

**İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ**

**BULANIK KÜMELEME ALGORİTMALARI KULLANILARAK BEYİN MR  
GÖRÜNTÜLERİNDEN MS LEZYONLARININ AYRIŞTIRILMASI**

**YÜKSEK LİSANS TEZİ**

**İpek TOKER**

**Elektronik ve Haberleşme Mühendisliği Anabilim Dalı**

**Biyomedikal Mühendisliği Programı**

**OCAK 2013**



**İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ**

**BULANIK KÜMELEME ALGORİTMALARI KULLANILARAK BEYİN MR  
GÖRÜNTÜLERİNDEN MS LEZYONLARININ AYRIŞTIRILMASI**

**YÜKSEK LİSANS TEZİ**

**İpek TOKER  
(504101404)**

**Elektronik ve Haberleşme Mühendisliği Anabilim Dalı**

**Biyomedikal Mühendisliği Programı**

**Tez Danışmanı: Prof. Dr. Sedef KENT PINAR**

**OCAK 2013**



İTÜ, Fen Bilimleri Enstitüsü'nün 504101404 numaralı Yüksek Lisans Öğrencisi **İpek TOKER**, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “**BULANIK KÜMELEME ALGORİTMALARI KULLANILARAK BEYİN MR GÖRÜNTÜLERİNDEN MS LEZYONLARININ AYRIŞTIRILMASI**” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

**Tez Danışmanı :**      **Prof. Dr. Sedef KENT**      .....

İstanbul Teknik Üniversitesi

**Jüri Üyeleri :**      **Yrd. Doç. Dr. İsa YILDIRIM**      .....

İstanbul Teknik Üniversitesi

**Prof. Dr. Cengizhan ÖZTÜRK**      .....

Boğaziçi Üniversitesi

**Teslim Tarihi :**      **17 Aralık 2012**  
**Savunma Tarihi :**      **25 Ocak 2013**



## ÖNSÖZ

“BULANIK KÜMELEME ALGORİTMALARI KULLANILARAK BEYİN MR GÖRÜNTÜLERİNDEN MS LEZYONLARININ AYRIŞTIRILMASI” başlıklı yüksek lisans tez çalışmamı tamamlamış bulunmaktayım. Çalışmalarım sırasında bana yardımcı olan tez danışmanım Prof. Dr. Sedef KENT PINAR’a teşekkür ederim. Çalışmamın neredeyse tamamında yol gösteren, manevi desteğini eksik etmeyen Arş. Gör. Berat DOĞAN’a ve Dr. Zafer İŞCAN’a; gerek tez çalışmam, gerekse ilerideki çalışmalarım için bana fikir veren, yol gösteren Yrd. Doç. Dr. İsa YILDIRIM’a teşekkürü bir borç bilirim.

Hayatımın tüm evrelerinde benden desteğini esirgemeyen, fedakârlıktan kaçınmayan aileme ve ihtiyacım olan her an yanımda olan değerli dostlarıma sonsuz teşekkürlerimi sunarım.

Ayrıca, çalışmalarımı yürütebilmem için bana maddi destek sağlayan TÜBİTAK Bilim İnsanı Destekleme Daire Başkanlığı’na teşekkür ederim.

Aralık 2012

İpek TOKER  
(Elektrik-Elektronik Mühendisi)





## İÇİNDEKİLER

### Sayfa

ÖNSÖZ.....	v
İÇİNDEKİLER .....	vii
KISALTMALAR .....	ix
ÇİZELGE LİSTESİ.....	xi
ŞEKİL LİSTESİ.....	xiii
ÖZET.....	xv
SUMMARY .....	xvii
<b>1. GİRİŞ.....</b>	<b>1</b>
1.1 Çalışmanın Amacı.....	1
1.2 Literatür Özeti .....	2
1.2.1 Öznitelik belirleme.....	2
1.2.2 Görüntü bölütleme ve sınıflandırma .....	2
<b>2. TIBBİ GÖRÜNTÜLEME.....</b>	<b>9</b>
2.1 Başlıca Görüntüleme Sistemleri.....	9
2.2 Manyetik Rezonans Görüntüleme.....	13
2.2.1 Manyetik rezonans görüntüleme sisteminin gelişimi.....	14
2.2.2 Manyetik rezonans görüntüleme yönteminin avantajları ve dezavantajları .....	15
2.2.3 Manyetik rezonans görüntüleme tekniğinin çalışma prensibi.....	15
2.2.3.1 Atomların manyetik alandaki davranışı .....	16
2.2.3.2 Radyo frekans darbesinin uygulanması .....	19
2.2.3.3 T1 ve T2 gevşeme zamanları .....	20
2.2.3.4 MR sinyalinin algılanması .....	23
2.2.3.4 Görüntü oluşturma teknikleri .....	25
2.3 Multiple Skleroz.....	28
2.4 Görüntü Bölütleme Yöntemleri.....	30
2.4.1 Eşiklendirmeye dayalı yöntemler.....	31
2.4.2 Örüntü tanımaya dayalı yöntemler.....	32
2.4.2.1 Kümeleme algoritmaları.....	32
2.4.2.2 Sınıflayıcılar .....	33
2.4.3 Markov rastgele alanları.....	34
2.4.4 Atlas tabanlı yöntemler .....	34
2.4.5 Deforme edilebilir modeller.....	34
<b>3. MATERYAL VE METOT .....</b>	<b>37</b>
3.1 Bulanık C-Ortalamalar Kümeleme Algoritması .....	37
3.3 Aralık Tip-2 Bulanık C-Ortalamalar Kümeleme Algoritması .....	40
3.4 Parçacık Sürü Optimizasyonu .....	45
3.5 Veri Seti .....	47
3.6 Yöntem.....	48
3.7 Değerlendirme Ölçütleri.....	49
<b>4. BULGULAR .....</b>	<b>53</b>

4.1 Bulanık C-Ortalamlar Yöntemiyle Elde Edilen Sonuçlar .....	53
4.2 Parçacık Sürü Optimizasyonu Algoritmasının Kullanılmasıyla Elde Edilen Sonuçlar.....	56
4.3 Aralık Tip-2 Bulanık C-Ortalamlar Yöntemiyle Elde Edilen Sonuçlar .....	58
4.2.1 m=1 için sonuçlar .....	59
4.2.2 m=2 için sonuçlar .....	61
4.2.3 m=3 için sonuçlar .....	62
<b>5. TARTIŞMA VE SONUÇLAR .....</b>	<b>69</b>
<b>KAYNAKLAR.....</b>	<b>71</b>
<b>ÖZGEÇMİŞ.....</b>	<b>77</b>

## **KISALTMALAR**

<b>MRG</b>	: Manyetik Rezonans Görüntüleme
<b>BT</b>	: Bilgisayarlı Tomografi
<b>PET</b>	: Pozitron Emisyon Tomografisi
<b>MS</b>	: Multipl Skleroz
<b>BCO</b>	: Bulanık C-Ortalamlar
<b>KO</b>	: K-Ortalamlar
<b>T2BCO</b>	: Tip-2 Bulanık C-Ortalamlar
<b>EKG</b>	: Elektrokardiyogram
<b>OCO</b>	: Olasılıksal C-Ortalamlar
<b>MR</b>	: Manyetik Rezonans
<b>US</b>	: Ultrasonla görüntüleme
<b>SVM</b>	: Support Vector Machine



## ÇİZELGE LİSTESİ

### Sayfa

Çizelge 2.1 : Elektromanyetik spektrumdaki bazı dalga tiplerinin özellikleri .....	9
Çizelge 2.2 : Bazı atomların manyetik özellikleri .....	17
Çizelge 2.3 : Görüntü ağırlıklandırma için TR ve TE değerleri .....	26
Çizelge 3.1 : Tez çalışmasında kullanılan görüntüdeki doku sınıfları .....	50
Çizelge 3.2 : Değerlendirme ölçütlerinin hesabında kullanılan değerler .....	51
Çizelge 4.1 : Bulanıklık sabiti ve küme sayısı tespiti için yapılan denemelerden elde edilen sonuçlar.....	54
Çizelge 4.2 : Seçilen bir parametre için istatistiki sonuçlar (Kesit no:100) .....	55
Çizelge 4.3 : Tezde kullanılan görüntüler için bulanık c-ortalamar yöntemi ile elde edilen sonuçlar.....	56
Çizelge 4.4 : Tezde kullanılan görüntüler için bulanık c-ortalamar yöntemi ile elde edilen sonuçlar (gürültülü) .....	56
Çizelge 4.5 : Parçacık sürü optimizasyonu algoritması için seçilen parametreler ....	57
Çizelge 4.6 : Başlangıç değerleri PSO ile belirlendiğinde elde edilen sonuçlar .....	57
Çizelge 4.7 : m parametresinin etkisi .....	64
Çizelge 4.8 : Bulanıklık sabiti ve küme sayısı tespiti için yapılan denemelerden elde edilen sonuçlar (tip-2) .....	65
Çizelge 4.9 : Tezde kullanılan görüntüler için aralık tip-2 bulanık c-ortalamar yöntemi ile elde edilen sonuçlar .....	67
Çizelge 4.10 : Tezde kullanılan görüntüler için aralık tip-2 bulanık c-ortalamar yöntemi ile elde edilen sonuçlar (gürültülü).....	67
Çizelge 4.11 : Seçilen bir parametre için istatistiki sonuçlar.....	67



## ŞEKİL LİSTESİ

### Sayfa

Şekil 2.1 : W.Roentgen tarafından ilk çekilen filmlerden biri (1895) .....	10
Şekil 2.2 : Bilgisayarlı tomografi tekniği ile elde edilmiş beyin görüntüsü .....	11
Şekil 2.3 : Ultrasonla görüntüleme tekniği ile elde edilmiş görüntü .....	12
Şekil 2.4 : PET/SPECT ile elde edilmiş görüntüler .....	12
Şekil 2.5 : MRG tekniği ile elde edilmiş beyin görüntüsü .....	13
Şekil 2.6 : Termal görüntüleme tekniğiyle elde edilmiş görüntü .....	13
Şekil 2.7 : Manyetik moment ve atomların manyetik alan yok iken davranışı .....	16
Şekil 2.8 : Harici manyetik alanın varlığında atomların davranışı .....	17
Şekil 2.9 : Atomların manyetik momentleri ve net manyetizasyon .....	18
Şekil 2.10 : Manyetik rezonans görüntüleme sisteminin basit temsili .....	19
Şekil 2.11 : 90°'lik darbenin etkisi altında manyetik momentlerin değişimi .....	20
Şekil 2.12 : Dönü-kafes etkileşimi .....	21
Şekil 2.13 : z-yönündeki net manyetizasyonun değişimi .....	22
Şekil 2.14 : Dönü-dönü etkileşimi .....	22
Şekil 2.15 : y yönündeki manyetizasyon bileşeninin değişimi .....	23
Şekil 2.16 : Kesit seçme işlemi .....	24
Şekil 2.17 : Kesit seçme gradyanının şiddetinin konuma bağlı değişimi .....	25
Şekil 2.18 : Uygulanan gradyanlar ve uygulama zamanları .....	26
Şekil 2.19 : PD,T2 ve T1 ağırlıklı beyin MR görüntüleri .....	27
Şekil 2.20: Farklı beyin dokularından alınan sinyalin TR ve TE ile değişimi .....	27
Şekil 2.21: Dünya genelinde MS hastalığının dağılımı .....	29
Şekil 3.1 : Bulanık c-ortalamlar algoritmasının sözde kodu.....	38
Şekil 3.2 : Bulanıklık sabitinin etkisi .....	39
Şekil 3.3 : Farklı hacimdeki iki küme için bulanıklık sabitinin etkisi .....	40
Şekil 3.4 : İki farklı bulanıklık sabitinin etkisi .....	41
Şekil 3.5 : Aralık tip-2 bulanık kümeleme algoritmasının akış şeması .....	42
Şekil 3.6 : Karnik-Mendel algoritmasının sözde kodu .....	44
Şekil 3.7 : Parçacık sürü optimizasyonu algoritmasının sözde kodu.....	46
Şekil 3.8 : Tez çalışmasında kullanılan görüntüler .....	48
Şekil 3.9 : T1, T2 ve PD ağırlıklandırılmış MR görüntüleri .....	48
Şekil 3.10 : Tez çalışmasında izlenen yöntem.....	49
Şekil 3.11 : Tez çalışmasında kullanılan hedef görüntüdeki doku sınıfları .....	50
Şekil 4.1 : Bulanıklık sabitinin farklı değerleri için hesaplanan duyarlılık ve benzerlik değerleri (Kesit no:100/gürültüsüz) .....	53
Şekil 4.2 : Bulanık c-ortalamlar algoritması ile ilk aşamadaki bölütleme sonuçları	54
Şekil 4.3 : Bulanık c-ortalamlar algoritması ile ikinci aşamadaki bölütleme sonuçları .....	55
Şekil 4.4 : BCO yöntemi ile yapılan bölütleme sonucu (Kesit no:100) a) Bölütleme sonucu b) Hedef görüntü c) Fark.....	55
Şekil 4.5 : Bulanık c-ortalamlar algoritmasının 100 kere denenmesi ile elde edilen sonuçların dağılımı.....	58

<b>Şekil 4.6</b> : PSO+BCO yönteminin 100 kere denenmesi ile elde edilen sonuçların dağılımı.....	58
<b>Şekil 4.7</b> : $m_1=1,1$ için farklı $m_2$ değerleriyle hesaplanmış değerlendirme ölçütleri ..	59
<b>Şekil 4.8</b> : $m_1=2$ için farklı $m_2$ değerleriyle hesaplanmış değerlendirme ölçütleri ....	59
<b>Şekil 4.9</b> : $m_1=3$ için farklı $m_2$ değerleriyle hesaplanmış değerlendirme ölçütleri ....	60
<b>Şekil 4.10</b> : $m_1=4$ için farklı $m_2$ değerleriyle hesaplanmış değerlendirme ölçütleri ..	60
<b>Şekil 4.11</b> : $m_1=5$ için farklı $m_2$ değerleriyle hesaplanmış değerlendirme ölçütleri ..	60
<b>Şekil 4.12</b> : $m_1=1,1$ için farklı $m_2$ değerleriyle hesaplanmış değerlendirme ölçütleri	61
<b>Şekil 4.13</b> : $m_1=2$ için farklı $m_2$ değerleriyle hesaplanmış değerlendirme ölçütleri ..	61
<b>Şekil 4.14</b> : $m_1=3$ için farklı $m_2$ değerleriyle hesaplanmış değerlendirme ölçütleri ..	61
<b>Şekil 4.15</b> : $m_1=4$ için farklı $m_2$ değerleriyle hesaplanmış değerlendirme ölçütleri ..	62
<b>Şekil 4.16</b> : $m_1=5$ için farklı $m_2$ değerleriyle hesaplanmış değerlendirme ölçütleri ..	62
<b>Şekil 4.17</b> : $m_1=1,1$ için farklı $m_2$ değerleriyle hesaplanmış değerlendirme ölçütleri	62
<b>Şekil 4.18</b> : $m_1=2$ için farklı $m_2$ değerleriyle hesaplanmış değerlendirme ölçütleri ..	63
<b>Şekil 4.19</b> : $m_1=3$ için farklı $m_2$ değerleriyle hesaplanmış değerlendirme ölçütleri ..	63
<b>Şekil 4.20</b> : $m_1=4$ için farklı $m_2$ değerleriyle hesaplanmış değerlendirme ölçütleri ...	63
<b>Şekil 4.21</b> : $m_1=5$ için farklı $m_2$ değerleriyle hesaplanmış değerlendirme ölçütleri ..	64
<b>Şekil 4.7</b> : Aralık tip-2 bulanık c-ortalamalar algoritması ile ilk aşamadaki bölütleme sonuçları .....	65
<b>Şekil 4.8</b> : Aralık tip-2 bulanık c-ortalamalar algoritması ile ikinci aşamadaki bölütleme sonuçları .....	66
<b>Şekil 4.9</b> : Aralık tip-2 bulanık c-ortalamalar yöntemi ile yapılan bölütleme sonucu (Kesit no:100) a) Bölütleme sonucu b) Hedef görüntü c) Fark.....	66



## **BULANIK KÜMELEME ALGORİTMALARI KULLANILARAK BEYİN MR GÖRÜNTÜLERİNDEN MS LEZYONLARININ AYRIŞTIRILMASI**

### **ÖZET**

Tıpta kullanılan biyomedikal düzenler, hastalıkların teşhisinde ve tedavi sürecinin yönetilmesi konusunda doktorlar için vazgeçilmez birer yardımcıdır. Tıbbi görüntüleme sistemleri de vücudun gözle görülemeyen bölgelerinde ortaya çıkan tümör gibi oluşumların, hastalıkların, kanamaların, kırıkların tespitinde ihtiyaç duyulması bakımından, en çok kullanılan biyomedikal cihazlardır.

Görüntüleme sistemlerinin birbirine göre üstün ya da zayıf kaldıkları noktalar olmakla birlikte, hangi sistemin kullanılacağı görüntüleme amacına ve hastanın fiziksel durumuna göre değişmektedir. Manyetik rezonans görüntüleme sistemi, yumuşak doku kontrastı yönünden diğer sistemlere olan üstünlüğü sebebiyle özellikle beynin görüntülenmesi için en sık kullanılan yöntemdir. Elde edilen görüntülerin yorumlanması ve hastalık teşhisi doktorlar tarafından yapılmaktadır. Bu işlemi kolaylaştırmak ve zaman kaybını azaltmak için doktorlara yardımcı olacak sistemlere ihtiyaç duyulmakta ve doğruluk, hız bakımından daha iyi sistemler geliştirebilmek için çalışmalar yapılmaktadır.

Multipl Skleroz (MS), merkezi sinir sisteminde görülen bir hastalıktır ve sinir hücrelerinin miyelin kılıfındaki tekrarlayan iltihaplanma ve yaralar olarak kendini gösterir. Sebepleri henüz tam anlamıyla tespit edilememiştir ve bulguları kolaylıkla başka bir hastalıkla karıştırılabilmektedir. Bu yüzden hastalığın teşhisi ancak MR görüntülerinin doğru yorumlanmasıyla mümkündür.

Bu tez çalışmasında, MS lezyonu içeren beyin MR görüntülerinin bölütlenmesi amaçlanmıştır. Bu amaçla, literatürde yaygın olarak kullanılan bir yöntem olan bulanık c-ortalamar algoritması ve daha yeni bir yaklaşım olan aralık tip-2 bulanık c-ortalamar yöntemi, Multipl Skleroz (MS) lezyonu içeren yapay beyin görüntülerine uygulanmış ve MS dokusunun normal beyin dokusundan ayrıştırılması hedeflenmiştir. Çalışmada kullanılan tüm kodlar MATLAB kullanılarak yazılmıştır.

Problemin çözümü için öncelikle bölütleme problemlerinde sık kullanılan bir yöntem olan, bulanık c-ortalamar kümeleme algoritması test edilmiştir. Algoritmanın performansı üzerinde etkili bir parametre olan bulanıklık sabitinin farklı değerleri için sonuçlar alınmış ve bu parametrenin probleme en uygun değeri tespit edilmiştir.

Bulanık c-ortalamar algoritmasının temel problemi olan başlangıç değerlerine bağıllığını azaltmak için parçacık sürü optimizasyon algoritmasından faydalanılmıştır. Yeni yaklaşımda, bulanık c-ortalamar algoritmasının başlangıç değerleri rastgele atanmak yerine parçacık sürü optimizasyon algoritması ile hesaplanmıştır. Bu yaklaşımla, hedeflenen şekilde sonuçlar arasındaki tutarsızlık azaltılmıştır.

Çalışmanın son adımında, bulanık c-ortalamar algoritmasına tip-2 yaklaşımının uyarlanmasıyla elde edilmiş olan aralık tip-2 bulanık c-ortalamar yöntemi aynı

probleme uygulanmış ve bulanıklık sabitlerinin algoritmanın performansı üzerine etkisi incelenerek en uygun değerleri tespit edilmiştir. Son olarak, elde edilen sonuçlar bulanık c-ortalamlar algoritmasının sonuçları ile karşılaştırılmış ve yeni yaklaşımın üstünlüğü gözlenmiştir.

Tez çalışmasında kullanılan görüntüler, McGill Üniversitesi'nin BrainWeb isimli veri tabanından alınmış yapay MR görüntüleridir. Bu veri tabanından; gürültü, yoğunluk homojensizliği, kesit kalınlığı gibi parametreler istenilen değerlerde seçilerek T1/T2/PD ağırlıklı yapay manyetik rezonans görüntüleri üretilebilmektedir. Bir görüntü seti 181\*217 piksel boyutlarında 181 kesitten oluşmaktadır. Aynı veri tabanından, görüntüye ait farklı dokuların işaretlendiği hedef görüntüye de ulaşılabilmektedir.

Çalışmada 181 adet kesitten 97 ile 105 arasında numaralanmış dokuz adet görüntü bölütleme için kullanılmıştır. Öznitelik olarak, görüntülerin T1 ve T2 yoğunluk değerleri kullanılmıştır. Kullanılan görüntüler 0% ve 9% olmak üzere iki farklı sinyal-gürültü oranına (SNR) göre üretilmiştir.

Bölütleme sonucunda elde edilen MS lezyonu içeren küme ile hedef görüntüden ayrıştırılan MS lezyonu görüntüsü arka plana ait pikseller dikkate alınmadan, piksel-piksel karşılaştırılmış; duyarlılık, özgünlük, benzerlik ve doğruluk olmak üzere dört farklı değerlendirme ölçütü hesaplanmıştır.

Birinci bölümde, çalışmanın amacı anlatılmış ve bu alanda yapılmış benzer çalışmalara yer verilmiştir.

İkinci bölümde, tıpta kullanılan görüntüleme sistemlerinden kısaca bahsedilmiş ve manyetik rezonans görüntüleme sisteminin prensipleri anlatılmıştır. Daha sonra, Multipl Skleroz hastalığının muhtemel sebepleri ve bulgularına yer verilmiştir. Son olarak, görüntü bölütleme çalışmalarında sıkça kullanılan bazı yöntemler kısaca anlatılmıştır.

Üçüncü bölümde, tez çalışması kapsamında kullanılan yöntemler olan bulanık c-ortalamlar algoritması, tip-2 bulanık c-ortalamlar algoritması ve parçacık sürü optimizasyonu algoritması detaylı olarak anlatılmış, yöntemlere ait akış şemaları ve sözde kodlar verilerek açıklanmıştır. Ayrıca, bölütlemeyi gerçekleştirmek için izlenen metot anlatılmış ve tez kapsamında kullanılan görüntülerle ilgili gerekli bilgiler verilmiştir.

Dördüncü bölümde, bulanık c-ortalamlar yöntemi kullanılarak bulanıklık sabitinin farklı değerleri için normal ve gürültülü görüntülerden elde edilen sonuçlara yer verilmiştir. Daha sonra, parçacık sürü optimizasyonu algoritmasının kullanılmasıyla elde edilen sonuçlara yer verilerek, yeni yaklaşımın üstünlüklerine değinilmiştir. Son olarak, tezde kullanılan temel yöntem olan tip-2 bulanık c-ortalamlar algoritmasının yine farklı bulanıklık sabiti değerleri için sonuçları verilmiş ve bulanık c-ortalamlar algoritmasına karşı üstünlükleri yorumlanmıştır.

Son bölümde, tez kapsamında elde edilen tüm sonuçlar yorumlanmış ve gelecekte yapılması planlanan çalışmalara yer verilmiştir.

# **SEGMENTATION OF MS LESIONS IN BRAIN MAGNETIC RESONANCE IMAGES USING FUZZY CLUSTERING ALGORITHMS**

## **SUMMARY**

Biomedical devices are commonly used by doctors for diagnosis and treatment of diseases. Early diagnosis is lifesaving and so medical imaging systems such as Magnetic Resonance Imaging (MRI), Computed Tomography (CT), Positron Emission Tomography (PET), Single Photon Emission Tomography (SPECT) and Ultrasound Imaging (US) are indispensable devices since they are needed to view diseases, tumors, fractures in the inner parts of the body. Each of medical imaging modalities has superiority and weakness to the others, so system to be used is chosen according to the purpose of imaging, organ to be imaged and physical condition of the patient.

