

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

**ESNEK HESAPLAMA VE BİYOBİLİŞİM
TEKNİKLERİ İLE BİR KLİNİK KARAR VERME
SİMÜLATÖRÜNÜN OLUŞTURULMASI**

DOKTORA TEZİ

Bilgisayar Yük. Müh. Orhan ER

Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ

Enstitü Bilim Dalı : ELEKTRONİK

Tez Danışmanı : Doç. Dr. Nejat YUMUŞAK

Nisan 2009

**ESNEK HESAPLAMA VE BİYOBİLİŞİM
TEKNİKLERİ İLE BİR KLİNİK KARAR VERME
SİMÜLATÖRÜNÜN OLUŞTURULMASI**


DOKTORA TEZİ

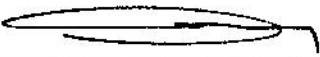
Bilgisayar Yük. Müh. Orhan ER


Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ

Enstitü Bilim Dalı : ELEKTRONİK

Bu tez 06/ 04 / 2009 tarihinde aşağıdaki jüri tarafından Oybirliği ile kabul edilmiştir.


Doç. Dr. Nejat YUMUŞAK
Jüri Başkanı


Prof. Dr. Osman ÇEREZCİ
Üye


Yrd. Doç. Dr. Ali GÜLBAĞ
Üye


Doç. Dr. Feyzullah TEMURTAŞ
Üye


Yrd. Doç. Dr. Hamdi M. SAROĞLU
Üye

ÖNSÖZ

Çalışmalarında her türlü katkıyı sağlayan, tezin oluşmasında ve sonuçlandırılmasında değerli bilgilerini paylaşarak bana destek olan Değerli Hocalarım Doç. Dr. Nejat YUMUŞAK ve Doç. Dr. Feyzullah TEMURTAŞ' a sonsuz teşekkürlerimi sunarım.

Ayrıca yetişmemde haklarını hiçbir zaman ödeyemeyeceğim sevgili aileme ve sevgili eşime gösterdikleri anlayıştan dolayı sonsuz teşekkür ederim.

ORHAN ER

İÇİNDEKİLER

ÖNSÖZ	ii
İÇİNDEKİLER.....	iii
SİMGELER VE KISALTMALAR LİSTESİ.....	vii
ŞEKİLLER LİSTESİ	viii
TABLolar LİSTESİ.....	x
ÖZET	xi
SUMMARY	xii
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
GÖĞÜS HASTALIKLARI.....	7
2.1. Giriş	7
2.2. Astım.....	8
2.2.1. Astımın nedenleri.....	9
2.2.2. Astımın belirtileri.....	10
2.2.3. Astım nöbetinin nedenleri	11
2.2.4. Astımın tanısı.....	12
2.2.5. Astım hastalığının gidişi	13
2.2.6. Astımın tedavisi	13
2.3. Kronik Obstrüktif Akciğer Hastalığı (KOAİ)	14
2.3.1. KOAİ' in belirtileri.....	15
2.3.2. KOAİ' ta tanı	16
2.3.3. KOAİ' ta risk faktörleri	16
2.3.4. KOAİ' in tedavisi	17

2. 4. Pnömoni (Zatürree).....	18
2.4.1. Pnömoni belirtileri	19
2.4.2. Pnömoninin tanısı	20
2.4.3. Pnömoninin tedavisi.....	20
2.5. Tüberküloz (Verem)	22
2.5.1. Tüberkülozda tanı	23
2.5.2. Tüberkülozda bulaşma	24
2.5.3. Tüberkülozda tedavi.....	25
2.6. Akciğer Kanseri.....	26
2.6.1. Akciğer kanserinin nedenleri.....	27
2.6.2. Akciğer kanserinde tarama ve erken tanı	28
2.6.3. Akciğer kanserinde tanı.....	28
2.6.4. Hastalığın evrelendirilmesi	30
2.6.5. Akciğer kanserinde tedavi.....	30
2.6.6. Hastaların takibi ve takibin önemi	32

BÖLÜM 3.

ESNEK HESAPLAMA VE BİYOBİLİŞİM TEKNİKLERİ	34
3.1. Giriş	34
3.2. Yapay Sinir Ağları (YSA)	35
3.2.1. YSA ve insan beyni	35
3.2.2. YSA hakkında genel bilgiler	38
3.2.3. Yapay sinir ağlarının kullanım alanları.....	40
3.2.4. YSA' nın yapısı	41
3.2.5. Yapay sinir ağlarının temel özellikleri.....	44
3.2.6. Yapay sinir ağı modelleri	46
3.2.6.1. İleri beslemeli yapay sinir ağları	47
3.2.6.2. Geri yayılmalı (backpropagation) YSA modeli.....	48
3.2.6.3. Yapay sinir ağlarında öğrenme	53
3.2.6.4. Yapay sinir ağlarında öğrenme algoritmaları	55
3.2.7. Çok katmanlı ağlar.....	58
3.2.7.1. Çok katmanlı ağın eğitilmesi.....	59
3.2.7.2. Çok katmanlı ağın çalışma prosedürü.....	62

3.2.8. Radyal tabanlı yapay sinir ağları	64
3.2.9. Olasılıksak yapay sinir ağları (PNN)	66
3.2.10. Sezgisel ve ileri seviyeli eğitim algoritmalar	66
3.2.10.1. Adaptif öğrenme katsayısı.....	67
3.2.10.2. Newton metodu.....	68
3.2.10.3. Gauss-newton metodu.....	69
3.2.10.4. Levenberg-marquardt algoritması.....	71
3.2.10.5. Esnek yayılım (resilient propagation) algoritması..	72
3.2.10.6. Eşleştirmeli eğim (Conjugate-Gradient)	
algoritmaları	73
3.3. Yapay Bağışıklık Sistemi (YSB).....	78
3.3.1. Giriş.....	78
3.3.2. YBS'nin tarihi gelişimi ve uygulama alanları.....	80
3.3.3. Bağışık hücre, molekül ve bunların etkileşiminin soyut	
modelleri	87
3.3.4. Algoritmalar ve işlemler	88
3.3.4.1. Kemik iliği modelleri.....	88
3.3.4.2. Timus modelleri.....	89
3.3.4.3. Klonal seçim algoritmaları.....	72
3.3.4.4. Bağışık ağ modelleri	95
3.4. Sinirsel - Bulanık Çıkarım	100
3.4.1. ANFIS (adaptif ağ yapısına dayalı bulanık çıkarım	
sistemi) mimarisi	100
3.5. Genetik Algoritmalar	104
3.5.1. Genetik algoritmaların temel teoremi	105
3.5.2. Basit genetik algoritma	106
3.5.3. Genetik algoritmalarda parametre seçimi	111
3.5.4. Genetik algoritmaların uygulama alanları.....	112

BÖLÜM 4.

KLİNİK KARAR VERME SİMÜLATÖRÜNÜN OLUŞTURULMASI

(GÖHAT)	117
4.1. Giriş	117

4.2. Uygulamada Kullanılan Veri Seti	117
4.3. GÖHAT' da Kullanılan Yapay Sinir Ağı Modeli	118
4.3.1. Ağın performans değerini ölçmede sınıflandırma doğruluk oranı	119
4.4. GÖHAT' da Kullanılan Yapay Bağışıklık Sistemi Modeli	120
4.5. GÖHAT' da Kullanılan Genetik Algoritma Modeli	123
4.6. GÖHAT Simülatörü	127
4.6.1. YSA ve GA eğitim ve test işlemleri formu	127
4.6.2. YSB eğitim ve test işlemleri formu	133
4.7. Göğüs Hastalıklarının Teşhisinde Kullanılan Diğer Yöntemler	136
4.7.1. Karakteristik davranış alıcı eğrileri (receiver operating characteristic curves- ROC)	136
BÖLÜM 5.	
SONUÇLAR VE ÖNERİLER	138
5.1. Sonuçlar	138
5.2. Öneriler	145
KAYNAKLAR	147
ÖZGEÇMİŞ	157

SİMGELER VE KISALTMALAR LİSTESİ

ANFIS	: Sinirsel bulanık sistemler
BP	: Backpropagation algoritması
GA	: Genetik Algoritmalar
GÖHAT	: Göğüs hastalıklarının teşhisinde esnek hesaplama ve biyobilişim tekniklerinin kullanılmasıyla geliştirilen örnek uygulama
GRNN	: Genel gerilemeli sinir ağı
KKDS	: Klinik karar destek sistemleri
KOAH	: Kronik obstrüktif akciğer hastalığı
LM	: Levenberg-marquardt algoritması
MLNN	: Multilayer neural network (çok katmanlı sinirsel ağlar)
PNN	: Olasılıksak yapay sinir ağları
RBNN	: Radyal tabanlı yapay sinir ağları
ROC	: Karakteristik davranış alıcı
YSA	: Yapay sinir ağları
YSB	: Yapay bağışıklık sistemi

ŞEKİLLER LİSTESİ

Şekil 3.1.	Beyin ve Sinir Sisteminin temel yapı elemanları.....	36
Şekil 3.2.	Örnek bir sinir hücresi.....	37
Şekil 3.3.	Örnek bir yapay sinir hücresi.....	42
Şekil 3.4.	YSA için kullanılan örnek eşik (aktivasyon) fonksiyonları	43
Şekil 3.5.	Çok modüllü yapay sinir ağları.....	46
Şekil 3.6.	Tek katmanlı ileri beslemeli ağ.....	47
Şekil 3.7.	İki katmanlı ileri beslemeli ağ	48
Şekil 3.8.	Geriye yayılım ağı modelinin yapısı	48
Şekil 3.9.	Çok katmanlı ağ yapısı.....	59
Şekil 3.10.	Üç katmanlı yapay sinir ağı	60
Şekil 3.11.	Radyal tabanlı ağın, gizli katman işlem elemanının yapısı	65
Şekil 3.12.	Yapay bağışıklık sistemi için katmanlı çatı.....	86
Şekil 3.13.	Komplemanterin bölgeleri aracılığıyla tanıma	87
Şekil 3.14.	Şekil-uzay formalizmi	87
Şekil 3.15.	Bir antikorun gen kütüphanelerinden yapımı/ifadesi.....	89
Şekil 3.16.	Pozitif seçim algoritması	89
Şekil 3.17.	Negatif seçim algoritması.....	91
Şekil 3.18.	Timik pozitif ve negatif seçimin gözleme aşaması.....	92
Şekil 3.19.	Klonal seçim algoritması.....	94
Şekil 3.20.	Timmis ve arkadaşlarının önerdiği ağ modeli	98
Şekil 3.21.	De Castro ve Zuben'in ağ modeli	98
Şekil 3.22.	(a) Birinci dereceden iki girişli ve iki kurallı “Sugeno Bulanık Modeli”, (b) Eşdeğer ANFIS yapısı.....	101
Şekil 3.23.	Bulanık uyarlamalı ağ mimarisi.....	103
Şekil 3.24.	Genetik Algoritma Akış Diyagramı	107
Şekil 4.1.	GÖHAT' da kullanılan iki gizli katmanlı yapay sinir ağının yapısı.....	119

Şekil 4.2.	Zatürree sınıflandırması için örnek bir klonlama işlemi	121
Şekil 4.3.	Uygulamada Adım 3 için kullanılan işlem bloğu	122
Şekil 4.4.	Uygulamada Adım 7 için kullanılan işlem bloğu	123
Şekil 4.5.	Genetik algoritma akış diyagramı	124
Şekil 4.6.	Aritmetiksel çaprazlama sonucunda oluşan örnek değerler	126
Şekil 4.7.	GÖHAT simülatörü ana formu ve YSA eğitim penceresi	127
Şekil 4.8.	(a) Yeni bir YSA oluşturma penceresi, (b) Yeni YSA'nın parametre seçim penceresi, (c) Aktivasyon fonksiyonu seçim penceresi.....	128
Şekil 4.9.	Katmanlar arasındaki ağırlıkları görüntüleme penceresi.....	129
Şekil 4.10.	Eğitim sonuç raporu	130
Şekil 4.11.	Test işlemi ve yeni hasta verisi giriş penceresi.....	131
Şekil 4.12.	Belirlenen 100 kayıt üzerinde test işlemi	131
Şekil 4.13.	Test işlemi sonucu doğru ve yanlış sonuçlar	132
Şekil 4.14.	GA parametre belirleme penceresi.....	132
Şekil 4.15.	GÖHAT Simülatörü YSB hesaplama penceresi ön işlemler arayüzü.....	133
Şekil 4.16.	GÖHAT Simülatörü YSB hesaplama penceresi eğitim işlemleri arayüzü	134
Şekil 4.17.	GÖHAT Simülatörü YSB hesaplama penceresi test işlemleri arayüzü ..	135
Şekil 4.18.	İdeal ve kötü performans göstergesi olan ROC eğrileri.....	137
Şekil 5.1.	GÖHAT simülatöründe eğitim ve test başarı değişim grafiği	144

TABLolar LİSTESİ

Tablo 1.1. Literatüre gemiş alıřmalar ve doęruluk oranları	5
Tablo 2.1. Pnömoni oluşumunu kolaylařtıran risk faktörleri.....	18
Tablo 2.2. Tedavi rejimlerine göre ölüm, kronik basil taşıyıcılığı ve řifa oranları..	25
Tablo 3.1. Pratikte en fazla kullanılan toplama fonksiyonları	43
Tablo 4.1. Uygulamada kullanılan veri seti	117
Tablo 5.1. MATLAB programı üzerinde gerekleřtirilen ve literatüre gemiş deneyler	140
Tablo 5.2. alıřma esnasında elde edilen (doęruluk/toplam) teřhis sayıları	141
Tablo 5.3. alıřma esnasında elde edilen (doęruluk/toplam) teřhis yüzdeleri	142
Tablo 5.4. Göęüs hastalıkları veri seti üzerinde yapılan sınıflandırma problemi sonuçları	143

ÖZET

Anahtar Kelimeler: Yapay Sinir Ağları, Yapay Bağışıklık Sistemi, Genetik Algoritmalar, Sinirsel Bulanık Çıkarım, Hastalık Teşhisi, Solunum Sistemi Hastalıkları, Klinik Karar Verme Simülatörü.

Dünyada her yıl milyonlarca insan, göğüs hastalıkları teşhisi ile hastanelere başvurmaktadır. Bu hastalıkların başında; kronik obstrüktif akciğer hastalığı, verem, astım, zatürree ve akciğer kanseri gelmektedir. Düşük gelirli ülkelerde, önemli bir sorun teşkil eden göğüs hastalıkları, 15 ile 49 yaş grubu insanların ölüm nedeni olarak ön sırada yer almaktadır. Solunum hastalıkları ülkemizde de çok önemli bir sağlık sorunudur. Bu çalışmada, solunum hastalıklarının teşhisinde yardımcı olacak bir klinik karar destek sistemi geliştirilmesi amaçlanmıştır. Bunun akabinde, literatürde spesifik bir hastalık üzerine yapılan uygulamalardan farklı olarak beş adet hastalık üzerinde sınıflandırma işlemi yapılmıştır. Bu doğrultuda geliştirilen uygulamada teşhis için yapay sinir ağı, yapay bağışıklık sistemi, genetik algoritma gibi esnek hesaplama ve biyobilişim teknikleri kullanılmıştır. Uygulama için gerekli olan veri seti, yerel bir hastanede yatan göğüs hastaları için düzenlenen epikriz raporlarından oluşturulmuştur. Gerçekleştirilen testler sonucunda; yapay bağışıklık sistemi ile % 93.83, yapay sinir ağları ile % 92.16, genetik algoritmalar ile % 91.31, ANFIS ile % 89.05 ve ROC ile % 93.00 doğruluk oranları elde edilmiştir. Sonuçlar bu alanda yapılan örnek çalışmalar ile karşılaştırılmıştır. Sonuç olarak, solunum hastalıklarının teşhisinde esnek hesaplama ve biyobilişim tekniklerinin kullanılmasında önemli sayılabilecek doğruluk oranı ile sınıflandırma işleminin başarılı olduğu görülmüştür. Ayrıca geliştirilen uygulama yerel bir hastane ortamında denenmiş olup uzman doktorların da desteğini almıştır.

THORACIC DISEASE DIAGNOSIS USING FLEXIBLE COMPUTING AND BIOINFORMATICS COMPUTING SYSTEM

SUMMARY

Keywords: Thoracic Disease Diagnosis, Artificial Neural Networks, Artificial Immune Systems, Genetic Algorithm, Neural Fuzzy System (ANFIS).

Millions of people are diagnosed every year with a chest disease in the world. Chronic obstructive pulmonary, pneumonia, asthma, tuberculosis, lung cancer diseases are the most important chest diseases. Thoracic disease is a great problem in most low income countries; it is the single most frequent cause of death in individuals aged fifteen to forty-nine years. Thoracic disease is an important health problem in Turkey also. In this study, an application on chest diseases diagnosis was realized by using flexible computing and bioinformatics computing systems. Used neural network structures in this study were multilayer, probabilistic, and learning vector quantization neural networks. A genetic algorithm system and an artificial immune system were also performed to realize chest disease diagnosis for the classification and comparison. The results of the study were compared with the results of the pervious similar studies reported focusing on different chest diseases diagnosis. The pulmonary disease dataset were taken from a state hospital's database using patient's epicrisis reports.

BÖLÜM 1. GİRİŞ

Sağlık hizmeti sunumunda bilgisayar sistemlerinin kullanımı son 30 yılda giderek yaygınlaşmıştır. Bu kullanım önceleri idari ve finansal alanlarla sınırlı iken günümüzde klinik karar verme süreçlerine yardımcı sistemler geliştirilmektedir. Klinik karar destek sistemleri (KKDS), hekimlere ve diğer sağlık personeline tanıl ve tedaviye yönelik klinik karar süreçlerinde destek sağlayan bilgisayar programlarıdır. Klinik konularda akıl yürütme özelliğine sahip karmaşık bilgisayar programları olan KKDS' ler, tıbbi bilginin miktarında meydana gelen artış nedeniyle bu bilginin yönetiminde zorlanan hekimlere uygun seçenekler arasından karar verebilme konusunda destek sunan sistemlerdir [1]. Hastalığın tanısı, tedavi seçenekleri, hangi ilaç kullanılması gerekliliği ve ilaç yan etkileri konularında güncel ve kaliteli alan bilgisine sahip sistemlerdir. Klinik karar destek sistemleri, güncel bilgileri kullanmanın yanı sıra hastaya özel bilgileri de dikkate alarak, hekimlerin hastayı en iyi biçimde değerlendirmesi yönünde yardım ederler. Diğer bazı işlevleri; hastalara özel değişkenlere bağlı olarak özel ilaç tavsiyesinde bulunmak [2], hastalara ait özel bilgileri uzman bilgi tabanı ile mukayese ederek hasta yönetimi ve konsültasyon (bilgi paylaşımı) işlevini gerçekleştirmek [3], klinik ve finansal bilgi depolarını bir araya getirerek, hizmet kullanımının, maliyet bileşenlerinin ve klinik performansın değerlendirilmesi işlevini yerine getirmektedir [4].

Solunum sistemi hastalıkları ölümle sonuçlanabilecek rahatsızlıklar olması dolayısıyla, teşhisi zor ve oldukça önemlidir. Teşhisteki gecikme ya da hatanın ölümle sonuçlanma ihtimali böyle bir hastalık teşhisinin önemini arttırır. Hastaya basit klinik testlerle hastalığın ilk evrelerinde göğüs hastalığı teşhisi koymak bu hastalıkların ilerlemesini engelleyebilir ve hayat kurtarır.

Solunum, yaşam için en öncelikli fonksiyondur. Dünyada en sık rastlanan, en ölümcül olan ve en fazla işgücü kayıplarına yol açan enfeksiyonlar solunum yolu

enfeksiyonlarıdır. Pnömoniler (zatürree) halen mortalitesi en yüksek enfeksiyon hastalıkları listesinin başında bulunmaktadır. Tüm dünyada en sık görülen ve en öldürücü tümörler akciğer kanserleridir. Tüberküloz, halen en öldürücü ve en yaygın enfeksiyon hastalığı olup, her yıl 4 milyon kişinin ölümüne neden olmaktadır. KOAH (kronik obstrüktif akciğer hastalığı), ölümlerin 5. nedeni ve dünyada en sık rastlanan hastalık durumundadır. Astım tüm dünyada en yaygın hastalıklardan biri olup %4–6 sıklıkta rastlanmaktadır. Akciğerler mesleki ve çevresel maruziyetlerden en fazla etkilenen organımızdır. Dünya Sağlık Örgütü' nün 2001 yılı içinde bildirdiğine göre 2. bin yılda dünyada en sık rastlanan ve en fazla öldüren, en çok sakatlayan ve ekonomik kayıplara yol açan 10 hastalıktan 5'i solunum sistemi hastalıkları olup (grip, zatürree, verem, KOAH, akciğer kanseri) bunların 3. bin yılda da toplum sağlığı bakımından en öncelikli sorunlar olmaya devam edeceği ön görülmektedir. Bu öncelikli küresel sorunlar göğüs hastalıkları disiplininin önemini ve ontolojik gerekçesini açıkça ortaya koymaktadır [5].

Küresel boyutta vurgulanan öncelikler, ülkemiz için de aynen geçerlidir. Buna ilaveten: Ülkemiz, tüberkülozun en sık görüldüğü coğrafyada yer almaktadır. Avrupa'da en çok sigara tüketilen ikinci ülkeyiz. Sigara tüketiminin son 20 yılda giderek arttığı ve buna bağlı olarak akciğer kanserlerinden ölümlerin ve KOAH sıklığının önümüzdeki yüzyılda da artan sorun olmağa devam edeceği bir popülasyona sahibiz. Türkiye'nin KOAH, astım ve akciğer kanseri gibi tütün içimiyle ilgili akciğer hastalıklarına yılda 1 katrilyon harcadığı hesaplanmaktadır. Bu ulusal gerekçeler yanında; globalleşen dünyada hak ettiğimiz yeri alabilmek için çabalayan ülkemiz, Avrupa Birliği ile uyumlu olarak bu disiplini hak ettiği önem ve öncelikle yapılandırmıştır [5].

Zor mühendislik problemlerini çözmek amacıyla yeni yaklaşımlar geliştirmek için, özellikle biyolojik sistemlerden esinlenerek yapılan çalışmalarda son yıllarda ilgi gittikçe artmıştır. Yapay sinir ağları ile gelişen sistemlerin yanında, bağışıklık sistemine de olan ilgi son birkaç yıldır artarak devam etmektedir. Ayrıca genetik algoritmalar da bu problemlerin çözümünde önemli başarılar sağlamıştır.

Yapay sinir ağı (YSA), insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir. Bu yetenekleri geleneksel programlama yöntemleri ile gerçekleştirmek oldukça zor veya mümkün değildir. Bu nedenle, yapay sinir ağlarının, programlanması çok zor veya mümkün olmayan olaylar için geliştirilmiş adaptif bilgi işleme ile ilgilenen bir bilgisayar bilim dalı olduğu söylenebilir.

Sinirsel bulanık sistemler (ANFIS), yapay sinir ağlarının paralel hesaplayabilme ve öğrenme kabiliyeti ile bulanık mantığın uzman bilgisini kullanarak sonuçlar çıkarabilme özelliklerinin birleşiminden oluşur. Sonuç olarak sinirsel bulanık sistemler sayesinde yapay sinir ağları daha anlaşılır hale gelir [6]. ANFIS, ele alınan problem için oluşturulan yapıya göre olası tüm kuralları atayabilmekte veya kuralların veriler yardımıyla uzman tarafından atanmasına olanak vermektedir. ANFIS'in kural oluşturabilmesi veya kural oluşturulmasına olanak sağlaması uzman görüşlerinden faydalanması anlamına gelmektedir. Bu nedenle birçok tahmin probleminde yapay sinir ağlarına uzman görüşlerinden faydalanma imkânı tanıdığı için ortalama hata kareler kriterine göre daha iyi sonuçlar elde edilmesini mümkün kılmaktadır [7].

Genetik algoritmalar (GA), doğal seçim ilkelerine dayanan bir arama ve optimizasyon yöntemidir. Temel ilkeleri John Holland tarafından ortaya atılmıştır. Temel ilkelerinin ortaya atılmasından sonra, genetik algoritmalar hakkında birçok bilimsel çalışma yayınlanmıştır. Ayrıca, genetik algoritmaların teorik kısmı ve uygulamaları hakkında birçok uluslararası konferans da düzenlenmektedir. Genetik algoritmaların, fonksiyon optimizasyonu, çizelgeleme, mekanik öğrenme, tasarım, hücresel üretim gibi alanlarda başarılı uygulamaları bulunmaktadır. Geleneksel optimizasyon yöntemlerine göre farklılıkları olan genetik algoritmalar, parametre kümesini değil kodlanmış biçimlerini kullanırlar. Olasılık kurallarına göre çalışan genetik algoritmalar, yalnızca amaç fonksiyonuna gereksinim duyar. Çözüm uzayının tamamını değil belirli bir kısmını tararlar. Böylece, etkin arama yaparak çok daha kısa bir sürede çözüme ulaşırlar [8]. Diğer bir önemli üstünlükleri ise

çözümlerden oluşan popülasyonu eş zamanlı incelemeleri ve böylelikle yerel en iyi çözümlere takılmamalarıdır.

Yapay Bağışıklık Sistemleri (YSB), yapay sinir ağları ve genetik algoritmalara benzer şekilde, insan vücudundaki biyolojik bağışıklık sisteminin özet modelidir ve birçok alanda uygulaması bulunmaktadır. Tanım olarak YBS, teorik bağışıklık ve karmaşık problem uzaylarına uygulanan gözlemlenmiş bağışık fonksiyonlar, ilkeler ve modellerden esinlenmiş hesapsal sistemlerdir [9].

Göğüs hastalıklarının teşhisinde yapay sinir ağları, yapay bağışıklık sistemi veya genetik algoritmaların kullanılması ile geliştirilen çok az sayıda çalışma bulunmaktadır [10-17].

Birinci çalışmada [10] yazarlar, KOAH hastalığı üzerinde yapmış olduğu çalışmada 26 özellik ile teşhisin çıkarımı gerçekleştirmişlerdir. Kullanılan yapay sinir ağının yapısı; bir gizli katman içeren, geri yayımlı MLNN' tür. Bu çalışmada rapor edilen yaklaşık doğruluk oranı %90'dır. İkinci çalışmada [11] yazarlar, KOAH hastalığı üzerinde yapılmış çalışmada göğüs filmi üzerinden özellik çıkarma yöntemi ile teşhisin belirlenmesi hedeflenmiştir. Kullanılan yapay sinir ağı yapısı; bir ve iki gizli katmanlı, ağırlıkların geri yayılma algoritması kullanılarak gerçekleştirilen MLNN ağıdır. Bu işlem sırasında eğitim seti 10-kat çaprazlama yöntemi kullanılmıştır. Bu çalışmada açıklanan en iyi doğruluk oranı, iki gizli katman kullanılarak elde edilen %90,6'dır. Üçüncü çalışmada [12] yazarlar, solunum güçlüğü çeken zatürree hastaları üzerinde yapmış oldukları çalışmada teşhisi gerçekleştirmede optimum çözümü elde etmek için genetik algoritma ve eğitim parametreleri için yapay sinir ağları kullanılmıştır. Bu çalışmada yazarlar, zatürree hastalığının teşhisini ROC hesaplama yöntemi ile % 82,8 doğruluğa ulaştıkları ifade edilmiştir. Dördüncü çalışmada [13] yazarlar, bir genel gerilemeli sinir ağı (GRNN) ile klinik ve göğüs filmi aracılığı ile belirledikleri parametrelerin kullanılmasıyla tüberküloz hastalığının teşhisini amaçlamışlardır. Bu çalışmada çevresel faktörler, genetik faktörler ve göğüs filmi semptomlarının oluşturduğu toplam 21 özellik ile ağın girişini belirlemişlerdir. Ağın çıkışı olarak da hastanın tüberküloz olma olasılığı hesaplanılmıştır. Ağın eğitimi sırasında giriş verisi 10-kat çaprazlama yöntemi kullanılarak işlenmiştir. Bu

çalışmanın sonucunda da yazarlar yaklaşık olarak %92,3 doğruluk oranına ulaşmışlardır. Beşinci çalışmada [14] yazarlar, negatif yaymalı akciğer tüberkülozu için bir ön tahmin modeli oluşturmayı hedeflemişlerdir. Yapay sinir ağını modellemek için fiziksel semptomlar kullanmışlardır. Bu çalışmada bir gizli katmana sahip MLNN yapısı ile yaklaşık olarak %77 doğruluk oranına ulaşmışlardır. Ayrıca astım ve akciğer kanseri üzerine yapılan çalışmalar da bulunmaktadır [15-17].

Solunum hastalıkları teşhisindeki çalışmalar sınırlı sayıda olup tek bir hastalığı teşhis etme konusunu ele almışlardır. Genellikle bu çalışmalar, yapay sinir ağlarının geri yayılım algoritması kullanarak doğruluk oranı elde etmişlerdir. Bu çalışmalar [10-17] içerisinde en iyi performans, %92.30 ile tüberküloz hastalığını teşhis etmede kullanılan GRNN algoritması ile ulaşılmıştır [13]. Diğer çalışmalar ise %90 civarında bir teşhis doğruluğu ortaya koymuştur [10,11,15-17]. En kötü performans ise %77 doğruluk oranıyla MLNN bir gizli katman ile geri yayılım algoritması kullanılarak akciğer tüberkülozu teşhis edilmeye çalışılırken elde edilmiştir [14]. Literatüre geçmiş çalışmalar ve sınıflandırma doğruluk oranları tablo 1.1'de görülmektedir.

Tablo 1.1. Literatüre geçmiş çalışmalar ve doğruluk oranları.

Çalışma	Metot	Eğitim Algoritması	Sınıflandırma Doğruluk Oranı (%)
Referans [10]	MLNN (bir gizli katman)	BP	90.00%
Referans [11]	MLNN (iki gizli katman)	BP (momentum)	90.60 %
Referans [12]	MLNN (iki gizli katman)	BP (momentum)	82.80 %
Referans [13]	GRNN (bir gizli katman)		92.30 %
Referans [14]	MLNN (bir gizli katman)	BP	77.00 %
Referans [15]	NN - Radial Basis Function	BP	90,00 %
Referans [16]	NN (ileri beslemeli)	FF	89,20 %
Referans [17]	MLNN (bir gizli katman)	BP	88,00 %

Bu çalışmanın amacı toplum sağlığının iyileşmesine aktif olarak katkıda bulunan, solunum sistemi hastalıklarının önlenmesinde önemli bir etken olan erken tanı için öncü bir karar destek sistemi oluşturmaktır. Bu doğrultuda, günümüzde tıbbi teşhis

problemlerinde yaygın olarak kullanılan esnek hesaplama ve biyobilişim teknikler ile solunum sistemi hastalıkları teşhisi konusunda örnek bir karar destek sistemi uygulaması gerçekleştirmektedir. Uygulama için yerel bir göğüs hastalıkları polikliniğinde yatan hasta epikrizlerine yansıyan parametrelerden elde edilen veri kümeleri ile çalışılmıştır. Gerçekleştirilen testler sonucunda; yapay bağışıklık sistemi ile % 93.83, yapay sinir ağları ile % 92.16, genetik algoritmalar ile % 91.31, ANFIS ile % 89.05 ve ROC ile % 93.00 doğruluk oranları elde edilmiştir. Bu doğruluk oranlarının literatürdeki çalışmalardan daha iyi bir teşhis yüzdesine de sahip olduğu görülmektedir. Bunun yanında literatürde bir hastalık üzerine çalışılmışken bu uygulama bile birden çok hastalık üzerinde teşhis işlemi denenmiş ve başarılı bir sonuç elde edildiği görülmüştür.

Bu çalışmanın ikinci bölümünde ülkemizde sık görülen solunum sistemi hastalıkları olarak da adlandırılan göğüs hastalıkları hakkında detaylı bilgi verilecektir. Üçüncü bölümde ise tasarlanmak istenen karar destek sisteminin altyapısında kullanılacak esnek hesaplama ve biyobilişim teknikleri açıklanacaktır. Dördüncü bölümde de göğüs hastalıkları verisi üzerinde hesaplama yöntemleri kullanılarak geliştirilmiş örnek bir uygulama anlatılacaktır. Uygulamanın geçerliliğini artırmak için teşhis alanında kullanılan diğer yöntemler incelenerek veri seti üzerindeki performansı araştırılacaktır. Bu yöntemlerin başında Karakteristik davranış alıcı (ROC) eğrileri gelmektedir. Sonuç olarak uygulamanın detaylarını ve neticelerini içeren son bölümde ise varılan nokta üzerinde yapılacak öneriler ve tartışmalara yer verilecektir.

BÖLÜM 2. GÖĞÜS HASTALIKLARI

2.1. Giriş

Göğüs Hastalıkları; solunum sistemi hastalıkları ile ilişkilidir. Solunum sistemi; vücuda alınan besinlerin yakılmasında temel yakıt olan oksijenin temin edildiği ve sonuçta oluşan karbondioksitin vücuttan atılması işleminin gerçekleştiği sistemdir. Solunum yolları ve akciğerlerden oluşur.

Solunum yolları; burun, sinüsler, yutak, küçük dil ve gırtlaktan oluşan üst solunum yolları ve soluk borusu, bronşlardan oluşan alt solunum yolları olarak ikiye ayrılır. Solunum yolları havanın sadece iletiminde görevlidir.

Akciğerler, solunum sisteminin temel organıdır. Akciğerler yaşam için mutlak gerekli olan oksijenin vücuda alınmasını ve vücutta oluşan karbondioksitin dışarı atılmasını sağlar. Her iki akciğerin etrafını iki katlı plevra dediğimiz bir zar çevreler.

Solunum sistemi ile ilgili belirtiler ve hastalıklar insanlık tarihinin başlangıcından itibaren toplumun ve bireylerin sık karşılaştıkları sorunlar arasında olagelmıştır. Solunum sistemi; göğüs boşluğu denilen, yan duvarları kaburgalardan, altta diyaframdan oluşan huni şeklindeki göğüs kafesiyle kuşatılmıştır. Solunum sistemi burun ve sinüslerden başlayıp, akciğerin en uç noktasına kadar devam eder. İnsanda sağ ve sol olmak üzere iki adet akciğer bulunmaktadır.

Akciğerler sistemik dolaşımın geçtiği organlar olduğu için, sadece kendi hastalıkları değil diğer organlarla ilgili hastalıklar nedeniyle de yakınmalara neden olurlar. Bu yakınmaların en önemlileri şunlardır: nefes darlığı, hırıltılı solunum, horlama, öksürük, balgam, ağızdan öksürükle kan gelmesi, göğüs ve yan ağrısı, sırt ve omuz

ağrısı. Daha az sıklıkla karşımıza çıkan yakınmalar ise şunlardır: kilo kaybı, halsizlik, iştahsızlık, gece terlemesi, ateş.

Ülkemizde göğüs hastalıkları polikliniğinde ayakta veya gerektiğinde yatarak takip ve tedavi edilen başlıca hastalıklar şunlardır:

1. Astım
2. Kronik obstrüktif akciğer hastalığı (kronik bronşit ve amfizem)
3. Pnömoni (zatürree)
4. Tüberküloz (verem)
5. Akciğer kanseri

diğer göğüs hastalıkları ise aşağıda belirtilmiştir:

1. Plevral (akciğer zarı) hastalıklar
2. Mesleki ve çevresel akciğer hastalıkları
3. Pulmoner tromboemboli (akciğer atardamarlarının pıhtı ile tıkanması)
4. Interstisyel akciğer hastalıkları (akciğer bağdokusu hastalıkları)
5. Uykuda solunum bozuklukları
6. Solunum yetmezliği
7. Alerjik solunum hastalıkları

Yukarıda anılan hastalıkların hepsi ülkemizin toplum sağlığını doğrudan ilgilendiren sorunlardır. Bu bölümde; ülkemizde sıklıkla karşılaşılan ve tanısı konulacak başlıca göğüs hastalıkları ile ilgili hesaplamaların daha anlaşılır olabilmesi için ayrıntılı bilgi verilmiştir.

2.2. Astım

Astım, kronik bir solunum yolları hastalığıdır. Bu hastalık, tipik olarak, öksürüğe, soluk alıp verirken çıkan ıslık sesine ve hepsinden önce solunum darlığına yol açar. Astım şikâyetlerinin karakteristik özelliği ise, kriz şeklinde olup, ara ara gelmesidir.

Bunun sebebi, geri dönen iltihap nedeniyle güçsüz düşen çok hassaslaşmış bronşiyal mukoza zarıdır [18].

Bronşiyal astım nefes darlığı (soluma güçlüğü), öksürük ve bazen de koyu kıvamlı balgam çıkarmayla seyreden, akut ya da subakut dönemlerle belirlenen bir hastalıktır. Belirtileri, bronş duvarındaki kasların yaygın kasılmasına bağlıdır. Kasılmayla birlikte bronş kanalını daraltan mukoza şişmesi (ödemi) gözlenir. Ayrıca, hafif yapışkan özellikte, koyu kıvamlı bir salgı üreten solunum yolları bezlerinin işlevi de artar.

Astım en sık rastlanan kronik solunum sistemi hastalığı olup, tüm dünyada yaklaşık 150 milyon insanı etkilemektedir. Dünya Sağlık Örgütü astımın ekonomik maliyetinin HIV ve tüberkülozun toplamından daha fazla olduğunu tahmin etmektedir [19,20]. Türkiye yaklaşık 4 milyon astım hastası bulunmaktadır. Dünyada ise yaklaşık 300 milyon astımlı bulunmaktadır. Astım ve KOAH başta olmak üzere kronik solunum hastalıklarından 2005 yılında 4.9 milyon kişinin hayatını kaybettiği gerçeği de artık bu konuda ciddi önlemler almayı gerektirmektedir. Tedavi edildiğinde astımlı olguların çoğu klinik ve fonksiyonel olarak normal düzeye gelebilmektedir [22]. Astımın en önemli özellikleri ise kronik hava yolu inflamasyonu (bağışıklık sistemini aktive etmesi) ve bunun sonucu gelişen bronş aşırı duyarlılığı ile reversibl (kısa süreli hastalanma), değişken hava yolu engellenmesidir [21]. İnflamasyon zemininde gelişen bronş aşırı duyarlılığı ve bunun reversibl (kısa süreli hastalanma) oluşu klinik bulguları belirleyen en temel özelliklerdir. Hasta herhangi bir zamanda duyarlı olduğu bir etkenle karşılaştığında bronş aşırı duyarlılığı, hava yolu obstrüksiyonu (engellenme) ile buna bağlı olarak öksürük ve nefes darlığı ortaya çıkmaktadır. Tüm bu belirtiler tedavi ya da kendiliğinden tamamen ya da kısmen ortadan kalkmaktadır. Hastanın sürekli olarak nefes darlığı oluşabileceği duygusu ile yaşaması, psikolojisini de etkileyebilecektir.

2.2.1. Astımın nedenleri

Astımın dış ve iç nedenlere bağlı iki türü bilinir. Organizmaya dışarıdan giren alerjik

nitelikli etkenler dış nedenlere bağlı astıma; enfeksiyonlardaki gibi hastanın vücudunda bulunan etkenler ise iç nedenlere bağlı astıma yol açar.

Bronşiyal astımla ruhsal süreçler arasındaki karşılıklı etkileşim oldukça karmaşıktır. Duygusal değişimler astım nöbetlerim başlatmakla kalmaz, aynı zamanda alerjik ya da enfeksiyona bağlı astım biçimlerinin şiddetini artırarak ya da azaltarak nöbetlerin klinik tablosunu da değiştirebilirler. Bronşiyal astım yaşamın herhangi bir döneminde ortaya çıkabilir, ama olguların üçte biri ergenlik döneminden önce başlar ve ileri yaşlarda sıklığı azalır. Kentsel alanlarda yaşayanlara oranla, kırsal bölge nüfusunda daha az görülür; hava kirliliği oranı yüksek olan ortamlarda Çalışan ya da yaşayanlarda daha yaygındır [23].

2.2.2. Astımın belirtileri

Hastalığın başlangıcı birden başlayan astım nöbeti biçiminde olabilir. Ama nöbet öncesinde, hafif bir soğuk algınlığına benzeyen bazı geçici belirtiler de görülebilir. Göğüs kemiği çevresinde ağrı nöbeti, bronşlarda balgam artışı, solunum güçlüğü, göğüste baskı duygusu gibi bulguların kaynağı bazı kokular, bazı maddeler ya da hayvanlar olabilir. Huzursuz, sıkıntılı, çöküntü içinde ve uykusuz olan hasta astım nöbetinin ilk belirtilerini genellikle iyi tanır. Astım nöbetinin en sık görülen ilk bulgularından biri koku duyusunun yitilmesidir; nöbetin sonlarına doğru bu duyu genellikle geri gelir. Nöbetlerin tipik tablosu balgamsız hırıltılı bir solunum, göğüste sıkışma ve boğulma duygusu ile başlar; daha sonra boğulma duygusu, sıkıntılı bir hava açıklığına dönüşür, hasta giderek artan bir korkuyla tüm çabalarına karşın, etkili solunum yapamaz, göğüs kafesinin genişlemesinin engellendiğini zanneder. Korkulu, gergin ve huzursuz olan hasta, solunumunu kolaylaştıracak bir konum arar. Yataktaysa, kollarını şilteye doğru uzatıp, omuzlarını yüksek tutmaya çalışarak oturur; ayaktaysa hava arayışı içinde sıkıntılı bir şekilde dönüp durur, pencereden dışarı sarkar ya da bir sandalyeye ata biner konumda oturarak, yardımcı solunum kaslarının işini kolaylaştıracak biçimde sandalyenin sırt kısmını sıkıca sarar. Yüzü solgunlaşır ve morarır, gözleri dışarı fırlar, konuşma güçlüğü çeker. Boyun, göğüs ve karındaki yardımcı solunum kasları gergindir; genişleyen göğüs kafesi yalnız çok yüzeysel ve sınırlı solunum hareketleri yapar. Soluk alma kısa sürelidir, çok az hava

alabilir ve aldığı havayı hemen dışarı verir. Solunum yolları gerilmiş olduğu için, hava zorlukla dışarı verilirken ıslık gibi bir ses çıkar.

Astım krizinin geçmesiyle hasta normale dönerek olağan etkinliklerini sürdürebilir. Ama şiddetli astım türlerinde, nöbetler sık olduğundan nöbet aralarında da en küçük bir güç harcamayla artan soluma güçlüğü ve hırıltılı solunum gibi bazı hafif temel belirtiler sürebilir. Uygun bir biçimde tedavi edilmezse bronşiyal astım, nöbetler halinde gelen bir hastalık olmaktan çıkıp, kalıcı bir hal alır ve gerçek bir “astmatik hastalığa” dönüşür: Artık solunum güçlüğü süreklidir; hasta her zaman hırıltılı olan öksürükle bronşlarda sürekli bulunan balgamı atmaya çalışır; en ufak bir yorgunluk, heyecan, ısı değişimi, hastalık belirtilerinin şiddetlenmesine yol açar [23].

2.2.3. Astım nöbetinin nedenleri

Astım nöbetinin nedenleri tam olarak bilinmemekle birlikte, bazı kişisel özellikler dikkate alınmalıdır. Bazı insanlar belirli alerji uyarıcı maddelere (alerjen) karşı aşırı duyarlıdır. Bu durum organizmanın özgün antikorlar denen bazı maddeler oluşturmasına neden olur; bunlar daha sonra alerjenlerle karşılaşınca astım nöbetlerini başlatır.

Olguların büyük bir bölümünde solunan hava aracılığıyla akciğerlere ulaşan alerjen madde, hücrelere yapışık olarak bulunan antikorlarla karşılaştığında, akciğer dokusunun tüm bileşenlerinin katıldığı, bir dizi ani gelişen süreç başlar. En ince bronş dallarının çevresindeki dairesel düz kas lifleri kasılarak büzülürler ve böylece hava ile kan arasında gaz alışverişinin (karbon dioksitin atılarak oksijenin alınması) gerçekleştiği hava keseciklerine (alveol) ulaşan havanın geçtiği alan daralır. Bronşların içini örten mukoza şişer (ödem) ve gergin bir görünüm alarak havanın geçişini daha da zorlaştırır; ayrıca, mukus salgılayan hücrelerin salgılan artar. Bronş mukozasında çok sayıda, mukus salgılayan hücre vardır; normal koşullarda çok yararlıdır, çünkü bunların salgılan solunum yollarını temizler. Astım nöbetlerinde ise yapışkan ve koyu kıvamlı aşırı mukus salgılayarak, zaten kasılmış durumdaki küçük bronşların iyice tıkanmasına ve durumun daha da kötüleşmesine neden olurlar.

Bir astım nöbetini başlatan en önemli süreçler, bronş kaslarının kasılması; mukoza şişmesi (ödem); aşın ve koyu kıvamlı salgılanmasıdır.

Astım olgularının yüzde 80-90' ında, sorumlu alerjenler havayla solunan maddelerdir (pnömoalerjenler); en yaygın olanları çiçek ve bitki tozları, hayvanların üst deri oluşundan, yani kedi, köpek, keçi, at, koyun kılları ya da kepeklerin, atların yele kılları, yataklarda kullanılan yünler, kuşların tüyleri, tahıl unu, bitkisel lifler (keten, pamuk, kenevir), ev tozlarıdır.

Besinlerdeki alerjen maddeler genellikle çocuklardaki astım nöbetlerinden sorumludur, erişkinlerde daha az etkilidirler. Yaygın olarak alerji yapan besinler yumurta, süt ve süt ürünleri, et, balık ve bazı sebzelerdir (örneğin ıspanak). Ama astımı ortaya çıkaran tek etkenin besin olması çok az görülen bir durumdur [23].

2.2.4. Astımın tanısı

Tipik olgularda bronşiyal astım tanısı zor değildir. Yukarıda tanımlanan ve bu hastalığa özgü belirtilerle seyreden nöbetler, beyaz, incimsi balgam vb belirtiler hastalığın kolayca tanınmasını sağlar. Oysa tipik astım biçimlerinin tanısı daha güçtür; kalp astımı ve boğmaca gibi solunum güçlüğüne yol açan başka hastalıklarla ayırıcı tanı yapılmalıdır.

