



**T.C.**  
**SELÇUK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**SAYISAL GÖRÜNTÜ İŞLEMEDE**  
**PARALEL BÖLÜTLEME**

**Yasemin PEKTATLI**

**YÜKSEK LİSANS TEZİ**

**Elektrik-Elektronik Mühendisliği Anabilim Dalı**

**Eylül-2011**  
**KONYA**  
**Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Yasemin PEKTATLI tarafından hazırlanan “Sayısal Görüntü İşlemede Paralel Bölütleme” adlı tez çalışması 09/09/2011 tarihinde aşağıdaki jüri tarafından oy birliği / ~~oy çokluğu~~ ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

#### Başkan

Yrd. Doç. Dr. Mesut GÜNDÜZ

#### Danışman


Doç. Dr. Yüksel ÖZBAY

#### Üye

Yrd. Doç. Dr. Nihat YILMAZ

### İmza

.....  


.....  


.....  


Yukarıdaki sonucu onaylarım.

Prof. Dr. Bayram SADE  
FBE Müdürü

## **TEZ BİLDİRİMİ**

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

## **DECLARATION PAGE**

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Yasemin PEKTATLI

Tarih: 23/09/2011

## ÖZET

### YÜKSEK LİSANS TEZİ

#### SAYISAL GÖRÜNTÜ İŞLEMEDE PARALEL BÖLÜTLEME

**Yasemin PEKTATLI**

**Selçuk Üniversitesi Fen Bilimleri Enstitüsü  
Elektrik-Elektronik Mühendisliği Anabilim Dalı**

**Danışman: Doç. Dr. Yüksel ÖZBAY**

**2011, 102 Sayfa**

**Jüri**

**Doç. Dr. Yüksel ÖZBAY**

**Diğer Üyenin Unvanı Adı SOYADI**

**Diğer Üyenin Unvanı Adı SOYADI**

Bölütleme, görüntü işlemede ilk ve en önemli adımdır. Bölütlemede hatanın yüksek olması özellikle biyomedikal görüntülerde, daha sonraki görüntü işleme aşamalarını da etkileyecektir. Bu nedenle bölütlemenin en az hata ile yapılması çok önemlidir.

Bu tez çalışmasında, farklı görüntü bölütleme (segmentasyon) metodlarının paralel hesaplama mantığı ile birlikte değerlendirilmesi sonucu daha hızlı yeni bir bölütleme sistemi tasarlanmıştır. Tasarlanan sistem ile bölütleme gerçekleştirilecek görüntü, paralel hesaplama sayesinde dört metotla aynı anda işlenmektedir. Paralel hesaplama kullanımı görüntü işlemede veri boyutu nedeniyle en önemli sorun olan sürenin kısaltılmasını sağlar. Paralel hesaplama mantığı kullanılarak daha kısa sürede birden fazla algoritma bölütleme için çalıştırılmış ve işletilen karar mekanizması ile en iyisi kullanıcıya görsel olarak sunulmuştur. Ayrıca literatürde yer alan mevcut metotlar ile görüntülerin bölütlenmesinde elde edilen hata değerlerinin de indirgenmesi hedeflenmiştir. Bu çalışmada görüntülerin bölütlenmesinde morfolojik bölütleme teknikleri, yapay sinir ağları, bulanık c-ortalamalar kümeleme algoritması ve hücrel sinir ağları kullanılmıştır.

Tez çalışmasında, hem sağlıklı hem de hastalıklı akciğer bölgesi görüntüleri üzerinde bölütleme gerçekleştirilmiştir. Elde edilen sonuçlar incelendiğinde, doğru bulunan piksel değerleri bakımından hücrel sinir ağı yapısı en başarılı olarak bulunmuştur. Hücrel sinir ağı 10 sağlıklı görüntü verisinin 9'unda en yüksek piksel doğruluğunu vererek % 90 başarı göstermiştir. 20 hastalıklı akciğer görüntüsünde 12 tanesinde yine en yüksek doğruluk hücrel sinir ağı ile elde edilmiştir. Hastalıklı görüntülerde de hücrel sinir ağı ile diğer metotlara göre % 60 başarı sağlanmıştır. Ayrıca tez çalışmasında paralel hesaplama kullanılarak dört algoritma ile 30 görüntü verisinin bölütlenmesinde % 67.25 süre kazancı sağlanmıştır.

**Anahtar Kelimeler:** Bölütleme, paralel hesaplama, yapay sinir ağları, bulanık c-ortalamalar kümeleme algoritması, hücrel sinir ağları, morfolojik bölütleme teknikleri, akciğer görüntüsü, bilgisayarlı tomografi

**ABSTRACT****MS THESIS****PARALLEL SEGMENTATION  
IN DIGITAL IMAGE PROCESSING****Yasemin PEKTATLI****THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE  
OF SELÇUK UNIVERSITY  
THE DEGREE OF MASTER OF SCIENCE / DOCTOR OF PHILOSOPHY  
IN ELECTRICAL-ELECTRONICS ENGINEERING****Advisor: Assoc. Prof. Dr. Yüksel ÖZBAY****2011, 102 Pages****Jury****Assoc. Prof. Dr. Yüksel ÖZBAY  
Diğer Üyenin Unvanı Adı SOYADI  
Diğer Üyenin Unvanı Adı SOYADI**

Segmentation is the first and most important step in image processing. Especially in biomedical images, being offhigh error affects latter phase of image processing. For this reason, making of segmentation with less error is very important.

In this thesis study, a new segmentation system is designed as fast as a result of evaluation different image segmentation techniques together by using parallel computing. By means of parallel computing, image to be segmented is processed with four segmentation methods at same time using designed system. Using of parallel computing is provided to decrease time that is the most important problem because of data size. Using parallel computing, algorithms that its number is more than one in less time were executed and the best algorithm was presented to user as visually and digitally. It is aimed that the error value obtained by the existing methods in the literature is reduced to minimization using this new system during the segmentation of images. In this study, morphological segmentation techniques, artificial neural network, fuzzy c-means and cellular neural network were used in segmentation of images.

In thesis study, segmentation was implemented on both healthy and unhealthy lung region images. When the obtained results were investigated, cellular neural network was founded as the most successful method according to pixel values found as true. Cellular neural network structure represented 90% successful by giving high pixel accuracy in 9 images of 10 images. Again, the highest accuracy was obtained using cellular neural network in 12 images of 20 images. In unhealthy images, 60% successful was provided in unhealthy images with cellular neural network. However, in thesis study, using parallel computing, 67.25 % time gain was obtained in segmentation of one images by four algorithms.

**Keywords:** Segmentation, paralel computing, artificial intelligence, fuzzy c-means clustering algorithm, cellular neural network, morphological segmentation techniques, lung images, computer tomography.

## ÖNSÖZ

Görüntü işlemenin ilk aşaması olan bölütlemenin (segmentasyon) başarısı, ilgili bölgenin çıkarılmasında kullanılan metoda ve görüntüye göre farklılık göstermektedir. Bu aşamada yapılan bir hata görüntü işleme sistemlerinin diğer adımlarına da artarak etki etmektedir. Ayrıca bir medikal görüntüde başarılı olan bölütleme metodu diğer medikal görüntüde başarısız olabilmektedir. Aynı medikal görüntüde birden fazla metot başarılı olsa bile, bu metotların başarılarının tespiti uzun süreler almaktadır.

Gerçekleştirilen tez çalışmasında, aynı medikal görüntü için paralel işleme mantığı kullanılarak aynı anda dört farklı metot ile bölütleme yapılmıştır. Her bir metodun uygulanması sonucu elde edilen görüntüler birlikte değerlendirilerek en yüksek doğruluğu veren sonuç kullanıcıya sunulmaktadır.

Bu çalışmanın en önemli avantajı dört farklı bölütleme yönteminin paralel olarak uygulanması ile bölütleme için harcanılan zamanın en aza indirgenmesidir.

Böylelikle gerçekleştirilen tez çalışmasının, özellikle gelişmiş ülkelerde görülen ve en öldürücü hastalıklar arasında yer alan akciğer kanserinin tespitinde daha kısa süre ve daha yüksek doğruluk oranları ile gerçekleştirilecek yeni bir ön işlem önerdiği ve bu yönü ile bilim dünyasına önemli katkılarda bulunacağı düşünülmektedir.

Tez çalışmalarım sırasında akciğer BT görüntülerini kullanmama izin veren ve desteğini esirgemeyen Yrd. Doç. Dr. Murat CEYLAN' a teşekkür ederim.

Yasemin PEKTATLI  
KONYA-2011

## İÇİNDEKİLER

|                                                                                                   |            |
|---------------------------------------------------------------------------------------------------|------------|
| <b>ÖZET.....</b>                                                                                  | <b>i</b>   |
| <b>ABSTRACT.....</b>                                                                              | <b>ii</b>  |
| <b>ÖNSÖZ.....</b>                                                                                 | <b>iii</b> |
| <b>İÇİNDEKİLER.....</b>                                                                           | <b>iv</b>  |
| <b>SİMGELER VE KISALTMALAR.....</b>                                                               | <b>vi</b>  |
| <b>1. GİRİŞ.....</b>                                                                              | <b>1</b>   |
| 1.1. Tez Konusunun Amacı.....                                                                     | 1          |
| 1.2. Tez Konusunun Önemi.....                                                                     | 2          |
| 1.3. Kaynak Araştırması.....                                                                      | 3          |
| <b>2. MATERYAL VE YÖNTEM.....</b>                                                                 | <b>8</b>   |
| 2.1. Yapay Sinir Ağları.....                                                                      | 8          |
| 2.1.1. Yapay sinir ağlarının genel yapısı.....                                                    | 9          |
| 2.1.1.1. Geriye yayılım algoritması.....                                                          | 10         |
| 2.1.1.2. Aktivasyon fonksiyonu.....                                                               | 18         |
| 2.1.1.3. Öğrenme oranı.....                                                                       | 20         |
| 2.1.2. Yapay sinir ağları ile görüntü bölütleme ve kenar dedeksiyonu.....                         | 22         |
| 2.2. Bulanık C-Ortalamlar Kümeleme Algoritması.....                                               | 25         |
| 2.2.1. Bulanık c-ortalamlar kümeleme algoritması ile literatürde gerçekleştirilen çalışmalar..... | 25         |
| 2.2.2. Bulanık c-ortalamlar kümeleme algoritması.....                                             | 27         |
| 2.2.3. Bulanık c-ortalamlar kümeleme algoritması ile ilgili çalışılması gereken konular.....      | 28         |
| 2.3. Hücresel Yapay Sinir Ağı.....                                                                | 29         |
| 2.3.1. HYSA yapısı.....                                                                           | 30         |
| 2.3.1.1. HYSA hücre yapısı.....                                                                   | 31         |
| 2.3.1.2. Hücresel yapay sinir ağlarının devre elemanları ile gösterimi.....                       | 33         |
| 2.3.2. HYSA eğitimi.....                                                                          | 36         |
| 2.4. Morfolojik Bölütleme Metotları.....                                                          | 39         |
| 2.4.1. Piksel tabanlı bölütleme.....                                                              | 40         |
| 2.4.2. Kenar tabanlı bölütleme.....                                                               | 43         |
| 2.4.3. Bölge tabanlı bölütleme.....                                                               | 45         |
| <b>3. PARALEL BÖLÜTLEME UYGULAMALARI.....</b>                                                     | <b>47</b>  |
| 3.1. Tez Çalışmasında Kullanılan Veriler.....                                                     | 47         |
| 3.2. Sonuçların Değerlendirilmesinde Kullanılan Değerlendirme ve Doğruluk Kriterleri.....         | 49         |
| 3.3. Dört Algoritmanın Tek Tek Çalıştırılması ile Elde Edilen Bölütleme                           |            |

|                                                                                           |            |
|-------------------------------------------------------------------------------------------|------------|
| Sonuçları .....                                                                           | 49         |
| 3.3.1. Morfolojik algoritmalar elde edilen bölütleme sonuçları.....                       | 50         |
| 3.3.2. Yapay sinir ağları ile elde edilen bölütleme sonuçları.....                        | 53         |
| 3.3.3. Bulanık c-ortalamlar kümeleme algoritması ile elde edilen bölütleme sonuçları..... | 60         |
| 3.3.4. Hücrel yapay sinir ağı ile elde edilen bölütleme sonuçları.....                    | 64         |
| 3.4. Paralel Bölütleme.....                                                               | 67         |
| 3.4.1. İkili paralel bölütleme sonuçları.....                                             | 69         |
| 3.4.2. Üçlü paralel bölütleme sonuçları.....                                              | 72         |
| 3.4.3. Dörtlü paralel bölütleme sonuçları.....                                            | 75         |
| <b>4. TARTIŞMA.....</b>                                                                   | <b>78</b>  |
| <b>5. SONUÇLAR VE ÖNERİLER.....</b>                                                       | <b>83</b>  |
| 5.1. Sonuçlar.....                                                                        | 83         |
| 5.2. Öneriler.....                                                                        | 84         |
| <b>KAYNAKLAR.....</b>                                                                     | <b>86</b>  |
| <b>EKLER.....</b>                                                                         | <b>92</b>  |
| EK-1 Yapay sinir ağı algoritmasına ait program.....                                       | 92         |
| EK-2 Bulanık c-ortalamlar kümeleme algoritmasına ait program.....                         | 94         |
| EK-3 Hücrel yapay sinir ağı algoritmasına ait program.....                                | 96         |
| EK-4 Morfolojik bölütleme algoritmasına ait program.....                                  | 98         |
| EK-5 İkili paralel bölütlemeye ait program.....                                           | 99         |
| EK-6 Üçlü paralel bölütlemeye ait program.....                                            | 100        |
| EK-7 Dörtlü paralel bölütlemeye ait program.....                                          | 101        |
| <b>ÖZGEÇMİŞ.....</b>                                                                      | <b>102</b> |

## SİMGELER VE KISALTMALAR

### Simgeler

- $e_j(n)$ : lokal hata  
 $d_j(n)$ : hedeflenen çıkış  
 $y_j(n)$ : çıkış  
 $w_{kj}(n)$ : Ağırlık vektörü  
 $\eta$ : Öğrenme oranı  
 $\delta(n)$ : Lokal eğim  
 $\Delta w_{ji}(n)$ : Ağırlık düzeltme  
 $\alpha$ : Momentum sabiti  
 $E_{ij}$ : Bağımsız gerilim kaynağı  
 $r$ : Komşuluk sayısı  
 $M$ : Satır sayısı  
 $N$ : Sütun sayısı  
 $u_{ij}$ : Bulanık küme üyelik değerleri  
 $k$ : Bulanıklık sabiti  
 $x_j$ :  $j$ . piksel  
 $\varphi$ : Aktivasyon fonksiyonu  
 $//$ : Paralel çalıştırma

### Kısaltmalar

- BCO: Bulanık c-ortalamalar kümeleme  
 BDT: Bilgisayar destekli teşhis  
 BT: Bilgisayarlı tomografi  
 CAD: Computer-aided diagnosis  
 DD: Dalgacık dönüşümü  
 HYSA: Hücresel yapay sinir ağı  
 MR: Manyetik rezonans  
 YSA: Yapay sinir ağı

## 1. GİRİŞ

Medikal görüntüleme tıbbın pek çok dalı için vazgeçilmez bir araçtır. Medikal görüntüleme, medikal görüntülerin tutulmasında, iletilmesinde ve analizinde kolaylık sağlar ve medikal teşhise yardım eder. Medikal görüntülemenin kullanımı görüntüleme cihazlarının yeteneklerine bağlı olarak sürekli gelişmekte ve artmaktadır. Son zamanlarda, hesapsal zekâ teknikleri medikal görüntülemenin birçok uygulamasında gerçekleştirilmektedir ve klasik yaklaşımlarla karşılaştırıldığında avantajları görülmektedir. Özellikle bazı medikal görüntülerin (bilgisayarlı tomografi, manyetik rezonans vb.) teşhisinde, klasik metotlarla formüle ve analiz etmek imkânsız olmaktadır. Yapay zekâ klasik metotlar ile çözilemeyen görüntüleme problemlerinin aşılmasında avantajlarının çokluğu her gün daha fazla görülen metotlar içermektedir.

Tez çalışmasının birinci bölümünde medikal görüntülemenin avantajlarına ve medikal teşhiste sağladığı kolaylıklara değinilmiştir. Ayrıca tezin amacına ve önemine değinilmiştir. Literatürde yapılan çalışmalardan örnekler verilerek konunun önemi ortaya konulmuştur.

Tezin ikinci bölümünde yapay sinir ağları (YSA), teorisi ve uygulama alanlarına değinilmiştir. Bulanık c-ortalamlar (BCO) kümeleme algoritması anlatılmıştır. Bu bölümde hücrel sinir ağları (HYSA) incelenerek medikal görüntülemedeki uygulamalarına değinilmiştir. Ayrıca klasik bölütleme metotları teori olarak anlatılmış ve medikal görüntülerde klasik metotlar ile bölütleme üzerinde durulmuştur.

Tezin üçüncü bölümünde YSA, BCO kümeleme algoritması, HYSA ve klasik morfolojik metotlar ile yapılan uygulamaların sonuçları detaylı olarak incelenmiştir. Dördüncü bölümde sonuçlar tartışılmıştır. Tezin beşinci bölümünde ise genel olarak yapılan çalışmaların sonuçları özetlenmiş, gelecekte yapılacak çalışmalar için önerilerde bulunulmuştur.

### 1.1. Tez Konusunun Amacı

Medikal görüntü işlemede, görüntünün anlamlı bölümünün çıkarılması tanı işleminin en önemli aşamalarından birisidir. Literatürde bölütleme olarak adlandırılan işlem için çok farklı metotlar önerilmiştir. Bu çalışmada ise, paralel işleme mantığı ile

literatürde yer alan teknikler kullanılarak, BT görüntülerinden akciğer bölgesinin tam bir başarı ile bölütlenmesi amaçlanmaktadır. Sayısal görüntü işleme ve yapay zekâ tekniklerinin paralel olarak işletilmesi sonucu tespit edilen görüntüler değerlendirilerek ilgili bölgeyi tam olarak ifade edebilen yöntem kullanıcıya sunulmaktadır.

Ayrıca paralel işleme mantığı ile yöntemlerin tek tek çalıştırılması ile sonuç elde edilmesinin yanında birlikte çalıştırılarak en iyi sonucu veren algoritmanın daha kısa sürede belirlenmesi hedeflenmiştir. Gerçekleştirilen yazılım kullanılarak yüksek doğruluk ile elde edilen bölütlenmiş görüntünün, bilgisayar destekli teşhis (BDT) sisteminin nodül belirleme, nodül sınıflama gibi diğer aşamalarının sonuçlarına da dolaylı olarak etki etmesi ve işlem doğruluklarını yükseltmesi amaçlanmaktadır.

## 1.2. Tez Konusunun Önemi

Görüntü verilerinin boyutları çok büyük olduğu için görüntünün işlenmesi ve sonucunun alınmasında süre çok uzundur. İyi sonuçlar elde edilmediğinde farklı tekniklerin denenmesi sonuca ulaşılmasındaki süreyi daha da uzatır. Paralel hesaplamada işlemci çekirdek sayısı kadar metot aynı anda tek bir görüntü üzerinde işleme yapabilmektedir. Böylece aynı anda pek çok metodun sonucu alınmış ve değerlendirilmiş olacaktır.

Sayısal görüntü işlemede görüntü sınıflama en son aşamadır. Görüntü sınıflamadaki başarının düşük olması ve farklı tekniklerin doğruluk oranlarının farklılık göstermesinin sebebi sınıflamanın ilk aşamasını oluşturan bölütlemenin çok başarılı olmamasıdır. Başka bir deyişle görüntünün daha iyi bölütlenmesi, bir sonraki aşamada oluşabilecek hatayı düşürecektir.

Tez çalışmasında paralel işleme uygulanması sonucu, seçilen dört yöntem ile aynı anda daha kısa sürede görüntü bölütlenerek ve optimum sonucu veren algoritmanın belirlenmesi amaçlanmaktadır. Paralel işleme kullanılarak dört algoritma aynı anda çalıştırılacağından yaklaşık bir algoritmanın çalışacağı sürede dört algoritmanın bölütleme sonucu elde edilmiş ve görüntüyü doğruluk bakımından en iyi bölütleyen algoritma tespit edilmiş olacaktır.

### 1.3. Kaynak Araştırması

Medikal görüntü işlemede uygulamaya bağlı olarak görüntünün anlamlı bölümünün çıkarılması en önemli tanı aşamasıdır. Literatürde bu işleme “bölütleme” denilmektedir. Başka bir ifade ile bölütleme, görüntünün tanımlanması ve sınıflanmasında temel basamaktır. Görüntünün bölütlenmesi sonucunda elde edilen görüntü parçasına “ilgili bölge” denir (Wismüller, 2000).

Literatürde bölütleme işlemi için gerçekleştirilen çalışmalarda çok farklı metotlar kullanılmıştır. Ginger ve ark. (1994), nodül tespiti için çoklu gri seviye eşikleme ve kuralla dayalı yaklaşım metodu kullanırlarken, Lo ve ark. (1995) iki aşamalı bir sistem önermişlerdir. Buna göre, ilk aşamada nodül olması muhtemel örnekler yerleştirilmiş, ikinci aşamada hücrel yapay sinir ağı (HYSA) kullanılarak nodül olanlar ile olmayanlar ayrıştırılmıştır. Nodüllerin tespitinde YSA kullanımını takip eden bir diğer çalışma ise, Xu ve ark. (1997) tarafından gerçekleştirilen, ileri yönlü YSA ve karar kurallarının bir kümesini kapsamaktadır.

Kullanılan metotlar arasında bir genelleştirme yapılacak olursa yapay zekâ algoritmalarının temel alındığı görülebilir. 1997 yılında Ahmed ve Farag tarafından gerçekleştirilen çalışmada bilgisayarlı tomografi (BT) ve manyetik rezonans (MR) görüntülerinde bölütleme için iki aşamalı yapay sinir ağı önerilmiştir. Çalışmada kullanılan iki aşamalı yapay sinir ağının ilk aşamasında özellik çıkarma kullanılmıştır. İkinci aşamasında kümeleme için kendinden organizeli özellik haritalama yapılmıştır. Çalışmada BT görüntülerinde % 97.21 doğruluk elde edilmiştir. Campell ve ark. (1997) medikal görüntü yorumlama amacıyla gerçekleştirdikleri çalışmada, anlamlı alanın sınıflandırılması ile objeleri ortalama % 87 doğrulukla sınıflandırmışlardır.

Hopfield sinir ağı, Sammouda ve ark. (1997) tarafından gerçekleştirilen çalışmada görüntü bölütleme amacıyla kullanılmıştır. Sziranyi ve Csapodi. (1998) ise bölütleme ve doku sınıflandırma işlemi için genetik öğrenme algoritmali hücrel sinir ağı önermişlerdir. Gerçekleştirilen çalışmada %1 hata ile doku sınıflandırma yapılmıştır. Görüntü bölütlemede kullanılan algoritmalarından bazıları da bulanık kümeleme temellidir. Örneğin Masulli ve Schenone 1999 yılında yaptıkları çalışmada, medikal görüntülerin teşhisi için bulanık kümeleme tabanlı görüntü bölütleme algoritmasını önermişlerdir. Çalışmada beyin MR görüntüleri üzerinde gerçekleştirilen bölütleme işleminde %95 doğruluk elde edilmiştir. 2000 yılında Sziranyi ve ark. tamamen paralel hücrel sinir ağına Markov Rasgele Alan Modeli’ ni kullanarak görüntü bölütleme

işlemini gerçekleştirmişlerdir. Çalışmada doku sınıflandırma işlemi için işlemciye gömülü algoritma ile 100 iterasyon 100  $\mu$ s' de yapılmıştır.

Bulanık kümeleme ve model temelli bölütleme teknikleri kullanarak akciğer nodüllerinin tespiti için bir model geliştiren Brown ve ark. (2001), nodüllerin tespitinde % 81' lik bir doğruluk oranı elde etmişler ve 27 nodülün 22' sini doğru olarak belirlemişlerdir. Literatürde pek çok alanda kullanıldığı gibi görüntü bölütlemeye de dalgacık analizi metodu sıklıkla yer almaktadır. Örnek olarak Wang ve Yuan (2001) tarafından önerilen yeni bir yaklaşımda, yüz tanıma için görüntü bölgelere ayrılmış ve ayrılan her bir bölge üzerinde dalgacık analizi uygulanmıştır. Elde edilen dalgacık parametreleri üç katmanlı yapay sinir ağı kullanılarak sınıflandırılmıştır. 60 farklı yüz görüntüsünde % 91.1 doğru sınıflandırma oranına ulaşılmıştır. Bilgisayar destekli teşhis (BDT) sistemlerine bir diğer örnek, Armato ve ark. (2002) nın gerçekleştirdiği bölütleme, üç boyutlu analiz ve özellik çıkarma bloklarından oluşan bir otomatik akciğer nodülü belirleme sistemidir. Bu sistem ile 38 kanserli nodülün 32' si (% 84) doğru sınıflanmıştır.

Literatürde çoğunlukla bölütleme işlemi medikal görüntülerde yapılmış, en çok mamografi görüntülerine uygulanmıştır. Papadopoulos ve ark. 2002 yılında otomatik mikrokalsifikasyon dedeksiyonu için hibrit sinir ağı kullanmışlardır. Gerçekleştirdikleri çalışmada önerilen yapı iki farklı mamografi veri tabanı üzerinde denenmiştir. Belirlilik parametresi (specificity) 0.96 olarak belirlenmiştir. Kurugollu ve ark. (2002) tarafından görüntü bölütleme için kısıtlamalı sinir ağı önerilmiştir. Önerilen yapı gerçek görüntüler üzerinde denenmiştir ve %80 başarı elde edilmiştir. Hibrit sinir ağı yapısı ayrıca Dokur ve Ölmez (2002) tarafından görüntü bölütleme amacı ile kullanılmıştır. Bu çalışmada böbrek ultrason görüntülerinin bölütlenmesinde ve kistlerin tespitinde hibrit sinir ağının performansı test edilmiştir.

Hücrel sinir ağları da literatürde pek çok çalışmada kullanılmıştır. Vilarino ve ark. hücrel sinir ağı kullanarak gerçekleştirdikleri görüntü bölütleme aracını 2003 yılında sunmuşlar ve BT görüntülerine uygulamışlardır. Aynı şekilde Alejo ve ark. (2003), yapay sinir ağlarını kullanarak MR görüntülerinde bölütleme üzerine çalışmışlardır. Çalışmada hem deneysel veriler hem de klinik veriler üzerinde yapılan simülasyonların sonuçları sunulmuştur. 2004 yılında Middleton ve Damper tarafından yine MR görüntülerinde bölütleme işlemi yapay sinir ağı ile aktif kontur modelinin birleştirilmesi ile oluşturulan yeni bir yapı kullanılarak gerçekleştirilmiştir. Önerilen yapı akciğer görüntüleri üzerinde denenmiştir.

Mamografi görüntüsünde mikrokalsifikasyonların tespitinde ise Fu ve ark. (2005) tarafından genel regresyonlu sinir ağı önerilmiştir. Özellik seçimi için destek vektör makineleri kullanılmıştır. Aubry ve arkadaşlarının 2007 yılında akciğer nodülleri üzerine gerçekleştirdikleri çalışmada 25 görüntü için 2 radyologun nodül belirleme performansları üzerine BDT sisteminin etkisi incelenmiştir. BDT sistemi ile birinci radyologun nodül belirlemek için doğruluk oranı % 9.6, ikinci radyologun nodül belirlemek için doğruluk oranı % 23 oranında artmıştır. Ortalama doğruluk % 91.3 olarak elde edilmiştir (Aubry 2007). Karaciğer BT görüntülerinin bölütlenmesi için gerçekleştirilen çalışmada bulanık hücreli sinir ağı kullanımı Shitong ve ark tarafından 2007 yılında sunulmuştur.

Lee ve ark. (2007)'nin gerçekleştirdikleri çalışmada, hastaların akciğer BT'lerinin görüntülenmesinde toplam 210 nodül üzerinde çalışılmış, toplam eşleştirme oranı % 66.7 (140/210) olarak bulunmuş ve eşleştirme oranlarının, akciğer başına toplam nodül sayısının artması ile azaldığı belirlenmiştir. Enquobahrie ve ark.'nın 2007 yılında yaptıkları çalışmada akciğer nodüllerinin aranacağı alanın belirlenmesi, aday nodüllerin seçimi ve yanlış pozitif sayısının düşürülmesini içeren 3 adımlı bir BDT sistemi ile nodüller belirlenmiştir. Çalışılan görüntü veri tabanı nodül büyüklüklerine göre A ve B olmak üzere iki sınıfa ayrılmıştır. A veri tabanı için duyarlılık % 72.1, B veri tabanı için duyarlılık ise % 82.3 olarak elde edilmiştir (Enquobahrie, 2007). Hirose ve ark. (2008) yılında yaptığı çalışmada, 21 hastadan alınan görüntülerin 6 tanesi nodül içermezken 15 tanesi nodül içermektedir. BDT kullanıldığında radyologun nodül belirleme duyarlılığı % 39.5' ten % 81' e çıkmıştır (Hirose, 2008). Hardie ve ark. 2008, adaptif uzaklık temelli eşik metodunu bölütleme için kullanmışlardır. Görüntüye ait 114 özellik çıkarılmış ve daha sonra Fisher diskriminant analiz metodu ile 46 özellik kullanılarak nodüller belirlenmiştir. Önerilen sistemin doğruluğu % 78.1' dir (Hardie, 2008).

Wang ve Lu (2008) tarafından sunulan çalışmada görüntü bölütleme için ihtiyaç duyulan işlem süresini kısaltmak için hızlı bulanık c-ortalamlar kümeleme algoritması kullanılmıştır. Hızlı bulanık c-ortalamlar kümeleme algoritmasında iterasyon sayısını kısaltmak için görüntünün gri histogram tepe değerleri algoritmanın başlangıç değerleri olarak alınmaktadır. Aynı zamanda önerilen algoritma ile geleneksel bulanık c-ortalamlar kümeleme algoritmasına oranla daha iyi bir gürültü eliminasyonu gerçekleştirilmiştir. Xin ve Shu (2008) aynı şekilde bulanık c-ortalamlar kümeleme algoritmasını geliştirerek görüntü bölütlemeye kullanmışlardır.

Geliştirilen algoritmaya ağırlıklandırılmış bulanık c-ortalamlar kümeleme algoritması adı verilmiştir. Renkli görüntüler üzerinde geleneksel bulanık c-ortalamlar kümeleme algoritmasından daha iyi sonuçlara ulaşılmıştır. 2009 yılında Zhang ve Jiang tarafından gerçekleştirilen çalışmada da bulanık c-ortalamlar kümeleme algoritması literatürde yer alan görüntüler üzerinde kullanılmıştır. Aynı yıl Jaffar ve ark. da aynı şekilde bulanık c-ortalamlar kümeleme algoritması kullanarak renkli görüntülerin bölütlenmesi üzerine çalışmışlardır. Yine bulanık c-ortalamlar kümeleme algoritması kullanarak renkli görüntü bölütleme işlemi Huang ve ark. tarafından (2009) gerçekleştirmişlerdir.