Magnetic resonance imaging modality has superiority over other methods in terms of soft tissue contrast and therefore it is the most common system which is used for imaging the brain. However, interpretation of magnetic resonance images is harder compared to other methods since grey levels of the pixels in the image differ based on the device used and interpretation of the images and diagnosis of the diseases can only be carried out by doctors. In order to make this process easier and reduce time loss, automatic systems should be developed which is sufficient in terms of accuracy and speed.

Multiple Sclerosis (MS) is an inflammatory disease of central nervous system and it occurs as recurrent inflammation of myelin sheath. The causes of MS haven't been discovered yet; it is thought to result from genetic factors. Another possible cause is the attack of immune system to the myelin sheath of nerve cells because of an unknown reason. Since its symptoms can be similar to other diseases in central nervous system, diagnosis of MS is possible only by accurate interpretation of magnetic resonance images.

In this study, segmentation of MS lesions in magnetic resonance brain images is aimed. Segmentation can be defined as separating an image to smaller units which have similar properties. The purpose of segmentation is simplifying the representation of an image and make it easier to analyze. Several algorithms are developed for image segmentation and clustering algorithms can also be used for this purpose.

In this thesis, the fuzzy c-means clustering algorithm which is commonly used in literature and a new approach called interval type-2 fuzzy c-means clustering algorithm are applied to synthetic magnetic resonance images with Multiple Sclerosis disease. All of the codes used in the study are implemented using MATLAB.

Synthetic MR images used in the study are downloaded from the simulated brain database (BrainWeb) of McGill University. T1, T2 and PD (proton density) weighted images can be produced using the user interface of database, by adjusting parameters such as intensity non-uniformity, noise SNR and slice thickness. In this study, T1

and T2 weighted images are produced choosing 1 mm slice thickness and 0% intensity non-uniformity. SNR of noise is chosen as 0% and 9% respectively for noiseless and noisy images. An image volume consists of 181 slices in size of 181\*217 pixels. For this study, nine slices numbered from 97 to 105 were segmented.

The target image of each slice is also accessible on the same dataset. Different tissues of the brain are labeled by different numbers in the target images. So, the cluster consists of MS lesion for each slice can be chosen using its label and can be used to evaluate clustering results.

In this study, initially, fuzzy c-means clustering algorithm which is commonly used for segmentation problems is implemented. The fuzzifier parameter ( $m$ ) is reasonably effective on the performance of algorithm. There is no method to calculate this parameter, so its value is determined based on experimental results. In this thesis, results for different values of fuzzifier (in the range of 1,1 to 10) were obtained and most proper value of this parameter is determined.

Fuzzy c-means clustering algorithm is sensitive to initialization values and can easily trap into local minima. To avoid this problem, the initial values are determined using particle swarm optimization algorithm instead of random choice. Objective function of fuzzy c-means clustering algorithm is used as fitness function of particle swarm optimization algorithm. Each particle is a candidate for cluster centers. The output of particle swarm optimization algorithm is used as initial value of cluster centers for fuzzy c-means clustering algorithm. Thus, increasing consistency of the results of study is succeeded as aimed.

Interval type-2 fuzzy c-means algorithm is a modified version of fuzzy c-means clustering algorithm. Two different fuzzifier parameters ( $m_1$  and  $m_2$ ) are used instead of only one. Thus, cluster centers and membership values are represented by not a single value but an interval. This approach gives more accurate results for clustering the datasets which consist of clusters in different volume.

Interval type-2 fuzzy c-means algorithm is implemented using MATLAB and used for MS segmentation. As in fuzzy c-means clustering algorithm, there is no method to calculate fuzzifier parameters ( $m_1$  and  $m_2$ ), so their values are determined based on experimental results. Effect of fuzzifier parameters on performance of the algorithm is examined and most proper values of the parameters are determined. Finally, the results of both clustering algorithms are compared and superiority of interval type-2 fuzzy c-means approach is observed.

Segmentation processes for both algorithms are the same. Firstly, image is segmented into  $C_1$  clusters using T1 weighted normalized pixel intensities as features. Then, background pixels and the clusters of brain tissues which MS lesion doesn't occur (such as CSF and skull) were eliminated to decrease number of data. The rest of the image is segmented into  $C_2$  clusters using T2 weighted normalized pixel intensities as features. At the end of this process; one of the clusters consists of MS lesion. This cluster is chosen and compared pixel-to-pixel with target MS cluster. The four evaluation criteria are calculated which are sensitivity, specificity, similarity and accuracy.

In the first chapter, the purpose of thesis is explained and previous studies on image segmentation, fuzzy c-means clustering algorithm and type-2 fuzzy c-means approach in literature are presented.

In the second chapter, imaging systems used in medicine are briefly explained and advantages/disadvantages are discussed. In order to explain image acquisition, principles of magnetic resonance imaging are described. Then, the possible causes and common symptoms of Multiple Sclerosis disease are presented. Some statistical information about MS disease and its distribution in the world are included. Finally, some of the methods which are used commonly in image segmentation are explained briefly.

In the third chapter of the thesis, the methods used in this study which are fuzzy c-means algorithm, type-2 fuzzy c-means algorithm and particle swarm optimization algorithm are explained in detail. Flow-charts and pseudo-codes of the methods are presented and the process followed for segmentation is described. Information on the images used in the thesis, the database, features used for segmentation and evaluation criteria are given.

In the fourth section, the results obtained from noisy and noiseless images for different values of fuzzifier parameter  $m$ , using fuzzy c-means clustering algorithm are presented. Then, results of fuzzy c-means algorithm when particle swarm optimization algorithm is used for initialization of cluster centers are given. Effect of initialization using particle swarm optimization algorithm is interpreted. Finally, the results of main algorithm used in the study, which is interval type-2 fuzzy c-means algorithm, for different values of fuzzifier parameters are given.

In the last section, all results obtained in this study are interpreted and future work is included.



## 1. GİRİŞ

Hastalıkların erken teşhisi, tedavi sürecinde çoğu zaman hayat kurtarıcı olmaktadır. Ancak iç organlarda ortaya çıkan hastalık ve tümörler, gözle görülememekte ve bulgular genellikle hastalık ilerlediğinde gözlenebilmektedir. Bu amaçla, günümüzde tıbbın neredeyse tüm alanlarında gerek teşhis gerekse tedavi sürecinde doktorlara yardımcı olacak biyomedikal düzenler kullanılmaktadır. Özellikle tıbbi görüntüleme sistemleri olarak adlandırılan manyetik rezonans görüntüleme (Magnetic Resonance Imaging, MRI) , ultrason, bilgisayarlı tomografi (Computed Tomography, CT), pozitron emisyon tomografisi (Positron Emission Tomography, PET) gibi cihazlar doktorlar tarafından vazgeçilmez birer yardımcısıdır. Bu sistemlerin birbirine göre üstün ya da zayıf kaldıkları noktalar olmakla birlikte, hangi sistemin kullanılacağı görüntülenmek istenen doku ve organa göre, hastanın fiziksel durumuna göre değişmektedir.

### 1.1 Çalışmanın Amacı

Vücudun gözle görülemeyen bölgelerinde ortaya çıkan tümör gibi oluşumların, hastalıkların, kanamaların, kırıkların tespitinde tıbbi görüntüleme sistemlerine ihtiyaç duyulmaktadır. Görüntülenen dokuya uygun görüntüleme sistemi kullanılarak elde edilen görüntünün yorumlanması ve hastalığın teşhisi doktorlar tarafından yapılmaktadır. Bu işlem el ile yapıldığında hem çok zaman almakta, hem de tamamıyla doktorun deneyimine ve mesleki becerisine bağlı olmaktadır. Bazen, mesleğe yeni başlamış doktorlar görüntüleri yorumlamakta zorlanmakta ya da hastalıklı dokunun sınırlarını tam doğrulukla çizememekte, birbirine benzer dokuları ayırtıramamaktadır. Bu sıkıntıları aşmak için, doktorlara yardımcı olacak sistemlere ihtiyaç duyulmakta ve doğruluk, hız bakımından daha iyi sistemler geliştirebilmek için çalışmalar yapılmaktadır.

Bu tez çalışmasında, medikal görüntülerin bölütlenmesi amaçlanmıştır. Bu amaçla, denetimsiz kümeleme algoritmaları olarak bilinen yöntemlerden bazıları multipl skleroz (Multiple Sclerosis, MS) lezyonu içeren yapay beyin görüntüleri üzerinde

uygulanmış ve hastalıklı bölgenin ayrıştırılması amaçlanarak elde edilen sonuçlar değerlendirilmiştir.

## **1.2 Literatür Özeti**

Literatürde beyin manyetik rezonans görüntülerinin bölütlenmesi ve sınıflandırılmasına yönelik çok sayıda çalışma mevcuttur. Yapılan çalışmalarda gerek öznitelik belirleme gerekse bölütleme ve sınıflandırma aşamasında aşağıda özetlenen birçok farklı yöntem kullanılmıştır.

### **1.2.1 Öznitelik belirleme**

Görüntü bölütleme ve sınıflandırma problemlerinde, görüntüde ayrıştırılmak istenen alanlara ait benzerlik ve farklılıkları içeren bilgiye ihtiyaç duyulmaktadır. Bu amaçla, öznitelik olarak adlandırılan ve seçimi uygulamanın amacı ile görüntü özelliklerine göre yapılan bazı parametreler kullanılmaktadır. Literatürde öznitelik çıkarma ve doğru özniteliklerin seçimi için önerilmiş birçok yöntem mevcuttur. Bu çalışmalarda gri seviye yineleme matrisleri (GLCM) [1], dalgacık dönüşümü katsayıları [2-4], Fourier dönüşümü katsayıları [5], kosinüs dönüşümü katsayıları [3], simetri özellikleri [6, 7] gibi öznitelikler farklı bölütleme yöntemleri ile birlikte kullanılmıştır.

### **1.2.2 Görüntü bölütleme ve sınıflandırma**

Medikal görüntülerin bölütlenmesi ve sınıflanması konusunda geçmişte yapılmış çok sayıda çalışma mevcuttur ve halen daha etkili yöntemler bulmak için çalışmalar sürmektedir. Yapılan çalışmalarda farklı yöntemler kullanılmıştır.

Yoon ve arkadaşları [8] MR beyin görüntülerinin otomatik bölütlenmesi ve lezyon tespitini amaçlayan çalışmalarında bulanık c-ortalama (BCO) algoritmasını kullanmışlardır. Anormallik tespiti için, beyin simetri özelliğinden ve beyinle ilgili anatomik bilgiden faydalanılmış, başarılı sonuçlar elde edilmiştir.

Literatürde, standart BCO algoritmasının kullanıldığı çok sayıda çalışma olmakla birlikte, algoritmanın bölütleme başarısını artırmak ya da işlem süresini kısaltmak amacıyla, çeşitli parametrelerin ya da amaç fonksiyonun modifiye edilmesiyle yapılmış çalışmalar da mevcuttur. Bunlardan birinde Szilagyi ve arkadaşları [9], hesaplama süresini azaltmak amacıyla klasik BCO yöntemindekinden farklı olarak



gama faktörü eklenmiş bir amaç fonksiyonunu minimize etmeyi amaçlamışlardır. Elde edilen sonuçlarda, yeni yöntemin eskisine göre daha kısa sürede sonuca ulaştığı görülmüştür.

Yine böyle bir çalışmada, Chuang ve arkadaşları [10] klasik bulanık c-ortalamlar algoritmasından farklı olarak yonteme uzaysal bilgi dahil etmişlerdir. Her pikselin sadece kendisinin değil, bir pencere içerisindeki komşularının üyelik derecelerinin de dikkate alınmasıyla küme merkezi güncellemesi için yeni eşitlikler türetilmiştir. Önerilen yöntem beyin MR görüntülerini bölütlemeye kullanılmış ve klasik bulanık c-ortalamlar algoritmasına göre daha iyi sonuçlar elde edilmiştir.

Wang ve arkadaşları tarafından [11] küresel bulanık c-ortalamlar olarak adlandırılan ve klasik bulanık c-ortalamlar algoritmasının başlangıç değerlerine bağlılık problemini çözmeyi amaçlayan bir yöntem önerilmiştir. Önerilen yonteme göre, başlangıçta seçilmesi gereken küme merkezi değerleri, klasik BCO algoritmasında olduğu gibi rastgele atanmak yerine, veri kümesi içerisinde seçilmektedir. Sonuçlara bakıldığında, yöntemin başlangıç değerine bağlılığının ortadan kalktığı ve her çalıştırıldığında aynı sonucu verdiği görülmektedir.

Vasuda ve Satheesh tarafından [12] veri sıkıştırmaya dayanan yeni bir geliştirilmiş BCO algoritması önerilmiştir. Yöntem, klasik BCO gibi başarılı sonuç vermiş, ayrıca veri sıkıştırma yapıldığından işlem süresi azalmıştır.

Kalaiselvi ve Somasundaram tarafından [13] klasik BCO algoritmasının kullanıldığı bir çalışmada küme merkezlerinin başlangıç değerleri rastgele seçilmek yerine histograma dayanarak atanmıştır. Önerilen yöntemde en büyük ve en küçük küme merkezi değerleri her zaman 255 ve 0 olacak şekilde, ara bölge histogramda 0 ve 255 değerleri arasındaki tepe (pick) sayısına göre eşit olarak bölünerek küme merkezlerinin başlangıç değerleri atanmıştır. Yöntem beyin manyetik rezonans görüntülerine uygulanmış ve sonuçta işlem süresinde kısalma gözlenmiştir.

Shasidhar ve arkadaşları tarafından işlem süresini kısaltmayı amaçlayarak yapılan bir başka çalışmada [14], veri sıkıştırma tekniği (quantization/ aggregation) ile veri sayısı azaltılmış ve buna bağlı olarak işlem süresi kısalmıştır.

Literatürde biyomedikal görüntü bölütlenmesi ve sınıflaması için en çok kullanılan yöntemlerden biri de yapay sinir ağlarıdır. Reddick ve arkadaşları tarafından yapılan bir çalışmada [15], manyetik rezonans (MR) görüntülerinin bölütlenmesi için yapay

sinir ağıları kullanılmıştır. Önerilen yöntemde, bölütleme için öz-örgütlemeli haritalar (self organizing maps, SOM), sınıflama içinse çok tabakalı geri yayımlı yapay sinir ağı (multilayer backpropagation artificial neural network) kullanılmıştır. Elde edilen sonuçlar güvenilirdir.

Alirezaie ve arkadaşları [16] beyin MR görüntülerinin bölütlenmesini amaçlayan çalışmalarında öz-örgütlemeli haritalar yapay sinir ağını kullanmış ve yöntemin performansını bulanık c-ortalama yönteminden elde ettikleri sonuçlar ile karşılaştırmışlardır. Yöntemin güvenilir sonuçlar verdiği görülmüştür.

Demirhan ve Güler tarafından [17] yapılan bir çalışmada, beyin MR görüntülerinin analizi için öz-örgütlemeli haritalar ve öznetelik olarak dalgacık dönüşümü katsayıları kullanılmıştır. Yüksek doğruluk oranına sahip sonuçlar elde edilmiştir.

Görüntü bölütlemesi ve sınıflaması için ayrıca bulanık mantık [18], global k-ortalama [19], genetik algoritma [20], bağımsız bileşen analizi [21], bölge büyütme [22], atlas-tabanlı algoritmalar [23], tumor-cut [24] gibi birçok farklı yöntem kullanılmıştır.

Bu tez çalışmasının amacı olan MS lezyonunun ayrıştırılmasına yönelik yapılmış birçok çalışma literatürde mevcuttur.

Boudraa ve arkadaşları [25] manyetik rezonans beyin görüntülerinden MS lezyonlarının ayrıştırılmasını amaçlayan çalışmalarında BCO algoritmasını kullanmışlardır. PD ve T2 ağırlıklı MR görüntülerinin kullanıldığı çalışmada, öncelikle bir maske oluşturularak görüntüden lezyon dokusu ve beyin-omurilik sıvısı (CSF) dışındaki dokuları içeren pikseller atılmıştır. Geriye kalan görüntü tekrar bölütlenerek MS lezyonları elde edilmeye çalışılmıştır. Elde edilen sonuçlar bir uzman tarafından manuel olarak ayrıştırılmış lezyonlarla karşılaştırıldığında, sonuçların kabul edilebilir doğrulukta olduğu görülmüştür.

Kawa ve Pietka [26] tarafından MS lezyonunun bölütlenmesi için çekirdek bulanık c-ortalama yöntemi kullanılmıştır. Yöntem 40 farklı hastadan alınan FLAIR olarak ağırlıklandırılmış MR görüntülerine uygulanmış ve kabul edilebilir sonuçlar elde edilmiştir.

Özkurt N. ve Özkurt A. [27] MR görüntülerinin bölütlenmesini amaçlayan çalışmalarında bağımsız bileşen analizi yöntemini kullanmışlardır. Çalışmada T1, T2 ve PD ağırlıklı bantlardan doğrusal ve doğrusal olmayan çeşitli işlemlerle elde edilen

yeni bantların bağımsız bileşenleri hesaplanmıştır. Bağımsız bileşenler arasından MS dokusunun en iyi görüntülediği bağımsız bileşen seçilmiş ve eşikleme yapılarak MS lezyonu ayrıştırılmıştır. Yöntem McGill Üniversitesi'ne ait BrainWeb veritabanından alınan sentetik görüntülere uygulanmış ve %90 başarı oranı sağlanmıştır.

Özyavru ve Özkurt N. tarafından [28] yapılan bir çalışmada, MR görüntülerinden MS lezyonlarının ayrıştırılması için bulanık mantık teknikleri kullanılmıştır. Yöntemin başarısını artırmak amacıyla öncelikle beyaz maddenin ayrıştırılması için bulanık çıkarım yöntemleri, elde edilen görüntülerin öbeklenerek MS plaklarının bölütlenmesi içinse bulanık kümeleme algoritması kullanılmıştır. Yöntem T1,T2 ve PD ağırlıklı sentetik görüntülere uygulanmış ve başarılı sonuçlar elde edilmiştir.

Khotanlou ve Afrasiabi tarafından [29] T1 ve T2 ağırlıklı MR görüntülerinden MS lezyonlarının ayrıştırılması için uzaysal olarak sınırlandırılmış olasılıksal bulanık c-ortalamlar (possibilistic fuzzy c-means) algoritması kullanılmıştır. Yöntem başarılı sonuç vermiştir.

Özyavru ve arkadaşları [30] bilinen birkaç bölütleme yöntemini birlikte kullanarak, beyin dokusu içinde MS plaklarını bölütlemeyi amaçlayan bir çalışma yapmışlardır. T1 ve T2 ağırlıklı MR görüntülerinin piksel-piksel çarpımı ile elde edilen maske ön işlemede kullanılmıştır. Öbek merkezlerinin bulunması için standart bulanık c-ortalamlar algoritması kullanılmıştır. Birbiriyle bağlantılı dokuların bulunması içinse eş seviye eğrilerinden faydalanılmıştır. Yöntem, Dokuz Eylül Üniversitesi Hastanesi'nden alınmış gerçek görüntülere uygulanmış ve düşük hata oranına sahip sonuçlar elde edilmiştir.

Bassem ve arkadaşları [31] T1, T2 ve FLAIR ağırlıklı beyin MR görüntülerinden MS lezyonlarının ayrıştırılması için eğitilmiş destek vektör makinelerini (SVM) kullanan bir yöntem önermişlerdir. Sonuçlar, farklı yöntemler uygulanan çalışmaların sonuçları ile karşılaştırıldığında rekabet edebilir doğrulukta olduğu görülmüştür.

Bu çalışmalara ek olarak 2008 yılında MICCAI (The Medical Image Computing and Computer Assisted Intervention Society) tarafından MS üzerine görüntü analizi konulu bir yarışma düzenlenmiş ve katılımcılar tarafından birçok yöntem önerilmiştir [32].

Tip-2 bulanık sistemler, bilinen bulanık sistemlerin bazı parametrelerinin belirsizlik (uncertainty) özelliğini kullanan sistemlerdir ve bu konuda literatürde yapılmış

birçok çalışma mevcuttur [33-37]. Tip-2 bulanık kümeleme algoritması diğer yöntemlere göre nispeten daha yeni bir yaklaşım olduğundan, kullanım alanı çok geniş olmasa da literatürde bu konuda yapılmış çalışmalara da rastlanmaktadır. Literatür taramasında, tip-2 bulanık kümeleme algoritmasının MS lezyonlarının ayrıştırılması için kullanıldığı bir çalışmaya rastlanmamıştır.

Tip-2 bulanık kümeleme ifadesi ilk defa Rhee ve Hwang [38] tarafından kullanılmıştır. Yapılan çalışmada tip-1 üyelik değerlerinin tip-2 üyelik değerlerine genişletilmesini öneren bir yöntem geliştirilmiştir. Bu yeni yaklaşımla elde edilen sonuçların gürültüye hassasiyetinin daha az olduğu gözlenmiştir. Bu yöntem, daha sonradan kullanılmaya başlanan tip-2 bulanık kümeleme algoritmasından farklı olsa da, bu kavramın ilk defa kullanılması açısından önemlidir.

Hwang ve Rhee [39] yaptıkları diğer bir çalışmada klasik BCO algoritmasına aralık tip-2 yaklaşımını uyarlamışlardır. Çalışmada bulanıklık sabitinin ( $m$ ) belirsizliği üzerinde durulmuş ve üyelik fonksiyonu iki farklı  $m$  değeri için bir aralıkla temsil edilmiştir. Buna göre küme merkezi güncellemeleri de bir aralık için Karnik-Mendel algoritması kullanılarak yapılmıştır. Böylelikle farklı hacim ve yoğunluğa sahip kümeleri öbekleştirmek konusunda daha verimli sonuçlar elde etmek amaçlanmıştır. Önerilen bu yeni algoritma, yaygın olarak kullanılan dört farklı veri seti ile iki farklı görüntünün bölütlenmesi için kullanılmış ve verimli sonuçlar elde edilmiştir.

Ceylan ve arkadaşları tarafından [40] tip-2 bulanık kümeleme algoritması ve yapay sinir ağlarını bir arada kullanan bir yöntem elektrokardiyogram (EKG) aritmi sınıflamada kullanılmıştır. Önerilen yöntemde öncelikle MIT-BIH veri tabanından alınan farklı aritmi tipindeki veriler kendi içinde öbekleştirilerek kümeyi en iyi temsil eden veriler seçilmiş, daha sonra bu yeni veri kümesi ile yapay sinir ağı eğitilmiştir. Aynı veri tabanından alınan farklı EKG aritmi kayıtları için yöntem test edildiğinde daha kısa sürede daha güvenilir sonuçlar elde edildiği görülmüştür.

Min ve arkadaşları [41], yaptıkları çalışmada gürültülü görüntülerde bulanık c-ortalamaları algoritmasının zayıflığına karşı geliştirilmiş olan olasılıksal c-ortalamalar algoritmasına tip-2 yaklaşımında bulunmuşlardır. Bulanıklık sabitinin belirsizliği üzerine odaklanılmış ve iki farklı  $m$  değeri için aralık tip-2 bulanık olasılıksal c-ortalamalar algoritması geliştirilmiştir. Yöntem iki farklı veri seti ve bir adet görüntünün bölütlenmesi için kullanılmış ve klasik OCO algoritmasına göre daha iyi sonuçlar elde edilmiştir.