Alerjik astım tanısı açısından yararlı olan birçok yöntem vardır. Astımı başlatan alerjenlerin araştırılması, gerek deri gerekse solunum yoluyla yapılabilir. Deri testleri iki tanedir; biri iğne (prick test) ya da çizme (scratch test) ile yapılan deri tepkimesi, öteki ise deri içi (intraderma) tepkimedir. İğne testi, alerjen olduğu düşünülen maddenin derinin çizildiği noktaya verilmesidir, ikinci test ise deri içine az miktarda alerjen şırınga edilerek yapılır. Kurdeşen döküntülerine benzeyen kızarıklık (eritem) ve şişliğin görülmesi olumlu tepkime anlamına gelir; bu belirtiler 10-20 dakika içinde en yüksek düzeye ulaşır ve 1-2 saat sonra kaybolur. Kuşku olgularda sonuçlan yorumlamaya yardım eden kaşıntı da ek bir belirtidir. Antihistaminikler, kortizon ve bazılarına göre tüm anti-astmatikler bu tepkimelerin olumsuz sonuç vermesine neden olur. Bu açıdan alerjik incelemenin her tür tedavinin

kesilmesinden 26-30 gün sonra, astım nöbeti ya da hastalık belirtisi görülmeyen bir zamanda yapılması önerilir. Üç yaşın altındaki çocuklarda alerji testleri, genellikle güvenilir sonuçlar vermez.

Kanda eozinofillerin (bir akyuvar türü) sayımı tanı açısından yararlıdır. Hastalığın ara dönemlerinde bu hücrelerin sayısı genellikle yüksektir. Zarlarının gerilmesiyle kesecik içi basınç yükselmesi neden olur. Uzun erimde, akciğer amfizemi kalp ya da kalp-akciğer yetmezliğine yol açar. Bronşiyal astımın çok sık görülmeyen bir başka komplikasyonu astım nöbetleri sırasında hava kesecikleri içinde oluşan basınç yükselmesi sonucunda amfizemli alanlardaki kabarcıkların yırtılmasıyla akciğer zarı (plevra) boşluğuna hava girmesidir (pnömotoraks). Son olarak pnömoni gelişebilir; amfizemle birlikte olduğunda oldukça ağır seyreder ve kronik astımlılarda sık görülen bir ölüm nedenim oluşturur [23].

2.2.5. Astım hastalığının gidişi

Bronşiyal astımın gidişi çok değişkendir. Zamanla ve uygun tedavi sonrasında bütünüyle iyileşen hastalar sık görülmez. İlk ya da ikinci çocukluk evresinde başlayan hastalığın erişkin evrede ortadan kalktığı bazı olgular olabilir. Astım nöbetinin ürkütücü boyutlarına karşın, ölümlü sonuçlanan olguların sayısı çok azdır [23].

2.2.6. Astımın tedavisi

Astımda tedavinin iki amacı vardır:

1. Bronş kaslarının kasılmasının giderilmesi, bronş mukozasında ödemin ve mukus salgısının azaltılmasıyla astım nöbetinin denetlenmesi (semptomatik tedavi);
2. Duyarlı olunan etkenlerden (çiçek tozları, ev tozları vb) korunarak duyarsızlaştırma, ruhsal etkenlerin belirleyici olduğu olgularda ruhsal tedavi ile nedenlerin ortadan kaldırılması (özellikle tedavi).

Duyarsızlaştırma tedavisinde alerjik madde özütü giderek artan dozlarda hastaya şırınga edilir. Tedavi organizmanın söz konusu maddeye duyarlılığının ortadan kalkmasına değin sürer. Başarılı bir sonucun elde edilebilmesi için bu tedavinin en az 3-4 yıl sürdürülmesi gerekir. Bronş enfeksiyonlarıyla birlikte görülen, içsel etkenlere bağlı astım biçimlerinde en etkili koruyucu tedavi, antibiyotik tedavisidir. En uygun antibiyotikler geniş spektrumlu olanlar ve bronş kasılmalarını ağırlaştıracak yerel duyarlılık süreçlerine yol açmayanlardır.

Ruhsal tedavi özellikle çocukların bronşiyal astımlarında yararlıdır, bu çocuklarda ruhsal etkenin hastalığın en önemli nedeni olduğu ortaya konmuştur. Bu gibi durumlarda ortam değişikliklerini öngören bir tedavi yaklaşımı çok iyi sonuçlar verir. Bazı olgularda anne babanın da ruh-bilim muayenesinden geçmesi ve gerekirse tedavi görmesi gerekebilir. Anne babanın duygusal sorunları varsa bunlar çözüme ulaştırılmalıdır. Aksi durumda çocuğun kişiliğinin gelişmesi olumsuz etkilenir, hastalık şiddetlenme eğilimi gösterir. Çocuğun astımında duygusal bileşenlerin bulunmadığı, alerjik ya da enfeksiyona bağlı olduğunda bile anne baba bir psikologla görüşmelidir; böylece reddetme ya da aşırı koruyucu tavırlar geliştirmeden çocuklarının hastalığını gerçekçi bir biçimde kabullenmeleri sağlanabilir [23].

2.3. Kronik Obstrüktif Akciğer Hastalığı (KOA)

Kronik Obstrüktif Akciğer Hastalığı (KOA), zararlı partikül ve gazların kronik inhalasyonu (parçacıkların gaz ya da buhar halinde akciğerlere ulaşması) sonucu akciğerlerde oluşan anormal inflamatuvar (doku yıkımı) yanıtın neden olduğu, ilerleyici hava akımı obstrüksiyonu ile karakterize bir hastalıktır. Akciğerlerde oluşan kronik inflamasyon (doku yıkımı); büyük hava yolları, küçük hava yolları ve akciğer parankimini etkilemekte ve sonuçta kronik bronşit, amfizem ve yerleşik hava akımı obstrüksiyonu gelişimine yol açmaktadır. Genetik olarak duyarlı kişilerin uygun çevresel risk faktörleri ile uzun süre karşılaşması, hastalık gelişimine neden olmaktadır. Günümüzde sigara içme salgınının yaygınlaşmasına paralel olarak, KOA da tüm dünyada giderek ivme kazanan bir salgın haline gelmektedir [24].

KOAH dünyada önemli bir morbidite ve mortalite nedenidir. Dünya Sağlık Örgütü verilerine göre bugün dünyada 600 milyon KOAH'lı hasta bulunmaktadır ve her yıl 2.3 milyon kişi KOAH nedeniyle ölmektedir [25]. KOAH ve diğer hava yolu hastalıklarıyla ilgili mortalite hızları, ülkeler arasında büyük farklılıklar göstermektedir. Avrupa ülkelerinde KOAH, astım ve pnömoniden oluşan hastalık grubu ölüm nedenleri içinde 3. sırayı alırken, ABD'de KOAH tek başına 4. ölüm nedeni olarak izlenmektedir [26]. Bugün dünyada en sık rastlanan ölüm nedenleri içinde 6. sırada yer alan KOAH'ın, 2020 yılında 3. ölüm nedeni haline gelmesi beklenmektedir [27]. ABD'de 1966-1986 yılları arasında diğer tüm akciğer hastalıklarından (kalp hastalıkları ve serebrovasküler hastalıklar dâhil) kaynaklanan ölümlerde %22 azalma görülürken, yaşa göre düzenlenmiş ölüm hızları KOAH 'ta %71 artmıştır. Bu özellikleri ile KOAH, çoğu gelişmiş ülkede modern bir veba özelliği taşımakta ve üçüncü dünya ülkelerinde en hızla artan hastalıklar arasında yer almaktadır. Ülkemizde kesin rakamlar bilinmemekle birlikte yaklaşık 2.5-3 milyon KOAH hastasının olduğu tahmin edilmektedir [28].

2.3.1. KOAH' ın belirtileri

Nefes darlığı, öksürük, balgam çıkarma, göğüste tıkanma, hırıltılı solunum ve morarma gibi yakınmalara yol açar. Ancak bu yakınmalar ani başlayıp, kısa süren, gelip geçici bir şekilde olmayıp, aylarca, yıllarca devam eden ve giderek artan bir seyir gösterir.

Nefes darlığının dışında öksürük ve balgam çıkarma bulguları ortaya çıkar. Öksürük gündüz olduğu kadar gece de görülür ve hastanın uyumasını engeller. Ayrıca bu hastaların nefes alıp vermeleri sırasında hırıltı ve hışırtıya benzer bir ses etraftan da duyulabilir. Bazen balgam çıkarma sırasında kan gelebilir. Nefes darlığına bağlı uyku, beslenme bozulabilir ve harcanan enerji artar. Bunun sonucunda hasta kilo kaybeder ve zayıflamış, düşkün bir hale gelebilir. İleri dönemlerde ise oksijen yetersizliğine bağlı morarma, aşırı yorgunluk, güçsüzlük, kalp yetersizliği ve kalpte ritim bozuklukları görülebilir [29].

2.3.2. KOAH' ta tanı

KOAH'da tanı koydurucu yakınmalar öksürük, balgam çıkartma ve nefes darlığıdır. Risk faktörlerine maruz kalan, özellikle sigara içen kişilerde yukarıdaki yakınmalar KOAH düşündürmelidir. KOAH'dan şüphelenilmeyen hastaya KOAH tanısı koymak güçtür. Şüphelenildiğinde ise spirometrik tetkik tanı konulmasında en önemli katkıyı yapar.

KOAH'da nefes darlığının özellikleri; devamlı gelişir, özellikle egzersizde artar, her gün devam eder ve geçmeyen inatçı bir yapıya sahiptir. Hastalar tarafından hava açlığı, efora solumasında artış, aldığı havanın yetmemesi gibi tanımlanır. Öksürük çoğu kez üretkendir, bazen hastalar balgam çıkartmakta güçlük çekerler. Hastaların anemnezleri (şikayetleri) alınırken kilo kayıpları, uyku kaliteleri, ayak bileklerinin şişip-şişmediği, efora tahammülleri, halsizliklerinin olup olmadığı sorulmalıdır [30].

2.3.3. KOAH' ta risk faktörleri

KOAH'ın önlenabilirliğini tartışmak risk faktörlerinin anlaşılmasıyla mümkündür. Sigara açıkça KOAH'ın en önemli sebebidir. Hastalığın global yayılımı, sigaranın coğrafik ve demografik yayılımına uyar. KOAH prevalansı yıllar boyunca sigara içme oranlarını takip etmektedir [33]. Sigara içenlerin akciğer işlevlerindeki gerileme doz ve süre bağımlı olarak hızlanır. Bu bireylerin %15'i 40 veya 50'li yaşlarında KOAH ilişkili şikayetler geliştirirler. KOAH hastalarının %80 kadarının da sebebin sigara içimi olduğu kestirilmektedir. Kalan %20 vakada ise değişik oranlarda çevresel sigara dumanı, mesleki toz ve kimyasallar ile ev içi kirli havaya maruziyet saptanır [34]. Hava kirliliği solunum işlevlerine zarar verse de KOAH etiyojisindeki yeri kesin değildir. Kötü havalandırılmış evlerde pişirme veya ısınma amaçlı biyolojik katı yakıtlara bağlı ev içi hava kirliliği, düşük gelirli ülkelerde özellikle kadında KOAH gelişimi ile ilişkilidir [35]. Endüstriyel etmenler arasında kömür tozu, kaynak dumanı, pamuk tekstil tozu ve kadmiyumdan özellikle bahsedilebilir ancak bunların tüm hastalar açısından etkileri sigara yanında çok düşük kalmaktadır [32]. KOAH'ın sigara dışındaki diğer muhtemel sebepleri hastalık gelişiminde bağımsız risk faktörü olabilseler de önemleri sigaraya oranla çok düşük

kalır. Önem açısından sigara ile karşılaştırılabilir tek risk 1-antitripsin eksikliğidir ancak bu KOAH vakalarının %1'inden azında görülür [33]. Bir glikoprotein olan $\alpha 1$ -antitripsin inhibitörü serumdaki antiproteaz etkinliğinin çoğundan sorumludur. Otozomal resesif geçişli eksiklik ile erken başlangıçlı amfizem arasındaki ilişki bulunmaktadır. Amfizem patogenezi, akciğer matrisindeki elastin ve diğer yapısal proteinlerin akciğer nötrofilleri, makrofajları ve mononükleer hücrelerinden kaynaklanan elastaz ve diğer proteazlarla aşırı yıkımını içerir [36].

Kronik bronşitli hastalarda yapılan çalışmalarda tekrarlayan enfeksiyonları engellemek için profilaktik antibiyotik verilmesi akut atakların süresinin kısalması gibi bazı etkileri görülse de akciğer işlevlerinde düşmeyi yavaşlatmamaktadır [30,37]. Birçok çalışma kronik respiratör hastalıklardan ölüm ve yetişkin solunum işlevlerinin doğum ağırlığı ve 1 yaştaki ağırlıkla ters korelasyon gösterdiğini önermektedir. Dolayısıyla bozuk hücresel büyüme kronik solunum sistemi hastalığı gelişimi için risk faktörü olabilir [31]. Beslenme araştırmaları balık, meyve ve sebze tüketiminin koruyucu etkileri olabileceğini göstermiştir [38].

2.3.4. KOAH' ın tedavisi

KOAH tedavisinin iki ana amacı vardır. Birincisi hastalığın bulgularını düzeltmek ya da azaltmak, ikincisi ise hastalığın ilerlemesini yavaşlatmaktır. Günümüzde KOAH'ı ortadan kaldıracak, tamamen düzelterek bir tedavi seçeneği yoktur. Ancak sigaradan uzak durmak bu hastalığı çok büyük ölçüde önler.

Bu hastalığın tedavi programında şunlar yer almaktadır: sigaranın bırakılması, çevresel ve mesleki sigaraya maruz kalmanın kontrolü, uzun süreli tedavi, ani başlayan atakların tedavisi.

Hastalığın derecesine göre tedavi, akciğerlere giden hava miktarını arttırmayı sağlayan bronkodilatatör gerektirebilir. Bunlar doktor kontrolünde düzenli olarak alınması gereken bakım ilaçları ve salbutamol, terbutalin v.b gibi bulguların ve krizlerin üstesinden gelmek için alınan rahatlatıcı ilaçlar olmak üzere iki çeşittir.

KOAH'ı kontrol altına almak ve daha sağlıklı bir yaşam için anahtarlar, doğru beslenme, doktor kontrolünde yapılacak düzenli bir egzersiz programı, düzenli uyku ve sigaradan uzak ortamlardır. Ayrıca KOAH tanısı konulduktan sonra hasta, hastalığı konusunda bilgilendirilip eğitilmeli; tedaviye aktif olarak katılması sağlanmalı ve olabildiğince aktif bir yaşam sürmeye teşvik edilmelidir [39].

2.4. Pnömoni (Zatürree)

Zatürree ya da tıbbi adıyla pnömoni bakteri, virüs ve nadiren parazitlerin neden olduğu akciğer enfeksiyonu olarak tanımlanır. Akciğerde meydana gelen bu enfeksiyon, alveol adı verilen havayla dolu küçük akciğer keseciklerine iltihap hücrelerinin birikmesine ve yine bu alana kan damarlarından gelen serumun dolmasına neden olur. İçeri serum sıvısı ve iltihap hücreleri ile dolan, yani hava içeriğini kaybeden alveoller solunum işlevlerini yerine getiremezler. Eğer pnömoni yaygın ise hastada solunum yetersizliği görülebilir [40].

Pnömoniler tüm dünyada ve ülkemizde en sık görülen ve en fazla ölüme neden olan hastalıklar arasındadır. Türkiye’de beşinci sıradaki ölüm sebebidir. Özellikle, bebeklerde, çocuklarda, yaşlılarda ve bilinen başka bir hastalığı olan kişilerde pnömoniler daha ölümcül olabilmektedir. Dünyada her yıl 5 yaşın altında 10 ile 12 milyon çocuk pnömoni nedeniyle ölmektedir. Bu ölümlerin %90’ı gelişmekte olan ülkelerde olmaktadır. Ülkemizde 1-12 aylık bebek ölümlerinin %48’inden pnömoni sorumludur. Bir ile dört yaş grubunda bu oran %42’dir. Toplum kökenli pnömoni için risk faktörleri Tablo 2.1’de belirtilmiştir:

Tablo 2.1. Pnömoni oluşumunu kolaylaştıran risk faktörleri

Erişkinler	Çocuklar
İleri yaş	< 2 yaş
Müzmün (kronik) hastalıklar	Düşük doğum ağırlığı
Akciğer hastalıkları (KOAH, bronşektazi, akciğer kanseri)	Erken doğum
Kalp hastalıkları	Anne sütü ile beslenememe
Böbrek hastalıkları	Yeterli beslenememe
	D vitamini eksikliği

Tablo 2.1'in devamı.

Karaciğer hastalıkları	Düşük sosyoekonomik düzey
Şeker hastalığı	Kalabalık yaşam koşulları
Sinir sistemi hastalıkları	Sağlık hizmetlerinden yeterince yararlanamama
(Kas hastalıkları, inmeler, bunama)	Altta yatan kronik hastalıkların varlığı
Yutma güçlüğü yapan durumlar	Doğumsal kalp, akciğer hastalığı,
(çene, kas, sinir hastalıkları,	Şeker hastalığı vb
tümörler, yemek borusu hastalıkları)	Yetersiz aşılama
Bağışıklık sistemi hastalıkları	Kızamık ve boğmaca aşılarının etkin
(AIDS, kan ve lenf bezi kanserleri)	bir şekilde uygulanmaması
Sigara kullanımı	Başta sigara olmak üzere hava kirliliği
Alkol alımı	Kış mevsimi
Kusmalar	Anne yaşı ve eğitimi
Geçirilmiş uzun süren ameliyatlara	
Grip salgınları	

Bazı pnömoni türlerinde hasta kişiden sağlam kişilere doğrudan bulaşma riski vardır. Ama hastalık çoğunlukla, hastanın kendi ağız, boğaz veya sindirim kanalında bulunan mikropların akciğere ulaşmasıyla meydana gelmektedir. Normal durumlarda hastalığa neden olmayan bu mikroplar, vücut savunması zayıf düşmüş kişilerde pnömoni oluşturur. Dolayısıyla pnömoninin ortaya çıkmasında bulaşmadan çok, kişinin vücut direncini kıran risk faktörleri rol oynar. Pnömoniye zemin hazırlayan grip ve benzeri viral solunum yolu enfeksiyonları ise çok bulaşıcıdır. Hapşırık ve öksürükle yayılabildikleri gibi, ağız ve burun sekresyonlarıyla bulaşmış bardak, mendil, çatal-kaşık, kapı kolu gibi eşyalar aracılığıyla diğer kişilere geçebilirler.

2.4.1. Pnömoni belirtileri

Pnömoni genellikle ateş, boğaz ağrısı gibi üst solunum yolu enfeksiyonu belirtilerini takiben başlar ve hastalarda bu belirtilerden 2-3 gün sonra yüksek ateş, titreme, hızlı soluk alıp verme, halsizlik, öksürük, balgam çıkarma, nefes almakla batıcı tarzda göğüs ağrısı ve hastalığın ciddiyeti ile ilişkili olarak nefes darlığı, siyanoz gibi semptomlar ortaya çıkar. Anormal seyirli pnömonilerde baş ağrısı, karın ağrısı, bulantı, kusma, ishal gibi belirtiler de olabilir. Hastaların birçoğunda dudak ve dudak çevresinde uçuk görülebilir.

Çocuklarda pnömoni belirtileri çocuğun yaşına ve pnömoniye yol açan etkene göre değişim gösterebilir. Pnömonili çocuklarda bazen tek bulgu hızlı soluma olabilir. Pnömoni akciğerlerin karna yakın alt kısımlarını etkilediğinde, solunum sistemi ile ilgili hiçbir bulgu olmaksızın çocuklarda sadece ateş, karın ağrısı ve kusma şikâyeti olabilir [40].

Çocuklarda pnömoni belirtileri: ateş, titreme, öksürük, balgam, hızlı soluma, nefes darlığı, çekilmelerin varlığı (göğüs kafesinin altındaki ve kaburgaların arasındaki kasların her nefes alma ile içeri çekilmesi), göğüs ağrısı, baş ağrısı, kas ağrısı, azalmış aktivite, büyük çocuklarda iştah azlığı ya da küçük çocuklarda beslenememe, kusma, karın ağrısı, nadiren dudaklarda ve tırnaklarda morarma.

2.4.2. Pnömoninin tanısı

Pnömoni ihmal edilmemesi gereken bir sağlık sorunudur. Erken teşhis edilmesi ve gecikmeden tedaviye başlanmasının ölümleri azalttığı bilinmektedir. Hastanın yakınmaları pnömoniye uyumlu ise, genellikle yapılan muayene ve akciğer röntgenindeki bulgularla teşhis konulabilir. Gerekli durumlarda kan ve balgam tahlilleri yapılabilir.

Yukarıdaki belirtilerle hekime başvuran hastada fizik muayenede saptanan yüksek ateş, ağız çevresinde herpes enfeksiyonlarına bağlı uçuk; dinlemede akciğerde pnömoniye özel solunum seslerinin duyulması gibi bulgular hekimi pnömoni tanısına yöneltir. Pnömonili hastalarda sedimantasyon hızı ve kandaki lökosit sayısının arttığı saptanır ve nihayet akciğer grafisinde görülen bazı değişiklikler ile yukarıda sayılan klinik bulguların ışığında pnömoni tanısına ulaşılır [40].

2.4.3. Pnömoninin tedavisi

Pnömoni tanısı konulan hastada hekim öncelikle hastanın klinik, radyolojik ve laboratuvar bulgularına dayanarak tedavinin evde mi yoksa hastane koşullarında mı yapılacağına karar verir.

Aşağıdaki kriterlerden birinin varlığında hasta hastane koşullarında tedavi edilmelidir.

1. 65 yaş üzeri hasta,
2. Kronik akciğer, kalp veya böbrek hastalığı varlığı,
3. Alkolizm veya madde bağımlılığı,
4. Evde 3 günlük antibiyotik tedavisine yeterli yanıt alınamayışı,
5. Bilinç bozukluğu,
6. Aşırı tansiyon düşüklüğü,
7. Akciğer grafisinde yaygın pnömoniye ilişkin bulguların varlığı,
8. Lökosit sayısının çok yüksek ya da çok düşük oluşu,
9. Tabloya plörezinin eşlik etmesi,
10. Böbrek yetersizliği tablosu gelişmesi,
11. Aşırı kansızlık,
12. Solunum sayısının çok artması,
13. Siyanoz varlığı

Yukarıdaki kriterleri taşımayan, genel durumu iyi olan genç hastalarda yakın takipte kalmak şartıyla evde antibiyotik tedavisi ve istirahat önerilir. Kullanılacak antibiyotiğe pnömoninin klinik bulguları ve olası etken mikroorganizma türüne göre hekim karar vermelidir. Yetersiz antibiyotik kullanımları tablonun ağırlaşmasına neden olabilir. Tedavinin ilk 3-5 günü içerisinde ateş düşer, diğer belirtiler geriler ve hastalık genellikle 1-2 haftada tam olarak iyileşir.

Pnömoni bazı olgularda tümör ya da yabancı cisim gibi bronşta tıkanmaya neden olan bir süreç arkasındaki akciğer alanında ortaya çıkabilir (obstrüktif pnömoni). Bu tür olgular genellikle antibiyotik tedavisine kısmi direnç gösterebilirler ancak bazen de uygulanan tedavi ile pnömoni ve pnömoninin röntgen bulguları tamamen düzelebilir ve altta yatan hastalık gözden kaçırılabilir. Bu nedenle özellikle sigara kullanan 40 yaşından büyük hastalarda tedavi sonrası bronkoskopik değerlendirme ile bronş içi tıkaçıcı bir hastalık olup olmadığı kontrol edilmelidir [40].

2.5. Tüberküloz (Verem)

Tüberküloz binlerce yıldır var olduğu bilinen bir mikropla oluşmaktadır; bu mikrobun adı: *Mycobacterium tuberculosis*'dir. Tüberküloz mikrobu vücuda girdikten sonra aylarca-yıllarca hastalık yapmadan kalabilir. Bu dönemde vücut tarafından oluşturulan savunma yanıtları, mikropları aktif olmayan bir şekilde tutarlar. Vücuttaki tüberküloz mikropları aktif hale gelirse hastalık yaparlar. Hastalık ciddidir. Tedavi edilmediği sürece, tuttuğu organda ya da organlarda hasar yapar, bu hasar giderek artar ve öldürücü olabilir.

Tüberküloz hastalığı, en çok akciğerleri tutar. Hastalığın tuttuğu diğer organlar, lenf bezleri, akciğer zarları, kemikler, böbrekler, beyin zarlarıdır. Vücudun hemen bütün organlarında hastalık yapabilir. Hastalanan organlarda ağır bir iltihap olur, erimeler görülebilir. Organların çalışması bozulur.

Mikropların vücuda girdikten sonra hastalık yapma süresi farklılıklar gösterir. Vücut direnci düşükse, hızla hastalık gelişebilir. Ya da yıllar sonra hastalık gelişebilir. Mikrop alıp enfekte olanlardan yüzde onu yaşamlarının herhangi bir döneminde hastalanırlar.

Tüberküloz, dünyada ciddi bir halk sağlığı sorunudur. Bütün kıtalarda, bütün ülkelerde tüberküloz vardır. Günümüzde hala tek mikrobun yaptığı en çok öldüren bulaşıcı hastalıktır. Yılda 8,9 milyon insan bu hastalığa yakalanırken 1,7 milyonu ölmektedir. Dünyadaki bütün hastalıkların yüzde 2,5'ünü ve önlenemez ölümlerin yüzde 26'sını oluşturmaktadır. Dünya Sağlık Örgütü, verem hastalığı için "Acil Durum" ilan etmiştir. Dünyada verem hastalarının sayısı yıllar içinde artış göstermektedir.

Dünyada tüberküloz en çok Güney-Doğu Asya ve Sahra Güneyi Afrika'da bulunmaktadır. Hindistan, Çin ve Endonezya'da Dünya'daki hastaların yarısı bulunmaktadır. Toplam 22 ülkede, dünyadaki tüberküloz hastalarının yüzde 80'i bulunmaktadır.

Ülkemizde tüberküloz hastalığı, bu yüzyılın ilk yarısında çok büyük bir salgın yapmıştı. Bir numaralı ölüm nedeni idi. 1940'lı yıllarda her yıl bin kişiden 2-3'ü

verem nedeniyle ölüyordu. Özellikle yirminci yüzyılın üçüncü çeyreğinde yürütülen yoğun verem savaşı çabaları sonucunda durum değişmiştir. Tüberküloz artık önemli bir ölüm nedeni değildir.

Verem savaşı dispanserlerinde kayıtlı hasta sayısı 2000 yılında 18.038 iken 2005 yılında 20.535'dir. Kayıtlı hastalar dışında, resmi ve özel hekim ve hastanelerde de tedavi edilen bazı hastaların olduğunu biliyoruz. Türkiye'de yılda yaklaşık 25 bin tüberküloz hastasının ortaya çıktığını tahmin edebiliriz. Bu hasta sayılarının nüfusa oranı, sanayileşmiş ülkelerde yüz binde 20 ve altında, Asya ülkelerinde yüz binde 100'den, Afrika'da sahra güneyi ülkelerde ise 300'den fazladır. Ülkemizde ise kayıtlı hastalar yüz binde 27'dir [41].

2.5.1. Tüberkülozda tanı

Tüberküloz tanısı, balgamda verem mikrobunun gösterilmesi ile konulur. Hastanın yakınmaları ve akciğer film bulguları ile hastalıktan şüphelenilir. Hastalarda şu yakınmalar olabilir: iki haftadan uzun süren öksürük, ateş, gece terlemesi, göğüs ağrıları, iştahsızlık, zayıflama (kilo kaybı), çocuklarda kilo alamama da olabilir, halsizlik, kan tükürme.

Yakınmalar genellikle hafif başlar ve yavaş ilerler. Bu nedenle, birçok hasta doktora başvurmakta gecikir. Bazıları da yakınmalarını sigara ya da başka bir nedene bağlar. Doktora başvuru gecikince, hastalık akciğerleri ya da tutulan diğer organları tahrip eder. Yanlış teşhis ve yanlış tedaviler de hastalığın ilerlemesine neden olur; aynı zamanda çevresine mikrop saçmayı sürdürmesine yol açar. Özellikle öksürük ve diğer yakınmaları olan hastaların gecikmeden verem savaşı dispanseri ya da göğüs hastalıkları uzmanına başvurmaları gerekir.

Hastanın yakınmaları ve akciğer film bulguları hastalıktan şüphelenmeyi sağlar. Şüphelenilen hastalarda kesin tüberküloz tanısı mikroskopta basilin gösterilmesi ve besiyerinde basilin üretilmesi ile konulur. Hastadan alınan balgam ya da nadiren diğer örnekler bu amaçla laboratuarda incelenir ve tanı kesinleştirilir. Verem savaşı dispanserlerinde tanı işlemleri, tedavi, ilaçlar ve takip ücretsizdir [42].

2.5.2. Tüberkülozda bulaşma

Tüberküloz hastalığı, Mycobacterium tuberculosis basili tarafından oluşturulur. Tüberküloz hastasından hava aracılığı ile sağlam kişiye bulaşır. En bulaştırıcı olan hastalar balgam mikroskopisinde ARB pozitif olan akciğer ve gırtlak tüberkülozlu hastalardır. Yayma negatif tüberkülozlu hastaların bulaştırıcılığı çok daha azdır [43]. Hasta ile yakın ve uzun süreli teması olan kişilere bulaşma riski fazladır. Bunlar, aile bireyleri, aynı evi paylaştığı arkadaşları, işyeri arkadaşları olabilir. Kaviteli hastalıkta, gırtlak tüberkülozunda, fazla öksürmekle, aksırıkla, öksürük yaratan işlemlerde tüberküloz hastası daha fazla basil saçır. Bazı mikropların daha fazla bulaştırıcı olduğu gösterilmiştir [44].

Çeşitli solunum manevralarının havada partikül (aerosol) oluşturma potansiyeli farklıdır. Konuşma ile 0-210, öksürme ile 0 - 3.500 ve hapşırma ile 4.500 - 1.000.000 partikül oluşur [45]. Bu nedenle öksürme ve hapşırma sırasında hastaların ağızlarını kâğıt ya da bezden bir mendille kapatmaları istenmelidir.

Etkili tedavi ile ilk günlerde basil sayısı hızla azalmakta [46], bunun yanında öksürük sıklığı da azalmaktadır [47]. Hastaların bulaştırıcılığı, etkili tedavi ile 2-3 haftada pratik olarak sona erer. Bu nedenle, Tüberkülozlu hastayı hemen izole etmek ve etkili tedaviye başlamak önemlidir. Tüberküloz basilinin akciğerlere yerleşip çoğalabilmesi için alveollere kadar ulaşması gerekmektedir. Bu da ancak hasta kişiden solunum ile havaya saçılan damlacık çekirdeklerinde asılı halde bulunan basillerle mümkün olabilmektedir. Çapları yaklaşık 1-10 mikron olan partiküller alveollere ulaşır, fakat 1-3 mikron olanlar daha yüksek oranda ulaşır. Yaklaşık 1 mikron çaplı partiküller havada birkaç saat asılı kalabilmektedir. Yapılan deneysel araştırmalar, tüberküloz basilinin tozla, toprakla, hastaların eşyalarını kullanmakla ya da aynı kaptan yemekle bulaşamayacağını göstermiştir.

İlaça-dirençli TB da bulaştırıcıdır. Birinci grup ilaçlarla yapılan tedavi etkisiz olursa bulaştırıcılık devam edecektir [48]. Akciğer dışı TB genellikle bulaştırıcı değildir, fakat otopside [49] ve doku ile [50] yapılan çalışmalarda aerosol oluşturulursa bulaşma görülebilmektedir.

2.5.3. Tüberkülozda tedavi

1950'den önce tüberküloz için etkin bir tedavi bulunmamaktaydı. Akciğer tüberkülozlu olguların yaklaşık %50'si 2 yıl içinde ölmekte, ¼'ü iyileşmekte kalan ¼'ü ise kronik hastalıkları ile yaşamlarını sürdürmekte idi. Bu dönemde uygulanan sanatoryum tedavisi ilerlemiş olgulara etkisizdi. 1950'lerin ortalarında hastaların ilaç tedavisi ile hemen tamamı tedavi edilebilir hale gelmiştir. Günümüzde eğer hastaya doğru bir tedavi şeması önerilir ve hasta da bu şemayı uygun bir şekilde uygularsa hemen tüm hastalar tedavi edilebilir hale gelmektedir.

Tedavinin amaçları: hastaları kısa sürede iyileştirmek, aktif hastalık ve onun komplikasyonları nedeniyle oluşabilecek ölümleri önlemek, akciğerde oluşabilecek yaygın hasarı önlemek, kazanılmış ilaç direnci gelişimini önlemek, tam olarak tedavi edilen hastalarla onların ailelerini ve toplumun hastalıktan korunmasını sağlamak şeklinde sıralanabilir.

Tablo 2.2. Tedavi rejimlerine göre ölüm, kronik basil taşıyıcılığı ve şifa oranları.

Uygulanan tedavi	Ölüm	Kronik Basil Taşıyıcılığı	Şifa
Tedavi yok (<1950)	%40	%30	%30
Kütlesel kemoterapi Az gelişmiş ülkeler	%10	%25	%65
Bireysel kemoterapi Gelişmiş ülkeler	%05	%03	%92

Tablo 2.2' de görüleceği gibi hiç bir tedavinin verilmediği dönemler göre yetersiz tedavinin verildiği ülkelerde hastalıktan ölümler azalmakta, fakat kronik basil saçan hastaların oranları artmaktadır. Hatta bu kez sağ kalan bu hastalar, kullanılan bu ilaçlardan bir veya birden fazlasına dirençli hale gelmektedir. Bu durum ilgili ülkelerde tüberküloz sorunun daha da ağırlaşmasına yol açmaktadır. Bu sorunu yenebilmek için günümüzde, tüberküloz tanısı konularak tedaviye başlanan her hastaya doğrudan gözlem altında kısa süreli tedavi rejimleri uygulayarak sorunun aşılması hedeflenmektedir.

Kullanılan İlaçlar kullanım önceliğine göre çeşitli kategorilere ayrılmaktadır. "Birinci seçenek ilaçlar" arasında INH, RIF, PZA, SM, EMB gelmektedir. EMB dışındakilerin hepsi bakteri yok edicidir. Toksin etkileri azdır ve kombine olarak kullanılırsa mükemmel bir etkiye sahiptirler. Günde tek doz olarak uygulanırlar. Çünkü etkilerinde sabit kan düzeyinden çok en yüksek serum konsantrasyonları önemlidir.

İkinci seçenek ilaçlar: Sikloserin, etionamid, tioasetozon, kanamisin, kapreomisin ve PAS şeklinde sıralanmaktadır. Bu ilaçlar birinci seçenek ilaçlara göre daha toksik, daha az tolere edilebilen ve daha az etkili ilaçlardır. Hastanelerde ve deneyimli hekimlerce kullanılması uygun olan ilaçlardır. Genellikle dirençli tüberküloza sahip hastalarca kullanılırlar. Bu ilaçlar özellikle dirençli tüberküloz olgularında faydalı olacağı düşünülmektedir [42].

Tedavinin 5 ana özelliği aşağıdaki gibi sıralanabilmektedir.

1. Her aktif tüberküloz olgusuna mutlaka tedavi uygulanmalıdır.
2. Tedavi kombine olmalıdır.
3. Tedavi uzun süreli olmalıdır.
4. İlaçlar yeterli dozda ve düzenli olarak alınmalıdır.
5. İlaçlara karşı primer ve sekonder direnç araştırılmalı ve basilin duyarlı olduğu ilaçlar kullanılmalıdır.

2.6. Akciğer Kanseri

Akciğer kanseri, akciğer dokularındaki hücrelerin kontrolsüz çoğaldığı bir hastalıktır. Bu kontrolsüz çoğalma, hücrelerin çevredeki dokuları istila etmeleri veya akciğer dışındaki organlara yayılmaları ile (metastaz) sonuçlanabilir. Dünya Sağlık Örgütü'nün (WHO) raporuna göre akciğer kanseri tüm dünyada kanser türleri arasında, erkeklerde en sık ölüme neden olan birinci, kadınlarda ise ikinci kanser türüdür ve tüm dünyada her yıl yaklaşık 1,3 milyon insanın ölümüne neden olmaktadır [51]. Dünyada tüm kanserlerin %12,8'sini, kanser ölümlerinin %17,8'sini akciğer kanseri oluşturur. Tüm dünyada global olarak insidans her yıl %0,5 artmaktadır.

Akciğer kanseri önemli bir sağlık problemi ve Türkiye’de en sık görülen kanser türüdür. Ülkemizde toplamda ve erkeklerde en sık görülen kanser tipidir. Yıllık insidans erkeklerde: 100.000’de 61.6, kadınlarda: 100.000’de 5.1’dir. Erkeklerde tüm kanserlerin %38.6’sını, kadınlarda ise %5.2’sini oluşturur.

2.6.1. Akciğer Kanserinin Nedenleri

Akciğer kanseri, etiolojisinde çok sayıda faktörün rol oynadığı bir hastalıktır. Sigara, hava kirliliği gibi çevresel faktörler, mesleki karsinojenler, diyet, viral enfeksiyonlar, geçirilmiş akciğer hastalıkları, genetik ve immünolojik faktörler başlıca etiolojik faktörlerdir [53,54]. Sigara akciğer kanseri gelişiminden sorumlu en önemli faktördür. Hastaların % 85-94’ünde kanser gelişiminden sigara sorumludur. Sigara içenlerde içmeyenlere göre akciğer kanseri gelişme riski 24-36 kat daha fazladır [52,53]. Pasif sigara içiminde ise risk % 3,5’tir [53]. Çeşitli organik ve inorganik maddeler ile temasın akciğer kanseri riskini arttırdığı bilinmektedir. Bu mesleki karsinojenler arasında, arsenik, polisiklik aromatik hidrokarbonlar, nikel, kadmiyum, krom, mustard gazlar, klorometil ether ve klorometil metil eter, radyasyon, vinil klorid, demir-çelik, asbest, berilyum, silika, formaldehid sayılabilir [53-55]. İç ve dış ortam hava kirliliği, çevresel sigara maruziyeti, dizel yakıtların atıkları ile petrokimyasal atıklar akciğer kanseri gelişiminde rol oynayan en önemli çevresel faktörlerdir [53-56]. Diyet, akciğer kanseri gelişiminde rol oynayan diğer bir faktördür. A vitamini ve Beta-karotenden fakir diyet akciğer kanseri riskini artırır. E vitamini ve selenyum kanser gelişme riskini azaltmaktadır [53,54]. Akciğerde skar gelişimine yol açabilen tüberküloz, interstisyel akciğer hastalığı, bronşektazi, pnömoni ve abse gibi hastalıklar akciğer kanseri gelişme riskini arttırmaları. Kronik obstrüktif akciğer hastalığı varlığında da bu risk yükselmektedir [53,54,58,59]. Kanserli hastaların birinci derece yakınlarında kanser riski yükselmektedir [53,54].

2.6.2. Akciğer kanserinde tarama ve erken tanı

Akciğer kanserli hastaların erken evrede saptanabilmesi amacı ile riskli gruplara tarama yapılması fikri ortaya atılmıştır. Bu amaçla balgam sitolojisi, akciğer grafisi ve düşük doz bilgisayarlı tomografi yöntemleri kullanılarak yakınmasız olgulara tarama uygulanmıştır. Çalışmaların sonuçları, yakınmasız hastalara bu yöntemlerle tarama yapılmasını önermemektedir [60].

2.6.3. Akciğer kanserinde tanı

Semptom ve Bulgular: Akciğer kanserli hastaların % 90'ından fazlası başvuru sırasında yakınma tanımlar. Bir çalışmada akciğer kanserli hastaların sadece % 6'sının yakınmasız olduğu, % 27'sinin primer tümör ile ilişkili yakınmalar, % 27'sinin iştahsızlık ve kilo kaybı gibi nonspesifik sistemik yakınmalar ve % 32'sinin ise metastaz düşündürülen yakınmalar tanımladığı rapor edilmiştir [61]. Akciğer kanserli hastalarda saptanan yakınmalar ve bulgular 4 grupta toplanmaktadır [53,61].

1. Primer Tümör ile İlişkili Yakınma ve Bulgular: Öksürük, nefes darlığı ve tükürükte kan bulunması en sık saptanan primer tümörle ilişkili yakınmalardır. Tümör hastalarda hava yolu obstrüksiyonuna yol açarak hırıltı, lokalize horultu, atelektazi, pnömoni, abse gibi bulgulara neden olabilir. Bu durumda, bu klinik tablolarla ilişkili yakınma ve bulgular ortaya çıkabilir [53,61].

2. İntratorasik (Göğüs içi) Yayılıma Bağlı Yakınma ve Bulgular: Akciğer kanserinin intratorasik yayılımı direkt uzanım ve lenfatik yayılıma bağlı olarak oluşur. Bu yayılım sonucu sinirler, göğüs duvarı ve plevra, vasküler yapılar ve toraks içi organlar tutulur. Sinir tutulumu sonucu ses kısıklığı, diyafragma paralizi, Horner Sendromu, kolda güçsüzlük, el kaslarında atrofi, göğüs duvarı ve plevra tutulumu sonucu göğüs ağrısı, plörezi ve buna bağlı nefes darlığı, vasküler yapıların tutulumu sonucu Vena Kava Superior Sendromu, kalp tamponadı ve özafagus tutulumu sonucu disfaji gibi yakınmalar ve bulgular meydana gelebilir [53,61,62].

3. Göğüs Dışı Metastazlara Bağlı Yakınma, Bulgu ve Laboratuar Testleri: Akciğer kanserli hastaların yaklaşık 1/3'ü başvuru sırasında göğüs dışı yayılıma bağlı yakınma ve bulgulara sahiptir. Uzak metastazların en sık olduğu bölgeler kemikler, karaciğer, beyin, böbreküstü bezleri, deri ve lenf bezleridir [61]. Lokalize kemik ağrısı, serum kalsiyum ve alkalen fosfataz yüksekliği kemik metastazını düşündüren bulgulardır. Böbreküstü metastazı düşündürecek spesifik bir yakınma veya bulgu yoktur. Serum transaminaz düzeylerinde yükseklik, epigastrik bölgede hassasiyet ve ağrı, iştahsızlık varlığında karaciğer metastazı düşünülmelidir. Beyin metastazı, başvuru sırasında hastaların % 10'unda saptanır. Baş ağrısı, bulantı-kusma, kişilik değişiklikleri, fokal nörolojik bulgular, denge kusuru, konfüzyon beyin metastazlı hastalarda saptanan bulgu ve yakınmalardır. Kilo kaybı ve anemi gibi bulgular uzak organ metastazı düşündürecek diğer bulgulardır [45,53].

4. Paraneoplastik Sendromlar: Bu bulgular akciğer kanserli hastaların % 10'undan fazlasında görülür. Paraneoplastik sendromlar, metastatik hastalık veya primer tümörle direkt ilişkisi olmayan bulgu ve yakınmaları kapsar. Akciğer kanseri ile ilişkili paraneoplastik sendromlar, endokrin (hiperkalsemi, uygunsuz ADH salınımı, Cushing Sendromu vb.), nörolojik (Lambert-Eaton Sendromu, ensefalomyelit, nöropati vb.), metabolik (hipoürisemi, hiperamilazemi vb.), renal (glomerülonefrit, nefrotik sendrom), hematolojik (trombositoz, lökositoz, eozinofili vb.), iskelet (hipertrofik osteoartropati, çomak parmak), kollajen-vasküler (dermatomyozit, vaskülit, SLE, polimiyozit), cild (Sweet Sendromu, Bazex Sendromu, hipertrikoz, eritrodermi vb.), koagülopati (DIC, tromboflebit vb.), diğer (ateş, kaşeksi vb.) olarak gruplandırılabilir [53,61,62]. Akciğer kanserli hastalarda saptanan yakınma ve bulguların sıklığı Tablo 2.3'de özetlenmiştir [61].

Radyolojik inceleme: Akciğer kanserinde radyolojik görüntülemenin amaçları, tümör tanısının konulması ve tümörün evrelendirilmesidir. İlk seçilecek radyolojik yöntem iki yönlü akciğer grafisidir. Akciğer grafisinde kör noktalar olarak tanımlanan bazı bölgeler vardır. Spiral toraks bilgisayarlı tomografi, akciğer kanseri tanısında yardımcı olan diğer bir radyolojik görüntüleme yöntemidir. Spiral toraks bilgisayarlı tomografi, magnetik rezonans ve PET incelemeleri özellikle akciğer kanserinin evrelendirilmesinde kullanılan görüntüleme yöntemleridir [53].

2.6.4. Hastalığın evrelendirilmesi

Yapılan tetkikler sonucu hastada kanser saptanırsa doktor hastalığın hangi evrede olduğunu öğrenmek isteyecektir. Bu evrelendirme kanserin yayılıp yayılmadığını yayılmış ise vücudun hangi bölgesine yayıldığını bulmak için yapılır.

Akciğer kanseri genellikle beyin ve kemiklere yayılır. Hastalığın evresini bilmek doktorun tedaviyi planlamasına yardımcı olur. Kanser yayılıp yayılmadığını bulmak için kullanılan bazı tetkikler şunlardır:

1. Bilgisayarlı tomografi
2. Magnetik Rezonans İncelemesi
3. Kemik sintigrafisi; Kanser kemiklere yayılıp yayılmadığını gösterir. Az bir radyoaktif madde kan dolaşımına verilir ve anormal kemik gelişimi olan yerde toplanır. Tarayıcı denilen alet bu alanlardaki radyo aktif seviyesini ölçer ve bunu röntgen filmine kaydeder.
4. Mediastinoskopi / Mediastinotomi: Mediastinoskopi kanserin göğüsteki lenf düğümlerine yayılıp yayılmadığını gösterir [63].

2.6.5. Akciğer kanserinde tedavi

Tedavi birçok faktöre bağlıdır. Bunlar akciğer kanserinin tipi, hastalığın evresi ve hastanın genel sağlık durumudur. Birçok değişik tedaviler ve tedavi kombinasyonları tedavide kullanılır.

Ameliyat sonrası gözle görünür, tespit edilecek düzeyde kanseri kalmayan hastalara verilen ek tedaviye adjuvan tedavi denir. Adjuvan tedavi ameliyat sonrası gözle görülmeyen ancak geride kalmış olması muhtemel az sayıdaki kanser hücrelerini öldürmek amacıyla verilir. Adjuvan tedavi verilip verilmeme kararı patoloji raporundaki özelliklere, hastanın yaşına ve genel durumuna göre belirlenir. Hastalar ameliyat sonrası adjuvan tedavi olarak sadece kemoterapi veya sadece radyoterapi veya hem kemoterapi hem radyoterapi tedavisi alabilirler. Bazen, çok erken evrede olan hastalarda ameliyat sonrası adjuvan tedavi gerekmez.