İşcan ve ark. (2009) tarafından gerçekleştirilen çalışmada ise 3 farklı medikal görüntü üzerinde çalışılmış ve genel olarak medikal görüntü bölütleme için dalgacık analizi kullanılarak gerçekleştirilmiş artımlı sinir ağı önerilmiştir. Önerilen çalışmanın önemli basamaklarından birini oluşturan paralel hesaplama yöntemi ile ilgili genel bir literatür incelemesi yapıldığında, çeşitli paralel hiyerarşik kümeleme algoritmalarında, farklı paralel hesaplama modellerinin kullanıldığı görülmektedir. 1997 yılında, Tsai ve ark. tarafından, iki farklı hiyerarşik kümeleme algoritması kullanılmıştır. Bu yapı üç boyutlu görüntüler üzerinde denenmiştir.

Kwok ve Constantinides tarafından 1999 yılında sunulan çalışmada ise çeşitli video ve görüntü kodlama sistemlerinde kullanılan “tekrarlama en kısa” algoritması paralel olarak uygulanmıştır. Bu uygulama sonucunda; daha önceki algoritmalarla karşılaştırıldığında;  $128 \times 128$  yada  $150 \times 150$  boyutunda bir görüntüde, bölütlemeye elde edilen görüntü ile istenen görüntü arasında 1.5 dB’ lik bir gürültü farkı olduğu sonucuna ulaşılmıştır.

Czuni ve Sziranyi’ nin (2001) gerçekleştirmiş olduğu çalışmada ise video görüntülerinin bölütlenmesi için paralel hesaplanmış model kullanılmıştır. Bu yöntem sayesinde hızlı ve kararlı sonuçlar alınmıştır. 2010 yılında Gabriel ve ark., paralel hesaplama metodunun biyomedikal veriler üzerine bir uygulamasına yer vermişlerdir. Bu çalışmada biyopsi ile alınan tiroid lezyonlarının yüksek performanslı hücre bölütlemesi üzerinde çalışılmıştır. Bir algoritmanın iki versiyonu paralel olarak doku tabanlı bölütleme yapmak için tiroid görüntüsüne uygulanmıştır.

Ayrıca Kakar ve Olsen’ nin 2009 yılında yaptıkları bu çalışmada, Gabor filtre ile görüntüden özellikler çıkartılmış ve bulanık c-ortalamlar kümeleme algoritması ile bölütleme yapılmıştır. Daha sonra istatistikî özellikler çıkartılarak destek vektör

makineleri ile nodüller belirlenmiştir. Elde edilen doğruluk % 92.47 iken, duyarlılık ise % 89.48' dir.

Yukarıda verilen literatür çalışmasından da görüldüğü gibi, genel olarak bölütlemeye 4 temel yöntem kullanılmıştır. Bu yöntemler şu şekilde sıralanabilir:

- Yapay Sinir Ağları
- Bulanık C-Ortalamalar Kümeleme Algoritması
- Hücresel Yapay Sinir Ağı
- Morfolojik Yöntemler

Bu tez çalışmasında bu yöntemler ile elde edilen en iyi sonuçlar birleştirilerek görüntü bölütlemeye literatürde verilen hata değerlerinin daha aza indirilmesi amaçlanmıştır.

## 2. MATERYAL VE YÖNTEM

Tez çalışmasında, yapay sinir ağları, bulanık c-ortalamalar kümeleme algoritması, hücresel sinir ağı ve morfolojik bölütleme metotları kullanılarak akciğer bölgesi görüntülerinin bölütlenmesi işlemi gerçekleştirilmiştir. Aynı zamanda paralel hesaplama ile bölütlemeye en önemli problemlerden biri olan süre kısaltılmıştır. Bu bölümde detaylı olarak bu metotların teorileri üzerinde durulacaktır.

### 2.1. Yapay Sinir Ağları

Yapay sinir ağları biyolojik sinir sistemini taklit eden bir bilgi işleme sistemidir. Bilgileri insan beyni gibi depolar ve işler. Yapay sinir ağı, giriş bilgisini öğrenen, harici işlemeyi koordine eden ve son çıkışı optimize eden birbiri ile bağlantılı pek çok işleme nöronundan oluşur. Son yıllarda yapay sinir ağları, bilgisayardan, mühendisliğe, teorik modellemeye kadar pek çok alanda geniş bir uygulama yelpazesi göstermektedir. Medikal görüntüleme yapay sinir ağlarının problemlerin çözülmesinde ve optimum çözümün sağlanmasında önemli bir rol oynadığı bir diğer alandır. Literatürde medikal görüntü analizi için sinir ağları ile ilgili pek çok algoritma verilmiştir (Schaefer ve ark., 2008).

Medikal görüntü işlemede yapay sinir ağlarının kullanıldığı alanlar genel olarak şu şekilde sıralanabilir (Schaefer ve ark., 2008):

- (a) Kanser görüntülemeye bilgisayar tabanlı teşhis sistemleri (CAD-Computer Aided Diagnostic)
- (b) Medikal görüntü içerik analizi için bölütleme (segmentasyon) ve kenar belirleme (edge detection)
- (c) Medikal görüntü yapılandırma (registration)
- (d) Medikal görüntü sıkıştırma da kapsayan diğer uygulamalar

Bilgisayar tabanlı teşhis sistemlerinde yapay sinir ağı uygulamaları medikal görüntülemeye hesaplanabilir zekânın temelini oluşturur. Bu sistemler hemen hemen bütün medikal problemler için aynı özelliklere sahiptir (Schaefer ve ark., 2008).


- (1) Sinir ağıları adaptif olarak giriş bilgisini öğrenebilir ve içeriğinin değişmesine göre öğrendiklerini güncelleyebilir
- (2) Sinir ağıları dağıtılmış hesaplama, eğitime ve işleme yoluyla özelliklerle belirlenmiş uygun çözüme yönelerek girişler ve çıkışlar arasındaki ilişkiyi optimize ederler
- (3) Medikal teşhis görsel incelemeye dayanır ve medikal görüntüleme, görselleştirme ve muayeneyi kolaylaştırma açısından çok önemli bir araç sağlar

Medikal görüntü bölütleme ve kenar belirleme bütün medikal görüntüleme uygulamaları için temel ortak bir problemdir. Her içerik analizi ve alansal inceleme (teşhis amaçlı muayene) ilgilenilen alanın bölütlenmesini gerektirir. Bölütleme işlemi kenar belirleme ve diğer tekniklerle gerçekleştirilebilir. Geleneksel yaklaşımlar sınır belirleme (watershed), alan büyütme (region-growing), yılan modelleme (snake modelling) ve kenar dedeksiyonu (contour detection) gibi algoritmaları içerir. Karşılaştırılacak olursa sinir ağlarının öğrenme kabiliyeti ve eğitim mekanizması, medikal görüntülerin sınıflandırılmasında ve segmentasyonun tamamlanmasında geleneksel metotlardan daha iyidir (Schaefer ve ark., 2008).

Medikal görüntülemelerde bir başka temel teknik yapılandırma (registration) dır ve medikal uygulamaların pek çoğunda önemli bir rol oynar. Tipik örnekler yaralanma bakımı (wound care), hastalık belirleme (disease prediction) ve sağlık hizmetleri (health care surveillance) ve görüntülemelerdir. Sinir ağıları yarışmalı öğrenme, kendinden öğrenme ve kümeleme gibi alternatif çözümler sağlamak amacıyla giriş özelliklerini işlemek ve farklı görüntülerle ya da veri setleri arasında mümkün olan en iyi çözümü bulmak için tasarlanabilir (Schaefer ve ark., 2008).

### **2.1.1. Yapay sinir ağlarının genel yapısı**

Bütün yapay sinir ağları nöronlar ve ağırlıklardan oluştuğu için literatürde önerilen yapılar arasında benzerlikler bulunmaktadır. Çeşitlilik farklı öğrenme kurallarından ve bu kuralların bir ağın yapısını nasıl değiştirdiğinden kaynaklanmaktadır. Yapay sinir ağı yapılarının öğrenme yöntemlerine göre sınıflandırılması Şekil 2.1’ de görülmektedir (Elmas, 2007).




**Şekil 2.1.** Yapay sinir ağı yapılarının öğrenme yöntemlerine göre sınıflandırılması (Elmas, 2007)

#### 2.1.1.1. Geriye yayılım algoritması

Geriye yayılım algoritması 1970' lerin başında geliştirilmiştir. Bu ağ karmaşık problemlere doğrusal olmayan çözümler getirebilen en popüler ve en etkili ağ çeşididir (Elmas, 2007).

Genel bir geriye yayılım ağı bir giriş katmanı, bir çıkış katmanı ve en az bir gizli katmandan oluşur. Gizli katman sayısı ve gizli katmandaki nöron sayısı ile ilgili literatürde bir teori mevcut değildir. Geriye yayılım ağlarında katman sayısı ve her katmandaki nöron sayısı dikkatle seçilmelidir. Yapılan çalışmalar karmaşık problemlerin çözülmesinde en az dört katmana ihtiyaç duyulduğunu göstermiştir. Şekil 2.2' de bir geriye yayılım ağı görülmektedir (Elmas, 2007).



**Şekil 2.2.** Bir geriye yayılım sinir ağı (Elmas, 2007)

Giriş verileri geriye yayılım sinir ağına uygulandıktan sonra, ağ boyunca ileri doğru bir hesaplama yapılır ve her bir nöronun çıkışı adım adım belirlenir. En son katmanın çıkışı elde edildikten sonra bu veriler istenen çıkışlarla karşılaştırılır. Elde edilen çıkış ile istenilen çıkış arasındaki farkın türevi kullanılarak delta-bar delta kuralına göre her katman arasındaki ağırlıklar güncellenir yani yeniden hesaplanır (Elmas, 2007).

Bir sinir ağında  $n$ . iterasyon sonucunda  $j$ . çıkış nöronundaki hata sinyali (2.1) eşitliği ile tanımlanır (Haykin, 1999).

$$e_j(n) = d_j(n) - y_j(n) \quad (2.1)$$

Burada  $j$  çıkış düğümü (nöronu) dır.  $j$ . nöron için hata enerjisinin anlık değeri ise  $\frac{1}{2}e_j^2(n)$  olarak tanımlanır. Buna uygun olarak toplam hata enerjisinin anlık değeri  $\varepsilon(n)$ , çıkış katmanındaki bütün nöronlar için  $\frac{1}{2}e_j^2(n)$  hatalarının toplamı olarak tanımlanır. Bu durum (2.2) eşitliği ile ifade edilir (Haykin, 1999).

$$\varepsilon(n) = \frac{1}{2} \sum_{j=C} e_j^2(n) \quad (2.2)$$

Burada  $C$  ağı çıkış katmanındaki bütün nöronlarını içeren bir kümedir.  $N$ , eğitim setindeki örüntülerin toplam sayısını gösterir. Ortalama karesel hata enerjisi, bütün  $n$  değerleri için  $\varepsilon(n)$  değerleri toplanarak ve  $N$  set boyutuna göre normalize edilerek (2.3) eşitliğine göre hesaplanır (Haykin, 1999).

$$\varepsilon_{ort} = \frac{1}{N} \sum_{n=1}^N \varepsilon(n) \quad (2.3)$$


Anlık hata enerjisi  $\varepsilon(n)$  ve ortalama hata enerjisi  $\varepsilon_{ort}$  ağı serbest parametrelerinin bir fonksiyonudur. Burada serbest parametreler ağı ağırlıklarını ve biaslarını ifade eder. Verilen bir eğitim seti için  $\varepsilon_{ort}$  ağı öğrenme performansının bir ölçüsü olarak maliyet fonksiyonunu gösterir. Öğrenme işleminin amacı,  $\varepsilon_{ort}$ ' ı minimize etmek için ağı serbest parametrelerini ayarlamaktır. Bu minimizasyonu yapmak için, en küçük kareler metodunun türevine uygun bir yaklaşım metodu kullanılır. Ağı eğitiminde ya ağırlıkları örüntü örüntü yani her iterasyon sonunda

güncelleyen bir eğitim algoritması veya bütün bir eğitim setinin ağı sunumundan sonra ağı güncelleyen bir eğitim algoritması kullanılır. İlkinde ağırlıkların güncellenmesi ağı sunulan her örüntüden sonra hesaplanan hata değerlerine göre yapılır (Haykin, 1999).

Bütün eğitim seti üzerindeki bireysel ağırlık değişimlerinin aritmetik ortalaması, bütün bir eğitim seti üzerinde  $\varepsilon_{ort}$  maliyet fonksiyonunu minimize etmeyi temel alarak ağırlıkları modifiye eden yaklaşımdan daha doğru bir değişim yaklaşımıdır (Haykin, 1999).

Şekil 2.3' de nöronlarla oluşturulan basit bir ağ yapısı görülmektedir.  $j$ . nöronla ilgili aktivasyon fonksiyonunun girişinde üretilen  $v_j(n)$  girişi şu şekilde ifade edilir (Haykin, 1999):

$$v_j(n) = \sum_{i=0}^m w_{ji}(n) y_i(n) \quad (2.4)$$



Şekil 2.3. j. çıkış nöronu için detaylı sinyal akış grafiği (Haykin, 1999)

Burada  $m$ ,  $j$ . nörona uygulanan toplam girişlerin sayısını verir. Sinaptik ağırlık  $w_{j0}$  (sabit giriş  $y_0 = +1$  için uygundur)  $j$ . nörona uygulanan  $b_j$  biasına eşittir. Bu sebepten  $n$ . iterasyonda  $j$ . nöronun çıkışında görülen  $y_j(n)$  fonksiyon sinyali (Haykin, 1999)

$$y_j(n) = \varphi_j(v_j(n)) \quad (2.5)$$

şeklinde hesaplanır. En küçük kareler metoduna uygun olarak geriye yayılım algoritması  $w_{ji}(n)$  sinaptik ağırlığı için  $\Delta w_{ji}(n)$  düzeltmesini uygular.  $\Delta w_{ji}(n)$  değeri,  $\partial \varepsilon(n) / \partial w_{ji}(n)$  kısmi türevi ile orantılıdır. Zincir kuralına göre, bu gradient yada kısmi türev şu şekilde hesaplanabilir (Haykin, 1999).

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = \frac{\partial \varepsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (2.6)$$

$\partial \varepsilon(n)/\partial w_{ji}(n)$  kısmi türevi bir hassaslık faktörünü gösterir ve sinaptik ağırlık  $w_{ji}$  için ağırlık uzayında aramanın yönünü belirler (Haykin, 1999).

(2.2) eşitliğinin  $e_j(n)$ ' e göre her iki tarafının türevi alınır aşağıdaki ifadeye ulaşılır (Haykin, 1999):

$$\frac{\partial \varepsilon(n)}{\partial e_j(n)} = e_j(n) \quad (2.7)$$

(2.1) eşitliğinin her iki tarafının da  $y_j(n)$ ' e göre türevi alınır (2.8) eşitliği elde edilir (Haykin, 1999).

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad (2.8)$$

(2.5) eşitliği  $v_j(n)$ ' e göre türevlenirse

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \varphi'_j(v_j(n)) \quad (2.9)$$

eşitliği elde edilir. Son olarak (2.4) eşitliğinin  $w_{ji}(n)$ ' e göre türevi alınır (Haykin, 1999)

$$\frac{\partial v_j(n)}{\partial w_{ji}(n)} = y_i(n) \quad (2.10)$$

eşitliğine ulaşılır. Elde edilen kısmi türev sonuçları (2.6) eşitliğinde yerine yazılırsa (2.11) eşitliği elde edilir (Haykin, 1999).

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = -e_j(n) \varphi'_j(v_j(n)) y_i(n) \quad (2.11)$$

$w_{ji}(n)$ ' e uygulanan  $\Delta w_{ji}(n)$  düzeltmesi delta kuralına göre tanımlanır (Haykin, 1999):

$$\Delta w_{ji}(n) = -\eta \frac{\partial \epsilon(n)}{\partial w_{ji}(n)} \quad (2.12)$$

Burada  $\eta$ , geriye yayılım öğrenme algoritmasının öğrenme oranı parametresidir. (2.12) eşitliğinde eksi işaretinin kullanımı ağırlık uzayında eğim düşümünü gösterir. Buna uygun olarak, (2.12)'deki (2.11) eşitliğinin kullanımı (2.13) eşitliğine ulaşılır (Haykin, 1999).

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_j(n) \quad (2.13)$$

(2.13) eşitliğinde  $\delta_j(n)$  eğim düşümü şu şekilde tanımlanır (Haykin, 1999):

$$\delta_j(n) = -\frac{\partial \epsilon(n)}{\partial v_j(n)} = \frac{\partial \epsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = e_j(n) \varphi'_j(v_j(n)) \quad (2.14)$$


(2.14) eşitliğine göre  $j$ . çıkış nöronu için  $\delta_j(n)$  yerel eğimi,  $e_j(n)$  hata sinyalinin üretimine eşittir. (2.13) ve (2.14) eşitliklerinde dikkat edilmesi gereken nokta, ağırlık ayarlamalarının ( $\Delta w_{ji}(n)$ ) hesaplanmasındaki anahtar faktör  $j$ . çıkış nöronundaki hata sinyali  $e_j(n)$ 'dir. Bu içerikte  $j$  nöronunun ağırlık yer aldığı bölümüne bağlı olarak iki durum ortaya çıkar. Birinci durum  $j$ . nöronun çıkış düğümü olmasıdır. Bu durumda ağırlık çıkış düğümlerinden arzu edilen cevaba göre hata sinyali inceleneceğinden  $\Delta w_{ji}(n)$ 'nin de hesaplanması basittir. İkinci durum  $j$  nöronunun bir gizli katman düğümü olmasıdır. Gizli katman nöronlarına doğrudan erişilememesine rağmen, ağırlık çıkışında oluşan hata ile ilgili sorumluluğu paylaşırlar. Asıl soru bu sorumluluğun paylaşılmasında gizli düğümlerin nasıl hata yaptığıdır veya hatanın ne kadarını oluşturduğudur. Bu problem ağırlık üzerinde hata sinyalinin geriye yayılması ile çözülür (Haykin, 1999).

#### 1. Durum: $j$ nöronu çıkış düğümü ise:

$j$  nöronu ağırlık çıkış katmanında yer aldığı ağırlık çıkışında elde edilmesi arzu edilen cevapla desteklenir. Hata sinyalini hesaplamak için Şekil 2.3' de olduğu gibi (2.1) eşitliği kullanılır.  $e_j(n)$  belirlenirken, (2.14) eşitliği kullanılarak  $\delta_j(n)$  lokal eğimi hesaplanır (Haykin, 1999).

## 2. Durum: $j$ nöron gizli düğüm ise:

$j$  nöronu ağız gizli katmanında yer alıyorsa, nöron çıkışı için bir hedeften (elde edilmesi arzu edilen bir çıkıştan) söz edilemez. Buna uygun olarak, bir gizli nöron için hata sinyali, gizli düğüme doğrudan bağlı olan bütün nöronların hata sinyallerinin ifadeleriyle belirlenecektir (Haykin, 1999).



Şekil 2.4.  $j$  gizli düğümüne bağlı  $k$  çıkış nöronu için sinyal akış grafiği (Haykin, 1999)

Böylece geriye yayılım algoritması tamamlanmış olur. Şekil 2.4' de çizilen durum göz önüne alınırsa,  $j$  nöronu ağız gizli düğümü olarak belirtilmiştir. (2.14) eşitliğine göre  $j$ . gizli nöronu için,  $\delta_j(n)$  lokal eğimini (2.15) eşitliği ile yeniden tanımlayabiliriz (Haykin, 1999).

$$\delta_j(n) = -\frac{\partial \varepsilon(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \Rightarrow \delta_j(n) = -\frac{\partial \varepsilon(n)}{\partial y_j(n)} \phi'_j(v_j(n)) \quad (2.15)$$

Burada ikinci terimde (2.9) eşitliği kullanılmıştır.  $\frac{\partial \varepsilon(n)}{\partial y_j(n)}$  kısmi türevini hesaplamak için, aşağıdaki yolu izleriz. Şekil (2.4)' den görülmektedir ki (Haykin, 1999)

$$\varepsilon(n) = \frac{1}{2} \sum_{k \in C} e_k^2(n) \quad (\text{k. çıkış düğümü ise}) \quad (2.16)$$

eşitliği söz konusudur. Eşitlik (2.2)' de  $j$  indisinin yerine  $k$  indisi kullanılmıştır. İkinci durumda,  $j$  indisinin kullanımı gizli katman nöronlarını,  $k$  indisinin kullanımı çıkış

katmanı nöronlarını göstermektedir. (2.16) eşitliği  $y_j(n)$  fonksiyon sinyaline göre türevlenirse (Haykin, 1999);

$$\frac{\partial \varepsilon(n)}{\partial y_j(n)} = \sum_k e_k \frac{\partial e_k(n)}{\partial y_j(n)} \quad (2.17)$$

eşitliği ile elde edilir.  $\frac{\partial e_k(n)}{\partial y_j(n)}$  kısmi türevi için zincir kuralı kullanılır ve (2.17) eşitliği yeniden yazılarak eşdeğeri (2.18) eşitliğine ulaşılır (Haykin, 1999).

$$\frac{\partial \varepsilon(n)}{\partial y_j(n)} = \sum_k e_k \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)} \quad (2.18)$$

Bununla beraber Şekil 2.4' den görüleceği gibi hata (Haykin, 1999);

$$\begin{aligned} e_k(n) &= d_k(n) - y_k(n) \\ e_k(n) &= d_k(n) - \varphi_k(v_k(n)) \quad (\text{k. çıkış düğümü ise}) \end{aligned} \quad (2.19)$$

olarak bulunur. Bu sebepten

$$\frac{\partial e_k(n)}{\partial v_k(n)} = -\varphi_k(v_k(n)) \quad (2.20)$$

dir (Haykin, 1999). Çıkış katmanı çıkışı;

$$v_k(n) = \sum_{j=0}^m w_{kj}(n) y_j(n) \quad (2.21)$$

eşitliği ile hesaplanır (Haykin, 1999). Burada  $m$ ,  $k$  nöronuna uygulanan girişlerin toplam sayısıdır. Burada tekrar edilirse; sinaptik ağırlık  $w_{k0}(n)$   $k$  nöronuna uygulanan bias  $b_k(n)$ ' e eşittir ve uygun giriş +1 değerine sabitlenmiştir. (2.21) eşitliğinin  $y_j(n)$ ' e göre türevi alınırsa

$$\frac{\partial v_k(n)}{\partial y_j(n)} = w_{kj}(n) \quad (2.22)$$

elde edilir (Haykin, 1999). (2.20) ve (2.22) eşitlikleri (2.18)' de yerine yazılırsa; arzu edilen kısmi türeve ulaşılır (Haykin, 1999):


$$\frac{\partial \varepsilon(n)}{\partial y_j(n)} = -\sum_k e_k \varphi'_k(v_k(n)) w_{kj}(n) \Rightarrow \frac{\partial \varepsilon(n)}{\partial y_j(n)} = -\sum_k \delta_k w_{kj}(n) \quad (2.23)$$

Burada, (2.14) eşitliğinde  $j$  yerine verilen  $k$  indisi ile lokal eğim  $\delta_k(n)$ ' in tanımı kullanılır (Haykin, 1999).

Sonuç olarak, (2.23) eşitliği (2.15)' de kullanılarak lokal eğim  $\delta_j(n)$  için geriye yayılım algoritması gerçekleştirilmiş olur ve (2.24) eşitliği ile tanımlanır (Haykin, 1999).

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k w_{kj}(n) \quad (j \text{ gizli düğüm ise}) \quad (2.24)$$

$m_L$  nöronlarına sahip çıkış katmanının geriye doğru sinyal akış grafiği Şekil 2.5' de görülmektedir (Haykin, 1999).



Şekil 2.5. Hata sinyalinin geriye yayılımı için sinyal akış grafiği (Haykin, 1999)

Eşitlik (2.24)' de lokal eğim  $\delta_j(n)$ ' nin hesaplanmasında kullanılan  $\varphi'_j(v_j(n))$  faktörü,  $j$  gizli nöronu ile ilgili aktivasyon fonksiyonuna bağlıdır.  $\varphi'_j(v_j(n))$ ' nin hesaplanmasında kullanılan diğer faktör,  $k$  indislerinin toplamı iki terime bağlıdır. Bu toplam ifadesindeki ilk terim  $\delta_k(n)$ , katmandaki bütün nöronların gizli  $j$  nöronuna doğru hata sinyali  $e_k(n)$ ' nin bilgisine ihtiyaç vardır. Toplam ifadesindeki ikinci ifade  $w_{kj}(n)$  bu bağlantılarla ilgili sinaptik ağırlıkları içerir (Haykin, 1999).

Geriye yayılım algoritması için türetilen eşitlikler şu şekilde özetlenebilir. İlk olarak  $j$  nöronu ile  $i$  nöronunu birbirine bağlayan ağırlığa uygulanan  $\Delta w_{ji}(n)$  düzeltmesi (2.25) eşitliğinde verilen delta kuralı ile tanımlanır (Haykin, 1999):

$$\begin{pmatrix} \text{ağırlık} \\ \text{düzeltme} \\ \Delta w_{ji}(n) \end{pmatrix} = \begin{pmatrix} \text{öğrenme} \\ \text{oranı} \\ \eta \end{pmatrix} \cdot \begin{pmatrix} \text{lokal} \\ \text{eğim} \\ \delta(n) \end{pmatrix} \cdot \begin{pmatrix} \text{j. nöronun} \\ \text{giriş sinyali} \\ y_j(n) \end{pmatrix} \quad (2.25)$$

İkinci olarak, yerel eğim  $\delta_j(n)$   $j$  nöronunun çıkış düğümü ya da gizli düğüm olup olmamasına bağlıdır. Bu durum iki madde ile özetlenebilir (Haykin, 1999):

- ✓ Eğer  $j$  nöronu çıkış düğümü ise,  $\delta_j(n)$ ,  $j$  nöronu ile ilgili  $\varphi'_j(v_j(n))$  türevinin ve  $e_j(n)$  hata sinyalinin çarpımına eşittir.
- ✓ Eğer  $j$  nöronu gizli düğüm ise,  $\delta_j(n)$ ,  $j$  nöronu ile ilgili  $\varphi'_j(v_j(n))$  türevinin ve yeni gizli katman yada çıkış katmanında  $j$  nöronuna bağlanan nöronlar için hesaplanan  $\delta_k$  toplamına eşittir.

#### 2.1.1.2. Aktivasyon fonksiyonu

Çok katmanlı sinir ağındaki her nöron için  $\delta'$  'nin hesaplanması nörona atanan aktivasyon fonksiyonu  $\varphi(\cdot)$  'nin türev bilgisine ihtiyaç duyar.  $\varphi(\cdot)$  'nin türevinin olması için bu fonksiyonun sürekli olması gerekir. Temel anlamda, türevlenebilirlik bir fonksiyonun bunu sağlamasını gerektirir. Çok katmanlı sinir ağlarında kullanılan sürekli olarak türevlenebilir bir aktivasyon fonksiyonuna örnek olarak sigmoidal nonlinear fonksiyonlar verilebilir. Sigmoidal nonlinear fonksiyonlar iki başlıkta özetlenebilir (Haykin, 1999):

**1) Logaritmik sigmoid fonksiyonu:** Logaritmik sigmoid fonksiyonunda sigmoidal nonlinearliğin genel tanımı şu şekilde yapılabilir (Haykin, 1999):

$$\varphi_j(v_j(n)) = \frac{1}{1+e^{-av_j(n)}} \quad a > 0 \text{ ve } -\infty < v_j(n) < \infty \quad (2.26)$$

Burada  $v_j(n)$ ,  $j$  nöronunun lokal alanında indüklenmiştir. Nonlineeriteye göre, çıkışın genliği  $0 \leq y_j \leq 1$  arasındadır. (2.26) eşitliğinin  $v_j(n)$ ' e göre türevlenmesi sonucu (2.27) eşitliğine ulaşılır (Haykin, 1999):

$$\phi_j'(v_j(n)) = \frac{ae^{-av_j(n)}}{[1+e^{-av_j(n)}]^2} \quad (2.27)$$

$y_j(n) = \phi_j(v_j(n))$  ifadesini kullanarak,  $e^{-av_j(n)}$  ifadesi (2.27) eşitliğinde elimine edilebilir ve  $\phi_j'(v_j(n))$  türevi şöyle ifade edilebilir (Haykin, 1999):

$$\phi_j'(v_j(n)) = ay_j(n)[1 - y_j(n)] \quad (2.28)$$

Çıkış katmanında yer alan bir  $j$  nöronu için  $y_j(n) = o_j(n)$  alınır. Bu sebepten  $j$  nöronu için lokal eğimi (2.29) eşitliğindeki gibi ifade edilebilir (Haykin, 1999):

$$\begin{aligned} \delta_j(n) &= e_j(n)\phi_j'(v_j(n)) \\ &= a[d_j(n) - o_j(n)]o_j(n)[1 - o_j(n)] \quad j \text{ nöronu çıkış düğümü ise} \end{aligned} \quad (2.29)$$

Burada  $o_j(n)$ ,  $j$  çıkış nöronundaki fonksiyon sinyalıdır ve  $d_j(n)$  bunun için arzu edilen cevaptır. Bir başka deyişle,  $j$  gizli nöronu için, (2.30) eşitliğindeki gibi ifade edilebilir (Haykin, 1999):

$$\begin{aligned} \delta_j(n) &= \phi_j'(v_j(n)) \sum_k \delta_k w_{kj}(n) \\ &= ay_j(n)[1 - y_j(n)] \sum_k \delta_k w_{kj}(n) \quad j \text{ nöronu gizli düğüm ise} \end{aligned} \quad (2.30)$$

(2.28) eşitliğinden hareketle,  $\phi_j'(v_j(n))$  türevi  $y_j(n) = 0.5$ ' de maksimum değerini,  $y_j(n) = 0$  yada  $y_j(n) = 1.0$ ' da minimum değerini "0" alır. Ağın sinaptik ağırlıklarındaki değişim miktarı  $\phi_j'(v_j(n))$  türevi ile doğru orantılı olduğu için, türevin orta aralıkta olduğu yerlerde sinaptik ağırlıklar en fazla değişir (Haykin, 1999).

