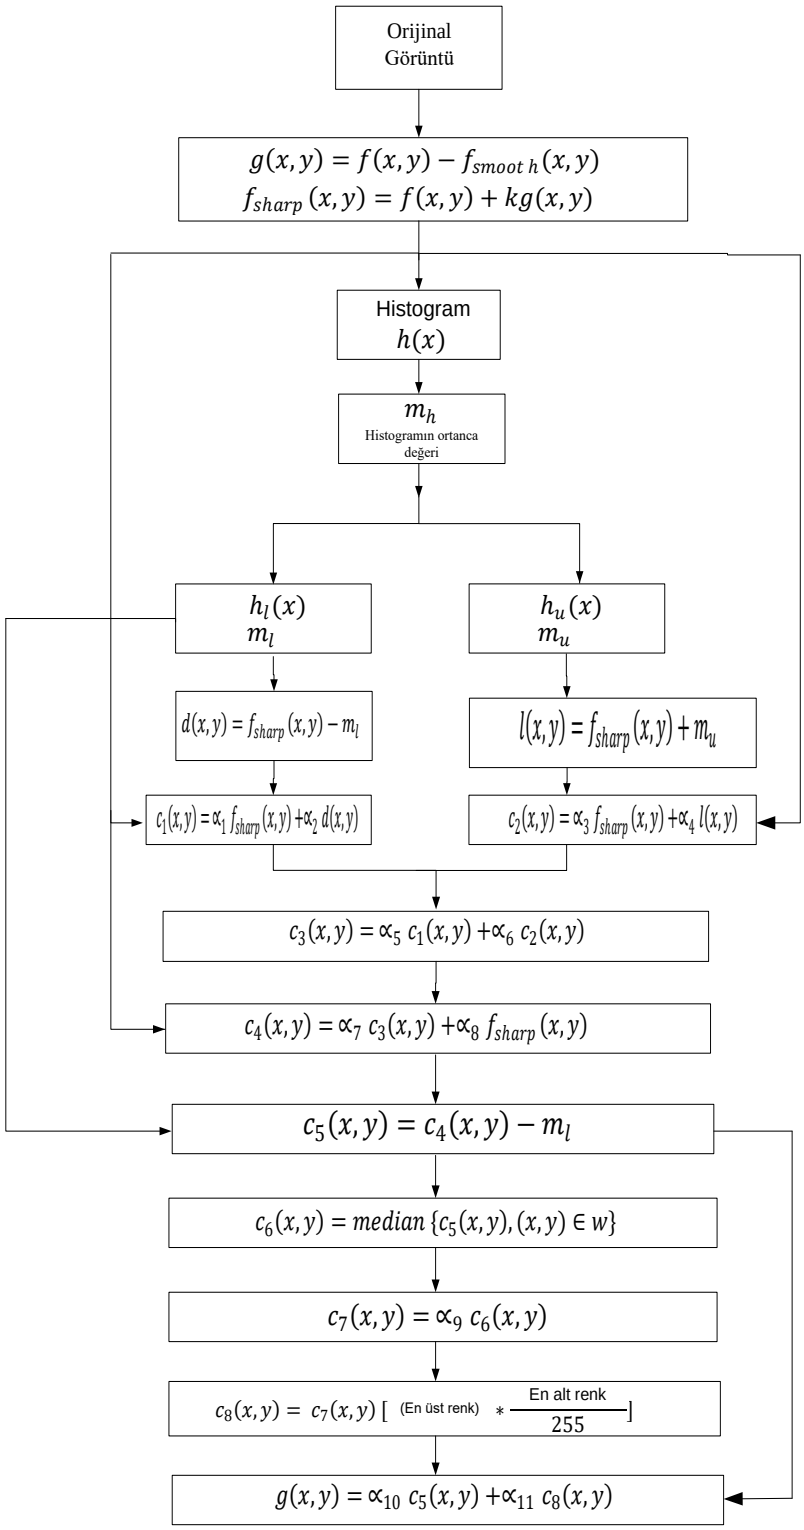
katsayıları Karaboğa ve Arkadaşları tarafından geliştirilen yapay arı koloni algoritması (Karaboga ve Akay 2009, Karaboga ve ark 2012, Akay ve Karaboga 2015) ile hesaplanmıştır. Güçlendirme algoritmasının başarısı dört genel ölçüm tekniği ile değerlendirilmiştir bunlar PSNR, EME, AMBE ve CIR'dir.

6.3.1 Metodoloji

Hastalık teşhisinde MRG görüntülerinin tanımlanabilirlik ve ayrılabilirlik değerleri çok büyük önem taşır. Teşhis ve analiz sürecinde görüntünün son ulaştığı nokta genellikle insan görsel sistemi ya da otomatik teşhis yapılıyorsa bir bilgisayar destekli teşhis sistemidir. Bu çalışmada görüntünün tanımlanabilirlik, ayrılabilirlik değerlerinin görüntünün karşıtlık değeri kullanılarak düzeltilmesi ve teşhisin daha rahat yapılması amaçlanmıştır.

Görüntü güçlendirme alanında pek çok algoritma mevcuttur. Bu algoritmalar şu başlıklar altında toplanabilir: histogram temelli güçlendirme, meta-sezgisel algoritmalar ile görüntü güçlendirme (Karnan ve ark 2006), bölgesel güçlendirme (Morrow ve ark 1992). Bu çalışmada histogram ayarlama tekniği kullanılmıştır.

Sunulan doğrusal harmanlama ile karşıtlık güçlendirme algoritması (CEULICA) 19 adımdan oluşur (Yilmaz ve Ozbay 2014). Algoritma 8 bitlik [0,255] arası gri değerli görüntüye, bu 19 adım uyguladıktan sonra yine aynı formatta bir çıkış görüntüsü vermektedir. Algoritmanın akış diyagramı Şekil 6.8'de gösterildiği gibidir.



Şekil 6.8 CEULICA algoritmasının akış diyagramı

Algoritmada uygulanan adımlar Eşitlik 6.16 - 6.34 ile ifade edildiği gibidir. Eşitliklerdeki tüm görüntüler 2B matrisler olarak tanımlıdır. Giriş görüntüsü g(x,y) olarak ifade edilir, ara işlemlerdeki görüntüler c(x,y) , çıkış görüntüsü ise g'(x,y) olarak tanımlanmıştır.

$$g(x,y) = f(x,y) - f_{smooth}(x,y) \tag{6.16}$$

$$f_{sharp}(x,y) = f(x,y) + kg(x,y) \tag{6.17}$$

burada "k", 0.2 – 0.7 arasında değişen bir skala katsayısıdır.

Bu aşamadan sonra algoritma keskinleştirilmiş görüntünün ortanca değerini ve gerekli diğer katsayıları hesaplar. Bu aşamalar aşağıdaki gibidir:

1. Keskinleştirilmiş görüntünün histogramı $h(x)$ olarak tanımlıdır
2. m_h,$h(x)$ in ortanca değerinin indeks değeridir.
3. $h_l(x)$, $h(x)$ içerisindeki, m_h den düşük değerleri ifade eder.
4. $h_u(x)$, $h(x)$ içerisindeki, m_h den yüksek değerleri ifade eder.
5. m_u,$h_u(x)$ in ortanca değerinin indeks değeridir.
6. m_l, $h_l(x)$ortanca değerinin indeks değeridir.
7. $d(x,y) = f_{sharp}(x,y) - m_l$
8. $l(x,y) = f_{sharp}(x,y) + m_u$

Daha önceki bölümlerde bahsedilen görüntü işleme teknikleri sayesinde, algoritma ile işlem sırasında kullanmak üzere yeni görüntüler üretilir. Bu görüntülerden $d(x,y)$, $f_{sharp}(x,y)$ görüntüsünün koyulaştırılmış halidir ve $l(x,y)$ ise aynı görüntünün parlaklaştırılmış halidir. Bu iki görüntüden faydalanarak, algoritma ile doğrusal harmanlama yöntemiyle yeni bir görüntü kümesi elde edilir.

$$c_1(x,y) = \propto_1 f_{sharp}(x,y) + \propto_2 d(x,y) \tag{6.18}$$

$$c_2(x,y) = \propto_3 f_{sharp}(x,y) + \propto_4 l(x,y) \tag{6.19}$$

$$c_3(x,y) = \propto_5 c_1(x,y) + \propto_6 c_2(x,y) \tag{6.20}$$

$$c_4(x,y) = \propto_7 c_3(x,y) + \propto_8 f_{sharp}(x,y) \tag{6.21}$$

$$c_5(x,y) = c_4(x,y) - m_l \tag{6.22}$$

$$c_6(x,y) = median\,(c_5(x,y), (x,y) \in w) \tag{6.23}$$

$$c_7(x,y) = \propto_9 c_6(x,y) \tag{6.24}$$

$$c_8(x,y) = c_7(x,y)\ [\ (en\ üst\ renk\ değeri) * \frac{En\ alt\ renk\ değeri}{255}] \quad (6.25)$$

$$g'(x,y) = \propto_{10} c_5(x,y) + \propto_{11} c_8(x,y) \quad (6.26)$$

Elde edilen son çıkış görüntüsü $g(x,y)$ ile elde edilir, burada w(x,y) noktası etrafındaki komşuluğu ifade eder. $[\propto_1, \propto_2, \ldots \propto_{11}]$ katsayıları, doğrusal harmanlama katsayıları olarak adlandırılır ve Yapay Arı Kolonisi Algoritması (Artificial Bee Colony Algorithm - ABC) kullanılarak elde edilmiştir (Karaboga ve Akay 2009, Karaboga ve ark 2012, Akay ve Karaboga 2015).

Sunulan bu algoritmanın en önemli kısım doğrusal harmanlama katsayılarını tespit etmektir. Çalışmanın sonucunda görülmüştür ki her bir MRG çekim tekniği için ayrı bir katsayı kümesi elde edilmelidir. Optimizasyon sürecinde uygunluk fonksiyonu olarak Evrensel görüntü kalite indeksi değeri (Universal Image Quality Index -UIQI) kullanılmıştır (Wang ve Bovik 2002, Mrak ve ark 2003, Sundaram ve ark 2011).

6.3.2 Doğrusal harmanlama katsayılarının tespiti

Algoritma uygun ve etkin bir karşıtlık güçlendirme işlemini gerçekleştirmek için bazı önceden hesaplanmış katsayılara ihtiyaç duyar. Bu amaçla yapay arı koloni algoritması en uygun doğrusal harmanlama katsayılarını bulmak için kullanılmıştır.

Algoritmanın akış diyagramından da görüldüğü gibi 11 adet doğrusal harmanlama katsayısını ihtiyaç duyulmaktadır. Bu katsayılar sonuçta elde edilen görüntünün kalitesini etkileyeceğinden uygun bir şekilde seçilmelidir. Algoritmanın geliştirilmesi aşamasında katsayı bulma işlemi arama uzayında uygun sonucu bulma problemi olarak ele alınmıştır. Algoritmanın hassas yapısı katsayıları dikkatli bir şekilde seçilmesini gerektirir çünkü her bir katsayı diğer katsayıları etkilemektedir. Dolayısıyla arama algoritmasının komşuluk ilişkilerine bağlı bir algoritma olması arama işleminin kalitesini arttıracaktır. Bu amaçla yapay arı koloni algoritması tercih edilmiştir.

Her arama işleminden sonra bulunan değerlerle fonksiyonun başarısını ölçmek için bir uygunluk fonksiyonuna ihtiyaç duyulmaktadır. Uygunluk fonksiyonu arama görevine göre değişiklik gösterir ve her problem için özel olarak tanımlanır. Bu tez çalışmasında evrensel görüntü kalite endeksi (UIQI), uygunluk fonksiyonu olarak kullanılmıştır (Wang ve Bovik 2002, Mrak ve ark 2003, Sundaram ve ark 2011). Evrensel görüntü kalite endeksi aşağıdaki gibi tanımlanır.

$x = \{x_i | i = 1,2,...,N\}$ ve $y = \{y_i | i = 1,2,...,N\}$

$$Q = \frac{4\sigma_{xy}\bar{x}\bar{y}}{(\sigma^2{}_x + \sigma^2{}_y)\left[(\bar{x})^2 + (\bar{y})^2\right]} \quad (6.27)$$

$$\bar{x} = \frac{1}{N}\sum_{i=1}^{N} x_i \quad , \quad \bar{y} = \frac{1}{N}\sum_{i=1}^{N} y_i \quad (6.28)$$

$$\sigma^2{}_x = \frac{1}{N-1}\sum_{i=1}^{N}(x_i - \bar{x})^2 \quad \sigma^2{}_y = \frac{1}{N-1}\sum_{i=1}^{N}(y_i - \bar{y})^2 \quad , \quad (6.29)$$

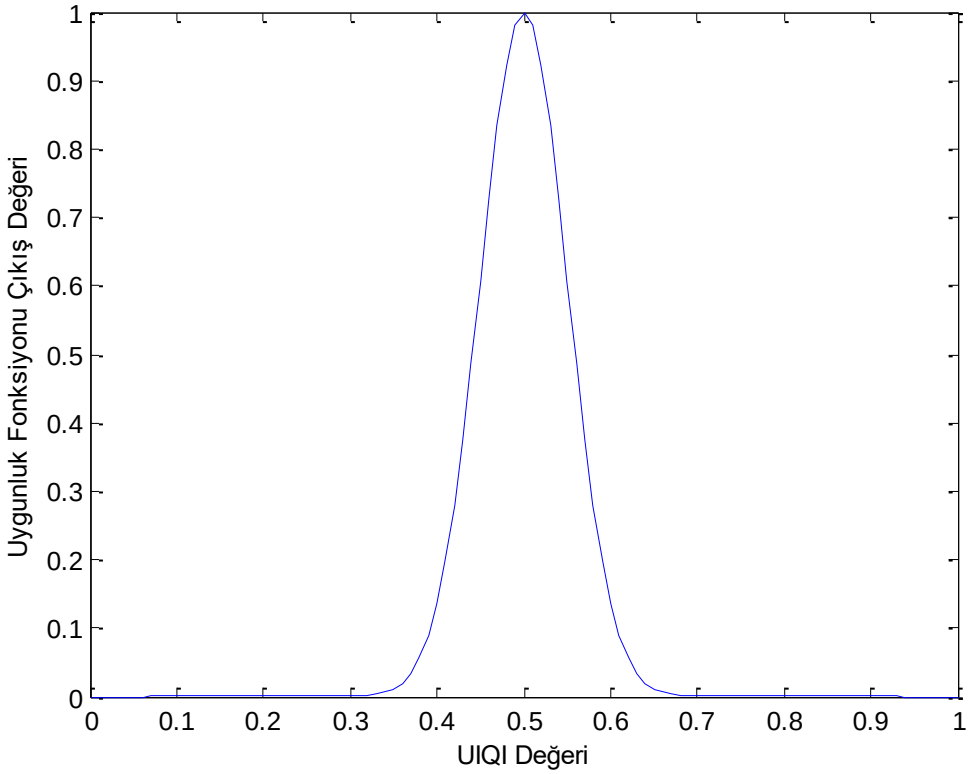
$$\sigma^2{}_{xy} = \frac{1}{N-1}\sum_{i=1}^{N}(x_i - \bar{x})(y_i - \bar{y}) \quad (6.30)$$

(6.31)

UIQI fonksiyonu güçlendirilmiş ve orijinal görüntüleri parametre olarak alır. Ölçüm sonucunda [0-1] aralığında bir karşılaştırma değeri üretir. Burada "0" karşılaştırılan görüntülerin tamamen farklı olduğunu "1" ise karşılaştırılan görüntüleri birebir aynı olduğunu ifade eder. Değeri 1' e yakın olan sonuçlar, güçlendirmenin yeterince başarılı olmadığını, 0'a yakın olanlar ise görüntünün tamamen bozulduğunu ifade eder. Çalışmada deneylere dayalı olarak, (0,45 - 0,55) arası UIQI değerlerinin üstünde çalışılan veri seti için optimum değerlerin olduğu görülmüştür. Uygunluk fonksiyonunun son değeri, UIQI fonksiyonunun çıkış değerini [0-1] aralığında tanımlı bir Gauss penceresinden geçirilmesi ile elde edilmiştir. Pencereleme işleminde kullanılan Gauss fonksiyonu aşağıdaki gibi tanımlanmıştır:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-(x-\mu)^2/(2\sigma^2)} \quad (6.32)$$

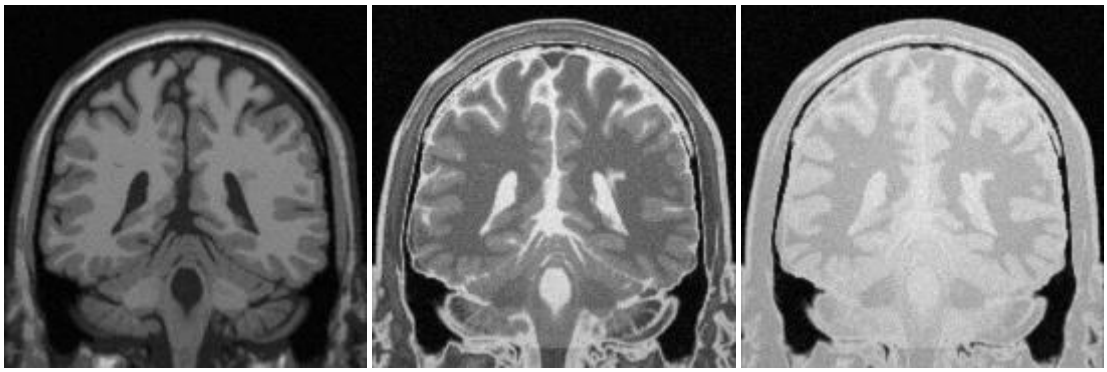
formülde, "e" Euler sayısını, "σ" standart sapmayı, "μ" ortalama değeri, "x" ise Gauss dağılımındaki değeri bulunacak olan sayıyı ifade eder. Fonksiyonun grafik gösterimi şekil 6.9'daki gibidir:



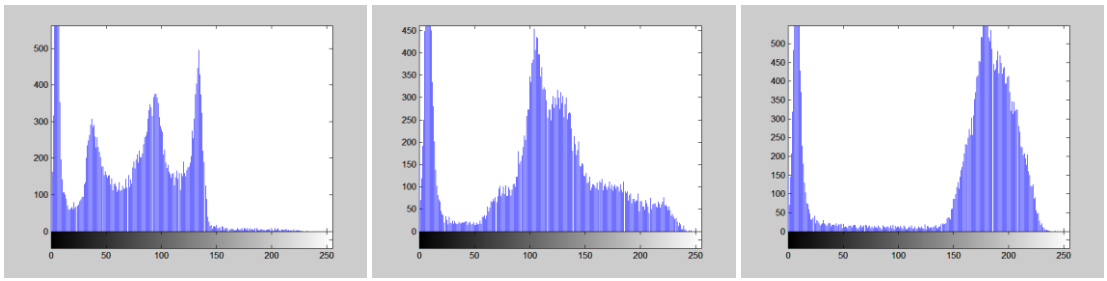
Şekil 6.9 Uygunluk Fonksiyonunun Çıkış Grafiği

6.3.3 CEULICA algortiması ile beyin görüntülerinin güçlendirilmesi

Farklı MRG çekim teknikleri ile elde edilen görüntüler bu çekim tekniklerine bağlı olarak değişik görüntü yoğunluk özelliklerine sahip olurlar. Örneğin Şekil 6.10'daki üç görüntü aynı dilimin sırasıyla T1, T2 ve PD teknikleriyle elde edilmiş halini göstermektedir. Görüntüler BrainWeb MRG görüntü veri tabandan elde edilen benzetim yapılmış görüntülerin 86. dilimidir (BrainWeb , Kwan ve ark 1996, Collins ve ark 1998, Kwan ve ark 1999). Şekil 6.10'daki (d,e,f) grafikleri sırasıyla yine aynı görüntülerin histogramlarını göstermektedir. Histogramlardan da görüldüğü gibi, görüntüler aynı dilimden elde edilmiş olsa da farklı özelliklere sahiptir.



(a) (b) (c)



(d) (e) (f)

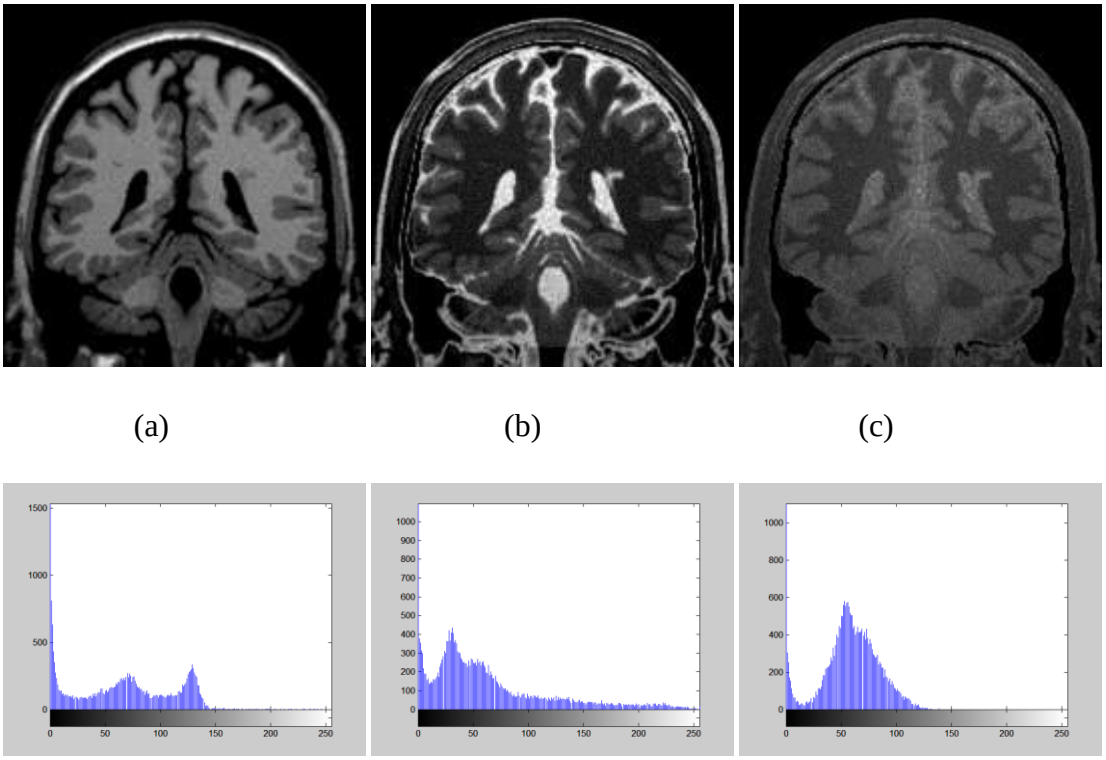
Şekil 6.10 BrainWeb MRG görüntüsünün 86. diliminin (a) T1, (b) T2 ve (c) PD versiyonları ve yine aynı görüntülerin histogramları (d), (e) ,(f)

Deneysel çalışmalarda BrainWeb veri tabanından alınan T1, T2, PD görüntüleri ile MIDAS veri tabanından alınan T1-MP-RAGE, T1-FLASH ve T2 yöntemi ile elde edilmiş görüntüler kullanılmıştır. Çalışmada görülmüştür ki, CEULICA algoritması, farklı görüntüleme teknikleri için farklı katsayı dizilerine ihtiyaç duyar. Dolayısıyla ABC algoritması kullanılarak her çekim tekniği için ayrı katsayı setleri üretilmiştir.

Veri setlerinin oluşturulmasından sonra, 2 ayrı durum çalışması yapılarak, algoritma başarısı ölçülmüştür. Bu çalışmalar sırasında veri tabanlarındaki görüntülerin, tüm dilimleri teker teker CEULICA algoritmasıyla işlenerek, güçlendirilmiş verilerden oluşan yeni bir veri seti oluşturulmuş daha sonra da ölçüm algoritmalarıyla analiz edilmiştir. Çalışma sırasında BrainWeb veri tabanından elde edilen T1, T2 ve PD görüntüleri MIDAS veri tabanındaki National Alliance for Medical Image Computing (NAMIC) setinden elde edilen T1-MP-RAGE, T1-FLASH, ve T2 görüntüleri kullanılmıştır (Bullitt ve ark 2005) .

CEULICA algoritmasının güçlendirme sonuçları örneği Şekil 6.11'de gösterilmiştir. şekilde BrainWeb veri tabanından alınan görüntü setinin 86. diliminin CEULICA algoritması sonuçları gösterilmiştir. Güçlendirilmiş görüntünün T1, T2 ve PD çekim teknikleriyle elde

edilmiş halleri sırasıyla Şekil 6.11 (a,b,c) olarak gösterilmiş, yine aynı görüntülerin histogramları sırasıyla Şekil 6.11 (d,e,f,) olarak gösterilmiştir.



(a) (b) (c)

(d) (e) (f)

Şekil 6.11 BrainWeb MRG görüntüsünün 86. diliminin CEULICA ile güçlendirilmiş hali (a) T1, (b) T2 ve (c) PD versiyonları ve yine aynı görüntülerin histogramları (d), (e) ,(f)

Algoritma her bir çekim tekniği için ayrı katsayı dizilerine ihtiyaç duymaktadır, çalışma sırasında bulunan katsayı setleri aşağıdaki gibi olmuştur:

T1 (BrainWeb), T1-MP-RAGE ve T1-FLASH (MIDAS – NAMIC veri tabanı) çekim teknikleri için katsayı dizisi:

$$\propto = [-1.336, 0.1359, -0.7102, 0.2326, 0.2647, 2, -0.216, 0.988, 0.5409, -0.264, 0.1186\ ] \quad (6.33)$$

T2 (BrainWeb ve MIDAS-NAMIC) çekim tekniği için katsayı dizisi:

$$\propto = [-0.121, 0.5576, -0.983, -2, 1.498, 0.509, -0.249, 1.362, 0.539, -0.7227, -0.4607] \quad (6.34)$$

PD (BrainWeb) çekim tekniği için katsayı dizisi:

$$\propto = [1.995, -1.093, -0.976, 0.9074, 0.811, -0.426, 1.063, -0.012, -1.077, -1.7649, 1.649] \quad (6.35)$$

Her katsayı dizisi üretildiği çekim tekniğine göre özelleşmiştir. Bu çalışmada T1, T2 ve PD teknikleri için diziler elde edilmiş olsa da, diğer teknikler için de yeni dişiler elde etmek mümkündür. T1 için oluşturulan diziler, T1-FLASH ve T1-MP-RAGE teknikleri için de kullanılabilir.

6.3.4 CEULICA algoritması deneysel sonuçları

Bu çalışmanın ana amacı beyin MRG görüntülerinin güçlendirilerek sınıflandırma ve bölütleme gibi aşamalara hazır hale getirmektir. Genel olarak yapılan işlemi arka plan gürültüsünün yoğunluk değerinin bastırılırken, gerekli bilgiyi içeren bölgenin güçlendirilmesi olarak özetlemek mümkündür, aynı zamanda bazı durumlarda uygun katsayı değerleri bulunarak özel bir dokunun daha belirgin hale getirilmesi de CEULICA algoritması ile mümkündür.

Ölçüm sürecinde ilk çalışmada BrainWeb simule edilmiş beyin görüntüsü veri tabanı kullanılmıştır. BrainWeb veri tabanı genel kullanıma açık üç boyutlu beyin görüntüleri içern çevrimiçi bir veri tabanıdır. Veri tabanı McGill Üniversitesinin McConnell Brain Imaging Center of the Montreal Neurological Institute tarafından sağlanmaktadır. Çalışmada kullanılan veri 1-mm dilim kalınlığına, %3 gürültü değerine ve %20 bozulma değerine sahiptir. Veriler T1 ağırlıklı, T2 ağırlıklı ve PD MRG görüntü alt dizilerini içermektedir. Her alt dizi 181×217×181 voksellik bir küp olarak kaydedilmiştir. Algortimanın başarı ölçümlerini yapmak için, her veri 181 adet 181×217 piksel çözünürlüğündeki görüntülere dönüştürülmüştür. Elde edilen bu 181 görüntünün her biri diğerlerinden farklıdır, dolayısıyla her bir görüntünün histogramı da farklı olacaktır. Öte yandan görüntüler aynı veri kümesinden üretildiği için her görüntü aynı çekim tekniği özelliklerini taşımaktadır.

