

EEG SİNYALLERİNE YAPAY ZEKA TEKNİKLERİNİN UYGULANMASI

SUNAY MUTLU

ELEKTRONİK-BİLGİSAYAR EĞİTİMİ

YÜKSEK LİSANS TEZİ


GAZİ ÜNİVERSİTESİ

BİLİŞİM ENSTİTÜSÜ

TEMMUZ 2008

ANKARA

Sunay MUTLU tarafından hazırlanan EEG SİNYALLERİNE YAPAY ZEKA TEKNİKLERİNİN UYGULANMASI adlı bu tezin Yüksek Lisans tezi olarak uygun olduğunu onaylarım.


Yrd. Doç. Dr. M. Rahmi CANAL
Tez Yöneticisi


Bu çalışma, jürimiz tarafından oy birliği ile Elektronik-Bilgisayar Eğitimi Anabilim Dalında Yüksek lisans tezi olarak kabul edilmiştir.

Başkan: : Prof. Dr. İnan GÜLER



Üye : Yrd. Doç. Dr. Mehmet Rahmi CANAL

Üye : Yrd. Doç. Dr. Hasan Hüseyin SAYAN



Tarih : 15/07/2008

Bu tez, Gazi Üniversitesi Bilişim Enstitüsü tez yazım kurallarına uygundur.

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada orijinal olmayan her türlü kaynağa eksiksiz atıf yapıldığını bildiririm.



Sunay MUTLU

EEG SİNYALLERİNE YAPAY ZEKA TEKNİKLERİNİN UYGULANMASI**(Yüksek Lisans Tezi)****Sunay MUTLU****GAZİ ÜNİVERSİTESİ****BİLİŞİM ENSTİTÜSÜ****Temmuz 2008****ÖZET**

Bu çalışmada EEG işareti gibi durağan olmayan rasgele işaretlerin sağlıklı ve hasta (epilepsi) hallerinde gösterdikleri farklılıklar değerlendirilip yapay sinir ağları kullanılarak bilgisayar destekli bir ortamda analiz edilmeye çalışılmıştır.

Elde edilen bulguların grafiklerinden de anlaşılacağı üzere sinir ağının sınıflandırma probleminde kullanılması başarı ile sağlanmıştır. Sinir ağının öğrenme katsayısı, aktivasyon fonksiyon değerleri gizli katman sayısı ve gizli katman nöron sayısının değişimlerine göre sinir ağının performansı değişmektedir. Bu değerler deneysel sonuçlara göre optimal duruma getirilmiştir.

Bilim Kodu : 704.3.013**Anahtar Kelimeler: EEG, Sinyal Analizi, Yapay Siniri Ağları****Sayfa Adedi : 60****Tez Yöneticisi : Yrd. Doç. Dr. M. Rahmi CANAL**

**APPLICATION OF ARTIFICIAL INTELLIGENCE TECHNIQUES TO EEG
SIGNALS**

(M.Sc. Thesis)

Sunay MUTLU

GAZI UNIVERSITY

INSTITUTE OF INFORMATICS

July 2008

ABSTRACT

In this study, it was aimed to make an analysis supported by computer by using artificial neural networks after evaluating differences in healthy and sick (epilepsy) conditions which are the signs nonstationary and random as EEG signal.

As it was understood from the discoveries' graphics which were got, it had been supplied for neural network in using classification problem successfully. Neural networks performance has been changing according to the changing of neural networks learning coefficient, activation function values, hidden layer number and hidden layer neuron number. This values had been made optimal according to experimental results.

Science Code : 704.3.013

Key Words : EEG, Signal Analysis, Artificial Neural Networks

Page Number : 60

Adviser : Asist. Prof. Dr. M. Rahmi CANAL

TEŐEKKÜR

Çalıőmalarım boyunca deęerli yardım ve katkılarıyla beni yönlendiren hocam Yrd. Doç. Dr. M. Rahmi CANAL'a yine kıymetli tecrübelerinden faydalandığım hocam Fırat HARDALAC'a, manevi desteęi ile beni hiçbir zaman yalnız bırakmayan Ayőe KARATAŐ'a ve aileme teőekkürü bir borç bilirim.

İÇİNDEKİLER

	Sayfa
ÖZET.....	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER.....	vii
ÇİZELGELER DİZİNİ.....	ix
ŞEKİLLER DİZİNİ.....	x
SİMGELER VE KISALTMALAR DİZİNİ.....	xi
1. GİRİŞ.....	1
1.1. EEG (Elektroensefalogram).....	1
2. EEG ÜZERİNE YAPILAN ÇALIŞMALARIN TARİHSEL GELİŞİMİ.....	5
3. MATERYAL VE METOT.....	7
3.1. Materyal.....	7
3.1.1. Giriş.....	7
3.1.2. Fourier temelli sinyal analiz metotlarının gelişimi.....	8
3.1.3. Fourier temelli sinyal analizi.....	8
3.1.3.1. Akan fourier dönüşümü.....	9
3.1.3.2. Kısa zaman fourier dönüşümü.....	9
3.1.3.3. Ayrık fourier dönüşümü.....	11
3.1.3.4. Hızlı fourier dönüşümü.....	13
3.1.4. Yapay zeka.....	13
3.1.5. Yapay sinir ağları.....	14
3.1.5.1. Biyolojik sinir sistemi.....	14
3.1.5.2. Biyolojik sinir ağı.....	15
3.1.5.3. Statik ve dinamik yapay sinir modelleri.....	16
3.1.5.4. Yapay sinir ağlarının özellikleri.....	22
3.1.5.5. Yapay sinir ağlarının sınıflandırılması.....	24
3.1.5.6. Tek katmanlı ve çok katmanlı ileri beslemeli yapay sinir ağları...27	27
3.1.5.7. Diğer yapay sinir ağları.....	29
3.1.6. Biyomedikal işaret islemede yapay sinir ağları.....	35
3.1.7. Nörolojide yapay sinir ağları.....	36

3.2. Metot.....	37
3.2.1.Giriş.....	37
3.2.1.1. Geriyayılım algoritması için veri hazırlanması.....	37
3.2.1.2. Düğüm ve katmanlar.....	38
3.2.1.3. Geriyayılım eğitimi ve öğrenimi.....	49
4. BULGULAR VE TARTISMA.....	43
5. SONUÇ VE ÖNERİLER.....	53
KAYNAKLAR.....	56
EKLER.....	58
EK-1 PROGRAM METNİ.....	58
ÖZGEÇMİŞ.....	60

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 1.1. EEG işaretleri, kapsadıkları frekans bantları.....	3
Çizelge 3.1. Biyolojik Sinir Sistemi ile YSA' nın Benzerlikleri.....	15
Çizelge 4.1. LM algoritması performansı.....	50
Çizelge 4.2. RP algoritması performansı.....	51
Çizelge 4.3. GDM algoritması performansı.....	52
Çizelge 5.1. Elde Edilen Sonuçlar.....	55

ŞEKİLLER DİZİNİ

Şekil	Sayfa
Şekil 1.1. İlk kaydedilen EEG sinyali.....	1
Şekil 1.2. EEG sinyalleri.....	4
Şekil 3.1. Biyolojik Sinir Sisteminin Blok Gösterimi.....	14
Şekil 3.2. Biyolojik Nöron.....	16
Şekil 3.3. Temel Statik Yapay Sinir Hücresi.....	17
Şekil 3.4. YSA'da En Çok Tercih Edilen Aktivasyon Fonksiyonları	20
Şekil 3.5. Step Fonksiyonu.....	20
Şekil 3.6. Lineer fonksiyon.....	21
Şekil 3.7. Tanjant fonksiyonu.....	22
Şekil 3.8. Sigmoid fonksiyonu.....	22
Sekil 3.9. İleri Beslemeli YSA için Blok Diyagram.....	24
Sekil 3.10. Geri Beslemeli YSA için Blok Diyagram.....	25
Şekil 3.11. Danışmanlı Öğrenme Yapısı.....	26
Şekil 3.12. Danışmansız Öğrenme Yapısı.....	26
Şekil 3.13. Takviyeli Öğrenme Yapısı.....	27
Sekil 3.14. Tek Katmanlı YSA.....	27
Şekil 3.15. Çok Katmanlı YSA.....	29
Şekil 3.16. LVQ Ağı.....	30
Şekil 3.17. Hopfield Ağı.....	31
Şekil 3.18.a). Elman Ağı.....	32
Şekil 3.18. b). Jordan Ağı.....	33
Şekil 3.19. Kohonen Ağı.....	34
Şekil 3.20. ART-1 Ağı.....	35
Şekil 3.21. Yapay Sinir Ağı Yapısı.....	41
Şekil 3.22. Çok Katmanlı Bir Ağ İçin Geriyayılım Akış Şeması.....	42
Şekil 4.1. Sağlıklı kişilerden elde edilen EEG örnekleri ve FFT sonuçları.....	45
Şekil 4.2. Hasta kişilerden elde edilen EEG örnekleri ve FFT sonuçları.....	48
Şekil 4.4. LM algoritması eğitim grafiği.....	49
Şekil 4.5. RP algoritması eğitim grafiği.....	51
Şekil 4.6. GDM algoritması eğitim grafiği.....	52

SİMGELER VE KISALTMALAR DİZİNİ

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler Açıklama

c	Öğrenme Katsayısı
f	Frekans
r	Öğrenme Fonksiyonu
S_i	Net Değeri
Δw	Ağırlıkların Değişimi
δ	Hata Sinyali
η	Delta Öğrenme Katsayısı
λ	Aktivasyon Hız Katsayısı
Δw	Bant genişliği.
Δt	Zaman açıklığı.

Kısaltmalar Açıklama

ADALINE	Uyarlanabilir Doğrusal Nöron (Adaptive Linear Neuron)
AFD	Ayrık Fourier Dönüşümü.
AR	Otoregresif (Auto Regressive)
ART	Uyarlanabilir Rezonans Teori (Adaptive Resonance Theory)
BMS	Bulanık Mantık Sistemleri
BSA	Bulanık Sinir Ağlar
CGA	Conjuge Gradient Algoritması
D	Eğitici Bilgi
E	Hata Fonksiyonu
EEG	Elektroensefalogram
EP	Uyarılmış Potansiyel
FD	Fourier Dönüşümü
FFT	Hızlı Fourier Dönüşümü (Fast Fourier Transform)

GAD	Genetik Algoritma Destekli Sistemler
GAT	Genetik Algoritma Temelli Sistemler
GDM	Gradient Descent With Momentum Algoritması
LMS	En Küçük Ortalamalı Kareler (Least Mean Square)
LQ	Levenberg-Marquardt Algoritması
MLP	Çok Katmanlı Algılayıcı (Multi Layer Perceptron)
MOS	Metal Oksit Yarıiletken (Metal Oxide Semiconductor)
O	Çıkış Fonksiyonu
RP	Resilient Backpropagation Algoritması
SBA	Sinir Bulanık Ağlar
SOM	Kendi Kendine Ayarlanabilir Harita (Self Organizing Map)
STFT	Kısa Zamanlı Fourier Dönüşümü (Short Time Fourier Transform)
T	Periyot
W	Ağırlık Vektörü
X	Giriş Vektörü
YS	Yapay Sinir
YSA	Yapay Sinir Ağı
YSAS	Yapay Sinir Ağı Sistemleri
Z	Empedans


1. GİRİŞ

Tıbbi teşhis ve arařtırmalarda kullanılan EEG (Elektroensefalogram) iřaretleri beynin sinirsel faaliyeti sonucu elde edilen biyoelektriksel iřaretler olup frekans bileřenleri son derece önemlidir. Bu iřaretlerde beynin fonksiyonları ile ilgili ok miktarda bilgi saklıdır. Bu bilgilerin kullanılabilmesi iin sinyal iřleyicileri ok eřitli arařtırmalar yapmaktadırlar. Bazı patolojik belirtiler zaman alanında fark edilmeyebilir. Nörologlar genellikle zaman alanına göre teşhis yapmaktadırlar. Son zamanlarda bilgisayarların bu sinyalleri kayıt etmeleri ve spektral analiz yöntemlerinin geliştirilmesi bu patolojik belirtilerin bulunmasında frekans bileřenlerinden faydalanılmayı mümkün kılmıştır [1].

Bu alıřmada EEG'nin spektral analizine ek olarak, sınıflandırma problemlerindeki başarılı uygulama yöntemlerinden dolayı yapay zeka uygulamalarının bir eřidi olan yapay sinir ağıları (YSA) kullanılmıştır. YSA'nın öğrenme özelliđi, arařtırmacıların dikkatini eken en önemli özelliklerinden birisidir. ünkü herhangi bir olay hakkında girdi ve ıktılar arasındaki iliřkiyi, dođrusal olsun veya olmasın, elde bulunan mevcut örneklerden öğrenerek daha önce hi görülmemiř olayları, önceki örneklerden ađrıřım yaparak olaya özümler üretebilme özelliđi YSA'daki zeki davranışın da temelini teşkil eder[2].

1.1. EEG (Elektroensefalogram)

Caton 1875 tarihinde hayvanlar üzerinde yaptığı deneyler sonucunda ilk defa, beyinde bir takım elektriksel faaliyetlerin varlığını keřfetmiştir. 1929 yılında ilk defa, Hans Berger, kafaya yerleřtirilen elektrotlar ve bunlara bađlı bir galvanometre yardımıyla insan beyinde elektriksel aktivitenin varlığını ortaya koymuştur. Berger, (1930)' da Elektroensefolagram adı verilen bu dalgaların gözün açılıp kapanmasıyla deđiřtiđini ortaya koymuştur[1].



řekil 1.1. İlk kaydedilen EEG sinyali

Elektronikteki gelişmelerle birlikte EEG işaretlerinin varlığı bilimsel bir şekilde ortaya konulmuş ve 1934 yılında Adrian ve Matthews, elektrotlarla alınan EEG işaretlerini kuvvetlendirip kaydedilmesini sağlamışlardır. 1939 yılında P. A. Davis, uyanık bir insanın EEG'sinde, sese karşı uyarılan yanıtların (EP) olduğunu bulmuştur. H. A. Davis ve arkadaşları aynı yıl, aynı olayın uyuyan insanda da meydana geldiğini göstermişlerdir. İkinci dünya savaşından sonra, elektronik ve bilgisayarlar alanlarında meydana gelen büyük gelişmelerin olumlu sonuçları, bu alanda da kendisini göstermiş ve EEG' nin klinik uygulamaları geliştirilerek tanımı üzerinde yapılan araştırmalar olumlu sonuçlar vermiştir [1]. EEG' nin çok karmaşık bir değişim şekli vardır ve yorumlanması oldukça güçtür. Yüzeiden ölçülen EEG potansiyelleri, alttaki birçok noktadan ve serebral korteksin oldukça geniş bir bölgesinden gelen potansiyellerin toplamından oluşur. Deneyler, EEG frekansının kişinin zihin faaliyeti ile değiştiğini göstermiştir. Bu durum, beynin tabii ve boşta çalışma frekansı gibi bir senkronizasyon durumunu göstermektedir. Kişi uyanır uyanmaz veya düşünmeye başlarken alfa ritmi kaybolur ve yerine senkronize olmayan biçimde, genellikle beta bandında bir ritim oluşmaktadır. Günümüzde, beyinde bu işlemi yapan mekanizmayı bulma üzerine pek çok araştırma yapılmaktadır. EEG işaretlerinin frekans bileşenleri oldukça önemli olduğu gibi, farklı bölgelerden alınan benzer EEG işaretleri arasındaki faz ilişkileri oldukça ilgi çekicidir. Bu tip bilgiler, EEG' nin kaynağının incelenmesinde çok faydalı olup beyin çalışması ile ilgili ilave bilgiler elde edilmesini sağlar. Kafa üzerinden algılanan EEG' lerin genliği tepeden tepeye 1-100 μ V ve frekans bandı ise 0.5-100 Hz' dir. Ölçümler beyin üzerinden doğrudan alındığı takdirde, genlik 10 kat daha artar. EEG' de oluşan farklı frekansların oluşum mekanizmaları henüz tam olarak anlaşılamamıştır. EEG, EKG ve EMG işaretlerinde olduğu gibi şekil bakımından değil, kapsadığı frekanslara göre değerlendirilmektedir. EEG işaretleri periyodik değildir; genlik, faz ve frekansları sürekli değişir. Bu nedenle anlamlı bir data elde etmek için ölçümlerin oldukça uzun bir sürede yapılması gerekir. EEG işaretlerinin ana frekansı ile beyin aktivitesi yakından ilişkilidir. Aktivite ile frekans birlikte yükselir. Tablo-1.1'de , EEG işaretleri, kapsadıkları frekans bantları ve bu bantlara verilen özel isimler ile birlikte verilmiştir[1].

Çizelge 1.1. EEG işaretleri, kapsadıkları frekans bantları

Delta (δ)	0,5 - 3,5 Hz
Teta (θ)	4 – 7 Hz
Alfa (α)	8 – 12 Hz
Beta (β)	13 – 22 Hz
Gamma (λ)	22 – 30 Hz

Alfa Dalgaları: 8-12 Hz arasındaki beyin dalgalarıdır. Uyanık normal ve sakin kimselerde görülür. Yoğun şekilde oksipital bölgede ortaya çıkar, genlikleri 5 μ V kadardır. Uyku durumunda yok olurlar. Uyanık kişi dikkatini özel bir şeye yöneltirse α dalgaları yerine, daha yüksek frekanslı, fakat düşük genlikli EEG işaretleri (β) dalgaları meydana gelir.


Beta Dalgaları: Frekansları 12 Hz' in üzerindeki beyin dalgalarıdır. 25 Hz' e ve nadir hallerde 50 Hz' e kadar uzanırlar. Saçlı derinin parietal ve frontal bölgelerinde belirgin olarak kaydedilebilir. Beta-I (BI) ve Beta-II (BII) diye ikiye ayrılırlar. BII dalgalarının frekansı, BI' inkinin iki mislidir ve α dalgalarında olduğu gibi zihinsel aktivitenin artması ile ortadan kalkarlar ve yerlerine düşük genlikli asenkron işaretler oluşur. BII dalgaları, merkezi sinir sisteminin kuvvetli aktivasyonunda veya gerginlik hallerinde ortaya çıkar.