**2) Hiperbolik tanjant fonksiyonu:** Bir başka sigmoidal nonlinear fonksiyon hiperbolik tanjant fonksiyonudur. Bu fonksiyonun genel formu aşağıdaki gibi tanımlanabilir (Haykin, 1999):

$$\varphi_j(v_j(n)) = \text{atanh}(bv_j(n)), \quad (a, b) > 0 \quad (2.31)$$

Burada  $a$  ve  $b$  sabittir. Gerçekte, hiperbolik tanjant fonksiyonu yeniden ölçeklenebilir ve biaslanabilir bir fonksiyondur.  $v_j(n)$ ' e göre fonksiyonun türevi (2.32) eşitliği ile tanımlanmaktadır (Haykin, 1999).

$$\begin{aligned} \varphi_j(v_j(n)) &= ab \text{sech}^2(bv_j(n)) \\ &= ab \left[ 1 - \tanh^2(bv_j(n)) \right] = \frac{b}{a} [a - y_j(n)][a + y_j(n)] \end{aligned} \quad (2.32)$$

Çıkış katmanında yer alan bir  $j$  nöronu için, lokal eğim

$$\begin{aligned} \delta_j(n) &= e_j(n) \varphi_j'(v_j(n)) \\ &= \frac{b}{a} [d_j(n) - o_j(n)][a - o_j(n)][a + o_j(n)] \end{aligned} \quad (2.33)$$

eşitliği ile ifade edilir. Bir gizli katmandaki bir  $j$  nöronu için (2.34) eşitliği yazılabilir (Haykin, 1999).

$$\begin{aligned} \delta_j(n) &= \varphi_j'(v_j(n)) \sum_k \delta_k w_{kj}(n) \\ &= \frac{b}{a} [a - y_j(n)][a + y_j(n)] \sum_k \delta_k w_{kj}(n) \quad j \text{ gizli katman düğümü ise} \end{aligned} \quad (2.34)$$

Logaritmik sigmoid fonksiyonu için (2.29) ve (2.30) eşitliği ve hiperbolik tanjant fonksiyonu için (2.33) ve (2.34) eşitliği kullanılarak, aktivasyon fonksiyonunun açık bilgisi gerekmeksizin lokal eğim  $\delta_j$  hesaplanabilir (Haykin, 1999).

### 2.1.1.3. Öğrenme Oranı

Geriye yayılım algoritması, “azalan eğim (steepest descent)” algoritması ile hesaplanan ağırlık uzayındaki minimuma bir yaklaşım sağlar. Öğrenme oranı

parametresi  $\eta$  ne kadar küçük ise bir iterasyondan diğerine oluşacak ağırlık sinaptik ağırlıkları için yapılan değişimlerde o kadar küçük olur. Dolayısıyla ağırlık uzayındaki değişimde yavaş olacaktır. Bu gelişme daha yavaş bir öğrenme oranı değişiminde gerçekleşir. Bir başka deyişle, eğer öğrenme oranını hızlandırmak için öğrenme oranı parametresi  $\eta$  büyük seçilirse, sinaptik ağırlıklardaki hızlı değişim ağda kararsızlığa yani osilasyona neden olacaktır. Kararsızlık tehlikesini önlemek için öğrenme oranının artırılmasının basit metodu (2.13) eşitliğindeki delta kuralını (2.35) eşitliği ile gösterildiği gibi bir momentum sabiti ile modifiye etmektir (Haykin, 1999).

$$\Delta w_{ji}(n) = \alpha \Delta w_{ji}(n-1) + \eta \delta_j(n) y_i(n) \quad (2.35)$$


Burada  $\alpha$  momentum sabiti olarak isimlendirilen bir pozitif sayıdır. Şekil 2.6' da görüldüğü gibi, momentum sabiti  $\Delta w_{ji}(n)$  etrafında gerçekleşen geri besleme döngüsünü kontrol eder. Burada  $z^{-1}$  birim gecikme operatörüdür. (2.35) eşitliği genelleştirilmiş delta kuralı olarak isimlendirilir (Haykin, 1999).

$\alpha$  momentum sabiti nedeniyle oluşan sinaptik ağırlıklardaki örüntü sunumlarının dizisinin etkisini görmek için, (2.35) eşitliği  $t$  indisli zaman serisi ile yeniden yazılabilir.  $t$  indisi, "0" başlangıç zamanından "n" zamanına gider. (2.35) eşitliği, ağırlık düzeltilmesi  $\Delta w_{ji}(n)$ ' deki birinci dereceden türev eşitliği olarak görülebilir.  $\Delta w_{ji}(n)$  için bu eşitlik çözülürse (Haykin, 1999)

$$\Delta w_{ji}(n) = \eta \sum_{t=0}^n \alpha^{n-t} \delta_j(t) y_i(t) \quad (2.36)$$

Burada eşitlik  $n+1$  uzunluğunda bir zaman serisini gösterir. (2.11) ve (2.14) eşitliklerinden,  $\delta_j(n) y_i(n)$  çarpımı  $-\partial \varepsilon(n) / \partial w_{ji}(n)$ ' na eşittir. Buna uygun olarak, (2.36) eşitliği (2.37)' deki gibi yeniden yazılabilir (Haykin, 1999):

$$\Delta w_{ji}(n) = -\eta \sum_{t=0}^n \alpha^{n-t} \frac{\partial \varepsilon(t)}{\partial w_{ji}(t)} \quad (2.37)$$



Şekil 2.6. Momentum sabiti  $\alpha$ 'nın etkisini gösteren sinyal akış grafiği (Haykin, 1999)


### 2.1.2. Yapay Sinir Ağları ile Görüntü Bölütleme ve Kenar Dedeksiyonu

Medikal görüntü bölütleme verilen bir görüntünün homojen özellikli anlamlı alanlara bölünmesi işlemidir. Görüntü bölütleme, klinik analiz sırasında organların ve tümörlerin sınırlarının çizilmesi ve insan dokularının görselleştirilmesinde göz ardı edilemeyecek bir işlem adıdır. Bu sebepten, klinik araştırma, teşhis ve uygulamalarda sağlam, güvenilir ve adaptif bölütleme tekniklerine ihtiyaç duyulduğundan medikal görüntülerin bölütlenmesi çok önemlidir (Schaefer ve ark., 2008).

Kobashi ve ark. (2001) üç boyutlu zaman-akış manyetik rezonans anjiyogram hacim verilerinden kan damarlarının bölütlenmesi için bir metot önermişlerdir. Bu metot 3 adımı içerir: (a) Arka planın çıkarılması, (b) Hacim nicelendirme (quantization) ve (c) bir yapay sinir ağı kullanarak temel öğeleri sınıflandırma.

Bir sınır belirleme bölütleme algoritması kullanarak hacim nicelendirmeden sonra, manyetik rezonans anjiyogram görüntüsündeki temel öğeler kendini gösterir. Bölütleme sonucunu daha fazla geliştirmek için elde edilen temel öğeler kan damarları sınıfı ve yağ sınıfına ayrılmalıdır. Üç özellik ve üç katmanlı ileri beslemeli sinir ağı sınıflandırmaya uygulanır. Yağ ile karşılaştırıldığında kan damarları bir tüpe benzer, dar ve uzundur. İki özellik, yani hacimsellik ve darlık, benzer özellikleri ölçmede kullanılabilir. Çünkü kan damarlarının histogramı şekilsel olarak yağlarınkinden oldukça farklıdır. Üçüncü özellik histogram yoğunluğu bölütlemenin daha fazla gelişmesi için eklenebilir.

İleri beslemeli sinir ağı üç katmandan oluşmaktadır: Giriş katmanı, bir gizli katman ve çıkış katmanı. Tanımlanan sinir ağının yapısı Şekil 2.7' de gösterilmiştir.



Şekil 2.7. Üç katmanlı ileri beslemeli sinir ağı

Görüldüğü gibi, giriş katmanı medikal görüntüden çıkarılan özelliklerin sayısını ile belirlenen üç giriş biriminden oluşmaktadır. Çıkış katmanındaki nöronların sayısı iki sınıflı üreteceği için birdir. Gizli katmandaki nöronların sayısına genellikle deneysel olarak karar verilir. Genel olarak, farklı sayı aralıkları gizli katmanda denenir ve en iyi eğitim sonuçlarına ulaşılan sayı seçilir.

Kobashi ve ark. (2001) tarafından önerilen metotta, üç boyutlu görüntü ve yoğunluğun değerlendirilmesi ile yapay sinir ağı her bir temel öge ile eğitilmiştir. Bu çalışmada yapay sinir ağları manyetik rezonans anjiyogram veri setinden çıkarılan 60 örüntülük veri seti ile eğitilmiştir. Her temel öge kan damarı ya da yağ olarak sınıflandırılmıştır. Çalışmada kan damarları “1”, yağ “0” olarak gösterilmiştir ve üç özelliğin değeri hesaplanmıştır. Bütün bu değerler nöronların ağırlıklarının eğitilmesinde ileri beslemeli sinir ağını beslemektedir. Ayrıca çalışmada 7 veri seti de eğitilen sinir ağının test edilmesinde kullanılmıştır. Bölütleme performansı (2.38)’ de verilen doğruluk değeri ile ölçülmüştür ve çalışmada önerilen metot ile % 80.8 doğruluğa ulaşılmıştır.

$$\text{Doğruluk (\%)} = \frac{\text{Doğru olarak sınıflana temel öğelerin sayısı}}{\text{Temel öğelerin toplam sayısı}} \times 100 \quad (2.38)$$

Kobashi ve ark. (2001) tarafından yapılan çalışmaların dışında bilgisayarlı tomografi (computed tomography-CT) ve manyetik rezonans görüntüleme (magnetic resonance imaging-MRI) ile üretilen görüntüler için pek çok uygulama vardır. Middleton ve Damper (2004) manyetik rezonans görüntülerindeki yapıların bölütlenmesinde sinir ağlarını ve aktif kontur modelini (“yılan modeli”) birleştirmişlerdir. Çalışmanın ana hatları aşağıdaki gibi iki adımda özetlenebilir:

- (1) Perceptron (idrak nöronu) sınır olan yada olmayan her pikselin binary (ikili) sınıflandırılmasını üretmek için eğitilir.
- (2) Sonuçlanan binary görüntüde (kenar noktaları-edge point) sınırlar yılan modellemesi ile birleştirilir.

Lin 2000 yılında gerçekleştirdiği çalışmada medikal görüntü bölütleme için Hopfield sinir ağı (geri beslemeli sinir ağı) ile bulanık c-ortalamlar kümeleme uygulanmıştır. Bu algorithmada, bir eğitime vektörü olarak n-en yakın komşuluktan oluşturulmuş birinci ve ikinci dereceden momentli pikseller uygun alanlar içindeki görüntünün sınıflandırılması amacı için iki boyutlu Hopfield sinir ağına haritalanır.

Dokur ve Ölmez (2003) MR (manyetik rezonans) ve BT (bilgisayarlı tomografi) görüntülerinin bölütlenmesi için bir nicelendirme sinir ağı (quantizer neural network-QNN) önermişlerdir. Nicelendirme sinir ağı yeni bir sinir ağıdır ve genetik algoritma ile eğitilir. MR ve BT baş (kafatası) görüntüleri için bir Kohonen ağı ile çok katmanlı perceptron (ÇKP) karşılaştırmalı olarak incelenmiştir. Çalışmada nicelendirme sinir ağı ile en kısa sürede ve en az nöronla en iyi sınıflandırma performansına ulaşmıştır.

Shen ve ark. (2005) geleneksel FCM kümeleme algoritmasının genişletilmiş halini temel alan bir bölütleme tekniği önermiştir. Çalışmada, komşu piksellerin özelliklerine ve göreceli yerleşime bağımlı komşuluk ilişkisinin bölütleme performansını geliştirdiği görülmüştür ve bu ilişkinin derecesi bir sinir ağı modeli ile optimize edilmektedir. Önerilen tekniğin üstünlüğünü göstermek için bölütlenmiş farklı gürültü seviyelerine sahip gerçek beyin MR görüntüleri bulanık c-ortalamlar tabanlı diğer metotlarla bölütlenmiş görüntülerle karşılaştırılmıştır.

BT ve MR görüntülerini temel alan pek çok uygulama geliştirilmiştir fakat yapay sinir ağları birçok farklı yöntemle adapte edilmiştir. Yapay sinir ağı görüntüdeki gürültü etkisini azaltabilir ve bu sebepten daha sağlam bir bölütleme yapılabilir. Ayrıca yapay sinir ağı farklı dokuları sınıflandırabilir ve onları geleneksel bölütleme tekniklerinin gücünün ötesinde bölütleme gereklerine göre birleştirebilir (Schaefer ve ark. 2008)..

## 2.2. Bulanık C-Ortalamlar Kümeleme Algoritması

Görüntü bölütleme (segmentasyonu) bir parametre uzayında benzer piksellerin gruplanmasıyla tanımlanabilir. Başka bir deyişle, görüntü bölütlemeye görüntüdeki pikseller arasında bir ilişki kurulur. Klasik görüntü bölütleme metodolojisi eşikleme (thresholding), kenar belirleme (edge detection), alan belirleme (region detection) ve bağlantıyı koruma (connectivity-preserving) adımlarını içerir. Bununla beraber bu sistemlerin birçoğu gürültünün ya da komşu yapıların varlığında daha az verimlilik gösterir (Schaefer ve ark., 2008).

Son yıllarda, c-ortalamlar ve k-ortalamlar bölütleme metotlarının kullanımına yönelik yapılan pek çok çalışma, bu algoritmaların hızlı hesaplama ve probleme uyarlanabilirlik bakımından klasik tekniklerden daha verimli olduklarını ortaya çıkarmıştır. Geleneksel katı c-ortalamlar (hard c-means) ve bulanık c-ortalamlar (fuzzy c-means) algoritmaları iki kümeleme tabanlı bölütleme tekniğidir. Katı c-ortalamların aksine, bulanık c-ortalamlar bir sınıfa ait piksellerin belirsizliğinin azaltılmasına izin verir ve böylece geliştirilmiş bir bölütleme sağlar. Ek olarak, değişen üyelik dereceli sınıflar aynı zamanda güncellenir (Schaefer ve ark., 2008).

### 2.2.1. Bulanık c-ortalamlar kümeleme algoritması ile literatürde gerçekleştirilen çalışmalar

Eşikleme metotları göreceli olarak anlaşılır ve doğrudur fakat benzer yoğunluk ve renge sahip farklı objelerin varlığında doğru bir bölütleme yapılması için hassasiyetten uzaktır. Kenar tabanlı metotlar, kontur belirlemeye çok benzer ve hızlıdır. Fakat arka planda gürültü olduğunda hassasiyette azalma olur, aynı zamanda bu metotlar ayrılan konturları birleştirmede başarısızdırlar. Alan belirleme, kararlılık ve uygunluk bakımından eşikleme ve kenar tabanlı metotlara göre daha iyidir. Buna rağmen bu yaklaşımlar verimli bir sonuç elde etmek için daha fazla modifikasyona ihtiyaç duyar. Bağlantıları koruma metotları aktif kontur modeli olarak isimlendirilir. Başlangıç kontur şeklinden başlar ve genişleme tanımlanan maliyet fonksiyonuna göre uygulanır. Ne yazık ki, hesapsal yaklaşım fonksiyonun lokal minimumdan kolaylıkla okunabilir (Schaefer ve ark., 2008).

Son zamanlarda, hesapsal (yapay) zekâ algoritmaları (yapay sinir ağları ve genetik algoritmalar gibi) literatürde oldukça fazla çalışılmaktadır. Bu yeni

algoritmaların keşfedilmesi bölütleme için görüntü özelliklerinin önceden tanımlanan benzerliklerini arayan ve genelleştirme, sağlamlık ve uygulanabilirlik bakımından eksik olan klasik stratejilerden daha iyi olmalarıdır. Yapay zekâ algoritmalarının kullanılması öğrenilen geometrik topoloji ile reel yapılar arasındaki benzerliğe bağlı olarak, benzer özelliklerin gruplanmasını geliştirir (Schaefer ve ark., 2008).

Yapay sinir ağları bölütlenecek bir görüntü için iyi tanımlanmış özelliklere ihtiyaç duymaz (Schaefer ve ark., 2008). Sinir ağları bir modelle eğitilir ve sonra ilerleyerek gerekli parametreleri tanımlarlar. Ahmet ve Farag (1997) sinir ağlarının danışmansız kümeleme yeteneğini temel alan hacim bölütleme metodunu önermişlerdir. Çalışmada, bir özellik örüntüsünün her vokseli türevsel geometrik özelliklerin ölçeklenmiş bir kümesi ile işaretlenmektedir. Bu özellikler iki aşamalı sinir ağı kullanılarak bir alana bağlanmaktadır. İlk aşama kendinden organizeli temel bileşen analizinden oluşmuştur ve burada özellik vektörü yönlendirilmiş bir temel eksene yansıtılır. İkinci aşama, girişleri farklı alanlara kümelemek için kendinden organizeli özellik uzayını kullanır. 2004 yılında Wismüller ve ark. tarafından voksel tabanlı bir görüntü bölütleme geliştirmişlerdir. Wang ve Xu benzer bir çalışmayı yapay sinir ağı kullanarak 2006 yılında gerçekleştirmişlerdir. Iscan ve ark. 2006’ da gerçekleştirdikleri çalışmada, ultrason görüntülerini bölütleyebilmek için otomatik eşikleme kullanarak gelişmiş bir kendinden organizeli ağ kullanmışlardır. Bu metot, klasik metotlardaki eşikleme problemini elimine eder.

Genetik algoritma kendi kendine adapte edilebilen en iyi arama algoritmasıdır. Özellikle nonlinear problemler için uygun çözümün bulunmasında uygundur. Özellikle, Chun ve Yang (1996) alan tabanlı bölütleme için bulanık genetik algoritmayı geliştirdi. Maulik ve Bandyopadhyay (2000) benzerlik özelliğini temel alan kümeleme tabanlı bir genetik algoritma önermişlerdir. Bu çalışmada kümelerin merkezleri gerçel sayılar dizisinden oluşan kromozomlarla kodlanır.

Bulanık c-ortalamlar kümeleme algoritması son yıllarda geniş bir önem kazanmıştır ve uygulamaları görüntü bölütleme ve kümeleme alanlarında yer bulmaktadır. Bulanık c-ortalamlar kümeleme algoritması çoklu sınıflara bölünebilme ve sınıf durumlarının evrimi özelliklerinden dolayı çok önemlidir. Pham 2002’ de gerçekleştirdiği çalışmada üyelik fonksiyonlarındaki penaltı fonksiyonunu entegre ederek geliştirilmiş bir FCM maliyet fonksiyonu önermiştir. Hesaplama zamanını azaltmak için, Chen ve Zhang 2004’ de gerçekleştirdikleri çalışmada maliyet fonksiyonunun komşuluk terimlerinde iki varyans önermişlerdir. Bu varyanslar medyan

filtre ile filtrelenmiş görüntüleri göz önüne alarak verimliliği genişletmektedir. Son zamanlarda bölütlemeyi hızlandırmak için genişletilmiş bulanık c-ortalamlar kümeleme algoritması önerilmektedir. Genişletilmiş bulanık c-ortalamlar kümeleme algoritmasının motivasyonu gri seviye sayısının genellikle görüntü büyüklüğünden daha küçük olması gerçeği ile sağlanır. Bu büyüklük lineer olarak ağırlıklandırılmış toplam görüntüyü formüle edebilir ve bu sebepten her bir pikselin yerine yoğunluk histogramında kümelemeye ulaşılabilir.

Yapay sinir ağları ve genetik algoritmalar ile karşılaştırıldığında, bulanık c-ortalamlar kümeleme algoritmasının bir eğitim aşamasına ihtiyaç duymadığı ve bu sebepten daha kısa sürede daha iyi sonuçlar ürettiği görülür.

### 2.2.2. Bulanık c-ortalamlar kümeleme algoritması

$X = (x_1, x_2, \dots, x_N)$ ,  $C$  görüntüsüne ait  $N$  pikseli bir görüntü olsun.  $x_i$  spektral bir veriyi gösterir. Bulanık c-ortalamlar kümeleme algoritması aşağıdaki maliyet fonksiyonunu minimize eden bir iterasyon prosesidir.

$$f = \sum_{j=1}^N \sum_{i=1}^C u_{ij}^k \|x_j - s_i\|^2 \quad (2.39)$$

Burada  $u_{ij}$ ,  $i$ . kümedeki  $x_j$  pikselinin üyeligidir.  $s_i$ ,  $i$ . küme merkezidir.  $\|\cdot\|$  bir norm ölçüsüdür ve  $k$ , sonuçlanan bölünmenin bulanıklığını gösteren bir sabittir.

Merkezden uzak verili piksellere düşük üyelik değerleri atanırken, pikseller yüksek üyelik değerlerine sahip uygun küme merkezlerine yakın olduğu zaman bu maliyet fonksiyonu global bir minimuma ulaşır. Üyelik fonksiyonları özel bir kümeye ait piksellerle doğru orantılıdır. Burada olasılık görüntü pikseli ile her bağımsız küme merkezi arasındaki uzaklığa bağlıdır. Üyelik fonksiyonu ve küme merkezi (2.40) ve (2.41) eşitliği ile güncellenir.

$$u_{ij} = \frac{1}{\sum_{m=1}^C (\|x_j - s_i\| / \|x_j - s_m\|)^{2/(k-1)}} \quad (2.40)$$

$$s_i = \frac{\sum_{j=1}^N u_{ij}^k x_j}{\sum_{j=1}^N u_{ij}^k} \quad (2.41)$$

Her küme merkezi için bir başlangıç değeri gereklidir. Bulanık c-ortalamlar kümeleme algoritması bir lokal minimizasyon çözümüne yaklaşabilir. İki komşu iterasyon arasındaki fark sabit bir eşik değerinden az değilse bulanık c-ortalamlar için gerçekleştirilen iterasyon bitirilmeyecektir.

Klasik bulanık c-ortalamlar görüntü bölütleme algoritmasının adımları şu şekildedir:

- s için bir başlangıç değeri ata ve küme merkezlerini kaydet.  $j = 0$  olarak ayarla.
- Bulanık bölünme matrisi  $u(j = 0)$  (2.40) eşitliğine göre başlatılır.
- j değerini bir artır ve  $j = j + 1$  yap. (2.41) eşitliğini kullanarak  $s'$  yi hesapla.
- (2.40) eşitliğini kullanarak  $u(j)'$  yi hesapla.
- Durdurma kriterine ulaşıncaya kadar 3. ve 4. adımları tekrarla.

### **2.2.3. Bulanık c-ortalamlar kümeleme algoritması ile ilgili çalışılması gereken konular**

Hesapsal zekâ karmaşık problemlerin çözümünde başarılı bir ilerlemeye sahiptir. Hesapsal zekâ metotlarının uygulamaları geniş bir alana yayılmışken, araştırmacılar ve pratisyenler donanımın otomasyonuna ve verimliliğine dikkat harcamaktadırlar. Hesapsal zekâ metotlarından biri olan bulanık c-ortalamlar kümeleme algoritması pek çok çeşidi vardır. Basit olarak bir aramayı teşkil eden iterasyon prosesi azaltılabilirse bütün bir donanımın hesapsal verimliliği gelişecektir. Bu teknik başarı medikal teşhiste gelişme için yeni fırsatlar yaratacaktır (Schaefer ve ark., 2008)..

İlk olarak şu söylenebilir: Seçilen yapay zekâ algoritması ne kadar verimli olursa, klinik teşhiste o kadar hızlı olabilir. Görüntü bölütleme ne kadar hızlanırsa, bölütlemenin doğru performans gelişimi hedeflenerek algoritmalar daha karmaşık hale getirilebilir. Sistem yüksek doğrulukla kararlı hale geldiği zaman var olan teknikleri temel alan bir otomatik bölütleme düzeninin keşfedilmesine başlanabilir. Böyle bir düzenin gerçekleştirilmesi için örneğin çalışmalar durdurma kriterinin otomatik seçimine yönelebilir (Schaefer ve ark., 2008).

İkinci olarak, bulanık c-ortalamlar kümeleme algoritmasında küme sayısının optimum değerinin ne olacağıdır. Literatürde yapılan çalışmalar küme sayısının artırılmasının görüntü bölütlemeye iterasyon süresini ve hesaplama yükünü ne kadar artırdığını göstermektedir. Bu sebeplerden gelecekteki çalışmalar küme sayısının verilen görüntüye göre optimum olarak belirlenmesine yönelebilir (Schaefer ve ark., 2008).


### 2.3. Hücresel Yapay Sinir Ağı

Hücresel yapay sinir ağı, birbirine bağlı iki boyutlu hücreler ve bu hücreler arasındaki bağlantılardan oluşan özel bir sinir ağı yapısıdır. Hücresel Yapay Sinir Ağı (HYSA) ilk olarak Leon Chua ve Lin Yang tarafından 1988 yılında özel bir dinamik yapay sinir ağı olarak önerilmiştir (Chua ve ark., 1988.a; Chua ve ark., 1988.b). HYSA' yı diğer YSA' lardan ayıran en önemli özellik, iki boyutlu hücrenin bileşenleri arasındaki bağlantı ağırlıklarının değişmez olmasıdır. Bu özellik HYSA' ya geleneksel anlamdaki YSA' lara göre büyük avantaj sağlamaktadır. HYSA' lar aynı zamanda geleneksel YSA yapılarının bazı temel özelliklerini de taşırlar. Bunun yanı sıra iki boyutlu yapılarından dolayı HYSA' lar pratikte görüntü işleme ve örüntü tanıma gibi pek çok güncel konuda uygulama alanları bulmuşlardır (Ceylan, 2009; Chua, 1991, Suzuki ve ark., 1992; Sziranyi ve ark., 1998; Özmen, 2001).

Görüntü işlemede giriş verisi görüntü olduğundan boyut olarak büyük olmasına karşın, HYSA ile çok hızlı şekilde işlem yapılabilir. HYSA' nın görüntü işleme uygulamalarında kullanımında, HYSA' nın hücresel yapısı, işlenecek görüntünün üzerinde hareket ettirilerek görüntü taranır ve sonuç elde edilir. Bu öğrenme metodu sayesinde hem resmi oluşturan her hücresel yapı benzeri parçacık hücre yapısına bir desen olarak tanıtılır hem de resmin ayırt edici özellikleri hücre tarafından öğrenilir. Literatürde HYSA paralel çalışma ve iki boyutlu özelliklerinden dolayı görüntünün bazı ayırt edici özelliklerinin çıkarılmasını sağlayan bir ön işleme elemanı olarak kullanılır. HYSA yapısında işlem yapılacak olan görüntü verisindeki her nokta bir nörona karşılık gelir. HYSA' lar, görüntü işlemenin yanı sıra hareket dedeksiyonu (motion detection) uygulamalarında da kullanılmaktadır (Ceylan, 2009; Özmen, 2001).

### 2.3.1. HYSA yapısı

Hücresel yapay sinir ağının temelini hücreler arasındaki komşuluk ilişkisi oluşturur. Şekil 2.8’ de HYSA yapısı içindeki komşuluk ilişkisi bir hücre için gösterilmiştir. Bu ağ yapısında, bir hücre belli komşuluklarla tanımlanmış sinirlerden meydana gelmiştir (Bal, 2002; Ceylan, 2009; Özmen, 2001).



Şekil 2.8. HYSA ve hücre komşuluk ilişkisi gösterimi (İki boyutlu (3x3)) (Ceylan, 2009)

Görüntü işlemede HYSA’ nın kullanım amacı, girişine uygulanan giriş görüntüsünü kullanarak ağdan beklenen hedefe uygun biçimde bir çıkış görüntüsü elde etmektir. HYSA ile elde edilen çıkış görüntüsünün her bir pikseli  $-1$  veya  $+1$  değerindedir. Ağın girişine sunulacak görüntü renkli yada gri seviye olabileceği gibi “.bmp” formatında da olabilir. Parametrelerin başlangıç değerlerinin düzgün seçilmesi durumunda HYSA’ ya sunulan görüntü için elde edilen hedef görüntü her zaman kararlı sabit bir durum noktasına yaklaşır (Özmen, 2001).


Görüntü işlemede çok kullanılan yapay zekâ algoritmalarından biri olan HYSA’ da giriş görüntüsü dinamik bir algorithmadan geçirildikten sonra çıkış görüntüsü elde edilir. HYSA algoritmasının iteratif bir yapıya sahip olmasından dolayı istenilen kararlı çıkış görüntüsü elde edilene kadar iterasyon işlemi devam eder. HYSA ile ilgili bir başka avantaj da HYSA’ ların komşuluk ilişkisine dayanan yapılarının sayesinde tüm devrelerde daha kolay uygulanabilmesidir (Ceylan, 2009; Özmen, 2001).

HYSA' yı diğer YSA' lardan ayıran özellikler üç madde altında özetlenebilir (Güzeliş 1995):

- İki boyutlu bir ızgaraya benzer hücreler sadece kendi komşuları ile ilişkilidirler.
- Bağlantı ağırlıkları tüm hücreler arasında aynıdır.
- Her bir hücre için hücre dışı bağlantı ağırlıkları da aynıdır.

### 2.3.1.1. HYSA hücre yapısı

HYSA' yı oluşturan her bir hücre ağırlıklı toplama yapan doğrusal bir giriş katmanı, doğrusal ve dinamik ara katman ve  $n$  parçalı (genellikle üç parçalı) orijine göre simetrik bir çıkış katmanından oluşur (Ceylan, 2009; Özmen, 2001). Şekil 2.9' da HYSA' yı oluşturan hücrelerden sadece bir tanesi için dinamik yapı gösterilmiştir.




Şekil 2.9. Hücrenin dinamik yapısı (Ceylan 2009)

HYSA ile ilgili hücre yapısının ilk ortaya çıkışı devresel bir gösterim ile belirlenmiştir. Devredeki hücrelerin her biri doğrusal ve doğrusal olmayan dirençler, kapasiteler ile akım ve gerilim kontrollü kaynaklardan oluşmaktadır.

$M \times N$  lik HYSA,  $M$  satır ve  $N$  kolondan oluşur. Böyle bir yapıda  $i$ . satır ve  $j$ . sütuna  $(i, j)$  hücresi adını vereceğiz ve  $H(i, j)$  olarak ifade edeceğiz. Burada herhangi bir  $H(i, j)$  hücresinin  $r$  komşuluğu aşağıdaki gibi tanımlanabilir (Chua ve ark., 1988.a).

$$K_r(i, j) = \{H(k, l) | \max(|i - k|, |j - l|) \leq r, 1 \leq i \leq M; 1 \leq j \leq N\} \quad (2.42)$$

(2.42) eşitliğinde  $r$  komşuluğu gösteren pozitif bir tamsayıdır ve bu tamsayı verilen bir hücrenin kendisinden ne kadar uzaklıktaki hücreler tarafından direkt olarak etkileneceğini gösterir. Şekil 2.10’ da, bir hücre için  $r = 1$  ve 2 komşulukları gösterilmiştir. Şekilden de görüleceği gibi yapı içerisinde  $r = 1$  komşuluğunda her bir hücre sadece çevresindeki hücrelerden etkilenmekteyken  $r=2$  komşuluğunda her bir hücre kendinden iki hücre uzaklıklardaki hücrelerden de etkilenmektedir (Ceylan, 2009; Chua ve ark., 1988.a ve b).