Cerrahi: Kanseri yok etmek için yapılan operasyondur. Cerrahi müdahalenin tipi kanserin akciğerdeki yerleşimine bağlıdır. Akciğerdeki küçük bir parçayı almak için yapılan operasyon 'wedge' veya 'segmental' rezeksiyon olarak adlandırılır.

Eğer cerrahi olarak tüm lob alınır (lobektomi), sağ veya sol akciğerin biri alınır (pnomonektomi) olarak adlandırılır. Bazı tümörler yerleşimi, büyüklüğü ve hastanın genel sağlık durumu nedeniyle ameliyat edilemez.

Kemoterapi: kanser hücrelerinin ilaçlarla öldürülmesidir. Genellikle birden fazla ilaçtan oluşur. Kemoterapiyi yalnız bu konuda özel eğitimi olan hemşireler verir. Kemoterapinin verilme sayısı kür diye ifade edilir (1. kür, 2. kür gibi) ve genellikle aynı ilaçlar 21 veya 28 günde bir tekrarlanarak verilir. Kemoterapi çoğunlukla damardan sıvı şeklinde ayaktan tedavi merkezlerinde veya ağızdan hap olarak verilir. Bazen hastanın genel durumundaki bozukluk, verilen ilaçlar veya ilaçların verilmiş şekillerine göre hastaların tedavilerini hastanede yatarak almaları gerekebilir. Her kür sonrası hastalar medikal onkoloji polikliniğinde kontrol edilirler. Bu kontrollerde hastalar muayene edilir, şikâyetleri dinlenir, ilaçların yan etkileri sorgulanır ve vücuttaki diğer organlara bir zarar verip vermediğini araştırmak için bazı kan tetkikleri istenir. Her kür öncesi kan sayımının yapılması ve bu sayımın kemoterapiyi veren yetkili hemşirelere gösterilmesi gerekmektedir. Bir hastanın ameliyat sonrası kemoterapi alıp almayacağını, eğer alacaksa kaç kür alacağını patoloji raporundaki tümöre ait özellikler belirler. Ancak bu kararların verilmesinde hastanın yaşı, genel durumu da önemli rol oynar.

Bir gün içinde 12 saatten fazla zamanını yatarak geçirecek kadar genel durumu kötü olan hastalara kemoterapi verilmesi, yan etkilere tahammül edemeyeceklerinden uygun değildir. Kemoterapi yapılması planlanan hastalar, ameliyat olmuşlarsa ameliyattan sonraki 3 hafta içinde kemoterapinin başlanması tercih edilir.

Kemoterapi alan hastalar her kemoterapiden yaklaşık bir hafta kadar sonra medikal onkoloji polikliniğinde doktor kontrolünden geçmelidir. Bu kontrolde hastalar muayene edilir, şikâyetleri dinlenir, kemoterapinin yaptığı yan etkiler değerlendirilerek gerekirse ilacın dozunda yeniden ayarlama yapılır.

Işın tedavisi: Aynı zamanda radyoterapi de denir. Kanser hücrelerini öldürmek için yüksek enerjili ışınlar kullanılmasıdır. Sınırlı her alana uygulanır ve bu alandaki kanser hücrelerini etkiler. Radyoterapi bir tümörü küçültmeye yönelik olarak cerrahiden önce veya kanser hücrelerini yok etmek için yapılan bir müdahaleden sonra uygulanabilir. Doktorlar radyoterapiyi genellikle kemoterapi ile birlikte cerrahi tedaviye karşı birinci alternatif olarak kullanırlar. Nefes darlığı gibi belirtilerin giderilmesi için de kullanılabilir.

Foto dinamik terapi: Bu özel bir kimyasal maddenin kan dolaşımına verilmesi ve hücreler tarafından alınmasıdır. Bu kimyasal madde normal hücreleri hızla terk eder. Fakat kanserli hücrelerde daha uzun bir süre kalır. Daha sonra bu hücrelere lazer ışığı uygulanarak maddenin aktif hale geçmesi sağlanır ve hücreler öldürülür.

Küçük hücreli olmayan akciğer kanseri tedavisi: Küçük hücreli olmayan akciğer kanseri hastaları birçok değişik yolla tedavi edilebilirler. Tedavinin seçimi hastalığın yaygınlığı ile ilgilidir. Cerrahi müdahale en yaygın tedavi şeklidir. Radyoterapi ve kemoterapi de hastalığın süresini yavaşlatma ve semptomları kontrol etmede kullanılabilir.

Küçük hücreli akciğer kanseri tedavisi: Küçük hücreli akciğer kanseri hızlı yayılır. Birçok vakada hastalık tanı konduğunda vücudun diğer bölümlerine de yayılmıştır. Doktorlar vücuda yayılmış kanser hücrelerine ulaşmak için hemen hemen her zaman kemoterapi kullanırlar. Kemoterapi içeren tedavi de akciğerdeki tümörler veya vücudun diğer bölümlerindeki tümörler hedeflenerek uygulanabilirler. Bazı hastalara beyine yönelik radyoterapi orada kanser olmasa da uygulanabilir. Bu tedaviye koruyucu beyin ışınlanması denir. Bu beyinde tümör oluşmasını engellemek için verilir. Cerrahi tedavi küçük hücreli akciğer kanserinde çok az uygulanır [63].

2.6.6. Hastaların takibi ve takibin önemi

Akciğer kanseri tedavisinden sonra hastanın takibi de çok önemlidir. Düzenli kontroller sağlık durumundaki değişiklikleri ortaya çıkarır. Böylece eğer kanser

tekrarlar ya da yeni kanser oluşursa bu mümkün olduğunca çabuk tedavi edilebilir. Bu kontroller muayene, göğüs filmi ve çeşitli laboratuvar testlerini içerir. Kontroller arasında ortaya çıkan herhangi bir sağlık problemi hemen doktora bildirilmelidir.

Tedavi sonrası önerilen özel bir diyet yoktur, dengeli beslenme, fazla yağlı yiyeceklerden kaçınma, düzenli egzersiz yapmak yani normal şartlar altında her sağlıklı insanın uyması gereken kurallar sizin için de geçerlidir.

Kilo kaybı, iştahsızlık, aşırı yorgunluk, bulantı-kusma, baş dönmesi, karın ağrısı ve dolgunluk, kemik ağrısı, iki haftadan fazla süren öksürük, baş ağrısı olduğunda normal periyodik kontrol zamanınızı beklemeden doktorunuza ulaşmanız gereklidir.

Tedavi sırasında ve sonrasında cinsel yaşamınıza eskiden olduğu gibi devam etmenizde bir sakınca yoktur. Kemoterapinin yumurtalık hücreleri üzerinde olan mutajenik (bebekte ciddi anormallikler olabilmesi) etkileri nedeni ile tedavi süresince gebeliği önlemek için doğum kontrol yöntemlerinden biri tercih edilmelidir.

Tanı sonrası tedavi planı ile yaşadığınız fiziksel ve ruhsal sıkıntılar, hastalığa veya tedaviye bağlı yorgunluk, halsizlik hissi, cinsel yaşamınızın, istek ve heyecan duyma gibi duygularınızı etkileyebilir [63].

BÖLÜM 3. ESNEK HESAPLAMA YÖNTEMLERİ VE BİYOBİLİŞİM TEKNİKLERİ

3.1. Giriş

Teknolojinin ilerlemesi, çözümü karmaşık problemleri beraberinde getirmiş ve bilinen yöntemler, karmaşıklaşan bu problemlerin çözümünde yetersiz kalmaya başlayınca, farklı çözüm yolları araştırılmaya başlanmıştır. İnsanoğlu çok eskilerden beri gerek doğada gerçekleşen olaylar anlamak, gerekse bu işleyişleri taklit ederek yaşamını kolaylaştırmak üzere çoğu problemin çözümünü çoğunlukla doğada aramıştır. Bunu takiben ortaya çıkan Yapay Sistemler, özellikle 1900'lü yılların ortalarından itibaren adını sıkça duyurmaya başlamıştır [64].

Ar kolonilerindeki iletişimden, karıncalar arasındaki işbirliğinden, sinir sistemindeki işleyişten ve genetik olaylardan esinlenilerek oluşturulmuş sistemler, Yapay Sistemler adı altında örneklenebilecek sistemlerdir. Yapay sistemler içerisinde en büyük yeri, amacı insandaki kavrama, yorumlama, öğrenme gibi birçok özelliği taklit etmek olan Yapay Zekâ teknikleri kaplamaktadır. Günümüzde mühendislikte, uzay bilimlerinde, fen ve doğa bilimlerinde, tıpta ve daha birçok alanda geniş bir uygulama alanına sahip olan Yapay Zekâ tekniklerinden en sık kullanılanlar; Yapay Sinir Ağları (YSA) ve Genetik Algoritmalarıdır (GA). Özellikle YSA ile ilgili yapılan çalışmalar büyük bir hızla ilerlemiş ve bilimin birçok farklı alanında elde ettiği başarılarla ses getirmiştir.

Yapay Zekâ teknikleri arasında yeni bir sistem, Yapay Bağışıklık Sistemleri (YBS), birçok özelliği ile etkin sonuçlar elde etme anlamında umut vadeden bir sistem olarak belirginleşmektedir. Diğer Yapay Zekâ tekniklerinin ortaya çıkışında olduğu gibi YBS, gelişimini Bağışıklık Sisteminde gerçekleşen olaylar kavramaya yönelik oluşturulan Bağışıklık Sistemi modellerine borçludur. Bu modellerden yola çıkılarak

oluşturulan Yapay Bağışıklık Sistemleri kısa zamanda araştırmacıların katkıları sayesinde pek çok alanda uygulanabilirliğe yönelik çalışmalar ile gelişimine hız katmıştır [64].

Bu bölümde yerel bir hastaneden elde edilen göğüs hastalıkları verileri üzerinde sınıflandırma yöntemleri denenmiştir. Bu sınıflandırma metotları şunlardır: yapay sinir ağları, yapay bağışıklık sistemi, genetik algoritmalar, bulanık kontrol sistemleri (ANFIS). Kullanılan hesaplama yöntemleri ve algoritmalar optimize edilmiş ve başarı sağlanan algoritmalar geliştirilen yazılım uygulaması içerisine alınmıştır.

3.2. Yapay Sinir Ağları (YSA)

Yapay sinir ağları, insan beyninin nöronlardan oluşan yapısını ve öğrenme yöntemlerini inceler. 19. yüzyıldaki psikolog ve nöropsikologların insan beynini anlamaya çalışmaları Yapay Sinir Ağları'nın temelini oluşturur. Fakat bu konulardaki ilk modern çalışmalar McCulloch ve W.Pitts ile başlar.

Yapay sinir ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir. Bu yetenekleri geleneksel programlama yöntemleri ile gerçekleştirmek oldukça zor veya mümkün değildir. Bu nedenle, yapay sinir ağlarının, programlanması çok zor veya mümkün olmayan olaylar için geliştirilmiş adaptif bilgi işleme ile ilgilenen bir bilgisayar bilim dalı olduğu söylenebilir.

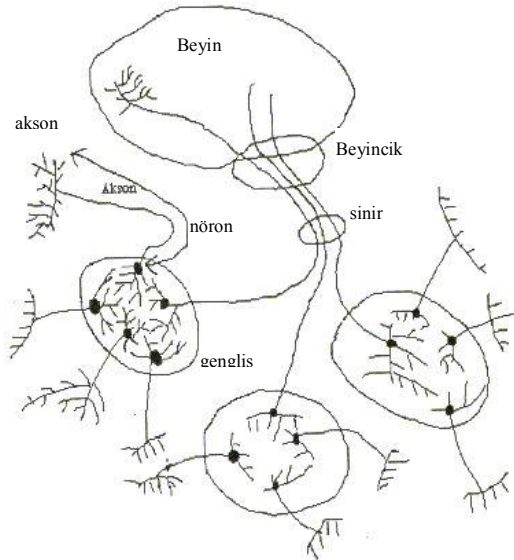
3.2.1. YSA ve insan beyni

İnsan vücudunun en önemli organlarından olan “beyin”, merkez sinir sisteminin kafatası içinde olan kısmıdır. Yetişkin bir insanda ortalama beyin ağırlığı 1360 gramdır ve bütün vücudun ağırlığının %2' si kadardır (doğuşta 1/7' si). Beyinde yaklaşık 12 milyar hücre vardır. Beyin kıvrımlarının toplam uzunluğu 500 bin kilometredir [65].

Beynin çalışma hızı 100–1000 Mhz arasında olmasına rağmen, çok karmaşık işlerde çok güçlü bilgisayarlardan daha hızlı ve doğru sonuçlar üretir. Beynin zeka ile alakalı konularda gösterdiği bu hız ve doğru sonuçlar muazzam bir yapıda organize edilmiş paralellikle izah edilir [66].

Bilim adamları ve mühendisler insan beyninin işlevinin, biyolojik yönünden daha çok bu işlevin oluşumundaki modellerle ilgilenmektedir. YSA 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. Sinir sisteminin temel yapı elemanı nörondur. Vücudun çeşitli bölümlerinden bu bölümlere bilgi ileten hücredir. İşte YSA, nöronların yoğun paralel dizisidir. YSA' ya ilginin artması, teknolojik gelişmeler oluşturmak kadar beyin nasıl çalıştığının daha ayrıntılı bir şekilde anlaşılması ihtiyacından da kaynaklanmaktadır. Bu ihtiyaç alışılmış sayısal bilgisayarlar için, çok zor olduğu düşüncesine varılan çeşitli problemleri çözecek, güçlü bir bilgisayar türünün oluşturulmasına zemin hazırlamaktadır [67].

Beyin ve Sinir Sisteminin temel yapı elemanları, Şekil 3.1' de gösterilmiştir.

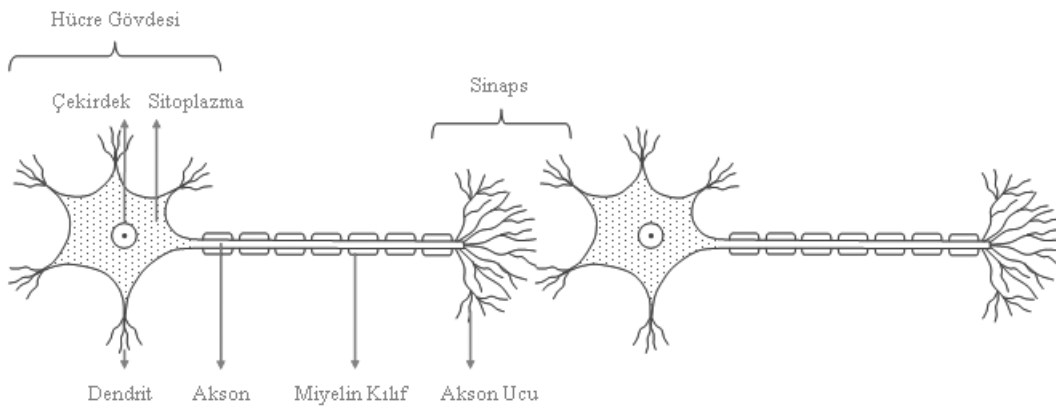


Şekil 3.1. Beyin ve sinir sisteminin temel yapı elemanları

İnsan beyinde yaklaşık 10^{11} nöron ve her bir nöronda yaklaşık 10^4 dendrit vardır. Sinir hücrelerini oluşturan dendrit, hücre gövdesi, akson ve akson uçları (sinaps) Şekil 3.2'de gösterilmiştir.

Hücrelerin tamamının bazı ortak özellikleri vardır. Nöronun bir ucunda “dentrit” adı verilen ve hücreye, diğer hücrelerden veya dış dünyadan gelen bilgileri toplayan bağlantı elemanı, diğer ucunda ise tek bir life benzer “akson” adı verilen ve hücreden diğer hücrelere ve dış dünyaya bilgi taşıyan bağlantı elemanı vardır. Akson, diğer hücrelerle birleşme esnasında dağınık dallara ayrılmaktadır. Bu iki uçtaki bağlantı noktalarının, elektrofizyolojik olarak hücrelerdeki bilgileri işlemede önemli yeri vardır.

Hücrelerin birbiri ile elektrik sinyalleri vasıtasıyla irtibat kurduğu belirlenmiştir. Sinyaller bir hücrenin akson’ undan, diğerinin dentritine gönderilir. Bir akson birden fazla dentrit ile bağlantı kurabilir. Bu bağlantıların yapıldığı yere “sinaps” denir. Hücreler, elektrik sinyalini hücre duvarlarındaki voltajı değiştirerek üretirler. Bu ise, hücrenin içinde ve dışında dağılmış iyonlar vasıtası ile olur. Bu iyonlar sodyum, kalsiyum, potasyum ve klorin gibi iyonlardır. Bir hücre, diğer hücreye elektrik enerjisini bu kimyasal iyonlar vasıtasıyla transfer eder. Bazı iyonlar elektrik ve manyetik kutuplaşmaya sebep olurken, bazıları kutuplaşmadan kurtulup hücre zarını açarak iyonların hücreye geçmesine olanak sağlar. Zaten sinyallerin bir hücreden diğerine akmasını sağlayan da bu kutuplaşmanın azalması olayıdır. Sinyaller, hücrenin etkinliğini belirler. Bir hücrenin etkinliği, hücreye gelen sinaps sayısı, sinapslardaki iyonların konsantrasyonu ve bir de sinapsın sahip olduğu güç olmak üzere üç faktöre bağlıdır.



Şekil 3.2. Örnek bir sinir hücresi

Bir hücre, sahip olduğu dürtü miktarınca diğer hücreleri etkiler. Bazı hücreler diğerlerinin dürtülerini pozitif yönde, bazı hücreler de negatif yönde etkiler. İnsan sinir ağı sistemi, bu şekilde çalışan milyonlarca hücrenin bir araya gelmesinden oluşmuştur [68].

YSA alanındaki araştırma ve geliştirmeler, beynin biyolojik yapısından esinlenip pek çok ilginç sistemler geliştirilmiştir. Bu yapıyı oluşturmada pek çok farklı bilim dalından istifade edilmiştir. Bunlara matematik, mantık, psikoloji vs. örnekleri verilebilir.

3.2.2. YSA hakkında genel bilgiler

YSA, çeşitli yollarla birbirine bağlı birimlerden oluşmuş topluluklardır. Her birim iyice basitleştirilmiş bir nöronun niteliklerini taşır. Nöron ağları sinir sisteminin parçalarında olup biteni taklit etmekte, işe yarar ticari cihazlar yapmakta ve beynin işleyişine ilişkin genel kuramları sınamakta kullanılır. Sinirsel ağ içindeki birimler, her birinin belli işlevi olan katmanlar şeklinde örgütlenmiştir ve bu yapıya “yapay sinir ağı mimarisi” denir.

Bilim adamları ve mühendisler insan beyninin işlevinin, biyolojik yönünden daha çok bu işlevin oluşumundaki modellerle ilgilenmektedir. YSA 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.

YSA’ların bağlantı, katman ve düğüm sayılarının çokluğu temsil edebilecekleri sistemin karmaşıklığını belirler. Ne kadar çok düğüm varsa o kadar karmaşık (gelişmiş) sistemler modellenebilir. Bu özellikleri ile YSA’lar klasik algoritmik yöntemlerle çözülemeyen problemleri insan beyninin çalışma sistemine benzer yöntemlerle çözmektedirler. Ancak bir YSA’nın kesinlikle (%100) doğru çalışacağı hiçbir zaman söylenemez. Çünkü o da insan beyni gibi her zaman için hata yapabilir.

YSA'nın her bir işlem birimi, basit anahtar görevi yapar ve şiddetine göre, gelen sinyalleri söndürür ya da iletir. Böylece sistem içindeki her birim belli bir yüke sahip olmuş olur. Her birim sinyalin gücüne göre açık ya da kapalı duruma geçerek basit bir tetikleyici görev üstlenir. Yükler, sistem içinde bir bütün teşkil ederek, karakterler arasında ilgi kurmayı sağlar.

YSA arařtırmalarının odağındaki soru, yüklerin, sinyalleri nasıl deęiřtirmesi gerektiğidir. Bu noktada herhangi bir formdaki bilgi girişinin, ne tür bir çıkıřa çevrileceęi, deęiřik modellerde farklılık göstermektedir. Dięer önemli bir farklılık ise, verilerin sistemde depolanma şeklidir. Nöral bir tasarımda, bilgisayarda saklı olan bilgiyi, tüm sisteme yayılmış küçük yük birimlerinin birleřerek oluşturduęu bir bütün evre temsil etmektedir. Ortama yeni bir bilgi aktarıldığında ise, yerel büyük bir deęiřiklik yerine tüm sistemde küçük bir deęiřiklik yapılmaktadır.

YSA özellikle tahmin problemlerinde kullanılabilmesi için çok fazla bilgi ile eğitilmesi gerekir. Ağların eğitimi için çeřitli algoritmalar geliştirilmiřtir.

Günümüzde sinirsel ağ uygulamaları ya geleneksel bilgisayarlar üzerinde yazılım simülatörleri kullanılarak veya özel donanım içeren bilgisayarlar kullanarak gerçekleştirilmektedir. Kredi risk deęerlemesinden imza kontrolü, mevduat tahmini ve imalat kalite kontrolüne kadar uzanan uygulamalar yazılım paketlerinden faydalanılarak yapılmaktadır.

YSA çevre şartlarına göre davranıřlarını şekillenebilir. Giriřler ve istenen çıkıřların sisteme verilmesi ile kendisini farklı cevaplar verebilecek şekilde ayarlayabilir.

Birazda YSA kavramını çekici kılan temel özelliklerden bahsedelim [69].

1. Sistemin paralellięi ve toplamsal işlevin yapısal olarak dağılımıdır. Birçok nöron eşzamanlı çalışır. Karmařık bir işlev çok sayıda küçük nöron aktivitesinin bir araya gelmesinden oluşur.

2. Genelleme yeteneđi. Ađ yapısının, eđitim esnasında kullanılan nümerik bilgilerden eşleřtirmeyi betimleyen kaba özellikleri çıkarsaması, böylelikle eđitim sırasında kullanılmayan girdiler içinde anlamlı yanıtlar üretebilmesidir.
3. Ađ fonksiyonunun nonlinear oluşudur. Yapı üzerinde dağılmıř belli tipteki nonlinear alt birimler özellikle, istenen eşleřtirmenin denetim ya da tanıtım işlemlerinde olduđu gibi nonlinear olması durumunda, işlevin dođru biçimde yerine getirilebilmesini matematiksel olarak olası kılar.
4. Sayısal ortamda tasarlanan sinir ađı yaklaşımlarının tüm devre gerçekleştirilebilirliklerinin olmasıdır. Bu da yakın gelecekte bu sistemlerin özellikle robotik uygulamalar ile birlikte düşünöldüğünde, günlün hayatta yaşam kalitesinin artırılmasında ne denli önemli bir rol oynayabileceklerine işaret eder.

3.2.3. Yapay sinir ađlarının kullanım alanları

YSA, karar verme problemlerinde sıkça kullanılan YZ tekniklerinden biridir. YSA, teorik hale getirilmiş zekâ ve beyin faaliyetlerinin matematiksel modelidir. Bu konu üzerinde konuşma, görüntü tanıma, parmak izi tanıma, el yazısı tanıma, karar verme, kontrol gibi çeřitli alanlarda insan gibi çeřitli davranış elde etmek amacıyla çalışılmaktadır [67].

Günümüzde birçok alanda YSA uygulamalarına rastlamak mümkündür. Bunlar,

1. Ses-iřaret işleme ve tanıma
2. Bilgisayar görmesi, resim işleme, karakter tanıma, örnek tanıma (pattern recognition)
3. Sistem tanılama, nonlinear denetim alanlarında
4. Veri ayrıştırma ve sıkıştırma
5. Askeri Uygulamalar: Pilot eđitiminde. Girdi olarak, bilgisayarın oluşturduđu bir uçađa farklı durumlar için örnek manevralar kullanılıp, farklı manevralar öğretilir. Böylece örnek manevralarla eđitilmiş uçak benzer durumlarda benzer manevraları yapar.

6. İmalat Yönetimi: İmalat sorunlarının belirlenmesi, iş akışını durdurmadan hem süreç hem ürün kalitesinin gerçek zamanlı ve sürekli olarak takibinde faydalanılmaktadır.
7. Optimizasyon: Hopfield ve Tank yaptıkları çalışmalarda şehirlerarası uzaklıklar hücreler arası bağlantıların ağırlıkları olarak düşünülerek, ağ eğitilerek en kısa rotayı veren çözüm bulunmuştur [70].
8. Borsa ve para yönetimi işlemleri.
9. Geleneksel yöntemlerin ve bilgisayarların yetersiz kaldığı sınıflandırma, hastalık teşhisi, veri işleme, çok duyulu makine vb. alanlarda başarılı sonuçlar verir. YSA özellikle tahmin probleminde kullanılabilmesi için çok fazla girdi ile eğitilmesi gerekir.

Bunun yanında YSA'lar özellikle öğrenme üzerinde odaklanmıştır ve lineer olmayan sistemlerde veya sisteme ait bilginin tam olmadığı, hatalı olduğu sistemlerde çözüme ulaşmak için uygundur. YSA'ların en önemli dezavantajı ise var olan bir uzman bilgisinin problem çözümüne aktarılmasındaki zorluktur.

Gelişen teknolojinin verilen örneklerle sınırlı kalmayacağı göz önüne alınmalıdır. Gün geçtikçe işlemsel akıl içeren sistemlerin yaygınlaştığı göz ardı edilmemelidir [69].

3.2.4. YSA' nın yapısı


Bu bölümde YSA' nın temel bileşenleri, özellikleri, YSA' nda kullanılan öğrenme türleri, öğrenme algoritmaları, ileri beslemeli YSA, Geri Yayılmalı (backpropagation) YSA Modelinin öğrenme adımları ve hesaplama adımları anlatılmıştır.

Temel bileşenler: Bir YSA modeli, birbirinden bağımsız ve paralel olarak çalışabilen proses elemanlarının(yapay sinir hücreleri) hiyerarşik bir şekilde organizasyonundan oluşur.

Yapay sinir hücresi, Yapay sinir Ağlarının temel elemanıdır. Diğer hücrelerden (ağın dışı da olabilir) girdiler alır. Aldığı bu girdileri işler. İşlediği bu girdileri kendisine bağlı diğer hücrelere (dış ortam da olabilir) girdi olarak verir. İlgili hücre, aynı anda birden fazla girdi alabilir. Fakat sadece bir adet çıktı üretebilir [71].

Şekil 3.3' de görüldüğü gibi yapay sinir hücresi (YSA' yı oluşturan her bir proses elemanı) 5 temel parçadan oluşur.

1. Girdi
2. Ağırlıklar
3. Toplama Fonksiyonu
4. Eşik Fonksiyonu
5. Çıktı



Şekil 3.3. Örnek bir yapay sinir hücresi

Aynen biyolojik sinir hücresi gibi, işlem elemanına birden fazla girdi gelmekte ve sadece bir çıktı gitmektedir. Girdiler, dentritlere benzer şekilde diğer yapay hücrelerden bağlantılar vasıtasıyla işlem elemanına bilgi gelmesini sağlarlar. Bazı durumlarda bir işlem elemanı kendisine de bilgi geri gönderebilir. Anlatılan bu bilgiler, elemanlar arasında bulunan bağlantı hatları üzerinde depolanır.

Her bağlantının bir ağırlığı vardır. Bu ağırlık bir işlem elemanının diğeri üzerindeki etkisini gösterir. Ağırlık büyüdükçe etki de büyür. Ağırlığın sıfır olması hiç bir etkinin olmaması, negatif olması ise etkinin ters yönde olması anlamına gelmektedir. Bu ağırlıklar sabit olabildikleri gibi değişken de olabilirler.


Toplama fonksiyonu, bir işlem elemanına gelen net girdiyi hesaplayan fonksiyondur. Net girdi, genellikle gelen bilgilerin ilgili bağlantıların ağırlıkları ile çarpılıp toplanması ile belirlenir. Bu nedenle adı, toplama fonksiyonu olarak verilmiştir. Şekil 3.3' de verilmiş olan yapay sinir hücresinin matematiksel ifadesi ise şu şekildedir [71];

$$Net = \sum_{i=1}^5 w_i \cdot x_i = w_1 \cdot x_1 + w_2 \cdot x_2 + w_3 \cdot x_3 + w_4 \cdot x_4 + w_5 \cdot x_5 \quad (3.1)$$

$$\zeta = F(Net)$$

Tablo 3.1. Pratikte en fazla kullanılan toplama fonksiyonları

Toplam : $Net_i = \sum_j w_{ij} I_j$	Çarpım : $Net_i = \prod_j w_{ij} I_j$
Maksimum : $Net_i = Max(w_{ij} I_j)$	Minimum : $Net_i = Min(w_{ij} I_j)$
Çoğunluk : $Net_i = \sum_j Sgn(w_{ij} I_j)$	Kümülatif Toplam : $Net_{yeni} = Net_{eski} + \sum_j w_{ij} I_j$
<p>Burada i, j : Proses elemanı, Net_i : Proses elemanına giren net girdi I_j : Proses elemanının çıktısı, W_{ij} : I ve J proses elemanları arasındaki bağlantının ağırlığını gösterir.</p>	



Şekil 3.4. YSA için kullanılan örnek eşik (aktivasyon) fonksiyonları

Eşik fonksiyonları, işlem elemanlarının sınırsız sayıdaki girişini önceden belirlenmiş sınırdaki çıkış olarak düzenler. En çok kullanılan dört tane eşik (aktivasyon) fonksiyonu vardır. Bunlar, lineer, rampa, basamak ve sigmoid fonksiyonudur. Şekil 3.4' de bu fonksiyonlar gösterilmiştir [70].

Çıktı ünitesi, çıktı fonksiyonunun ürettiği dürtüyü diğer işlem elemanlarına veya dış dünyaya aktarma işlevini yapar (ağların sonuçları). İşlem elemanları, ağın topolojik yapısına bağlı olarak tamamen birbirinden bağımsız ve paralel olarak çalışabilirler. Her bir süreç elemanı, sadece bir çıktı üretebilir fakat birden fazla girdiye sahip olabilir [72].

3.2.5. Yapay sinir ağlarının temel özellikleri

YSA'nın hesaplama ve bilgi işleme gücünü, paralel dağılmış yapısından, öğrenebilme ve genelleme yeteneğinden aldığı söylenebilir. Genelleme, eğitim yada öğrenme sürecinde karşılaşılmayan girişler için de YSA'nın uygun tepkileri üretmesi olarak tanımlanır. Bu üstün özellikleri, YSA'nın karmaşık problemleri çözebilme yeteneğini gösterir. Günümüzde birçok bilim alanında YSA, aşağıdaki özellikleri nedeniyle etkin olmuş ve uygulama yeri bulmuştur [73].

Doğrusal olmama: YSA'nın temel işlem elemanı olan hücre, doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen YSA da doğrusal değildir ve bu özellik bütün ağa yayılmış durumdadır. Bu özelliği ile YSA, doğrusal olmayan karmaşık problemlerin çözümünde en önemli araç olmuştur.

Öğrenme: YSA'nın arzu edilen davranışı gösterebilmesi için amaca uygun olarak ayarlanması gerekir. Bu, hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması gerektiğini ifade eder. YSA'nın karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlı olarak verilemez ya da tasarlanamaz. Bu nedenle YSA, istenen davranışı gösterecek şekilde ilgilendiği probleminden aldığı eğitim örneklerini kullanarak problemi öğrenmelidir.

Genelleme: YSA, ilgilendiği problemi öğrendikten sonra eğitim sırasında


karşılaşmadığı test örnekleri için de arzu edilen tepkiyi üretebilir. Örneğin, karakter tanıma amacıyla eğitilmiş bir YSA, bozuk karakter girişlerinde de doğru karakterleri verebilir ya da bir sistemin eğitilmiş YSA modeli, eğitim sürecinde verilmeyen giriş sinyalleri için de sistemle aynı davranışı gösterebilir.

Uyarlanabilirlik: YSA, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir ve değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu özelliği ile YSA, uyarlamalı örnek tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda etkin olarak kullanılır.

Hata toleransı: YSA, çok sayıda hücrenin çeşitli şekillerde bağlanmasından oluştuğu için paralel dağılmış bir yapıya sahiptir ve ağına sahip olduğu bilgi, ağdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir YSA'nın bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağın doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, geleneksel yöntemlere göre hatayı tolere etme yetenekleri son derece yüksektir.

Yapay sinir ağları; ses tanıma, yazılan karakteri tanıma, robot kontrolleri, resim işleme ve yüz tanıma sistemlerinde çok sık olarak kullanılmaktadır. İnsanı (özellikle insan beynini ve algı sistemlerini) modellemenin giderek öne çıktığı son yıllarda, yüz tanıma sistemlerinin önemi de giderek artmaktadır. Gelecekte hem de çok yakın gelecekte yüz tanıma sistemleri havaalanlarında, ATM'lerde, güvenlik kamerası olan yerlerde kullanılmaya başlanacaktır. Şu sıralarda birkaç havaalanında ve şirkette deneme aşamasında olan bu sistemlerin performanslarının gerçek zamanlı çalışmalara uygun hale getirilmesi için çalışmalar yapılmaktadır. Bu sistemlerin en büyük zorluğu, gerçek zamanlı olarak doğru bir şekilde çalışmasının sağlanmasıdır; çünkü gerçekleştirilecek sistemin çok değişik görüntüleme şartlarında çalışması gerekmektedir ve görüntü işleme algoritmalarının uygulanması için çok hızlı ve çok büyük bellekli bilgisayarlara ihtiyaç vardır. Gerçek zamanlı çalışmaya ihtiyaç duymayan uygulamalarda -örneğin polis sabıka kayıtlarında-, çok yüksek doğruluk oranları ve çok hızlı çalışan sistemler kullanılmaktadır. Bu sistemler çok modüllü

ağlar ile mümkün olmaktadır. Şekil 3.5’de çok modüllü bir ağın yapısı görülmektedir.




Şekil 3.5. Çok modüllü yapay sinir ağları.

3.2.6. Yapay sinir ağı modelleri

Yapay sinir ağları, genel olarak ağın yapısına göre; ileri beslemeli (feed-forward) ve geri beslemeli (feed-back) olarak ikiye, öğrenme kuralına göre; Hebb, Hopfield, Delta ve Kohonen olmak üzere dörde, öğrenme algoritmasına göre; danışmanlı, danışmansız ve takviyeli olmak üzere üçe ve uygulamaya göre de; off-line ve on-line olmak üzere ikiye ayrılabilir. Ayrıca ağırlık matrislerinin simetrik veya asimetrik oluşuna, ağırlık matrisi değerlerinin sabit veya değişken oluşuna, ağda yer alan düğümlerin özelliklerine, kullanılan aktivasyon fonksiyonlarının deterministik veya stokastik oluşuna göre de sınıflandırılabilir. İleri beslemeli ağlar genellikle örüntü tanıma problemlerinde, geri beslemeli ağlar da optimizasyon problemlerinde yaygın olarak kullanılmaktadır [79].

3.2.6.1. İleri beslemeli yapay sinir ağları

Giriş tabakası, gizli tabaka ve çıkış tabakası olmak üzere üç tabakalı bir yapıya sahiptirler. Bu ağ yapısında nöronlar arka arkaya beslenirler. Öğrenme aşamasında, girdiler ağın girişlerine sunulurlar. Birinci tabakada yer alan nöronlar, çıktılarını hesaplarlar ve bir sonraki tabakaya girdi değeri olarak gönderirler. Böylece her bir tabaka aynı işlemi gerçekleştirir ve en sondaki tabakada yer alan çıktı değerleri de, işlemi sonuçlandırır. Aşağıda ileri beslemeli ağlara örnek olarak bir ve iki katmanlı ağ yapıları görülmektedir.



Şekil 3.6. Tek katmanlı ileri beslemeli ağ.

Şekil 3.7' de, iki katmanlı ağ görülmektedir. Buradaki çalışma, bir katmanın girişi, bir önceki katmanın çıkışıdır. Giriş katmanının görevi çoğullamaktır(giriş ve çıkış aynıdır). Giriş katmanı ile çıkış katmanı arasındaki katmanlara saklı katmanlar(gizli) denir. Uygulamalarda genellikle, bir veya iki saklı katman kullanmak yeterli olmaktadır.


w^i , i. Katmanın ağırlık matrisi,

b^i , i. Katmanın eşik vektörü,

Γ^i , i. Katmanın matris operatörü

Bu anlatılanlardan sonra, 2 katmanlı bir ağın çıkışı

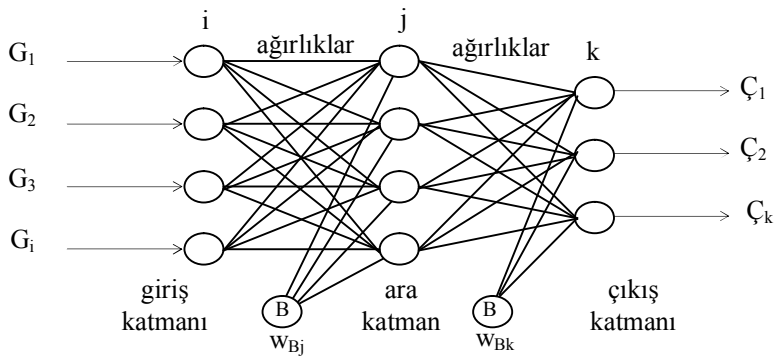
$$y = \Gamma^2 [w^2 \Gamma^1 [w^1 x + b^1] + b^2] \quad \text{şeklinde yazılabilir.}$$



Şekil 3.7. İki katmanlı ileri beslemeli ağ

3.2.6.2. Geri yayımlı (backpropagation) YSA modeli

YSA'nın değişik modelleri vardır. Bunlardan birkaçını sayacak olursak, perceptron, hücresel YSA(HYSA), hopfield, çok katmanlı, kohonen, geri yayımlı modellerdir. Biz çalışmalarımızda Geriye Yayımlı YSA modelini kullandık. Geriye Yayımlı YSA, çok katmanlı perceptron ağ yapısı üzerinde, geriye yayılma yöntemiyle geliştirilmiş delta öğrenme kuralının uygulandığı bir ağ sistemidir. Ağ üç katmandan oluşur. Ancak ara katman sayısı birden fazla olabilir. Ara katman sayısı, belli bir yöntem olmadığı için deneme yanılma yöntemi ile belirlenir.



Şekil 3.8. Geri yayılım ağı modelinin yapısı

Bu yöntemde eğitim sırasında bir girdi YSA'ya gönderilir ve bu girdiye karşılık bir çıktı üretilir. Daha sonra olması gereken çıktı YSA'ya söylenir. YSA, gerçek çıktı ile ürettiği çıktı arasındaki farkı hata olarak değerlendirir. Toplam hatayı en aza indirmek için YSA'nın yönünün tersine yani çıktı biriminden girdi birimine doğru

bağlantılı ağırlık değerleri toplam hataya katkısı oranında yeniden ayarlanır. Düzeltilmiş veya birleştirilmiş ağırlıklar Delta Kuralının (Delta rule) düzeltme etkisi kullanılarak kolayca elde edilebilir.

Geriye yayılım algoritmasında YSA' nın eğitilmesindeki amaç, giriş değerleri ile ağırlık üreteceği cevabın istenilen çıkış vektörünün aynısını veya istenen hassasiyette yakın değeri sağlayacak bir ağırlık kümesi bulmaktır. Bu ağırlık kümesinin bulunması, çözüm manasına gelir.

Çok gizli katmana sahip sistemlerde her sistemin hata işaretleri, bir önceki katmanın düzeltilmiş işaretlerinden bulunarak işlem tekrarlanır. Ağırlık düzeltme işlemi çıkış seviyesine bağlı ağırlıklardan başlar ve işlem ters yönde, giriş seviyesine gelene kadar devam eder. Sonuçta sistem; hatalar yapar, bu hatalardan bir şeyler öğrenip isteneni bulana kadar işleme devam eder. Bu yöntem hatanın geriye yayılma algoritması denir.

Geriye yayılım ağı modelinde öğrenme adımları:

1. Ağ yapısının tanımlanması; girdi, çıktı, ara katman, ara katman eleman sayısı
2. Başlangıç ağı parametrelerinin belirlenmesi; öğrenme katsayısı, momentum katsayısı
3. Öğrenme setinin ağa tanıtılması
4. Ağı son çıktısının bulunması
5. Ağ çıktısının istenen sonuç ile arasındaki hatanın hesaplanması
6. Aradaki hatanın, çıktı katmanından başlayıp geriye doğru bağlantı ağırlıklarına Delta Kuralına göre yayılması
7. Hata kabul edilebilir seviyede ise işlemin durdurulması, değilse
8. Adım c' ye dönülmesi
9. Ağı toplam hatasının hesaplanması

$$Err = (1/2) \sum_{i=1}^k (O_i - \theta_j^2) \quad (3.2)$$

k, çıktı katmanındaki hücre sayısı ve O_i , i. hücrenin istenilen çıktısı.

Geriye yayılım algoritmasının hesaplama adımları:

Geriye Yayılım Algoritması, bir veya birden çok ara katmanlı ileriye doğru çalışan bir ağdır. Ara katmanların sayısı hakkında kısıtlama yoktur. Ara katman hücresi için aktivasyon fonksiyonu olarak Sigmoid fonksiyonu kullanılmıştır. Geri yayılım, çok katmanlı YSA' nın eğitimi için sistematik bir yöntemdir.

1. İleriye doğru hesaplama

Girdiler ve ilişkili ağırlıklar çarpılarak NET değerleri hesaplanır. Ara katman ünitesi için NET ve OUT değerleri aşağıdaki gibi hesaplanır.

$$NET_J = \sum I_i \cdot W_{ij} + W_{Bj}^{YENI} \quad (3.3)$$

$$OUT_J = \frac{1}{1 + e^{-NET_J}}$$

Ara katman çıktıları, sonraki ara katmanın veya çıktı katmanının girdisi olarak gösterilir. W_{Bj}^{YENI} ve W_{Bk}^{YENI} , bias değerleridir.

$$NET_k = \sum I_k \cdot W_{jk} + W_{BK}^{YENI} \quad (3.4)$$

$$OUT_K = \frac{1}{1 + e^{-NET_K}}$$

2. Hataların geriye yayılması(Çıktı katmanından sonra ara katmana)

Sinir ağı modelinin çıktıları, çıktı katmanından elde edilir. Gerçek değerlerle bulunan değerler arasındaki fark, sistem hatasıdır. Elde edilen hata değerleri, bağlantı ağırlıklarına geriye doğru dağıtılır.

$$\delta_k = f'(NET_k)(TARGET_k - OUT_k) \quad (3.5)$$

$$\delta_k = OUT_k(1 - OUT_k)(TARGET_k - OUT_k)$$

$$\Delta W_{kj}(n+1) = \eta \delta_k OUT_k + \alpha [\Delta W_{kj}(n)]$$

$$W_{kj}^{YENI} = W_{kj}^{ESKI} + \Delta W_{kj}(n+1)$$

TARGET_k, istenen çıktı değerini gösterir. η öğrenme katsayısı, α momentum katsayısı, $f'(NET_k)$ aktivasyon fonksiyonunu gösterir. n iterasyon sayısını gösterir. ΔW ilişkili ağırlık değişimidir.

3. Hataların geriye yayılması(ara katmandan girdi katmanına)

Bu proses öncekine benzer ve aşağıdaki gibi yapılabilir:

$$\begin{aligned}\delta_j &= f'(NET_j) \cdot \sum \delta_k W_{kj} \\ \delta_j &= OUT_j(1 - OUT_j) \cdot \sum \delta_k W_{kj} \\ \Delta W_{ji}(n+1) &= \eta \delta_j \cdot OUT_j + \alpha[\Delta W_{ji}(n)] \\ W_{ji}^{YENI} &= W_{ji}^{ESKI} + W_{ji}(n+1)\end{aligned}\tag{3.6}$$

4. Bias ağırlıklarının hesaplanması

Bias, öğrenme prosesi için aktivasyon fonksiyonunu etkiler. Bias değerleri aşağıdaki şekilde hesaplanabilir:

$$\begin{aligned}\Delta W_{Bk}(n+1) &= \eta \delta_k + \alpha[\Delta W_{Bk}(n)] \\ W_{Bk}^{YENI} &= W_{Bk}^{ESKI} + \Delta W_{Bk}(n+1) \\ \Delta W_{Bj}(n+1) &= \eta \delta_j + \alpha[\Delta W_{Bj}(n)] \\ W_{Bj}^{YENI} &= W_{Bj}^{ESKI} + \Delta W_{Bj}(n+1)\end{aligned}\tag{3.7}$$

Sinir ağı modelinin eğitimi, önceki procesten anlaşılabilceği gibi iki aşamalıdır. İlk aşama, NET ve OUT değerleri hesaplanan ileri doğru geçiştir. İkinci aşama, bulunan hatanın bağlantı ağırlıklarına dağıtıldığı geriye doğru geçiştir. Bu tekrarlanan proses, TARGER ve OUT arasındaki farkın minimize edildiği öğrenme seviyesi elde edilinceye kadar sürer. Sinir Ağı modelinin eğitimi, anlaşılacağı gibi iki aşamalıdır. İlk aşama, NET ve OUT değerleri hesaplanan ileri doğru geçiştir. İkinci aşama, bulunan hatanın bağlantı ağırlıklarına dağıtıldığı geriye doğru geçiştir. Tekrarlanan bu çalışma, TARGET ve OUT arasındaki farkın minimize edildiği öğrenme seviyesi elde edilinceye kadar sürer [70].

Adaptif öğrenme: Geri yayılım, hata yüzeyindeki minimum noktanın araştırılmasında işlemi uzattığı için istenmeyen bir durumdur (kötü olarak algılanmaktadır). Buna ilaveten birçok metotlar önerilmiştir. Birçok ilginç ve çekici metotlardan birisi öğrenme oranının uygunlaştırılmasıdır. Bu metotta hedefe varmak için sınır oranlarını hızlandıracak dört tane bulgu tanımlanmıştır. Bunlardan birincisi, momentum katsayısının (teriminin) artırılmasıdır. İkincisi, hem ağırlıkların hem de öğrenmenin yükseltilmesinde delta-delta kuralının uygulanmasıdır. Üçüncüsü ve en önemlilerinden bir tanesi ikisinden biri değiştirilerek delta-bar-delta kuralıdır. Sonuncusu ise hibrit algoritmadır.