Teta Dalgaları: 4-7 Hz arasındaki dalgalarıdır. Özellikle, çocuklarda parietal ve temporal bölgelerde ortaya çıkarlar. Yetişkinlerde de duygusal gerginlik, düş kırıklığı durumlarında ortaya çıkarlar. Genlikleri 100 μ V (p-p)' den küçüktür.

Delta Dalgaları: 3.5 Hz' in altındaki beyin dalgalarıdır. Bazı durumlarda 1 Hz' in altına da düşer. Süt çocuklarında ve ağır organik beyin hastalıklarında görülür. Genlikleri 100 μ V(p-p)' den küçüktür.

Gamma Dalgaları: Bazı araştırmacılar tarafından kullanılmaktadır. Bazı araştırmacılar da bu dalgaların yerine, BII dalgalarını kullanmaktadır. Genlikleri, 2 μ V (pp)' den daha küçüktür.

Kafanın merkezinde, genlikleri daha büyüktür. Uykunun karakteristik belirtisini taşırlar.



Şekil 1.2. EEG sinyalleri

2. EEG ÜZERİNE YAPILAN ÇALIŞMALARIN TARİHSEL GELİŞİMİ

Sweldens (1994), çalışmasında bir fonksiyonun dalgacık sabitlerini bu fonksiyonun örneklerinden hesaplanması üzerine interpolasyon, quadrature formül ve filtreleme metotlarıyla uygulamalar sunmuştur[3].

Anderson (1995), çalışmasında EEG işaretleri yardımıyla zihinsel durumun tanımlanması amacıyla Yapay Sinir Ağları kullanmışlardır[3].

Grap (1995), makalesinde geleneksel Fourier metotları, Dalgacık teorisi ve analizlerinin gelişimini inceleyerek sinyal işleme alanı temelli çeşitli karşılaştırmalar yapmış, ayrıca henüz gelişen dalgacık analizinin uygulama alanlarından bahsetmiştir

Kalaycı ve Özdamar (1995), giriş ve çıkış datasının sinyalin karakteristik özelliklerini gösterebilecek şekilde işlenebilmesi durumunda Yapay Sinir Ağlarının daha iyi sonuç verdiğini gösteren bir çalışma yapmışlardır[2].

Prodhan (1996), LVQ(Learning Vector Quantization) temelli bir Yapay Sinir Ağı kullanarak nöbet aktivitesinin sınıflandırılması için bir ön çalışma yapmışlardır.

Dograhmi (1997), çalışmasında EEG kayıtlarının spektral analiz temelli sınıflandırılmasını amaçlayarak elektrot sayısının ve uygulanan spektral analiz yöntemi özelliklerinin bir sınıflandırıcı gibi kullanılması konusunu incelemişlerdir [2].

Mckeown ve ark. (1997), EEG işaretlerinin analizi ve uyarı değişikliklerinin bulunması amacıyla istatistiksel yöntemler kullanarak bir çalışma yapmışlardır [3].

Jung (1997) çalışmasında uyku ve uyanıklık durumlarının Yapay Sinir Ağları ile sınıflandırılmasında, ham EEG işaretlerinden ziyade Fourier Dönüşümü alınmış EEG'nin daha uygun sonuçlar verdiğini gözlemlemişlerdir [2].

Miner (1998), bu raporda geleneksel Fourier metotları, Dalgacık teorisi ve analizlerinin gelişimini inceleyerek sinyal işleme alanı temelli çeşitli karşılaştırmalar yapılmış, ayrıca sürekli ve ayrık dalgacık analizi algoritmaları verilmiştir [3].

Torrence (1998), çalışmalarında yaygın olarak kullanılan temel dalgacık fonksiyonları sınıflandırılmış, özellikleri verilerek ayrık zaman diziler için sürekli dalgacık dönüşümü yaklaşıklığı verilmiştir. Sonlu uzunlukta zaman serilerine Pencerelemiş Fourier ve Dalgacık dönüşümü uygulayarak istatistik önem ile güvenilirlik aralığı analizleri yapmışlardır [3].

Suleesathira (2000), deterministik durağan olmayan sinyallerin gösteriminin ayrık evrimsel dönüşümle yapılabilirliği konusunda çalışmışlardır [3].

Girault (2000), çalışmalarında durağan olmayan benzetim ve gerçek sinyaller üzerinde FFT, AR, Zamanla değişen parametrik model yaklaşımı metotlarını kullanmışlar, frekans kestirimi için de karşılaştırma maksadıyla spektral ağırlık merkezi hesabıyla değerlendirmelerde bulunmuşlardır [3].

Guler İ. (2001) çalışmasında EEG sinyallerini AR (autoregressive method) kullanarak analiz etmiştir. Bu çalışmada parametreler maksimum olabilirlik kestirimi (MLE) yöntemi kullanılarak belirlenmiştir [4].

Kıymık M. (2004), gerçek zamanlı uygulamalar için EEG sinyallerindeki epileptik sürecin belirlenmesinde STFT (Short Time Fourier Transform) ve Dalgacık Analiz yöntemlerini kapsayan bir çalışma yapmışlar ve bu çalışmada Dalgacık Dönüşümü'nün diğer spektral analiz yöntemi olan STFT' ye oranla daha başarılı sonuçlar verdiğini göstermişlerdir [3].

3. MATERYAL VE METOT

3.1. Materyal

3.1.1. Giriş

Bu bölümde sinyal analiz yöntemlerinin gelişimine değinilerek tez çalışmasında kullanılan yöntem hakkında ayrıntılı bilgi verilecektir. Sınıflandırma probleminin, Yapay Zeka yazılımlarından biri olan Yapay Sinir Ağı kullanarak çözümü amaçlandığından YSA hakkında bilgi verilerek YSA' nın temelleri ayrıntılı bir biçimde ele alınacaktır. Kullanılan materyaller hakkında bilgi verilecektir.

EEG işaretlerinde beyin fonksiyonlarıyla ilgili çok miktarda bilgi saklıdır. Bu bilgilerin tıbbi araştırmalarda ve hastalık teşhisinde kullanılabilmesi için, modern parametrik yöntemlerle gerçek zamanda spektral analizinin gerçekleştirilmesi ve otomasyona geçilmesi gerekmektedir. Sinyallerin analiz edilmesi direk sinyalin kendisi veya sinyalin gösteriminin başka boyutlara (zaman, frekans, zaman-ölçek...v.b.) taşınarak gerçekleştirilmesiyle yapılmaktadır. Amaç; sinyalin bilgi kaybına uğratılmadan bu boyutlardan birisine dönüşümü yapılarak işlenmemiş haldeki verilerden sağlıklı seçilemeyen anlamlı detay bilgilerine ulaşmaktır [5].

EEG sinyallerinin analiz edilmesi için öncelikle dönüşüm işlemine ihtiyaç duyulur. Her hangi bir sinyalden daha fazla bilgi almak için matematiksel dönüşüm işlemi uygulanır. Mevcut bir çok dönüşüm teknikleri farklı tip sinyaller ve amaçlar için kullanılmaktadır. Hilbert, Kısa Zamanlı Fourier Dönüşümü (KZFD) , Zak Fourier, Running Fourier, Wigner, Radon ve Wavelet dönüşümü gibi matematiksel dönüşümler kullanılabilir. Her bir dönüşüm tekniğinin kendine göre avantajları ve dezavantajları vardır. Bunlardan en eski olanlardan biriside Fourier Dönüşüm tekniğidir [6].

Çoğu sinyaller zaman alanında gösterilir. Zaman alanında bir sinyalin çizilmesi zaman-genlik gösterimi ile ifade edilir. Bu gösterim genellikle sinyal işlemede iyi bir gösterim olmamaktadır. Sinyallerin yapılarına bağlı olmakla birlikte çoğu kez ayırt edilebilir önemli bilgiler frekans bileşenlerinde gizli tutulurlar [6].

Fourier Dönüşümü sinyalin de mevcut olan frekans bileşenlerini bize verir. Fakat bu tip bir dönüşüm frekansların hangi zaman aralığında var olduğunu gösteremez. Bu bilgiler sinyal şayet durağan ise gerekli değildir. Çünkü durağan sinyallerde zamana göre frekans değişmez. Şayet sinyalin zamana göre frekansı değişiyorsa bunlara durağan olmayan sinyaller denir.

Fourier Dönüşümü durağan olmayan sinyallerde ne tür bir spektral bileşen olduğunu öğrenmek için kullanılabilir, fakat nerede oluştuğunu söyleyemez [6].

3.1.2. Fourier temelli sinyal analiz metotlarının gelişimi

19.Yüzyılda Fourier herhangi bir periyodik fonksiyonun sonsuz sayıdaki kompleks üstel fonksiyonların toplamıyla ifade edilebileceğini söylemiştir. Fourier temelli dönüşüm teknikleri daha sonraki yıllarda Ayrık Fourier Dönüşümü (AFT) ve Hızlı Fourier dönüşümü (FFT) algoritmalarının geliştirilmesiyle bilgisayarlarda veri işleme için önemli bir basamak atlanmıştır [6].

Denis Gabor 1946 yılında Gabor Dönüşümü olarak bilinen Fourier temelli analiz yöntemini sunmuştur. Bu metod da pencereleme yöntemini kullanır ki pencere fonksiyonu Gauss Hata fonksiyonudur, işaretin küçük bir parçasını zaman tanım aralığında ele alınmış, işaret zaman ve frekansın fonksiyonu olarak iki boyutta ifade edilmiştir.

Böylece durağan olmayan sinyallerin işlenmesi daha sağlıklı hale gelmiştir. Gabor dönüşümü bugün Kısa Zaman Hızlı Fourier Dönüşümü (KZFD) olarak yöntemin kaynağı olarak görülmektedir [6].

Bu şekilde Fourier serisi yaklaşımıyla başlayan sinyal frekans analizi kavramı günümüze değin ölçek analizi kavramına ve bununla sıkı sıkıya bağlı dalgacık dönüşümüne kadar gelişmiştir.

Ölçek analizi, basitçe bir $f(x)$ fonksiyonunun ölçeği değişen matematiksel yapılar oluşturarak analiz edilmesidir. Önce basit bir temel fonksiyon tasarlanır, sonra bir miktar ötelenir ve ölçeği değiştirilir. Bu yapı her hangi bir fonksiyonun yaklaşımında kullanılır ve aynı işlemler tekrar edilir. Böylelikle yeni yaklaşımlar aynı basit yapısal temel fonksiyondan türetilerek elde edilir. Bu ölçek analizi dizisi, sinyalin farklı ölçeğe sahip ortalama dalgalanmalarını ölçtüğünden gürültüye de en az duyarlıdır.

3.1.3. Fourier temelli sinyal analizi

19.Yüzyılda Fourier herhangi bir periyodik fonksiyonun sonsuz sayıdaki kompleks üstel fonksiyonların toplamıyla ifade edilebileceğini söylemiştir. Fourier dönüşümü sonuçları frekans bileşenlerinin yerel zaman, başlangıç veya bitiş bilgileri hakkında kesin veriler sağlamaz çünkü bu bilgi Fourier spektrumu boyunca yayılmıştır. Yani Fourier dönüşümü ancak genel bir bakış sağlar. Bunun sebebi Fourier temel fonksiyonlarının (sinüs ve kosinüs) tam dayanaklı olmamalarıdır. Bundan dolayı durağan sinyallere uygulanmalarında en iyi

sonuç verir. Eşitlik 3.1' de görüldüğü gibi herhangi bir t_1 veya t_2 anı integrale aynı etkide bulunacaktır [6].

$$X(f) = \int_{-\infty}^{\infty} x(t) e^{-j\omega t} dt \quad (3.1)$$

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} X(f) e^{j\omega t} df \quad (3.2)$$

3.1.3.1. Akan fourier dönüşümü

Bir $f(t)$ sinyalinin Akan Fourier Dönüşümü ifadesi; c verilen bir sabit olmak üzere Eşitlik 3.3 ile verilir. $F(t, \tau)$, $f(t)$ sinyalinin τ dilimine karşılık gelen $f(t+\tau)$ sinyalinin Fourier dönüşümüdür. Böylelikle durağan olmayan sinyaller için spektrumun değişimi sinyalin durağan kabul edildiği τ dilimleri ile belirlenebilmektedir [5].

$$F(t, \omega) = \int_{-c}^c f(t+\tau) e^{-j\omega t} d\tau = e^{j\omega} \int_{t-c}^{t+c} f(a) e^{-j\omega} da \quad (3.3)$$

$F(t, \omega)$ nin Ters Dönüşümü ifadesi de $\omega_0 = \frac{\pi}{c}$ olmak üzere ;

$$f(t) = \frac{1}{2c} \sum_{m=-\infty}^{\infty} F(t, m\omega_0) \quad (3.4)$$

eşitliği ile verilir.

3.1.3.2. Kısa zaman fourier dönüşümü

Daha önce FD' nin durağan olmayan sinyaller için elverişli olmadığı ifade edilmişti. Denis Gabor, 1946 yılında pencereleme yöntemini kullanarak, işaretin küçük bir parçasını zaman tanım aralığında ele almış, işareti zaman ve frekansın fonksiyonu olarak iki boyutta ifade etmiştir. Bu dönüşüm yönteminde işaretin belirli bir kesiminin durağan olduğu kabul edilebilecek bir pencereden geçirilir ve yerel bir frekans parametresiyle FD işlemi gerçekleştirilir. KZFD ile FD arasında çok az bir fark bulunur. KZFD' de sinyal küçük çerçeveler bölünür ve bu çerçeve anlarında sinyalin durağan olduğu kabul edilir. Durağanlığın geçerli olduğu bu çerçeveler sinyalin bir pencere fonksiyonu ile çarpılmasıyla elde edilir. FD'nin yerelleştirilmesi fikrine dayanan bu teknik ilgilenilen yerde uygun bir pencere seçilerek dönüşüm işlemi gerçekleştirilir[6].

Durağan olmayan sinyallerin spektral analizi çok iyi zaman ve frekans çözünürlüğü sunması gereken yetenekli işlemlere ihtiyaç duyar.

KZFD temel bir pencere fonksiyonundan zaman alanında kaydırma ve frekans parametreleri olmak üzere iki ayrı şekilde türetilir. Burada kullanılan pencere fonksiyonu Eşitlik 3.5 ile ifade edilmiştir. Pencere fonksiyonu sonlu enerjiye sahip olması ve entegralinin alınabilmesi gerekmektedir. KZFD yönteminde zaman ekseninde bir τ noktasına $w(t)$ pencere fonksiyonunu yerleştirilerek pencerelenmiş fonksiyonun Fourier Dönüşümü gerçekleştirilir. Daha sonra pencere kaydırılır ve tekrar Fourier dönüşümü alınarak işleme devam edilir. Bu yöntemin matematiksel ifadesi Eşitlik 3.6'da ifade edilmiştir [6].

$$g_{w,\tau}(t) = e^{j\omega t} w(t - \tau) \quad (3.5)$$

$$KZFD(w, \tau) = \int_{-\infty}^{\infty} f(t) w(t - \tau) e^{-j\omega t} dt = \langle g_{w,\tau}(t), f(t) \rangle \quad (3.6)$$

KZFD' deki $f(t)$ fonksiyonu tekrar elde edilebilir özelliktedir. Bu durum Eşitlik 3.7 ile gösterilmiştir [7].

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} KZFD(w, \tau) g_{w,\tau}(t) dw d\tau \quad (3.7)$$

KZFD' nin zaman çözünürlüğü pencere fonksiyonu zaman genişliği tarafından belirlenir dolayısıyla spektrum sonlu çözünürlükle elde edilir. KZFD Pencere fonksiyonun bant genişliği ile zaman genişliği çarpımı sabittir ve sadece kullanılan pencere fonksiyonun şekline bağlıdır dolayısıyla sabit çözünürlükle dönüşüm elde edilebilir [7].

Dolayısıyla KZFD' de uygun bir pencere kullanılmalıdır. Dikdörtgensel bir pencere zayıf bir frekans çözünürlüğü doğurur. Örneğin üçgensel bir pencere $1/w^2$ 'ye göre azalan bir frekans spektrumu verir ve dikdörtgene göre daha iyi bir pencere sayılır. Fakat daha iyi pencereler sinyal analizcileri tarafından geliştirilmiştir. Bunlardan birisi olan Hanning pencere ifadesi Eşitlik 3.8 ile gösterilmiştir [5].

$$w(t) = \begin{cases} [1 + \cos(2\pi t/T)]/2 & ; t \in [-T/2, T/2] \\ 0 & ; \text{diğer} \end{cases} \quad (3.8)$$

KZFD' nin diğer bir ismi de Gabor Dönüşümüdür. Gabor tarafından kullanılan klasik pencerelerden biriside Gaussian penceresidir (Eşitlik 3.9).

$$w(t) = \beta e^{-\alpha^2 t^2} \quad \alpha, \beta > 0 \quad (3.9)$$

Burada α genişliği, β ise normalizasyon faktörünü göstermektedir. Bu metodun başlıca problemi pencere boyutunun sabit olmasıdır. KZFD zaman ve frekans bilgilerini kapsamı

yönüyle önemli olsa bile seçilen pencere $w(t)$ fonksiyonunun bütün frekanslar için sabit olması bir dezavantajdır. Bir çok işaret daha esnek yaklaşımlara yani zaman veya frekans hakkında daha çok bilgi alabilmek için değişebilen pencereleme tekniklerine ihtiyaç duymaktadır. Pencere fonksiyonu $w(t)$ sabit zaman-frekans çözünürlüğü vererek KZFD' yi sınırlar. Bu sınırlama Heisenberg belirsizlik ilkesi olarak adlandırılır ve matematiksel olarak Eşitlik 3.10 ve 3.11'de ifade edilmiştir [6].

$$W(t) \leftrightarrow \Psi(w) \quad (3.10)$$

$$\Delta t \Delta w \geq \frac{1}{2} \quad (3.11)$$

Burada Δw bant genişliği ve Δt zaman açıklığı şeklinde ifade edilirse, matematiksel olarak Eşitlik 3.12 ve 3.13'de ifade edilen sınırlamalarla karşılaştırılır.

$$\Delta t^2 = \frac{\int t^2 |W(t)|^2 dt}{\int |W(t)|^2 dt} \quad (3.12)$$

Ayrıca sinyalin pencerelenmesine dayanan metotlarda Gibbs olayı ile karşılaştırılır. Gibbs olayı analizin doğruluğunun kaybına neden olur [6].

$$\Delta w^2 = \frac{\int w^2 |\Psi(w)|^2 dw}{\int |\Psi(w)|^2 dw} \quad (3.13)$$

3.1.3.3. Ayrık fourier dönüşümü

Fonksiyonların otomatik olarak tanımlı olduğu hallerde Fourier dönüşümleri rahatlıkla hesaplanabilir. Ancak uygulamada sinyallerin kesin fonksiyonel ifadeleri yoktur ve işlenmeleri için analog sinyallerden örneklenmiş sınırlı sayıda sayısal ayrık dizileri mevcuttur. Bu yüzden daha önce bahsedilen şekilde Fourier dönüşümleri hesaplanamaz. Ayrıca bütün frekans boyutunun analog olarak gösterimi sonsuz sayıda örneklenmiş işareti gerektirmektedir bu ise uygulamada mümkün değildir. Sayısal işaretler için Fourier dönüşümünün hesaplanması için belirli sınırlamalı içindeki yaklaşıklıklarla verilebilir. Bir $f[k]$ ayrık dizisinin N örneği için tanımlanan bu yeni dönüşüm Ayrık Fourier dönüşümü (AFD) olarak adlandırılır [6].

