

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**GENETİK ALGORİTMALI YAPAY SİNİR AĞLARI
KULLANILARAK TÜBERKÜLOZ HASTALIĞININ
TEŞHİSİ**

YÜKSEK LİSANS TEZİ

Bilgisayar Müh. Erhan ELVEREN

Enstitü Anabilim Dalı : BİLGİSAYAR VE BİLİŞİM MÜHENDİSLİĞİ

Tez Danışmanı : Doç. Dr. Nejat YUMUŞAK

Haziran 2009

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

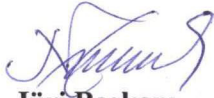
GENETİK ALGORİTMALI YAPAY SİNİR AĞLARI
KULLANILARAK TÜBERKÜLOZ HASTALIĞININ
TEŞHİSİ

YÜKSEK LİSANS TEZİ

Bilgisayar Müh. Erhan ELVEREN

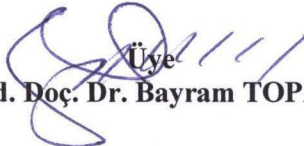
Enstitü Anabilim Dalı : BİLGİSAYAR VE BİLİŞİM MÜHENDİSLİĞİ

Bu tez 10 / 06 / 2009 tarihinde aşağıdaki jüri tarafından Oybirliği ile kabul edilmiştir.



Jüri Başkanı

Doç. Dr. Nejat YUMUŞAK



Üye

Yrd. Doç. Dr. Bayram TOPAL



Üye

Yrd. Doç. Dr. Ali BÜLBAĞ

ÖNSÖZ

Çalışmalarında desteğini hiçbir zaman esirgemeyen, bu tezin oluşmasında değerli bilgilerini sunduğu için değerli hocam Doç. Dr. Nejat YUMUŞAK'a teşekkürlerimi bir borç bilirim.

Ayrıca bu günlere gelmemde yıllarımı, sevgilerini benimle paylaşan, bana daima güvenen sevgili aileme de sonsuz teşekkür ederim.

ERHAN ELVEREN

İÇİNDEKİLER

ÖNSÖZ	ii
İÇİNDEKİLER	iii
SİMGELER VE KISALTMALAR	v
ŞEKİLLER LİSTESİ	vi
TABLolar LİSTESİ	vii
ÖZET	viii
SUMMARY	ix

BÖLÜM 1.

GİRİŞ	1
-------------	---

BÖLÜM 2.

TÜBERKÜLOZ HASTALIĞI	6
2.1. Giriş	6
2.2. Tüberküloz'un Tanımı	7
2.3. Tüberkülozun Özellikleri	8
2.4. Tüberkülozda Tanı	9
2.5. Tüberkülozda Bulaşma	10
2.6. Tüberkülozda Tedavi	11
2.7. Dünya'da Tüberküloz	12
2.8. Türkiye'de Tüberküloz	13

BÖLÜM 3

HESAPLAMA YÖNTEMLERİ	15
3.1. Giriş	15
3.2. Yapay Sinir Ağları (YSA)	16

3.2.1. Yapay sinir ađı modelleri	18
3.2.1.1. İleri beslemeli yapay sinir ađları	19
3.2.1.2. Geri yayılmalı (backpropagation) YSA modeli	20
3.2.2. Yapay sinir ađlarında öğrenme	20
3.2.2.1. Yapay sinir ađlarında öğrenme algoritmaları.....	21
3.2.3. Çok Katmanlı Ađlar.....	25
3.2.3.1. Çok katmanlı ađın eğitilmesi	27
3.2.3.2. Çok katmanlı ađın çalışma prosedürü	28
3.3 Genetik Algoritmalar	28
3.3.1 Genetik algoritmaların temel teoremi.....	29
3.3.2 Basit genetik algoritma	30
3.3.3 Genetik algoritmaların uygulama alanları	34

BÖLÜM 4

TÜBERKÜLOZ HASTALIĞININ TEŞHİSİ İÇİN GELİŞTİRİLEN ÖRNEK

UYGULAMA	35
4.1. Giriş.....	35
4.2. Uygulamada Kullanılan Veri Seti	35
4.3. THT’de Kullanılan Yapay Sinir Ađı.....	36
4.3.1. Ađın performans deđerini ölçmede doğruluk oranı kullanımı	37
4.4. THT’de Kullanılan Genetik Algoritma Modeli	38
4.5. THT Uygulama Programı	40
4.5.1. Uygulamanın kullanımı	40

BÖLÜM 5

SONUÇ VE ÖNERİLER	44
5.1. Sonuçlar.....	44
5.2. Öneriler	46

KAYNAKLAR	48
-----------------	----

ÖZGEÇMİŞ	54
----------------	----

SİMGELER VE KISALTMALAR LİSTESİ

ÇKA	: Çok Katmanlı Ağ
GA	: Genetik Algoritma
KKDS	: Klinik karar destek sistemleri
THT	: Tüberküloz hastalığının teşhisi için geliştirilmiş örnek uygulama
YSA	: Yapay sinir ağları

ŞEKİLLER LİSTESİ

Şekil 3.1	Örnek biyolojik sinir	17
Şekil 3.2	Örnek çok katmanlı yapay sinir ağı mimarisi	19
Şekil 3.3.	Perceptron örneği	22
Şekil 3.4	Ara katmansız bir yapay sinir ağı modeli	23
Şekil 3.5	İki gizli katmana sahip bir Çok Katmanlı Ağ şeması	26
Şekil 3.6	Genetik Algoritma Akış Diyagramı	31
Şekil 4.1	THT'de kullanılan YSA'nın yapısı	37
Şekil 4.2	Genetik algoritma akış şeması	38
Şekil 4.3	THT uygulaması ana formu	40
Şekil 4.4	Rapor ekranı	42
Şekil 4.5	Test formu	43
Şekil 4.6	Doğruluk testi sonucu	43
Şekil 5.1	Başarı oranı karşılaştırması	46

TABLULAR LİSTESİ

Tablo 1.1	Literatüre geçmiş çalışmalar ve doğruluk oranları.	4
Tablo 2.1	PPD testi sonuçlarının yorumlanması.....	10
Tablo 4.1	Hasta veri sınıfları.....	35
Tablo 5.1	Eğitimde kullanılan Genetik Algoritma parametreleri	45
Tablo 5.2	Ağın çeşitli zamanlarda sıfırdan tekrar eğitilme sonuçları	45

ÖZET

Anahtar Kelimeler: Yapay Sinir Ağları, Genetik Algoritmalar, Hastalık Teşhisi, Tüberküloz, Karar Destek Sistemi

Dünyada her yıl milyonlarca insan tüberküloz mikrobuyla tanışmakta ve hastalanmakta. İnsanlığı yüzyıllarca kırmış, zamanla efsanelerin doğmasına neden olmuş bu hastalık günümüzde özellikle düşük gelirli ülkelerde, tanı ve tedavi imkânlarının çok kısıtlı olması nedeniyle çok sayıda ölüme sebep olmaktadır. Tüberküloz, tamamen tedavi edilebilir hatta önlenabilir bir hastalık olmasına rağmen tek tip mikrobun neden olduğu en çok ölüm oranına sahiptir. Ülkemizde ince hastalık olarak da bilinen bu hastalık, zamanında çok ölümlere neden olmuştur fakat geçtiğimiz yüzyılın ortalarında gerçekleştirilen büyük atılımlar sayesinde hastalığın kontrolü sağlanabilmiştir. Bu amaçla veremle savaş dispanserleri kurulmuş, hastalığın önlenmesi için aşı yöntemi kullanılmış, hastalar bu dispanserler vasıtasıyla gözetlenmeye ve ücretsiz tedavi edilmeye başlanmıştır. Günümüzde geliştirilen tekniklerin tıpta kullanım alanı bulmasıyla hastalık teşhisleri daha isabetli yapılabilir hale gelmiştir. Bu çalışmada yerel bir hastaneden kullanılmak üzere hasta verileri alınmıştır. Bu veriler oluşturulan yapay sinir ağının eğitimi için kullanılmıştır. Bu ağın eğitiminde genetik algoritma seçilmiş ve tüberküloz hastalığının teşhisinde ortalama %94,88 başarı elde edilmiştir.

TUBERCULOSIS DISEASE DIAGNOSIS USING ARTIFICIAL NEURAL NETWORKS WITH GENETIC ALGORITHM

SUMMARY

Key Words: Artificial Neural Network, Genetic Algorithm, Disease Diagnosis, Tuberculosis, Decision Support System

Every year millions of people meets the tuberculosis microbe and gets the infection. That disease, which killed humanity for centuries and caused to born some myths in time, causes so many deaths in low-income countries because of low diagnosis and treatment opportunities. Despite tuberculosis is a remediable and also avoidable disease, has the most mortality ratio that is caused by single kind of mycobacterium. In our country, a special name has been given to it, caused so many deaths in time but in the middle of last century, it has been controlled through the big steps done. In that matter, tuberculosis dispensaries has been built, vaccines used to prevent the disease and in these dispensaries, free treatment opportunities provided for infected people. With the usage of newly developed techniques in medicine, disease diagnosis can be acquired more accurately. In this project, some patient's data is gathered from a local hospital to be used in training of the Multi Layer Neural Network. Genetic Algorithm is used as the training algorithm of the Neural Network. For the Tuberculosis disease diagnosis, approximately 94.88% of success is achieved by that structure.

BÖLÜM 1. GİRİŞ

Sağlık hizmetleri sektöründe bilgisayar sistemlerinin kullanımı son 30 yılda artan bir hızla 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 hastalığı tanımlama ve tedavisine 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 arasında 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 [2]. 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 [3], hastalara ait özel bilgileri uzman bilgi tabanı ile mukayese ederek hasta yönetimi ve konsültasyon (bilgi paylaşımı) işlevini gerçekleştirmek [4], klinik ve finansal bilgi depolarını bir araya getirerek, hizmet kullanımının, maliyet bileşenlerinin ve klinik performansın değerlendirilmesi işlevini yerine getirmektedir [5].

Solunum sistemi hastalıkları ölüm riski çok ve teşhisi zor olması nedeniyle oldukça önemlidir. Yanlış ve ya geç yapılacak teşhislerin ölümcül sonuçları olabilmesi nedeniyle böyle bir hastalığın teşhisinde hızlı ve uygun yöntemler kullanılması çok önemlidir. Hastaya basit klinik testler uygulayarak hastalığın erken evrelerinde teşhisin konulabilmesi hastalığın durdurulması ve tedavi edilebilmesi açısından büyük önem taşımaktadır

Solunum tüm canlılar için hayati öneme sahip bir fonksiyondur. Dünyada en sık rastlanan, en ölümcül olan ve en fazla iş gücü kayıplarına yol açan enfeksiyonlar solunum yolu enfeksiyonlarıdır [2]. Tüberküloz, halen en öldürücü ve en yaygın enfeksiyon hastalığı olup, dünya üzerinde her yıl 1,7 milyon kişinin ölümüne neden olmaktadır. Tüberküloz hava yoluyla bulaşabilme özelliğinden ve tanısı uzun süren testler sonucunda konulabilmesinden dolayı kolaylıkla göz ardı edilip hasta üzerinde geri dönülemez hasarlara hatta ölüme yol açabilmektedir. Günümüzde hâlâ tek mikrobun yaptığı en çok öldüren bulaşıcı hastalıktır. Dünyadaki bütün hastalıkların yüzde 2,5'ini ve önlenebilir ölümlerin yüzde 26'sını oluşturmaktadır. Dünya Sağlık Örgütü, verem hastalığı için "Acil Durum" ilan etmiştir [6].

Küresel boyutta vurgulanan öncelikler, ülkemiz için de aynen geçerlidir. Ayrıca ülkemiz, tüberkülozun en sık görüldüğü coğrafyada yer almaktadır ve 70'li yıllarda bir salgın olarak ülkemizde çok sayıda ölüme neden olmuştur.

Karmaşık ve çözümü zor mühendislik problemlerinin çözümlenmesi amacıyla biyolojik olguları bilgisayar dünyasına uygulayabilecek algoritmalar geliştirmeye başlanmıştır. Yapay sinir ağları kullanılan sistemlerin yanında genetik algoritmaların kullanıldığı sistemler de yaygınlaşmaya başlamıştır.

Yapay sinir ağları (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 [2].

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 [7]. Diğer bir önemli üstünlükleri ise çözümlerden oluşan popülasyonu eş zamanlı incelemeleri ve böylelikle yerel en iyi çözümlere takılmamalarıdır [2].

Tüberküloz hastalığının teşhisinde yapay sinir ağları kullanılması ile geliştirilen çok az çalışma bulunmaktadır [8, 2].