Delta kuralı hem ağırlıkların yükseltilmesi kuralını hem de öğrenmenin yükseltilmesi kuralını içine alır. Ağırlığın yükseltilmesi kuralı steepest descent algoritmasına benzer, sadece öğrenme oranı parametre olmasının dışında ağırlık işlemlerinin her birisi sahip oldukları parametredir. Ağırlık yükseltme kuralı aşağıdaki gibi yazılabilir.

$$w(t+1) = w(t) - \varepsilon(t+1) \frac{\partial j(t)}{\partial w(t)} \quad (3.8)$$

Burada $w(t)$ özel sinaptik ağırlık ve $\varepsilon(t)$ uygun öğrenme oranı, t zamandır. Hata yüzeyi üzerinde dik eğim (gradient descent) performansı öğrenme oranı parametre üzerinde tanımlanır. Basitçe tek bir doğrusal elaman durumunda türev için düşünülür. İlk olarak giriş ve çıkış ilişkisi tanımlanır. $W(t)$ ağırlık vektörünün doğrusal elamanı olsun $x(t)$ giriş vektörü olsun bu durumda $y(t)$ şöyle tanımlanır.

$$y(t) = w^T(t)x(t) \quad (3.9)$$

$\varepsilon(t)$ köşegen (diagonal) matris t zaman ve $d(t)$ hedef çıkış vektör eşitliğinin arzu edilen cevabıdır. Bu elamanların ağırlık yükseltme algoritması aşağıdaki gibi yazılabilir.

$$w(t) = w(t) + \varepsilon(t+1)[d(t) - y(t)]x(t) \quad (3.10)$$

Şimdi hata fonksiyonu, güncelleştirilen öğrenme kuralı tarafından minimize edilmesiyle tanımlanır. Bu hata fonksiyonu ağırlığın güncelleştirilmesiyle minimize edilen hata fonksiyonunda farklıdır. İlk olarak G ve daha sonra J olarak isimlendirilir. G aşağıdaki gibi tanımlanır.

$$G(t) = \frac{1}{2} [d(t) - y(t)]^2$$

$$G(t) = \frac{1}{2} [d(t) - w^T(t)x(t)] \quad (3.11)$$

$$G(t) = \frac{1}{2} [d(t) - (w(t-1) + \varepsilon(t)[d(t-1) - y(t-1)]x(t-1))^T x(t)]^2$$

$$G(t) = \frac{1}{2} [d(t) - (w(t-1) + \varepsilon(t)[d(t-1) - w^T(t-1)]x(t-1))^T x(t)]^2$$

Şimdi öğrenme oranının her birine göre $G(t)$ farklılaştırılır. ε_i w_i ağırlığının i . öğrenme oranı. Bu değer (i,i) . ε köşegen matrisin bileşenidir. I eşitliğinin bir teriminin dışındaki bütün bileşenleri sıfır ile karesel matris olmasıdır [77].

3.2.6.3. Yapay sinir ağlarında öğrenme

Bu kısımda YSA'nda öğrenme kavramından neyin amaçlandığı anlatılmış olup, belli başlı öğrenme algoritmalarından bahsedilmiştir.

Öğrenmenin tanımı şöyle yapılmaktadır, "Bilginin Çözümü" demektir. Sistemin aldığı bilgiyi, kendi bünyesinde çözerek öğrenmek demektir. Bu işlemi de öğrenme süreci boyunca, yapısını değiştirerek yerine getirmektedir [74].

YSA, belirli bir probleme göre programlanmadığı halde o problemi çözmeyi öğrenebilir. Eğitim ve öğrenme YSA' ların temelini oluşturur. YSA' nda değişebilen sistem parametreleri, hücreler arası bağlantıları sağlayan sinapsları temsil eden

ağırlıklarıdır. Öğrenme, nöronlar arasındaki bağlantı ağırlıklarının değiştirilmesi ile gerçekleştirilmektedir.

Michaliski, öğrenme-anlama ve zekâ kavramlarının birbirleriyle ilişkili ifadeler olduğunu söylemiştir [75].

Özet olarak öğrenme kavramını şu şekilde ifade edebiliriz; sistemin parametrelerini değiştirerek, verilen iş değerlerine karşılık istenen çıkış değerlerinin alınması veya üretilmesini sağlayacak uyarılama sürecidir [76].

YSA, gerek yapısal açıdan gerekse öğrenme algoritmalarının çeşitliliği açısından karmaşık problemlerin çözümünde tasarımcıya oldukça değişik olanaklar sunmaktadır.

Teknolojik gelişmelerin büyük ivme kazandığı bu dönemde gerek donanım teknolojilerinin gerekse yazılım geliştirme ortamlarının tasarımcıya sunmuş olduğu imkânlar, kullanıcı istekleri doğrultusunda sistemlerin ve yaklaşımların karmaşıklığındaki artışı da beraberinde getirmiştir. Bir başka yönden uzman bilgisini öğrenebilen ve karmaşık eşleştirmeleri kolayca gerçekleştirebilen akıllı sistemler, yapısal ve metodolojik güçlerin aşılması anlamında geleneksel yöntemlere alternatif olma durumlarını sürdürme gelmişlerdir. Bu nedenle çok parametrelili sistemler üzerinde çalışırken maliyeti azaltıp, kazancı artırmak, insan aklının donanımını taklit etme felsefesine dayanan YSA yapılarının kullanımına, oldukça uygun problemler oluşturmuşlardır [76].

1960'lı yıllarda sembolik öğrenme ortaya çıkmıştır. Bu öğrenmede, istatistik yöntemler yerine semantik ağ ve yüklem mantığı gibi teknikler kullanılmıştır. Sistem, verilen kavram setini sembolik gösterimle öğrenmekte, verilen kavramların örnekleri ve ters örneklerini analiz etmektedir.

YSA'nda öğrenme üç ana başlık altında incelenebilir [76].

1. Eğitici öğrenme
2. Takviyeli öğrenme
3. Eğitici öğrenme

Eğitici öğrenme: Hedeflenen sonuçları bilen eğitici, ağa müdahalesi vardır. Ağa bir girdi-çıkı kümesi verilir ve istenen çıktılar alınana kadar ağa müdahalelerle sonuca ulaşılır. Ağırlıklar bir öğrenme kuralı ile ayarlanarak, girdi-çıkı arasındaki hata en aza, mümkünse sıfıra indirgenmeye çalışılır. Bağlantı ağırlık katsayılarıdaki değişim, geri besleme olarak gelen hatayı azaltacak veya hatta mümkünse sıfırlayacak şekilde ayarlanır. Bunun için çeşitli öğrenme kuralları kullanılır.

Eğitici öğrenmeye en güzel örnek, öğrenciler ile öğretmenin bir sınıftaki ders işleme çalışmasıdır. Öğretmen ve öğrenciler ders boyunca karşılıklı etkileşim içindedirler. Öğrencilerin, sorulan sorulara verdiği cevaplar, öğretmen tarafından anında kontrol edilmektedir. Gerekirse doğru cevap öğretmen tarafından öğrencilere iletilmektedir. Bizde çalışmalarımızda eğitici öğrenmeyi kullandık.

Takviyeli öğrenme: YSA takviyeli öğrenmede, bir öğreticiye gereksinim duyar. Bu öğrenmenin farklı yanı, çıktının istenilen çıktı olup olmadığı hususunda ağa öğretici tarafından müdahalede bulunulmasıdır. Bu öğrenme seçeneği, girdi modellerine karşılık istenilen çıktı modellerinin oluşturulmasının zor olduğu durumlarda kullanılır.

Eğitici öğrenme: Kısaca, “kendi kendine öğrenme” (self-organized learning) diye de adlandırılmaktadır. Herhangi bir eğiticiden, ağın ürettiği yanıtın doğruluğuna dair herhangi bir geri besleme gelmemektedir. Ağ, kendine gösterilen örnekleri alır ve belli bir kritere göre sınıflandırır. Bu kriter önceden bilinmesi şart değildir. Ağ, kendi öğrenme kriterlerini kendisi oluşturmaktadır. Bu öğrenme, her YSA için yoktur ve her probleme uygulanamaz.

3.2.6.4. Yapay sinir ağlarında öğrenme algoritmaları

Öğrenme, başlangıçtaki rastgele seçilmiş ağırlıkların, belirli bir kurala göre değiştirilmesine dayanmaktadır. Öğrenme algoritmalarının önemli olanlarından

bazılarına aşağıda yer verilmiştir. Bu algoritmalarda, $w_i = [w_{i1} \ w_{i2} \ \dots \ w_{im}]$ vektörü ağdaki i . hücreye gelen m tane girişin ağırlık katsayılarını, $x = [x_1 \ x_2 \ \dots \ x_n]$ vektörü ağa gelen n tane girişi, y_i ve d_i 'de sırasıyla i . hücrenin hesaplanan ve istenen çıkışını temsil etmektedirler.

Hebb öğrenme algoritması: Bu algoritmadaki temel amaç, hücrenin çıkış üretmesine sebep olan bağlantıların ağırlık katsayılarını büyüterek, etkilerini arttırmaktır. Algoritmadaki değişim, aşağıdaki gibi gerçekleştirilir.

$$w_i(t+1) = w_i(t) + \varepsilon \cdot f(w_i(t) \cdot x(t)) \cdot x(t)$$

veya

(3.12)

$$w_i(t+1) = w_i(t) + \varepsilon \cdot y_i(t) \cdot x(t)$$

Burada ε 'a öğrenme katsayısı veya öğrenme oranı denilmektedir. Dışarıdan istenilen herhangi bir çıkış uygulanmadığından, eğitici bir öğrenme algoritmasıdır

Algılayıcı (perceptron) öğrenme algoritması: Rosenblatt tarafından önerilmiştir. w değişimi, nöron çıkışı ve istenilen çıkışın farkı ile orantılıdır. İstenilen çıkışın farkı ile orantılı olduğundan eğitici bir öğrenme algoritmasıdır.

$$w_i(t+1) = w_i(t) + \varepsilon \cdot [d_i(t) - \text{sgn}(w_i(t) \cdot x(t))] \cdot x(t)$$

(3.13)

Ağın ürettiği çıkış istenilen çıkıştan farklı olması durumunda, hata azaltılacak yönde hareket edilmektedir. Hata sıfır olduğunda w değişimi durmaktadır.

Delta kuralı (eğim düşme) öğrenme algoritması: Eğim düşme (gradient descent) öğrenme algoritması veya "delta kuralı" öğrenme algoritması ile tanımlanmaktadır. Sadece üretilebilir fonksiyonlara sahip olan ağlara uygulanabilmektedir. Bundan dolayı, eğitici bir öğrenme algoritmasıdır. w değişimi, hatanın eğiminin tersi yöndedir. Böylece, hata fonksiyonunun minimum olduğu yere doğru hareket ettirilmektedir.

$$w_i(t+1) = w_i(t) - \varepsilon \cdot \frac{\partial E(t)}{\partial w(t)} \quad (3.14)$$

$E(t)$, hata fonksiyonunu ifade etmesi durumunda ve aşağıdaki gibi tanımlama yapmak mümkündür.

$$E(t) = \frac{1}{2} (d_i(t) - y_i(t))^2$$

$$E(t) = \frac{1}{2} [d_i(t) - f(w_i(t).x(t))]^2 \quad (3.15)$$

$$\frac{\partial E(t)}{\partial w(t)} = -[d_i(t) - f(w_i(t).x(t))] \cdot \frac{\partial f(w_i(t).x(t))}{\partial (w_i(t).x(t))} \cdot x(t)$$

Hata geriye yayılma algoritmasının temeli, bu öğrenme algoritmasına dayanmaktadır.

Widrow-Hoff öğrenme algoritması: w değişimi ağırlık çıkışından bağımsızdır. Bu bağımsızlıktan dolayı algoritma, eğitici bir öğrenme algoritmasıdır.

$$w_i(t+1) = w_i(t) + \varepsilon \cdot (d_i(t) - w_i(t).x(t)) \cdot x(t) \quad (3.16)$$

İlintili öğrenme algoritması: Hebb öğrenme algoritmasının, eğitici uyarlamasıdır. $f(w_i(t).x_i(t))$ yerine $d_i(t)$ istenen çıkış alındığında aşağıdaki denklem elde edilir.

$$w_i(t+1) = w_i(t) + \varepsilon \cdot d_i(t) \cdot x(t) \quad (3.17)$$

Yarışmacı öğrenme algoritması: Bu algoritmadaki temel fikir, giriş işaretine en yakın olan bağlantı ağırlık katsayılarını bulmaya dayanmaktadır. w' (ağırlık)lara ilişkin nöron, kazanan nöron olarak tanımlanmaktadır. Burada sadece kazanan nöron bir çıkış üretmekte ve bu nörona ilişkin w 'ler değişim göstermektedir. Eğitici bir öğrenme türüdür. İşlemlerin sonucunda, bu algoritma ağa gelen girişleri sınıflandırmaktadır.

$$w(t+1) = w(t) + \varepsilon \cdot (x(t) - w_m(t)) \quad (3.18)$$

Burada w_m kazanan hücrenin bağlantı ağırlık katsayısıdır. Bu çalışma aşağıdaki gibi tanımlanmıştır.

$$w_m \cdot x = \max(w_i \cdot x) \quad \text{ve} \quad i = 1, 2, \dots, p \quad \text{dir.}$$

Outstar öğrenme algoritması: Amaç, w 'leri istenen çıkışa benzetmektir. Eğitici öğrenme algoritmasını bir türüdür [71].


$$w(t+1) = w(t) + \varepsilon \cdot (d_i(t) - w(t)) \quad (3.19)$$

3.2.7. Çok katmanlı ağlar

Yapay sinir ağlarının ilk modellerinden olan tek katmanlı algılayıcı modellerinin en temel özelliği doğrusal problemleri çözebilme yetenekleridir. Bu tip ağlarla doğrusal olmayan problemler öğrenilememektedir. Bu sorunu çözmek için çok katmanlı ağlar geliştirilmiştir. Rumelhart ve arkadaşları tarafından geliştirilen bu modele hata yayma modeli veya geriye yayılım modeli denmektedir. Bu model delta öğrenme kuralını kullanmaktadır. Çok katmanlı ağların yapısı Şekil 3.9' da gösterildiği gibidir. Çok katmanlı ağlar ileri beslemelidir ve giriş, gizli ve çıkış olmak üzere üç katmana sahiptirler. Giriş ve çıkış katmanları, sinyaller için aynı sayıda sinirlere sahiptir. Gizli katman sayısı için genel olarak bir ölçüt yoktur ve genellikle deneme yanılma ile bulunur.

Girdi katmanında herhangi bir bilgi işleme olmaz. Girdi katmanındaki her işlem elemanı, bir sonraki gizli katmanda bulunan her işlem elemanı ile bağlantılıdır. Gizli katman, girdi katmanından gelen bilgileri işleyerek çıkış katmanına gönderir. Yine, gizli katmandaki her işlem elemanı, çıkış katmanındaki bütün işlem elemanlarıyla

bağlantılıdır. Birden fazla gizli katman olabilir. Çıkış katmanı, gizli katmandan gelen bilgileri işleyerek çıktıları dış dünyaya iletir.




Şekil 3.9. Çok katmanlı ağ yapısı

Çok katmanlı ağlar danışmanlı öğrenme prensibine göre çalışır. Bu ağlara eğitim sırasında hem girdiler hem de o girdilere karşılık üretilmesi gereken çıktılar gösterilir. Ağın görevi her girdi için o girdiye karşılık gelen çıktıyı üretmektir. Çok katmanlı ağın öğrenme kuralı en küçük kareler yöntemine dayalı delta öğrenme kuralının geliştirilmiş halidir. O nedenle öğrenme kuralına “Genelleştirilmiş Delta Kuralı” da denir. Bu kural iki safhadan oluşur. İlki, ağın çıktısının hesaplandığı ileri doğru hesaplama kısmı, ikincisi ise ağırlıkların değiştirildiği geriye doğru hesaplama kısmıdır.

3.2.7.1. Çok katmanlı ağın eğitilmesi

Katman sayısının fazla olması iyi olmakla beraber hesapsal yükü üssel bir biçimde arttıracığından pratikte genel olarak üç katmanlı ağlar kullanılır. Üç katmanlı bir ağın genel yapısı Şekil 3.10’da gösterilmiştir.



Şekil 3.10. Üç katmanlı yapay sinir ağı

Ara katman çıkışları,

$$\bar{O}_{pk} = f\left(\bar{b}_k + \sum_{n=1}^N \bar{w}_{kn} x_{pn}\right) \quad p=1, \dots, P \quad k=1, \dots, K \quad (3.20)$$

Çıkış katmanı, gizli katman çıkışlarını kullanır. Çıkış katmanı çıkışları,

$$O_{pm} = f\left(b_m + \sum_{k=1}^K w_{mk} \bar{O}_{pk}\right) \quad p=1, \dots, P \quad m=1, \dots, M \quad (3.21)$$

Herhangi bir veri için hata,

$$E_p = \frac{1}{2} \sum_{m=1}^M (y_{pm} - O_{pm})^2 \quad (3.22)$$

Bütün verileri kapsayan toplam hata,

$$E = \sum_{p=1}^P E_p = \frac{1}{2} \sum_{p=1}^P \sum_{m=1}^M (y_{pm} - O_{pm})^2 \quad (3.23)$$

Çıktı katmanı ile gizli katman arasındaki ağırlık düzeltme miktarları,

$$\begin{aligned}\Delta w_{mk}(t+1) &= -\eta \frac{\partial E}{\partial w_{mk}} + \alpha \Delta w_{mk}(t) \\ &= -\eta \frac{\partial E}{\partial O_{pm}} \frac{\partial O_{pm}}{\partial w_{mk}} + \alpha \Delta w_{mk}(t) = \eta \delta_{pm} \bar{O}_{pk} + \alpha \Delta w_{mk}(t)\end{aligned}\quad (3.24)$$

$$\begin{aligned}\Delta b_m(t+1) &= -\eta \frac{\partial E}{\partial b_m} + \alpha \Delta b_m(t) \\ &= -\eta \frac{\partial E}{\partial O_{pm}} \frac{\partial O_{pm}}{\partial b_m} + \alpha \Delta b_m(t) = \eta \delta_{pm} + \alpha \Delta b_m(t)\end{aligned}\quad (3.25)$$

Girdi katmanı ile gizli katman arasındaki ağırlık düzeltme miktarları,

$$\begin{aligned}\Delta \bar{w}_{kn}(t+1) &= -\eta \frac{\partial E}{\partial \bar{w}_{kn}} + \alpha \Delta \bar{w}_{kn}(t) \\ &= -\eta \sum_{m=1}^M \frac{\partial E}{\partial O_{pm}} \frac{\partial O_{pm}}{\partial \bar{O}_{pk}} \frac{\partial \bar{O}_{pk}}{\partial \bar{w}_{kn}} + \alpha \Delta \bar{w}_{kn}(t) = \eta \bar{\delta}_{pk} x_{pn} + \alpha \Delta \bar{w}_{kn}(t)\end{aligned}\quad (3.26)$$

$$\begin{aligned}\Delta \bar{b}_k(t+1) &= -\eta \frac{\partial E}{\partial \bar{b}_k} + \alpha \Delta \bar{b}_k(t) \\ &= -\eta \sum_{m=1}^M \frac{\partial E}{\partial O_{pm}} \frac{\partial O_{pm}}{\partial \bar{O}_{pk}} \frac{\partial \bar{O}_{pk}}{\partial \bar{b}_k} + \alpha \Delta \bar{b}_k(t) = \eta \bar{\delta}_{pk} + \alpha \Delta \bar{b}_k(t)\end{aligned}\quad (3.27)$$

Düzeltilme miktarlarının ağırlıklara ilavesi ile ağırlık ve biasların bir sonraki değerleri,

$$\begin{aligned}w_{mk}(t+1) &= w_{mk}(t) + \Delta w_{mk}(t+1) \\ b_m(t+1) &= b_m(t) + \Delta b_m(t+1)\end{aligned}\quad (3.28)$$

$$\bar{w}_{kn}(t+1) = \bar{w}_{kn}(t) + \Delta \bar{w}_{kn}(t+1)$$

$$\bar{b}_k(t+1) = \bar{b}_k(t) + \Delta \bar{b}_k(t+1)$$

Gizli ve çıkış katmanında sigmoid transfer fonksiyonu kullanılması durumunda,

$$\begin{aligned}\delta_{pm} &= O_{pm}(1-O_{pm})(y_{pm}-O_{pm}) \\ \bar{\delta}_{pk} &= \bar{O}_{pk}(1-\bar{O}_{pk}) \sum_{m=1}^M \delta_{pm} w_{mk}(t)\end{aligned}\quad (3.29)$$

olarak bulunur.

Yukarıdaki formüllerde kullanılan η öğrenme katsayısı ne kadar büyük olursa ağırlıklardaki değişiklikler de o oranda büyük olmaktadır. Pratik uygulamalar için osilasyona sebep olmayacak en büyük öğrenme katsayısının seçilmesi, öğrenmenin daha hızlı olmasını sağlayacaktır. Osilasyona sebep olmadan öğrenme hızını artırmanın bir yolu, genel delta kuralına bir momentum terimi (α) eklemektir. Bu metot özellikle hata yüzeyini bir minimuma indirgeyen keskin inişler için yararlıdır. Keskin inişte yapılan bir hızlı ilerleme bu minimum düzeyde osilasyonlara sebep olabilir. Buna karşı alınacak önlem küçük adımlarla ilerlemektir. Fakat bu da o keskin iniş boyunca işlemin çok yavaşlamasına sebep olur. Eklenen momentum terimi o bölgedeki keskinliği filtreleyerek daha hızlı olarak ağırlıkların değiştirilmesine olanak verir.

3.2.7.2. Çok katmanlı ağıın çalışma prosedürü

Çok katmanlı ağların çalışması şu adımları içermektedir:

Örneklerin toplanması: Ağın çözmesi istenilen olay için daha önce gerçekleşmiş örneklerin bulunması adımıdır. Ağın eğitilmesi için örnekler toplandığı gibi ağın test edilmesi için de örneklerin toplanması gerekmektedir. Ağın eğitilmesi sırasında test seti ağa hiç gösterilmez. Eğitim setindeki örnekler tek tek gösterilerek ağın olayı öğrenmesi sağlanır. Ağ olayı öğrendikten sonra test setindeki örnekler gösterilerek ağın performansı ölçülür. Hiç görmediği örnekler karşısındaki başarısı ağın iyi öğrenip öğrenmediğini ortaya koymaktadır.

Ağın topolojik yapısının belirlenmesi: Öğrenilmesi istenen olay için oluşturulacak ağın topolojik yapısı belirlenir. Kaç tane girdi elemanı, kaç tane gizli katman, her gizli katmanda kaç tane işlem elemanı ve kaç tane çıktı elemanı olması gerektiği bu adımda belirlenmektedir.

Öğrenme parametrelerinin belirlenmesi: Ağın öğrenme katsayısı, işlem elemanlarının aktivasyon fonksiyonları, momentum katsayısı gibi parametreler bu adımda belirlenmektedir.

Ağırlıkların başlangıç değerlerinin atanması: İşlem elemanlarını birbirine bağlayan ağırlık değerlerinin ve eşik değer ünitesi ağırlıklarının başlangıç değerlerinin atanması yapılır. Başlangıçta genellikle rastgele değerler atanır. Daha sonra ağ uygun değerleri öğrenme sırasında kendisi belirler.

Öğrenme setinden örneklerin seçilmesi ve ağa gösterilmesi: Ağın öğrenmeye başlaması ve yukarıda anlatılan öğrenme kuralına uygun olarak ağırlıkları değiştirmesi için ağa örnekler belirli bir düzeneğe göre gösterilir.

Öğrenme sırasında ileri hesaplamaların yapılması: Yukarıda anlatıldığı şekilde sunulan girdi için ağın çıktı değeri hesaplanır.

Gerçekleşen çıktının beklenen çıktı ile karşılaştırılması: Ağın ürettiği hata değerleri bu adımda hesaplanır.

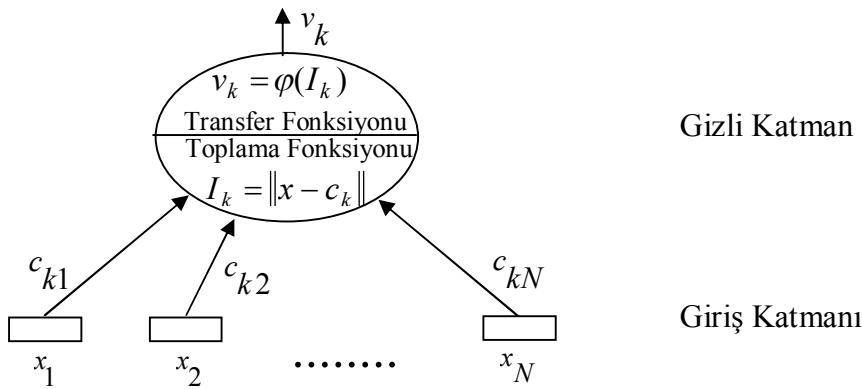
Ağırlıkların değiştirilmesi: Yukarıda anlatıldığı gibi geri hesaplama yöntemi uygulanarak üretilen hatanın azalması için ağırlıkların değiştirilmesi yapılır.

Yukarıdaki adımlara, çok katmanlı ağın öğrenmesi tamamlanıncaya, yani gerçekleşen çıktılar ile beklenen çıktılar arasındaki hatalar kabul edilir düzeye gelinceye kadar devam edilir. Ağın öğrenmesi için bir durdurma kriterinin olması gerekmektedir. Bu ise genellikle üretilen hatanın belirli bir düzeyin altına düşmesi olarak alınmaktadır [78].

3.2.8. Radyal tabanlı yapay sinir ağıları

Çok katmanlı ağlarda, gizli katmandaki işlem elemanlarının aktivasyon fonksiyonları türevleri alınabilen ve girilen değerlere göre sürekli artan türdendir. Bunlar büyük değerlere büyük, küçüklere de küçük işlemci değerleri atayan matematik fonksiyonlarıdır. Bu tür işlemciler bir kümelemenin veya sınıflandırmanın bulunmaması durumlarında kullanılırlar. Ancak verilerde bazı kümelenmelerin bulunması durumunda gizli katmandaki işlem elemanlarının da böyle bir yapıya sahip olması beklenir. Bu tür kümeleme işlemlerine pratikte sık rastlanır. Bu nedenle önceden kümelenmiş verilerle çalışabilen radyal tabanlı yapay sinir ağıları (RBNN) geliştirilmiştir [80]. Bu tip ağlarda gizli katmandaki işlem elemanları, girişlerin ağırlıklandırılmış şeklini kullanmamakta ve gizli katmandaki işlem elemanlarının çıkışları, yapay sinir ağı girişleri ile temel fonksiyonun merkezi arasındaki uzaklığa göre belirlenmektedir. Radyal tabanlı yapay sinir ağlarının en genel anlamıyla radyal olarak simetrik olan gizli katman işlem elemanları içeren bir yapıdadır.

Radyal olarak simetrik olan gizli katman işlem elemanı için üç bileşen vardır. İlki giriş uzayındaki bir merkez vektörüdür. Bu vektör, giriş ve gizli katman arasındaki ağırlık vektörü olarak saklanır. İkincisi, bir giriş vektörünün merkezden ne kadar uzak olduğunu belirlemek için uzaklık ölçütüdür. Tipik olarak bu ölçüt standart Öklid uzaklığı olarak alınır. Sonuncusu ise, tek değişkenli olan ve uzaklık fonksiyon çıkışını giriş olarak alan işlem elemanının çıkış değerini belirleyen bir aktivasyon fonksiyonu yapısıdır. Diğer bir ifadeyle gizli katman işlem elemanı çıkışı, sadece merkezle giriş vektörü arasındaki uzaklığın bir fonksiyonudur ve çok değişkenli enterpolasyon yaklaşımlarında kullanılan yapay sinir ağı yapılarındandır. İlk katmandaki işlem elemanları girişlerin ağırlıklandırılmış şeklini kullanmaz. İlk katmandaki işlem elemanlarının çıkışları, yapay sinir ağı girişleri ile temel fonksiyonun merkezi arasındaki uzaklığa göre belirlenir. Radyal tabanlı yapay sinir ağı yapılarının son katmanı lineerdir ve ilk katmanın çıkışlarından ağırlıklandırılmış toplam çıkışı üretir.



Şekil 3.11. Radyal tabanlı ağıın, gizli katman işlem elemanının yapısı

Genellikle uygulamalarda kullanılan radyal tabanlı ağların yapısı, Moody ve Darken tarafından önerilmiştir. Bu yapıda, gizli katman işlem elemanları, lineer aktivasyon fonksiyonuna sahip çıkış katmanına bütünüyle bağlantılıdır.

İşlem elemanının çıkışı,

$$I_k = \|x - c_k\| = \sqrt{\sum_{i=1}^N (x_i - c_{ki})^2} \quad k = 1, 2, 3, \dots, N \quad (3.30)$$

Nöron çıkışı ise,

$$v_k = e^{-\frac{I_k}{\sigma_k^2}} \quad \text{ile ifade edilir.} \quad (3.31)$$

x çok boyutlu giriş vektörü, c giriş vektörü ile aynı boyutta olan merkez vektörünü, σ ise standart sapma değeridir. Gizli katmana işlem elemanlarının eğitilmesi için c_k ağırlıkları ile σ_k genişliklerinin belirlenmesi gerekmektedir.

Radyal tabanlı yapay sinir ağları, çok katmanlı algılayıcı ağlardan daha hızlı öğrenir. Fakat artan girişle, çok yüksek boyutlu radyal tabanlı yapay sinir ağlarına ihtiyaç duyulur. Bu yapılar genellikle sistem modelleme, tahmin ve sınıflandırma gibi problemlerin çözümleri için kullanılırlar.

3.2.9. Olasılıksal yapay sinir ağları (PNN)

Bir diğer ileri beslemeli ağ yapısı ise olasılıksal sinir ağıdır (PNN). Giriş katmanına ek olarak PNN’de iki gizli katman ve bir çıkış katmanı daha bulunmaktadır. Hatanın geriye yayılımı algoritmasıyla eğitilen ileri beslemeli bir ağdan en temel farkı, PNN’nin eğitim setini sadece bir eğitime adımında kullanmasıdır.

PNN bir Bayes-Parzen sınıflandırıcıdır. Bu yaklaşım son çeyrek asra damgasını vurmasına rağmen, temelleri 1960’lara dayanmaktadır. İlk defa Spech tarafından çok sayıda basit işleme uygulanmıştır. Daha sonra paralel işlem gören çok katmanlı ağlara da uygulanmıştır.

Olasılıksal sinir ağlarında bir nörondaki aktivasyon fonksiyonu, eğitim örneklerine dayanan istatistiksel yoğunluk fonksiyonundan (PDF) hesaplanarak türetilmiştir. PNN’nin topolojisini oluşturan katmanlar şöyle şekillendirilirler:

Giriş katmanı m boyutlu giriş vektörü uygulanmak üzere m nörona sahiptir. İlk katman her giriş örneği için bir model oluşturur. İkinci saklı katman her sınıf için bir toplama işlemi gerçekleştirir. Her toplama işlemi bir önceki katmandaki çıkışlardan bir toplam belirlemek amacıyla kullanılır. Çıkış katmanı, toplamın çıkışlarından en yüksek olasılığı seçerek karar kuralını uygulamak için oluşturulan katmandır. Bu karar katmanı “kazanan alır” ağları ile kurulabilir [81].

3.2.10. Sezgisel ve ileri seviyeli eğitim algoritmalar

Geri yayılım öğrenme kuralı en genel anlamıyla, her bir katmandaki toplam karesel hatanın gradyeninin tahminine dayalı, gradyen azaltım algoritmasıdır.

$$\Delta W(n) = -\eta \nabla E(n) = \eta \delta(n) X^T(n) \quad (3.32)$$

Bu algoritma 2 sebepten dolayı yavaş işler:

1. Her bir iterasyonda ortalama karesel hatayı ($J(W)$) minimize etmek için toplam karesel hatayı ($E(W,n)$) kullanır. Ortalama karesel hatanın gradyeni, toplam karesel hatanın gradyeninden iyi bir şekilde tahmin edilemez. Bundan dolayı daha fazla iterasyona gereksinim duyar.
2. Birinci mertebe minimizasyon algoritması olduğundan, birinci mertebeden türevlerden oluşur (gradyen). Oysa hızlı algoritmalar ikinci mertebeden türevleri (Hessian matrisi) de içerirler.

Algoritmanın yapısından dolayı, yerel minimumlara takılma eğilimindedir. Bir momentum terimi eklenmesiyle iyileştirme yapılabilir:

Ağırlıkların değişim miktarı,

$$\Delta W(n) = \eta \delta(n) X^T(n) + \alpha \Delta W(n-1), 0 < \alpha < 1 \quad (3.33)$$

olarak bulunur. Bu parametrenin eklenmesi algoritmaya, alçak geçiren filtre özelliği kazandırır.

3.2.10.1. Adaptif öğrenme katsayısı

Yakınsama hızını arttırmanın bir yolu da değişken öğrenme katsayısı kullanmaktır. Bu algoritmanın temelinde, ortama karesel hatanın değişim oranını gözlemlenmesi vardır. Eğer ortalama karesel hatada (J) azalma varsa, ∇J negatiftir. Bu durumda öğrenme katsayısı doğrusal olarak arttırılır,

$$\eta(n+1) = \eta(n) + a, a > 0 \quad (3.34)$$

Eğer hata arttıysa ($\nabla J > 0$), öğrenme katsayısı oransal olarak azaltılır,

$$\eta(n+1) = b.\eta(n), 0 < b < 1 \quad (3.35)$$

Öğrenme katsayısındaki artış neticesinde öğrenme, kararlı halden uzaklaşmaya başlar ve hata fonksiyonu artar. Bundan dolayı öğrenme katsayısının hızlı bir biçimde azaltılması önemlidir [79].

3.2.10.2. Newton metodu

Newton'un minimizasyon metodu, performans kriterinin ikinci türevlerinden yararlanılması esasına dayalıdır. Performans fonksiyonunun (ortalama karesel hata) Taylor serisine açılımı,

$$J(W_{n+1}) = J(W) + \Delta W \cdot \nabla J + \frac{1}{2} \cdot \Delta W \cdot H \cdot \Delta W^T + \dots \quad (3.36)$$

$J(W_{n+1})$ 'i minimize etmek için gradyeni alınır ve sifıra eşitlenirse,

$$\nabla J(W_{n+1}) = \nabla J + \Delta W \cdot H + \dots = 0 \quad (3.37)$$

ve yüksek mertebeli terimler ihmal edilirse,

$$\Delta W = -\nabla J \cdot H^{-1} \text{ olur.} \quad (3.38)$$

Denklem (3.38)'nin, Hessian'ının tersiyle modifiye edilmiş olan J 'nin gradyeni sayesinde, daha iyi ağırlık güncellemesi yaptığı söylenebilir. Hessian matrisi, ağırlık vektörlerinin yakın civarında, performans fonksiyonunun yüzeyinin şekli hakkında ek bir bilgi içerir.

Newton'un metodu, Conjugate-Gradient algoritmalarından daha hızlıdır. Buna karşılık, Hessian matrisinin tersinin hesaplanması dolayısıyla nispeten daha karmaşıktır.

Bir çok spesifik algoritmanın temelinde Newton'un metodu vardır. En hızlı ve en popüler olan Levenberg-Marquardt algoritmasının orijininde de Gauss-Newton metodu vardır [79].

3.2.10.3. Gauss-newton metodu

Tüm ağırlıklar satır vektörü olarak düşünülürse,

$$W = [W_1 \dots W_j \dots W_k] \quad (3.39)$$

Anlık hata da sütun vektörü olarak düşünülürse,

$$e(W, n) = d(n) - y(n) = [\varepsilon_1 \dots \varepsilon_k \dots \varepsilon_m]^T \quad (3.40)$$

Anlık performans fonksiyonu $E(W, n)$, hataların karelerinin toplamıdır,

$$E(W, n) = \frac{1}{2} \cdot \sum_{k=1}^m \varepsilon^2(n) = \frac{1}{2} \cdot \varepsilon(n) \cdot \varepsilon^T(n) \quad (3.41)$$

Toplam performans $J(W)$ (Ortalama karesel hata),

$$J(W) = \frac{1}{M} \cdot \sum_{n=1}^N E(W, n), \quad M = mN \quad \text{olur.} \quad (3.42)$$

Anlık hatanın birinci türevleri düşünülürse, anlık gradyen vektörünün j . bileşeni,

$$\begin{aligned} [\nabla E(W, n)]_j &= \frac{\partial E(W, n)}{\partial W_j} = \sum_{k=1}^m \varepsilon_k(W) \cdot \frac{\partial \varepsilon_k(W)}{\partial W_j} \\ &= \varepsilon^T(W) \cdot \left[\frac{\partial \varepsilon_1(W)}{\partial W_j} \dots \frac{\partial \varepsilon_M(W)}{\partial W_j} \right]^T \end{aligned} \quad (3.43)$$

olarak bulunur.

Eşitlik (3.43), gradyen için matrisel formda genelleştirilirse,

$$\nabla E(W, n) = \varepsilon^T(W, n) \cdot J(W, n) \text{ olur.} \quad (3.44)$$

$$\text{Eşitlik (3.44)'de } J(W, n) = \begin{pmatrix} \frac{\partial \varepsilon_1(W)}{\partial W_1} & \dots & \frac{\partial \varepsilon_1(W)}{\partial W_k} \\ \vdots & & \vdots \\ \frac{\partial \varepsilon_m(W)}{\partial W_1} & \dots & \frac{\partial \varepsilon_m(W)}{\partial W_k} \end{pmatrix} \text{ birinci mertebeden türevleri}$$

içeren Jacobian matrisidir.

Anlık performans fonksiyonunun Hessian matrisini bulmak için Eşitlik (3.44)'den faydalanılırsa,

$$\nabla^2 E(W, n) = \frac{\partial}{\partial W} (\varepsilon^T(W) \cdot J(W)) \text{ olur.} \quad (3.45)$$

Daha kolay anlaşılması bakımından, Hessian matrisinin k, j bileşeni hesaplanırsa,

$$\begin{aligned} [\nabla^2 E(W, n)]_{k, j} &= \frac{\partial^2 E(W)}{\partial W_k \cdot \partial W_j} = \sum_{i=1}^M \left(\frac{\partial \varepsilon_i}{\partial W_k} \cdot \frac{\partial \varepsilon_i}{\partial W_j} + \frac{\varepsilon_i \cdot \partial^2 \varepsilon_i}{\partial W_k \cdot \partial W_j} \right) \\ &= \left[\frac{\partial \varepsilon_1}{\partial W_k} \dots \frac{\partial \varepsilon_M}{\partial W_k} \right] \cdot \begin{bmatrix} \frac{\partial \varepsilon_1}{\partial W_j} \\ \vdots \\ \frac{\partial \varepsilon_M}{\partial W_j} \end{bmatrix} + \varepsilon^T \cdot \frac{\partial^2 \varepsilon_i}{\partial W_k \cdot \partial W_j} \end{aligned} \quad (3.46)$$

Eşitlik (3.46) matrisel formda genelleştirilirse,

$$\nabla^2 E(W) = J^T(W) \cdot J(W) + \varepsilon^T(W) \cdot R(W), \quad R(W) = \left\{ \frac{\partial^2 \varepsilon_i}{\partial W_k \cdot \partial W_j} \right\} \quad (3.47)$$

Hata küçük olduğundan $\varepsilon^T(W).R(W)$ terimi ihmal edildiğinde Gauss-Newton metodu elde edilir [79],

$$H(W, n) = \nabla^2 E(W, n) \approx J^T(W, n).J(W, n) \quad (3.48)$$

Ağırlık değişim miktarını Eşitlik (3.38)'den yararlanılarak bulunabilir,

$$\Delta W(n) = -\varepsilon^T(n).J(n).(J^T(n).J(n))^{-1} \quad (3.49)$$

3.2.10.4. Levenberg-marquardt algoritması

Temel olarak bu algoritma, maksimum komşuluk fikri üzerine kurulmuş bir en küçük kareler hesaplama metodudur. Bu algoritma, Gauss-Newton ve Steepest-Descent (Geri Yayılım) algoritmalarının en iyi özelliklerinden oluşur ve bu iki metodun kısıtlamalarını ortadan kaldırır. Genel olarak bu metod yavaş yakınsama problemlerinden etkilenmez.

Gauss-Newton metodunda karşılaşılan problemlerden biri yaklaşık Hessian matrisinin tersinin hesaplanamaması durumudur. Bu problemin üstesinden gelmek için Levenberg-Marquardt (LM) algoritmasında Hessian matrisine küçük bir μ sabiti eklenir,

$$H(W) = J^T(W).J(W) + \mu I \quad (3.50)$$

Burada, $H(W)$ Hessian matrisi, $J(W)$ Jacobian matrisi, I birim matris ve μ de küçük bir sabit sayıdır. Ağırlıkların güncellenmesi Gauss-Newton metodunun ufak bir modifikasyonu ile aşağıdaki gibi hesaplanır,

$$\Delta W = -\varepsilon^T(W).J(W).(J^T(W).J(W) + \mu I)^{-1} \quad (3.51)$$

Bu algoritmanın çalışması şu şekilde özetlenebilir:

1. Performans fonksiyonu hesaplanır,
2. Küçük bir μ değeriyle başlanır ($\mu=0.01$),
3. ΔW hesaplanarak, performans fonksiyonunun bir sonraki değeri hesaplanır,
4. Performans fonksiyonunun bir sonraki değeri, şimdiki değerinden büyükse μ 10 kat artırılır,
5. Performans fonksiyonunun bir sonraki değeri, şimdiki değerinden küçükse μ 10 kat azaltılır,
6. Ağırlıklar güncellenir ve (3) adımına gidilir.

Kısaca, ağırlıklara başlangıç değerleri atanır ve hataların karelerinin toplamının hesaplanmasıyla devam edilir. Her hata terimi, hedef çıkış ile gerçek çıkış arasındaki farkın karesini ifade eder. Bütün veri seti için hata terimlerinin tamamının elde edilmesiyle, ağırlık vektörü (1)'den (5)'e kadar olan LM metodu adımlarının uygulanmasıyla adaptasyon sağlanır [79].

3.2.10.5. Esnek yayılım (resilient propagation) algoritması

Çok katmanlı algılayıcılarda, genellikle ara katmanlarda sigmoid transfer fonksiyonu kullanılır. Sonsuz genişlikteki bir aralıkta yer alan giriş değerlerini sınırlı bir aralığa sıkıştırıldığı için bu fonksiyonlar sıkıştırıcı fonksiyonlar olarak adlandırılmaktadır. Sigmoid fonksiyonlarının eğimleri, çok büyük giriş değerleri için sıfıra yakınsayacak şekilde karakterize edilirler. Bu ise ağırlık ve bias değerleri henüz optimum değerlere erişmemişken çok katmanlı YSA'da sigmoid transfer fonksiyonlarının kullanılmasından dolayı eğim değerinin çok yavaş değişebilme olasılığı karşısında, yüksek eğim azaltma ile öğrenmede problemlere neden olur [79].

Bu öğrenme algoritmasının amacı kısmi türevlerin olumsuz etkilerini öğrenme sürecinden uzaklaştırmaktır. Bu algoritma Riedmiller ve Braun tarafından 1993 yılında geliştirilmiştir. Ağırlıkların güncelleştirme yönü için sadece türevlerin işaretleri kullanılır. Ağırlıkların güncelleştirilmesinde türev değerinin alınmaması bu algoritmayı diğerlerinden ayıran en önemli özelliğidir. Bu özelliği esnek yayılıma, hızlı çözüme ulaşma yeteneği kazandırmıştır.

Ağırlıkların değişimi, her adımda hata fonksiyonu $E(k)$ 'nin ağırlık değişim değeri $A_{ji}(k)$ 'nin bulunmasıyla başlar. Ağırlıkların değişimi ise,

$$\Delta W_{ji}(k) = \begin{cases} -A_{ji}(k), & \text{Eğer } B(k) > 0 \\ +A_{ji}(k), & \text{Eğer } B(k) < 0 \\ 0, & \text{Aksi halde} \end{cases} \quad (3.52)$$

ile hesaplanır. Burada $B(k) = \frac{\partial E}{\partial W_{ji}}(k)$ ile hesaplanır. $A_{ji}(k)$ ise,

$$A_{ji}(k) = \begin{cases} \eta A_{ji}(k-1), & \text{Eğer } B(k-1).B(k) > 0 \\ \mu A_{ji}(k-1), & \text{Eğer } B(k-1).B(k) < 0 \\ A_{ji}(k-1), & \text{Aksi halde} \end{cases} \quad (3.53)$$

Burada $B(k-1) = \frac{\partial E}{\partial W_{ji}}(k-1)$, η ve μ sırasıyla $0 < \mu < 1 < \eta$ arasında artma ve azaltma faktörleridir.

Ardışık iki iterasyonda, performans fonksiyonu ile türev işaretleri aynı ise her bir ağırlık ve bias değeri için güncelleme faktörü değeri, birden büyük bir katsayı ile çarpılır. Eğer farklı işaretler söz konusu ise güncelleme faktörü değeri birden küçük bir katsayı faktörü kadar azaltılır. Türev değeri sıfır ise güncelleme değeri sabit kalır. Ağırlıklar salınım yaptığında, ağırlık değişimi azalacaktır. Eğer ağırlıklar birkaç iterasyon boyunca aynı yönde değişim gösterirse ağırlık değişimi artar. Bu öğrenme algoritması genel olarak standart yüksek eğitim azaltma algoritmalarından çok hızlıdır. Hafızada eski değerlerin saklanması gerektirmez.

3.2.10.6. Eşleştirmeli eğitim (conjugate-gradient) algoritmaları

Geri yayılım algoritması ağırlık değerlerini, eğimin negatifi yönünde dengeler. Bu doğrultu eğimin hızla düştüğü doğrultu olarak bilinir. Bu doğrultuda performans fonksiyonu da hızla düşer. Performans fonksiyonundaki hızlı düşüş, ağırlık hızlı

yakınsamasını sağlamayabilir. Conjugate-Gradient algoritmalarında, eğim azaltım yöntemindeki doğrultulardan genellikle daha hızlı yakınsayan eşleştirme doğrultularındaki bir arama işlemi yapılır [79].

Eğim azaltımlı öğrenme algoritmalarında global minimuma doğru olan ağırlık güncellemesindeki adım oranını belirleyen bir öğrenme oranı parametresi kullanılmaktadır. Eşleştirmeli eğim algoritmasında adım boyutu, her bir iterasyonda yeniden güncellenir. Performans fonksiyonunun o doğrultu boyunca minimize edileceği adım boyutunu belirlemek için, eşleştirmeli eğim doğrultusu boyunca bir arama gerçekleştirilir.

Literatürde mevcut olan eşleştirmeli eğim algoritmalarının farklı varyasyonları aşağıda özetlenmiştir.