Qiu ve arkadaşları [42] görüntü bölütlemesi için aralık tip-2 bulanık c-ortalamlar algoritmasını (T2BCO) kullanan bir çalışma yapmışlardır. Önerilen yöntemin daha önceki çalışmalardan farkı, kümeleme için uzaysal bilgiyi de kullanmasıdır. Çalışmanın gürültülü görüntüler için iyi sonuçlar verdiği görülmüştür.

Özbay ve arkadaşları [43], yaptıkları çalışmada T2BCO algoritması ile yapay sinir ağlarını bir arada kullanmışlardır. Öznitelik olarak dalgacık dönüşümü katsayıları kullanılmış ve yöntem MIT-BIH veri tabanından alınan EKG aritmilerini sınıflamada kullanılmıştır. Çalışmada eğitim süresini kısaltmak ve doğruluk oranını artırmak amaçlanmış ve çalışma sonucunda bu hedeflere ulaşılmıştır.

Kaur ve arkadaşları tarafından yapılan çalışmada [44] BT ve MR beyin görüntülerinin bölütlenmesi için çekirdek tip-2 bulanık c-ortalamlar algoritması önerilmiştir. Yöntem sentetik görüntü ile gerçek MR ve BT görüntülerine uygulanmış ve sonuçları tip-2 BCO ile kıyaslandığında hata oranında düşüş olduğu gözlenmiştir.

Wang ve arkadaşları [45] tarafından küresel aralık tip-2 BCO olarak adlandırılan ve klasik tip-2 BCO algoritmasının başlangıç değerlerine bağlılık problemini çözmeyi amaçlayan bir yöntem önerilmiştir. Önerilen yöntemde göre, başlangıçta bir küme için küme merkezi hesaplanmakta ve bu değer bir sonraki aşamada iki küme için yapılacak öbekleştirmenin ilk küme merkezinin başlangıç değeri olarak atanmaktadır. İkinci küme merkezinin başlangıç değerinin ataması için veri kümesindeki her değer küme merkezi gibi düşünülerek hedef fonksiyon hesaplanmakta ve bu değeri minimum yapan veri, küme merkezinin başlangıç değeri kabul edilmektedir. Her aşamada küme sayısı 1 artırılarak hedeflenen küme sayısına ulaşıncaya kadar aynı işlem tekrarlanmaktadır. Sonuçlara bakıldığında, yöntemin başlangıç değerine bağlılığı ortadan kaldırdığı görülmüştür ve program her çalıştırıldığında aynı sonucu vermektedir.

Görüntü bölütlemesi için bir başka yaklaşım, optimizasyon algoritmalarının kullanılmasıdır. Forghani ve arkadaşları tarafından [46] yapılan çalışmada, MRI görüntülerinin bölütlenmesi için geliştirilmiş bulanık c-ortalamlar algoritması ve parçacık sürü optimizasyonu bir arada kullanılmıştır. Gürültülü görüntülerin bölütlenmesinde BCO algoritmasının performansı düşeceğinden, iki yeni parametre

tanımlanarak algoritmanın performansı iyileştirilmeye çalışılmıştır. Daha önce yapılan çalışmalarda bu parametreler yapay sinir ağları kullanılarak hesaplanmış, bu çalışmada ise bu iki parametrenin hesabı için parçacık sürü optimizasyonu algoritmasının kullanılması önerilmiştir. Yöntem gürültü içeren ve içermeyen T1 ağırlıklı MR görüntüsüne uygulanmış, başarılı sonuçlar elde edilirken işlem süresi de kısalmıştır.

Taherdangkoo ve arkadaşları [47] çalışmalarında bulanık c-ortalamar algoritmasının performansını iyileştirmek için kullanılan parametrelerin hesabı için yapay arı kolonisi (Artificial Bee Colony, ABC) optimizasyonu algoritmasını kullanmış ve işlem süresini azaltırken bölütleme performansını da artırmayı amaçlamışlardır. Yöntem gerçek MR görüntüleri üzerinde denenmiş ve sonuçlar aynı amaçla parçacık sürü optimizasyonu ve genetik algoritma kullanıldığında elde edilen sonuçlarla karşılaştırılmıştır. Bölütleme başarısında artış ve işlem süresinde kısalma gözlenmiştir.

Doğan ve Korürek [48] EKG vurularını kümelemek için bulanık c-ortalamar ve parçacık sürü optimizasyonuna dayalı bir yöntem önermişlerdir. MIT-BIH aritmi veri tabanından alınan EKG kayıtları ön işlemden geçirilmiş, sonrasında farklı aritmi tiplerine ait öznitelikler çıkarılmıştır. Bu öznitelikler önerilen yöntem ile öbekleştirilmiş ve basit ama kararlı bir sınıflayıcı yapısı kullanılarak sınıflandırılmıştır. Sonuç olarak önerilen yöntemin BCO algoritmasının başlangıç değerlerine bağlılık ve yerel minimuma takılma problemlerinin üstesinden geldiği görülmüştür.

Izakian ve Abraham [49] çalışmalarında bulanık c-ortalamar algoritması ile parçacık sürü optimizasyon algoritmasını bir arada kullanmışlardır. Böylece bulanık c-ortalamar algoritmasının başlangıç konumlarına bağlılık ve yerel minimuma takılma problemlerinin üstesinden gelmeyi amaçlamışlardır. Yöntemi altı farklı veri seti üzerinde test etmiş ve başarılı sonuçlar elde etmişlerdir.

## 2. TIBBİ GÖRÜNTÜLEME

### 2.1 Başlıca Görüntüleme Sistemleri

Günümüzde klinik amaçlarla kullanılan tıbbi görüntüleme sistemleri beş temel tekniğe dayanır

- 1-İnsan vücudundan geçirilen x-ışınının ölçülmesi
- 2- Gönderilen ultrases dalgalarının çeşitli dokulardan yansıtılarak geri dönmesi ve ölçülmesi
- 3-Damara enjekte edilen radyoaktif maddelerden yayılan gama ışınlarının ölçülmesi
- 4-Vücuttaki hidrojen atomlarının yüksek manyetik alana maruz bırakılması esasına dayanan manyetik rezonans görüntüleme
- 5- Termal görüntüleme teknikleri [50].

İnsan vücudunun gözle görülmeyen kısımlarını görüntülemek için ilk kullanılan yöntem x-ışınlarının kullanımınıdır. X-ışınları 1895 yılında Wilhelm Roentgen tarafından keşfedilmiş ve Roentgen bu buluşu ile 1901 yılında Nobel fizik ödülüne layık görülmüştür [51]. X-ışınlarının frekansı  $3 \cdot 10^{16} \text{ Hz}$  ile  $3 \cdot 10^{20} \text{ Hz}$  arasında, dalga boyu ise  $10^{-10} \text{ m}$  ile  $10^{-12} \text{ m}$  aralığındadır. Çizelge 2.1'de elektromanyetik spektrumdaki bazı dalga tiplerine ait özellikler verilmiştir.

**Çizelge 2.1 :** Elektromanyetik spektrumdaki bazı dalga tiplerinin özellikleri [52].

Dalganın tipi	Frekans	Dalga boyu
FM radyo	88-108 MHz	3.4-3 m
Televizyon	54 MHz-0.8 GHz	5.6-0.4 m
Mikrodalga	0.1-100 GHz	3 m-3 mm
Kızılaltı	100 GHz-400 THz	3 mm-0.7 m
Görünür ışık	400-700 THz	0.7 m-0.4 m
Morötesi	1-100 PHz	300-3 nm
X-ışınları	100 PHz-100 EHz	3 nm-3 am
Gama ışınları	$\geq 100 \text{ EHz}$	3-0 am

X-ışınlarının medikal görüntülemedeki ilk uygulaması olan X-ışını radyografi tekniği, bir kaynaktan yayılan x-ışınlarının hastanın vücudundan geçirilerek diğer

tarafında bir film üzerine düşürülmesi prensibine göre çalışır. Dokular x-ışınının bir kısmını soğuracağından hastanın vücudundan geçen ve diğer tarafta ölçülen edilen x-ışını yoğunluğu farklı olacaktır. X-ışınının soğurulma miktarı maddenin yoğunluğuna ve maddeyi oluşturan atomların atom numarasına bağlıdır, dolayısıyla farklı dokulardan geçen X-ışını farklı miktarlarda soğurulacak ve film üzerine düştüğünde farklı oranda karartmaya sebep olacaktır. Film üzerindeki renk farklılıklarından yola çıkarak farklı dokular ayırt edilebilmektedir [53]. Şekil 2.1’de Roentgen tarafından ilk çekilen filmlerden biri görülmektedir.



**Şekil 2.1 :** W.Roentgen tarafından ilk çekilen filmlerden biri (1895) [54].

X-ışını radyografi yönteminde, basitçe görüntülenecek bölgenin düzlemsel izdüşümü alındığından, üst üste gelen dokular birbirinden ayırt edilemez. Örneğin, x-ışını soğurma oranı yüksek olan kemik dokunun arkasındaki yumuşak doku görüntülenemez. Bu sebeple, üç boyutlu ya da kesitsel görüntülerin gerektiği durumlarda yine x-ışınlarını kullanan bir yöntem olan bilgisayarlı tomografiden faydalanılmaktadır [53].

Bilgisayarlı tomografi 1970’li yıllarda Hounsfield tarafından geliştirilmiştir. Hounsfield bu çalışması ile 1979 yılında, daha önce yöntemin matematiği üzerine çalışmış olan Allan Cormack ile birlikte tıpta Nobel ödülünü kazanmıştır[51]. Bilgisayarlı tomografi tekniğinde, x-ışını kaynağı, dedektörler veya her ikisi birden hasta etrafında hareket ettirilerek, görüntülenmek istenen bölgenin farklı açılardan izdüşümleri alınır. Daha sonra bu izdüşüm bilgileri işlenerek ilgili bölgenin kesitsel görüntüsü elde edilir. Bilgisayarlı tomografi özellikle x-ışını radyografi ile görüntülenemeyen iç organların ve kafatasıyla çevrili olduğundan radyografide



görüntüsü alınamayan beynin görüntülenmesinde faydalı bir yöntemdir. Şekil 2.2’de bu yöntemle elde edilmiş bir beyin görüntüsü görülmektedir.



**Şekil 2.2 :** Bilgisayarlı tomografi tekniği ile elde edilmiş beyin görüntüsü [55].

X-ışını kullanan sistemlerin en büyük dezavantajı insan sağlığına olan zararıdır. Elektromanyetik spektrumda,  $10^{15}$  Hz’den daha yüksek frekansa ve  $400\text{ nm}$ ’den düşük dalga boyuna sahip dalgalar iyonlaştırıcı dalgalar olarak ifade edilir. X-ışınları da bu bölgede bulunduğu için, dokular ile etkileşime girdiğinde iyonlaştırıcı özellik gösterir. Bu yüzden bir insanın bir senede maruz kalabileceği radyasyon dozunun bir limiti vardır ve bilgisayarlı tomografi zorunlu olmayan durumlarda kullanılmamalıdır.

Görüntüleme sistemlerinde kullanılan diğer bir teknik olan ultrases (ultrason) ile görüntüleme (US), ultrases dalgalarının darbe-yansıma prensibinden yola çıkarak geliştirilmiştir. İnsan kulağı 20 Hz ile 20 kHz arasındaki sesleri duyabilir. Bu frekans aralığının üzerindeki akustik dalgalara ultrases dalgaları denir [50]. Teşhis amaçlı kullanılan ultrases dalgaları 20 kHz -10 MHz arasındadır. 1-3 MHz frekans aralığındaki ses dalgaları derindeki dokuları görüntülemek için kullanılırken, 5-10 MHz frekans aralığındaki dalgalar vücut yüzeyine daha yakın olan dokuları görüntülemekte kullanılır [53].


Ultrasonla görüntüleme yönteminde görüntülenmek istenen bölgeye ultrases darbesi gönderilir ve hedeften yansıtılarak gelen eko geri alınır. Ses dalgalarının yayılma hızı ortamın cinsi, yoğunluğu, sıcaklığı gibi faktörlere bağlı olduğundan, giden dalga ile yansıyan dalga arasındaki genlik farkı, gecikme ve faz farkı gibi bilgilerden yola çıkarak gözle görülmeyen hedefle ilgili istenen bilgiler çıkarılabilir. Bu yöntem insan vücuduna hiçbir zararının olmaması, kolay uygulanabilir ve ucuz olması gibi

sebeplerle yaygın bir şekilde kullanılmaktadır. Şekil 2.3'te bu teknikle elde edilmiş bir görüntü görülmektedir.



**Şekil 2.3 :** Ultrasonla görüntüleme tekniği ile elde edilmiş görüntü [56].

Medikal görüntüleme sistemlerinde kullanılan diğer bir yöntem, damara enjekte edilen, solunum veya sindirim yoluyla alınan radyoaktif maddelerden yayılan gama ışınlarının ölçülmesi tekniğine dayanır. İlk olarak 1926 yılında [50] uygulanan teknik, radyoaktif maddeler kullanıldığı için nükleer tıp olarak adlandırılmıştır. Bu tekniği kullanan yöntemler olan pozitron emisyon tomografisi (PET) ve tek foton emisyon bilgisayarlı tomografi (SPECT) temelde aynı prensibe göre çalışmakla birlikte aralarındaki temel fark, pozitron emisyon tomografide kullanılan radyonüklid pozitron yayarken, tek foton emisyon tomografide gama ışını fotonlarının yayılmasıdır. Bu yöntemin diğer görüntüleme yöntemlerinden en temel farkı, diğer yöntemlerde vücudun anatomik görüntüsü alınırken, bu teknikte radyoaktif maddenin yayılmasına bağlı olarak organların fizyolojik durumu hakkında bilgi sahibi olunabilmesidir. Şekil 2.4'te PET/SPECT ile elde edilmiş örnek görüntüler görülmektedir. Nükleer tıp uygulamalarında, insan vücuduna az miktarda da olsa radyoaktif madde verildiğinden, sağlık açısından zararlı olduğu söylenebilir.




**Şekil 2.4 :** PET/SPECT ile elde edilmiş görüntüler [53].

Medikal görüntüleme sistemlerinde özellikle yumuşak doku görüntüleme amacıyla yaygın olarak kullanılan diğer yöntem, vücuttaki hidrojen atomlarının yüksek manyetik alana maruz bırakılması esasına dayanan manyetik rezonans görüntülemedir (MRG). İyonize edici radyasyon içermediğinden, insan sağlığına olumsuz etkisi yoktur. Şekil 2.5'te örnek bir manyetik rezonans beyin görüntüsü görülmektedir. Bu yöntemle ilgili detaylı bilgi diğer bölümde verilecektir.

Görüntüleme amaçlı kullanılan bir teknik de termal görüntülemedir. Termal görüntüleme sistemlerinin temeli kızılaltı (infrared) ışımadır. Dalga boyu  $0.7\mu\text{m}$  den daha uzun, mikrodalgadan daha kısa ışımaya kızılaltı denir. İnsan vücudu, kızılaltı bölgede ışımaya yapar ve bu ışımaya uygun detektörler ile algılanarak farklı oranlarda ışımaya yapan bölgeler ayırt edilebilir. Şekil 2.6'da bu teknikle elde edilmiş bir görüntü görülmektedir [50].



Şekil 2.5 : MRG tekniği ile elde edilmiş beyin görüntüsü [53].



Şekil 2.6 : Termal görüntüleme tekniğiyle elde edilmiş görüntü [57].

## 2.2 Manyetik Rezonans Görüntüleme

Manyetik rezonans görüntüleme (MRG), çok güçlü bir mıknatıs ( $1,5-2\text{ T}$ )<sup>1</sup> ve radyo dalgaları kullanılarak görüntü elde edilmesini sağlayan ve iyonize edici radyasyon

<sup>1</sup> Dünyanın manyetik alanı  $0,5 \cdot 10^{-4}$  Tesla'dır.

içermeyen kesitsel bir radyolojik inceleme yöntemidir [58]. Beyin rahatsızlıkları ve bel kemiğindeki problemlerin teşhisi, anjiyografi ve kalp fonksiyonlarının kontrolü başlıca kullanım alanları olarak sayılabilir.

MRG yönteminde, farklı dokuları birbirinden ayırmak için gerek duyulan bilgi, vücuttaki hidrojen atomlarının manyetik alanla etkileşiminden elde edilen manyetik rezonans sinyalinden çıkarılır. Uygulamada hidrojen atomunun tercih edilme sebepleri, insan vücudunda bulunan en yaygın element olması ve manyetik rezonansa en duyarlı element olmasıdır [50].

### **2.2.1 Manyetik rezonans görüntüleme sisteminin gelişimi**

1946 yılında Felix Bloch ve Edward Purcell, birbirlerinden bağımsız olarak manyetik rezonans prensibini keşfetmişler ve her ikisi de 1952 yılında Nobel ödülüne layık görülmüşlerdir [51]. 1950 ve 1970 yılları arasında, nükleer manyetik rezonans geliştirilmiş ve fiziksel ve kimyasal moleküler analiz için kullanılmıştır [59].

1971 yılında Raymond Damadian'ın dokuların ve tümörlerin nükleer manyetik gevşeme zamanlarının farklı olduğunu göstermesi, bilim adamlarının manyetik rezonans tekniğini medikal teşhis amaçlı kullanmak konusunda araştırma yapmaya başlamalarını sağlamıştır. 1973 yılında Hounsfield tarafından x-ışını bilgisayarlı tomografinin geliştirilmesi hastanelerin medikal görüntüleme donanımlarına yüksek miktarlarda para harcayabileceğini göstermiş ve aynı yıl, Paul Luterbur tarafından ilk manyetik rezonans görüntüleme denemeleri yapılmıştır. Luterbur çalışmalarında bilgisayarlı tomografide olduğu gibi geri izdüşüm (backprojection) yöntemlerini kullanmıştır. 1975 yılında, Richard Ernst faz ve frekans kodlaması ile Fourier dönüşümü kullanan manyetik rezonans görüntüleme sistemini önermiştir. Bu yöntem günümüzdeki manyetik rezonans görüntüleme yöntemlerinin temelidir ve 1991 yılında, Richard Ernst çalışmalarıyla kimya dalında nobel ödülüne layık görülmüştür [51]. Edelstein ve çalışma arkadaşları, 1980 yılında Ernst'in tekniğini kullanarak görüntüleme yapmışlardır. Bu yöntemle, tek bir görüntünün elde edilmesi beş dakika sürmüştür. 1986'da görüntü kalitesini çok fazla azaltmadan görüntüleme zamanı yaklaşık beş saniyeye düşürülmüştür. 2003 yılında, Paul C. Lauterbur ve Sir Peter Mansfield manyetik rezonans görüntüleme alanındaki keşifleriyle tıpta Nobel ödülünü kazanmışlardır [51, 59].

### **2.2.2 Manyetik rezonans görüntüleme yönteminin avantajları ve dezavantajları**

Manyetik rezonans fiziğinden ve manyetik rezonans görüntüleme tekniğinin detaylarından bahsetmeden önce, yöntemin avantaj ve dezavantajlarına değinmek faydalı olacaktır.

MRG yöntemi, uzaysal çözünürlüğü ve kontrastı yüksek görüntüler elde edilmesine imkân vermektedir. Özellikle yumuşak doku kontrastı bilgisayarlı tomografi ile karşılaştırıldığında oldukça yüksektir ve birçok patolojinin teşhisi bu sayede mümkün olmaktadır. MR görüntülemenin bir diğer avantajı, hastanın yatış pozisyonu değiştirilmeden istenilen düzlemde kesitsel görüntünün elde edilebilmesidir. Bu özellik hem olası bir patolojinin konumunun tam olarak saptanmasına imkân verirken, hem de hastayı rahatsız etmemesi açısından önemlidir. Manyetik rezonans görüntülemenin en önemli avantajlarından biri de, yöntemin iyonize edici radyasyon içermemesidir. Bu sayede yöntem istenilen her an tekrar kullanılabilme özelliğine sahiptir.

Bunlara karşın, yöntemin en önemli dezavantajı elde edilen görüntülerin yorumlanmasının diğer sistemlere göre daha zor olmasıdır. MRG cihazı kullanılırken işlem süresinin uzun olması, cihazın kapalı ve dar yapısının hastalar üzerindeki psikolojik etkisi ve fiziki kısıtlamaları düşünüldüğünde, yöntemin dezavantajı olarak değerlendirilebilir. Yöntem, görüntüleme için kontrast ajanları kullanıldığında insan sağlığına zararlı olabilmekte, manyetik etkilerden dolayı kalp pili ya da metal implant kullanan hastalara uygulanamamaktadır. Son olarak, cihazın maliyetinin yüksek olması da yöntemin dezavantajları arasında sayılabilir.


### **2.2.3 Manyetik rezonans görüntüleme tekniğinin çalışma prensibi**

Doğadaki atomların birçoğunun manyetik özelliği vardır. Atomların manyetik alanla etkileşimleri ve gösterdikleri davranış atom türüne göre, atom yapısındaki parçacıklara göre farklılıklar gösterir. Manyetik rezonans görüntüleme tekniğinde, vücuttaki hidrojen atomlarının manyetik alanla ve uygulanan radyo frekans darbeleriyle etkileşimi sonucu elde edilen manyetik rezonans sinyalinden faydalanılarak görüntü elde edilir. Yöntemin uygulamasında hidrojen atomunun tercih edilmesinin sebepleri, hidrojen atomunun su ve yağın yapısında bulunmasından dolayı vücuttaki en yaygın element olması ve sahip olduğu manyetik özelliklerdir [50].

### 2.2.3.1 Atomların manyetik alandaki davranışı

Doğada bulunan atomlardan tek sayıda protona ya da kütle numarasına sahip olanlar dönü denilen bir özelliğe sahiptir. Dönü özelliğini tam olarak açıklamak için kuantum mekaniğine gerek duyulsa da, basitçe atom çekirdeğinin manyetik alan doğrultusunda düşey eksenden biraz saparak kendi eksenini etrafında yaptığı dönme hareketi olarak tanımlanabilir. Dönü,  $\frac{1}{2}$ 'nin katları ile ifade edilir ve pozitif ya da negatif işaretli olabilir. Hidrojen atomunun çekirdeği sadece tek bir protondan oluşur ve  $\frac{1}{2}$  dönüye sahiptir [59].

Proton, yüklü bir parçacık olduğundan, kendi eksenini etrafında dönme hareketi hidrojen atomuna manyetik moment kazandırır. Bu manyetik moment küçük bir mıknatıs gibi düşünülebilir ve bir manyetik alan oluşturur. Harici bir manyetik alanın yokluğunda üretilen manyetik alanın yönü rastgeledir ve insan vücudundaki çok sayıda protonun oluşturduğu etkiler birbirini yok edeceğinden tek bir doğrultuda net bir manyetik etki meydana getirmez. Bu durum Şekil 2.7'de görülmektedir.



**Şekil 2.7 :** Manyetik moment ve atomların manyetik alan yok iken davranışı [53].

Harici bir manyetik alan uygulandığında, artık atomların manyetik momentleri rastgele yönlerde değildir. Manyetik alanın uygulama doğrultusunda, manyetik alanla aynı yönde (paralel) veya manyetik alana zıt yönde (anti-paralel) olacak şekilde hizalanırlar. MR sistemlerinde, çoğunlukla hasta sırtüstü uzanır pozisyondayken, baş- ayak doğrultusu z-ekseni olarak kabul edilir ve harici manyetik alan +z yönünde uygulanır.