Birinci çalışmada [8] yazarlar, bir gizli katmana sahip bir Genel Gerilemeli Sinir Ağı (General Regression Neural Network – GRNN) kullanmışlardır. Demografik değişkenler (yaş, cinsiyet, evlilik durumu, eğitim v.s.), sıhhi semptomlar (göğüs ağrısı, kilo kaybı, öksürük v.s.) ve radyolojik bulgular şeklinde gruplanmış toplam 21 adet parametre yapay sinir ağının girişi olarak vermişlerdir. Sinir ağının çıkışlarını doğrulamak için 10 kat çapraz doğrulama yöntemi (10-fold cross-verification) kullanmışlardır. Bu yöntemde hastaların verileri rastgele şekilde 10 gruba ayrılır, bunlardan bir tanesi doğrulama için ayrılır ve geri kalanlar eğitim işlemlerinde kullanılır. Bu işlem her bir grup doğrulamada kullanılana kadar toplam 10 defa yapılır. Bu çalışmanın sonucunda yazarlar yaklaşık olarak ortalama %92,3'lük bir doğruluk oranına ulaşmışlardır.

İkinci çalışmada [2] yazarlar iki adet gizli katmana sahip bir çok katmanlı yapay sinir ağı kullanmışlardır. Her gizli katmanda 50 adet sinir ve eğitim için momentumlu geri yayılım ve Levenberg-Marquardt algoritmaları kullanılmıştır. Hasta kayıt örneklerinin her biri 38 adet muayene (öksürük şikâyeti, vücut ısısı, güçsüzlük v.s.) ve laboratuvar test sonucu (trombosit, hemoglobin, albümin v.s.) içeriyor ve bu örnekler yapay sinir ağına giriş verileri olarak verilmiştir. Yapay sinir ağının çıkışlarını doğrulamak için 3 kat çapraz doğrulama yöntemi kullanmışlardır. Bu çalışmanın sonunda yazarlar iki gizli katmana sahip, momentumlu geri yayılım

algoritmasıyla eğitilmiş bir çok katmanlı yapay sinir ağı kullanarak %93,93 başarı elde etmişlerdir

Tüberküloz hastalığı teşhisindeki çalışmalar çok sınırlı sayıda olup özellikle tek tip solunum hastalığı teşhis etmek için kullanılan yöntemlerde genellikle geri yayılım algoritması kullanarak eğitilmiş yapay sinir ağları kullanılmıştır. Bu çalışmalar [2, 13] içinde en iyi performansa sahip olan %92,30'luk başarı oranı ile tüberküloz hastalığını teşhis etmek için kullanılmış GRNN algoritması ile elde edilmiştir [8]. Bu çalışmalar içinde de en kötü performans ise %77'lik başarı oranı ile yine tüberküloz hastalığını teşhis etmek için kullanılmış bir MLNN ile elde edilmiştir [9]. Literatüre geçmiş çalışmalar ve doğruluk oranları tablo 1.1'de görülmektedir.

Tablo 1.1. Literatüre geçmiş çalışmalar ve doğruluk oranları.

Çalışma	Metot	Eğitim Algoritması	Sınıflandırma Doğruluk Oranı (%)
Referans [8]	GRNN (bir gizli katman)		92.30 %
Referans [9]	MLNN (bir gizli katman)	BP	77.00 %
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]	NN - Radial Basis Function	BP	90,00 %
Referans [14]	NN (ileri beslemeli)	FF	89,20 %
Referans [15]	MLNN (bir gizli katman)	BP	88,00 %

Bu çalışmanın amacı dünya üzerinde milyonlarca insanı tehdit eden, zamanında teşhis ve doğru tedavilerle tamamen iyileştirilebilen ve önlenabilir ölümlerin büyük bir kısmını oluşturan tüberküloz hastalığının teşhisi sürecinde öncü bir karar destek sistemi oluşturmaktır. Günümüzde tüberküloz hastalığının teşhisi radyoloji, laboratuvar kültür testleri ve muayene gibi toplamda tam tanı süresi oldukça uzundur ve şahıs belli şikâyetlerle geldiğinde bu kişiler için varsa tüberküloz şüphesinin kısa sürede oluşması ve bu yönde tetkiklerin yapılması çok önemlidir [6]. Bu nedenle bu çalışmada hasta verileri kullanılarak hasta için varsa tüberküloz şüphesini belirtmek

üzere bir karar destek sistemi yapılması amaçlanmıştır. Uygulama için yerel bir göğüs hastalıkları polikliniğinde yatan hasta epikrizlerine yansıyan parametrelerden elde edilen veri kümeleri ile çalışılmıştır. Yapılan uygulama sonuçlarına göre genetik algoritma ile eğitilmiş olan YSA, ortalama %94,88 başarı ile literatürdeki benzer çalışmalardan daha iyi sonuç vermiştir.

Bu çalışmanın ikinci bölümünde dünyada sık rastlanan tüberküloz hastalığı hakkında detaylı bilgi verilecektir. Üçüncü bölümde ise tasarlanmak istenen karar destek sisteminin altyapısında kullanılacak teknikler açıklanacaktır. Dördüncü bölümde de tüberküloz hastalığı verisi üzerinde hesaplama yöntemleri kullanılarak geliştirilmiş örnek bir uygulama anlatılacaktır. Sonuç olarak uygulamanın detaylarını ve sonuçlarını içeren son bölümde ise varılan nokta üzerinde yapılacak öneriler ve tartışmalara yer verilecektir.

BÖLÜM 2. TÜBERKÜLOZ HASTALIĞI

2.1. Giriş

Tüberküloz (verem), *Mycobacterium tuberculosis* bakterilerinin (mikrobunun) bulaşmasıyla ortaya çıkan bulaşıcı bir hastalıktır. Verem binlerce yıldır varlığı bilinen (eski Mısır mumyalarında hastalığa ait izler saptanmıştır) ve dünya nüfusunun büyük kısmını tehdit eden bir hastalıktır. Tüberküloz mikrobunu vücuda girdikten sonra aylarca-yıllarca hastalık yapmadan kalabilir. Bu süre içinde vücut savunması tarafından baskı altında kalır ve etkin değildir. Verem mikropları, etkin değilken herhangi bir hasarda bulunamaz veya başkalarına geçirilemezler. Kişi enfeksiyonlu olabilir ama hasta değildir. Çoğu kişide (insanların yüzde 90'ı) mikroplar hiçbir zaman etkin değildir [16]. Ancak vücut direnci zayıfladığında (sağlıksız beslenme, aşırı sigara-alkol tüketimi, HIV gibi bağışıklık sistemini çökerten hastalıklar v.s. gibi durumlarda bağışıklık sisteminin zayıflaması durumunda) mikrop etkin hale gelir ve kişide hastalık yapar.

Tüberküloz, en çok akciğerde olmak üzere her organda hastalık yapabilir ve bu organlara zarar verir [6]. Hastalık yaptığı organlarda ağır iltihap olur, erimeler görülebilir [2]. Tedavisi bırakılırsa ya da kötü tedavi edilirse hastalık kullanılan ilaçlara karşı direnç kazanabilir ve bu tedavi sürecini kötü etkiler ve de bu durumun öldürücü sonuçları olabilir.

Mikropların vücuda girdikten sonra hastalık yapma süresi değişkendir. Zayıf vücut direnci olanlarda hastalık hızla gelişebilir ya da yıllarca hiç etkin olmayabilir. Mikrobu alıp enfekte olanların yüzde 10'u hayatının herhangi bir döneminde bu mikrop nedeniyle hastalanır [2].

Tedavi tamamıyla iyileştiricidir. Erken ve uygun tedavi başlanır, yeterli süre tedavi edilirse hastalar yüzde yüz iyileştirilir ve bu iyileşme kalıcıdır [6].

Dünya üzerinde her ulusta zengin-fakir, genç-yaşlı fark etmeden hastalık yapabilir. Dünya Sağlık Örgünü (DSÖ) bu hastalığın ciddiyetini görmüş ve 1993 yılında ilk defa bir hastalık için “Acil Durum” ilan etmiştir [6].

DSÖ'nün tahminlerine göre her yıl 8,5 milyon kişi tüberküloz hastalığına yakalanmakta ve 3 milyon insan ölmektedir. Dünya nüfusunun yaklaşık 3'te 1'inin, yani 1,7 milyar kişinin *Mycobacterium tuberculosis* ile enfekte olduğu düşünülmektedir.

Ülkemizde tüberküloz hastalığı, 20. yüzyılın ilk yarısında büyük bir salgın yapmıştır. Tüberküloz nedeniyle olan ölümler, bütün ölüm nedenleri içinde birinci sırada yer alıyordu. Bu durum 1950'li yıllara kadar devam etti [17]. Özellikle 20. yüzyılın ikinci yarısında yürütülen yoğun verem savaşı çalışmaları sonucunda artık tüberküloz önemli bir ölüm nedeni değildir [2].

2.2. Tüberküloz'un Tanımı

TÜBERKÜLOZ (VEREM): Tüberküloz, '*Mycobacterium tuberculosis*' adlı mikrobun neden olduğu bir enfeksiyon hastalığıdır. Tüberkülozun etkeni ilk kez 1882 yılında Robert Koch tarafından ortaya çıkarılmıştır. Bu nedenle Tüberküloz mikrobuna 'Koch basili' de denilmektedir. *Mycobacterium tuberculosis* tipi pratikte solunum yoluyla insanlara ulaşır.

Tüberkülozlu insanların balgamlarında, öksürürken ya da konuşurken havaya saçtıkları solunum yolları salgılarında tüberküloz mikrobi bulunur. Havaya saçılan bu salgılar, havada küçük damlacıklar şeklinde uçuşurlar. Sağlıklı bir insan bu havayı soluduğunda, tüberküloz mikrobunu taşıyan damlacıkları akciğerlerine çeker. Böylece sağlıklı insan tüberküloz mikrobunu almış olur. Mikrobun bu şekilde bulaşmasına 'Damlacık enfeksiyonu ile bulaşma' denir. Solunum yoluyla alınan

Mycobacterium tuberculosis ilk oturdukları yer akciğerlerdir ve hastalığı etkinleşmesi durumunda kan ve lenf kanalları vasıtasıyla başka organlara doğru yayılırlar [18].

Tüberküloz bulaştığı kişilerin hepsinde hastalık yapmaz. Bir kişi bu mikrobu aldıysa bu kişiye “enfekte”, eğer mikrop etkin ve hastalık yapar hale geldiyse bu kişiye de “hastalıklı” kişi denir. Enfekte olmuş insanlarda mikrop bağışıklık sisteminin baskısı altında etkin olmayan bir durumdadır. Bu dönemde mikroplar bir anlamda hapsedilmişlerdir. Bir *Mycobacterium tuberculosis* mikrobu çoğalmadan baskı altında aylarca, hatta yıllarca yaşayabilir. Enfekte olmuş kişilerin bu mikrobu aldığını cilt testi ile öğrenmeleri mümkündür.

Enfekte olmuş bir kişinin çeşitli nedenlerle (HIV enfeksiyonu, ağır sigara içiciliği, kronik alkolizm, kronik böbrek yetmezliği, ideal kilonun altında olmak v.s.) bağışıklık sisteminin zayıflaması nedeniyle vücutta baskı altında tutulan mikrop aktif hale geçer hastalık yapmaya başlar. Hastalık çoğunlukla (%80-%90) akciğerlerde görülür. Diğer organ tüberkülozlarının birçoğu da akciğerdeki tüberküloz enfeksiyonunu takiben ikincil olarak meydana gelir [19].

2.3. Tüberkülozun Özellikleri

Tüberküloz, *Mycobacterium tuberculosis* adı verilen aerobik (oksijenli solunum yapan), 2–4 mikron boyunda ve çomak şeklinde bir bakteridir (basil). Basilin yaşayabilmesi ve üreyebilmesi için kesinlikle oksijene ihtiyacı vardır. Bu nedenle organizmaya giren tüberküloz basilleri, daha çok oksijen basıncı yüksek olan doku ve organlara yerleşirler. Bu organların başında akciğerler gelmektedir. Akciğerlerin tepe bölgelerinde oksijen basıncı 120–130 mm/cıva kadardır. Böbrekler ve büyümekte olan kemiklerin epifiz bölgelerinde bu basınç 100mm/cıva kadardır. Tüberküloz basillerinin sayıca iki katına çıkmaları için uygun bir ortam oluştururlar. Tüberküloz basillerinin sayıca iki katına çıkmaları için gerekli süre yaklaşık 12 saattir. Karbondioksit basıncının yüksek olduğu ortamlarda basillerin yaşamları güçleşir.

Tüberküloz basilleri özellikle lipid yönünden çok zengindirler. Bunun yanı sıra proteine ve polisakkaridlere de sahiptir. Tüberküloz basillerinin bir başka Özelliği de herhangi bir toksin (zehir) üretmemeleridir. Vücuda girip bir dokuya yerleşen basiller, buradaki monositlerin, retiküloendotelial hücrelerin ve dev hücrelerin içine girip bu hücrelerin içinde yaşarlar. Basillerin bu özelliklerinden dolayı tüberkülozun İlaç tedavisinde birtakım zorluklar çıkmaktadır [20].