İkinci çalışmada MIDAS – NAMIC veri tabanından faydalanılmıştır. Veri tabanı gönüllülerden elde edilen MRG görüntülerini içermektedir. Görüntüler 3 Teslalık MRG cihazı ile standart protokollerle elde edilmiş $1\times1\times1$ mm^3 voksel hassasiyetindeki T1 ve T2, çekim tipindeki MRG görüntüleridir. Bu çalışmada T1-FLASH, T1-MP-RAGE ve T2 görüntüleri kullanılmıştır.

Çalışmada sunulan algoritmanın başarısını ölçmek için dört ayrı güçlendirme ölçme algoritmasından faydalanılmıştır, bunlar Enhancement Measure (EME), Absolute Mean Brightness Error (AMBE), Peak Signal to Noise Ratio (PSNR) (Wang ve Bovik 2002, Mrak ve ark 2003, Sundaram ve ark 2011) ve Contrast Improvement Ratio (CIR) (Khademi ve ark 2009) algoritmalarıdır.

Bu ölçüm algoritmaları şu şekilde ifade edilebilir:

Enhancement Measure (EME):

$$EME(\hat{f}) = EME_{\Phi}(\hat{f}) = \frac{1}{k^2}\sum_{m=1}^{k}\sum_{n=1}^{k} 20\log_2 \frac{\max(\hat{f}[m,l])}{\min(\hat{f}[m,l])} \tag{6.36}$$

Absolute Mean Brightness Error (AMBE):

$$AMBE = \left|E(X) - E(Y)\right| \tag{6.37}$$

Universal Image Quality Index (UIQI):

$$x = \{x_i | i = 1,2,...,N\} \text{ ve } y = \{y_i | i = 1,2,...,N\} \tag{6.38}$$

$$Q = \frac{4\sigma_{xy}\bar{x}\bar{y}}{(\sigma^2{}_x + \sigma^2{}_y)\left[(\bar{x})^2 + (\bar{y})^2\right]} \tag{6.39}$$

$$\bar{x} = \frac{1}{N}\sum_{i=1}^{N} x_i \quad , \quad \bar{y} = \frac{1}{N}\sum_{i=1}^{N} y_i \tag{6.40}$$

$$\sigma^2{}_x = \frac{1}{N-1}\sum_{i=1}^{N}(x_i - \bar{x})^2 \quad \sigma^2{}_y = \frac{1}{N-1}\sum_{i=1}^{N}(y_i - \bar{y})^2 \tag{6.41}$$

$$\sigma^2{}_{xy} = \frac{1}{N-1}\sum_{i=1}^{N}(x_i - \bar{x})(y_i - \bar{y}) \tag{6.42}$$

Contrast Improvement Ratio (CIR) :

$$CIR = \frac{\sum_{(x,y)\in R}|c(x,y) - \tilde{c}(x,y)|^2}{\sum_{(x,y)\in R} c(x,y)^2} \tag{6.43}$$

CIR yüzde olarak ifade edilir ve $c(x,y)$, $\tilde{c}(x,y)$ sırasıyla güçlendirmeden önceki ve sonraki yerel karşıtlık değerleridir. Yerel karşıtlık değeri $C(x,y)$ Eşitlik 6.44'deki gibi hesaplanır:

$$C(x,y) = \frac{|p-a|}{p+a} \tag{6.44}$$

eşitlikte p ve a sırasıyla seçilen bölgeyi ortasına alan (3×3)'lük ve (7×7)'lik matrislerin ortalama değerleridir.

Peak Signal to Noise Ratio (PSNR):

PSNR değerini hesaplamak için, önce ortalama kare hatası(mean-squared error) hesaplanmalıdır, MSE Eşitlik 6.35'deki gibi hesaplanır:

$$MSE = \frac{\sum_{M,N}[I_1(m,n) - I_2(m,n)]^2}{M \cdot N} \tag{6.45}$$

eşitlikte M ve N sırayla hesaplanacak görüntünün satın ve sütun değerlerini ifade eder.

Ölçülecek görüntünün PSNR değeri Eşitlik 6.36'daki gibi hesaplanır:

$$PSNR = 10 \log_{10} \left(\frac{R^2}{MSE} \right) \tag{6.46}$$

eşitlikte R görüntüde bir pikselin alabileceği maksimum değeri ifade eder, bu değer 8 bitlik gri seviyeli görüntüler için R = 255'dir.

Bu karşılaştırma ölçütlerinin sonuçları şu şekilde yorumlanabilir:

Yüksek EME değerleri aşırı güçlendirme ve yerel bilgi kaybı manasına gelmektedir. Öte yandan çok düşük EME değerleri lezyonlar gibi ilk bakışta görülmeyen bölgelerin yeterince güçlenmediğini ve kaybedildiğini gösterir (Sundaram ve ark 2011).

Çok düşük AMBE değerleri karşıtlık güçlendirmede düşük bir performans sergilendiğini gösterir (Sundaram ve ark 2011). Bu değerin ortalama seviyelerde tutulması başarılı bir güçlendirme yapıldığını göstermektedir.

PSNR değeri orijinal görüntü ile güçlendirilmiş görüntü arasında karşılaştırma yaparak elde edilir, yüksek PSNR değerleri gürültü giderilirken görüntüde az bozulma olduğunu ifade eder. Genel olarak yüksek PSNR değeri yüksek görüntü kalitesini ifade eder, fakat bu çalışmada yüksek değerler düşük güçlendirmeyi ve düşük değerler görüntünün güçlendirildiği sırada bozulduğunu gösterir.

Karşıtlık güçlendirme oranı (CIR)orijinal görüntü ile güçlendirilmiş görüntü arasındaki güçlendirme oranını ifade eder. Yüksek değerler, yüksek güçlendirme kalitesini ifade eder (Khademi ve ark 2009).

Güçlendirme başarısının karşılaştırılmasında kullanılan algoritmalar Karşıtlık Limitli Adaptif Histogram Eşitleme (Contrast Limited Adaptive Histogram Equalization (CLAHE)), Histogram Eşitleme (Histogram Equalization (HE)), Unsharp Mask (US). Yöntemleri formülleri aşağıdaki Eşitliklerde verildiği gibidir:

Unsharp Maskesinin matris yapısındaki ifadesi:

$$f(\alpha)=\frac{1}{\alpha+1}\begin{bmatrix} -\alpha & \alpha-1 & -\alpha \\ \alpha-1 & \alpha+5 & \alpha-1 \\ -\alpha & \alpha-1 & -\alpha \end{bmatrix} \tag{6.47}$$

Contrast Limited Adaptive Histogram Equalization (CLAHE):

$$g=\left[g_{\max}-g_{\min}\right]p(f)+g_{\min} \tag{6.48}$$

burada g_{max} maksimum piksel değeri, g_{min} minimum piksel değeri, g hesaplanan piksel değeri, $p(f)$ kümülatif olasılık dağılım fonksiyonunu göstermektedir.

Histogram eşitleme (HE):

$$p_n=\frac{\text{yogunluk degerindeki piksel sayısı}}{\text{toplam piksel sayısı}} \qquad n = 0, 1, ..., L - 1. \tag{6.49}$$

Histogram eşitlenmiş görüntü şu şekilde tanımlanır:

$$g_{i,j}=floor((L-1)\sum_{n=0}^{f_{i,j}}p_n \tag{6.50}$$

6.3.5 Deney 1

İlk çalışmada CEULICA algoritmasının performansı, BrainWeb veri tabanından elde edilen görüntüler kullanılarak ölçülmüştür. BrainWeb veri tabanından alınan görüntüler koronal düzlemde incelenmiştir, dilimler başın ön tarafından başlayarak arkaya doğru artan numaralarla ilerler. Yüksek dilim numarası inferior bölgeden görüntü alındığı manasına gelir.

Çizelge 6.2, 6.3 ve 6.4, CLAHE, HE, USM ve CEULICA algoritmalarının performans ölçüm sonuçlarını göstermektedir. Her bir çizelge farklı çekim teknikleri kullanılarak (T1, T2 ve PD) elde edilmiştir. Satırlar algoritmaların performans sonuçlarını sütunlar ise CIR, EME, AMBE ve PSNR puanlarını göstermektedir. BrainWeb veri tabanındaki veriler 181 adettir ve her biri güçlendirme algoritmalarıyla güçlendirilerek sonuçlar elde edilmiştir. Çizelgelerin boyunu kısa tutmak amacıyla sadece bazı dilim numaralarına karşılık gelen sonuçlar ve tüm veri tabanının ortalama sonuçları çizelgede gösterilmiştir. Çizelge 6.2 BrainWeb veri tabanından T1 çekim tekniğiyle elde edilmiş 1-mm dilim kalınlığı, %3 gürültü ve %20

bozulma değerlerine sahip görüntülerin ölçüm sonuçlarını göstermektedir. Görüntüler 181×217 piksel çözünürlüğünde 181 dilimden oluşur.

Çizelge 6.2 BrainWeb T1 görüntü kümesi ölçüm sonuçları

Dilim Numarası	CIR				EME				AMBE				PSNR			
	CLAHE	*HE*	*US*	*CEULICA*	*CLAHE*	*HE*	*US*	*CEULICA*	*CLAHE*	*HE*	*US*	*CEULICA*	*CLAHE*	*HE*	*US*	*CEULICA*
1	0,016	1,431	0,006	1,000	9,329	22,546	18,907	0,000	12,929	122,562	0,003	4,938	25,583	5,131	50,092	33,939
2	0,015	1,498	0,007	1,000	9,366	23,097	18,772	0,000	12,896	122,040	0,003	4,970	25,615	5,144	50,080	33,887
3	0,016	1,497	0,006	1,000	9,245	22,517	18,736	0,000	12,934	122,775	0,003	4,961	25,584	5,114	50,136	33,900
⋮																
20	0,050	0,954	0,004	9,486	9,278	15,468	15,661	2,392	23,163	106,040	0,003	6,418	18,019	6,655	48,496	24,557
21	0,052	0,872	0,004	8,839	9,401	15,260	15,869	2,887	23,759	105,454	0,003	5,679	17,835	6,724	48,374	24,350
22	0,058	0,897	0,004	8,963	9,349	14,648	15,636	2,664	24,098	105,048	0,002	6,694	17,683	6,782	48,329	24,477
⋮																
80	0,137	0,246	0,002	6,070	10,137	7,234	10,047	7,597	35,749	58,608	0,004	19,792	14,938	11,834	45,736	20,588
81	0,138	0,269	0,002	6,213	10,250	7,214	10,141	7,483	35,614	58,136	0,003	21,483	14,929	11,892	45,665	20,160
82	0,136	0,253	0,002	6,006	10,247	7,367	10,118	7,549	35,864	57,811	0,004	21,279	14,909	11,948	45,645	20,211
⋮																
160	0,116	0,453	0,002	4,827	10,835	7,663	13,102	6,868	29,334	67,023	0,004	16,032	16,600	10,998	45,427	21,667
161	0,117	0,458	0,002	4,578	10,682	7,764	12,962	6,921	29,178	67,923	0,004	14,587	16,627	10,878	45,513	22,265
162	0,116	0,502	0,002	4,450	10,561	7,929	13,160	6,729	28,927	68,577	0,004	14,142	16,696	10,786	45,658	22,401
⋮																
180	0,095	0,615	0,002	4,717	11,062	12,372	15,180	6,384	30,475	83,646	0,003	12,909	16,010	8,942	46,201	23,013
181	0,094	0,730	0,002	5,244	10,553	9,762	14,627	6,223	29,900	84,526	0,003	12,492	16,094	8,820	46,336	23,119
Ortalama	0,117	0,493	0,002	5,844	10,188	9,567	12,353	6,217	31,372	72,083	0,004	15,045	16,161	10,414	46,303	22,150

Çizelge 6.2'de görüldüğü gibi, CEULICA 5.844 CIR, 6.217 EME, 15.045 AMBE, ve 22.15 dB PSNR ortalama değerlerine sahiptir.

Çizelge 6.3 BrainWeb veri tabanından T2 çekim tekniğiyle elde edilmiş 1-mm dilim kalınlığı, %3 gürültü ve %20 bozulma değerlerine sahip görüntülerin ölçüm sonuçlarını göstermektedir. Görüntüler 181×217 piksel çözünürlüğünde 181 dilimden oluşur.

Çizelge 6.3 BrainWeb T2 görüntü kümesi ölçüm sonuçları

Dilim Numarası	CIR				EME				AMBE				PSNR			
	CLAHE	*HE*	*US*	*CEULICA*	*CLAHE*	*HE*	*US*	*CEULICA*	*CLAHE*	*HE*	*US*	*CEULICA*	*CLAHE*	*HE*	*US*	*CEULICA*
1	0,016	1.431	0,006	**1,000**	9,329	22,546	18,907	**0,000**	12,929	122,562	0,003	**4,938**	25,583	5,131	50,092	**33,939**
2	0,015	1.498	0,007	**1,000**	9,366	23,097	18,772	**0,000**	12,896	122,040	0,003	**4,970**	25,615	5,144	50,080	**33,887**
3	0,016	1.497	0,006	**1,000**	9,245	22,517	18,736	**0,000**	12,934	122,775	0,003	**4,961**	25,584	5,114	50,136	**33,900**
...																
20	0,050	0,954	0,004	**8,665**	9,278	15,468	15,661	**4,631**	23,163	106,040	0,003	**5,756**	18,019	6,655	48,496	**15,256**
21	0,052	0,872	0,004	**8,325**	9,401	15,260	15,869	**4,939**	23,759	105,454	0,003	**5,290**	17,835	6,724	48,374	**15,077**
22	0,058	0,897	0,004	**8,186**	9,349	14,648	15,636	**5,203**	24,098	105,048	0,002	**5,609**	17,683	6,782	48,329	**14,883**
...																
80	0,137	0,246	0,002	**3,533**	10,137	7,234	10,047	**10,800**	35,749	58,608	0,004	**16,697**	14,938	11,834	45,736	**10,763**
81	0,138	0,269	0,002	**3,750**	10,250	7,214	10,141	**11,046**	35,614	58,136	0,003	**17,175**	14,929	11,892	45,665	**10,695**
82	0,136	0,253	0,002	**3,685**	10,247	7,367	10,118	**11,079**	35,864	57,811	0,004	**17,800**	14,909	11,948	45,645	**10,637**
...																
160	0,116	0,453	0,002	**4,365**	10,835	7,663	13,102	**10,088**	29,334	67,023	0,004	**26,809**	16,600	10,998	45,427	**11,292**
161	0,117	0,458	0,002	**4,428**	10,682	7,764	12,962	**10,004**	29,178	67,923	0,004	**26,325**	16,627	10,878	45,513	**11,322**
162	0,116	0,502	0,002	**4,541**	10,561	7,929	13,160	**9,915**	28,927	68,577	0,004	**25,721**	16,696	10,786	45,658	**11,333**
...																
180	0,095	0,615	0,002	**3,826**	11,062	12,372	15,180	**9,000**	30,475	83,646	0,003	**16,209**	16,010	8,942	46,201	**12,699**
181	0,094	0,730	0,002	**4,076**	10,553	9,762	14,627	**8,739**	29,900	84,526	0,003	**15,026**	16,094	8,820	46,336	**12,807**
Ortalama	**0,117**	**0,493**	**0,002**	**4,736**	**10,188**	**9,567**	**12,353**	**9,251**	**31,372**	**72,083**	**0,004**	**17,652**	**16,161**	**10,414**	**46,303**	**12,680**

Çizelge 6.3'de de görüldüğü gibi, CEULICA algoritması 4.736 CIR, 9.251 EME, 17.652 AMBE ve 12.68 dB PSNR ortalama puanları almıştır.

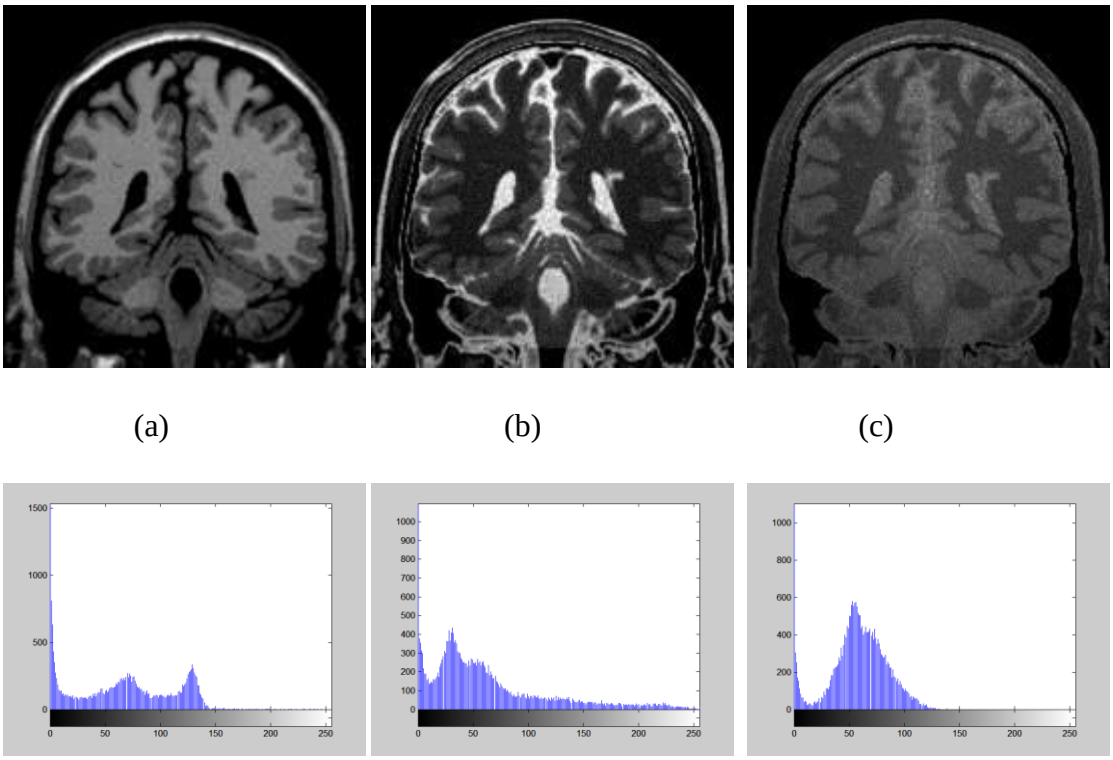
Çizelge 6.4 BrainWeb veri tabanından PD çekim tekniğiyle elde edilmiş 1-mm dilim kalınlığı, %3 gürültü ve %20 bozulma değerlerine sahip görüntülerin ölçüm sonuçlarını göstermektedir. Görüntüler 181×217 piksel çözünürlüğünde 181 dilimden oluşur.

Çizelge 6.4 BrainWeb PD görüntü kümesi ölçüm sonuçları

Dilim Numarası	CIR				EME				AMBE				PSNR			
	CLAHE	*HE*	*US*	*CEULICA*	*CLAHE*	*HE*	*US*	*CEULICA*	*CLAHE*	*HE*	*US*	*CEULICA*	*CLAHE*	*HE*	*US*	*CEULICA*
1	0,016	1,431	0,006	**1,000**	9,329	22,546	18,907	**0,000**	12,929	122,562	0,003	**4,938**	25,583	5,131	50,092	**33,939**
2	0,015	1,498	0,007	**1,000**	9,366	23,097	18,772	**0,000**	12,896	122,040	0,003	**4,970**	25,615	5,144	50,080	**33,887**
3	0,016	1,497	0,006	**1,000**	9,245	22,517	18,736	**0,000**	12,934	122,775	0,003	**4,961**	25,584	5,114	50,136	**33,900**
⋮																
20	0,050	0,954	0,004	**6,705**	9,278	15,468	15,661	**2,458**	23,163	106,040	0,003	**6,821**	18,019	6,655	48,496	**20,096**
21	0,052	0,872	0,004	**6,538**	9,401	15,260	15,869	**2,638**	23,759	105,454	0,003	**8,028**	17,835	6,724	48,374	**20,117**
22	0,058	0,897	0,004	**6,441**	9,349	14,648	15,636	**2,885**	24,098	105,048	0,002	**6,127**	17,683	6,782	48,329	**19,689**
⋮																
80	0,137	0,246	0,002	**2,643**	10,137	7,234	10,047	**5,563**	35,749	58,608	0,004	**17,644**	14,938	11,834	45,736	**15,557**
81	0,138	0,269	0,002	**2,651**	10,250	7,214	10,141	**5,619**	35,614	58,136	0,003	**22,512**	14,929	11,892	45,665	**15,140**
82	0,136	0,253	0,002	**2,524**	10,247	7,367	10,118	**5,595**	35,864	57,811	0,004	**21,879**	14,909	11,948	45,645	**15,195**
⋮																
160	0,116	0,453	0,002	**3,280**	10,835	7,663	13,102	**5,493**	29,334	67,023	0,004	**19,513**	16,600	10,998	45,427	**15,694**
161	0,117	0,458	0,002	**3,420**	10,682	7,764	12,962	**5,372**	29,178	67,923	0,004	**20,222**	16,627	10,878	45,513	**15,621**
162	0,116	0,502	0,002	**3,283**	10,561	7,929	13,160	**5,437**	28,927	68,577	0,004	**19,863**	16,696	10,786	45,658	**15,659**
⋮																
180	0,095	0,615	0,002	**3,092**	11,062	12,372	15,180	**4,775**	30,475	83,646	0,003	**12,340**	16,010	8,942	46,201	**17,399**
181	0,094	0,730	0,002	**3,338**	10,553	9,762	14,627	**4,683**	29,900	84,526	0,003	**11,747**	16,094	8,820	46,336	**17,531**
Ortalama	**0,117**	**0,493**	**0,002**	**3,594**	**10,188**	**9,567**	**12,353**	**4,871**	**31,372**	**72,083**	**0,004**	**16,209**	**16,161**	**10,414**	**46,303**	**17,211**

Çizelge 6.4'de de görüldüğü gibi, CEULICA algoritması 3.594 CIR, 4.871 EME, 16.209 AMBE, and 17.211 dB PSNR ortalama puanları almıştır.

Şekil 6.12'de BrainWeb veri tabanından alınan verinin CEULICA ile güçlendirilmiş 86. diliminin T1, T2, ve PD çekim teknikleriyle elde edilmiş görüntüsü sırasıyla Şekil 6.12 (a,b,c)'de verilmiştir. Aynı görüntülerin histogramları, yine sırasıyla Şekil 6.12 (d,e,f)'de verilmiştir.



(a) (b) (c)

(d) (e) (f)

Şekil 6.12 BrainWeb MRG görüntüsünün 86. diliminin CEULICA ile güçlendirilmiş hali (a) T1, (b) T2 ve (c) PD versiyonları ve yine aynı görüntülerin histogramları (d), (e) ,(f)

6.3.6 Deney 2

İkinci çalışmada, CEULICA algoritmasının başarısı MIDAS-NAMIC veri tabanından alınan görüntülerle ölçülmüştür. MIDAS-NAMIC veri tabanından alınan, 186 MRG taraması bu amaçla seçilmiştir (Bullitt ve ark 2005). Çizelge 6.5, 97 gönüllüden elde edilen bu verilerin yapısını göstermektedir. Bu taramalar T1-FLASH, T1-MP-RAGE ve T2 çekim teknikleriyle elde edilmiştir. Her taramanın farklı sayıda dilim içermektedir. Dolaysıyla 186 taramadan elde edilen toplam 27.504 adet görüntü güçlendirmeye tabi tutulmuştur. MIDAS-NAMIC veri tabanından elde edilen görüntüler "MetaImage" formatında kaydedilmiş olup pikseller 12-bit'lik tamsayı değerlerle ifade edilmiştir.

Çizelge 6.5 MIDAS-NAMIC veri tabanından alınan, 186 MRG taraması

Gönüllü Numarası	T1-FLASH		T1-MP-RAGE		T2	
	Dilim Numarası	Görüntü boyutu(piksel)	Dilim Numarası	Görüntü boyutu(piksel)	Dilim Numarası	Görüntü boyutu(piksel)
3	176	176×256	NA	NA	128	192×256
4	176	176×256	NA	NA	128	192×256
20	NA	NA	NA	NA	128	192×256
21	176	176×256	NA	NA	NA	NA
27	NA	NA	NA	NA	128	192×256
28	176	176×256	128	208×256	128	192×256
29	176	176×256	128	208×256	NA	NA
30	176	176×256	NA	NA	128	192×256
31	NA	NA	128	208×256	128	192×256
32	176	176×256	NA	NA	128	192×256
34	176	176×256	128	208×256	NA	NA
37	176	176×256	128	208×256	NA	NA
41	176	176×256	128	208×256	128	192×256
42	NA	NA	128	208×256	128	192×256
43	176	176×256	128	208×256	NA	NA
46	NA	NA	128	208×256	NA	NA
47	176	176×256	128	208×256	NA	NA
49	176	176×256	128	208×256	128	192×256
50	176	176×256	128	208×256	NA	NA
53	176	176×256	NA	NA	128	192×256
54	176	176×256	128	208×256	NA	NA
56	176	176×256	NA	NA	NA	NA
59	176	176×256	NA	NA	NA	NA
60	NA	NA	128	208×256	128	192×256
62	176	176×256	NA	NA	128	192×256
66	NA	NA	128	208×256	128	192×256
69	NA	NA	128	208×256	128	192×256
72	NA	NA	NA	NA	128	192×256
73	176	176×256	NA	NA	128	192×256
74	176	176×256	160	208×256	128	192×256
75	NA	NA	160	208×256	NA	NA
76	NA	NA	160	208×256	128	192×256
80	160	176×256	160	208×256	128	192×256
82	NA	NA	160	208×256	128	192×256
83	NA	NA	160	208×256	NA	NA
86	NA	NA	NA	NA	128	192×256
88	160	176×256	NA	NA	NA	NA
89	160	176×256	160	208×256	128	192×256
90	160	176×256	160	208×256	NA	NA
91	160	176×256	NA	NA	NA	NA
96	NA	NA	NA	NA	160	392×512
97	NA	NA	160	208×256	NA	NA
100	NA	NA	160	208×256	NA	NA
101	NA	NA	160	208×256	160	392×512
102	NA	NA	NA	NA	NA	NA
103	NA	NA	160	208×256	NA	NA
106	NA	NA	160	208×256	160	392×512
107	NA	NA	160	208×256	NA	NA

Çizelge 6.6, 6.7 ve 6.8 CLAHE, HE, USM ve CEULICA algoritmalarının performans ölçüm sonuçlarını göstermektedir. Her bir çizelge farklı çekim teknikleri kullanılarak (T1, T2 ve PD) elde edilmiştir. Satırlar algoritmaların performans sonuçlarını sütunlar ise CIR, EME, AMBE ve PSNR puanlarını göstermektedir.

Tüm MIDAS-NAMIC veri tabanı (186 dosya, 27,504 görüntü dilimi) algoritmalarla işlenmiştir, fakat tablo büyüklüğünü kısa tutmak amacıyla sadece bir kısmı ve sonuçların tamamının ortalama değerleri tablolarda verilmiştir.

Çizelge 6.6 MIDAS-NAMIC verisi MP-RAGE ölçüm sonuçları

Dosya	CIR				EME				AMBE				PSNR (dB)			
	CLAHE	*HE*	*USM*	*CEULICA*	*CLAHE*	*HE*	*USM*	*CEULICA*	*CLAHE*	*HE*	*USM*	*CEULICA*	*CLAHE*	*HE*	*USM*	*CEULICA*
031-T1-MP-RAGE	0,071	0,495	0,144	0,442	45,733	36,554	3,828	18,182	19,717	88,743	3,972	0,832	20,044	8,432	21,594	37,605
⋮																
081-T1-MP-RAGE	0,067	0,467	0,150	2,905	44,479	37,920	4,488	15,847	23,304	89,977	3,400	0,943	18,488	8,353	21,948	35,860
083-T1-MP-RAGE	0,087	0,489	0,153	15,667	44,020	38,079	4,181	12,761	24,973	99,084	2,908	1,161	17,710	7,405	23,700	34,904
⋮																
100-T1-MP-RAGE	0,120	0,460	0,164	15,050	45,763	40,865	4,510	13,474	30,958	90,018	2,596	11,862	16,003	8,337	22,741	11,656
101-T1-MP-RAGE	0,134	0,511	0,171	8,982	46,370	46,131	3,505	10,270	23,716	93,615	2,898	6,758	17,946	7,873	23,167	12,917
103-T1-MP-RAGE	0,121	0,484	0,195	3,874	45,594	47,723	4,059	11,217	26,148	96,165	2,900	7,281	17,277	7,631	23,515	12,401
106-T1-MP-RAGE	0,103	0,458	0,171	17,795	46,620	38,881	4,162	14,470	30,165	94,234	2,689	12,094	16,238	7,893	23,494	11,635
Ortalama	0,115	0,430	0,171	6,983	46,359	39,848	4,708	17,356	23,858	90,459	3,509	3,514	18,717	8,281	22,254	30,157

Çizelge 6.5'de görüldüğü gibi CEULICA algoritması 6.983 CIR, 17.326 EME, 3.514 AMBE ve 30.157 dB PSNR ortalama puanları almıştır.