**Şekil 2.10.**  $r=1$  ve  $r=2$  komşuluk için HYSA’nın hücre ilişkileri (Ceylan, 2009)

$r = 1$  komşuluğunda genellikle “ $3 \times 3$ ”,  $r = 2$  komşuluğu söz konusu olduğunda ise “ $5 \times 5$ ” komşu hücre mevcuttur. Genelleştirilirse, bir  $r$  derece komşuluğu  $(2r + 1) \times (2r + 1)$  tane hücreden oluşur. HYSA’ da hücreler aynı zamanda simetri özelliğine de sahiptir. Burada şu şekilde tanımlanabilir:  $H(k, l) \in Kr(i, j)$  ise  $H(i, j) \in Kr(k, l)$  dir. Şu ana kadar verilen bütün gösterimlerde hücreler karesel olarak sıralanmıştır, fakat aynı komşuluk ilişkileri içerisinde karesel olmayan hücre sıralanmaları da mevcuttur. Örnek olarak altıgen sıralanmış bir hücre gösterimi Şekil 2.11’ de görülmektedir (Ceylan, 2009; Özmen, 2001).



çıkış kontrol gerilimi ( $v_{y_{kl}}$ ) tarafından geri beslemeli olarak kontrol edilen komşu hücrelerin iki katı sayıda doğrusal gerilim kontrollü akım kaynakları. Burada  $I_{xy}(i,j;k,l) = A(i,j;k,l)v_{y_{kl}}$  ve  $I_{xu}(i,j;k,l) = B(i,j;k,l)v_{u_{kl}}$  ifadeleri  $I_{xy}(i,j;k,l)$  ve  $I_{xu}(i,j;k,l)$  gerilim kontrollü akım kaynaklarının karakteristiklerini  $H(k,l) \in K_r(i,j)$  komşuluğu altında göstermektedir. Her bir hücre içerisinde doğrusal olmayan tek eleman gerilim kontrollü akım kaynağıdır ve kısmi doğrusal bir  $I_{yx} = (1/R_y)f(v_{x_{ij}})$  fonksiyonuna sahiptir. Şekil 2.13,  $f(\cdot)$  fonksiyonunu göstermektedir, bu fonksiyon kısmi doğrusal çıkış karakteristiğine sahiptir (Ceylan, 2009; Özmen, 2001).



Şekil 2.13. Kısmi doğrusal çıkış karakteristiği (Ceylan 2009)

Bu devredeki kısmi doğrusal fonksiyonları elektriksel devre olarak gerçekleyebilmek için işlemsel yükselteçlerin (OPAMP) kullanımını gerekir (Ceylan, 2009; Özmen, 2001).

Kirchhoff gerilimler ve akımlar yasası uygulanarak bu hücre devrenin eşdeğeri aşağıda gösterildiği gibi, kolayca türetilebilir (Ceylan, 2009; Özmen, 2001).

Eğer  $M$  hücrenin satır sayısını,  $N$  de hücrenin sütun sayısını gösteriyorsa;  $1 \leq i \leq M$ ;  $1 \leq j \leq N$  değişkenlerinin kullanılması durumunda devrenin durum denklemi (2.43) eşitliğinde verildiği gibi olacaktır (Ceylan, 2009; Özmen, 2001).

$$C \frac{dv_{x_{ij}}(t)}{dt} = -\frac{1}{R_x} v_{x_{ij}}(t) + \sum_{H(k,l) \in K_r(i,j)} A(i,j;k,l) v_{y_{kl}}(t) + \sum_{H(k,l) \in K_r(i,j)} B(i,j;k,l) v_{u_{kl}}(t) + I \quad (2.43)$$

Devrenin çıkış denklemi aşağıdaki gibi

$$v_{y_{ij}}(t) = \frac{1}{2} (|v_{x_{ij}}(t) + 1| - |v_{x_{ij}}(t) - 1|) \quad (2.44)$$

eşitliği ile ifade edilir.

Devrenin giriş denklemi, gerilim kaynağı cinsinden

$$v_{u_{ij}}(t) = E_{ij} \quad (2.45)$$

eşitliği ile tanımlanır.

Başlangıç şartları ve parametrik kabuller aşağıda (2.46)-(2.49) eşitliklerinde görüldüğü gibi alınarak devre analiz edilebilir (Ceylan, 2009; Özmen, 2001):

$$|v_{x_{ij}}(0)| \leq 1 \quad 1 \leq i \leq M; 1 \leq j \leq N \quad (2.46)$$

$$|v_{u_{ij}}| \leq 1 \quad 1 \leq i \leq M; 1 \leq j \leq N \quad (2.47)$$

$$A(i, j; k, l) = A(k, l; i, j) \quad 1 \leq i \leq M; 1 \leq j \leq N \quad (2.48)$$

$$C > 0, R_x > 0 \quad (2.49)$$

2.3.1.2 alt başlığında verilmeye çalışılan bilgiler üç madde ile şu şekilde özetlenebilir (Ceylan, 2009; Özmen, 2001)

- Bir hücresel yapay sinir ağını oluşturan tüm merkezi hücreler için aynı devre yapısı ve aynı devre elemanı değerleri söz konusudur.
- Bir merkezi hücre, tanımlanan  $r$  komşuluğunda  $(2r + 1)^2$  sayıda komşu hücreye sahiptir. Bu yapının haricinde kalan hücreler “sınır hücresi” olarak tanımlanır.
- Elektriksel devre şeması ile tanımlanan HYSA yapıları doğrusal olmayan bir denklem takımı ile ifade edilirler.

Çıkış geri beslemesinin etkisini ifade eden  $A(i, j; k, l)$  parametresi ile girişin kontrol etkisini ifade eden  $B(i, j; k, l)$  parametreleri hücresel yapay sinir ağındaki bir hücrenin dinamiklerini teşkil eder. Bu parametrelerden  $A(i, j; k, l)$  “Geri Besleme Ağırlık Katsayısı” ve  $B(i, j; k, l)$  “Giriş Ağırlık Katsayısı” olarak isimlendirilir.  $A$  geri

besleme ve  $B$  giriş ağırlık katsayıları, 1. dereceden bir komşuluk için matris formatında (2.50) eşitliğinde gösterildiği gibi tanımlanabilir (Ceylan, 2009; Özmen, 2001).

$$A = \begin{bmatrix} a_1 & a_2 & a_3 \\ a_4 & a_5 & a_4 \\ a_3 & a_2 & a_1 \end{bmatrix} \quad B = \begin{bmatrix} b_1 & b_2 & b_3 \\ b_4 & b_5 & b_4 \\ b_3 & b_2 & b_1 \end{bmatrix} \quad (2.50)$$

### 2.3.2. HYSA eğitimi

HYSA' da için literatürde verilen öğrenme metotları geleneksel geri yayımlı YSA' larda kullanılan metotlarla benzerlik gösterir. Genellikle HYSA' nın eğitiminden danışmanlı öğrenme algoritmaları kullanılır (Ceylan, 2009; Özmen, 2001).

Danışmanlı öğrenme algoritmaları, (2.51) eşitliği ile verilen formülasyonlardaki  $v$  girişi ve  $d$  istenen kalıcı çıkışı ile verilen bilinmeyen bir  $d = f(v)$  fonksiyonuna, en az hata veren bir hücresel yapay sinir ağı ile ulaşma temeline dayanır (Ceylan, 2009; Özmen, 2001).

$$\{(v_1, d_1), (v_2, d_2), \dots, (v_n, d_n)\} \quad (2.51)$$

Minimum değerine ulaşılmaya çalışılan hata fonksiyonu, gerçek ve hedeflenen çıkışlar arasındaki fark ile ölçülür. Tüm örnek örüntüler için hesaplanan hata değeri, her bir örüntünün hatalarının toplamına eşittir. Ağın çıkışı  $y(t)$ , hedeflenen çıkış  $d(t)$  ile ifade edilirse; her bir giriş için ağın çıkışı ile hedeflenen çıkış arasındaki hata,  $\varepsilon_i(w)$  ;

$$\varepsilon(w) = \sum_{i=1}^n \varepsilon_i = \sum_i \sum_{k,l} (y_{k,l}^i(\infty) - d_{k,l}^i)^2 \quad (2.52)$$

eşitliği ile tanımlanır (Ceylan, 2009; Özmen, 2001).

Şu ana kadar verilen formüller dikkate alınırsa, ikili kararlı durum çıkış modunda çalıştırılan tam kararlı HYSA' nın durum çıkışlarının danışmanlı öğrenilmesi, sınırlı bir optimizasyon problemi olarak ele alınabilir. Burada hatası minimuma indirgenen örüntülerin hatalarının toplamı  $\varepsilon(w)$  ağın toplam hatasıdır. Hedeflenen çıkışa ulaşılma koşulları ise belirli sınırlamaları ortaya koyar (Ceylan, 2009; Özmen, 2001).

(2.52) eşitliğinde verilen toplam hata hesaplamasında kullanılacak eşitlikten sabitler atılarak;

$$\varepsilon(w) = \sum_{k,l} y_{k,l}^i(\infty)(y_{k,l}^i(\infty) - d_{k,l}^i) = \sum_{(k,l,i) \in D^+} y_{k,l}^i(\infty) - \sum_{(k,l,i) \in D^-} y_{k,l}^i(\infty) \quad (2.53)$$

şeklinde toplam hata ifadesi yeniden yazılabilir (Ceylan, 2009; Özmen, 2001).

(2.54) eşitliklerindeki  $D^+$  ve  $D^-$  terimlerini aşağıdaki gibi tanımlanabilir (Ceylan, 2009; Özmen, 2001).

$$\begin{aligned} D^+ &= \{(k, l, i) | y_{k,l}^i(\infty) = -d_{k,l}^i = 1\} \\ D^- &= \{(k, l, i) | y_{k,l}^i(\infty) = -d_{k,l}^i = -1\} \end{aligned} \quad (2.54)$$

HYSA eğitimini anlayabilmek için (2.43) eşitliğinde verilen  $v_{x_{ij}}(t)$   $t$  değerinin sıfır olduğu kabul edilir ve aşağıdaki formülasyon değişiklikleri yapılırsa;

$$\begin{aligned} x_{k,l}^i(t) &= C \frac{dv_{x_{ij}}(t)}{dt} \\ w_{k,l;\bar{k},\bar{l}} &= A(i, j; k, l) \\ y_{\bar{k},\bar{l}} &= v_{y_{kl}}(t) \\ z_{k,l;\bar{k},\bar{l}} &= B(i, j; k, l) \\ u_{\bar{k},\bar{l}} &= v_{u_{kl}} \\ x_{k,l}^i(\infty) &= \sum_{(\bar{k},\bar{l}) \in n(k,l)} w_{k,l;\bar{k},\bar{l}} \cdot y_{\bar{k},\bar{l}} + \sum_{(\bar{k},\bar{l}) \in n(k,l)} z_{k,l;\bar{k},\bar{l}} \cdot u_{\bar{k},\bar{l}} + I = [Y_{k,l}^i]^T \cdot w \end{aligned} \quad (2.55)$$

eşitliği elde edilir (Ceylan, 2009; Özmen, 2001).

Hücrenin kalıcı durumdaki toplam girişi (2.56) eşitliği ile ifade edilebilir (Ceylan, 2009; Özmen, 2001).

$$Y_{k,l}^i = \left[ [y_{k,l}^i]^T [u_{k,l}^i]^T I \right]^T \quad (2.56)$$

(2.56) ile verilen denklemdeki anlık kararlı durum çıkışlarını ve hücre girişlerini;

$$y_{k,l}^i = [y_{k-1,l-1}^i(\infty) + y_{k+1,l+1}^i(\infty) \quad y_{k-1,l}^i(\infty) + y_{k+1,l}^i(\infty) \quad y_{k-1,l+1}^i(\infty) + y_{k+1,l-1}^i(\infty) \quad y_{k,l-1}^i(\infty) + y_{k,l+1}^i(\infty) \quad y_{k,l}^i(\infty)]^T \quad (2.57)$$

$$u_{k,l}^i = [u_{k-1,l-1}^i + u_{k+1,l+1}^i \quad u_{k-1,l}^i + u_{k+1,l}^i \quad u_{k-1,l+1}^i + u_{k+1,l-1}^i \quad u_{k,l-1}^i + u_{k,l+1}^i]^T \quad (2.58)$$

şeklinde ifade edilebilir (Ceylan, 2009; Özmen, 2001).

HYSA' da ardışıl öğrenmeyi gerçekleştirebilmek için (2.55) eşitliğinde verilen bağlantı ağırlık vektörü  $w$  (bu ağırlık vektörü bir ileriki adımda ağ çıkışının hesabında kullanılır) (2.59)' de görüldüğü gibi hesaplanabilir (Ceylan, 2009; Özmen, 2001).

$$w(n+1) = [w(n) - e(n)\Re[w(n)]] \quad (2.59)$$

(2.59) ile verilen eşitlikteki  $\Re[w(n)]$ , (2.60) eşitliğinde tanımlanmıştır. Bu  $\Re[w(n)]$  fonksiyonu, hataların toplamının minimum olmasını sağlayan bir hesaplama içerir ve matematiksel olarak aşağıdaki gibi

$$\Re[w(n)] = (\sum_{(k,l,i) \in D^+} Y_{k,l}^i(n) - \sum_{(k,l,i) \in D^-} Y_{k,l}^i(n)) \quad (2.60)$$

hesaplanır (Ceylan, 2009; Özmen, 2001).

(2.59) eşitliğindeki  $e(n)$  ise, çoğunlukla küçük bir sayı olarak seçilen öğrenme oranıdır (Ceylan, 2009; Özmen, 2001).

## 2.4. Morfolojik Bölütleme Metotları

Bütün görüntü işleme işlemlerinde tartışılan konu nesne ayrıntılarının daha iyi nasıl tanımlanacağıdır. Bir görüntüde uygun yerel özellikler bulunarak ilgilenilen obje, diğer objelerden ve arka plandan ayrılabilir. Bu işlemde sonra ki, adım ise bireysel piksellerin objeye ait olup olmadığının belirlenmesidir. Bu operasyon “**bölütleme**” olarak adlandırılır ve sonuçta ikili bir görüntü oluşturulur. Bir piksel görüntüde; nesneye aitse bir, değilse sıfır olarak değer alır. Bölütleme sonucunda hangi pikselin hangi nesneye ait olduğu anlaşılır. Başka bir ifadeyle görüntü bölütleme, ilgili görüntü yapısının zeminden ve diğer görüntü bileşenlerinden ayrılması işlemidir. Bölütleme işlemi, bir görüntüyü bir veya birden fazla karakteristiğe uygun olarak bölgelere ayrılmasıdır. Bölütleme özellikle medikal görüntü işlemede önemli bir araçtır ve çoğu uygulamada faydalanılmaktadır (Gonzalez, 2004).

Bölütleme aşaması, görüntü işlemede uygulanan ilk işlemdir ve bu işlemin amacı görüntüden anlamlı nesneler oluşturmaktadır. Bunun anlamı, ilgili her nesnenin şekli, bir görüntü nesnesine dayalı olarak gösterilmelidir.

Bölütleme işlemi birçok basamaktan oluşur. Örneğin piksel tabanlı bölütleme tekniğinde sadece bireysel piksellerin gri seviyeleri incelenir. Bölge bazlı metotta ise gri değerleri büyük alanlarda incelenir. Eşikleme yaygın olarak bilinen bölge bölütleme metotlarından biridir. Bu teknikte bir eşikleme değerine göre görüntüde bu değer altında olan pikseller bir bölgeye, eşik ve üstü değerler bir bölgeye ayrılır. Birçok eşikleme yöntemi mevcuttur. Bunlar “global eşikleme” ve “yerel eşikleme” adı altında incelenebilir. Global eşikleme gri seviyeli histogramı baz alır. Yerel eşiklemede ise yerel özelliklere göre işlem yapılır. Üçüncü olarak dinamik eşikleme; bölütleme yöntemleri arasında sayılabilir (Gonzalez, 2004).

Kümeleme algoritmaları da bölge bölütleme yöntemleri arasında sayılabilir. Bu yöntemde ise benzer özelliklere sahip pikseller kümelenerek, piksel kümeleri oluşturulur. Böylece ilgilenilen bölgenin kümeleme ile pikselleri (aynı özelliklere sahip) bir araya getirilerek karakteristiği çıkarılabilir. Diğer bir bölge bölütleme yöntemi ise bölge büyümesi (region growing) yani komşu pikselleri bir araya aynı segmente getirerek; tabii ki özellikleri yeteri kadar aynı ise yapılan bir yöntemdir. En son olarak kenar bazlı segmentasyonda ise kenarlar belirlenir ve takip edilir. Kenar bazlı bölütleme algoritması, objenin sınırlarını bulmada kullanılır. Bu yöntemde kullanılan üç metot vardır (Gonzalez, 2004):

1. Gradient Operatörleri
2. Grafik araştırması
3. Kontur (sınır) takibi

Bu yöntemlerin hepsindeki sınırlama ise sadece lokal özelliklere dayanmalarıdır. Piksel tabanlı teknikte lokal komşuluğa bakılmamaktadır, kenar bazlı teknikte ise süreksizlik noktalarına bakılmaktadır. Bölge bazlı teknikte ise alanların homojenliği önemlidir. Bu durumda geometrik şekli önemli olan bir nesnede model bazlı bölütleme uygulanabilir (Gonzalez, 2004).

Görüntü işlem; bölütleme, özellik çıkarma, görüntü ölçümü vb işlemlerde önemlidir. Bazı uygulamalarda anatomik bölgelerin örneğin kemik, kas ve kan damarları gibi çıkarılması gerekli iken; bazı uygulamalarda ise patolojik bölgeler yani kanserli yada doku deformasyonu olan bölgelerin çıkartılması gerekebilir, yada sadece bir yapının çıkarılması gerekebilir. (örneğin akciğer MR görüntüsünden akciğer tümörünün çıkarılması gibi.)

Genelde görüntü bölütlenmesinde MR, BT, PET, SPEBT, ultrasound vb. görüntü tiplerinden biri kullanılır.

#### **2.4.1. Piksel tabanlı bölütleme**

Nokta tabanlı yada piksel tabanlı bölütleme tekniği; bölütlemeye en basit yaklaşımdır. Bu teknik basit olmasına rağmen kompleks bölütleme tekniklerinden önce uygulandığı zaman sonuç daha iyi olmaktadır (Gonzalez, 2004).

Bu teknikte görüntü belli bir özelliğe göre ayrılıyorsa ve görüntüyü histogramı aldığında histogramda iki pik değeri oluşuyorsa; görüntü belli bir eşik değerine göre ayrıldığında iki pik arasındaki değerlerin sıfır olmaması istenir. Böyle bir durumda ne yapılmalıdır? Görüntüde arka plan ve nesne piksel değerleri belli bir eşikle ayrılmış ise bölütlemeye bu eşikleme değerine göre ayırım yapılabilir. Böylece arka plan ve nesne tam olarak ayrılabilir. Bunun için çeşitli eşikleme yöntemleri mevcuttur. Bazıları görüntü histogramına dayanırken; diğerleri lokal özellikleri; görüntüdeki sapma, lokal gradient (eğim) e dayanır (Gonzalez, 2004).

Genellikle öğrenilen yaklaşım global eşiklemedir. Tüm görüntüde bir eşikleme değeri belirlenirse buna “global eşikleme” adı verilmektedir. Eğer görüntüde lokal özelliklere göre eşikleme yapılırsa; örneğin lokal ortalama gri değerine göre yapılırsa

“lokal eşikleme” adını alır. Lokal eşikleme her piksel için bağımsız alınırsa buda “adaptif(dinamik) eşikleme” adını alır (Gonzalez, 2004).

### **a. Global Eşikleme**

Global eşikleme de iki model (şekil) bir histogramda arka plan (background) ve obje ayrı ayrı belirtildiği varsayılırsa belli bir eşikleme değeri bu histograma göre belirlenir ve değerler bu eşikleme ile belirlenir (Gonzalez, 2004).

$$g(x,y)=\begin{cases} 1 & \text{if } (x,y) > T \\ 0 & \text{if } (x,y) < T \end{cases} \quad (2.61)$$

Değeri 1 olan pikseller nesneyi gösterirken; değeri 0 olan pikseller arka plan olarak tanımlanır.

Farklı global eşikleme yöntemleri de mevcuttur. Örneğin sınıflama yöntemine göre arka plan piksellerinin yanlış sınıflanması, ya da obje pikselinin arka plan pikseli olarak tanımlanmış olması yani yanlış sınıflanmasının hatası hesaplanır.

Görüntü bölütlemeye global bölütleme yöntemi hızlı ve basittir. Ama görüntüde nesne ve arka plan arası farklılık az ise ve arka plan parlaklığı önemli ölçüde değişiyorsa yada parlaklık belli bir düzen içinde değilse uygulanması zordur (Gonzalez, 2004).

### **b. Lokal Eşikleme**

Bir çok uygulamada; global eşikleme bir histogramdan elde edilemez veya bir eşik değeri tüm görüntü için iyi sonuç vermeyebilir. Örneğin arka plan piksel değerleri sabit değilse global eşikleme iyi bir sonuç vermeyecektir (Gonzalez, 2004).

Lokal eşiklemede görüntü alt görüntülere ayrılarak her bir parça için ayrı eşikleme değeri belirlenir yada piksel yoğunlukları her pikselin komşuluğuna göre belirlenir (Gonzalez, 2004).

Geleneksel metotlara göre görüntü önce dikdörtgen şeklinde alt parçalara ayrılır. Bu parçalar hem nesneyi hem de arka planı içine alacak şekilde olmalıdır. Her parça için ayrı ayrı eşik değeri bimodel histogramdan çıkarılır. Ama eğer histogram düzenli değilse yan parçaların eşik değerlerine göre bir eşikleme belirlenir. Böylece tüm

görüntünün doğru eşikleme değeri her piksel için son olarak tekrar belirlenir (Gonzalez, 2004).

Eşikleme değeri için farklı metotlar kullanılabilir. Örneğin; ortalama pozitif standart sapma, ortalama en büyük ve en küçük değeri, lokal yoğunluk eğim büyüklüğü gibi (Gonzalez, 2004).

Genel olarak lokal eşiklemenin maliyeti; global eşiklemeye göre daha fazladır. Ama değişken arka plandan nesne çıkarımı ve küçük bölgelerin belirlenmesinde daha yararlıdır (Gonzalez, 2004).

### c. Görüntü işleme ve eşikleme

Çoğu medikal görüntü düşük zıtlık içerir. Bir görüntüdeki farklı yapılara bağlı olarak eşiklemeyi histograma göre elde etmek zor olabilir. Önileme yöntemleri görüntü işlemede görüntü histogram şeklinin çıkarılmasında yardımcı olabilir. Bu tekniklerden biri olan düzgünleştirme (smoothing) tekniği ortalama veya medyan filtreleri kullanılarak yapılabilir. Ortalama filtresinde; her pikselin değeri lokal komşuluk içerisindeki piksel değerlerinin ortalamasına göre değiştirilir. Medyan filtresinde ise komşuluğuna göre medyan değerleri hesaplanır ve değiştirilir. Medyan filtresinin, ortalama filtreden farkı kenarları yani bölge sınırlarını bulanıklaştırmamasıdır. Medyan filtresi histogramda pik değerlerini keskinleştirerek eşiklemeye yardımcı olur (Gonzalez, 2004).

Yaygın olarak kullanılan bir başka smoothing filtresi ise gaussian filtresidir ve aşağıdaki eşitlikle formülize edilir (Gonzalez, 2004):

$$g[i,j] = \exp\left[-\frac{(i^2+j^2)}{2\alpha^2}\right] \quad (2.62)$$

Ayırma parametresinin değeri ne kadar büyük olursa düzgünleştirme o kadar iyi olur. Digital görüntülerde ise  $n \times n$  lik bir konvolüsyon maskesi uygulanır.

Medyan filtresi ile uç (aşırı) keskinleştirme yapılarak da ön işlem yapılabilir. Daha çok mikroskopik kan hücre görüntülerinde faydalı sonuç vermektedir. Bu metotda ise  $n \times n$  bir filtre ile bir en büyük ve en küçük belirlenmektedir. Bu keskinleştirme işlemi medyan filtresi uygulandıktan sonra yapılmaktadır (Gonzalez, 2004).

9×9 medyan filtre gürültü azaltma, 3×3 extramum keskinleştirme, 5×5 medyan filtre eşikleme için kullanılır (Gonzalez, 2004).

#### 2.4.2. Kenar tabanlı bölütleme

Piksel tabanlı bölütleme sonuçlarına göre bir görüntüdeki nesneler farklı gri seviyelerine sahipse; karanlık olan nesneler daha küçük, aydınlık olan nesneler daha büyük hale gelmektedir. Eğer görüntüdeki nesne ve arka planın gri değerleri düzgün dağılım gösteriyorsa ya da tüm nesneler aynı gri değerine sahipse piksel değerlerinin ortalaması alınarak eşikleme yapılabilir. Ya da bu yaklaşım için her nesneye farklı eşikleme uygulanmalıdır (Gonzalez, 2004).

Kenar tabanlı bölütleme tekniğinde ise kenar pozisyonları birinci dereceden derivasyon yada sıfır çaprazlamasına göre belirlenir. Bir görüntüdeki kenar yada sınır lokal piksel yoğunluğunun gradient (eğim)' ne göre belirlenmektedir. Eğim bir tür görüntünün 1. dereceden kaynağı (derivation) olarak tanımlanan bir yaklaşımdır.

Bir görüntüde büyüklük ve eğim aynı anda gösterilebilir. Büyüklük, lokal yoğunluk değişkeni olarak tanımlanır. Yön ise en büyük lokal eğim ile gri seviyeli olarak gösterilebilir (Gonzalez, 2004).

Laplacien operatörü de kenar belirlemede kullanılan bir yöntemdir (Gonzalez, 2004).

$$\nabla^2 f(x, y) = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2} \quad (2.63)$$

Gradient ve Laplacian'e dayanan kenar belirleme metotlarının çoğu gürültüye karşı duyarlıdır. Bazı uygulamalarda bu yüzden önce düzgünleştirme(smoothing) işlemi gerçekleştirilir, daha sonra kenar operatörleri kullanılır (Gonzalez, 2004).

Kenar tabanlı bölütleme tekniğinde, farklı gri seviyelerine sahip ve farklı parlaklıklara sahip bir görüntü üzerinde çalışılmıştır. Nokta yayılım fonksiyonu  $h(x)$  vasıtasıyla bir basamak kenar ile bulanıklaştırma sağlanarak nesne kenarları modellenenir. Görüntüdeki nesnenin parlaklığı ile orijindeki kenar için aşağıdaki gibi bir denklem yazılabilir (Gonzalez, 2004).

$$g(x) = g_0 \int_{-\infty}^x h(x) dx \text{ ile } \int_{-\infty}^{\infty} h(x) dx = 1 \quad (2.64)$$

Arka plan yoğunluğu ise parabolik bir varyasyonla modellenenebilir (Gonzalez, 2004).

$$b(x) = b_0 + b_1 x + b_2 x^2 \quad (2.65)$$

Total yoğunluk ise aşağıdaki gibi formulize edilebilir (Gonzalez, 2004).

$$g(x) = g_0 \int_{-\infty}^x h(x) dx + b_0 + b_1 x + b_2 x^2 \quad (2.66)$$

Birinci ve ikinci dereceden türevleri ise (Gonzalez, 2004):

$$g_x(x) = g_0 h(x) + b_1 + 2b_2 x \quad (2.67)$$

$$g_{xx}(x) = g_0 h_x(x) + 2b_2 \quad (2.68)$$

Ve maksimum noktası etrafında nokta yayılım fonksiyonunu  $h(x)$  parabol olarak ifade edersek;  $h(x) \approx h_0 - h_2 x^2$  (Gonzalez, 2004).

$$g_x(x) \approx g_0 h_0 - g_0 h_2 x^2 + b_1 + 2b_2 x \quad (2.69)$$

$$g_{xx}(x) = 2g_0 h_2(x) + 2b_2 \quad (2.70)$$

İkinci dereceden türevde ise kenarlar sıfır olarak bulunmaktadır. Bu yüzden kenar pozisyonundaki tahmini eşikleme,  $x_b$ , aşağıdaki gibi formülize edilebilir (Gonzalez, 2004).

$$x_b \approx \frac{b_2}{g_0 h_2} \quad (2.71)$$

Son denkleme göre (Gonzalez, 2004):

1. Kenar tabanlı bölütleme gösteriyor ki arka plan yoğunluğunda eğim olsa bile kenar pozisyonunda eşikleme yoktur.
2. Kenar tabanlı bölütleme gösteriyor ki yoğunluk tabanlı bölütlemeye olduğu gibi kenar yoğunluğu  $g_0$  ile eşikleme yoktur.

3. Kenar tabanlı bölütleme da sadece arka plan yoğunluğu ile eşikleme yapılmaktadır. Buradan da anlaşılmaktadır ki eşikleme değeri nesnenin parlaklığı ile ters orantılıdır. Sadece nesnedeki zayıf zıtlık olan yerlerde nesneyi etkilemektedir. Yani eğim kenarların bulanık olduğu yerlerde daha büyüktür.

Kenar tabanlı bölütleme yöntemi ardışıl bir yöntemdir. Piksel tabanlı ya da bölge tabanlı bölütleme yöntemlerinde olduğu gibi paralel işlem yapılamamaktadır. İlk önce eğimine göre maksimum nokta görüntü satır satır taranarak belirlenir. Başlangıç noktasına gelene kadar bu tarama devam eder. Başlangıç noktasına gelindiğinde bir sonraki maksimum nokta bulunur ve tarama devam eder (Gonzalez, 2004).

Kenar bazlı teknikler hızlıdır ve görüntü hakkında öncelikli bir bilgiye ihtiyaç duymaz. Tek dezavantajı nesneyi tam olarak kapatamamasıdır. Bu yüzden bir son işleme ihtiyaç vardır. Kenar linklerini belirleme yaklaşımı ise ayrı büyüklük ve kenar yönüne göre belirlenir. Ama bu teknik güvenilir değildir ve işlem karmaşası fazladır (Gonzalez, 2004).

### 2.4.3. Bölge tabanlı bölütleme

Bölge tabanlı bölütleme teknikleri, piksel tabanlı bölütleme tekniklerine göre daha farklıdır. Bu teknikte bir piksel nesne olarak algılanır ve sadece gri değerine bakılarak devam edilir. Eşikleme de önemli olan piksel yoğunlukları arasındaki farklar iken; bu yöntemde ise grup olarak piksellerin benzerlikleri önemlidir. Yani piksel gruplarının benzer yoğunlukta olmaları önemlidir. Bunun anlamı küçük bir alan nesnenin pikseli olarak sınıflandırılır (Gonzalez, 2004).