2.4. Tüberkülozda Tanı

Tüberkülozda tanı balgamda tüberküloz mikrobunun bulunması ile konur. Hastanın yakınmaları ve akciğer film bulguları ile hastalıktan şüphelenilir [6]. Hastalarda şu şikâyetler bulunabilir:

- Üç haftadan uzun süren öksürük
- Ateşlenmeler
- Açıklanamayan kilo kaybı
- Gece terlemeleri
- Daima yorgun hissetmek
- İştah kaybı
- Kanlı tükürük
- Verem ciğerlerin dışındaysa etkilenen yerde ağrı ve/veya şişme

Etkin verem hastalığı olan kimi kişilerde belirtiler ılımlı olabilir [16].

Bir doktora bu şikâyetlerle gidildiğinde öncelikli olarak tüberkülozdan şüphelenilmelidir. Hastalığı doğrulamak için bazı testlerin yapılması gerekir. Hastalıktan şüphelenilen kişilerden akciğer röntgeni alınır ve filmde tüberkülozu düşündüren görüntüler olup olmadığına bakılır. Ancak bu tür görüntüler sadece tüberkülozda değil, başka birçok hastalıkta da görülebildiği için direkt olarak bu yöntemle tüberküloz tanısı konamaz. Tüberkülozun kesin tanısı bakteriyolojiktir. Tüberkülozdan şüphelenilen hastalardan usulüne uygun üç balgam örneği alınmalı ve öncelikle yayma ile incelenmelidir ve geri kalanları kültür testi için ayrılmalıdır. Tüberkülin testi (PPD), kişinin tüberküloz ile karşılaşmış olmadığını, yani enfekte olup olmadığını gösteren bir testtir. Hastalık aktivitesi hakkında bilgi vermez. Ancak çocukluk çağındakilerde bu test sonucu değerlidir. Çocuklarda

tüberkülin pozitifliği, hiçbir radyolojik ve klinik bulgu olmasa bile ilaçla korunmayı gerektirir. Yetişkinlerde ise tüberkülin pozitifliği çok yaygındır ve bunların ne zaman enfekte olduklarını ayırt etmek mümkün değildir. Bu pozitifliklerin bir kısmı da BCG'ye bağlıdır [19].

Tablo 2.1. PPD testi sonuçlarının yorumlanması [19]

PPD müspetliğine aşağıdaki kriterlerle karar verilir:	
BCG'lilerde	
0-4 mm	Menfi kabul edilir.
5-14 mm	BCG'ye atfedilir.
15 mm ve üzeri	Müspet kabul edilir, enfeksiyon olarak değerlendirilir.
BCG'sizlerde	
0-4 mm	Menfi kabul edilir.
5-9 mm	Şüpheli kabul edilir, testten sonraki 7-14 gün içinde test tekrarlanır; yine 5-9 mm bulunursa menfi kabul edilir; 10 mm ve üzeri müspet kabul edilir
10 mm ve üzeri	Müspet kabul edilir.
Bağışıklığı baskılanmış, malnütrisyonlu, ve HIV pozitiflerde 5 mm ve üzeri müspet kabul edilir	

2.5. 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 [21]. Hasta ile yakın ve uzun süreli temasta 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 bulaşıcı olduğu gösterilmiştir [22].

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 [23]. Bu nedenle öksürme ve hapşırma sırasında hastaların ağızlarını kâğıt ya da bezden bir mendille kapatmaları istenmelidir [17].

Etkili tedavi ile ilk günlerde basil sayısı hızla azalmakta [24], bunun yanında öksürük sıklığı da azalmaktadır [25]. 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 [19]. 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 [17].

Yapılan deneysel araştırmalar, tüberküloz basilinin tozla, toprakla ya da hastaların eşyalarını kullanmakla veya aynı kaptan yemekle bulaşamayacağını göstermiştir. Yiyeceklerle bulaşma, meme tüberkülozu olan ineklerin kaynatılmadan, çiğ olarak içilen sütleriyle olabilmektedir [19].

İlaça-dirençli TB da bulaştırıcıdır. Birinci grup ilaçlarla yapılan tedavi etkisiz olursa bulaştırıcılık devam edecektir [26]. Akciğer dışı TB genellikle bulaştırıcı değildir, fakat otopside [27] ve doku ile [28] yapılan çalışmalarda aerosol oluşturulursa bulaşma görülebilmektedir.

2.6. 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 [2].

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 [2].

Tüberkülozun tedavisinde çok güçlü ilaçlar vardır. Bu ilaçlar, ülkemizde Verem Savaşı Dispanserleri tarafından ücretsiz verilir. Mikropları etkili bir şekilde öldürmek için yeni hastaların tedavisinde dört ilaç kullanılmaktadır. Verem mikrobi, diğer mikroplara göre çok daha yavaş çoğaldığından, ilaçları uzun süre kullanmak gerekir. Tedavi süresi en az altı aydır. Bazı özel durumlarda ilaçları kullanma süresi uzatılabilir [6].

Hastayı iyileştiren tedavi, hastanın sağlığı yanında toplum sağlığı açısından da son derece önemlidir. Tedavi, bulaşıcı bir hastalık olan veremle savaşın en önemli yöntemidir. Bu nedenle, tedavinin düzenli sürdürülmesi ve tamamlanması zorunludur [6].

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].

2.7. Dünya’da Tüberküloz

Tüberküloz (TB) tüm dünyada giderek artan ve gelişmekte olan ülkelerde yetişkin ölümlerine neden olan önemli bir hastalıktır [29]. Tüberküloz, dünyada ciddi bir halk sağlığı sorunudur. Bütün kıtalarda, bütün ülkelerde tüberküloz vardır. Günümüzde hala tek mikrobun yaptığı en çok öldüren bulaşıcı hastalıktır. Yoğun küresel çabalara karşın yeni Tüberküloz (TB) olgularının sayısı tüm dünyada giderek artmaktadır [30]. Yılda 8,9 milyon insan bu hastalığa yakalanırken 1,7 milyonu ölmektedir. Dünyadaki bütün hastalıkların yüzde 2,5’ünü ve önlenebilir ölümlerin yüzde 26’sını

oluşturmaktadır. Dünya Sağlık Örgütü, verem hastalığı için “Acil Durum” ilan etmiştir. Dünyada verem hastalarının sayısı yıllar içinde artış göstermektedir [6].

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 [6].

2.8. Türkiye’de Tüberküloz

Ülkemizde TB ile etkin mücadele 1950’li yıllarda başlamıştır. Çıkarılan bir yasa ile 1960 yılında Verem Savaş Dispanseri (VSD) kurulmuştur. Bu çalışmalar sayesinde 1965’te yüz binde 172 olan tüberküloz insidansı 1975 yılında yüz binde 50’ye düşmüştür. Doksanlı yıllarla birlikte ‘Göğüs Hastalıkları ve Tüberküloz’ alanında bilimsel dernek örgütlenmeleri gerçekleşmiş; düzenli, disiplinli bir şekilde bilimsel çalışmalar, mezuniyet sonrası mesleki eğitimler yapılmaya başlanmıştır. Böylece ulusal tüberküloz insidansı ilk defa 2000 yılında yüz binde 30’un altına düşmüştür. Ancak Türkiye’nin resmi olgu bulma oranı dikkate alındığında gerçek insidansının yüz binde 50–60 arası olması gerektiği hesap edilmektedir [30].

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 [2].

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 [17]. Son yıllarda ülkemizdeki kayıtlı tüberküloz tanısı

rakamlarına bakıldığında Türkiye’de verem savaşı dispanserlerine 2005 ve 2006’da kayıt edilen hasta sayıları karşılaştırıldığında; çok büyük bir fark olmadığı görülmektedir.

2006 Yılı		2005 Yılı	
Toplam hasta	: 20.526	Toplam hasta	: 20.535
Yeni olgular	: 18.544	Yeni olgular	: 18.753
Tedavi görmüşler	: 1.982	Tedavi görmüşler	: 1.782
Erkek hastalar	: 13.225	Erkek hastalar	: 13.359
Kadın hastalar	: 7.301 [31].	Kadın hastalar	: 7.176 [32]

BÖLÜM 3. HESAPLAMA YÖNTEMLERİ

3.1. Giriş

Hızla ilerleyen teknolojinin getirilerinden biri olan yüksek miktarda veri ve bunları işlemek üzere gerekli olan karmaşık problemlerin çözümü için yüzyıllardır kullanılmakta olan klasik yöntemler yetersiz kalmıştır. Bu hesapların kolayca ve etkili bir şekilde yapılabilmesi adına yeni arayışlar başlamıştır. İnsanoğlu asırlardır karşılaştığı problemleri çözüme doğanın aynı tür problemleri nasıl çözümlendiğini gözlemleyerek bu çözümleri kendi problemlerine adapte etme yöntemini kullanmıştır. Bu çözüm yöntemlerinden biri olan Yapay Sistemler konusunda, bulunduğumuz yüzyılda büyük atılımlar yapılmıştır.

Arı kovanındaki arıların iletişiminden, karıncalar arasındaki işbirliğine, biyolojik sinirin işleyişinden doğada gerçekleşen genetik seçim ve çeşitliliğe kadar birçok konu Yapay Sistemler şeklinde adlandırılabilir sistemlere esin kaynağı olmuştur. Yapay Sistemler içinde, üzerinde en çok çalışılan ve geliştirilen, insanın öğrenme, olayları kavrama, yorumlama ve karar verme yetilerini taklit etme üzerine kurulmuş Yapay Zekâ teknikleridir. Günümüzde astronomi, mühendislik, doğa bilimleri, tıp, ekonomi ve daha birçok alanda geniş bir kullanım alanı bulmuştur. Yapay Zekâ tekniklerinden en sık kullanılanlar; Yapay Sinir Ağları (YSA) ve Genetik Algoritmalar (GA). Özellikle YSA üzerindeki çalışmaların başarılı sonuçlar vermesi ve YSA'nın bilimin çok çeşitli alanlarında kullanılabilirlik özelliğinin keşfedilmesi önemli bir gelişmedir.

Bu bölümde yerel bir hastaneden alınan tüberküloz hastalarının epikriz raporları üzerinden sınıflandırma işlemi yapılmıştır. Bu sınıflandırma işleminde bir İleri


Beslemeli Yapay Sinir Ağı, Genetik Algoritma ile eğitilerek, hesaplama yöntemleri ve optimize edilmiş değerler geliştirilen uygulamada kullanılmıştır.

3.2. Yapay Sinir Ağları (YSA)

YSA'lar bilgiyi alabilen, depolayan ve kullanabilen hücresel sistemlerdir. Yapay zekânın bir dalı olan yapay sinir ağları, biyolojik beyinden daha iyisini yapmaya çalışan büyük paralel hesaplama mekanizmalarıdır. Bunlar zekâyı birbiriyle bağlantılı ağırlıklarında depolarlar. Bu değişken ağırlıklar düğümleri (nöronları) paralel ve ardışık bir biçimde birleştirirler. Tüm mekanizma hiyerarşik olarak girdi vektörünü düğümler ve ağırlıklar doğrultusunda işleyerek çıktı vektörüne ulaştırır [33].

En genel anlamda yapay sinir ağları ileri beslemeli ve geri beslemeli ağlar şeklinde iki ana grup ta düşünülebilir. İleri beslemeli ağlarda nöronlar; girdi, saklı ve çıktı olarak adlandırılan katmanlar vasıtasıyla organize edilir. Her bir katmandaki nöronlar; bir sonraki katman nöronları ile bağlantı ağırlıkları vasıtasıyla ilişkilidir. Ancak katmanların kendi aralarında her hangi bir bağlantı yoktur. Bilgi, girdi katmanından çıktı katmanına doğru ilerler. Buna aktivasyon yönü de denilir. Bu tür yapay sinir ağına örnek olarak tek ve çok katmanlı perceptron verilebilir. Bu tür ağlar denetimli öğrenme teknikleriyle eğitilir.

Yapay sinir ağlarındaki işleme elemanları biyolojik olarak insan beyindeki nöronlara karşılık gelmektedir, Şekil 1. Dendrit olarak adlandırılan yapı, diğer hücrelerden bilgiyi alan nöron girişleri olarak görev yapar. Diğer hücrelere bilgiyi transfer eden eleman aksonlardır. Dolayısıyla aksonlar nöron çıkışları olarak görev yaparlar. Akson ile dendrit arasındaki bağlantı ise sinapslar tarafından gerçekleştirilir [34].



Şekil 3.1 Örnek biyolojik sinir

YSA'nın temel işlevi bilgisayarların öğrenmesini sağlamaktır. Olayları öğrenerek benzer olaylar karşısında benzer karar vermeye çalışırlar [35].