Tersi de alınabilen bu dönüşümün önemli özellikleri vardır. Ayrık Fourier Temelli dönüşümler, dizinin periyodik olduğunu kabul ederler dolayısıyla bir ayrık zaman sinyali

periyodik ise bunun yaklaşık Fourier dönüşümü AFD' dir. Özellikle iki AFD' nin çarpımı bunlara karşı düşen dizilerin ayrık-zaman boyutunda konvolusyon toplamıdır. Ayrıca sayısal ortamdaki bir çok spektral analiz yöntemi AFD' ye dayanmaktadır [5].

AFD, $f(k)$, $k = 0, 1, \dots, N-1$, gibi bir sonlu diziyi , $F(n)$, $n = 0, 1, \dots, N - 1$ gibi diğer bir sonlu diziyeye eşleyen önemli bir operatördür. Normalize edilmiş örnekleme frekansı 2π olmak üzere :

$$F[n]=AFD\{f[k]\}=\sum_{k=0}^{N-1}f[k]e^{-j2\pi kn/N} \quad (3.14)$$

Ters Ayrık Fourier dönüşümü (TAFD) ise $F[n]$ 'yi yeniden $f[k]$ dizisine dönüştürür:

$$f[k]=TAFD\{F[n]\}=\frac{1}{N}\sum_{n=0}^{N-1}F[n]e^{j2\pi kn/N} \quad (3.15)$$

Eğer $f[k]$ dizisi bant sınırlı bir $f(t)$ işaretinin T_0 örnekleme aralığı (f_0 örnekleme frekansı) ile Nyquist şartları sağlanmış şekildeki örneklerini temsil ediyorsa, AFD dizisi $F[n]$ (pencereleme etkisi ihmal edilerek) orijinal işaretin Fourier dönüşümünün örneklerini temsil edebileceği açıktır:

$$F[n]=F(\omega) \Big|_{\omega=\frac{2\pi f_0 kn}{N}} \quad k=0,1,\dots,N-1 \quad (3.16)$$

$f(t)$ sinyali toplam T süresi boyunca örneklenmişse dolayısıyla T süreli bir pencere ile sinyal örneklenmiş ise AFD, FD için sadece bir kestirim sağlar ve bunun frekans çözünürlüğü

$$\Delta f = \frac{f_0}{N} = \frac{1}{T} \quad (3.17)$$

dir.

Burada dikkat edilmesi gereken husus T ' nin örnekleme periyodu değil pencere süresi olduğudur. Dolayısıyla daha uzun pencere kullanılarak çözünürlük artırılabilir. Daha uzun pencere kullanımı mümkün olmayan durumda mesela işaret durağan olmadığında, sıfır ekleme (zero padding) yöntemi kullanılabilir. Dizinin sonuna aynı N örnek sayıda sıfırlardan oluşan bir dizi daha eklenir:

$$f_z[k] = \{f[0], f[1], \dots, f[N-1], 0, \dots, 0\} \quad (3.18)$$

Sıfır eklenmiş dizi $f_z[k]$, $k = 0, 1, \dots, L - 1$, ; orijinal diziden N eleman içerirken LN kadar sıfır içermektedir. Böylece daha fazla örneğe dolayısıyla daha geniş pencereye sahip bu dizinin frekans çözünürlüğü, T pencere süresi arttığı için artırılmış olur.

3.1.3.4. Hızlı fourier dönüşümü

Ayrık Fourier Dönüşümünün doğrudan hesaplanmasında her bir $f[k]$ değeri için N karmaşık çarpma ve N-1 karmaşık toplama işlemi kullanılmaktadır. Bu nedenle N adet AFD değeri bulunurken, N^2 çarpma ve $N(N-1)$ toplama işlemi gereklidir. Ayrıca her karmaşık çarpma işlemi için dört gerçel çarpma ve iki gerçel toplama işlemi ve her bir karmaşık toplama iki gerçel toplama işlemi ile gerçekleşmektedir. Neticede, dizi uzunluğu olan N'nin 1000'in üzerinde olması halinde doğrudan AFD' nin hesaplanması çok fazla miktarda işlem gerektirmektedir. Yani N sayısı artarken gereken işlem sayısı çok fazla artmaktadır [6].

AFD hesaplanmasında bugün kullanılmakta olan verimli ve etkin bir yaklaşım Hızlı Fourier dönüşüm algoritmalarıdır. Eşitlik 3.13'de ilk dönemlerde fark edilmeyen ve sonuçlardaki periyodik sayısal tekrarlama özelliğine dayanan dairesel katlamadan yararlanılarak geliştirilen birbirinden farklı algoritmalar mevcuttur. Her ne kadar farklı bir dönüşüm olarak adlandırılmışsa da HFD AFD' den farklı değildir. Sadece kullanılan hesaplama yöntemi FD tahmini için HFD' yi cazip kılar. Kullanılmakta olan bazı HFD algoritmalarına göre zaman desimasyonlu, frekans desimasyonlu HFD en genel olanlarıdır [6].

Son olarak Ayrık zamanlı bir $f[k]$ işaretinin $w[k]$ ayrık pencere dizisi kullanılarak AFD ifadesini aşağıdaki denklemle verebiliriz:

$$F[n]=AFD\{f[k]\}=\sum_{k=0}^{N-1}f[k]w[k]e^{-j2\pi kn/N} \quad (3.19)$$

3.1.4. Yapay zeka

İnsanoğlu, mağara duvarlarına hayvan figürleri çizerek başladığı veri işleme sürecine artık insan gözüyle görülemeyecek küçüklükteki “chip”lerle devam etmektedir. Bu gelişim yaklaşık 4000 yıl gibi uzun bir süreye yayılmasına karşın gerçek gelişim son 50 yıl içinde yaşanmıştır. Günümüzde hayatımızın her alanına girmiş ve hayatımızın bir rutini haline dönüşmüş olan bu teknolojiyi insanoğlunun önceden tahmin etmesi bile olanaksızdı. Bu gelişim sürecinde artık kendi zekasıyla yetinmeyen insanoğlu makinelere de zeka verme uğraşı içindedir; artık amaç daha zeki, insan davranışlarını örnekleyebilen ve karar verebilen makineler üretmektir [7].

Yapay Zeka kavramı bu noktada karşımıza çıkmaktadır. Günümüzde insanlığın en büyük hayallerinden biri haline gelen, üzerine filmler çekilen, kitaplar yazılan yapay zeka konusunu

iyi anlayabilmek için felsefeden bilgisayar bilimine, elektrik-elektronikten biyoloji ve psikolojiye kadar çok geniş bir alanda çalışma yapmak gerekir [7].

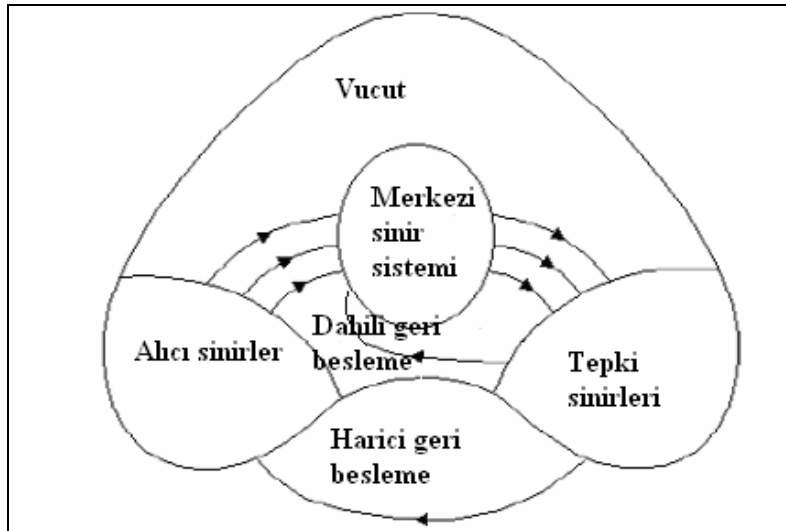
3.1.5. Yapay sinir ağları

YSA' nın hesaplama ve bilgi işleme gücünü, paralel dağılmış yapısından, öğrenbilme ve genelleme yeteneğinden aldığı söylenebilir. Genelleme, eğitim ya da öğrenme sürecinde karşılaşılmayan girişler için de YSA' nın uygun tepkileri üretmesi olarak tanımlanır. Bu üstün özellikleri, YSA' nın karmaşık problemleri çözebilme yeteneğini gösterir [7].

YSA, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almaksızın otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgi işleme modelleridir. İnsan beyninin fonksiyonel özelliklerine benzer şekilde, öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi konularda başarılı bir şekilde uygulanmaktadır. Bu yetenekleri geleneksel programlama yöntemleri ile gerçekleştirmek oldukça zor veya mümkün değildir. Literatürde 100'den fazla yapay sinir ağı modeli vardır [7,8,9].

3.1.5.1. Biyolojik sinir modeli

Biyolojik sinir sistemi, merkezinde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beyin (merkezi sinir ağı) bulunduğu üç katmanlı bir sistem olarak açıklanır. Alıcı sinirler (receptor) organizma içerisinden ya da dış ortamlardan algıladıkları uyarıları, beyne bilgi ileten elektriksel sinyallere dönüştürür. Tepki sinirleri (effector) ise, beyin ürettiği elektriksel darbeleri organizma çıktısı olarak uygun tepkilere dönüştürür.



Şekil 3.1. Biyolojik Sinir Sisteminin Blok Gösterimi

Merkezi sinir ađında bilgiler, alıcı ve tepki sinirleri arasında ileri ve geri besleme yönünde deđerlendirilerek uygun tepkiler üretilir. Bu yönüyle biyolojik sinir sistemi, kapalı çevrim denetim sistemi karakteristiklerini taşır. Merkezi sinir sisteminin temel işlem elemanı, sinir hücresidir (nöron). Diđer bir taraftan bir sinir hücresinin tepki hızı, günümüz bilgisayarlarına göre oldukça yavaş olmakla birlikte duygusal bilgileri son derecede hızlı deđerlendirebilmektedir. Bu nedenle insan beyni; öğrenme, birleştirme, uyarılma ve genelleştirme yeteneđi nedeniyle son derece karmaşık, doğrusal olamayan ve paralel dağılmış bir bilgi işleme sistemi olarak tanımlanabilir.

Yapay sinir ađları, insan beyninin çalışma prensibi örnek alınarak geliştirmeye çalışılmıştır ve biyolojik sinir modeli ile aralarında yapısal benzerlikler bulunmaktadır. Bu benzerlikler çizelge 3.1’de verilmiştir [7,8,9].

Çizelge 3.1. Biyolojik Sinir Sistemi ile YSA’nın Benzerlikleri

Sinir sistemi	YSA sistemi
Sinir hücresi	İşlem elemanı
Dendrit	Toplama fonksiyonu
Hücre gövdesi	Transfer fonksiyonu
Aksonlar	Eleman çıkışı
Sinapslar	Ağırlıklar


3.1.5.2. Biyolojik sinir ađı

Bir insan beyni, her biri yaklaşık olarak diđer sinirlerle 10^4 bađıntıya sahip olan deđişik yapı ve görevde yaklaşık olarak 10^{11} biyolojik sinir içermektedir. Buna göre toplam olarak 10^{15} birbirleriyle olan bađıntıdan söz edilebilir. Her bir sinirin diđer sinirlerle bađlantıya sahip olduđu bu yapı, Biyolojik Sinir Ađı olarak adlandırılmaktadır. Bir biyolojik sinir hücresi (nöron) temel olarak dört ana bölüme ayrılabilir [7].

Girişler (Dendritler): Dendritler, kısa lifler olup diđer sinirlerden gelen bilgileri alan yapılardır.

Soma (Hücre Gövdesi): Soma, gelen bilgileri toparlayan, birleştiren ve biçimini deđiştirerek diđer sinirlere gönderen yapıdır.

Çıkış (Aksonlar): Aksonlar, uzun lifler olup bilgiyi diđer sinirlere transfer etmekte kullanılan yapılardır.



Şekil 3.2. Biyolojik Nöron

Sinapslar: Akson ile diğer bir sinir hücresinin dendritinin birleşme noktası sinaps olarak adlandırılır. Tipik bir nöron 10^3 - 10^5 sinapsa sahiptir. Gerçekte akson ve akson arasında veya bir dendrit ile diğerleri arasında sinaptik birleşim tipleri de bulunmaktadır. Bununla birlikte basit sinir hücresi modelinde bunlar görmezlikten gelinmektedir. Kavşak uçlarındaki iletim doğal olarak kimyasaldır ve işaret miktarı, akson tarafından serbest bırakılan kimyasalların büyüklüğüne bağlı olarak transfer edilir ve dendritler vasıtasıyla alınır. Şekil 3.2’de biyolojik sinir hücresi ve bileşenleri gösterilmiştir [7].

3.1.5.3. Statik ve dinamik yapay sinir modelleri

YSA, insan beyninin kaba bir modeline dayanmaktadır. Hesaplama ünitesi olarak bir çok yapay sinir içermektedir. Bunlar birbirlerine kuvvetli büyük bir paralel yapıda uyarlamalı ağırlıklarla bağlanmaktadır. Yapay sinirler, aslında belirlenmiş veri kümelerini öğrenebilen tek ve bağımsız yapılardır. Bir başka deyişle bunlar uyarlamalı fonksiyon hesaplayıcılarıdır. İnsan beyninin kaba bir biyolojik sinir ağı taklididirler. Donanım veya yazılım olarak uygulanabilirler. Bir insan beyni aşırı geniş sayıda farklı işlemler yerine getirmektedir. Bu özellikleri taklit etmeye uğraşan birçok sayıda YSA bulunmaktadır. YSA’nın temel elemanı olan tek hesaplama sinirinin insan beynine olan benzerliği esasında; çok-girişli, genellikle doğrusal olmayan işlem elemanına ve birbirleriyle bağıntıyı sağlayan ağırlıklara sahip olmasından kaynaklanmaktadır. YSA, biyolojik sinir aktivitelerini taklit etmeye çalışmaktadır. Böyle olmasına karşın bir insan beynin sinirinin biyolojik sinir işlemlerinin doğru bir biçimde temsil edilmesi aşırı derecede güçtür. Fakat iyi bir şekilde temsil eden basit

yapay sinir modeli elde etmek mümkündür. Bu, donanım, yazılım veya hibrit teknikler kullanılarak uygulanabilir.

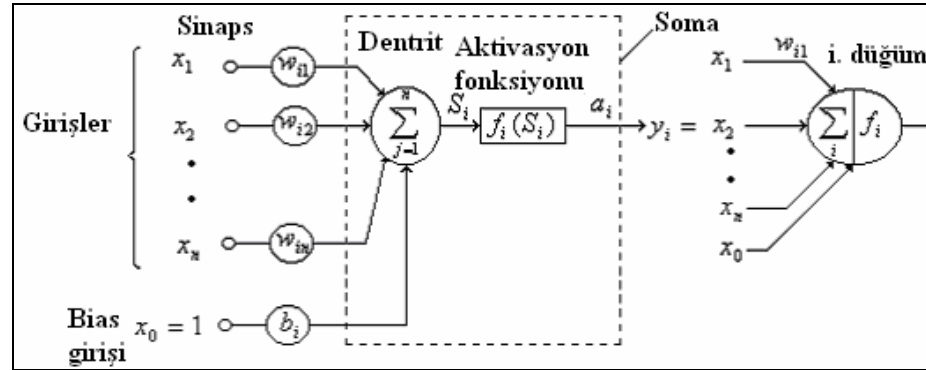
Statik Yapay Sinir modeli olarak adlandırılan modelin dört ana bölümü mevcuttur [7,8,9].

1. Giriş veya girişler
2. Ağırlıklar
3. Dinamik olmayan fonksiyon (aktivasyon fonksiyonu), bir çok uygulamada doğrusal olmayan olmakta fakat lineer fonksiyonları da kullanabilen YSA modelleri bulunmaktadır.

4. Çıkış veya çıkışlar

Bu sinir modeli literatürde perceptron (algılayıcı) sinir modeli olarak geçmektedir. Fakat tam anlamıyla konuşulan ve göze alınan orijinal tanımlaması Rosenblatt (1958) tarafından yapılmıştır. Eğer aktivasyon fonksiyonu keskin sınırlayıcı gibi özel bir aktivasyon fonksiyon formunda ise sinir modeli algılayıcı (perceptron) olarak anılır.