Çizelge 6.7 MIDAS-NAMIC verisi FLASH ölçüm sonuçları

Dosya	**CIR**				**EME**				**AMBE**				**PSNR (dB)**			
	CLAHE	*HE*	*USM*	*CEULICA*	*CLAHE*	*HE*	*USM*	*CEULICA*	*CLAHE*	*HE*	*USM*	*CEULICA*	*CLAHE*	*HE*	*USM*	*CEULICA*
023-T1-Flash	0,101	0,499	0,178	9,878	41,481	32,270	4,362	**10,572**	25,069	101,52	2,680	**1,788**	17,444	7,234	24,061	**34,482**
⋮																
085-T1-Flash	0,132	0,518	0,186	3,771	41,638	38,232	5,036	**9,245**	27,878	99,444	2,647	**5,737**	16,803	7,385	23,416	**17,552**
087-T1-Flash	0,123	0,512	0,188	3,653	43,667	38,090	4,441	**11,431**	29,091	101,02	2,658	**4,572**	16,475	7,190	23,402	**18,044**
088-T1-Flash	0,116	0,511	0,172	7,467	42,426	30,353	5,401	**11,455**	29,926	95,664	2,797	**6,699**	16,236	7,758	22,621	**18,627**
091-T1-Flash	0,104	0,405	0,174	0,146	45,213	37,731	6,329	**15,715**	35,448	92,830	3,301	**9,588**	15,056	7,996	21,731	**15,712**
093-T1-Flash	0,115	0,454	0,164	0,387	43,503	37,879	5,921	**13,329**	33,778	94,053	3,006	**8,856**	15,405	7,875	22,184	**16,049**
094-T1-Flash	0,112	0,428	0,171	0,332	44,160	40,546	5,327	**12,866**	34,732	94,561	2,992	**7,862**	15,332	7,787	22,234	**15,780**
Ortalama	**0,112**	**0,483**	**0,177**	**10,191**	**43,534**	**34,304**	**5,068**	**12,820**	**26,291**	**97,541**	**2,991**	**2,884**	**17,660**	**7,611**	**22,966**	**30,948**

Çizelge 6.7'da görüldüğü gibi, CEULICA algoritması, 10.191 CIR, 12.82 EME, 2.884 AMBE ve 30.948 dB PSNR ortalama puanları almıştır.

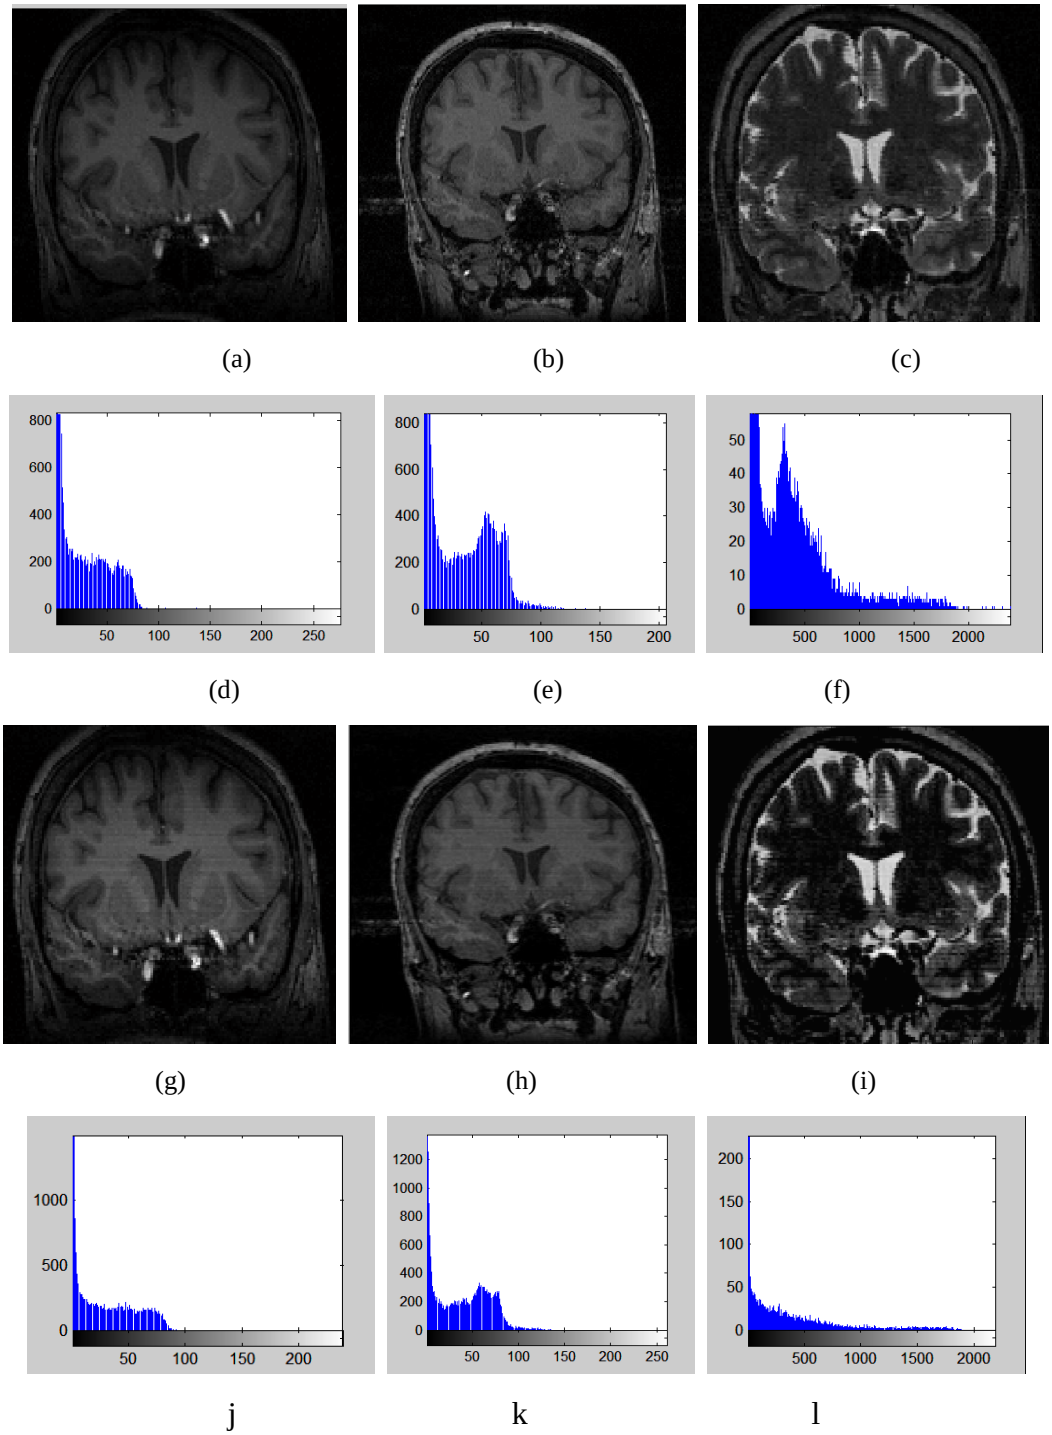
Çizelge 6.8 MIDAS-NAMIC verisi T2 ölçüm sonuçları

Dosya	**CIR**				**EME**				**AMBE**				**PSNR (dB)**			
	CLAHE	*HE*	*USM*	*CEULICA*	*CLAHE*	*HE*	*USM*	*CEULICA*	*CLAHE*	*HE*	*USM*	*CEULICA*	*CLAHE*	*HE*	*USM*	*CEULICA*
014-T2	0,859	0,361	0,244	**1,739**	46,34	87,37	2,98	**59,764**	12,33	8,973	21,7	**5,115**	8,559	26,4	2,655	**21,358**
⋮																
061-T2	0,978	0,439	0,217	**2,452**	54,52	97,44	2,41	**74,048**	11,35	7,414	21,2	**-1,232**	10,53	25,4	1,270	**20,911**
062-T2	0,860	0,421	0,185	**2,162**	82,95	88,15	2,65	**66,935**	11,01	9,255	22,4	**3,271**	8,838	30,9	1,735	**14,056**
⋮																
096-T2	0,855	0,589	0,046	**0,592**	5,034	92,63	0,83	**3,197**	32,04	8,006	28,5	**17,459**	58,33	34,9	8,105	**19,262**
099-T2	0,893	0,505	0,048	**0,813**	8,176	90,82	0,74	**5,305**	26,78	8,196	28,3	**17,776**	43,60	18,8	9,562	**21,520**
101-T2	0,856	0,575	0,049	**0,579**	5,110	97,35	0,81	**4,607**	31,58	7,545	29,2	**17,953**	58,35	36,5	7,606	**18,531**
106-T2	0,907	0,537	0,065	**0,772**	19,71	95,93	0,81	**14,693**	13,88	7,757	29,6	**15,509**	39,81	23,3	9,209	**21,669**
Ortalama	**0,937**	**0,425**	**0,205**	**2,705**	**64,71**	**94,86**	**2,59**	**73,111**	**12,04**	**7,947**	**22,2**	**2,073**	**12,68**	**30,7**	**2,777**	**20,240**

Çizelge 6.8'de görüldüğü gibi, CEULICA algoritması 2.705 CIR, 73.111 EME, 2.073 AMBE ve 20.24 dB PSNR ortalama puanları almıştır.

MIDAS-NAMIC veri tabanındaki 28. gönüllüden alınan T1-MP-RAGE, T1-FLASH ve T2 görüntülerinin 100. dilimi Şekil 6.13'de gösterilmiştir. Şekilde sırasıyla Şekil 6.13 (a,b,c)'de orijinal görüntüleri, Şekil 6.13 (d,e,f)'de orijinal görüntülerin histogramını, Şekil

6.13 (g,h,i)'de güçlendirilmiş görüntüleri, j,k,l ise güçlendirilmiş görüntülerin histogramını göstermektedir.



Şekil 6.13 CEULICA ile güçlendirme öncesi ve sonrası MRG görüntüleri a) T1-MP-RAGE, b) T1-FLASH, c) T2, d) T1-MP-RAGE histogramı, e) T1-FLASH histogramı, f) T2 histogramı, g) güçlendirilmiş T1-MP-RAGE, h) güçlendirilmiş T1-FLASH i) güçlendirilmiş T2, j) T1-MP-RAGE histogramı, k) T1-FLASH histogramı ve l) T2 histogramı

Çizelge 6.2'den çizelge 6.8'e kadar olan çizelgeler deney 1 ve deney 2'yi özetlemektedir. Elde edilen sonuçlardan da görülebileceği gibi CEULICA, ne en yüksek ne de en düşük değerleri almıştır. Ölçüm algoritmalarında optimum sonuçların alınması, güçlenme algoritmaları için istenen bir durumdur. Böylece algoritmanın verileri bozmadan güçlendirdiği sonucuna varılabilir. CEULICA algoritmasının PD görüntülerindeki başarısı diğer görüntü kümelerine göre yetersizdir. Deney 1'de, algoritma USM algoritmasına göre tüm ölçümlerde daha düşük bir PSNR puanı almıştır, bu da USM algoritmasının gürültüyü CEULICA'ya göre daha çok bastırdığını gösterir. Öte yandan Deney 2'de algoritma, diğer algoritmalara göre daha yüksek bir PSNR puanı almıştır bu da CEULICA algoritmasının MIDAS-NAMIC veri tabanında daha başarılı bir gürültü bastırma işlemi yaptığını gösterir. PSNR sonuçlarına göre CEULICA'nın MIDAS-NAMIC veri tabanında BrainWeb'e göre daha başarılı olduğu görülmüştür.

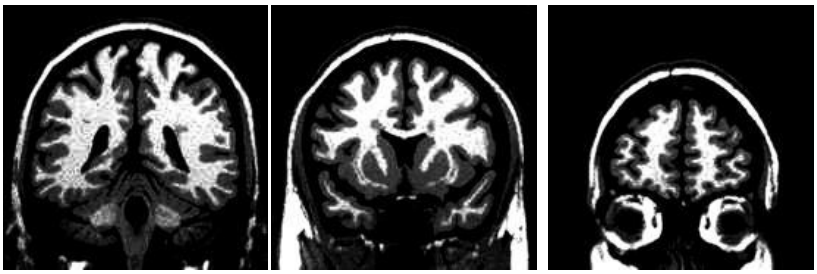
6.3.7 CEULICA algoritmasının sınıflama amacıyla kullanımı

Deneyler sırasında CEULICA'nın bir getirisi daha olduğu görülmüştür. Algoritma, güçlendirmenin yanı sıra bazı sınıflama işlemleri için de kullanılabilmektedir. Algoritmanın bu amaçla kullanılması için ihtiyaç duyulan şey uygun katsayı dizilerinin bulunmasıdır. Uygun katsayılar ile algoritma pek çok sınıflama işlemi yapabilir. Aşağıdaki katsayılar ve görüntüler, algoritmanın bu yeteneğini göstermektedir. BrainWeb'den alınan 86. , 136. ve 181. görüntü dilimleri bu kısa gösterim için kullanılmıştır. Böylece T1, T2 ve PD çekim teknikleri için üç ayrı katsayı dizisi üretilmiştir.

T1 görüntüleri için katsayı dizisi:

$$\propto = [1.426, -1.934, 0.24375, -1.358, 0.504, 2, 0.329, 0.421, 0.484, -1.097, -0.792]. \quad (6.51)$$

Bu dizi ile beynin beyaz cevher bölgesi sınıflandırılmaktadır. Şekil 6.14 (a,b ve c) bu sınıflandırma sonuçlarını gösterir.



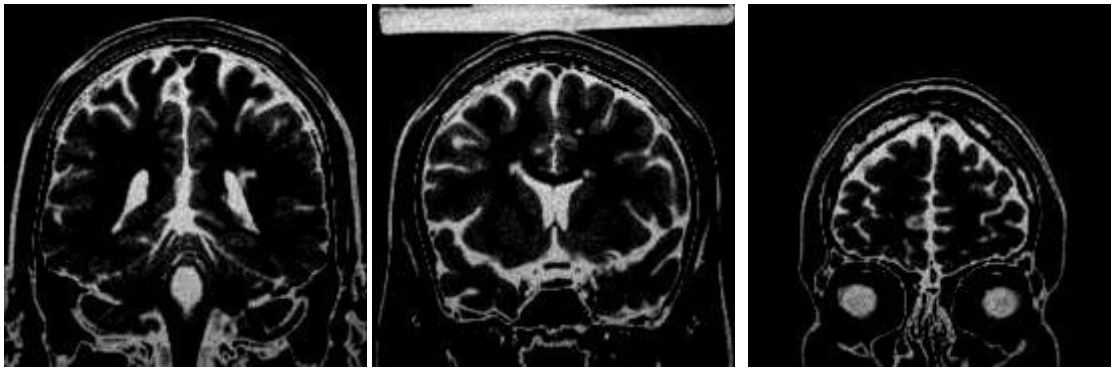
(a) (b) (c)

Şekil 6.14 Sınıflandırılmış BrainWeb a) 86. görüntü, b)163. görüntü, c)181. görüntü.

T2 görüntüleri için katsayı dizisi:

$\propto$ = [3.622, 1.893, 2.069, 0.4756, –1.684, –4, 2.865, 0.387, 3.844, –3.844, –0.543] (6.52)

Bu dizi ile beynin BOS bölgesi sınıflandırılmaktadır. Şekil 6.15 (a,b ve c) bu sınıflandırma sonuçlarını gösterir.



(a) (b) (c)

Şekil 6.15 Sınıflandırılmış BrainWeb a) 86. görüntü, b)163. görüntü, c)181. görüntü.

PD görüntüleri için katsayı dizisi:

$\propto$ = [3.622, 1.893, 2.069, 0.475, –1.684, –4, 2.861, 0.387, 3.844, –3.844, –0.543] (6.53)

Bu dizi ile görüntüdeki arka plan sınıflandırılmaktadır. Şekil 6.16 (a,b ve c) bu sınıflandırma sonuçlarını gösterir.



(a) (b) (c)

Şekil 6.16 Sınıflandırılmış BrainWeb a) 86. görüntü, b)163. görüntü, c)181. görüntü.

Görüntü güçlendirme aşamasından sonra gelen işlem, görüntülerden beynin ve kafatasının ayrılması işlemidir. Bu amaçla, yapılan tez çalışması sırasında çoklu kararlı HYSA temelli bir algoritma olan mCNN-MRI-SS algoritması geliştirilmiştir.

6.4 Beyinin Kafatasından Ayrılması

Beyin MRG görüntüleri yapılacak çalışmaya göre genel olarak detaylı bir şekilde analiz edilirler. Dolayısıyla analizlerden önce görüntülerin farklı bölgelere ayrılması gerekebilir. Örneğin MS plaklarının sınıflandırılmasında tüm beyin görüntüsünü analiz etmek, konuyla plak bulundurmayan bölgelerin, analiz başarısını düşürmesine sebep olacaktır. Dolayısıyla görüntülerden kafatası, yağlı doku, deri gibi bölgelerin ayrılması zorunlu hale gelmektedir. Bu işleme literatürde Kafatası Sıyırma (Skull Stripping) adı verilir.

Literatürde pek çok kafatası sıyırma algoritması mevcuttur. Bu algoritmalar, kontur, şekil, bölgesel, istatistik, olasılık, çoklu çözünürlüklü, atlas, örüntü tanıma, makina öğrenmesi ya da bunların karışımı gibi yöntemleri temel alır (El-Dahshan ve ark 2014). Algoritmaların bu kadar geniş bir yelpazede yayılmış olmasının sebebi kafatası sıyırma işleminin karmaşıklığından kaynaklanmaktadır.

Demirhan ve Güler de kendi kendini düzenleyen haritalara (SOM) ve doğrusal vektör kuantizasyonuna (LVQ) dayanan bir yöntem önermişlerdir (Demirhan ve Güler 2011). Tanoori ve ark. aktif kontur modelleri ve destek vektör makinelerine (SVM) dayanan bir yöntem önermiştir (Tanoori ve ark 2011). Rajendrahan ve Dhanasekeran, bulanık kümeleme ve deforme olabilen modellere dayanan bir yöntem önermişlerdir (A.Rajendran ve Dhanasekaran 2012). El-Sayed ve ark. Dalgacık dönüşümü ve darbe-bağlı sinir ağları içeren hibrid bir yöntem önermiştie (El-Dahshan ve ark 2014).

Her kafatası sıyırma yöntemi benzersizdir ve kendi kullanışlı özelliklerine ve darboğazlarına sahiptirler. Örneğin, atlas temelli teknikler, beyin MR görüntüsünü piksel yoğunluğuna bağlı olmadan bölütleme gibi bir avantaja sahiptir (El-Dahshan ve ark 2014). Diğer bir deyişle ortalama atlas modelleri net olarak tanımlanmış anatomik sınırlara sahiptir. Ancak bu sınırlar bir bireyden diğerine değişebilir bu da bölütlemede bazı istenmeyen etkilere neden olabilir (Oishi ve ark 2009). Kafatası soyma görevi için YSA'lar başka bir örnek olarak verilebilir. Gürültüye karşı oldukça bağışıktırlar ve hastaya özgü yöntemlerdir, ancak geleneksel YSA teknikleri, çok zaman ve kaynak harcayan algoritmalardır (El-Dahshan ve ark 2014).

Kafatası sıyırma görevinde genel olarak karşılaşılan, homojenlik, gürültü (örneğin Riccian gürültüsü), doku şeklindeki deformasyon ve benzeri bazı zorluklar vardır (Xue ve ark 2003). Gürültü ve homojenlik, komşu doku sınıflarında çakışmalara neden olabilir veya görüntüdeki doku modeline zarar vererek hatalı bölütlemeye sebep olabilir (Khademi ve ark

2009). Bölütleme problemlerinin üstesinden gelmek ve başarıyı artırmak için, genellikle ön işleme amaçlı görüntü işleme teknikleri kullanılır. Önişleme algoritmaları, histogram eşitleme, filtreleme ve kontrast geliştirme tekniklerinden oluşur (Yilmaz ve Ozbay 2014). Örneğin, keskin olmayan maskeleme (USM) (Panetta ve ark 2008) ve uzamsal bant geçiren filtreleme (Smathers ve ark 1986) çok yaygın tekniklerdir. Chen ve ark. tarafından önerilen "optimize edilmiş görüntü karşıtlık geliştirme için otomatik bir yöntem" gibi gelişmiş teknikler de vardır (Chen ve ark 2006). Khademi ve ark. sıvı zayıflamalı inversiyon geri kazanım (FLAIR) ile MRI'da otomatik karşıtlık geliştirme algoritması geliştirmiştir (Khademi ve ark 2009). Vidaurrazaga ve ark. dalgacık katsayılarının doğrusal kombinasyonunu kullanarak bir yöntem önerdi (Vidaurrazaga ve ark 2000). Bu çalışmada, ön işleme için CEULICA algoritması tercih edilmiştir (Yilmaz ve Ozbay 2014). Algoritma aynı anda hem gürültüyü bastırır hem de karşıtlığı geliştirmektedir.

Tipik bir beyin MR görüntüsü aşağıdaki bölgelerden oluşur; vücut, kafatası, damarlar, kemik iliği, beyin-omurilik sıvısı (CSF), gri madde (GM) ve beyaz cevher (WM). Bu çalışmada CSF, GM ve WM bölgeleri beyin olarak kabul edilmiş ve diğer kısımlar ortadan kaldırılacak bölgeler olarak seçilmiştir. Dolayısıyla aynı anda birden fazla sınıflandırma işlemi yapılacağı için hem geleneksel HYSA hem de çoklu-kararlı HYSA modelleri içeren bir algoritma önerilmiştir. Önerilen algoritma, Beyin MRG'lerinde kafatası sıyırmak için çoklu-kararlı HYSA olarak adlandırılmıştır (mCNN-MRI-SS). Algoritmada eğitim şablonları yapay arı koloni algoritması kullanarak oluşturulmuştur (Yilmaz ve ark 2016).

Tıbbi görüntüleme çalışmalarında bazı farklı MR görüntü çekim teknikleri vardır. Her yöntem kendi karşıtlık ve yoğunluk özelliğine sahiptir, dolayısıyla belirli dokuların yoğunluk değerleri bu yöntemler arasında değişir. Bu yüzden, farklı çekim teknikleri üzerinde çalışırken, şablon setleri her teknik için ayrı tanımlanır. Bu, zaman alıcı bir sorundur, çünkü HYSA'lar her bir yöntem için ayrı ayrı eğitilmelidir. Bu çalışmada, bu sorunun üstesinden gelmek için CEULICA algoritmasından faydalanılmıştır çalışma hem T1 hem de T2 görüntüleri üzerindeki etkisi araştırılmıştır.

Algoritma, BrainWeb, MIDAS-NAMIC veri setleri ve hastaneden kaydedilmiş veriler olmak üzere üç veri kümesiyle değerlendirilmiştir. Hastaneden kaydedilen veriler, NEÜ Meram Tıp Fakültesi'nden alınan MR görüntülerinden oluşturulmuştur. Önceden sınıflandırılmış ve kafatası sıyırılmış beyin MR görüntülerini içeren veri setleri; BrainWeb, T1 ağırlıklı MR görüntülerinden ve MIDAS NAMIC T2 ağırlıklı MR görüntülerinden oluşur.

Bu veri tabanlarının her ikisindeki MRI verileri, Talairach atlasına uyumludur (Woods ve ark 1999).

NEÜ Meram Tıp Fakültesinden elde edilen veriler, diğer veri setlerinden farklıdır. Talairach uyumlu değildir ve diğer veritabanlarından daha az dilim içermektedir. Referans görüntülerini üretmek için, veriler 20 yıllık tecrübeli bir doktor tarafından manüel olarak bölütlenmiştir.

Değerlendirmeler şu metriklerle gerçekleştirildi; Jaccard, Dice, Gerçek Pozitif Fraksiyon (TPF) ve Gerçek Negatif Fraksiyon (TNF) parametreleri. Algoritma, BET (Beyin Çıkarma Aracı) ve BSE (Beyin Yüzey Çıkartıcısı) olarak adlandırılan tanınmış endüstri standardı algoritmaları ile karşılaştırılmıştır (Somasundaram ve Kalaiselvi 2011). BET algoritması, beyin ve beyin-dışı bölgeler arasındaki yoğunluk tahminlerine dayanmaktadır, BSE algoritması kenar algılama ve filtreleme tekniklerine dayanmaktadır (Boesen ve ark 2004). Geliştirilen algoritmanın diğerlerine göre farklı bir yaklaşımı vardır ve bu algoritmanın HYSA yapılarını kullanarak örüntü tanımaya dayanmasıdır.

Geliştirilen algoritma, MIDAS-NAMIC T2 ağırlıklı görüntülerle BrainWeb T1 ağırlıklı görüntüler ve 0,837 Jaccard, 0,898 Dice, 0,0124 TNF ve 0,1511 TPF ortalama değerleri ile 0,595 Jaccard, 0,744 Dice, 0,0344 TPF ve 0,383 FPR ortalama değerlerini sağlamıştır. Geliştirilen algoritma T2 ağırlıklı görüntülerle diğer algoritmalar arasında ikinci en iyi değerlendirme sonucunu ve T1 ağırlıklı görüntüler ile diğer algoritmalar arasında en düşük değerlendirme sonucunu almıştır. Öte yandan, üçüncü değerlendirmenin sonuçları ümit vaat etmektedir. Algoritma, 0,8297 Jaccard, 0,9012 Dice, 0,0951 TNF ve 0,1225 TPF ortalama değerlerine ulaşmış ve diğer algoritmalar arasında en iyi değerleri elde etmiştir.

Açıkçası, BET ve BSE algoritmaları, Talairach atlasına uyumlu iyi çakıştırılmış verilerle başarılıdır, ancak veriler bozuksa ya da iyi kayıt edilmediğinde, diğer tekniklerle ele alınması gerekir. Geliştirilen mCNN-MRI-SS algoritması HYSA'nın hücresel seviyede örüntü tanıma yeteneğinden dolayı bu algoritmalardan biridir. Bu yetenek algoritmayı daha hassas yapar. Algoritmanın diğer önemli bir yeteneği ise kontrast geliştirme adımında kullanılan parametrelere bağlı olarak farklı çekim tekniklerine uyumlu şekilde çalışabilmesidir.

6.4.1 Metodoloji

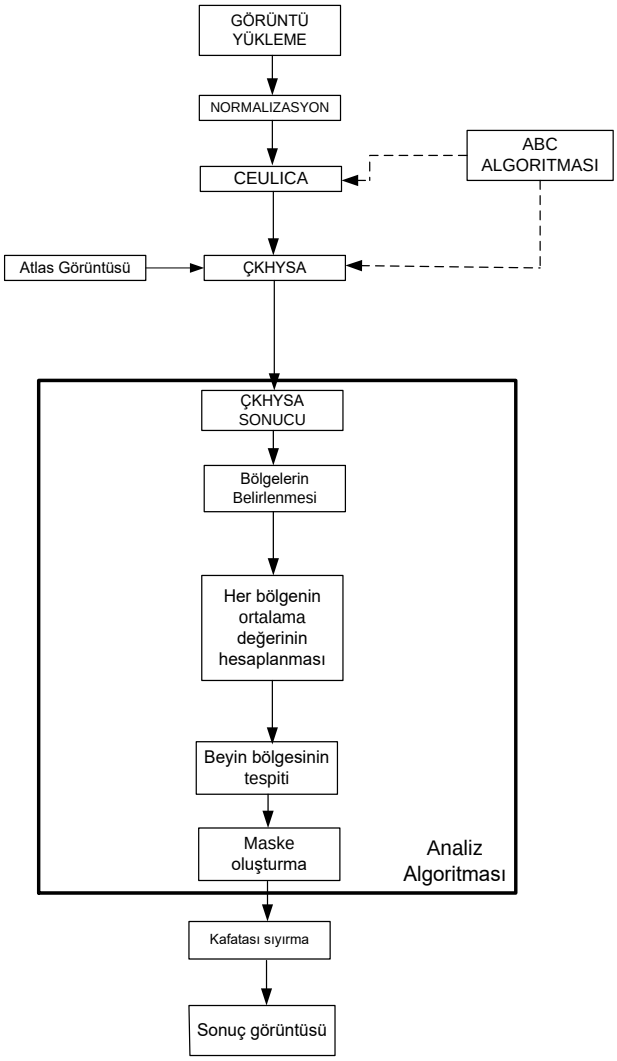
Bu çalışmada T1 ağırlıklı görüntüler için BrainWeb veri tabanından alınan, 1 mm dilim kalınlıklı, 181×256×256 boyutlu [0-4095] arasında kısa tamsayı değerleri ile

tanımlanmış 20 görüntü ve yine her orijinal görüntü için oluşturulmuş 0,5 mm dilim kalınlığı, 362×434×362 boyutlu, [0-255] arasında değerlerle tanımlı bir anatomik model kullanılmıştır.