Yapay Sinir Ağlarının temel özellikleri şu şekildedir:

1-Doğrusal olmama: Bütün sonuçların her bir girdiyle etkileşim içerisinde olduğu manasına gelir. Doğrusal bir sistemde girdilerin biri değiştirildiğinde, çıktı bu değişmeye orantılı olarak değişir ve bu etki sadece değiştirilen girdinin değeri ile bağlantılıdır [36]. 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. [2]

2-Hata Toleransı: YSA paralel dağılmış parametrelili bir sistem olduğundan her bir işlem elemanı izole edilmiş bir ada gibidir. Bu nedenle, eğitilmiş bir YSA'nın bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağın doğru bilgi üretmesini önemli ölçüde etkilemez. YSA sistemlerinin hata toleranslı olmasının sebebi, bilginin sisteme dağıtılıyor olmasıdır. Dolayısıyla geleneksel yöntemlere göre hatayı tolere etme yetenekleri son derece yüksektir.

3-Eğitilme: 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 [2]. YSA nöron ağı

kendi parametrelerini (yapısını, ağırlık katsayılarını) değiştirerek, somut problemin çözümü için kendini adapte etme özelliğine sahiptir.

4-Öğrenme: YSA'nın bir problemi öğrenmesi için problemin giriş verilerine karşılık gelen çıkış verilerinin veya sadece giriş verilerinin sağlanması gerekir. Giriş ve çıkış verileri ile tanımlanan öğrenme kümesi yeteri sayıda örnek içermelidir. Öğrenme süreci sistem girişleri ve sistem çıkışı arasındaki ilişkiyi veya giriş verileri arasındaki ilişkilendirmeyi tanımlayan ağırlık verilerinin elde edilme süreci olarak ta tanımlanabilir [37].

5-Genelleştirme: 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 [2].

6-Bellek: YSA'nın önemli bir özelliği, bilgiyi saklama şeklidir. Biyolojik sistemlerde veri dağınık yapıda saklanır. YSA'da bellek, birçok yerel bellekler oluşturularak dağıtılır. Bağlantı ağırlıkları YSA bellek biçimleridir. Ağırlıkların değerleri, ağın o anki bilgi durumunu temsil eder. Örneğin; bir giriş/istenen çıkış çiftinin belirtilen bilgi parçası ağın içinde birçok bellek biçimine dağıtılmıştır. Bellek üniteleri ile diğer saklı bilgiler, bu bilgiyi paylaşırlar [38].

3.2.1. Yapay sinir ağı modelleri

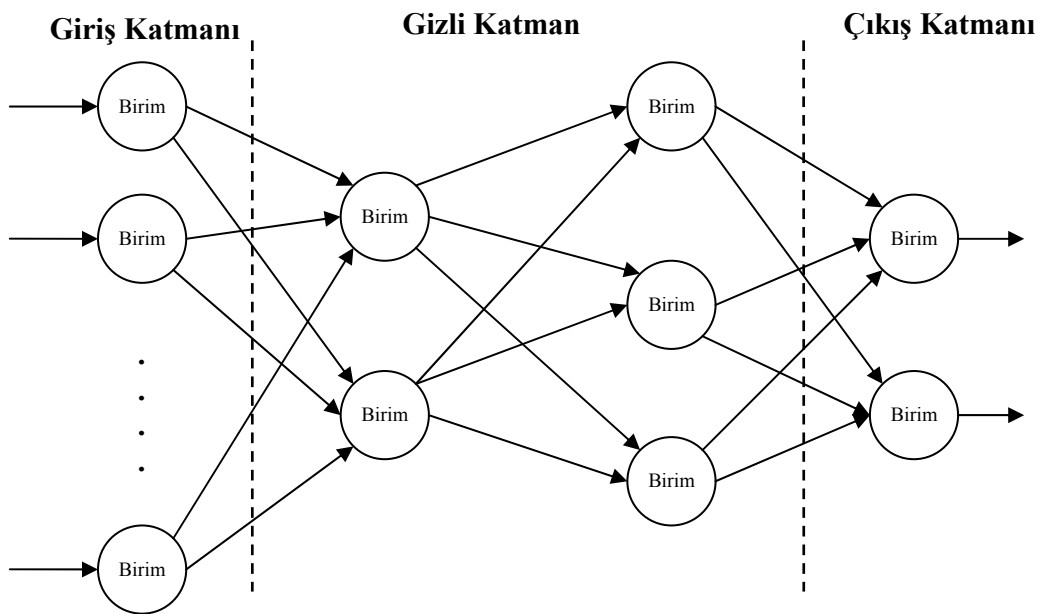
Yapay sinir ağları, genel olarak ağın yapısına göre; ileri beslemeli (feed-forward) ve geri beslemeli (feed-back) olarak ikiye, öğrenme kuralına göre; Hebb, Hopfield, Delta ve Kohonen olmak üzere dörde, öğrenme algoritmasına göre; danışmanlı, danışmansız ve takviyeli olmak üzere üçe ve uygulamaya göre de; off-line ve on-line olmak üzere ikiye ayrılabilir. Ayrıca ağırlık matrislerinin simetrik veya asimetric 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 [37].

3.2.1.1. İleri beslemeli yapay sinir ağları

İleri beslemeli YSA'larda katmanlar ileri yöndedir, tersine bir yönelme yoktur (Haykin, S., Neural Networks: A Comprehensive Foundation, New York: MacMillan College Publishing Company, 1994.). Her bir katmandaki hücreler sadece bir önceki katmanın hücrelerince beslenir [38].

İleri beslemeli yapay sinir ağları nöron adı verilen çok katmanlı karar verici düğümleri kapsar. İlk katman girdi katmanyken son katman ise çıktı katmanıdır. Girdi ve çıktı katmanları dış çevreyle bağlantılı olan katmanlardır. En az bir gizli katman ortada bulunmaktadır. İleri beslemeli YSA'da her bir girdi nöronu ilk gizli katmandaki her nörona bağlıdır. Ve her bir katmanın çıktısı bir sonraki katmanın girdisidir [39].



Şekil 3.2. Örnek çok katmanlı yapay sinir ağı mimarisi

3.2.1.2. 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. Geriye Yayımlı YSA, çok katmanlı perceptron ağ yapısı üzerinde, geriye yayılma yöntemiyle genelleştirilmiş 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. 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 [2].

Bu çalışmada geriye yayımlı YSA modeli kullanılmamıştır.

3.2.2. Yapay sinir ağlarında öğrenme

Sinir ağlarının en önemli özelliği, öğrenme yeteneğidir. Bir sinir ağında öğrenmenin anlamı, ağın belirli bir probleme ait doğru çıktıları üretmesini sağlayacak optimum ağırlık değerlerinin bulunmasıdır. Bilgi, ağ boyunca bağlantılarda ağırlıklar şeklinde dağıtıldığı için tek bir bağlantı herhangi bir anlamlı bilgiyi ifade etmez. Daha doğrusu, anlamlı bir bilgi oluşturmak için işlem elemanları olan bir grup bağlantıyı tasarlamak gerekmektedir. Problemin çözümü için ağın, bağlantılarına ait doğru ağırlık değerlerine sahip olması gerekmektedir. Bu öğrenme veya eğitime olarak adlandırılan bir işlem vasıtasıyla gerçekleştirilir. Öğrenme, ağırlık değerlerinin nasıl değiştirilmesi gerektiğini ifade eden bir öğrenme kuralına dayanır. Geliştirilen birçok öğrenme kuralı vardır. Bir öğrenme kuralının temel ilkesi, benimsenen öğrenme stratejisi ile tanımlanır. Literatürde, üç tip öğrenme stratejisinden söz edilir [40]:

Denetimli Öğrenme: Burada, ağı eğitmek için bir öğretici gerekir. Öğretici, basitçe, çıktı katmanında ağın ne üretmesi gerektiğini söyler. Bir girdi/ çıktı örneği ağa verilir. Ağ, girdiyi süzgeçten geçirir, çıktıyı üretir ve üretilen çıktıyı doğru çıktı ile karşılaştırır. Bağlantılardaki ağırlıklar, daha iyi çıktıyı üretmek için yeniden ayarlanır ve bu işlem, kabul edilebilir bir hata seviyesine erişinceye dek devam eder.

Destekli Öğrenme: Destekli öğrenme de bir öğretici gerektirir. Ancak, çıktının ne olması gerektiği ağa söylenmez. Bunun yerine, üretilen çıktının doğru veya yanlış olduğu ağa söylenir.

Denetimsiz Öğrenme: Denetimsiz öğrenme, bir öğreticiye gerek duymaz. Bu stratejide ağ, girdi/çıkıtı eşleştirmesini düzenlemek için kendi ölçütlerini geliştirir. Bu nedenle, denetimsiz öğrenme stratejisini kullanan ağlar, kendi kendine organize olan ağlar olarak adlandırılır.

3.2.2.1. Yapay sinir ağlarında öğrenme algoritmaları

Bu bölümde öğrenme algoritmaları içerisinde sadece önemli olanlarına değinilecektir.

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: Bir A nöronunun bir aksonu, bir B hücrelerini uyandırmak üzere ona yaklaşmışsa ve onu sürekli olarak tetikliyorsa hücrelerden birisinde veya her ikisinde öyle bir değişim veya metabolik değişim meydana gelir ki, B hücrelerinin tetiklenmesinde rol alan A nöronu aksonunun verimliliğinde bir atış olur [41]. Böylece, hücrenin çıkış üretmesine sebep olan bağlantıların ağırlık katsayılarını büyütür, etkilerini artırır. Algoritmadaki değişim, aşağıdaki gibi gerçekleştirilir.


$$w_i(t+1) = w_i(t) + \epsilon \cdot f(w_i(t) \cdot x(t)) \cdot x(t) \quad (3.1)$$

veya

$$w_i(t+1) = w_i(t) + \varepsilon \cdot y_i(t) \cdot x(t) \quad (3.2)$$

Burada ε 'a öğrenme katsayısı veya öğrenme oranı denilmektedir. Dışarıdan istenilen herhangi bir çıkış uygulanmadığından, eğitici bir öğrenme algoritmasıdır [2]

Algılayıcı (perceptron) öğrenme algoritması: Rosenblatt tarafından önerilmiştir. Perceptronlar, son derece sınırlı olmalarına karşın en eski sinir ağlarından biridir. Perceptron, bir sinir hücresinin birden fazla girdiyi alarak bir çıktı üretmesi prensibine dayanır. Bunun en basit gösterimi aşağıdaki gibidir.

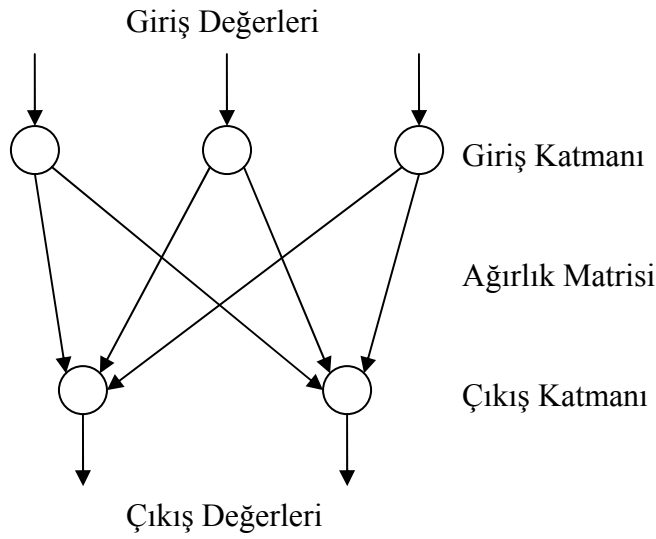


Şekil 3.3. Perceptron örneği

w değişimi, nöron çıkışı ve istenilen çıkışın farkı ile orantılıdır. İstenilen çıkışın farkı ile orantılı olduğundan eğitici bir öğrenme algoritmasıdır.

$$w_i(t+1) = w_i(t) + \varepsilon \cdot [d_i(t) - \text{sgn}(w_i(t) \cdot x(t))] \cdot x(t) \quad (3.3)$$

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



Şekil 3.4. Ara katmansız bir yapay sinir ağı modeli

Delta kuralı (eğimdüşme) öğrenme algoritması: Hebb tarafından 1949'da ortaya atılan bu öğrenme kuralı diğer öğrenim kurallarına yol göstermiştir. Örneğin, iki sinir birbirine bağlanır ve aynı anda harekete geçerse bu iki sinir arasındaki bağlantı daha da güçlenir. Hebb kavram ve düşüncelerin saklanan hafıza değil de sinirler arası hareketlilik örnekleri olduğunu söyler. Güçlü bağ noktalarının ayarlanması ile ilgili önemli başka bir nokta da şudur; ayarlamalar için gerekli olan bilgi genel olarak bağlantılarda bulunmaktadır. Yani programcının ayrıca kurallar oluşturulmasına gerek yoktur. Hebb kuralının sınırlı bir tarafı da şudur; öğrenilecek bilgiler tamamıyla birbirinden farklı olmalıdır. Öğrenme ancak o zaman gerçekleşebilir [42].

w değişimi, hatanın eğiminin tersi yöndedir. Böylece, hata fonksiyonunun minimum olduğu yere doğru hareket ettirilmektedir [2].

$$w_i(t+1) = w_i(t) - \varepsilon \cdot \frac{\partial E(t)}{\partial w(t)} \quad (3.4)$$

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

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

$$E(t) = \frac{1}{2} [d_i(t) - f(w_i(t).x(t))]^2 \quad (3.5)$$

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

Hata geriye yayılma algoritmasının temeli, bu öğrenme algoritmasına dayanmaktadır.

