



**İSTANBUL ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**YÜKSEK LİSANS TEZİ**

**YAPAY SİNİR AĞLARI İLE BEYİN TÜMÖRÜ  
TOMOGRAFİ GÖRÜNTÜLERİNİN SINIFLANDIRILMASI**

**Elkt.Müh. Serdar KARGIN  
Biyomedikal Mühendisliği Anabilim Dalı**

**Danışman  
Prof.Dr. O.Nuri UÇAN**

**Ekim, 2007**

**İSTANBUL**

ÖNSÖZ

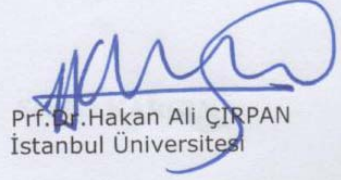
Bu çalışma 19/10/2007 tarihinde aşağıdaki jüri tarafından Biyomedikal Mühendisliği Anabilim Dalı Biyomedikal Mühendisliği programında ~~Doktora~~ / Yüksek Lisans Tezi olarak kabul edilmiştir.

Bu çalışma boyunca yardımlarına uğremeyen değerli konusmalarına ve çalışma adımlarında gösterdikleri beşerlik için teşekkür ederim.

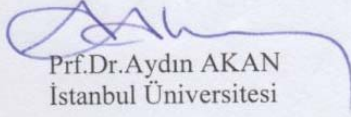
Tez Jürisi



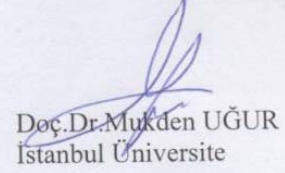
Prof. Dr. Osman Nuri UÇAN  
İstanbul Üniversitesi



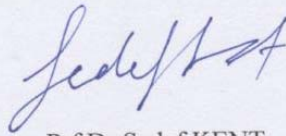
Prof. Dr. Hakan Ali ÇIRPAN  
İstanbul Üniversitesi



Prof. Dr. Aydın AKAN  
İstanbul Üniversitesi



Doç. Dr. Mukden UĞUR  
İstanbul Üniversite



Prof. Dr. Sedef KENT  
İstanbul Teknik Üniversitesi

## **ÖNSÖZ**

Lisans ve yüksek lisans öğrenimim sırasında ve tez çalışmalarım boyunca gösterdiği her türlü destek ve yardımdan dolayı çok değerli hocam Prof. Dr. O.Nuri UÇAN'a en içten dileklerle teşekkür ederim.

Bu çalışma boyunca yardımlarını esirgemeyen değerli komutanlarıma ve çalışma arkadaşlarıma teşekkürü borç bilirim.

**Ekim, 2007**

**Serdar KARGIN**

## İÇİNDEKİLER

ÖNSÖZ .....	I
İÇİNDEKİLER .....	II
ŞEKİL LİSTESİ .....	V
TABLO LİSTESİ .....	VII
SEMBOL LİSTESİ .....	VIII
ÖZET .....	IX
SUMMARY .....	X
<b>1. GİRİŞ .....</b>	<b>1</b>
1.1. TOMOGRAFİK GÖRÜNTÜLEME.....	1
1.2. TÜMÖR GÖRÜNTÜLERİNİN ELDE EDİLMESİ.....	2
1.2.1. Bilgisayarlı Beyin Tomografisi (BBT) .....	2
1.2.1.1. <i>Bilgisayarlı Tomografinin Yan Etkileri</i> .....	3
1.2.1.2. <i>İletim Tomografisi</i> .....	4
1.2.1.3. <i>Radon Dönüşümü</i> .....	6
1.2.1.4. <i>Geri Projeksiyon (İzdüşürme) Operatörü</i> .....	7
1.2.1.5. <i>Projeksiyon Teoremi</i> .....	9
1.2.1.6. <i>Ters Radon Dönüşümü</i> .....	10
1.2.1.7. <i>Konvolüsyon Geri-Projeksiyon Metodu</i> .....	12
1.2.1.8. <i>Filtre Geri-Projeksiyon Metodu</i> .....	13
1.2.2. Manyetik Rezonans Görüntüleme .....	14
1.2.2.1. <i>Atomik Çekirdeklerin Manyetik Alandaki Davranışları</i> .....	15
1.2.2.2. <i>Çekirdeklerin RF Darbeleri Yoluyla Uyarılması</i> .....	18
1.2.2.3. <i>RF Darbesinin Kesilmesinden Sonra Çekirdek Gevşemesi</i> .....	19
1.2.2.4. <i>MR İşaretlerinin Algılanması</i> .....	20

1.2.3. Pozitron Emisyon Tomografisi .....	23
1.2.4. Anjiyografi .....	23
1.2.5. Tek Foton Emisyonlu Bilgisayar Tomografisi.....	24
<b>2. GENEL KISIMLAR .....</b>	<b>26</b>
2.1. YAPAY SİNİR AĞLARI KAVRAMI VE TARİHSEL GELİŞİMİ .....	26
2.2. YAPAY SİNİR AĞLARININ TANIMI VE MODELİ .....	35
2.2.1. Biyolojik Beyinin İşlevi .....	35
2.2.2. Biyolojik Sinirin Yapısı ve Modeli .....	36
2.3. YAPAY SİNİR AĞLARININ MİMARİSİ VE İŞLEM ELEMANI .....	39
2.3.1. Giriş İşareti Sınıfları .....	41
2.3.2. Bağlantı Geometrilere .....	42
2.4. AĞ TIPLERİ .....	43
2.5. EŞİK FONKSİYONLARI .....	44
<b>3. MALZEME VE YÖNTEM.....</b>	<b>47</b>
3.1. YAPAY SİNİR AĞLARINDA EĞİTME .....	47
3.1.1. Öğreticili Eğitim .....	47
3.1.2. Skor ile Eğitim .....	48
3.1.3. Kendini Düzenleme ile Eğitim .....	48
3.2. YAPAY SİNİR AĞLARINDA ÖĞRENME .....	49
3.2.1. İdrak .....	50
3.2.2. Çok Katmanlı İdrak .....	52
3.2.3. Hatanın Geriye Yayılması Algoritması ve Delta Kuralı .....	54
3.2.4. Öğrenme ve Momentum Katsayıları .....	59
<b>4. BULGULAR .....</b>	<b>60</b>
4.1. NESNE TANIMA .....	60
4.2. UYGULAMA ÖRNEKLER .....	61
<b>5. TARTIŞMA VE SONUÇ .....</b>	<b>69</b>
5.1. SONUÇLAR .....	69
5.2. TARTIŞMA .....	71
<b>KAYNAKLAR .....</b>	<b>73</b>

<b>ÖZGEÇMİŞ</b> .....	<b>76</b>
-----------------------	-----------

## ŞEKİL LİSTESİ

Şekil 1.1	: İki daire için farklı açılarda elde edilen iki izdüşüm .....	1
Şekil 1.2	: X-ışınlı CT tarama sistemi .....	5
Şekil 1.3	: Bilgisayarlı tomografide projeksiyon görüntüleme geometrisi.....	5
Şekil 1.4	: $(r, \Phi)$ koordinatlarında $g_1(s)$ ve $g_2(s)$ nin geri projeksiyonu.....	8
Şekil 1.5	: Görüntü oluşumu için toplam algoritması.....	9
Şekil 1.6	: Projeksiyon teoremi , $G(\xi, \theta) = F_p(\xi, \theta)$ .....	10
Şekil 1.7	: Ters radon dönüşümü metodları .....	13
Şekil 1.8	: Bilgisayarlı tomografi kafatası kesiti .....	14
Şekil 1.9	: Çekirdeğin manyetik özellikleri .....	16
Şekil 1.10	: Alan ile aynı ve ters yöndeki çekirdekler ve enerji düzeyleri .....	16
Şekil 1.11	: Eğirme .....	17
Şekil 1.12	: $90^\circ$ darbesi ve etkileri.....	18
Şekil 1.13	: Boyuna gevşeme.....	19
Şekil 1.14	: Enine gevşeme.....	20
Şekil 1.15	: Proton dağılımını gösteren tek boyutlu basit bir örnek .....	22
Şekil 1.16	: MR kafatası kesiti.....	22
Şekil 2.1	: Basit bir nöron yapısı .....	37
Şekil 2.2	: Yapay nöron modeli .....	38
Şekil 2.3	: Genel işlem elemanı yapısı.....	39
Şekil 2.4	: Tek katmanlı YSA.....	39
Şekil 2.5	: Çok katmanlı YSA .....	40
Şekil 2.6	: Komşu hücrelerin merkez hücreye etkisi .....	41
Şekil 2.7	: Tetikleyici ve yasaklanan girişlere sahip bir işlem elemanı.....	41
Şekil 2.8	: Yapay sinir ağı sınıflandırıcıları.....	42
Şekil 2.9	: İleri doğru tek yönlü, çift yönlü tamamen bağlantılı YSA modeli.....	43
Şekil 2.10	: Sıkça kullanılan eşik fonksiyonları .....	44
Şekil 3.1	: Tek katmanlı perceptron.....	50
Şekil 3.2	: Lineer ayrılabilirliğin gösterimi .....	50
Şekil 3.3	: Tek katmanlı perceptronun çok katmanlıları sınırladığı bölgeler .....	52
Şekil 3.4	: $(n:m:p)$ mimarisine sahip bir çok katmanlı perceptronun yapısı.....	53
Şekil 3.5	: Hatanın geriye yayılması algoritmasının blok diyagramı .....	54
Şekil 3.6	: Gizli katmanı olmayan ağın hata fonksiyonu.....	55
Şekil 3.7	: Katmana ait ağın hata fonksiyonu .....	56
Şekil 4.1	: Nesne tanıma sisteminin blok diyagramı .....	61
Şekil 4.2	: Birinci tip beyin tümörü .....	62
Şekil 4.3	: İkinci tip beyin tümörü .....	63
Şekil 4.4	: Üçüncü tip beyin tümörü.....	63
Şekil 4.5	: Dördüncü tip beyin tümörü .....	64
Şekil 4.6	: Beşinci tip beyin tümörü .....	64
Şekil 4.7	: Altıncı tip beyin tümörü .....	65
Şekil 4.8	: Yedinci tip beyin tümörü.....	65
Şekil 4.9	: Sekizinci tip beyin tümörü .....	66

<b>Şekil 4.10</b>	: Dokuzuncu tip beyin tümörü.....	66
<b>Şekil 4.11</b>	: Onuncu tip beyin tümörü.....	67
<b>Şekil 4.12</b>	: Uygulamadaki çok katmanlı yapay sinir ağı.....	68
<b>Şekil 5.1</b>	: Kullanılan YSA programının eğitme formu .....	69
<b>Şekil 5.2</b>	: Kullanılan YSA programına ait test formu .....	70
<b>Şekil 5.3</b>	: İterasyona bağlı hata analizi.....	71



## TABLO LİSTESİ

<b>Tablo 2.1</b>	: Değişik YAS modellerinin tarihi gelişimi ve kullanma alanları.....	34
------------------	--	----

## SEMBOL LİSTESİ

$\mathcal{R}$	: Radon dönüşüm operatörü
$\mathcal{B}$	: geri projeksiyon operatörü
$\mathcal{F}$	: Fourier dönüşüm operatörü
$\mathcal{H}$	: Hilbert dönüşüm operatörü
$\mathcal{D}$	: türev operatörü
$\gamma$	: cayromanyetik oran
$h$	: Planck sabiti
$\sigma$	: bağlantı demetinin seçim fonksiyonu
$[w_{ij}]$	: YSA'ya ait $n \times n$ boyutlu bağlantı matrisi
$\alpha$	: reel değerli momentum katsayısı
$\theta$	: idrak fonksiyonunun hesaplanmasında kullanılan eşik değeri
$x_i$	: $i$ katmanındaki nöronların çıkış değerleri
$\mathbf{d}_k$	: $n$ -boyutlu çıkış nöronları
$\text{net}_j$	: $j$ katmanındaki bir nörona gelecek olan toplam giriş
$f_j$	: transfer fonksiyonu
$y_j$	: gizli katmandaki $j$ nöronunun çıkışı
$\mathbf{o}_k$	: çıkış katmanındaki bir $k$ nöronunun lineer olmayan çıkışı
$e_k$	: hata fonksiyonu
$E$	: toplam karesel hata
$\varepsilon$	: öğrenme oranı katsayısı
$\delta_o$	: çıkış katmanında oluşan hata işareti
$\delta_y$	: gizli katmanda oluşan hata işareti
$n$	: öğrenme döngülerinin iterasyon sayısı

## ÖZET

### YAPAY SİNİR AĞLARI İLE BEYİN TÜMÖRÜ TOMOGRAFİ GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

Temel olarak tomografik görüntüleme, izdüşümlerden yararlanarak görüntü oluşturma yöntemi olarak tanımlanabilir. Son yıllarda tıbbi tanılamada sıkça kullanılan görüntüleme tekniklerinden biride tomografi görüntüleme yöntemidir. Tomografik görüntüleme yardımıyla vücudun değişik organlarında oluşan tümörler veya diğer problemleri görmek mümkündür.

Tümör, herhangi bir tipte hücrenin vücut tarafından kontrol edilememesi sonucu oluşur. Beyin tümörleri, beyin içinde büyüyen tümörler olduğundan hücre çoğalması kontrol dışı kalır. Tümör tanısı konulan birisinde tümörler, iyi ve kötü huylu olmak üzere ikiye ayrılır. Tümörler beynin kendi hücrelerinden oluşursa primer (birincil) beyin tümörleri adı verilir. Vücudun diğer sistemlerinde gelişen tümörler ise, beyne sıçrayarak (metastaz) tümör oluşturduklarından metastatik beyin tümörleri olarak adlandırılır. Bu nedenle beyin tümörleri için değişik görüntüleme yöntemleri kullanılır. Bunlardan başlıcaları; BBT (Bilgisayarlı Beyin Tomografisi), MRG (Magnetik Rezonans Görüntüleme), PET Scan (Positron Emission Tomography), DSA (Anjiyografi) ve SPECT (single photon emission computed tomography) dir.

Bu çalışmada, beyinde oluşan değişik tümörlerin tanılama amacıyla sınıflandırılması yapılmıştır. Sınıflandırıcı olarak son yıllarda sıkça kullanılan ve etkin bir sınıflandırma tekniği olarak bilinen Yapay Sinir Ağları kullanılmıştır. Kullanılan Yapay Sinir Ağı tipi, Hatanın Geriye Yayılması (Back-Propagation) eğitme algoritmasıdır. Bu sınıflandırıcı yardımıyla, değişik hastalara ait Bilgisayarlı Beyin Tomografilerinden alınan üç değişik tümörün görüntülerinin öznelik vektörleri çıkarılarak başarılı bir şekilde sınıflandırılması yapılmıştır.

Tezin ilk bölümünde; Tomografik görüntüleme tekniği ve yöntemlerinden bahsedilmiştir. Çalışmanın ikinci bölümünde, kullanılan Yapay Sinir Ağları (YSA) sınıflandırıcılarından bahsedilmiştir. En son bölümde ise izlenen yöntem ve kullanılan YSA programı tanıtılarak alınan sonuçlar irdelenmiştir.

## **SUMMARY**

### **CLASSIFICATION OF TOMOGRAPHICAL IMAGES OF BRAIN TUMORS USING ARTIFICIAL NEURAL NETWORKS**

Basically, tomographical imaging is known to be an image formation method using projections. Recently, one of the techniques frequently used in imaging in medical diagnosis is tomographical imaging method. It is possible to see some tumors or other problems appearing in different organs of a body using tomographical imaging.

A tumor is formed when any cell can not be controlled. Since brain tumors are those growing inside the brain, the number of cells increases without control. Tumors are separated into two types: benign and malign. If the tumors are formed from the cells of the brain, they are called as primary brain tumors. The tumors developing in other systems of the body are called as metastatic brain tumors since they formed tumors by jumping to the brain (metastasize). For this reason different imaging methods are used for brain tumors. Mainly, the important ones are CBT (computerized brain tomography), MRI (magnetic resonance imaging), Pet Scan (positron emission tomography), DSA (angiography) and SPECT (single photon emission computed tomography).

In this study, the classification of different tumors formed in the brain for diagnosis. As the classifier, a technique, which is frequently used and known as an active classification technique, artificial neural network is used. The artificial neural network type used here is error back-propagation training algorithm. Using this classifier, a active classification is achieved by extracting feature vectors of three different tumor images obtained from computerized brain tomographies belonging different patients.

In the first part of this thesis, the tomographical imaging technique and methods are mentioned. In the second part, the artificial neural network (ANN) classifiers are mentioned. In the final part of the thesis, the method followed and ANN program used is introduced and the results are discussed.


# 1. GİRİŞ

## 1.1. TOMOGRAFİK GÖRÜNTÜLEME

Tomografi, bir cismin, üzerine birçok farklı yönden ışın göndererek cisimden geçen veya yansıyan ışınlar göre alan-kesit izdüşümlerinden faydalanarak görüntüsünün elde edilmesine denir. Bu teknik daha sonra organların görüntülenmesinde kullanılmış olup modern tıbbın vazgeçilmez uygulamalarından biri olmuştur.

Tıptaki kullanımı dışında Bilgisayarlı Tomografi (BT) metodunu kullanan çeşitli alanlar bulunmaktadır. Yeraltı kaynaklarının yerinin tespitinde, bazı özel yapı sağlamlığı testlerinde, hacimsel bir bölgedeki bir parametreye ait yoğunluğun tespitinde ve üç boyutlu görüntüleme yaygın olarak kullanılmaktadır.

Temel olarak tomografik görüntüleme, izdüşümlerden (projeksiyonlardan) yararlanarak görüntü oluşturma yöntemiyle yapılmaktadır. Bir açıda elde edilen izdüşüm, cismin görüntüsünün Şekil 1.1'deki gibi o yöndeki parçasını belirtmektedir.



Şekil 1.1: İki daire için farklı açılarda elde edilen iki izdüşüm.

İlk klinik uygulamalı bilgisayarlı beyin tomografisini geliştiren Hounsfield'in kullandığı matematiksel teknikler ile  $80 \times 80$ 'lik çözünürlüğe sahip bir görüntü,  $1/100$  doğrulukla izdüşümü yöntemleri kullanarak oluşturulmuştur. Uygulamada, tomografik görüntüleme metoduyla cisimlerin yerinin algılanması işlemi gerçekleştirilmektedir. Görüntü ise  $8 \times 8$ 'lik çözünürlüğe sahip bir bilgisayar çıktısı

olarak elde edilmektedir. Bu işlem için kullanılan matematiksel yöntemler ikinci, yapılan çalışmalar ise üçüncü bölümde açıklanmaktadır.

## **1.2. TÜMÖR GÖRÜNTÜLERİNİN ELDE EDİLMESİ**

Beyin tümörleri, beyin içinde büyüyen tümörlerdir. Tümör, herhangi bir tipte hücrenin vücut tarafından kontrol edilememesi sonucu ortaya çıkar. Diğer bir deyişle hücre çoğalması kontrol dışında kalır. Tümör tanısı konduğunda en sık iki terim kullanılır: iyi ve kötü huylu.

Kafatası kemik bir yapıdır. Hareketli eklem yerleri yoktur. Beyin içinde bir tümör geliştiğinde, kafatası genişleyemeyeceği için, tümör beyne baskı yaparak büyür. Tümörün yerleştiği yerde baskı yaptığı alanın özelliklerine göre hastada değişik bulgular ortaya çıkar.

Tümörler beynin kendi hücrelerinden oluşursa primer (birincil) beyin tümörleri adı verilir. Vücudun diğer sistemlerinde gelişen tümörler beyne sıçrayarak (metastaz) tümör oluşturduklarında, bunlara metastatik beyin tümörleri denir.

Beyin tümörlerinde tanı hastanın değişik yakınmalarla hekime başvurmasıyla başlar. Ardından yapacağı nörolojik muayene sonrasında, beyni ilgilendiren bir hastalık ya da tümörden kuşkulandıysa değişik incelemeler yaptırarak tanıya ulaşmaya çalışır. Kafatası, beyni ve içinde gelişen tümörü gizler. Hekim, hastasını muayene ederken tümörü göremez veya hissedemez. Yalnızca tümörün oluşturduğu belirti ve bulgulardan yola çıkarak kafatası içinde yer kaplayan bir olayın varlığını tahmin edebilir. Bu nedenle beyin tümörleri değişik görüntüleme yöntemleriyle görüntülenir. Bunlardan başlıcaları BBT (Bilgisayarlı Beyin Tomografisi), MRG (Manyetik Rezonans Görüntüleme), PET Scan (Positron Emission Tomography), DSA (Anjiyografi) ve SPECT (Single Photon Emission Computed Tomography) dir.