T2 ağırlıklı MRG görüntüleri için NAMIC veri tabanından alınan, 20 farklı T2 ağırlıklı görüntüden ve aynı zamanda her bir görüntü için kafatası sıyrılmış referans görüntüsü kullanılmıştır. Tarama parametreleri şu şekildedir; TR = 2500ms, TE = 80ms, 25.6 cm^2 görüş alanı, 1 mm dilim kalınlığı. voksel boyutları 1×1×1 mm'dir.

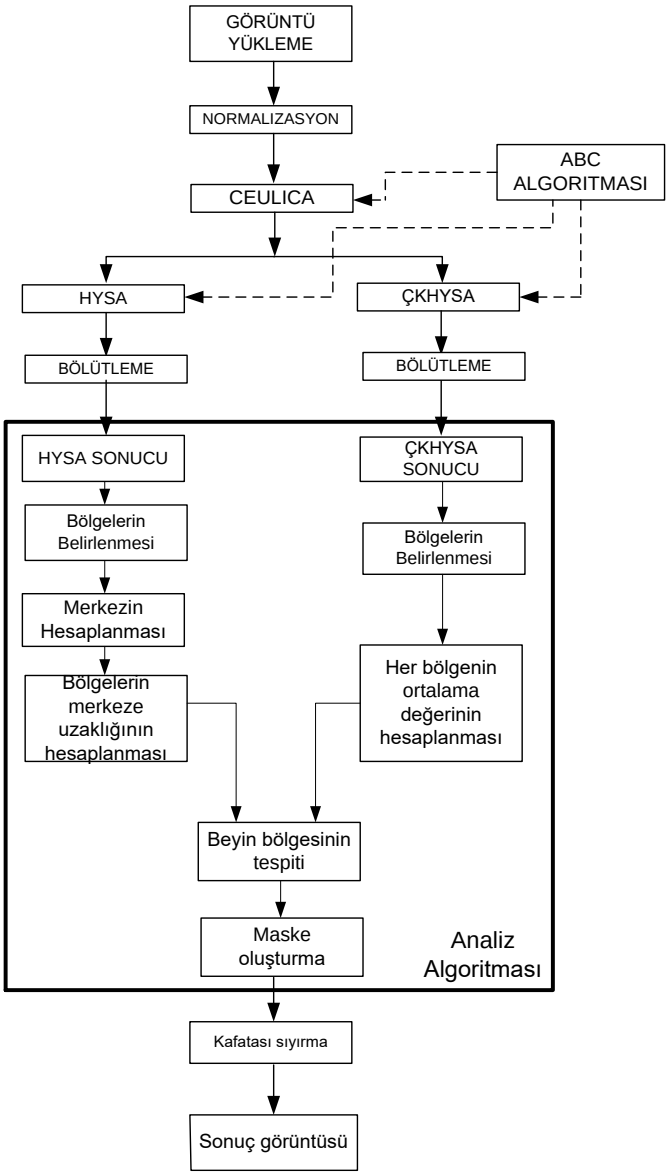
NEÜ veri tabanından alınan veriler ise 10 adet, 3 mm dilim kalınlığı ve 10 mm mesafe olan 21 dilimden oluşur. Bu verilerin en önemli eksikliği Talairarch atlasına göre uyumsuz olmasıdır. NEÜ veri tabanındaki MRG beyin görüntüleri manuel olarak bölütlenmiştir. Bu amaçla sağlıklı gönüllülerden rastgele 10 MRG görüntüsü seçilmiştir. Gönüllüler 21-45 yaşları arasındadır. Gönüllülerin cinsiyeti, 5 erkek 5 kadın olacak şekilde tercih edilmiştir. Kaynak görüntü setini seçtikten sonra, 20 yıllık tecrübeye sahip bir hekim tarafından bir hedef görüntü seti oluşturulur. Hekim, kaynak veri setindeki beyin MR görüntülerinde beyin bölgesini manuel olarak çıkarmıştır.

Geliştirilen algoritma HYSA'ları temel alacak şekilde tasarlanmıştır. Eğer kafatası sıyırma işlemi gerçekleştirilecek görüntüler, Talairarch atlasına uyumlu ise algoritma Atlas tabanlı olarak kullanılabilmektedir. Atlas tabanlı modelde ÇK-HYSA algoritmasına atlas görüntüsü giriş olarak ve bölütlenecek görüntü ise başlangıç durumu olarak verilir. Algoritma bu çalışma kipinde bir ÇK-HYSA iş akışından ve toplam 11 adımdan oluşmaktadır. Tüm eğitimler ve parametre belirleme işlemleri ABC algoritması ile daha önceden belirlenmiştir (Karaboğa 2014). Algoritma hem T1 ağırlıklı hem de T2 ağırlıklı MR görüntüleri üzerinde çalışabilir, CEULICA adım katsayıları görüntünün T1 veya T2 çekim tekniğinde olup olmadığına göre seçilir. Algoritmanın atlas tabanlı çalışma kipinde kullandığı akış diyagramı Şekil 6.17'deki gibidir.



Şekil 6.17 mCNN-MRI-SS algoritmasının atlas tabanlı çalışma kipi

Eğer algoritma Talaiarch ya da herhangi bir beyin atlasına göre uyumsuz verilerde çalışacaksa, iş akışı değişir. Algoritma atlassız kipe geçtiğinde, 2 paralel HYSA iş akışından ve toplam 22 adımdan oluşarak çalışır. Yine bu kipte de eğitimler ve parametre belirleme işlemleri, ABC algoritması ile yapılmıştır (Karaboğa 2014). Algoritma, hem T1 ağırlıklı hem de T2 ağırlıklı MR görüntüleri üzerinde çalışabilir. CEULICA katsayıları, görüntünün T1 veya T2 çekim tekniğinde olup olmadığına göre seçilir. Bu çalışmada, daha önce önerilen aynı CEULICA parametreleri kullanılmıştır (Yilmaz ve Ozbay 2014). Algoritmanın paralel HYSA tabanlı çalışma kipinde kullandığı akış diyagramı Şekil 6.18'deki gibidir.



Şekil 6.18 mCNN-MRI-SS algoritmasının paralel HYSA tabanlı çalışma kipi

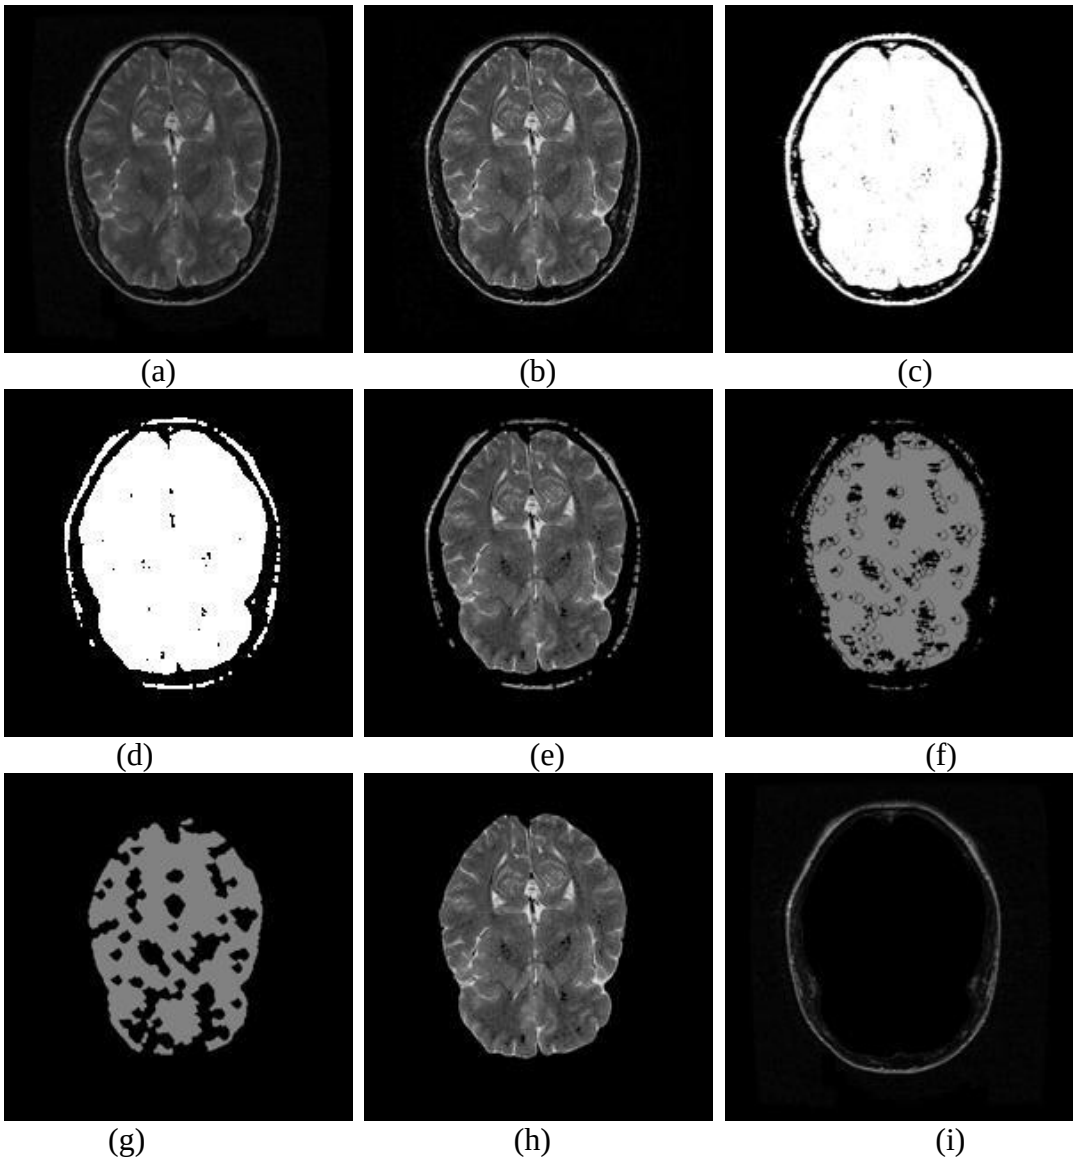
Algoritma, her iki çalışma kipinde de aksiyel düzlemde çalışır ve analizler her bir dilime ayrı ayrı uygulanır. Algoritma, MRG veri küpünden seçilen herhangi bir rasgele kesiti analiz edebilir, bu özelliği sayesinde aynı anda birden fazla görüntü aynı anda paralel işleme sokulabilir.

Geliştirilen algoritma aşağıdaki adımları gerçekleştirmektedir. Öncelikle görüntü alınır ve tamsayılı değerleri [-1,1] aralığında normalize edilir. Böylece görüntü HSYA sınıflandırmaları için hazır hale getirilir. CEULICA adımında, hem gürültü azaltma hem de karşıtlık geliştirme işlemleri MR görüntüsünde uygulanır, daha sonra HYSA basamakları uygulanır. Eğer atlas bilgisi kullanılacaksa kafatası sıyırma işlemi uygulanacak görüntü ile görüntünün aynı dilimine denk gelen atlas görüntüsü Şekil 6.17'deki aşamalardan geçirilir.

Eğer atlas tabanlı çalışılmayacaksa bu durumda Şekil 6.18'de gösterilen 2 ayrı HYSA iş akışı gerçekleştirilecektir. Burada amaç, tek bir görüntü kullanarak yine atlas görüntüsüne benzeyen bir görüntü daha oluşturmaktır. İş akışlarından biri geleneksel HSYA ve diğeri ise ÇK-HYSA yapılarını temel almaktadır. Tüm MRG'de ayrılacak parçaların tespiti, geleneksel HYSA iş akışında gerçekleştirilir. Beyin ve diğer bölgelerin etiketlenmesi, ÇK-HYSA iş akışında gerçekleştirilerek her bölge farklı bir sayı ile etiketlenir.

Algoritmanın analiz aşamasında gereksiz parçacıkları kaldırmak için çıktılara, önce aşınma sonra genleşme işlemleri uygulanır, aksi takdirde bu gereksiz parçacıklar analiz sırasında ekstra zaman tüketir. Aşınma ve genişleme işlemi sırasında 3×3 kare şeklinde bir yapısal eleman kullanılır. Bu adımdan sonra eğer atlas kullanılmışsa ÇK-HYSA çıktısı ve atlas görüntüsü, atlas kullanılmamışsa hem HYSA hem de ÇK-HYSA iş akışlarının çıktıları, üste bindirilir. Bu bölgelerin üst üste yerleştirilmesi analiz edilecek bir veri seti üretir. Hesaplama için, her bir parçanın ortalama piksel değerleri ve merkez koordinatları seçilir. Bu hesaplamalardan sonra her parça, beynin bir parçası olup olmadığını gösteren bir sayı alır. Analiz basamağının sonunda beyin bölgeleri tespit edilir ve bu bölgeler kullanılarak son bir beyin maskesi oluşturulur. Algoritma içindeki her basamağın çıktıları Şekil 6.19'da gösterilmiştir. Şekil 6.19(i), algoritma sonucunun orijinal görüntüden çıkarılmasıyla elde edilen ekstra bir görüntüdür.

Algoritmadaki analiz kısmı ayrı bir algoritma olarak düşünülebilir ve algoritma başarısını arttırmak için, daha hızlı bir algoritma ile değiştirilebilir. Bu çalışmada merkez uzaklıklarına dayanan analiz yöntemi tercih edilmektedir.

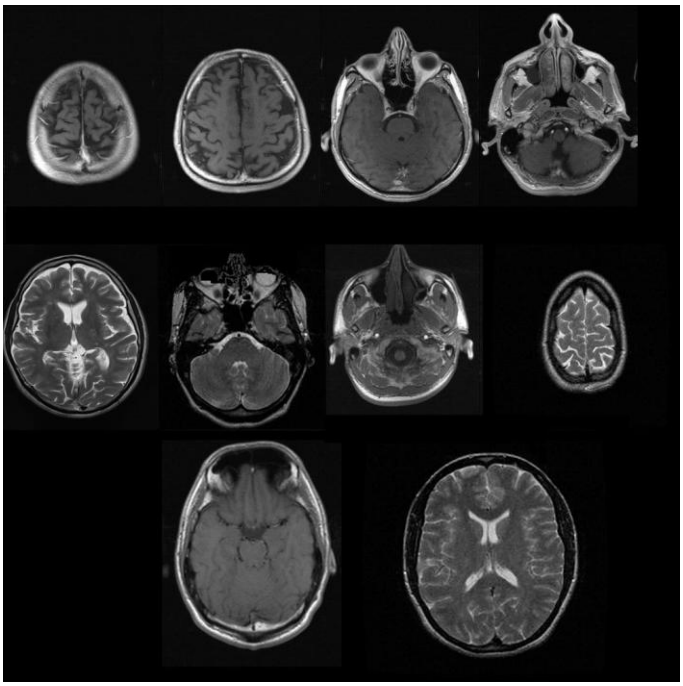


Şekil 6.19 Algoritmadaki her iş akışının çıktıları. (a) Orijinal resim. (b) CEULICA'nın uygulanmasından sonra orijinal görüntü. (c) HYSA basamağının çıktısı. (d) HYSA çıktısının aşınma ve genleşmesi. (e) HYSA çıktısı maskeden sonra uygulanan orijinal görüntü. (f) ÇK-HYSA Çıktısı. (g) ÇK-HYSA'nın aşınma ve genleşmesi. (h) Analiz algoritmasının çıktısı. (i) Orijinal görüntüden analiz görüntüsünün çıkarılmış hali.

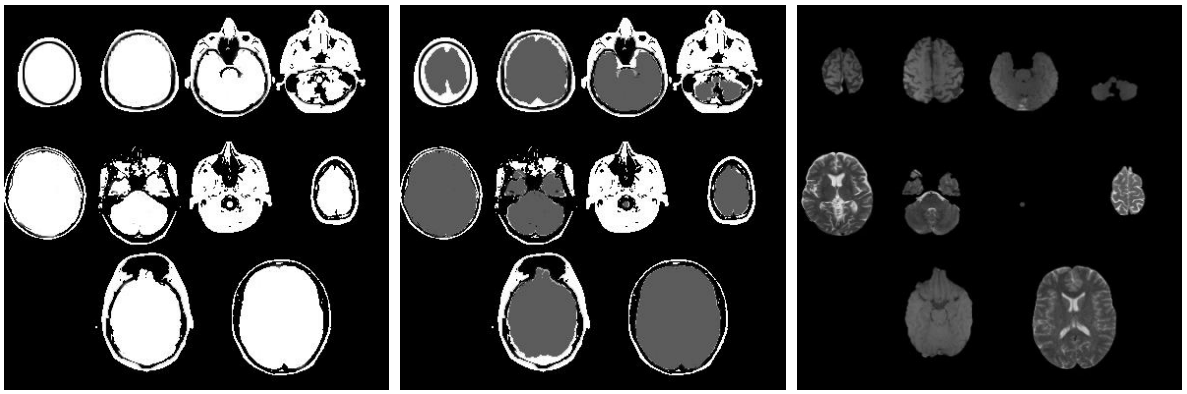
6.4.2 Kafatası sıyırma algoritması için katsayı tespiti

İş akışları ve CEULICA algoritması için gerekli katsayılar belirlenirken Arı Koloni Algoritması kullanılmıştır, bunun sebebi Arı Koloni Algoritmasının arama uzayında geniş bir arama kapasitesine sahip olmasıdır. Çalışmada katsayıların belirlemesi işlemi çok boyutlu bir uzayında arama yapma görevi olarak düşünülebilir. Arı Koloni Algoritması (Karaboğa 2014), arama becerileri ve hassaslığı nedeniyle bu görevin ihtiyaçlarını karşılar.

Eğitim sırasında, bir kaynak ve hedef görüntü veri seti oluşturulmuş ve algoritmaya verilen kaynak görüntülerinin veri setindeki hedef görüntülere yakınlığı, bir uygunluk fonksiyonuyla ölçülmüştür. Bu amaçla BrainWeb, MIDAS-NAMIC ve NEÜ veri tabanlarından 10 adet rastgele görüntü seçilmiştir. Seçilen görüntüler kaynak setini ve bu görüntülerin kafatası sıyrılmış halleri hedef setini oluşturmuştur. Üç veri kümesinden elde edilen kaynak görüntüler Şekil 6.20'de gösterilmektedir. Hedef veri kümesinde üç farklı veri seti kullanılmıştır: Şekil 6.21 (a), geleneksel HSYA iş akışına yönelik hedef verileri göstermektedir, Şekil 6.21 (b) iki sınıfı içeren ÇK-HYSA iş akışındaki hedef veriyi ve Şekil 6.21 (c) nihai çıktının başarı oranlarını değerlendirmek için hedef verileri temsil etmektedir.



Şekil 6.20 Kaynak veri seti



(a) (b) (c)

Şekil 6.21 Hedef veri seti (a) geleneksel HSYA iş akışı için hedef verileri, (b) ÇKHSYA iş akışı için hedef verileri (c) tüm algoritma için hedef verileri.

Uygunluk fonksiyonu Eşitlik 5.52'deki korelasyon formülüne göre hesaplanır. Çalışmada [0.86 – 1] aralığındaki korelasyon değerleri uygun değerler olarak kabul edilmiştir.

Eğitimler sonucunda CEULICA algoritması için T1 ve T2 ağırlıklı MRG görüntülerinde kullanılmak üzere şu katsayılar elde edilmiştir:

T1 ağırlıklı görüntüler için katsayı seti:

$$\propto = [-1.3364, 0.1359, -0.7102, 0.2326, 0.2647, 2, -0.216, 0.9881, 0.5409, -0.2644, 0.1186] \quad (6.54)$$

T2 ağırlıklı görüntüler için katsayı seti:

$$\propto = [-0.1211, 0.5576, -0.9834, -2, 1.4984, 0.5089, -0.2491, 1.3623, 0.5396, -0.72, -0.46] \quad (6.55)$$

Eğitimler sonucu geleneksel HYSA algoritması için elde edilen A,B ve I şablonları şu şekilde olmuştur:

$$A = \begin{bmatrix} -0.725997748 & -0.023794223 & 0.692663089 & 0.435977593 & -0.055545095 \\ -0.171197179 & 0.095616906 & 1 & -1 & -0.197778485 \\ 0.360682092 & -0.029209404 & 0.242058011 & 0.68345776 & -0.492545456 \\ 0.962256128 & 0.171766718 & 0.29541435 & 0.746871162 & 0.475551323 \\ -0.708038365 & 0.712631023 & -1 & 0.961899103 & -0.493535162 \end{bmatrix} \quad (6.56)$$

$$B = \begin{bmatrix} -0.758623914 & 0.116659562 & -0.095158867 & -0.500283695 & 0.432672136 \\ -0.54269791 & -0.449721799 & -0.072679169 & 0.334911004 & 0.92166344 \\ 0.137895634 & -0.218756516 & 0.629324733 & -0.712146178 & -0.93245422 \\ 0.187444258 & -0.560720551 & -0.006956683 & 0.361582645 & -0.327197559 \\ 0.631871299 & -0.577565805 & 0.804659254 & -0.0095228 & -0.082415912 \end{bmatrix} \quad (6.57)$$

$$I = [-0.620033189] \quad (6.58)$$

Eğitimler sonucu ÇK-HYSA modeli için elde edilen A,B,I,r katsayıları ise şu şekildedir:

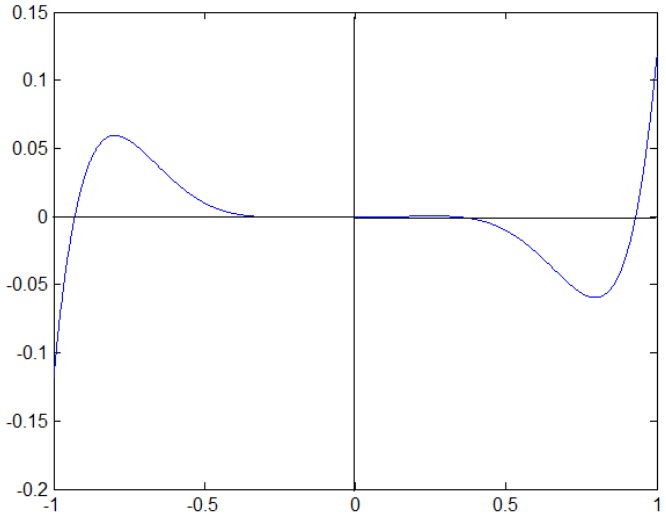
$$A = \begin{bmatrix} 0.6723 & -25.139 & 18.575 \\ 15.554 & 6.927 & 1.503 \\ 1.273 & -2.955 & 25.448 \end{bmatrix} \quad (6.59)$$

$$B = \begin{bmatrix} 0.92 & 20.578 & -0.617 \\ -3.124 & -32.164 & 1.447 \\ -17.646 & -114.824 & -0.86147 \end{bmatrix} \tag{6.60}$$

$$I = [-0.6928] \tag{6.61}$$

$$r = [0.93 \quad 0.325 \quad 0.148] \tag{6.62}$$

ÇK-HYSA'nın r kökleri ile elde edilmiş çıkış fonksiyonunun, grafik gösterimi Şekil 6.22'deki gibidir.



Şekil 6.22 ÇK-HYSA'nın çıkış fonksiyonunun grafik gösterimi

6.4.3 Başarım ölçümleri

Algoritmanın performans değerlendirmesi aşağıdaki metodoloji ile gerçekleştirilmiştir. MIDAS-NAMIC (Bullitt ve ark 2005), BrainWeb (Cocosco ve ark 1997) ve hastane verileri, FSL yazılım paketi (Kasiri ve ark 2010), Brain Suite yazılımı ve mCNN-MRI-SS algoritması ile kafatası sıyırma işlemine tabi tutulmuştur. Algoritmaların sonuçları, veritabanlarından elde edilen orijinal kafatası sıyırma verileri ile karşılaştırılmıştır. Karşılaştırma Jaccard, Dice, gerçek pozitif fraksiyon (TPF), gerçek negatif fraksiyon (TNF) parametreleri ile gerçekleştirilmiştir.

Karşılaştırmada kullanılan algoritmalardan FSL paketindeki Beyin Çıkarma Aracı (BET) algoritması, beyin dışındaki tüm dokuları görüntüden otomatik olarak ortadan kaldırır. BET algoritması, beyin ve beyin olmayan bölgeler arasındaki yoğunluk eşiğinin MRI verilerinde tahmin edilmesine dayanmaktadır. Algoritma, bir küre ile başlar ve küre, beyin

yüzeyine erişene kadar dışa doğru deforme olur. Kürenin merkezi beyin MRG'nin merkeziyle aynıdır (Boesen ve ark 2004). Bu çalışmada BET algoritması 0.5 değerli fraksiyonel yoğunluk eşiği ve 0.0 değerli eşik gradyanı ile çalıştırılmıştır.

Karşılaştırmada kullanılan Brainsuite yazılımındaki, Beyin Yüzey Ekstraksiyonu (BSE) algoritması kenar algılama ve anizotropik difüzyon filtrelemesi için kullanılır. Algoritmada, Gauss alçak geçiren filtre ve Laplacian sıfır geçiş algılama filtresi ile 2D Marr-Hildret operatörü uygulanmaktadır. Algoritma, kenar haritasında morfolojik işlemler gerçekleştirir (Boesen ve ark 2004). Bu çalışmada BSE algoritması aşağıdaki parametrelerle çalıştırılmıştır; Difüzyon yinelemeleri = 3, difüzyon sabiti = 25, kenar sabiti = 0.64, erozyon boyutu = 1.

Deneyler sırasında mCNN-MRI-SS, ilk iki deneydeki veri tabanlarının Talairach atlasına uyumlu olmalarından dolayı, atlas tabanlı çalıştırılmıştır. Üçüncü deneydeki veri tabanı atlas uyumlu olmadığı için atlas kullanmadan çalıştırılmıştır.

Değerlendirme sürecinde mCNN-MRI-SS, BSE ve BET algoritmaları bölütleme sonuçlarının dijital maskeleri üretilmiş. Bu maskeler ayrıca veri tabanlarından elde edilen orijinal görüntü ve referans görüntüleriyle eşit olacak şekilde boyutlandırılmıştır. Literatürde sıklıkla kullanılan Jaccard, Dice, TPF, TNF parametreleri ile yapılan nicel değerlendirmeler elde edilmiştir. Jaccard ve Dice katsayıları, ikili görüntüler arasındaki örtüşmeyi temsil eder, 0 ile 1 arasında değişen değerlerden "0" hiçbir çakışma olmadığını ve "1" tam eşlemeyi temsil eder. Bu metriklerin tanımları aşağıdaki gibidir:

$$D = \frac{2|S \cap R|}{|S|+|R|} \times 100 \tag{6.63}$$

$$J = \frac{|S \cap R|}{S \cup R} \times 100 = \frac{D}{2-D} \tag{6.64}$$

Burada S bölütleme sonucunda elde edilen görüntüyü, R ise vertabanından alınan referans görüntüsünü ifade eder.

TPF, TNF parametreleri hassasiyet ve özgünlüğü temsil eder ve aşağıdaki gibi tanımlanır:

$$TPF = \frac{TP}{TP+FN} \tag{6.65}$$

$$TNF = \frac{TN}{TN+FP} \tag{6.66}$$

Burada TP "gerçek pozitif", FN "yanlış negatif", TN "gerçek negatif" ve FP "yanlış pozitif" değerlerini gösterir.

Değerlendirme, üç farklı değerlendirme süreci yürütülerek gerçekleştirilmiştir. İlk değerlendirmede BrainWeb veri tabanı, BSE, BET ve mCNN-MRI-SS algoritmaları ile bölütlenmiştir. İkinci değerlendirmede, NAMIC veri tabanı, daha önce bahsedilen algoritmalarla bölütlenmiştir. Üçüncü değerlendirme, Meram Tıp Fakültesi'nden alınan MRG verileri üzerinde yapılmıştır ve yine aynı yöntemlerle bölütlenmiştir.