Widrow-Hoff öğrenme algoritması: Widrow ve Hoff ADALİNE (Adaptive Linear Neuron) modeli yapay sinir ağlarının mühendislik uygulamalarına başlanması için ilk adımlardan sayılmaktadır. Bu model, Rosenblatt' ın algılayıcı modeli ile aynı niteliklere sahip bir model olup sadece öğrenme algoritması daha gelişmiş bir modeldir. Daha sonra yapay sinir ağları modellerinin gelişmesinde katkıda bulunmuş bir çalışmadır.

W değişimi ağırlık çıkışından bağımsızdır. Bu bağımsızlıktan dolayı algoritma, eğitici bir öğrenme algoritmasıdır.

$$w_i(t+1) = w_i(t) + \varepsilon \cdot (d_i(t) - w_i(t).x(t)) \cdot x(t) \quad (3.6)$$

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.

$$w_i(t+1) = w_i(t) + \varepsilon \cdot d_i(t) \cdot x(t) \quad (3.7)$$

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 [2].

$$w(t+1) = w(t) + \varepsilon \cdot (x(t) - w_m(t)) \quad (3.8)$$

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

$$w_m \cdot x = \max(w_i \cdot x) \quad \text{ve} \quad i = 1, 2, \dots, p \quad \text{dir.} \quad (3.9)$$

Outstar öğrenme algoritması: Amaç, w 'leri istenen çıkışa benzetmektir. Eğitici öğrenme algoritmasını bir türüdür [43].

$$w(t+1) = w(t) + \varepsilon \cdot (d_i(t) - w(t)) \quad (3.10)$$


Genetik öğrenme algoritması: Ağ içindeki her bir w bir gen olarak düşünülür. Popülasyondaki her bir birey ağ için genler taşır. Her bireyin başarısı ağın girdileri kullanılarak test edilir ve ürettikleri sonuçların ortalama karesel hatalarına göre azdan çoğa sıralanırlar. Belli bir seçim oranı kadar alınır ve popülasyondaki diğer bireyler atılır. Daha sonra başarı sıralamasında seçilen bireyler arasında eşleştirmeler yapılır ve bu bireylerin genleri arasında çaprazlama işlemi gerçekleştirilir. Daha sonra rastsal olarak genler mutasyona uğratılır. Bu işlem belli bir nesil veya hata oranına ulaşıncaya kadar devam eder.

3.2.3. Çok katmanlı ağlar

Bu tür ağlar, giriş katmanı, bir veya birden çok gizli katman ve çıkış katmanından oluşmaktadır. Bir katmandaki her sinir, bir sonraki katmanın bütün sinirleri ile bağlantılıdır. Aynı katmandaki sinirler arasında veya geri-besleme şeklinde bağlantıları yoktur. Giriş katmanından alınan girişler, giriş katmanı ve gizli girişler arasında bulunan bağlantı ağırlıkları ile çarpılıp gizli katmana iletilmektedir. Gizli katmandaki sinirlere gelen girişler toplanarak aynı şekilde gizli katman ile çıkış

katmanı arasındaki bağlantı ağırlıkları ile çarpılarak çıkış katmanına iletilir. Çıkış katmanındaki sinirler de kendisine gelen girişleri toplayarak buna uygun bir çıkış üretirler. Burada giriş katmanından çıkış katmanına doğru, gizli katmanlar üzerinden tek yönlü bir iletişim mevcuttur [42].

ÇKA'lar, öğretmenli öğrenme stratejisine göre çalışırlar. Eğitim sırasında ağa, hem girdiler hem de bu girdilere karşılık gelen çıktı değerleri gösterilir. Ağın görevi bu girdiye karşılık gelen çıktı değerini öğrenmektir. ÇKA'ların öğrenme kuralı en küçük kareler yöntemine dayalı Delta Öğrenme Kuralının genelleştirilmiş halidir. Genelleştirilmiş Delta Kuralı iki safhadan oluşur. 1. safhaya, ileri doğru hesaplama safhası adı verilir ve bu safhada ağa gösterilen örnek seti için ağın çıktısı hesaplanır. 2. safhaya geriye doğru hesaplama safhası adı verilir; bu safhada ise ağın ağırlıkları güncellenir.



Şekil 3.5. İki gizli katmana sahip bir Çok Katmanlı Ağ şeması

3.2.3.1. Çok katmanlı ağın eğitilmesi

Yapay sinir ağlarının eğitilmesi demek, mevcut örneklerin tek tek ağa gösterilmesi ve ağın kendi mekanizmalarını çalıştırarak örnekteki olaylar arasındaki ilişkileri belirlemesidir. Eğitim yeterli sayıda giriş-çıkış örnek kümesi için yapılmalıdır. Eğitim sonucunda ağ hem eğitime örnek kümesine ait veriyi tanımalı hem de interpolasyon ve ekstrapolasyon yapabilmelidir. Yani eğitim kümesinde olmayan örnek için uygun çıktılar vermelidir. Aslında eğitilmiş bir yapay sinir ağından beklenen de budur [34].

Her ağı eğitmek için elde bulunan örnekler iki ayrı sete bölünür. Birinci ağı eğitmek için (eğitim seti) diğeri ise ağın performansını sınamak için (test seti) kullanılır. Her ağ önce eğitim seti ile eğitilir. Ağ bütün örneklerle doğru cevaplar vermeye başlayınca eğitim işi tamamlanmış kabul edilir. Daha sonra ağın hiç görmediği test setindeki örnekler ağa gösterilerek ağın verdiği cevaplara bakılır. Eğer ağ hiç görmediği örneklerle kabul edilebilir bir doğrulukta cevap veriyor ise o zaman ağın performansı iyi kabul edilir ve ağ kullanıma alınarak gerekirse çevrimiçi (on-line) kullanılır. Eğer ağın performansı yetersiz olursa o zaman yeniden eğitmek veya yeni örnekler ile eğitmek gibi bir çözüme gidilir. Bu işlem ağın performansı kabul edilebilir bir düzeye gelinceye kadar devam eder [42].

Yapay sinir ağları ne kadar çok örnekle eğitilirse hem öğrenebilecekleri olay ve tanıyabilecekleri obje sayısı artar, hem de hata oranı azalarak daha hassas sonuçlar elde edilir. En genel anlamda nöral ağlar; kullanılan nöron modeli, bu nöronların ağ yapısında bir arada bulunma şekli yani ağ mimarisi, ağırlıkların ayarlanması için öğrenme kuralının belirlenmesi ve kullanılan aktivasyon fonksiyonu gibi dört farklı özellik ile karakterize edilir. Ağdaki her bir katman işleme elemanının bir toplamından oluşur. Her bir işleme elemanı kendi girdi bağlantılarındaki değerlerin ağırlıklı toplamını bir eşik fonksiyonundan geçirerek bir çıktı değeri üretir. Bilginin ağ içerisinde saklanması bağlantı ağırlıklarının ayarlanarak uygun değerleri almasıyla sağlanır. Bu ağırlık değerleri eğitim işlemi başlangıcında rasgele küçük sayılara atanır. İstenen çıktı ile ağ çıktısı arasındaki fark yeterince küçük oluncaya

kadar yapılan eğitime işlemi sırasında öğrenme kuralına bağlı olarak ağırlıklar düzenlenerek sonuç değerleri elde edilir [34].

3.2.3.2. Çok katmanlı ağıın çalışma prosedürü

Çok katmanlı ağların çalışması şu adımları içermektedir:

Örneklerin Toplanması ve Ağıın Topolojik Yapısının Belirlenmesi: İlk olarak ağıın çözmesi istenilen olay için daha önce gerçekleşmiş örnekler temin edilir. Örneklere göre, kaç tane girdi ünitesi, ara katman, her ara katmanda kaç proses elemanı ve kaç çıktı elemanı olacağı belirlenir. Ağıın görevi her girdi için o girdiye karşılık gelen çıktıyı üretmektir.

Öğrenme Parametrelerinin Belirlenmesi: Ağıın öğrenme katsayısı, proses elemanlarının toplama ve aktivasyon fonksiyonları, momentum katsayısı gibi parametreler bu adımda belirlenir.

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 İşlemi: Çok Katmanlı YSA'nın öğrenme kuralı en küçük kareler yöntemine dayalı Delta Öğrenme kuralının geliştirilmiş halidir. Çok Katmanlı Ağa örnekler (girdi, çıktı değerleri) belirli bir düzene göre gösterilip ağıın bulduğu çıktı ile gerçek çıktı değerleri karşılaştırılarak hata değeri hesaplanır. Amaç toplam hatayı minimize etmektir. Hata değerini azaltmak için bağlantı ağırlıkları değiştirilir. Belirli bir iterasyondan sonra öğrenme tamamlanır.

3.3. 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 [7]. Diğer bir önemli üstünlükleri ise çözümlerden oluşan popülasyonu eş zamanlı incelemeleri ve böylelikle yerel en iyi çözümlere takılmamalarıdır [2].

3.3.1. 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, $\{0, 1, *\}$ alfabesi kullanılarak tanımlanır. Örneğin H alt dizisi, ilk konumunda 0, ikinci ve dördüncü konumunda 1 değeri olan kromozomlar kümesi içindir.

$$H = 0 1 * 1 * \quad (3.11)$$

* 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 [7].

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.

Genetik algoritmanın temel teoremi ise şöyle açıklanmaktadır [44]:

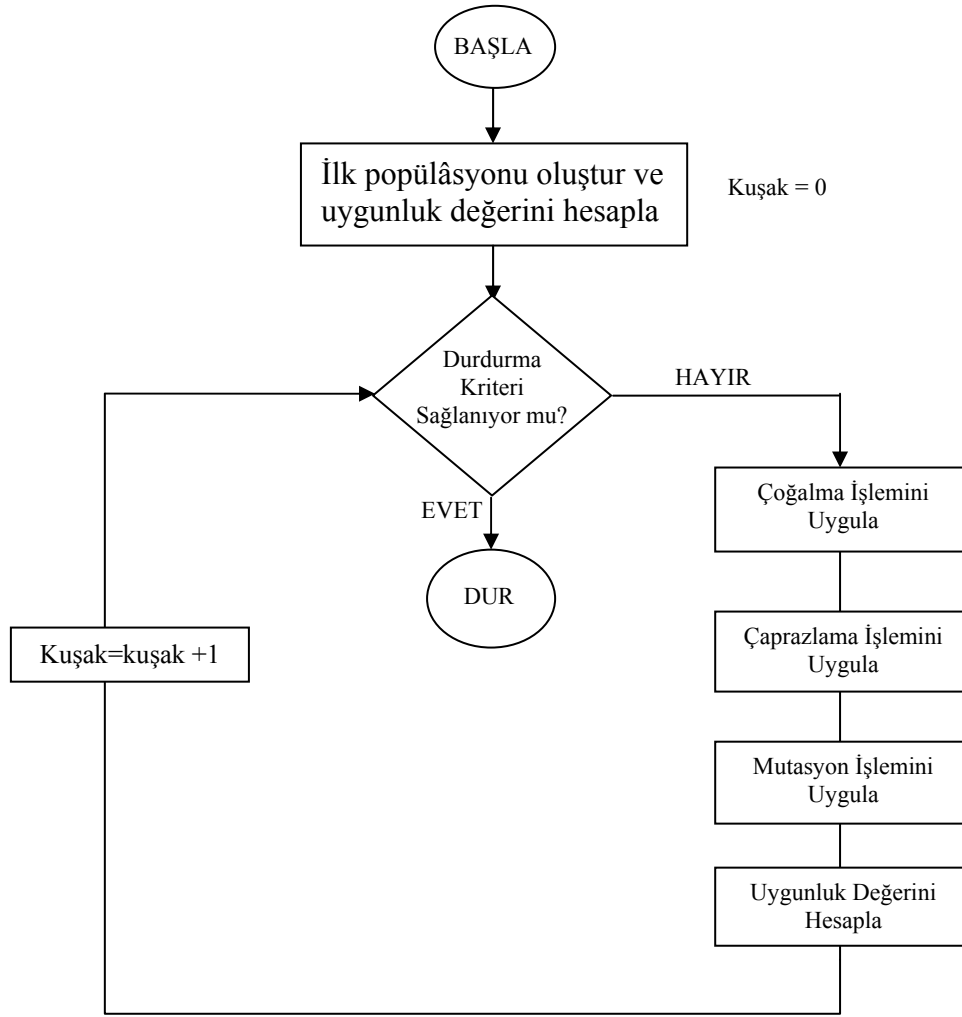
Popülasyon ortalamasının üstünde uyum gücü gösteren, kısa uzunluğa ve düşük dereceye sahip alt diziler zamanın ilerlemesiyle üstsel olarak çoğalırlar.