Görüldüğü üzere statik yapay sinir ağı modeli dinamik eleman içermemektedir. Bununla birlikte, dinamik yapay sinir ağı modeli olarak adlandırılan modelde, yukarıda açıklanan dört ana bölüme ek olarak aktivasyon fonksiyon bloğunu takiben bir dinamik blok bulunmaktadır. Bu dinamik blok basit bir gecikme elemanı ile temsil edilmektedir [7,8,9].



Şekil 3.3. Temel Statik Yapay Sinir Hücresi

Basit statik YSA modelinde soma toplama işlemi ve aktivasyon fonksiyonunu temsil etmektedir. Şekil 3.3'de birçok sinir içeren YSA'nın i . siniri olan tek bir statik yapay sinirin (YS) basit modeli görülmektedir. Şekil 3.3'te ayrıca tartışılan biyolojik terminolojiye karşı gelen terimlerde gösterilmektedir. En basit sinir modelinde bir sinir olmasına rağmen genelde n tane giriş bulunmaktadır. Şekilde $x_1(t), x_2(t), x_3(t), \dots, x_n(t)$, olarak gösterilmektedir. Bunlar n boyutlu giriş vektörünün elemanları olarak düşünülebilir.

$$\mathbf{x}(t) = [x_1(t) \ x_2(t) \ x_3(t) \ \dots \ x_n(t)]^T \quad (3.20)$$

Sinir çıkışı sayıl bir niceliktir $y(t)$. Sinir toplama ağırlık toplamalarının yapıldığı toplama operatörü içermektedir. Toplama operatörünün çıkışı ağ değeri olarak (net değeri) alınırsa,


$$S_i(t) = \sum_{j=1}^n w_{ij} x_j(t) + b_i \quad (3.21)$$

şeklinde gösterilir. Burada w_{ij} i . sinir j . giriş arasındaki bağlantı ağırlıklarını, b_j de sapma veya aktivasyon fonksiyonun eşik değeri olarak adlandırılan sabit değeri göstermektedir. Ağırlıklarla girişler çarpılarak girişler bağlantı ağırlıklarından iletilirler. Ağırlık toplamada toplanırlar ve net değeri (S_i) bunlara sapmanın eklenmesi ile elde edilir. Son olarak sinirin çıkışı sinir aktivasyon fonksiyonu kullanılarak elde edilir. Ağırlıklar, sayısal veri taşıyan tek yönlü haberleşme kanallarıdır. Birçok YSA'nın eğitim veya öğrenme aşamalarında kullanılmak üzere ağırlık değerleri sağlanır. Eğitim veya öğrenme aşamalarında sunulan giriş eğitim verileri temelinde sistem çıkışının doğru çıkışa hemen hemen uyması için ağırlıklar değiştirilir. Ağırlıkların değişimi yalnızca eğitim ve öğrenme aşamalarında mümkündür. Genelde hepsi farklı sabit değerler alırlar. Çoğunlukla ağırlıkların başlangıç değerleri rasgele seçilir ve pozitif veya negatif değer alabilirler.[7,8]

Girişler; bir nöron girişinin dışsal ve içsel olmak üzere iki kaynağı vardır. İçsel girişler diğer nöronlardan gelen girişlerdir. Şekil 3.3'de görüldüğü üzere giriş olarak sapma girişi de ele alınmalıdır. Böylelikle toplam $n + 1$ giriş bulunmaktadır. Eşik değeri $x_0 = 1$ ve b_i ağırlığına karşı düşen ağırlığın kullanılması ile oluşturulmaktadır.

Sapmanın $\sum_{j=1}^n w_{ij} x_j(t)$ toplamına eklenmesi nöron aktivasyon fonksiyonunun kaymasına neden olur. Aktivasyon Fonksiyonu; Şekil 3.3'de de görüldüğü üzere nöron dinamik olmayan bir aktivasyon fonksiyonu içermektedir. Bu fonksiyonun doğrusal olmaması durumunda biyolojik hücrenin doğrusal olmayan somatik transfer fonksiyonunun yerine geçmektedir. Doğrusal olmayan aktivasyon fonksiyonunun kullanılmasının sonucu bile nöron modeline doğrusal olmama özelliği kazandırmaktır. Bundan dolayı ağda, çıkışlar ve girişler arasında daha kuvvetli bir doğrusal olmayan ilişki sağlama özelliği elde edilir. Doğrusal olmayan bir fonksiyon kullanılmaması durumunda, yapay nöron doğrusal bir sistemi temsil eder. Bu tip yapay nöronlar doğrusal olmayan sistem eşlemesinde kullanılmaz ve doğrusal olmayan hesaplamaları yerine getiremez. Doğrusal aktivasyon fonksiyonları gürültüyü

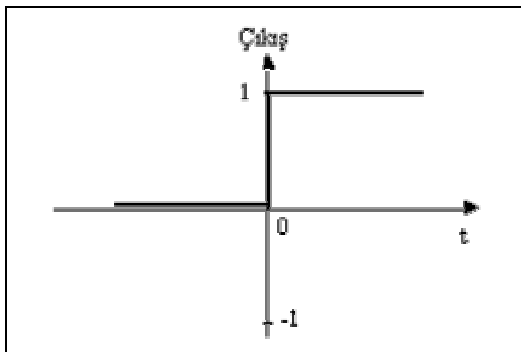
bastıramamaktadır. Bu sebepten sağlam bir doğruluk yapısında değildir. Şu da belirtilmelidir ki doğrusal aktivasyon fonksiyonu içeren nöron modeline sahip ağlar da kullanılmaktadır. Fakat bunlar sadece doğrusal sistem modellemesinde kullanılır. Doğrusal aktivasyon fonksiyonlu sinir modeli literatürde Widrow-Hoff modeli olarak bahsedilmektedir. YSA’nda kullanılan aktivasyon fonksiyonlarının (matematiksel fonksiyonlar) çeşitli türleri bulunmaktadır. Bununla birlikte aktivasyon fonksiyonu seçiminde doğrusal olmama ve basitlik iki anahtar faktördür. Ayrıca bazı eğitim tekniklerinde aktivasyon fonksiyonunun birinci dereceden türevi gerekmektedir. Eğer YSA’da bu teknikler kullanılacaksa aktivasyon fonksiyonu türevi alınabilir olmak zorundadır. Kronolojik olarak ilk önce aktivasyon fonksiyonları olarak keskin sınırlayıcı (hard-limit) fonksiyonu kullanılmıştır. Bunun amacı ayrı nöronlarda, ON ve OFF olarak iki bölge meydana getirmektir. Daha sonraları, sürekli tip nöronlarda asimptotik aktivasyon fonksiyonları kullanıldı. Keskin sınırlayıcı aktivasyon fonksiyonlu nöron modelleri tamamında olmamakla birlikte kesinlikle sınıflandırma amaçlı olarak kullanılmaktadır. Burada giriş uzayı iki bölgeyle ayrılmıştır. Çıkış vektörü girişlere bağlı olarak 0 yada 1 dir. Yukarıda bahsedilen keskin sınırlayıcı aktivasyon fonksiyonu kullanan sinir modeli algılayıcı olarak adlandırılmaktadır. Aktivasyon fonksiyonları çeşitli türde sınıflandırılabilir. Bu sınıflandırma, yumuşak sınırlayıcı ve keskin sınırlayıcı olarak ayırt edilebilir. Yumuşak sınırlayıcı fonksiyonları bazı ağırlık uyarlamalarında gerekmektedir. Keskin sınırlayıcı fonksiyonları ayrı algoritmalarda kullanılır. Örnek olarak tek kutuplu sigmoid fonksiyon ve doğrusal aktivasyon fonksiyonları Şekil 3.4’de görülmektedir [10].



Şekil 3.4. YSA'da En Çok Tercih Edilen Aktivasyon Fonksiyonları a) Tek Kutuplu Sigmoid b) Doğrusal c) Hiperbolik Tanjant d) Keskin Sınırlayıcı

Darbe Tipi ve Adım Tipi Fonksiyonlar; bu sınıflandırmada aktivasyon fonksiyonları sıfır yakınındaki girişler için anlamlı çıkış değerine sahip olunmasına göre ayırılır. Darbe tipi fonksiyonlar, adım tipi fonksiyonların türevi alınarak yaratılabilir. En çok kullanılan aktivasyon fonksiyonu çeşitleri şunlardır:

- Step fonksiyonu:




Şekil 3.5. Step Fonksiyonu

$$F(NET) = \begin{cases} 1 & ; NET \geq 0 \\ 0 & ; NET < 0 \end{cases} \quad (3.22)$$

Gelen NET girdi değerinin 0 (eşik değeri)'dan büyük veya küçük olmasına göre hücrenin çıktısı 1 veya 0 değerlerini alırlar. Belirlenen eşik değeri problemler için farklılık gösterebilir [10].

- Doğrusal fonksiyon:



Şekil 3.6. Doğrusal fonksiyon

$$F(NET)=NET \quad (3.23)$$

Gelen girdiler, olduğu gibi hücrenin çıktısı olarak kabul edilir.

- Sinüs fonksiyonu:

$$F(NET)=\text{Sin}(NET) \quad (3.24)$$

Öğrenilmesi düşünülen olayların sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır [10].

- Eşik değer fonksiyonu:


$$F(NET)=\begin{cases} 0 & ; \quad NET \leq 0 \\ NET & ; \quad 0 < NET < 1 \\ 1 & ; \quad NET \geq 1 \end{cases} \quad (3.25)$$

Gelen bilgilerin 0 veya 1'den büyük yada küçük olmasına göre değerler alır. 0 ve 1 arasında da değerler alabilirler. Bunların dışında değerler alamaz.

- Hiperbolik tanjant fonksiyonu:

$$F(NET)=\frac{e^{NET} + e^{-NET}}{e^{NET} - e^{-NET}} \quad (3.26)$$


Gelen NET girdi değerinin tanjant fonksiyonundan geçirilmesi ile hesaplanır.



Şekil 3.7. Tanjant fonksiyonu

- Sigmoid fonksiyonu:

Yapay sinir ağları oluşturulurken en çok kullanılan aktivasyon fonksiyonudur. Doğrusal ve doğrusal olmayan davranışlar arasında denge sağlayan sürekli artan bir fonksiyon olarak tanımlanır [10].



Şekil 3.8. Sigmoid fonksiyonu

$$F(NE\text{T}) = \frac{1}{1 + e^{-x}} \quad (3.27)$$

şeklinde gösterilir.

3.1.5.4. Yapay sinir ağlarının özellikleri

Yukarıda verilen açıklamalardan, 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 [7].

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 [7].

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 yada tasarlanamaz. Bu nedenle YSA, istenen davranışı gösterecek şekilde ilgilendiği problemde aldığı eğitim örneklerini kullanarak problemi öğrenmelidir [7].

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 yada bir sistemin eğitilmiş YSA modeli, eğitim sürecinde verilmeyen giriş sinyalleri için de sistemle aynı davranışı gösterebilir [7].

Uyarlanabilirlik

YSA, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir, 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 [7].

Hata Toleransı

YSA, çok sayıda hücrenin çeşitli şekillerde bağlanmasından oluştuğundan paralel dağılmış bir yapıya sahiptir ve ağına sahip olduğu bilgi, ağıdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir YSA nın bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağına doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, geleneksel yöntemlere göre hatayı tolere etme yetenekleri son derece yüksektir [7].

Donanım ve Hız

YSA, paralel yapısı nedeniyle büyük ölçekli entegre devre (VLSI) teknolojisi ile gerçekleştirilebilir. Bu özellik, YSA nın hızlı bilgi işleme yeteneğini artırır ve gerçek zamanlı uygulamalarda arzu edilir [7].

Analiz ve Tasarım Kolaylığı

YSA' nın temel işlem elemanı olan hücrenin yapısı ve modeli, bütün YSA yapılarında yaklaşık aynıdır. Dolayısıyla, YSA' nın farklı uygulama alanlarındaki yapıları da standart yapıdaki bu hücrelerden oluşacaktır. Bu nedenle, farklı uygulama alanlarında kullanılan YSA'ları benzer öğrenme algoritmalarını ve teorilerini paylaşabilirler. Bu özellik, problemlerin YSA ile çözümünde önemli bir kolaylık getirecektir [6].

3.1.5.5. Yapay sinir ağlarının sınıflandırılması


YSA, genel olarak birbirleri ile bağlantılı nöronlardan oluşurlar. Her bir nöron arasındaki bağlantıların yapısı ağıın yapısını belirler. İstenilene ulaşmak için bağlantıların nasıl değiştirileceği öğrenme algoritması tarafından belirlenir. Buna göre YSA, yapılarına ve öğrenme algoritmalarına göre sınıflandırılabilirler [9].

a) YSA'nın Yapılarına Göre Sınıflandırılması

YSA, yapılarına göre ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olarak ikiye ayrılırlar.

i. İleri Beslemeli Ağlar

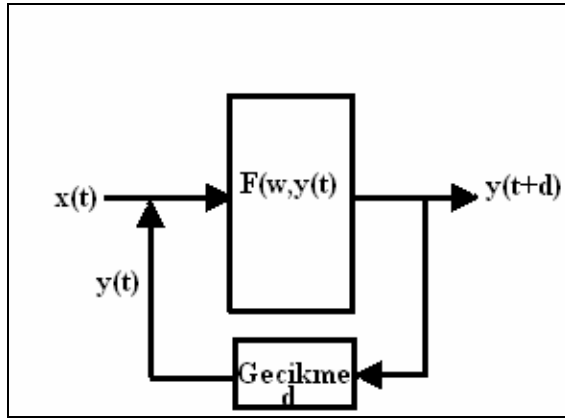
Nöronlar, genellikle katmanlara ayrılmış olmaktadır. İşaretler , giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilir. Nöronlar bir katmandan diğer bir katmana bağlantı kurarlarken, aynı katman içerisinde bağlantıları bulunmaz. Şekil 3.9'da ileri beslemeli YSA için blok diyagram gösterilmiştir. İleri beslemeli ağlara örnek olarak çok katmanlı perceptron (Multi-Layer Perceptron – MLP) ve LVQ (Learning Vector Quantization) ağları verilebilir [10].



Sekil 3.9. İleri Beslemeli YSA için Blok Diyagram

ii. Geri Beslemeli Ağlar

Bir geri beslemeli sinir ağı, çıkış ve ara katmanlardaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Böylece girişler hem ileri yönde hem geri yönde aktarılmış olur. Şekil 3.10’da bir geri beslemeli ağ blok diyagramı görülmektedir. Bu çeşit sinir ağlarının dinamik hafızaları vardır. Bu ağlarda bir andaki çıkış, hem o andaki hem de önceki girişleri yansıtır. Bundan dolayı özellikle önceden tahmin uygulamaları için uygundur. Bu ağlar çeşitli tipteki zaman-serilerinin tahmininde oldukça başarı sağlamışlardır. Geri beslemeli YSA’na örnek olarak Hopfield, SOM (Self Organizing Map), Elman ve Jordan ağları verilebilir [10].



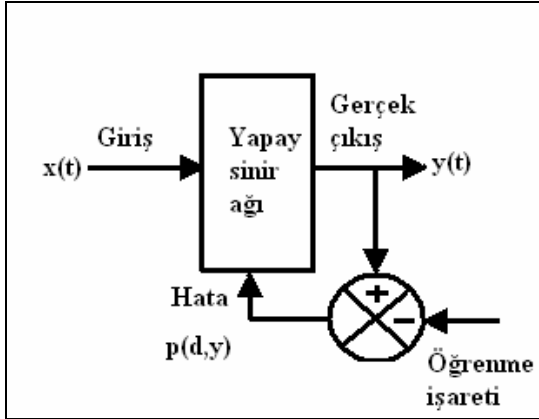
Şekil 3.10. Geri Beslemeli YSA için Blok Diyagramı

b) YSA'nın Öğrenme Algoritmalarına Göre Sınıflandırılmaları

Öğrenme, gözlem, eğitim ve hareketin doğal yapıda meydana getirdiği davranış değişikliği olarak tanımlanmaktadır. Bir takım metot ve kurallara bağlı olarak gözlem ve eğitim tabanında ağıdaki ağırlıkların değişimi sağlanmalıdır. Burada genel olarak üç öğrenme metodundan ve bunların uygulandığı değişik öğrenme kurallarından söz edilebilir [10].

i. Danışmanlı Öğrenme (Supervised Learning)

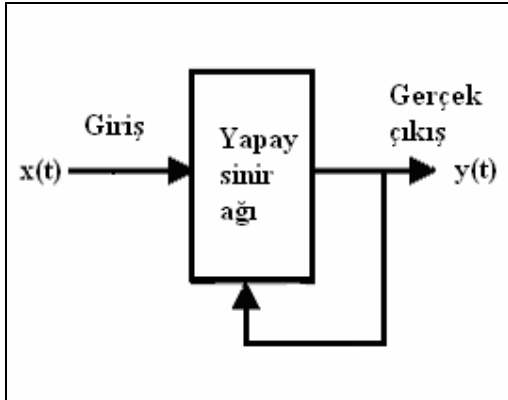
YSA'na örnek olarak bir doğru çıkış verilir. İstenilen ve gerçek çıkış arasındaki fark hata olarak ele alınır. Bu hataya göre nöronlar arasındaki bağlantıların ağırlıkları en uygun çıkışı elde etmek için düzenlenir. Bu sebeple danışmanlı öğrenme algoritmasında bir “öğretmene” veya “danışmana” ihtiyaç duyulmaktadır. Şekil 3.11’de danışmanlı öğrenmenin blok diyagramı gösterilmiştir. Widrow-Hoff tarafından geliştirilen delta kuralı ve Rumelhart ve McClelland tarafından geliştirilen genelleştirilmiş delta kuralı veya geri yayılım (back propagation) algoritması danışmanlı öğrenme algoritmalarına örnek olarak verilebilir [10].