Eğer bölütleme işlemi için orijinal görüntü yerine özellik görüntüsü kullanıyorsa, özellik sadece bir piksel ile gösterilmez. Çok az da olsa komşu pikseller kullanılan operatörün maske boyutuna bağlı olarak özellik görüntüsünde bulunabilir. Özellikle kenarlarda maske yararlı pikselleri de hesaplayamayabilir. Bu durumda maske boyutu kenarlara göre sınırlandırılmalıdır. Bu sınırlandırma çok önemlidir. Görüntüde arka plan ve nesnenin ayrılması zaten hesaplamadan sonra olmaktadır (Gonzalez, 2004).

Bu işlemin tek bir adımda çözülemeyeceği açıktır. Bölütleme ve özellik çıkarma işlemleri birlikte yürütülerek yapılabilir. İlk önce özellik çıkarımı ile işe başlanır. Daha sonra bölütleme işlemi yapılır ve ikinci defa özellik çıkarma uygulanır. Tekrar yapılan

bölütleme işlemi sonucuna göre nesne belirlemede kullanılacak olan maske boyutu sınırlandırılır. Bu sınırlandırma işleminde merkez pikselin yeri önemlidir. Sonucu geliştirmek için durağan bir görüntü elde edene kadar bölütleme ve özellik çıkarımı işlemlerine devam edilir (Gonzalez, 2004).

“Region growing” işlemi “Region merging” yani bölge birleştirme olarak da adlandırılır. İlk önce belli bir piksel yada çekirdek dediğimiz piksel grubu alınır. Bu grup belli özellikleri ile benzer yapıdadırlar. İkinci basamakta ise benzer özellikte olup olmadığına bakmak için komşu pikseller test edilir. Benzer özellikte ise yapıya katılır. Bu yöntemin sonucu homojenlik kriterine çok güçlü bir şekilde bağlıdır. Eğer başlama noktası yanlış seçildiyse veya seçilen pikseller bölgeye uygun değilse sonuç olarak obje farklı parçalara katılmış olabilir. Bu yöntemin avantajı ise bölgeler arası bağlantı üretir ve doğru başlanırsa obje ayrımı tam olarak yapılabilir (Gonzalez, 2004).

Bölge birleştirmede ilginç yöntemlerden biri de “ hill climbing ” olarak tanımlanır (Gonzalez, 2004).

$$s(x, y) = \frac{f(x_0, y_0) - f(x, y)}{d(x_0, y_0, x, y)} \quad (2.72)$$

Bu sayede kalsifikasyonların etrafı bir kontur ile çevrilir. İlk önce kenarlar belirlenir. 16 yöne en büyük pikselden hareketle kenarlar bulunur. Sonra bu kenarlar çekirdek olarak belirlenir ve bölge birleştirme yöntemine geçilir. Bu yöntem düşük zıtlıktaki mikrokalsifikasyon hücrelerine mamografilerde uygulandığında başarılı sonuç vermiştir. Buradaki avantaj bir eşikleme değerine gerek olmamasıdır. Çünkü kenarlardan merkeze doğru tarama yapar (Gonzalez, 2004).

Bölge birleştirme yöntemi daha çok beyin yüzeyinin belirlenmesinde, kan damarlarının çıkarılmasında, kardiyak görüntüsünden karıncıkların segmente edilmesinde kullanılmaktadır (Gonzalez, 2004).

Bölge tabanlı bölütlemede diğer bir metot ise piramit bağlama(linki) olarak adlandırılır. Burada ilk önce her pikselin dörtlü komşuluğu hesaplanır ve ortalaması bir üst piramide yazılır. Daha sonra bu piksellere düzgünleştirme yada yumuşatma işlemini uygulanır. Bu işlemden sonra piramit link yöntemi ile segmente edilir (Gonzalez, 2004).

### 3. PARALEL BÖLÜTLEME UYGULAMALARI

Paralel hesaplama mantığı geliştirilerek literatürde yer alan dört adet bölütleme algoritması akciğer BT görüntülerinin bölütlenmesi için kullanılmıştır. Tezde, bölütlemelerde kullanılan morfolojik yöntemler ve yapay zekâ algoritmalarının bölütleme yeteneklerinin incelenmesi ve paralel hesaplama ile bu algoritmaların sonuçlarının aynı anda elde edilerek süre kazanımı sağlanması amaçlanmıştır. Tez çalışmasındaki hedeflerden biri de kullanıcıya bu dört algoritma ile bir görüntü üzerinde aynı anda işlem yapabilme ve en iyi algoritmayı belirleme olanağının sunulmuş olmasıdır. Geçekleştirilen paralel hesaplama algoritması, algoritmaların sonuçlarını doğru bulunan piksel sayısı bakımından karşılaştırarak sonuçları kullanıcıya sunmaktadır. Aynı zamanda gerçekleştirilen çalışmalarda bölütleme sonuçları da geliştirilmiştir.

Tezde 10 adet sağlıklı ve 20 adet “akciğer kanseri” tanısı konmuş (hastalıklı) akciğer görüntüsü üzerinde bölütleme uygulanmıştır. Çalışmada ilk olarak, her algoritma için bu verilerin kullanılması ile elde edilen bölütleme sonuçları “Dört Algoritmanın Tek Tek Çalıştırılması ile Elde Edilen Bölütleme Sonuçları” başlığı altında sunulmuştur. Sonuçlar her algoritma için detaylı bir şekilde tartışılarak üstünlükleri ve dezavantajları incelenmiştir. Daha sonra bu dört bölütleme algoritması paralel hesaplama mantığı ile ikili, üçlü ve dördü çalıştırılmıştır. Elde edilen sonuçlar “Paralel Bölütleme” başlığı altında detaylı olarak sunulmuş ve tartışılmıştır. Çalışmada gerçekleştirilen bütün algoritmalar Matlab yazılım paketi kullanılarak oluşturulmuştur.


#### 3.1. Tez Çalışmasında Kullanılan Veriler

Daha önce doktora çalışmasında (Ceylan, 2009) kullanılmış olan 30 adet BT görüntüsü (Başkent Üniversitesi, Konya Uygulama ve Araştırma Hastanesi, Radyoloji Bölümü) bu tez çalışmasında gerçekleştirilen algoritmaların doğruluk analizlerinde kullanılmıştır. Görüntüler uzman radyolog doktorun gözetimi altında alınmıştır ve her bir görüntü kesiti tek tek incelenerek nodülün bulunduğu BT kesiti kaydedilmiştir (Ceylan, 2009).


Etiketlenen 30 görüntüden 10 görüntü sağlıklı (iyi huylu nodül içeren) ve 20 görüntü ise hastalıklı (kötü huylu nodül içeren) dir. Görüntüleri alınan hastaların 25

tanisi ise erkektir, bunlara ait görüntülerden 8 tanesi sağlıklı, 17 tanesi hastalıklıdır. Ayrıca 5 tanesi kadındır ve sözkonusu görüntülerden 2 tanesi sağlıklı, 3 tanesi hastalıklıdır. Hasta yaş ortalaması 64' tür ve hastaların yaş dağılımları 52 ile 77 arasındadır. Çalışmada kullanılan akciğer BT görüntülerinde yer alan nodüllerin en küçüğünün çapı 15 mm, en büyüğünün çapı ise 130 mm' dir. Görüntüler sayısal ortamda 752x752 piksel boyutunda ve gri seviyededir (Ceylan, 2009).

Kullanılan görüntülerden rastgele seçilmiş sağlıklı ve hastalıklı akciğer BT görüntüleri, sırasıyla Şekil 3.1 ve Şekil 3.2' de yer almaktadır.



**Şekil 3.1.** İyi huylu nodüller içeren akciğer BT görüntüleri (a) 2 nolu hastaya ait görüntü (b) 5 nolu hastaya ait görüntü (c) 6 nolu hastaya ait görüntü (d) 9 nolu hastaya ait görüntü



**Şekil 3.2.** Kötü huylu nodüller içeren BT görüntüleri (a) 12 nolu hastaya ait görüntü (b) 15 nolu hastaya ait görüntü (c) 17 nolu hastaya ait görüntü (d) 20 nolu hastaya ait görüntü

### 3.2. Sonuçların Değerlendirilmesinde Kullanılan Değerlendirme ve Doğruluk Kriterleri

Tez çalışmasında bölütleme için gerçekleştirilen algoritmalar sonucunda elde edilen görüntüler doğru piksel sayısı kullanılarak elde edilen doğruluk kriterine göre değerlendirilmiştir. Bölütleme sonucu elde edilen görüntü ve hedef görüntü binary formata sahip olduğundan bu kriterde iki görüntü her noktadaki piksel değeri karşılaştırılarak gerçekleştirilmektedir. Doğruluk, doğru bulunan piksellerin sayısı görüntüyü oluşturan toplam piksel sayısına bölünerek elde edilen oranın yüzdesinin alınması ile elde edilmektedir. Doğrulukların hesaplanması (3.1) eşitliğine göre yapılmıştır.

$$\text{Doğruluk} = \frac{\text{Doğru bulunan piksel sayısı}}{\text{Toplam piksel sayısı}} \times 100 \quad (3.1)$$

Çalışmada gerçekleştirilen algoritmaların sonuçları bu kriterle göre incelenmiş ve çizelgelerde doğru piksel sayısı, doğruluk ve süre için elde edilen değerler sunulmuştur.

Ayrıca YSA ve BCO için optimum parametre değerlerinin belirlenmesinde kullanılan eğitim ve test hatası aşağıdaki formüle göre hesaplanmıştır. (3.2) eşitliğinde

$$\text{Hata (\%)} = \frac{\sum_{j=1}^m \sum_{i=1}^k |t(i, j) - a(i, j)|}{\text{toplam piksel sayısı}} \times 100 \quad (3.2)$$


Burada  $t(i, j)$  bölütlenme sonucunda elde edilmesi istenen görüntü ve  $a(i, j)$  ise yapay zekâ algoritması sonucunda elde edilen çıkış görüntüsüdür.

### 3.3. Dört Algoritmanın Tek Tek Çalıştırılması ile Elde Edilen Bölütleme Sonuçları

Tez çalışmasında ilk olarak bölütleme için kullanılan dört algoritma ile paralel hesaplama olmaksızın akciğer BT görüntülerinde bölütleme gerçekleştirilmiştir. Başka bir deyişle, bölütleme işlemi her algoritma için ayrı ayrı yapılmıştır. Elde edilen sonuçlar her algoritma için ilerleyen dört alt bölümde detaylı olarak sunulmuştur. Sonuçlar doğru piksel sayısı ve doğruluk bakımından incelenmiş ve 30 BT görüntü verisi (10 sağlıklı ve 20 hastalıklı akciğer BT görüntüsü) için çizelgelerde sunulmuştur.

### 3.3.1. Morfolojik algoritma ile elde edilen bölütleme sonuçları


Tez çalışmasında morfolojik algoritma kullanılarak akciğer BT görüntüleri üzerinde bölütleme gerçekleştirilmiştir. Gerçekleştirilen bölütleme algoritmasına ait blok gösterim Şekil 3.3’ de görülmektedir. Şekilden görüleceği üzere morfolojik bölütleme algoritmasında hedef görüntüsü kullanılmamaktadır. Hedef görüntüsü sadece doğruluk hesabında yani elde edilen bölütleme sonucu ile istenilen sonuç arasındaki hatanın hesaplanmasında kullanılmıştır.




Şekil 3.3. Morfolojik bölütleme prosedürü için blok gösterim

Burada  $752 \times 752$  piksel boyutundaki görüntü morfolojik bölütleme algoritması ile bölütlenir ve bölütleme sonucu yine  $752 \times 752$  piksel boyutlarında bir görüntü elde edilir. Algoritmanın girişinde sadece bölütlenecek görüntü verilir. Algoritma için herhangi bir eğitim prosedürü söz konusu değildir. Morfolojik bölütleme algoritması sonucu elde edilen görüntü ile elde edilmesi istenilen görüntü karşılaştırılarak doğruluk hesabı yapılır. Böylece istenilen sonuca ne kadar yaklaşıldığı tespit edilmiş olur.

Şekil 3.3’ de verilen morfolojik bölütleme algoritması için adım adım bulunan sonuçlar ve akış diyagramı sırasıyla Şekil 3.4 ve 3.5’ de görülmektedir. Morfolojik bölütleme algoritmasında giriş görüntüsüne sırasıyla genişletme, kenar bulma, doldurma ve tümleyen alma işlemleri uygulanır. Elde edilen görüntü hedefle karşılaştırılır ve hata hesaplanır.



Şekil 3.4. Morfolojik bölütleme algoritması akış diyagramı




Şekil 3.5. Morfolojik bölütlemeye (a) Giriş görüntüsü, (b) Genişletme sonucu, (c) Kenar belirleme sonucu (d) Elde edilen görüntü

Morfolojik bölütleme algoritması ile 10 sağlıklı ve 20 hastalıklı akciğer BT görüntüsü için elde edilen sonuçlar Çizelge 3.1’ de sunulmuştur. Çizelgeden de görüleceği gibi ortalama doğru piksel sayısı 519372 ve doğruluk % 91.84 olarak bulunmuştur (Toplam piksel sayısı  $752 \times 752 = 565504$  pikseldir). En yüksek doğruluk olan % 97.84, 10 nolu hastaya ait sağlıklı akciğer BT görüntüsü ile elde edilmiştir. En düşük doğruluk değeri olan % 85.3 ise 8 nolu hastaya ait sağlıklı akciğer BT görüntüsü ile bulunmuştur.

**Çizelge 3.1.** Morfolojik bölütleme algoritması ile elde edilen sonuçlar

| VERİ            | Doğru bulunan<br>piksel sayısı | Doğruluk (%) |
|-----------------|--------------------------------|--------------|
| N1              | 540709                         | 95,61        |
| N2              | 516075                         | 91,26        |
| N3              | 520896                         | 92,11        |
| N4              | 500127                         | 88,44        |
| N5              | 547559                         | 96,83        |
| N6              | 528816                         | 93,51        |
| N7              | 519987                         | 91,95        |
| N8              | 482403                         | 85,3         |
| N9              | 549350                         | 97,14        |
| N10             | 553290                         | 97,84        |
| H1              | 503519                         | 89,04        |
| H2              | 500404                         | 88,48        |
| H3              | 518156                         | 91,63        |
| H4              | 488287                         | 86,34        |
| H5              | 523092                         | 92,5         |
| H6              | 495908                         | 87,69        |
| H7              | 533544                         | 94,34        |
| H8              | 497316                         | 87,94        |
| H9              | 547328                         | 96,78        |
| H10             | 513899                         | 90,87        |
| H11             | 491975                         | 86,99        |
| H12             | 510998                         | 90,36        |
| H13             | 523915                         | 92,64        |
| H14             | 529833                         | 93,69        |
| H15             | 518097                         | 91,62        |
| H16             | 543746                         | 96,15        |
| H17             | 526181                         | 93,04        |
| H18             | 518911                         | 91,77        |
| H19             | 503832                         | 89,09        |
| H20             | 532998                         | 94,25        |
| <b>ORTALAMA</b> | <b>519372</b>                  | <b>91,84</b> |

Morfolojik bölütleme algoritması ile 30 BT görüntüsünün testi sonucunda elde edilen doğruluk değerleri Çizelge 3.1’ de detaylı olarak verilmiştir. Ayrıca elde edilen görüntülere örnek olması açısından N5 test verisi için elde edilen bölütleme sonucu Şekil 3.6’ da verilmiştir. Çizelge 3.1’ den görüleceği gibi N5 test verisi için bölütleme sonucu elde edilen görüntüde doğru piksel sayısı 547559 ve doğruluk %96,83 olarak elde edilmiştir (Toplam piksel sayısı  $752 \times 752 = 565504$  pikseldir).




**Şekil 3.6.** (a) N5 test verisi, (b) Bölütleme ile elde edilmesi hedeflenen görüntü ve (c) N5 test verisi için morfolojik bölütleme ile elde edilen bölütleme sonucu

### 3.3.2. Yapay sinir ağları ile elde edilen bölütleme sonuçları

Tez çalışmasında görüntü bölütleme amacı ile yapay sinir ağı algoritması kullanılmıştır. Ancak yapay sinir ağı yapısı kendi başına bölütleme için yeterli sonucu üretilmediğinden, sonucu geliştirmek adına görüntülere ağa sunulmadan önce 2-boyutlu ayırık dalgacık dönüşümü 1, 2 ve 3 seviye olarak uygulanmıştır. Eğitim amacı ile yapay sinir ağına verilen giriş ve hedef görüntüleri 3.seviyede dalgacık dönüşümü sonucu

96 × 96 piksel boyutuna düşürülmüştür. Böylece giriş verisinin boyutu azaltılacağından yapay sinir ağı için eğitim ve test süresi de kısaltılmıştır.


Çalışmada kullanılan bütün görüntüler 752\*752 piksel boyutlarındadır. Gerçekleştirilen dalgacık dönüşümü ve adım adım elde edilen sonuçları gösteren blok diyagramı Şekil 3.7’ de görülmektedir. Şekil 3.7’ de verilen görüntüler eğitim giriş görüntüsü için uygulanan 2-boyutlu dalgacık dönüşümü sonuçlarıdır. Aynı işlem hedef görüntüsü için de uygulanmıştır. Şekil 3.7’ deki görüntüler her seviyede elde edilen yaklaşım katsayılarının çizdirilmesi ile elde edilmiştir. Yapay sinir ağına giriş olarak da 2-boyutlu dalgacık dönüşümü ile elde edilen yaklaşım katsayıları verilmiştir. 2- boyutlu dalgacık dönüşümünün 1, 2 ve 3 seviyelerinde kullanılması ile elde edilen sonuçlarda bölütleme hatasını yükseltecek derecede özellik kaybı olmadığı görülmüştür. Literatürde özellik çıkarma amacıyla kullanılan pek çok algoritma (temel bileşen analizi, Fourier dönüşümü vb.) vardır. Ancak 2 boyutlu dalgacık dönüşümü en az özellik kaybını veren algoritma olduğu için tez çalışmasında tercih edilmiştir.



Şekil 3.7. Dalgacık dönüşümü ile özellik çıkarma ve elde edilen görüntüler


2-boyutlu dalgacık dönüşümü ile boyutu azaltılan giriş ve hedef görüntüsü yapay sinir ağına sunulmuştur. Gerçekleştirilen yapıya ait blok diyagram Şekil 3.8’ de görülmektedir. Şekil 3.8’ den de görüleceği gibi ilk olarak 752\*752 piksel boyutlarındaki eğitim giriş ve hedef görüntüsü 2-boyutlu dalgacık dönüşümü ile azaltılmaktadır. Şekilde görüntü boyutları dalgacık dönüşümünün 3 seviyeli olarak

uygulanması durumu için verilmiştir. Bu nedenle  $96 \times 96$  piksellik eğitim giriş ve hedef görüntüleri YSA' ya sunulmuştur. Eğitim giriş verisi için elde edilen sonuca ters dalgacık dönüşümü uygulanarak  $752 \times 752$  piksel boyutlarına getirilmiştir. Bu sonuç eğitim hedef verisinin  $752 \times 752$  piksel boyutlarındaki orijinal hali ile karşılaştırılarak eğitim için doğruluk değeri hesaplanmıştır. Böylece YSA için eğitim aşaması sonlanmış olur. Test aşaması için bu görüntülerle eğitilen YSA' ya yine 2-boyutlu dalgacık dönüşümü ile azaltılan  $96 \times 96$  piksellik test verisinin giriş görüntüsü sunulmuştur. Test giriş görüntüsü için elde edilen bu sonuç ters dalgacık dönüşümü uygulanarak  $752 \times 752$  piksel boyutlarına getirilmiştir. Son olarak, elde edilen test sonuç görüntüsü, test verisinin  $752 \times 752$  piksellik hedef görüntüsü ile karşılaştırılarak doğruluk hesabı yapılır. Test aşamasında çalışmada kullanılan 30 akciğer BT görüntüsü için 3 seviyede uygulanan dalgacık dönüşümü ile gerçekleştirilen yapıların her birinde test işlemi gerçekleştirilmiş ve elde edilen test doğruluk sonuçları kaydedilmiştir.



**Şekil 3.8.** Dalgacık dönüşümü-Yapay sinir ağı sistemine ait blok gösterim

Şekil 3.8' de gerçekleştirilen yapıdaki yapay sinir ağı algoritmasına ait akış diyagramı Şekil 3.9' da verilmiştir. Görüldüğü gibi önce eğitim verisinin giriş ve hedef görüntüleri ile sinir ağı eğitilmiştir, sonra test verisinin giriş ve hedef görüntüleri sunulmuştur. Şekil 3.9' da verilen akış şemasının Şekil 3.8' de blok diyagramı görülen yapının sadece YSA bloğunu oluşturduğu dikkate alınmalıdır.



Şekil 3.9. Yapay sinir ağı algoritmasına ait akış şeması

Yapay sinir ağında eğitim için en önemli parametrelerden olan gizli düğüm sayısının optimum değerinin bulunması için 1 seviyeli dalgacık dönüşümü ve YSA kaskat yapısı (YSA1) kullanılarak gerçekleştirilen deneysel çalışmalar sonucu elde edilen değerler Çizelge 3.2’ de sunulmuştur. Çizelgeden de görüleceği gibi en düşük test hatası değerini verdiği için optimum gizli düğüm sayısı 24 olarak bulunmuştur. Çizelge 3.3 ve Çizelge 3.4’ de de sırasıyla optimum öğrenme oranı ve momentum sabiti değerleri görülebilir. Çizelgelerden de görüleceği gibi optimum öğrenme oranı 0.7,

optimum momentum sabiti ise 0.9 olarak bulunmuştur. Optimum değerlerin belirlenmesinde ilk olarak test hatasının düşük olduğu noktalar ele alınır. Sonra bu noktalar arasında eğitim hatası ve sürenin de düşük olduğu optimum yer belirlenmeye çalışılır. Örneğin gizli düğüm sayısının belirlenmesinde önce test hatasının düşük olduğu nokta belirlenmiştir. Bu nokta gizli düğüm sayısının “24” olduğu değerdir. Daha sonra eğitim hatasının düşük olduğu noktalara bakılmıştır. Örneğin gizli düğüm sayısının “22” olduğu değerde eğitim hatası daha düşüktür, fakat test hatası ve süre daha fazladır. Bu sebepten gizli düğüm sayısı “24” olarak belirlenmiştir.

**Çizelge 3.2.** YSA1 için optimum gizli düğüm sayısının bulunması

| Gizli düğüm sayısı | Eğitim Hatası  | Test Hatası   | Süre           |
|--------------------|----------------|---------------|----------------|
| 10                 | 21.8347        | 9.3411        | 67.2410        |
| 20                 | 22.7695        | 8.9769        | 66.9691        |
| 22                 | 18.6647        | 9.2387        | 80.0617        |
| <b>24</b>          | <b>18.8084</b> | <b>8.9215</b> | <b>74.7262</b> |
| 26                 | 20.5770        | 8.9872        | 74.5478        |
| 28                 | 19.9374        | 9.1414        | 75.2125        |
| 30                 | 18.5926        | 9.2093        | 71.5375        |
| 40                 | 19.8977        | 9.5385        | 74.2831        |
| 50                 | 20.3162        | 8.9798        | 83.3498        |
| 60                 | 21.4546        | 8.9923        | 91.5057        |
| 70                 | 21.0711        | 9.2032        | 93.0251        |
| 80                 | 19.5600        | 9.2998        | 97.5199        |
| 90                 | 18.1328        | 8.9406        | 107.7089       |
| 100                | 19.8007        | 9.3824        | 125.2749       |
| 110                | 20.8101        | 9.2882        | 116.9591       |
| 120                | 21.5091        | 9.4057        | 131.2748       |
| 130                | 19.8997        | 9.1938        | 139.6234       |

**Çizelge 3.3.** YSA1 için optimum öğrenme oranının bulunması

| Öğrenme oranı | Eğitim Hatası  | Test Hatası   | Süre           |
|---------------|----------------|---------------|----------------|
| 0.5           | 19.0311        | 8.9549        | 78.0015        |
| <b>0.7</b>    | <b>18.8084</b> | <b>8.9215</b> | <b>74.7262</b> |
| 0.8           | 19.3282        | 8.9792        | 75.9099        |
| 0.9           | 19.4103        | 9.0138        | 85.5286        |
| 1.0           | 18.6293        | 8.9307        | 70.4405        |
| 1.5           | 18.9722        | 9.0005        | 70.6817        |
| 2.0           | 18.2137        | 9.0270        | 69.9293        |
| 2.5           | 18.1375        | 9.0231        | 73.0871        |
| 3.0           | 18.2187        | 9.0524        | 81.3982        |
| 3.5           | 18.9371        | 9.0602        | 79.9376        |
| 4.0           | 18.1892        | 9.0333        | 79.6157        |
| 4.5           | 18.1985        | 9.0331        | 71.9984        |
| 5.0           | 18.2112        | 9.0318        | 71.0398        |
| 5.5           | 18.1083        | 9.0301        | 73.3036        |
| 6.0           | 18.2161        | 9.0361        | 72.1605        |
| 6.5           | 18.1723        | 9.0362        | 72.3273        |
| 7.0           | 18.2641        | 9.0472        | 71.7765        |


**Çizelge 3.4.** YSA1 için momentum sabitinin bulunması

| Momentum sabiti | Eğitim Hatası  | Test Hatası   | Süre           |
|-----------------|----------------|---------------|----------------|
| 0.1             | 19.1823        | 8.8873        | 79.8146        |
| 0.2             | 19.1647        | 9.0163        | 76.7025        |
| 0.3             | 19.1951        | 8.9614        | 76.4644        |
| 0.4             | 19.1449        | 8.9420        | 71.6126        |
| 0.5             | 18.8084        | 8.9215        | 77.7433        |
| 0.6             | 19.4364        | 8.9818        | 73.1035        |
| 0.7             | 19.2211        | 8.9641        | 75.7047        |
| 0.8             | 16.7374        | 9.0586        | 73.4766        |
| <b>0.9</b>      | <b>17.6871</b> | <b>8.9586</b> | <b>73.7274</b> |

Dalgacık dönüşümü üç farklı seviye olarak uygulandığından bir seviye uygulanarak YSA' ya sunulan sonuçlarda yapı "YSA1", iki seviye uygulanarak YSA' ya sunulan sonuçlarda yapı "YSA2" ve üç seviye uygulanarak YSA' ya sunulan sonuçlarda yapı "YSA3" olarak adlandırılmıştır. 30 akciğer BT görüntüsünün YSA1, YSA2 ve YSA3 yapılarında test edilmesiyle ulaşılan sonuçlar Çizelge 3.5' de doğru piksel sayısı ve doğruluk olarak analiz edilmiştir.

Çizelge 3.5' den de görüleceği gibi doğruluk bakımından en iyi sonuçlar 1.seviyede dalgacık dönüşümü ile gerçekleştirilen yapıda yani YSA1' de elde edilmiştir. 10 sağlıklı ve 20 hastalıklı akciğer BT görüntüsü için sonuçların sunulduğu Çizelge 3.5' de YSA1, YSA2 ve YSA3 yapılarında sırasıyla doğruluk % 86.11, %85.45 ve % 85.48 olarak elde edilmiştir. Dikkatle incelenecek olursa; YSA1 için en yüksek doğruluk 10 nolu sağlıklı veri için elde edilirken, YSA2 ve YSA3 için 6 nolu hasta verisinde en yüksek doğruluk değerine ulaşılmıştır. Bütün YSA yapıları 24 gizli düğüme sahiptir.

YSA2 yapısı ile N5 test verisi için elde edilen bölütleme sonucu Şekil 3.11' de görülmektedir. Çizelge 3.5' den görüleceği gibi N5 test verisi için doğruluk % 90,04 olarak elde edilmiştir (Toplam piksel sayısı  $752 \times 752 = 565504$  pikseldir).




**Şekil 3.10.** (a) N5 test verisi, (b) Bölütleme ile elde edilmesi hedeflenen görüntü, (c) N5 test verisi için YSA2 ile elde edilen bölütleme sonucu

**Çizelge 3.5.** Ayırık dalgacık dönüşümü ve YSA ile elde edilen sonuçlar

| VERİ            | YSA1 (1.seviye DD+YSA)<br>(377:24:377) |              | YSA2 (2.seviye DD+YSA)<br>(190:24:190) |              | YSA3 (3.seviye DD+YSA)<br>(96:24:96) |              |
|-----------------|----------------------------------------|--------------|----------------------------------------|--------------|--------------------------------------|--------------|
|                 | Doğru<br>bulunan<br>piksel sayısı      | Doğruluk (%) | Doğru<br>bulunan<br>piksel sayısı      | Doğruluk (%) | Doğru<br>bulunan<br>piksel sayısı    | Doğruluk (%) |
| N1              | 508687                                 | 89,95        | 498688                                 | 88,18        | 498755                               | 88,19        |
| N2              | 496790                                 | 87,85        | 484734                                 | 85,71        | 484770                               | 85,72        |
| N3              | 491672                                 | 86,94        | 485417                                 | 85,83        | 486132                               | 85,96        |
| N4              | 493967                                 | 87,35        | 497047                                 | 87,89        | 497619                               | 87,99        |
| N5              | 507162                                 | 89,68        | 509199                                 | 90,04        | 509547                               | 90,1         |
| N6              | 485979                                 | 85,94        | 484290                                 | 85,63        | 485293                               | 85,81        |
| N7              | 491729                                 | 86,95        | 503337                                 | 89           | 503378                               | 89,01        |
| N8              | 467544                                 | 82,67        | 467573                                 | 82,68        | 467660                               | 82,69        |
| N9              | 507966                                 | 89,82        | 492728                                 | 87,13        | 492785                               | 87,14        |
| N10             | 509352                                 | 90,07        | 506258                                 | 89,52        | 506322                               | 89,53        |
| H1              | 469182                                 | 82,96        | 468527                                 | 82,85        | 468737                               | 82,88        |
| H2              | 462586                                 | 81,8         | 489764                                 | 86,6         | 489816                               | 86,61        |
| H3              | 480399                                 | 84,95        | 480304                                 | 84,93        | 480345                               | 84,94        |
| H4              | 476080                                 | 84,18        | 465488                                 | 82,31        | 465624                               | 82,34        |
| H5              | 500838                                 | 88,56        | 501480                                 | 88,67        | 501534                               | 88,68        |
| H6              | 504928                                 | 89,28        | 514774                                 | 91,03        | 514896                               | 91,05        |
| H7              | 501743                                 | 88,72        | 495220                                 | 87,57        | 495106                               | 87,55        |
| H8              | 460014                                 | 81,34        | 472367                                 | 83,53        | 472386                               | 83,53        |
| H9              | 504608                                 | 89,23        | 505499                                 | 89,38        | 505615                               | 89,41        |
| H10             | 469796                                 | 83,07        | 453038                                 | 80,11        | 452904                               | 80,08        |
| H11             | 469915                                 | 83,09        | 453456                                 | 80,18        | 453312                               | 80,16        |
| H12             | 482061                                 | 85,24        | 479766                                 | 84,54        | 479735                               | 84,83        |
| H13             | 480977                                 | 85,05        | 466753                                 | 82,54        | 466628                               | 82,51        |
| H14             | 491327                                 | 86,88        | 487586                                 | 86,22        | 487633                               | 86,23        |
| H15             | 469245                                 | 82,97        | 460684                                 | 81,46        | 460681                               | 81,46        |
| H16             | 502173                                 | 88,8         | 504063                                 | 89,13        | 504208                               | 89,16        |
| H17             | 490680                                 | 86,76        | 471145                                 | 83,31        | 471369                               | 83,35        |
| H18             | 484909                                 | 85,74        | 488415                                 | 86,37        | 488401                               | 86,36        |
| H19             | 463342                                 | 81,93        | 458511                                 | 81,08        | 458901                               | 81,15        |
| H20             | 483706                                 | 85,53        | 452459                                 | 80,01        | 452510                               | 80,02        |
| <b>ORTALAMA</b> | <b>486979</b>                          | <b>86,11</b> | <b>483286</b>                          | <b>85,45</b> | <b>483420</b>                        | <b>85,48</b> |

### 3.3.3. Bulanık c-ortalamlar kümeleme algoritması ile elde edilen bölütleme sonuçları

Tez çalışmasında akciğer BT görüntülerinin bölütlenmesi amacıyla bulanık c-ortalamlar kümeleme algoritması da kullanılmıştır. Gerçekleştirilen bulanık c-ortalamlar kümeleme algoritmasına ait blok diyagramı Şekil 3.11’ de verilmiştir.