### **1.2.1. Bilgisayarlı Beyin Tomografisi (BBT)**

Bilgisayarlı tomografi, x-ışını kullanılarak, vücudun incelenen bölgesinin kesitsel görüntüsünü oluşturmaya yönelik radyolojik teşhis yöntemidir. İnceleme sırasında

hasta, bilgisayarlı tomografi cihazının masasında hareket etmeksizin yatar. Masa, elle ya da uzaktan kumanda ile cihazın "gantry" adı verilen açıklığına sokulur. Cihaz, bir bilgisayara bağlıdır. X-ışını kaynağı, incelenecek hasta etrafında 360 derecelik bir dönüş hareketi gerçekleştirirken, oyuk ya da "gantry" boyunca dizilmiş dedektörler tarafından x-ışını demetinin vücudu geçen kısmı toplanır elde edilen veriler bir bilgisayar tarafından işlenir. Sonuçta, dokuların birbiri ardısına kesitsel görüntüleri oluşturulur. Bilgisayarlı tomografi cihazlarında kolimasyon ile radyasyon demeti, istenilen boyut ya da kesit kalınlıklarında sınırlanır. Bilgisayarlı tomografide absorpsiyon ölçümü yapılan en küçük hacime "voksel" adı verilir. Oluşturulan görüntüler bilgisayar ekranından izlenebilir. Ayrıca görüntüler filme aktarılabileceği gibi gerektiğinde tekrar bilgisayar ekranına getirmek üzere diskte depolanabilir. Bilgisayarlı tomografi diğer x-ışın incelemelerine göre bazı avantajlara sahiptir. Özellikle organların, yumuşak doku ve kemiklerin şekil ve yerleşimini oldukça net gösterir. Ayrıca BT incelemeleri doktorlara basit bir kist (İçinde sıvı veya yarı sıvı madde bulunan etrafı çevrili kese şeklinde oluşum) ve solid tümör (bir kısım hücrelerin süratle çoğalması nedeniyle oluşan doku kitlesi, ur) gibi oluşumların tanısında yardımcı olarak hastalıkların daha iyi değerlendirilmesini sağlar. BT direkt grafiklerden çok daha ayrıntılı görüntüler oluşturarak kanserlerin yayılımının değerlendirilmesinde yardımcı olur. Kanser yayılımı hakkında elde edilecek bilgiler doktorları kansere yönelik uygulanacak tedavi konusunda yönlendirerek kemoterapi, radyoterapi, cerrahi tedavi veya bunların belirli kombinasyonlarının kullanılıp kullanılmayacağıyla ilgili karar vermelerinde yardımcı olur. Böylece sağlam dokular, bir çok faydaları olmakla birlikte ciddi yan etkileri olabilecek tedavi yöntemlerinin gereksiz müdahalelerinden korunmuş olur. BT, direkt grafiklerle gösterilemeyen vücudun beyin gibi birçok kesiminin değerlendirilebilmesini mümkün kılmıştır. Ayrıca BT diğer görüntüleme yöntemlerinden daha erken ve doğru şekilde birçok hastalığın teşhisini sağlamıştır. Hastalıklar erken teşhis edildiğinde daha iyi tedavi edildiklerinden, BT bu üstün özellikleriyle doktorların birçok hayat kurtarmasına yardımcı olmuştur.

#### *1.2.1.1. Bilgisayarlı Tomografinin Yan Etkileri*

İncelemenin kendisi tamamen ağrısızdır. İnceleme sırasında hastadan BT cihazının masasında hareket etmeksizin yatması istenir. Yapılacak incelemenin türüne bağlı

olarak hastaya kol damarlarından kontrast madde enjekte edilebileceği gibi kontrast madde içmesi de istenebilir. İncelemenin bu kısmı hasta için biraz rahatsızlık verici olabilir. Kontrast maddeler iyot içerdiği için bazı kişilerde allerjik reaksiyonlara neden olabilir. Hastanın inceleme öncesinde teknisyen ya da radyoloğa bu tür maddelere karşı daha önce allerjik bir reaksiyon gösterip göstermediğini ve eğer varsa başka maddelere karşı allerjisini bildirmesi gerekir. Hastaya daha önceden yapılmış bir BT incelemesinde, IVP olarak adlandırılan böbrek incelemesinde veya kalp ve damarların anjiyografi olarak da adlandırılan kateterizasyonunda kontrast madde verilmiş olabilir. Bu konuda doktorlar, muhakkak bilgilendirilmelidir.

BT cihazları X ışınlarını kullanır. Sistem, hasta güvenliğini en iyi şekilde sağlaması için inceleme sırasında maruz kalınan radyasyon miktarı, en az düzeyde olacak şekilde tasarlanır. Özellikle X ışınları anne karnında gelişmekte olan fetusa zarar verebileceğinden inceleme hazırlığına başlamadan önce hasta hamilelik şüphesi varsa bu konuda doktora veya teknisyene bilgi vermelidir.

Projeksiyon, nesneyi radyasyon altında aydınlatarak, bulunan gölge resmi (shadowgram). Şekil 1.2 projeksiyon bulmanın tipik bir metodunu göstermektedir. Perdeye yansıtılan görüntüdeki her benek kaynaktan dedektöre kadar olan toplam X ışınını soğurmasını temsil eder. Kaynak-dedektör ikilisi, nesnenin etrafında döndürerek değişik açılar için projeksiyon görüntüleri elde edilir. Görüntü oluşturmadaki amaç nesnenin arakesit görüntülerini bu projeksiyonlardan elde edebilmektir. Bunun gibi objelerin kesit görüntülerini meydana getiren görüntüleme sistemleri (Computerized Tomography - CT) bilgisayarlı tomografi olarak adlandırılır. Projeksiyonlar elde edilirken X ışınlarının katettiği yol boyunca bir çözünürlük kaybı meydana gelir. Bilgisayarlı tomografide bu kayıp, çeşitli projeksiyonlardan elde edilen bilgiler kullanarak giderilmektedir.

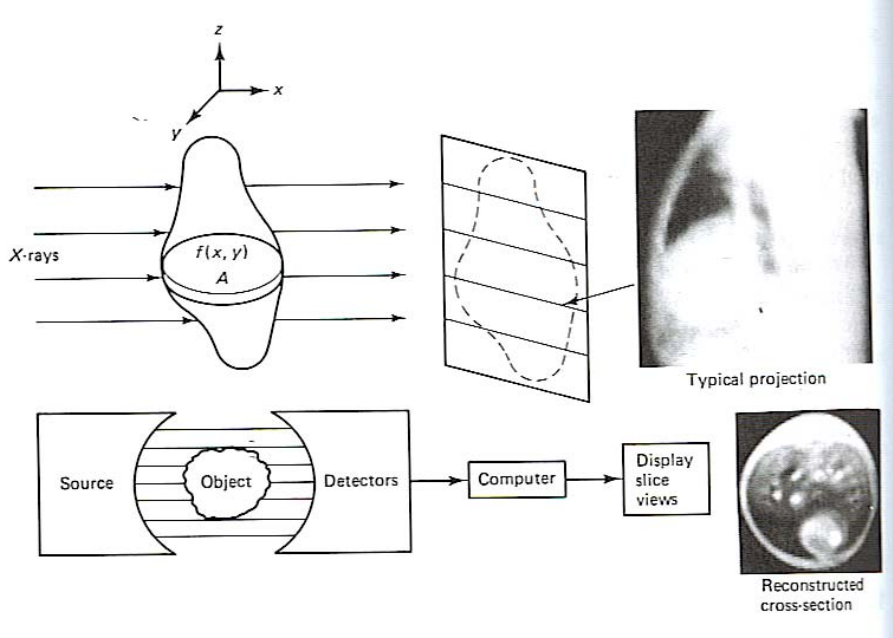
#### *1.2.1.2. İletim Tomografisi*

Bilgisayarlı tomografide, X ışını ile elde edilen görüntünün basit modeli aşağıda verilmektedir.  $f(x,y)$  objesinin  $(x,y)$  noktasındaki  $z$  değeri, nesnenin sabit soğurma katsayısını belirtsin (Şekil 1.2). Aydınlanmanın sonsuz ince paralel X ışınları




demetinden meydana geldiğini varsayarsak, detektörden elde edilen ışın demetinin yoğunluğu aşağıdaki formülle ifade edilir.

$$I = I_0 \cdot \exp \left[ \int_L f(x, y) \cdot du \right] \quad (1.1)$$



Şekil 1.2: X-ışınlı CT tarama sistemi

Burada  $I_0$  kaynağın ışın yoğunluğu,  $L$  ışığın gittiği yolu,  $u$  ise  $L$  boyunca katedilen mesafeyi gösterir (Şekil 1.3).



Şekil 1.3: Bilgisayarlı tomografide projeksiyon görüntüleme geometrisi

Gözlenen işareti aşağıdaki gibi ifade edersek

$$g = \ln(I_0 / I) \quad (1.2)$$

aşağıda ki lineer dönüşümü elde ederiz.

$$g = g(s, \theta) = \int_L f(x, y) \cdot du ; -\infty < s < \infty , 0 \leq \theta \leq \pi \quad (1.3)$$

Burada  $(s, \theta)$ , X ışınının koordinatlarını nesneye bağlı olarak yeniden ifade eder. Bu durumda, görüntü oluşturma problemi  $f(x, y)$ 'yi  $g(s, \theta)$ 'dan belirlemektir. Yukarıda gösterilen görüntüleme tekniği nesnenin iletim karakteristiklerini göstermesinden dolayı "iletim tomografisi" olarak adlandırılır.

### 1.2.1.3. Radon Dönüşümü

$f(x, y)$  fonksiyonunun  $g(s, \theta)$  olarak belirtilen radon dönüşümü,  $f(x, y)$ 'nin  $y$  eksenine  $\theta$  açısı yapan ve orijinden  $s$  kadar uzaklıkta bulunan eğimli doğru boyunca çizgisel integralidir (Şekil 1.3). Bu işlem, aşağıdaki gibi matematiksel olarak ifade edilir:

$$g(s, \theta) = \mathcal{R}f = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \cdot \delta(x \cdot \cos \theta + y \cdot \sin \theta - s) \cdot dx \cdot dy ;$$

$$-\infty < s < \infty , 0 \leq \theta \leq \pi \quad (1.4)$$

Radon dönüşüm operatörünü belirten  $\mathcal{R}$  sembolü, aynı zamanda projeksiyon operatörü olarak da adlandırılır.  $f(x, y)$ 'nin Radon dönüşümü  $g(s, \theta)$ ,  $f(x, y)$ 'nin  $\theta$  açısındaki tek boyutlu projeksiyonudur. Yeni  $(s, u)$  koordinat sisteminde;

$$\begin{aligned} s &= x \cos \theta + y \sin \theta & x &= s \cos \theta - u \sin \theta \\ & & \text{veya} & \\ u &= -x \cos \theta + y \sin \theta & y &= s \sin \theta + u \cos \theta \end{aligned} \quad (1.5)$$

(1.4) te gösterilen ifade yeniden düzenlenirse

$$g(s, \theta) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(s \cdot \cos \theta - u \cdot \sin \theta, s \cdot \sin \theta + u \cdot \cos \theta) \cdot du ;$$

$$-\infty < s < \infty , 0 \leq \theta \leq \pi \quad (1.6)$$

s uzaklığı ve  $\theta$  açısında ışın boyunca  $f(x,y)$ 'lerin toplamını ifade ettiği için  $g(s,\theta)$ , ışın toplamı olarak da adlandırılır. Radon dönüşümü, uzay domeni  $(x,y)$  bilgilerini  $(s,\theta)$  domenine aktarır.  $(s,\theta)$  uzayındaki her nokta, uzay domeni  $(x,y)$ 'deki her bir doğruya karşılık gelir. Burada  $(s,\theta)$  nin  $(x,y)$  nin polar koordinatları olmadığına dikkat edilmelidir. Aslında, eğer  $(r,\Phi)$ ,  $(x,y)$  nin polar koordinatları ise buradan,

$$x = r \cos\Phi, \quad y = r \sin\Phi \quad (1.7)$$

ve

$$s = r \cos(\theta - \Phi) \quad (1.8)$$

bulunur.


#### 1.2.1.4. Geri Projeksiyon (İzdüşürme) Operatörü

Radon dönüşümüne benzer olarak geri projeksiyon operatörü  $\mathcal{B}$ , aşağıdaki gibi tanımlanır.

$$b(x,y) = \mathcal{B} g = \int_0^\pi g(x \cdot \cos \theta + y \cdot \sin \theta, \theta) \cdot d\theta \quad (1.9)$$

Geri projeksiyon operatörü  $\mathcal{B}$ ,  $(s,\theta)$  koordinatlarındaki bir fonksiyonun,  $(x,y)$  veya  $(r,\Phi)$  uzaysal koordinatlardaki bir fonksiyona izdüşümünü gösterir.

Geri projeksiyon  $b(x,y)$ 'deki herhangi bir noktayı elde etmek için (1.9)'daki formülden de anlaşılacağı üzere her yönden projeksiyonlar hesaplanır.



Şekil 1.4:  $(r, \Phi)$  koordinatlarında  $g_1(s)$  ve  $g_2(s)$  nin geri projeksiyonu

Gösterilebilir ki geri izdüşürülen Radon dönüşümü  $f'$

$$f' = \mathcal{B}g = \mathcal{B} \mathcal{R}f \quad (1.10)$$

$f(x, y)$  nin  $1/(x^2 + y^2)$  ile konvolüsyonu şeklinde düşünülür. Yani,

$$f'(x, y) = f(x, y) \circledast (x^2 + y^2)^{-1/2} \quad (1.11)$$

burada  $\circledast$  kartezyen koordinatlardaki iki boyutlu konvolüsyonu gösterir. Polar koordinatlarda ise;


$$\widehat{f}_p(r, \phi) = f_p(r, \theta) \circledast \frac{1}{|r|} \quad (1.12)$$

Burada  $\circledast$ , polar koordinatlarda konvolüsyonu gösterir. Bu yüzden geri projeksiyon operatörü  $\mathcal{B}$ , Radon dönüşüm operatörü  $\mathcal{R}$  nin tersi değildir.  $f(x, y)$  nesnesinin ve bunun görüntüsü olan  $g(s, \theta)$ 'nin her  $\theta$  için ayrıklaştırılmış olduğunu ve her birinin arasında  $g = \mathcal{R}f$  ilişkisi olacak şekilde  $f$  ve  $g$  vektörleri ile temsil edildiğini varsayalım.  $\mathcal{R}$  matrisi, Radon dönüşüm operatörü  $\mathcal{R}$  nin sonlu fark yaklaşımıdır.  $\mathcal{R}^T$  ise, geri projeksiyon operatörü  $\mathcal{B}$  nin yaklaşımını ifade eder.


$f' = \mathcal{B}g = \mathcal{B}[\mathcal{R}f]$  işlemi, radon dönüşümlerinin toplamını verir (Şekil 1.5).

$f(x,y)$  nesnesi, frekans cevabı  $|\xi| = (\xi_1 + \xi_2)^{1/2}$  olan iki-boyutlu ters (inverse) filtre kullanılarak,  $f'(x,y)$  den yeniden elde edilebilir.

$$f(x,y) = \mathcal{F}_2' [|\xi| \mathcal{F}_2[\mathcal{B}g]] \quad (1.13)$$



(  $f(x,y)$  nesnesinin geri iz düşürülen projeksiyonu  $f'(x,y)$  )



Şekil 1.5: Görüntü oluşumu için toplam algoritması

Burada  $\mathcal{F}_2$ , iki-boyutlu Fourier dönüşüm operatörüdür. Uygulamada  $|\xi|$  filtresinin yerine fiziksel olarak gerçekleştirilebilen daha farklı yaklaşımlar kullanılır. FFT yoluyla filtreleme işlemi de kullanılmaktadır.

#### 1.2.1.5. Projeksiyon Teoremi

$f(x,y)$  fonksiyonun iki-boyutlu Fourier dönüşümü ile  $f(x,y)$  fonksiyona ait  $g(s,\theta)$  Radon dönüşümünün tek boyutlu Fourier dönüşümü arasında temel bir ilişki vardır.

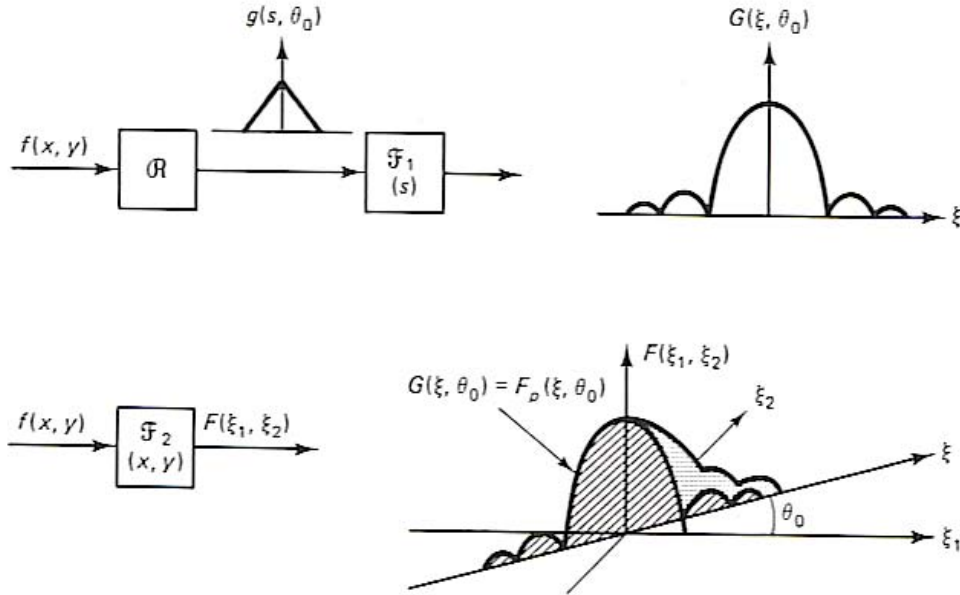
$g(s, \theta)$  projeksiyonununun  $s$ ' e bağılı olarak alınan tek-boyutlu Fourier dönüşümü,  $f(x, y)$  nesnesinin  $\xi - \theta$  değerlerine bağılı iki-boyutlu Fourier dönüşümüne eşittir. Yani,

$$g(s, \theta) \xleftrightarrow[s]{\mathcal{F}_1} G(\xi, \theta)$$

buradan da,

$$G(\xi, \theta) = F_p(\xi, \theta) = F(\xi \cos \theta, \xi \sin \theta) \quad (1.14)$$

Şekil 1.6'de bu sonucun anlamı gösterilir. Bu teorem ayrıca projeksiyon-dilim teoremi (projection-slice theorem) adıyla da anılır.



Şekil 1.6: Projeksiyon teoremi ,  $G(\xi, \theta) = F_p(\xi, \theta)$

#### 1.2.1.6. Ters Radon Dönüşümü

Görüntü oluşturma işleminde  $f(x, y)$ 'yi bulmak için bir başka metot da  $g(s, \theta)$  nin ters Radon dönüşümünü hesaplamaktır. Projeksiyon teoremi, ters Radon dönüşümünü elde etmede kullanışlı bir metoddur.

$g(s, \theta) = \mathcal{R}f$ ,  $-\infty < s < \infty$ ,  $0 < \theta < \pi$  fonksiyonunun ters Radon dönüşümü,

$$f(x, y) = \frac{1}{2\pi^2} \int_0^\pi \int_{-\infty}^\infty \frac{[\partial g(s, \theta) / \partial s]}{x \cdot \cos \theta + y \cdot \sin \theta - s} \cdot ds \cdot d\theta \quad (1.15)$$

polar koordinatlarda ifade edecek olursak

$$f_p(r, \phi) = f(r \cos \phi, r \sin \phi) = \frac{1}{2\pi^2} \int_0^\pi \int_{-\infty}^\infty \frac{[\partial g(s, \theta) / \partial s]}{r \cos(\theta - \phi) - s} \cdot ds \cdot d\theta \quad (1.16)$$

olarak bulunur.

İspat: Ters Fourier dönüşümü

$$f(x, y) = \int_{-\infty}^\infty \int_{-\infty}^\infty F(\xi_1, \xi_2) \exp [j2\pi(\xi_1 x + \xi_2 y)] d\xi_1 d\xi_2$$

polar koordnatlarda ve frekans domeninde yazılırsa ;

$$f(x, y) = \int_0^{2\pi} \int_0^\infty F_p(\xi, \theta) \exp [j2\pi\xi(x \cos \theta + y \sin \theta)] \xi d\xi d\theta \quad (1.17)$$

şeklini alır.  $\xi$  yi negatif ve  $0 \leq \theta < \pi$  alırsak integralin sınırlarını değiştirebilir ve (1.14)'teki eşitliği kullanabiliriz.

$$\begin{aligned} f(x, y) &= \int_0^\pi \int_{-\infty}^\infty |\xi| F_p(\xi, \theta) \exp [j2\pi\xi(x \cos \theta + y \sin \theta)] d\xi d\theta \\ &= \int_0^\pi \left\{ \int_{-\infty}^\infty |\xi| G(\xi, \theta) \exp [j2\pi\xi(x \cos \theta + y \sin \theta)] d\xi \right\} d\theta \\ &= \int_0^\pi \bar{g}(x \cos \theta + y \sin \theta, \theta) d\theta \end{aligned} \quad (1.18)$$

burada

$$\bar{g}(s, \theta) = \int_{-\infty}^\infty |\xi| G(\xi, \theta) e^{-j2\pi s \xi} d\xi \quad (1.19)$$

eğer  $|\xi| \cdot G$  yerine  $\xi \cdot G \cdot \text{sgn}(\xi)$  yazar ve konvolüsyon uygularsak, aşağıdaki sonucu elde ederiz.

$$\begin{aligned} \hat{g}(s, \theta) &= [F_1^{-1}\{\xi G(\xi, \theta)\}] \Theta [F_1^{-1}\{\text{sgn}(\xi)\}] \\ &= \left[ \left( \frac{1}{j2\Pi} \right) \frac{\partial g}{\partial s}(s, \theta) \right] \Theta \left( \frac{-1}{j\Pi s} \right) \\ &= \left( \frac{1}{2\Pi^2} \right) \int_{-\infty}^{\infty} \left[ \frac{\partial g(t, \theta)}{\partial t} \right] \frac{1}{s-t} dt \end{aligned} \quad (1.20)$$

burada  $(1/j2\pi)[\partial g(s, \theta)/\partial s]$  ve  $(-1/j2\pi s)$  sırasıyla  $\xi G(\xi, \theta)$  ve  $\text{sgn}(\xi)$  nin ters Fourier dönüşümleridir. (1.18) ve (1.20) eşitliklerini birleştirirsek, istediğimiz sonuç olan (1.15) eşitliğini buluruz. Bu eşitlikte  $x = r \cos\Phi$  ve  $y = r \sin\Phi$  yazarsak (1.16) daki sonucu elde ederiz.