6.4.3.1 Deney 1

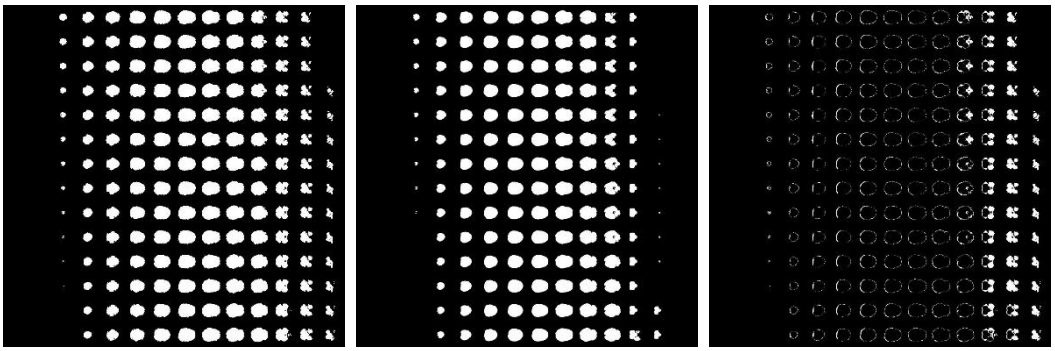
Değerlendirme, BrainWeb veritabanından elde edilen 19 normal T1 ağırlıklı MR görüntüsü üzerinde gerçekleştirilerek, algoritma performansı Jaccard, Dice, TPF ve TNF ölçümleri ile gerçekleştirilmiştir. Algoritmaların performans değerlendirmeleri Çizelge 6.9'da gösterilmektedir.

Çizelge 6.9 T1 ağırlıklı görüntülerde performans değerlendirmesi

	BET (FSL)				BSE (BrainSuite)				mCNN-MRI-SS			
	Jaccard	**Dice**	**TNF**	**TPF**	**Jaccard**	**Dice**	**TNF**	**TPF**	**Jaccard**	**Dice**	**TNF**	**TPF**
subject04	0,907	0,951	0,075	0,024	0,921	0,959	0,048	0,035	0,853	0,921	0,083	0,076
subject05	0,607	0,756	0,027	0,377	0,599	0,750	0,079	0,353	0,565	0,722	0,024	0,421
subject18	0,611	0,759	0,029	0,371	0,596	0,747	0,016	0,395	0,584	0,738	0,025	0,401
subject20	0,619	0,765	0,024	0,366	0,602	0,751	0,011	0,392	0,578	0,733	0,044	0,396
subject38	0,613	0,760	0,027	0,371	0,596	0,747	0,014	0,396	0,575	0,730	0,039	0,402
subject41	0,600	0,750	0,023	0,386	0,603	0,752	0,022	0,384	0,589	0,742	0,021	0,399
subject42	0,611	0,758	0,030	0,371	0,595	0,746	0,013	0,397	0,536	0,698	0,064	0,430
subject43	0,590	0,742	0,019	0,399	0,586	0,739	0,014	0,406	0,557	0,715	0,013	0,436
subject44	0,645	0,780	0,032	0,333	0,637	0,774	0,027	0,345	0,605	0,750	0,039	0,370
subject45	0,618	0,764	0,017	0,372	0,596	0,747	0,064	0,366	0,600	0,750	0,022	0,387
subject46	0,612	0,759	0,030	0,370	0,600	0,750	0,016	0,391	0,553	0,712	0,041	0,425
subject47	0,608	0,757	0,018	0,381	0,596	0,747	0,023	0,390	0,603	0,752	0,013	0,389
subject48	0,605	0,754	0,016	0,385	0,604	0,753	0,012	0,389	0,598	0,749	0,014	0,394
subject49	0,604	0,753	0,023	0,382	0,617	0,763	0,053	0,350	0,570	0,726	0,023	0,417
subject50	0,603	0,752	0,019	0,386	0,592	0,744	0,015	0,399	0,603	0,753	0,021	0,384
subject51	0,621	0,766	0,031	0,360	0,593	0,744	0,236	0,267	0,580	0,734	0,054	0,389
subject52	0,613	0,760	0,024	0,373	0,596	0,746	0,012	0,397	0,591	0,743	0,031	0,391
subject53	0,610	0,758	0,032	0,370	0,600	0,750	0,017	0,390	0,593	0,744	0,030	0,389
subject54	0,615	0,762	0,032	0,365	0,610	0,758	0,148	0,300	0,574	0,729	0,053	0,395
Ortalama	**0,627**	**0,769**	**0,028**	**0,355**	**0,618**	**0,761**	**0,044**	**0,355**	**0,595**	**0,744**	**0,034**	**0,384**

Çizelge 6.9'un son satırında sonuçların ortalama değerlerini temsil etmektedir. Sonuçlarda görüldüğü gibi BET algoritması 0.6269 Jaccard, 0.7687 Dice, 0.0278 TPF, 0.3548 TNF değerlerine ulaşmıştır. BSE algoritması 0.6178 Jaccard, 0.7614 Dice, 0.0442 TPF, 0.3548 TNF değerlerine ulaşmıştır. mCNN-MRI-SS algoritması 0.595 Jaccard, 0.744 Dice, 0.0344 TPF, 0.383 TNF değerleri ile tüm algoritmalar arasında daha az fakat yeterli değer elde etmiştir.

Algoritmanın nispeten düşük skor almasının başlıca nedeni, beyin ve kafatası bölgelerinin T1 ağırlıklı MR görüntülerinde benzer kontrast yoğunluğu ve desen özelliklerine sahip olmasıdır. Bu skorların bir diğer nedeni, algoritmadaki analiz akışının, MRI verilerindeki anterior ve posterior dilimlerle yeterince başarılı olmamasıdır. Bu durum, algoritmanın genel başarısını etkiler. Algoritmanın zaman tüketimi de çok yüksektir, çünkü dilim dilim ve yüksek çözünürlüklü kipte çalışmaktadır. Algoritmanın başarısı, Şekil 6.23'de görülmektedir. Şekil 6.23'de "subject 49" verisinin verisinin, referans, algoritma sonucu ve fark görüntüleri verilmiştir.



(a) (b) (c)

Şekil 6.23 "subject 49" verisinin (a) veri tabanından elde edilen referans görüntüsü, (b) algoritmanın sonucu, (c) ise iki görüntü arasındaki farkı temsil etmektedir.

6.4.3.2 Deney 2

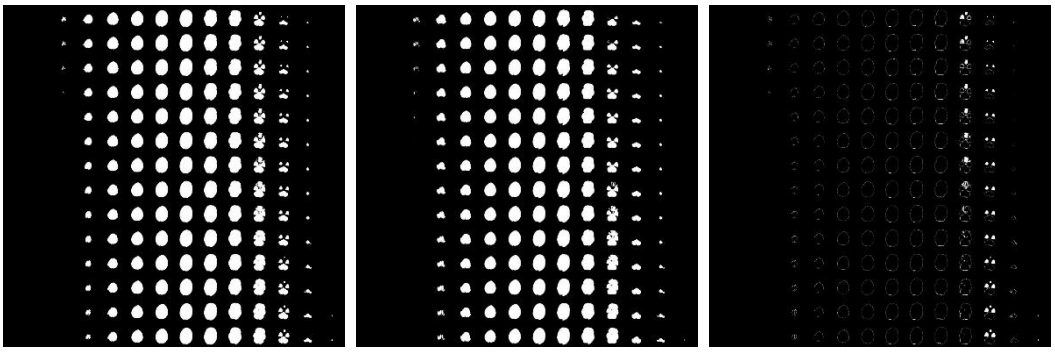
İkinci deney NAMIC veri tabanından elde edilen 19 normal T2 ağırlıklı MR görüntüleri üzerinde gerçekleştirilmiştir, algoritma performansı Jaccard, Dice, TPF ve TNF değerleri ile ölçülmüştür. Çizelge 6.10'da algoritmaların performans değerlendirmeleri gösterilmiştir.

Çizelge 6.10 NAMIC veri tabanından alınan T2 ağırlıklı görüntülerle algoritmanın performans değerlendirmesi.

	BET (FSL)				BSE (BrainSuite)				mCNN-MRI-SS			
	Jaccard	**Dice**	**TNF**	**TPF**	**Jaccard**	**Dice**	**TNF**	**TPF**	**Jaccard**	**Dice**	**TNF**	**TPF**
Case01011-t2w	0,954	0,977	0,047	0,001	0,565	0,722	0,627	0,081	0,936	0,967	0,024	0,042
Case01015-t2w	0,961	0,980	0,039	0,002	0,751	0,858	0,004	0,246	0,959	0,979	0,003	0,038
Case01017-t2w	0,953	0,976	0,049	0,001	0,470	0,639	0,581	0,257	0,707	0,828	0,003	0,291
Case01018-t2w	0,955	0,977	0,040	0,007	0,551	0,710	0,601	0,118	0,959	0,979	0,004	0,037
Case01019-t2w	0,947	0,973	0,051	0,004	0,628	0,771	0,006	0,369	0,947	0,973	0,017	0,037
Case01025-t2w	0,948	0,973	0,054	0,001	0,795	0,886	0,010	0,197	0,957	0,978	0,010	0,034
Case01026-t2w	0,932	0,965	0,068	0,005	0,465	0,635	0,398	0,052	0,540	0,702	0,008	0,455
Case01028-t2w	0,931	0,964	0,073	0,001	0,699	0,823	0,011	0,293	0,943	0,971	0,014	0,043
Case01029-t2w	0,978	0,989	0,013	0,010	0,000	0,000	0,332	1,000	0,873	0,932	0,002	0,126
Case01033-t2w	0,913	0,955	0,093	0,002	0,416	0,587	0,727	0,282	0,917	0,957	0,048	0,039
Case01034-t2w	0,932	0,965	0,070	0,003	0,393	0,564	0,634	0,358	0,491	0,659	0,007	0,506
Case01035-t2w	0,949	0,974	0,047	0,007	0,483	0,652	0,642	0,207	0,937	0,967	0,008	0,056
Case01039-t2w	0,931	0,964	0,072	0,002	0,503	0,669	0,843	0,073	0,959	0,979	0,019	0,023
Case01041-t2w	0,919	0,958	0,086	0,002	0,497	0,664	0,393	0,308	0,939	0,968	0,022	0,041
Case01042-t2w	0,930	0,964	0,074	0,001	0,502	0,668	0,916	0,039	0,319	0,484	0,008	0,678
Case01044-t2w	0,928	0,963	0,076	0,002	0,470	0,639	0,453	0,318	0,943	0,971	0,023	0,035
Case01045-t2w	0,952	0,975	0,049	0,001	0,515	0,680	0,738	0,104	0,802	0,890	0,002	0,196
Case01073-t2w	0,953	0,976	0,034	0,015	0,677	0,808	0,004	0,320	0,925	0,961	0,002	0,073
Case01104-t2w	0,930	0,964	0,069	0,006	0,587	0,740	0,306	0,234	0,867	0,929	0,013	0,121
Ortalama	**0,942**	**0,970**	**0,058**	**0,004**	**0,525**	**0,669**	**0,467**	**0,256**	**0,838**	**0,899**	**0,013**	**0,151**

Çizelge 6.10'un son satırında, tüm değerlendirmelerin ortalamasını göstermektedir. Sonuçlarda görüldüğü gibi BET algoritması 0.9419 Jaccard, 0.970 Dice, 0.0580 TPF, 0.0038 TNF değerlerine ulaşmıştır. BSE algoritması, 0.5245 Jaccard, 0.6692 Dice, 0.4666 TPF, 0.2556 TNF değerlerine ulaşmıştır. MCNN-MRI-SS algoritması 0.8379 Jaccard, 0.8986 Dice, 0.0125 TPF, 0.1511 TNF değerleri ile tüm algoritmalar arasında ikinci başarılı oranları göstermiştir.

İkinci deney çalışmasında mCNN-MRI-SS algoritması T2 ağırlıklı MRG görüntülerinin örüntü ve yoğunluk özelliklerinden dolayı daha başarılı sonuçlar elde etmiştir. T2 ağırlıklı MR görüntülerinde beyin ve diğer bölgeler arasındaki farklar daha belirgindir. Sonuç olarak algoritma, T2 ağırlıklı MR görüntülerinde daha iyi skor elde etmektedir. Şekil 6.24'de " Case01026-t2w " verisinin, referans, algoritma sonucu ve fark görüntüleri verilmiştir.



(a) (b) (c)

Şekil 6.24 " Case01026-t2w " verisinin (a) veritabanından elde edilen referans görüntüsü, (b) algoritmanın sonucu, (c) iki görüntü arasındaki fark.

6.4.3.3 Deney 3

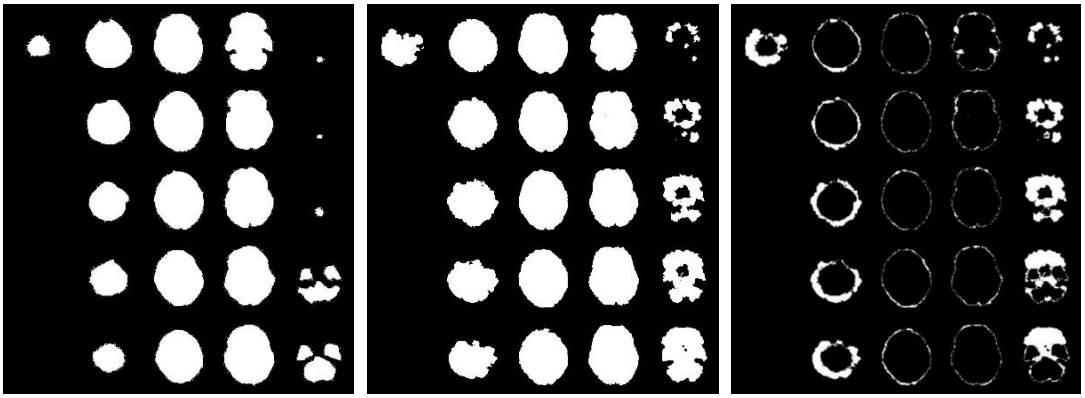
Üçüncü deney çalışması, Meram tıp fakültesinde elde edilen 10 normal T1 ağırlıklı MR görüntüsü üzerinde gerçekleştirilmiş, algoritma performansı Jaccard, Dice, TPF ve TNF katsayıları ile ölçülmüştür. Çizelge 6.11'de algoritmaların performans değerlendirmeleri gösterilmektedir.

Çizelge 6.11 Hastane veritabanı ile algoritmanın değerlendirme sonuçları

	BET (FSL)				BSE (BrainSuite)				mCNN-MRI-SS			
	Jaccard	**Dice**	**TNF**	**TPF**	**Jaccard**	**Dice**	**TNF**	**TPF**	**Jaccard**	**Dice**	**TNF**	**TPF**
MRM01	0,123	0,219	0,627	0,081	0,435	0,341	0,118	0,203	0,959	0,979	0,022	0,037
MRM02	0,177	0,301	0,006	0,101	0,455	0,114	0,047	0,076	0,780	0,876	0,013	0,022
MRM03	0,551	0,710	0,001	0,011	0,344	0,141	0,395	0,356	0,891	0,942	0,206	0,186
MRM04	0,465	0,635	0,012	0,118	0,371	0,084	0,323	0,330	0,540	0,702	0,376	0,385
MRM05	0,262	0,416	0,003	0,060	0,406	0,102	0,183	0,356	0,979	0,990	0,018	0,036
MRM06	0,904	0,950	0,009	0,062	0,529	0,326	0,094	0,064	0,868	0,929	0,052	0,035
MRM07	0,453	0,624	0,006	0,206	0,330	0,075	0,109	0,356	0,689	0,816	0,078	0,256
MRM08	0,199	0,332	0,008	0,071	0,465	0,231	0,268	0,254	0,917	0,957	0,041	0,039
MRM09	0,416	0,587	0,003	0,060	0,000	0,000	0,233	0,406	0,810	0,895	0,111	0,194
MRM10	0,429	0,601	0,009	0,099	0,341	0,277	0,279	0,292	0,864	0,927	0,034	0,036
Ortalama	**0,398**	**0,538**	**0,068**	**0,087**	**0,374**	**0,196**	**0,147**	**0,187**	**0,830**	**0,901**	**0,095**	**0,123**

Çizelge 6.11'in son satırı sonuçların ortalama değerlerini temsil etmektedir. Sonuçlarda görüldüğü gibi BET algoritması 0,3980 Jaccard, 0,5375 Dice, 0,0684 TPF, 0,0868 TNF değerlerine ulaşmıştır. BSE algoritması 0,3744 Jaccard, 0,1957 Dice, 0,1470 TPF, 0,1867 TNF değerlerine ulaşmıştır. mCNN-MRI-SS algoritması 0,8297 Jaccard, 0,9012 Dice, 0,0951 TPF, 0,1225 TNF değerleri ile tüm algoritmalar arasında en başarılı sonuçları üretmiştir.

Son deney ilginç sonuçlar üretmiştir. Algoritmanın diğerlerine göre daha iyi puanlar üretmesinin sebebi, veri kümesinin bozuk olmasıdır. Hastaneden alınan MR verileri diğer veritabanlarından alınan verilere göre farklıdır. Hastane verilerin her dilimi tek tek dosyalar halinde kaydedilmiştir ve kafatası sıyırma işleminden önce birleştirilmesi gerekmektedir. Bununla birlikte, bu tür veriler her türlü beyin atlasına kaydolacak kadar uygun değildir. Dolayısıyla bu MRG verileriyle BET ve BSE algoritmaları, kafatası sıyırma görevini gerçekleştirirken zorluklarla karşılaşmıştır. Öte yandan mCNN-MRI-SS algoritması, dilim dilim tarzında çalışır, bu nedenle algoritma diğer algoritmalar arasında bu tür MRG verileriyle daha iyi performans göstermiştir. Şekil 6.25 "MRM01" verisinin referans, algoritma sonucu ve fark görüntüleri verilmiştir.



(a) (b) (c)

Şekil 6.25 "MRM01" verisinin (a) veritabanından elde edilen referans görüntüsü, (b) algoritmanın sonucu, (c) iki görüntü arasındaki fark

Çalışmada görüntüler, atlasa oturtulup, kafatası sıyırma işlemi yapıldıktan sonra beynin alt bölgelere ayrılması işlemi ile devam edilir. Bu çalışmada beynin alt bölgelere ayrılması işlemi özellikle kafatası ayrılma işleminden sonra yapılmıştır, bunun sebebi, görüntüde istenmeyen bölgelerin, incelenecek bölgelere etki edip veri kaybına sebep olmasını engellemektir.

6.5 Beyinin Alt Bölgelere Ayrılması

MRG görüntülerinin detaylı analizi yapmadan önce, görüntülerin ön işleme tabi tutulması ve farklı bölütlenmesi gerekir. Tipik bir beyin MRG görüntüsü, kafatası, damarlar, kemik iliği, beyin-omurilik sıvısı (BOS), gri madde (GM) ve beyaz cevher (WM) bölgelerinden oluşur. Görüntünün incelenecek hastalığın yapısına göre bu alt bölgelere ayrılması gerekli olabilir. Bu amaçla literatürde birçok beyin görüntüsü bölütleme algoritması bulunmaktadır. Bu algoritmalar; kontur, şekil ve bölge temelli, istatistiksel, olasılık, atlas, örüntü tanıma, makine öğrenmesi ve hibrid yöntemler gibi farklı yöntemler olabilmektedir (Somasundaram ve Kalaiselvi 2011).

Beyin görüntülerinin analizi için geliştirilmiş pek çok yazılım paketi mevcuttur. Bunların en çok bilinenlerinden bazıları; SPM8 yazılımı, FSL yazılım paketi ve Dr. David W Shattuck tarafından geliştirilen BrainSuite olarak listelenebilir (Kasiri ve ark 2010)

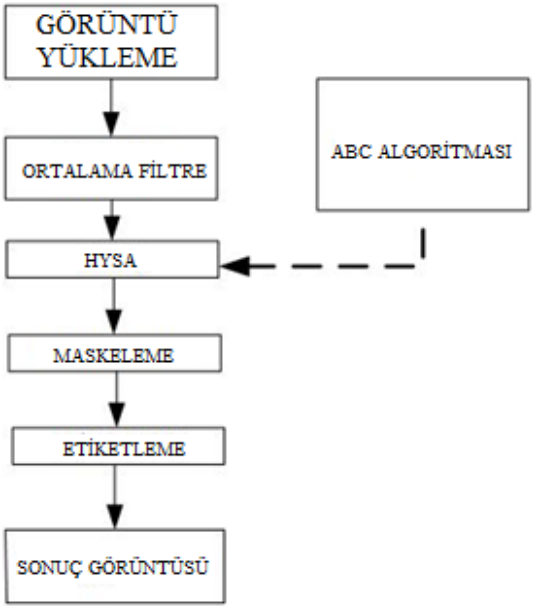
Bu çalışmada beyinde BOS, GM ve WM bölgelerinin bölünmesi için ÇK-HYSA algoritmasına dayalı yeni bir yaklaşım kullanılmıştır. ÇK-HYSA şablonları ve polinom katsayıları, ABC ile oluşturulmuştur. Bu çalışmada, ön işleme için standart ortalama filtre kullanılmıştır.

ÇK-HYSA ile beyin bölütleme algoritması BrainWeb veri seti ile değerlendirilmiştir. Veri seti, 20 adet T1 ağırlıklı MR görüntüsünden oluşmaktadır. Değerlendirmeler Jaccard, Dice, Gerçek Pozitif Fraksiyon (TPF) ve Gerçek Negatif Fraksiyon (TNF) parametreleri ile ölçülmüştür. Algoritma, daha önce Kasiri ve arkadaşları tarafından değerlendirilen SPM8, FSL FAST ve Brain Suite yazılım paketleri ile karşılaştırılmıştır (Kasiri ve ark 2010).

ABC algoritmasıyla eğitim işlemi tamamlandıktan sonra elde edilen matrisler ve polinom kökleri Eşitlik 6.67'deki gibi bulunmuştur:

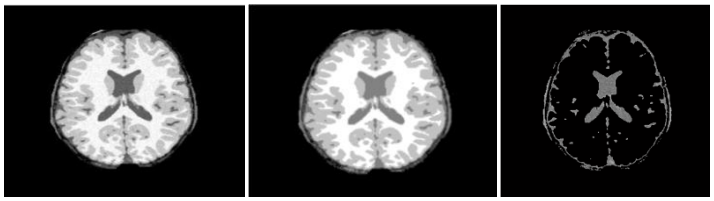
$$A=\begin{bmatrix} -0,38 & 1 & -0.46 \\ 0.195 & -1 & 0.195 \\ -0.21 & 0.72 & -0.18 \end{bmatrix}, B=\begin{bmatrix} -0.51 & -0.17 & 0.67 \\ -0.95 & 0.57 & 0.5 \\ -0.21 & -0.44 & 0.96 \end{bmatrix}, I=[0.45] \quad (6.67)$$
$$r=\begin{bmatrix} 0.93 & 0.65 & 0.18 \end{bmatrix}$$

Beyin bölütleme algoritmanın genel akış diyagramı, Şekil 6.26'da gösterildiği gibidir.

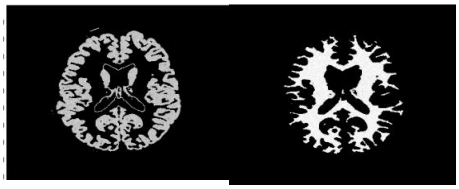


Şekil 6.26 Beyin görüntüsünü alt bölgelere ayıran ÇK-HYSA algoritmasının akış diyagramı

BrainWeb veri tabanındaki subject04'ün 120 numaralı dilimi kullanılarak elde edilen giriş ve çıkış görüntüleri algoritmanın sonucuna örnek olarak Şekil 6.27'de gösterilmiştir.



(a) (b) (c)



(d) (e)

Şekil 6.27 ÇK-HYSA ile Bölütleme örneği (a) Algoritmanın, girişine uygulanan görüntü, (b) ÇK-HYSA sonucu , (c) BOS olarak etiketlenen pikseller, (d) Gri madde olarak etiketlenen pikseller, (e) Beyaz madde olarak etiketlenen pikseller

BrainWeb veri tabanı kullanılarak yapılan ölçümlerde her bir görüntü kendi içerisinde BOS, GM ve WM bölgelerine ayrılarak ölçümler yapılmıştır. Bölütleme performansı ve standart sapma değerleri Çizelge 6.12'de gösterilmiştir. Algoritma (Kasiri ve ark 2010) tarafından daha önceden yapılan ölçümlerle karşılaştırılmıştır.

Çizelge 6.12 Algoritmanın değerlendirme sonuçları.

Yöntem	**Metrik**	**CSF**		**GM**		**WM**	
		Ortalama	STD	Ortalama	STD	Ortalama	STD
SPM8	Dice %	93,39	0,56	93,55	0,7	95,12	0,95
	J %	87,6	0,99	87,89	1,24	90,7	1,72
	TPF %	97,91	0,52	92,81	1,63	93,37	2,96
	TNF %	99,33	0,05	99,18	0,31	99,69	0,2
FSL FAST	Dice %	71,22	1,98	89,46	0,63	94,70	1,39
	J %	55,33	2,39	80,93	1,03	89,95	2,49
	TPF %	73,92	3,89	86,54	1,36	91,53	3,77
	TNF %	98,09	0,07	98,99	0,42	96,82	0,17
Brain Suite	Dice %	72,37	0,35	94,52	1,46	96,23	1,52
	J %	56,70	0,43	89,65	2,63	92,78	2,84
	TPF %	64,58	0,43	93,60	1,87	96,60	0,95
	TNF %	99,21	0,04	99,35	0,15	99,56	0,23
MS-CNN	**Dice %**	**71,80**	**2,36**	**85,74**	**1,26**	**86,62**	**1,06**
	J %	**56,06**	**2,83**	**75,07**	**1,92**	**76,42**	**1,64**
	TPF %	**78,90**	**3,66**	**83,73**	**1,80**	**93,42**	**1,70**
	TNF %	**98,67**	**0,29**	**98,94**	**0,09**	**98,76**	**0,14**

Çizelge 6.12'den de görüldüğü gibi, ÇK-HYSA algoritmasının performansının diğerlerinin gerisinde kalmamaktadır. SPM8 programının diğer algoritmalar arasında en iyi olduğu söylenebilir, çünkü SPM8 sadece saf görüntü işleme değil aynı zamanda istatistiksel analiz de gerçekleştirir. Öte yandan ÇK-HYSA algoritması ile diğer algoritmalar arasındaki fark yüksek değerlere sahip değildir.

6.6 Analiz Yapılacak Bölgenin Seçimi

MS plaklarının yapısal görünümü, akut ya da kronik olma durumuna göre değişkenlik gösterir. Kronik dönemde plaklar hemisferik beyaz cevherde geniş lezyonlar şeklinde görülebilirler. Plaklar, yüksek oranda ventrikül çevresinde, özellikle de lateral ventriküllerin ön ve arka köşelerinde görünürler (Diren 2000). Dolayısıyla, görüntüler incelenirken özellikle görüntünün beyaz cevher bölgesinin detaylı incelenmesi gerekmektedir.

Çalışmada beyin alt bölgelere ayrıldıktan sonra, inceleme için beyaz cevher bölgesi bölütlenerek ayrılmıştır. Ancak burada dikkat edilmesi gereken bir durum vardır. MS plakları, T1 ağırlıklı görüntülerde MT (Magnetization Transfer) sekansı ile görüntülendiğinde proteinlerin baskılanması ile daha net görünmektedirler (Elmalıoğlu ve Çelik 2013). Bir diğer yöntem de T2 - FLAIR sekansı ile çekilmiş görüntüler kullanarak analiz yapmaktır. Bu görüntüleme tekniği ile BOS bölgesini ve yağları baskıladığından dolayı görüntüdeki bozulmaları en aza indirmektedir (Elmalıoğlu ve Çelik 2013).

İncelenecek görüntü tipine göre beynin alt bölgelere ayrılma işlemi yapıldıktan sonra, MS plaklarının tespiti aşamasına geçilir. Bu aşamada, MS plakları gerek HYSA kullanılarak, gerek de doku özellikleri göz önünde bulundurularak tespit edilir. MS plaklarının özelliklerinden dolayı T2-FLAIR ağırlıklı görüntüler seçilir ve görüntü alt bölgelere ayrılıp beyaz cevher bölgesi analiz edilerek MS plakları tespit edilir.