**Şekil 3.11.** Bulanık c-ortalamlar kümeleme algoritması ile gerçekleştirilen bölütleme yapısına ait blok diyagramı

Şekil 3.11’ den de görüldüğü gibi bulanık c-ortalamlar kümeleme algoritması danışmanlı bir algoritma değildir. Başka bir deyişle bulanık c-ortalamlar kümeleme algoritması ile bir görüntü için bölütleme sonucu üretilirken istenilen sonuç (hedef) görüntü kullanılmaz. Şekilden de görüleceği gibi, giriş görüntüsü için bölütleme sonucunda bulunması gereken görüntü (hedef görüntü), sadece bölütleme sonuç görüntüsü için doğruluk hesabı yapılırken kullanılmıştır. Ayrıca algoritmanın kullanım amacı görüntü bölütleme olduğu için hedef görüntüler binary (ikili) bir yapıya sahiptir. Dolayısıyla bu açıdan bakıldığında bölütlenecek görüntü aslında iki kümeye yani siyah

pikseller için “0”, beyaz pikseller için “1” değerine kümelenebilir. Algoritmada girişe verilen BT görüntüsü kümelenebilirken iki küme için yani siyah ve beyaz pikseller için başlangıç piksel parlaklık değerleri verilir. Bu değerler söz konusu kümeler için başlangıç küme merkezi değerleridir. İterasyon boyunca bulanık c-ortalamlar kümeleme algoritmasına uygun olarak siyah ve beyaz pikselleri temsil eden bu küme merkezi değerleri güncellenir.

Gerçekleştirilen bulanık c-ortalamlar kümeleme algoritmasına ait akış diyagramı Şekil 3.12’de görülmektedir. Algoritma için bulanıklık sabiti 2.0’dir.



Şekil 3.12. Bulanık c-ortalamlar kümeleme algoritması için akış diyagramı

Şekil 3.12’den de görüldüğü gibi öncelikle başlangıç küme merkezleri belirlenir. Sonra bu küme merkezleri ile giriş görüntüsü arasındaki uzaklıklar

hesaplanarak görüntüyü oluşturan piksellerin hangi kümeye ait olduğu belirlenir ve her piksele üyelik değerleri atanır. Üyelik değerlerini ve hesaplanan uzaklıkları kullanarak algoritmaya ait maliyet fonksiyonu hesaplanır. İki iterasyon arasındaki maliyet fonksiyonu farkı eğer durdurma kriterini aşarsa iterasyona devam edilir ve küme merkezleri güncellenir. Eğer fark durdurma kriterini aşmazsa iterasyon durdurulur ve son küme merkezi değerleri kaydedilir.

Bulanık c-ortalamalar kümeleme algoritmasında başlangıç küme merkezi değerlerinin nasıl belirleneceği ile ilgili literatürde herhangi bir çalışma olmadığından tez çalışmasında küme merkezlerinin optimum değerleri deneysel olarak bulunmuştur. Burada sabit bir görüntü için başlangıç küme merkezleri Cc1 için 7-63 arasında ve Cc2 için 220-255 arasında değiştirilerek süre ve test hatası değerleri incelenmiştir. Bulunan süre ve hata değerleri Çizelge 3.6’ da görülmektedir.

**Çizelge 3.6.** Optimum başlangıç küme merkezlerinin belirlenmesi

| Simülasyon No | Cc1 | Cc2 | İterasyon sayısı | Süre    | Test Hatası (%) |
|---------------|-----|-----|------------------|---------|-----------------|
| 1             | 7   | 220 | 8                | 18.1748 | 8.95            |
| 2             | 14  | 225 | 9                | 19.6134 | 8.95            |
| 3             | 21  | 230 | 9                | 20.0529 | 8.95            |
| 4             | 28  | 235 | 9                | 20.0517 | 8.95            |
| 5             | 35  | 240 | 9                | 19.5977 | 8.95            |
| 6             | 42  | 245 | 9                | 19.8385 | 8.95            |
| 7             | 49  | 250 | 10               | 21.4041 | 8.95            |
| 8             | 56  | 255 | 10               | 22.0499 | 8.95            |
| 9             | 63  | 255 | 10               | 21.8537 | 8.95            |


Çizelge 3.6’ dan da görüleceği gibi küme merkezi değerlerinin değiştirilmesi hatada kayda değer bir etki göstermemiştir. Bu nedenle küme merkezi değerleri siyah pikseller için “8” beyaz pikseller için “250” olarak alınmıştır.

Bulanık c-ortalamalar kümeleme algoritmasına göre 10 sağlıklı ve 20 hastalıklı akciğer BT görüntüsü için elde edilen sonuçların doğru piksel sayısı ve doğruluk bakımından analizi Çizelge 3.7’ de verilmiştir. Çizelge 3.7’ den görüldüğü gibi ortalama doğru piksel sayısı 515766 ve ortalama doğruluk % 91.20’ dir. Görüntülerde toplam piksel sayısı  $752 \times 752 = 565504$  pikseldir. En yüksek doğruluğun elde edildiği veri 9 nolu sağlıklı veriye ait görüntüdür. En düşük doğruluğun elde edildiği veri ise 7 nolu sağlıklı veriye ait görüntüdür.

**Çizelge 3.7.** Bulanık c-ortalamlar kümeleme algoritması ile elde edilen bölütleme sonuçları

| <b>VERİ</b>     | <b>Doğru bulunan piksel sayısı</b> | <b>Doğruluk (%)</b> |
|-----------------|------------------------------------|---------------------|
| N1              | 513121                             | 90,74               |
| N2              | 522837                             | 92,45               |
| N3              | 508200                             | 89,86               |
| N4              | 505270                             | 89,35               |
| N5              | 514685                             | 91,01               |
| N6              | 511157                             | 90,4                |
| N7              | 498440                             | 88,14               |
| N8              | 494686                             | 87,47               |
| N9              | 529731                             | 93,67               |
| N10             | 527028                             | 93,19               |
| H1              | 518546                             | 91,7                |
| H2              | 504447                             | 89,2                |
| H3              | 515495                             | 91,15               |
| H4              | 524872                             | 92,81               |
| H5              | 516522                             | 91,34               |
| H6              | 513366                             | 90,78               |
| H7              | 510990                             | 90,36               |
| H8              | 514265                             | 90,94               |
| H9              | 519659                             | 91,9                |
| H10             | 513319                             | 90,77               |
| H11             | 528241                             | 93,41               |
| H12             | 511553                             | 90,46               |
| H13             | 523115                             | 92,5                |
| H14             | 525131                             | 92,86               |
| H15             | 508573                             | 89,93               |
| H16             | 524777                             | 92,79               |
| H17             | 522739                             | 92,44               |
| H18             | 522201                             | 92,34               |
| H19             | 511889                             | 90,52               |
| H20             | 518130                             | 91,62               |
| <b>ORTALAMA</b> | <b>515766</b>                      | <b>91,20</b>        |


BCO algoritması ile N5 test verisi için elde edilen bölütleme sonucu Şekil 3.13’ de görülmektedir. Çizelge 3.7’ dan görüleceği N5 test verisi için doğruluk % 91,01 olarak elde edilmiştir.



**Şekil 3.13.** (a) N5 test verisi, (b) Bölütleme ile elde edilmesi hedeflenen görüntü ve (c) N5 test verisi için BCO ile elde edilen bölütleme sonucu


### 3.3.4. Hücresel yapay sinir ağı ile elde edilen bölütleme sonuçları

Hücresel yapay sinir ağları görüntü işlemede literatürde en çok kullanılan yapay zekâ algoritmasıdır. Hücresel yapay sinir ağı ile gerçekleştirilen bölütleme sistemine ait blok gösterim Şekil 3.14’ de görülmektedir. Şekilde de görüleceği gibi hücresel yapay sinir ağı danışmansız bir yapı gösterir. Dolayısıyla ağa giriş görüntüsü için bulunması hedeflenen görüntü sunulmaz. Hedef görüntü sadece bölütleme sonucu için doğruluk hesabında kullanılır.



**Şekil 3.14.** Hücresel yapay sinir ağı ile gerçekleştirilen bölütleme yapısına ait blok diyagramı

Bölütleme için gerçekleştirilen hücresel yapay sinir ağına ait akış diyagramı Şekil 3.15’ de görülmektedir. Hücresel yapay sinir ağı algoritması için en önemli aşama şablon matrisin parametrelerinin belirlenmesidir. Şekilden görüldüğü gibi bu çalışmada sözkonusu parametreler sabit alınmıştır. Hücresel sinir ağı yapısında çıkışın belirlenmesi şablon matrisin görüntü matrisi ile konvole edilmesiyle elde edilir. Son olarak elde edilen görüntü ile hedef görüntü arasındaki hata hesaplanır ve algoritma durdurulur.




Şekil 3.15. Hücresel yapay sinir ağı algoritmasına ait akış diyagramı

Hücresel yapay sinir ağı ile 10 sağlıklı ve 20 hastalıklı akciğer BT görüntüsü için elde edilen sonuçlar Çizelge 3.8’ de sunulmuştur. Çizelgeden de görüleceği gibi ortalama doğru piksel sayısı 526577 ve ortalama doğruluk % 93.09’ dur. Görüntülerde toplam piksel sayısı  $752 \times 752 = 565504$  pikseldir. En yüksek doğruluk 10 nolu sağlıklı görüntü verisi için elde edilmiştir.

**Çizelge 3.8.** Hücresel yapay sinir ağı ile elde edilen bölütleme sonuçları

| <b>VERİ</b>     | <b>Doğru<br/>bulunan<br/>piksel sayısı</b> | <b>Doğruluk<br/>(%)</b> |
|-----------------|--------------------------------------------|-------------------------|
| N1              | 529392                                     | 93,61                   |
| N2              | 520409                                     | 92,03                   |
| N3              | 529607                                     | 93,65                   |
| N4              | 512404                                     | 90,61                   |
| N5              | 555147                                     | 98,16                   |
| N6              | 532288                                     | 94,13                   |
| N7              | 531019                                     | 93,91                   |
| N8              | 492168                                     | 87,03                   |
| N9              | 556953                                     | 98,49                   |
| N10             | 560025                                     | 99,03                   |
| H1              | 513239                                     | 90,76                   |
| H2              | 507571                                     | 89,75                   |
| H3              | 525175                                     | 92,87                   |
| H4              | 519586                                     | 91,88                   |
| H5              | 535356                                     | 94,67                   |
| H6              | 551007                                     | 97,44                   |
| H7              | 544152                                     | 96,22                   |
| H8              | 504021                                     | 89,13                   |
| H9              | 552205                                     | 97,65                   |
| H10             | 513466                                     | 90,79                   |
| H11             | 486960                                     | 86,11                   |
| H12             | 520455                                     | 92,03                   |
| H13             | 525891                                     | 92,3                    |
| H14             | 536125                                     | 94,8                    |
| H15             | 509852                                     | 90,16                   |
| H16             | 547254                                     | 96,77                   |
| H17             | 528919                                     | 93,53                   |
| H18             | 526520                                     | 93,11                   |
| H19             | 507123                                     | 89,67                   |
| H20             | 523019                                     | 92,48                   |
| <b>ORTALAMA</b> | <b>526577</b>                              | <b>93,09</b>            |

HYSA ile N5 test verisi için elde edilen bölütleme sonucu Şekil 3.16' da görülmektedir. Şu ana kadar diğer algoritmalarla da elde edilen sonuçlar incelenecek olursa en iyi bölütleme sonucu HYSA yapısı ile bulunmuştur. Başka bir deyişle hedef görüntüye en çok HYSA algoritması ile ulaşılmıştır. Çizelge 3.8' den de görüleceği N5 test verisi için doğruluk % 98,16 olarak elde edilmiştir.





**Şekil 3.16.** (a) N5 test verisi, (b) Bölütleme ile elde edilmesi hedeflenen görüntü ve (c) N5 test verisi için HYSA ile elde edilen bölütleme sonucu

### 3.4. Paralel Bölütleme

Tez çalışmasında gerçekleştirilen algoritmalar dört çekirdekli işlemciye sahip bir bilgisayarda ikili, üçlü ve dördü olarak paralel çalıştırılmıştır. Elde edilen sonuçlar 10 sağlıklı ve 20 hastalıklı akciğer BT görüntüsü için süre bakımından incelenmiştir. Gerçekleştirilen çalışmada yaklaşık bir algoritma için kullanılan sürede dört algoritmanın sonucunun alındığı görülmüştür. Çalışmada paralel bölütleme algoritmasının sonucunda kullanıcıya her görüntü için en iyi sonuç veren algoritma sunulmaktadır. Böylece paralel hesaplama mantığı kullanılarak daha kısa sürede en iyi sonuca ulaşılabileceği gösterilmiştir. Paralel hesaplama Matlab yazılım paketi kullanılarak gerçekleştirilmiştir.

Çok çekirdekli bilgisayarlarda paralel hesaplama mantığı ile farklı programların çalışmasını gösteren blok diyagramlar Şekil 3.17 (a) ve (b)' de verilmiştir. Şekil 3.17(a) incelenecek olursa, işlemciyi oluşturan her çekirdekte bir görev (task) gerçekleştirilerek yani bir fonksiyon çalıştırılarak sonuçlar elde edilebilmektedir. Elde edilen sonuçlar kullanıcı (client-istemci) tarafından hep beraber de değerlendirilebilmektedir.

Şekil 3.17(b)' de görüleceği gibi öncelikle programda bir “Çizelgeleyici” oluşturulur. Daha sonra bu çizelgeleyicide “İş” nesneleri oluşturulur ve son olarak her iş nesnesinde “Görev” nesneleri oluşturulur. Görev nesnelerinin her biri işlemcinin bir çekirdeğinde çalıştırılır ve bir fonksiyonu icra eder.




**Şekil 3.17.** (a) Matlab yazılımında paralel işleme mantığını gösteren blok diyagram  
(b) Tezde gerçekleştirilen dörtlü paralel işleme blok gösterimi

Paralel hesaplamada bölütleme algoritmaları yani işlemci çekirdeklerinde çalıştırılan fonksiyonlar değişmeyeceğinden elde edilen doğruluk değerleri de değişmeyecektir. Bir başka deyişle her görüntü verisi için dört algoritma ile paralel bölütlemeye elde edilen doğruluk değerleri “Dört Algoritmanın Tek Tek Çalıştırılması ile Elde Edilen Bölütleme Sonuçları” bölümünde sunulan sonuçlarla aynıdır. Bu sebepten paralel bölütleme sonuçlarında sadece süre bazında karşılaştırma yapılmıştır. İkili, üçlü ve dörtlü paralel bölütlemeyi ifade eden blok gösterimlerde görülen blok diyagramlardan anlaşılacağı üzere doğruluk hesabı, gerçekleştirilen paralel bölütleme algoritmalarının içeriğinde mevcuttur, ancak doğruluk değerleri aynı olacağından bu değerler çizelgelere tekrar eklenmemiştir.

### 3.4.1. İkili paralel bölütleme sonuçları

Tez çalışmasında paralel hesaplama kullanılarak işlemciyi oluşturan 4 çekirdekten ikisi kullanılarak 2 algoritma aynı anda çalıştırılmıştır. Bu amaçla HYSA//Morfolojik, HYSA//YSA ve HYSA//BCO ikili paralel bölütleme yapıları oluşturulmuştur. Paralel ikili bölütleme yapılarından HYSA//YSA için blok gösterim Şekil 3.18’ de sunulmuştur. Blok diyagramdan da anlaşılacağı üzere iki algoritma da aynı anda ayrı ayrı birer işlemci çekirdeğinde çalıştırılmakta ve aynı anda sonuçları elde edilmektedir. Doğruluk değerleri bir görüntü için aynı algorithmada değişmeyeceğinden paralel bölütleme sonuçlarında sadece süre bazında karşılaştırma yapılmıştır. Her görüntü verisi için dört algoritma ile paralel bölütlemeye elde edilen doğruluk değerleri “Dört Algoritmanın Tek Tek Çalıştırılması ile Elde Edilen Bölütleme Sonuçları” başlığında sunulan sonuçlarla aynıdır. Şekil 3.18’ de görülen blok diyagramdan anlaşılacağı üzere doğruluk hesabı paralel bölütleme algoritmasının içeriğinde mevcuttur, ancak doğruluk değerleri aynı olacağından bu değerler çizelgeye tekrar eklenmemiştir.

Bütün ikili paralel bölütleme yapıları için elde edilen sonuçların süre analizi Çizelge 3.9-3.11’ de verilmiştir. Çizelgelerde algoritmalar için verilen süreler, algoritmaların tek başına çalışma sürelerini ifade etmektedir. “Toplam” şeklinde verilen değerler bir veri için bütün algoritmaların tek tek çalıştırılmasıyla harcadığı toplam süreyi ifade eder. Çizelge 3.9’ da görüldüğü gibi HYSA//Morfolojik ikili paralel bölütleme yapısında iki algoritmanın ayrı ayrı çalıştırılması için harcanan ortalama toplam süre 95.86 sn’ dir. Bu iki algoritmanın paralel bölütleme ile aynı anda çalıştırılması için harcanan süre 51.97 sn’ dir. Elde edilen süre kazancı % 45.78’ dir. Aynı şekilde HYSA//YSA ve HYSA//BCO ikili paralel bölütleme yapıları için paralel bölütleme süreleri sırasıyla 52.53 sn ve 48.53 sn olarak bulunmuştur. Bu iki paralel bölütleme yapısında algoritmaların ayrı ayrı çalıştırılması durumunda harcanan toplam süre HYSA//YSA için 95.99 sn ve HYSA//BCO için 59.52 sn’ dir. Bu durumda HYSA//YSA ikili paralel yapısı için süre kazancı % 45.47, HYSA//BCO için ise % 22.67’ dir.



Şekil 3.18. İkili paralel bölütleme için blok gösterim

Çizelge 3.9. HYSA//Morfolojik ikili paralel yapısı için bölütleme süre sonuçları

| VERİ            | SÜRE (sn)    |              |              |                |              |
|-----------------|--------------|--------------|--------------|----------------|--------------|
|                 | HYSA         | Morfolojik   | Toplam       | Paralel İşleme | Kazanç (%)   |
| N1              | 48,46        | 47,83        | 96,29        | 53,05          | 44,91        |
| N2              | 48,13        | 47,70        | 95,83        | 52,03          | 45,71        |
| N3              | 48,18        | 47,67        | 95,85        | 52,05          | 45,70        |
| N4              | 48,35        | 47,87        | 96,22        | 52,05          | 45,91        |
| N5              | 48,00        | 47,55        | 95,55        | 51,01          | 46,62        |
| N6              | 48,21        | 47,76        | 95,97        | 52,05          | 45,77        |
| N7              | 47,87        | 47,44        | 95,31        | 51,02          | 46,47        |
| N8              | 48,36        | 47,83        | 96,19        | 52,04          | 45,90        |
| N9              | 48,24        | 47,81        | 96,05        | 52,05          | 45,81        |
| N10             | 48,29        | 47,74        | 96,04        | 52,05          | 45,81        |
| H1              | 48,11        | 47,60        | 95,70        | 51,03          | 46,67        |
| H2              | 48,23        | 47,75        | 95,99        | 52,04          | 45,79        |
| H3              | 48,23        | 47,75        | 95,98        | 52,06          | 45,76        |
| H4              | 48,20        | 47,73        | 95,93        | 52,05          | 45,74        |
| H5              | 47,97        | 47,51        | 95,48        | 52,05          | 45,49        |
| H6              | 48,13        | 47,63        | 95,76        | 52,05          | 45,64        |
| H7              | 48,25        | 47,81        | 96,06        | 52,05          | 45,81        |
| H8              | 48,06        | 47,58        | 95,65        | 52,05          | 45,58        |
| H9              | 48,17        | 47,62        | 95,79        | 52,03          | 45,68        |
| H10             | 48,20        | 47,69        | 95,89        | 52,03          | 45,74        |
| H11             | 47,61        | 47,16        | 94,77        | 51,01          | 46,18        |
| H12             | 47,96        | 47,45        | 95,40        | 51,02          | 46,52        |
| H13             | 48,29        | 47,78        | 96,07        | 52,03          | 45,84        |
| H14             | 48,60        | 47,92        | 96,52        | 53,04          | 45,05        |
| H15             | 48,26        | 47,63        | 95,89        | 53,07          | 44,66        |
| H16             | 48,41        | 47,77        | 96,18        | 52,05          | 45,88        |
| H17             | 48,40        | 47,95        | 96,34        | 52,03          | 45,99        |
| H18             | 48,10        | 47,50        | 95,60        | 52,03          | 45,57        |
| H19             | 48,14        | 47,70        | 95,84        | 52,04          | 45,71        |
| H20             | 48,05        | 47,57        | 95,62        | 52,04          | 45,58        |
| <b>ORTALAMA</b> | <b>48,18</b> | <b>47,68</b> | <b>95,86</b> | <b>51,97</b>   | <b>45,78</b> |

**Çizelge 3.10.** HYSA//YSA ikili paralel yapısı için bölütleme süre sonuçları

| VERİ            | SÜRE (sn)    |              |              |                |              |
|-----------------|--------------|--------------|--------------|----------------|--------------|
|                 | HYSA         | YSA          | Toplam       | Paralel İşleme | Kazanç (%)   |
| N1              | 48,05        | 47,67        | 95,72        | 52,05          | 45,62        |
| N2              | 48,18        | 47,85        | 96,03        | 53,04          | 44,77        |
| N3              | 48,22        | 47,90        | 96,13        | 53,04          | 44,83        |
| N4              | 48,15        | 47,80        | 95,95        | 52,04          | 45,77        |
| N5              | 47,85        | 47,60        | 95,45        | 52,03          | 45,49        |
| N6              | 48,10        | 47,87        | 95,98        | 52,04          | 45,78        |
| N7              | 48,15        | 47,89        | 96,04        | 52,03          | 45,82        |
| N8              | 48,30        | 47,90        | 96,19        | 52,04          | 45,90        |
| N9              | 48,12        | 47,83        | 95,96        | 53,05          | 44,71        |
| N10             | 48,21        | 47,92        | 96,14        | 53,05          | 44,82        |
| H1              | 48,23        | 48,07        | 96,30        | 53,07          | 44,89        |
| H2              | 48,34        | 48,04        | 96,39        | 52,04          | 46,01        |
| H3              | 47,92        | 47,65        | 95,57        | 52,08          | 45,50        |
| H4              | 48,58        | 48,10        | 96,68        | 53,07          | 45,11        |
| H5              | 48,03        | 47,72        | 95,75        | 52,03          | 45,66        |
| H6              | 48,18        | 47,85        | 96,03        | 52,06          | 45,79        |
| H7              | 48,10        | 47,78        | 95,89        | 52,05          | 45,71        |
| H8              | 47,62        | 47,34        | 94,96        | 52,04          | 45,20        |
| H9              | 48,34        | 47,91        | 96,25        | 52,04          | 45,93        |
| H10             | 47,71        | 47,44        | 95,15        | 52,05          | 45,30        |
| H11             | 48,01        | 47,77        | 95,78        | 52,04          | 45,67        |
| H12             | 48,44        | 48,05        | 96,48        | 52,04          | 46,07        |
| H13             | 48,28        | 47,89        | 96,18        | 52,02          | 45,91        |
| H14             | 48,13        | 47,70        | 95,83        | 52,02          | 45,71        |
| H15             | 48,43        | 48,18        | 96,61        | 52,04          | 46,13        |
| H16             | 48,33        | 47,92        | 96,25        | 53,05          | 44,88        |
| H17             | 48,36        | 48,03        | 96,39        | 53,07          | 44,94        |
| H18             | 48,26        | 47,93        | 96,19        | 53,05          | 44,85        |
| H19             | 47,92        | 47,67        | 95,59        | 52,06          | 45,54        |
| H20             | 48,14        | 47,81        | 95,94        | 52,07          | 45,73        |
| <b>ORTALAMA</b> | <b>48,16</b> | <b>47,84</b> | <b>95,99</b> | <b>52,35</b>   | <b>45,47</b> |

**Çizelge 3.11.** HYSA//BCO ikili paralel yapısı için bölütleme süre sonuçları


| VERİ            | SÜRE (sn)    |              |              |                |              |
|-----------------|--------------|--------------|--------------|----------------|--------------|
|                 | HYSA         | BCO          | Toplam       | Paralel İşleme | Kazanç (%)   |
| N1              | 44,87        | 14,86        | 59,73        | 47,98          | 24,49        |
| N2              | 44,92        | 14,83        | 59,75        | 47,97          | 24,57        |
| N3              | 44,99        | 14,77        | 59,76        | 49,01          | 21,95        |
| N4              | 44,88        | 16,52        | 61,40        | 48,02          | 27,87        |
| N5              | 44,83        | 13,09        | 57,91        | 49,01          | 18,17        |
| N6              | 44,84        | 14,85        | 59,69        | 47,98          | 24,42        |
| N7              | 44,90        | 16,54        | 61,44        | 47,97          | 28,08        |
| N8              | 44,99        | 14,82        | 59,81        | 47,98          | 24,64        |
| N9              | 44,83        | 13,27        | 58,10        | 48,01          | 21,03        |
| N10             | 44,94        | 13,13        | 58,07        | 49,02          | 18,46        |
| H1              | 44,94        | 16,49        | 61,42        | 48,00          | 27,98        |
| H2              | 44,91        | 13,17        | 58,08        | 49,02          | 18,47        |
| H3              | 44,91        | 13,15        | 58,06        | 47,99          | 20,98        |
| H4              | 44,91        | 16,48        | 61,40        | 48,99          | 25,32        |
| H5              | 45,03        | 16,43        | 61,46        | 49,02          | 25,39        |
| H6              | 44,89        | 13,17        | 58,06        | 47,99          | 20,98        |
| H7              | 45,00        | 13,11        | 58,12        | 49,01          | 18,58        |
| H8              | 44,92        | 13,15        | 58,07        | 48,00          | 20,97        |
| H9              | 44,99        | 13,07        | 58,06        | 49,02          | 18,43        |
| H10             | 45,01        | 16,56        | 61,56        | 48,99          | 25,67        |
| H11             | 44,91        | 16,45        | 61,36        | 48,99          | 25,25        |
| H12             | 44,90        | 14,85        | 59,75        | 47,99          | 24,52        |
| H13             | 44,90        | 14,85        | 59,75        | 47,98          | 24,53        |
| H14             | 44,96        | 14,82        | 59,78        | 48,99          | 22,02        |
| H15             | 44,92        | 14,74        | 59,66        | 48,99          | 21,78        |
| H16             | 44,87        | 13,13        | 58,01        | 49,02          | 18,34        |
| H17             | 44,97        | 14,92        | 59,88        | 49,01          | 22,19        |
| H18             | 44,89        | 13,13        | 58,02        | 48,98          | 18,45        |
| H19             | 44,94        | 14,78        | 59,72        | 49,00          | 21,86        |
| H20             | 44,82        | 15,04        | 59,86        | 47,99          | 24,75        |
| <b>ORTALAMA</b> | <b>44,92</b> | <b>14,61</b> | <b>59,52</b> | <b>48,53</b>   | <b>22,67</b> |

### 3.4.2. Üçlü paralel bölütleme sonuçları

Tez çalışmasında paralel hesaplama kullanılarak işlemciyi oluşturan 4 çekirdekten üçü kullanılarak sadece 3 algoritma aynı anda çalıştırılmıştır. Üçlü paralel bölütleme yapıları HYSA//Morfolojik//BCO ve HYSA//YSA//BCO şeklinde oluşturulmuştur.

Üçlü paralel bölütleme yapılarından HYSA//YSA//BCO için blok gösterim Şekil 3.19’ da sunulmuştur. Blok diyagramdan da anlaşılacağı üzere üç algoritma aynı anda her biri ayrı işlemci çekirdeklerinde çalıştırılmakta ve aynı anda sonuçları elde edilmektedir. Şekil 3.19’ da verilen blok gösterimde doğruluk hesabı da görülmektedir, ancak doğruluklar “Dört Algoritmanın Tek Tek Çalıştırılması ile Elde Edilen Bölütleme Sonuçları” başlığı altında sunulan sonuçlarla aynı olduğundan çizelgelerde bu değerler verilmemiştir. Paralel bölütlemelerde algoritmalar değiştirilmemektedir. Sadece aynı anda çalıştırılarak süre kazancı sağlanmaktadır. Bu sebepten doğruluk değerleri görüntü verileri için değişmeyecektir. Üçlü paralel bölütleme sonuçlarının sunulduğu çizelgelerde sadece süre analizi yapılmıştır.