$\Phi(t)$  fonksiyonunun Hilbert dönüşümü aşağıdaki gibi tanımlanır.

$$\psi(s) = \mathcal{H}\phi = \phi(s) \left( \frac{1}{\Pi s} \right) = \left( \frac{1}{\Pi} \right) \int_{-\infty}^{\infty} \frac{\Phi(t)}{s-t} dt \quad (1.21)$$

Buradaki  $\hat{\mathcal{H}}$  Hilbert dönüşüm operatörünü ifade eder. Bu tanımdan hareketle  $\hat{g}(s, \theta)$ , her  $\theta$  değeri için,  $(1/2\pi) \partial g(s, \theta)/\partial s$  in Hilbert dönüşümüdür.

#### 1.2.1.7. Konvolüsyon Geri-Projeksiyon Metodu

Türev operatörünü

$$\mathcal{D}\Phi = \frac{\partial \Phi(s)}{\partial s} \quad (1.22)$$

şeklinde ifade edersek ters Radon dönüşümü aşağıdaki gibi yazılabilir.

$$f(x, y) = (1/2\pi) \mathcal{B} \hat{\mathcal{H}} \mathcal{D}g \quad (1.23)$$


Buradan ters radon dönüşümü ;

$$\mathcal{R}^1 = (1/2\pi) \mathcal{B} \hat{\mathcal{H}} \mathcal{D}$$




olarak bulunur. Buradan ters Radon dönüşümü, türevi alınan projeksiyonlar


$(\frac{\partial g(s, \theta)}{\partial s})$  ile  $1/s$  fonksiyonunun konvolüsyonu olarak tanımlanır (Şekil 1.7b).



a) ters radon dönüşümü



b) konvolüsvon geri izdüsürme metodu



c) filtre geri izdüsürme metodu

Şekil 1.7: Ters radon dönüşümü metodları

### 1.2.1.8. Filtre Geri-Projeksiyon Metodu

(1.18) ve (1.19)'u kullanarak  $f(x,y)$ 'yi aşağıdaki gibi ifade edebiliriz.

$$f(x,y) = \mathcal{B} \hat{\mathcal{H}} g \quad (1.24)$$


Burada  $\hat{\mathcal{H}}$  frekans cevabı  $|\xi|$  olan tek boyutlu filtreyi göstermek üzere,

$$\begin{aligned}\hat{g} &= \mathcal{H}g = \int_{-\infty}^{\infty} |\xi| G(\xi, \theta) e^{-j2\pi\mu} ds \\ &= F_1^{-1} \left\{ \int_{-\infty}^{\infty} |\xi| [F_1 g] \right\}\end{aligned}\quad (1.25)$$

elde edilir ve bu da bize,

$$f(x, y) = \mathcal{B}F_1^{-1} [ |\xi| F_1(g) ] \quad (1.26)$$

eşitliğini verir.  $f(x, y)$  fonksiyonu, projeksiyonların Fourier domeninde filtrelenmesi ve çıkan sonucun ters Fourier dönüşümünün geri projekt edilmesiyle elde edilir (Şekil 1.7c). Burada sözü edilen yöntemin kullanılması ile elde edilen bilgisayarlı kafatası kesiti tomografisi aşağıda gösterilmektedir (Şekil 1.8).



Şekil 1.8: Bilgisayarlı tomografi kafatası kesiti

### 1.2.2. Manyetik Rezonans Görüntüleme

Yeni görüntüleme teknolojileri arasında en etkileyici olanlardan biri manyetik rezonans görüntüleme ya da kısaca MRG veya MR'dır. MR ağrısız, allerjiye yol açacak ilaç verilme zorunluluğu olmayan ve x-ışını gibi zararlı olabilecek ışınlar kullanmayan bir tanı tekniğidir. Hasta güçlü bir elektromanyet içeren bir silindirin

içinde yatarken, vücuttaki hidrojen atomlarının enerji salmasına yol açan radyo dalgaları gönderilerek işlem gerçekleştirilir. Manyetik etkisi ile hareket eden atomlara ait bilgi, bir bilgisayara gönderilir ve incelenen alanın oldukça kaliteli bir resmi elde edilir. Radyolog doktorlar, bu görüntüleri değerlendirilerek hastalık hakkında bilgi edinirler. Manyetik rezonans görüntüleme yönteminde hasta radyasyon almaz.


Manyetik rezonans (MR) görüntülemenin dayandığı fiziksel prensipler 1946'dan beri bilinmesine rağmen, MR tomografi diğer görüntüleme tekniklerine nispeten daha yeni bir görüntüleme tekniğidir. X-ışınlı CT, PET, SPECT vb görüntüleme teknikleriyle karşılaştırıldığında, MR tomografide oldukça değişik prensipler ile kullanılmaktadır. Tomografi sisteminin hasta sağlığı üzerindeki etkileri göz önüne alındığında MR'ın önemli avantajlarından biri sistemin radyofrekans bandında (MHz bölgesi) işlevini sürdürmesi ve bu sayede X-ışınlı CT'de kullanılan iyonikleştirme radyasyonunun kullanılmamasıdır. MR tomografinin bir avantajı da insan vücudunda doğal olarak bulunan hidrojen gibi maddeleri kullanması ve hasta sağlığını fiziksel ve psikolojik olarak etkileyebilecek olan radyoaktif izotopları kullanmamasıdır. Bu sistemde -diğer sistemlerde çok zor olan- yumuşak dokuların yüksek bir kontrastla görüntülenmesi mümkündür.

#### *1.2.2.1. Atomik Çekirdeklerin Manyetik Alandaki Davranışları*


İnsan vücudundakiler de dahil olmak üzere doğadaki (tek valans elektronuna sahip) çekirdekler, sürekli olarak kendi eksenleri etrafında spin atarak dönerler (Şekil 1.9a). Bu spin işlemi ile oluşan manyetik dipol, tüm çekirdeklerde manyetik bir moment oluşturur (Şekil 1.9b).

Nükleer spin ve manyetik moment birbirlerine paralel olan vektörel niceliklerdir. Normal şartlarda termal denge sağlandığında bu vektörlerin yönleri rasgele dağılır (Şekil 1.10a). Sabit bir manyetik alan uygulandığı takdirde, bu çekirdekler (veya vektörler), kuantum mekaniği kurallarına uygun olarak uygulanan alana paralel şekilde -alan ile aynı yönünde veya ters yönde- dizilir. Aynı yöndeki atomların (Düşük enerji seviyesi) sayısı ters yöndeki atomların (Yüksek enerji seviyesi) sayısından bir miktar büyüktür (Şekil 1.10b). Çekirdekler -manyetik alanda termal dengedeysen- aynı yöne veya ters yöne bir geçiş yaparken, bu hareket esnasında

komşularıyla çarpıştıkça enerji emme ve yayma eğilimindedirler. Ortalama olarak çok küçük de olsa alan ile aynı yönde çekirdeklerin sayısı, diğer yönde bulunan çekirdeklerin sayısından -yaklaşık milyonda bir kadar- fazladır. Bu farkın sonucunda uygulanan manyetik alan doğrultusunda net bir manyetizasyon oluşur (Şekil 1.10c). Bu bir anlamda klasik fizikteki manyetizasyon vektörüdür.




Şekil 1.9: Çekirdeğin manyetik özellikleri



Şekil 1.10: Alan ile aynı ve ters yöndeki çekirdekler ve enerji düzeyleri

Dönme işlemi sırasında çekirdekler, manyetizasyon vektörü doğrultusundan bir miktar saparak eğilir. Buradaki eğirme, yerçekimi etkisi altında vektörün üst kısmının spin atarak daire çizmesidir. Burada vektör, hem kendi eksenini etrafında hem de toprağa dik bir eksen etrafında döner (Şekil 1.11).



Şekil 1.11: Eğirme

Uygulanan alan yönü z-ekseni olmak üzere M magnetizasyonunun  $M_z$  ve  $M_{xy}$  olmak üzere iki bileşeni olduğunu varsayarsak,  $M_z$  bileşeninin sabit kaldığı  $M_{xy}$  bileşeninin ise açısal frekansı  $\omega$  olan dairesel bir hareket çizdiği görülür.  $\omega$  açısal frekansı, uygulanan B manyetik alanı ile orantılıdır.

$$\omega = \gamma B \quad (1.27)$$

Burada  $\gamma$  sabiti cayromanyetik oran olarak adlandırılır ve çekirdek tipine göre değişir. Yukarıdaki eşitliğe “Larmor” eşitliği ve  $\omega$  frekansına ise “Larmor” frekansı denir. Eşitlikte uygulanan manyetik alan ile eğirme frekansı arasındaki bu basit ilişki, manyetik rezonans görüntülemenin temelini teşkil eder. Objeye uzamsal olarak değişken bir manyetik alan yoğunluğu uygulandığı zaman, “Larmor” eşitliği sayesinde frekans bilgisi ve pozisyon arasında bir ilişki kurulacaktır.

### 1.2.2.2. Çekirdeklerin RF Darbeleri Yoluyla Uyarılması

Bir önceki bölümde anlatılan iki durum arasındaki geçiş belirli miktarda elektromanyetik radyasyon soğurularak gerçekleştirilebilir. Elektromanyetik radyasyonun enerjisi aşağıdaki formülle verilir.


$$\Delta E = h f_0 \quad (1.28)$$

Burada  $\Delta E$ ; iki durum arasındaki enerji farkı,  $h$ ; "Planck" sabiti,  $f_0$ ; "Larmor" eşitliğine göre çekirdeğe uygulanan  $B_0$  manyetik alanıyla bulunan elektromanyetik darbenin frekansıdır.

$$f_0 = (\gamma / 2\pi) B_0 \quad (1.29)$$

MR tekniğinde iki durum arasındaki geçiş, nükleer spinin yönünün tersine dönmesi anlamına gelir. Çekirdek uygun bir RF frekansı ile enerjilendirildiğinde z eksenine doğrultusundaki  $M_z$  net magnetizasyon sıfıra gider ve tüm magnetizasyon x-y ekseninde ortaya çıkar. Bu durumun oluşması frekansı  $f_0$  olan kısa bir darbe ile sağlanır (hidrojen çekirdeği için 1000 Gauss'luk bir alanda  $f_0 = 4.2576$  MHz).

Magnetizasyon vektörü  $90^\circ$  döndürüldüğünden (z ekseninden xy eksenine), meydana gelen radyofrekans darbesi (RF)  $90^\circ$  darbesi olarak adlandırılır (Şekil 1.12).



Şekil 1.12:  $90^\circ$  darbesi ve etkileri


Bu radyofrekans (RF.) darbesi, nesnenin içine girdiği bir bobin düzeneği ile sağlanabilir. Bazı uygulamalarda, RF ile gönderilen enerji ile alana ters yönde bulunan çekirdek sayısının alan ile aynı yönde bulunan çekirdek sayısından fazla olması sağlanır. Bu durumda  $M_z$  manyetizasyon vektörü, z ekseninin ters yönünü gösterir. Bu çeşit darbeler,  $180^\circ$  darbeleri olarak adlandırılır.

### 1.2.2.3. RF Darbesinin Kesilmesinden Sonra Çekirdek Gevşemesi

Uyarılmış durumdaki çekirdekler radyofrekans darbesinin sonunda normal durumlarına dönerler. Orijinal duruma dönerken bu dönüşün iki bileşeni ayrı ayrı incelenir. Bunlardan birincisi  $M_z$ 'nin yeniden meydana çıkması ve orijinal yoğunluğuna -eski durumuna- dönmesidir. İkincisi ise  $M_{xy}$  bileşeninin sıfıra gitmesidir. Bunlardan ilki, boyuna gevşeme ("longitudinal relaxation") olarak adlandırılır. Çünkü burada z bileşeninin denge durumuna -eski durumuna- dönmesi söz konusudur. Bu geçiş hareketi, üsteldir.

$$M_z = M_0 (1 - e^{-t/T_1}) \quad (1.30)$$

Burada  $M_0$ ; orijinal magnetizasyon,  $T_1$  ise boyuna dinlenme zamanı olarak adlandırılan bağıl zaman sabitini göstermektedir (Şekil 1.13).




Şekil 1.13: Boyuna gevşeme

Orijinal duruma dönmenin ikincisi ise enine gevşeme ("transverse relaxation") olarak adlandırılan  $M_{xy}$  nin sıfıra düşmesidir. Bu dönüş işlemi aşağıdaki formüle edildiği gibi üstel bir azalmadır.

$$M_y = M_0 e^{-t/T_2} \quad (1.31)$$

Burada  $T_2$  zaman sabiti, enine dinlenme zamanı olarak adlandırılır (Şekil 1.14).



Şekil 1.14: Enine gevşeme

$T_1$  zaman sabiti ayrıca spin-kafes dinlenme zamanı (“spin-lattice relaxation time”) olarak adlandırılır. Çünkü buradaki enerji transferi, uyarılmış çekirdekten bu çekirdeyi çevreleyen moleküler şebekeye doğrudur.  $T_2$  ise  $T_1$ 'e alternatif olarak spin-spin dinlenme zamanı olarak adlandırılır. Çünkü buradaki enerji transferi, uyarılmış çekirdekten spin değişiminin olduğu komşu çekirdeklere doğrudur. İlki enerjinin ısı şeklinde moleküllere yayılmasına; ikincisi ise çevredeki moleküllerin manyetizasyonu ile ilgilidir.

#### 1.2.2.4. MR İşaretlerinin Algılanması

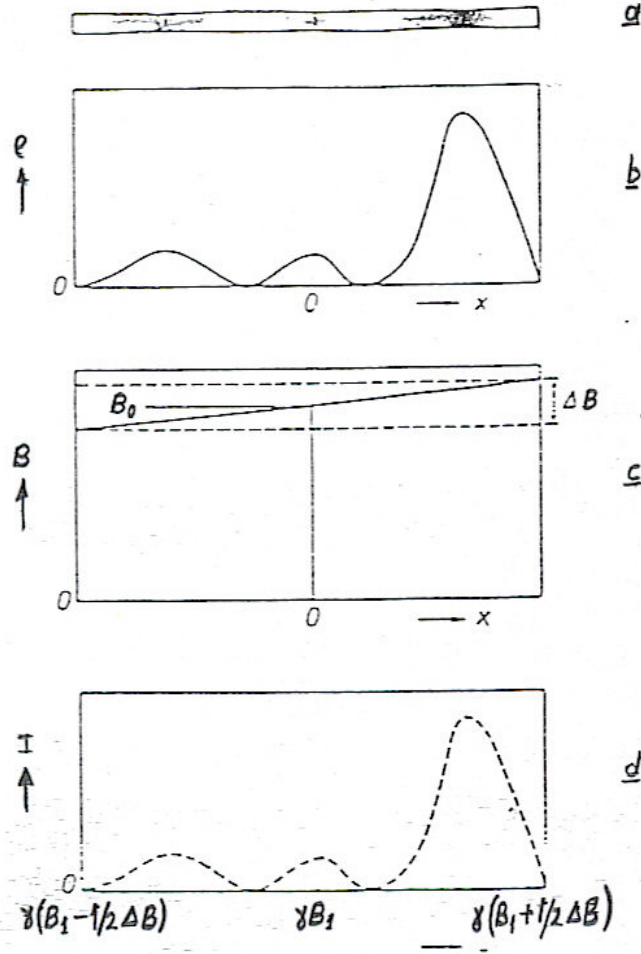
Nükleer eğirme veya osilasyonun frekansı  $f_0$  aynı zamanda bobindeki magnetizasyonla ilişkili osilasyonunun da frekansıdır. Manyetik alan içinde önce alınıp sonra sebest bırakılan enerji sonucu, bobinde ölçülebilen bir voltaj indüklenir ve bu sönümlü salınımın frekansı,  $f_0$  dır. Bu şekilde elde edilen MR işaretleri “Free Induction Decay” veya kısaca FID işaretleri olarak adlandırılır. Bobin hem verici hem de alıcı olarak kullanılır. Klinikle ilgili görüntülemelerde ise genellikle “Hahn spin-echo” (HSE) dizisi kullanılır ve genellikle “spin-echo” olarak belirtilir. “Spin-echo”



dizisi bir RF darbesine kısa bir süre sonra ( $t_e/2$ ) ikinci bir RF darbesi eklenmesiyle oluşturulur. Oluşan bu yeni işarete, eko işaret denir. Eko işaret eğrilen vektörlerin yakınsamasıyla oluşur ve ikinci RF darbesinden  $t_e/2$  periyodunda işaret tepe değerine ulaşır. En kuvvetli eko (“echo”) işaretleri RF işaretinin çevirme açıları  $90^0$  ve  $180^0$  olduğunda oluşur. RF darbesinin merkeziyle eko işaretinin tepe noktası arasındaki zaman periyodu “eko zamanı” ( $t_e$ ) olarak adlandırılır ve önemli bir parametredir.


$f_0$  frekansı manyetik alan yoğunluğuna bağlı olduğu için, vücut içindeki her nokta, yoğunluğu değişen alan içinde farklı frekanslar yayacaktır. Uzamsal olarak değişken manyetik alan, sabit bir alan üzerine yerleştirilen gradyan alanlar yardımıyla üretilir. Bu durumda alıcı bobinde ortaya çıkan frekans, MR işaretleri yayan çekirdeğin pozisyonu hakkında bilgiler içerir. Çekirdeklerin yoğunluğu (H için su miktarı) ise, spektrum (Fourier) analizine benzer metodla elde edilebilir, yayılan frekansın genliği ile ilişkilidir.

Tek boyutlu proton (hidrojen atomu) dağılımının olduğu durum şekilde gösterilmiştir (Şekil 1.15). Buradaki obje, içinde düzensiz bir proton (su) dağılımına sahip olan bir borudur (Şekil 1.15a). Proton yoğunluğunun ( $g$ ) mesafeye ( $x$ ) bağlı değişimi de şekilde gösterilmiştir (Şekil 1.15b). Yapılacak ilk şey boruyu uniform manyetik bir alana yerleştirmektir. Daha sonra boru içindeki protonları uyarmak amacıyla obje içine -çekirdeklere- kısa  $f_0$  frekansında radyofrekans (RF) darbesi uygulanır. Darbe bir süre sonra kesilir ve sabit manyetik alan üzerinde  $x$  eksenini boyunca değişen manyetik gradyan oluşturulur. Bu gradyan alan, sistem içindeki diğer bobin parçaları kullanılarak uygulanır. Manyetik alan yoğunluğu boru boyunca  $[B_0 - (1/2)\Delta B_0]$  dan  $[B_0 + (1/2)\Delta B_0]$  a değişim göstermesi sağlanır (Şekil 1.15c). RF darbesinin bittiği ve değişken manyetik alanın uygulandığı anda detektör bobininde indüklenen voltaj hemen ölçülür. Ölçülen işaret, obje içindeki her bir protondan gelen işaretlerin toplanmasıyla oluşmuştur. Bu işaretin frekans spektrumu bulunur. Larmor eşitliğine göre bu işaretlerin açısal frekansları,  $\gamma[B_0 - (1/2)\Delta B_0]$  ile  $\gamma[B_0 + (1/2)\Delta B_0]$  arasında değişir. Frekanslar pozisyonu gösterirken, toplam işaretin Fourier dönüşümünün modül değerleri ise, o frekanstaki (pozisyonadaki) protonların yoğunluğunu verecektir (Şekil 1.15d). Sonuç spektrum, protonların uzamsal dağılımlarını gösterir. İnsan vücudunun arakesitleri (iki boyutlu görüntüleri) oluşturulurken iki boyutlu Fourier dönüşümleri (iki boyutta değişen manyetik alan) kullanılmak zorundadır.



Şekil 1.15: Proton dağılımını gösteren tek boyutlu basit bir örnek

Şekil 1.16'de, MR ile elde edilmiş bir kafatası kesiti görülmektedir.



Şekil 1.16: MR kafatası kesiti

### 1.2.3. Pozitron Emisyon Tomografisi

PET sistemleri pozitron yayan  $^{18}\text{F}$ ,  $^{11}\text{C}$ ,  $^{15}\text{O}$ ,  $^{13}\text{N}$  gibi vücudun yapı taşları olan elementlerle çeşitli biyolojik farmasötiklerin kombine edilmesi ile elde edilen radyofarmasötikleri kullanarak hücre canlılığını ve metabolizmasını değerlendirme imkanı sunan görüntüleme yöntemleridir.

Hem BT hem de PET akciğer kanseri tanısında ve evrelemede önemli rol oynayan görüntüleme teknikleridir. Pozitron emisyon tomografisi/bilgisayarlı tomografi (PET/BT) iyi bilinen bu iki görüntüleme tekniğinin entegrasyonu ile elde edilmiş hibrid görüntüleme sistemidir. PET cihazında elde edilen ve dokuların metabolik-biyolojik işlevi hakkında fikir veren çok önemli bilgiler, BT’de elde edilen anatomik görüntüler ile birleştirilmekte, böylece PET teknolojisi sayesinde yüksek duyarlılıkla saptanan anormal metabolizma gösteren dokular, BT teknolojisi sayesinde vücut içerisinde anatomik olarak doğru lokalize edilebilmekte, boyut ve karakterlerinin anlaşılması mümkün olmaktadır. PET/BT nin en önemli avantajlarından biri de doku kalınlığı düzeltmesinin X-ışını ile yapılabilmesi sayesinde inceleme süresinin belirgin olarak kısalmasıdır. Tüm vücut görüntüleme böyle bir sistemle 15-22 dakikada tamamlanabilmektedir.