Şekil 3.11. Danışmanlı Öğrenme Yapısı

ii. Danışmansız Öğrenme (Unsupervised Learning)

Girişe verilen örnekten elde edilen çıkış bilgisine göre ağ sınıflandırma kurallarını kendi kendine geliştirmektedir. Bu öğrenme algoritmalarında istenen çıkış değerinin bilinmesine gerek yoktur. Öğrenme süresince sadece giriş bilgileri YSA'na verilir. Ağ daha sonra bağlantı ağırlıklarını aynı özellikleri gösteren örüntü oluşturmak üzere ayarlar. Şekil 3.12'de danışmansız öğrenme algoritma yapısının blok diyagramı gösterilmektedir. Grosberg tarafından geliştirilen ART (Adaptive Resonance Theory) veya Kohonen tarafından geliştirilen SOM (Self Organizing Map) öğrenme kuralları danışmansız öğrenmeye örnek olarak verilebilir [10].

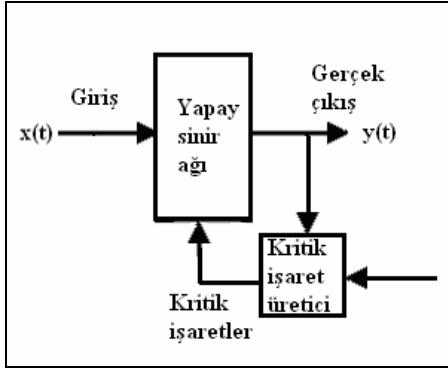


Şekil 3.13. Danışmansız Öğrenme Yapısı

iii. Takviyeli Öğrenme (Reinforcement Learning)

Denetimsiz öğrenme algoritması, istenen çıkışın bilinmesine gerek duymaz. Hedef çıktıyı vermek için bir "öğretmen" yerine, burada YSA'na bir çıkış verilmemekte fakat elde edilen çıkışın verilen girişe karşılık iyiliğini değerlendiren bir kriter kullanılmaktadır. Şekil 3.13'de

takviyeli öğrenme algoritması yapısının blok diyagramı verilmiştir. Optimizasyon problemlerini çözmek için Hinton ve Sejnowski'nin geliştirdiği Boltzmann kuralı veya genetik algoritmalar takviyeli öğrenmeye örnek olarak verilebilir [10].



Şekil 3.13. Takviyeli Öğrenme Yapısı


3.1.5.6. Tek katmanlı ve çok katmanlı ileri beslemeli yapay sinir ağları

a) Tek Katmanlı YSA'lar:

Nöronlar, yapay sinir ağlarının yapı taşlarıdır. Tek katmanlı ileri beslemeli YSA olarak adlandırılan ağ yapısı en azından yukarıda söz edilen tipte bir nörondan oluşmaktadır. Şekil 3.14'de genel yapısı gösterilmiştir. Burada n tane giriş, giriş vektörünü $x = [x_1 \ x_2 \ \dots \ x_n]$ oluşturmaktadır. YSA'nın tek katmanında k tane nöron bulunmaktadır.

Genelde nöron sayısı ile giriş sayısı birbirine eşit değildir ($k \neq n$). Girişler her bir nöronun girişine uygun ağırlıklarla bağlanır. Her bir nöron, kendi girişleri ve sapmanın ağırlıklarını toplar ve bu toplamı kendi aktivasyon fonksiyonuna uygular. Bunu takiben tek katmanlı olarak tanımlanan YSA'nın k tane çıkışı, çıkış vektörünü

$y_1 = [y_{11} \ y_{12} \ y_{13} \ \dots \ y_{1k}]$ oluşturur [10].



Şekil 3.14. Tek Katmanlı YSA

Çıkış vektörünün ifadesi

$$yI = F_I[W_I x \ bI_I] \quad (3.28)$$

olarak yazılabilir. Bu Eşitlikte; F_I , bu tek katmanın k elemanlı köşegen aktivasyon matrisidir ve bu katmanın net girişlerine bağlıdır.

$$F_I(SI) = \text{diag}[fI(S_1) \ fI(S_2) \ \dots \ fI(S_k)] \quad (3.29)$$

Burada k düğümlerinin her birinin aktivasyon fonksiyonları eşit kabul edilmiştir.

$$fI_1 = fI_2 = \dots = fI_k = fI$$

SI net vektörü $S1 = [S_1 \ S_2 \ \dots \ S_k]^T$ oluşturulur. S_1, S_2, \dots, S_k ; sırasıyla 1., 2., ..., k . nöronlara karşılık gelir ve

$$S_i = \sum_{j=1}^n w_{ij} x_j(t) + b_i \quad (3.30)$$

olarak ifade edilir. Ayrıca WI çıkış katmanının ağırlık matrisi, sinir ağının yapısına bağlı olarak, k satır n sütundan oluşturulmaktadır.

$$W1 = \begin{pmatrix} w_{11} & \dots & w_{1n} \\ \vdots & \ddots & \vdots \\ w_{k1} & \dots & w_{kn} \end{pmatrix} \quad (3.31)$$

Genelde w_{ij} ; j . hedef düğüm ile i . kaynağın ağırlığını temsil eder. $B1$ sapma vektörü tek katmanlı ağlarda $b1_1, b1_2, \dots, b1_k$; sırasıyla çıkış katmanının 1., 2., ..., k . düğümlerinin sapmalarıdır.


$$B1 = [b1_1 \ b1_2 \ \dots \ b1_k]^T \quad (3.32)$$

Tek katmanlı YSA sadece sınırlı sayıda sistemlerde kullanılır. Tüm doğrusal olmayan fonksiyonları temsil edemezler. Tek katmanlı YSA'da aktivasyon fonksiyonu olarak keskin-sınırlayıcı fonksiyonu kullanıldığı zaman tek katmanlı perceptron adlı model meydana gelmektedir. Bu model bazı sınıflandırma problemlerinde aktivasyon fonksiyonunun giriş uzayını iki bölgeye bölmesi ve çıkış uzayının giriş vektörüne bağlı olarak 1 ve 0 değerleri alması ile gerçekler. Tek katmanlı ağlarda doğrusal aktivasyon fonksiyonu kullanıldığında doğrusal sınırlara sahip bir ağ oluşur. Bu sınırlar, ADALINE sınırlarından (Adaptive Linear Neurons) Widrow-Hoff sınırları olarak adlandırılır. Bu nöronlardan meydana gelen ağda adaptif öğrenme kullanılıyorsa ADALINE ağ veya MADALINE ağ olarak adlandırılır [9].

a) Çok Katmanlı Yapay Sinir Ağları

Çok sayıda katman içeren yapay sinir ağlarıdır. Çok katmanlı YSA'nda sinirler ayrı paralel katmanlara yerleştirilmişlerdir. Ağda ayrı katmanlara bağlantının sonucu olarak giriş ve çıkış

arasındaki doğrusal olmayan eşlemenin daha karmaşık olması mümkündür. Bu özellik sınıflandırma ve hatırlama uygulamalarında değişkenler arasındaki doğrusal olmayan ilişkiyi göstermek için kullanılır. Şekil 3.15’de çok katmanlı YSA’ndan üç katmanlı bir yapay sinir ağı şeması verilmektedir [9].



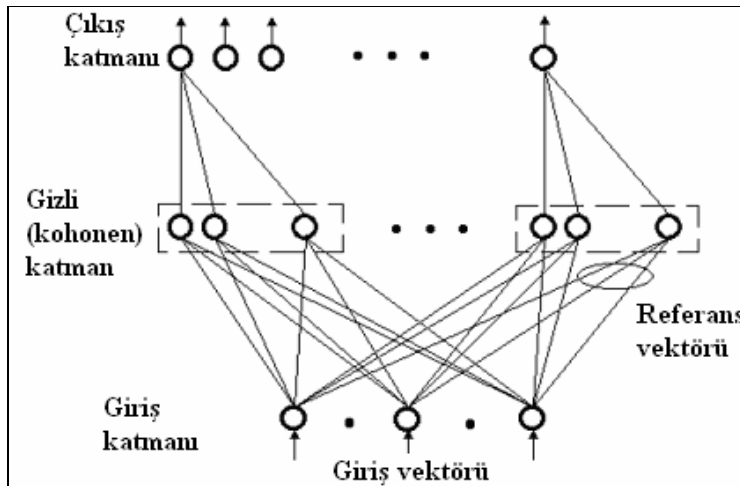
Şekil 3.15. Çok Katmanlı YSA

İlk katman olan giriş katmanında hesaplama için nöronlar bulunmaz sadece birinci gizli katmandaki nöronları beslemek için girişler bulunur. Bu katmanı ikinci gizli katman ve diğer gizli katmanlar takip eder. En son olarak çıkış katmanı yer alır. Genel olarak giriş katmanı ile çıkış katmanı arasındaki katmanlar gizli katman olarak anılır. Aynı katmandaki düğümler arasında bir bağlantı bulunmamaktadır. Teorik olarak çok sayıda gizli katman bulunur. Fakat bu eğitilmiş ağı karmaşıklığını önemli derecede artırır. Bir veya iki gizli katmanlı ağlarda doğruluk, sağlamlık ve genelleştirme çoğu durumda sağlanmaktadır. Eğer tek gizli katman varsa gizli katmanda doğrusal olmayan aktivasyon fonksiyon, çıkış katmanında doğrusal aktivasyon fonksiyonu kullanılarak yeterli performans elde edilebilir. İleri beslemeli YSA’nda her nöron bitişikteki katmanın tüm nöronları ile bağlantılıdır ve diğer nöronlarla bağlantısı bulunmamaktadır. Katman içindeki bağlantılara izin verilmemektedir. Genelde farklı katmanların farklı nöron sayıları ve farklı ağırlıkları bulunmaktadır. Gizli katman sayısının ve saklı katman nöron sayılarının belirlenmesinde genel bir kural yoktur. Belirlenme işlemi yapılan eşlemenin kompleksliğine bağlıdır. Giriş sayılarının ve çıkış sayılarının belirlenmesi tabi ki tamamen probleme özgüdür. Nöronların ve bağlantılarının sayıları sinir ağının doğru olarak saklayabildiği örüntü sayısına kadar sınırlıdır [10].

3.1.5.7. Diğer yapay sinir ağları

i. LVQ (Learning Vector Quantization)

Şekil 3.16 üç katmandan oluşan LVQ ağını göstermektedir. Bu katmanlar, giriş katmanı, gizli katman ve çıkış katmanıdır. LVQ ağı, giriş katmanı ile gizli katman birbirleriyle tamamen, gizli katman ile çıkış katmanı da kısmen bağlıdır. Her çıkış nöron düğümü farklı bir gizli nöron düğümü kümesine bağlıdır. Gizli ve çıkış nöronları arasındaki ağırlıklar “1”e sabitlenmiştir. Girişler ile gizli katmandaki nöronların bağlantılarının ağırlıkları “referans” vektörlerinin elemanlarını oluşturur (her gizli katman nöronuna bir referans vektör atanmıştır). Ağın öğretilmesi aşamasında bunlar yeniden değerler alırlar. Hem gizli katman nöronları (bunlar Kohonen nöronları olarak da bilinir) hem de çıkış katmanı nöronları ikili (binary) çıkışa sahiptir. Ağa bir giriş örüntüsü verildiğinde referans vektörü giriş örüntüsüne en yakın olan gizli nöron kümesi “1”, diğerleri “0” üretir. “1” üreten çıkış nöronu giriş işaretini sınıflar ve her nöron ayrı bir sınıfa atanmıştır [10].

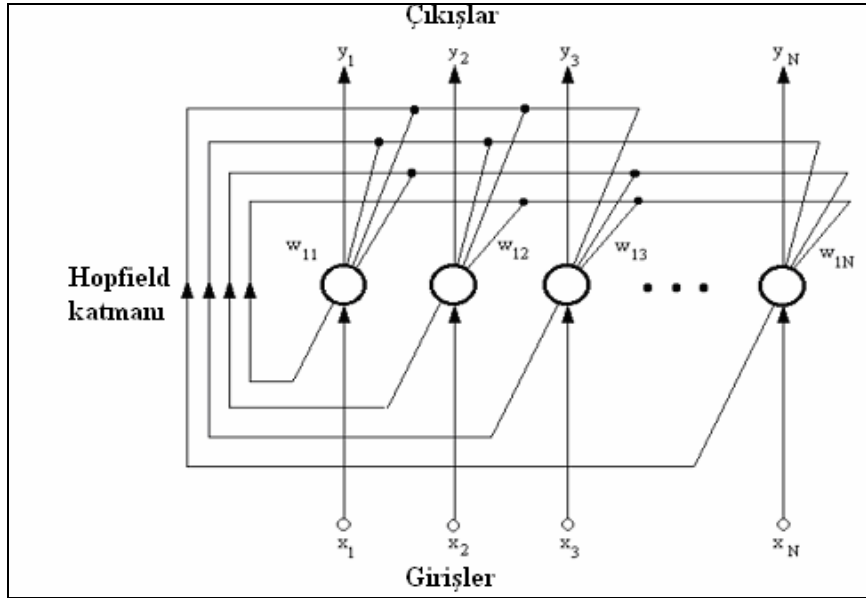


Şekil 3.16. LVQ Ağı

- En basit LVQ öğretim prosedürü şu sıra ile açıklanabilir.
- Referans vektörlerinin ağırlıklarının başlangıç değerlerinin belirlenmesi.
- Ağa giriş örüntüsünün uygulanması.
- Giriş deseni ile her referans vektörü arasındaki öklit (Euclidian) uzaklığının hesaplanması.
- Giriş örüntüsüne en yakın referans vektörünün ağırlıklarının yeniden düzenlenmesi. Eğer bu gizli katman nöronu, o çıkış katmanı nöronunun bağlı olduğu gizli katman nöron kümesine bağlı ise referans vektörünü giriş örüntüsüne daha yakın hale getirir. Aksi takdirde referans vektörünü uzaklaştırır.

- İkinci numaralı adıma yeni bir giriş örüntüsü ile dönülür ve işlemlere sınıflandırılması istenen giriş örüntüsü kalmayana dek devam edilir.

ii. Hopfield Ağı



Şekil 3.17. Hopfield Ağı

Şekil 3.17’de Hopfield Ağının bir şekli gösterilmiştir. Bu ağ genellikle ikili (0 veya 1) ve iki kutuplu (+1 veya -1) girişler kabul eder. Tek katman işlemci nöronlar vardır ve her bir nöron diğerine bağlıdır. Böylelikle geribeslemeli bir yapıya sahip olduğu görülmektedir. Hopfield ağının eğitilmesi sadece bir adım alır ve w_{ij} ağırlıkları aşağıda verildiği gibi hesaplanır [10].

$$w_{ij} = \begin{cases} \frac{1}{N} \sum_{c=1}^P x_i^c x_j^c & ; i \neq j \\ 0 & ; i = j \end{cases} \quad (3.35)$$

Burada w_{ij} , i nöronundan j nörona olan bağlantı ağırlığını, x_i^c c sınıfı için eğitime giriş deseninin i ’inci elemanını, P sınıf sayısını ve N de nöron sayısını gösterir. Eşitlik 3.33’de $w_{ij} = w_{ji}$ ve $w_{ii} = 0$ durumları ağın kararlılığını garantiler. Bilinmeyen bir bilgi ağa girildiğinde, ağın çıkışları bilinmeyen bir desen elemanına eşitlenir. Yani;

$$y_i(0) = x_i \quad 1 \leq i \leq N \quad (3.34)$$

Bu başlangıç değerleri ile başlayarak hopfield ağı bir sonraki denklemi kullanarak minimum enerji durumuna geçmek için döngüye girer [10].


$$y_i(k+1) = f \left[\sum_{j=1}^N w_{ij} y_j(k) \right] \quad 1 < i \leq N \quad (3.35)$$

Burada f aşağıdaki gibi tanımlanan keskin sınırlama (hard-limiting) fonksiyonudur.

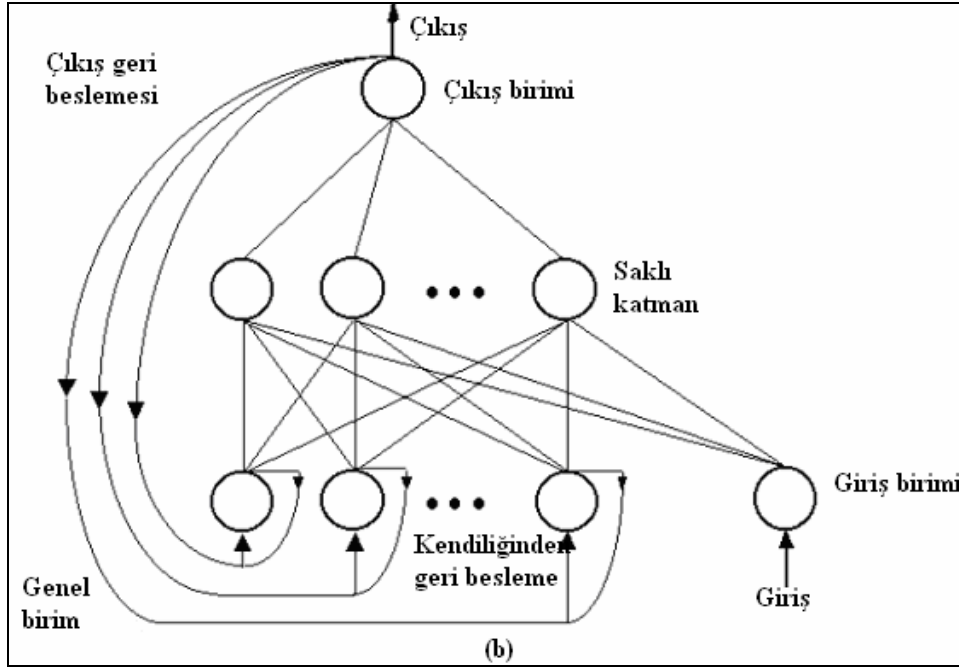
$$f(x) = \begin{cases} -1 & ; \quad x < 0 \\ 1 & ; \quad x > 0 \end{cases} \quad (3.36)$$

iii. Elman ve Jordan Ağları

Şekil 3.18.a ve Şekil 3.18.b Elman ve Jordan ağlarını göstermektedir. Bu ağlar, MLP'lere benzer bir yapıdadırlar. Her iki ağda da gizli katmana ek olarak bir "durum" katmanı denilen özel bir gizli katman daha bulunmaktadır. Bu katman gizli katmandan veya çıkış katmanından geri besleme işaretleri alır. Jordan ağının aynı zamanda durum katmanındaki her nöronun kendisine bağlantıları vardır. Her iki ağda da durum katmanındaki nöronların çıkışları ileriye doğru gizli katmana verilmektedir. Eğer sadece ileri doğru bağlantılar göz önüne alınır ve geri besleme bağlantılarına sabit değerler verilirse, bu ağlar sıradan ileri beslemeli ağlar haline gelir [8].