Fletcher-Reeves eşleştirmeli eğim algoritmalarında ilk iterasyon, negatif eğim değeriyle belirlenen doğrultuda arama işlemiyle başlar,

$$p_0 = -g_0 \quad (3.54)$$

Mevcut arama doğrultusu boyunca gidilecek optimum mesafenin belirlenmesi için bir doğrultu araması gerçekleştirilir,

$$X_{k+1} = X_k + \alpha_k p_k \quad (3.55)$$

Daha sonra bir önceki arama doğrultusuyla eşleştirilmek üzere yeni arama doğrultusu belirlenir. Yeni arama doğrultusunun belirlenmesinde uygulanan genel yöntem bir önceki arama doğrultusu ile yeni eğim arama doğrultusunu doğrusal olarak birleştirmektir,

$$p_k = g_k + \beta_k p_{k-1} \quad (3.56)$$

Burada β_k skaler değeri p_k ve p_{k-1} doğrultularının Hessian matrisine (performans fonksiyonunun ikinci mertebeden türevleri) göre birbirine eşleştirmeli olacak şekilde seçilmesiyle elde edilir.

Fletcher-Reeves'in β_k için önerdiği güncelleme yaklaşımı Eşitlik (3.57)'de verilmiştir.

$$\beta_k = \frac{\mathbf{g}_k^T \mathbf{g}_k}{\mathbf{g}_{k-1}^T \mathbf{g}_{k-1}} \quad (3.57)$$

Bu ise mevcut eğimin norm karesinin bir önceki eğimin norm karesine oranıdır. Eşleştirmeli eğitim algoritmaları genel olarak değişken değerli öğrenme oranına sahip geri yayılım algoritmalarından daha hızlıdır. Genellikle sonucun problemden probleme farklı olabilmesine karşın esnek öğrenmeden de hızlı oldukları söylenebilir. Eşleştirmeli öğrenme algoritmaları basit algoritmalara nazaran çok daha az hafızaya ihtiyaç duyarlar. Çok sayıda ağırlığın söz konusu olduğu YSA yapılarında kullanımları son derece uygundur.

Polak-Ribiere eşleştirmeli eğitim algoritmasında, her bir iterasyondaki arama doğrultusu Fletcher-Reeves yöntemindeki Eşitlik (3.56) ile aynıdır. Bu denklemdeki β_k ifadesi,

$$\beta_k = \frac{\Delta \mathbf{g}_{k-1}^T \mathbf{g}_k}{\mathbf{g}_{k-1}^T \mathbf{g}_{k-1}} \quad (3.58)$$

olarak değiştirilerek, bir önceki iterasyondaki eğitim değişiminin mevcut iterasyondaki yeni eğitim değeriyle olan iç çarpımının önceki eğimin norm karesiyle bölümü ile elde edilir. Önceki yöntemden daha fazla hesaplama ihtiyacı olmasına rağmen performans olarak hangisinin daha iyi olduğunu söylemek zordur. Bu yöntemin hafıza ihtiyacı Fletcher-Reeves yönteminden oldukça fazladır.

Tüm eşleştirmeli eğim algoritmalarında arama doğrultusu, periyodik olarak eğimin negatif olarak oluşturulur. Normalde, algoritma iterasyon sayısı, ağ parametre sayısına (ağırlık ve bias) eşit olduğu zaman standart ilk değere dönme noktası oluşur. Bununla beraber eğitimin etkinliğini artırabilecek başka geri döndürme yöntemleri de mevcuttur. Powell-Beale yöntemi bunlardan biridir. Bu yöntemde eğer bir önceki eğim değeriyle o andaki eğim değeri arasında çok az ortogonallık varsa geri başlatım işlevi gerçekleşir. Bu koşul,

$$\left| g_{k-1}^T g_k \right| \geq 0.2 \|g_k\|^2 \quad (3.59)$$

eşitliği ile test edilir. Bu koşulun sağlanması durumunda arama doğrultusu eğimin negatifine geri döndürülür. Powell-Beale öğrenme algoritması bazı problemlerde Polak-Ribiere'den daha iyi sonuç verebilmektedir. Fakat algoritmanın hafıza ihtiyacı Polak-Ribiere'den biraz daha fazladır.

Eşleştirmeli eğim algoritmaları her bir iterasyonda doğrultu arama işlemi gerektirmektedir. Bu işlem, her bir arama işleminde ağ giriş verilerine karşı ağıın ürettiği çıkışların hesaplanmasını gerektirdiği için işlemsel olarak yoğundur. Moller tarafından geliştirilen Ölçeklendirilmiş Eşleştirmeli Eğim Algoritması zaman alıcı bir arama işleminden kaçınacak şekilde tasarlanmıştır. Eşleştirmeli eğim algoritmasıyla Levenberg-Marquardt algoritmasında kullanılan model güvenilir alan yönteminin birleştirilmesidir. Adım büyüklüğü,

$$\alpha_k = - \frac{p_k^T g_k}{p_k^T A_k p_k + \lambda_k \|p_k\|^2} \quad (3.60)$$

ile belirlenir. Ölçekleme parametresi λ 'nın yeteri kadar büyük seçilmesiyle Hessian matrisinin pozitif tanımlı olması sağlanır. Bu parametrenin optimal değeri iterasyondan iterasyona değişir. Bu parametrenin değeri büyüdükçe öğrenme oranı (adım büyüklüğü) küçülür. Bu yöntem model-güvenilir bölge olarak adlandırılır. Çünkü model sadece mevcut arama noktası etrafındaki küçük bir bölgede etkin

olarak güvenilirdir. Güven bölgesinin büyüklüğü λ parametresiyle kontrol edilir. Eğer $\lambda = 0$ ise ağırlık vektörü arama doğrultusu boyunca minimum doğru yaklaşır ve hata fonksiyonu kuadratik bir fonksiyonla ifade edilebilir ve payda pozitif olur. Eğer bu şartlar sağlanmazsa λ değerinin uygun olarak arttırılması gerekmektedir. İlk olarak Hessian matrisinin pozitif tanımlı olmaması durumunda eşitlik, $-p_k^T A_k p_k$ terimine bölünür. Yerel kuadratik yakınsamanın doğruluğu,

$$\Delta_k = \frac{E(W_k) - E(W_k + \alpha_k p_k)}{E(W_k) - (E(W_k) + \alpha_k p_k^T g_k + \frac{1}{2} \alpha_k^2 p_k^T g_k)} \quad \text{ile belirlenir.} \quad (3.61)$$

Eğer, Eşitlik (3.61)'te bulunan değer 1'e yakınsarsa yakınsama iyidir ve λ değeri azaltılabilirken tersi bir durumda λ değeri arttırılabilir. λ_k değeri Eşitlik (3.62)'daki şartlara göre güncellenebilir,

$$\begin{aligned} \Delta_k > 0.75 \text{ ise } \lambda_{k+1} &= \frac{\lambda}{2} \\ \Delta_k < 0.25 \text{ ise } \lambda_{k+1} &= 4\lambda_k \\ \text{veya} \quad \lambda_{k+1} &= \lambda_k \end{aligned} \quad (3.62)$$

Eğer $\Delta_k < 0$ ise hatada bir artış olacak ve ağırlıklar güncellenmeyecektir. Bunun yerine Δ_k değerlendirilir. Sonunda algoritma yeterince geniş bir λ_k değeri için eğimin negatifi yönünde küçük bir adım ilerleyeceği için hata azaltımı elde edilecektir. Birbirini izleyen her bir ağırlık güncellemesinden sonra Eşitlik (3.62)'daki payda artışının pozitif olmasını sağlayan λ_k 'nin arttırılma aşamaları ve yerel eğim yakınsamasının doğruluğuna uygun olarak λ_k 'nin güncellenmesi uygulanacaktır. Bu öğrenme algoritmasında bir doğru üzerinde arama işlemi bulunmadığından hesap yükü azdır. Buna karşın iterasyon sayısı diğer eşleştirmeli eğim algoritmalarından daha fazladır. Hafıza ihtiyacı Fletcher-Reeves ile yaklaşık aynıdır [79].

3.3. Yapay Bağışıklık Sistemi (YSB)

3.3.1. Giriş

Bağışıklık Sistemi; vücudumuz sürekli olarak dış çevreden gelen mikropların, virüslerin, bakterilerin vb. saldırısına uğramaktadır. Bağışıklık sistemi, bu mikroorganizmaların vücuda zarar vermesini engellemek ve bir an önce vücudu terk etmelerini sağlamak için gerekli işlemleri başlatır. Bu işlemlerin hepsine birden ‘bağışıklık cevabı’ adı verilir. Bağışıklık cevabının gerçekleştiği süre içerisinde “hastalık” devam eder. Bu süre, mikroorganizmanın yapısına ve vücudun direncine göre farklılık gösterdiği için hastalık süreçleri de farklılık arz etmektedir. Bağışıklık cevabının sonunda vücut mikroorganizmayı yenmeyi başardıysa bu mikroorganizmaya duyarlı hücreler hafıza hücreleri olarak saklanır. Buradaki amaç, vücudun söz konusu mikroorganizmaya karşı bağışıklık kazanmasını sağlamaktır. Bağışıklık cevabında olumlu bir yanıt oluşmayabilir. Bu durumda hastalığın ilerlemesi söz konusudur ve vücut hastalıkla savaşmaya devam eder [100].

Bu sistemin çalışmasının en güzel ve basit örneği mikropların vücudumuza girdiğinde onlara karşı antikorların oluşması ve bunlarla savaşılmasıdır; aynı mikropla tekrar karşılaşıldığında bu antikorlar bizi hastalanmaktan korur. Antikor vücuda giren yabancı maddelere karşı savunma hücrelerinin verdiği yanıtıdır.

Bağışıklık sisteminin uygun bir yol gösterici model olmasının nedeni, sahip olduğu karakteristik özellikleri. Memelilerdeki bağışıklık sistemleri, yeni bilgileri öğrenebilmektedir ve önceden öğrenilmiş bilgileri hatırlayabilmektedir. Ayrıca oldukça yaygın bir örüntü algılama kapasitesine sahiptir. Öğrenme, hatırlama, algılama ve sınıflandırma görevlerini, paralel ve adaptasyonu yüksek bir sistem kullanarak yerine getirmektedir. Bu özelliği sayesinde, birbirinden bağımsız birçok farklı tehdidin üstesinden gelebilmektedir. Karşılık verebildiği moleküler imza ya da antijen sayısı, 10 katrilyondur. Tek bir merkezden yönetilmemektedir ve hata toleransı çok yüksektir. Bu da bazı hücreler fonksiyonunu yitirdiğinde ya da sistemin belli bir kısmı yok olduğunda, sistemde bir çökme yaşanmamasını sağlamaktadır. Ayrıca bağışıklık sistemi belli bir patojenin antijenlerini algılamayı bir kez

öğrendikten sonra, bu bilgi yok olmaz. Hücrelerden bazıları çok uzun süre hayatta kalacak "bellek" hücreleri haline gelmekte ve aynı patojenin sonraki saldırılarında yeniden aktif hale gelmektedir. Bunların tümü, bilgisayar güvenliği bilimcilerinin oldukça işine yarayacak özelliklerdir.

Ancak, bağışıklık sisteminin iyi bir model olmasını sağlayan asıl özelliği, tüm bu fonksiyonlarının işleyiş yapısının kolayca basit algoritmalara dönüştürülebilir nitelikte olmasıdır. Bilgisayar güvenliği alanında halen kullanılmakta olan yöntemlerin tümü, kural tabanıdır. Yani verimli olabilmeleri için, olası tüm saldırı ve tehlike türlerinin önceden tanımlanarak sisteme girilmesi gerekmektedir. Bunun en önemli dezavantajı, bilgisayar alanındaki yeni bir dolandırıcılık tipinin ya da virüsün, yayılmadan önce belirlenip tanımlanmasındaki güçlülüdür. Özellikle finans işlemlerinde sahtekârlık yapmaya çalışan kişiler, kendilerini dolandıracakları şirketin çalışanıymış gibi göstermeye kadar varan türlü yöntemlere başvurmaktadır. Vücudumuzdaki proteinleri taklit eden patojenik virüslerin davranışları da, bu kişilerinkine benzer niteliktedir. Ancak memelilerin bağışıklık sistemi, barındırdığı hatırlama, genelleme ve sınıflandırma gibi özellikleri kullanarak önceden tanımadığı bu tür tehlikelere karşı da tepki verebilmektedir. Bağışıklık tabanlı sistemler üzerinde çalışan uzmanların amacı, bağışıklık sistemimizin bu sorunun üstesinden gelmek için kullandığı süreçlerin benzerlerini kullanarak bilgisayar sistemlerindeki güvenlik sorunlarını çözmektir. Doğal bağışıklık sistemlerinin diğer bir önemli özelliği ise, dışarıdan gelen saldırılar yanında, içeriden yapılan saldırıları da tespit edebiliyor olmasıdır. Bağışıklık sistemimiz bunu, vücudun kendi hücre ve moleküllerini temsil eden "öz" ve bunların dışında kalan her şeyi kapsayan "öz olmayan" ayrımını yaparak başarmaktadır.

YBS, yapay sinir ağları ve genetik algoritmalara benzer şekilde, insan vücudundaki biyolojik bağışıklık sisteminin özet modelidir ve birçok alanda uygulaması bulunmaktadır. Tanım olarak YBS, teorik bağışıklık ve karmaşık problem uzaylarına uygulanan gözlemlenmiş bağışık fonksiyonlar, ilkeler ve modellerden esinlenmiş hesapsal sistemlerdir [9].

3.3.2. YSB' nin tarihi gelişimi ve uygulama alanları

YBS düşüncesinin ilk doğuşunu sağlayan bilgisayar virüsleridir. Bilgisayarlardaki "virüs" terimini 1986 yılında ilk kez kullanan Fred Cohen, bu terimin tanımını "kendisinin yeni bir versiyonunu üreterek, başka programların içine giren ve bunları değiştiren bir program" olarak yapmıştı. Bu tanıma yaparken ilham kaynağı, saldırdıkları hücrenin kaynaklarını kullanarak kendilerini çoğaltan biyolojik virüslerdi. Bu örnekte olduğu gibi doğadaki "iyi fikirleri" çalmak, bilgisayar biliminin köklü bir geleneğidir. Yapay sinir ağları ve genetik algoritmalar, bu geleneğin en önemli temsilcilerindedir. İlham kaynağı insan beyni olan yapay sinir ağları çalışmalarının amacı, sinir hücrelerinin insan beynindeki düzenlenişlerini modelleyerek yapay zekâ geliştirmek. Genetik algoritmalarsa, doğadaki evrim mekanizmalarını taklit ederek makinelerin öğrenmesini sağlamayı hedefliyor. Şimdiye kadar kendine oldukça yaygın uygulama alanı bulan bu ikisine göre daha yeni olan bir yaklaşımsa YBS'dir. YBS düşüncesinin doğuşunu sağlayan, bilgisayar virüsleri siber âleme yıllarca tehdit salmış ve bu dijital canavarlarla mücadele yolları üzerinde çalışan uzmanlar, bunu başarabilmek için türlü yöntemler denemişlerdir. Ancak bunların hiçbiri, bilgisayarlarımıza bulaşan virüslerden tamamen kurtulmamızı sağlayamadı. Son yıllardaysa bu mücadelede, biyolojik bir benzetmeye başvurarak yapay bir bağışıklık sistemi kurulmaktadır. İnsan vücudundaki bağışıklık sistemi, bilgisayar virüslerinin isim babalarının insan vücudunda yarattığı sorunların üstesinden başarıyla geliyor. Buradan yola çıkan uzmanlar, insan vücudunun virüslere karşı gösterdiği biyolojik savunma yöntemlerini taklit ederek bilgisayarlar üzerinde kurulacak bir bağışıklık sisteminin, tüm dünyadaki bilgisayarlardan yayılan yeni virüsleri çabucak ve otomatik olarak bulup analiz ederek, ortadan kaldırdırabileceğini savunuyor [100].

YBS alanındaki çalışmaların kökeni daha eskilere dayanıyorsa da, bu alana duyulan asıl ilgi 1996 yılında yapılan Bağışıklık Tabanlı Sistemler (Immunity Based Systems) isimli uluslararası toplantıyla başladı. Bu toplantıdan sonra bir grup, bağışıklık sisteminin modelini çıkartarak çalışma şeklini daha iyi anlama yolunu seçti. Diğerleriyse yapay sinir ağları ve genetik algoritmalar alanlarında olduğu gibi, bağışıklık sistemini bir metafor olarak kullanma yoluna gitti. Doğadan gelen bu son

metaforun en doğal uygulama alanlarıysa, finans sektöründeki ve elektronik ticaret alanındaki dolandırıcılık tespiti ve bilgisayar güvenliği oldu. Çünkü vücuttaki bağışıklık sisteminin karşılaştığı sorunlarla bilgisayar güvenliği alanında yaşanan sorunlar arasında, oldukça fazla benzerlik bulunmaktadır. Doğal bağışıklık sistemleri canlıları bakteriler, virüsler, parazitler ve toksinler gibi tehlikeli dış patojenlerden korumaktadır. Bu nedenle vücuttaki rolleri, bilgisayarlardaki güvenlik sistemlerinininkine benzer. Canlı organizmalarla bilgisayar sistemleri arasında birçok farklılık varsa da, benzerlikler bilgisayar güvenliğini geliştirmek için yeterince yol göstericidir [100].

Forrest ve arkadaşları, r -ardışık bit kuralı ve bir negatif seçim algoritması kullanılarak “self” ve “nonself” ayırımına dayanan bir bilgisayar güvenliği sistemi incelenmiştir. Sistem negatif seçim algoritması mantığına göre çalışmaktadır. Önce bir algılayıcılar kümesi oluşturulmakta, sonra korunan veriler oluşturulan algılayıcılar ile karşılaştırılarak izlenmektedir. Eğer iki dizideki ortak ardışık bitlerinin sayısı bir r sayısından büyük veya eşit ise, bir eşleşmeden bahsedilebilir. Çalışmada ayrıca, iki rastgele dizi arasında bir eşleşme olma olasılığını ve sistemin farklı konfigürasyonları için değişiklik-tespit olasılığını tahmin etmek üzere formüller verilmiştir. Elde edilen sonuçlara göre, korunacak dizilerin sayısı arttıkça, kullanılan algılayıcıların boyutunun artmasına gerek yoktur. Tespit olasılığı, bağımsız tespit algoritmalarının sayısı ile üstel olarak artmaktadır. Algılayıcı oluşturmanın maliyeti “self” kümesinin büyüklüğü ile üstel artmaktadır [88].

Bir yapay bağışıklık sisteminin dağıtılmış, sağlam (robust), dinamik, çeşitlendirilmiş, adapte edilebilen bir sistem olması özelliklerini kullanarak, bilgisayar ağı güvenliği konusunda yapılmış çalışmalar bulunmaktadır. Bu yapay bağışıklık sistemlerinde, bağışıklık sisteminin kullanışlı özelliklerinin hepsini içeren temel bir tip algılayıcı tanımlanmıştır. Algılayıcılar ikilik bir Hamming şekil-uzayında bit-dizileri ile gösterilmiştir. Tespit olayı, iki dizi arasındaki r -ardışık bit’in eşleşmesi süreci ile sağlanır. Negatif seçim ile birlikte yalnız algılayıcıların hafıza algılayıcılarına olgunlaştırılması sistemin öğrenme kısmının sorumluluğudur. Kurulan yapay bağışıklık sistemi, bir sınıflandırıcı sistemin (classifier system) çoğu önemli özelliği ile örtüşmektedir. Önerilen YBS, her birinde 100 algılayıcının bulunduğu, 50

bilgisayardan oluşan bir ağ sisteminde; sekiz tane normal dışı olayın tamamını tespit etmiştir. Bu alandaki bazı sistemler, bir ayda, milyonlarca yanlış alarm verirken; önerilen sistem günde ortalama iki yanlış alarm vermiştir [89,90].

Somayaji ve arkadaşları, biyolojik bağışıklık sistemine dayanarak bir bilgisayar bağışıklık sisteminin geliştirilmesi sürecini geniş bir şekilde anlatmışlardır. Bağışıklık sisteminin kullanılabilir prensiplerini ve uygulama için mümkün olan yapıyı ortaya koymuşlardır [91].

Yapay bağışıklık sisteminin uygulama alanlarından biri de optimizasyon problemleridir. De Castro ve Von Zuben optimizasyon problemleri için kendilerinin önerdiği CLONALG algoritmasını kullanmışlardır. CLONALG algoritmasını 30 şehirli bir gezgin satıcı problemine uygulamışlardır. Problem için çalışmada bir tam sayılı şekil uzayı (shape space) kullanılmıştır. L uzunluğundaki tamsayı değerli vektörler, $C=\{1,2,\dots,L\}$ elemanlarının permütasyonlarından oluşur ve bu vektörler mümkün turları belirtirler. Tamsayı vektörünün her bir bileşeni bir şehri gösterir. Her bir turun toplam uzunluğu, bir tura karşılık gelen vektörün benzerlik ölçüsünü verir [83,92].

Mutasyon basitçe, turları belirten antikolar içindeki şehir çiftlerinin yerlerini değiştirmek ile sağlanır. Çalışmada, Moscato ve Fontanari tarafından ele alınan problem YBS ile çözülmüştür. Popülasyon büyüklüğü (antikor popülasyonu) 300 bireydir. Her 20 nesilde bir, antikoların en kötü %20'lik kısmı yenileri ile yer değiştirir. Algoritma 300 adım sonra, optimal sonuca ulaşmıştır [87].

Costa ve arkadaşları, paralel makinelerde toplam tamamlanma zamanının (makespan) indirgenmesi problemi üzerinde durmuşlardır. Çalışmada CLONALG algoritması üzerine kurulan bir yapay bağışıklık sistemi modeli ile bazı sezgiseller karşılaştırılmıştır. Karşılaştırılan sezgiseller; LPT, Multifit, Lokal Arama ve Tavlama Benzetimidir. Problem için her olurlu çözüm, örneğin tam bir çizelge, sabit n büyüklüğünde bir dizi olarak kodlanmıştır. Dizi üzerindeki her pozisyon bir süreç ile ilişkilidir. Her i pozisyonunun değeri işlemin yerleştirileceği makineyi belirtir [93].

Popülasyonun her bir antikoru (çözümü) için bir benzerlik (affinity) değeri vardır. Aşağıdaki denklemde gösterilen bu benzerlik değeri, çözümün kalitesini yansıtır:

$$\text{LB Benzerlik}(k) = (1+M(k) - \text{LB}) \quad (3.63)$$

Burada; $M(k)$; k antikoru ile gösterilen çözümün toplam tamamlanma zamanını (makespan) gösterir. LB ; problemin alt limitini belirtir. Bu alt limit, tüm işlem zamanları toplamının işlemci sayısına oranı ile bulunur [93].

Denklemdaki payda; $M(k)$ 'nın LB 'ye yakın olduğu durumlarda benzerliğin daha yüksek olmasını dolayısıyla çözümün iyileşmesini sağlar. Durdurma kriteri, en iyi çözüm üzerinde ilerleme sağlamadan geçen belirli bir nesil sayısıdır, ayrıca bir zaman sınırı da verilmiştir. Algoritma, 390 örnek problem üzerinde test edilmiştir, her bir işin işlem süresi $[1,k]$ aralığında uniform dağılımdan seçilmiştir. Algoritma diğer yöntemlere göre daha iyi sonuçlar vermiştir, özellikle uzun işlem süreli ve az sayıda makinenin olduğu problemlerde algoritma oldukça etkilidir. Yazarlar, iyi performansın nedeninin bağışıklık sisteminin sunduğu yüksek çeşitlilikten kaynaklandığını belirtmişlerdir [93].

Atölye tipi çizelgeleme problemlerine sağlam (robust) çözümler bulmak amacıyla Jensen ve Hansen tarafından bir çalışma yapılmıştır. Gerçek bir sistem için optimal çizelgeler yerine, değişen şartlara göre üzerinde kolayca değişiklik yapılabilecek çizelgelerin bulunmasının önemine dikkat çeken yazarlar, bu amaca yönelik bir yapay bağışıklık sistemi geliştirmişlerdir. Çalışmada her biri bir miktar genetik dizi içeren kütüphaneler kurulmuştur, her dizi bir atölye tipi problem kümesi çözümünün bir parçasıdır. Atölye tipi probleme çözüm, her kütüphaneden dizileri seçerek (bu dizi bir antikordur) ve seçilen dizinin kodu çözülerek bulunabilir. Her işin başlama tarihleri değiştirilerek bir antijen kümesi elde edilir. Bu antijenler, çeşitli hatalar veya duraksamalar nedeniyle mevcut planlardan farklı olarak ortaya çıkan çizelgelere karşılık gelir. Çalışmada, bir sağlamlık ölçütü tanımlanmıştır. Bu ölçüte göre yapılan

değerlendirmeler göstermiştir ki, sağlam çözümler mevcuttur ve bu çözümler YBS ile bulunabilir [94].

Hart ve arkadaşları, her işin belirli başlama ve bitiş tarihlerinin olduğu atölye tipi çizelgeleme problemlerinde maksimum gecikmeyi, en aza indirmek için yapay bağışıklık sistemi modeli kullanmışlardır. Model iki aşamalı çalışmaktadır. Sistemin birinci aşamasında, fabrikada en sık kullanılan ortak iş çizelgeleri modellerini tespit etmek için genetik algoritma (GA) ile birleştirilmiş bağışıklık sistemi yaklaşımı kullanılmaktadır. İkinci aşamada, tespit edilen modelleri kullanarak yeni çizelgeler üretmek için doğal bağışıklık sistemlerinin kombinatorik özellikleri modellenmiştir. Sonuçlar, geniş çaplı bir araştırma prosedürü kullanan bir model ile karşılaştırılmıştır. Önerilen algoritma oldukça başarılı sonuçlar vermiştir, şöyle ki, daha önce ortaya çıkan herhangi bir duruma karşılık gelen çizelgeler kolaylıkla tekrar oluşturulabilmektedir [95].

Mori ve arkadaşları, bir yarı iletken üretim hattını kontrol etmek için genel bir otonom dağıtılmış sistem tanımlamışlardır. Çalışmalarında, üretim hattının kontrolü bir ajanlar (agents) kümesi (detector, mediator, inhibitor ve restoration ajanları) ile yapılmaktadır. Her bir ajan üretim hattı ve diğer ajanlarla ilişki içindedir. Bu ilişki omurgalı bağışıklık sistemindeki ilişkiye dayanmaktadır. Örneğin, detektör ajanlar, bağışıklık sistemindeki B hücrelerine karşılık gelir ve sistemdeki belirli aksaklıkları tespit etmek için kullanılır. Sistem pratikte denenmemesine rağmen, çalışmada sistemin gerçek zamanlı karar vermede ve değişen çevreye uyum sağlamada başarılı olacağı iddia edilmiştir [96].

Dasgupta, ve Forrest, alet hatası tespiti için bir yapay bağışıklık algoritması geliştirmişlerdir. Metot; bağışıklık sisteminin self (vücut elemanları) ve nonself (yabancı elemanlar) hücreleri birbirinden ayırmayı sağlayan negatif-seçim mekanizmasından ilham almıştır. Bu uygulamada ‘self’, normal kesme operasyonu değerlerini, ‘nonself’ ise izin verilen kesme kuvveti farklılığının ötesinde herhangi bir sapmayı belirtir. Önerilen algoritma, torna operasyonları için bir simülasyon çalışması ile gösterilmiş ve kalem ucunun bozulması durumunda algoritmanın bunu

tespit etme performansı belirlenmiştir. Algoritma, tüm test durumları için kalem ucundaki bozulmaları tespit etmiştir [97].

Lee ve arkadaşları, yapay bağıklık sistemini dağıtılmış, otonom robot sistemine (DARS-Distributed Autonomous Robot System) uygulamışlardır. Her robot; bir “B” hücresi, her bir çevresel durum; bir antijen, bir davranış stratejisi; bir antikor ve bir kontrol parametresi de bir “T” hücresi olarak ele alınmıştır. Sistemin çalışmasında; çevresel durum değiştiğinde her robot uygun bir davranış stratejisi seçer ve onun bu davranış stratejisi iletişim ile diğer robotlar tarafından tetiklenir ve yayılır. Sonuçta en çok kabul gören strateji, kümenin davranış stratejisi olarak belirlenir. Bu kontrol şeması klonal seçim ve idotopik ağ hipotezine dayanır. T hücre modellemesi kullanılarak, robotun dinamik ortamlara uyum yeteneği geliştirilmiştir [98].

Dasgupta ve Forrest, zaman serileri verilerindeki farklılaşmaları tespit etmek üzere bir negatif seçim algoritması önermişlerdir. Zamanla kesme kuvveti değerleri değişmektedir. İzin verilen sapmanın ötesindeki değerler sistemdeki ‘non-self’ leri belirtmektedir. Sistemin elemanlarını tasvir etmek için bir ikilik Hamming şekiluzayı uygulamışlar ve algılayıcılar ile kodu çözülmüş veri arasındaki algılamının derecesini belirlemek için bir r ardışık bit kuralı uygulamışlardır. Yazarlar iki veri seti için sonuçları vermişlerdir: bir tornalama operasyonunun kesici dinamikleri ve bir sentetik sinyal. Eşleştirme fonksiyonu ile seçilen r -ardışık bitlerinin sayısının hataların tespitindeki riskin güvenilirliğini etkilediğini göstermişlerdir [99].


Bağıklık sisteminin diğer özelliklerini şöyle sıralayabiliriz:

1. Örüntü tanıma
2. Eşsizlik
3. Öz kimlik
4. Çeşitlilik
5. Kullanıldıktan sonra atılabilme
6. Özerklik
7. Çok katmanlılık
8. Güvenlik katmanı yok

9. Anomali tespiti
10. Dağıtıklılık
11. Gürültü toleransı
12. Esneklik dirençlilik
13. Hata toleransı
14. Sağlamlılık
15. Bağışık öğrenme ve hafıza
16. Cevabın av-avcı örüntüsü
17. Kendi kendine organizasyon
18. Diğer sistemlerle entegrasyon

YBS çatısı, katmanlı bir yaklaşım olarak düşünülebilir (Şekil 3.12). Her sistemin temeli uygulama domenidir. Uygun bir temsile karar verildikten sonra bir ya da daha fazla afinite ölçüleri sistemin elemanları arasındaki etkileşimleri ölçmek için kullanılır. Birçok olası afinite ölçüleri, Hamming ya da Öklid uzaklıkları gibi, vardır. Bir sonraki katman sistemin davranışını (dinamiğini) yöneten işlemler ya da algoritmaları içerir. Bu da bize, cevabı verir.

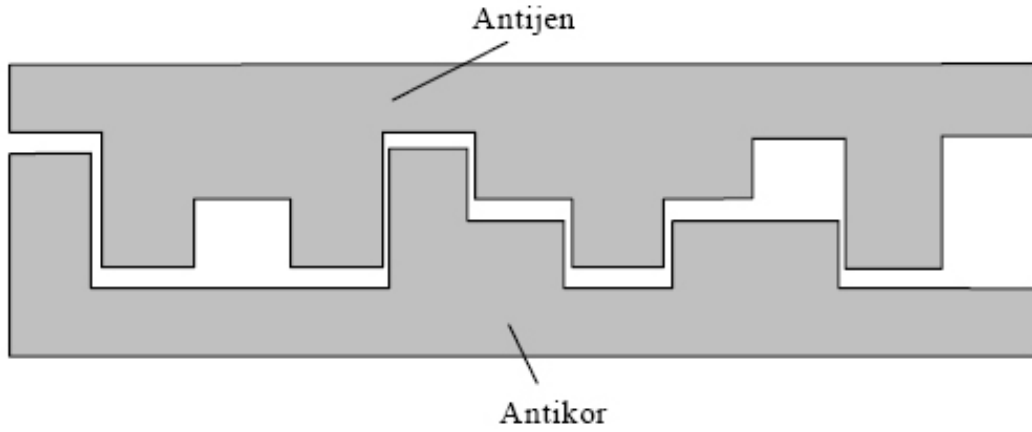
Bu yapıya göre çatı, şekil-uzayı olarak adlandırılan bağışık hücreler ve moleküllerin genel soyut modelini çıkarmakla başlar [100].



Şekil 3.12. Yapay bağışıklık sistemi için katmanlı çatı

3.3.3. Bağışık hücre, molekül ve bunların etkileşiminin soyut modelleri

Bir antijenin tanınabilmesi için moleküllerin (antijen ya da antikor) yüzeylerindeki belli bölgelerde birbirleriyle komplementer bağlanmaları gerekmektedir. Bu yüzden Şekil 3.13'te gösterildiği gibi moleküller arasında geniş komplementer bölgelerine ihtiyaç vardır.




Şekil 3.13. Komplementerin bölgeleri aracılığıyla tanıma

ε parametresi çapraz reaktivite eşiği olarak adlandırılır. V_s tanıma bölgesidir. Şekil 3.14, bunlar arasındaki ilişkiyi göstermektedir.

Temsil olarak vektörler kullanılabilir.

$$\mathbf{Ab} = (Ab_1, Ab_2, \dots, Ab_L) \quad (3.64)$$

$$\mathbf{Ag} = (Ag_1, Ag_2, \dots, Ag_L)$$



Şekil 3.14. Şekil-uzay formalizmi

Gerçek değerli şekil uzayı, tam sayı şekil uzayı, Hamming şekil uzayı sembolik şekil uzayı da kullanılabilir. Hücreler arasındaki etkileşim de afinite ile açıklanır. Afinite çeşitli uzaklık ölçülerine bağlıdır. Öklit uzaklığını şu şekilde gösteririz:

$$D = \sqrt{\sum_{i=1}^L (Ab_i - Ag_i)^2} \quad (3.65)$$

Diğer uzaklık ölçüleri olarak Hamming, Manhattan vb. uzaklıklar kullanılabilir [100].

3.3.4. Algoritmalar ve işlemler

İki temel bileşen (kemik iliği ve timus) ve iki ayrı teori (klonal seçim ve bağışık ağ) bağışıklık sistemini modellemek için kullanılır.

Kemik iliği modeli: Hücrelerin ve moleküllerin repertuarını üretmede kullanılır.

Timus modeli: Öz/öz olmayan ayrımı yapmaya yetenekli hücre ve moleküllerin repertuarını üretmede kullanılır.

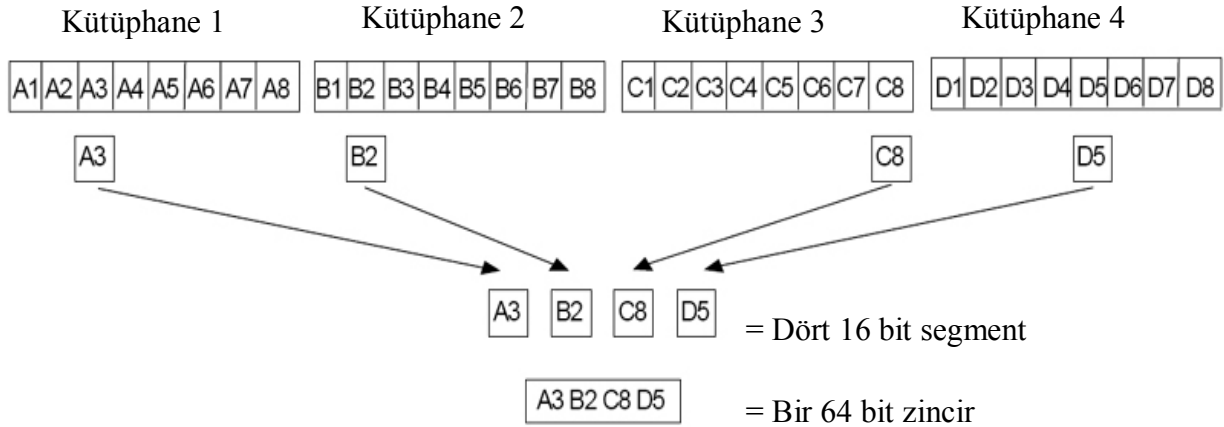
Klonal seçim algoritmaları: Bağışıklık sisteminin bileşenlerinin harici çevre ve antijenlerle nasıl etkileşim yaptığını kontrol etmede kullanılır.

Bağışık ağ modelleri: Yapılarını, dinamiğini ve metadinamiğini de içeren bağışık ağları simüle etmede kullanılır [100].

3.3.4.1. Kemik iliği modelleri

Gen kütüphanesi kemik iliğinden antikorları üretmek için kullanılır. Bu fikri reseptörleri temsil eden nitelik dizgelerini üretmek için kullanırız. Antikorlar gen kütüphanelerinden gelişigüzel birbirine bağlanma ile oluşur. Bu, Şekil 3.15'te gösterilmiştir [100].

Dört kütüphaneye uyan bir birey genomu:



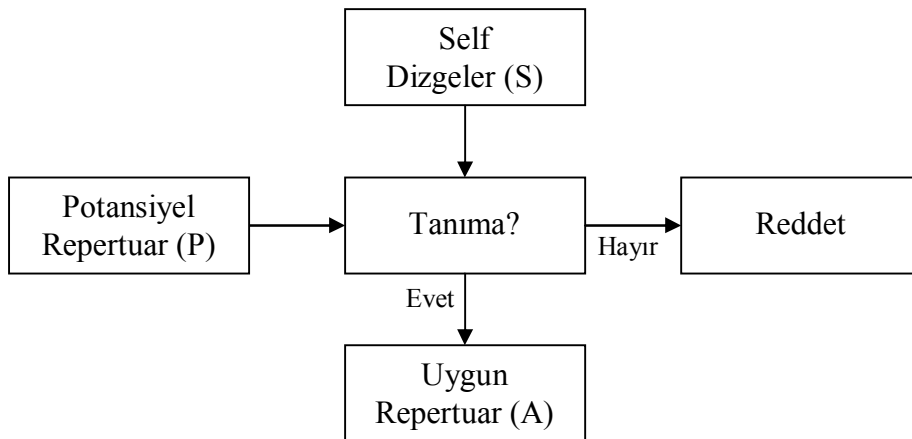
İfade edilen Ab molekülü

Şekil 3.15. Bir antikorun gen kütüphanelerinden yapımı/ifadesi

3.3.4.2. Timus modelleri

T hücreleri kemik iliğinde üretilir, timusa göçer ve orada immünokompetent hücrelere farklılaşır (pozitif seçim); diğerleri öz peptit/MHC kompleksleriyle güçlü bir tanıma yaptığından repertuardan temizlenir (negatif seçim). Bu timik pozitif ve negatif seçim timustan ayrılan ve perifere giden T hücre popülasyonunun öz peptitleri tanıyan hücreleri ihtiva etmediğini ve aynı zamanda bir öz MHC molekülü tarafından sunulan bir peptit ile uyarılmaya hazır olduğunu garanti eder [100].

Pozitif Seçim Algoritmaları:



Şekil 3.16. Pozitif seçim algoritması

Şekil 3.16'da gösterilmiştir ve şu şekilde özetlenebilir:

1. Başlangıç: Olgunlaşmamış T hücrelerinin potansiyel repertuarını, P , üret. Tüm molekülleri (reseptör ve MHC'ler) aynı uzunluklu, L , ikili dizgeler ile temsil edildiği varsayıldığında 2^L ayrı hücre üretilir.
2. Afinite değerlendirmesi: P 'deki tüm elemanların öz hücre kümesi S 'deki tüm elemanlar ile afinitelerini belirle.
3. Uygun repertuarın üretimi: P 'nin bir elemanı ile MHC'nin en az bir elemanı arasındaki afinite verilen çapraz reaktif eşiği ϵ 'den büyükse ya da buna eşitse o zaman T hücresi bu MHC'yi tanır ve pozitif olarak seçilerek sisteme tanıtılır (uygun repertuar A 'ya); değilse T hücresi elimine edilir.

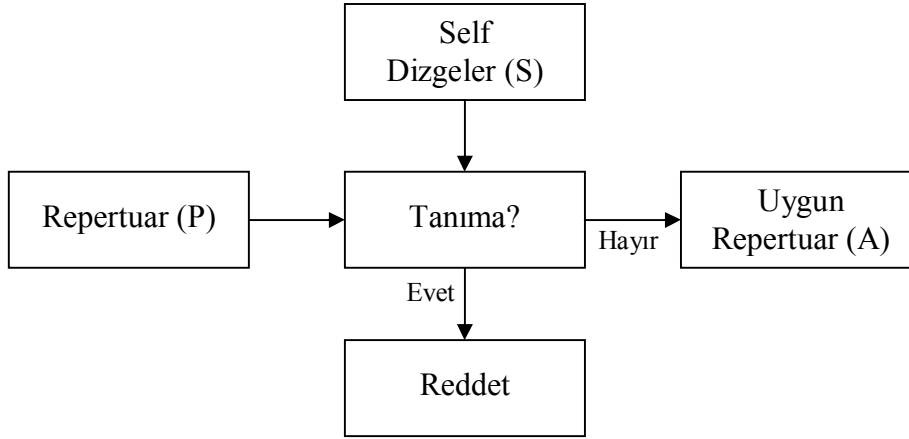
Negatif Seçim Algoritması:

T hücrelerinin negatif seçimi, reseptörleri öz MHC tarafından sunulan öz peptitlere bağlanma kabiliyeti olan T hücrelerinin eliminasyonundan sorumludur. Bu işlem timustan ayrılan T hücrelerinin herhangi bir öz hücreyi ya da molekülü tanımayacağını garanti eder.

Bir bilgi işleme perspektifi ile olaya bakılırsa, negatif seçim, örüntü tanımayı gerçekleştirmek için alternatif bir paradigma sunar. Bu paradigma tanınacak örüntüleri (öz) tamamlayıcı küme (öz olmayan) hakkında bilgi depolama mantığı ile çalışır. Literatürde; bilgisayar ve ağ saldırıları, zaman serileri tahmini, şekil denetimi ve kesimlemesi ve donanım hatası toleransı gibi anormallik belirleme problemleri ile ilgili uygulamalarla birlikte bir negatif seçim algoritması [9] önerilmiştir. Negatif seçim algoritması Şekil 3.17'de gösterilmiştir ve aşağıdaki gibi özetlenebilir:

1. Başlangıç: Gelişigüzel dizgeler üret ve bunları olgunlaşmamış T hücrelerinin bir P kümesine yerleştir. Tüm moleküllerin (reseptör ve öz peptitler) aynı uzunlukta, L , ikili dizgeler olarak temsil edildiğini varsay.
2. Afinite değerlendirmesi: P 'deki tüm T hücrelerinin S 'deki tüm elemanlarla afinitesini belirle.

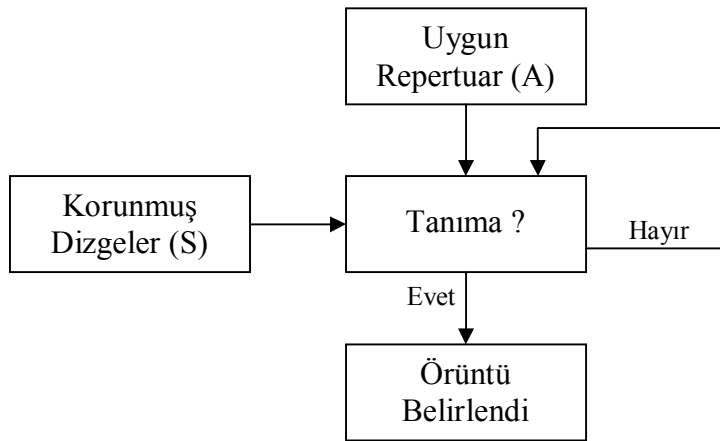
3. Uygun repertuarın üretimi: Olgunlaşmamış bir T hücresinin (P 'nin elemanı) en az bir öz peptitle afinitesi, verilen çapraz reaktif eşliğinden, ε , büyükse ya da buna eşitse o zaman T hücresi bu öz peptidi tanır ve elimine edilmelidir (negatif seçim); değilse T hücresi uygun repertuar A 'ya tanıtılır.



Şekil 3.17. Negatif seçim algoritması

Negatif seçim iki aşamaya bölünmüştür. Yukarıda anlatılan algılama safhasıdır. Algılayıcı kümesini (A) oluşturduktan sonra, algoritmanın diğer aşaması öz olmayan modellerin varlığı için sistemi izlemekten oluşan gözetleme safhasıdır ve Şekil 3.18'de gösterilmiştir.

Korunmuş dizgeler kümesi, S^* uygun repertuar A 'nın elemanları ile karşılaştırılır. S^* kümesi S 'nin kendisi olabilir ya da tamamen yeni bir küme olabilir ya da, S 'nin elemanlarından oluşmuş olabilir. Öz olmayan modellerine karşılık gelen, algılayıcı kümesinin tüm elemanları için, S^* kümesinin bir elemanını tanıyıp tanıyamadığını (eşleşme) kontrol et. Eşleşme var ise, o zaman bir öz olmayan modeli tanınmıştır ve reaksiyon başlamalıdır. Öz olmayan tespitinde sonuç aksiyonu değerlendirme problemine göre çeşitlilik gösterir ve negatif seçim algoritmasının model tanıma kapsamı dışındadır [100].



Şekil 3.18. Timik pozitif ve negatif seçimin gözleme aşaması

3.3.4.3. Klonal seçim algoritmaları

Klonal seçim prensibi önceden de değinildiği gibi bağışıklık sisteminin bir antijenik uyarıma karşı bağışıklık cevabının temel özelliklerini tanımlamak amacıyla kullanılır. Klonal seçim mekanizması, negatif seçimin rolünü tamamlayıcı olarak, bir “öz olmayan” hücre bir B hücresi tarafından tanındığı zaman nasıl bir bağışıklık tepkisi verileceğini açıklamak için kullanılmaktadır. Bu prensip, sadece antijenleri tanıyan hücrelerin çoğaldığı yani tanımayanlara göre seçildiği fikrini vurgular. Bu seçilmiş hücreler, afinite olgunlaşma işlemine mazur kalırlar ve bu işlem seçilmiş hücrelerin antijenlere benzerliğini geliştirir [100].

Bir antijen vücutta tespit edildiği zaman, kemik iliğinden antikor üretilerek bağışıklık tepkisi veren hücreler salgılanır (B hücreleri). Bu antikorlar (hücre algılayıcıları) antijenlerle birleştiği zaman yardımcı T hücrelerinden gelen sinyallerin de etkisi ile B hücresini uyarır. B hücresi uyarma ile birlikte çoğalır (bölünür) ve plazma hücreleri denilen terminal (bölünmeyen) antikor salgılayan hücelere dönüşür (farklılaşma). Hücre bölünmesi süreci (mitoz) bir klon (kopya) oluşturur. Bu klon bir tek yavru hücre veya bir küme yavrudur. Beyaz plazma hücreleri en aktif antikor salgılayıcılarıdır. Ayrıca, hızlı şekilde bölünen büyük B lenfositleri de daha düşük bir oranda antikor salgırlar.