### 1.2.4. Anjiyografi

Anjiyografi; insan vücudundaki tüm damarların, içlerine yüksek yoğunlukta bir madde verilerek grafilerinin çekilmesi anlamında, genel bir tanımlamadır. İnsan vücudundaki tüm organların (kalp, beyin, iç organlar, kol ve bacaklar dahil) damarları olduğu için anjiyografileri yapılmaktadır. Yapılan bu anjiyografiler sayesinde damarlar ile ilgili birçok hastalığa sağlıklı biçimde tanı koymak olasıdır.

Anjiyografi, uygulandığı bölgelere göre bazı isimler ile belirtilmektedir:

**Serebral Anjiyografi:** Beyin ve boyun damarlarının anjiyografisi.

**Koroner Anjiyografi:** Kalp ve kalbi besleyen damarların anjiyografisi.

**Visseral Anjiyografi:** Tüm iç organlara ait anjiyografiler (Böbrek, akciğer, dalak, karaciğer v.s.).

**Periferik Anjiyografi:** Kol veya bacak damarlarına yönelik yapılan anjiyografiler.

Ayrıca, tüm adı geçen sistem ve organların toplar damarlarının görüntülediği venografik incelemeler ile bazı bölgelerdeki lenf damarlarının görüntülediği lenfanjiyografik incelemeler de anjiyografi kapsamındaki radyolojik inceleme yöntemleridir.

Anjiyografik işlemler; en sağlıklı olarak, özel olarak geliştirilmiş DSA (Digital Subtraksiyon Anjiyografisi) cihazlarında yapılmaktadır. Bu işleme uygun olmayan cihazlar ile yapılan incelemelerde, tanıya yanılgılar olabilmektedir. Adı geçen anjiyografik işlemlerde, değişik tipte malzemeler kullanılmaktadır. Ayrıca damar görüntülenmesi için, içlerine yüksek yoğunlukta bir madde (kontrast madde) verilmesi zorunluluğu vardır. Anjiyografi sırasında incelenmesi istenilen damar içine özel olarak geliştirilmiş kateter adı verilen ince bir tüp sistemi ile girilerek adı geçen kontrast madde verilmekte ve bu sırada seri biçimde grafler alınmaktadır. Grafi çekimi sırasında hastanın hareketsiz kalması ve bazı bölgeler için de kısa süreli nefes tutması gerekmektedir.

### **1.2.5. Tek Foton Emisyonlu Bilgisayar Tomografisi**

Beyin perfüzyon SPECT (Single Photon Emission Computerized Tomography), beyin kan akımının bölgesel olarak nasıl olduğunu belirlemek için yapılan bir görüntüleme tetkikidir. Bu sayfa, hastaların bu tetkik ile ilgili en sık sordukları soruların yanıtlanması ile, beyin perfüzyon SPECT tetkikini anlamanız için hazırlanmıştır. Beyin SPECT görüntüleme, beynin üç-boyutlu görüntülerinin elde edilmesi ile beyin işlevlerinin klinisyenler tarafından değerlendirilmesini sağlayan bir nükleer tıp görüntüleme yöntemidir. Beynin farklı bölgelerinin işlevleri hakkında sağladığı bilgiler ile doktorunuzun daha doğru bir tanıya ulaşmasına olanak verir. Bir hastanın belirtilerini tam olarak değerlendirmek için, sıklıkla beynin hem yapısı (anatomisi) hem de kanlanması hakkında bilgi edinmek gerekir. BT (Bilgisayarlı Tomografi) ve MRG (Manyetik Rezonans Görüntüleme) beynin yapısı hakkında ayrıntılı bilgi sağlarlar. Ancak birçok hastada belirtiler bu yapısal değişikliklerle açıklanamaz. Beyin perfüzyon SPECT, doktorunuza beynin

kanlanması hakkında diğerk yöntemlerle gösterilemeyen önemli bilgiler sağlar. Bazı hastalarda tanıya en iyi, bölgesel beyin kan akımının incelenmesi ve normal kanlanma biçimi ile karşılaştırılması sonucunda ulaşılır. Klinisyenler beynin anatomisi ve işlevi ile ilgili bilgileri birlikte değerlendirdiğinde, belirtilerin nedeninin ne olduğunu daha iyi anlayabilirler. Beyin SPECT ayrıca tedavi başarısını değerlendirmek amacıyla da kullanılabilir.

## 2. GENEL KISIMLAR

### 2.1. YAPAY SİNİR AĞLARI KAVRAMI VE TARİHSEL GELİŞİMİ

Hayattaki bir işleyişi bilgisayar ortamına geçirmek her zaman zor olmuştur. Bilgisayarın zeka yaşının sıfır oluşu, normal hayattaki işleyişleri, anladığımız manada bilgisayara uygulamamızı imkansız kılar. Bu da işleyişleri algoritmalar halinde bilgisayarın anlayacağı dile çevirmemiz gerektiğini ortaya çıkarır. İnsanlar gibi "anlayan", "akıl yürüten" ve "yorum yapan" makineler üretmeyi gaye edinen "Yapay Zeka" adlandırılan bir araştırma alanı bu problemlerle ilgilenmektedir. Yapay Zeka çalışmaları o kadar hızlı gelişmektedir ki, bazı bilim adamlarına göre ileride Yapay Zeka, İnsan Zekasına denk, hatta ondan daha üstün bir duruma gelecektir. Öte yandan bazı bilim adamları bunun imkansız olduğunu düşünmektedirler. Yapay Zekadaki bazı eksiklikleri telafi etmek için bilim adamları Yapay Sinir Ağlarından yararlanmayı düşünmüşlerdir. Yapay Zekanın bir alt dalı olan Yapay Sinir Ağları, 1940'lı yıllarda ortaya atılmış ve son senelerde de içine aldığı konular bakımından büyük önem kazanmış, dikkatleri üzerine çekmiştir. Yapay Sinir Ağları konusundaki araştırmaların amacı, insan beyninin hesapları nasıl oluşturduğunu ve yaptığını anlamak ve daha sonra bu hesaplama gücünü taklit eden ya da tekrarlayan sinir ağı modellerini kavramaktır.

Yapay Sinir Ağları (YSA) insan beyninin çalışma sisteminin yapay olarak benzetimi çabaların bir sonucu olarak ortaya çıkmıştır. Yani YSA, insan sinir sistemindeki nöronların fonksiyonu gören temel elemanlardan oluşmaktadır. Bu elemanlar insan beyninin anatomisine benzer şekilde organize edilmişlerdir. Bu büyük benzemenin yanı sıra, YSA'nı insan beyninin şaşırtıcı derecede bir çok özelliklerini taşırlar. Örneğin, tecrübe ile öğrenirler, daha önce öğrenilen bilgileri genele indirgeyerek yeni sonuçlar çıkarırlar, yani bir bilgiden gereksiz kısımlarını çıkararak önemli olan özü alırlar. Yapay Sinir Ağı, gerçek nesnelerin biyolojik sistemlere benzer şekilde gösterimlerine olanak sağlayan, işlemsel elemanlar olarak tanımlanan basit sinir hücrelerinin paralel bağlı düzenlemeleri ile oluşturulur. YSA, katmanlar biçiminde düzenlenen basit işlem elemanı gruplarından oluşur .Her bir katman, farklı ağırlık değerlerine sahip olan bağlantılar aracılığıyla iletişimde bulunduğu belli sayıda işlem

elemanını içermektedir. YSA'nın oluşturulmasında, hücrelerin karşılıklı bağlantı biçimleri ya da işlem elemanlarının düzenlenmesi, bilgi (kodlama) öğrenme ve bilgiyi (çağırma) kullanma yöntemi olarak üç temel elemana gereksinim vardır[1].

YSA'nın temel özellikleri aşağıda özetlenmektedir:

- Problemlerin nasıl çözümleneceğini öğrenen bilgisayarlardır
- Problem çözme örnek verilere ve öğrenme biçimine dayandırılır
- Uzman bilgisine gereksinim göstermezler
- Değişik örüntüleri ayırt etmede önemli özellikleri ve ilintileri kendi içlerinde tanımları için eğitilirler
- Gerçek zamanda gerçek veriler ile ya da örnek veriler ile öğretilirler
- Yeterli yetenekte uygun bir mimariye ve öğrenme yapısına gereksinim duyarlar.

Yapay Sinir Ağlarının güçlü ve zayıf yönleri aşağıda verilmektedir.

Güçlü Yönleri:

- Kullanıcı veri örneklerine dayanan tekil çözümler üretirler
- Algoritmayı bilmeye gereksinim göstermezler
- Çok az yazılım ya da hiç yazılım gereksinimi yoktur, daha çok donanım işlem gücüne gereksinim duyarlar
- Değişik birçok probleme çözüm bulabilirler
- Paralel yapısından dolayı işlem yoğunluklu çok sayıda probleme hızlı çözüm getirirler
- Karmaşık karar alanlarını kendi içlerinde üretirler
- Gürültü yok etmede iyi başarımlar sağlarlar
- Hata dayanma yeteneğini kendiliğinden oluştururlar.

Zayıf Yönleri:

- Bütün işlemsel problemlere uygulanamazlar
- Eğitim ve test veri örneklerine gereksinim duyarlar.

YSA uygulamaları; ilgilenilen nesne hakkında hemen - hemen hiç bilgi olmaması ya da çok az bilgi olması, bu nesnenin parametrelerinin ve durumunun matematiksel olarak ya da kuralla dayalı olarak tanımlanamaması koşulların da ya da alışılmış

işlemcilerle çözümlenemeyen problemlerin varlığında birçok probleme çözüm getirebilmektedir. Buna karşın algoritma ve yazılım geliştirme, doğrulama ve gerçekleştirme mali harcamaları ve süresi yüksektir. Yapay Sinir Ağlarının başarı ile uygulandığı alanlar aşağıda verilmektedir:

- Görüntü tanıma,
- Kendiliğinden yapılanma, uyarlamalı uzman sistemler,
- Uyarlamalı işaret işleme,
- Denetim, kararlılık, güdüm,
- Karar oluşturma,
- İyileştirme prosesleri,
- Çoklu algılayıcı verilerinin kaynaştırılması,
- Robot denetimi,
- Akıllı kontrol sistemleri,
- Medikal tanılama,
- Deneysel olarak zor elde edilen değerleri kolayca bulmak.

Yapay Sinir Ağlarını önceleri, Bilgisayar, Elektrik-Elektronik mühendisleri ile Matematikçiler kullanıyordu. Daha sonra tüm mühendisler, fen bilimleri ile uğraşan araştırmacılar çalışmalarında YSA dan faydalanmaktadırlar. Son yıllarda sosyal bilimlerle uğraşan araştırmacılar tarafından bile kullanılmaya başlanmıştır. Genelde yapılan bu çalışmalarda en sık kullanılan YSA yöntemi Back-Propagation (Hatanın geriye yansması) algoritması, ağ yapısı da çok katmanlı ileri beslemeli ağ olmuştur.

YSA birçok açıdan kazançlı ve faydalıdır. Birincisi; kolayca adapte olabilirler, bilgi alabilirler ve öğrenebilirler. Böylece kendileri için hazırlanan datalardan, çözümleri anlayabilirler. Bu işlemde genelde bilgiler arasındaki ilişkileri (bağları) kurnazca yakalayarak yaparlar. Bu özellik YSA'nı diğer algoritmalarından farklı kılar çünkü, bu sistemde kurallar programcının önceliklerine göre belirlenmez ve programcıya bağlı kalmaz. YSA, bilgiler arası ilişkilerin altını çizerek (önemseyerek) uygulama geliştirme zamanını kısaltır. Ayrıca eksik çözümler de, bu sistemle tam çözüme kavuşturulabilir.



İkincisi; genellemedir. Daha önceden sistemin eğitilmiş olduğu konularda, eksik bilgi verilerek sonuç istenirse, sistem bunu geneller veya tamamlar. Bu özellik gerçekten önemlidir çünkü, gerçek dünyada bilgiler eksik veya kirlidir. Örneğin; sisli havada görülen bir cismin insan tarafından kısa bir uğraşla tanınabilmesi. Buradaki görüntü kirliliği (puslu) olmasında rağmen tanınabilmektedir.

Üçüncüsü; YSA'nın doğrusal olmayışıdır (None-Linear). Bu da bütün sonuçların her bir girdiyle etkileşim içerisinde olduğu manasına gelir. Doğrusal bir sistemde girdilerin biri değiştirildiğinde, çıktı bu değişmeye orantılı olarak değişir ve bu etki sadece değiştirilen girdinin değeri ile bağıntılıdır. Çünkü girdiler seri olarak işlenir. Doğrusal olmayan sistemlerde ise çıktılar bütün girdilere bağlıdır ve bir girdi değiştirildiğinde bu değişiklik çıktıda önemli bir değişikliğe sebep olmaz. Çünkü çıktı bütün girdilerin paralel işlenmesi ile elde edilir. Gerçek hayattaki sistemler genelde doğrusal değildir. Örneğin; ülke ekonomisindeki finansal durumlar, faiz oranları, fiyatlar, kurlar, borsa karmaşık bir etkileşim içerisinde dirler. Dolar fiyatının artışı, ekmeğin fiyatının değişmesinde veya faiz oranlarının artmasında etkili olabilir.

Dördüncüsü; YSA'ı paralel işlemlerde son derece başarılıdır. Bir çok benzer ve birbirlerinden bağımsız işlemler aynı anda simüle edilerek işlenebilir. Aynı zamanda, paralel bazlı donanımlar bildiğimiz klasik mikro işlemlerden binlerce kez daha hızlıdır.

İnsan daima kendi düşünceleri hakkında merak sahibi olmuştur. Bu öncelikle kendisine soru yönelmekle, yani beynini çalıştırarak beynini düşünmesi çerçevesi sonucunda nörobiologların ve nöroanatomistlerin uzun süren çalışmaları insan sinir sisteminin yapısı ve fonksiyonları hakkında oldukça önemli bilgiler elde edildi. Bu alandaki bilgi arttıkça, karmaşıklığın ağır ağır çözüldüğü görülmüştür. Enteresan olan, sayıları milyarları bulan ve birbiriyle bağlantılı nöronlar, en gelişmiş bilgisayarları bile cüce bırakan bir sistem oluşturmaktadır. Örneğin, nümerik işlemlerde insandan çok daha hızlı ve hatasız çalışan bir sistem, zeka isteyen işlerde (tic-tac-toe oyunu veya el yazısı tanıma vs.) tamamen başarısızdır. İşte araştırmacılar bu karmaşık bulmacayı çözmek için yaklaşık 50 yıldır çalışıyorlar. İnsan sinir sisteminin daha iyi anlaşılması için nöronların fonksiyonları ve birbiriyle olan bağlantılarını test etmek amacıyla matematiksel modeller geliştirmelerine imkan sağlamıştır. Bu modellerin

beyin fonksiyonları taklit ilgilerini etmelerinin yanı sıra kendi başlarına bazı yararlı fonksiyonları da oluşturabildiklerini göstermiştir. Ve bunun için iki ana hedef belirlenmiştir. Birincisi insan sinir sisteminin fizyolojik ve psikolojik işleyişini anlamak, ikincisi ise, beyine benzeyen fonksiyonlar gerçekleştiren YSA üretmek.

Bu çalışmalar diğer ilimlerin de ilgisini çekmiştir. Nöroanatomi ve nöropsikoloji alanındaki gelişmelerle birlikte psikologlar da insanların öğrenme işini modelleme çalışmalarını başladılar. İlk adımları psikolog ve nöroanatomist McCulloch ve matematikçi Pitts 1940’larda attılar. 1943 yılı YSA Sistemleri için bir doğuş yılı olarak görülür[2]. McCulloch ve Pitts nöronun lojik fonksiyonlarını sağlayan basit bir eşik cihazı olarak modellenebileceğini gösterdi. Onların yaptıkları bu ilk YSA, vakum tüplerinden ve çeşitli aletlerden oluşuyordu. Bu sistem genel olarak basit mantıksal işlemleri çözüme kullanıldı. Fakat, sistem büyük bir alan kaplıyor, büyük parçalardan oluşuyor ve yavaş işliyordu. Yine de bu iki araştırmacı YSA araştırmalarında, ilk fonksiyonel nöronu yaparak, yeni bir devir açtılar. Bu tarihten sonra kısaca gelişmeler şöyle gerçekleşti:

1949’da Donald Hebb “The organization behaviour ” adlı kitabında hücrese seviyede beyinin öğrenme mekanizmasından bahsetmiştir ve YSA öğrenme algoritmaları için başlangıç noktası sayılan bir öğrenme kanunu ileri sürdü[3]. Bu gün üzerine bazı eklemeler yapılmış olan bu model, o dönemin bilim adamlarına, bir nöron ağının öğrenme işini nasıl gerçekleştireceği konusunda fikir vermiştir. Daha sonra Rosenblatt (1958) nöron benzeri bir kavram ortaya attı[4]. Bu kavram perceptron idi ve bu küçük sanal makine desenleri sınıflandırmayı, bağlantı ağırlıklarını değiştirerek öğrenebiliyordu. Bu gelişmeden sonra desen tanıma üzerine çalışmalar gittikçe hızlandı. 1960 yıllarının başında ADALINE (ADaptive LINEar combiner) denen bir sistem bulmuşlardır[5]. Bu yeni buluş, Widrow-Hoff adında güçlü öğrenme kuralına sahiptir. Bu kural kısaca şöyledir; desen tanıma sırasında oluşan hata payları karesel bir orantı ile hesaplanıp sisteme geri gönderiliyordu. Böylece sistem, tanıma işlemini daha doğru bir şekilde yeniden yapıyordu. Bu dönemde bilim adamları “zeka”nın anlaşıldığı, çözüldüğü düşüncesine kapıldılar ve beyinin benzerini üretmenin yeterince büyük bir ağı oluşturulmasından ibaret olduğu iyimserliğine kapıldılar. Bu iyimser düşüncüler kısa sürede sona erdi. 1969’lara gelindiğinde yapılan çalışmalarda ağlar, o güne kadar çözebildiği problemlere genel hatları ile benzer farklı problemleri

çözümleyememiştir. Bu sebebi bilinmeyen başarısızlıklar, yoğun bir analiz ve inceleme dönemini başlattı. Bu dönem araştırmalar, daha çok olayın formülize edilmesi ve yeni matematiksel formüller üretme çerçevesinde yapıldı. Marwin Minsky, matematiksel teknikleri kullanarak, ağ işlemleriyle ilgili sağlam teoriler geliştirdi. Fakat 1969 yılında Minsky ve Papert yayınladıkları Perceptron adlı bir kitapta YSA yardımı ile öğrenmede ve hesaplamada aşılması zor engeller olduğunu iddia etmişler ve bu iddia YSA konusundaki çalışmalarını büyük ölçüde yavaşlatmıştır. Onların vardığı sonuçlara hiç kimse karşı çıkmamıştır. Hatta, Cesareti kırılan bazı araştırmacılar başka alanlara kaymışlardır. Bu tür çalışmalara uygulanan teşvik destekleri çekilmiş ve bu konuda yapılan araştırmalar yaklaşık 15 yıllık bir karanlık döneme girmiştir. Fakat YSA ile ilgili çalışmalar, Teuvo Kohonen, Stephen Grossberg ve James Anderson gibi bir kaç bilim adamı tarafından sürdürülmüştür. John Hopfield (1982-84) tarafından yayınlanan “Neural Networks and Physical systems” [6] adlı çalışması ile çağdaş YSA devri başlar. Bu çalışmada Hopfield nöronların karşılıklı etkileşimlerine dayanan bir nöral hesaplama modeli önermiştir. Model bir enerji fonksiyonunu alabileceği en az değerine indiren birinci mertebeden lineer olmayan diferansiyel denklemlerden oluşmuştur. Hopfield ağ seviyesinde, tek nöron seviyesinde var olmayan hesaplama kapasitesinin bulunduğunu öne sürdü. Bu tür YSA’na Hopfield ağı denmektedir. Hopfield’in geri beslemeli YSA modelini ortaya atması ve bunun pratik optimizasyon problemlerinde kullanılabilirliğini göstermesi YSA konusundaki çalışmalarını yeniden hızlandırmıştır. Daha sonra, Grossberg ART (Adaptive Resonance Theory) adında bir YSA yapısı geliştirdi[7]. ART çok gelişmiş bir YSA’dır ve henüz çok fazla probleme uygulanmamıştır. O sıralarda Kohonen de “kendini düzenleyen nitelik haritasını” (Self Organizing Maps) geliştireyordu[8]. Bu YSA nümerik aerodinamik akış hesaplamaları için çoğu algoritmik yöntemden daha etkili olmuştur.

1986’da Rumelhart ve arkadaşları “Parallel Distributed Processing” (paralel dağıtık işleme) adlı kitaplarında, ileri beslemeli (feed-forward) ağlarda yeni öğrenme modeli olan hatanın geriye yayılması algoritmasını (backpropagation algorithm) geliştirerek, daha önce bu konuda Minsky ve arkadaşları tarafından iddia edilen aksaklıkların aşılabileceğini göstermişlerdir[9-11]. Bugün endüstride birçok YSA uygulamasında bu öğrenme yöntemi ile bunun değişik varyasyonları kullanılmaktadır. Back-propagation algoritması, kullanımı çok yaygın olan ve öğrenilmesi kolay bir ağıdır.

Ayrıca önceki bölümde anlatıldığı gibi biyolojik işaretlerin sınıflamalarında tercih edilen bir ağ yapısıdır. İççe girmiş konveks yapıdaki kümelerin sınıflamasını rahatlıkla yapmaktadır.