Şekil 3.19.a) Elman Ağı



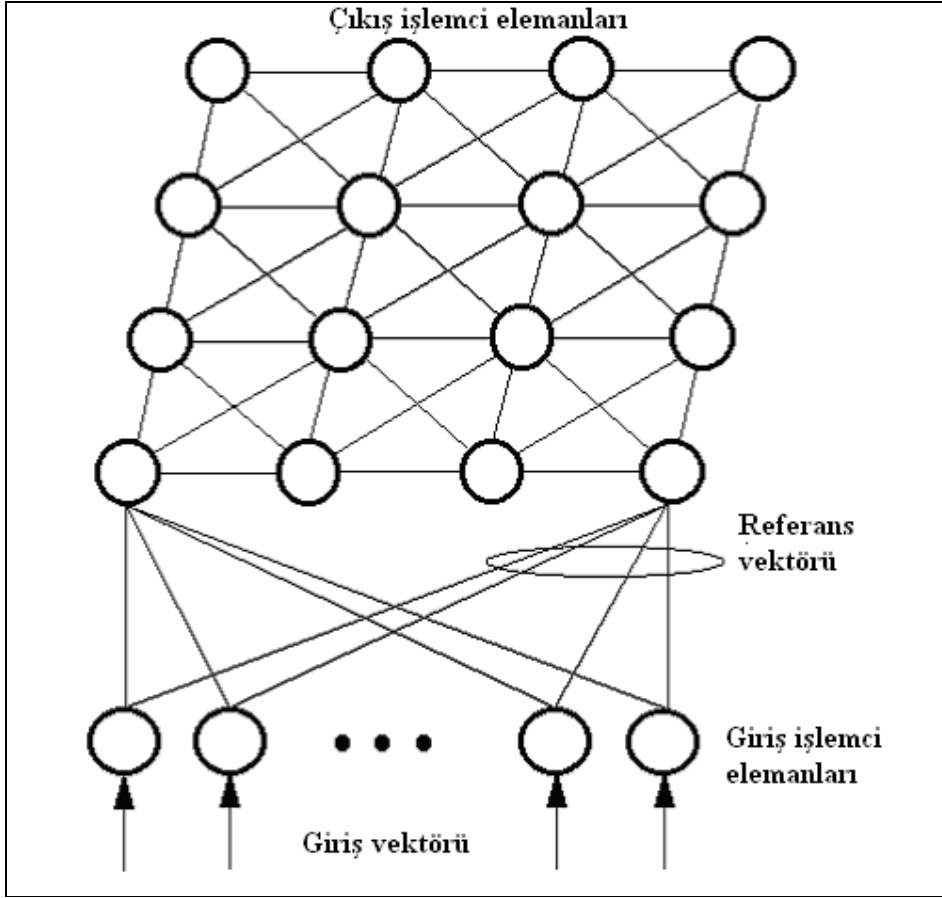
Şekil 3.19. b) Jordan Ağı

iv. Kohonen Ağı

Kohonen ağı, bir giriş katmanı ve bir de çıkış katmanı olmak üzere iki katmandan oluşur. Bu ağ Şekil 3.20’de gösterilmiştir. Çıkış katmanındaki nöronlar genellikle düzenli iki boyutlu aralıklar olarak düzenlenir. Çıkiştaki her nöron bütün giriş düğümlerine bağlıdır. Bağlantıların ağırlıkları verilen çıkış elemanı ile ilgili olan referans vektörünün elemanlarını oluşturur. Kohonen ağının öğrenme adımları aşağıdaki gibidir [10].

- Çıkış nöronlarının bütün referans vektörlerini küçük rasgele değerlere çekilmesi.
- Bir giriş örüntüsünün alınması.
- Giriş örüntüsüne en yakın referans vektörüne sahip nöronun belirlenmesi.
- Belirlenen nöronun ve onun komşularının referans vektörlerinin güncelleştirilmesi. Bu referans vektörleri giriş vektörüne yaklaştırılır. Bu yaklaştırma (ayarlar) belirlenen nöron için en fazla ve bu nörondan uzaklaştıkça daha azdır. Öğrenme ilerledikçe komşuların sayısı azalmakta ve öğrenme sonunda belirlenen nöronun referans vektörü ayarlanmaktadır.

Öğrenmeden sonra bir etiketleme işlemine başlanır. Bilinen sınıfların giriş örüntüleri ağı giriş olarak verilir ve bu giriş örüntüleri tarafından aktif hale gelen çıkış nöronlarına bu sınıf etiketleri verilir.



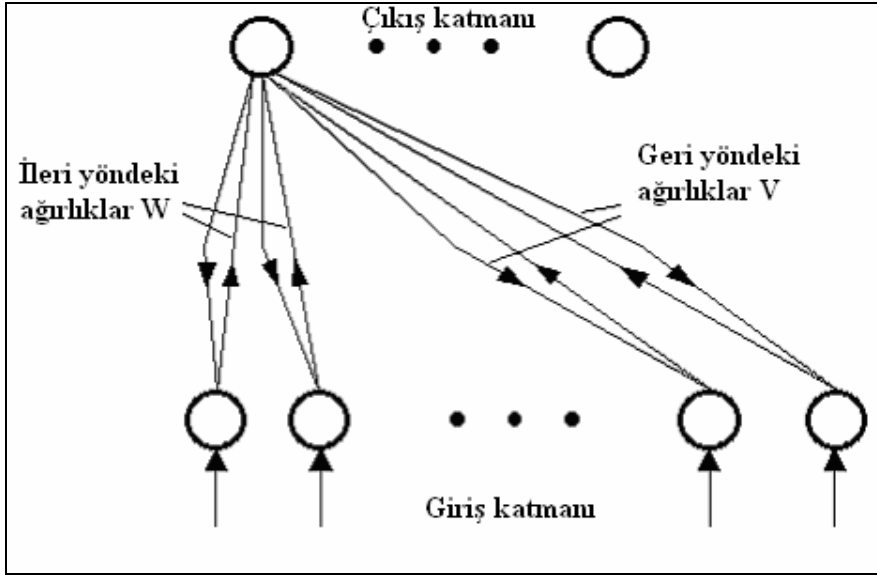
Şekil 3.19. Kohonen Ağ

v.ART (Adaptive Resonance Theory) Ağ

ART ağının, ART-1, ART-2, Fuzzy-ART, MART gibi değişik çeşitleri vardır. Şekil 3.20’de ikili girişler kabul eden ART-1 gösterilmiştir. ART-2 gerçek değerler kabul etmektedir. Şekil 3.20’de görüldüğü gibi, ART-1 ağının giriş ve çıkış olmak üzere iki katmanı vardır. İki katman birbiriyle tamamen bağlantılıdır ve bağlantılar ileri ve geri yöndedir. i ’inci çıkış nöronunun ileri yöndeki bağlantılarının ağırlıklarının oluşturduğu W_i vektörü, temsil ettiği sınıfın bir örneğini oluşturur. İleri bağlantılarının W_i vektörlerinin toplamı ART ağının uzun-dönem (long-term) hafızasını oluşturur. Bu vektörler, giriş desenine benzerlikleri ölçüşünde, çıkış nöronlarını belirlerler. Çıkış nöronlarının geri bağlantılarının W_i vektörleri ise, giriş deseninin, hafızadaki desene yeterince benzeyip benzemediğini (o sınıfa ait olup olmadığını) kesin olarak belirlemek için bir çeşit test “vigilance” amacıyla kullanılır. Bu test vektörleri diyebileceğimiz V_i vektörleri ART ağının kısa-dönem (short-term) hafızasını oluştururlar. W_i , V_i ’nin normalize edilmiş halidir.

$$W_i = \frac{V_i}{\epsilon + \sum V_{ij}} \quad (3.37)$$

Burada ϵ küçük bir sabittir ve V_{ji} , V_i 'nin j 'inci elemanıdır.



Şekil 3.20. ART-1 Ağı

3.1.6. Biyomedikal işaret işlemede yapay sinir ağları

Yapay sinir ağları ile hesaplama, yapay zeka tarihindeki en hızlı gelişen alanlardan birisidir. Çünkü sinir ağları giriş ve çıkış arasında doğrusal olmayan örüntüleri tanıması için eğitilebilir ve kompleks sorunları sayısal bilgisayarlardan daha hızlı çözebilirler. Yapay sinir ağlarının geniş uygulanabilirlik alanları ve karmaşık ve doğrusal olmayan ilişkileri öğrenme yetenekleri onları biyomedikal mühendisliğinde ve özellikle de biyomedikal işaretlerin analizindeki sorunları çözmeye cazip hale getirmiştir. Yapay sinir ağları, sürekli konuşma tanımda ve sentezinde, örüntü tanımda (pattern recognition), gürültülü veriyi sınıflandırmada, doğrusal olmayan özellik algılamada ve diğer alanlarda önemli gelişmelere sahiptir. Yapısı gereği yapay sinir ağları, gerçek zamanda yüksek-hız paralel işaret işleme yeteneğine sahiptir. Geleneksel teknolojilere göre oldukça avantajlıdır; çünkü, algoritmik çözümü olmayan veyahut algoritmik çözümü bulunamayacak kadar kompleks problemleri çözebilirler. Yapay sinir ağları, kurallar yerine örnek tarafından eğitilir ve otomatik hale getirilir. Tıbbi teşhiste kullanılırken, insan yorgunluğu, duygusal durumlar gibi faktörlerden etkilenmezler. Hızlı tanımlama, şartları analiz etme ve gerçek zamanda teşhis etme yeteneğine sahiptirler [10].

3.1.7. Nörolojide yapay sinir ađları

Yapay sinir ađları nöroloji de de kendine uygulama alanı bulmuştur. Özellikle hafıza da oluşan hastalıkların belirlenmesinde ve Parkinson ve Alzheimer gibi kolaylıkla tespit edilen hastalıklarda kullanılmaktadır. Her iki hastalıkta yok edici etkiler gösterip bunun sonucunda yaşamı bozucu etki yaparlar [11].

3.2. Metot

3.2.1. Giriş

Bu çalışmada kullanılan EEG verileri Bonn Üniversitesi veri tabanından elde edilmiştir. Sinyallerin örnekleme frekansı 173.61 Hz'dir. Sinyalleri görüntülemek ve analiz etmek için MATLAB 7.5 araç kutuları kullanılmıştır. Spektral Analizi gerçekleştirilen verilerin sınıflandırma probleminin matematiksel olarak bağıntısı kurulamayan, ya da kurulsada dahi çözümlenmesi çok karmaşık olan problemlerin sezgisel olarak çözümlenmesine imkan sağlayan YSA ile çözülmesi hedeflenerek bu yönde çalışılmıştır.

Yapay sinir ağlarının en yaygın kullanılan mimarisi, geri-yayılım algoritması tarafından eğitilen çok katmanlı algılayıcı mimarisidir. Geri-yayılım algoritması ağın ortalama karesel hatasını minimum yapmaya çalışan bir gradient-descent algoritmasıdır. Gerçek uygulamalarda, ağ basit tek boyutlu bir sistem değildir ve hata eğrisi yuvarlak şekilli veya düzgün değildir. Bunun yerine oldukça kompleks olup tepe ve vadilerden oluşmuş çok boyutlu bir eğri şekline sahiptir [7,10,12].

Geri yayılım algoritması bir çok uygulamalarda kullanılmış en yaygın öğrenme algoritmasıdır. Anlaşılması kolay ve tercih edilen öğretim algoritmasıdır. Bu algoritma ; hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geri yayılım ismini almıştır. Geri yayımlı öğrenme kuralı ağ çıkışındaki mevcut hata düzeyine göre her bir tabakadaki ağırlıkları yeniden hesaplamak için kullanılmaktadır. Bir geri yayımlı ağ modelinde giriş , gizli ve çıkış olmak üzere 3 katman bulunmakla birlikte , problemin özelliklerine göre gizli katman sayısını artırabilmek mümkündür [7,10,12].

Geri-yayılım ilk olarak P.Werbos tarafından 1974' te geliştirilmiştir. Parker tarafından 1982' de yeniden keşfedilip daha sonra 1986' da Rummelhart tarafından popüler hale getirilmiştir. Bu algoritmanın birçok değişik varyasyonları vardır. Bunlar özellikle hızını ve performansını arttırmak üzerine yapılan çalışmalardır [7,9,11].

3.2.1.1. Geriyayılım algoritması için veri hazırlanması

Geriyayılımda üç tip veri kullanılır. Eğitim kümesi, test kümesi ve gerçek veri. Eğitim kümesi, YSA'nın uygun ağırlıklarının konfigürasyon edilmesinde kullanılır. Doğru ağırlıklı YSA, test kümesi ile test edilir. Test kümesi eğitim kümesinin birinci altkümesidir. Eğer YSA eğitim kümesini ezberlemiyorsa, test verisinin uygulanmasında başarıya ulaşılmıştır. Böylelikle YSA gerçek problemlere (özel gerçek verilere) uygulanabilir. Eğitim veri kümesinin çok önemli bir rolü vardır ve özenli bir seçim gerektirmektedir. YSA ile gösterilen

bilgi ancak onun eğitiminde kullanılan veri gibidir. Verinin hazırlanması üç adım gerektirmektedir: Verinin ayrıntıları, verinin denetlenmesi ve verinin ön işlemedir. Bazı zamanlar ilk adım en güç olanıdır. (Özgül problem hakkında neyin önemli olduğu ile etkilenirler.) Problemin bütünüyle YSA ile belirtilmesi önemlidir. Bununla birlikte; her giriş karakteristiği YSA’nda giriş düğümü olarak gösterildiğinden ve çok sayıda giriş karakteristiği geniş bir YSA’ya gereksinim duyulduğundan YSA’nın karakteristiklerin her tipini içermesi mümkün değildir. Genelde geniş bir YSA, daha fazla hesaplama gücü gerektirir ve çevrim daha yavaş olur. YSA’nın sadece giriş-çıkış ilişkisinin öğrenilmesinin mümkün olduğu girişlere gereksinimi bulunmaktadır. Eğitim başladıktan sonra, YSA’nın birkaç çevrim sonunda giriş katmanına bağlı ağırlıklar bazı sonuçlar vermektedir. YSA tarafından gereksinim duyulmayan herhangi bir ağırlık, gerçekten ihtiyaç duyulan diğer ağırlıklarla karşılaştırıldığında küçük ağırlıklara sahiptir [10].

Veri hazırlamanın ikinci aşamasında eğitim kümesinden herhangi sahte verilerin dışarı atılması için olağan olmayan davranışlar aranmak üzere veri gözden geçirilir. Veri hazırlanmasında son aşamada; YSA’nın girişleri için verinin normalizasyonu gerekmektedir. Geriye YSA 0 ila 1 aralığında veri tercih edilir. Veri normalizasyonu için, eğitim kümesindeki her girişin tipik aralığı göz önüne alınmak zorundadır. Çeşitli yollarla normalize değerler (n_v) tanımlanabilir.

$$n_v = \frac{\text{gerçek değer-minimum değer}}{\text{maksimum değer-minimum değer}} \quad (3.38)$$

Geriyayılım YSA’nın eğitilmesi için gereken veri sayısı da önemli bir faktördür. Eğer problem alanı kompleks ise, daha geniş veriye ihtiyaç vardır [10].

3.2.1.2. Düğüm ve katmanlar

Geriyayılım algoritmasının zor yönlerinden birisi direkt bir metodun olmamasından gizli katman sayısı ve gizli düğüm sayılarının seçimidir. Giriş ve çıkış düğümleri problem gözden geçirilerek tespit edilir, gereksinim duyulan gizli katmanlar ve gizli düğümlerin sayısı önceden bilinmemektedir. Bununla birlikte bu gizli düğüm ve gizli katman seçimini kolaylaştırmamaktadır. Örneğin, tek gizli katmanlı bir YSA’da eğer gizli katman düğüm sayıları çok miktarda ise YSA kolay basit bir şekilde eğitim kümesini ezberlemesini sağlar [10].

Çok az gizli düğüm olması durumunda ise iyi bir öğrenme gerçekleşemez. Optimal gizli düğüm sayısı sınırlayan bu iki şekil arasında bir yerde bulunmaktadır. Uygulamalara özgü

olarak ilk olarak gizli katman düğüm sayısı uydurulur. YSA tarafından test verisi kullanılarak kararlaştırılır. Genellikle YSA eğitim verisini ezberler fakat yeni bir veri uygulandığında genelde doğru olmayan sonuçlar verir. Bu durumda gizli düğüm sayıları indirgenir ve çıkış kontrol edilir. Gizli katman sayısı tekrar indirilir, YSA tekrar eğitilir. Böylelikle gizli düğüm sayısı bulunmaya çalışılır. Tek bir gizli katman içeren YSA'nda bazen sadece bir gizli düğüm kullanılır fakat saklı düğüm sayıları problem ilişkisine bağlıdır. Bununla birlikte, bazen çoklu gizli katmanlar kullanışlı olabilirler. Buna göre; teoride durağan ileri beslemeli tek gizli katmanlı, YSA herhangi doğrusal olmayan bir sistemin eşlemesi yapılabilir. Pratikte iki gizli katmanlı YSA sıklıkla kullanılmaktadır. Böyle YSA'nın değişik yakınsama özellikleri sunmalarına rağmen, iki katmanlı ağdan elde edilenden oldukça farklı olabilecek dayanıklılık ve genelleme karakteristikleri sunar [10].