Lenfositler çoğalma ve/veya plazma hücrelerine dönüşmenin (farklılaşma) dışında uzun ömürlü B hücrelerine (hafıza hücreleri) dönüşebilirler. Hafıza hücreleri kan, lenf, dokular boyunca dolaşır ve ikinci bir antijenik durumla karşılaşıldığında yüksek benzerlikte antikorlar üretme kabiliyetinde olan büyük lenfositlere dönüşebilir.

Bağışıklık sisteminin en önemli özelliği kuşkusuz öğrenmedir. Bağışıklık sistemindeki öğrenme, antijenleri tanıyarak kendini kanıtlayan lenfositlerin göreceli popülasyon büyüklüğünü (kopyalama ile) ve antijenlere olan benzerliklerini artırmalarını (farklılaşma) içerir [82].

Normal bir bağışıklık sistemi evriminde, organizma, bir antijen ile hayatı boyunca defalarca karşılaşır. Bir antijen saldırısına ilk tepki her biri farklı benzerlik derecesinde antikor üreten, düşük benzerlik değerine sahip B hücreleri tarafından verilir. Bağışıklık sisteminin 2. saldırıya verdiği tepkinin etkinliği ilk enfeksiyon sonucunda oluşan hafıza hücrelerinin varlığı ile artırılır. Hafıza hücreleri, yüksek benzerlikte antikor üretebilirler. Bu strateji ile her enfeksiyondan sonra bağışıklık tepkisinin sürati ve doğruluğu artar. Bu mutasyon ve seçim algoritmasını defalarca tekrar ederek, bağışıklık sistemi yüksek benzerlikteki antikorları üretmeyi “öğrenir”. Bu olay, sistemin yeteneğini sürekli olarak artırmayı sağlayan bir takviyeli öğrenme stratejisidir [82-83].

Klonal seçim, Charles Darwin’in evrim teorisinin üç temel fonksiyonu olan farklılaştırma, çeşitlendirme ve doğal seçim mekanizmalarını kullanır. Burada, bağışıklıkla ilgili dikkate alınan temel olaylar aşağıda verilmiştir:

1. Dağarcıktan fonksiyonel olarak ayırt edilmiş olan hafıza hücrelerinin varlığının sağlanması
2. En fazla uyarılmış hücrelerin seçimi ve klonlaşması
3. Uyarılmamış hücrelerin ölümü
4. Daha yüksek afiniteli klonların afinite olgunlaşması ve tekrar seçimi
5. Farklılaşmanın üretilmesi ve sağlanması
6. Hücre afinitesi ile orantılı olarak hipermutasyon işleminin uygulanması

Bu özellikler bir problemi çözmek için algoritma formunda temel adımlar olarak şu şekilde yazılabilir:

1. Hafıza hücrelerinin (M) bir bölümünün geri kalan popülasyona (P_r) ilave edilmesiyle ($P=P_r+M$) elde edilen hücreler kümesinden oluşmuş bir aday çözümler seti (P) üret.
2. P popülasyonundan afinite ölçümüne göre en iyi n bireyi (P_n) belirle.
3. Popülasyondaki bu en iyi n tane bireyi, klonların (C) geçici bir popülasyonunu oluşturmak için klonla (tekrar üret). Klon büyüklüğü antijene benzerlikle artan bir değere sahiptir.
4. Klonlar popülasyonunu hipermutasyon işlemine tabi tut (Hipermutasyon oranı antikorun benzerliği ile doğru orantılıdır). Olgunlaşmış antikor popülasyonu (C^*) oluştur.
5. Hafıza setini, gelişmiş hücreler C^* 'den tekrar seçerek oluştur (P kümesinin bazı üyeleri C^* 'nin diğer bazı gelişmiş hücreleri ile yer değiştirebilir).
6. Farklılaşmayı sağlamak için popülasyonun düşük afiniteli antikorlarını (d) yenileri ile değiştir.

Algoritma Şekil 3.19'da gösterilmiştir:

```

Gelişigüzel bir popülasyon ( $P$ ) üret
For  $Ag$ 'deki her örüntü için
    Her  $P$  ile afiniteyi belirle
     $P$ 'den en yüksek  $n$  afiniteliyi seç
         $Ag$  afinitesi ile doğru orantılı olarak klonlama ve mutasyon yap
     $P$ 'ye yeni mutantlar ekle
endFor
 $M$ 'nin bölümünü oluşturmak için en yüksek afiniteli  $P$ 'yi seç  $n$  tanesini yeni
oluşturulmuşlarla yer değiştir

Sonlandırma kriterine kadar

```

Şekil 3.19. Klonal seçim algoritması

3.3.4.4. Bağışık ağ modelleri

Diferansiyel denklemler temelli sürekli ağ modelleri başarılı bir şekilde özerk hareket, optimizasyon ve otomatik kontrol gibi kompleks problemlere uygulanmıştır. Bunlar aynı zamanda fark denklemleri temelli ayrık ağ modellerine de ilham olmuştur.

Farmer ve arkadaşları bağışık ağ teorisi için bit dizgesi modeli önermişlerdir [84]. Bunların çalışması çok önemlidir, çünkü matematiksel teorili bağışıklık ile hesapsal zekâ paradigmasını birlikte ilk kullanma adımını atmışlardır. Bu modelde bağışık hücre ve moleküller bir Hamming şekil-uzayında değişken uzunluklu ikili dizgeler olarak temsil edilmiştir. Dizgelerin, iki molekülün birden fazla yolla reaksiyon verebileceği muhtemel herhangi bir dizilimde komplementer olarak uyuşmalarına izin verilmiştir. Aşağıdaki denklem uyuşma kesinlik matrisini belirtmektedir.

$$m_{ij} = \sum_k G\left(\left(\sum e_i(n+k) \wedge p_j(n)\right) - \varepsilon + 1\right) \quad (3.66)$$

$e_i(n)$ i . paratopun n . biti, $p_j(n)$ j . paratopun n . biti, $\wedge e_i(.)$ ve $p_j(.)$ arasındaki Hamming uzaklığına ve ε çapraz-reaktivite eşliğine tekabül eder. k parametresi bir paratop ve epitop arasındaki verilen bir dizilime karşılık gelir. Bir ya da daha fazla dizilimde eğer uyuşma olursa, bunların kuvvetleri toplanır. Bu farklı uzunluklu dizgelerin durumunu içerir. $G(.)$ fonksiyonu bir epitop ve bir paratop arasındaki muhtemel reaksiyonun gücünü ölçer ve şu şekilde hesaplanır:

$$G(x) = \begin{cases} x & x > 0 \\ 0 & \text{diğer durum} \end{cases} \quad (3.67)$$

Ağ dinamiğini modellemek için, $\{c_1, \dots, c_N\}$ konsantrasyonlu N antikor ve $\{y_1, \dots, y_M\}$ konsantrasyonlu M antijen olduğu varsayıldığında, antikor konsantrasyonunun değişim oranı şu formülle bulunur:

$$\frac{dc_i}{dt} = k_1 \left[\sum_{j=1}^N m_{j,i} c_i c_j - k_2 \sum_{j=1}^N m_{i,j} c_i c_j + \sum_{j=1}^n m_{j,i} c_i y_j \right] - k_3 c_i \quad (3.68)$$

Burada, ilk terim bir i tipinde antikorun paratopunun j tipinde bir antikor tarafından uyarımını temsil eder. İkinci terim i tipindeki antikorun epitopu j tipinde paratopla tanındığında bastırılmasını temsil eder. k_1 parametresi birim zaman başına çarpışma sayısına ve bir çarpışma ile uyarılan antikor üretim oranına bağlı sabit bir orandır. k_2 uyarı ve baskı arasındaki olası eşitsizliği temsil eder. Üçüncü terim antijen konsantrasyonunu ve son terim de ölecek hücrelerin eğilimini (doğal ölüm oranı, k_3) modeller.

Ağ yaklaşımı özellikle hesapsal araçların gelişimi için ilginçtir çünkü öğrenme, hafıza, öze tolerans, hücre popülasyonunu büyüklüğü ve çeşitliliği ağın çevre ve kendi bileşenleriyle etkileşimini içermektedir. Genel terimlerle, çoğu ağ modelinin yapısı basitçe şu şekilde açıklanabilir:

$$\begin{bmatrix} \text{popülasyon} \\ \text{çeşitlilik} \\ \text{oranı} \end{bmatrix} = \begin{bmatrix} \text{Ağ} \\ \text{uyarıya} \end{bmatrix} - \begin{bmatrix} \text{Ağ} \\ \text{bastırası} \end{bmatrix} + \begin{bmatrix} \text{Yeni} \\ \text{elemanların} \\ \text{eklenmesi} \end{bmatrix} - \begin{bmatrix} \text{Uyarıyarıl} \\ \text{ş} \\ \text{ölmü} \end{bmatrix} \quad (3.69)$$

İlk iki terim bağışık ağ dinamiğiyle ilgiliyken, son iki terim bağışık metadinamiğine tekabül eder. Ağ aktivasyonu bir paratopun başka bir antikor ya da antijenik epitop üzerinde bir idyotop tarafından uyarımını kapsar. Ağ baskısı ise bir idyotopun bir paratop tarafından tanınmasının bir sonucudur.

Timmis de RAIN (Resource limited Artificial Immune Network-Kaynak Sınırlandırılmalı Yapay Bağışık Ağ) adlı bağışık ağ öğrenme algoritması önermiştir [85]. Her ağ elemanı bir antikordan (yani Öklit şekil-uzayında bir nitelik dizgesi), bir uyarı seviyesinden ve tutulan kaynakların sayısının bir kaydından oluşan bir B hücresine tekabül eder. Bir kaynak yerleştirme mekanizması B hücre popülasyonunu kontrol etmek için kullanılır. Ağ antikorları giriş örüntülerinin (Ag) alt bir bölümü alınarak gelişigüzel başlatılır; uyarı seviyesi ve kaynakların kaydı sifıra eşitlenir.

Bir sonraki aşama antijenik örüntülerin sunumudur. Her örüntü her ağ hücresine sunulur ve uyarı seviyesi tüm s_i antijenleri i hücresine sunulduktan sonra Denklem (3.70)'e göre belirlenir.

$$s_i = \sum_{j=1}^M (1 - D_{i,j}) + \sum_{k=1}^n (1 - D_{i,k}) - \sum_{k=1}^n D_{i,k} \quad (3.70)$$

M antijen sayısı; n , bağlantılı B hücre sayısı; $D_{i,j}$ her j antijeni ve i B hücresi arasındaki Öklit uzaklığı (Denklem (3.65)); $D_{i,k}$, i hücresi ve ona bağlı k B hücresi arasındaki Öklit uzaklığıdır. $(1-D_{i,j})$ B hücresi ile antijenler ya da ağdaki diğer B hücreleri arasındaki afiniteyi gösterir. Bu durumda, afinite uzaklıkla ters orantılıdır.

Uyarı seviyesi hangi hücrelerin klonal genişletme için seçileceğini ve hangi hücrelerin de ağdan atılacağını belirler (metadinamik). Hangi hücrelerin ağda korunacağına karar vermek için, bir kaynak yerleştirme mekanizması uygulanır. Her B hücresinin yarışmak zorunda olduğu önceden belirli sayıda maksimum kaynağı vardır. Her B hücresine uyarı seviyesiyle orantılı olarak kaynak atanır: uyarı seviyesi yüksekse yüksek sayıda kaynak atanır. Atanan kaynak sayısı izin verilen maksimum sayıdan büyükse o zaman en az sayıdaki kaynağı tutan B hücreleri ağdan atılır. Bu, atanan kaynak sayısı izin verilen maksimum sayıya eşit ya da bundan küçük olana kadar tekrar edilir.

Kalan bazı ağ hücreleri uyarı seviyelerine göre klonal genişletme için seçilir: uyarı seviyesi büyükse klonlama olasılığı da yüksektir. Klonlama için seçilen hücreler aynı zamanda uyarı seviyeleriyle orantılı olarak çoğalırlar: uyarı seviyesi ne kadar yüksekse üretilecek klon sayısı da o kadar yüksektir.

Afinite olgunlaşması, seçilen ağ hücrelerinin antikorlarını sunulan antijenik örüntülere adapte olmasına izin verir. Her antikor B hücresinin uyarı seviyesiyle ters orantılı olarak mutasyona uğrar: uyarı ne kadar büyükse mutasyon oranı da o kadar düşüktür. Son olarak, mutasyona uğramış klonlar tüm ağ hücreleriyle eşleştirilir ve afiniteleri hesaplanır. Eğer afiniteleri, verilen bir eşğin altındaysa, bunlar birbirine bağlanır.

Bu işlemler, belli sayıdaki iterasyona kadar ya da ağ dengeye ulaşıncaya kadar, yani ağ B hücrelerinin sayısı verilen bir zaman dilimi boyunca sabit kalıncaya kadar tekrarlanır.

RAIN öğrenme algoritması Şekil 3.20’de gösterilmiştir:

1. Başlangıç: Antijenlerin alt bölümü dışında bir başlangıç ağı oluştur;
2. Antijenik temsil: Her antijenik örüntü için, do:
 - 2.1. Klonal seçim ve ağ etkileşimleri: Her ağ hücresi için, bunun uyarı seviyesini belirle (Denklemler (3.70))
 - 2.2. Metadinamik: Kaynak yerleştirme mekanizmasıyla düşük uyarılı hücreleri elimine et
 - 2.3. Klonal genişletme: En çok uyarılmış hücreleri seç ve bunları uyarılarıyla orantılı olarak tekrar üret
 - 2.4. Somatik mutasyon: Uyarı seviyesiyle ters orantılı olarak her klona mutasyon uygula
 - 2.5. Ağ yapımı: Mutasyona uğramış klonları ağa katılmak üzere seç
3. İkinci adımı durdurma kriterine kadar tekrarla

Şekil 3.20. Timmis ve arkadaşlarının önerdiği ağ modeli

Castro ve Zuben’in önerdiği model [86] ise Şekil 3.21’de gösterilmiştir.

1. Başlangıç: Ağ antikorlarının gelişigüzel bir başlangıç popülasyonunu üret
2. Antijenik temsil: Her antijenik örüntü için do:

Klonal seçim ve genişletme: Her ağ elemanı için sunulan antijen için afiniteyi hesapla. Yüksek afiniteli birkaç elemanı seç ve afiniteleri ile doğru orantılı olarak bunları tekrar üret (klonla)

Afinite olgunlaşması: Afinitelerle ters orantılı olarak her klona mutasyon uygula. En iyi afiniteli birkaç klonu tekrar seç ve bunları klonal bellek setine yerleştir.

Metadinamik: Antijenle afinitesi verilen eşikten düşük olan hafıza klonlarını elimine et

Klonal etkileşim: Klonal hafıza setinin tüm elemanları arasında ağ etkileşimini

(afinite) belirle

Klonal baskı: Birbirleriyle afinitesi verilen eşikten az olan hafıza klonlarını elime et

Ağ yapımı: Kalan klonal hafızanın klonlarını tüm ağ antikorları ile dahil et

3. Ağ etkileşimi: Her ağ antikor çifti arasındaki benzerliği belirle

4. Ağ baskılama: Afinitesi verilen eşikten az olan ağ antikorlarını elimine et

5. Çeşitlilik: Ağa yeni gelişigüzel üretilmiş antikorlar ilave et

6. Çevrim: İkidem beşinciye kadar olan adımları verilen iterasyon sayısına kadar tekrar et

Şekil 3.21. De Castro ve Zuben'in ağ modeli

3.4. Sinirsel - Bulanık Çıkarım

Modern tanılama ya da kimliklendirme yöntemleri, kullanılarak bir sistemin kimliklendirilmesi söz konusu olduğunda, öncelikle sisteme uygun bir model önerilir. Daha sonra söz konusu model, sisteme ilişkin giriş çıkış verisi kullanılmak suretiyle eğitilerek güncelleştirilir. Yapısı karmaşık, nonlineer sistemlerin kimliklendirilmesi için yapay sinir ağlarından istifade edilerek gerçekleştirilen çalışmalardan, başarılı sonuçlar alınmıştır [102]. Uyarlanır (adaptif) bulanık sistemlerin kullanılmasıyla gerçekleştirilen, modelleme ve denetim uygulamaları da literatürde geniş bir biçimde yer almaktadır (Passino, 1997). Bu nedenle bulanık sistemlerin etkinliğinin artırılmasında, uyarlama tekniğinin katkısını sağlamaya yönelik çeşitli yöntemler geliştirilmiştir. Bunlardan biri, kimliklendirme işleminin, işleyişi adaptif ağ yapısı içerisinde gerçekleşen, bulanık bir modelle (ANFIS) gerçekleştirilmesidir. Sistemin kimliklendirilmesinde kullanılacak olan bulanık model, adaptif ağ yapısı tarzındaki işleyişi sayesinde, hem sistem hakkındaki çevresel bilgiyi kullanarak, hem de sisteme ilişkin giriş çıkış verisinden faydalanarak kendi kendini güncelleme yeteneği edinmiştir [101].

3.4.1. ANFIS (adaptif ağ yapısına dayalı bulanık çıkarım sistemi) mimarisi

Esasen ANFIS yapısı, Sugeno tipi bulanık sistemlerin, sinirsel öğrenme kabiliyetine sahip bir ağ yapısı olarak temsilinden ibarettir. Bu ağ, her biri belli bir fonksiyonu gerçekleştirmek üzere, katmanlar halinde yerleştirilmiş düğümlerin birleşiminden oluşmuştur [83].

Basit olması açısından, bulanık çıkarım sistemini, x ve y gibi iki girişi ve z gibi bir çıkışı olduğunu farz ederek ele alalım. İki tane bulanık Eğer-O Halde kuralı bulunan, birinci dereceden Sugeno bulanık modeli için tipik kural kümesi;

Kural-1: Eğer x A_1 ise ve y B_1 ise O Halde $f_1 = p_1 x + q_1 y + r_1$

Kural-2: Eğer x A_2 ise ve y B_2 ise O Halde $f_2 = p_2 x + q_2 y + r_2$

şeklinde ifade edilir. Şekil 22(a) bu Sugeno bulanık modeli için bulanık akıl yürütme mekanizmasını göstermektedir. Bu yapıya karşılık gelen, eşdeğer ANFIS mimarisi Şekil 22(b) de gösterildiği gibidir. Söz konusu bu ANFIS mimarisi için aynı katmanda bulunan düğümler, aşağıda da gösterildiği üzere aynı düğüm fonksiyonlarına sahiptirler. (Burada l . Katmandaki i . Düğümün çıkışı $O_{l,i}$ şeklinde belirtilmiştir.)



Katman-1:

Bu katmanda yer alan her bir i düğümü, çıkışı aşağıdaki gibi tanımlanan, adaptif bir düğümdür.

$$O_{l,i} = \mu A_i(x), \quad i=1,2, \text{ yada} \quad (3.71)$$

$$O_{l,i} = \mu B_{i-2}(x), \quad i=3,4, \text{ için}$$

Burada x (yada y) düğümün girişini, A_i (yada B_{i-2}) ise söz konusu düğüme ait bulanık kümeyi ifade etmektedir.



Şekil 3.22. (a) Birinci dereceden iki girişli ve iki kurallı “Sugeno Bulanık Modeli”,

(b) Eşdeğer ANFIS yapısı.

Bir başka ifadeyle, bu katmanın çıkışları, kuralların şart ya da öncül kısımlarına ait üyelik değerlerini oluştururlar. Burada A_i ve B_i için söz konusu üyelik fonksiyonları, uygun bir biçimde parametrelendirilmiş herhangi bir üyelik fonksiyonu olabilir.

Örneğin A_i aşağıda belirtilen genelleştirilmiş çan eğrisi fonksiyonu ile ifade edilebilir.

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}} \quad (3.72)$$

burada yer alan $\{a_i, b_i, c_i\}$ kümesi, parametre kümesidir. Bu katmanın parametreleri, şart ya da giriş parametreleri olarak ifade edilirler.

Katman-2:

Bu katmandaki her bir düğüm, kendisine gelen sinyallerin çarpımını çıkış olarak üreten Π ile etiketlenmiş sabit bir düğümdür. Örneğin;

$$O_{2,i} = w_i = \mu_{A_i}(x) * \mu_{B_i}(y), \quad i=1,2. \quad (3.73)$$

Her bir düğümün çıkışı, her bir kural için gerçekleştirme derecesini oluşturur. (3.73) no'lu bağıntıda çarpma işlemi yerine bulanık (VE) işlemini icra eden, başka T-norm işlemleri de düğüm fonksiyonu gibi kullanılabilirler.

Katman-3:

3. katmanda yer alan her bir düğüm, N ile etiketlenmiş, sabit bir düğümdür. Katmandaki i . düğüm, i . kuralın gerçekleştirme derecesinin, bütün kuralların gerçekleştirme dereceleri toplamına oranını hesaplar.

$$O_{5,i} = \text{toplam çıkış} = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (3.74)$$

Bu katmanda yer alan düğümlerin çıkışları, hesaplanışlarına uygun olarak, normalize edilmiş gerçekleştirme dereceleri olarak adlandırılırlar.

Katman-4:

Bu katmana ait her i düğümü, düğüm fonksiyonu aşağıdaki gibi olan, adaptif bir düğümdür.

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1, 2. \quad (3.75)$$

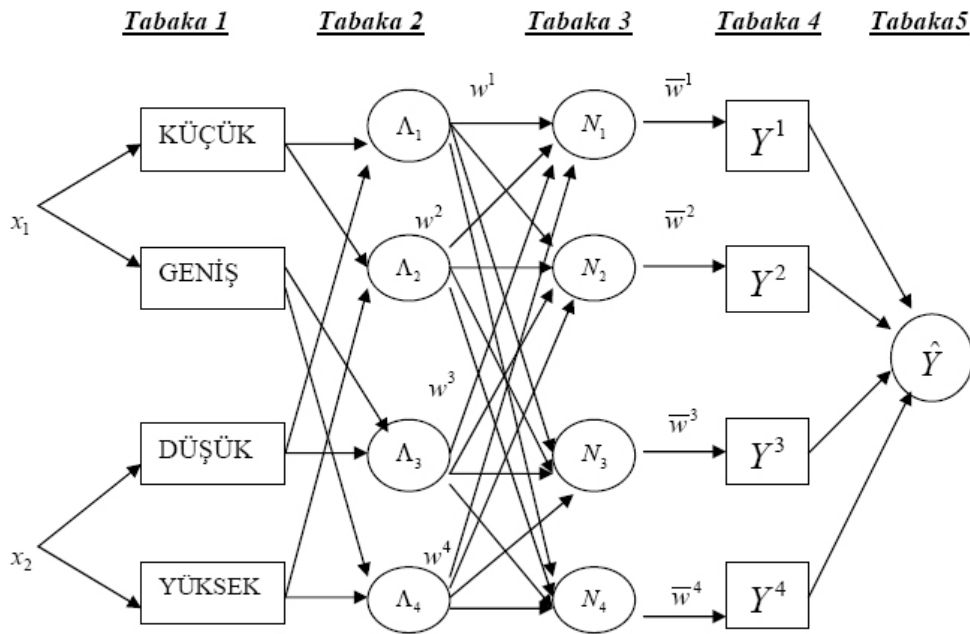
Burada \bar{w}_i , katman 3'ün çıkışı olup, $\{p_i, q_i, r_i\}$ ise bu katmanda bulunan düğümlerin parametrelerinden oluşan, parametre kümesidir. Bu katmanın parametreleri, sonuç ya da çıkış parametreleri olarak ifade edilecektir.

Katman-5:

Son katman olan 5. katmanda Σ ile etiketlenmiş olan ve toplam çıkışı hesaplamak üzere, kendisine gelen sinyallerin tümünü toplayan, sabit, tek bir düğüm yer alır.

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (3.76)$$

Böylece, tamamıyla Sugeno bulanık modelinin işleyişine sahip, adaptif bir ağ yapısı inşa edilmiş olup şekil 3.23'te gösterilmiştir [92].



Şekil 3.23. Bulanık uyarlamalı ağ mimarisi

ANFIS ağına ait parametrelerin güncellenmesinde genellikle hibrit öğrenme algoritması kullanılır. Hibrit öğrenme algoritmasında, ANFIS ağ yapısına ait parametreler, giriş ve çıkış parametreleri olarak iki kısımda ele alınır. Hibrit algoritmanın ilk aşaması ya da ileri yön geçişi ile ANFIS ağına ait giriş parametreleri, ikinci aşamada ya da geri yön geçişinde ise ağın sonuç parametreleri güncellenir. İlk aşamada en küçük kareler yöntemi, ikinci aşamada ise geri yalınım yöntemi kullanılır [103].

3.5. Genetik Algoritmalar

Günümüzün karmaşık ve zor koşulları problemlere hızlı ve kolay çözüm veren yeni çözüm yöntemleri arayışına neden olmuştur. Özellikle sert (hard) optimizasyon teknikleri yerine, yumuşak hesaplama (soft computing) ve evrimsel algoritma (evolutionary algorithm) kullanımı ön plana çıkmıştır. Evrimsel yaklaşımlardan olan genetik algoritmalar da, bu arayışlar içinde önemli bir yer tutmaya başlamıştır. Uygulama başarıları artan ve sürekli geliştirilmeye çalışılan genetik algoritmalar diğer yumuşak hesaplama yöntemleri ile birlikte kullanılarak hibrid (hybrid) çözümler geliştirilmesine çalışılmaktadır. Genetik algoritmalar, doğal seçim ilkelerine dayanan bir arama ve optimizasyon yöntemidir. Temel ilkeleri John Holland tarafından ortaya atılmıştır. Temel ilkelerinin ortaya atılmasından sonra, genetik algoritmalar hakkında birçok bilimsel çalışma yayınlanmıştır. Ayrıca, genetik algoritmaların teorik kısmı ve uygulamaları hakkında bir çok uluslararası konferans da düzenlenmektedir. Genetik algoritmaların, fonksiyon optimizasyonu, çizelgeleme, mekanik öğrenme, tasarım, hücresel üretim gibi alanlarda başarılı uygulamaları bulunmaktadır. Geleneksel optimizasyon yöntemlerine göre farklılıkları olan genetik algoritmalar, parametre kümesini değil kodlanmış biçimlerini kullanırlar. Olasılık kurallarına göre çalışan genetik algoritmalar, yalnızca amaç fonksiyonuna gereksinim duyar. Çözüm uzayının tamamını değil belirli bir kısmını tararlar. Böylece, etkin arama yaparak çok daha kısa bir sürede çözüme ulaşırlar [8]. Diğer bir önemli üstünlükleri ise çözümlerden oluşan popülasyonu eş zamanlı incelemeleri ve böylelikle yerel en iyi çözümlere takılmamalarıdır.

Reeves; ulusal hükümetler ve organizasyonlar tarafından genetik algoritma tabanlı projelere, tavlama benzetimi (simulated annealing) ve yasaklı arama (tabu search) tabanlı projelere göre daha fazla kaynak ayrılmakta olduğunu belirtmektedir [104]. Bu ifadeden anlaşılacağı üzere, genetik algoritmaların geleneksel optimizasyon yöntemlerine olduğu gibi sözü edilen yapay zeka yöntemlerine göre de çeşitli alanlarda üstünlükleri bulunmaktadır. Bu üstünlükler genetik algoritmaların arama yapısı ile ilgilidir. Genetik algoritmaların arama yapısı ise, alt diziler teoremi ve yapı blokları hipoteziyle açıklanmaktadır.

3.5.1. Genetik algoritmaların temel teoremi

Genetik algoritmaların nasıl arama yaptığı alt dizi kavramıyla açıklanmaktadır. Alt diziler, genetik algoritmaların davranışlarını açıklamak için kullanılan teorik yapılardır. Bir alt dizi, belirli dizi kümeleri arasındaki benzerliği tanımlayan bir dizidir. Alt diziler, $\{0, 1, *\}$ alfabeti kullanılarak tanımlanır. Örneğin H alt dizisi, ilk konumunda 0, ikinci ve dördüncü konumunda 1 değeri olan kromozomlar kümesi içindir.

$$H = 0 1 * 1 * \quad (3.77)$$

* sembolü dizinin o konumunun hangi değeri alıp almadığının önemli olmadığı anlamındadır. Dizi o konumda 0 veya 1 değeri alabilir. Eğer bir x dizisi, alt dizinin kalıbına uyarsa x dizisine “H’nin bir örneğidir” denir. Alt dizilerin iki özelliği mevcuttur. Bu özellikler aşağıda verilmiştir [8].

1. Alt dizi derecesi: Bir H alt dizisinin derecesi $o(H)$ ile gösterilir ve mevcut alt dizi kalıbında bulunan sabit konumların sayısıdır. Bu sayı ikili alfabede 0 ve 1 değerlerinin sayısının toplamına eşittir.

2. Alt dizi uzunluğu: Bir H alt dizisinin uzunluğu $\delta(H)$ ile gösterilir ve mevcut alt dizi kalıbında bulunan belirli ilk ve son konumlar arasındaki uzaklıktır.

Alt dizi derecesi ve alt dizi uzunluğu kavramlarının genetik algoritmaların temel teoreminde son derece önemli bir yeri vardır. Alt dizi derecesi düşük, alt dizi uzunluğu kısa olan diziler “yapı blokları” olarak adlandırılır. John Holland, genetik algoritmaların işleyişinde uygun yapı bloklarının tanımlanmasını ve bu yapı bloklarının daha uygun yapı blokları elde etmek amacıyla birleştirilmesini önermektedir. Bu fikir yapı blokları hipotezi olarak bilinmektedir. Genetik algoritmanın temel teoremi ise şöyle açıklanmaktadır [104]:

Popülasyon ortalamasının üstünde uyum gücü gösteren, kısa uzunluğa ve düşük dereceye sahip alt diziler zamanın ilerlemesiyle üstsel olarak çoğalırlar.


Bu çoğalma, genetik işlemler aracılığı ile gerçekleşmektedir ve sonucunda ana-babadan daha üstün özellikler taşıyan bireyler ortaya çıkmaktadır. Bu çözüm kalitesinin kuşaktan kuşağa artması iki nedene bağlanmaktadır. Bu nedenler şöyle açıklanabilir [105]:

1. Başarısız olan bireylerin üreme şansları azaltıldığı için kötüye gidiş zorlaşmaktadır.
2. Genetik algoritmaların yapısı kötüye gidişi engellemekle kalmamakta, genetik algoritmaların temel teoremi uyarınca, zaman içinde hızlı bir iyiye gidiş de sağlayabilmektedir.

Genetik algoritmaların işleme adımları incelendiğinde bu nedenler daha iyi anlaşılmaktadır. Genetik algoritmalar yapısı gereği, kötü bireyleri yani uygun olmayan çözümleri, operatörleri sayesinde elemektedir. Bu işlemler bir döngü içerisinde durdurma kriteri sağlanana kadar devam etmektedir.

3.5.2. Basit genetik algoritma

Bir çok alanda uygulama imkanı ve uygulamaları olan genetik algoritmaların işleme adımları şöyle açıklanabilir [106]:



Şekil 3.24. Genetik Algoritma Akış Diyagramı

1. Arama uzayındaki tüm mümkün çözümler dizi olarak kodlanır.
2. Genellikle rastsal bir çözüm kümesi seçilir ve başlangıç popülasyonu olarak kabul edilir.
3. Her bir dizi için bir uygunluk değeri hesaplanır, bulunan uygunluk değerleri dizilerin çözüm kalitesini gösterir.
4. Bir grup dizi belirli bir olasılık değerine göre rastsal olarak seçilip çoğalma işlemi gerçekleştirilir.
5. Yeni bireylerin uygunluk değerleri hesaplanarak, çaprazlama ve mutasyon işlemlerine tabi tutulur.
6. Önceden belirlenen kuşak sayısı boyunca yukarıdaki işlemler devam ettirilir.
7. İterasyon, belirlenen kuşak sayısına ulaşıncaya işlem sona erdirilir. Amaç fonksiyonuna göre en uygun olan dizi seçilir.

Genetik algoritmalar bir çözüm uzayındaki her noktayı, kromozom adı verilen ikili bit dizisi ile kodlar. Her noktanın bir uygunluk değeri vardır. Tek bir nokta yerine, genetik algoritmalar bir popülasyon olarak noktalar kümesini muhafaza eder. Her kuşakta, genetik algoritma, çaprazlama ve mutasyon gibi genetik operatörleri kullanarak yeni bir popülasyon oluşturur. Birkaç kuşak sonunda, popülasyon daha iyi uygunluk değerine sahip üyeleri içerir. Bu, Darwin'in rastsal mutasyona ve doğal seçime dayanan evrim modellerine benzemektedir. Genetik algoritmalar, çözümlerin kodlanmasını, uygunlukların hesaplanmasını, çoğalma, çaprazlama ve mutasyon operatörlerinin uygulanmasını içerir [107].

1. Çözümlerin kodlanması: Bir problemin çözümü için genetik algoritma geliştirmenin ilk adımı, tüm çözümlerin aynı boyutlara sahip bitler dizisi biçiminde gösterilmesidir. Dizilerden her biri, problemin olası çözümler uzayındaki rastsal bir noktayı simgeler [104]. Parametrelerin kodlanması, probleme özgü bilgilerin genetik algoritmanın kullanacağı şekle çevrilmesine olanak tanır [107].

2. İlk popülasyonun oluşturulması: Olası çözümlerin kodlandığı bir çözüm grubu oluşturulur. Çözüm grubu popülasyon, çözümlerin kodları da kromozom olarak adlandırılır. İkili alfabenin kullanıldığı kromozomların gösteriminde, ilk popülasyonun oluşturulması için rastsal sayı üreticileri kullanılabilir. Rastsal sayı üreticisi çağrılır ve değer 0,5'den küçükse konum 0'a değilse 1 değerine ayarlanır [108]. Birey sayısının ve kromozom uzunluğunun az olduğu problemlerde yazı-tura ile de konum değerleri belirlenebilmektedir. Genetik algoritmalarda ikili kodlama yöntemi dışında, çözümü aranan probleme bağlı olarak farklı kodlama yöntemleri de kullanılmaktadır [8].

3. Uygunluk değerinin hesaplanması: Bir kuşak oluşturulduktan sonraki ilk adım, popülasyondaki her üyenin uygunluk değerini hesaplama adımıdır. Örneğin, bir maksimizasyon problemi için i . üyenin uygunluk değeri $f(i)$, genellikle o noktadaki amaç fonksiyonunun değeridir [107]. Çözümü aranan her problem için bir uygunluk fonksiyonu mevcuttur. Verilen belirli bir kromozom için uygunluk fonksiyonu, o kromozomun temsil ettiği çözümün kullanımıyla veya yeteneğiyle orantılı olan

sayısal bir uygunluk değeri verir. Bu bilgi, her kuşakta daha uygun çözümlerin seçiminde yol göstermektedir. Bir çözümün uygunluk değeri ne kadar yüksekse, yaşama ve çoğalma şansı o kadar fazladır ve bir sonraki kuşakta temsil edilme oranı da o kadar yüksektir [104].

4. Çoğalma işleminin uygulanması: Çoğalma operatöründe diziler, amaç fonksiyonuna göre kopyalanır ve iyi kalıtsal özellikleri gelecek kuşağa daha iyi aktaracak bireyler seçilir. Üreme operatörü yapay bir seçimdir. Dizileri uygunluk değerlerine göre kopyalama, daha yüksek uygunluk değerine sahip dizilerin, bir sonraki kuşaktaki bir veya daha fazla yavruya daha yüksek bir olasılıkla katkıda bulunması anlamına gelmektedir. Çoğalma, bireyleri seçme işleminden, seçilmiş bireyleri bir eşleme havuzuna kopyalama işleminden ve havuzda bireyleri çiftler halinde gruplara ayırma işleminden oluşur [109].

Uygunluk değerinin hesaplanması adımından sonra mevcut kuşaktan yeni bir popülasyon yaratılmalıdır. Seçim işlemi, bir sonraki kuşak için yavru üretmek amacıyla hangi ailelerin yer alması gerektiğine karar vermektedir. Bu doğal seçimdeki en uygunun yaşaması durumuna benzerdir. Bu yöntemin amacı, ortalama uygunluğun üzerindeki değerlere çoğalma fırsatı tanımaktır. Bir dizinin kopyalanma şansı, uygunluk fonksiyonuyla hesaplanan dizinin uygunluk değerine bağlıdır [107]. Seçim yöntemlerine rulet tekerleği seçimi, turnuva seçimi ve sıralama seçimi gibi seçim yöntemleri örnek verilebilir.

5. Çaprazlama işleminin uygulanması: Mevcut gen havuzunun potansiyelini araştırmak üzere, bir önceki kuşaktan daha iyi nitelikler içeren yeni kromozomlar yaratmak amacıyla çaprazlama operatörü kullanılmaktadır. Çaprazlama genellikle, verilen bir çaprazlama oranına eşit bir olasılıkla seçilen aile çeşitlerine uygulanmaktadır [107].

Genetik algoritmanın performansını etkileyen önemli parametrelerden biri olan çaprazlama operatörü doğal popülasyonlardaki çaprazlamaya karşılık gelmektedir. Çoğalma işlemi sonucunda elde edilen yeni popülasyondan rastsal olarak iki kromozom seçilmekte ve karşılıklı çaprazlama işlemine tabi tutulmaktadır.

Çaprazlama işleminde dizi uzunluğu L olmak üzere, $1 \leq k \leq L-1$ aralığında k tamsayısı seçilmektedir. Bu tamsayı değerine göre dizi çaprazlamaya uğratılır. En basit çaprazlama yöntemi tek noktali çaprazlama yöntemidir. Tek noktali çaprazlama yapılabilmesi için her iki kromozomun da aynı gen uzunluğunda olması gerekir. İki noktali çaprazlamada ise kromozom iki noktadan kesilir ve karşılıklı olarak pozisyonlar yer değiştirilir [109].

6. Mutasyon işleminin uygulanması: Çaprazlama mevcut gen potansiyellerini araştırmak üzere kullanılır. Fakat popülasyon gerekli tüm kodlanmış bilgiyi içermez ise, çaprazlama tatmin edici bir çözüm üretmez. Bundan dolayı, mevcut kromozomlardan yeni kromozomlar üretme yeteneğine sahip bir operatör gerekmektedir. Bu görevi mutasyon gerçekleştirir. Yapay genetik sistemlerde mutasyon operatörü, bir daha elde edilemeyebilir iyi bir çözümün kaybına karşı koruma sağlamaktadır [8]. İkili kodlama sisteminin kullanıldığı problemlerde mutasyon, düşük bir olasılık değeri altında bir bit değerini (0 veya 1 olabilir) diğer bit değerine dönüştürür. İkili kodlama sisteminin kullanılmadığı problemlerde ise daha farklı mutasyon yöntemleri kullanılmaktadır. Hangi yöntem kullanılırsa kullanılsın, mutasyonun genel amacı, genetik çeşitliliği sağlamak veya korumaktır [110].

7. Yeni kuşağın oluşması ve döngünün durdurulması: Yeni kuşak çoğalma, çaprazlama ve mutasyon işlemlerinden sonra tanımlanmakta ve bir sonraki kuşağın ebeveynleri olmaktadır. Süreç yeni kuşakla çoğalma için belirlenen uygunluk ile devam eder. Bu süreç, önceden belirlenen kuşak sayısı kadar veya bir hedefe ulaşıncaya kadar ya da başka bir durdurma kriteri sağlanana kadar devam eder [108]. İstenen hassasiyet derecesine göre de maksimum iterasyon sayısı belirlenebilmekte ve iterasyon bu sayıya ulaştığında döngü durdurulabilmektedir. Durdurma kriteri iterasyon sayısı olabileceği gibi hedeflenen uygunluk değeri de olabilmektedir [111].

3.5.3. Genetik algoritmalarda parametre seçimi

Parametreler, genetik algoritma performansı üzerinde önemli etkiye sahiptir. Optimal kontrol parametreleri bulmak için bir çok çalışma yapılmıştır fakat tüm problemler için genel olarak kullanılacak parametreler bulunamamıştır [112]. Bu parametreler, kontrol parametreleri olarak adlandırılmaktadır. Kontrol parametreleri popülasyon büyüklüğü, çaprazlama olasılığı, mutasyon olasılığı, kuşak aralığı, seçim stratejisi ve fonksiyon ölçeklemesi olarak sayılabilir. Bu parametreler aşağıda açıklanmıştır [104, 113, 114]:

Popülasyon büyüklüğü: Genetik algoritma kullanıcısı tarafından verilen en önemli kararlardan birisidir. Bu değer çok küçük olduğunda, genetik algoritma yerel bir optimuma takılabilmektedir. Popülasyonun çok büyük olması ise çözüme ulaşma zamanını arttırmaktadır. Bu konuda Goldberg 1985’de, yalnızca kromozom uzunluğuna bağlı bir popülasyon büyüklüğü hesaplama yöntemi önermiştir. Ayrıca Schaffer ve arkadaşları 1989’da çok sayıda test fonksiyonları üzerinde yaptıkları araştırmalar sonucunda, 20-30 arası bir popülasyon büyüklüğünün iyi sonuçlar verdiğini belirtmişlerdir.

Çaprazlama olasılığı: Çaprazlamanın amacı, mevcut iyi kromozomların özelliklerini birleştirerek daha uygun kromozomlar yaratmaktır. Kromozom çiftleri $P(c)$ olasılığı ile çaprazlamaya uğramak üzere seçilirler. Çaprazlamanın artması, yapı bloklarının artmasına neden olmakta fakat aynı zamanda bazı iyi kromozomların da bozulma olasılığını arttırmaktadır.

Mutasyon olasılığı: Mutasyonun amacı popülasyondaki genetik çeşitliliği korumaktır. Mutasyon $P(m)$ olasılığı ile bir kromozomdaki her bitte meydana gelebilir. Eğer mutasyon olasılığı artarsa, genetik arama rastsal bir aramaya dönüşür. Fakat bu aynı zamanda kayıp genetik malzemeyi tekrar bulmada yardımcı olmaktadır.

Kuşak aralığı: Her kuşaktaki yeni kromozom oranına kuşak aralığı denmektedir. Genetik operatörler için kaç tane kromozomun seçildiğini gösterir. Yüksek bir değer birçok kromozomun yer değiştirdiği anlamına gelmektedir.

Seçim stratejisi: Eski kuşağı yenilemenin çeşitli yöntemleri mevcuttur. Kuşaksal stratejide, mevcut popülasyondaki kromozomlar tamamen yavrular ile yer değiştirir. Popülasyonun en iyi kromozomu da yenilendiğinden dolayı bir sonraki kuşağa aktarılamaz ve bu yüzden bu strateji en uygun (elitist) stratejisiyle beraber kullanılmaktadır. En uygun stratejisinde, popülasyondaki en iyi kromozomlar hiçbir zaman yenilenmemektedir, bundan dolayı çoğalma için en iyi çözüm her zaman elverişlidir. Denge durumu stratejisinde ise, her kuşakta yalnızca birkaç kromozom yenilenmektedir. Genellikle, yeni kromozomlar popülasyona katıldığında en kötü kromozomlar yenilenir.

Fonksiyon ölçeklemesi: Doğrusal ölçekleme, üstsel ölçekleme gibi yöntemler mevcuttur. Probleme göre en uygun ölçekleme yönteminin seçilmesi genetik algoritmanın etkin işlemesi açısından önem taşımaktadır.

3.5.4. Genetik algoritmaların uygulama alanları

Karmaşık problemleri hızlı ve optimale yakın olarak çözebilen genetik algoritmalar, çeşitli problem tiplerine uygulanabilmektedir. Büyük çözüm uzaylarının geleneksel yöntemlerle taranması hesaplama zamanını arttırmaktadır. Ancak bu tip problemlere, genetik algoritmalar ile kısa sürede, kabul edilebilir çözümler bulunabilmektedir [115]. Genetik algoritmalar özellikle çözüm uzayının geniş, süreksiz ve karmaşık olduğu problem tiplerinde başarılı sonuçlar vermektedir.

Genetik algoritmaların genel uygulama alanları şöyledir:

Optimizasyon:

Bir arama yöntemi olan genetik algoritmalar, farklı bilim dallarındaki optimizasyon problemlerini çözmeye kullanılmaktadır. Genetik algoritmaların uygulandığı

optimizasyon problemleri, fonksiyon optimizasyonu ve birleş (combinatorial) optimizasyonu altında toplanabilir.

Genetik algoritma arařtırmalarının önemli bir bölümü fonksiyon optimizasyonu ile ilgilidir. Genetik algoritmalar, geleneksel optimizasyon tekniklerine göre zor, süreksiz ve gürültü (noisy) içeren fonksiyonları çözümede daha etkindirler [116]. Optimize edilecek amaç fonksiyonunun süreksiz olması halinde, süreksizlik noktalarında fonksiyonun türevi alınamayacağından, türev almaya dayalı optimizasyon yöntemleri kullanılamamaktadır. Oysa genetik algoritmalar, problemlerin çözümü için türev veya diğ er yardımcı bilgilere gereksinim duymadığından özellikle bu tip problemlerin çözümünde geleneksel yöntemlere göre önemli bir üstünlük sağlamaktadır [117].

Genetik algoritmaların uygulandığı diğ er bir optimizasyon problem sınıfı olan birleş i optimizasyon problemleri ise, istenen amaçlara ulaşmak üzere, sınırlı kaynakların etkin tahsis edilmesiyle ilgilidir. Bu sınırlar genel olarak, işgücü, tedarik veya bütçe ile ilgilidir. Sözü geçen “birleş i” kelimesi, yalnızca sonlu sayıda alternatif uygun çözümün mevcut olması ile ilgilidir. Birleş i optimizasyon, iyi tanımlanmış bir problem uzayında bir veya daha fazla optimal çözüm bulma sürecidir. Bu tip problemler yönetim biliminin tüm dallarında da (finans, pazarlama, üretim, stok kontrolü, veritabanı yönetimi vb.) ortaya çıkmaktadır. Gezgin satıcı problemi, araç rotalama problemi, Çinli postacı problemi, iş atölyesi çizelgeleme problemi, atama problemi, yerleşim tasarımı problemi ve sırt çantası problemi birleş i optimizasyon problemlerine örnektir [118]. Birleş i optimizasyon problemlerinde, incelenen değışken sayısı arttıkça çözüme ulaşma zamanı üstsel olarak artmaktadır. Çözüm uzayının tamamının taranmasını gerektiren geleneksel çözüm yöntemlerinde problem çözümü değışken sayısının artmasıyla imkansız hale gelebilmektedir. Genetik algoritmalar ise çözüm uzayının yalnızca belirli bir kısmını taradığı ve eş zamanlı arama yaptığı için, bu tip problemlerde çözüme daha kısa sürede ulaşabilmektedir.