Widrow ve öğrencileri ise ADALINE'den (Adaptive LINEar Element) sonra MADALINE'da geliştirip bu YSA'ya uygulama alanları buldular [12]. MADALINE-I'i, 1987'de MADALINE-II, 1988'de (David Andes'in keşfettiği) MADALINE-III takip etti[13]. Geliştirilen bu yeni kurallar 1960'dan 1987'ye kadar olan süreçteki, çözilemeyen problemleri ortadan kaldırdı. Böylece yeni YSA araştırma programlarının ortaya çıkışları hızlandı, araştırmalar kuvvetlenmeye başladı. Bunu, dünya çapında verilen konferanslar, yeni yayınlar izledi. Hopfield ve Tank (1985); belirli problemlerin çözümü için ağ yapılandırmasıyla ilgili genel prensipleri ele almışlardır. YSA'nın hesaplama gücünü göstermek için, zor ama iyi tanımlanmış bir optimizasyon probleminin çözümüne tasarlanmış bir YSA'nın bilgisayar simülasyonlarının sonuçlarını vermişlerdir[14]. Lippmann (1987); YSA ile hesaplamaya bir giriş yaparak çeşitli ağ tiplerini ve algoritmaları incelemiş, bunların birbirlerine göre üstünlüklerini ve sakıncalarını tartışmıştır[15]. Hornik (1991); rastgele koşullandırılmış ve değişken aktivasyon fonksiyona sahip ve tek bir gizli katmanı olan standart çok-katmanlı ileri-beslemeli ağların performanslarının bile, çok genel yaklaşım kabiliyetleri olduğunu göstermiştir[16]. Yeteri kadar düzgün aktivasyon fonksiyonları olan ağları, bir fonksiyona ve onun türevlerine rastgele doğruluk düzeyinde yaklaşabilmelerini mümkün kılan çok genel şartlar vermiştir. Daha sonra, kullanılan transfer fonksiyonlarına, ağ yapısı ve bağlantılarına göre değişik YSA modelleri geliştirmiştir. Bunların çoğu eğitme algoritması olarak Hatanın Geriye Yansımaları (Back Propagation) algoritmasını kullanır. YSA'nın bu tarihi gelişimi özet olarak aşağıda Tablo 2.1 de verilmiştir. [17-25]

YSA üzerindeki çalışmalar önceleri temel tıp bilimlerinde insan beynindeki nöronların matematiksel modelleme çabaları ile başlamasına rağmen, bugün fizik, matematik, elektrik ve bilgisayar mühendisliği gibi çok farklı bilim dallarında araştırma konusu haline gelmiştir. YSA'nın pratik olarak kullanımı genelde, çok farklı yapıda ve formlarda bulunabilen bilgi (information) verilerini hızlı bir şekilde tanımlama ve algılama üzerinedir. Aslında mühendislik uygulamalarında YSA'nın geniş çaplı kullanımının en önemli nedeni, klasik tekniklerle çözümü zor olan

problemler (çok sayıda nonlinear deęiřkene sahip sistemler) için etkin bir alternatif oluřturmasıdır. Bu sistemlerin başlıca belirgin özellikleri algoritmasız, tamamıyla paralel, uyarlanabilen (adaptive), öğrenebilen ve paralel dağıtık bir hafızaya sahip olmalarıdır. Ama, YSA sistemleri özellikle donanım olarak hala gelişmektedir.

Tablo 2.1 : Değişik YSA modellerinin tarihi gelişimi ve kullanma alanları

Peryod	Geliştirenler	Modelin Ismi	Uygulamaları	Öğrenme tipi
1957-1960	F. Rosenblatt	Perceptron	Type character recognition and Classification	Supervised
1959-1962	B. Widrow M. E. Hoff	LMS	Prediction, noise cancellation	Supervised
1971-1994	I. Aleksander J. G. Taylor T. G. Clarkson D. Gorse	RAM model PRAM (Weightless neurons)	Pattern recognition, Classification	Supervised-reinforcement
1982-1987	J.J. Hopfield	Feed-Forward and Feed back	Recognition, Classification, Prediction, etc.	
1974-1986	P. Werbos, D. Parker D. Rumelhart	Back propagation	Pattern, recognition, Prediction, etc.	Supervised
1975-1983	K. Fukushima	Neocognitron	Pattern recognition	Supervised/Unsupervised
1978-1986	G. Carpenter S. Grossberg	Adaptive Resonance Theory (ART)	Recognition: classification of complex pattern	Supervised/Unsupervised
1987-1988	B. Widrow and David Andes	ADALINE MADALINE-1-2-3	Pattern recognition, Prediction, etc.	Supervised
1980	T. Kohonen	Self Organizing Map	Image recognition	Unsupervised
1982	B. Wilkie J. Stonham I. Aleksander	WISARD	Pattern and image recognition	RAM based model
1982-1984	J. Hopfield	Associative Memory	Speech Processing	Association (Hebbian)
1985	B. Kosko	Bi-directional Associative Memory (BAM)	Image Processing	Association (Hebbian)
1980-1993	M. J. D. Powell, J. E. Moody, C. J. Darken, S. Renals T. Poggio, F. Giros	Radial Base Function (RBF) (Hybrid system)	Prediction Recognition	Supervised
1987-?	E. Alpaydın		Pattern and image recognition	Supervised
1994-1997	G. Dorffner	Conic Section Func. neuralnet. (CSFNN)	Pattern recognition, Prediction etc.	Supervised
2001-2003	B. Karlık	Fuzzy Clustering Neural net. (FCNN)	Pattern recognition, Prediction etc.	Supervised

## 2.2. YAPAY SİNİR AĞLARININ TANIMI VE MODELİ

### 2.2.1. Biyolojik Beyinin İşlevi

Beyin ve omurilik birlikte Merkezi Sinir Sistemini oluştururlar. Beyinden ve omurilikten zuhur eden, vücudun her yerine ulaşan sık ve beyaz sinir hücreleri de “çevresel sinir sistemini” meydana getirir. Merkezi sinir sistemi iki bölümden oluşur.

- Beyin; entegre, kurumsal, düşünce, davranış kontrolü.
- Omurilik; beyinden gelen ve beyine giden mesajları taşır, omurga refleks merkezidir.

Beyin canlıların en önemli organıdır. Bütün canlılar bu organ sayesinde vücutlarını kontrol eder ve karar verirler. Bu organ insanlarda çok daha gelişmiştir. Bir insan beyni yaklaşık 1,4 kg ağırlığındadır. Buna rağmen içerisinde milyarlarca sinir hücresi barındırır. Peki zeka neye bağlıdır? Beyindeki sinir hücrelerinin fazlalığına veya beyinin büyüklüğüne mi? Bunun cevabı kesin olarak bilinmese de genel kanı, sinir hücreleri arasındaki bağların çokluğunun önemli rol oynadığıdır. Yani sinir hücreleri arasındaki bağlar (dentritler) ne kadar karışık ve çoksa, düşünce gücünün o denli fazla olduğu görüşü yaygındır. Ve bu bağlar beyin jimnastiği yaptıkça, düşündükçe gelişir. Aslında bu bağların her biri bilgiler arası bağlantıları ifade eder. Burası çok önemlidir çünkü bilgisayar ortamında da önemli bir noktayı teşkil eder. Beyinde bir diğer merak konusu da hafızadır. Bilgiler nerede depolanır? Bunun da cevabı bilinmiyor. Bir görüş bilgilerin sinir hücrelerinde saklandığıdır, diğer bir görüş ise beyin özel bir hafıza merkezi olduğudur. Fakat bu konudaki araştırmalar pek hızlı yürüyememektedir ve genelde bulgular teorik kalmaktadır. Bunun başlıca nedenlerinden biri canlı denek kullanılamamasıdır.

Bilgisayarın araştırma alanına girişine kadar beyin hakkında bilinenler çok azdı. Daha sonra sinir hücreleri bilgisayarlar da simüle edilmeye başlandı ve duruma göre tepkileri kontrol edilmeye başlandı. Bir bakıma beyin simülasyonu yapıldı. Tabii ki milyarlarca hücreyi simüle etmek şu anki teknoloji itibari ile imkansızdır. İnsan beyninin değişik iki işlevinin olduğu bilinmektedir. Birincisi, bilinçli olarak tanımlanmış ardışık adımlardan oluşan bir işlemin mantıksal olarak sıralanması


düşüncesidir. Program olarak listelenmiş istekleri ardışık olarak işleyen günümüzün sayısal bilgisayarları, beynin bu işlevinden esinlenerek, 1940'lı yıllarda bulunan "Ardışık Bilinçli Düşünme"nin bir sonucu olarak geliştirilmiştir. Diğer yönden ise, bilinç dışı düşünmenin ya da bilinç dışı zekânın çok daha karmaşık yapıda olduğu bilinmektedir. Çevremize ait birçok veri, duyu organlarımız tarafından sağlanan algılama ve öz nitelik çıkarma süreçlerinden bilinç dışı olarak geçmektedir. Örneğin; hareketlerimizin üç boyutta uyarı ve tepki sınırları aracılığıyla denetimi büyük oranda bilinç dışı bir düşünmedir. Bilinç dışı düşünme yapısı, belleğimizin büyük bir yeteneğe sahip olmasında temel oluşturmaktadır. Bilinç dışı gerçekleştirilen işlevlerin tamamı, birbirine yakın karşılıklı bağlantılardaki etkileşimden ve elektro kimyasal süreçlerden dolayı sinir hücrelerinin oluşturduğu ağlarda paralel olarak çalışırlar.

Beynimiz, her biri yaklaşık binden yüz bine kadar sinir hücresinden oluşan işlevsel birimlerin üst düzeyde tümleştirilmiş bir sistemi olarak biçimlendirilmiştir. Her bir hücre ondan on bine kadar eşit olarak değişen bağlantılarla bir diğer hücreye bağlanır. Merkezi sinir sistemimiz kabaca yüz milyar ile bir trilyon hücreden oluşmaktadır. Yapay olarak, bu büyüklükte bir bilgi işlem sisteminin tamamıyla oluşturulamayacağı ve genetik bilgiler ele alınmadığında bile doğum öncesi bilgilerin programlanamayacağı açıktır. Beynimiz kendini düzenleme, öğrenme ve ilişki kurma yeteneklerine sahiptir. Biyolojik bilgi işlem modellerinin taklit edilmesinde ise, farklı düzenleme ve düşünce seviyeleri oluşturulmaktadır. Sinir hücresinin uyarlanma davranışının yanı sıra, durağan ve durağan olmayan elektriksel özelliklerinin gösteriminde tek hücre seviyesi ele alınmaktadır. Ağ seviyesinde, ağı oluşturan benzer sinir hücrelerinin karşılıklı bağlantıları uyarı-tepki işlevlerini tanımlamak için incelenmektedir. Algılama ve problem çözme gibi akılsal işlev seviyesinde, ağlar çok daha karmaşıktır. Bunlar biyolojik bilgi işlem sürecinin en üst seviye ağlarıdır.

### **2.2.2. Biyolojik Sinirin Yapısı ve Modeli**

Sinir sistemini oluşturan ve birbirlerine Axon ve Dentritlerle bağlı, aralarında elektriksel akış olan (Şekil 2.1), birbiriyle etkileşim içinde olan, canlılarda bütün reflekssel, hareketssel, algısal, düşünsel olayları sağlayan canlı hücrelere sinir hücreleri denir.






Şekil 2.1: Basit bir nöron yapısı

İnsan sinir sistemi yaklaşık olarak  $10^{12}$  ( 1 trilyon ) nöron (sinir hücresi) içerir. Sinir sisteminin temel yapıtaşı olan nöronlar, çeşitli uyarılara kasılarak yanıt verirler. Nöron, soma adı verilen hücre gövdesi dendrit denilen kıvrımlı uzantılar ve somanın dalları sayesinde nöronu dallarına bağlayan tek sinir fiberli aksondan oluşur. Dendritler hücreye gelen girişleri toplarlar. Dendrit tarafından alınan işaretler hücrede birleştirilerek bir çıkış darbesi üretilip üretilmeyeceğine karar verilir. Eğer bir iş yapılacaksa üretilen çıkış darbesi aksonlar tarafından taşınarak diğer nöronlarla olan bağlantılara veya terminal organlara iletilir. Fakat korteks, işin yapılabilmesi için hangi nöron harekete geçirilecekse, sadece ona komut gönderir. Sinir hücrelerinin bilgi göndermesi üç çeşittir:

- Elektriksel
- Kimyasal
- Mekanik

Her bir gönderme tepkisine sinaps adı verilir. Bir sinir hücresine giren sinapslar, o hücrenin özelliklerine göre işlenir ve tek bir çıktı (sinaps) axondan gönderilir. Şunu unutmamak gerekir ki her bir sinir hücresine sayısız dendritler girebilir. Her bir sinir hücresi bir eşik değerine sahiptir. Buna Threshold değeri adı verilir ve Teta ile gösterilir. Eğer gelen sinapsların toplu bir işleminden geçirildikten sonraki sonuç değeri Threshold değerini aşabilirse, ulaşılan değer axondan sinaps olarak gönderilir. Ayrıca her bir dentritin ağırlık değeri vardır. Gelen bilgi bu ağırlık değeri ile çarpılır (işlenir) ve önemine göre (ağırlık değerinin büyüklüğüne göre) yeni değeri oluşturulur ve hedef sinir hücresine yeni değeri ile girer. Burada dikkatimizi çekmesi gereken nokta, ilişkilerin derecelendirilmesidir. İki veya daha fazla bilgiler arasındaki bağlar ilişki kurarken, ağırlık değerleri (önemlilik) belirlenir. Eğer sonradan bu önem derecesi

değiştirilmesi gerekirse, bu değerler üzerinde oynama yapılır. Bilgisayar uygulamalarında ağırlık değerlerinin önemi büyüktür. Sinir hücrelerindeki bu değerler, kendi spesifik özelliklerine göre değişir. Örneğin; burundaki bir sinir hücresinin kokulara karşı olan hassasiyeti, gözdeki sinir hücrelerine göre daha hassas eşik değerine sahiptir. Veya göz aşırı bir ışığa maruz kalırsa, buradaki sinir hücreleri otomatik olarak ışığa karşı olan hassasiyetlerini azaltırlar yani eşik değerlerini arttırırlar ki, gelen tepkiler büyük olsalar bile bu eşik değerinden geçmesin. Sinir sistemi milyarlarca nöron ile tek bir nörondan çıkan aksonun 10000 kadar diğer nöronu bağlayan bir ağdır. Sinapslarla düzeltilen işaretleri taşıyan aksonlar ve dendritlerle iç içe geçmiş nöronlar bir sinir ağı oluştururlar. Şekil 2.2'de en basit formda gösterilen nöron modeli, bir eşik birimi olarak algılanabilir. Eşik birimi, çıkışları toplayan ve sadece girişin toplamı iç eşik değerini aştığında bir çıkış üreten işlem elemanıdır.

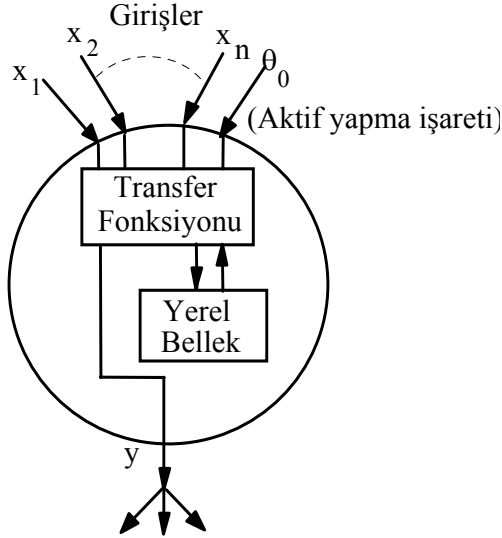


Şekil 2.2: Yapay Nöron (sinir) modeli


Bir eşik birimi olarak nöron sinapslarında ki işaretleri alır ve hepsini toplar. Eğer toplanan işaret gücü eşiği geçecek kadar güçlü ise diğer nöronları ve dendritleri uyaran akson boyunca bir işaret gönderilir. Kesişen dendritlerden gelen sinapslarla kapılanan bütün işaretleri soma toplar. Toplam işaret daha sonra nöronun iç eşik değeri ile karşılaştırılır ve eşik değeri aşmışsa aksona bir işaret yayar. YSA, bu basit nöronların (düğümünün ya da ünitelerin) bağlanarak bir ağ'a dönüştürülmesiyle meydana getirilir.

### 2.3. YAPAY SİNİR AĞLARININ MİMARİSİ VE İŞLEM ELEMANI

YSA temel olarak, basit yapıda ve yönlü bir graf biçimindedir. Her bir düğüm hücre denilen  $n$ . dereceden lineer olmayan bir devredir. Düğümler işlem elemanı olarak tanımlanır. Düğümler arasında bağlantılar vardır. Her bağlantı tek yönlü işaret iletim yolu (gecikmesiz) olarak görev yapar. Her işlem elemanı istenildiği sayıda giriş bağlantısı ve tek bir çıkış bağlantısı alabilir. Fakat bu bağlantı kopya edilebilir. Yani bu tek çıkış birçok hücreyi besleyebilir. Ağdaki tek gecikme çıkışları ileten bağlantı yollarındaki iletim gecikmeleridir. İşlem elemanının çıkışı istenilen matematiksel tipte olabilir. Kısmen sürekli çalışma konumunda "aktif" halde eleman bir çıkış işareti üretir. Giriş işaretleri YSA'na bilgi taşır. Sonuç ise çıkış işaretlerinden alınabilir. Şekil 2. 3'te YSA'na ait işlem elemanının (nöron, düğüm) genel yapısı verilmiştir.



Şekil 2.3: Genel işlem elemanı yapısı

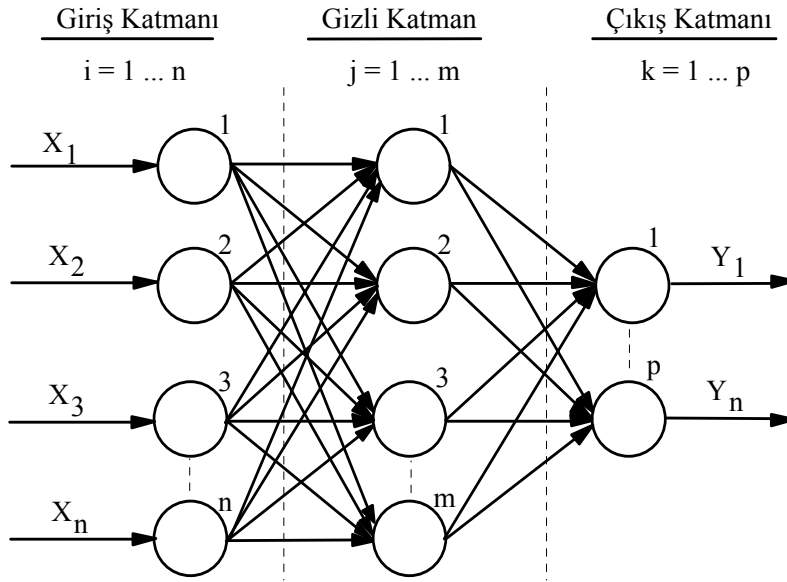


Şekil 2.4: Tek katmanlı YSA

YSA birtakım alt kümelerle ayrılabilir. Bu alt kümelerdeki elemanların transfer fonksiyonları aynıdır. Bu küçük gruplara "katman" layer adı verilir. Ağ katmanlarının

birbirlerine hiyerarşik bir şekilde bağlanmasından oluşmuştur. Dış dünyadan alınan bilgi giriş katmanı ile taşınır. YSA transfer fonksiyonu ve yerel bellek elemanı bir öğrenme kuralı ile giriş çıkış işareti arasındaki bağıntıya göre ayarlanır. Aktif yapma girişi için bir zamanlama fonksiyonu tanımlaması gerekebilir. Basit işleme elemanlarından oluşmuş birçok ağıın temel yapısı Şekil 2.4'teki tek katmanlı yapıdır.

Araştırmacılar tek katmanlı ağların çeşitli uygulamalarda sınırlı yetenekler gösterdiklerini ispatlamışlardır. Fakat bu ağlar iki veya daha fazla nöral katmanını kaskat bağlayarak oluşturulan çok katmanlı ağlara yol açmışlardır. Çok katmanlı ağların çalışması tek katmanlı ağların çalışmasına benzer. Her katmanın çıkışı önceki katmanın çıkışlarından ağırlıklı toplam olarak üretilir. Çok katmanlı YSA Şekil 2.5'de gösterilmiştir.

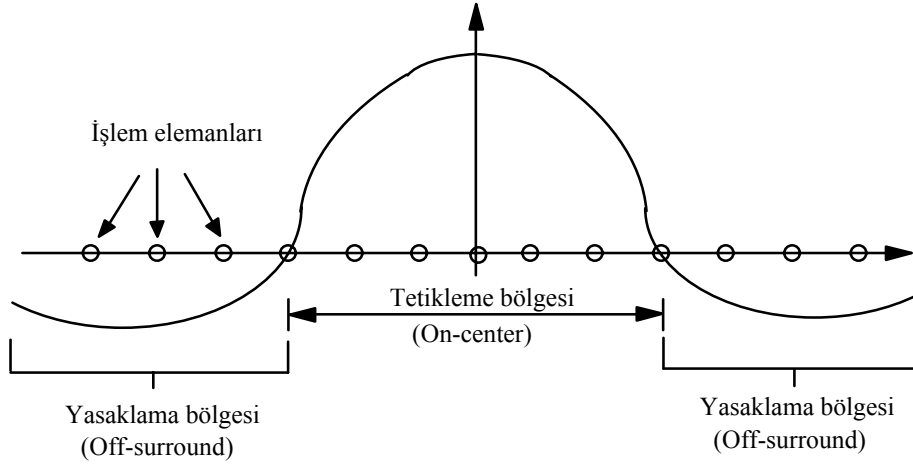


Şekil 2.5: Çok (üç) katmanlı YSA

Çok katmanlı ağda her katmanda nöron sayısı farklı olabilir. Araştırmacılar çok katmanlı ağlarının sistematik eğitilmesine imkan sağlayan algoritmalar geliştirmişlerdir. Bu algoritmaların çok katmanlı ağlara uygulanması ile, tek katmanlı ağların başarısız oldukları bir çok iş, çok katmanlı ağlar tarafından başarılı bir şekilde yapılmıştır.