3.2.1.3. Geriyayılım eğitimi ve öğrenimi

Eğitim aşamasında, giriş vektörleri YSA'na sırasıyla uygulanır ve eğer sinir ağının çıkışı doğru ise ağ mimarisi (ağırlıklar ve biaslar) değiştirilmez, diğer durumlarda değiştirilirler. Giriş eğitim vektörlerinin uygulanması ile eşzamanlı olarak YSA'nın eğitilmesi mümkündür. Geriyayılım algoritması kullanıldığında YSA'nın eğitimi genellikle yavaştır. Genelde yakınsamaya ulaşmadan önce bu bir kaç bin devir (epoch) almaktadır [10].

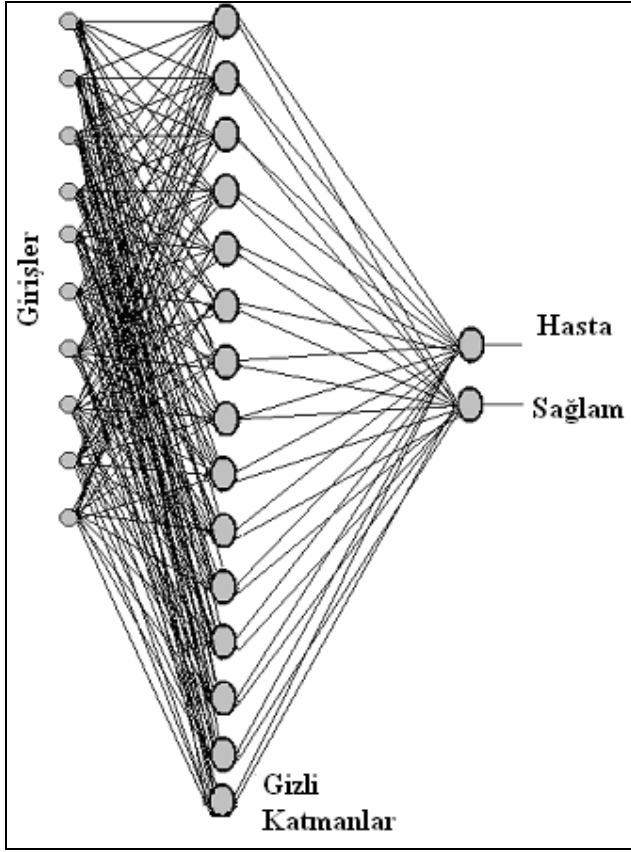
Bununla birlikte; geriyayılım algoritma tabanlı simülasyonun çalıştırılması büyük problemlerde dahi sadece birkaç saniye gerektirmektedir. Teorik olarak; ileri yönlü bir çalışmada düğüm aktivasyonları giriş katmanından akış yönüne ilk önce hesaplanır. Daha sonra ağ çıkışı veya çıkışları istenilen değer veya değerlerle karşılaştırılır ve hata ağırlıkların ayarlanması için geri yayılır. Bununla beraber pratikte birkaç sayısal hızlandırma teknikleri öğrenme işlemini hızlandırmaktadır. Geriyayılımın öğrenilmesi iki adımdan oluşur. İlk adımda giriş katmanından akış yönünde olan tüm düğümler için düğüm aktiviteleri hesaplanır. İkinci adımda, ağın çıkışı (çıkış düğüm veya düğümlerinin aktivasyon değer veya değerleri) arzulanan çıkış değer veya değerleri ile kıyaslanır. Daha sonra hata ağda çıkış katmanından akış yönüne ters yönde tüm ara bağlantıları sağlayan ağırlıkların ayarlanarak geriye doğru aktarılacak yayılır. Çıkış katmanında, ağırlıklar genellikle doğrudan doğruya bir kez düğüm hatası hesaplandığında modifiye edilir. Eğer bir genel çıkış düğümü j ., önceki katmanın i . düğümüne bağlanırsa, ağırlık değişimi aşağıdaki gibi ifade edilebilir.

$$\Delta w_{ij} = \eta \delta_j y_i = \eta (d_i - y_i) f'_j(S_j) y_j \quad (3.39)$$


Bu ‘‘Delta Öğrenme Kuralı’’ olarak da adlandırılır. Eşitlik 3.39’da η öğrenme oranı, δ çıkış düğümü (j . düğüm) eşdeğer hatası ve y_j ; i .düğüm çıkış sinyali. Ağırlık değişimi; öğrenme katsayısı çarpı j . düğüm çıkışının eşdeğer hatası çarpı i . düğümün aktivasyon sinyalidir. Eşdeğer hata; d ’nin j . düğümün istenen çıkış değeri ve y_j , j . düğümün gerçek çıkış değeri olmak üzere hata sinyaline karşılık gelen ($e_j = d_j - y_j$) ile aktivasyon fonksiyonunun türevinin $f'_j(S)$ çarpımıdır. Bunu takiben düğüm hatası öğrenildiğinde, o düğüme etki eden tüm ağırlıkların ayarlanması hesaplanabilir ve uygulanır. Bu bazen ‘‘stokastik güncelleme metodu’’ olarak adlandırılır. Alternatif olarak, tüm ağırlık değişimleri saklanabilir çevrim arasında sadece bir kez uygulanır. Bu da ‘‘kümülatif güncelleme’’ metodu olarak adlandırılır ve özel koşullar altında yakınsama oranını geliştirmektedir. Bu teknik seyrek olarak kullanılır, fakat stokastik güncelleme veya kümülatif metotlardan biri kullanıldığında, amaç aynıdır. Amaç, hata için kabul edilebilir minimum elde etmektir. ‘‘Kabul edilebilir’’ olması birden fazla çözümün olduğu izlenimini uyandırmaktadır [10].

Çıkış katmanı ile ilişkilendirilip bağlanmış ağırlıklar için 3.39 eşitliği uygulanmaz. Genelleştirilmiş Delta Öğrenme Kuralı kullanılır. Bu durumda, ağırlık güncellemesi için $\eta \delta_j y_j$ kullanımı yerine benzer bir ifade kullanılır. Bu ifadede δ_j , genel hata eşdeğeri ile yer değiştirilir. Genel eşdeğer hata, birbirine yakın takip eden düğüm katmanlarının eşdeğer hatalarının ağırlıklı toplamı ile orantılıdır. Giriş eğitim kümesindeki tüm vektörler için en küçük ortalamalı kareler (Least Mean Square LMS) hatası daha önceden belirlenen bir değer altında kaldığında öğrenme tamamlanmış ve bir çözüm elde edilmiştir. Çevrim sayısına karşı LMS hatasının çizimi öğrenme eğrisini verir. Eğer sistemin kabul edilebilir bir çözüme yakınsadığı düşünülüyorsa bu eğri düşer. YSA’nın öğrenme işlemleri esnasında bu eğriyi gözden geçirmek faydalı olabilir ve işlem durdurulur, bazı değerler modifiye edilir ve algoritmaya dönülür [10].

Analiz için oluşturulan sinir ağ yapısı denemelerden sonra en iyi sonucu verecek şekilde 15 nöronlu gizli katman bir çıkış katmanı olan 2 nöronlu bir yapıya sahiptir. Şekil 4.3’de görüldüğü gibi giriş sayısı da 10 olarak seçilmiştir. Ağın eğitimi için verilerden 10 adet sağlam ve 10 adet hasta kişilere ait sinyaller kullanılmıştır. Ağ eğitildikten sonra 90 sağlıklı ve 90 hasta EEG sinyali ile test edilmiştir. Kullanılan ağda trainlm, trainrp, traingdm öğrenme algoritmaları kullanılmış ve karşılaştırılmıştır.



Şekil 3.21. Yapay Sinir Ağı Yapısı

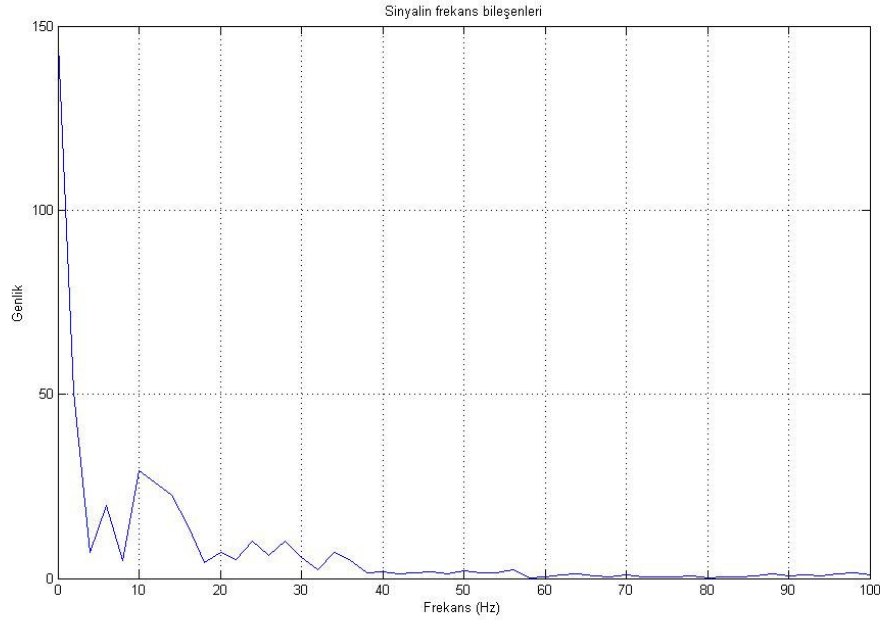



Şekil 3.21. Çok Katmanlı Bir Ağ İçin Geriyayılım Akış Şeması



4. BULGULAR VE TARTIŞMA

Bu çalışmada 100 sağlıklı kişiden ve 100 epileptik bozukluk gösteren hastadan alınan sinyaller kullanılmıştır. Sinyaller 173.61 Hz’de örneklenmiş olup 0.53-40Hz’lik bant geçiren filtreye uygulanmıştır. Sinyaller 23,6 saniye süresince kaydedilmiştir [13].



Şekil 4.1’de sağlıklı kişilere ait ham (işlenmemiş) EEG sinyalleri ve Hızlı Fourier Dönüşümü (FFT) uygulandıktan sonra oluşan sinyaller görülmektedir. Şekil 4.2’de de hasta (epilepsi) kişilere ait ham (işlenmemiş) EEG sinyalleri ve FFT sonucunda oluşan sinyaller gösterilmektedir.



(a)

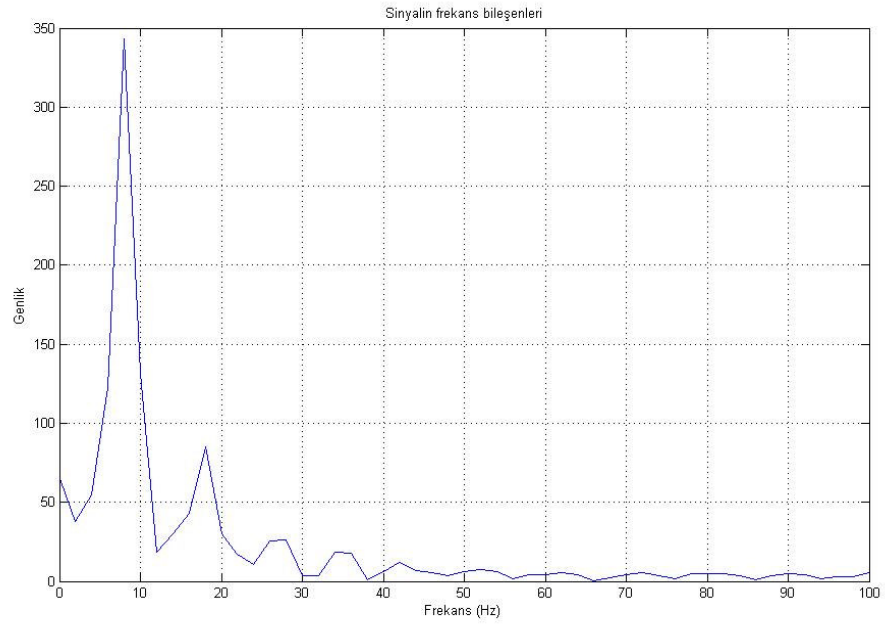



(b)

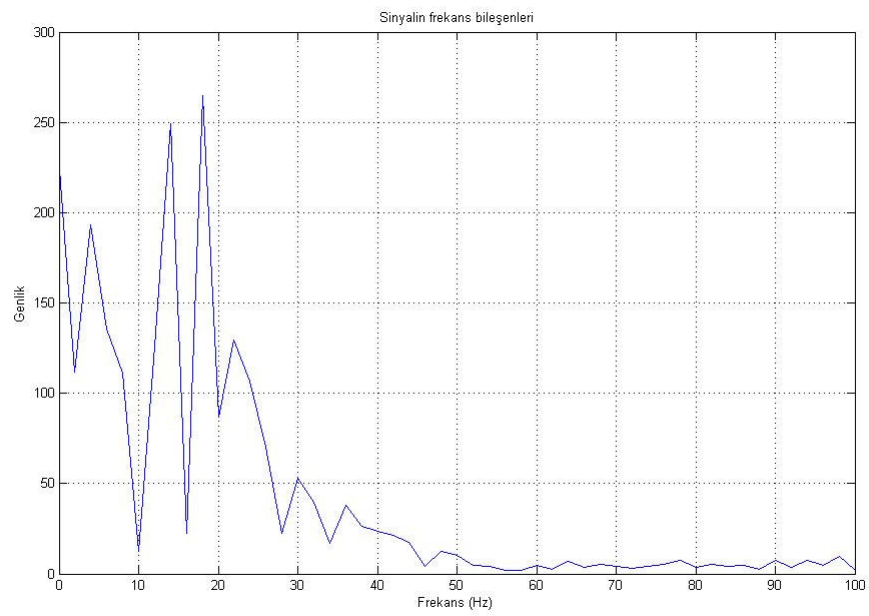



(c)


Şekil 4.1. Sağlıklı kişilerden elde edilen EEG örnekleri ve FFT sonuçları



(a)



(b)



(c)


Şekil 4.2. Hasta kişilerden elde edilen EEG örnekleri ve FFT sonuçları

Burada oluşan FFT sonuçları incelendiğinde sağlıklı kişilerde meydana gelen sapmalar ile bu sapmalara karşılık gelen frekans değerleri arasındaki bağlantı ortaya çıkmaktadır. Daha önce EEG sinyalleri ile ilgili verilen bilgilerde de anlatıldığı üzere alfa sinyalleri 8-12'Hz frekansında ve normal kişilerde görülmektedir ve genlikleri çok büyük değildir. Bu sonuç oluşan FFT sinyal sonuçlarını destekler durumdadır. Hasta kişilere (epilepsi) ait FFT sonuçları da aynı şekilde incelendiğinde genliklerinde ani sapmalar meydana gelmektedir. Sağlıklı kişilere göre aynı frekansa karşılık gelen ani sapmalar EEG işaretinde oluşan farklılığa işaret etmektedir. Epilepsi hastalığında sinyalin frekansında bir değişiklik olmamakla beraber genliğinde ani yükselmeler olmaktadır.

FFT analizi yapılmış EEG işaretleri geriyayılım algoritması kullanılarak analiz edilmeye çalışılmıştır.

İlk olarak trainlm (Levenberg-Marquardt geriyayılım) algoritması kullanılmıştır. Şekil 4.4'de eğitim grafiği görülen ağda hata değeri 10^{-5} olarak seçilmiştir . Burada momentum katsayısı

sabit olan 0.9 değeri seçilmiştir. Transfer fonksiyonu olarak da gizli katmanlar için ‘tansig’ ve çıkış katmanı için ‘purelin’ kullanılmıştır. Öğrenme katsayısı olarak da sabit değeri olan 0.05 değeri seçilmiştir. Bu değerler ağın optimal olarak çalışmasını sağlamak için denemelerden sonra bulunmuştur. Bu şekilde ağ eğitilmiş olup istenilen değere 6 denemeden (epoch) sonra ulaşılmıştır.



Şekil 4.4. LM algoritması eğitim grafiği

Daha sonra ağa test verileri uygulanmış olup ağ test edilmiştir. Ağın başarısı hesaplanmak istenilirse,

$$\text{Başarı oranı} = (\text{doğru sonuç sayısı/toplam test verisi}) * 100 \quad (4.1)$$

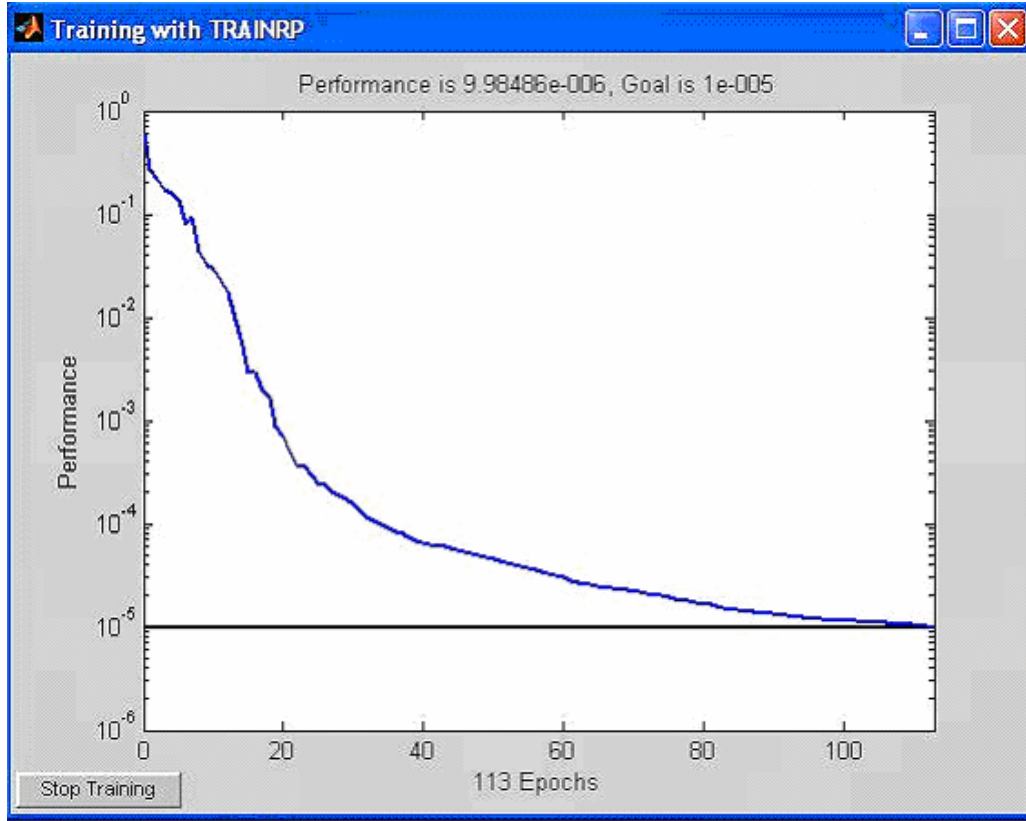
formülü ile bulunur.