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 [45]:

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.

3.3.2. Basit genetik algoritma

Birçok alanda uygulama imkânı ve uygulamaları olan genetik algoritmaların işleme adımları şöyle açıklanabilir [46]:



Şekil 3.6 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. 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. Genetik algoritmalar, çözümlerin kodlanmasını, uygunlukların hesaplanmasını, çoğalma, çaprazlama ve mutasyon operatörlerinin uygulanmasını içerir [47].

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 [44]. Parametrelerin kodlanması, probleme özgü bilgilerin genetik algoritmanın kullanacağı şekle çevrilmesine olanak tanır [47].

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. 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 [7].

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 [47]. 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. 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 [44].

4. Çoğalma işleminin uygulanması: Çoğalma operatöründe diziler, amaç fonksiyonuna göre kopyalanır ve iyi kalıtsal özellikleri gelecek kuşağa daha iyi aktaracak bireyler seçilir. Çoğalma, bireyleri seçme işleminden, seçilmiş bireyleri bir eşleme havuzuna kopyalama işleminden ve havuzda bireyleri çiftler halinde gruplara ayırma işleminden oluşur [48].

Uygunluk değerinin hesaplanması adımından sonra mevcut kuşaktan yeni bir popülasyon yaratılmalıdır. Bu yöntemin amacı, ortalama uygunluğun üzerindeki değerlere çoğalma fırsatı tanımaktır. Bir dizinin kopyalanma şansı, uygunluk fonksiyonuyla hesaplanan dizinin uygunluk değerine bağlıdır [47].

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 [47].

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 uğrattılır. En basit çaprazlama yöntemi tek noktalı çaprazlama yöntemidir. Tek noktalı çaprazlama yapılabilmesi için her iki kromozomun da aynı gen uzunluğunda olması gerekir. İki noktalı çaprazlamada ise kromozom iki noktadan kesilir ve karşılıklı olarak pozisyonlar yer değiştirilir [48].

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 [7]. Mutasyonun genel amacı, genetik çeşitliliği sağlamak veya korumaktır [2].

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 [49]. İstenen hassasiyet derecesine göre de maksimum iterasyon sayısı belirlenebilmekte ve iterasyon bu sayıya ulaştığında döngü durdurulabilmektedir.

3.3.3. 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 [50]. Genetik algoritmalar özellikle çözüm uzayının geniş, süreksiz ve karmaşık olduğu problem tiplerinde başarılı sonuçlar vermektedir [2].

Genetik algoritmalar optimizasyon, otomatik programlama ve bilgi sistemleri, mekanik öğrenme, ekonomik ve sosyal sistem modelleri gibi alanlarda etkin bir biçimde kullanılabilir. Özellikle optimizasyon işlemlerinde kullanılan klasik yöntemlerin işlemler içinde uygunluk fonksiyonunu kullanması ve sürekli olmayan fonksiyonlarda bu fonksiyonun türevinin alınamaması, bu yaklaşımların yetersiz kalmasına neden olmaktadır. Oysaki genetik algoritma türev gibi yardımcı bilgilere ihtiyaç duymadığından bu tür bir sorunla karşılaşmamaktadır [2].

BÖLÜM 4. TÜBERKÜLOZ HASTALIĞININ TEŞHİSİ İÇİN GELİŞTİRİLEN ÖRNEK UYGULAMA

4.1. Giriş

Bu bölümde tüberküloz hastalığının teşhisi için hesaplama algoritmalarının kullanıldığı örnek uygulama (THT) anlatılmıştır. Öncelikle bu konuda kullanılan yazılım aracı belirtilmiş, ardından eğitim ve test için kullanılan yapılar hakkında bilgi verilmiştir. Daha sonra programın arayüzü üzerinde detaylı açıklama yapılmıştır.

Uygulama, Microsoft Visual Studio .NET 2008 yazılım geliştirme ortamında C# programlama dili kullanılarak oluşturulmuştur. Yaygın kullanım alanının olması, kaynak ve örnekler bakımından çeşitliliğin bulunması, yazılım oluşturma esnekliği ve performans yeterliliği göz önünde bulundurularak uygulama dili için C# seçilmiştir.

4.2. Uygulamada Kullanılan Veri Seti

THT’de kullanılmak üzere Diyarbakır Göğüs Hastalıkları Hastanesinden hasta epikrizleri temin edilmiştir. Verilerdeki dağılım şu şekildedir:

Tablo 4.1 Hasta veri sınıfları

Sınıf	Hastalık	Hasta Sayısı
1. Sınıf	Normal	50
2. Sınıf	Tüberküloz	100

Mevcut epikriz raporlarının bir uzman tarafından yorumlanması yordamıyla elde edilen ve uygulamada kullanılan özellik parametreleri şunlardır; Yakınma-Öksürük, Yakınma-Ateş, Yakınma-Göğüste Ağrı, Yakınma-Göğüste Sıkışma, Yakınma-Halsizlik, Yakınma-Nefes Darlığı, Yakınma-Hırıltı, Yakınma-Balgam, Muayene-Solunum Sistemi, Sigara Alışkanlığı, WBC, RBC, HCT, PLT, Albümin2, Alkale 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), Kolesterol, Kreatinin, LDH, Potasyum, Sodyum (Na), Total Protein, Trigliserid, Ürik Asit.

THT’de kullanılan veri seti 3-kat çapraz doğrulama (3-fold cross-validation) yöntemi ile 3 parçaya ayrılarak her bir parça hem eğitimde hem de test aşamasına kullanılmıştır.

4.3. THT’de Kullanılan Yapay Sinir Ağı Modeli

Bu çalışmada tüberküloz hastalığının teşhisi için kullanılmak üzere iki gizli katmana sahip bir ÇKA yapısı oluşturulmuştur. Bu ağın yapısı; 1 giriş katmanı, 2 gizli katman, 1 çıkış katmanı şeklindedir (Şekil 4.1). Gizli katmanların her birinde 50şer adet sinir ve tüm sinirlerde aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmıştır. Sisteme 38 adet özellik verilip iki çeşit sınıflandırma (Normal, Tüberküloz) yapılması hedeflenmiştir. Yapay sinir ağını modellemek için aşağıdaki denklemler kullanılmıştır.

Katmanlar arasındaki sinirlerin çıkışları;

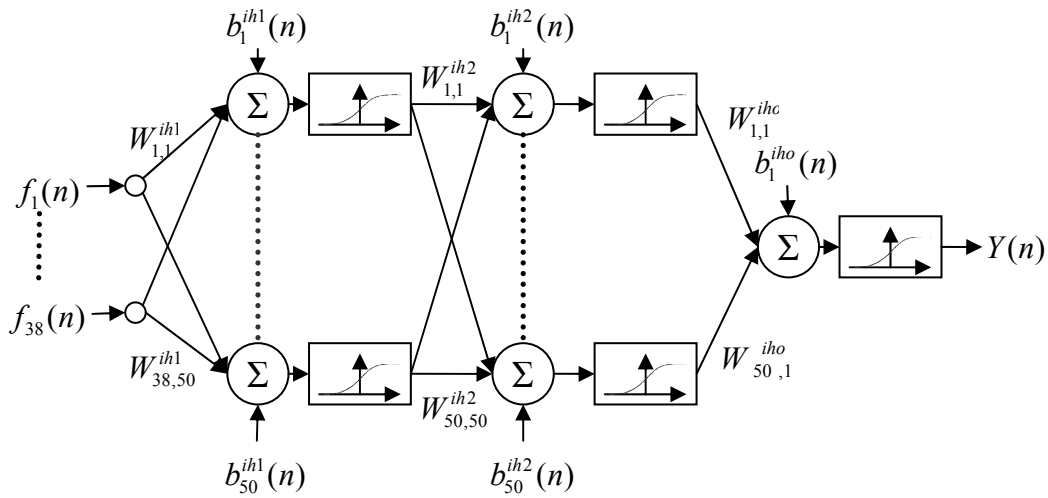
$$\vec{X}^{ihm}(n) = \frac{1}{\left(1 + \exp\left(W^{ihm}(n) * \vec{f}(n) + \vec{b}^{ihm}(n)\right)\right)} \quad (4.1)$$

Ağın çıkışı;

$$\vec{Y}(n) = \frac{1}{\left(1 + \exp\left(W^{ho}(n) * \vec{X}^{ih2}(n) + \vec{b}^{ho}(n)\right)\right)} \quad (4.2)$$

$W^{ihm}(n)$: m. Katman ile (m+1). katman arasındaki ağırlıklar

- $\vec{b}^{ih1}(n)$: m. katman bias değeri
 $W^{ho}(n)$: İkinci gizli katman ile çıkış arasındaki ağırlıklar
 $\vec{b}^{ho}(n)$: 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. THT'de kullanılan YSA'nın yapısı

4.3.1. Ağın performans değerini ölçmede doğruluk oranı kullanımı

Bu çalışmada sınıflandırma başarı performansını ölçmede aşağıdaki denklem kullanılmıştır:

$$Basarim(N) = \frac{\sum_{i=1}^{|N|} Siniflandir(n_i)}{|N|} \quad (4.3)$$

$$Siniflandir(n) = \begin{cases} 1 & \text{eger } sinif(n) = nb \\ 0 & \text{diger} \end{cases} \quad (4.4)$$

N : Sınıflandırılacak veri seti

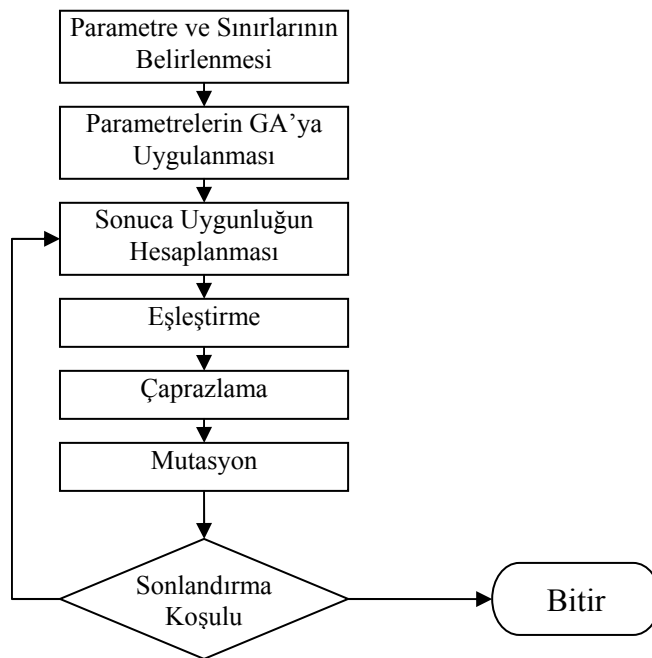
n : Veri setinden bir örnek

nb : Alınan örnek için beklenen sınıf

$Siniflandir(n)$: Alınan örnek için ağ tarafından hesaplanan sınıf

4.4. THT'de Kullanılan Genetik Algoritma Modeli

Bilindiği gibi problemi çözmeye kullanılan yöntemlere göre kromozomların ifade edilmesi iki şekilde olmaktadır; ikili kodlama ve gerçek kodlama. Bu uygulama için parametrelerin gösteriminde gerçek kodlama kullanılmıştır.



Şekil 4. 2 Genetik algoritma akış şeması

1.Adım: Bu adımda amaç fonksiyonu, kısıtlamalar ve aralıklar tanımlı olduğundan bu bilgiler eşliğinde ilk başlangıç popülasyonu rastsal olarak oluşturulur.

2.Adım: Bu uygulamada elde edilen popülasyondan seçim işlemi yapmak için turnuva seçim şekli tercih edilmiştir. Bu tür bir seçim şeklinde popülasyondaki eşleştirilecek çiftler popülasyon çapında rastgele seçilirler. Çiftlerden hangilerinin popülasyonda kalacağına ise sonuca uygunluğun denetlendiği kısıt fonksiyonu sonucu elde edilen sonuçla karar verilir.

Kısıt fonksiyonlarının deęerlendirmesi, popülasyondaki tüm kromozomların amaç fonksiyonu sonucundan ne kadar uzak olduğuna bakılarak yapılır. Buna göre popülasyondaki her kromozom işlem sonucuna uzaklığına göre yakından uzağı doğru sıralanır ve belirlenen sınıra göre sınırdan uzaktakiler popülasyondan atılır.