### 2.3.1. Giriş İşareti Sınıfları

İşlem elemanının transfer fonksiyonu gelen bütün giriş işaretleri için tanımlanır. Bazen değişik katman davranışlarının farklı olması doğaldır. İşaretlerin hangi bölgelerden geldiğinin bilinmesi gerekir. Değişik bölgelere göre işaretlerin sınıfları tamamlanabilir. Sıkça izlenen bir yapı ise merkezde evet/çevrede hayır (on centre/off surround) yapısıdır. Şekil 2.6'de bu yapı gösterilmektedir. Meksika şapkasına benzer bağlantı tipindedir [26].



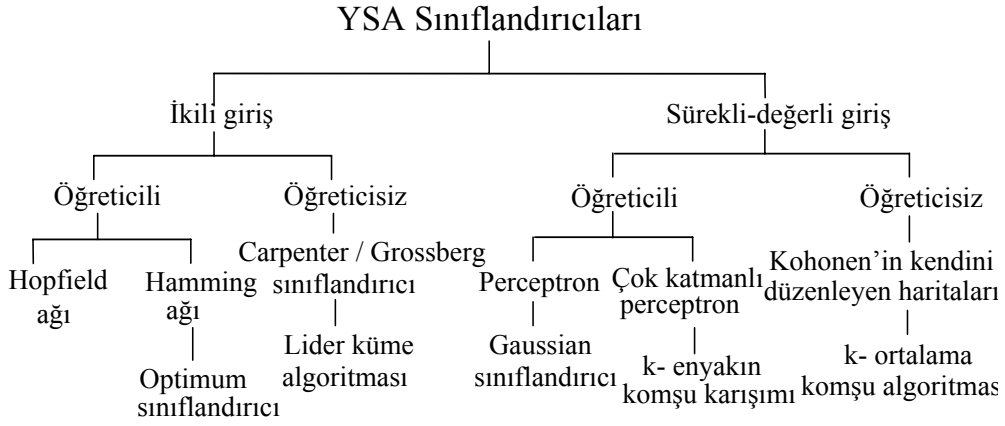
Şekil 2.6: Komşu hücrelerin merkez hücreye etkisi

İşlem elemanı tetikleyici girişlerin kendine yakın komşu girişlerden yasaklanan girişlerini daha uzaktan alır. Böylece işlem elemanına gelen girişler sınıflarına göre değerlendirilmiş olur. Tetikleyici bölgeden gelen girişler yasaklanan sınıfı oluşturur. Şekil 2.7 böyle bir işlem elemanını gösterir [26].



Şekil 2.7: Tetikleyici ve yasaklanan girişlere sahip bir işlem elemanı

Lippmann örüntülerin sınıflandırılmasında kullanılabilen altı önemli sinir ağına ait sınıflandırma vermiştir. Sınıflandırma öncelikle giriş biçimlerine bağlı ikili ve sürekli değerli giriş olmak üzere ikiye ayrılmıştır (Şekil 2.8). Bunun altında ise ağlar, öğreticili (supervised) ve öğreticisiz (unsupervised) eğitimlerine bağlı olarak sınıflandırılmışlardır.



Şekil 2.8: Yapay sinir ağı sınıflandırıcıları

### 2.3.2. Bağlantı Geometrileri

Bağlantılarda, taşınan işaret verisinin cinsi tanımlanmalıdır. Bağlantı geometrisi YSA için çok önemlidir, bağlantı işareti her cinsten olabilir. Bağlantının nerede başlayıp nerede bittiğinin bilinmesi gerekir. 1'den n'e kadar olan bir işlem elemanı kümesinin bağlantıları aşağıda tanımlandığı gibi (n x n) boyutlu matris biçiminde gösterilebilir.

$$[w_{ij}] = \begin{bmatrix} w_{11} & w_{12} & \cdot & \cdot & w_{1n} \\ w_{21} & w_{22} & \cdot & \cdot & w_{2n} \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ w_{n1} & w_{n2} & \cdot & \cdot & w_{nn} \end{bmatrix} \quad (2.1)$$

$$w_{ij} = w_{ji} = 1 \quad \Leftrightarrow \text{i. işlem elemanı j. işlem elemanına bağlı}$$

$$w_{ij} = w_{ji} = 0 \quad \Leftrightarrow \text{bağlı değil}$$

En fazla  $n^2$  bağlantı olur. Bağlantılar çeşitli geometrik bölgeler arasında demetler halinde düşünülebilir. Bu bağlantı demetlerinde olması gereken kurallar şunlardır:

1) Bağlantı demetini oluşturan işlem elemanları aynı bölgeden çıkmalıdır.

- 2) Bağlantı demetinin işaretleri aynı matematiksel tipten olmalıdır.
- 3) Bağlantı demetinin işaretleri aynı sınıftan olmalıdır.
- 4) Bağlantı demetinin bir seçim fonksiyonu (s) olmalıdır.

$$\sigma : T \rightarrow 2^S \quad T : \text{Hedef bölgesi} \quad s : \text{Kaynak bölgesi}$$

Hedef bölgesindeki her işlem elemanı, kaynak bölgesindeki her elemana giderse “tam bağlıdır”. Eğer hedef bölgesi elemanı, n adet kaynak bölgesi elemanına bağlı ise “düzgün dağılmış (üniform)” denir. Ayrıca bir elemana, yine bir kaynak elemanı bağlı ise buna “bire-bir bağlı” denir.


## 2.4. AĞ TİPLERİ

Genel anlamda, üç çeşit ağ tipi vardır:

1- İleri Beslemeli Ağ: Herbir katmandaki hücreler sadece önceki katmanın hücrelerince beslenir ve dolayısıyla bilgi akışı sadece ileriye doğrudur.

2- Kaskat Bağlı Ağ: Hücreler sadece önceki katmanlardaki hücrelerce beslenir.

3- Geri Beslemeli Ağ: En az bir hücre sonraki katmanlardaki hücrelerce beslenir. Bir katmandan diğerine veya kendisine doğru uzanan ağırlıklar yoluyla geri besleme bağlantılarına izin veren daha genel bir ağ yapısı gösterir. Bu çalışmada hem ileri, hem de geri beslemeli (hatanın geriye yayılımı sırasında) ağ tipi birlikte uygulanmaktadır.




Şekil 2.9: (a) İleri doğru tek yönlü, (b) Çift yönlü tamamen bağlantılı YSA modeli

Şekil 2.9 (a)'da tek yönlü bağlantıların olduğu, bir katmandaki bilgilerin sadece bir üst katmana geçtiği ve yine bir katmandaki işlem elemanlarının bir üst katmana tamamen bağlandığı bir ağ yapısı gösterilmiştir. Bilinen meşhur geriye yayılım ağı modeli bu tür yapıya örnek olarak verilebilir. Şekil 2.9-(b)'de ise çift yönlü ilişkilerin olduğu bir yapı sergilenmektedir. Hopfield modeli bu tür ağlara örnek olarak gösterilebilir. Ayrıca, kısmi bağlantılı, rezonans bağlantısı ve hiyerarşik bağlantı vs gibi özel bağlantı tipleri mevcuttur.

## 2.5. EŞİK FONKSİYONLARI

Transfer veya işaret fonksiyonları olarak da adlandırılan eşik (aktivasyon) fonksiyonları, muhtemel sonsuz giriş kümesine sahip işlem elemanlarından önceden belirlenmiş sınırlar içinde çıkışlar üretirler. Beş tane yaygın olarak kullanılan eşik fonksiyonu vardır. Bunlar liner, rampa, basamak, sigmoid ve  $\tanh(x)$  fonksiyonlarıdır. Şekil 2.10'da bu fonksiyonlar gösterilmiştir.



Şekil 2.10: Sıkça kullanılan eşik fonksiyonları



Şekil 2.10-a gösterilen lineer fonksiyonun denklemi aşağıdaki gibidir.

$$f(x) = \alpha \cdot x \quad (2.2)$$

$\alpha$  işlem elemanının  $x$  aktivitesini ayarlayan reel değerli bir sabittir. Lineer fonksiyon  $(-\tau, +\tau)$  sınırları arasında kısıtlandığında Şekil 1.9-b'deki rampa eşik fonksiyonu olur ve denklemi;

$$f(x) = \begin{cases} +\tau & : \text{Eğer } x \geq \tau \text{ ise} \\ x & : \text{Eğer } |x| < \tau \text{ ise (yani } -\tau < x < \tau) \\ -\tau & : \text{Eğer } x \leq -\tau \text{ ise} \end{cases} \quad (2.3)$$

şeklini alır.  $+\tau$  / $-\tau$  işlem elemanının maksimumu (minimumu) çoğu zaman doyma seviyesi olarak adlandırılan çıkış değeridir. Eğer eşik fonksiyonu bir giriş işaretine bağlı ise yaydığı  $+\tau$  giriş toplamı pozitif, bağlı değilse eşik basamak fonksiyonu  $|\delta|$  olarak adlandırılır. Şekil 2.10-c, basamak eşik fonksiyonunu gösterir ve denklemi;

$$f(x) = \begin{cases} +\tau & : \text{Eğer } x > 0 \text{ ise} \\ -\delta & : \text{Diğer durumlar} \end{cases} \quad (2.4)$$

şeklindedir. Diğer bir eşik fonksiyonu ise sigmoid fonksiyonudur ve bu tez çalışmada eşik fonksiyonu olarak kullanılmıştır. Şekil 2.10-d'de gösterilen yatık S biçimindeki sigmoid fonksiyonu; seviyeli, doğrusal olmayan(non-linear) çıkış veren, sınırlı, monoton artan bir fonksiyondur ve denklemi;

$$f(x) = \frac{1}{1+e^{-x}} \quad (2.5)$$

biçimindedir. Son olarak Şekil 2.10-e'de ise  $\tanh(x)$  fonksiyonu görülmektedir ve denklemi;

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (2.6)$$

şeklindedir. Her işlem elemanı kendisine gelen bir yerel veriye göre, kendisini ayarlayarak bütün YSA'nın bilgi bölgesini öğrenmesini sağlar. Yukarıdaki transfer fonksiyonlarını kullanabilmek için, giriş verilerinin gerçek değerlerinin "0" ile "1" arasındaki bir reel sayıya dönüştürülmesi (normalizasyon) gerekir. (Normalize etmek: mesela gerçek değeri 85 olan bir girişi 0.85 şeklinde ağa uygulamaktır.) Normalizasyon aynı anda bütün girişlere uygulanabilir.

Ayrıca, kullandığı eşik fonksiyonuna bağlı olarak isimlendirilen YSA modelleri vardır. Eğer Gaussian (olasılık yoğunluk) fonksiyonu kullanılıyorsa Gaussian NN, Konik Section fonksiyonu kullanılıyorsa, CSFNN, Fuzzy üyelik (Fuzzy membership) fonksiyonları kullanılıyorsa Fuzy-Neural Networks adı verilir.

### 3. MALZEME VE YÖNTEM

#### 3.1. YAPAY SİNİR AĞLARINDA EĞİTME

YSA belirli bir probleme göre programlanmadığı halde o problemi çözmeyi öğrenebilir. Eğitim ve Öğrenme hemen-hemen bütün sinir (nöral) ağların temelidir. Öğrenme, ağdaki nöronların değiştirilmesi ile değil, nöronlar arasındaki bağlantı ağırlıklarının değiştirilmesi ile sağlanır. Tek bir nöronun çıkışının nasıl belirlendiğini göz önüne alalım. Nöronun transfer fonksiyonunun sabit olması koşulu ile çıkışını yalnızca gelen işaret ve nörona giriş bağlantı ağırlıkları belirler. Nöronun gelen işarete doğru cevap vermesinde ve performansının artırılmasında en önemli eleman bağlantı ağırlıklarıdır.

YSA sinir ağının öğrenme işlemini gerçekleştirebilmesi için, sahip olduğu bütün ağırlıkların, ilgili problemde öğrenilmesi istenen özellikleri genelleştirecek şekilde doğru değerlere sahip olması gerekir. Bu doğruluk ne kadar artarsa ağın sınıflandırma kabiliyeti dolayısıyla öğrenme işlemi o kadar iyi olur. Doğru ağırlık değerleri, bir öğrenme kuralına göre tespit edilirler. Çoğunlukla bağlantılara başlangıç değerleri olarak rastgele ağırlıklar atanır ve bu ağırlıklar eldeki örnekler incelendikçe bir kurala göre değiştirilerek doğru ağırlık değerleri bulunmaya çalışılır. Kısaca belirtmek gerekirse öğrenme kuralları, bir işlem elemanının örnekleri gördükçe kazandığı tecrübeye göre, ilgili bağlantı ağırlıklarını nasıl değiştireceğini belirleyen algoritmalarıdır.

Eğitim ve Öğrenme aynı anlama gelmezler. Eğitim, ağın öğrenmesi için bir işlemdir. Öğrenme ise eğitim işleminin neticesidir. Eğitim ağa dışarıdan etkidir. Öğrenme ise ağın içerisinde geliştirilen bir aktivitesidir. YSA'nın örnekler ile eğitilmesi üç ayrı yol ile gerçekleştirilebilir.

##### 3.1.1. Öğreticili Eğitim ( Supervised Training )

Bu yöntemde, dışarıdan bir eğiticinin sinir ağına müdahalesi söz konusudur. Eğitici, sinir ağının ilgili girdi için üretmesi gereken sonucu sinir ağı sistemine verir. Yani

yapay sinir ağına girdi/çıkıktı ikilisinden oluşan örnekler sunulur. Bu ikili, ağın öğrenmesi gereken özellikleri temsil eder. Ağ girdi kısmını alır ve o anki bağlantı ağırlıklarının temsil ettiği bilgi ile bir çıktı oluşturur. Bu çıktı, olması gereken çıktı ile mukayese edilir ve aradaki hata tekrar ağa aktarılarak ağırlıklar bu hatayı azaltacak şekilde değiştirilirler. Öğreticili eğitimde, elde doğru örnekler vardır. Yani eğitim örneklerinin tamamı için  $(x_1, x_2, \dots, x_n)$  şeklindeki giriş vektörünün;  $(y_1, y_2, \dots, y_n)$  şeklindeki çıkış vektörü, tam ve doğru olarak bilinmektedir. Herbir  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  çifti için, ağ doğru sonuçları verecek şekilde, seçilen bir öğrenme kuralı yardımıyla eğitilir.

### 3.1.2. Skor ile Eğitim (Graded Training)

Öğreticili eğitimin benzeridir. Yukarıdaki yöntemden farkı ise; bu durumda eğiticinin, ağın üretmesi gereken sonuç yerine, onun ürettiği sonucun sadece doğru veya yanlış olduğunu söylemesidir. Yani, bu yöntem giriş işaretine karşılık istenen çıkış işaretleri verilmez. Yerine ağ çıkışının durumuna göre, "başarılısın", "başarısızsın" veya "çok yüksek", "çok düşük" gibi değerlendirmelerle ağ performans seviyesi ile ilgili geri besleme bilgisi verilmez. Ağ giriş işaretine göre kendisini organize eder. Bu yöntem, ilgili örnek için beklenen çıktının oluşturulamadığı durumlarda çok faydalıdır. Özellikle kontrol uygulamaları için idealdir. Çeşitli maliyet (cost) fonksiyonları kullanılır.

### 3.1.3. Kendini Düzenleme ile Eğitim (Self-Organization Training or Unsupervised Training)

Bu yöntemde ağa giriş örnekler verilir ve performans seviyesi ile ilgili geri besleme bilgisi verilmez. Ağ giriş işaretine göre değiştirilmesi esastır. Bu durumda hiçbir eğiticiye ihtiyaç yoktur. Probleme ait veri girişlerine karşın çıkışlar mevcut değildir. Bu yüzden bu tür bir eğitim, giriş verilerini gruplandırarak eğittikten sonra verilen herhangi bir girişin eğitim sınıflarından hangi sınıfa ait olduğunu gösterebilir. Kendini düzenleyen ağ, giriş işaretine göre kendini düzenleyerek organize eder. Bu eğitim tipi olasılık yoğunluk fonksiyonlarına, sınıflandırma ve şekil tanıma problemlerine uygulanabilir.

Ne tür eğitme yöntemi kullanılırsa kullanılsın, herhangi bir ağ için gerekli karakteristik özellik, ağırlıkların verilen eğitme örneğine nasıl ayarlanacağını belirtilerek öğrenme kuralının oluşturulmasıdır. Öğrenme kuralının oluşturulması için bir örneğin ağa defalarca tanıtılması gerekebilir. Öğrenme kuralı ile ilişkili parametreler (öğrenme katsayısı vb.) ağın zaman içinde gelişme kaydetmesiyle değişebilir. Hangi YSA algoritmasında ne tür bir eğitme kullanıldığı bu bölümün giriş işaretlerinin sınıflandırılması kısmında gösterilmiştir.

### 3.2. YAPAY SİNİR AĞLARINDA ÖĞRENME

Bilginin kurallar şeklinde açıklandığı klasik uzman sistemlerin tersine, YSA gösterilen örnekten öğrenerek kendi kurallarını oluşturur. Öğrenme; giriş örneklerine veya (tercihen) bu girişlerin çıkışlarına bağlı olarak ağın bağlantı ağırlıklarını değiştiren veya ayarlayan öğrenme kuralı ile gerçekleştirilir. Ağ, ağırlık bileşendeki değerler değiştirilerek örneklere göre eğitilir ve herhangi bir örnek ile yeniden karşılaştırıldığında uygun cevabı üretir. Öğrenmede iyi bir model kullanıp, ağırlıkların bu modele göre değiştirilmesi esastır. Bu ağırlıkların değiştirilmesi belli bir hata oranına kadar itere edilir. En son ağırlık değerleri test etmede kullanmak için kaydedilir. Öğreticisiz öğrenmede her giriş işareti için istenen çıkış sisteme tanıtılır ve YSA giriş/çıkış ilişkisini gerçekleştirene kadar kademe kademe kendini ayarlar. Günümüzde kullanılan birçok öğrenme kuralı vardır. Bilinen ve en çok kullanılan öğrenme kuralları şunlardır:


- 1- Rastlantısal (Hebb) öğrenme kuralı,
- 2- Performans (Widrow ve *ADALINE*) öğrenme kuralı,
- 3- Kompetitif (Kohonen) öğrenme,
- 4- Filtreleme (Grossberg),
- 5- Spotitemporal öğrenme,
- 6- Genelleştirilmiş delta kuralı öğrenme.

### 3.2.1. İdrak (Perceptron)


Perceptron (idrak-algılayıcı) ağı, ilk defa 1943 yılında Mc Culloch ve Pitts tarafından ortaya atılmıştır. Şekil 3.1-a'da tek katmanlı perceptronun yapısı görülmektedir.

$$\sum_{j=1}^n w_j x_j - \theta = 0 \quad ; \text{ n boyutlu uzayda, n-1 boyutlu bir düzlem belirler.}$$

Ağın ürettiği çıkış istenen çıkıştan farklı ise, hata azaltılacak yönde hareket edilmektedir. Hata sıfır olduğunda w değişimi durmaktadır. Bu basit ağ, ilk defa geliştirildiğinde basit örüntüleri öğrenme kabiliyetlerinden ötürü oldukça ilgi toplamıştır.



Şekil 3.1: (a) Tek katmanlı perceptron yapısı, (b) Bir analog giriş vektörünü A ve B ile gösterilen iki sınıfa ayıran tek katmanlı bir perceptron




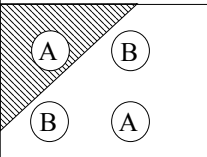
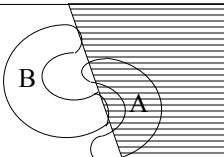
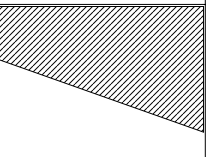

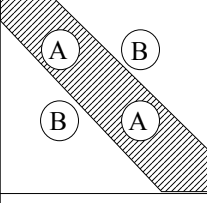
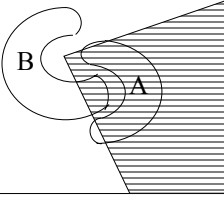
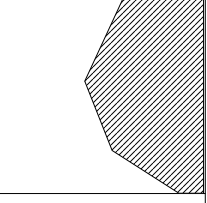

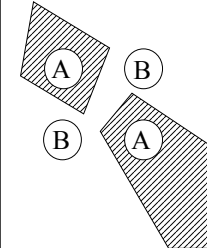
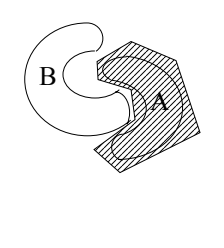
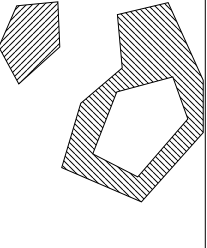
Şekil 3.2: Lineer ayrılabirliğin gösterimi

Şekil 3.1-b'de bir girişin iki sınıftan (A veya B) hangisine ait olduğuna karar veren bir perceptron görülmektedir. Bir tek düğüm giriş elemanlarının ağırlıklı toplamını hesaplar, bir eşik  $\theta$ 'yı çıkarır ve  $y'$  çıkışı +1 veya -1 olacak şekilde sonucu bir süreksizlikten geçirir. Karar verme kuralı ise; çıkış +1 ise A sınıfı ile, -1 ise B sınıfı ile gösterilir. Yani bu ilk perceptron modeli, giriş bilgisinin mevcut iki sınıftan hangisine eşit olabileceğini bulacak şekilde eğitilen basit bir ağıdır. Daha sonra 1960 yıllarında F. Rosenblatt yukarıdaki ağ tipini biraz daha geliştirmiştir. Fakat, Minsky ve Papert, bu tek katmanlı perceptronun XOR işlemini gerçekleştiremediğini ispatlamışlardır. Şekil 3.1 ve 3.2'den anlaşılacağı gibi 0'ların bir tarafta, 1'lerin bir tarafta ayrılacağı şekilde bir bölge oluşmamaktadır. XOR gibi 3 veya daha fazla sınıfa ihtiyaç duyulan problemleri çözmek için yapılması gereken işlem ise YSA ya yeni katmanlar eklemektir. Eşik bağlarıyla oluşturulan karar bölgesi şeklinin karmaşıklığı, sadece eklenmiş olan katmanların sayısı ile sınırlıdır. Şekil 3.3'de gösterildiği gibi içbükey ayrılabilir fonksiyonlar gerçekleştirilebilir [13].