Çizelge 4.1. LM algoritması performansı

Veri Sayısı		Doğru Sonuç Sayısı	Yanlış Sonuç Sayısı	Sonuç
Hasta	90	72	18	%80
Sağlıklı	90	85	5	%94
Toplam	180	157	23	%87

Ağ eğitimini 6 deneme (epoch) gibi kısa bir sürede tamamlamıştır. Bu sonuç ağın hızlı öğrenme gerçekleştirdiği gösterir. Ağa test verileri uygulandığında 90 adet sağlam verinin 85 tanesi doğru bulunmuştur. Hasta verilerde ise 90 verinin 72 tanesi doğru bulunmuştur. Burada aradaki farkın temel nedeni, hasta verilerin FFT sonuçlarından da anlaşılacağı üzere hasta verilerin daha fazla ayrıntı taşınması gösterilebilir. Sağlam verilerde ayrıntı azalmakta ve sinyaller daha kolay ayrıt edilebilmektedir. Genel olarak performansa bakıldığında hasta verilerde %80, sağlam verilerde %94 ve toplamda %87 başarı sağlanmıştır.

Daha sonra aynı işlem RP (Esnek Geriyayılım) algoritması için tekrar edilmiştir. Aynı şekilde transfer fonksiyonu gizli katmanlar için 'tansig' ve çıkış katmanı için de 'purelin' fonksiyonları seçilmiştir. Momentum katsayısı 0.9 ve öğrenme katsayısı 0.05 olarak seçilmiştir. Hata oranı 10^{-5} olarak belirlenmiştir. Elde edilen eğitim grafiği şekil 4.5'te görülmektedir. Bu değere 113 denemeden (epoch) sonra ulaşılmıştır.



Şekil 4.5. RP algoritması eğitim grafiği


Ağ daha önce gösterilmeyen test verileri ile test edildiğinde sonuç Çizelge 4.2'deki gibi olmaktadır.

Çizelge 4.2. RP algoritması performansı

Veri Sayısı		Doğru Sonuç Sayısı	Yanlış Sonuç Sayısı	Sonuç
Hasta	90	64	26	%71
Sağlıklı	90	77	13	%85
Toplam	180	141	39	%78

Sonuçlara bakıldığında 77 adet sağlam veri doğru bulunmuş, hasta verilerden iste 64 adet veri doğru bulunmuştur. Trainlm algoritması ile karşılaştırınca daha geç öğrenmenin gerçekleştiği (113 epoch) ve başarı oranının düştüğü söylenebilir. Başarı yüzdesi sağlam verilerde %85, hasta verilerde %71 ve toplam veride %78 olarak bulunmuştur.

Aynı işlem GDM(Gradient Descent With Momentum) algoritması için tekrar edilmiştir. Momentum katsayısı 0.9, öğrenme katsayısı 0.05 ve hata değeri 10^{-1} olarak seçilmiştir. Transfer fonksiyonu olarak gizli katmanlar için ‘tansig’ ve çıkış katmanı için de ‘purelin’ fonksiyonu kullanılmıştır. Elde edilen eğitim grafiği şekil 4.6’da görülmektedir. Hata oranı 10^{-1} olarak belirlenmiştir. Bu değere 1341 denemden sonra ulaşılmıştır.



Şekil 4.6. GDM algoritması eğitim grafiği

Ağ daha önce gösterilmeyen test verileri ile test edildiğinde sonuç Çizelge 4.3’deki gibi olmuştur. Traingdm algoritması diğer iki algoritmaya göre (trainlm ve traingdm) daha geç öğrenme gerçekleştirmiş ve genel başarı düzeyi de düşmüştür. Sağlam verilerde %78, hasta verilerde %64 ve toplam verilerde de %71 olarak performansı hesaplanmıştır.

Çizelge 4.3.GDM algoritması performansı

Veri Sayısı		Doğru Sonuç Sayısı	Yanlış Sonuç Sayısı	Sonuç
Hasta	90	58	32	%64
Sağlıklı	90	71	19	%78
Toplam	180	129	51	%71

5. SONUÇ VE ÖNERİLER

Sınıflandırma işlemi, en genel haliyle bir karar verme mekanizmasıdır. Bu çalışmada EEG işareti gibi durağan olmayan rasgele işaretleri sağlıklı ve hasta (epilepsi) hallerinde gösterdikleri farklılıklar değerlendirilip yapay sinir ağları kullanılarak bilgisayar destekli bir ortamda analizi yapılmıştır. Yapay sinir ağları gibi öğrenme yöntemleri örneklerden öğrenmeye dayanmaktadır. Örneklerden öğrenmenin temel felsefesi bir olay hakkındaki gerçekleşmiş örnekleri kullanarak olayın girdi ve çıktıları arasındaki ilişkileri öğrenmek ve bu ilişkilere göre daha sonra oluşacak olan yeni örneklerin çıktılarını belirlemektir. Burada bir olay ile ilgili örneklerin girdi ve çıktıları arasındaki ilişkinin olayın genelini temsil edecek bilgiler içerdiği kabul edilmektedir. Değişik örneklerin olayı değişik açılardan temsil ettiği varsayılmaktadır. Farklı örnekler kullanılarak böylece olay değişik açılardan öğrenilmektedir. Burada bilgisayara sadece örnekler gösterilmektedir. Bunlardan başka herhangi bir ön bilgi verilmektedir. Öğrenmeyi gerçekleştirecek olan sistem (bu çalışmada yapay sinir ağı) aradaki ilişkiyi kendi algoritmasını kullanarak keşfetmektedir [14,15,16].

Sinir ağının öğrenme katsayısı, aktivasyon fonksiyon değerleri gizli katman sayısı ve saklı katman nöron sayısının değişimlerine göre sinir ağının performansı değişmektedir. Bu değerler deneysel sonuçlara göre optimal duruma getirilmiştir.[17]

FFT ile işaretin zaman- ölçek domeni analizi de pratik bir şekilde elde edilebilmekte ve bu sayede sinyal bilgi kaybına uğratılmadan, sinyalde işlenmemiş haldeki verilerden sağlıklı seçilemeyen kimi detay bilgilerine ulaşılmaktadır. Bu yöntem değişik problemlerin çözümlenmesinde faydalı olabilecek bir yöntemdir. Sinyalin pencereleme aralığının değiştirilebilir olma özelliğinin, özellikle keskin sıçramaların ve süreksizliklerin meydana geldiği durumları çözmek için oldukça etkili olmasının sinyal işleme açısından önemi düşünüldüğünde, yöntemin kullanılmasının faydaları daha iyi anlaşılabilir [18].

Yapılan çalışmada en verimli sonuçların LM (Levenberg-Marquardt geriyayılım) algoritmasının kullanılmasıyla olduğu görülmektedir. Burada genel başarı %87 olmuştur. Performansa hasta ve sağlam veriler için ayrı ayrı bakılırsa sağlam verilerde başarının daha fazla olduğu gözlemlenmiştir. Sağlam verilerde başarı %94, hasta verilerde %80 olarak ölçülmüştür. Bunun nedeni hasta verilerde sinyalin özneliklerinin daha fazla olması ve bunların ayrıt edilebilirliğinin daha zor olmasıdır. Sağlam verilerde ise sinyaller arasında daha az farklılıklar bulunmakta ve bunlar daha kolay sınıflandırılabilir. Ayrıca yine sonuçlardan anlaşıldığı gibi en hızlı ağ yapısı da LM algoritmasında gözlenmiştir. (6 epoch).

Bu durumda en verimli sonucun gerek hız ve gerek başarı olarak trainlm algoritmasında elde edildiği söylenebilir. RP (Esnek geriyayılım) algoritmasında genel başarıyı %78 olarak bulunmuş ve ağıın hızı da 113 deneme (epoch) olarak gözlenmiştir. Burada da sağlam ve hasta verilerde başarı sağlam verilerde daha yüksek olmuştur. Sağlam verilerde %85, hasta verilerde %71. Son olarak da GDM (Gradient Descent with Momentum) algoritmasında genel başarı %71 olarak bulunmuştur. GDM algoritması hem hız hem de genel başarı olarak LM ve RP algoritmalarına göre daha etkisiz kalmıştır. Bu sonuçlar ardından en iyi sonucun LM algoritmasında elde edildiği gözlemlenmiştir.

Yapay sinir ağıları tabanlı sınıflandırma sistemlerinde çeşitli YSA mimarileri oluşturularak uygun YSA mimarileri seçilebilmektedir. Bu YSA mimarilerine göre sistemin performansının değiştiği örneklerde görülmüştür. Kullanılan mimaride öğrenme katsayısı, momentum sabiti gibi parametrelerin ayarlanarak sistem optimum şekle getirildiği gibi, sistem performansının artışı için sayısal hızlandırma metotlarından dinamik öğrenme metodu kullanılabilir. Bunun yanı sıra kullanılan aktivasyon fonksiyon ve parametrelerinin değişimleri ile de performans artışı mümkündür [22].

Çizelge.5.1. Elde Edilen Sonuçlar

		LM Algoritması	RP Algoritması	GDM Algoritması
Transfer fonksiyonu		Tansig Purelin	Tansig Purelin	Tansig Purelin
Öğrenme katsayısı		0.05	0.05	0.05
Momentum katsayısı		0.9	0.9	0.9
Hata oranı		10^{-5}	10^{-5}	10^{-1}
Gizli katman		15	15	15
Çıkış katmanı		2	2	2
Giriş sayısı		10	10	10
Başarı	Hasta	%80	%71	%64
	Sağlam	%94	%85	%78
	Genel	%87	%78	%71

KAYNAKLAR

1. Yazgan, E., Korurek, K. M., “Tıp Elektroniği”, **İ.T.Ü. Matbaası**, İstanbul, 95-220 (1996).
2. Elmas, Ç., “Yapay Sinir Ağları”, **Seçkin Yayıncılık**, Ankara, 36-57 (2003).
3. Başar, H., “EEG İşaretlerinin Dalgacık Analiz Yöntemleri Kullanılarak Yapay Sinir Ağları İle Sınıflandırılması”, Yüksek Lisans Tezi, **Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü**, Kahramanmaraş, 15-46, 55-61 (2005).
4. Güler, I., Kıymık, M. K., Akın, M., Alkan, A., “AR spectral analysis of EEG signals by using maximum likelihood estimation”, **Computers in Biology and Medicine**, 31: 441-450 (2001).
5. Haselsteiner, E., Pfurtscheller, G., “Using time-dependent neural Networks for EEG classification”. **IEEE Trans Rehab Eng**, 8: 457-63 (2000).
6. Roberts, R.A., Mullis, C.T., “Digital Signal Processing”, **Addison-Wesley Publishing Company**, New York, 85-102 (1987).
7. Öztemel, E., “Yapay Sinir Ağları”, **Papatya Yayıncılık**, İstanbul, 112-238 (2003).
8. Nabiyeve, V.V., “Yapay Zeka”, **Seçkin Yayıncılık**, Ankara, 14-27 (2005).
9. Kayran, A. H., Ekşioğlu, E. M., “Bilgisayar Uygulamalarıyla Sayısal İşaret İşleme”, **Birsen Yayınevi**, 104-127 (2004).
10. Sağıroğlu, S., “Mühendislikte Yapay Zeka Uygulamaları:Yapay Sinir Ağları”, **Ufuk Yayıncılık**, İstanbul, 25-36 (2003).
11. Semmlow, L., “Biosignal And Biomedical Image Processing Matlab Based Application”, **CRC Press**, New York, 198-206 (1998).
12. Uysal, M., “Matlab ile Matematiksel Uygulamalar ve Mühendislik Uygulamaları”,**Beta Yayınları**, İstanbul, 315-332 (2004).
13. İnternet: Univercity of Bonn, “EEG Database Archives”
http://www.meb.unibonn.de/epileptologie/cms/front_content.php?idcat=193&lang=3&changelang=3 (2008).
14. Webber, W. R. S., Lesser, R. P., Richardson, R. T., Wilson, K., “An approach to seizure detection using an artificial neural network (ANN)”, **Electroencephalography and Clinical Neurophysiology**, 98: 250-272 (1996).

15. Vuckovic, A., Radivojevic, V. A., Chen, C. N., Popovic, D., "Automatic recognition of alertness and drowsiness from EEG by an artificial neural network", **Medical Engineering & Physics** , 24: 349–360 (2002).
16. Tsoi, A.C., So, D.S.C., Sergejew, A., "Classification of electroencephalogram using artificial neural networks", **Medical Engineering & Physics** ,6: 1151–1158 (1994).
17. Tseng, S.Y., Chen, R.C., Chong, F.C., Kuo, T.S.," Evaluation of parametric methods in EEG signal analysis", **Medical Engineering And Physics**, 17: 71–78 (1995).
18. Anderson, C.W., Devulapalli, S. V. , Stolz, E. A.," Determining mental state from EEG signals using neural Networks", **Scientific Programming**, 4: 171-183 (1995).
19. Valluru, B. Rao .," C++ Neural Networks and Fuzzy Logic", **IDG Books Worldwide Inc**, 45-78 (1995).
20. Medsker ,L.R., Jain, L.C., "Recurrent Neural Networks Design And Applications", **CRC Press**, New York, 99-155 (1995).
21. Nikola, K. Kasabov, A., "Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering", **The MIT Press** , Massachusetts, 88-95, (1998).
22. Bankman, I.N., "Handbook Of Medical Imaging :Processing And Analysis", **Academic Press**, London, 27-38 (2001).

EKLER

Analizlerde kullanılan program metni şu şekilde yazılmıştır.

Resilient backpropagation algoritması için program

Load data

```
P=[s1 s2 s3 s4 s5 s6 s7 s8 s9 s10 e1 e2 e3 e4 e5 e6 e7 e8 e9 e10];
>> T=[0 0 0 0 0 0 0 0 0 1 1 1 1 1 1 1 1 1;1 1 1 1 1 1 1 1 1 0 0 0 0 0 0 0 0 0];
>> net=newff(minmax(P),T,[15,2],{ },'trainrp');net=init(net);
>> net.divideFcn = "";
>> net.trainParam.show= 200;
>> net.trainParam.goal = 1e-05;
>> net.trainParam.epochs = 10000;
>> [net,tr]=train(net,P,T);
TRAINRP-calcgrad, Epoch 0/10000, MSE 0.612343/1e-005, Gradient 0.729665/1e-006
TRAINRP-calcgrad, Epoch 113/10000, MSE 9.98486e-006/1e-005, Gradient
0.000344438/1e-006
TRAINRP, Performance goal met.
```

Levenberg-Marquardt backpropagation algoritması için program

```
P=[s1 s2 s3 s4 s5 s6 s7 s8 s9 s10 e1 e2 e3 e4 e5 e6 e7 e8 e9 e10];
T=[0 0 0 0 0 0 0 0 0 1 1 1 1 1 1 1 1 1;1 1 1 1 1 1 1 1 1 0 0 0 0 0 0 0 0 0];
net=newff(minmax(P),T,[15,2],{ },'trainlm');net=init(net);
net.divideFcn = "";
net.trainParam.show= 200;
net.trainParam.goal = 1e-05;
net.trainParam.epochs = 10000;
[net,tr]=train(net,P,T);
TRAINLM-calcjx, Epoch 0/10000, MSE 0.789649/1e-005, Gradient 0.889751/1e-010
TRAINLM-calcjx, Epoch 6/10000, MSE 7.73522e-007/1e-005, Gradient 0.000601287/1e-
010
TRAINLM, Performance goal met.
```

Gradient Descent With Momentum öğrenme algoritması için program:

```
P=[s1 s2 s3 s4 s5 s6 s7 s8 s9 s10 e1 e2 e3 e4 e5 e6 e7 e8 e9 e10];
T=[0 0 0 0 0 0 0 0 0 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 0 0 0 0 0 0 0 0 0];
net=newff(minmax(P),T,[15,2],{ },'traingdm');net=init(net);
net.divideFcn = "";
net.trainParam.show= 500;
net.trainParam.goal = 1e-01;
net.trainParam.epochs = 10000;
[net,tr]=train(net,P,T);
TRAININGDM-calcgrad, Epoch 0/10000, MSE 0.711874/0.1, Gradient 0.805851/1e-010
TRAININGDM-calcgrad, Epoch 500/10000, MSE 0.23469/0.1, Gradient 0.0797995/1e-010
TRAININGDM-calcgrad, Epoch 1000/10000, MSE 0.167398/0.1, Gradient 0.139192/1e-010
TRAININGDM-calcgrad, Epoch 1341/10000, MSE 0.0999781/0.1, Gradient 0.136753/1e-010
TRAININGDM, Performance goal met.
```

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : MUTLU, Sunay
Uyruğu : T.C.
Doğum tarihi ve yeri : 03.03.1982 Haskova
Medeni hali : Bekar
Telefon : 0 (346) 215 09 99
e-mail : sunaym@gmail.com

Eğitim

Derece	Eğitim Birimi	Mezuniyet tarihi
Lisans	Gazi Üniversitesi/ Elektronik Öğr.	2005
Lise	S.T.F.A Anadolu Meslek Lisesi	2000

İş Deneyimi

Yıl	Yer	Görev
2005-	M.E.B.	Öğretmen

Yabancı Dil

İngilizce

Hobiler

Spor, Film seyretme, Müzik dinleme , Teknoloji