3. Adım: Seçim işlemi yapıldıktan sonra çaprazlama işlemi yapılır. Gerçek kodlu genetik algorithmada da iki kodlu algorithmada olduğu gibi çeşitli çaprazlama yöntemleri mevcuttur. Lineer çaprazlama, heuristic çaprazlama, tek düzen metodu, kuadratik çaprazlama, karma çaprazlama vb. Bu problem için aritmetik çaprazlama yöntemi uygulanmıştır.

Aritmetiksel çaprazlama işleminde eşleşen kromozomların karşılıklı her bir geni için $[0,1]$ aralığında rastgele bir sayı üretilir. Eğer üretilen bu sayı çaprazlama oranından küçük ise çaprazlama işlemi gerçekleştirilir. Daha sonra ρ adı verilen $[0,1]$ aralığındaki rastgele deęer kullanılarak aşağıdaki formüle göre çaprazlama işlemi yapılır.

$$x_n^{1,t+1} = \rho \cdot x_n^{2,t} + (1 - \rho) \cdot x_n^{1,t} \quad \text{ve} \quad x_n^{2,t+1} = \rho \cdot x_n^{1,t} + (1 - \rho) \cdot x_n^{2,t} \quad (4.5)$$

4. Adım: Çaprazlama işlemi bittikten sonra mutasyon işlemi yapılır. Popülasyondaki her kromozomun her bir geni için $[0,1]$ aralığında rastgele bir sayı üretilir ve eęer bu sayı mutasyon oranından küçükse gen tekrar üretilerek kromozom mutasyona uğratılmış olur.

5. Adım: Seçilen sonlandırma koşuluna göre işlemlerin tekrarlanıp tekrarlanmayacağına karar verilir. Sonlandırma koşulu belli bir nesil (iterasyon) sayısı veya hata oranına ulaşma durumu olabilir.

Sonuç olarak işlemler sonlandırma koşulu sağlanana kadar tekrar ederek problemin çözümüne en yakın kromozomlar popülasyonda toplanmış olur. Geliştirilen uygulamada 50 iterasyon için 5 seçim oranı, 3 mutasyon oranı ve 0,6 mutasyon genliğinde 250 popülasyon ile problem için optimum sonuç bulunmuştur.

4.5. THT Uygulama Programı

Geliştirilen C# uygulamasında Şekil 4.3’de görüldüğü gibi eğitim için bir ana form bulunmaktadır ve bu ekran vasıtasıyla verilerin girilmesi, ağın eğitilmesi, test edilmesi, genetik algoritma parametreleri ayarlanması işlemleri gerçekleştirilebilmektedir.

Yakınma Öksürük	Yakınma Ateş	Yakınma Göğüsste Ağrı	Yakınma Halsizlik	Yakınma Nefes Darlığı	Yakınma Hırıltı	Yakınma Göğüs Sıkı
0	0	0	0	0	0	0
1	1	1	1	0	0	0
1	0	0	0	1	1	0
0	0	0	0	0	0	0
1	0	0	0	1	1	0
1	1	1	1	0	0	0
1	0	0	0	1	1	0
1	1	1	1	0	0	0
1	0	0	0	1	1	0
1	0	0	0	1	1	0
1	0	0	0	1	1	1
0	0	0	0	0	0	0
1	0	0	0	1	1	0
0	0	0	0	0	0	0
1	0	0	0	1	1	0
1	0	0	0	1	1	0
1	0	0	0	1	1	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0

Şekil 4.3 THT uygulaması ana formu

4.5.1. Uygulamanın kullanımı

Ağın eğitilmesi için yapılması gerekenler:

1. Öncelikle yapay sinir ağını eğitmek için kullanılacak olan verilerin yüklenmesi gerekiyor. Bu işlem iki adımda gerçekleştirilir:
 - a. Verilerin normalizasyonu ve sütun başlıklarına veri türü isimlerinin yazılabilmesi için başlıkların yüklenmesi gerek. Bunun için Dosya menüsünün altındaki Başlıkları Yükle butonuna basılması yeterlidir. Bu düğmeye basıldığında kullanıcının karşısına dosya açma ekranı

gelecektir. Geçerli formatta bir başlık dosyası seçilerek Tamam düğmesine basılır ve başlıklar yüklenmiş olur.

- b. YSA'nın eğitiminde kullanılacak verilerin yüklenmesi için ise Dosya menüsünün altındaki Verileri Yükle butonuna basılır. Ekranı bir dosya açma formu gelir. Doğru formatta bir dosya seçilerek Tamam butonuna basılır. Eğer verilerin formatı doğruysa yüklenen veriler ana form üzerindeki sol boşlukta görüntülenecektir.
2. Veriler yüklendikten sonra formun sağ tarafında bulunan alan içindeki boşluklara GA eğitim algoritmasında kullanılacak parametreler girilir.
3. Veriler ve parametreler girildikten sonra ağın eğitilmesi için menü çubuğundaki Eğitim butonuna basılması veya F5 tuşuna basılması yeterlidir. Uygulamaya girilen veriler 3-katlı çapraz doğrulama yönteminde kullanılmak üzere üç gruba ayrılır. Her bir grup eğitimi için durum bilgisi eğitimler boyunca formun alt kısmındaki durum çubuğundan takip edilebilir.
4. Eğitimler bittikten sonra kullanıcının karşısına rapor formu gelmektedir (Şekil 4.4). Bu ekranda her bir eğitim grubunun eğitiminin ne kadar sürdüğü, eğitim setindeki toplam veri miktarı, eğitim sonrasında gerçekleştirilen testlerde kaç verinin sonucunun hatalı olduğu, hata ve başarı yüzdeleri ile birlikte hangi sonuçların hatalı olduğu beklenen ve test sırasında bu verilere ağın verdiği sonuçlar görülmektedir.
5. İstendiği takdirde eldeki hazır verileri kullanarak ağın güvenilirliğinin test edilmesi için menü çubuğundaki Test butonuna basıldığı takdirde ekrana test formu gelecektir (Şekil 4.5). Bu ekranda her bir hasta verisinin girilebileceği alanlar mevcuttur ve bu alanlara veriler girilerek Test butonuna basıldığında girilen verilere ağın verdiği yanıt ve bu yanıtın hangi sınıflandırmaya girdiği bilgisi görülecektir. Aynı zamanda ana form üzerinden yüklenmiş veriler içinden rastgele bir tanesinin değerleri alınıp bu verilerin de testi yapılabilir. Ayrıca form üzerinde herhangi bir boşluğa çift tıklatıldığı zaman yüklü verileri içinden rastgele 100 adet veri sırayla test işlemine tutulur ve sonucu küçük bir bilgilendirme ekranında görüntülenir (Şekil 4.6).

1. set sonuçları	
Eğitim süresi: 1 dakika 28 saniye 136 milisaniye	
Toplam veri sayısı: 50	
Hatalı sonuç sayısı: 5	
Hata Oranı: %10 (Başarı Oranı: %90)	
Hatalı sonuçlar:	
BEKLENEN	TEST SONUCU
Normal(1)	Tüberküloz(2)
Normal(1)	Tüberküloz(2)
Normal(1)	Tüberküloz(2)
Normal(1)	Tüberküloz(2)
Normal(1)	Tüberküloz(2)
2. set sonuçları	
Eğitim süresi: 5 dakika 36 saniye 627 milisaniye	
Toplam veri sayısı: 50	
Hatalı sonuç sayısı: 1	
Hata Oranı: %2 (Başarı Oranı: %98)	
Hatalı sonuçlar:	
BEKLENEN	TEST SONUCU
Tüberküloz(2)	Normal(1)
3. set sonuçları	
Eğitim süresi: 24 saniye 358 milisaniye	
Toplam veri sayısı: 50	
Hatalı sonuç sayısı: 2	
Hata Oranı: %4 (Başarı Oranı: %96)	
Hatalı sonuçlar:	
BEKLENEN	TEST SONUCU
Normal(1)	Tüberküloz(2)
Normal(1)	Tüberküloz(2)
ORTALAMA BAŞARI: %94,67	

Şekil 4.4. Rapor ekranı

Test Formu

Yakınma (Öksürük) [0-Yok; 1-Var] 0	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] 0
Yakınma (Hırıltı) [0-Yok; 1-Var] 0	Yakınma (Göğüste Sıkışma) [0-Yok; 1-Var] 0	Yakınma (Balgam) [0-Yok; 1-Var] 0	Muayene (Solunum Sistemi) [0-Normal; 1-Kötü] 0	Alışkanlıklar (Sigara) [0-Yok; 1-Var] 0
WBC [4; 11] 10,6	RBC [4,20; 6,20] 5,4	HGB [12; 18] 12,67	HCT [35; 55] 36,96	PLT [150; 400] 344
Albumin 2 [3,5; 5,2] 4,27	Alkalen Fosfataz 2 L [38; 155] 59,6	ALT [5; 41] 5	Amilaz [28; 100] 36	AST [5; 37] 9
Bilirubin (Total+ Direkt) [0; 1,0] 0,71	CK / Kreatin Kinaz [15; 170] 61	CK - MB [6; 24] 11	Demir (Serum) [37; 145] 131	GGT [8; 61] 41
Glukoz [70; 110] 92	HDL Kolesterol [35; 65] 61	Kalsiyum (CA) [8,4; 10,8] 9,74	Kan Üre Azotu (BUN) [13; 50] 42	Klor (CL) [96; 110] 104
Kolesterol [40; 200] 121	Kreatinin [0,4; 1,5] 1,25	LDH [240; 480] 465	Potasyum [3,5; 5,5] 5,46	SODYUM (Na) [140; 157] 156
TOTAL PROTEIN [6,4; 8,3] 7,89	TRİGLİSERİD [40; 200] 91	ÜRİK ASİT [0; 7] 6,04	Beklenen Çıktı :	Test Sonucu :

Rastgele Kayıt Al

Test

Şekil 4.5. Test formu

Doğruluk Testi

100 deneme içinden 93 adedi doğru

Tamam

Şekil 4.6. Doğruluk testi sonucu

BÖLÜM 5. SONUÇ VE ÖNERİLER

5.1. Sonuçlar

Bu çalışmada, bir hastanenin göğüs hastalıkları bölümünden alınmış hasta epikriz raporları alınmış ve bir uzman tarafından teşhiste etkili olacağı düşünülen parametreler seçilmiştir. Bu parametrelerden oluşan verilerin bir YSA'nın eğitiminde kullanılabilmesi için THT adında bir uygulama programı geliştirilmiştir. Yapılan işlemler ve testler sonucunda YSA'nın öğrenme ve rasyonel sonuçlar üretebilme yeteneğinin, karar destek sistemi olarak geliştirilen uygulamanın başarılı sonuçlar vermesinde büyük katkısı olduğu görülmüştür.

Kullanılan Genetik Algoritmanın, ağırlık eğitimindeki etkinliği, GA'nın çok çeşitli alanlarda olduğu gibi bu çalışmada uygulaması yapılan hastalık teşhisinde de başarılı olabildiği görülmüştür. Genetik algoritma, bu çalışmada olduğu gibi, parametre uzayının çok geniş olduğu alanlarda, diğer algoritmalara göre daha etkili olabilmektedir. Özellikle kullanılan YSA modelinde bulunan ağırlık değer uzayının genişliği düşünüldüğünde farklı algoritmalar göre performansının daha yüksek olabildiği görülmüştür.

Genetik Algoritma, problem uzayında çözüme ulaşmak için rastsal değerler kullandığı için uygulamanın performansı zamanla küçük dalgalanmalar gösterebilmektedir. Fakat yapılan çalışmada uygulamanın performansının çoğunlukla %93 üzerinde olduğu gözlenmiştir. Aynı parametrelerle yapılan 3 eğitim sonucu ve kullanılan parametreler Tablo 5.1'de gösterilmiştir.