Çeşitli avantajlarına rağmen genetik algoritmaların uygulamalarında bir takım sorunlarla da karşılaşmaktadır. Bu sorunları aşmak için çeşitli yöntemler geliştirilmiştir. Buna kısıtların ele alınmasındaki soruna karşı ceza fonksiyonu

yönteminin kullanılması örnek verilebilir. Ancak, bulunan çeşitli yöntemlere rağmen bu konuda yeni yaklaşımlara gereksinim duyulmaktadır [114].

Otomatik programlama ve bilgi sistemleri:

Genetik algoritmaların yaygın olarak kullanıldığı alanlardan biri, belirli ve özel görevler için gerekli olan bilgisayar programlarını geliştirmedir. Ayrıca, diğer hesaplama gerektiren yapıların tasarımı için de kullanılmaktadır. Bunlara örnek olarak, bilgisayar çipleri tasarımı, ders programı hazırlanması ve ağların çizelgelenmesi verilebilir.

Genetik algoritmalar kullanılarak dağıtılmış bilgisayar ağlarının tasarımı da gerçekleştirilmektedir. Bu problem tipinde ağ güvenilirlik parametrelerini (çap, ortalama uzaklık ve bilgisayar ağ güvenilirliği gibi) optimize etmek için birden fazla amaç fonksiyonu kullanılmaktadır. Genetik algoritmalar ile 100 düğüme kadar olan ağlar başarıyla tasarlanmıştır. Ağ tasarımında genetik algoritmaların kullanılması, tasarım sürelerinin ve maliyetlerinin azalmasında önemli bir katkı sağlamıştır. Özellikle, maksimum miktardaki verinin minimum iletişim hattıyla taşınmasında yüksek bir performans göstermiştir [119]. Ayrıca genetik algoritmaların kullanımıyla, çeşitli alanlara dağıtılmış bir sistem için en uygun dosya tahsisatı gerçekleştirilmektedir.

Mekanik öğrenme:

Mekanik öğrenme; ilki, gözlenmiş bir veri takımını anlamak ve yorumlamak, ikincisi de görülmemiş objelerin özelliklerini tahmin etmek olan iki temel amaç için model kurmayı amaçlar. Parametrik istatistikten ziyade çok büyük veri takımlarının yönetimi üzerinde çalışır. Kullandığı metotların çoğu dağılımdan bağımsız metotlar olarak sınıflanabilir. Uygun model seçimi için işe problem hakkındaki varsayımlarla başlanmaz. Onun yerine uygun model yapısını belirlemek için doğrudan mevcut veriden hareketle bir araç kutusu yaklaşımı kullanır [120].

Sınıflama sistemi, genetik algoritmaların mekanik öğrenme alanında bir uygulamasıdır [117]. Basit dizi kurallarını öğrenen bir mekanik öğrenme sistemi olan sınıflama sisteminin kural ve mesaj sistemi, özel bir üretim sistemi olarak adlandırılabilir. Bu üretim sistemi, “eğer-sonra” kural yapısını kullanır. Bir üretim kuralı, “eğer” yapısından sonra belirtilen durum için, “sonra” yapısından sonra gelen faaliyetin gerçekleştirilmesini içerir [8]. Genetik algoritmalar, sınıflama sistemlerinde kural-bulma mekanizması olarak kullanılmaktadırlar [117]. Genetik algoritmalar ayrıca, sinir ağlarında ve proteinin yapısal analizinde de kullanılmaktadır [8].

Ekonomik ve sosyal sistem modelleri:

Bir sistemi ölçen ampirik olarak gözlenmiş değişkenler arasındaki matematiksel ilişkiyi keşfetme problemi ekonomide en önemli problemlerden biridir. Pratikte gözlenmiş veri gürültü içerebilir ve kapsanan ilişkileri kesin ve açık bir şekilde açıklayacak bir yol bilinmeyebilir. Bu tip problemler, sembolik sistem tanımlama, kara kutu, veri madenciliği ve modelleme problemleri olarak bilinir. Eğer keşfedilen model, sistemin durum değişkenlerinin gelecek değerlerini tahmin etme için kullanılacaksa problem öngörüleme problemi adını alır. Geleneksel doğrusal, kuadratik ve üstsel regresyon modellerinde sapma hataları minimize edilerek fonksiyonlara uygun sayısal katsayılar bulunur. Buradaki yaklaşım, model seçildikten sonra uygun sayısal katsayıların aranmasıdır. Gerçek problem ise verinin değerlendirilmesi için hangi tip modelin uygun olduğunun kararıdır. Keyfi bir matematiksel ilişkiyi açıklamada bilgisayarlar, bu ilişkiyi formüller ve denklemler aracılığı ile açıklamaktan daha esnektir. Bu nedenle, bu tip ilişki açıklamaları için sembolik regresyon kullanılabilir. Sembolik regresyonlar, hem fonksiyon formunu hem de o fonksiyondaki uygun katsayıyı araştırmaktadır. Bunu bulma ise, verilen girdiler için arzu edilen çıktıları üreten özel bir hesaplama programı ile program uzayında arama yapmaya benzemektedir. Genetik algoritmaların kullanıldığı genetik programlamayla bu tip problemlere tatmin edici çözümler çok daha kolay getirilebilmektedir [121].

Genetik algoritmalar yenilik sürecinin modellenmesi amacıyla da kullanılmaktadır. Ayrıca genetik algoritmaların, fiyat verme stratejilerinin gelişim süreçlerini ve kazanç getiren pazarların ortaya çıkış süreçlerini modelleme alanlarında da kullanımları oldukça yaygındır. Genetik algoritmalar sosyal sistemlerin evrimsel yönlerini anlamak amacıyla kullanılmaktadır. Bunlara örnek olarak işbirliğinin evrimi, iletişimin evrimi ve karıncalardaki iz takibi davranışının evrimi verilmektedir.

BÖLÜM 4. GÖĞÜS HASTALIKLARININ TEŞHİSİ İÇİN GELİŞTİRİLEN ÖRNEK UYGULAMA (GÖHAT)

4.1. Giriş

Bu bölümde göğüs hastalıklarının teşhisi için hesaplama algoritmalarının kullanımı ile gerçekleştirilen örnek uygulama (GÖHAT) anlatılmıştır. Öncelikle bu konuda kullanılan yazılım aracı belirtilmiş ardından eğitim ve test için kullanılan veri kümeleri hakkında detaylı bilgi verilmiştir. Daha sonra uygulamada kullanılan algoritmaların yapıları hakkında bilgi verilmiş ve uygulamanın ara yüzleri üzerinde program detaylı bir biçimde açıklanmıştır.

Uygulamanın gerçekleştirildiği programlama dili C# olarak belirlenmiştir. Gelişmiş fonksiyon tanımlamalarına sahip olması, kullanım kolaylığı ve geniş kullanım alanlarına sahip olması bu dilin seçilmesinin başlıca nedenlerindedir.

4.2. Uygulamada Kullanılan Veri Seti

GÖHAT' da kullanılmak üzere Diyarbakır Göğüs Hastalıkları Hastanesinden hasta epikrizleri temin edilmiştir. Bu göğüs hastalıkları biriminde yatan hasta epikrizler hastalık sayılarına göre aşağıdaki şekilde sınıflandırılmıştır.

Tablo 4.1. Uygulamada kullanılan veri seti.

Sınıfı	Hastalık	Hasta Sayısı (Adet)
1. Sınıf	KOAH	71
2. Sınıf	Zatürree	60
3. Sınıf	Tüberküloz (Verem)	50
4. Sınıf	Astım	44
5. Sınıf	Akciğer Kanseri	32
6. Sınıf	Normal	100
TOPLAM		357

Bu epikriz raporlarından bir uzmanın görüşü alınarak elde edilen ve uygulamada özellik olarak kullanılan parametreler şunlardır: Yakınma Öksürük, Yakınma Ateş, Yakınma Göğüste Ağrı, Yakınma Halsizlik, Yakınma Nefes Darlığı, Yakınma Hırıltı, Yakınma Göğüste Sıkışma, Yakınma Balgam, Muayene Solunum Sistemi, Alışkanlıklar Sigara, WBC, RBC, HGB, HCT, PLT, Albümin2, Alkalen Fosfataz 2L, Alt, Amilaz, Ast, Bilirubin (Total+ Direkt), CK / Kraatin Kinaz, CK – MB, Demir (Serum), GGT, Glukoz, HDL Kolesterol, Kalsiyum (Ca), Kan Üre Azotu (BUN), Klor (Cl), Kolestrol, Kreatinin, LDH, Potasyum, Sodyum (Na), Total Protein, Triglesid, Ürik Asit.

GÖHAT' da kullanılan toplam veri seti 3 kat çaprazlama (3-fold cross-valuation) yöntemi ile 3 parçaya ayrılarak çaprazlanma suretiyle hem eğitim hem de test işlemi için kullanılmıştır.

4.3. GÖHAT' da Kullanılan Yapay Sinir Ağı Modeli

Bu çalışmada göğüs hastalıklarının teşhisini gerçekleştirmek için iki gizli katmanlı bir MLNN yapısı kullanılmıştır. Bu çok katmanlı yapay sinir ağının yapısı (1 giriş katmanı, iki gizli katman, bir çıkış katmanı) Şekil 4.1'de görülmektedir. Gizli katman sinirleri (birinci katman için 55 adet, ikinci gizli katman 55) ve çıkış katman sinirleri için nonlinear sigmoid aktivasyon fonksiyonu kullanılmıştır. Bu sistemde 38 adet özellik ve 6 adet hastalık teşhis sınıflandırılması (Astım, Verem, Zatürree, KOAH, Akciğer Kanseri, Normal) içermektedir. Yapay sinir ağını modellemek için aşağıdaki eşitlikler kullanılmıştır.

Birinci gizli katman sinirlerinin çıkışı,

$$\bar{X}^{ih1}(n) = 1 / \left(1 + \exp(W^{ih1}(n) * \bar{f}(n) + \bar{b}^{ih1}(n)) \right) \quad (4.1)$$


İkinci gizli katman sinirlerinin çıkışı,

$$\bar{X}^{ih2}(n) = 1 / \left(1 + \exp(W^{ih2}(n) * \bar{X}^{ih1}(n) + \bar{b}^{ih2}(n)) \right) \quad (4.2)$$

Ağın çıkışı,

$$\bar{Y}(n) = 1 / \left(1 + \exp(W^{ho}(n) * \bar{X}^{ih2}(n) + \bar{b}^{ho}(n)) \right) \quad (4.3)$$

- $W^{ih1}(n)$: Giriş ile birinci gizli katman arasındaki ağırlıklar
 $\bar{b}^{ih1}(n)$: Birinci gizli katman bias değeri
 $W^{ih2}(n)$: Birinci gizli katman ile ikinci gizli katman arasındaki ağırlıklar
 $\bar{b}^{ih2}(n)$: İkinci gizli katman bias değeri
 $W^{ho}(n)$: İkinci gizli katman ile çıkış arasındaki ağırlıklar
 $\bar{b}^{ho}(n)$: Çıkış katmanı bias değeri
 $\vec{f}(n)$: Giriş için kullanılan özellik değerleri
 $\vec{Y}(n)$: Çıkış için sınıflandırma değerleri
 n : Eğitim iterasyon sayısı



Şekil 4.1. GÖHAT' da kullanılan iki gizli katmanlı yapay sinir ağının yapısı (Y_1 : Tüberküloz, Y_2 : KOAH, Y_3 : Pnömoni, Y_4 : Astım, Y_5 : Akciğer Kanseri, Y_6 : Normal).

4.3.1. Ağın performans değerini ölçmede sınıflandırma doğruluk oranı

Bu çalışmada sınıflandırma başarısını ölçmede (4.5) denkleminde yararlanılmıştır [122,123] :

$$\text{Sınıflandırma başarısı}(N) = \frac{\sum_{i=1}^{|N|} (n_i)}{|N|}, \quad n_i \in N \quad (4.4)$$

$$\text{Class}(n) = \begin{cases} 1 & \text{eger Sınıf}(n) = nc \\ 0 & \text{diger} \end{cases} \quad (4.5)$$

N : Sınıflandırılacak veri seti (test seti), $n \in N$, nc : örneğin sınıfı n ve $class(n)$: n ağının çıkışı.

4.4. GÖHAT' da Kullanılan Yapay Bağışıklık Sistemi Modeli

Yapay bağışıklık sistemi kullanılarak gerçekleştirilen uygulamanın YBS algoritma yapısı şu şekildedir.

Adım 1. Eğitim verilerini oku ve antikor popülasyonunu oluştur.

Açıklama: Antikor popülasyonu başlangıç eğitim verilerinden oluşturulmaktadır.

Adım 2. Eşik değer belirle.

Açıklama: Eğitim işleminin ilk kısmı olan eşik değer belirleme işlemi gerçekleşir. Eşik değer aynı sınıfa dâhil olan veriler arasında her bir özellik için belirlenen, kabul edilebilir fark değerini ifade eder. Eşik değer belirlenebilmesi için başlangıç eğitim seti kullanılmıştır.

Adım 3. Popülasyondaki antikor hücrelerinden klonlama ile yeni antikorlar oluştur.

Açıklama: Mevcut popülasyon türetim ile genişletilir. Eğitim verilerinden bilgi olarak sisteme verilen sınıflar bir kümeyi ifade eder. Klonlama işlemindeki amaç sınıflar arasındaki hiçbir sınıfa dâhil olmayan boşlukları bir sınıfa dâhil etmek ve bu sayede sınıfların tanım alanlarını genişletmektir.

Adım 4. Oluşan antikor hücrelerinin affinitelerini (akrabalıklarını) mevcut antikor popülasyonu ile test et, affinite değeri eşik değeri altında kalan antikorları yok et, diğerlerini popülasyona ekle.

Açıklama: Klonlama ile elde edilen yeni verilerin (türetilmiş antikor hücreleri) sağlıklı olup olmadığı kontrol edilir. Yani türetilmiş yeni veriler eğer başka sınıfların kümesi içine girmiş ise bu türetim yanlış yapılmıştır. Yanlış türetilen veri popülasyona dâhil edilmez.

Adım 5. Eğer popülasyondaki antikor miktarı değiştiyse, Adım 3 'e dön.

Açıklama: Eğer klonlama başarılı ve popülasyon genişledi ise yeni türetimler halen yapılabilir demektir, klonlama işlemine devam edilmelidir. Aksi takdirde türetim bitmiştir ve eğitim tamamlanmıştır.

Adım 6. Test verilerini oku.

Açıklama: Test verileri okunur. Test işlemi için hazır hale getirilir.

Adım 7. Test hücrelerini eğitim sonucu oluşan antikor popülasyonu ile karşılaştır, sınıflandır.

Açıklama: Eğitim ile oluşturulmuş son antikor popülasyonu ile test verileri karşılaştırılır. Bu işlem için her bir popülasyon verisi ile her bir test verisi sırasıyla karşılaştırılır eşik değer sınırları içerisinde olmak koşulu ile özellikler arasındaki farklardan benzerlik oranları bulunur. Bu oranlar her bir özellik için ayrı ayrı hesaplanır, toplanır ve ortalaması alınır, sonuç oran ilgili test verisinin karşılaştırıldığı eğitim verisinin sınıfına benzerlik oranıdır. Bu oranı elde eden eğitim veri sınıfı, benzerlik oranı ile birlikte test verisinin yanındaki sütunlara yazılır. Elde edilen yeni başarı oranı eğer mevcut orandan yüksek ise bu test verisi bu sınıfa dâhildir denir ve yeni oran yine yanındaki sütuna yazılır. Bu işlem test verisi her bir eğitim verisi ile karşılaştırılıncaya kadar devam eder. Test verisinin karşılaştırması sonucunda sınıflar artık belirlenmiştir.

Algoritmadaki antikor, hastalık teşhisinin hangi sınıflandırma sonucuna varıldığını ifade etmektedir. Antikor hücrelerinin mutasyonu ile antikor klonları üretilmiştir. Bu çalışmada her bir antikor 38 tane antikor hücresi içermektedir. Başka bir deyişle antikor hücresi olarak hastalık teşhisine yardımcı olacak 38 özellik kullanıldı. Uygulamada kullanılan örnek bir antikor klonlama işlemi şekil 4.2’de görülmektedir.

Antikor Hücresi	→	1	2	...	32	33	34	35	36	37	38	
		0	0	...	1.38	354	5.38	151	6.83	139	2.14	1. Varol an antikor (zatürree)
							↓		↓			
		0	1	...	1.44	455	5.11	140	6.46	162	0.59	2. Var olan antikor (zatürree)
		0	1	...	1.44	455	5.38	140	6.83	162	0.59	Yeni Klon (Antikor/Antijen)

Şekil 4.2. Zatürree sınıflandırması için örnek bir klonlama işlemi.

Üretilen antikör hücrelerinin affinity değerlerini ölçmek için Hamming modeli kullanıldı. Adım 4'te anlatılan YSB modelinin hesaplama işlemi için kullanılan kod bloğu:

```


$$A_p = 0$$

for( $n = 1; n < N; n++$ )
{

$$A_f = \sum_{i=1}^{38} \delta, \quad \delta = \begin{cases} 1 & \text{eger } |Ab_i(n) - Ag_i| \leq E \\ 0 & \text{diğer} \end{cases}$$

if ( $A_p < A_f$ ) then
{

$$A_p = A_f$$


$$Y_f = Ab_i(n) \text{ 'nin Class}$$

}
}
if ( $Y_f = Y_d$ ) then
{

$$Ag_i \text{ 'yi antibody popülasyonuna ekle (Ab)}$$

}
Else
{

$$Ag_i \text{ Yoket (Öldür)}$$

}

```

Şekil 4.3. Uygulamada Adım 3 için kullanılan işlem bloğu.

- N : Eğitim için alınan örnek sayısı
 $Ab_i(n)$: Mevcut antikör
 Ag_i : Yeni klonlanarak oluşturulmuş popülasyon
 A_p : Önceki affinity (benzerlik - ilgi)
 A_f : Sonuç affinity
 Y_f : Tahmini Sonuç
 Y_d : Hedeflenen sonuç
 E : Eşik Değeri (bu çalışmada 0.5 olarak alındı)
 n : Algoritma iterasyon sayısı

Adım 7’de test verilerinin sınıflandırması işlemi yapılmıştır. Bu aşamada eğitim sonucunda oluşturulan antikor popülasyonu temel alınarak test verileri sırayla karşılaştırılır ve sınıflama işlemi gerçekleştirilir. İşlem sonucunda elde edilen başarı oranları listelenir. Sınıflandırma işlemini gerçekleştiren kod bloğu:

```

for(t = 1; t < T; t++)
{
    Ap = 0
    for(n = 1; n < N; n++)
    {
        Af =  $\sum_{i=1}^{38} \delta$ ,  $\delta = \begin{cases} 1 & \text{eger } |Ab_i(n) - Ag_i(t)| \leq E \\ 0 & \text{diğer} \end{cases}$ 
        if (Ap < Af)
        {
            Ap = Af
            Yf = Abi(n) 'nin Classı
        }
    }
    Agi(t) 'nin Classı = Yf
}


```

Şekil 4.4. Uygulamada Adım 7 için kullanılan işlem bloğu.

T : Test örneklerinin sayısı

4.5. GÖHAT’ da Kullanılan Genetik Algoritma Modeli

Bilindiği gibi genetik algoritmalarda çözüme ulaşırken problemin türüne göre kromozomların gösterimi, ikili kodlu veya gerçek kodlu olmak üzere iki şekilde seçilebilir. Bu uygulama için değişkenlerin (parametrelerin) gösteriminde gerçek kodlu genetik algoritma kullanılmıştır.



Şekil 4.5. Genetik algoritma akış diyagramı.

1.Adım: Buna göre; amaç fonksiyonu, kısıt fonksiyonları ve aralıklar tanımlı olduğundan ve popülasyonun gösterim şekli seçildiğinden, yapılması gereken ilk işlem başlangıç popülasyonunu eldeki verilerden oluşturmaktır. Aralıkları problemde belirtilen parametrelerin (genlerin) ilk değerleri rastgele olarak bu değerler arasında üretilir ve başlangıç popülasyonu oluşturulmuş olunur.

2.Adım: Bu uygulamada, elde edilen popülasyondan doğal seçim işlemini yapmak için turnuva seçimi tercih edilmiştir. Turnuva seçiminde, eşleşecek çiftler (popülasyon boyutu kadar) rastgele seçilir. Çiftlerden popülasyona alınacak olan bireylerin (kromozomların) belirlenmesinde kısıt fonksiyonlarından elde edilen bir penaltı (cezalandırma – $\psi(x)$) fonksiyonundan faydalanılır.

Penaltı fonksiyonu, uygulamada verilen kısıt fonksiyonlarının istenen aralık dışında olması durumunda, üretilen kromozomların olması gereken değerlere yakınlığını değerlendiren bir fonksiyondur. Buna göre çiftlerden penaltı fonksiyonu sonucu

küçük olan birey popülasyona alınır. Aşağıda, kullanılan penaltı fonksiyonu görülmektedir.

$$\phi(x, r) = f(x) + \sum_{k=1}^K r_{kl} G_k [g_k(x)]^2 \quad (4.6)$$

Turnuva seçinde, seçim sürecini üç maddeyle özetleyebiliriz:

- a) Eğer kromozom çiftinin her ikisi de uygun aralıkta değilse, penaltı fonksiyonu sonucu küçük olan birey alınır. Yani uygun aralığa daha yakın olan birey tercih edilmiş olur. Ayrıca her iki bireyin de uygunlukları hesaplanmaz.
- b) Eğer kromozomlardan yalnız biri uygun aralıkta ise, yani penaltı fonksiyonu sonucu sıfır ise, bu kromozom popülasyona alınır. Diğer kromozomun uygunluğu hesaplanmaz.
- c) Eğer her iki kromozom da uygun aralıkta ise, kromozomların uygunluk değerleri amaç fonksiyonu yardımıyla hesaplanır ve daha uygun olan birey popülasyona alınır. Bu uygulama için minimizasyon yapıldığından dolayı uygunluk değeri daha küçük olan birey seçilir.

3.Adım: Seçim işleminden sonra sıra çaprazlama işlemindedir. Gerçek kodlu genetik algortmada da ikili kodludaki gibi çeşitli çaprazlama yöntemleri mevcuttur. Tek düzen metodu, lineer çaprazlama, heuristic çaprazlama, karma çaprazlama, kuadratik çaprazlama vb. Bu problem için tercih edilen metot, aritmetiksel çaprazlamadır.

Aritmetiksel çaprazlamada eşleşen kromozomların, karşılıklı her bir geni için rastgele [0,1] aralığında bir sayı üretilir. Bu sayı çaprazlama oranından küçük ise genler çaprazlama işlemine alınabilir. Daha sonra her bir gen için ρ adı verilen [0,1] aralığında rastgele üretilen bir katsayı ile kromozomlar (4.7) deki formüle göre çaprazlanır. Oluşan yeni nesil değerleri Şekil 4.6'da görülmektedir.

$$x_n^{1,t+1} = \rho.x_n^{2,t} + (1 - \rho).x_n^{1,t} \quad \text{ve} \quad x_n^{2,t+1} = \rho.x_n^{1,t} + (1 - \rho).x_n^{2,t} \quad (4.7)$$

Geçişten önceki örnek değerler

Girişler	X_1	X_2	...	X_{23}	X_{24}	X_{25}	X_{26}	...	X_{38}
Giriş 1	1	0	...	19	55	40	4,25	...	8,4
Giriş 2	0	1	...	63	54	117	3,43	...	0,39
Geçişten sonraki döl (nesil) değerleri									
Girişler	X_1	X_2	...	X_{23}	X_{24}	X_{25}	X_{26}	...	X_{38}
Nesil 1	1	0	...	19	55	40	3,76	...	8,4
Nesil 2	0	1	...	63	54	117	3,94	...	0,39

$a=0,38$ için rastgele seçilen geçiş değerleri

Şekil 4.6. Aritmetiksel çaprazlama sonucunda oluşan örnek değerler.


4.Adım: Çaprazlamadan sonra mutasyon işlemine geçilir. Popülasyondaki her bir kromozomun her bir geni (parametresi) için $[0,1]$ aralığında rastgele bir ρ sayısı üretilir. Eğer ρ mutasyon oranından küçükse, gen tekrar üretilerek kromozom mutasyona uğratılmış olunur.

5.Adım: Seçilen sonlanma ölçütüne göre kontrol yapılarak sürecin devam edip etmemesine karar verilir. Sonlandırma belli bir iterasyon sayısına ulaşmak ya da bir uygunluk değerine yakınsamak olabilir.

Sonuç olarak; işlemler istenilen sonlandırma ölçütüne kadar devam ettirildikten sonra problemin çözümüne en uygun olan bireyler popülasyonda birikmiş olur. Buna göre geliştirilen uygulamada, 100 iterasyon için, 0.7 çaprazlama oranında, 0.05 mutasyon oranı ile 357 popülasyon boyutlu ve penaltı parametresi 1000 seçilerek optimum sonuca ulaşılmıştır.

4.6. GÖHAT Simülatorü

Geliştirilen C# uygulamasında Şekil 4.7’de görülmekte olan bir ana form üzerinde her bir algoritma için ayrı bir teşhis işlem formu oluşturulmuştur. Formun üzerinde iki menü şeklinde YSB, YSA ve GA formları mevcuttur. Bu işlemler kendi formlarında sonuçlandırılarak ana formun bilgi çubuğunda kullanıcıya verilmektedir.



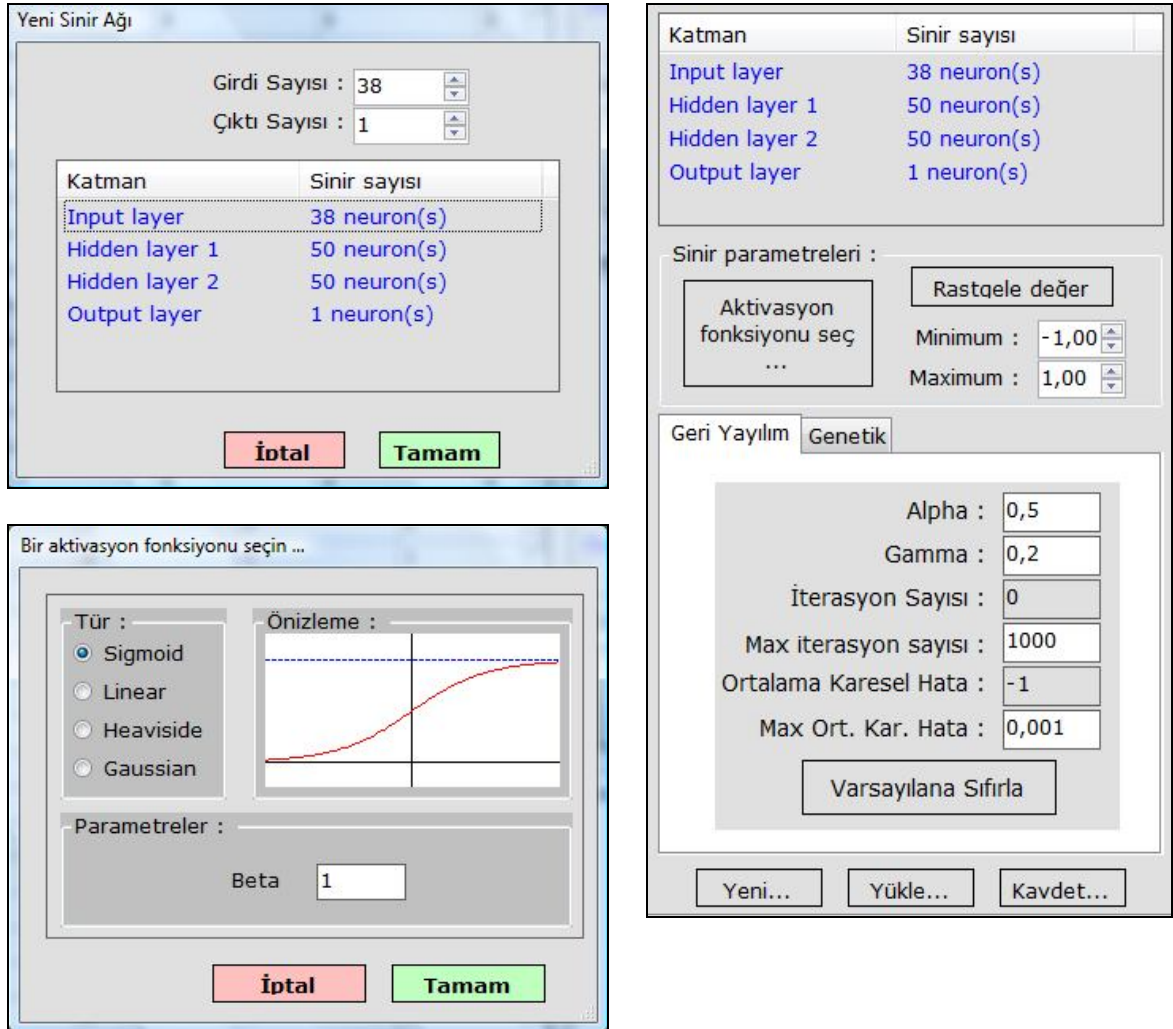
Şekil 4.7. GÖHAT simülatorü ana formu ve YSA eğitim penceresi.

4.6.1. YSA ve GA eğitim ve test işlemleri formu

Bu işlem esnasında uygulanması gereken işlem adımları şunlardır:

1. Ağın yapısının belirlenmesi: Bu işlem ile GÖHAT’da kullanılacak YSA yapısı oluşturulur. Şekil 4.8 (a)’da görüldüğü üzere yeni butonuna basarak ağın girdi, gizli ve çıktı katman sayıları belirlenmektedir. Bunun yanında aktivasyon

fonksiyonun seçilmesi ve rastgele parametre seçimine de olanak sağlayan ayar penceresi de Şekil 4.8 (b)'de görülmektedir.




Şekil 4.8. (a) Yeni bir YSA oluşturma penceresi
(b) Yeni YSA'nın parametre seçim penceresi
(c) Aktivasyon fonksiyonu seçim penceresi

Ayrıca aktivasyon fonksiyonu seçme ekranı da kullanıcıya görsel bir şekilde sunulmuştur. Şekil 4.8 (c)'de aktivasyon fonksiyonu seçim ekranı görülmektedir.

2. Eğitim veri setinin okunması ve normalize edilmesi: Bu işlem ile hasta veritabanımız program ortamına aktarılmaktadır. Önce giriş parametrelerinin

başlıkları dosya yardımı ile gösterilmekte, sonra da veriler okutulmaktadır. Verilerin okutulması ile oluşan ekran görüntüsü Şekil 4.7’de görülmektedir.

3. Eğitime başlanması: YSA eğitim işleminin başlaması ile oluşturulan ağ öğrenme işlemini gerçekleştirir. Bu işlem sırasında oluşan ağırlıklar her bir sinir ağı için görülebilmektedir. Şekil 4.9’da giriş katmanı ile birinci gizli katman arasındaki ağırlıklar görülmektedir. Bu pencere yardımı ile tekrardan rastgele ağırlıklar istenilen maksimum ve minimum değerler arasında üretilebilir, aktivasyon fonksiyonu değiştirilebilir ve katman sinir ağırlıkları tek tek incelenebilir.



Şekil 4.9. Katmanlar arasındaki ağırlıkları görüntüleme penceresi.

4. Eğitim sonucunun raporlanması: Bu işlem ile eğitim sona ermiş ve sonuç rapor formu oluşmuştur. Şekil 4.10’da görüldüğü gibi eğitim işleminin sonuç olarak çıkan raporda; 3 set halinde işleme konan verilerin eğitim süreleri, toplam veri

sayıları, hatalı sonuç sayıları, başarı oranı yüzdeleri ve hatalı oran yüzdeleri ile hangi verilerin hatalı sonuç bulduğu bilgisi kullanıcıya sunulmuştur.

**** 1. set sonuçları ****		
Eğitim süresi: 1 dakika 31 saniye 977 milisaniye		
Toplam veri sayısı: 32		
Hatalı sonuç sayısı: 2		
Başarı Oranı: %93,75 (Hata Oranı: %6,25)		

Hatalı sonuçlar:		
-> Beklenen: KOAH(3)	-	Test Sonucu: Normal(4)
-> Beklenen: Normal(4)	-	Test Sonucu: KOAH(3)
**** 2. set sonuçları ****		
Eğitim süresi: 1 dakika 31 saniye 369 milisaniye		
Toplam veri sayısı: 32		
Hatalı sonuç sayısı: 3		
Başarı Oranı: %90,625 (Hata Oranı: %9,375)		

Hatalı sonuçlar:		
-> Beklenen: Pnömani(1)	-	Test Sonucu: KOAH(3)
-> Beklenen: Astım(2)	-	Test Sonucu: Normal(4)
-> Beklenen: Normal(4)	-	Test Sonucu: KOAH(3)
**** 3. set sonuçları ****		
Eğitim süresi: 1 dakika 31 saniye 540 milisaniye		
Toplam veri sayısı: 32		
Hatalı sonuç sayısı: 3		
Başarı Oranı: %90,625 (Hata Oranı: %9,375)		

Hatalı sonuçlar:		
-> Beklenen: Normal(4)	-	Test Sonucu: KOAH(3)
-> Beklenen: Normal(4)	-	Test Sonucu: KOAH(3)
-> Beklenen: Astım(2)	-	Test Sonucu: KOAH(3)

Şekil 4.10. Eğitim sonuç raporu.

5. Test işlemi: Eğitim sonucu öğrenen ağda test verileri işleme alınır. Bu işlem için tasarlanan pencere aynı zamanda hastalık veritabanını oluşturma işleminde de kullanılmaktadır. Pencere üzerine rastgele kayıt al butonu ile daha önce belirlenen test seti içerisinde bir kayıt olarak kullanıcı ekranına getirilmektedir. Daha sonra test butonu ile eğitilmiş ağda bu veri kümesi işleme tabii tutulmaktadır. İşlem sonunda da beklenen değer ve test sonucu karşılaştırılmıştır.

TestForm					
Yakınma (Öksürük) [0-Yok; 1-Var]	1	Yakınma (Ateş) [0-Yok; 1-Var]	0	Yakınma (Göğüste Ağrı) [0-Yok; 1-Var]	0
Yakınma (Halsizlik) [0-Yok; 1-Var]	0	Yakınma (Nefes Darlığı) [0-Yok; 1-Var]	1	Yakınma (Hıltı) [0-Yok; 1-Var]	1
Yakınma (Göğüste Sıkışma) [0-Yok; 1-Var]	0	Yakınma (Balgam) [0-Yok; 1-Var]	1	Muayene (Solunum Sistemi) [0-Normal; 1-Kötü]	1
Alışkanlıklar (Sigara) [0-Yok; 1-Var]	1	WBC [4; 11]	7,51	RBC [4,20; 6,20]	5,78
HGB [12; 18]	14,89	HCT [35; 55]	48,9	PLT [150; 400]	380
Albumin 2 [3,5; 5,2]	3,56	Alkalemi Fosfat 2 L [38; 155]	80	ALT [5; 41]	7
Amilaz [28; 100]	55	AST [5; 37]	9	Bilirubin (Total+ Direkt) [0; 1,0]	0,49
CK / Kreatin Kinaz [15; 170]	18	CK - MB [6; 24]	18	Demir (Serum) [37; 145]	36
GGT [8; 61]	12	Glukoz [70; 110]	125	HDL Kolesterol [35; 65]	34
Kalsiyum (CA) [8,4; 10,8]	8,61	Kan Üre Azotu (BUN) [13; 50]	22	Klor (CL) [96; 110]	101
Kolesterol [40; 200]	158	Kreatinin [0,4; 1,5]	0,71	LDH [240; 480]	358
Potasyum [3,5; 5,5]	4,82	SODYUM (Na) [140; 157]	140	TOTAL PROTEİN [6,4; 8,3]	7,14
TRİGLİSERİD [40; 200]	99	ORİK ASİT [0; 7]	4,75		
Beklenen Çıktı : KOAH (3)			Test Sonucu: Pnömani (1)		<input type="button" value="Test"/>
<input type="button" value="Rastgele Kayıt Al"/>					

Şekil 4.11. Test işlemi ve yeni hasta verisi giriş penceresi.

Ayrıca form üzerinde bir boş alana fare ile basıldığında belirlenen 100 veri üzerinde test işlemi yapılmakta ve başarı oranı da ekranda gösterilmektedir. Şekil 4. 12’de 100 adet test verisi üzerinde yapılan işlem sonucu görülmektedir.

Alkalemi Fosfat 2 L [38; 155]	46
<div style="border: 1px solid black; padding: 5px; width: fit-content; margin: 0 auto;"> <p>Doğruluk Testi</p> <p>100 deneme içinden 93 adedi doğru</p> <p style="text-align: center;"><input type="button" value="Tamam"/></p> </div>	
SODYUM (Na) [140; 157]	136

Şekil 4.12. Belirlenen 100 kayıt üzerinde test işlemi.

Hatalı görülen ve doğru teşhiste bulunan örnekler Şekil 4.13’de görülmektedir.

		Test
Beklenen Çıktı : KOAH (3)	Test Sonucu: Pnömani (1)	Rastgele Kayıt Al

		Test
Beklenen Çıktı : KOAH (3)	Test Sonucu: KOAH (3)	Rastgele Kayıt Al

Şekil 4.13. Test işlemi sonucu doğru ve yanlış sonuçlar.

6. Test işleminin tamamlanması ve sonucun ana pencere üzerindeki bilgi çubuğuna yazılması.
7. Sonuçların değerlendirilmesi.

GA için kullanılacak parametre ayar penceresi de ana form üzerinde ve Şekil 4.14'te görülmektedir. GA hesaplama yöntemi de YSA ile aynı işlem adımlarına sahiptir. Teşhis işlemine başlamadan önce sistemin parametreleri belirlenmektedir. Sonra yukarıda açıklanan işlem basamakları uygulanmaktadır. Sonuç ana formun bilgi çubuğuna yazılmaktadır.

Geri Yayılım		Genetik	
Popülasyon Boyutu :	50		
Seçim Oranı :	10		
Mutasyon Oranı :	4		
Mutasyon Genliği :	1,00		
Nesil :	0		
Max. Nesil Sayısı :	1000		
Karesel Hata :	-1		
Max. Karesel Hata :	0,001000		
Tüm popülasyonu rastgele oluştur			
Yeni...		Yükle...	
Kavdet...			

Şekil 4.14. GA parametre belirleme penceresi.


4.6.2. YSB eğitim ve test işlemleri formu

GÖHAT' ın AIS hesaplama penceresinin takip ettiği adımlar şu şekildedir;

1. Eğitim veri setinin okunması ve normalize edilmesi: Bu işlem ile yolu belirtilen eğitim dosyası programa yüklenerek okunması sağlanmaktadır. Bu veri yükleme işlemi sırasında normalize işlemleri de bu arayüz sayesinde yapılmaktadır. Ayrıca problemin giriş sayısı, çıkış sayısı, veriler arasındaki ayırıcın belirlenmesi de bu aşamada tayin edilmektedir. GÖHAT simülatörünün YSB karar destek sistemi bölümü eğitim seti ön işlemleri Şekil 4.15'te görülmektedir.

Şekil 4.15. GÖHAT Simülatorü YSB hesaplama penceresi ön işlemler arayüzü.

2. Eğitime başlanması: Bu işlem verilerin okunması ile başlar. Dosya yolu gösterilen veriler program ortamına normalize edilmiş bir şekilde aktarılır. Böylece başlangıç popülasyonu belirlenmiş olunur.



Şekil 4.16. GÖHAT Simülâtörü YSB hesaplama penceresi eğitim işlemleri arayüzü.

3. Eşik değerlerinin belirlenmesi: Verilerin yüklenmesinden sonra oluşturulan başlangıç popülasyonu ile her adım için uygun eşik değeri bulunur. İstenildiği takdirde her bir eşik değeri program aracılığı ile değiştirilebilir. Buradan elde edilen değerler belirli işlem aralıkları ile saklanır, bu sayede eğitim ile öğrenen sistemin öğrenme diyagramı oluşturulur ve bu aralıklarda elde edilen test başarı durumu da diyagram olarak oluşturulmaktadır. Bu bilgiler doğrultusunda eğitimin bitirilmesi için gereken iterasyon sayısı ve yüksek başarının sağlandığı eşik değerleri saptanmış olunur. Eşik değer belirleme işleminde Öklid bağıntısı kullanılmıştır.

4. Mutasyon ve veri türetimi: Eşik değerlerinin bulunması sonucu eğitim verilerinden mutasyon ve klonlama teknikleri ile yeni türetimler yapılmakta ve eğitim popülasyonu genişletilmeye çalışılmaktadır. Bu işlem Şekil 4.16’da görülen “Türetim” butonu sayesinde gerçekleştirilmektedir.
5. Eğitimin tamamlanması: Eğitim için gerekli adımlar geçildikten sonra ağ eğitime başlar. Bu işlem, Şekil 4.16’da görülen “Eğitimi Gerçekleştir” butonuna basılması ile neticelendirilmektedir.
6. Test veri setinin okunması ve normalize edilmesi: Test veri dosyası sistem tarafından okunur ve özelliklerine ayrıştırılır. Sınıf sayıları belirlenir ve normalizasyon işlemine tabi tutulur. Bu sayede test popülasyonu, YSB diliyle sınıflandırılmayı bekleyen antijen popülasyonu oluşturulmuş olur.



Şekil 4.17. GÖHAT Simülatorü YSB hesaplama penceresi test işlemleri arayüzü.

7. Sınıflandırma işleminin tamamlanması: Eğitim sonucunda oluşturulan antikör popülasyonu baz alınarak test verileri sırayla karşılaştırılır ve sınıflama işlemi gerçekleştirilir. İşlem sonucunda elde edilen başarı oranları listelenir. Test işlemlerinin yapıldığı GÖHAT simülatörü penceresi Şekil 4.17’de görülmektedir.
8. Sonuçların değerlendirilmesi: Test işlemi sonucu elde edilen doğruluk oranları ile eğitimin ve testin başarısı ortaya çıkmıştır. Bu işlemin doğruluk oranı GÖHAT ana penceresindeki bilgi çubuğuna yazılarak kullanıcıya hesaplama yöntemlerinden elde ettiği sonuçların karşılaştırılması olanağı sunulmuştur.

4.7. Göğüs Hastalıklarının Teşhisinde Kullanılan Diğer Yöntemler

GÖHAT simülatörüne eklenmesi planlanan diğer hesaplama yöntemlerinin başında ANFIS gelmektedir. Bu yöntem Matlab 2007 matematik hesaplama programı aracılığı ile bu alanda uygulanabilirliği test edilmiş ve veri setimiz üzerinde sınıflandırma işlemlerinde kullanılmıştır.

Ayrıca tıbbi teşhis alanında kullanılan karakteristik davranış alıcı eğrileri (ROC) de sonuca ulaşmada önemli bir yöntem olarak gösterilmektedir.


4.7.1. Karakteristik davranış alıcı eğrileri (receiver operating characteristic curves- ROC)

Tanı Testi performanslarının değerlendirilmesi ve kıyaslanması için en yaygın kullanıma sahip olan yöntem ROC eğrisidir. Klinik çalışmalarda sürekli sayıların kullanıldığı ölçümlerde olguları ayırma (hasta/sağlam), çözümlmeyi karmaşık hale getirir ve hata olasılığını yükseltir. Sonuçta, klinik şartlara bağlı olarak tanı testinin optimum etki noktası değişmektedir [124].

Bu çerçevede seçilen farklı eşik değerleri için bulunan farklı duyarlılık-özgüllük karakterlerine bağlı olarak ara seçenekler belirlenerek, ROC eğrileri oluşturulmuştur. ROC eğrisi yöntemi;

1. Testin ayırt etme gücünün belirlenmesine,
2. Çeşitli testlerin etkinliklerinin kıyaslanmasına,
3. Uygun pozitiflik eşliğinin belirlenmesine,
4. Laboratuvar sonuçlarının kalitesinin izlenmesine,
5. Uygulayıcının gelişiminin izlenmesine,
6. Farklı uygulayıcıların etkinliklerinin kıyaslanmasına olanak sağlar.

ROC eğrisinin oluşturulacağı koordinat sisteminin ordinatında tanı testinin gerçek pozitif değeri (duyarlılık), apsisinde ise yanlış pozitif değeri (1-özgüllük) yer alır. Tanı testi ne kadar iyi ise eğri o kadar yukarıya (yüksek duyarlılık bölgesi) ve sola (düşük yanlış pozitif oranı bölgesi) doğru kayar. Yanlış değerlere sahip olmayan ideal bir testte ROC eğrisi (0,0)-(0,1)-(1,1) noktalarını birleştirmektedir. Buna karşın ROC çizimi $y=x$ fonksiyonuna yaklaştıkça başarısız bir test ortaya çıkar. Çünkü bu testte yanlış değerlerin oranı yükselmektedir. Bu fonksiyonun altındaki ROC eğrisine sahip test başarısızdır [124].



Şekil 4.18. İdeal ve kötü performans göstergesi olan ROC eğrileri.

Böylece, bir tanı testi için ROC altında kalan alan etkinlik düzeyine bağlı olarak 0.50 ile 1.00 arasında değerler alabilecektir. Bu alan ne kadar büyükse, tanı testi o denli ayırım yeteneğine sahip olacaktır. Bu alan 0.975 ve daha üzerinde ise mükemmel sayılmaktadır [124].

BÖLÜM 5. SONUÇ VE ÖNERİLER

5.1. Sonuçlar

Bu çalışmada, öncelikle bir göğüs hastalıkları hastanesinden temin edilmiş 357 adet epikriz raporu üzerindeki parametreler ele alınmış ve hastalığının teşhisine yardımcı olabileceği uzman doktorlar aracılığı ile belirlenmiş 38 parametre seçilmiştir. Bu parametrelerden oluşmuş ve hastanın özelliklerinin bulunduğu veritabanı, GÖHAT adında geliştirilen uygulama aracılığı ile içerisinde barındırdığı esnek hesaplama ve biyobilişim tekniklerinin kullanılmasıyla işlenmiştir. Sonuç olarak karar destek sistemi olarak geliştirilen ve hastalığının teşhisine yardımcı olacağı düşünülen uygulamanın sonuçlarında başarı sağlandığı görülmüştür.