6.7 MS Plaklarının Tespiti

MS plakları beyin dokusunda bozulmalara sebep olmasından dolayı, MRG görüntülerinde normal beyaz cevher görüntüsüne göre daha farklı doku özelliklerine sahiptir. Bu doku özellikleri istatistiki analizlerle, yapay zekâ teknikleriyle veya örüntü tanıma algoritmalarıyla ayırt edilebilir. Literatürde bu konuda geliştirilmiş birçok yöntem mevcuttur.

Örneğin Lei ve ark., MS hastalığının erken teşhisine yönelik yaptıkları çalışmada T2 ağırlıklı MRG görüntülerinden çeşitli bölgeler seçilmiştir. Özellik çıkartım için yeni bir komşuluk fark algoritması kullanılarak dört parametre çıkartılmıştır. Bu parametreler gözlemlenerek iki özdeğer vektörü ile örnek ifade edilebilmiştir. Çalışmada beynin mikrokozmik yapısı tartışılarak çıkartılan doku parametrelerinden, beynin normal beyaz maddesi ile beyaz görünen maddesi arasında gözle görünür bir fark olduğu istatistiki analiz sonucu gözlenmiştir (Lei ve ark 2007).

Lei ve ark. çalışmalarında ön işlem olarak yüksek frekanslı bilgiler güçlendirilmiştir. Çünkü sınıflandırılabilir bilgi yüksek frekanslarda bulunmaktadır. Fourier transformu yapıldıktan sonra, yüksek frekanslı bileşenler aşağıdaki formüllerle güçlendirilmiştir:

$$H(u,v) = \frac{1}{1+[\frac{D_0}{D(u,v)}]^{2n}} \tag{6.68}$$

$$H_{hfe}(u,v) = a + b.H(u,v) \tag{6.69}$$

A ≥ 0 ve b > a, a ϵ (0.25, 0.5), b ϵ (1.5, 2.0) bu çalışmada a=0.4 ve b= 1.7 seçilmiştir.

Çalışmada komşuluk fark metodu kullanılmıştır. Bu metod, piksel ve gri değerlerin komşuluk yoğunluğu değerlerini temel alır. Görüntünün gri yoğunluk fonksiyonunu f(x,y) ve komşuluk matrisi MxN'lik bir matris olsun. Bu durumda:

$$f'(x,y) = \frac{1}{MN-1}\sum_{(u,v)\in S} f(u,v) \tag{6.70}$$

Örneğin 8 komşuluk değerine göre piksel gri seviye farkı:

$$Diff(x,y) = \left| f(x,y) - \frac{1}{8}\sum_{(u,v)\in S} f(u,v) \right| \tag{6.71}$$

Bu metodla gri seviye yoğunluk komşuluğu matrisi elde edilir ve bu matrisden dört parametre çıkarılır (Lei ve ark 2007) :

MAX(Diff) (6.72)

$$S^2 = \frac{1}{N}\sum(Diff(i,j) - \overline{D})^2 \tag{6.73}$$

$$EN = \sum Diff(i.j)^2 \tag{6.74}$$

$$ER = \sum Diff(i,j)\, log\big(Diff(i,j)\big) \tag{6.75}$$

Yapılan analizlerden sonra MAX ve Deviasyonun toplamı DS ve fark matrisinin enerjisi EN olarak ifade edilmek üzere Çizelge 6.13'deki sonuçlar elde edilmiştir:

Çizelge 6.13 NBC,NGBC ve ABC bölgelerinin istatistiki analiz sonuçları (Lei ve ark 2007)

	NBC	**NGBC**	**NOBC**
DS	0,04130	0,05988	0,1046
	±0,01298	±0,02933	±0,04054
EN	0,07854	0,09728	0,3612
	±0,01626	±0,03639	±0,1958

Çizelgede Normal Beyaz Cevher (NBC), Normal Görünen Beyaz Cevher (NGBC) ve Normal Olmayan Beyaz Cevher (NOBC) olarak ifade edilmiştir. Çizelgede elde edilen sayısal değerlere ve bunların standart sapmalarına bakarak elde edilen öznitelik vektörlerinin, sınıflandırma için belirleyici olduğu söylenebilir (Lei ve ark 2007).

Yine Lei ve ark. 2005 yılında yaptığı benzer bir çalışmada bu bölgelerin doku özelliklerinin matematik modellerini oluşturmak da mümkün olmuştur (Lei ve ark 2005). Bu

araştırmaya göre beyin beyaz cevherinde oluşan değişimler, eğri uydurma metoduyla elde edilen aşağıdaki Eşitliklerle ifade edilebilmektedir (Lei ve ark 2005):

Enerji: $Y_1 = 0{,}044 + 0{,}152x - 0{,}023x^2 + 0.001x^3$ (6.76)

Karşıtlık: $Y_2 = 0{,}962 - 0{,}257x + 0.021x^2$ (6.77)

Deviasyon: $Y_3 = 30{,}29e^{-0{,}7x}$ (6.78)

Ters Fark Momenti: $Y_4 = 0{,}471 + 0{,}143x - 0{,}016x^2$ (6.79)

Entropi: $Y_5 = 1{,}573 - 0{,}131x$ (6.80)

Görüldüğü gibi MRG görüntülerinin örüntü özelliklerinin analizi hem istatistiki bilgi sunmakta hem de bu bilgiler sayesinde matematik model elde etmek mümkün olmaktadır. Bu tez çalışma sırasında geliştirilen yöntem, öncelikle Cerasa ve ark. tarafından geliştirilen HYSA modeline dayalı bölütleme tekniğini kullanmaktadır (Cerasa ve ark 2012). HYSA metoduyla elde edilen MS plak görüntüleri daha sonra Lei ve ark. tarafından belirlenene doku özelliklerine göre analiz edilmektedir.

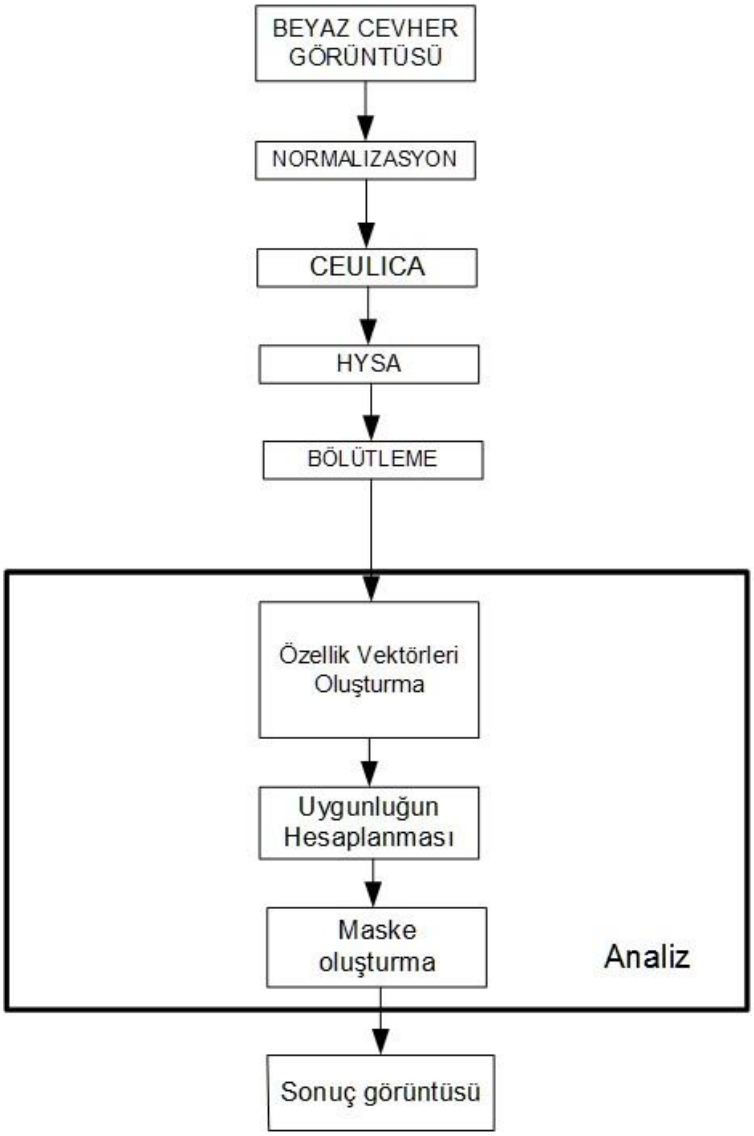
MS plaklarının sınıflandırılmasında kullanılan HYSA, Cerasa ve ark. tarafından Genetik Algoritma kullanılarak eğitilmiş ve Eşitlik 6.81'deki matris şablonu bulunmuştur (Cerasa ve ark 2012) :

$$A = \begin{bmatrix} 0{,}322 & 0{,}581 & -1.649 \\ 0{,}471 & 2{,}437 & 0{,}471 \\ -1.649 & 0{,}581 & 0{,}322 \end{bmatrix}, B = \begin{bmatrix} -1{,}200 & -3{,}646 & -3{,}454 \\ 1{,}089 & -6{,}187 & 1{,}089 \\ -3{,}454 & -3{,}646 & -1{,}200 \end{bmatrix}, I = [-6{,}628] \quad (6.81)$$

Tez çalışmasında HSYA şablonlarının bulunması için aynı yöntem izlenmiş fakat eğitimde ABC (Artificial Bee Colony) algoritması kullanılmıştır. Eğitim sonucu elde edilen matris şablonu Eşitlik 6,82'deki gibidir:

$$A = \begin{bmatrix} 0{,}33615 & -0{,}25695 & 0{,}01365 \\ 0{,}02777 & 0{,}1100 & 0{,}02777 \\ 0{,}01365 & -0{,}25695 & 0{,}33615 \end{bmatrix}, B = \begin{bmatrix} 0{,}460 & 1{,}0289 & -0{,}3823 \\ -0{,}062 & -0{,}876 & -0{,}062 \\ -0{,}3823 & 1{,}0289 & 0{,}460 \end{bmatrix}, I = [0{,}790] \quad (6.82)$$

Bu çalışmada HYSA tek başına MS plaklarını tespit edebilmektedir. Bunun yanında Lei ve ark. (Lei ve ark 2007) geliştirdiği özellik vektörlerinden de faydalanılarak daha başarılı sonuçlar elde etmek amaçlanmıştır. Algoritmanın genel akış diyagramı Şekil 6.28'deki gibidir.

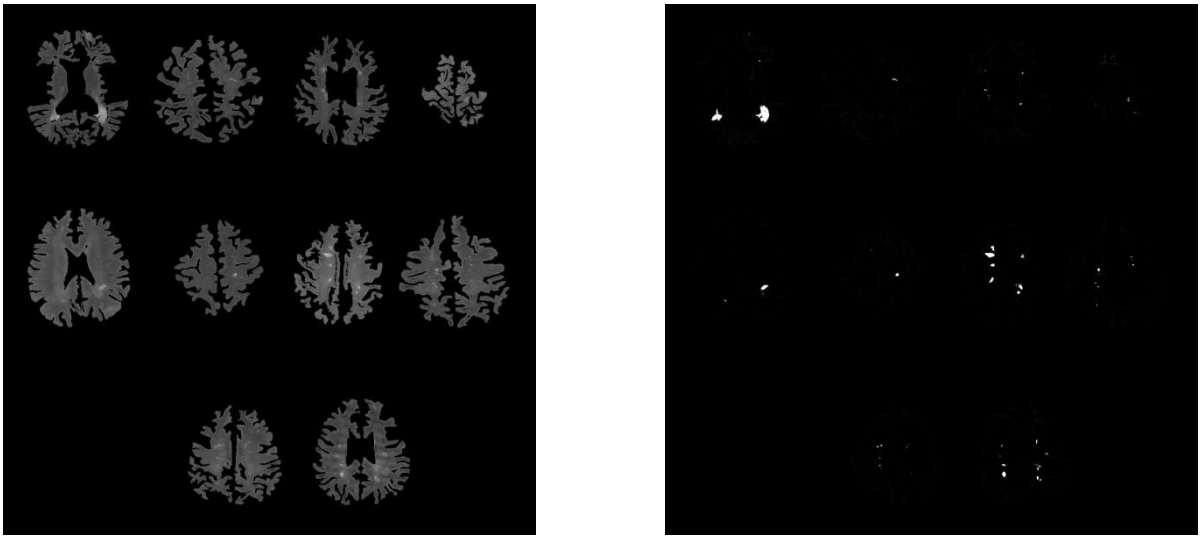


Şekil 6.28 MS plak tespiti algoritması genel akış diyagramı

Başarım ölçümlerinde ve eğitimde kullanılan kaynak ve hedef görüntüler NEÜ Meram Tıp Fakültesi'nden alınan verileri kullanarak oluşturulan MERAM veri tabanından alınmıştır. Algoritmada HYSA şablon parametrelerini belirlemek için MERAM veri tabanından elde edilen kaynak ve hedef görüntüleri kullanılmıştır. Uygunluk fonksiyonu olarak Eşitlik 5.52'deki iki boyutlu korelasyon fonksiyonu kullanılmıştır (Sutton ve ark 2009).

Başarım ölçümünde kullanılan görüntüler T2-FLAIR çekim tekniği ile kaydedilmiştir. MS'li gönüllülerden rastgele 10 MRG görüntüsü seçilmiştir. Gönüllüler 21-45 yaşları arasındadır. Gönüllülerin cinsiyeti 5 erkek 5 kadın olacak şekilde tercih edilmiştir. Kaynak görüntü setini seçtikten sonra, uzman hekim tarafından bir hedef görüntü seti oluşturulmuştur.

Hekim, kaynak veri setindeki beyin MR görüntülerinde MS plaklarını manüel olarak işaretlemiştir. Şekil 6.29'da eğitim için kullanılan kaynak ve hedef görüntüleri verilmiştir.



(a) (b)

Şekil 6.29 Eğitimde kullanılan görüntü setleri, (a) Kaynak görüntü seti (b) Hedef görüntü seti

Eğitimde, veritabanından alınan sadece tek dilimlik 10 adet görüntü kullanılmıştır. Başarım ölçümlerinde ise, veritabanındaki her bir 3 boyutlu görüntünün tüm dilimleri kullanılarak analiz yapılmış ve manüel bölütlenene MS plak hacmi ile HYSA ile bölütlenen plakların hacimleri ölçülmüştür. Ölçümlerde tutarlı sonuçlar elde edebilmek amacıyla her bir dilim 256×256 piksel olarak boyutlandırılmıştır.

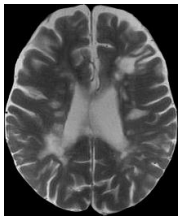
6.7.1 Başarım ölçümleri

Ölçüm işlemi, uzman hekim tarafından manüel olarak bölütlenmiş olan MS plak görüntüleri ile algoritmanın tespit ettiği plaklar arasındaki örtüşme Dice değeri ölçülerek gerçekleştirilmiştir. Çizelge 6.14'de bu ölçümlerin sonucu gösterilmektedir. Görüntüler kaydedilirken az dilim sayısı ile kaydedildiğinden ve atlaslara uyumlu olmadığından hacim ölçümleri voksel sayısı olarak alınmıştır.

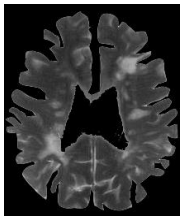
Çizelge 6.14 HYSA ile MS plaklarının bölütleme sonuçları

	Dice	Manüel Hacim	HYSA Hacmi	Hacim Oranı
MS_MRM01	0,74	18898	16244	0,85
MS_MRM02	0,99	25650	24942	0,97
MS_MRM03	0,82	28570	32628	1,14
MS_MRM04	0,67	14633	18345	1,25
MS_MRM05	0,98	10195	9855	0,96
MS_MRM06	0,67	10200	12249	1,20
MS_MRM07	0,96	15710	15227	0,96
MS_MRM08	0,81	46833	55822	1,19
MS_MRM09	0,41	18898	16244	0,85
MS_MRM10	0,74	25650	24942	0,97
Ortalama	**0,83**	**21336**	**23164**	**1,07**

Çizelge 6.14'de de görüldüğü gibi manüel ölçümler ile HYSA sonuçları birbirine yakın ve korelasyon içerisindedir. Şekil 6.30'da MS_MRM07 görüntüsünün 13. diliminin hem manüel olarak hem de HYSA ile MS plaklarının bölütlenmiş halleri ve bu iki görüntünün farkı verilmiştir.



(a)



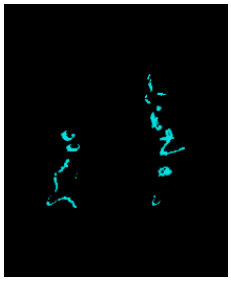
(b)



(c)



(d)



(e)

Şekil 6.30 Bölütleme sonuçları (a) MS_MRM07 görüntüsünün 13. dilimi, (b) incelenecek bölge, (c) manüel bölütleme sonucu, (d) HYSA ile bölütleme sonucu, (e) bölütleme sonuçlarının fark görüntüsü

MS plaklarının görüntüden ayrılmasından sonraki aşama, bu plakların aktif-inaktif plak olma durumlarının incelenmesidir. Bu amaçla tez çalışması kapsamında "Sanal Gadolinyum" adı verilen teknik geliştirilmiştir.

6.8 Sanal Gadolinyum Tekniği

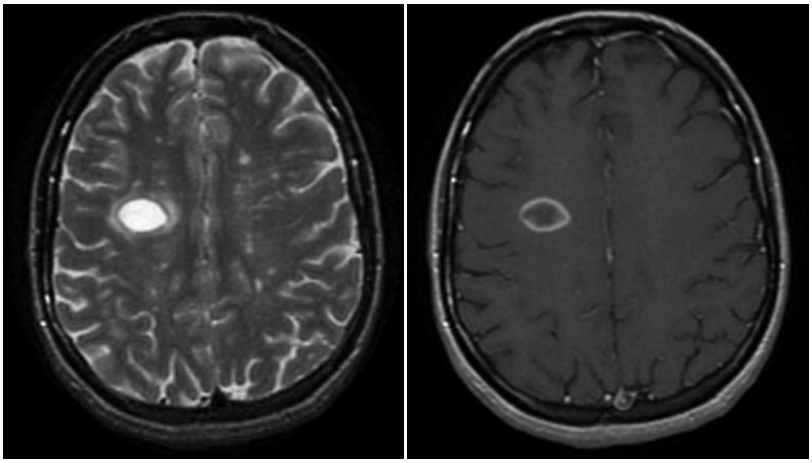
MS plaklarının yapısal görünümü, akut (aktif) ve kronik (inaktif) süreçte olmasına göre değişiklikler göstermektedir. Kronik dönemde plaklar beyaz cevherde geniş alanlar oluşturan lezyonlar şeklindedirler.Akut dönemde ise T2 ağırlıklı MR görüntülerinde yuvarlak hiperintens görüntüler olarak görünürler (Diren 2000). MS plaklarının aktiflik-inaktiflik durumunun analizinde genel olarak kontrast arttırıcı ajan olan Gadolinyum maddesi kullanılmaktadır. Gadolinyum maddesi çekimi yapılacak hastaya damar yoluyla verildikten sonra MR çekimleri gerçekleştirilir ve görüntüdeki kontrast değişimleri incelenir. MS plaklarının incelenmesinde, akut dönemdeki plaklarda Gadolinyum enjeksiyonundan sonra kontrast tutulumu olduğu görülür (Diren 2000).

Akut dönemde MS plakları; harekete geçmiş tek çekirdekli hücreler, lenfositler, mikroglia, oligodendrositler ve miyelini parçalamakta olan makrofajları içermektedir. Kronik dönemdeki plaklarda ise, kalan oligodendrositlerin yeni miyelin kılıfı oluşturma çabasından dolayı bu içeriğin yapısı değişmektedir (Piani ve ark 1991). Böylece MR görüntülerinde akut dönemdeki plaklar ile kronik dönemdeki plaklar arasında tespit edilebilir bir örüntü farkı oluştuğu söylenebilir .

Yine akut dönemde, plakların oluştuğu bölgede kan-beyin bariyerinde bozulmalar olmaktadır. Gadolinyum (Gd) bazlı kontrast maddeler ile çekilen MR görüntüleri aktif MS lezyonlarını ve akut enflamasyon nedeniyle kan-beyin bariyerinin yerel bir bozulmasını tespit etmek için kullanılır. Nadir olmasına rağmen, Gd enjeksiyonu böbrek fonksiyonlarında azalma olan hastalarda nefrojenik sistemik fibroza sebep olabilir ve ani advers etkiler için potansiyel bir risk söz konusudur (Blystad ve ark 2016).

MS'in MRG yöntemi ile teşhisinde T2-FLAIR çekim tekniği ile elde edilmiş görüntüler kullanılmaktadır. Gadolinyum ile güçlendirilmiş görüntüler söz konusu olduğunda T1 ağırlıklı görüntüler tercih edilmektedir, çünkü kontrast madde tutulumu bu çekim tekniğinde daha belirgin olarak gözlemlenebilmektedir. Şekil 6.31 (a)'da T2w çekim tekniğiyle elde edilmiş MR görüntüsü Şekil 6.31 (b)'de aynı hastadan elde edilmiş T1 ağırlıklı MR görüntüsünün gadolinyum ile çekilmiş halleri görünmektedir. Görüntüler Trebă ve ark.

"Cerebral lesions of multiple sclerosis: is gadolinium always irreplaceable in assessing lesion activity?" adlı yayınından alınmıştır (Treabă ve ark 2014).

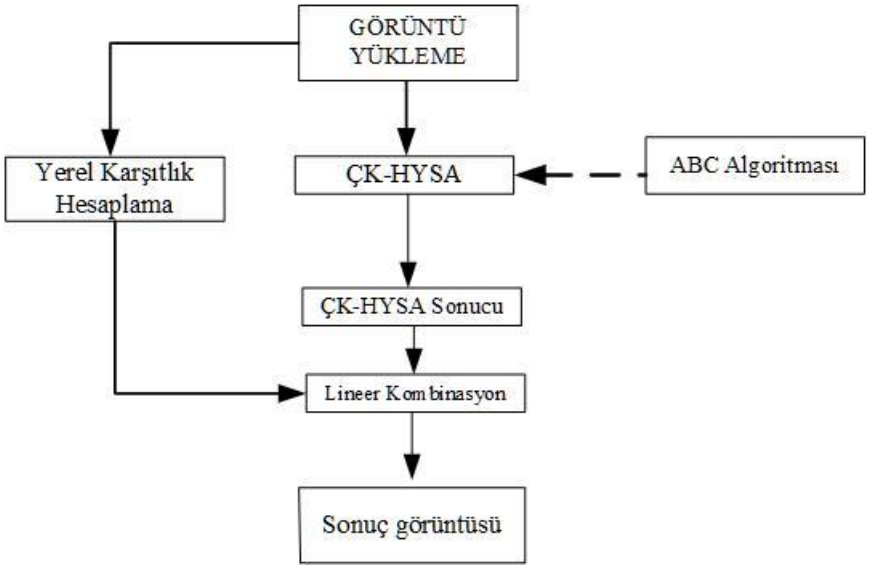


(a) (b)

Şekil 6.31 (a) T2w çekim tekniğiyle elde edilmiş MR görüntüsü (b)de aynı hastadan elde edilmiş T1 ağırlıklı MR görüntüsünün gadolinyum ile çekilmiş hali (Treabă ve ark 2014)

Bu teknik ile çekilen görüntülerde, kronik plaklarda kontrast madde tutulumu olmazken, Şekil 6.31 (b)'den de görüleceği gibi akut plaklarda kontrast madde tutulumu oluşur. Bu tez çalışmasında, MS plaklarının örüntü özelliklerinden faydalanarak plakların akut-kronik dönemde olup olmadıklarını gadolinyum enjeksiyonuna ihtiyaç duymadan belirleyecek bir metot geliştirilmiştir.

Bu metot, ÇK-HYSA mimarisidir. MS plaklarının aktif olması durumunda örüntü özelliklerinin plağın merkezine doğru farklı dış çeperlerine göre farklı olmaktadır. Plakların bu özelliğinden faydalanarak, gadolinyum maddesinin tutulum davranışı benzetilmeye çalışılmıştır. Plağın iki ayrı bölgesinin tespit edilmesi söz konusu olduğundan ÇK-HYSA'nın çıkış fonksiyonu buna göre düzenlenmiştir. Algoritmada kullanılan şablon ve fonksiyon kökleri ABC algoritması ile belirlenmiştir. Sanal gadolinyum algoritmasının genel akış diyagramı Şekil 6.32'deki gibidir.



Şekil 6.32 Sanal gadolinyum algoritması akış diyagramı.

Şekil 6.32'den de görüleceği gibi algoritma altı işlem ve bir eğitim adımından oluşmaktadır. Metotta ÇK-HYSA algoritması tek başına etkili olmadığı için Karşıtlık Geliştirme Oranı (Contrast Improvement Ratio) algoritmasında, her pikselin çevresindeki piksellere göre kontrast ilişkisini hesaplamada kullanılan Yerel Karşıtlık Hesaplama yöntemi kullanılmıştır. Yöntem Eşitlik 6.44'deki gibi ifade edilir. Eşitlikten faydalanılarak işlenecek görüntünün kontrast farklarından oluşan bir yardımcı görüntüsü de oluşturulmaktadır.

6.8.1 Başarım ölçümleri

Başarım ölçümlerinde kullanılan görüntüler MERAM veri tabanından alınmıştır. Görüntüler T2-FLAIR çekim tekniği ile kaydedilmiştir. MS'li gönüllülerden rastgele 10 MRG görüntüsü seçilmiştir. Gönüllüler 21-45 yaşları arasındadır. Gönüllülerin cinsiyeti 5 erkek 5 kadın olacak şekilde tercih edilmiştir. Görüntüler içerisinden incelenecek dilim seçildikten sonra plaklarının tespiti işlemine tabi tutularak 37 adet MS plağı görüntüsünden oluşan veri seti elde edilmiştir. Veri seti daha sonra, uzman hekim tarafından akut ve kronik olmak üzere sınıflandırılmıştır. Çizelge 6.15 doktorun ve algoritmanın sınıflandırma sonuçlarını göstermektedir. Çizelgede algoritmanın bulduğu her bir plağın merkez koordinatları, genişliği ve akut-kronik sınıflandırma sonucu gösterilmiştir.