Üçlü paralel bölütleme yapıları için de elde edilen sonuçların süre analizi Çizelge 3.12 ve 3.13’ de verilmiştir. Çizelgelerde algoritmalar için verilen süreler algoritmaların tek başına çalıştırılması ile elde edilen süreleri ifade etmektedir. “Toplam” şeklinde verilen değerler bir veri için bütün algoritmaların ayrı ayrı çalıştırılmasıyla elde edilen toplam süredir. Çizelge 3.12’ den görüleceği gibi HYSA//Morfolojik//BCO üçlü paralel bölütleme yapısında ortalama toplam süre dört algoritma için 112.24 sn olarak bulunmuştur. Buna karşılık paralel çalışmada üç algoritma ile bölütleme gerçekleştirilirken harcanan süre 52.95 sn olarak bulunmuştur. Elde edilen süre kazancı % 52.82’ dir. HYSA//YSA//BCO üçlü paralel bölütleme yapısı için Çizelge 3.13’ de sunulan paralel çalışma sonuçları incelenirse, üç algoritma için ortalama toplam süre 112.28 sn olarak bulunmuştur. Buna karşılık paralel çalışmada sözkonusu yapı için harcanan süre 53.34 sn’ dir. HYSA//YSA//BCO üçlü paralel bölütleme yapısında elde edilen süre kazancı % 52.49’ dur.



Şekil 3.19. Üçlü paralel bölütleme için blok gösterim

**Çizelge 3.12.** HYSA//Morfolojik//BCO üçlü paralel bölütleme yapısı için süre sonuçları

| VERİ            | SÜRE (sn)    |              |              |               |                |              |
|-----------------|--------------|--------------|--------------|---------------|----------------|--------------|
|                 | HYSA         | Morfolojik   | BCO          | Toplam        | Paralel İşleme | Kazanç (%)   |
| N1              | 48,47        | 47,97        | 15,79        | 112,22        | 52,16          | 53,52        |
| N2              | 48,52        | 47,95        | 15,55        | 112,02        | 53,15          | 52,55        |
| N3              | 48,66        | 48,12        | 15,74        | 112,52        | 53,17          | 52,74        |
| N4              | 48,68        | 48,07        | 17,39        | 114,15        | 53,22          | 53,38        |
| N5              | 48,70        | 48,12        | 13,97        | 110,79        | 53,18          | 52,00        |
| N6              | 48,58        | 47,99        | 15,82        | 112,40        | 53,17          | 52,69        |
| N7              | 48,96        | 48,39        | 17,66        | 115,01        | 53,17          | 53,77        |
| N8              | 48,57        | 47,99        | 15,73        | 112,28        | 52,27          | 53,45        |
| N9              | 48,65        | 48,12        | 14,21        | 110,99        | 53,16          | 52,10        |
| N10             | 48,62        | 48,08        | 14,02        | 110,73        | 53,19          | 51,96        |
| H1              | 48,86        | 48,15        | 17,62        | 114,63        | 52,19          | 54,47        |
| H2              | 48,81        | 48,17        | 14,01        | 110,99        | 53,17          | 52,09        |
| H3              | 48,59        | 48,07        | 14,06        | 110,72        | 53,20          | 51,95        |
| H4              | 48,51        | 48,01        | 17,56        | 114,08        | 54,24          | 52,46        |
| H5              | 48,62        | 47,97        | 17,33        | 113,92        | 53,17          | 53,33        |
| H6              | 48,73        | 48,15        | 14,06        | 110,94        | 53,20          | 52,05        |
| H7              | 49,18        | 48,52        | 14,17        | 111,88        | 52,17          | 53,36        |
| H8              | 48,50        | 48,01        | 13,82        | 110,33        | 53,19          | 51,79        |
| H9              | 48,69        | 48,01        | 13,99        | 110,69        | 52,17          | 52,87        |
| H10             | 48,79        | 48,23        | 17,31        | 114,33        | 52,16          | 54,38        |
| H11             | 48,28        | 47,75        | 17,49        | 113,52        | 53,14          | 53,19        |
| H12             | 48,30        | 47,82        | 15,65        | 111,77        | 53,17          | 52,43        |
| H13             | 48,77        | 48,08        | 15,75        | 112,61        | 53,16          | 52,79        |
| H14             | 48,87        | 48,18        | 15,99        | 113,04        | 53,16          | 52,98        |
| H15             | 48,14        | 47,66        | 15,77        | 111,57        | 53,16          | 52,35        |
| H16             | 48,59        | 47,98        | 14,04        | 110,62        | 53,19          | 51,92        |
| H17             | 48,96        | 48,43        | 15,83        | 113,22        | 53,17          | 53,04        |
| H18             | 48,50        | 47,87        | 14,24        | 110,61        | 52,16          | 52,84        |
| H19             | 48,65        | 48,15        | 15,52        | 112,32        | 52,18          | 53,54        |
| H20             | 48,53        | 48,04        | 15,65        | 112,22        | 53,19          | 52,60        |
| <b>ORTALAMA</b> | <b>48,64</b> | <b>48,07</b> | <b>15,53</b> | <b>112,24</b> | <b>52,95</b>   | <b>52,82</b> |

**Çizelge 3.13.** HYSA//YSA//BCO üçlü paralel bölütleme yapısı için süre sonuçları


| VERİ            | SÜRE (sn)    |              |              |               |                 |              |
|-----------------|--------------|--------------|--------------|---------------|-----------------|--------------|
|                 | HYSA         | YSA          | BCO          | Toplam        | Paralel Çalışma | Kazanç (%)   |
| N1              | 48,78        | 48,34        | 15,71        | 112,83        | 53,16           | 52,89        |
| N2              | 48,54        | 48,09        | 15,53        | 112,16        | 53,17           | 52,60        |
| N3              | 48,95        | 48,57        | 15,75        | 113,27        | 53,16           | 53,07        |
| N4              | 48,75        | 48,37        | 17,40        | 114,52        | 53,17           | 53,57        |
| N5              | 48,60        | 48,08        | 13,77        | 110,45        | 54,19           | 50,94        |
| N6              | 48,34        | 47,94        | 15,60        | 111,87        | 53,16           | 52,48        |
| N7              | 48,30        | 47,99        | 17,31        | 113,59        | 53,17           | 53,19        |
| N8              | 48,75        | 48,25        | 15,67        | 112,66        | 53,17           | 52,80        |
| N9              | 48,44        | 47,94        | 14,18        | 110,55        | 54,21           | 50,97        |
| N10             | 48,72        | 48,17        | 13,82        | 110,70        | 53,18           | 51,96        |
| H1              | 48,53        | 48,28        | 17,50        | 114,31        | 53,20           | 53,46        |
| H2              | 48,54        | 48,15        | 13,97        | 110,65        | 54,23           | 50,99        |
| H3              | 48,63        | 48,26        | 14,07        | 110,96        | 52,17           | 52,98        |
| H4              | 48,98        | 48,60        | 17,51        | 115,08        | 54,19           | 52,92        |
| H5              | 48,99        | 48,55        | 17,53        | 115,07        | 53,17           | 53,79        |
| H6              | 48,85        | 48,28        | 13,77        | 110,90        | 53,19           | 52,04        |
| H7              | 48,44        | 48,05        | 14,14        | 110,63        | 53,18           | 51,93        |
| H8              | 48,66        | 48,26        | 13,99        | 110,91        | 53,17           | 52,06        |
| H9              | 48,44        | 48,07        | 14,10        | 110,62        | 53,17           | 51,94        |
| H10             | 48,25        | 47,98        | 17,36        | 113,59        | 53,17           | 53,19        |
| H11             | 48,73        | 48,37        | 17,34        | 114,43        | 53,15           | 53,55        |
| H12             | 48,58        | 48,14        | 15,78        | 112,49        | 53,17           | 52,73        |
| H13             | 48,68        | 48,32        | 15,62        | 112,62        | 53,17           | 52,79        |
| H14             | 48,70        | 48,18        | 15,52        | 112,40        | 53,16           | 52,71        |
| H15             | 48,46        | 48,05        | 15,76        | 112,28        | 54,17           | 51,75        |
| H16             | 48,70        | 48,31        | 14,13        | 111,14        | 53,17           | 52,16        |
| H17             | 48,74        | 48,33        | 15,45        | 112,52        | 53,19           | 52,73        |
| H18             | 48,23        | 47,91        | 13,94        | 110,08        | 53,16           | 51,71        |
| H19             | 48,62        | 48,18        | 15,66        | 112,47        | 54,19           | 51,82        |
| H20             | 48,93        | 48,31        | 15,53        | 112,77        | 53,17           | 52,85        |
| <b>ORTALAMA</b> | <b>48,63</b> | <b>48,21</b> | <b>15,45</b> | <b>112,28</b> | <b>53,34</b>    | <b>52,49</b> |

### 3.4.3. Dörtlü paralel bölütleme sonuçları

Tez çalışmasında paralel hesaplama kullanılarak işlemciyi oluşturan 4 çekirdeğin her birinde bir algoritma aynı anda çalıştırılmıştır. Algoritmalar HYSA//Morfolojik//BCO//YSA şeklinde paralel olarak çalıştırılmıştır. Paralel olarak

dörtlü çalıştırma için blok gösterim Şekil 3.20’ de sunulmuştur. Blok diyagramdan da anlaşılacağı üzere dört algoritma aynı anda her biri ayrı işlemci çekirdeklerinde çalıştırılmakta ve aynı anda sonuçları elde edilmektedir. Böylece her algoritma için tek tek sonuç alınıp, sonra sonuçların değerlendirilmesi gibi bir prosedürün takip edilmesine gerek kalmamaktadır. Şekil 3.20’ de verilen blok gösterimde doğruluk hesabı da görülmektedir, ancak doğruluklar “Dört Algoritmanın Tek Tek Çalıştırılması ile Elde Edilen Bölütleme Sonuçları” başlığı altında sunulan sonuçlarla aynı olduğundan çizelgelerde bu değerler verilmemiştir. Paralel bölütlemelerde çekirdeklerde çalışan fonksiyonlar yani bölütleme algoritmaları değiştirilmemektedir. Sadece bu algoritmaların dördüde aynı anda çalıştırılarak süre kazancı sağlanmaktadır. Bu sebepten dörtlü paralel bölütlemelerde doğruluk değerleri görüntü verileri için değişmeyecektir. Dörtlü paralel bölütleme sonuçlarının sunulduğu çizelgelerde sadece süre analizi yapılmıştır.

Dörtlü paralel bölütleme yapısında elde edilen sonuçların süre analizi Çizelge 3.14’ de verilmiştir. Çizelgelerde algoritmalar için verilen süreler bir algoritmanın tek olarak çalışma süresini ifade etmektedir. “Toplam” şeklinde verilen değerler bir veri için bütün algoritmaların ayrı ayrı çalıştırılması ile elde edilen toplam süredir. Çizelge 3.14’ den görüleceği gibi HYSA ile bir görüntü üzerinde bölütleme gerçekleştirebilmek için harcanan ortalama süre 53.73 sn iken, morfolojik bölütleme için 52.99 sn, BCO için 17.22 sn ve YSA için 53.20 sn’ dir. Ortalama toplam süre dört algoritma için 177.14 sn olarak bulunmuştur. Buna karşılık paralel çalışmada dört algoritma ile bölütleme gerçekleştirilirken harcanan süre 58.01 sn olarak bulunmuştur. Paralel bölütleme ile elde edilen süre kazancı % 67.25’ dir.



Şekil 3.20. Dörtlü paralel bölütleme için blok gösterim

Çizelge 3.14. HYSA//Morfolojik//BCO//YSA dörtlü paralel bölütleme yapısı için süre sonuçları

| VERİ            | SÜRE (sn)    |              |              |              |               |                |              |
|-----------------|--------------|--------------|--------------|--------------|---------------|----------------|--------------|
|                 | HYSA         | Morfolojik   | BCO          | YSA          | Toplam        | Paralel İşleme | Kazanç (%)   |
| N1              | 53,45        | 52,84        | 17,83        | 53,30        | 177,41        | 58,30          | 67,14        |
| N2              | 53,84        | 52,94        | 17,50        | 52,89        | 177,17        | 58,29          | 67,10        |
| N3              | 53,55        | 52,72        | 17,48        | 52,86        | 176,61        | 57,27          | 67,57        |
| N4              | 54,10        | 53,15        | 18,65        | 53,20        | 179,09        | 58,31          | 67,44        |
| N5              | 53,90        | 53,25        | 15,87        | 53,54        | 176,57        | 58,29          | 66,99        |
| N6              | 53,54        | 52,72        | 17,12        | 52,96        | 176,34        | 58,31          | 66,93        |
| N7              | 53,97        | 52,92        | 19,91        | 53,06        | 179,86        | 58,27          | 67,60        |
| N8              | 53,48        | 52,84        | 17,72        | 52,97        | 177,01        | 57,30          | 67,63        |
| N9              | 54,06        | 53,22        | 15,73        | 53,37        | 176,38        | 58,31          | 66,94        |
| N10             | 54,02        | 53,30        | 15,57        | 53,73        | 176,62        | 58,32          | 66,98        |
| H1              | 53,65        | 52,89        | 19,15        | 53,19        | 178,87        | 57,34          | 67,94        |
| H2              | 53,82        | 52,96        | 15,69        | 53,19        | 175,68        | 58,34          | 66,79        |
| H3              | 54,00        | 53,06        | 16,06        | 53,71        | 176,83        | 58,32          | 67,02        |
| H4              | 53,84        | 53,04        | 19,05        | 53,08        | 179,02        | 57,31          | 67,99        |
| H5              | 53,89        | 53,05        | 19,41        | 53,32        | 179,67        | 57,31          | 68,11        |
| H6              | 53,70        | 52,75        | 15,62        | 53,13        | 175,20        | 57,32          | 67,28        |
| H7              | 53,54        | 52,93        | 15,50        | 53,02        | 174,99        | 58,32          | 66,67        |
| H8              | 53,60        | 53,02        | 15,61        | 53,16        | 175,40        | 58,32          | 66,75        |
| H9              | 53,88        | 53,20        | 15,77        | 53,16        | 176,02        | 58,32          | 66,87        |
| H10             | 53,70        | 53,03        | 19,05        | 53,23        | 179,01        | 57,27          | 68,00        |
| H11             | 53,65        | 53,13        | 19,27        | 53,43        | 179,48        | 58,28          | 67,53        |
| H12             | 53,77        | 53,46        | 17,87        | 53,53        | 178,63        | 58,36          | 67,33        |
| H13             | 53,80        | 53,08        | 17,44        | 53,28        | 177,61        | 58,32          | 67,16        |
| H14             | 53,59        | 52,72        | 17,30        | 52,86        | 176,47        | 58,34          | 66,94        |
| H15             | 53,62        | 53,14        | 17,60        | 53,19        | 177,55        | 58,32          | 67,15        |
| H16             | 53,80        | 52,87        | 15,36        | 53,21        | 175,25        | 57,29          | 67,31        |
| H17             | 53,60        | 53,10        | 17,21        | 53,32        | 177,23        | 58,30          | 67,10        |
| H18             | 53,54        | 52,97        | 15,40        | 53,10        | 175,01        | 57,29          | 67,26        |
| H19             | 53,38        | 52,44        | 17,49        | 52,64        | 175,96        | 58,33          | 66,85        |
| H20             | 53,55        | 52,99        | 17,50        | 53,25        | 177,29        | 58,31          | 67,11        |
| <b>ORTALAMA</b> | <b>53,73</b> | <b>52,99</b> | <b>17,22</b> | <b>53,20</b> | <b>177,14</b> | <b>58,01</b>   | <b>67,25</b> |

#### 4. TARTIŞMA

Bölütleme (segmentasyon), görüntüde işlem yapılacak bölgenin, yani ilgilenilen alanın çıkarılmasıdır. Başka bir deyişle görüntü işlemede tanıma ve sınıflandırma aşamalarına geçilebilmesi için, önce görüntüde tanımayı ve sınıflandırmayı ilgilendiren özelliklerin bulunduğu alanların çıkarılması, sonucu olumsuz yönde etkileyecek unsurların görüntüden elimine edilmesi gereklidir. Bu nedenlerle, bölütleme görüntü işlemenin ilk ve en önemli adımı olarak adlandırılır. Bir görüntünün bölütlenebilmesi için literatürde pek çok algoritma geliştirilmiştir. Yapay sinir ağları, bulanık c-ortalamalar kümeleme algoritması, genetik algoritmalar, hızlı bulanık c-ortalamalar kümeleme algoritması, hücrel sinir ağı algoritması bu bölütleme algoritmalarından bazılarıdır.

Görüntü işlemede problemi oluşturan görüntünün bölütlenecek kısımları problemin içeriğine ve istenen çözüme göre çeşitlilik arz eder. Bu durumda genellikle ilk uygulanan bölütleme algoritması problemin çözümünü sağlamaz ve farklı pek çok algoritma denemek gerekir. Bu algoritmaların hepsi için sonuç alma ve değerlendirme prosedürü büyük bir iş yükü ve zaman kaybını içerir. Söz konusu bölütleme algoritmalarının sonuçlarının aynı anda alınabilmesi bu zaman kaybını önleyecektir. Paralel hesaplama, bu algoritmaların aynı anda çalıştırılarak sonuçlarının değerlendirilmesini ve problemi oluşturan görüntü için en iyi metodun tespitini sağladığından çok önemlidir.

Paralel hesaplamada bir işlemci üzerindeki çekirdek sayısı kadar algoritma (fonksiyon) aynı anda icra edilebilmekte ve sonuçları kullanıcı tarafından değerlendirilebilmektedir. Paralel (aynı anda) çalıştırılan algoritmaların her biri bir işlemci çekirdeğinde çalıştırılmaktadır. Dolayısıyla paralel hesaplamada işlemi sınırlandırıcı tek unsur, kullanıcının sahip olduğu işlemcinin çekirdek sayısıdır. Gerçekleştirilen tez çalışmasında paralel hesaplama kullanılarak görüntü bölütlemeye işlem süresini azaltan yani problemi oluşturan görüntünün bölütlenmesi için doğru metodun daha hızlı bulunmasını sağlayan bir paralel bölütleme yapısı önerilmiştir. Çalışmada görüntülerin bölütlenmesi için yapay sinir ağları, bulanık c-ortalamalar kümeleme algoritması, hücrel sinir ağları ve morfolojik bölütleme algoritmaları kullanılmıştır.

İlk olarak çalışmada bölütleme için kullanılan bütün yapay zekâ algoritmaları ve morfolojik bölütleme teknikleri ile ayrı ayrı bölütleme işlemi gerçekleştirilmiş ve her biri için elde edilen sonuçlar doğru piksel sayısı ve doğruluk bakımından değerlendirilmiştir. Değerlendirme amacıyla Konya Başkent Üniversitesi Hastanesi Radyoloji Kliniği'nden alınan 10 sağlıklı ve 20 “akciğer kanseri” tanısı konmuş hastalıklı akciğer BT görüntüsü (Ceylan, 2009) kullanılmıştır. Bütün BT görüntüleri için dört metot ile elde edilen ortalama doğruluk değerleri Çizelge 5.1’de özetlenmiştir. Yapay sinir ağları ile bölütleme gerçekleştirilirken, görüntü ağı sunulmadan önce 2-boyutlu dalgacık dönüşümü kullanılarak görüntü boyutu azaltılmıştır. Dalgacık dönüşümü 1., 2. ve 3. seviyede gerçekleştirilmiştir ve  $752 \times 752$  piksel boyutlarındaki giriş görüntüsü sırasıyla her seviye için  $377 \times 377$ ,  $190 \times 190$  ve  $96 \times 96$  piksel boyutlarına indirgenmiştir. Elde edilen bu görüntüler sinir ağı için giriş görüntüsüdür. 2-boyutlu ayırık dalgacık dönüşümü hedef görüntüsüne de uygulanmıştır. 1. seviye dalgacık dönüşümü sonunda elde edilen görüntünün yani  $377 \times 377$  piksellik görüntünün sunulduğu sinir ağı sonuçları “YSA1”, 2. seviye dalgacık dönüşümü ile elde edilen görüntünün sunulduğu sinir ağı sonuçları “YSA2” ve 3. seviye dalgacık dönüşümü sonucu elde edilen görüntünün sunulduğu sinir ağı sonuçları “YSA3” olarak etiketlenmiştir. Giriş görüntü boyutu  $752 \times 752$  piksel olduğu için toplam piksel sayısı 565504’dür.

**Çizelge 5.1.** Bütün görüntüler için dört algoritma ile elde edilen ortalama doğruluk sonuçları

| METOT      | Doğru bulunan piksel sayısı | Doğruluk |
|------------|-----------------------------|----------|
| Morfolojik | 519372                      | 91,84    |
| YSA1       | 486979                      | 86,11    |
| YSA2       | 483286                      | 85,45    |
| YSA3       | 483420                      | 85,48    |
| BCO        | 515766                      | 91,2     |
| HYSA       | 526577                      | 93,09    |

Çizelge 5.1 incelenecek olursa, doğru piksel sayısı ve doğruluk bakımından en iyi sonuçlar HYSA yapısı ile elde edilmişlerdir. 30 akciğer BT görüntüsü için en iyi sonucu veren yapılar Çizelge 5.2’de sunulmuştur. Buradan da görüleceği gibi tek tek görüntü verileri üzerinde yapılan incelemelerde morfolojik bölütleme algoritması, 4 görüntü verisi üzerinde en iyi sonucu veren algoritmadır. Buna karşılık bulanık c-

ortalamalar kümeleme algoritması, 5 görüntü verisi üzerinde başarılı olmuştur. Yapay sinir ağı algoritması ise bu dört algoritma içinde karşılaştırma yapıldığında, görüntü verileri üzerinde hiç başarı gösterememiştir. Hücresel sinir ağı algoritmasının ise 21 görüntü verisi üzerinde en iyi sonucu veren algoritma olduğu görülmüştür. Çizelge 5.1 ve Çizelge 5.2’ de verilen sonuçlara dayanarak “görüntü bölütlemeye en iyi sonucu HYSA algoritması vermektedir” denilebilir. Ayrıca hücresel sinir ağı algoritması 10 sağlıklı görüntünün 9’ unda en yüksek doğruluğu veren yapıdır. Bu hücresel sinir ağının sağlıklı akciğer BT görüntülerinin bölütlenmesinde % 90 başarı sağladığını göstermektedir. Ayrıca 20 hastalıklı görüntünün 12’ sinde en iyi doğruluğu veren yapı yine HYSA olduğundan, hastalıklı görüntülerde de % 60 başarı sağladığı söylenebilir.

**Çizelge 5.2.** 30 BT görüntüsünde en iyi sonucu veren algoritmalar

| VERİ | METOT      |     |     |      |
|------|------------|-----|-----|------|
|      | Morfolojik | YSA | BCO | HYSA |
| N1   | X          |     |     |      |
| N2   |            |     |     | X    |
| N3   |            |     |     | X    |
| N4   |            |     |     | X    |
| N5   |            |     |     | X    |
| N6   |            |     |     | X    |
| N7   |            |     |     | X    |
| N8   |            |     |     | X    |
| N9   |            |     |     | X    |
| N10  |            |     |     | X    |
| H1   |            |     | X   |      |
| H2   |            |     |     | X    |
| H3   |            |     |     | X    |
| H4   |            |     | X   |      |
| H5   |            |     |     | X    |
| H6   |            |     |     | X    |
| H7   |            |     |     | X    |
| H8   |            |     | X   |      |
| H9   |            |     |     | X    |
| H10  |            |     |     | X    |
| H11  |            |     | X   |      |
| H12  |            |     |     | X    |
| H13  | X          |     |     |      |
| H14  |            |     |     | X    |
| H15  | X          |     |     |      |
| H16  |            |     |     | X    |
| H17  |            |     |     | X    |
| H18  |            |     |     | X    |
| H19  |            |     | X   |      |
| H20  | X          |     |     |      |

Çalışmada ikinci bir aşama olarak, paralel hesaplama gerçekleştirilerek süre kazancı sağlanması amaçlanmıştır. Paralel hesaplama, işlemci üzerindeki her çekirdeğin bir fonksiyonun icrasında kullanılmasını, böylece aynı anda bütün algoritmaların sonuçlarının elde edilmesini sağlar. Süre kazancının ne kadar sağlandığının değerlendirilebilmesi açısından algoritmaların tek tek çalışmasında (klasik bölütleme) harcadıkları toplam süre ve paralel bölütlemelerde harcanan süre karşılaştırılmıştır. Paralel bölütlemelerde algoritmalar ikili, üçlü ve dörtlü çalıştırılarak elde edilen sonuçların özeti Çizelge 5.3’ de sunulmuştur.

**Çizelge 5.3.** Paralel bölütleme ve klasik bölütlemenin süre olarak karşılaştırılması

| <b>Kombinasyonlar</b>      | <b>Klasik Çalışma için harcanan süre</b> | <b>Paralel Çalışma için harcanan süre</b> | <b>Süre Kazancı (%)</b> |
|----------------------------|------------------------------------------|-------------------------------------------|-------------------------|
| HYSA//Morfolojik           | 95,86                                    | 51,97                                     | 45,78                   |
| HYSA//YSA                  | 95,99                                    | 52,35                                     | 45,47                   |
| HYSA//BCO                  | 59,52                                    | 48,53                                     | 22,67                   |
| HYSA//Morfolojik//BCO      | 112,24                                   | 52,95                                     | 52,82                   |
| HYSA//YSA//BCO             | 112,28                                   | 53,34                                     | 52,49                   |
| HYSA//Morfolojik//BCO//YSA | 177,14                                   | 58,01                                     | 67,25                   |

Çizelge 5.3’ de elde edilen süre kazançları incelenecek olursa klasik bölütlemeye (algoritmaların tek tek bölütleme için çalıştırılması ve sonuçların değerlendirilmesi) göre, paralel bölütleme ile minimum % 22,67 maksimum % 67.25 kazanç sağlandığı görülmektedir. Klasik bölütleme için harcanan süre, paralel bölütleme yapılarını oluşturan algoritmaların her birinin bölütleme işlemi için kullandıkları sürelerin toplamı ile bulunur. Süre kazancı, paralel bölütlemelerde harcanan süre ile klasik bölütlemelerde harcanan sürenin farkının klasik bölütleme süresine oranını ifade eder.

Gerçekleştirilen tez çalışmasında akciğer bölgesi görüntülerinin bölütlenmesinde kullanılan bütün algoritmalar ile ortalama % 85-93 arasında doğruluk sağlanırken, aynı zamanda %67,25 süre kazancı elde edilmiştir. Çalışma sonuçlarının özellikle BDT sistemlerinin tasarımını hızlandırıcı bir etkiye sahip olacağı düşünülmektedir. Bu yönüyle tez çalışması, BDT sistemlerinde en önemli aşamayı teşkil eden bölütleme için hızlı ve verimli yeni bir model sunmaktadır.

Tez çalışmasında gerçekleştirilen bölütleme metotları ile elde edilen sonuçlar literatürde yapılan bölütleme çalışmaları ile karşılaştırılarak Çizelge 5.4’ de sunulmuştur. Çizelgeden de görüleceği gibi tez çalışması 30 görüntü verisi ile veri sayısı bakımından literatürdeki benzerlerinden daha ileri bir seviyedir. Çalışmada elde edilen sonuçlar % 93.09 doğrulukla literatürde iyi bir noktadır. Daha yüksek doğruluk değerine sahip çalışmaların çok az veri içerdiğine dikkat edilmelidir. Veri sayısının yüksek olması ve verilerin birbirlerine göre farklılıklarının olması doğruluk oranını düşüren bir etkidir.

**Çizelge 5.4.** Tez çalışmasındaki sonuçların literatürle karşılaştırılması

| <b>Çalışma</b>             | <b>Metot</b>                                                   | <b>Veri Özellikleri</b>                      | <b>Doğruluk</b> |
|----------------------------|----------------------------------------------------------------|----------------------------------------------|-----------------|
| Masulli ve Schenone (1999) | Posibilistik neuro-fuzzy c-means algoritması                   | 10 Beyin MR Görüntüsü (256 × 256 piksel)     | % 76            |
| Lin ve ark.(2003)          | Kohonen yarışmalı öğrenme algoritması                          | 8 Beyin MR                                   | % 53.3          |
| Shen ve ark. (2005)        | YSA optimizasyonlu komşuluk ilgisi                             | 256 × 256 piksel boyutlarında MR görüntüleri | % 96.93         |
| Zhang ve Jiang             | Geliştirilmiş hızlı bulanık c-ortalamalar kümeleme algoritması | 217 × 181 piksel Beyin MR görüntüleri        | % 97.12         |
| Bu tez çalışması           | Morfolojik algoritmalar                                        | 30 akciğer BT görüntüsü (752 × 752 piksel)   | % 91.84         |
| Bu tez çalışması           | YSA1                                                           | 30 akciğer BT görüntüsü (752 × 752 piksel)   | % 86.11         |
| Bu tez çalışması           | YSA2                                                           | 30 akciğer BT görüntüsü (752 × 752 piksel)   | % 85.45         |
| Bu tez çalışması           | YSA3                                                           | 30 akciğer BT görüntüsü (752 × 752 piksel)   | % 85.48         |
| Bu tez çalışması           | BCO                                                            | 30 akciğer BT görüntüsü (752 × 752 piksel)   | % 91.2          |
| Bu tez çalışması           | HYSA                                                           | 30 akciğer BT görüntüsü (752 × 752 piksel)   | % 93.09         |

## 5. SONUÇLAR VE ÖNERİLER

### 5.1. Sonuçlar

Görüntü bölütleme, görüntüde benzer alanlardaki pikselleri ayırma yada kümeleme olarak tanımlanabilir. Görüntünün bölütlenmesinde amaç, görüntünün sınıflandırılmasını veya tanınmasını zorlaştıran ve problemin çözümü ile ilgisi olmayan kısımların görüntüden çıkarılmasıdır. Son zamanlarda literatürde görüntü bölütleme çalışmalarının pek çoğu yapay zekâ tekniklerini içermektedir. Ancak problem oluşturan görüntü üzerinde istenilen bölütlemeyi gerçekleştirecek metodu bulmak için genellikle pek çok metodu denemek ve sonuçlarını değerlendirmek gerekir. Çünkü her görüntü için iyi sonuç veren bir bölütleme algoritmasından söz etmek mümkün değildir. Bu açıdan bakıldığında, paralel hesaplama pek çok algoritmayı aynı anda çalıştırarak sonuçlarının değerlendirilebilmesini sağladığından çok önemli bir araçtır. Paralel hesaplamada işlemci üzerindeki çekirdek sayısı kadar algoritma aynı anda icra edilerek sonuçlar değerlendirilebilmektedir. Bu da süre ve karşılaştırma bakımından önemli bir kazanç sağlar.

Gerçekleştirilen tez çalışmasında, akciğer BT görüntüleri üzerinde akciğer bölgesinin bölütlemesi paralel hesaplama mantığından hareketle yapay zekâ ve morfolojik bölütleme metotları kullanılarak gerçekleştirilmiştir. Böylece kısa sürede görüntü için istenilen çözümü veren metot tespit edilebilmektedir. Bölütlemedeki performans ve sürenin bir sonraki aşama olan sınıflandırma ya da tanı aşamalarını da etkileyeceği düşünülürse; çalışmanın mevcut BDT sistemlerinin performanslarının geliştirilmesinde en önemli adım olan görüntü bölütleme aşaması için verimli bir çözüm önerildiği söylenebilir.