Harici manyetik alanın varlığında, dönü vektörleri manyetik alan eksenini etrafında alan şiddeti ile orantılı bir frekansta dönerler. Bu frekansa Larmor frekansı denir. Larmor frekansı (2.1) ve (2.2) eşitlikleri kullanılarak hesaplanabilir.

$$\omega = \gamma \cdot B_0 \quad (2.1)$$

$$f = \frac{\gamma}{2\pi} \cdot B_0 \quad (2.2)$$

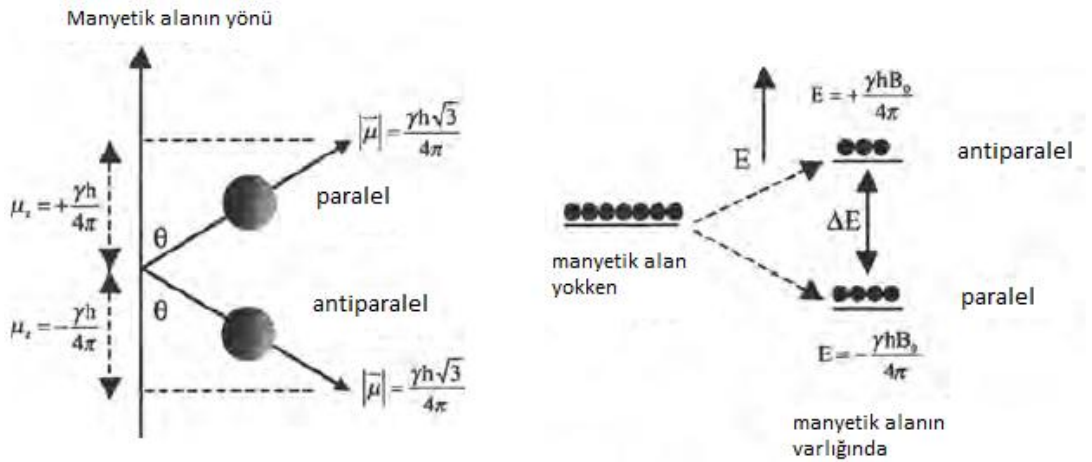
Burada  $\gamma$  cayromanyetik sabit olarak adlandırılır ve farklı atom çekirdekleri için karakteristik değere sahiptir. Çizelde 2.2’de bazı atomların manyetik özellikleri verilmiştir.

Hidrojen atomu için:  $\gamma = 2,67522 \cdot 10^8 \frac{1}{sT}$   $f = 42,577 \frac{MHz}{T} B_0$

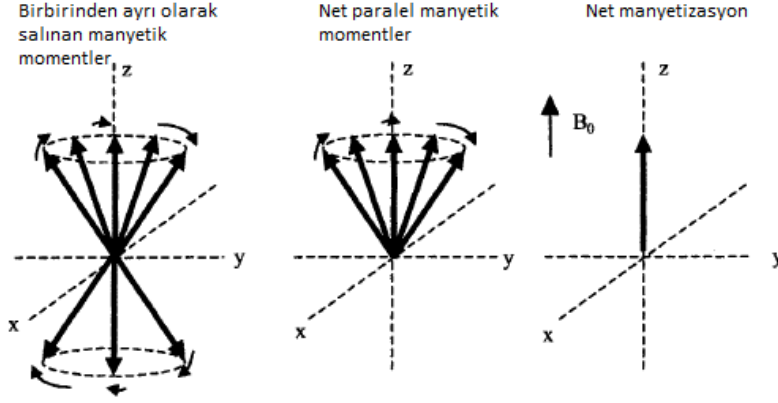
**Çizelge 2.2 :** Bazı atomların manyetik özellikleri [59].

Atom	Eşleşmemiş proton sayısı	Eşleşmemiş nötron sayısı	Net dönü	$\Upsilon$ (MHz/T)
$^1\text{H}$	1	0	1/2	42.58
$^2\text{H}$	1	1	1	6.54
$^{31}\text{P}$	1	0	1/2	17.25
$^{23}\text{Na}$	1	2	3/2	11.27
$^{14}\text{N}$	1	1	1	3.08
$^{13}\text{C}$	0	1	1/2	10.71
$^{19}\text{F}$	1	0	1/2	40.08

Manyetik alana maruz kalan atomlar iki farklı enerji seviyesine sahip olurlar. Bu durum Şekil 2.8’de görülmektedir. Paralel hizalanmış atomlar düşük enerji seviyesindeyken, antiparalel hizalanmış olanlar daha yüksek enerjiye sahiptir. Manyetik alana paralel olarak uzanan proton sayısının daha fazla olduğu durumlarda Şekil 2.9’da görüldüğü gibi net manyetizmanın yönü manyetik alan yönü ile aynı olacaktır.



**Şekil 2.8 :** Harici manyetik alanın varlığında atomların davranışı [53].



Şekil 2.9 : Atomların manyetik momentleri ve net manyetizasyon [53].

İki enerji seviyesi arasındaki fark  $\Delta E$  olarak adlandırılırsa, paralel konumdaki atomların antiparalel konuma geçirilmesi için sisteme  $\Delta E$  ile orantılı enerji uygulanması gerektiği sonucuna ulaşılır.

$$\Delta E = E_{antiparalel} - E_{paralel} \quad (2.3)$$

$E = h \cdot f$  eşitliğinden yola çıkarsak,

$$f = \frac{\gamma}{2\pi} \cdot B_0 \text{ olduğundan,}$$

$$E = h \frac{\gamma \cdot B_0}{2\pi} \quad (2.4)$$

olarak yazılabilir. Eşitlik (2.4)'ten görüldüğü gibi, iki seviye arasındaki enerji farkı  $B_0$  ile doğru orantılı olarak artar.

Burada,

$h$ : planck sabiti ( $6,626 \times 10^{-34}$  J.s)

$\gamma$  : cayromanyetik sabit

$\omega, f$  :rezonans frekansı (Larmor frekansı)

Boltzmann istatistiklerine göre, düşük enerjili dönü vektörlerinin sayısı ile yüksek enerjili dönü vektörlerinin sayısı arasındaki oran, (2.5) eşitliği ile hesaplanır.

$$\frac{N^-}{N^+} = e^{-E/kT} \quad (2.5)$$

Burada,

$k$ : Boltzmann sabiti( $1,3805 \times 10^{-23}$  J/K)

$T$ : sıcaklık(K)




MR çalışmalarında hastanın vücut sıcaklığı  $37\text{ }^{\circ}\text{C}=310\text{ K}$  olarak sabitlenmiştir. Oda sıcaklığında, düşük enerjili dönü vektörlerinin sayısı yüksek enerjili dönü vektörlerinin sayısından fazladır. Sıcaklık azaldıkça,  $\frac{N^-}{N^+}$  oranı da azalır. Sıcaklık arttıkça bu oran 1'e yaklaşır [50].

Dönü vektörleri için manyetik alana paralel ya da anti-paralel ifadesi kullanılsa da, gerçekte bu vektörler manyetik alan eksenini ile belli bir açı yaparlar. Bu yüzden, dönü vektörlerinin iki bileşeni vardır. Manyetik alan doğrultusundaki bileşen boyuna (longitudinal) bileşen olarak adlandırılırken, manyetik alana dik olan bileşene enine (transversal) bileşen denir. Sadece  $B_0$  manyetik alanının varlığında, dönü vektörlerinin enine bileşenlerinin toplam etkisi ihmal edilebilir seviyededir.

### 2.2.3.2 Radyo frekans darbesinin uygulanması

Manyetik rezonans görüntüleme sisteminde, görüntü oluşturmada kullanılan manyetik rezonans sinyali protonların paralel ve anti-paralel konumları arasında geçişler sırasında oluşur. Geçişler için ihtiyaç duyulan enerji farkı, RF bobinleri ile üretilen manyetik alandan sağlanır. Verici RF bobini ile darbe şeklinde manyetik alan üretilir ( $B_1$ ) ve sisteme uygulanır. Manyetik alan kesildiğinde enerji değişimleri alıcı RF bobini ile algılanarak MR sinyali üretilir. Şekil 2.10'da manyetik rezonans görüntüleme sisteminin temel bileşenleri gösterilmiştir.



Şekil 2.10 : Manyetik rezonans görüntüleme sisteminin basit temsili [53].

Seviyeler arasındaki enerji farkını karşılayabilmek için, uygulanan RF alanın frekansı dönü vektörlerinin salınım yaptığı Larmor frekansına eşit olmalıdır. RF darbeye üretilen  $B_1$  manyetik alanının etkisi altında manyetik moment iki farklı hareket yapar. Aynı anda hem  $B_0$  manyetik alanının hem de  $B_1$  manyetik alanının

etrafında döner.  $B_1$  manyetik alanı yönündeki hareketin hızı ( $\varphi$ ),  $B_1$  alanının şiddetine ve uygulama süresine ( $\Delta t$ ) bağlıdır ve (2.6) eşitliği ile hesaplanabilir.


$$\varphi = \gamma \cdot B_1 \cdot \Delta t \quad (2.6)$$

Sadece  $B_1$  manyetik alanın varlığında net manyetizasyon vektörünün tek bir bileşenden oluştuğu daha önce belirtilmişti ( $M_x = 0, M_y = 0, M_z = 0$ ). Ölçülebilir MR işareti, net manyetizasyonun x ve y bileşenleri tarafından üretilir. Sadece  $B_0$  alanının varlığında olmayan bu bileşenleri üretmek için, net manyetizasyon vektörünün yönünü değiştirecek şekilde ikinci bir alan uygulanır. Uygulanan darbenin genliğine ve süresine göre, net manyetizasyon vektörünün yönü değişir.

Uygulanan RF darbe manyetizma vektörünü z ekseninden x-y düzlemine saptırırsa, bu darbe  $90^\circ$ 'lik darbe olarak tanımlanır. Manyetizma vektörünü tamamen ters yöne yani  $-z$  yönüne çeviren darbe ise  $180^\circ$ 'lik darbedir.

### 2.2.3.3 T1 ve T2 gevşeme zamanları


$90^\circ$ 'lik RF darbenin uygulanmasıyla, net manyetizasyon vektörü x-y düzlemine taşınır ve tüm manyetik momentler eş fazlı olur. Bu durum Şekil 2.11'de görülmektedir. Uygulanan RF darbenin kesilmesinden belli bir süre sonra, manyetizma vektörü dengedeki durumuna döner. Bu geçiş sırasında manyetik rezonans görüntülemenin temelini oluşturan iki durum oluşur.



Şekil 2.11 :  $90^\circ$ 'lik darbenin etkisi altında manyetik momentlerin değişimi [53].

- 1) Dönü vektörlerinin enerjilerini çevrelerindeki alana vermesinden dolayı, protonlar kademeli olarak enerji kaybeder ve yeniden manyetik alana göre

hizalanırlar. Bu durum dönü-kafes etkileşimi olarak adlandırılır. 90 derecelik darbenin uygulanmasıyla sıfırlanan manyetizasyonun boyuna bileşeni, tekrardan oluşmaya başlar [50]. Dönü-kafes etkileşimi Şekil 2.12’de görülmektedir.



**Şekil 2.12 : Dönü-kafes etkileşimi [60].**

Bu değişim (2.7) eşitliği ile ifade edilir.

$$M_z = M_{z0} ( 1 - e^{-t/T1} ) \quad (2.7)$$

Burada,

$M_z$ : Net manyetizasyon vektörünün z-doğrultusundaki bileşeni

$M_{z0}$ : Net manyetizasyon vektörünün RF darbe uygulanmadan önceki değeri


Boyuna manyetizasyon bileşeninin 63%’ünün geri kazanıldığı üstel zaman sabiti T1 zamanı olarak adlandırılır.

Eğer uygulanan darbe 180 derecelik ise net manyetizasyon +z yönünden -z yönüne döndürülür. Darbe kesildikten sonra, manyetizasyon vektörü T1 ile kontrol edilen bir oranda kademeli olarak +z yönündeki denge durumuna dönecektir. Bu davranışa ait değişim, eşitlik (2.8) kullanılarak hesaplanabilir.

$$M_z = M_{z0} ( 1 - 2e^{-t/T1} ) \quad (2.8)$$


olarak yazılabilir. (2.7) ve (2.8) eşitliklerine ait göre çizilen eğriler Şekil 2.13’te görülmektedir.

T1 süresi, ortam sıcaklığına ve doku viskozitesine bağlıdır. Manyetik rezonans görüntüleme uygulamasında hastanın vücut ısısı değişmediğinden, T1 süresi sadece doku tipine bağlı olarak değişir. Bu özellik, T1 zamanındaki farklılıklardan yola çıkarak farklı doku tiplerinin tespit edilmesine olanak verir.



Şekil 2.13 : z-yönündeki net manyetizasyonun değişimi [53].

- 2) Her protonun komşusundaki çekirdeklerle enerji alışverişi yapması sonucunda, protonların manyetik momentleri faz dışı olmaya başlar. Faz bozulması enine manyetizasyon bileşeninin toplam etkisinin azalmasına, dolayısıyla da alıcı bobindeki sinyal seviyesinde azalmaya sebep olur. Bu olay dönü-dönü etkileşimi olarak adlandırılır [50]. Şekil 2.14'te dönü-dönü etkileşimi gösterilmiştir.



Şekil 2.14 : Dönü-dönü etkileşimi [60].

Bu etkileşime ait eşitlik (2.9)'da verilmiştir.

$$M_{XY} = M_{XY0} e^{-t/T2} \quad (2.9)$$

Burada,


$M_{XY}$ : Net manyetizasyon vektörünün xy-düzlemindeki bileşeni

$M_{XY0}$ : Net manyetizasyon vektörünün xy-düzlemindeki bileşeninin başlangıçtaki değeri

Net manyetizasyon vektörünün 63%'ünün faz dışı olması için geçen süreyi temsil eden zaman sabiti T2 olarak adlandırılır. Manyetizasyon vektörünün y-yönündeki bileşeninin zamanla değişimi Şekil 2.15'te gösterilmiştir.

T2\* etkileri: Manyetizasyon vektörünün faz dışı kalmasında sadece uygulanan darbenin kesilmesi değil, uygulanan  $B_0$  alanındaki homojensizlikler de etkilidir.

Manyetik alan her noktada homojen olmadığından, protonların salınım frekanslarında küçük de olsa farklılıklar vardır ve bu farklılıklar protonlar arasında faz farkına sebep olur. Bu iki etkinin de dikkate alınmasıyla  $T_2^*$  zaman sabiti tanımlanmıştır ve eşitlik (2.10) ile hesaplanır.



**Şekil 2.15 :** y yönündeki manyetizasyon bileşeninin değişimi [53].

$$1/T_2^* = 1/T_2 + 1/T_{2inhomo}. \quad (2.10)$$

Bu iki etki aynı anda oluşsa da,  $T_2$  zamanı her zaman  $T_1$  zamanından daha küçük ya da eşittir. Sebebi, XY düzlemindeki net manyetizasyon sıfıra gittikten sonra boyuna manyetizasyonun z eksenine boyunca  $M_0$  değerine ulaşana kadar artmasıdır.

#### 2.2.3.4 MR sinyalinin algılanması


90 derecelik darbenin ( $B_1$ ) uygulanıp kesilmesinden sonra alıcı bobinler tarafından algılanan sinyal FID sinyali (free induction decay) olarak adlandırılır. Bu işaret manyetizma vektörünün faz dışı olmasından dolayı, zamanla yoğunluğu azalan bir işarettir.

FID sinyali faz dışı olmaya başladıktan sonra, ikinci bir darbe uygulanarak kısmen de olsa faz birlikteliği yeniden sağlanabilir. İkinci darbenin uygulanmasından sonra ölçülen sinyal eko sinyali olarak adlandırılır.

**Kesit seçme:** Manyetik rezonans görüntüleme sisteminde, dokular tarafından üretilen manyetik rezonans sinyali, tek bir alıcı bobin ile algılanır. Dolayısıyla, algılanan toplam sinyalden dokuları ayırarak görüntü elde etmek mümkün olmamaktadır. Dokulara ait konum bilgisini de içeren MR sinyali elde edebilmek için, uygulanan  $B_0$


ve  $B_1$  alanlarına ek olarak, gradyan bobinler yardımıyla ilave alanlar uygulanmaktadır.

İlk olarak, görüntülenmek istenen kesitin seçilmesi için, RF vurumu uygulanmadan önce ana manyetik alan üzerine gradyan bobinler yardımıyla konuma bağlı ilave bir manyetik alan uygulanır. Uygulanan alanın yönüne bağlı olarak hangi düzlemde kesit seçileceği Şekil 2.16'da görülmektedir. Uygulamada genellikle kesit seçme gradyanı z-doğrultusundadır. Gradyan bobinler Şekil 2.17'de görüldüğü gibi pozitif z yönünde lineer olarak artan negatif z yönünde ise lineer olarak azalan bir manyetik alan üretirler. Uygulanan bu ilave alan ile protonların salınım frekansı değişecek, sadece manyetik alanın merkezinde gradyanın etkileri birbirini yok ettiği protonların Larmor frekansında salınmaya devam edecektir. Uygulanan alanın uzaklığa göre değişimi ( $G_z$ ) ve alandan etkilenen bölgenin uzunluğu ( $\Delta z$ ) kullanılarak kesit içerisinde Larmor frekanslarının band genişliği belirlenebilir. Aynı RF band genişliğinde daha ince kesitler daha yüksek gradyan alanlar gerektirir.



Şekil 2.16 : Kesit seçme işlemi [53].

Bir kesit seçildikten sonra, iki boyutlu görüntü oluşturabilmek için diğer iki boyuta ait bilgi de kodlanmalıdır. Bunlardan biri uzaysal konuma bağlı faz bilgisi kullanılarak, diğeri ise uzaysal konuma bağlı frekans bilgisi kullanılarak kodlanır.



**Şekil 2.17 :** Kesit seçme gradyanının şiddetinin konuma bağlı değişimi [53].

**Faz kodlama:** Kesit seçim darbesinden sonra, belirli bir  $\tau_{pe}$  süresi için faz gradyanı uygulanır ve veri alma işlemi başlamadan önce kesilir.

Faz gradyanının yönü  $y$  ile gösterilirse,  $\tau_{pe}$  süresi boyunca protonlar  $\omega_y$  frekansında salınım yaparlar. Salınım frekansı, (2.11) eşitliği ile hesaplanabilir.

$$\omega_y = \gamma \cdot G_y \cdot y \quad (2.11)$$

Faz gradyan alanı aktive edilmeden önce tüm manyetizma vektörleri aynı frekans ve aynı fazdadırlar. Bu nedenle tüm manyetizma vektörleri aynı yönü gösterirler. Faz gradyan alanının aktive edildiği süre içerisinde manyetizma vektörleri  $y$  eksenini boyunca farklı frekanslarda dönerler. Alan devreden çıkarıldığında tüm elemanlar tekrar aynı frekansa sahip olurlar fakat manyetizma vektörleri faz birlikteliklerini kaybederler.


**Frekans kodlama:** Kesit seçimine ek olarak, diğer bir boyuta ait konum bilgisi, gradyan bobini kullanılarak üretilen frekans gradyanı uygulanarak, farklı frekanslarda salınım olarak kodlanır [53].

Kesit seçme, frekans ve faz gradyanlarının uygulanış zamanları ve süreleri Şekil 2.18'de görülmektedir.

#### 2.2.3.4 Görüntü oluşturma teknikleri

Manyetik rezonans görüntüleme sistemlerinde, görüntü oluşturmak için farklı tiplerde darbe dizileri kullanılabilir. Kullanılan darbe dizisine göre, T1 ağırlıklı, T2 ağırlıklı ya da PD ağırlıklı görüntüler elde edilebilir.

Gradyan-eko darbe dizileri en basit MR dizisidir. Birbirinden TR zamanı ile ayrılmış darbelerden oluşur. Darbe uygulandıktan belli bir süre sonra işaret alınır ve bu süre TE zamanı olarak adlandırılır [61].



**Şekil 2.18 :** Uygulanan gradyanlar ve uygulama zamanları [53].

Spin-eko darbe dizileri en yaygın kullanıma sahip olan darbe dizisidir. Gradyan-eko dizilerine benzerdir, tek fark ek olarak  $180^\circ$ 'lik darbe içermesidir. Tüm dönü-eko dizileri  $90^\circ$ 'lik darbeyi takip eden bir ya da daha fazla  $180^\circ$ 'lik darbeden oluşur. Sonuçta elde edilen sinyal eko sinyali olarak adlandırılır.

İki darbe dizisi arasındaki zaman (TR) ve RF darbe ile eko arasındaki zaman (TE), elde edilecek görüntünün nasıl ağırlıklandırılacağını belirleyen faktörlerdir. Çizelge 2.3'te görüntünün ağırlıklandırılma tipine göre seçilmesi gereken TR ve TE süreleri verilmiştir.

**Çizelge 2.3 :** Görüntü ağırlıklandırma için TR ve TE değerleri [61].

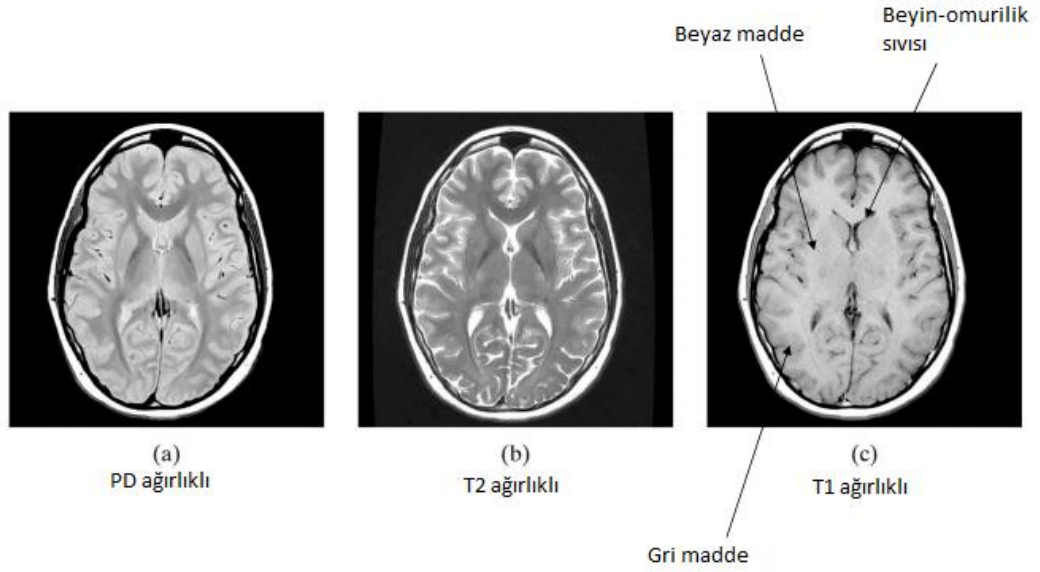
Görüntü tipi	TR	TE
T1 ağırlıklı	Kısa	Kısa
T2 ağırlıklı	Uzun	Uzun
PD ağırlıklı	Uzun	Kısa

TR, her vektörün bir sonraki RF darbesi ile uyarılmadan önce ne kadar hızlı geri kazanılacağını kontrol ettiğinden, T1 ağırlıklı görüntü elde etmek için TR yeterince kısa olmalıdır. TR çok uzun olursa, hem yağ hem su tamamen geri kazanılır. Bu durum gerçekleştiğinde, doku farkları görüntüde ayırt edilemez.

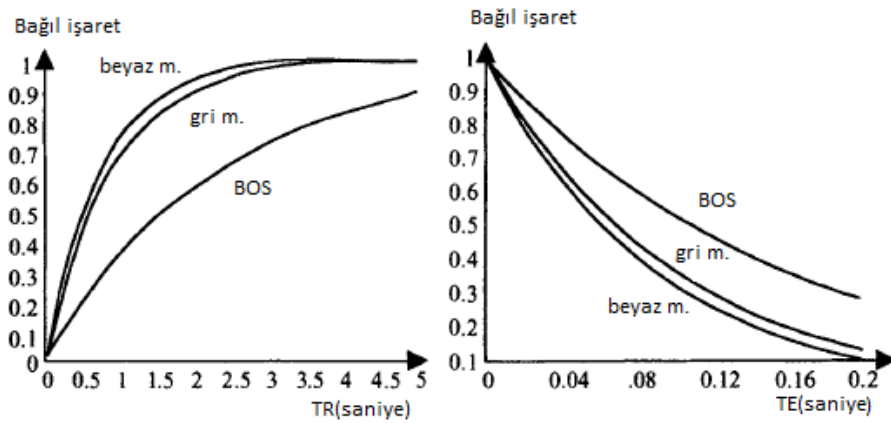


TE, sinyal alınmadan önce T2 bozunmasının miktarını kontrol eder. T2 ağırlıklı görüntü elde etmek için, TE yeterince uzun olmalıdır. Eğer TE kısa olursa, ne su ne yağ bozunamaz ve T2 farklılıkları görüntüde gösterilemez.