Şekil 3.3'de tek ve çok katmanlı perceptronların sınırlayabileceği (ayırabileceği) karar bölgeleri görülmektedir (Lippmann 1987). Taranmış bölgeler A sınıfına ait karar bölgelerini göstermektedir. Tek katmanlı perceptron, bir düzlemi ikiye ayıran karar bölgeleri oluşturur. İki katmanlı bir perceptron, açık ve kapalı konveks bölgeler oluşturabilir. Üç katmanlı perceptron ise, keyfi derecelerde kompleks karar bölgelerini ayırabilir. Buradan anlaşılmaktadır ki; perceptron gibi ileri yayımlı ağlarda, iki adet gizli katmandan fazlasına gerek yoktur.

Üç katmanlı perceptronlarda (giriş katmanı dahil değil) kullanılacak düğüm sayılarının belirlenmesine gelince; karar bölgeleri arasında bağlantı yoksa veya bu bölgeler bir konveks alan ile oluşturulamıyorsa, ikinci katmandaki düğüm sayısı bir'den büyük olmalıdır. En kompleks durum için, ikinci katmandaki düğümlerin sayısı, giriş dağılımlarındaki ayrı bölgelerin sayısı kadar olmalıdır [26]. Benzer şekilde birinci katmandaki düğüm sayıları da herbir ikinci katman düğümünce oluşturulan herbir konveks bölge için üç veya daha fazla kenar sağlanacak şekilde yeterli sayıda olmalıdır. Bununla beraber, Gutierrez ve arkadaşları, değişik perceptron ağlarının ihtiyacı olan düğüm sayıları hakkında araştırma yapmışlar ve

çok fazla düğümün de, çok az sayıda olduğu gibi zararlı etkisi olduğunu bulmuşlardır [17] Tek katmanlı perceptron uygulanan her eğitim seti modelinin en önemli özelliği, lineer biçimde dağılmak zorunda olmasıdır. Eğer bu doğrudur; Rosenblatt, perceptron ağının kararlı olacağını göstermiştir (Örneğin ağırlıklar iterasyonla yakınsar).

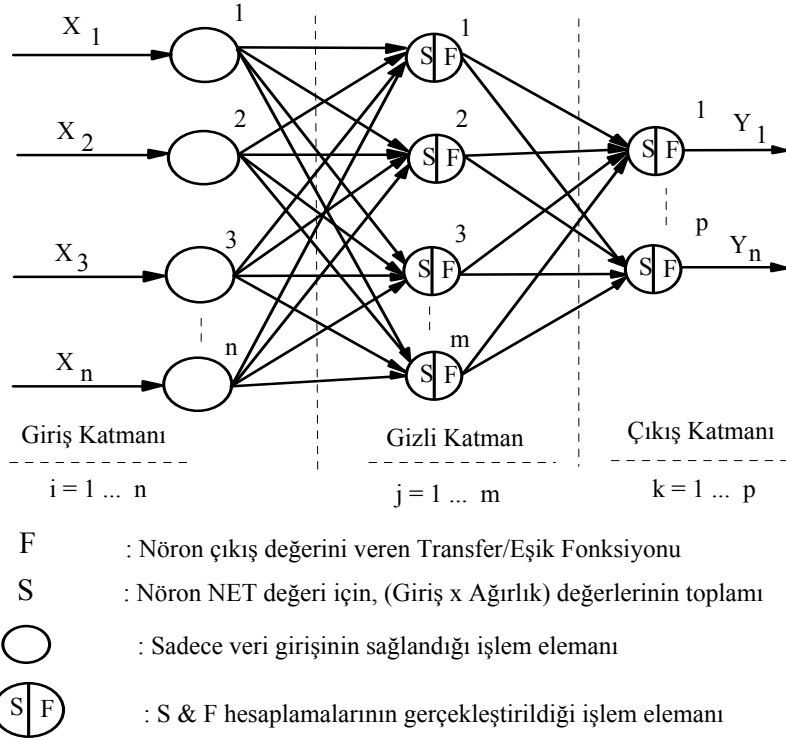
Yapı	Karar bölgeleri tipi	XOR problemi	Bölgelere dayalı sınıflar	En iyi ayırdığı bölge şekilleri
Tek katman  (a)	Doğrusal ayrıştırabilir, XOR işlevini gerçekleyemez			
İki katman  (b)	Rastgele bölgeler Konveks açık veya kapalı bölgeler			
Üç katman  (c)	Komplekslik derecesi düğüm sayısına bağlı olarak sınırlıdır			

Şekil 3.3: Tek katmanlı perceptron ile iki ve üç katmanlı bulunan çok katmanlı perceptronların sınırlayabileceği karar bölgeleri

### 3.2.2. Çok katmanlı idrak (Multi-Layer Perceptron)

Çok katmanlı Perceptron (idrak-algılayıcı) giriş ve çıkış katmanları arasında birden fazla katmanın kullanıldığı ileri yayımlı (feed-forward) YSA sistemidir. Gizli katman (hidden layer) olarak isimlendirilen bu ara katmanlarda, düğümleri giriş ve çıkış katmanlarına doğrudan bağlı olmayan işlem elemanları vardır. Şekil 3.4'de çok katmanlı perceptronun genel yapısı verilmiştir. Çok katmanlı perceptronlar, tek katmanlı perceptronlara ait sınırlamaların birçoğunu ortadan kaldırmalarına rağmen, önceleri etkin eğitime algoritmalarının mevcut olmamasından ötürü uygulamaları yaygın değildi. Ancak yeni eğitime algoritmalarının geliştirilmesi ile bu durum değişmiştir.






Şekil 3.4: (n:m:p) mimarisine sahip bir çok katmanlı perceptronun yapısı

Çok katmanlı ağlarda, veriler giriş katmanı tarafından kabul edilirler. Ağ içinde yapılan işlemler sonucunda çıkış katmanında oluşan sonuç değer, istenen cevap ile karşılaştırılır. Bulunan cevap ile istenen cevap arasında herhangi bir ayrılık varsa, ağırlıklar bu farkı azaltacak şekilde yeniden düzenlenir. Girişteki değer, ağırlıklar uygun noktaya ulaşana kadar değişmez. Hesaplanan çıkışlar, istenilen cevaplarla karşılaştırılarak sonuçta gerekirse hata belirtilir. Hata işareti gizli işlem elemanlarından çıkış birimine olan ağırlıkları değiştirmekte kullanılır. Ama bunu yaparken giriş katmanından gizli katmana gelenin değiştirilip değiştirilemediğini düşünmek gerekir. Gizli birimlerden ne tür bir çıkış istendiği bilinmeyeceği için gizli birimlerin çıkışında hata işareti verilmesi kolay bir şey değildir. Bunun yerine her birimin çıkış biriminin hatalarına olan etkisi bilinmelidir. Bu ise hatalı birim için gizli birime bağlı olan çıkış birimlerinin hata işaretlerinin toplamı alınarak yapılır.

Çok sayıda gizli katmana sahip sistemlerde, her sistemin hata işaretleri, bir önceki katmanın düzeltilmiş işlemlerinden çıkartılarak işlem tekrarlanır. Sonuç olarak, ağırlık düzeltme işlemi çıkış seviyesine bağlı ağırlıklardan başlar ve işlem ters yönde, giriş seviyesine varana kadar devam eder. Sonuçta sistem hatalar yapar, ama bu hatalardan birşeyler öğrenip isteneni bulana kadar işleme devam eder. Bu yöntemle “hatanın geriye yayılması algoritması” (back-propagation algorithm) denilir[24].

### 3.2.3 Hatanın Geriye Yayılması Algoritması ve Genelleştirilmiş Delta Kuralı

Hatanın geriye yayılması eğitime algoritması, çok katmanlı, ileri yayımlı bir perceptrondan elde edilen çıkışlar ile elde edilen hedef çıkışlar arasındaki hataların karesinin ortalamasını minimum yapmak için geliştirilmiş iteratif bir gradyan algoritmasıdır ve eğitime işlemi için genelleştirilmiş delta kuralını (Generalized Delta Rule) kullanır (Şekil 3.5).



Şekil 3.5: Hatanın geriye yayılması algoritmasının blok diyagramı

Şekil 3.5’de blok diyagramı gösterilen algoritma, ana hatlarıyla şöyledir : Ağ mimarisi tanımlanır ve ağırlıklar bazı rastgele küçük sayılar ile başlatılarak, ağa ilk giriş sunulur. Burada m-boyutlu giriş örüntüleri girildiğinde;  $x_1 = [x_1, x_2, \dots, x_m]^T$  dir. Benzer şekilde istenilen n-boyutlu çıkış örüntülerini ise;  $d_k = [d_1, d_2, \dots, d_n]^T$  belirtir.  $x_i$  değerleri i katmanındaki nöronların çıkış değerleri ise, j katmanındaki bir nörona gelecek olan toplam giriş,

$$\text{net}_j = \sum_{i=1}^m w_{ji} \cdot x_i \quad (\text{i. düğümden j. düğüme}) \quad (3.1)$$

olur. Gizli katmandaki j nöronunun çıkışı (transfer fonksiyonu çıkışı);

$$y_j = f_j(\text{net}_j) \quad , \quad j=1,2,\dots,J \quad (3.2)$$

dir ve burada  $f_j$  transfer fonksiyonudur. Çıkış katmanındaki  $k$  nöronuna gelecek olan toplam giriş ise,

$$\text{net}_k = \sum_{j=1}^J w_{kj} \cdot y_j \quad (3.3)$$

dir. Yine çıkış katmanındaki bir  $k$  nöronun lineer olmayan çıkışı;

$$o_k = f_k(\text{net}_k), \quad k = 1, 2, \dots, n \quad \text{olur.} \quad (3.4)$$

Ağdan elde edilen çıkış, asıl çıkış ile karşılaştırılır ve  $e_k$  hatası aşağıdaki gibi hesaplanır;


$$e_k = (d_k - o_k) \quad (3.5)$$

Burada  $d_k$  ve  $o_k$  sırasıyla çıkış katmanındaki herhangi bir  $k$  nöronunun hedef (istenen) ve ağdan elde edilen (asıl) çıkışlardır. Dikkat edilmesi gereken husus, böyle bir karşılaştırmanın sadece ağın çıkış katmanı için mümkün olmasıdır. Böylece çıkış katmanıyla olan bağlar için ağırlık ayarlaması öncelikle gözönüne alınır. Herbir örüntü (pattern) için toplam karesel hata;


$$E = \frac{1}{2} \sum_k (d_k - o_k)^2 \quad (3.6)$$

olur. Hata fonksiyonu Şekil 3.6 ve Şekil 3.7'de gösterildiği gibidir. Gizli katman olduğu zaman; hata düzeyi Şekil 3.6'da olduğu gibi sadece bir minimumdan oluşmaz, Şekil 3.7'deki gibi çeşitli minimumlar oluşur. Bu minimumlar lokal ve global olarak sınıflandırılırlar. Lokal minimumlar birden fazla olabilir. Global minimum, hatanın en küçük olduğu minimumdur. Öğrenme sırasında global minimuma ulaşmak amaçlanır. Ağırlıkların değişimi;

$$\Delta w_{kj} = -\varepsilon \frac{\partial E}{\partial w_{kj}} \quad (3.7)$$



Şekil 3.6: Gizli katmanı olmayan ağın hata fonksiyonu



Şekil 3.7: i Katmana ait ağırlığın hata fonksiyonu

Burada  $\varepsilon$ , öğrenme oranı katsayısı adı verilen küçük değerde pozitif bir sayıdır (çoğunlukla 0.01 ile 0.9 arasında seçilir). Bu öğrenme oranı, bir sayısal optimizasyon algoritmasındaki adım boyutu parametresine benzemektedir. (3.7)'de eşitliğin sağ tarafı açılırsa (Rumelhart ve ark.1986), şu sonuç elde edilir:

$$\frac{\partial E}{\partial w_{kj}} = \frac{\partial E}{\partial net_k} \frac{\partial net_k}{\partial w_{kj}} \quad (3.8)$$

$$\frac{\partial net_k}{\partial w_{kj}} = \frac{\partial}{\partial w_{kj}} \sum_j w_{kj} \cdot y_j = \sum_j \frac{\partial w_{kj} \cdot y_j}{\partial w_{kj}} = y_j \quad (3.9)$$

Amaç, uygun  $w$  seçimiyle,  $E = \sum_p E_p$  toplam hatayı yeterince küçük yapmaktır. Bu amacı gerçekleştirmek için, bir  $p \in P$  örüntüsü ard arda ve rastgele biçimde seçilir.  $k$ . nöronda oluşan ve "delta" adı verilen hata işareti,

$$\delta_o = -\frac{\partial E}{\partial net_k} \quad (3.10)$$

(3.9) ve (3.10)'yi (3.8)'de yerine konulursa,

$$\frac{\partial E}{\partial w_{kj}} = -\delta_o \cdot y_j \quad (3.11)$$

ve, (3.11) ifadesi (3.7)'de yerine konulursa,

$$\Delta w_{kj} = \varepsilon \delta_o y_j \quad (3.12)$$

elde edilir.  $E_p$  değerini düşürmek demek, ağırlığı  $\delta_o y_j$  'ye bağlı olarak değiştirmek demektir. Buna "Delta kuralı" denir. Önceki gizli katmandaki tüm nöronlar ile çıkış katmanındaki  $k$ . nöron arasındaki bağ mukavemetleri, (3.12)'deki  $\Delta w_{kj}$  miktarı ile ayarlanır. (3.10) denklemi kısmi türevlerine ayrılırsa,

$$\delta_o = -\frac{\partial E}{\partial \text{net}_k} = -\frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial \text{net}_k} \quad (3.13)$$

$$\frac{\partial E}{\partial o_k} = -(d_k - o_k) \quad (3.14)$$

olup; k. nöron çıkışının lokal hatasını verir.

$$\frac{\partial o_k}{\partial \text{net}_k} = f'_k(\text{net}_k) \quad (3.15)$$

Son iki formül (3.13)'de yerine konulursa,

$$\delta_o = (d_k - o_k) f'_k(\text{net}_k) \quad (3.16)$$

bulunur. Bu son terim (3.12)'de yerine konulduğunda k nöronu için;

$$\Delta w_{kj} = \varepsilon (d_k - o_k) f'_k(\text{net}_k) y_j \quad (3.17)$$

olur. Eğer ağırlıklar çıkış nöronlarını doğrudan etkilemiyorsa (arada gizli katman varsa), (3.12)'e benzer biçimde delta kuralı bu gizli katman için de şu şekilde uygulanır.

$$\begin{aligned} \Delta w_{ji} &= -\varepsilon \frac{\partial E}{\partial w_{ji}} \\ &= -\varepsilon \frac{\partial E}{\partial \text{net}_j} \frac{\partial \text{net}_j}{\partial w_{ji}} = -\varepsilon \frac{\partial E}{\partial \text{net}_j} x_i \end{aligned} \quad (3.18)$$

$$= -\varepsilon \left( -\frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial \text{net}_j} \right) x_i = \varepsilon \left( \frac{\partial E}{\partial y_j} \right) f'_j(\text{net}_j) x_i$$

$$\Delta w_{ji} = \varepsilon \delta_y x_i \quad (3.19)$$

Bununla birlikte,  $\partial E / \partial y_j$  faktörü doğrudan geliştirilemez. Özel olarak çıkış katmanına etkisi,

$$-\frac{\partial \mathcal{E}}{\partial y_j} = -\sum_k \frac{\partial \mathcal{E}}{\partial \text{net}_k} \frac{\partial \text{net}_k}{\partial y_j} = \sum_k \left( -\frac{\partial \mathcal{E}}{\partial \text{net}_k} \right) \frac{\partial}{\partial y_j} \sum_m w_{km} y_j = \sum_k \left( -\frac{\partial \mathcal{E}}{\partial \text{net}_k} \right) w_{kj} = \sum_k \delta_o w_{kj}$$

şeklinde bulunur. Bu durumda;

$$\delta_y = f'_j(\text{net}_j) \sum_k \delta_o w_{kj} \quad (3.20)$$

olur. Kısaca özetlenecek olursa; (3.19) formülü şayet j. nöron, çıkış katmanı nöronuysa (3.16)'e benzer biçimde,

$$\delta_y = (d_y - o_y) f'_j(\text{net}_j) \quad (3.21)$$

olur. Eğer j nöronları gizli katmana ait nöronlar ise, o zaman (3.21) denklemi kullanılır. Transfer (eşik) fonksiyonu olarak sigmoid fonksiyonu kullanıldığında,

$$f(\text{net}_j) = y_j = \frac{1}{1 + e^{-\text{net}_j}} \quad (3.22)$$

olur. Bu ifadenin türevi alınıp, gerekli sadeleştirme yapıldığında,

$$f'(\text{net}_j) = \frac{1}{1 + e^{-\text{net}_j}} \frac{1 + e^{-\text{net}_j} - 1}{1 + e^{-\text{net}_j}} \quad (3.23)$$

$$\frac{\partial y_j}{\partial \text{net}_j} = y_j(1 - y_j) \quad (3.24)$$

bulunur. Benzer işlem k katmanı için de yapılırsa;

$$\frac{\partial o_k}{\partial \text{net}_k} = f'_k(\text{net}_k) = o_k(1 - o_k) \quad (3.25)$$

elde edilir. (3.25) denklemi (3.16)'da, (3.24) denklemi de (3.20)'da yerine konursa, (3.16) ve (3.20)'daki delta ifadeleri aşağıdaki gibi olur. ( $\delta_o$  çıkış katmanı,  $\delta_y$  gizli katman elemanları içindir);

$$\delta_o = (d_k - o_k) o_k(1 - o_k) \quad (3.26)$$

$$\delta_y = y_j(1 - y_j) \sum_k \delta_o w_{kj} \quad (3.27)$$

$w_{ji}$  yi öğrenme durumunda her eğitime örüntüsünün seti için  $\Delta w_{ij}$  yi hesaplamak gerekir. Öğrenme oranı  $\varepsilon$ , hızlı öğrenmeyi sağlar; fakat dalgalanmalara sebep olabilir.

Rumelhart ve McClelland (1986), (3.17) ve (3.19) ifadelerine bir tür momentum terimi dahil ederek bir deęişim öngörmüşlerdir. Bu durumda;

$$\Delta w_{ji}(n+1) = \varepsilon \delta_y x_i + \alpha \Delta w_{ji}(n) \quad (3.28)$$

$$\Delta w_{kj}(n+1) = \varepsilon \delta_o y_j + \alpha \Delta w_{kj}(n) \quad (3.29)$$

olarak yazılabilir. Burada n, öğrenme döngülerinin (iterasyon) sayısını gösterir. Momentum terimi olan  $\alpha$ , küçük deęerde pozitif bir sayıdır.

### 3.2.4. Öğrenme ve Momentum Katsayıları

YSA ile ilgili bir başka sorun da, düzgün bir öğrenme katsayısının ( $\varepsilon$ ) ayarlanmasıdır. Ağırlıkları çok yüksek tutmak davranışın bozulmasına sebep olabilir. Öğrenme katsayısını böyle bir davranışı önlemek için küçük tutmak gereklidir. Öğrenme katsayısı,  $0.01 < \varepsilon < 10$  aralığında seçilen sabit bir sayıdır. Öte yandan, çok küçük bir öğrenme oranında, öğrenme işleminin yavaşlamasına yolaçar.

Momentum ( $\alpha$ ) fikri bu noktadan hareketle ortaya atılmıştır. Momentum mevcut delta ağırlığı üzerinden önceki delta ağırlığının belirli bir kısmını besler. Böylece daha düşük öğrenme katsayısı ile daha hızlı öğrenme elde edilir. Momentum katsayısı genellikle  $0 < \alpha < 1$  aralığında deęişen bir sayıdır.

Hatanın geriye yayılması algoritması genellikle iyi bir performans göstermesine rağmen; bu algoritma, bir gradyent arama teknięi olduęu için, global minimum yerine, en küçük kareler (Least Mean Square) fonksiyonunun bir lokal minimumunu bulabilmektedir. Performansı artırmak ve lokal minimum problemini azaltmak için; gizli düğümler ilave edilmesi, ağırlıkların ayarlanması için kullanılan öğrenme katsayısının azaltılması ve farklı rastgele ağırlık setlerinden başlayarak birçok defa eğitim işleminin tekrarlanması öneriler arasındadır (Lippmann 1987).