Çizelge 6.15 Sanal gadolinyum algoritmasının başarı ölçümleri

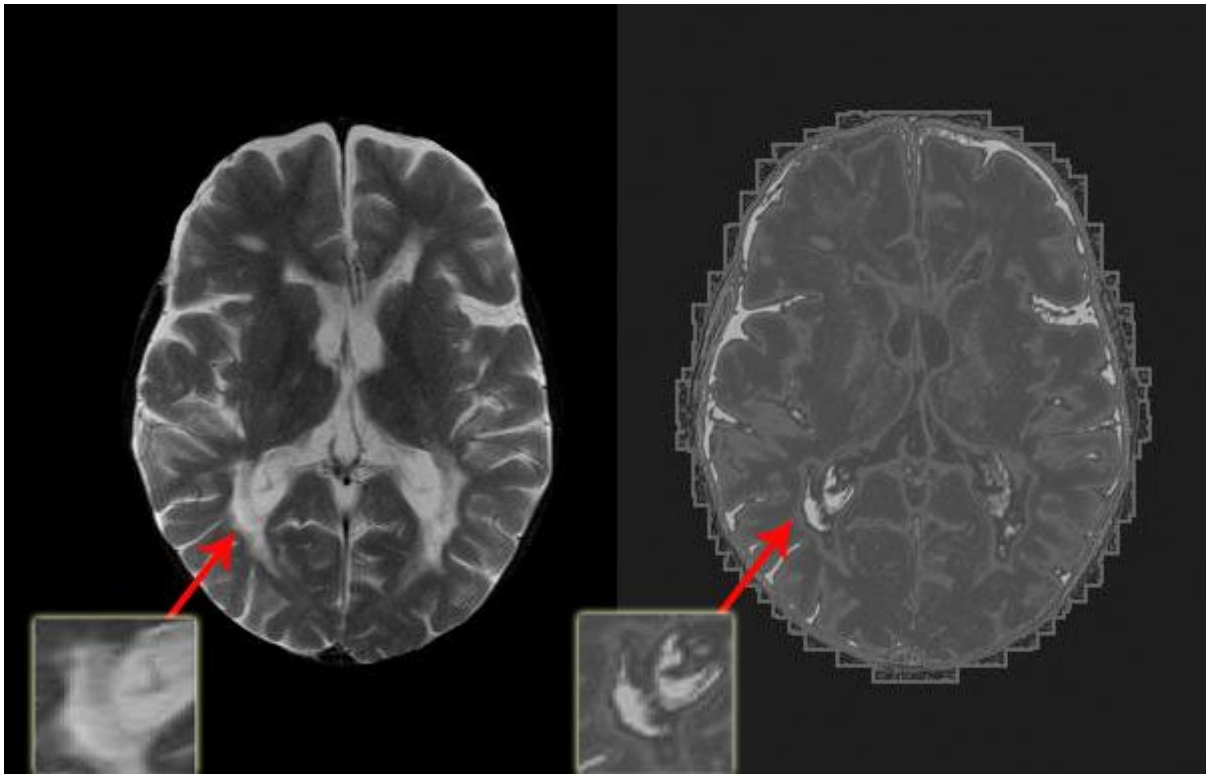
	Manüel Bölütleme			Algoritma Sonucu			
	Merkez Koordinatı	**Çap**	**Akut-Kronik**	**Merkez Koordinatı**	**Çap**	**Akut-Kronik**	**Başarım**
MS_MRM01	(154x185)	25	K	(163x213)	37	K	1
	(92x127)	59	K	(65x97)	76	A	2
	(104x204)	30	K	(97x151)	35	K	1
	(218x199)	45	K	(232x201)	39	K	1
	(119x84)	15	K	(117x94)	18	K	2
MS_MRM02	(97x228)	23	K	(109x262)	22	K	1
	(173x164)	35	A	(160x176)	30	K	2
	(216x92)	52	A	(249x88)	45	A	1
	(160x146)	14	K	(180x160)	14	K	0
MS_MRM03	(121x137)	10	K	(127x150)	9	K	0
	(132x197)	19	K	(132x174)	19	K	1
	(169x174)	52	K	(189x197)	47	K	1
MS_MRM04	(205x170)	16	A	(180x187)	17	K	0
	(93x212)	28	K	(89x178)	34	A	2
	(107x114)	11	K	(87x102)	11	K	0
MS_MRM05	(195x198)	16	K	(193x195)	18	K	1
	(207x122)	45	K	(212x137)	59	K	1
MS_MRM06	(125x123)	47	K	(140x139)	50	K	1
	(186x189)	15	K	(220x169)	14	K	0
	(149x228)	40	K	(107x218)	49	K	1
MS_MRM07	(112x117)	11	A	(105x113)	9	A	1
	(220x74)	30	A	(240x63)	36	A	1
	(84x123)	10	A	(67x112)	13	A	1
	(77x109)	46	K	(83x123)	62	A	0
	(171x180)	42	K	(173x174)	45	K	0
	(204x130)	33	A	(151x103)	42	A	0
MS_MRM08	(82x82)	57	K	(87x71)	68	K	1
	(187x132)	37	K	(150x114)	49	A	2
	(200x173)	13	K	(144x170)	17	K	0
MS_MRM09	(158x144)	20	K	(115x101)	22	K	0
	(195x80)	22	K	(230x95)	22	K	0
	(161x159)	16	A	(175x178)	16	A	1
	(216x84)	45	K	(211x98)	50	K	1
MS_MRM10	(75x201)	47	K	(56x225)	64	K	1
	(151x76)	16	K	(126x89)	22	K	1
	(75x161)	39	K	(56x171)	35	A	2
	(214x227)	58	K	(244x265)	58	K	1

Çizelge 6.15'deki başarım ölçümünü ifade eden sınıf numaralarının açıklaması şu şekildedir:

0: başarısız, 1: başarılı, 2:plak tespiti başarılı sanal gadolinyum başarısız.

Gadolinyum benzetimini yaparken metot T1w çekim tekniği ile çekilmiş görüntülere ihtiyaç duymadan, T2-FLAIR görüntüler üstünde çalışmıştır. Kontrast madde tutulumunu benzetirken algoritma gadolinyum maddesinden farklı olarak plağın dış çeperini değil iç

kısmını boyamaktadır. Şekil 6.33'de MS_MRM10 görüntüsünün sanal gadolinyum algoritması öncesi ve uygulama sonucunda tutulum oluşan bölgesi gösterilmektedir.



Şekil 6.33 MS_MRM10 görüntüsünün sanal gadolinyum algoritması öncesi ve uygulama sonucunda tutulum oluşan bölgesi

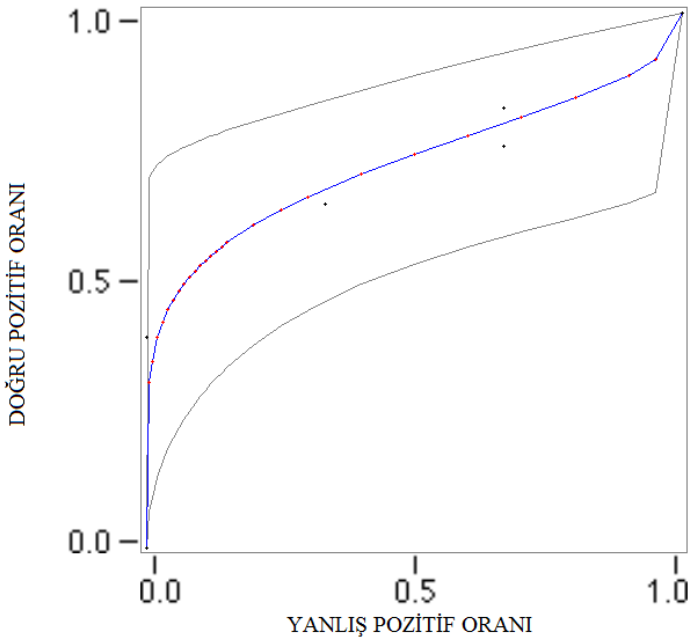
Şekil 6.33'den de görüldüğü gibi algoritma bir sınıflayıcı olarak değil, gadolinyum maddesinin dijital benzetimi olarak çalışmaktadır. İşaretlenen bölge, akut bir MS plağıdır ve inflamasyon mevcuttur. Öte yandan görüntüdeki kronik evredeki plaklarda böyle bir tutulum görülmemektedir. Şekil 6.33'de görüldüğü gibi MS plağının yanı sıra ventrikülün bir bölgesinin boyandığı da görülmektedir. Bu durum, gerçek gadolinyum uygulamaları için de geçerlidir. Gadolinyum uygulamalarında ventrikül bölgesinde kan-beyin bariyeri olmadığı için buralarda da kontrast madde tutulu görülmektedir. Bu da sanal gadolinyum algoritmasının başarısı için ek bir göstergedir.

Metot uygulanırken çalışan ÇK-HYSA algoritmasının matris şablonları ve çıkış fonksiyonun kökleri Eşitlik 6.83'deki gibidir.

$$A=\begin{bmatrix} -0,726 & 0,962 & 0,096 \\ -0,171 & -0,708 & -0,029 \\ 0,361 & -0,024 & 0,172 \end{bmatrix}, B=\begin{bmatrix} 0,713 & 0,242 & 0,436 \\ 0,693 & 0,295 & -1,000 \\ 1,000 & -1,000 & 0,683 \end{bmatrix}, I=[0.746] \quad (6.83)$$

$$r=\begin{bmatrix} 0,93 & 0,85 \end{bmatrix}$$

Yöntemin genel başarım ölçüm analizi için ise, yine daha önce doktor tarafından işaretlenmiş MS plakları ile yöntemin bulduğu MS plaklarının karşılaştırılması yapılarak Şekil 6.34'deki ROC eğrileri elde edilmiştir.



Şekil 6.34 Genel başarı ölçümünü gösteren ROC eğrisi

Ölçümler sonucu elde edilen nicel değerler şöyledir:

Olguların Sayısı: 37

Doğru sınıflandırma sayısı : 24

Doğruluk: % 64,9

Duyarlılık: % 75

Özgüllük: % 33,3

Yanlış sınıflandırılan pozitif olgu sayısı : 7

Yanlış sınıflandırılan negatif olgu sayısı: 6

Ampirik ROC Alanı: 0.708

7 SONUÇLAR VE ÖNERİLER

7.1 Sonuçlar

MS hastalığı nörolojik fonksiyonlarda ilerleyici ve kalıcı kayıplarla sebep olan bir hastalıktır. Hastalık nöronların dış kısmını kaplayan Schwann hücrelerinden oluşan miyelin kılıfı adı verilen bir yapıda bozulmalara sebep olmaktadır. MS Hastalığı MSS içerisinde birden çok bölgede ortaya çıkan demiyelinizasyona uğramış plaklar şeklinde görülür.

MS plakları özellikle beyin beyaz cevherinde görülmektedir. MS hastalığının oluşturduğu doku bozulmaları, MRG teknikleri sayesinde tanılanabilmektedir. Bu plaklar çeşitli boyutlarda ve değişik yerlerde meydana geldiklerinden dolayı, kesin olarak belirlenmesi önemlidir. Bu amaçla görüntü işleme ve yapay zekâ teknikleri uzmanların hizmetine sunulmuştur. Bu tez çalışmasında görüntü işleme ve yapay zekâ teknikleri kullanarak bu bölgede hastalığın erken tanılanması ve kontrast madde kullanılmadan, tespit edilen MS plaklarının aktiflik-inaktiflik durumlarının tespiti için yeni bir yöntem geliştirilmesi amaçlanmıştır.

Çalışmada temel olarak HYSA algoritması ve geliştirilmiş bir modeli olan ÇK-HYSA algoritması örüntü tanıma ve sınıflandırma amacıyla kullanılmıştır. Algoritmanın eğitim parametreleri ABC algoritması ile bulunmuştur (Karaboğa 2014).

Çalışmada takip edilen adımlar görüntünün elde edilmesinden sonra, incelenecek ilk görüntünün beyin atlasları ile çakıştırılması ile başlar. Bu işlem için ilgin dönüşümü metodu tercih edilmiş ve ilgin dönüşüm parametreleri ABC algoritmasıyla belirlenmiştir..

Görüntünün istenilen atlas modeline çakıştırılması adımından sonra, normalizasyon ve görüntü ön işleme aşamasına geçilir. Bu amaçla CEULICA adlı bir görüntü güçlendirme algoritması geliştirilmiştir (Yilmaz ve Ozbay 2014).

CEULICA algoritması beyin MRG görüntüleri için yeni bir karşıtlık güçlendirme algoritmasıdır. BrainWeb ve MIDAS veri tabanları algoritmanın başarısını değerlendirmek için kullanılmıştır. Bu çalışmada, sunulan algoritmanın performansı hem 8-bit ve 12-bit gri görüntüler üzerinde değerlendirilmiştir. 8-bit görüntü seti için, BrainWeb multipl skleroz benzetim veri tabanı kullanılmıştır. BrainWeb veri tabanı T1, T2 ve PD yöntemi ile elde edilmiş MRG görüntü taramaları içerir ve 181×217 piksel çözünürlüğe sahip 181 adet 1 mm kesit kalınlığı,% 3 gürültü ve% 20 bozulma değerlerine sahip görüntüden oluşur.

12-bit görüntü seti için MIDAS-NAMIC veri tabanı kullanılmıştır. MIDAS-NAMIC veri tabanı sağlıklı gönüllülerin beyin MRG görüntülerini içermektedir. Görüntüler standart

protokoller altında 3T ünite kullanılarak 1×1×1 mm3 voksel hassasiyetiyle elde edilmiştir. Bu çalışmada, T1-FLASH, T1-MP-RAGE ve T2 dizileri kullanılmaktadır.

CEULICA her çekim tekniğine uygun olarak tasarlanmış farklı bir katsayı dizisi ile çalışır. Katsayı dizilerinin oluşturulması için Karaboğa ve arkadaşları tarafından geliştirilen ABC algoritması kullanılmıştır (Karaboga ve Akay 2009). CEULICA farklı görevler için farklı katsayı dizilerine ihtiyaç duyar. Örneğin, T1 yöntemi görüntüler için oluşturulan katsayı seti PD veya T2 yöntemi görüntüler için uygun değildir. Öte yandan T1 görüntüler için oluşturulan katsayı seti T1-FLASH ve T1-MP-RAGE görüntülere uygulanabilir. Aynı zamanda uygun katsayı dizileri kullanılarak bölütleme yapmak da mümkündür.

Deney 1'de, görülmüştür ki algoritma 5,844 CIR, 6,217 EME, 15,045 AMBE ve 22,150 dB PSNR ortalama puanları ile T1 yöntemi görüntülerinde en iyi başarıyı göstermiştir. Algoritma ayrıca, T2 ve PD görüntüleri ile yeterli iyi bir performans sergilemektedir; CEULICA ile işlenmiş T2 görüntülerde 4,736 CIR, 9,251 EME, 17,652 AMBE ve 12.680 dB PSNR ortalama puanları almıştır. CEULICA ile PD görüntü değerlendirme puanları ortalama olarak 3,594 CIR, 4,871 EME, 6,209 AMBE ve 17,211 dB PSNR değerlerine ulaşmıştır. Ancak, hâlâ T2 ve PD çekim teknikleri için doğrusal harmanlama katsayıları ekstra araştırma ile geliştirilmesi gerekmektedir.

Deney 2'de, algoritma 6,983 CIR, 17,326 EME, 3,514 AMBE ve 30,157 dB PSNR ortalama puanları ile T1-MP-RAGE görüntüleri ile en iyi şekilde gerçekleştirir. T1-FLASH yöntemidir görüntüleri ile algoritmanın performansı 10,191 CIR, 12,820 EME, 2,884 AMBE ve 30,948 dB PSNR ortalama değer puanları ile tatmin edici sonuçlar verir. CEULICA ile işlenmiş MIDAS-NAMIC veri tabanında T2 tipi görüntülerin değerlendirilme puanları 2.705 CIR, 73,111 EME, 12,683 AMBE ve 20,240 dB PSNR ortalama değer olarak puanlanır.

Tez çalışmasında bir sonraki adım, görüntüdeki beyin ve kafatası bölgelerinin ayrılmasıdır. Bu işlem, kafatası ve diğer gereksiz bölgelerin, beyin bölgesinin analizini etkileyecek veriler içermesidir. Bu işleme literatürde kafatası sıyırma adı verilir. Tez çalışmasında kafatası sıyırma işlemi için mCNN-MRI-SS isimli algoritma geliştirilmiştir (Yilmaz ve ark 2016). Algoritma hem T1 hem de T2 ağırlıklı MR görüntüleri üstünde çalışabilmektedir. Algoritma, HYSA ve ÇK-HYSA topolojisine dayanan, beyin MR görüntü işlemede yeni bir yöntem sunmaktadır. Değerlendirmeler, önerilen algoritmanın performansının diğerlerinin gerisinde olmadığını göstermektedir. Algoritmanın ayrıca, Talaiarch atlasına uyumlu olmayan veriler üzerinde çalışma ve hem T1 hem de T2 ağırlıklı

görüntülere uyumlu olma gibi ekstra yetenekleri vardır. Algoritma her dilimi bağımsız olarak analiz eder, bu nedenle algoritma çok çekirdekli işlemcilerde paralel analiz gerçekleştirebilir. Algoritma başarısını ölçmek için üç ayrı deney gerçekleştirilmiştir:

Deney 1'de BrainWeb veri tabanından elde edilen 20 normal T1 ağırlıklı MRG verileri kullanılmıştır. mCNN-MRI-SS algoritması 0,595 Jaccard, 0,744 Dice, 0,0344 TPF ve 0,383 TNF ortalama değerleri elde etmiştir.

Deney 2'de, NAMIC veri tabanından elde edilen 20 normal T2 ağırlıklı MRG verileri kullanılmıştır. Algoritma, T2 ağırlıklı görüntülerle 0,8379 Jaccard, 0,8986 Dice, 0,0125 TPF ve 0,1511 TNF ortalama değerlerine ulaşmıştır.

Deney 3'ün sonuçlarında algoritmanın başka bir kabiliyeti de görülebilir. Önceki veri tabanları Talairach uyumlu, iyi oluşturulmuş veri tabanlarıdır. Öte yandan, hastaneden alınan MRG verileri Talairach uyumlu değildir ve veriler aşağı örneklenmiştir. Veriler, eksik veri olduğu anlamına gelen 10 mm dilim kalınlığına sahiptir. Hastaneden alınan 10 normal T1 ağırlıklı MRG verileri. BET ve BSE algoritmaları, bu tür verilerle kafatası sıyırma konusunda hoş performans sergilemedi. Öte yandan mCNN-MRI-SS algoritması, her dilim üzerinde bağımsız olarak çalışır, böylece algoritma bu verilerle başarıyla sonuçlanır. Algoritma, 0.8297 Jaccard, 0.9012 Dice, 0.0951 TNF ve 0.1225 TPF ortalama değerlerini elde etmiştir.

Bununla birlikte mCNN-MRI-SS algoritmasının bazı zayıf yönleri vardır, algoritma anterior ve posterior dilimlerdeki kafatası sıyırma işleminde düşük performans göstermektedir. Bunun nedeni, algoritmanın analiz aşamasındaki hesaplama hatalarıdır.

Çalışmadaki takip eden adım kafatası bölgesinden arındırılmış görüntünün, alt bölgelere ayrılarak, MS plaklarının inceleneceği bölgeleri net bir şekilde belirlemektir. Bu amaçla ÇK-HYSA temelli bir yöntem geliştirilmiştir.

Tekniğin, ÇK-HYSA algoritması tek bir çalıştırmada çoklu bölütleme gerçekleştirebilen benzersiz bir avantaja sahiptir. Çizelge 6.12'de de görüldüğü gibi, algoritmanın performansının diğerlerinin gerisinde kalmamaktadır. Karşılaştırma yapılan algoritmalardan SPM8 programının diğer algoritmalar arasında en iyi olduğu söylenebilir, çünkü SPM8 sadece saf görüntü işleme değil aynı zamanda istatistiksel analiz de gerçekleştirir. Bu, SPM8 algoritmasını daha kesin sonuçlar vermesini sağlar . Öte yandan ÇK-HYSA algoritması ile diğer algoritmalar arasındaki fark büyük değerlere sahip değildir, dolayısıyla MS-CNN algoritmasının bu ilkel versiyonunun umut verici olduğu söylenebilir.

Algoritma, herhangi bir atlas veya görüntü kaydı gerektirmediği için, algoritma, Talairach uyumlu olmayan veriler üzerinde çalışmak gibi ekstra yeteneklere de sahiptir. Algoritma her dilimi bağımsız olarak analiz eder, bu nedenle algoritma çok çekirdekli işlemcilerde paralel analiz gerçekleştirebilir.

Genel akış diyagramına göre bir sonraki adım, MS plaklarının tespitidir. Bu işlem için Lei ve ark. tarafından tespit edilen örüntü parametreleri (Lei ve ark 2007) ile Cerasa ve ark. tarafından geliştirilen (Cerasa ve ark 2012) HYSA temelli yöntemin bir kombinasyonu kullanılmıştır. Bu yeni geliştirilen teknik Şekil 6.28'deki akış diyagramıyla ifade edilir.

Algoritmanın başarısı Dice metoduyla ölçülmüştür. Algoritma başarısı manüel olarak sınırları ve hacmi belirlenmiş MS plaklarıyla karşılaştırılmıştır. Genel ortalamaya bakıldığında yöntemin manüel ölçümlerin bir miktar üstünde hacim işaretlediği görülmektedir. Bunun sebebi üzerinde çalışılan T2-FLAIR görüntülerinde ventrikül bölgesinin MS plaklarına benzer doku özellikleri taşımasıdır. Bu algoritmanın bazı görüntülerde hatalı sonuç vermesine sebep olmaktadır.

Genel akış diyagramına göre en son aşama MS plaklarının akut-kronik olma durumunun incelenmesidir. Bu amaçla ÇK-HYSA temelli bir algoritma geliştirilmiştir. Yöntem gadolinyum adlı kontrast arttırıcı boyar maddenin davranışını modellemektedir. Gadolinyum maddesi kana enjekte edildiğinde, akut MS plaklarında kan-beyin bariyerini aşarak, bölgeyi boyamaktadır. Geliştirilen algoritma ise benzer bir davranış göstererek, kan-beyin bariyeri bölgesini koyulaştırırken, plağın iç bölgesinde parlamaya sebep olmaktadır.

Şekil 6.33'de sanal gadolinyum algoritmasının bir uygulama sonucu gösterilmiştir. Algoritma bir sınıflayıcı olarak değil, gadolinyum maddesinin dijital benzetimi olarak çalışmaktadır. Şekil 6.33'de görüldüğü gibi MS plağının yanı sıra ventrikülün bir bölgesinin boyandığı da görülmektedir. Gerçek gadolinyum uygulamalarında da bu bölge kontrast madde tutulumu yapmaktadır. Bu da sanal gadolinyum algoritmasının başarısı için ek bir göstergedir.

Bu çalışmanın her aşamasında, o aşamaya özgü yeni bir yöntem geliştirilmiştir. Geliştirilen yöntemlerden elde edilen sonuçlarla, "Turkish Journal of Electrical Engineering and Computer Sciences" dergisinde 2014 yılında "Contrast enhancement using linear image combinations algorithm (CEULICA) for enhancing brain magnetic resonance images" adlı makale yayınlanmıştır. 2016 yılında "9th International Conference on Computer and Electrical Engineering (ICCEE 2016)" adlı konferansta sunulan "Brain Image Segmentation Using Multistable Cellular Neural Networks" bildiri de yine tez çalışmasından elde edilen

sonuçlarla yayınlanmıştır. Son olarak 2016 yılında "Neural Computing and Applications" dergisinde yayınlanan "A new method for skull stripping in brain MRI using multistable cellular neural networks" adlı makale de bu tez çalışmasından elde edilen yöntem ve sonuçlarla yazılmıştır.

7.2 Öneriler

Tez çalışmasına genel olarak bakıldığında, birden çok yöntemin bir araya geldiği, her bir aşamanın gendi içerisinde yenilikler barındırdığı bir teknik olduğu söylenebilir. Teknik özellikle MS için geliştirilmiştir ve bir paket program özelliği taşımaktadır. Bunun yanında uygun parametrelerin belirlenmesi ile başka hastalıkların tespitinde kullanılması da mümkündür. Çalışmada sunulan tekniğin paket program haline getirilmesi halinde muadillerinin yerine kullanılabileceği ve böylece ülke ekonomisine katkıda bulunabileceği düşünülmektedir. Tez çalışmasından sonraki dönemde bu alanda çalışmalar gerçekleştirilebilir.

Bunun yanında tez çalışmasında tanıtılan tekniğin içerisinde kullanılan alt yöntemlere bakıldığında görüntü çakıştırma, kafatası sıyırma, MS plaklarının tespiti gibi aşamalarda kullanılan analiz algoritmaları daha detaylı incelenebilir. Analiz algoritmaları keskin sınırlara sahip bir sınıflandırma yaklaşımına sahiptir. Algoritmaların başarısı, daha fazla analiz parametresi eklenerek artırılabilir. Ya da bulanık mantık gibi daha hassas analizler yapabilecek yöntemler kullanılabilir.

Bir diğer sorun kafatası sıyırma algoritmasının yavaşlığıdır. Bunun sebebi dilim temelli çalışırken bulunan parçaların her birinin teker teker inceleniyor olmasıdır. Algoritmanın başarı oranları, algoritmada analiz iş akışını geliştirerek artırılabilir.

Beynin alt bölgelere ayrılmasında kullanılan algoritmada ise zayıf performansın sebebi, algoritmanın sınıflar arasındaki sınırları kesin belirleyememesinden kaynaklanmaktadır. Gelecekteki çalışmalarda, bu sorunları işleme koymak için yeni adımlar eklenecektir. Algoritmanın örüntü algılama yeteneğinin umut vericidir fakat gelecekte algoritmanın hassasiyetinin arttırılmalıdır.

Geliştirilen sanal gadolinyum tekniği mevcut durumda T2-FLAIR tekniği ile elde edilen görüntülerde çalışmaktadır. Uygun şablon matrisleri belirlenerek yöntemin diğer çekim tekniklerine de uyumlu olması sağlanabilir.

Tezde sunulan bu genel teknik mevcut hali ile amacına ulaşmış olsa da daha detaylı çalışmalarla geliştirilmeye açıktır.

8 KAYNAKLAR

A.Rajendran, Dhanasekaran R, 2012. Fuzzy Clustering and Deformable Model for Tumor Segmentation on MRI Brain Image: A Combined Approach. Procedia Engineering, 30, 327-33.

Akay B, Karaboga D, 2015. A survey on the applications of artificial bee colony in signal, image, and video processing. Signal, Image and Video Processing, 9, 4, 967-90.

Akça O, 2009. Erken başlangıçlı multiple skleroz hastalarının fonksiyonel manyetik rezonans görüntüleme ile kortikal fonksiyonların değerlendirilmesi, Tıpta Uzmanlık Tezi, Hacettepe Üniversitesi.

Altıntaş A, Benbir G, 2005. Miyelinizasyon, Demiyelinizasyon ve Remiyelinizasyon Mekanizmaları. Türk Nöroloji Dergisi, 11, 2, 7.

Asyalı MH, Kara S, Yılmaz B, 2014. Biyomedikal Mühendisliğinin Temelleri. In. Eds. ANKARA: Nobel Akademik Yayıncılık, p.

Atalay K, Diren HB, Gelmez S, Incesu L, Terzi M, 2005. The effectiveness of magnetization transfer technique in the evaluation of acute plaques in the central nervous system of multiple sclerosis patients and its correlation with the clinical findings. Diagn Interv Radiol, 11, 3, 137-41.

Aubert-Broche B, Evans AC, Collins L, 2006. A new improved version of the realistic digital brain phantom. NeuroImage, 32, 1, 138-45.

Aubert-Broche B, Griffin M, Pike GB, Evans AC, Collins DL, 2006. Twenty new digital brain phantoms for creation of validation image data bases. IEEE transactions on medical imaging, 25, 11, 1410-6.

Baratti C, Barkhof F, Hoogenraad F, Valk J, 1995. Partially saturated fluid attenuated inversion recovery (FLAIR) sequences in multiple sclerosis: comparison with fully relaxed FLAIR and conventional spin-echo. Magnetic resonance imaging, 13, 4, 513-21.

Barbosa S, Blumhardt LD, Roberts N, Lock T, Edwards RH, 1994. Magnetic resonance relaxation time mapping in multiple sclerosis: normal appearing white matter and the "invisible" lesion load. Magnetic resonance imaging, 12, 1, 33-42.

Beken S, Talim B, Anlar B, 2013. Subakut sklerozan panensefalitte demiyelinizasyon mekanizması: deneysel bir çalışma. Çocuk Sağlığı ve Hastalıkları Dergisi, 5.

Blonda P, Satalino G, Baraldi A, De Blasi R, 1998. Segmentation of multiple sclerosis lesions in MRI by fuzzy neural networks: FLVQ and FOSART. 1998 Conference of the North American Fuzzy Information Processing Society - Nafips, 39-43.

Blystad I, Håkansson I, Tisell A, Ernerudh J, Smedby Ö, Lundberg P, Larsson E-M, 2016. Quantitative MRI for Analysis of Active Multiple Sclerosis Lesions without Gadolinium-Based Contrast Agent. American Journal of Neuroradiology, 37, 1, 94-100.

Boesen K, Rehm K, Schaper K, Stoltzner S, Woods R, Luders E, Rottenberg D, 2004. Quantitative comparison of four brain extraction algorithms. NeuroImage, 22, 3, 1255-61.

BrainWeb: Simulated Brain Database. McGill University, Erişim tarihi 04.09.2015. Erişim adresi, http://brainweb.bic.mni.mcgill.ca/brainweb/.

Bullitt E, Zeng D, Gerig G, Aylward S, Joshi S, Smith JK, Lin W, Ewend MG, 2005. Vessel tortuosity and brain tumor malignancy: a blinded study. Academic radiology, 12, 10, 1232-40.

Cerasa A, Bilotta E, Augimeri A, Cherubini A, Pantano P, Zito G, Lanza P, Valentino P, Gioia MC, Quattrone A, 2012. A Cellular Neural Network methodology for the automated segmentation of multiple sclerosis lesions. Journal of neuroscience methods, 203, 1, 193-9.