Proton yoğunluk görüntü elde etmek için T1 ve T2'nin kontrast etkileri azaltılmalıdır ki proton yoğunluğu baskın olabilsin. Uzun TR süresi T1 etkisini bastırmaya, kısa TE süresi ise T2 etkisini bastırmaya yarar [61]. Farklı ağırlıklarda elde edilmiş beyin görüntüleri Şekil 2.19'da görülmektedir. Şekil 2.20'de ise, farklı beyin dokularından alınan sinyalin TR ve TE ile değişimi gösterilmiştir.



Şekil 2.19 : PD,T2 ve T1 ağırlıklı beyin MR görüntüleri [62].



Şekil 2.20: Farklı beyin dokularından alınan sinyalin TR ve TE ile değişimi [53].

### 2.3 Multiple Skleroz

Multipl skleroz, merkezi sinir sisteminde görülen yaygın bir hastalıktır. Skleroz Yunanca'da sertleşme demektir ve multipl skleroz çoklu sertleşme anlamına gelmektedir. MS ilk defa 1849 yılında teşhis edilmiştir. Hastalık, merkezi sinir sisteminin herhangi bir bölgesinde oluşan ve tekrarlayan iltihaplanmalar şeklinde kendini gösterir. İltihaplanma sonucu sinir hücrelerinin miyelin kılıfında tahribat ve yara (skleroz) oluşur.


Araştırmalar sonucunda hastalığın nedeni tam olarak tespit edilemese de, araştırmacılar birkaç muhtemel sebep öne sürmüşlerdir ve sebeplerin tam olarak tespit edilmesi için çalışmalar sürmektedir. Yapılan araştırmalar sonucunda, hastalığın ilk akla gelen sebebi genetik faktörlerdir. Çalışmalar, yüksek oranda MS hastası içeren popülasyonlarda bazı genlerin yaygın olarak bulunduğunu göstermiştir [63]. Ancak yine yapılan çalışmalar sonucunda, tek yumurta ikizlerinden biri MS hastası iken diğeri de hasta olma olasılığı  $\frac{1}{4}$  olarak bulunmuştur. Buradan yola çıkarak, hastalığın tek sebebinin genetik faktörler olmadığı anlaşılabılır.

MS hastalığının nedenleri ile ilgili bir diğer teori, vücudun bağışıklık sistemi ile ilişkilidir. Bu teoriye göre, insan bağışıklık sisteminin antikorları sebebi bilinmeyen bir şekilde sinir hücrelerinin miyelin kılıfına saldırmakta ve tahribata yol açmaktadır. Bu saldırının sebebinin, miyelin kılıfın yapısındaki daha önce tespit edilmemiş bir virüs ya da virüs benzeri hücre olabileceği düşünülmektedir. Ayrıca bu zamana kadar tespit edilmemiş olsa da, direkt olarak MS hastalığını tetikleyen bir virüs ya da enfeksiyon olması mümkündür.

Yapılan araştırmalar, MS hastalığının ekvatorдан uzak bölgelerde daha yaygın olduğunu göstermiştir. Bu bilgi, hastalığın çevresel faktörler sebebiyle de tetiklenebileceğini göstermektedir. Bu bölgelere yapılan göçler ve belirli bölgelerde daha yoğun olarak bulunan toksinler bu faktörler arasına alınmaktadır. Ayrıca, ekvatorдан uzak bölgelerin güneş ışınına daha az maruz kalması sebebiyle, güneş ışını ile vücuttaki üretiminin arttığını bildiğimiz D-vitamininin vücuttaki miktarının hastalık üzerinde etkisi olduğu düşünülebilir. Şekil 2.21'de dünya genelinde MS hastalığının dağılımı gösterilmiştir.

Araştırmalar sonucunda hastalığın dağılımı ile ilgili bazı istatistikî veriler elde edilmiştir. Buna göre;

1. Hastalık kadınlarda 2-3 kat daha yaygındır ve bunun hormonal sebeplerden kaynaklandığı düşünülmektedir.
2. Genel popülasyonda hastalığın görülme olasılığı 1/750 iken hasta bireylerin yakın akrabalarında bu olasılık 1/40 olmaktadır. Yakınlık arttıkça hastalığın görülme olasılığı artar ve tek yumurta ikizlerinde çift yumurta ikizlerine göre daha yüksektir [64].
3. Tek yumurta ikizleri aynı genleri taşımasına rağmen, biri hasta olduğunda diğerinin de olma olasılığı  $\frac{1}{4}$ 'tür.
4. Hastalık tüm yaş gruplarında görülebilmekle beraber 20-50 yaş arasında daha yaygındır.
5. Ekvatordan uzak bölgelerde hastalık diğer bölgelere göre daha sık görülmektedir.
6. Bazı ırklarda hastalık daha yaygındır [63].



**Şekil 2.21:** Dünya genelinde MS hastalığının dağılımı [63].

Hastalığın bulguları, tahribatın sinir sisteminin hangi bölgesinde gerçekleştiğine göre değişir. Sık rastlanan bulgular aşağıda sıralanmıştır [63, 65].

- Yorgunluk, bitkinlik
- Uyuşukluk, hissizlik
- Yürüme, denge ve koordinasyon problemleri, kas zayıflığı
- Mesanede fonksiyon bozukluğu
- Bağırsaklarda fonksiyon bozukluğu

- Görme bozuklukları(bulanık görme, çift görme, tek gözde körlük)
- Sersemlik hissi ve baş dönmesi
- Cinsel fonksiyon bozukluğu
- Kavrama problemleri(dikkat ve konsantrasyon zorluğu, hafızanın zayıflaması)
- Duygusal dengesizlikler
- Depresyon
- Kasılma eğilimi

Hastalığın daha az rastlanan bulguları [63, 65] ise şunlardır:

- Konuşma problemleri( konuşmada yavaşlama, kelimelerin yanlış telaffuzu, konuşma ritminde değişim)
- Yutma problemleri
- Baş ağrısı
- Duyma kaybı
- Felç, inme
- Çarpıntı, solunum problemleri
- Kaşıntı

Benzer bulgular sinir sistemindeki başka bir problemten de kaynaklanıyor olabileceğinden, her bulguyu MS olarak değerlendirmek yanlıştır. Hastalığın kesin tanısı ancak beyin görüntüsünün uzmanlar tarafından incelenmesiyle konulabilir.

## **2.4 Görüntü Bölütleme Yöntemleri**

Bölütleme, bir görüntüyü benzer özellik ya da özellikler taşıyan alanlara ayırmak olarak tanımlanabilir. Bunu yaparken ya piksellerin birbirlerine olan benzerlikleri ya da farklılıkları esas alınır. Benzerlik ölçütü olarak Euclidean, City-Block, Chessboard, Mahalanobis gibi uzaklık hesapları kullanılabilir.

Bölütleme amaçlı kullanılan birçok yöntem vardır. Bu yöntemler farklı özelliklerine göre çeşitli başlıklar altında toplanabilir [66].

- Manuel, yarı-otomatik ve otomatik yöntemler
- Eğitilmiş ve eğitimsiz yöntemler
- Piksel tabanlı ve bölge tabanlı yöntemler

-Klasik, bulanık, istatistiki yöntemler

Bu bölümde, bu yöntemlerden yaygın olanlarına değinilecektir.

#### 2.4.1 Eşiklendirmeye dayalı yöntemler

Eşiklendirme, görüntüyü belirlenen bir kritere göre karşılaştırma yoluyla gruplara ayırmak olarak tanımlanır. Tek bir eşikleme değeri kullanılabileceği gibi, birden fazla eşikleme değeri kullanılarak (çoklu eşikleme) görüntü belirli değer aralıklarında gruplara ayrılabilir. Eşiklemeye dayalı yöntemler, piksel tabanlı, bölge tabanlı ve hibrid olarak gruplanabilirler [67].

**Piksel tabanlı yöntemler:** Bu yöntemler basitçe görüntüdeki her pikselin belli bir eşik değeri ile karşılaştırılması ve eşik değerden büyük ya da küçük oluşuna göre gruplandırılmasına dayanır. Eşik değeri, çeşitli algoritmalar ile hesaplanabilirken, direkt olarak görüntü hakkında sahip olunan önbilgiye göre de kestirilebilir.

**Bölge tabanlı yöntemler:** Bu yöntemlerde birbirlerine komşu olan piksellerin benzer özellikleri taşıdığı yaklaşımından yola çıkılarak, önceden belirlenen bir şarta göre görüntü gruplara ayrılır. Bu yöntemlere örnek olarak bölge büyütme algoritması verilebilir. Bölge büyütme algoritmasında, kullanıcı tarafından seçilen ya da bir algoritma ile hesaplanan tohum (seed) noktasından başlanarak, komşu pikseller belirli bir şarta uyup uymamasına göre bölgeye dahil edilir. İşlem hiçbir piksel istenilen şartı sağlamayana kadar devam eder.

Bölge tabanlı yöntemlere örnek olarak, kenar bulma algoritması da gösterilebilir (canny, laplacian). Kenar bulma algoritmalarında pikselin yoğunluk bilgisi değil, komşu pikseller arasındaki farklılıklar esas alınır. Büyük değişimlerin olduğu noktalar (büyük gradyan değerine sahip) , kenar pikseli olarak kabul edilir. Kenar bulma algoritmaları tarafından tespit edilen kenarlar, ayrık piksel değerlerinden elde edileceğinden, eksik ya da kopuk olabilir. Bu yüzden, ileri işleme yapılması gerekebilir.

Ayır ve birleştir yöntemi (split and merge), bölge büyütme benzer bir prensiple çalışan bölge tabanlı bir yöntemdir. Bölge büyütmeden farkı, tohum nokta gerektirmemesidir. Bu yöntemde, görüntü önce rastgele küçük parçalara ayrılır, daha sonra her bir parçanın komşusundaki parçalarla belirli bir şarta göre benzerliği karşılaştırılıp, şart sağlanırsa iki parça birleştirilir.

**Hibrid yöntemler:** Eşiklendirmeye dayalı hibrid yöntemler arasında alınabilecek yöntemlerden biri Watershed algoritmasıdır. Bu yöntem, görüntünün yoğunluk bilgisi ile gradyan bilgisini bir arada kullanır. Bu yöntemde basitçe, görüntü dağlardan ve vadilerden oluşan 3 boyutlu kabartma bir görüntü gibi düşünülür ve kabartmalara ait yükselti gradyan genliklerine göre belirlenir. Gradyan genliklerinin yerel minimum olduğu noktalardan hareketle, watershed eğrileri elde edilir ve bu eğrilere göre görüntü bölütlenir [66].

## 2.4.2 Örüntü tanımaya dayalı yöntemler

Görüntüyü oluşturan her piksel ve dolayısıyla her öznitelik vektörü birer örüntü olduğundan, örüntü tanıma yöntemleri görüntü bölütlemek için kullanılabilir. Örüntü tanıma tekniklerine dayalı yöntemlere örnek olarak kümeleme algoritmaları, destek vektör makinaları, yapay sinir ağları verilebilir.

### 2.4.2.1 Kümeleme algoritmaları

Kümeleme algoritmaları, bir veri seti içerisinde birbirine benzer özellik taşıyan verileri gruplamak için kullanılır. Herhangi bir eğitim verisine ihtiyaç duyulmadan, sadece küme elemanlarının benzerliklerine göre birbirine en yakın olan noktaları aynı kümeye dahil eder.

Kümeleme algoritmaları katı kümeleme algoritmaları ve bulanık kümeleme algoritmaları olarak gruplanabilir. Bu tez çalışmasında, bölütleme yöntemi olarak kümeleme algoritmaları kullanıldığından, bu konuda detaylı bilgi diğer bölümde verilecektir.

Kümeleme prensiplerini uygulayan bir diğer yöntem olasılık-maksimizasyon algoritmasıdır. Algoritma, verinin gaussian dağılımında olduğunu kabul ederek iteratif olarak maksimum olasılık kestirimini uygular. Her iterasyon E ve M olmak üzere iki adımda gerçekleşir. E-adımında bilinmeyen veri verilen model parametreleri kullanılarak kestirilir. M-adımında ise, eksik verinin bilindiği kabul edilerek olasılık fonksiyonu maksimize edilir. Olasılık fonksiyonunun değeri arttığı sürece devam edilir. EM algoritması başlangıç değerlerine k-ortalamlar ve bulanık c-ortalamlar yöntemlerinden daha duyarlıdır. Ayrıca gürültü ve yoğunluk düzensizliklerine de duyarlıdır [55].

### 2.4.2.2 Sınıflayıcılar

Sınıflayıcı, bir verinin önceden belirlenen sınıflardan hangisine ait olduğunu tespit etmeye yarayan yöntemlerdir. Eğitimli ve eğitimsiz sınıflayıcılar olmak üzere gruplanabilirler.

Eğitimli sınıflayıcılar, elemanlarının hangi sınıflara ait olduğu bilinen bir eğitim kümesinden yola çıkarak, bilinmeyen verilerin sınıfını tespit etmeye çalışır. Eğitimsiz sınıflayıcılar ise, sınıflama işlemi yaparken eğitim kümesine ihtiyaç duymazlar. Elemanlar arasındaki benzerliklerden yola çıkarak sınıflama işlemini gerçekleştirirler.

En basit eğitimli sınıflama yöntemi k-en yakın komşu sınıflayıcısıdır. Bu yöntemde, hangi sınıfa ait olduğu bilinmeyen bir verinin eğitim kümesindeki tüm elemanlara olan uzaklığı hesaplanır. Uzaklığın en küçük olduğu k veri arasında en çok hangi sınıfa ait örüntü varsa, bilinmeyen veri o sınıfa dahil edilir.

Görüntü sınıflamada kullanılan en yaygın sınıflayıcı yapay sinir ağlarıdır. Yapay sinir ağları, insan beyninin öğrenme yeteneğini taklit edebilmek için önerilmiş bir yöntemdir. Eğitimli ve eğitimsiz yapay sinir ağları mevcuttur. Eğitimli yapay sinir ağlarında, eğitim kümesindeki veriler sistemin girişine uygulanarak, hedef çıkışa göre ağ ağırlıkları ayarlanır. Bu işlem, ne kadar çok sayıda eğitim verisi ile tekrarlanırsa, sistemin öğrenme kabiliyeti o derece artar. Daha sonra, bilinmeyen bir sınıfa ait veri sisteme uygulandığında, mevcut ağırlıklar kullanılarak olası çıkış hesaplanır.

Eğitimsiz yapay sinir ağlarında ise, minimize edilmek istenen bir zarar fonksiyonu vardır ve ağ bu fonksiyonu minimize edecek şekilde kendini ayarlar.

Bayesian sınıflayıcı, Bayes kuralını temel alan olasılıksal bir sınıflandırıcıdır. Bir verinin bir kümeye olan olasılıksal üyeliğinin kestirimini amaçlar. Kestirim yaparken (2.12) eşitliği kullanılır [55].

$$P(C_j|x) = \frac{P(x|C_j)P(C_j)}{p(x)} = \frac{p(x|C_j)P(C_j)}{\sum_k p(x|C_k)P(C_k)} \quad (2.12)$$

Burada,

$p(\mathbf{x}|C_j)$  : Sınıf j'den bir örneğin x olma olasılığı

$P(C_j)$  : Sınıf j'nin ilk olasılığı

$p(\mathbf{x})$  : Herhangi bir örneğin  $x$  olma olasılığı

$P(C_j|\mathbf{x})$  :  $x$  olan bir örneğin sınıf  $j$ 'den olma olasılığı (son olasılık)

### 2.4.3 Markov rastgele alanları

Kümeleme ve sınıflandırma algoritmaları, görüntüdeki pikselleri birbirinden bağımsız olarak değerlendirir ve işler. Bu yüzden, bir piksel ile çevresindeki pikseller arasındaki bağlamsal bilgiyi dikkate almaz. Bu eksikliğin önüne geçebilmek için Markov rastgele alanları görüntü bölütleme uygulamalarında kullanılabilir.

Markov rastgele alanları temelde bir bölütleme algoritması değildir. Bölütleme algoritmaları ile bir arada kullanılacak istatistiki bir modeldir. Görüntüde, komşu piksellerin çoğunlukla aynı gruba ait olduğu düşünülerek, markov rastgele alanları bir piksel ile çevresindeki piksellerin etkileşimini dikkate alır.

MRA ile yapılan bölütleme uygulamalarında, tek bir pikselden ya da az sayıda pikselden oluşan parçalar ayrıştırılmaz. Dolayısıyla yöntem, gürültü karşısında verimlidir. Yöntemin zorluğu, uzaysal etkileşimleri belirleyecek olan parametrelerin seçimidir. Doğru değerler seçilmezse, görüntüdeki detaylar kaybolur. MRA sadece bölütleme amaçlı değil, özellikle MR görüntülerinde ortaya çıkan yoğunluk homojensizliklerini modellemek için de kullanılır [68].

### 2.4.4 Atlas tabanlı yöntemler

Atlas tabanlı yöntemler, önceden hazırlanmış atlas adı verilen etiketli bir görüntüden orjinal görüntüye geçiş için bir geometrik dönüşüm bulmayı amaçlar. Atlas, bölütleme için gerekli bilginin derlenmesiyle üretilir ve daha sonra yeni görüntülerin bölütlenmesi için kullanılır. Sınıflayıcılar ile benzer yapıdadırlar, tek fark özellik uzayında değil direkt olarak görüntü üzerinde uygulanmasıdır. Atlastan hedef görüntüye ulaşmak için yapılacak dönüşüm bir dizi lineer ve lineer olmayan dönüşümler uygulanarak yapılır. Yöntemin en büyük avantajı, bölütleme ile birlikte etiketlerin de hedef görüntüye aktarılmasıdır.

### 2.4.5 Deforme edilebilir modeller

Deforme edilebilir model tabanlı uygulamalar, bölge sınırlarını belirlemek için kapalı parametrik eğriler ya da yüzeyler kullanır. Bu eğri ya da yüzey, iç ve dış kuvvetlerin etkisi altında deforme olur. Bir bölgenin sınırlarını tespit etmek için, başlangıçta



tahmini olarak bölgenin etrafına kapalı bir eğri yerleştirilir, daha sonra iteratif olarak eğri şekil değiştirerek istenen sınırlara yaklaşması sağlanır. Burada eğrinin şeklini belirleyen iki kuvvet vardır. İç kuvvetler eğri özelliklerine göre hesaplanıp, eğrinin şeklini sabit tutmaya çalışırken, dış kuvvetler ise görüntü özelliklerinden çıkarılan ve eğriyi şekil değiştirmeye zorlayan etkilerdir.

Bu yöntemin temel avantajı, gürültü ve yanlış kenarlar karşısında verimli oluşudur. Dezavantajı ise, başlangıçta eğrinin konumunu belirlemenin gerekliliği ve uygun parametrelerin seçilmesidir. Başlangıç değerlerine olan duyarlılığın azaltılması bile başlı başına bir araştırma konusu haline gelmiştir [68].



### 3. MATERYAL VE METOT

#### 3.1 Bulanık C-Ortalamlar Kümeleme Algoritması

Bulanık c-ortalamlar algoritması J.Bezdek ve arkadaşları tarafında 1984 yılında önerilmiştir [69]. Yöntem, Zadeh tarafından 1965 yılında [70] ortaya atılan bulanık mantığı esas alır. Katı kümelemenin aksine, bu yöntemde her veri noktası önceden belirlenen sayıda kümeye 0 ile 1 arasında bir üyelik derecesi ile üyedir.

Bulanık c-ortalamlar algoritması ile hedeflenen, eşitlik (3.1)'deki gibi bir amaç fonksiyonunun minimize edilmesidir.

$$J = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m d_{ij}^2 \quad (3.1)$$

Burada,

$C$ : küme sayısı (kullanıcı tarafından belirlenir)

$N$ : veri sayısı

$u_{ij}$ :  $i$ . verinin  $j$ . kümeye üyeliği

$m$ : bulanıklık sabiti

Veri集中的 elemanlar  $x_i$  ( $i = 1, \dots, N$ ) ile küme merkezleri ise  $v_j$  ( $j = 1, \dots, C$ ) ile temsil edilirse,  $d_{ij}$ ;  $i$ . veri noktasının  $j$ . küme merkezine olan uzaklığını gösterir. Uzaklık ölçümü farklı yaklaşımlarla yapılabilir de (Euclidean, City-Block, Chessboard, Mahalanobis), en yaygın olanı  $d_{ij} = \|x_i - v_j\|$  şeklinde hesaplanan öklid uzaklığıdır.

Üyelik derecesi  $u_{ij}$ , veri noktası ile küme merkezleri arasındaki bağıl uzaklık kullanılarak (3.2) eşitliği ile hesaplanır. Buna göre, bir veri noktası daha yakın olduğu kümeye daha yüksek üyelik derecesi ile bağlı olacaktır. Üyelik derecelerini gösteren  $u_{ij}$  parametresi aşağıdaki özellikleri sağlar:

- 1)  $\sum_{j=1}^C u_{ij} = 1 \quad i = 1, \dots, N$
- 2)  $\sum_{i=1}^N u_{ij} > 0 \quad j = 1, \dots, C$

$$3) \sum_{i=1}^N u_{ij} < N \quad j = 1, \dots, C$$

$$u_{ij} = \frac{1}{\sum_{k=1}^C \left(\frac{d_{ij}}{d_{ik}}\right)^{2/(m-1)}} \quad (3.2)$$

Bulanık c- ortalamalar algoritmasına ait sözde kod Şekil 3.1 'de verilmiştir.

```

Pseudo Code:

Initialization

WHILE comparison=0

    FOR all data points

        Calculate distance between data point and cluster centers

    END

    Calculate membership values using relative distance

    Calculate cluster centers using membership values

    IF |new center-old center| < ε

        comparison=1

    END

END

```

**Şekil 3.1 :** Bulanık c-ortalamalar algoritmasının sözde kodu

Algoritma şu şekilde işler:

1. Algoritma için başlangıç değerleri seçilir. Bu değerler ya küme merkezi ya da üyelik dereceleridir. Bu tez çalışmasında algoritma küme merkezleri ile başlatıldığından, sonraki adımlar buna göre açıklanacaktır.
2. Her elemanın küme merkezlerine olan uzaklığı (3.3) eşitliği ile hesaplanır ve uzaklık matrisi oluşturulur.