## 4. BULGULAR

### 4.1 NESNE TANIMA

Nesne tanıma; aralarında ortak özellik bulunan ve aralarında bir ilişki kurulabilen şekilleri veya nesnelere bazı tesbit edilmiş özellikler veya karakterler vasıtası ile tanımlama veya sınıflandırma olayıdır. Ortak özelliklere sahip nesne ve cisimlerin oluşturduğu topluluğa nesne sınıfları ismi verilir. Nesne tanımanın en önemli iki amacı;

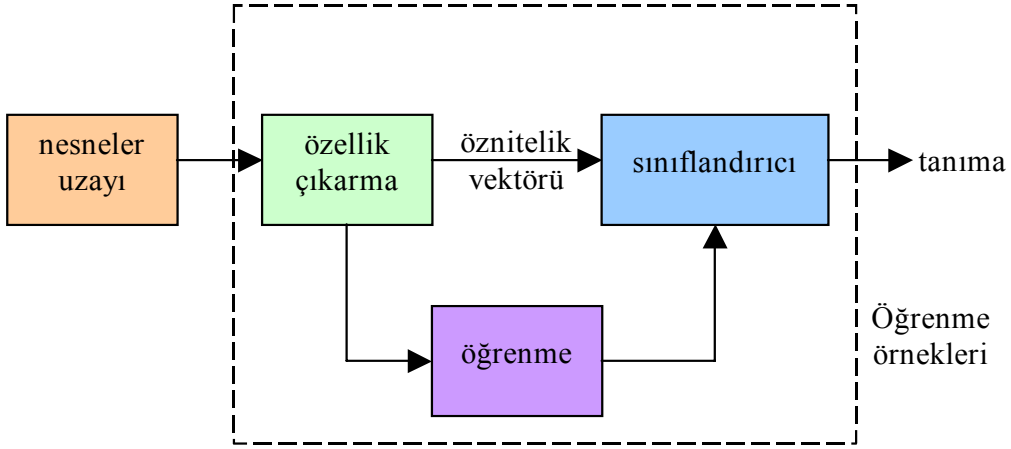
- Bilinmeyen nesne sınıflarına belirli bir şekil vermek,
- Bilinen bir sınıfa ait olan nesneyi teşhis etmektir.

Nesne tanıma sistemleri genellikle iki kısımdan oluşur; birinci kısım, nesnelerin tanınması için gerekli özelliklerin veya ölçülecek büyüklüklerin seçilmesi işlemini gerçekleştirir. Bu işleme, özellik çıkarma (feature extraction) ve bu işlemi gerçekleştiren sisteme, özellik çıkarıcı (feature extractor) adı verilmektedir[27]. Şekil veya nesnelere belirlemede kullanılan her bir özelliğin veya ölçülecek büyüklüğün, ölçüm sonucunu veren gerçel sayıya özellik adı verilmekte ve bileşenleri bu özelliklerden oluşmuş vektöre, özelliklerin alındığı nesneye ilişkin öznitelik vektörü denilmektedir. Pratikte uygun özellik seçimi, bir nesne tanıma probleminin en güç ve en önemli bölümünü oluşturur. Eğer seçilen özellikler nesnelerin bütün özelliklerini tam olarak taşıyamıyorsa, tanıma ve sınıflandırma işlemlerinde yapılacak hatalar büyük olacaktır [28]. Nesne tanımanın ikinci kısmı ise, elde edilen öznitelik vektörlerinden faydalanarak nesnelerin sınıflandırılmasıdır. Bir nesne tanıma sisteminin blok diyagramı Şekil 4.1'de verilmiştir.

Nesne sınıflandırma işlemi, öznitelik vektörlerinden oluşmuş uzayın her bölümü bir nesne sınıfına karşı düşecek şekilde, birbirlerinden ayırık bölümlere ayrılması ve her bölüme ilişkin bir doğrusal ayırım fonksiyonu tanımlanması temeline dayanır. Nesne tanıma modellerinde, nesne sınıflarını ayıran ayırım fonksiyonlarının matematiksel biçimlerinin bilinmemesi durumunda, önce bir öğrenme işleminin gerçekleştirilmesi gerekir. Öğrenme işlemi, bu ayırım fonksiyonlarının bilinmeyen gerçek değerlerinin,



nesne sınıflarının herbirinden alınan örnek nesnelere yardımıyla belirlenmesi ya da öğrenilmesini sağlar.



Şekil 4.1: Nesne tanıma sisteminin blok diyagramı


Nesne tanıma için yeni bir yaklaşım olan yapay sinir ağları, olayları öğrenerek karar verme prensibi üzerine kurulduğundan, yapay sinir ağları ile nesne tanıma klasik nesne tanıma modellerine göre daha başarılı sonuçlar verir. Bu başarı, özellikle bu ağ yapılarının programlama yerine verilmiş bir öğrenme kümesi üzerinden öğrenilebilmesi sayesinde. Ama bilinmelidir ki, yapay sinir ağının herhangi bir uygulamada kolayca çok başarılı olabilmesi söz konusu değildir; herhangi bir yöntem gibi değişik durumlarda verilmesi gereken kararlar ve bunların getirdiği üstünlük ve kısıtlamalar vardır [29-30].

## 4.2. UYGULAMA ÖRNEKLERİ


Bu çalışmada tümör tanıma işlemi şu dört aşamadan oluşmaktadır:

- Birinci aşama tümör görüntülerinin elde edilmesi ve bu görüntülerin öznitelik vektörü oluşturmak için uygun bitmap formata dönüştürülmesi aşaması,
- İkincisi oluşturulan görüntülerden test datalarının oluşturulması ve öznitelik vektörünün hazırlanması aşaması,
- Üçüncüsü elde edilen öznitelik vektörü kullanılarak yapay sinir ağının eğitimi,
- Dördüncüsü aşama ise, sisteme verilecek düzgün test datalarından tanıma işleminin yapılmasıdır.


Çalışma için ihtiyaç duyulan tümör görüntüleri, manyetik rezonans görüntüleme (MRI) tıbbi cihazı vasıtasıyla elde edilmiştir. Tümör görüntüleri 8x8 pixel büyüklüğünde bitmap formatında alınmıştır. Daha sonra bu bitmap formatındaki görüntüler “Adobe Photoshop” kullanılarak 8 bit gri-ton bitmap formatına dönüştürülmüş ve sırasıyla; image\_tip01.bmp, image\_tip02.bmp, image\_tip03.bmp,..., image\_tip10.bmp şeklinde sayısallaştırılarak hafızaya alınmıştır. Toplam 10 değişik tümör görüntüsü eğitime için kullanılmıştır (Şekil 4.2-11). Ayrıca yine 10 değişik tümör için test verisi de oluşturulmuştur.




Şekil 4.2: Birinci tip beyin tümörü




Şekil 4.3: İkinci tip beyin tümörü




Şekil 4.4: Üçüncü tip beyin tümörü




Şekil 4.5: Dördüncü tip beyin tümörü




Şekil 4.6: Beşinci tip beyin tümörü




Şekil 4.7: Altıncı tip beyin tümörü




Şekil 4.8: Yedinci tip beyin tümörü



Şekil 4.9: Sekizinci tip beyin tümörü



Şekil 4.10: Dokuzuncu tip beyin tümörü




Şekil 4.11: Onuncu tip beyin tümörü

Öznitelik vektörünün oluşturulmasında ilk adım, tümör resimlerinin tek tek matris içine okunmasıdır. Bitmap.h içinde yer alan open\_Image fonksiyonu yardımıyla her bir tümör görüntüsünün başlık kısmının okunması ile kütük okuma işlemi gerçekleştirilir.

Yapay sinir ağının giriş katmanı için 8 girdi oluşturmak için mevcut 256x256 piksellik matrisi 8x8 matris oluşturacak şekilde segmentlere (bölgelere) ayırarak her bir segmentin ( $-X/256$  değeri  $Y/256$ 'lık matrisin) gri seviyeleri değerlerinin ortalamasını almamız ve bu değerleri bir \*.dat uzantılı dosyaya yazdırmamız gerekir. Öznitelik vektörü fonksiyonu için; her bir  $X/256 \times Y/256$  piksel büyüklüğündeki segmentleri alıp piksellerin renk değerlerini toplamak 8'e bölerek segmentin renk değeri ortalamasını bulmak gerekir. Bu değer daha sonra eşik değeri olan 256'ya bölünerek 0 ile 1 arasında bir giriş değeri bulunur [30-31].

Şekil 4.12'de görüleceği gibi kullanılan yapay sinir ağının yapısı için; her bir görüntü için 8 giriş olduğundan giriş katmanındaki nöron sayısı (8), çıkış katmanında toplam tanımlanacak görüntü sayısı kadar (10) nöron seçilmiştir.



Şekil 4.12: Uygulamadaki çok katmanlı yapay sinir ağı

Gizli katmandaki nöron sayısını belirlemede değişik sayılarla denemeler yapılmış en uygun değer olarak 10 bulunmuştur. Zaten, önceki çalışmalarda, çıkacak olan değer giriş ile çıkış katmanlarındaki nöron sayılarından büyük olanına eşit veya ondan büyük seçildiğinde başarılı sonuçlar alınabildiği görülmüştür [31]. Böylece yapay sinir ağı giriş, gizli ve çıkış olmak üzere 3 katmandan meydana gelmektedir.

Sunulan YSA yapısını eğitmek için; iyi bilinen Hatanın Geriye Yayılması Algoritması (Back-Propagation Algorithm) ve Genelleştirilmiş Delta Kuralı kullanılarak tümör görüntülerinin tanınmasına yönelik yazılım gerçekleştirilmiştir.



## 5. TARTIŞMA VE SONUÇ

### 5.1. SONUÇLAR

Hastaneden alınan 10 değişik tümör görüntüsü ilk etapta sayısallaştırılarak, bu değerler sınıflandırıcıya giriş olarak uygulanmıştır. Burada sınıflandırıcı yöntemi olarak literatürde en çok rastlanılan yapay sinir ağları yöntemlerinden biri olan Hatanın Geriye Yayılımı algoritması seçilmiştir. Bu algorithmada 8:10:10 şeklinde üç katmanlı idrak (perceptron) yapısı tercih edilmiştir. Burada, ilk değer olan (8); giriş katmanındaki nöron sayısını, ikinci değer (10) değeri ise saklı katmandaki nöron sayısını, son değer (10) ise, tanınması istenen on değişik tümörü belirtir. Kullanılan Yapay Sinir Ağı programı, Delphi altında Pascal Yüksek seviyeli dil ile yazılmıştır. Aşağıda Şekil 5.1’de programa ait form gözükmektedir.

Training Data

Load File

Reset Network

Iteration Count

Learning Rate

Train Network

25000

0,95

Test Network

Iteration : 24999, Total Square : 6,8509219

Tip\_1

Tip\_2

Tip\_3

Tip\_4

Tip\_5

Tip\_6

Tip\_7

Tip\_8

Tip\_9

Tip\_10

Input Count : 8

Şekil 5.1 : Kullanılan YSA programının eğitim formu


Şekil 5.1'den de görüleceği gibi, 25000 iterasyon sonucu yapılan test aşamasında ikinci tümöre ait tomografi görüntüsü yüzde yüz oranında tanınmıştır. Program değişik öğrenme oranı verilerek sınanmış ve bunun sonucunda en iyi öğrenme oranı olarak 0.95 değeri bulunmuştur. 25.000 iterasyon sonucu elde edilen toplam karasel ortalama hata (Mean Square Error-MSE) yaklaşık olarak % 6,85 bulunmuştur. Bu sonuç, tanıma oranının yaklaşık olarak ortalama % 93,15 olduğunu gösterir.

Şekil 5.2'de ise ağın test etme aşamasında seçilen 10 değişik test verisi için test sonucunu gerçek zamanda tanınması söz konusudur. Test için verilen üçüncü tip tümör verisi, elde edilen tanılama sonucu renkli olarak belirlenmektedir. Şekilden de görüleceği gibi burada tanıma oranı % 98 olmuştur.

Training Data	Load File	Reset Network	Iteration Count	Learning Rate	Train Network
0,000 0,098 0,114 0,192 0,208 0,173 0,200 0,00E			25000	0,95	Test Network
0,027 0,325 0,365 0,443 0,424 0,435 0,467 0,039					
0,118 0,451 0,447 0,576 0,565 0,518 0,678 0,180					
0,286 0,620 0,459 0,604 0,557 0,537 0,718 0,353					
0,424 0,506 0,541 0,639 0,627 0,596 0,522 0,459					
0,451 0,549 0,800 0,596 0,624 0,831 0,608 0,525					
0,298 0,608 0,620 0,549 0,561 0,588 0,627 0,290					
0,004 0,220 0,459 0,498 0,498 0,443 0,251 0,000					
<b>Iteration : 24999, Total Square : 6,8509219</b>					
Tip_1					0,00
Tip_2					0,00
Tip_3					0,98
Tip_4					0,02
Tip_5					0,00
Tip_6					0,00
Tip_7					0,00
Tip_8					0,00
Tip_9					0,00
Tip_10					0,00
Input Count : 8					

Şekil 5.2: Kullanılan YSA programına ait test formu

Doğal olarak, iterasyon arttıkça hatanın düştüğü gözlenmiştir. Her 5000 iterasyonda programın gösterdiği hata (MSE) oranlarının grafiği aşağıda Şekil 5.3’de verilmiştir. Şekilden de görüleceği gibi 25000 iterasyondan sonra toplam hata daha düşük seviyeye inmemekte, sinir ağı kararlı hale gelmektedir.



Şekil 5.3: İterasyona bağlı hata analizi

## 5.2. TARTIŞMA

Bu çalışmada, yapay sinir ağı modelleri ve tomografik görüntülere dayalı tıbbi tanılama amaçlandı. Bir cismin, üzerine birçok farklı yönden ışın göndererek cisimden geçen veya yansıyan ışınlar göre alan-kesit izdüşümlerinden faydalanarak görüntüsünün elde edilmesi yöntemiyle yapılan tomografik görüntüleri sınıflamada akıllı sistemlerden biri olan yapay sinir ağlarında kullanılmaya başlanmıştır. Bu şekilde yapay sinir ağları eğitilerek tomografi görüntüleri, günümüzde kullanılan metotlara göre daha verimli ve daha hassas bir şekilde tespit edilmektedir. Bu da tıp alanında uzmanlara hastalığın teşhis ve tedavisinde çok büyük kolaylıklar sağlamaktadır; gelecekte daha da geliştirilerek daha erken teşhis ve daha sağlıklı tedavi yöntemleri ortaya çıkacaktır.

Beyin tomografilerinin görüntülenmesinde kullanılan yapay sinir ağları, sadece tıp alanında değil; endüstri mühendisliği, kontrol mühendisliği, çevre mühendisliği, elektronik mühendisliği, haberleşme mühendisliği gibi çok geniş bir yelpazeye sahip bir alanda kullanılmaktadır. Yapay sinir ağları algoritmaları eğitilerek; örneğin savunma sanayiinde; silahların otomasyonu ve hedef izleme, nesnelere/görüntüleri ayırma ve tanıma, haberleşmede; görüntü ve veri sıkıştırma, otomatik bilgi sunma

servisleri, konuşmaların gerçek zamanda çevirisi, çevresel olarak; numuneleri analiz etme, hava tahmini, finans alanında; kredi riski değerlendirilmesi, sahte para ve evrak tanıma, elyazısı formlarının değerlendirilmesi ve askeri alanda; radar sinyallerini anlama, yeni ve gelişmiş silahlar yaratma, keşif yapma, kıt kaynakların kullanımını optimize etme, hedef tanıma, izleme ve daha birçok alanda farklı uygulamaları vardır. Ayrıca, bu çalışma, uygun algoritmalar geliştirilerek uçak radar ara kesitlerinin belirlenmesinde kullanılarak, bu şekilde Hava Kuvvetleri'ne çok önemli katkılar sağlayabilir.

Bu tez çalışmasında, kullanılan yapay sinir ağı programı farklı biyomedikal tıbbi tanılama problemleri için de uyarlanabilir.

**KAYNAKLAR**

1. Simon, H.A.,1983, *Why should machine learn. Machine Learning*, RS Michalski, JG Garbonell (ed.) Morgan Kaufmann Publishing. ISBN: 0-201-50932-6
2. Culloch, W.S. and Pitts, W.H. 1943, A logical calculus of the ideas immanent in neural nets. *Bull. Math.Biophys.* 5:115-133.
3. Hebb, D.O. 1949, *The Organization of Behaviour*, John Wiley Sons, New York.
4. Rosenblatt, F. 1959, *Principles of Neuradynamics*, Spartan Books, New York.
5. Widrow, B. and Hoff, M. 1960. Adaptive switching circuits. *IRE WESCON Convention Record* 4:96-104.
6. Hopfield, J.J.1982. Neural networks and physical systems with emergent collective computational abilities. *Proc.Nat.Acad.Sci* 79:2554-2558.
7. Kohonen, T. 1984. *Self-Organization and Associative Memory*, Springer-Verlag, Berlin. ISBN: 0387513876
8. Grossberg, S.1986. *The Adaptive Brain I:Cognition, Learning, Reinforcement, and Rhythm, and The Adaptive Brain II: Visions, Speech, Language, and Motor Control*, page 41-49, Elsevier/North-Holland, Amsterdam.
9. Rumelhart, D. E., Hinton, G.E. and Williams, R.J. 1986. *Learning Internal Representations by Error Propagation*, MIT Press, Cambridge, MA, ISBN: 0-262-18190-8
- 10.Pao, Y.H. 1989. *Adaptive Pattern Recognition and Neural Networks*, Addison-Wesley Publishing Co., Reading, Mass.
- 11.Gutierrez,W. J. and Grandin, R.D.1989. Estimating hidden units for two layer perceptrons. *Proc. of the 1st Int.Conf. on Artificial Neural Networks*, October , London, U.K., 120-124.
12. Rumelhart, D. E., Hinton, G.E. and Williams, R.J. (1986), *Learning representations by back-propagating errors*. *Nature*, 323:533–536
13. Pao, Y.H. (1989), *Adaptive Pattern Recognition and Neural Networks*, Addison-Wesley Publishing Co., Massachusetts, Reading, Mass.
14. Hopfield, J.J and Tank, D., 1985, Neural computation of decisions in optimization problems. *Biological Cybernetics*, 52:141-152.
15. Lippmann, R.P. 1987, An introduction to computing with neural nets. *IEEE ASSP Magazine*, pp. 4-22.

16. Grossberg, S. 1988, Nonlinear neural networks: Principles, mechanisms, and architectures, *Neural Networks*, 1:17-61.
17. Gutierrez, W. J. and Grandin, R.D. 1989, Estimating hidden units for two layer perceptrons, *Proc. of the 1st Int.Conf. on Artificial Neural Networks*, 16-18 October London, U.K., pp.120-124.
18. Fukushima, K. 1975, Cognitron: a self-organizing multilayered neural network, *Biological Cybernetics*, 20:121-136.
19. Hecht-Nielsen, R., 1987, Counterpropagation networks, In *1st Int. Conference Neural Nets*, San Diego, volume 2.
20. Hinton, G.E., Sejnowski, T.J and Ackley, D., 1984, Boltzmann machines: Constraint satisfaction networks that learn, Carnegie Mellon University, Technical Report CMU-CS-84-119,.
21. Gurney, K. 1989, *Learning in networks of structured hypercubes*. PhD thesis, Dept. Electrical Engineering, Brunel University, Uxbridge, Middx, UK. Available as Technical Memorandum CN/R/144.
22. Carpenter G.A., Grossberg, S. and Reynolds, J.H., 1991, ARTMAP: Supervised real-time learning and classification of non-stationary data by a self-organizing neural network, *Neural Networks*, 4:565-588.
23. Dorffner, G. 1994, Unified framework for MLP's and RBFNs: Introducing conic section function networks, *Cybern. Syst.*, vol. 25, pp. 511–554
24. Karlık, B., 2002, The Effects of Fuzzy Clustering on The Back-Propagation Algorithm, *International Conference on Computational and Applied Mathematics*, Ukraine, Abstract Book, Kiev, Ukraine, pp.9-10
25. Karlık, B., Tokhi, O., Alcı, M., 2003, A Fuzzy Clustering Neural Network Architecture for Multi-Function Upper-Limb Prosthesis, *IEEE Trans. on Biomedical Engineering*, vol.50, no.11, pp.1255-1261
26. Karlık, B., 2005, *Yapay Sinir Ağları Ders Notları*, Haliç Üniversitesi.
27. Schalkoff, R., 1990, *Pattern Recognition: Statistical, Sctructural and Neural Approaches*. John Wiley & Sons, ISBN 0-471-55238-0
28. Karlık, B. ve Aydın, S., 1996, Pattern Recognition by Using ANN for Tactile Sensor of a Robot Manipulator, *Proceedings of the First Symposium on Mathematical & Computational Applications*, pp. 86-90
29. Özmeterler, E., 1989, *Yapay Nöral Ağları*, Yüksek Lisans Tezi, İ.T.Ü. Fen Bilimleri Enstitüsü, İstanbul

30. Şirvan, O., 2003, Güvenlik Amaçlı İris Tanıma, Yüksek Lisans Tezi, Ege Üni. Fen Bilimleri Enstitüsü, İzmir
31. Şirvan O., Karlık B., Tunalı T., Yapay Sinir Ağları Kullanılarak Güvenlik Amaçlı Biyometrik Tanıma, *HİTEK-2004*, 9-10 Aralık 2004, Hava Harp Okulu, İstanbul, cilt:2, sayfa:591-594

## ÖZGEÇMİŞ

Serdar KARGIN, 1962 yılında Ulukışla'da doğdu. İlk öğrenimini İzmir Kemal Reis İlkokulu'nda, orta ve lise öğrenimini İzmir Karataş Lisesi'nde tamamladı. 1981 yılında başladığı İ.T.Ü. Elektronik ve Haberleşme Mühendisliği Bölümü'nden 1985 yılında mezun oldu. İ.T.Ü. Fen Bilimleri Enstitüsü'nden, sırasıyla, 1993 yılında yüksek mühendis, 2000 yılında doktora ünvanlarını aldı. Halen, Hava Harp Okulu Dekanlığı'nda Elektronik Mühendisliği Bölüm Başkanı olarak görev yapmaktadır.