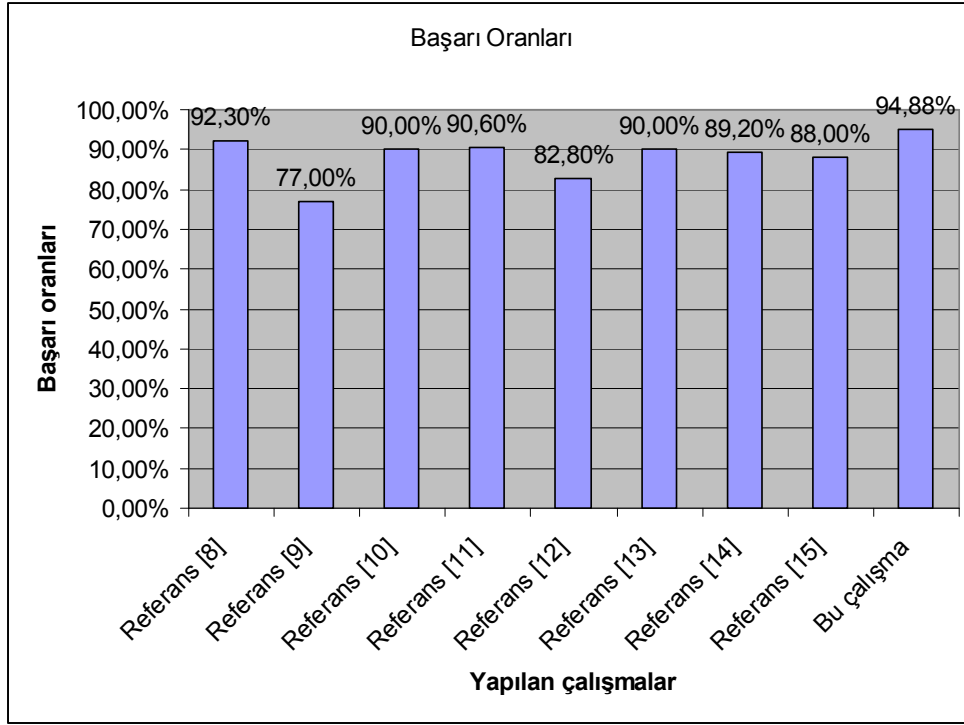
Tablo 5.1. Eğitimde kullanılan Genetik Algoritma parametreleri

Popülasyon Boyutu	Seçim Oranı	Mutasyon Oranı	Mutasyon Genliği	Maximum Nesil Sayısı
250	5	3	0,60	50

Tablo 5.2. Ağın çeşitli zamanlarda sıfırdan tekrar eğitime sonuçları

Eğitim numarası	Hesaplanan ortalama başarı
1	%95,17
2	%94,03
3	%95,48
Ortalama Başarı: %94,88	

Birinci bölümde ifade edilen benzer çalışmaların sonuçlarına bakıldığı zaman bulunan performans sonuçlarının diğerlerinden yüksek olduğu görülmüştür. Bu sonucun oluşmasında ağın verileri ezberlemeye başlamasının etkili olduğu düşünülmektedir. Ayrıntılı parametre ayarlamaları ve daha geniş veri setiyle bu sorun aşılabilecektir. Uygulama esnasında çeşitli parametrelerle eğitim denenmiş ve nesil sayısının başarıyı olumsuz etkilediği görülmüştür. Aynı zamanda popülasyon miktarının çokluğunun başarıyı arttırdığı fakat eğitim süresini uzattığı görülmüştür. Eğitim süresi ve başarıyı optimum seviyeye çekmek için yapılan çeşitli denemeler sonucunda Tablo 5.1’de gösterilen değerler elde edilmiştir.



Şekil 5.1 Başarı oranı karşılaştırması

Şekil 5.1’de de görülebileceği gibi referans alınan çalışmalarla kıyaslandığında bu çalışmanın performansı diğerlerine göre daha iyidir.

Geliştirilen uygulama gerekli değişiklikler yapıldıktan sonra genel amaçlı, çoklu hastalık teşhis edebilen bir sistem haline getirilebilir. Bu hastalıklarla ilgili veriler sistemin eğitiminde kullanılıp uygulamanın birden fazla hastalığı teşhis etmesi sağlanabilir. Bu özelliği sayesinde kullanılan teknik esnektir ve zamanla hem başarıyı hem de uygulama alanı genişletilebilir.

5.2. Öneriler

Bu çalışma sonucunda ülkemizde Tüberküloz hastalığının teşhisinde Yapay Zekâ Tekniklerinden yararlanılması konusunda yeterli çalışma yapılmadığı görülmüştür. Ayrıca bu tür sistemlerin geliştirilmesinde kullanmak üzere veri bulmak oldukça güçtür.

THT uygulamasının temelinde kullanılan teknikler birçok bilim dalında olduğu gibi tıp alanında da kullanılabilmesi, bu tekniklerin esnekliğini desteklemektedir. Bunun yanında Yapay Sinir Ağlarının öğrenme ve genelleme yeteneği bir kez daha bu uygulama sayesinde görülmüştür.

THT uygulaması yapısı itibarıyla tüberküloz hastalığının ön tanı ve teşhisinde hızlı ve başarılı bir teknik olarak öne çıkmaktadır. Bu sayede bu tür bir hastalığın teşhisinde çabukluk ve hassasiyet sağlanmış olur. Uygulamanın esnekliği sayesinde farklı hastalık verileriyle de çalışılarak uygun sonuçlar elde edilebilir ve bu hastalık tanılarının konulmasında hızlı ve etkin bir çözüm olarak kullanılabilir.

Bu sistemin kullandığı tekniklerin esnekliği sayesinde tıp alanında çeşitli çalışmalara zemin olabileceği düşünülmektedir.

Ayrıca gelecek çalışmalarda tamamen deneme yanılma yöntemiyle bulunan eğitim parametrelerinin bulunması için bir algoritma geliştirilmesi ve eğitim sürecinin paralel bilgisayarlar üzerinde tamamlanması için mevcut algoritmada iyileştirmeler yapılması planlanmaktadır.

KAYNAKLAR

- [1] PERSIDIS, A., Medical Expert Systems: An Overview. Journal of Management in Medicine, 5(3): Abstract, 1991.
- [2] ER, O., Esnek Hesaplama Ve Biyobilişim Teknikleri İle Bir Klinik Karar Verme Simülatörünün Oluşturulması, Doktora Tezi, SAÜ Fen Bilimleri Enstitüsü, 2009
- [3] 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).
- [4] THORESN, T., MAKELA, M., Professional Practice; Theory and Practice of Clinical Guidelines Implementation. DSI, Copenhagen Denmark. Cdc, National Vital Statistics Report, 1999; 48: 11.
- [5] NIEDERMAN, F., Date Warehousing at An Urban Hospital. Journal of Data Warehousing, 1997; 1: 15-27.
- [6] Türkiye Ulusal Verem Savaşı Dernekleri Federasyonu, http://www.verem.org.tr/pdf/kisa_bilgi.pdf (Son erişim: 07 Mayıs 2009)
- [7] GOLDBERG, D.E., (1989) Genetic Algorithms in Search, Optimization and Machine Learning, Addison-Wesley, USA.
- [8] 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.
- [9] 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.
- [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] 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.
- [14] 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.
- [15] 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
- [16] "Verem, Tuberculosis", NSW HEALTH, [DOH-7600], Temmuz 2005
- [17] ÖZKARA, Ş., "Türkiye’de Tüberkülozun Kontrolü İçin Başvuru Kitabı", T.C. Sağlık Bakanlığı Verem Savaş Dairesi Başkanlığı, Ankara Nisan 2003.
- [18] Sağlık’ım, <http://www.saglik.im/tuberkuloz-verem/> (Son erişim: 25 Nisan 2009)
- [19] "Tüberküloz Hastalarının Tanı-Tedavi Ve İzlenmesi", T.C. Sağlık Bakanlığı Verem Savaşı Daire Başkanlığı, Ankara, 1998
- [20] Sağlık’ım, <http://www.saglik.im/tuberkuloz-basilinin-ozellikleri/> (Son erişim: 25 Nisan 2009)
- [21] 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.
- [22] 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.

- [23] DUGUID, J., Expulsion of pathogenic organisms from the respiratory tract. *Br Med J* 1946; 1:245.
- [24] 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.
- [25] LOUDON, R.G., ROMANS, W.E., Cough frequency and infectivity in patients with pulmonary tuberculosis. *Am Rev Respir Dis* 1969; 99:109-111.
- [26] 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.
- [27] 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.
- [28] 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.
- [29] KIRKIL, G., ÖZEL, E, TURGUT, T., DEVECİ, F., MUZ, H., “Akciğer Tüberkülozlu Olgularda Mevcut Risk Faktörlerinin Değerlendirilmesi”, Fırat Üniversitesi Tıp Fakültesi Göğüs Hastalıkları Anabilim Dalı, *Akciğer Arşivi*: 2006; 7: 30-33
- [30] Dr. ARSLAN, Z., “Tüberküloz Hastası İle Temaslı Çocuklarda, INH Profilaksisinin Elispot Yöntemi İle Değerlendirilmesi”, Uzmanlık tezi, Heybeliada Sanatoryumu Göğüs Hastalıkları ve Göğüs Cerrahisi Eğitim ve Araştırma Hastanesi, İstanbul, 2005
- [31] GÜMÜŞLÜ, F., ÖZKARA, Ş., ÖZKAN, S., BAYKAL, F., GÜLLÜ, Ü., *Türkiyede verem savaşı 2008 raporu*
- [32] “Türkiyede Verem Savaşı 2007 Raporu” Türkiye Cumhuriyeti Sağlık Bakanlığı Verem Savaşı Dairesi Başkanlığı, Ankara 2007
- [33] SMITH, A. E., X-Bar and R Control Chart Interpretation Using Neural Computing, *International Journal of Production Research*, 32 (2), 309-320, 1994
- [34] CİVALEK, Ö., ÜLKER, M, “Dikdörtgen Plakların Doğrusal Olmayan Analizinde Yapay sinir Ağı Yaklaşımı”, *IMO Teknik Dergi*, 3171-3190, 2004

- [35] ÖZTEMEL, E., Yapay Sinir Ağları, Papatya Yayıncılık, 2003.
- [36] ALLAHVERDİ, N., Yapay Sinir Ağları, Yayınlanmamış Ders Notları, Selçuk Üniversitesi, Konya, 2003
- [37] SAĞIROĞLU, Ş., BEŞDOK, E., ERLER, M., Mühendislikte Yapay Zeka Uygulamaları-I, Ufuk Kitap Kırtasiye-Yayıncılık Tic. Ltd., 2003.
- [38] KARLIK, B., Çok Fonksiyonlu Protezler İçin Yapay Sinir Ağları Kullanılarak Miyoelektrik Kontrol, İstanbul,1994
- [39] AUGER, M., Detection of Laser-Welding Defects Using Neural Networks, A Thesis for The Degree Of Master of Science (Engineering), Queen's University, 2001
- [40] Yrd. Doç. Dr. TAŞGETİREN, M. F., Sakarya Üniversitesi, Endüstri Mühendisliği Bölümü.
http://www.bilimbilmek.com/sayfa/Fatih_Tasgetiren-Cok_Katmanli_Yapay_Sinir_Aglari.html (Son erişim: 07 Mayıs 2009)
- [41] Stent, 1973; Changeux and Danchin, 1976
- [42] T.C. Kahramanmaraş Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı Güler Elbistanlı yüksek lisans tezi Şubat – 2007
- [43] ÖZTEMEL, E., “Bilgisayarda öğrenme ve Yapay Sinir Ağları”, Otomasyon, s. 134-140, Mart 1996.
- [44] YENİAY, Ö. (2001), “An Overview of Genetic Algorithms”, Anadolu Üniversitesi Bilim ve Teknoloji Dergisi, Cilt: 2, Sayı: 1, s. 37-49.
- [45] İŞLİER, A.A. (2001), “Üretim Hücrelerinin Bir Genetik Algoritma Kullanılarak Oluşturulması”, Anadolu Üniversitesi Bilim ve Teknoloji Dergisi, Cilt: 2, Sayı: 1, s. 137-157.
- [46] ENGİN, O. (2001), Akış Tipi Çizelgeleme Problemlerinin Genetik Algoritma ile Çözüm Performansının Arttırılmasında Parametre Optimizasyonu, İTÜ, Fen Bilimleri Enstitüsü, Yayınlanmamış Doktora Tezi.
- [47] 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.
- [48] FİĞLALİ, A. ve ENGİN, O. (2002), “Genetik Algoritmalarla Akış Tipi Çizelgelemede Üreme Yöntemi Optimizasyonu”, İTÜ Dergisi, s. 1-6.

- [49] YEO M.F. ve AGYEL, E.O. (1996), "Optimizing Engineering Problems Using Genetic Algorithms", Engineering Computations, Volume: 15, Number: 2, s. 268-280.

- [50] 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.

- [51] KARR, C.L. ve FREEMAN, M.L. (1999), Industrial Applications of Genetic Algorithms, CRC Press, USA.

ÖZGEÇMİŞ

1984 Düzce doğumlu olan Erhan ELVEREN, ilk, orta ve lise eğitimini Düzce’de tamamlamıştır. 2002 yılında Eskişehir Osmangazi Üniversitesi Mühendislik Mimarlık Fakültesi Bilgisayar Mühendisliği bölümünü kazanarak üniversite eğitimine başlamıştır. 2007 yılında bu bölümden mezun olarak Mühendis ünvanı almıştır. Aynı yıl Sakarya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar ve Bilişim Mühendisliği bölümünde yüksek lisans yapmaya başlamıştır.