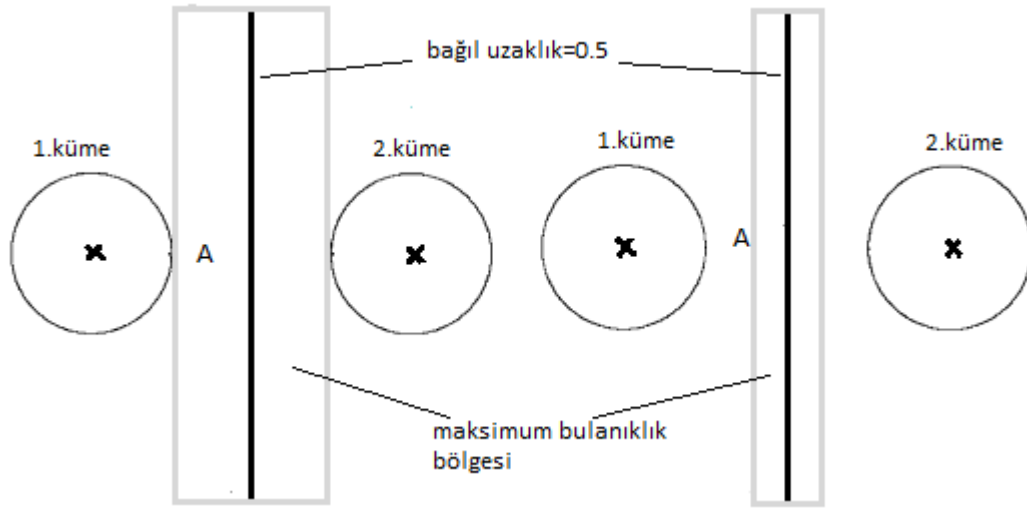
$$d_{ij} = \|x_i - v_j\| \quad (3.3)$$

3. Son durumdaki küme merkezlerine göre üyelik değerleri (3.2) eşitliği kullanılarak hesaplanır.
4. Hesaplanan üyelik derecelerine göre, kümelerin yeni merkezleri (3.4) eşitliği kullanılarak hesaplanır.

$$v_j = \frac{\sum_{i=1}^N (u_{ij})^m x_i}{\sum_{i=1}^N (u_{ij})^m} \quad (3.4)$$

5. Önceki iterasyonda hesaplanan küme merkezi ile yeni hesaplanan küme merkezi karşılaştırılır. Aradaki fark, seçilen  $\epsilon$  değerinden küçükse, işlem sonlandırılır. Şart sağlanmıyorsa, 2.adıma geri dönlür.

Küme merkezi ve üyelik hesaplarında kullanılan bulanıklık sabiti  $m$ , sonucu etkileyen önemli bir parametredir. Bu parametrenin değeri maksimum bulanıklık sınırını belirler. Bulanıklık sabitinin değeri 1'e yaklaştıkça kümeleme sonucu katı kümelemeye yaklaşır. Tersine, bulanıklık sabitinin değeri arttıkça işlemlerin bulanıklığı artar ve farklı kümelere ait küme merkezi değerleri birbirine yaklaşır. Bu parametre ayrıca algoritmanın yakınsama hızı üzerinde de etkilidir. Değeri büyüdükçe, yakınsama hızı düşer. Bulanıklık sabitinin optimum değerini belirlemek için herhangi bir yöntem ya da kural yoktur. Bu ancak, deneysel olarak belirlenebilir. Şekil 3.2'de bulanıklık sabitinin önemi sembolik olarak gösterilmiştir.



Şekil 3.2 : Bulanıklık sabitinin etkisi [39].

Burada basitçe, maksimum bulanıklık bölgesinin içinde kalan noktalar daha bulanık, dışında kalan noktalar ise daha keskin üyelik değerine sahipmiş gibi düşünülebilir. Buna göre,  $m$  parametresinin büyük değeri için çizilen ilk şekilde, A noktasındaki bir örüntünün 1.kümeyle olan üyeliği bulanık bir değer olurken, daha küçük  $m$  değeri için çizilen ikinci şekilde, aynı nokta bulanıklık bölgesinin dışında kalacağından 1.küme merkezine olan üyeliği daha keskin yani 1'e daha yakın olacaktır. Hâlbuki A noktası, 1.kümenin dışında kaldığından, üyelik değeri 1'e yakın olmamalıdır. Bu


yüzden, daha büyük bulanıklık sabitinin bu örnek için daha uygun olduğu söylenebilir [39].

Bulanık c-ortalamlar algoritması birçok probleme uygulanabilir oluşu ve elde edilen sonuçların güvenilir olması sebebiyle sık kullanılan bir yöntemdir. Yöntemin dezavantajı, k-ortalamlar algoritmasına göre daha yavaş yakınsaması ve performansının bulanıklık sabitinin değerine doğrudan bağlı olmasıdır.

### 3.3 Aralık Tip-2 Bulanık C-Ortalamlar Kümeleme Algoritması


Bulanık c-ortalamlar kümeleme algoritması, m parametresinin doğru seçimi ile birçok problem için kabul edilebilir doğrulukta sonuçlar vermektedir. Veri setindeki farklı kümeler yaklaşık olarak aynı hacimde ve yoğunlukta iken, yöntemin performansı yeterli olmaktadır. Ancak, farklı hacim ve yoğunlukta kümeleri ayırmak amaçlandığında klasik bulanık c-ortalamlar algoritması yetersiz kalabilmektedir. Çünkü seçilen m parametresi tüm kümeleri aynı şekilde etkiler. Şekil 3.3'te görüldüğü gibi, bulanıklık sabitinin değeri kümelere bir ya da birkaçı için uygunken diğerleri için uygun olmayabilir.

Şekil 3.3'te B noktası 1.kümenin sınırları içinde yer almasına rağmen, maksimum bulanıklık bölgesine dahil olmasından dolayı, 1.küme üyeliği değeri 1'den uzaklaşacaktır ve küme merkezi hesaplanırken katkısı daha az olacaktır. Bulanıklık sabitinin değeri küçültülürse, bu defa da A noktası maksimum bulanıklık bölgesinin dışında kalacak ve 2. küme üyeliği 1'e yakın bir değeriyle bağlı olacaktır. Görüldüğü gibi, her iki küme için de uygun bir bulanıklık bölgesini tek m değeri ile oluşturmak mümkün değildir [39].



**Şekil 3.3 :** Farklı hacimdeki iki küme için bulanıklık sabitinin etkisi [39].

Bu problemde yola çıkarak, Rhee ve arkadaşları 2007 yılında m parametresinin belirsizliği üzerine yoğunlaşmışlardır [39]. Yaptıkları çalışmada tek bir bulanıklık sabiti yerine iki farklı değer kullanılmasının yöntemin farklı hacim ve yoğunluktaki veri kümeleri üzerinde performansını artırdığını göstermişler ve klasik bulanık c-ortalama algoritmasına aralık tip-2 yaklaşımını uyarlamışlardır. İki farklı bulanıklık sabitinin etkisi temsili olarak Şekil 3.4’te gösterilmiştir.



**Şekil 3.4 :** İki farklı bulanıklık sabitinin etkisi [39].


İki farklı bulanık sabiti kullanılarak eşitlik (3.5) ve (3.6) ile iki farklı üyelik değeri hesaplanır. Böylece bir veri noktasının üyeliği tek bir değerle değil bir değer aralığı ile temsil edilmiş olur. Bu değer aralığı birincil üyelik olarak adlandırılır. Bu durumda veri seti artık tip-2 veri setidir ve klasik bulanık c-ortalama algoritmasındaki küme merkezi ve üyelik eşitliklerinin bu yeni yaklaşıma uyarlanması gerekmektedir.

İkincil üyelik değeri tüm noktalar için 1’e eşit kabul edildiğinde, bu yaklaşım aralık tip-2 yaklaşımı olarak adlandırılır. Başka bir deyişle, aralık tip-2 yaklaşımı tip-2 yaklaşımının özel bir halidir.

$$\bar{u}_j(x_i) = \left\{ \begin{array}{ll} \frac{1}{\sum_{k=1}^c (d_{ji}/d_{ki})^{2/(m_1-1)}} & \text{if } \frac{1}{\sum_{k=1}^c (d_{ji}/d_{ki})^{2/(m_1-1)}} > \frac{1}{\sum_{k=1}^c (d_{ji}/d_{ki})^{2/(m_2-1)}} \\ \frac{1}{\sum_{k=1}^c (d_{ji}/d_{ki})^{2/(m_2-1)}} & \text{otherwise} \end{array} \right\} \quad (3.5)$$

$$\underline{u}_j(x_i) = \left\{ \begin{array}{ll} \frac{1}{\sum_{k=1}^c (d_{ji}/d_{ki})^{2/(m_2-1)}} & \text{if } \frac{1}{\sum_{k=1}^c (d_{ji}/d_{ki})^{2/(m_1-1)}} > \frac{1}{\sum_{k=1}^c (d_{ji}/d_{ki})^{2/(m_2-1)}} \\ \frac{1}{\sum_{k=1}^c (d_{ji}/d_{ki})^{2/(m_1-1)}} & \text{otherwise} \end{array} \right\} \quad (3.6)$$

Algoritmanın işleyişi Şekil 3.5’te gösterilmiştir. Bulanıklık sabitinin iki farklı değeri için eşitlik (3.5) ve (3.6) ile alt ve üst üyelik değerleri hesaplanır.



**Şekil 3.5 :** Aralık tip-2 bulanık kümeleme algoritmasının akış şeması

Eşitlik (3.7) ile hesaplanan üyelik değeri kullanılarak (3.8) eşitliğine göre küme merkezi değeri hesaplanır.

$$u = \frac{\bar{u} + u}{2} \quad (3.7)$$



$$v = \frac{\sum_{i=1}^N u^m x_i}{\sum_{i=1}^N u^m} \quad (3.8)$$

İki farklı m değeri kullanıldığından tıpkı üyelik değerleri gibi küme merkezleri de bir aralık ile temsil edilecektir. Bulanık c-ortalamar algoritmasındaki gibi küme merkezlerinin iteratif olarak güncellenebilmesi için tip azaltma işlemi yapılmalıdır. Herhangi bir tip-2 veri seti, N veri için  $2^N$  tane alt veri setinden (tip-1) oluşur ve tip azaltma işlemi yapılabilmesi için hesaplamalarda bunların hepsi dikkate alınmalıdır. Çok sayıda veri mevcutken bu mümkün olmadığından, küme merkezi aralığının sınırlarını ( $v_R$  ve  $v_L$ ) hesaplayıp tip azaltma işlemi yapmak için Karnik ve Mendel [34] tarafından önerilen yöntem kullanılır. Karnik-Mendel algoritmasına ait sözde kod Şekil 3.6'da verilmiştir.

Burada şöyle bir yol izlenir: ( $v_R$ )

1. Data artan şekilde sıralanır ve  $x_k \leq v \leq x_{k+1}$  şartını sağlayan k değeri bulunur. ( $1 \leq k \leq N - 1$ )
2.  $i > k$  ise  $u' = \bar{u}$   
 $i \leq k$  ise  $u' = \underline{u}$  olarak seçilir.
3. Yeni  $u'$  değeri kullanılarak (3.8) eşitliği ile  $v'$  değeri hesaplanır,  $v$  ile  $v'$  değeri karşılaştırılır. Aradaki fark, seçilen  $\epsilon$  değerinden küçükse, işlem sonlandırılır. Şart sağlanmıyorsa, 1.adıma geri dönülür.

Küme merkezi aralığının diğer sınırı olan  $v_L$  değerini hesaplamak için de aynı işlem yapılır. Sadece 2.adım aşağıdaki şekilde değiştirilmelidir.

$$i \leq k \text{ ise } u' = \bar{u}$$

$$i > k \text{ ise } u' = \underline{u}$$

Karnik- Mendel algoritması kullanılarak, küme merkezi aralığının sınır değerleri bulunduktan sonra, (3.9) eşitliği ile tip azaltma işlemi tamamlanmış olur.

$$v'' = \frac{v_R + v_L}{2} \quad (3.9)$$

Yeni hesaplanan küme merkezi bir önceki adımda hesaplanan ile karşılaştırılır. Aradaki fark, seçilen  $\epsilon$  değerinden küçükse, işlem sonlandırılır. Şart sağlanmıyorsa, alt ve üst üyelik değerleri yeniden hesaplanarak aynı işlemler tekrarlanır.

Algoritmanın sonlandırma şartı sağlandıktan sonra, bölütleme işlemi yapılabilmesi için katı-sınıflama işlemi gereklidir. Ancak veri seti artık tip-2 olduğundan bu aşama

da klasik bulanık c-ortalamalar algoritmasındaki gibi uygulanamaz. Burada da tip azaltma işlemi gereklidir.

```
Pseudo code of Karnik-Mendel algorithm for finding  $v_R$ :  
  
FOR all data points  
  Compute primary memberships ( $\bar{u}$  and  $\underline{u}$ )  
  
END  
  
Set  $u = \frac{\bar{u} + \underline{u}}{2}$  and calculate cluster centers ( $v'$ ) using these membership values.  
  
Sort pattern indexes in ascending order.  
  
  FOR all features  
    WHILE comparison=0  
      Find k index so that  $x_k \leq v'_j \leq x_{k+1}$   
  
      FOR all data points  
        IF  $i \leq k$  THEN  
          Set  $u_j = \underline{u}$   
        ELSE  
          Set  $u_j = \bar{u}$   
        END IF  
  
      END FOR  
  
      Compute center candidate using new membership values ( $v''$ )  
  
      IF  $v' = v''$  THEN  
        Set comparison=1  
      END IF  
  
    END WHILE  
  
  END FOR  
  
Set  $v_R = v''_j$ 
```

Şekil 3.6 : Karnik-Mendel algoritmasının sözde kodu

Tip azaltma, (3.10) eşitliğine göre yapılır.

$$u_{ij} = \frac{u_{ij}^R + u_{ij}^L}{2} \quad (3.10)$$

Burada,

$$u_{ij}^R = \frac{\sum_{i=1}^M u_{jl}(x_i)}{M} \quad (3.11)$$

$$u_{jl}(x_i) = \begin{cases} \overline{u_{ij}} & \text{eğer } l. \text{ özellik için, } v_j^R \text{ hesaplanırken } \overline{u_{ij}} \text{ kullanılmışsa} \\ \underline{u_{ij}} & \text{eğer } l. \text{ özellik için, } v_j^L \text{ hesaplanırken } \underline{u_{ij}} \text{ kullanılmışsa} \end{cases}$$

$$u_{ij}^L = \frac{\sum_{i=1}^M u_{jl}(x_i)}{M} \quad (3.12)$$

$$u_{jl}(x_i) = \begin{cases} \overline{u_{ij}} & \text{eğer } l. \text{ özellik için, } v_j^L \text{ hesaplanırken } \overline{u_{ij}} \text{ kullanılmışsa} \\ \underline{u_{ij}} & \text{eğer } l. \text{ özellik için, } v_j^R \text{ hesaplanırken } \underline{u_{ij}} \text{ kullanılmışsa} \end{cases}$$

### 3.4 Parçacık Sürü Optimizasyonu

Kümeleme amaçlı kullanılan tüm yöntemler, başlangıç değerlerine bağlıdır. Başlangıçta seçilen küme merkezleri ya da üyelik değerleri sonucun doğruluğunu önemli ölçüde etkilemektedir. Bu problemin önüne geçmek için önerilmiş birçok yöntem mevcuttur. Başlangıç değerlerini histograma göre seçmek, uygulanacak yöntemlerden biridir. Wang ve arkadaşları tarafından önerilen ve kümeleme algoritmalarına uygulanan global yöntemler [11, 45] bir diğer yaklaşımdır.

Başlangıç değeri probleminin önüne geçmek için kullanılan bir diğer yöntem ise optimizasyon algoritmaları ile veri seti içerisindeki verilerden, bir hedef fonksiyonu minimize edecek noktayı bulup, bu değerleri başlangıç değeri olarak kullanmaktır.

Parçacık sürü optimizasyonu Russell Eberhart ve James Kennedy tarafından 1995 yılında sürü davranışları modellenerek önerilen bir optimizasyon yöntemidir [71]. Algoritma, parçacık adı verilen ve her biri ele alınan problemin farklı bir çözümünü temsil eden elemanlardan oluşur. Tüm elemanlar bir araya gelerek sürüyü oluşturur.

Yöntem, başlangıçta seçilen parçacık konumlarının iteratif olarak güncellenmesi ve en iyi konumun bulunması prensibini esas alır. Parçacık sürü optimizasyonu algoritmasının sözde kodu Şekil 3.7’de verilmiştir.

Pseudo code of particle swarm optimization algorithm:

Set particle number, maximum and minimum value of speed, limits of particle location, value of  $w$ ,  $c_1$  and  $c_2$ .

Initialization of particle locations.

WHILE comparison  $< \epsilon$

    FOR all particles

        Compute the value of fitness function

            IF new fitness value  $<$  previous fitness value THEN

                Set location as the best location of this particle

            END

    END

Find minimum fitness value of whole swarm and set it as best position of swarm.

Update the velocities of particles using equation()

Update the positions of particles using equation()

Comparison = abs(old position - new position)

END

**Şekil 3.7 :** Parçacık sürü optimizasyonu algoritmasının sözde kodu

Algoritma şu şekilde işler:

1. Parametre değerleri seçilir (parçacık sayısı, maksimum hız, minimum hız, sınır değerler,  $w$  parametresi,  $c_1$  ve  $c_2$ , iterasyon sayısı)
2. Başlangıçtaki parçacık konumları rastgele seçilir.
3. Her parçacık için uygunluk fonksiyonunun değeri hesaplanır. Önceki iterasyondaki uygunluk değeri ile karşılaştırılır. Yeni uygunluk değeri daha küçükse (maksimizasyon problem için daha büyük), şimdiki konum o parçacığın en iyi konumu olarak atanır.
4. Tüm parçacıklar arasında en düşük uygunluk değerine sahip olan parçacığın konumu sürünün en iyi konumu olarak kabul edilir.
5. (3.13) eşitliği kullanılarak, parçacıkların hızı hesaplanır. Burada hız denilen, aslında parçacıkların yer değiştirme miktarıdır.

6. (3.14) eşitliği kullanılarak, parçacıkların yeni konumları hesaplanır. Algoritma sonlandırma şartı kontrol edilir. Şart sağlanıyorsa, işlem bitirilir. Şart sağlanmıyorsa, 3.adıma geri dönülür.
7. Belirli bir iterasyon sonunda, sürünün en iyi değeri problemin çözümü olur.

$$v_{ij}^{t+1} = w \cdot v_{ij}^t + c_1 r_1 (p_{best,ij} - x_{ij}) + c_2 r_2 (g_{best} - x_{ij}) \quad (3.13)$$

Burada,

$t$ : iterasyon sayısı

$c_1, c_2$ : hızlandırma katsayıları

$r_1, r_2$ : [0,1] aralığında rastgele atanan katsayılar

$w$ : atalet katsayısı

$p_{best,ij}$ : Parçacığın en iyi konumu

$g_{best}$ : Sürünün en iyi konumu


$x_{ij}$ : Parçacığın konumu

$$x_{ij}^{t+1} = x_{ij}^t + v_{ij}^{t+1} \quad (3.14)$$


### 3.5 Veri Seti

Bu tez çalışmasında kullanılan görüntüler, McGill Üniversitesinin BrainWeb veri tabanından alınmıştır [72]. Bu veri tabanından, T1,T2 ve PD ağırlıklı sentetik manyetik rezonans görüntüleri, istenilen parametreler ayarlanarak (gürültü, yoğunluk homojensizliği vb.) üretilebilmektedir. Bir görüntü seti, 181\*217 piksellik 181 kesitten oluşmaktadır. Aynı veri tabanından, görüntüye ait farklı dokuların işaretlendiği hedef görüntüye de ulaşılabilmektedir.

Tez çalışması kapsamında, 181 adet kesitten 97.kesit ile 105. kesit arasındaki 9 adet görüntü bölütleme için kullanılmıştır. Şekil 3.8'de bu kesitlere ait T1 ağırlıklı görüntüler; Şekil 3.9'da ise 100 nolu kesite ait T1,T2 ve PD ağırlıklı görüntüler görülmektedir. Öznitelik olarak, görüntülerin T1 ve T2 yoğunluk değerleri kullanılmıştır. Kullanılan görüntüler 0% ve 9% olmak üzere iki farklı sinyal-gürültü oranına (SNR) göre üretilmiştir. SNR hesabında referans doku olarak, görüntüdeki en parlak piksel kullanılmıştır. Kullanılan yöntemle ilişkin detaylar diğer bölümde anlatılacaktır.



Şekil 3.8 : Tez çalışmasında kullanılan görüntüler [72].




Şekil 3.9 : T1, T2 ve PD ağırlıklandırılmış MR görüntüleri [72].

### 3.6 Yöntem

Bu tez çalışmasında, MS plakları içeren beyin görüntülerinin bölütlenmesi ve MS plaklarının ayrıştırılması amaçlanmıştır. Bu amaçla aralık tip-2 bulanık kümeleme algoritması kullanılmış ve daha yaygın olarak kullanılan yöntemlerle karşılaştırılmıştır. Çalışmada kullanılan tüm kodlar, MATLAB kullanılarak yazılmış, hazır fonksiyonlar kullanılmamıştır.

Kümeleme için farklı öznitelikler kullanılmış, sonuç olarak en iyi kümeleme performansının T1 ve T2 ağırlıklı görüntülerin gri seviye değerleri ile elde edildiği görülmüştür. Aynı şekilde, yöntem farklı küme sayıları seçilerek test edilmiş ve en

iyi sonucu veren küme sayısı tespit edilmiştir. Bölütleme için izlenen yöntem, Şekil 3.10'da verilmiştir.



Şekil 3.10 : Tez çalışmasında izlenen yöntem

1. T1 ve T2 ağırlıklı görüntüler, sütun vektörü haline getirilir ve gri seviyeleri 0 ile 1 arasında olacak şekilde normalize edilir.
2. Her pikselin T1 ağırlıklı gri seviyesi, o piksele ait öznitelik değeri olarak kullanılır ve uygun küme sayısı seçilerek, bölütleme işlemi yapılır.
3. MS hastalığının çoğunlukla beyaz maddede ve bazen de gri maddede olduğu bilindiğinden, bölütleme sonucunda oluşan, hastalığın oluşma ihtimali bulunmayan dokulara ait kümeler (kafatası, beyin-omurilik sıvısı) ile arkaplana ait pikseller veri kümesinden atılır. Böylece hem veri sayısı azaltılarak işlem süresi kısaltılmış, hem de yöntemin performansı artırılmış olur.
4. İlk aşamadan sonra geriye kalan piksellere ait T2 ağırlıklı görüntüdeki gri seviyeleri yeni öznitelikler olarak kullanılır ve uygun bir küme sayısı ile bölütleme işlemi yapılır.
5. Sonuçta elde edilen kümelerden bir tanesi, sadece MS dokusu içermektedir.


### 3.7 Değerlendirme Ölçütleri

Tez çalışmasında kullanılan görüntülerin edinildiği veri tabanı, bölütlenmiş hedef görüntüyü de sunmaktadır. Buradan edinilen hedef görüntü 10 farklı doku ve arka plan olmak üzere 11 kümeden oluşmaktadır. Hedef görüntüde, farklı kümelerle ait

pikseller farklı numaralarla Çizelge 3.1’de verildiği şekilde etiketlenmiştir. Farklı dokulara ait hedef görüntüler Şekil 3.11’de görülmektedir.

**Çizelge 3.1 :** Tez çalışmasında kullanılan görüntüdeki doku sınıfları [72].

Etiket	Küme adı
0	Arkaplan
1	Beyin-omurilik sıvısı
2	Gri madde
3	Beyaz madde
4	Yağ
5	Kas/Deri
6	Deri
7	Kafatası
8	Glial madde
9	Bağ doku
10	MS lezyonu



**Şekil 3.11 :** Tez çalışmasında kullanılan hedef görüntüdeki doku sınıfları [72].

Buradan, 10 numara ile etiketlenmiş pikseller seçilerek, sadece MS lezyonu içeren hedef görüntü elde edilmiştir. Bölütleme sonucunda elde edilen MS lezyonu içeren küme ile hedef görüntüden ayrıştırılan MS lezyonu görüntüsü arka plana ait pikseller dikkate alınmadan, piksel-piksel karşılaştırılmış ve Çizelge 3.2’de verilen şartlara göre doğru pozitif (DP), yanlış pozitif (YP), doğru negatif (DN), yanlış negatif (YN) değerleri hesaplanmıştır.