Paralel hesaplama bir işlemcinin üzerindeki her çekirdekte bir algortimanın çalıştırılmasını sağladığından kayda değer bir süre kazancı sağlanmaktadır. Tezde gerçekleştirilen sistemin en önemli üstünlüğü, biyomedikal görüntülerin işlenmesinde karşılaşılan dezavantajları ortadan kaldırabilmesidir. Biyomedikal görüntülerin boyutlarının büyük olması sebebi ile görüntü üzerinde gerçekleştirilen tekniklerde sistemin yavaş olması, sonuçta elde edilen çıktıların istenilen görüntüden doğruluk açısından çok farklı olması ve tüm bu işlemler için yüksek performanslı bilgisayar sistemlerine ihtiyaç duyulması biyomedikal görüntü işlemede karşılaşılan

dezavantajlardır. Bu açıdan bakıldığında, çalışmanın temelini oluşturan paralel işleme, büyük veriler için hızlı sonuç elde edilmesinin yanı sıra, en iyi sonuca daha kısa sürede ulaşılmasını da sağlamaktadır.

Tez çalışmasında hücrel sinir ağı, yapay sinir ağı, bulanık c-ortalamlar kümeleme algoritması ve morfolojik bölütleme teknikleri kullanılarak akciğer BT görüntülerinin bölütlenmesi gerçekleştirilmiştir. Çalışmada amaç bir görüntü için en iyi bölütleme sonucunu veren metoda en kısa sürede erişmeyi sağlayan bir yöntem geliştirmektir. Bu amacı gerçekleştirmek için paralel hesaplama kullanılarak bir görüntü için bütün algoritmaların sonuçlarının aynı anda alınması ve değerlendirilerek en iyi metodun kullanıcıya sunulması sağlanmıştır.

30 akciğer BT görüntüsü üzerinde gerçekleştirilen çalışmalarda, 21 görüntü üzerinde en iyi bölütleme sonucu, ortalama % 93.09 doğruluk değerini veren HYSA algoritması ile alınmıştır. 5 görüntü üzerinde en iyi sonuca BCO algoritması ile erişilirken, 4 görüntüde ise en iyi sonucu morfolojik algoritma üretmiştir. Yapay sinir ağı kenar belirleme için iyi sonuçlar üretmesine rağmen istenilen bölütleme sonucuna yaklaşmadığından hiçbir görüntü üzerinde başarı elde edememiştir. Sonuçların değerlendirilmesinde doğru piksel sayısı ve doğruluk parametreleri kullanılmıştır.

Çalışmada önerilen metod ile sağlanan süre kazancını göstermek amacıyla; kullanılan bölütleme algoritmaları tek tek çalıştırılarak elde edilen toplam süre ile paralel (aynı anda) çalıştırılmalarıyla harcanan toplam süreler karşılaştırmalı olarak incelenmiştir. Dört çekirdekli bir işlemci üzerinde gerçekleştirilen paralel bölütlemeye klasik bölütleme (tek tek çalıştırma) ile harcanan süreye göre % 67.25 kazanç sağlanmıştır.

Böylece tez çalışmasında başlangıçta hedeflenen “görüntü bölütleme için en iyi metoda en kısa sürede ulaşılması” amacı gerçekleştirilmiştir.

## 5.2. Öneriler

Gerçekleştirilen tez çalışmasında, akciğer BT görüntülerinde akciğer bölgesinin bölütlenmesi için doğruluk oranı yüksek ve hızlı bir modelin oluşturulması amaçlanmıştır. Hedeflenen amaçlar doğrultusunda paralel işleme ve yapay zekâ metodları kullanılarak yeni bir model tasarlanmıştır.

Bölütleme görüntü işlemenin ilk ve en önemli adımıdır. Bu sebepten bölütlemenin doğruluk oranı yüksek ve hızlı gerçekleştirilmesi daha sonra gelecek tanı aşamasının hata oranlarını da doğrudan etkileyecektir.

Çalışmada önerilen paralel bölütleme modeli, görüntü üzerinde işlem yapması düşünülen bölütleme tekniklerinin aynı anda sonuç vermesini sağladığından klasik bölütlemeye (yani algoritmaların bir veri için ayrı ayrı çalıştırılmasına) göre % 67.25 süre kazancı vermektedir. Aynı zamanda çalışmada HYSIA yapısı ile bölütleme için %93.09 doğruluk elde edilmiştir. Çalışmada paralel işleme konusundaki tek sınır kullanılan işlemcinin çekirdek sayısıdır. İşlemcinin çekirdek sayısı ne kadarsa o kadar fonksiyon (bölütleme tekniği) aynı anda icra edilebilir.

Ayrıca hücrel sinir ağı yapısının şablon matrisini belirleyen parametrelerin başlangıç değerleri genetik algoritma gibi farklı bir yapay zekâ tekniği ile belirlenebilir. Böylece hücrel sinir ağı algoritması ile elde edilen ortalama % 93.09 doğruluk değeri daha yüksek değerlere çekilebilir.

Önerilen model kompleks değerli verileri de işleyebilir hale getirilirse kompleks-değerli sinyal işleme metotlarının uygulanmaya başlandığı manyetik rezonans görüntüleri üzerine de uygulanabilir. Ayrıca önerilen model bir sınıflama sistemi ile kaskat olarak kullanılırsa, akciğer kanseri tanısında büyük önemi olan nodüllerin belirlenmesi ve sınıflandırılması da gerçekleştirilmiş olur.

## KAYNAKLAR

- Ahmed, MN., Farag, AA., 1997, Two-stage neural network for volume segmentation of medical images, *Pattern Recognition*, 18, 1143-1151.
- Alejo, R., Cabello, JR., Cortijo, M., Rodriguez, I., Echave, I., Regadera, J., Arrazola, J., Aviles, Barreiro, Gargallo, D., Grana, M., 2003, Computer-assisted enhanced volumetric segmentation magnetic resonance imaging data using a mixture of artificial neural networks, *PubMed*, 21, 901-912.
- Armato, S. G., Li, F. Giger, M. L., MacMahon, H., Sone, S., Doi, K., 2002, Lung cancer: performance of automated lung nodule detection applied to cancers missed in a BT screening program, *Radiology*, 225, 685-692.
- Aubry, C. B., Raffy, , Yang, W., Castellino, R. A., Grenier, A., 2007, Computer-aided detection of solid lung nodules on follow-up MDCT screening: evaluation of detection, tracking and reading time, *American Journal of Roentgenology*, 189, 948-955.
- Bal, A., 2002, Dalgacık Yapay Sinir Ağları ve Öğrenme Algoritması, Doktora Tezi, *Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Brown, M. S., McNitt-Gray, M. F., Goldin, J. G., Suh, R. D., Sayre, J. W., Aberle, D. R., 2001, Patient-specific models for lung nodule detection and surveillance in BT images, *IEEE Transactions on Medical Imaging*, 20, no.12, 1242-1250.
- Campbell, NW., Mackeown, WPJ., Thomas, BT., Troschianko, T., 1997, Interpreting image databases by region classification, 30, 555-563.
- Ceylan, M., 2009, Bilgisayar Tomografili Akciğer Görüntülerinin Değerlendirilmesinde Kompleks Değerli Yeni Bir Akıllı Sistem Tasarımı, Doktora Tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya.
- Chen, S., Zhang, D., 2004, Roboust image segmentation using FCM with spatial constraints based on new kernel-induced distance measure, *IEEE Trans.on Systems, man and Cybernetics-Part B*, 34, 1907-1916.
- Chua L. O., Yang L., 1988a, Cellular Neural Networks: Application, *IEEE Transactions on Circuit and Systems*, 35 (10), 1273-1290.

- Chua L. O., Yang L., 1988b, Cellular Neural Networks: Theory, *IEEE Transactions on Circuit and Systems*, 35 (10), 1257-1272.
- Chua L. O., 1991, An Analytic Method for Designing Simple Cellular Neural Networks, *IEEE Transactions on Circuit and Systems*, 38 (11), 1332-1341.
- Chun, D., Yang, H., 1996, Roboust image segmentation using genetic algorithm with a fuzzy measure, *Pattern recognition*, 29, 1195-1211.
- Czuni, L., Sziranyi, T., 2001, Motion segmentation and tracking with edge relaxation and optimization using fully parallel methods in the cellular nonlinear network architecture, 7, 77-95.
- Dokur, Z., Ölmez, T., 2002, Segmentation of ultrasound images by using a hybrid neural network, *Pattern Recognition Letter*, 23, 1825-1836.
- Dokur, Z., Ölmez, T., 2003, Segmentation of MR and CT images by using a quantiser neural network, *Neural Computing and Applications*, 11, 168-177.
- Elmas, Ç., 2007, Yapay Zeka Uygulamaları, Seçkin Yayıncılık, Ankara.
- Enquobahrie, A. A., Reeves, A., Yankelevitz, D. F., Henscheke, I., 2007, Automated detection of small pulmonary nodules in whole lung CT scans, *Academic Radiology*, 14 (5), 579-593.
- Fu, JC., Lee, SK., Wong, STC., Yeh, JY., Wang, AH., Wu, HK., 2005, Image segmentation feature selection and pattern classification for mammographic microcalcifications, 29, 419-429.
- Gabriel, E., Venkatesan, V., Shah, S., 2010, Towards high performance cell segmentation in Multispectral fine needle aspiration cytology of thyroid lesions, *Computer Methods and Programs in Biomedicine*, 98 (3), 231-240.
- Ginger, M. L., Giger, M.L., Bae, K.T., MacMahon, H., 1994, Computerized detection of pulmonary nodules in computed tomography images, *Invest. Radiol.* 29, 459–465.
- Gonzalez, R., Woods, R.E., Eddins, S.L., Digital Image Processing Using Matlab, Prentice Hall, 2004, USA.

- Güzeliş C., Karamahmut S., 1995, Recurrent perceptron learning algorithm for CNNs with application to edge detection, *IEEE Int. Conf. Neural Networks*, 2, 1134-1139.
- Hardie, R. C., Rogers, S. K., Wilson, T., Rogers, A., 2008, Performance analysis of a new computer aided detection system for identifying lung nodules on chest radiographs, *Medical Image Analysis*, 12, 240-258.
- Haykin, S., 1999, *Neural Networks: A Comprehensive Foundation*, Prentice Hall International.
- Hirose, T., Nitta, N., Shiraishi, J., Nagatani, Y., Takahashi, M., Murata, K., 2008, Evaluation of computer-aided diagnosis software for the detection of lung nodules on multidetector row computed tomography: JAFROC study for the improvement in radiologists diagnostic accuracy, *Academic Radiology*, 15 (12), 1505-1512.
- Huang, X., Xie, Y., Liu, D., Hou, L., 2009 Using fuzzy c-means cluster for histogram-based color image segmentation, *IEEE Internatinal Conference on Information Technology and Computer Science*.
- Iscan, Z., Kurnaz, M., Dokur, Z., Olmez, T., 2006, Ultrasounda image segmentation by using wavelet transform and self-organizing neural network, *Neural Information Processing-Letters and Review*, 10, 183-191.
- Iscan, Z., Yuksel, A., Dokur, Z., Korürek, M., Ölmez, T., 2009, Medical image segmentation with transform and moment based features and in cremental supervised neural network, 19, 890-901.
- Jaffar, MA., Naveed, N., Ahmed, B., Hussain, A., Mirza, AM., 2009, Fuzzy c-means clustering with spatial information for color image segmentation, *IEEE*.
- Kakar, M., Olsen, D. R., 2009, Automatic segmentation and recognition of lungs and lesion from BT scans of thorax, *Computerized Medical Imaging and Graphics*, 33, 72-82.
- Kobashi, S., Kamiura, N., Hata, Y., Miyawaki, F., 2001, Volume-quantization-based neural network approach to 3D MR angiography image segmentation, *Image and Vision Computing*, 19, 185-193.

- Kurugollu, F., Sankur, B., Harmancı, AE., 2002, Image segmentation by relaxation using constraint satisfaction neural network, *Image and Vision Computing*, 20 (7), 483-497.
- Kwok, SH., Constantinides, AG., 1999, A parallel recursive shortest spanning tree algorithm for image segmentation in distributed computing environment, *Journal of Parallel and Distributed Computing*, 56 (3), 181-207.
- Lee, K. W., Kim, M., Gierada, D. S., Bae, K. T., 2007, Performance of a computer-aided program for automated matching of metastatic pulmonary nodules detected on follow-up chest CT, *American Journal of Radiology*, 189, 1077-1081.
- Lin, J.S., 2000, Segmentation of medical images through a penalized fuzzy Hopfield network with moments preservation, *Journal of Chinese Institute of Engineers*, 23, 633-643.
- Lo, S.C.B., Lou, S.-L.A., Lin, J.-S., Freedman, M., Chien, M.V., Mun, S.K., 1995, Artificial convolutional neural network techniques and applications for lung nodule detection, *IEEE Transactions on Medical Imaging*, 14, 711-718.
- Masulli, F., Schenone, A., 1999, A fuzzy clustering based segmentation system as support to diagnosis in medical imaging, *Artificial Intelligence in Medicine*, 16(2), 129-147.
- Maulik, U., Bandyopadhyay, S., 2000, Genetic algorithm-based clustering technique, *Pattern Recognition*, 33, 1455-1465.
- Middleton, I., Damper, R.I., 2004, Segmentation of magnetic resonance images using a combination of neural networks and active contour models, *Medical Engineering and Physics*, 26, 71-86.
- Özmen, A., 2001, Hücresel yapay sinir ağları ve görüntü işleme uygulamaları, Doktora Tezi, *İstanbul Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul
- Papadopoulos, A., Fotiadis, D.I., Likas, A., 2002, An automatic microcalcification detection system based on a hybrid neural network classifier, *Artificial Intelligence in Medicine*, 25, 149-167.

- Pham, D., 2002, Fuzzy clustering with spatial constraints, *International Conference on Image Processing*.
- Sammauda, R., Niki, N., Nishitani, H., 1997, Hopfield neural network for the multichannel segmentation of magnetic resonance cerebral images, *Pattern Recognition*, 30 (6), 921-927.
- Schaefer, G., Hassanien, A.E., Jiang, J., 2008, Computational Intelligence in Medical Imaging, *Taylor and Francis Group CRC Press*.
- Shen, S., Sandham, W., Granat, M, Sterr, A., 2005, MRI fuzzy segmentation of brain tissue using neighborhood attraction with neural network optimization, *IEEE Transactions on Information Technology in Biomedicine*, 9, 459-467.
- Shitong, W., Duan, F., Min, X., Dwen, H., 2007, Advanced fuzzy cellular neural network: Application to CT liver images, *Artificial Intelligence in Medicine*, 39 (1), 65-77.
- Suzuki, H., Matsimoto, T., Chua, L. O., 1992, A CNN Handwritten Character Recognizer , *International Journal of Circuit Theory and Application*, 20, 601-612.
- Sziranyi, T., Csapodi, M., 1998, Texture Classification and Segmentation by Cellular Neural Networks Using Genetic Learning, *Computer Vision and Image Understanding*, 71 (3), 255-270.
- Sziranyi, T., Zerubia, J., Czuni, L., Geldreich, D., Kato., 2000, Image Segmentation Using Markov Random Field Model in Fully Parallel Cellular Network Architectures, 6, 195-211.
- Tsai, H., Horng, S., Lee, S., Tsar, S., Kao, T., 1997, Parallel hierarchical clustering algorithms on processor arrays with a reconfigurable bus system, *Pattern Recognition*, 30 (5), 801-815.
- Vilarino, DL., Cabello, D., Pardo, XM., Brea VM., 2003, Cellular neural networks and active contours: a tool for image segmentation, *Image and Vision Computing*, 21(2), 189-204.

- Wang, S., Xu, M., 2006, A new detection algorithm (NDA) based on fuzzy cellular neural Networks for white blood cell detection, *IEEE Trans. On Information Technology Biomedical*, 10 (1), 5-10.
- Wang, Y., Yuan, B., 2001, A novel approach for human face detection from color images under complex background, *Pattern Recognition*, 34, 1983-1992.
- Wang, Z., Lu, R., 2008, A new algorithm for image segmentation based on fast fuzzy c-means clustering, *IEEE International Conference on Computer Science and Software Engineering*.
- Wismüller, A., F, Vietze., 2000, Segmentation with neural network, *Academic Press*.
- Wismüller, A., Vietze, F., Behrends, J., Meyer-Baese, A., Reiser, M., Ritter, H., 2004, Fully automated biomedical image segmentation by self-organized model adaptation, *Neural Networks*, 17, 1327-1344.
- Xin, J., Shu, X., 2008, Image segmentation algorithm based on improved weighted fuzzy c-means clustering, *IEEE International Symposium on Information Science and Engineering*.
- Xu, X.W., Doi, K., Kobayashi, T., MacMahon, H., Giger, M., 1997, Development of an improved CAD scheme for automated detection of lung nodules in digital chest images, *Medical Physics*, 24, 1395–1403.
- Zhang, X., Jiang, L., 2009, An image segmentation algorithm based on fuzzy c-means clustering, *IEEE International Conference on Digital Image Processing*.

## EKLER

### EK-1 Yapay sinir ağı algoritmasına ait program

```
function [dogruluk_ysa sure Ic_ysa egt_dogru egt_yanlis egt_toplam]=ysa_image_aa1(image)
tic

I=image;
I=im2double(I);
I=rgb2gray(I);

% egitim verileri
egt_giris=double(I(1:752,1:752));
[CA1_egt,CH1_egt,CV1_egt,CD1_egt]=dwt2(egt_giris,'db2');
[CA_egt,CH_egt,CV_egt,CD_egt]=dwt2(CA1_egt,'db2');
load nor1_h;
egt_hedef=im2bw(nor1_h);
[CA1_hedef,CH1_hedef,CV1_hedef,CD1_hedef]=dwt2(egt_hedef,'db2');
[CA_hedef,CH_hedef,CV_hedef,CD_hedef]=dwt2(CA1_hedef,'db2');

% test verileri
I1=imread('nor5.bmp');
test_giris=double(I1(1:752,1:752));
[CA1_testg,CH1_testg,CV1_testg,CD1_testg]=dwt2(test_giris,'db2');
[CA_testg,CH_testg,CV_testg,CD_testg]=dwt2(CA1_testg,'db2');
load nor5_h;
test_hedef=im2bw(nor5_h);
[CA1_testh,CH1_testh,CV1_testh,CD1_testh]=dwt2(test_hedef,'db2');
[CA_testh,CH_testh,CV_testh,CD_testh]=dwt2(CA1_testh,'db2');

% Yapay sinir ağı kodları
rand('state',0);
net=newff(minmax(CA_egt),[24 190],{'hardlim','hardlim'},'traingdx');
net.trainParam.show = 200; % her 200 iterasyonda hata grafiğini yeniler
net.trainParam.epochs = 1500;% maksimum iterasyon sayısı=10000
net.trainParam.goal = 0;% hedeflenen hata=0
net.trainParam.time=inf;% süre sınırsız
net.trainParam.max_fail=5;
net.trainParam.min_grad = 1e-20;% ardışık iki iterasyon arasındaki lokal hata farkı
net.trainParam.lr=0.7;% öğrenme oranı 0.7 olarak alınmıştır
net.trainParam.mc=0.9; % momentum sabiti 0.9 olarak alınmıştır
[net,tr]=train(net,CA_egt,CA_hedef);
egt_ag_cikis=sim(net,CA_egt); % Egitilen YSA' da girişin simüle edilmesi ve çıkışların üretilmesi
test_ag_cikis=sim(net,CA_testg); % eğitilen YSA' nın test girişleri ile simüle edilmesi

% Egitim hatasının hesaplanması
egt_sonuc1=idwt2(egt_ag_cikis,CH_hedef,CV_hedef,CD_hedef,'db2');egt_sonuc2=egt_sonuc1(1:377,1:377);
egt_sonuc=idwt2(egt_sonuc2,CH1_hedef,CV1_hedef,CD1_hedef,'db2');
egt_hata1=sum(abs(egt_hedef-egt_sonuc));
egt_hata =((sum(egt_hata1))/(752.*752)).*100;

% test hatasının hesaplanması
```

```

test_sonuc1=idwt2(test_ag_cikis,CH_testh,CV_testh,CD_testh,'db2');test_sonuc2=test_sonuc1(1:377,1:3
77);
test_sonuc=idwt2(test_sonuc2,CH1_testh,CV1_testh,CD1_testh,'db2');
goruntu=(test_sonuc.*egt_hedef);
test_hata1=sum(abs(test_hedef-goruntu));
test_hata=((sum(test_hata1))/(752.*752)).*100;

I4=test_sonuc;
Ic_ysa=im2bw(I4);
load nor5_h;
lh=im2bw(nor5_h);
egt_dogru=0;egt_yanlis=0;
for k=1:752
    for m=1:752
        if abs(lh(m,k)-Ic_ysa(m,k))==0;
            egt_dogru=egt_dogru+1;
        else egt_yanlis=egt_yanlis+1;
        end
    end
end
egt_dogru
egt_yanlis
egt_toplam=egt_dogru+egt_yanlis

dogruluk_ysa=100*(egt_dogru/egt_toplam)
sure=toc % program için harcanan CPU süresi

```

## EK-2 Bulanık c-ortalamalar kümeleme algoritmasına ait program

```

function [dogruluk_fuzzy sure Ic_fuzzy egt_dogru egt_yanlis egt_toplam]=fuzzycmeans_aa1(image)
tic
IM=image;
IM=im2double(IM);
IM=rgb2gray(IM);
IM=IM(1:752,1:752);
cc1=7;
cc2=250;

[maxX,maxY]=size(IM);
IMM=cat(3,IM,IM);
ttFcm=0;

while(ttFcm<20)
    ttFcm=ttFcm+1

    c1=repmat(cc1,maxX,maxY);
    c2=repmat(cc2,maxX,maxY);
    if ttFcm==1
        test1=c1; test2=c2;
    end
    c=cat(3,c1,c2);

    ree=repmat(0.000001,maxX,maxY);
    ree1=cat(3,ree,ree);

    distance=IMM-c;
    distance=distance.*distance+ree1;

    daoShu=1./distance;

    daoShu2=daoShu(:,1)+daoShu(:,2);
    distance1=distance(:,1).*daoShu2;
    u1=1./distance1;
    distance2=distance(:,2).*daoShu2;
    u2=1./distance2;

    ccc1=sum(sum(u1.*u1.*IM))/sum(sum(u1.*u1));
    ccc2=sum(sum(u2.*u2.*IM))/sum(sum(u2.*u2));

    tmpMatrix=[abs(cc1-ccc1)/cc1,abs(cc2-ccc2)/cc2];
    pp=cat(3,u1,u2);

    for i=1:maxX
        for j=1:maxY
            if max(pp(i,j,:))==u1(i,j);
                IX2(i,j)=1;
            else
                IX2(i,j)=2;
            end
        end
    end

    if max(tmpMatrix)<0.0001
        break;
    else

```

```

        cc1=ccc1;
        cc2=ccc2;

    end

    for i=1:maxX
        for j=1:maxY
            if IX2(i,j)==2
                IMMM(i,j)=254;
            else
                IMMM(i,j)=8;
            end
        end
    end
end
end

%=====
% Görüntünün elde edilmesi
for i=1:maxX
    for j=1:maxY
        if IX2(i,j)==2;
            IMMM(i,j)=200;
        else
            IMMM(i,j)=1;
        end
    end
end
end

%=====

IMMM=uint8(IMMM);
I4=IMMM;
load nor1_h;
lh=nor1_h;
Ic_fuzzy=I4;
egt_dogru=0;egt_yanlis=0;

for k=1:752
    for m=1:752
        if abs(lh(m,k)-Ic_fuzzy(m,k))==0;
            egt_dogru=egt_dogru+1;
        else egt_yanlis=egt_yanlis+1;
        end
    end
end
egt_dogru
egt_yanlis
egt_toplam=egt_dogru+egt_yanlis

dogruluk_fuzzy=100*(egt_dogru/egt_toplam)
sure=toc

```

### EK-3 Hücresel yapay sinir ağı algoritmasına ait program

```

function [dogruluk_dhysa sure Ic_dhysa egt_dogru egt_yanlis egt_toplam]=DHYSA_CI_aa1(image)

tic

image=im2double(image);
image=rgb2gray(image);
x{1}=image;

%===== C I
=====

C=[-0.319438 -0.179828 -0.319438 %5 ler 3 oldu...
   -0.370861  3.633786 -0.370861
   -0.319438 -0.179828 -0.319438];
I=[-1.107413];

%===== CNN Algoritmasi
=====

i=2;
[k l]=size(x{1});
bir=ones(k,l);
y{1}=((1/2)*(abs(x{1}+bir)-abs(x{1}-bir)));
c=conv2(y{1}+x{1},C,'same');

x{2}=c+I;

while i~=1000
y{i}=((1/2)*(abs(x{i}+bir)-abs(x{i}-bir)));
c=conv2(y{i}+x{1},C,'same');
x{i+1}=c+I;

IMMM=y(i);

%===== karsilastirma
=====

yy=sum(sum(abs(y{i})));
if yy~=k*l
i=i+1;
else
it=i;
i=1000;
end
end
disp('iterasyon sayisi')
it

I=y{it};
level = graythresh(I);
BW = im2bw(I,level);
acquired_image=BW;
A=ones(752,752);
A=double(A);
acquired_image=acquired_image(1:752,1:752);
acquired_image=double(acquired_image);
[r,c]=size(acquired_image);

```

```

for n=1:c;% Matris uzunluğunun döngüde belirtilmesi
for i=1:r;% Matris y uzunluğunun döngüde belirtilmesi
B(i,n)=A(i,n)-acquired_image(i,n);
end
end
I4=B;
load nor5_h;
lh=nor5_h;
Ic_dhysa =im2bw(I4);
egt_dogru=0;egt_yanlis=0;

for k=1:752
    for m=1:752
        if abs(lh(m,k)-Ic_dhysa(m,k))==0;
            egt_dogru=egt_dogru+1;
        else egt_yanlis=egt_yanlis+1;
        end
    end
end
egt_dogru
egt_yanlis
egt_toplam=egt_dogru+egt_yanlis

dogruluk_dhysa=100*(egt_dogru/egt_toplam)

sure=toc

```

## EK-4 Morfolojik bölütleme algoritmasına ait program

```

function [dogruluk_morfo sure Ic_morfo egt_dogru egt_yanlis egt_toplam]=morfojeni_aa1(image)

tic

I=image;
I=I(1:752,1:752,:);
a=I;
b=rgb2gray(a);
c=imextendedmax(b,120);
d=bwmorph(c,'majority');
f=imcomplement(d);
g=imfill(f,'holes');
lut = makelut('sum(x(:)) == 4',2);
BW2 = applylut(g,lut);
SE = strel('line',5,45);
SE1 = strel('diamond', 5);
BW2=imcomplement(BW2);
e = imdilate(BW2,SE);
h= imdilate(e,SE1);
acquired_image=imcomplement(h);

I4=acquired_image;
load nor5_h;
lh=nor5_h;
Ic_morfo=im2bw(I4);
egt_dogru=0;egt_yanlis=0;

for k=1:752
    for m=1:752
        if abs(lh(m,k)-Ic_morfo(m,k))==0;
            egt_dogru=egt_dogru+1;
        else egt_yanlis=egt_yanlis+1;
        end
    end
end
egt_dogru;
egt_yanlis;
egt_toplam=egt_dogru+egt_yanlis;

dogruluk_morfo=100*(egt_dogru/egt_toplam);
sure=toc;

```

## EK-5 İkili paralel bölütlemeye ait program

```
function [results]=parallel1(Y)

tic
image=imread(Y);
sched=findResource('scheduler','configuration', 'local');
job=createJob(sched);
task1= createTask(job,'DHYSA_CI_aa1',6,{image})
task2= createTask(job,'morfojeni_aa1',6,{image})
submit(job);
waitForState(job, 'finished');
results = getAllOutputArguments(job);

if results{1,1}>results{2,1}
imshow(results{1,3});title('DHYSA SONUCU')
else
imshow(results{2,3});title('MORFOLOJIK SONUCU')
end
sure_parallel=toc
```

**EK-6 Üçlü paralel bölütlemeye ait program**

```
function [results]=parallel_three1(Y)

tic
image=imread(Y);
sched=findResource('scheduler','configuration', 'local');
job=createJob(sched);
task1= createTask(job,'DHYSA_CI_aa1',6,{image})
task2= createTask(job,'morfojeni_aa1',6,{image})
task3= createTask(job,'fuzzycmeans_aa1',6,{image})
submit(job);
waitForState(job, 'finished');
results = getAllOutputArguments(job);
sure_parallel=toc
```

**EK-7 Dörtlü paralel bölütmeye ait program**

```
function [results]=parallel_four(Y)

tic
image=imread(Y);
sched=findResource('scheduler','configuration', 'local');
job=createJob(sched);
task1= createTask(job,'DHYSA_CI_aa1',6,{image})
task2= createTask(job,'morfojeni_aa1',6,{image})
task2= createTask(job,'fuzzycmeans_aa1',6,{image})
task2= createTask(job,'ysa_image_aa1',6,{image})
submit(job);
waitForState(job, 'finished');
results = getAllOutputArguments(job);

sure_parallel=toc
```

## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

**Adı Soyadı** : Yasemin PEKTATLI  
**Uyruğu** : TC  
**Doğum Yeri ve Tarihi** : Konya, 1986  
**Telefon** : 0506 8655029  
**Faks** : -  
**e-mail** : ypektatli@yahoo.com

### EĞİTİM

| Derece        | Adı, İlçe, İl                                                          | Bitirme Yılı |
|---------------|------------------------------------------------------------------------|--------------|
| Lise          | : Süleyman Demirel Milli Piyango Anadolu Lisesi,<br>Karatay, Konya     | 2004         |
| Üniversite    | : Selçuk Üniversitesi, Müh.Mim.Fak. Elk.-Elt. Müh.,<br>Selçuklu, Konya | 2008         |
| Yüksek Lisans | : Selçuk Üniversitesi, Müh.Mim.Fak. Elk.-Elt. Müh.<br>Selçuklu, Konya  | ---          |

### İŞ DENEYİMLERİ

| Yıl      | Kurum        | Görevi |
|----------|--------------|--------|
| 2008-... | Türk Telekom | Uzman  |

**UZMANLIK ALANI:** XDSL, IP TV, Biyomedikal Görüntü işleme

**YABANCI DİLLER:** İngilizce

### BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

### YAYINLAR

1. **Y.Pektatlı**, A.M.Aktan, Y.Özbay, "Sayısal görüntü işleme teknikleri ile diş görüntülerinin analizi ve dental özelliklerinin çıkarılması", Biyomut 2008, Biyomedikal Mühendisliği Ulusal Toplantısı, 29-31 Mayıs 2008, ODTÜ, Ankara