YSA'daki öğrenme özelliği, değişik birçok problemde olduğu gibi teşhis probleminde de olumlu sonuçlar verdiği bu çalışma ile bir kez daha görülmüştür. Geri yayılım öğrenme algoritmaları uygulanmış ve eğiticili algoritma ile ileri beslemeli sinir ağların eğitimi gerçekleştirilmiştir. YSA modeli, eğitim yüzlerinden yararlanarak kendi modelini oluşturmuş ve hastalıkları sınıflandırmıştır. Yapılan çalışma; geri yayılım algoritmaları ağların hastalığı teşhis ile ilgili sınıflandırma görevi için kullanılabileceğini göstermiştir. Gerçekleştirilen sistemin YSA hesaplama yöntemi ile elde edilen sonuçlar ve Matlab 2007 yazılımında diğer YSA modelleri ile elde edilen sonuçlar tablo 5.4 içerisinde sunulmuştur.

Yapılan çalışmada, YSA algoritmalarının yanında, hızlı ve etkili bir problem çözme tekniği olan yapay bağışıklık sistemleri incelenmiş, literatür incelemesinden elde edilen bilgiler doğrultusunda, YBS tabanlı ve göğüs hastalıkları arasında teşhis yapabilen zeki bir sistem geliştirilmiştir. Yapay bağışıklık sistemleri, yapay sinir ağları ve genetik algoritmalara benzer şekilde, bazı biyolojik sistemlerin özet modelleridir ve birçok alanda uygulaması bulunmaktadır. Çalışmada öncelikle Yapay

Bağışıklık Sistemleri'nde kullanılan doğal bağışıklık mekanizmaları, bu mekanizmalara dayanan algoritmalar verilmiştir. Bu modeller ile farklı problemlerin çözümleri için yapılmış çalışmalardan bahsedilmiştir. Bu çalışmalardaki sonuçlara göre YBS karar destek sistemi olarak geliştirilen hastalık teşhis alanında oldukça tatmin edici sonuçlar vermiştir. Gerçekleştirilen sistem YSB hesaplama yöntemi kullanılarak geliştirilen bölümünde elde edilen sonuçlar tablo 5.4 içerisinde görülmektedir.

Bu tez çalışmasında kullanılan GA, çözüm(ler) bulmak için taranması gereken parametre uzayının çok büyük olduğu durumlarda bu arama işlemi, için en akılcı yöntemdir. Evrimin her sürecinde edinilen bilgi sonra ki nesillere aktarılarak taramanın daha uygun bölgelerde gezmesi sağlandığı gibi değişim işlemi yardımıyla yerel çözüm noktalarına sıkışıp kalma olasılığı da azaltılıyor. Ayrıca GA'nın paralel işlem yapılan bilgisayarlarda kullanılmaya elverişli yapısı da zaman alıcı problemlerin çözümü için çekici bir seçenek olmasını sağlamaktadır. Bu çalışma da kullanılan GA yapısı ile hastalık teşhis alanında küçümsenmeyecek bir doğruluk oranı sağlandığı görülmüştür.

Bu çalışma esnasında öncelikli olarak veritabanı üzerinde MATLAB programı aracılığı ile uygulamanın gerçekleştirilebilirliğini görmek için bazı deneyler yapılmıştır. Projenin aşamaları bu sayede gözlemlenmiş olup uygun algoritmaların seçimi de kolaylaştırılmıştır. Ön çalışmalar sırasında yapılan deneyler için gerekli parametreler değiştirilerek defalarca denenmiş olup optimum sonuca ulaşmada uzun uğraşlar verilmiştir. Deneylerin başarı oranlarının tatmin edici seviyeye gelmesinin ardından C # programlama dilinde geliştirilen bir uygulama aracılığı ile karar destek sistemi haline getirilmiştir. Bu deneylerin sonucunda elde edilen sınıflandırma doğruluk oranları Tablo 5.1'de gösterilmiştir [125-127].

Tablo 5.1. MATLAB programı üzerinde gerçekleştirilen ve literatüre geçmiş deneyler.

Çalışma	Metot	Eğitim Algoritması	Sınıflandırma Doğruluk Oranı (%)
Referans [125]	MLNN (bir gizli katman)	BP (momentum)	93,14 %
	MLNN (bir gizli katman)	LM	94.46 %
	MLNN (iki gizli katman)	BP (momentum)	95.43 %
	MLNN (iki gizli katman)	LM	96.08 %
Referans [126]	MLNN (iki gizli katman)	BP (momentum)	92.14 %
	MLNN (iki gizli katman)	LM	93.08 %
	PNN	-	93.92 %
	LVQ	-	92.65 %
	AIS	-	94.00 %
Referans [127]	GRNN (bir gizli katman)	-	93.18 %
	MLNN (bir gizli katman)	BP (momentum)	93.04 %
	MLNN (bir gizli katman)	LM	93.42 %
	MLNN (iki gizli katman)	BP (momentum)	93.93 %
	MLNN (iki gizli katman)	LM	95.08 %

Bölüm 1’de anlatılan ve literatüre geçmiş çalışmalar dikkate alındığında bu konuda yapmış olduğumuz araştırmaların daha iyi performans sağladığı da görülmüştür. Ayrıca literatürdeki çalışmalardan farklı olarak birden fazla hastalık üzerine de sınıflandırma işleminin başarıldığı görülmüştür. İlk çalışmamızda KOAH’ a sahip hastalıklı veriler ile normal veriler arasında yapılan sınıflandırma probleminde %96,08 başarı oranına ulaşılmıştır. Bu çalışmada 2 gizli katman ve LM eğitim algoritması kullanılarak gerçekleştirilen ve en iyi başarı oranına sahip YSA algoritmasının teşhis konusunda tatmin edici bir sonuç elde edildiği de kanıtlanmıştır [125]. İkinci çalışmamızda KOAH, Pnömoni ve normal verilerin oluşturduğu veri seti üzerinde yapılan sınıflandırma probleminde YSA ve YSB algoritmaları kullanılmıştır. Bu çalışmada YBS algoritması ile %94,00 ve YSA’nın PNN algoritması ile %93,92’lik bir doğruluk oranı elde edilmiştir [126]. Üçüncü çalışmamızda ise tüberküloza sahip hastalıklı veriler ile normal veriler arasında yapılan sınıflandırma probleminde %95,08 başarı oranına ulaşılmıştır. Bu çalışmada da ilk çalışmamız gibi YSA kullanılarak geliştirilen testlerde 2 gizli katman ve LM

algoritmasının teşhis konusunda oldukça başarılı olduğu görülmüştür [127]. Bu çalışmalar, GÖHAT simülatörünün gerçekleştirilebilirliğini ortaya koymuştur.

Diğer yandan bu tez çalışmasında, referanslardaki uygulamalarla aynı yapıda kullanılan yapay sinir ağı ile sınıflandırma işlemleri yapılmış olup daha iyi bir performans elde edilmiştir. Bunun nedenlerinden biri ağın girişi için kullanılan özelliklerin farklılığından olduğu düşünülmektedir. Bu çalışmada hastalık teşhisinde kullanılan giriş özellikleri ve ağın parametrelerinin doğru seçilmesi ile başarı oranının arttığı düşünülmektedir.

Tablo 5.2. Çalışma esnasında elde edilen (doğruluk/toplam) teşhis sayıları

Metot	Tanıma Esnasındaki (Doğru / Toplam) Teşhis Sayıları						
	Tüberküloz	KOAH	Pnömoni	Astım	Akc. K.	Normal	Toplam
GRNN (bir gizli katman)	43/50	59/71	53/60	38/44	27/32	95/100	315/357
MLNN -BPwM (bir gizli katman)	42/50	60/71	53/60	39/44	28/32	96/100	318/357
MLNN - BPwM (iki gizli katman)	42/50	62/71	54/60	40/44	28/32	98/100	324/357
MLNN - LM (bir gizli katman)	42/50	62/71	55/60	39/44	30/32	95/100	323/357
MLNN - LM (iki gizli katman)	44/50	63/71	54/60	40/44	29/32	96/100	326/357
PNN	44/50	63/71	53/60	40/44	30/32	99/100	329/357
LVQ	42/50	60/71	52/60	38/44	30/32	94/100	316/357
AIS	45/50	66/71	56/60	40/44	30/32	98/100	335/357
GA	44/50	65/71	54/60	39/44	28/32	96/100	326/357
ANFIS	44/50	62/71	52/60	37/44	28/32	95/100	318/357
ROC	332/357						

GÖHAT simülatörü elde edilen veriler üzerinde üç farklı hesaplama yöntemi kullanılarak geliştirilmiştir. İnsanın biyolojik yapısının taklit edildiği matematiksel modellerin kullanıldığı simülatörde işlenen YSA, YBS ve GA yapılarının yanında Matlab 2007 yazılımı kullanılarak ANFIS ve internet ortamından elde edilen ROC hesaplama programı ile de sınıflandırma işlemi denenmiştir. Bu işlemler esnasında

hastalık ve doğru teşhis sayıları tablo 5.2’de görülmektedir. Bu uygulama ile farklı yöntemlerin de teşhis alanında başarılı olabileceği bir kez daha ortaya konmuştur.

Tablo 5.2’de görüldüğü üzere sınıflandırma esnasında elde edilen doğru teşhis sayıları içerisinde “Normal” sınıfının ayırt edilme yüzdesinin iyi olduğu söylenebilir. Bu durum normal kişiye hasta demek sorununda hata olasılığının oldukça düşük olduğunu vurgulamaktadır. Yapılan testler sonucunda PNN algoritmasının 99/100 oranı ile en iyi hasta-normal ayırımını yaptığı da gözlemlenmektedir. Ayrıca tüberküloz hastalığının doğru teşhis sayıları diğer hastalıklara nazaran daha düşük olduğu da görülmektedir. Bunun nedenlerinin başında eldeki verilerin hastalığın karakteristik özelliklerini yansıtmaması ve yetersiz olması gelmektedir. Göğüs hastalıklarının semptomları birbirine çok yakın olmakla birlikte insan üzerindeki etkileri de birbirine yakındır. Bunun neticesinde hastalığı diğerlerinden ayırt etmek de zorlaşmaktadır. Bu durumun giderilmesi için veri setinin artırılması ve hastalığı doğru temsil edecek örneklerin kullanılması gerekmektedir.

Tablo 5.3. Çalışma esnasında elde edilen (doğruluk/toplam) teşhis yüzdeleri

Metot	Tanıma Esnasındaki (Doğru / Toplam) Teşhis Yüzdeleri						
	Tüberküloz	KOAH	Pnömoni	Astım	Akc. Kan.	Normal	Toplam
GRNN (bir gizli katman)	86,00%	83,10%	88,33%	86,37%	84,38%	95,00%	88,24%
MLNN - BPwM (bir gizli katman)	84,00%	84,51%	88,33%	88,64%	87,50%	96,00%	89,08%
MLNN - BPwM (iki gizli katman)	84,00%	87,32%	90,00%	90,91%	87,50%	98,00%	90,76%
MLNN - LM (bir gizli katman)	84,00%	87,32%	91,67%	88,84%	93,75%	95,00%	90,48%
MLNN - LM (iki gizli katman)	90,00%	88,73%	90,00%	90,91%	90,63%	96,00%	91,60%
PNN	88,00%	88,73%	88,33%	90,91%	93,75%	99,00%	92,16%
LVQ	84,00%	84,51%	86,67%	86,37%	93,75%	94,00%	88,52%
AIS	90,00%	92,96%	93,33%	90,91%	93,75%	98,00%	93,84%
GA	88,00%	91,55%	90,00%	88,64%	87,50%	96,00%	91,32%
ANFIS	88,00%	87,32%	86,67%	84,09%	87,50%	95,00%	89,08%
ROC	93,00%						
Her bir hastalık için yapılan doğru teşhis yüzdeleri	86,60%	87,61%	89,33%	88,66%	90,00%	96,20%	90,74%

Tablo 5.3’de her bir hastalık için sınıflandırma sonucu elde edilen doğru teşhis yüzdeleri görülmektedir. Akciğer kanserinin diğer hastalıklardan ayırt edici özelliğinin biraz fazla olduğu görülmektedir. Hastalık verisi az olduğu halde teşhis yüzdesinin fazla olduğu da dikkat çekmektedir. Verilerin hastalığa özgü özellikler taşıdığı düşünülmele birlikte bu hastalığı ifade ettiği söylenebilir. Ayrıca hastalığı temsil eden örnek sayısı arttırıldığı takdirde doğru teşhis oranının artacağı görülecektir.

GÖHAT simülatörü içerisinde kodlanan algoritmaların eğitim ve test işlemleri sonucu elde edilen doğruluk yüzdeleri tablo 5.4’de görülmektedir.

Tablo 5.4. Göğüs hastalıkları veri seti üzerinde yapılan sınıflandırma problemi sonuçları.

Çalışma	Metot	Doğruluk (%)
(YSA)	GRNN (1 gizli katman ile)	88.24 %
	MLNN - BPwM (1 gizli katman ile)	89.08 %
	MLNN - LM (1 gizli katman ile)	90.48 %
	MLNN - BPwM (2 gizli katman ile)	90.76 %
	MLNN - LM (2 gizli katman ile)	91.60 %
	PNN	92.16 %
	LVQ	88.52 %
(AIS)	AIS	93.83 %
(GA)	GA	91.31 %
(ANFIS)	ANFIS (Matlab Prog.)	89.05 %
(ROC)	ROC (MedCalc Hesaplama Prog.)	93.00 %

GÖHAT simülatöründe, YSB hesaplama yönteminin kullanılması sonucu, %93,83’lük doğruluk oranı ile en iyi performans elde edilmiştir. İkinci olarak en iyi performansa YSA algoritmalarının kullanılması ile ulaşılmıştır. Bu yöntem ile %91,59 doğruluk oranı sağlanmıştır. Kullanılan YSB, YSA ve GA hesaplama yöntemleri arasında en az doğruluk oranı %91,31 ile GA’ ya aittir. Fakat YSA ve GA yapılarından çıkan sonucun çok yakın olduğu görülmektedir.


GÖHAT simülatörünü desteklemek amacıyla yapılan diğer çalışmalardan da olumlu sonuçlar alınmıştır. Bu tez çalışmasının geneline bakıldığında en iyi performansın

yine YSB'ye ait olduğu söylenebilir. İkinci en iyi performans, MadCal uygulaması kullanılarak ve ROC eğrilerinin altında kalan alanın hesaplaması ile elde edilen %93'lük başarı oranıdır. Üçüncü en iyi performansın PNN ağ yapısının kullanılması sonucu elde edilen %92,15'lik doğruluk oranıdır.

Bu çalışmada GRNN ağının performansının eldeki veriler üzerinde sınıflandırma performansının düşüklüğü dikkat çekmektedir. Ağın parametrelerinin iyileştirilmesi ve eldeki verilerin hastalığı daha çok simgelemesi de bu oranın yükselmesi için yeterli olacağı düşünülmektedir.

Aynı tabloda görüldüğü üzere, yapılan çalışmalarda çok katmanlı yapay sinir ağı için kullanılan LM eğitim algoritmasının BP eğitim algoritmasından daha iyi sonuç verdiği de görülmektedir.

Tüm algoritmaların uygulama sonucundaki teşhis yüzdelerinin ortalaması %90,74 olarak bulunmuştur. Elde edilen bu ortalamanın, tıp alanında göğüs hastalıklarının teşhisi konusunda karar destek sistemi olarak kullanılabilmesi için küçümsenmeyecek bir öneme sahip olduğu düşünülmektedir.



Şekil 5.1 GÖHAT simülöründe eğitim ve test başarı değişim grafiği.

Eđitim ve test ařamaları byk bir dikkatle izlenen GHAT simlatrnde karřılařılan sorunların bařında ađın ezberleme yapmasıdır. Hastalık sınıflarının veri setlerine homojen dađılımı bu durumun en byk etkendir. Eđitim srecinde dikkat edilen bir diđer durum eđitimin devam ettirilmesine karřın test bařarı oranının belli bir deđerini ařmamıřtır. Bu da gerekli iterasyon sayısının dođru belirlenmemesinden kaynaklanan bir durumdur. Akabinde bu yanlıř iterasyon sayısı eđitimin gerektiđinden daha fazla zaman kaybına neden olmasına yol amaktadır.

Geliřtirilen sistem aynı zamanda genel bir sınıflandırma ve tanıma sistemi olarak kullanılabilir. Belli hastalıkların parametrelerinden yeni veri setleri oluřturularak tıbbın deđiřik alanlarında kullanılabilir. Bu problemler ile ilgili veri setlerinin sisteme giriř olarak verilmesi durumunda sistem ilgili problem iin eđitilebilir, ilgili problemi đrenebilir. Bu zelliđi ile herhangi bir sınıflandırma ve tanıma problemi iin genel bir simlatrdr.

5.2. neriler

alıřma genel olarak deđerlendirildiđinde;

lkemizde, gđs hastalıklarının teřhisi konusunda bir karar destek sistemi oluřturmak iin yeterli alıřmanın bulunmadıđı grlmřtr. Ayrıca bu sistemlerin geliřtirilmesi iin gerekli olan veri kmelerinin temini de olduka gctr.

Literatrde, hastalık teřhisi konusunda yapılan sınıflandırma problemleri alıřmalarının yeterli ve gncel olmadıđı grlmřtr. Bu alanda yapılan alıřmalar genellikle spesifik bir hastalık zerinde yođunlařtıkları grlmřtr.

Bu alıřma ile literatrdeki alıřmalardan farklı olarak aynı anda birden fazla hastalık arasında bir sınıflandırma iřleminin yapılabileceđi vurgulanmıř ve nemsenecek bir bařarı elde edilmiřtir. Bu ama dođrultusunda farklı hesaplama yntemleri incelenmiř olup bu alanda yapılacak diđer alıřmalara rnek teřkil edeceđi dřnlmektedir.

Geliştirilen GÖHAT karar destek sistemi örnek uygulamasının zemininde kullanılan algoritmalar, birçok alanda başarılı sonuç verdiği gibi tıbbi teşhis alanında da küçümsenmeyecek bir başarı oranı ile sonuca gittiği görülmüştür. Bu algoritmalar arasında yeni bir alan olan yapay bağışıklık sistemleri, sınıflandırma problemleri karşısında öğrenme yeteneği ile başarılı bir performans göstermiş ve diğer çalışmalar için uygulanabilirliği desteklenmiştir. Bunun yanında yapay sinir ağlarının da uygulamalardaki başarısı bir kez daha bu proje ile görülmüştür.

Geliştirilen uygulama belirlenecek pilot hastanelerde laboratuvar ortamlarında kullanılacak paket program haline getirilmiştir. Teşhis doğruluğunu artırmak için diğer çalışmalarla paralel olarak işleme özelliğine sahip olmakla birlikte, bu çalışmaya ilaveten farklı yöntemlerin eklenmesi ile uygulama daha geniş kapsamlı bir sınıflandırma yapısına kavuşturulabilecektir.

GÖHAT simülatörünün yapısı itibari ile farklı tıbbi alanlarda insanoğluna hizmet etmesi amaçlandığından, genel bir uygulama olarak geliştirilmiştir. Belirlenecek farklı hastalık türleri üzerinde de başarılı bir sınıflandırma işlemi yapılabileceği de düşünülmektedir. Bunun için sisteme girilecek özelliklerin doğru seçilmesi ve hastalıkları simgeleyecek verilerin doğru örneklendirilmesi, sonucun başarısına katkı sağlayacaktır.

Bu sistemlerin gelişiminin bir uzman doktor denetiminde gerçekleşmesinden ötürü bu alandaki diğer çalışmalara zemin olabileceği düşünülmektedir.

KAYNAKLAR

- [1] PERSIDIS, A., Medical Expert Systems: An Overview. Journal of Management in Medicine, 5(3): Abstract 1991.
- [2] TROVBRIDGE, R. and WEINGARTEN, S., Clinical Decision Support Systems, Internet; University of California, San Fransisco School of Medicine www.apchr.gov/clinic/ptsafety/chap53.htm (Şubat 2009).
- [3] THORESN, T., MAKELA, M., Professional Practice; Theory and Practice of Clinical Guidelines Implementation. DSI, Copenhagen Denmark. Cdc, National Vital Statistics Report, 1999; 48: 11.
- [4] NIEDERMAN, F., Data Warehousing at An Urban Hospital. Journal of Data Warehousing, 1997; 1: 15-27.
- [5] ÖZLÜ, T., BÜLBÜL, Y., “Niçin Göğüs Hastalıkları”, Karadeniz Teknik Üniversitesi Tıp Fakültesi Göğüs Hastalıkları Anabilim Dalı, http://vimed.s.ktu.edu.tr/tozlu/public_html/ontoloji.html (Mart 2009).
- [6] JANG, J.S.R., “ANFIS: Adaptive-Network Based Fuzzy Inference Systems”, IEEE Trans. on Systems, Man, and Cybernetics, 23 (03), 1993,s.665-685.
- [7] ÖZKAN, İ.A., SARITAŞ, İ., HERDEM, S., (2007) “Manyetik Filtreleme İşleminin ANFIS ile Modellenmesi”, 12. Elektrik, Elektronik, Bilgisayar, Biyomedikal Mühendisliği Ulusal Kongresi ve Fuarı, Eskişehir.
- [8] GOLDBERG, D.E., (1989) Genetic Algorithms in Search, Optimization and Machine Learning, Addison-Wesley, USA.
- [9] DE CASTRO, L. N. and TIMMIS, J., (2002) Artificial Immune Systems: A New Computational Intelligence Approach, Springer, 357p.
- [10] ASHIZAWA, K., ISHIDA, T., MACMAHON, H., VYBORNÝ, C.J., KATSURAGAWA, S., DOI, K., ROSSMAN, K. (2005) “Artificial neural networks in chest radiography: Application to the differential diagnosis of interstitial lung disease”, Academic Radiology, Volume 11, Issue 1, Pages 29-37.
- [11] COPPINI, G., MINIATI, M., PATERNI, M., MONTI, S., FERDEGHINI, E.M., (2007) “Computer-aided diagnosis of emphysema

in COPD patients: Neural-network-based analysis of lung shape in digital chest radiographs”, *Medical Engineering & Physics*, 29, 76–86.

- [12] PAUL, S., HECKERLING B.S., GERBER T.G., TAPE R.S., WIGTON, “Use of genetic algorithms for neural networks to predict community-acquired pneumonia”, *Artificial Intelligence in Medicine* 30 (2004), Pages 71–84.
- [13] EL-SOLH, A.A., HSIAO C-B., GOODNOUGH, S., SERGHANI, J., GRANT, B.J.B., (1999) “Predicting active pulmonary tuberculosis using an artificial neural network”, *Chest*, 116, 968-973.
- [14] SANTOS, A.M. ve PEREIRA, B.B., Seixas, J. M. de, “Neural Networks: An Application for Predicting Smear Negative Pulmonary Tuberculosis”, *Proceedings of the Statistics in the Health Sciences*, March, 2004.
- [15] HANİF, N.H.H.M., LAN, W.H., DAUB, H.B. ve AHMAD, J., (2009) *Classification of Control Measures for Asthma using Artificial Neural Networks*, A scientific and technical publishing company, ACTA pres, Malaysia.
- [16] ALIFERIS C.F., HARDIN D., MASSION P.P., (2002) *Machine learning models for lung cancer classification using array comparative genomic hybridization*. *Biomedical Informatics, Proc AMIA Symp. 2002:7-11*, Vanderbilt University, Nashville, TN, USA.
- [17] BIBI, H., NUTHAN, A., SHOSEYOV, D., SHALOM, M., PELED, R., KIVITY S. and NUTMAN, J. (2002), *Prediction of Emergency Department Visits for Respiratory Symptoms Using an Artificial Neural Network*. *Chest* 2002; 122; 1627-1632 DOI 10.1378/ chest 122.5.1627
- [18] http://www.luft-zum-leben.de/lzl/content/e9/e274/e1307/asthmabro_tuer.pdf (Şubat 2009)
- [19] World Health Organization: *Bronchial asthma*, (Mart 2009) www.who.int/mediacentre/factsheets/fs206/en/print.html
- [20] LAVOIE K.L., CARTIER, A., LABRECQUE, M. et al., *Are psychiatric disorders associated with worse asthma control and quality of life in asthma patients?* *Respir Med* 2005;99:1249-1257.
- [21] National Institutes of Health. *Global strategy for asthma management and prevention (GINA)*. NIH Publication No. 02-3659, 2002.
- [22] AYDINLI, F., “Solunum hastalıklarına karşı Türkiye gardını aldı”, *Actual Medicine*, s. 71, Haziran 2008.
- [23] *Astım (Bronşiyal Astım)*, (Haziran 2008) <http://www.saglik.im/astim-bronsiyal-astim/>

- [24] KOCABAŞ, A., KOAH: Epidemiyoloji ve Doğal Gelişim. In: Umut S, Erdinç E (eds). Kronik Obsrükatif Akciğer Hastalığı. Ankara. Toraks Derneği Yayınları; 2000:8-25.
- [25] BUSSET, A.S., Risk factors for COPD. Eur Respir Rev 1996; 6.253-8.
- [26] American Thoracic Society. Standards for the diagnosis and care of patients with chronic obstructive pulmonary disease. Am J Crit Care Med 1995; 152: 77-120.
- [27] MURRAY, C.J.L., LOPEZ, A.D., Alternative projections of mortality and disability by cause 1990-2020: Global burden of disease study. Lancet 1997; 359: 1498-504.
- [28] SAMURKAŞOĞLU, B., Epidemiyoloji ve risk faktörleri. In: Saryal S.B, Acıcan T (eds). Güncel Bilgiler Işığında KOAH. Bilimsel Tıp Yayınevi, Ankara, 2003: 9-19.
- [29] “Kronik Obstruktif Akciğer Hastalığı (KOAH): Belirtileri, tanısı ve tedavisi“ <http://www.bizimdoktor.com/KOAH> (Şubat 2009).
- [30] YILDIRIM, N., “Türk Toraks Derneği Okulu – KOAH”, İstanbul Üniversitesi Cerrahpaşa Tıp Fakültesi, Göğüs Hastalıkları EABD, İstanbul, 2007.
- [31] MACNEE, W., Chronic obstructive pulmonary disease. In: Oxford Textbook of Medicine (Ed's.) Warrell DA, Cox TM, Firth JD, Benz EJ. 4th edition. Oxford Pres, 2003.
- [32] Executive Summary: Global Strategy for the Diagnosis, Management, and Prevention of COPD, Haziran 2008.
<http://www.goldcopd.org/Guidelineitem.asp?l1=2&l2=1&intId=996>
- [33] REILLY, J.R., SILVERMAN, E.K., SHAPIRO, S.D., Chronic obstructive pulmonary disease. In: Harrison's Principles Of Internal Medicine. (Ed's) Kasper DL, Braunwald E, Fauci A, Hauser S, LongoD, Jameson JL. 16th Ed. McGraw-Hill Professional, 2005
- [34] RODARTE, J.R., Chronic bronchitis and emphysema. In: Cecil Textbook of Medicine. (Ed's) Goldman L, Bennett JC. 21st ed. W. B. Saunders Company, 2000. 394-402.
- [35] World Health Organization, <http://www.who.int/indoorair/en/> (Şubat 2009).
- [36] LYMAN HELLEWELL, S.C., FAIRMAN, P., Alpha1-antitrypsin deficiency (21 Eylül 2006).
<http://www.emedicine.com/med/TOPIC108.HTM>

- [37] RAM, F.S., RODRIGUEZ-ROISIN, R., GRANADOS-NAVARRETE, A., GARCIA-AYMERICH, J., BARNES, N.C., Antibiotics for exacerbations of chronic obstructive pulmonary disease. *Cochrane Database Syst Rev.* 2006 19;(2):CD004403
- [38] ROMIEU, I., TRENGA, C., Diet and obstructive lung diseases. *Epidemiol Rev.* 2001;23(2):268-87.
- [39] TORAKS Derneği KOAH Çalışma Grubu (Şubat 2009)
<http://www.toraks.org.tr/sub/rehkoah.php>
- [40] “TORAKS Derneği Eğitim Kitapları Serisi – Zatürree: Nedir? Nasıl Korunulur?” Sayı A4, Turgut Yayıncılık 2004.
- [41] ÖZKARA, Ş., “Türkiye’de Tüberkülozun Kontrolü İçin Başvuru Kitabı”, T.C. Sağlık Bakanlığı Verem Savaş Dairesi Başkanlığı, Ankara Nisan 2003.
- [42] KARLIKAYA, C., “Tüberküloz Ders Notları”, Trakya Üniversitesi Tıp Fakültesi Göğüs Hastalıkları ABD, 1998.
- [43] BEHR, M.A., WARREN, S.A., SALAMON, H., et al., Transmission of *Mycobacterium tuberculosis* from patients smear-negative for acid-fast bacilli. *Lancet* 1999; 353:444-449.
- [44] VALWAY, S.E., SANCHEZ, M.P.C., SHINNICK, T.F., et al., An outbreak of tuberculosis involving extensive transmission of a virulent strain of *M. tuberculosis*. *N Engl J Med* 1998; 338:633-639.
- [45] DUGUID, J., Expulsion of pathogenic organisms from the respiratory tract. *Br Med J* 1946; 1:245.
- [46] JINDANI, A., ABER, V.R., EDWARDS, E.A., MITCHISON, D.A., The early bactericidal activity of drugs in patients with pulmonary tuberculosis. *Am Rev Respir Dis* 1980; 121: 939-949.
- [47] LOUDON, R.G., ROMANS, W.E., Cough frequency and infectivity in patients with pulmonary tuberculosis. *Am Rev Respir Dis* 1969; 99:109-111.
- [48] SMALL, P.M., SHAFER, R.W., HOPEWELL, P.C., Exogenous reinfection with multidrug resistant *Mycobacterium tuberculosis* in patients with advanced HIV infection. *N Engl J Med* 1993; 328:1137-1144.
- [49] TEMPLETON, G.L., ILLING, L.A., YOUNG, L., et al., The risk of transmission of *Mycobacterium tuberculosis* at the bedside and during autopsy. *Ann Intern Med* 1995; 122:922-925.

- [50] HUTTON, M.D., STEAD, W.W., CAUTHEN, G.M., BLOCH, A.B., EWING, W.M., Nosocomial transmission of tuberculosis associated with a draining abscess. *J Infect Dis* 1990; 161:286-295.
- [51] Akciğer Kanseri (Ocak 2009), http://tr.wikipedia.org/wiki/Ana_Sayfa
- [52] LOEB, L.A., ERNSTER, V.L., WARNER, K.E., ABBOTTS, J., LASZIO, J., Smoking and lung cancer: An overview. *Cancer Research* 1984; 44: 5940-58.
- [53] Akciğer ve Plevra Maligniteleri Çalışma Grubu. Akciğer kanseri tanı ve tedavi rehberi. *Toraks Dergisi* 2006; 7 (Ek 2): 1-37.
- [54] ALBERG, A.J., SAMET, J.M., Epidemiology of lung cancer. *Chest* 2003; 123: 21s-49s.
- [55] BECKETT, W.S., Epidemiology and etiology of lung cancer. *Clin Chest Med.* 1993; 14: 1-16.
- [56] ALBERG, A.J., BROCK, M.V., SAMET, J.M., Epidemiology of lung cancer: looking to the future. *J Clin Oncol* 2005; 23: 3175-85.
- [57] YANG, C.Y., CHENG, M.F., CHIU, J.F., TSAI, S.S., Female lung cancer and petrochemical air pollution in Taiwan. *Arch Envir Health* 1999; 54: 180-5.
- [58] KREUZER, M., HEINRICH, J., KREIENBROCK, L., ROSARIO, A.S., GERKEN, M., WICHMANN, H.E., Risk factors for lung cancer among nonsmoking women. *Int J Cancer* 2002; 100: 706-13.
- [59] OSANN, K.E., Lung cancer in women: The importance of smoking, family history of cancer, and medical history of respiratory disease. *Cancer Res* 1991; 51: 4893-7.
- [60] BACH, P.B., NIEWOEHNER, D.E., BLACK, W.C., Screening for lung cancer. The guidelines. *Chest* 2003; 123: 83s-8s.
- [61] BECKLES, M.A., SPIRO, S.G., COLICE, G.L., RUDD, R.M., Initial evaluation of the patient with lung cancer. Symptoms, signs, laboratory tests, and paraneoplastic syndromes. *Chest* 2003; 123: 97s-104s.
- [62] COLLINS, G.L., HAINES, C., PERKEL, R., ENCK, R.E., Lung cancer: Diagnosis and management. *Am Fam Physician* 2007; 75: 56-63.
- [63] TURHAL, S., "Akciğer Kanseri Hakkında Bilmeniz Gerekenler", Marmara Üniversitesi Tıp Fakültesi (Şubat 2009) <http://www.serdarturhal.com.tr/Akciger%20Ca.pdf>, 2006.
- [64] ŞAHAN, S., "Yapay Bağışıklıkta Yeni Algoritmalar", Selçuk

- Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Konya, 2004.
- [65] ZEYLAN, T. “Genç Beyin”, s-9, Nisan 2002.
- [66] ADORF, H.M., “Connectionism and Neural Networks”, Knowledge Based System in Astronomy, pp. 215-216, Berlin, 1989.
- [67] KIRAN, Y.K. “Yapay Zeka Uygulamalı Askeri Proje Değerlendirme Sistem Tasarımı”, Yüksek Lisans Tezi, GYTE 2001.
- [68] KARLIK, B., Yapay Sinir Ağları. “Yüksek lisans ders notları”, 1995.
- [69] EFE, M.Ö., KAYNAK, O., “Yapay Sinir Ağları ve Uygulamaları”, Boğaziçi Üniversitesi Yayınları, 2000.
- [70] DOĞUÇ, U., “Esnek İmalat Sistemlerinde Makine Sayılarının ve Teslim Tarihinin Belirlenmesinde Yapay Sinir Ağlarının Kullanılması”, Sakarya Üniversitesi Fen Bilimleri Enstitüsü Doktora Tezi, EKİM 2001.
- [71] ÖZTEMEL, E., “Bilgisayarda öğrenme ve Yapay Sinir Ağları”, Otomasyon, s. 134-140, Mart 1996.
- [72] TÜRKOĞLU, İ. “Yapay Sinir Ağları ile Nesne Tanıma”, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 1996.
- [73] ERGEZER, H., DİKMEN, M. ve ÖZDEMİR, E., Yapay sinir ağları ve tanıma sistemleri. PIVOLKA, 2(6), 14-17, 2003.
- [74] AYDIN, A.E, “Yapay Sinir Ağları ve İğdaş’ ta Günlük Yük Tahmininde Kullanılması”, Sakarya Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, Haziran 1997.
- [75] MICHALISKI, R.S., “Understanding the nature of learning”, Machine Learning, vol.1(1986), 20-29.
- [76] ÖZTEMEL, E., “Integrating Expert Systems and NNs for Intelligent On-Line Statistical Process Control”, University of Wales, PhD. Thesis, School of Electrical-Electronic and System Engineering, Cardiff, December, pp. 14, 1992.
- [77] GÜNTÜRKÜN, R., “İleri Beslemeli ve Elman Geri Beslemeli Yapay Sinir Ağı Kullanarak Harmonik Kompanzasyon ”, Sakarya Üniversitesi Fen Bilimleri Enstitüsü Doktora Tezi, 2003.
- [78] ÖZTEMEL, E., Yapay Sinir Ağları, Papatya Yayıncılık, 2003.
- [79] SAĞIROĞLU, Ş., BEŞDOK, E., ERLER, M., Mühendislikte Yapay Zeka Uygulamaları-I, Ufuk Kitap Kırtasiye-Yayıncılık Tic. Ltd., 2003.

- [80] ŞEN, Z., Yapay Sinir Ağları İlkeleri, Su Vakfı Yayınları, 2004.
- [81] AVCI, M., YILDIRIM, T., Classification of Escherichia Coli Bacteria by Artificial Neural Networks, IEEE International Symposium on Intelligent Systems Vol III, Sf. 16-20, Varna, Bulgaristan, 2002.
- [82] DE CASTRO, L.N. ve VON ZUBEN, F.J., 2000, The Clonal Selection Algorithm with Engineering Applications, GECCO 2000, Las Vegas, Nevada, USA.
- [83] DE CASTRO, L.N. ve VON ZUBEN F.J., 2002, Learning and optimization Using the Clonal Selection Principle, In the Special Issue on Artificial Immune Systems of the Journal IEEE Transactions on Evolutionary Computation, June 6(3).
- [84] FARMER, J.D., KAUFFMAN, S. A., PACKARD, N. H, PERELSON, A. H., 1987, Adaptive Dynamic Networks as Models for the Immune System and Autocatalytic Sets, Ann. Of the N. Y. Acad. Of Sci., 504, pp. 118-131.
- [85] TIMMIS, J., NEAL, M., HUNT, J., 2000, An Artificial Immune System for Data Analysis, Biosystems, 55, pp. 143-150.
- [86] DE CASTRO, L.N., VON ZUBEN, F.J., 2000, An Evolutionary Immune Network for Data Clustering, Proc of the IEEE Brazilian Symposium on Artificial Neural Networks, pp. 84-89.
- [87] ENDLER, D., Intrusion detection applying machine learning to solaris audit data, 1998 Annual Computer Security Applications Conference (ACSAC'98), 268-269,1998.
- [88] FORREST, S., PERELSON, A., ALLEN,L., Self-Nonself Discrimination in a Computer, Proceedings of the IEEE Symposium on Research in Security and Privacy: 202-212, 1994.
- [89] FOREST, S., ve HOFMEYR, S.A., John Holland's Invisible Hand: An Artificial Immune System, presented at the FESTSCHIRIFT, 1999.
- [90] HOFMEYR, S.A., FORREST, S., Immunity by Design: An Artificial Immune System, Proceedings of the Genetic and Evolutionary Computation Conference, San Francisco, CA, 1289-1296, 1999.
- [91] SOMAYAJI, A., HOFMEYR, S.A., FORREST, S., Principles of a Computer Immune System" Proceedings of the New Security Paradigms Workshop, 75-81, 1997.
- [92] DE CASTRO, L.N., VON ZUBEN, F.J., The Clonal Selection Algorithm with Engineering Applications, GECCO 2000, Las Vegas, Nevada, USA, July 8 ,2000.

- [93] COSTA, A.M., VARGAS, P.A., VON ZUBEN, F.J. ve FRANCA, P.M., Makespan Minimization On Paralel Processors: An Immune-Based Approach, In the proceedings of the special sessions on artificial immune systems in the 2002 Congress on Evolutionary Computation, 2002 IEEE World Congress on Computational Intelligence, Honolulu, Hawaii ,2002.
- [94] JENSEN, M., HANSEN, T., Robust solutions to job shop problems”, http://wwwiuf.unifr.ch/~wangl/immune_reference.html, Ekim 2007.
- [95] HART, E., ROSS, P., NELSON, J., Producing Robust Schedules via an Artificial Immune System, ICEC, 464- 469 ,1998.
- [96] MORI, K., TSUKIYAMA, M., FUKUDA, T., Artificial Immunity Based Management System for a Semiconductor Production Line, In IEEE International Conference on Systems, Man, and Cybernetics, 1: 852-856 1997.
- [97] DASGUPTA, D., FORREST, S., Artificial Immune systems in Industrial Applications, In the proceedings of the Second International Conference on Intelligent Processing and Manufacturing of materials (IPMM), Honolulu, July 10-15 1999.
- [98] LEE, D., JUN, H., SIM, B., Artificial Immune System for Realization of Cooperative Strategies and Group Behaviour in collective Autonomous mobile Robots, Proceedings of 4th Int. Symp. On Artificial Life and Robotics:232-235 ,1999.
- [99] DASGUPTA, D., FORREST, S. Novelty Detection in Time Series Data Using Ideas From Immunology, Proceedings of the ISCA’96,1996.
- [100] ALATAS, B.,”Yapay Bağışıklık Sistemi”, Fırat Üniversitesi FBE, Doktora Semineri 2004.
- [101] ÖZÇALIK, H.R., UYGUR, A.F., “Dinamik Sistemlerin Uyumlu Sinirsel-Bulanık Ağ Yapısına Dayalı Etkin Modellenmesi”, KSÜ Fen ve Mühendislik Dergisi, 6(1), Sayfa :36-46, 2003.
- [102] NARENDRA, K. ve PARTHASARATHY, K., “Identification and Control of Dynamical Systems Using Neural Networks”, IEEE Trans. on Neural Networks, vol.1, 1990, s.4-27.
- [103] GÜLBAĞ, A., “Yapay sinir ağı ve bulanık mantık tabanlı algoritmalar ile uçucu organik bileşiklerin miktarsal tayini” Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, 2006.
- [104] YENİAY, Ö. (2001), “An Overview of Genetic Algorithms”, Anadolu Üniversitesi Bilim ve Teknoloji Dergisi, Cilt: 2, Sayı: 1, s. 37-49.

- [105] İŞLİER, A.A. (2001), “Üretim Hücrelerinin Bir Genetik Algoritma Kullanılarak Oluşturulması”, Anadolu Üniversitesi Bilim ve Teknoloji Dergisi, Cilt: 2, Sayı: 1, s. 137-157.
- [106] ENGİN, O. (2001), Akış Tipi Çizelgeleme Problemlerinin Genetik Algoritma ile Çözüm Performansının Arttırılmasında Parametre Optimizasyonu, İTÜ, Fen Bilimleri Enstitüsü, Yayınlanmamış Doktora Tezi.
- [107] JANG, J.S.R. (1997), Neuro-Fuzzy and Soft Computing: A Computational Approach To Learning and Machine Intelligence, Chapter 7: Derivative-Free Optimization, Prentice-Hall, USA, s. 173-196.
- [108] YEO M.F. ve AGYEL, E.O. (1996), “Optimizing Engineering Problems Using Genetic Algorithms”, Engineering Computations, Volume: 15, Number: 2, s. 268-280.
- [109] FİĞLALI, A. ve ENGİN, O. (2002), “Genetik Algoritmalarla Akış Tipi Çizelgelemede Üreme Yöntemi Optimizasyonu”, İTÜ Dergisi, s. 1-6.
- [110] BRAYSY, O. (2001), Local Search and Variable Neighborhood Search Algorithms for The Vehicle Routing Problem With Time Windows, PH D Thesis.
- [111] FUNG, R.Y.K., TANG, J. ve WANG D. (2001), “Extension Of A Hybrid Genetic Algorithm For Nonlinear Programming Problems With Equality And Inequality Constraints”, Computers & Operations Research, Volume: 29, Issue: 3, s. 261-274.
- [112] ALTIPARMAK, F., DENGİZ, B. ve SMITH, A.E. (2000), “An Evolutionary Approach For Reliability Optimization in Fixed Topology Computer Networks”, Transactions On Operational Research, Volume: 12, Number: 1-2, s. 57-75.
- [113] SINRIECH, D. ve SAMAKH, E. (1999), “A Genetic Approach to the Pickup/Delivery Station Location Problem in Segmented Flow Based Material Handling Systems”, Journal of Manufacturing Systems, Volume: 18, Number: 2, s. 81-99.
- [114] DEB K., “Genetic Algorithm in Search and Optimization: The Technique and Applications”, s. 1-29.
- [115] GONZALES, E.L. ve FERNANDEZ M.A.R. (2000), “Genetic Optimization of A Fuzzy Distribution Model”, International Journal of Physical Distribution & Logistics Management, Volume 30, Number 7/8, s. 681-696.
- [116] BEASLEY, D., BULL, D.R. ve MARTIN, R.R. (1993), “A Sequential Niche Technique For Multimodal Function Optimization.”

www.citeseer.nj.nec.com/beasley93sequential.html, (06/05/2002).

- [117] KARR, C.L. ve FREEMAN, M.L. (1999), *Industrial Applications of Genetic Algorithms*, CRC Press, USA.
- [118] HOFFMAN, K. ve PADBERG, M., “Combinatorial and Integer Optimization.” www.iris.gmu.edu/~khoffma/papers/newcomb1.html (07/05/2002), s.1-10.
- [119] DAVIS, L. ve COOMBS, S. (1987), “Genetic Algorithms And Communication Link Speed Design: Theoretical Considerations”, *Grefenstette*, s. 252-256.
- [120] WEHENKEL, L., “Machine Learning & Data mining.” (Mayıs 2002). <http://www.montefiore.ulg.ac.be/~lwh/>
- [121] KOZA, J. R. (1992), “A Genetic Approach to Econometric Modelling”, in Bourguine, P. and B. Walliser (eds.), *Economics and Cognitive Science*, Pergamon Press, s. 57-75.
- [122] TEMURTAS, F., (2007) “A comparative study on thyroid disease diagnosis using neural networks”, *Expert Systems With Applications*, in Press - DOI: 10.1016/j.eswa.2007.10.010.
- [123] WATKINS, A. (2001) “AIRS: A resource limited artificial immune classifier” Master Thesis, Mississippi State University.
- [124] DIRICAN, A., “Tanı Testi Performanslarının Değerlendirilmesi ve Kıyaslanması”, İÜ Cerrahpaşa Tıp Fakültesi, Biyoistatistik Bilim Dalı, Cerrahpaşa, İstanbul, 2000.
- [125] ER, O., TEMURTAS, F., (2008) “A Study on Chronic Obstructive Pulmonary Disease Diagnosis Using Multilayer Neural Networks”, *Journal of Medical Systems*, 32(5), 429-432.
- [126] ER, O., SERTKAYA C., TEMURTAS, F., TANRIKULU A.C., (2008) “A Comparative Study on Chronic Obstructive Pulmonary and Pneumonia Diseases Diagnosis using Neural Networks and Artificial Immune System”, *Journal of Medical Systems*, Published Online : 25.08.2008.
- [127] ER, O., TEMURTAS, F., TANRIKULU A.C., (2008) “Tuberculosis disease diagnosis using artificial neural networks”, *Journal of Medical Systems*, Published Online : 23.12.2008.

ÖZGEÇMİŞ

1978 Kebabçı/MARDİN doğumlu olan Orhan ER, ilk, orta ve lise eğitimini Diyarbakır'da tamamlamıştır. 1996 yılında Sakarya Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümünü kazanarak üniversite eğitimine başlamış ve bu bölümden 2001 yılında mezun olarak mühendis ünvanı almıştır. 2001 yılında Sakarya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar ve Bilişim Mühendisliği Anabilim dalında başladığı yüksek lisans eğitimini 2004 yılında tamamlamış ve aynı yıl doktora eğitimine başlamıştır. 2002 tarihinde Sakarya Üniversitesi Bilgi İşlem Dairesi Başkanlığı Yazılım Teknolojileri Şube Müdürlüğü'nde uzman olarak göreve başlamış olup son olarak çalışma hayatına aynı üniversitenin Bilgisayar Araştırma ve Uygulama Merkezinde devam etmektedir.