**Çizelge 3.2 :** Değerlendirme ölçütlerinin hesabında kullanılan değerler

	<b>Bölütleme sonucu</b>	<b>Gerçek değer</b>
<b>DP</b>	Lezyon var	Lezyon var
<b>YP</b>	Lezyon var	Lezyon yok
<b>DN</b>	Lezyon yok	Lezyon yok
<b>YN</b>	Lezyon yok	Lezyon var

Eşitlik (3.15) ile hesaplanan duyarlılık kriteri, MS lezyonlarından ne kadarının tespit edilebildiğini ifade eder. Özgünlük, duyarlılığın aksine MS lezyonu içermeyen bölgelerin ne kadarının doğru tespit edildiğini gösteren bir kriterdir ve eşitlik (3.16) ile hesaplanır. Benzerlik kriteri eşitlik (3.17) ile hesaplanır ve bölütleme sonucunda ayrıştırılan MS dokusu ile, gerçekte var olan MS dokusunun birbirine ne kadar benzediğini ifade eder. Eşitlik (3.18) ile hesaplanan doğruluk ise, görüntünün toplam alanından ne kadarının doğru etiketlendiğinin ölçüsüdür [73].

$$\text{Duyarlılık (Sensitivity)} = \frac{DP}{DP+YN} \quad (3.15)$$

$$\text{Özgünlük (Specificity)} = \frac{DN}{DN+YP} \quad (3.16)$$

$$\text{Benzerlik (Similarity)} = \frac{2*DP}{2*DP+YP+YN} \quad (3.17)$$


$$\text{Doğruluk (Accuracy)} = \frac{DP+DN}{DP+DN+YP+YN} \quad (3.18)$$



## 4. BULGULAR

### 4.1 Bulanık C-Ortalamlar Yöntemiyle Elde Edilen Sonuçlar

Bulanık c-ortalamlar algoritmasının performansı üzerinde bulanıklık sabitinin değerinin etkisini gözlemek amacıyla, farklı bulanıklık sabiti değerleri için yöntemin performansı test edilmiş ve elde edilen sonuçlar Şekil 4.1’de grafiksel olarak gösterilmiştir. Bu aşamada yöntem performansının bir tek bulanıklık sabitine bağlı olmasını sağlamak için tüm denemelerde program aynı başlangıç değerleri ile başlatılmış ve küme sayıları aynı seçilmiştir (ilk aşamada 4 küme ( $C_1$ ), ikinci aşamada 7 küme ( $C_2$ )).



**Şekil 4.1 :** Bulanıklık sabitinin farklı değerleri için hesaplanan duyarlılık ve benzerlik değerleri (Kesit no:100/gürültüsüz)


Elde edilen sonuçlara bakıldığında, bulanıklık sabitinin bazı değerleri için duyarlılık oldukça yüksek iken doğruluk değerlerinin düşük olduğu görülmektedir. Bu durumun nedeni, MS dokusuna ait neredeyse tüm piksellerin doğru tespit edilmesine rağmen beyin diğer dokularına ait piksellerin de MS olarak kümeleneşidir. Buradan hareketle, bu durumun gözleendiği parametre değerleri için farklı küme sayıları seçilerek daha iyi sonuçlar elde edilebileceği düşünölmüş ve elde edilen sonuçlardan bazılarına Çizelge 4.1’de yer verilmiştir. En iyi sonucun  $m=6$  değeri için ilk aşamada 5, ikinci aşamada 7 küme ile bölütleme yapıldığında elde edildiği

görülmektedir. İlerleyen kısımlarda verilecek tüm sonuçlar için, bu parametreler kullanılmıştır.

**Çizelge 4.1 :** Bulanıklık sabiti ve küme sayısı tespiti için yapılan denemelerden elde edilen sonuçlar


<b>m</b>	<b>1.aşama</b>	<b>2.aşama</b>	<b>Duyarlılık</b>	<b>Özgünlük</b>	<b>Benzerlik</b>	<b>Doğruluk</b>
1,4	5 küme	8 küme	0,5509	0,9998	0,6943	0,9970
1,7	5 küme	8 küme	0,5509	0,9998	0,6943	0,9970
3	5 küme	8 küme	0,7725	0,9999	0,8629	0,9985
4	5 küme	8 küme	0,7964	0,9999	0,8750	0,9986
5	5 küme	7 küme	0,7904	0,9999	0,8771	0,9986
<b>6</b>	<b>5 küme</b>	<b>7 küme</b>	<b>0,9641</b>	<b>0,9993</b>	<b>0,9253</b>	<b>0,9990</b>

Şekil 4.2’de ilk aşama için T1 ağırlıklı görüntüdeki yoğunluk değerleri öznitelik olarak kullanılıp, küme sayısı 5 seçilerek yapılan bölütleme sonucunda oluşan kümeler verilmiştir. Kümenin üyesi olan pikseller beyaz renkle, diğerleri siyah renkle gösterilmiştir.



**Şekil 4.2 :** Bulanık c-ortalamalar algoritması ile ilk aşamadaki bölütleme sonuçları

Birinci aşamada oluşan kümelerden MS lezyonu oluşma ihtimali olmayanlar (kafatası ve beyin-omurilik sıvısı) ile arkaplana ait pikseller görüntüden atılmış ve geriye kalan veri kümesi T2 ağırlıklı görüntüdeki yoğunluk değerleri öznitelik olarak kullanılarak 7 kümeye bölütlenmiştir. Bölütleme sonucunda elde edilen kümeler Şekil 4.3’te gösterilmiştir. Şekil 4.4’te bölütleme sonucunda ayrıştırılan MS dokusu, veri tabanından alınan hedef görüntü ve aradaki fark gösterilmiştir. Burada yer verilen sonuç için duyarlılık 0,9820 ve benzerlik 0,8325 olarak hesaplanmıştır.



**Şekil 4.3 :** Bulanık c-ortalamlar algoritması ile ikinci aşamadaki bölütleme sonuçları



(a) (b) (c)  
**Şekil 4.4 :** BCO yöntemi ile yapılan bölütleme sonucu (Kesit no:100)  
a) Bölütleme sonucu b) Hedef görüntü c) Fark

Bulanık c-ortalamlar algoritması başlangıçta seçilen küme merkezi değerlerine bağlı sonuç verdiği için, performansını tek bir değerle ifade etmek mümkün değildir. Bu yüzden aynı parametreler kullanılarak, farklı başlangıç değerleri ile algoritma 100 kere çalıştırılmış ve değerlendirme ölçütlerine ait Çizelge 4.2’de verilen ortalama ve standart sapma değerleri hesaplanmıştır.

**Çizelge 4.2 :** Seçilen bir parametre için istatistik sonuçları (Kesit no:100)

	<b>Ortalama</b>	<b>Standart sapma</b>
<b>Duyarlılık</b>	0,9096	0,0787
<b>Özgünlük</b>	0,9929	0,0194
<b>Benzerlik</b>	0,8094	0,2291
<b>Doğruluk</b>	0,9924	0,0191

Tek bir görüntüye bağlı kalmamak için yöntem, MS lezyonu içeren 9 farklı görüntüye uygulanmış ve elde edilen sonuçlar Çizelge 4.3’te verilmiştir. Gürültünün algoritma performansı üzerine etkisini gözleyebilmek için yöntem aynı

parametrelerle 9% SNR değerine sahip gürültü eklenmiş görüntüler üzerinde test edilmiş ve elde edilen sonuçlar Çizelge 4.4'te verilmiştir.

**Çizelge 4.3 :** Tezde kullanılan görüntüler için bulanık c-ortalamar yöntemi ile elde edilen sonuçlar

Kesit no	Duyarlılık	Özgünlük	Doğruluk	Benzerlik
97	0,8589	1,0000	0,9211	0,9991
98	0,8442	1,0000	0,9123	0,9991
99	0,7124	1,0000	0,8289	0,9983
100	0,7904	0,9999	0,8771	0,9986
101	0,8466	0,9999	0,9117	0,9988
102	0,8348	0,9999	0,9056	0,9985
103	0,7602	1,0000	0,8615	0,9980
104	0,8063	1,0000	0,8927	0,9988
105	0,8750	1,0000	0,9333	0,9995
<b>Ortalama</b>	<b>0,8143</b>	<b>1,0000</b>	<b>0,8938</b>	<b>0,9987</b>

**Çizelge 4.4 :** Tezde kullanılan görüntüler için bulanık c-ortalamar yöntemi ile elde edilen sonuçlar (gürültülü)

Kesit no	Duyarlılık	Özgünlük	Doğruluk	Benzerlik
97	0,6380	0,9599	0,1536	0,9580
98	0,6753	0,9625	0,1635	0,9608
99	0,6209	0,9623	0,1507	0,9604
100	0,7066	0,9602	0,1753	0,9587
101	0,7302	0,9570	0,1883	0,9554
102	0,7500	0,9601	0,2333	0,9584
103	0,6561	0,9638	0,2209	0,9612
104	0,7375	0,9567	0,1681	0,9554
105	0,7321	0,9601	0,1336	0,9591
<b>Ortalama</b>	<b>0,6940</b>	<b>0,9603</b>	<b>0,1764</b>	<b>0,9586</b>

Elde edilen sonuçlara bakıldığında, yöntemin performansı üzerinde bulanıklık sabitinin ve küme sayısının doğrudan etkili olduğu görülmüştür. Ayrıca, gürültünün algoritmanın performansını önemli ölçüde azalttığı sonucuna da varılabilmektedir.

#### 4.2 Parçacık Sürü Optimizasyonu Algoritmasının Kullanılmasıyla Elde Edilen Sonuçlar

Bulanık c-ortalamar algoritması ile elde edilen sonuçlara bakıldığında, yöntemin başlangıç değerlerine bağlı olduğu görülmektedir. Dolayısıyla, program her çalıştırılmada farklı sonuç verebilmektedir. Yöntemin başlangıç değerlerine bağlılığını azaltmak için, küme merkezlerinin ilk değerlerinin rastgele atanması yerine, parçacık sürü optimizasyonu ile hesaplanan değerlerin kullanılması çözümlü düşünülmüştür [49] .

Bu amaçla parçacık sürü optimizasyonu algoritması, Çizelge 4.5'te değerleri verilen parametreler kullanılarak bulanık c-ortalamar algoritmasının zarar fonksiyonunu minimize etmek için kullanılmıştır. Burada her parçacık, küme merkezlerinin olası değerlerini temsil etmektedir. Parçacık sürü optimizasyon algoritmasının çıktısı, bulanık c-ortalamar algoritmasının küme merkezlerinin başlangıç değeri olarak kullanılmıştır. Bulanık c-ortalamar algoritması için  $m=6$ ,  $C_1=5$ ,  $C_2=7$  olarak seçilmiştir.

**Çizelge 4.5 :** Parçacık sürü optimizasyonu algoritması için seçilen parametreler

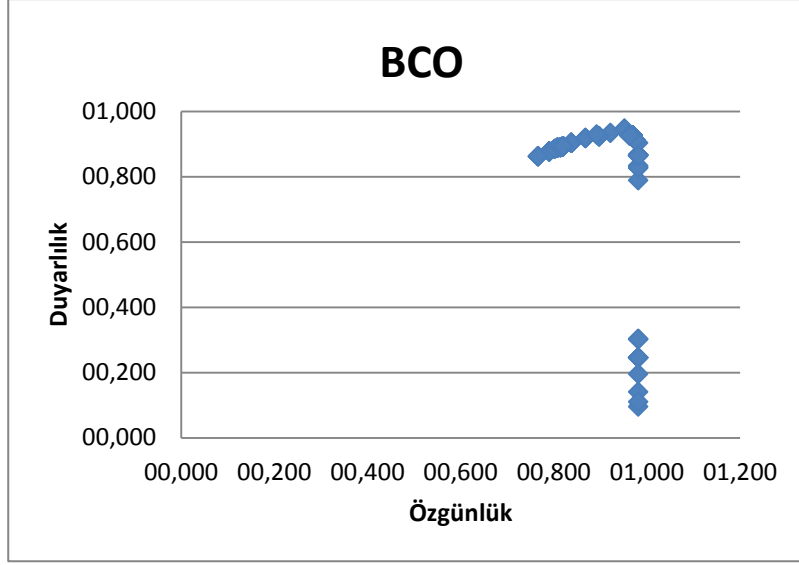
Parçacık sayısı	100
Maksimum iter.	500
$c_1$ ve $c_2$	1,496
Minimum hız	-0,3
Maksimum hız	0,3
w	0,7298

Parçacık sürü optimizasyon algoritması açısından önemli olan, başlangıçta seçilen parçacık konumlarıdır. Birden fazla minimumu olan fonksiyonlar için, algoritma başlangıçtaki parçacık konumlarına göre minimumlardan birine yakınsar. Buradaki uygulamada da, standart sapma hesabı için aynı algoritma 100 kere işletildiğinde, başlangıçtaki parçacık konumlarına göre farklı sonuçlar bulunabilmektedir. Elde edilen sonuçlardan, değerlendirme ölçütleri için hesaplanan ortalama ve standart sapma değerleri Çizelge 4.6'da verilmiştir. Elde edilen sonuçların dağılım grafiği Şekil 4.5 ve Şekil 4.6'da gösterilmiştir.

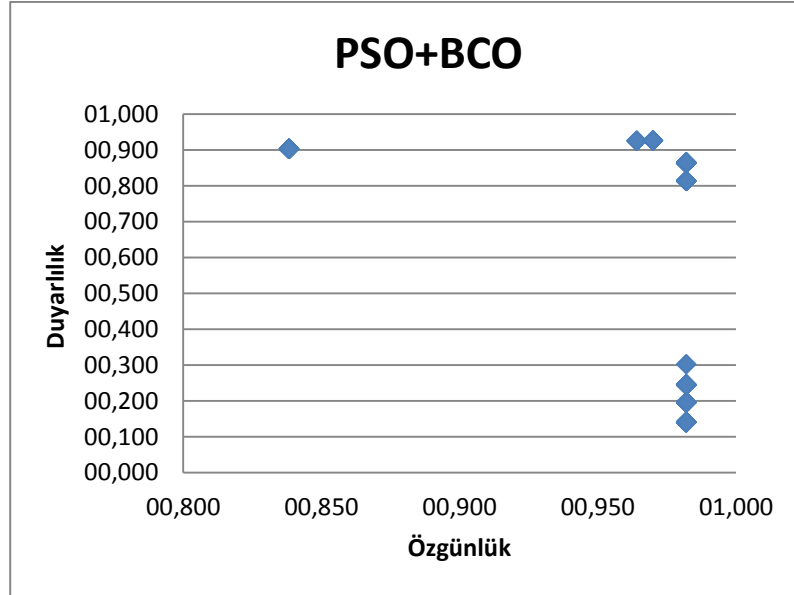
**Çizelge 4.6 :** Başlangıç değerleri PSO ile belirlendiğinde elde edilen sonuçlar

	Ortalama	Standart sapma
<b>Duyarlılık</b>	0,9694	0,0389
<b>Özgünlük</b>	0,9705	0,0285
<b>Benzerlik</b>	0,5085	0,3386
<b>Doğruluk</b>	0,9705	0,0282

Görüldüğü üzere, BCO algoritmasının başlangıç değerleri rastgele atandığında çok sayıda farklı sonuç elde edilmesine rağmen, başlangıç değerleri PSO algoritması ile belirlendiğinde sonuçların farklılığı daha az olmaktadır. Sonuçlara bakıldığında, aynı bulanıklık sabiti ile daha yüksek duyarlılıkta sonuçlar elde edilebildiği görülmüştür.



**Şekil 4.5 :** Bulanık c-ortalamalar algoritmasının 100 kere denenmesi ile elde edilen sonuçların dağılımı



**Şekil 4.6 :** PSO+BCO yönteminin 100 kere denenmesi ile elde edilen sonuçların dağılımı

### 4.3 Aralık Tip-2 Bulanık C-Ortalamalar Yöntemiyle Elde Edilen Sonuçlar


Aralık tip-2 bulanık c-ortalamalar algoritmasının performansı,  $m_1$  ve  $m_2$  ile temsil edilen bulanıklık sabitlerinin değerlerine göre değişmektedir. En doğru sonucu veren bulanıklık sabitinin değerini hesaplamak için herhangi bir yöntem olmadığından, bu değerler bu iki parametrenin farklı kombinasyonları denenerak tespit edilmiştir. Küme merkezlerinin güncellenmesi için kullanılan eşitliklerde yer alan üçüncü bulanıklık sabitinin ( $m$ ) değerinin ne olacağı hakkında net bir bilgiye



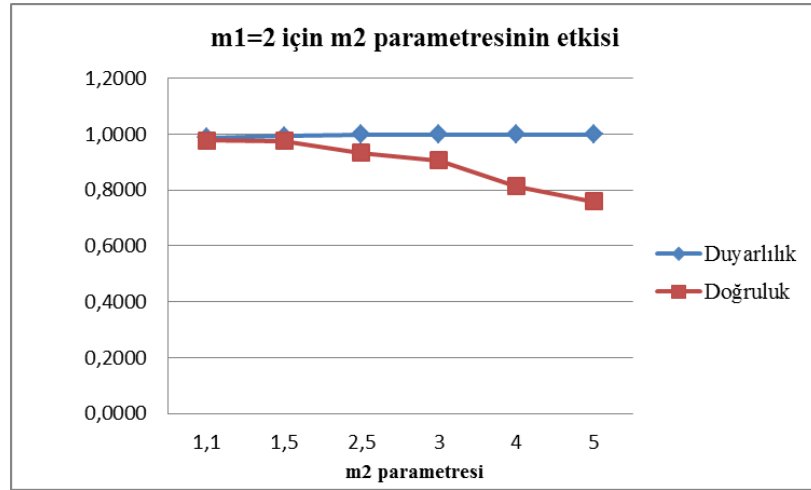
ulaşılamadığından, bu değer de  $m=1$ ,  $m=2$ ,  $m=3$  olarak seçilerek deneme yoluyla tespit edilmiştir.

#### 4.2.1 $m=1$ için sonuçlar


İlk olarak,  $m=1$  seçilerek diğer iki parametrenin farklı kombinasyonları için değerlendirme ölçütleri hesaplanmış ve elde edilen sonuçlar Şekil 4.7 – Şekil 4.11 ile verilmiştir.




Şekil 4.7 :  $m_1=1,1$  için farklı  $m_2$  değerleriyle hesaplanmış değerlendirme ölçütleri




Şekil 4.8 :  $m_1=2$  için farklı  $m_2$  değerleriyle hesaplanmış değerlendirme ölçütleri



Şekil 4.9 :  $m_1=3$  için farklı  $m_2$  değerleriyle hesaplanmış değerlendirme ölçütleri




Şekil 4.10 :  $m_1=4$  için farklı  $m_2$  değerleriyle hesaplanmış değerlendirme ölçütleri




Şekil 4.11 :  $m_1=5$  için farklı  $m_2$  değerleriyle hesaplanmış değerlendirme ölçütleri

#### 4.2.2 m=2 için sonuçlar


Küme merkezi eşitliğinde kullanılan  $m=2$  seçilerek diğer iki parametrenin farklı kombinasyonları için elde edilen sonuçlar Şekil 4.12 – Şekil 4.16 ile verilmiştir.




Şekil 4.12 :  $m_1=1,1$  için farklı  $m_2$  değerleriyle hesaplanmış değerlendirme ölçütleri




Şekil 4.13 :  $m_1=2$  için farklı  $m_2$  değerleriyle hesaplanmış değerlendirme ölçütleri



Şekil 4.14 :  $m_1=3$  için farklı  $m_2$  değerleriyle hesaplanmış değerlendirme ölçütleri




Şekil 4.15 :  $m_1=4$  için farklı  $m_2$  değerleriyle hesaplanmış değerlendirme ölçütleri




Şekil 4.16 :  $m_1=5$  için farklı  $m_2$  değerleriyle hesaplanmış değerlendirme ölçütleri

#### 4.2.3 $m=3$ için sonuçlar


Son olarak,  $m=3$  seçilerek diğer iki parametrenin farklı kombinasyonları hesaplanan sonuçlar Şekil 4.17 – Şekil 4.21 ile verilmiştir.




Şekil 4.17 :  $m_1=1,1$  için farklı  $m_2$  değerleriyle hesaplanmış değerlendirme ölçütleri




Şekil 4.18 :  $m_1=2$  için farklı  $m_2$  değerleriyle hesaplanmış değerlendirme ölçütleri



Şekil 4.19 :  $m_1=3$  için farklı  $m_2$  değerleriyle hesaplanmış değerlendirme ölçütleri



Şekil 4.20:  $m_1=4$  için farklı  $m_2$  değerleriyle hesaplanmış değerlendirme ölçütleri



**Şekil 4.21** :  $m_1=5$  için farklı  $m_2$  değerleriyle hesaplanmış değerlendirme ölçütleri

Yapılan denemeler sonucunda, kullanılan üç farklı bulanık sabitinin değerlerinin sonuçlar üzerinde önemli etkileri olduğu görülmüştür. Yöntemin küme merkezi güncelleme aşamasında kullanılan  $m$  parametresinin üç farklı değeri için diğer iki parametrenin yöntem performansına olan etkileri araştırılmıştır. Sonuçta,  $m_1$  ve  $m_2$  parametrelerinin büyük değerleri için ( $m_1, m_2 > 5$ ) küme merkezlerinin birbirine yakın hesaplandığı, hatta neredeyse aynı olduğu görülmüştür. Dolayısıyla, parametrelerin değerleri 1,1 ile 5 arasında seçilmiştir. Aynı  $m_1$  ve  $m_2$  değerleri için  $m$  parametresinin sonuçlara etkisi Çizelge 4.7’de görülmektedir ( $m_1=2$  ve  $m_2=3$  olarak seçilmiştir). Buradan,  $m$  parametresinin değeri arttıkça, yöntem başarısının azaldığı gözlemlenmektedir.

**Çizelge 4.7** :  $m$  parametresinin etkisi


<b>m değeri</b>	<b>Duyarlılık</b>	<b>Benzerlik</b>
<b>1</b>	0,9581	0,9996
<b>2</b>	0,9581	0,9821
<b>3</b>	0,6467	0,9629
<b>4</b>	0,5928	0,9655
<b>5</b>	0,5928	0,9655

Elde edilen sonuçlara bakıldığında, bulanıklık sabitlerinin bazı kombinasyonları için oldukça yüksek duyarlılık değerleri elde edilmesine rağmen, doğruluk değerlerinin düşük olduğu görülmektedir. Bu durumun nedeni, MS dokusuna ait neredeyse tüm piksellerin doğru tespit edilmesine rağmen beynin diğer dokularına ait piksellerin de MS olarak kümelenebilir. Buradan hareketle, bu durumun gözlemlendiği parametre değerleri için farklı küme sayıları seçilerek daha iyi sonuçlar elde edilebileceği düşünülmüş ve elde edilen sonuçlardan bazılarında Çizelge 4.8’de yer verilmiştir.

**Çizelge 4.8 :** Bulanıklık sabiti ve küme sayısı tespiti için yapılan denemelerden elde edilen sonuçlar (tip-2)

<b>m</b>	<b>m<sub>1</sub></b>	<b>m<sub>2</sub></b>	<b>C<sub>1</sub></b>	<b>C<sub>2</sub></b>	<b>Duyarlılık</b>	<b>Özgünlük</b>	<b>Benzerlik</b>	<b>Doğruluk</b>
1	2	1,1	5	7	0,9281	0,9995	0,9254	0,9991
<b>1</b>	<b>2</b>	<b>1,5</b>	<b>5</b>	<b>7</b>	<b>0,9581</b>	<b>0,9996</b>	<b>0,9440</b>	<b>0,9993</b>
2	1,1	3	5	7	0,8323	0,9997	0,8854	0,9987
2	1,1	4	5	7	0,9940	0,9980	0,8579	0,9980
2	2	2,5	5	7	0,8144	0,9998	0,8831	0,9987
2	4	1,5	5	8	0,9880	0,9986	0,8943	0,9985
2	4	1,1	5	7	0,9940	0,9980	0,8579	0,9980
3	1,1	4	5	7	0,8024	0,9998	0,8730	0,9985
3	2	3,5	5	7	0,7784	0,9999	0,8638	0,9985
3	2	5	5	7	0,9102	0,9995	0,9129	0,9989
3	3	4	5	7	0,9461	0,9996	0,9405	0,9993
3	3	4	5	8	0,8982	0,9997	0,9259	0,9991
3	5	1,5	5	7	0,8263	0,9997	0,8790	0,9986
3	5	1,75	5	7	0,8503	0,9997	0,8931	0,9987


Çizelge 4.8’de görüldüğü gibi, aralık tip-2 bulanık c-ortalamlar algoritması için en iyi sonuç  $m=1$ ,  $m_1=2$ ,  $m_2=1,1$ ,  $C_1=5$  ve  $C_2=7$  olarak seçildiğinde elde edilmiştir. İlerleyen kısımlarda verilecek tüm sonuçlar için bu parametreler kullanılmıştır. Şekil 4.22’de ilk aşama için T1 ağırlıklı görüntüdeki yoğunluk değerleri öznitelik olarak kullanılıp, küme sayısı 5 seçilerek yapılan bölütleme sonucunda oluşan kümeler verilmiştir. Kümenin üyesi olan pikseller beyaz renkle, diğerleri siyah renkle gösterilmiştir.