Charcot JM, 1868. Histologie de la sclérose en plaques, p.
Chau W, McIntosh AR, 2005. The Talairach coordinate of a point in the MNI space: how to interpret it. NeuroImage, 25, 2, 408-16.
Chen Z, Abidi BR, Page DL, Abidi MA, 2006. Gray-level grouping (GLG): an automatic method for optimized image contrast enhancement--Part II: the variations. IEEE transactions on image processing : a publication of the IEEE Signal Processing Society, 15, 8, 2303-14.
Chow CK, Kaneko T, 1972. Automatic boundary detection of the left ventricle from cineangiograms. Comput Biomed Res, 5, 4, 388-410.
Chua LO, 1989. Cellular Neural Networks. Artificial Neural Networks : Journees Delectronique 1989, 105-.
Chua LO, Roska T, 2002. Cellular Neural Networks and Visual Computing: Foundations and Applications, Cambridge University Press, p.
Chua LO, Yang L, 1988. Cellular neural networks: applications. Ieee T Circuits Syst, 35, 10, 1273-90.
Chua LO, Yang L, 1988. Cellular neural networks: theory. Ieee T Circuits Syst, 35, 10, 1257-72.
Clarke LP, Velthuizen RP, Camacho MA, Heine JJ, Vaidyanathan M, Hall LO, Thatcher RW, Silbiger ML, 1995. MRI segmentation: methods and applications. Magnetic resonance imaging, 13, 3, 343-68.
Cocosco CA, Kollokian V, Kwan RK-S, Pike GB, Evans AC. Brainweb: Online interface to a 3D MRI simulated brain database. NeuroImage.
Collins DL, Zijdenbos AP, Kollokian V, Sled JG, Kabani NJ, Holmes CJ, Evans AC, 1998. Design and construction of a realistic digital brain phantom. IEEE transactions on medical imaging, 17, 3, 463-8.
Compston A, Coles A, 2008. Multiple sclerosis. Lancet, 372, 9648, 1502-17.
Değirmenci E, 2006. Relapsing Remitting Multipl Skleroz Hastalarında Vestibüler Semptomlar ve Elektronistagmografi Bulguları, T.C. Pamukkale Üniversitesi Denizli.
Demirhan A, Güler İ, 2011. Combining stationary wavelet transform and self-organizing maps for brain MR image segmentation. Engineering Applications of Artificial Intelligence, 24, 2, 358-67.
Despotovic I, Goossens B, Philips W, 2015. MRI segmentation of the human brain: challenges, methods, and applications. Computational and mathematical methods in medicine, 2015, 450341.
Diren HB, 2000. MAgnetik Rezonans Görüntüleme: Kranium-2, Ankara, Sevgi Özel Sağlık Hizmetleri A.Ş., Mine Ofset Ankara, p.
El-Dahshan E-SA, Mohsen HM, Revett K, Salem A-BM, 2014. Computer-aided diagnosis of human brain tumor through MRI: A survey and a new algorithm. Expert Systems with Applications, 41, 11, 5526-45.
Elmalıoğlu M, Çelik A, 2013. MR El Kitabı - Temel MR Fiziği - Hasta Pozisyonları - Grafiksel Planlamalar ve Protokoller, İstanbul, p. 247.
Friston KJ, 2007. Statistical parametric mapping : the analysis of functional brain images, Amsterdam; Boston, Elsevier / Academic Press, p.
Glocker B, Sotiras A, Komodakis N, Paragios N, 2011. Deformable medical image registration: setting the state of the art with discrete methods. Annu Rev Biomed Eng, 13, 219-44.
Gonzalez RC, Woods RE, 2006. Digital Image Processing (3rd Edition), Prentice-Hall, Inc., p.
Gonzalez RC, Woods RE, Eddins SL, 2004. Digital Image Processing Using MATLAB, Pearson Education, p.

Griffiths DJ, 1995. Introduction to quantum mechanics, Upper Saddle River, N.J., Prentice Hall, p.

Grossman RI, Gonzalez-Scarano F, Atlas SW, Galetta S, Silberberg DH, 1986. Multiple sclerosis: gadolinium enhancement in MR imaging. Radiology, 161, 3, 721-5.

Guzelis C, Karamahmut S. Recurrent perceptron learning algorithm for completely stable cellular neural networks. Cellular Neural Networks and their Applications, 1994. CNNA-94., Proceedings of the Third IEEE International Workshop on, 177-82, 18-21 Dec 1994.

Myelin and nerve structure, 2006. Erişim tarihi 25.06. Erişim adresi, http://www.healthcentral.com/multiple-sclerosis/encyclopedia/myelin-and-nerve-structure-4009613.

Hernández JAM, Castaneda FG, Cadenas JAM. Multistable cellular neural networks and their application to image decomposition. 2009 52nd IEEE International Midwest Symposium on Circuits and Systems, 873-6.

Honeyman-Buck J, 2012. Thomas M. Deserno (ed): Biomedical Image Processing. Journal of digital imaging, 25, 6, 689-91.

Horsfield MA, Bakshi R, Rovaris M, Rocca MA, Dandamudi VSR, Valsasina P, Judica E, Lucchini F, Guttmann CRG, Sormani MP, Filippi M, 2007. Incorporating domain knowledge into the fuzzy connectedness framework: Application to brain lesion volume estimation in multiple sclerosis. IEEE transactions on medical imaging, 26, 12, 1670-80.

http://chemwiki.ucdavis.edu/, (2014). Section 5.1: The origin of the NMR signal. image004.png. http://chemwiki.ucdavis.edu/Organic_Chemistry/Organic_Chemistry_With_a_Biological_Emphasis/Chapter_05%3A_Structure_Determination_II/Section_5.1%3A_The_origin_of_the_NMR_signal, http://chemwiki.ucdavis.edu/. **880 x 744:** Precession of Photons.

Chua's circuit diagram and equations, 2015. Erişim. Erişim adresi, http://www.chuacircuits.com/diagram.php.

Comparing different types of imaging, 2015. NPS: Better choices, Better health, Erişim. Erişim adresi, http://www.nps.org.au/medical-tests/medical-imaging/for-individuals/imaging-compared.

Jenkinson M, Beckmann CF, Behrens TE, Woolrich MW, Smith SM, 2012. Fsl. NeuroImage, 62, 2, 782-90.

Kabir MH, Abdullah-Al-Wadud M, Chae O, 2010. Brightness preserving image contrast enhancement using weighted mixture of global and local transformation functions. Int. Arab J. Inf. Technol., 7, 4, 403-10.

Karaboga D, Akay B, 2009. A survey: algorithms simulating bee swarm intelligence. Artif Intell Rev, 31, 1-4, 61-85.

Karaboga D, Gorkemli B, Ozturk C, Karaboga N, 2012. A comprehensive survey: artificial bee colony (ABC) algorithm and applications. Artif Intell Rev, 42, 1, 21-57.

Karaboğa D, 2014. Yapay zeka optimizasyon algoritmaları: tabu araştırma, ısıl işlem, genetik, karınca koloni, bağışıklık ve diferansiyel gelişim algoritmaları, Nobel, p.

Karnan M, Thangavel K, Thanushkodi K, Geetha K, 2006. Particle swarm optimization for segmentation of microcalcifications in mammograms. IMECS 2006: International Multiconference of Engineers and Computer Scientists, 115-20.

Kasiri K, Javad DM, Kazemi K, Sadegh HM, Kafshgari S. Comparison evaluation of three brain mri segmentation methods in software tools. Biomedical Engineering (ICBME), 2010 17th Iranian Conference of, 1-4.

Khademi A, Venetsanopoulos A, Moody A, 2009. Automatic contrast enhancement of white matter lesions in FLAIR MRI. 2009 Ieee International Symposium on Biomedical Imaging: From Nano to Macro, Vols 1 and 2, 322-5.

Khayati R, Vafadust M, Towhidkhah F, Nabavi M, 2008. Fully automatic segmentation of multiple sclerosis lesions in brain MR FLAIR images using adaptive mixtures method and Markov random field model. Computers in biology and medicine, 38, 3, 379-90.

MIDAS (Multimedia Digital Archiving System), 2015. Erişim tarihi 13.09.2015. Erişim adresi, http://www.midasplatform.org/.

Kocagül MT, 2012. Klinik İzole Sendrom ve Relapsing-Remitting Multipl Skleroz Ttanıları İle Takip Edilen Hastalarda Demiyelinizan Hastalık Seyir Sürecinde Dengesizlik, PhD, T.C. Pamukkale Üniversitesi, Denizli.

Kosheleva O, Arenas J, Aguirre M, Mendoza C, Cabrera SD, 1998. Compression degradation metrics for analysis of consistency in microcalcification detection. 1998 Ieee Southwest Symposium on Image Analysis and Interpretation, 35-40.

Krishnamurthy R, Cheong B, Muthupillai R, 2014. Tools for cardiovascular magnetic resonance imaging. Cardiovasc Diagn Ther, 4, 2, 104-25.

Kurtzke JF, 1977. Geography in multiple sclerosis. J Neurol, 215, 1, 1-26.

Kwan RK, Evans AC, Pike GB, 1999. MRI simulation-based evaluation of image-processing and classification methods. IEEE transactions on medical imaging, 18, 11, 1085-97.

Kwan RKS, Evans AC, Pike GB, 1996. An extensible MRI simulator for post-processing evaluation. Visualization in Biomedical Computing, 1131, 135-40.

Lauterbur PC, 1973. Image Formation by Induced Local Interactions: Examples Employing Nuclear Magnetic Resonance. Nature, 242, 5394, 190-1.

Lei W, Longzheng T, Xinglong L, Xundong L, Chunshui Y. Study on normal appearing white matter of multiple sclerosis by texture analysis and modeling with MRI. 2005 IEEE International Conference on Information Acquisition, 4 pp., 27 June-3 July 2005.

Lei W, Ning L, Xiaoxia Z, L. T, 2007. Texture Characteristic Analysis of MRI for Exploratory Study on Early Diagnosis of Multiple Sclerosis. 2007 IEEE/ICME International Conference on Complex Medical Engineering, Vols 1-4, 652-5.

Lucchinetti C, 2008. Pathological heterogeneity of idiopathic central nervous system inflammatory demyelinating disorders. Current topics in microbiology and immunology, 318, 19-43.

Majumder A, Irani S, (2006). Contrast enhancement of images using human contrast sensitivity. Proceedings of the 3rd symposium on Applied perception in graphics and visualization. Boston, Massachusetts, USA, ACM**:** 69-76.

Manganaro G, Arena P, Fortuna L, 2012. Cellular Neural Networks: Chaos, Complexity and VLSI Processing, Springer Berlin Heidelberg, p.

McDonald WI, Compston A, Edan G, Goodkin D, Hartung HP, Lublin FD, McFarland HF, Paty DW, Polman CH, Reingold SC, Sandberg-Wollheim M, Sibley W, Thompson A, van den Noort S, Weinshenker BY, Wolinsky JS, 2001. Recommended diagnostic criteria for multiple sclerosis: guidelines from the International Panel on the diagnosis of multiple sclerosis. Annals of neurology, 50, 1, 121-7.

Morrow WM, Paranjape RB, Rangayyan RM, Desautels JL, 1992. Region-based contrast enhancement of mammograms. IEEE transactions on medical imaging, 11, 3, 392-406.

Mrak M, Grgic S, Grgic M, 2003. Picture quality measures in image compression systems. Ieee Region 8 Eurocon 2003, Vol a, Proceedings, 233-7.

Napadow V, Dhond R, Kennedy D, Hui KK, Makris N, 2006. Automated brainstem co-registration (ABC) for MRI. NeuroImage, 32, 3, 1113-9.

Oishi K, Faria A, Jiang H, Li X, Akhter K, Zhang J, Hsu JT, Miller MI, van Zijl PCM, Albert M, Lyketsos CG, Woods R, Toga AW, Pike GB, Rosa-Neto P, Evans A, Mazziotta J,

Mori S, 2009. Atlas-based whole brain white matter analysis using large deformation diffeomorphic metric mapping: Application to normal elderly and Alzheimer's disease participants. NeuroImage, 46, 2, 486-99.
Otsu N, 1979. A Threshold Selection Method from Gray-Level Histograms. IEEE Transactions on Systems, Man, and Cybernetics, 9, 1, 62-6.
Panetta KA, Wharton EJ, Agaian SS, 2008. Human visual system-based image enhancement and logarithmic contrast measure. IEEE Trans Syst Man Cybern B Cybern, 38, 1, 174-88.
Piani D, Frei K, Do KQ, Cuenod M, Fontana A, 1991. Murine brain macrophages induced NMDA receptor mediated neurotoxicity in vitro by secreting glutamate. Neuroscience letters, 133, 2, 159-62.
Prastawa M, Bullitt E, Ho S, Gerig G, 2004. A brain tumor segmentation framework based on outlier detection. Medical image analysis, 8, 3, 275-83.
Pratt WK, 1991. Digital image processing (2nd ed.), John Wiley \& Sons, Inc., p.
Quintanilla-Dominguez J, Cortina-Januchs MG, Ojeda m, x, a B, Jevtic, x, A., Vega-Corona A, Andina D. Microcalcification detection applying artificial neural networks and mathematical morphology in digital mammograms. World Automation Congress (WAC), 2010, 1-6, 19-23 Sept. 2010.
Rotstein D, O'Connor P, 2014. Diagnostic Process. In: Multiple Sclerosis and CNS Inflammatory Disorders. Eds: John Wiley & Sons, Ltd., p. 18-28.
Rovira A, Leon A, 2008. MR in the diagnosis and monitoring of multiple sclerosis: an overview. European journal of radiology, 67, 3, 409-14.
Sankur Bl, 2004. Survey over image thresholding techniques and quantitative performance evaluation. ELECTIM, 13, 1, 146.
Semmlow JL, 2004. Biosignal and Medical Image Processing, Taylor & Francis, p.
Serag A, Aljabar P, Ball G, Counsell SJ, Boardman JP, Rutherford MA, Edwards AD, Hajnal JV, Rueckert D, 2012. Construction of a consistent high-definition spatio-temporal atlas of the developing brain using adaptive kernel regression. NeuroImage, 59, 3, 2255-65.
Serra J, 1983. Image Analysis and Mathematical Morphology, Academic Press, Inc., p.
Seul M, O'Gorman L, Sammon MJ, 2000. Practical algorithms for image analysis: description, examples, and code, Cambridge University Press, p.
Shams R, Sadeghi P, Kennedy RA, Hartley RI, 2010. A survey of medical image registration on multicore and the GPU. IEEE Signal Processing Magazine, 27, 2, 50-60.
Shattuck DW, Leahy RM, 2002. BrainSuite: an automated cortical surface identification tool. Medical image analysis, 6, 2, 129-42.
Smathers RL, Bush E, Drace J, Stevens M, Sommer FG, Brown BW, Jr., Karras B, 1986. Mammographic microcalcifications: detection with xerography, screen-film, and digitized film display. Radiology, 159, 3, 673-7.
Somasundaram K, Kalaiselvi T, 2011. Automatic brain extraction methods for T1 magnetic resonance images using region labeling and morphological operations. Computers in biology and medicine, 41, 8, 716-25.
Sundaram M, Ramar K, Arumugam N, Prabin G, 2011. Histogram Modified Local Contrast Enhancement for mammogram images. Appl Soft Comput, 11, 8, 5809-16.
Sutton MA, Orteu JJ, Schreier H, 2009. Image Correlation for Shape, Motion and Deformation Measurements: Basic Concepts,Theory and Applications, Springer US, p.
Şahin Ş, Yağız O, Saçak Ş, Aslan H, Tekeşin A, (2009). Multiple Skleroz ve Demiyelinizan Polinöropati Birlikteliği: Olgu Sunumu. İstanbul Tıp Dergisi**:** 101-3.

Tanoori B, Azimifar Z, Shakibafar A, Katebi S, 2011. Brain volumetry: an active contour model-based segmentation followed by SVM-based classification. Computers in biology and medicine, 41, 8, 619-32.

Tereshko V, 2000. Reaction-Diffusion Model of a Honeybee Colony's Foraging Behaviour. In: Parallel Problem Solving from Nature PPSN VI. Eds: Schoenauer M, Deb K, Rudolph G et al.: Springer Berlin Heidelberg, p. 807-16.

Treabă CA, Bălaşa R, Podeanu DM, Simu IP, Buruian MM, 2014. Cerebral lesions of multiple sclerosis: is gadolinium always irreplaceable in assessing lesion activity? Diagnostic and Interventional Radiology, 20, 2, 178-84.

Uçan ON, Osman O, Albora M, 2006. Görüntü işleme teknikleri ve mühendislik uygulamaları, Nobel Yayın Dağıtım, p.

Van Leemput K, Maes F, Vandermeulen D, Colchester A, Suetens P, 2001. Automated segmentation of multiple sclerosis lesions by model outlier detection. IEEE transactions on medical imaging, 20, 8, 677-88.

van Waesberghe JH, Castelijns JA, Scheltens P, Truyen L, Lycklana ANGJ, Hoogenraad FG, Polman CH, Valk J, Barkhof F, 1997. Comparison of four potential MR parameters for severe tissue destruction in multiple sclerosis lesions. Magnetic resonance imaging, 15, 2, 155-62.

Vidaurrazaga M, Diago LA, Cruz A, 2000. Contrast enhancement with wavelet transform in radiological images. Proceedings of the 22nd Annual International Conference of the Ieee Engineering in Medicine and Biology Society, Vols 1-4, 22, 1760-3.

Viergever MA, Maintz JB, Klein S, Murphy K, Staring M, Pluim JP, 2016. A survey of medical image registration - under review. Medical image analysis, 33, 140-4.

Vovk U, Pernus F, Likar B, 2007. A review of methods for correction of intensity inhomogeneity in MRI. IEEE transactions on medical imaging, 26, 3, 405-21.

Wang Z, Bovik AC, 2002. A universal image quality index. Ieee Signal Proc Let, 9, 3, 81-4.

WebMD M, (2003). Structure of Neuron and Mechanism of Demyelination. art-fig1.gif, Medscape Web MD. **714 x 743:** Structure of Neuron and Mechanism of Demyelination.

Woods RP, Dapretto M, Sicotte NL, Toga AW, Mazziotta JC, 1999. Creation and use of a Talairach-compatible atlas for accurate, automated, nonlinear intersubject registration, and analysis of functional imaging data. Human brain mapping, 8, 2-3, 73-9.

Wyawahare MV, Patil PM, Abhyankar HK, 2009. Image registration techniques: an overview. International Journal of Signal Processing, Image Processing and Pattern Recognition, 2, 3, 11-28.

Xu M, Nowinski WL, 2001. Talairach–Tournoux brain atlas registration using a metalforming principle-based finite element method. Medical image analysis, 5, 4, 271-9.

Xue J-H, Pizurica A, Philips W, Kerre E, Van De Walle R, Lemahieu I, 2003. An integrated method of adaptive enhancement for unsupervised segmentation of MRI brain images. Pattern Recognition Letters, 24, 15, 2549-60.

Yang HY, Lee YC, Fan YC, Taso HW, 2007. A novel algorithm of local contrast enhancement for medical image. Ieee Nucl Sci Conf R, 3951-4.

Yetkin MF, 2014. Relaps Ve Remisyonla Seyreden Multipl Skleroz Hastalarında Beta İnterferon Tedavisine Yanıtın Manyetik Rezonans Spektroskopi İle Değerlendirilmesi, Tıpta Uzmanlık, Erciyes Üniversitesi, Kayseri.

Yiğitbaşı ED, 2014. Yapay Arı Kolonisi Optimizasyonu ile Kenar Bulma, Selçuk Üniversitesi, Konya.

Yilmaz B, Durdu A, Emlik GD, 2016. A new method for skull stripping in brain MRI using multistable cellular neural networks. Neural Computing and Applications, 1-17.

Yilmaz B, Ozbay Y, 2014. Contrast enhancement using linear image combinations algorithm (CEULICA) for enhancing brain magnetic resonance images. Turk J Electr Eng Co, 22, 6, 1540-63.

Yılmaz N, 2005. WEB tabanlı mobil robot sistemi tasarımı, gerçekleştirilmesi ve uygulamaları / Design, realization and applications of a WEB-based mobile robot system, Selçuk Üniversitesi, KONYA.

Young IR, Hall AS, Pallis CA, Legg NJ, Bydder GM, Steiner RE, 1981. Nuclear magnetic resonance imaging of the brain in multiple sclerosis. Lancet, 2, 8255, 1063-6.

Zwillinger D, 2011. CRC Standard Mathematical Tables and Formulae, 32nd Edition, CRC Press, p.

EKLER

T.C.
SELÇUK ÜNİVERSİTESİ
Meram Tıp Fakültesi Dekanlığı

Sayı : B.30.2.SEL.0.20.71.00.281- 3627 Tarih: 08 EYLÜL 2011
Konu:

Sayın
Doç.Dr. Yüksel ÖZBAY
S.Ü. Müh. Mimarlık Fakültesi Elektrik-Elektronik Müh. Böl.

İlgi: 15.08.2011 tarihli dilekçeniz;

"Mr Görüntülerinde Ms Hastalığının Teşhisine Yeni Bir Yaklaşım" başlıklı doktora tez çalışması hakkında Fakültemiz Klinik Araştırmalar Etik Kurulunun 18 Ağustos 2011 tarihinde aldığı 2011/235 sayılı karar ilişikte gönderilmiştir.

Bilgilerinizi rica ederim.

Prof.Dr. Rahmi ÖRS
Klinik Araştırmalar Etik Kurulu Başkanı

Eki: 1

Adres: S.Ü. Meram Tıp Fakültesi Dekanlığı 77080 –Meram /KONYA
Faks: (332) 223 61 81
Web Adresi: www.etikmeram@gmail.com
Bilgi İçin :Personel Şubesi Tel : (0332) 2236523
:Etik Kurul Tel : (0332) 2236180

T.C.
SELÇUK ÜNİVERSİTESİ
KAM TIP FAKÜLTESİ DEKANLIĞI

KLİNİK ARAŞTIRMALAR ETİK KURULU KARARI

Toplantı Sayısı:09	Toplantı Tarihi: 18.08.2011

Karar Sayısı:2011/235:S.Ü. Müh. Mimarlık Fakültesi Elektrik-Elektronik Müh. Böl. Doç.Dr. Yüksel ÖZBAY' ın **"Mr Görüntülerinde Ms Hastalığının Teşhisine Yeni Bir Yaklaşım"** başlıklı doktora tez çalışması ile ilgili 15.08.2011 tarihli dilekçesi ve ekleri görüşüldü, doktora tez çalışmasının S.Ü. Müh. Mimarlık Fakültesi Elektrik-Elektronik Müh. Böl. Doç.Dr. Yüksel ÖZBAY' ın sorumluluğunda yürütülmesinin uygun olduğuna oybirliği ile karar verilmiştir.

ASLI GİBİDİR
18.08.2011

Prof.Dr. Rahmi ÖRS
Klinik Araştırmalar Etik Kurulu Başkanı

KONYA

MERAM
TIP FAKÜLTESİ

T.C.
NECMETTİN ERBAKAN ÜNİVERSİTESİ
Meram Tıp Fakültesi Dekanlığı

KONYA NECMETTİN ERBAKAN ÜNİVERSİTESİ
e
09/02/2017 Sayı: 512
giden 2017.02.09.512

Sayı : 14567952-050/
Konu :

Sayın
Yrd. Doç. Dr. Akif DURDU
S.Ü. Elektrik-Elektronik Mühendisliği Bölümü
Elektrik Makinaları Anabilim Dalı Öğretim Üyesi

İlgi:03.01.2017 tarihli dilekçeniz;

"MR Görüntülerinde MS Hastalığının Teşhisine Yeni Bir Yaklaşım" başlıklı Yrd. Doç. Dr. Akif DURDU' nun sorumluluğunda Uzm. Burak YILMAZ' ın doktora tez çalışması hakkında Fakültemiz İlaç ve Tıbbi Cihaz Dışı Araştırmalar Etik Kurulunun 03 Şubat 2017 tarihinde aldığı 2017/795 sayılı karar ilişikte gönderilmiştir.

Bilgilerinizi rica ederim.

Prof. Dr. Saim AÇIKGÖZOĞLU
İlaç ve Tıbbi Cihaz Dışı Araştırmalar
Etik Kurul Başkanı

Eki: 1

Adres:Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi Dekanlığı 42080 –Meram KONYA
Tel: (0332) 223 65 00 Faks: (0332) 223 61 81
Bilgi İçin : Personel Subesi Tel : (0332) 2236504

T.C.
NECMETTİN ERBAKAN ÜNİVERSİTESİ MERAM TIP FAKÜLTESİ
İLAÇ VE TIBBİ CİHAZ DIŞI ARAŞTIRMALAR ETİK KURUL KARARI

Toplantı Sayısı:44	Toplantı Tarihi: 03.02.2017

Karar Sayısı:2017/795:S.Ü. Elektrik-Elektronik Mühendisliği Bölümü Elektrik Makinaları Anabilim Dalı Öğretim Üyesi Yrd. Doç. Dr. Akif DURDU' nun **"MR Görüntülerinde MS Hastalığının Teşhisine Yeni Bir Yaklaşım"** başlıklı doktora tez çalışması ile ilgili 01.02.2017 tarihli sorumlu araştırmacı değişikliği dilekçesi ve ekleri görüşüldü, Uzm. Burak YILMAZ' ın doktora tez çalışmasının 09.11.2016 tarih ve 42/37 sayılı S.Ü. Fen Bilimleri Enstitüsü Yönetim Kurulu Kararına istinaden çalışmasının S.Ü. Elektrik- Elektronik Mühendisliği Bölümü Elektrik Makinaları Anabilim Dalı Öğretim Üyesi Yrd. Doç. Dr. Akif DURDU' nun sorumluluğunda yürütülmesinin uygun olduğuna oybirliği ile karar verilmiştir.

ASLI GİBİDİR
03.02.2017

Prof. Dr. Saim AÇIKGÖZOĞLU
İlaç ve Tıbbi Cihaz Dışı Araştırmalar Etik Kurul Başkanı

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı	**:**	Burak Yılmaz
Uyruğu	**:**	T.C.
Doğum Yeri ve Tarihi	**:**	ELAZIĞ / 1978
Telefon	**:**	+90 533 634 86 38
Faks	**:**	
e-mail	**:**	burakyilmaz@selcuk.edu.tr

EĞİTİM

Derece		**Adı, İlçe, İl**	**Bitirme Yılı**
Lise	:	**Elazığ Anadolu Lisesi**	**1995**
Üniversite	:	**Fırat Üniversitesi**	**2001**
Yüksek Lisans	:	**Selçuk Üniversitesi**	**2007**
Doktora	:	**Selçuk Üniversitesi**	**2017**

İŞ DENEYİMLERİ

Yıl	**Kurum**	**Görevi**
2005-2010	**S.Ü. A.R.E. Akören M.Y.O**	**Öğretim Görevlisi**
2010-Günümüz	**S.Ü. B.A.U.M.**	**Uzman**

UZMANLIK ALANI

Biyomedikal, Görüntü işleme, Yazılım, Robotik, Otomatik Kontrol

YABANCI DİLLER

İngilizce (YDS :86.25)

YAYINLAR

1- Makale: "A new method for skull stripping in brain MRI using multistable cellular neural networks" **(Doktora tezinden)** Aralık 2016 · Neural Computing and Applications

2- Bildiri:"Brain Image Segmentation Using Multistable Cellular Neural Networks" **(Doktora tezinden)** Aralık 2016 · International Conference on Computer and Electrical Engineering (ICCEE 2016)

3- Bildiri:"Denoising MR Images With Weighted 3D Discrete Wavelet Transform" Kasım 2016 · 4th International Conference on Advanced Technology & Sciences (ICAT)

4- Bildiri:"Elimination of Pectoral Muscle from Mammograms" Ağustos 2015 · InternationalConference on Science, Ecology and Technology ICONSETE'15

5- Makale: "Detection of microcalcification in digitized mammograms with multistable cellular neural networks using a new image enhancement method: Automated lesion intensity enhancer (ALIE)" Aralık 2015 · Turkish Journal of Electrical Engineering and Computer Sciences

6- Makale: "Contrast enhancement using linear image combinations algorithm (CEULICA) for enhancing brain magnetic resonance images" **(Doktora tezinden)** Kasım 2014 · Turkish Journal of Electrical Engineering and Computer Sciences

7- Bildiri:"Mamogram görüntülerinde mikrokalsifikasyonların bulanık mantık yöntemiyle bölütlenmesi" · Haziran 2010 ASYU 2010, Akıllı Sistemler ve Uygulamaları Sempozyumu

8- Makale: "Assesment of condylar position by quantitive and qualitive methods" · Şubat 2009 · Selcuk Dental Journal

9- Bildiri:"A Method For Fast Covering The Boolean Sets By Their Prime İmplicants" **(Yüksek lisans tezinden)** Mayıs 2007 · 9'th International Conference on Pattern Recognition And Information Processing (PIRIP 2007)