**Şekil 4.22 :** Aralık tip-2 bulanık c-ortalamlar algoritması ile ilk aşamadaki bölütleme sonuçları

Birinci aşamada oluşan kümelerden MS lezyonu oluşma ihtimali olmayanlar (kafatası ve beyin-omurilik sıvısı) ile arkaplana ait pikseller görüntüden atılmış ve geriye kalan veri kümesi T2 ağırlıklı görüntüdeki yoğunluk değerleri öznitelik olarak kullanılarak 7 kümeye bölütlenmiştir. Bölütleme sonucunda oluşan kümeler Şekil 4.23'te gösterilmiştir.

Şekil 4.24'te bölütleme sonucunda ayrıştırılan MS dokusu, veri tabanından alınan hedef görüntü ve aradaki fark gösterilmiştir. Burada yer verilen sonuç için duyarlılık 0,9581 ve benzerlik 0,9996 olarak hesaplanmıştır.



**Şekil 4.23 :** Aralık tip-2 bulanık c-ortalamlar algoritması ile ikinci aşamadaki bölütleme sonuçları



(a)

(b)

(c)

**Şekil 4.24 :** Aralık tip-2 bulanık c-ortalamlar yöntemi ile yapılan bölütleme sonucu (Kesit no:100) a) Bölütleme sonucu b) Hedef görüntü c) Fark

Yöntem aynı parametreler kullanılarak, MS lezyonu içeren 9 farklı görüntüye uygulanmış ve elde edilen sonuçlar Çizelge 4.9'da verilmiştir. Gürültünün etkisini gözleyebilmek için 9% SNR oranına sahip gürültü eklenmiş görüntüler üzerinde de aynı uygulama yapılmış ve Çizelge 4.10'da verilen sonuçlar elde edilmiştir.



**Çizelge 4.9 :** Tezde kullanılan görüntüler için aralık tip-2 bulanık c-ortalamlar yöntemi ile elde edilen sonuçlar

Kesit No	Duyarlılık	Özgünlük	Doğruluk	Benzerlik
97	0,9264	0,9999	0,9497	0,9994
98	0,9675	0,9998	0,9644	0,9996
99	0,9281	0,9997	0,9373	0,9993
100	0,9581	0,9996	0,9440	0,9993
101	0,9524	0,9997	0,9524	0,9993
102	0,9330	0,9997	0,9500	0,9992
103	0,9095	1,0000	0,9504	0,9992
104	0,9625	1,0000	0,9778	0,9997
105	0,9643	1,0000	0,9774	0,9998
<b>Ortalama</b>	<b>0,9446</b>	<b>0,9998</b>	<b>0,9559</b>	<b>0,9994</b>

**Çizelge 4.10 :** Tezde kullanılan görüntüler için aralık tip-2 bulanık c-ortalamlar yöntemi ile elde edilen sonuçlar (gürültülü)

Kesit No	Duyarlılık	Özgünlük	Doğruluk	Benzerlik
97	0,7730	0,9574	0,1746	0,9563
98	0,7857	0,9621	0,1864	0,9611
99	0,7712	0,9585	0,1702	0,9574
100	0,8263	0,9599	0,2006	0,9590
101	0,8254	0,9619	0,2303	0,9609
102	0,8214	0,9631	0,2669	0,9619
103	0,7828	0,9606	0,2430	0,9591
104	0,8750	0,9628	0,2206	0,9622
105	0,8571	0,9594	0,1523	0,9589
<b>Ortalama</b>	<b>0,8131</b>	<b>0,9606</b>	<b>0,2050</b>	<b>0,9596</b>

Yöntemin başlangıç değerlerine bağlılığını incelemek için, aynı parametreler kullanılarak farklı başlangıç değerleri ile algoritma 100 kere çalıştırılmıştır. Elde edilen sonuçların değerlendirme ölçütlerine göre hesaplanan ortalama ve standart sapma değerleri Çizelge 4.11’de verilmiştir.

**Çizelge 4.11 :** Seçilen bir parametre için istatistiki sonuçlar

	Ortalama	Standart sapma
<b>Duyarlılık</b>	0,9581	0
<b>Özgünlük</b>	0,9996	0
<b>Benzerlik</b>	0,9440	0
<b>Doğruluk</b>	0,9993	0

Görüldüğü gibi, tip-2 bulanık ortalamlar algoritması hem performans açısından daha yüksek duyarlılık ve doğrulukta; hem de başlangıç değerlerinden bağımsız sonuçlar vermektedir. Bu da, beklenildiği gibi tek bir bulanıklık sabiti yerine, iki farklı bulanıklık sabiti kullanarak küme merkezleri ve üyelik değerlerini bir aralıkla temsil etmenin, kümeleme performansını olumlu yönde etkilediğini göstermiştir.



## 5. TARTIŞMA VE SONUÇLAR

Tez çalışmasında, beyin görüntülerinden MS lezyonlarının ayrıştırılması için üç farklı yöntem kullanılmış ve sonuçları karşılaştırılmıştır.

Bulanık c-ortalamalar ile yapılan bölütleme sonucunda başarılı sonuçlar elde edilmiş ancak sonuçların başlangıç küme merkezi değerlerine çok bağlı olduğu görülmüştür. Algoritma, her işletilmesinde farklı sonuçlar verebilmektedir. Bu problemin önüne geçebilmek için, başlangıç değerlerinin rastgele seçilmesi yerine parçacık sürü optimizasyonu kullanılması önerilmiştir.

Başlangıç küme merkezi değerleri parçacık sürü optimizasyon algoritması ile hesaplandığında, elde edilen sonuçlar daha tutarlıdır. Aynı bulanıklık sabiti için iki yaklaşımla elde edilen sonuçlar karşılaştırıldığında, parçacık sürü optimizasyon algoritması kullanıldığında elde edilen sonuçların ortalama duyarlılık ve doğruluk oranlarının daha yüksek olduğu görülmüştür.

Son olarak, aralık tip-2 bulanık c-ortalamalar algoritması bölütleme için kullanılmıştır. Yöntemde, iki farklı bulanıklık sabiti kullanılmasının performansı artıracağı düşünülmüş ve sonuçlara bakıldığında beklenenin gerçekleştiği görülmüştür. Yöntem hem daha yüksek duyarlılık ve doğrulukta hem de başlangıç değerlerinden bağımsız sonuçlar vermiştir. Burada önemli nokta, bulanıklık sabiti değerlerinin seçimidir. Bulanıklık sabitinin değerlerine bağlı olarak yöntemin başarımı değişmektedir ve bu parametrenin değerinin belirlenmesi için hiçbir yöntem yoktur. Tez çalışmasında, farklı bulanıklık sabiti değerleri için algoritma test edilmiş ve sonuçlara yer verilmiştir.

Burada bir diğer önemli nokta, tüm yöntemler için küme sayısının kullanıcı tarafından belirlenmesidir. Küme sayısının seçimine göre yöntemlerin performansı önemli ölçüde değişmektedir ve bu da yapılan denemeler sonucunda tespit edilmiştir.

Bulanıklık sabiti ve küme sayısının belirlenmesinin otomatikleştirilmesi, yöntemlerin uygulanmasını ve performansın artırılmasını kolaylaştıracaktır. Bu amaçla, gelecekte bu parametrelerin optimizasyonu ile ilgili çalışmalar yapılması planlanmaktadır.

Bununla beraber, bölütleme sonucunda elde edilen kümelerin etiketlenmesi de yapılırsa, geliştirilen yöntemin doktorlara önemli ölçüde yardımcı olacağı düşünülmektedir.

## KAYNAKLAR

- [1]**Kalas, M. S.** (2010), An Artificial Neural Network for Detection of Biological Early Brain Cancer. *International Journal of Computer Applications.*, **1**(6), 17-23.
- [2]**Pittner, S. ve Kamarthi S.V.** (1999), Feature extraction from wavelet coefficients for pattern recognition tasks. *IEEE Transactions on Pattern Analysis and Machine Intelligence.*, **21**(1): 83-88.
- [3]**İşcan, Z., Dokur Z., ve Ölmez T.** (2007), Improved incremental self-organizing map for the segmentation of ultrasound images, in *Mathematical Methods in Engineering*, K. Taş, J.A. Tenreiro Machado, and D. Baleanu, Editors., Springer Netherlands. 293-302.
- [4]**İşcan, Z., Kurnaz, M.N., Dokur, Z. ve Ölmez, T.** (2006), Ultrasound Image Segmentation by Using Wavelet Transform and Self-Organizing Neural Network. *Neural Information Processing-Letters and Reviews.* **10**(8-9).
- [5]**Tao, Y., Muthukkumarasamy, V., Verma, B. ve Blumenstein, M.** (2003), A texture extraction technique using 2D-DFT and Hamming distance. In *Computational Intelligence and Multimedia Applications (ICCIMA)*.
- [6]**Zhang, W. ve Wang, X.** (2007), Feature Extraction and Classification for Human Brain CT Images. In *International Conference on Machine Learning and Cybernetics*.
- [7]**Wang, X., ve Lin, W.** (2007), Application of Inductive Learning in Human Brain CT Image Recognition. In *International Conference on Machine Learning and Cybernetics*.
- [8]**Ock-Kyung, Y., Dong-Min, K., Dong-Whee, K. ve Kil-Houm P.** (1999), MR brain image segmentation using fuzzy clustering. In *IEEE International Fuzzy Systems Conference Proceedings*.
- [9]**Szilagyi, L., Benyo, Z., Szilagyi, M. ve Adam, H.S.** (2003), MR brain image segmentation using an enhanced fuzzy C-means algorithm. In *Engineering in Medicine and Biology Society, Proceedings of the 25th Annual International Conference of the IEEE*.
- [10]**Chuang, K.S., Tzeng, H.L., Chen, S., Wu, J. ve Chen, T.** (2006), Fuzzy c-means clustering with spatial information for image segmentation. *Computerized Medical Imaging and Graphics.*, **30**(1): 9-15.
- [11]**Wang, W., Zhang, Y., Li, Y. ve Zhang, X.** (2006), The Global Fuzzy C-Means Clustering Algorithm. In *The Sixth World Congress on Intelligent Control and Automation (WCICA)*.

- [12]**Vasuda, P. ve Satheesh, S.** (2010), Improved Fuzzy C-Means Algorithm for MR Brain Image Segmentation. *International Journal on Computer Science and Engineering*. **2**(5): 1713-1715.
- [13]**Kalaiselvi, T. ve Somasundaram, K.** (2011), Fuzzy c-means technique with histogram based centroid initialization for brain tissue segmentation in MRI of head scans. In International Symposium on Humanities, Science & Engineering Research (SHUSER).
- [14]**Shasidhar, M., Raja, V.S. ve Kumar, B.V.** (2011), MRI Brain Image Segmentation Using Modified Fuzzy C-Means Clustering Algorithm. In International Conference on Communication Systems and Network Technologies (CSNT).
- [15]**Reddick, W.E., Glass, J.O., Cook, E.N., Elkin, T.D. ve Deaton, R.J.** (1997), Automated segmentation and classification of multispectral magnetic resonance images of brain using artificial neural networks. *IEEE Transactions on Medical Imaging*. **16**(6): 911-918.
- [16]**Alirezaie, J., Jernigan, M.E. ve Nahmias, C.** (1996), Automatic segmentation of cerebral MR images using artificial neural networks. In IEEE Nuclear Science Symposium.
- [17]**Demirhan, A. ve Güler, İ.** (2010), Using wavelet transform and neural networks for the analysis of brain MR images. In Signal Processing and Communications Applications Conference (SIU).
- [18]**Hata, Y., Kobashi S. ve Hirano, S.** (1998), Medical image segmentation by fuzzy logic techniques. In IEEE International Conference on Systems, Man, and Cybernetics.
- [19]**Likas, A., Vlassis, N. ve Verbeek J. J.** (2003), The global k-means clustering algorithm. *Pattern Recognition.*, **36**(2): 451-461.
- [20]**Selvathi, D., Arulmurgan, A., Thamarai, S.S. ve Alagappan, S.** (2005), MRI image segmentation using unsupervised clustering techniques. In Sixth International Conference on Computational Intelligence and Multimedia Applications.
- [21]**Zehui, L., Shengdong, N. ve Zhaoxue, C.** (2008) Application of Independent Component Analysis in MR Image Segmentation. In The 2nd International Conference on Bioinformatics and Biomedical Engineering.
- [22]**Abundez Barrera, I., Gutiérrez Estrada, C., Díaz Zagal, S. ve Nieto Perez, M.** (2008), Segmentation of medical images by region growing. In IEEE International Conference on Information Reuse and Integration.
- [23]**Luo, Y. ve Chung A.C.S.** (2011), An atlas-based deep brain structure segmentation method: from coarse positioning to fine shaping. In IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP).
- [24]**Hamamci, A., Kucuk, N., Karaman, K., Engin, K. ve Unal, G.** (2012), Tumor-Cut: Segmentation of Brain Tumors on Contrast Enhanced MR Images for Radiosurgery Applications. *IEEE Transactions on Medical Imaging*, 2012., **31**(3): 790-804.

- [25] **Boudraa, A-O., Dehak, S.M.D, Zhu, Y-M., Pachai, C., Bao, Y-G., ve Grimaud, J.** (2000), Automated segmentation of multiple sclerosis lesions in multispectral MR imaging using fuzzy clustering. *Computers in Biology and Medicine.*, **30**(1): 23-40.
- [26] **Kawa, J. ve Pietka, E.** (2007), Kernelized Fuzzy c-means Method in Fast Segmentation of Demyelination Plaques in Multiple Sclerosis. In Annual of the IEEE 29th International Conference Engineering in Medicine and Biology Society.
- [27] **Ozkurt, N. ve Ozkurt, A.** (2007), Unsupervised Segmentation of MRI using Independent Component Analysis. In IEEE 15th Signal Processing and Communications Applications (SIU).
- [28] **Ozyavru, H. ve Ozkurt, N.** (2008), Segmentation of MS plagues in MR images using fuzzy logic techniques. In IEEE 16th Signal Processing, Communication and Applications Conference (SIU).
- [29] **Khotanlou, H. ve Afrasiabi M.** (2011), Segmentation of Multiple Sclerosis Lesions in Brain MR Images Using Spatially Constrained Possibilistic Fuzzy C-Means Classification. *Journal of Medical Signals & Sensors.*, **1**(3): p. 149-55.
- [30] **Ozyavru, H., Ozkurt, N. ve Men, S.** (2012), MS plaque segmentation using masking clustering and level set method. In 20th Signal Processing and Communications Applications Conference (SIU).
- [31] **Bassem, A.A., Akmal, A.Y. ve Nigel, M.J.** (2012), Multi-Sectional Views Textural Based SVM for MS Lesion Segmentation in Multi-Channels MRIs. *Open Biomed. Eng. J.* **6**: 56-72.
- [32] *Medical Image Analysis on Multiple Sclerosis* (2008). Available: <http://miams08.inria.fr>
- [33] **Liang, Q. ve Mendel J.M.** (2000), Interval type-2 fuzzy logic systems: theory and design. *IEEE Transactions on Fuzzy Systems.*, **8**(5): 535-550.
- [34] **Karnik, N.N. ve Mendel J.M.** (1998), Type-2 fuzzy logic systems: type-reduction. In IEEE International Conference on Systems, Man, and Cybernetics.
- [35] **Mendel, J.M.** (2007), Type-2 fuzzy sets and systems: an overview. *IEEE Computational Intelligence Magazine.*, **2**(1): 20-29.
- [36] **Woei Wan, T., Chek Liang, F. ve Teck Wee, C.** (2007) Type-2 Fuzzy System for ECG Arrhythmic Classification. In IEEE International Fuzzy Systems Conference.
- [37] **Phong, P.A. ve Thien, K.Q.** (2009), Classification of Cardiac Arrhythmias Using Interval Type-2 TSK Fuzzy System. In International Conference on Knowledge and Systems Engineering.
- [38] **Rhee, F.C.H. ve Hwang, C.** (2001), A type-2 fuzzy C-means clustering algorithm. In IFSA World Congress and 20th NAFIPS International Conference.

- [39]Hwang, C. ve Rhee, F.C.H. (2007), Uncertain Fuzzy Clustering: Interval Type-2 Fuzzy Approach to C-Means. *IEEE Transactions on Fuzzy Systems*, **15**(1): 107-120.
- [40]Ceylan, R., Özbay, Y. ve Karlik, B. (2009), A novel approach for classification of ECG arrhythmias: Type-2 fuzzy clustering neural network. *Expert Systems with Applications*. **36**(3, Part 2): 6721-6726.
- [41]Min, J-H., Shim, E.A. ve Rhee, F.C.H. (2009), An interval type-2 fuzzy pcm algorithm for pattern recognition. In IEEE International Conference on Fuzzy Systems.
- [42]Qiu, C., Xiao, J., Yu, L. ve Han, L. (2011), An interval type-2 fuzzy c-means algorithm based on spatial information for image segmentation. In Eighth International Conference on Fuzzy Systems and Knowledge Discovery.
- [43]Özbay, Y., Ceylan, R., ve Karlik, B. (2011), Integration of type-2 fuzzy clustering and wavelet transform in a neural network based ECG classifier. *Expert Systems with Applications*. **38**(1): 1004-1010.
- [44]Kaur, P., Lamba, I.M.S., ve Gosain, A. (2011), Kernelized type-2 fuzzy c-means clustering algorithm in segmentation of noisy medical images. In IEEE Recent Advances in Intelligent Computational Systems.
- [45]Wang, L., Zhang, Y. ve Cai, M. (2011), The Global Interval Type-2 Fuzzy C-Means clustering algorithm. In International Conference on Multimedia Technology (ICMT).
- [46]Forghani, N., Forouzanfar, M. ve Forouzanfar, E. (2007), MRI fuzzy segmentation of brain tissue using IFCM algorithm with particle swarm optimization. In 22nd international symposium on Computer and information sciences.
- [47]Taherdangkoo, M., Yazdi, M. ve Rezvani, M.H. (2010), Segmentation of MR brain images using FCM improved by artificial bee colony (ABC) algorithm. In 10th IEEE International Conference on Information Technology and Applications in Biomedicine (ITAB).
- [48]Dogan, B. ve Korurek, M. (2012), ECG beat clustering using fuzzy c-means algorithm and particle swarm optimization. In 20th Signal Processing and Communications Applications Conference (SIU).
- [49]Izakian, H. ve Abraham, A. (2011), Fuzzy C-means and fuzzy swarm for fuzzy clustering problem. *Expert Systems with Applications*., **38**(3): p. 1835-1838.
- [50]Karagöz, İ. and Eroğul, O. (1998), *Tıbbi Görüntüleme Sistemleri*. ,Haberl Eğitim Vakfı.
- [51][http://www.nobelprize.org/nobel\\_prizes/](http://www.nobelprize.org/nobel_prizes/)
- [52]Sherer, M.A.S., Visconti, P.J., ve Ritenour. E.R. (2006), *Radiation protection in medical radiography*., Mosby Elsevier.
- [53]Webb, A. (2003), *Introduction to Biomedical Imaging*. IEEE Press Series on Biomedical Engineering, ed. M. Akay., Hoboken, New Jersey: John Wiley & Sons, Inc.



- [54] <http://www4.nau.edu/microanalysis/microprobe-sem/history.html>
- [55] **Lauric, A. ve Frisken, S.** (2007), Soft Segmentation of CT Brain Data., Tufts University.
- [56] <http://www.mc.uky.edu/obg/facultyinfo/facultypage.asp>.
- [57] <http://www.testone.com.tr/urun.aspx?uid=559&urun=NEC%20G100%20EX>
- [58] **Herek, D. and Karabulut, N.** (2010), Manyetik Rezonans Görüntüleme. TTD Toraks Cerrahisi Bülteni., **1**(3).
- [59] <http://www.cis.rit.edu/htbooks/mri/>
- [60] **Lefebvre, C.D.** (t.y.), *An Introductory Guide to MRI & fMRI*.
- [61] **Bassem, A.A.** (2012), *Segmentation of Multiple Sclerosis Lesions in Brain MRI.*, Phd thesis, University of Miami.
- [62] **Wang, Y.** (t.y.), *Physics of MRI.*, Polytechnic University.
- [63] *Multiple Sclerosis International Federation.*, <http://www.msif.org/en/>
- [64] **Behan, P.O., Chaudhuri, A. ve Roep, B.O.** (2002), The Pathogenesis of Multiple Sclerosis Revisited. *J R Coll Physicians Edinb*, cilt: **32**.
- [65] **Ma, P.** (2001), Automatic Segmentation of Multiple Sclerosis Lesions in Magnetic Resonance Brain Images., Master thesis, Dalhousie University, Halifax, Nova Scotia.
- [66] **Rogowska, J.** (2000), *Overview and Fundamentals of Medical Image Segmentation*, in *Handbook of Medical Imaging*, I.N. Bankman, Editor. sf. 69-80.
- [67] **Ma, Z., Tavares, J.M.R.S. ve Jorge, R.M.N.** (2009), A Review on the Current Segmentation Algorithms for Medical Images, In 1st International Conference on Imaging Theory and Applications( IMAGAPP).
- [68] **Pham, D.L., Xu, C. ve Prince, J.L.** (2000), Current Methods in Medical Image Segmentation., *Annu. Rev. Biomed. Eng.*, cilt: **2**: sf. 27.
- [69] **Bezdek, J.C., Ehrlich, R. ve Full, W.** (1984), Fcm: The Fuzzy c-Means Clustering Algorithm. *Computers & Geosciences*, **10**(2-3): 191-203.
- [70] **Zadeh, L.A.** (1965), Fuzzy sets. *Information and Control*, **8**(3): 338-353.
- [71] **Kennedy, J. and Eberhart, R.** (1995), Particle swarm optimization., In IEEE International Conference on Neural Networks.
- [72] McGill University, BrainWeb: Simulated Brain Database  
URL: <http://www.bic.mni.mcgill.ca/brainweb/>
- [73] **Ghasemi, J. ve diğ.** (2011), Separation of brain tissues in MRI based on multi-dimensional FCM and spatial information. In Eighth International Conference on Fuzzy Systems and Knowledge Discovery (FSKD).



## **ÖZGEÇMİŞ**

**Ad-Soyad:** İpek TOKER

**Doğum Yeri ve Tarihi:** 24.09.1989 / Tarsus

**E-Posta:** ipektoker@itu.edu.tr

**Lisans:** Erciyes Üniversitesi / Elektrik- Elektronik Mühendisliği

**Mesleki Deneyim ve Ödüller:** Araştırma Görevlisi/Abdullah Gül Üniv./ Eylül 2011-  
Aralık 2011

Araştırma Görevlisi (35.madde) / İstanbul Teknik Üniversitesi/ Aralık 2011-(devam ediyor)