

**DÖVİZ KURU TAHMİNİNDE
YAPAY SİNİR AĞLARININ KULLANIMI**

ÖMÜR YILDIZ

**Eskişehir Osmangazi Üniversitesi
Sosyal Bilimler Enstitüsü**

**İşletme Anabilim Dalı
İşletme Bilim Dalı
YÜKSEK LİSANS TEZİ**

**Eskişehir
Temmuz, 2006**

Sosyal Bilimler Enstitüsü Müdürlüğüne

Bu çalışma, jürimiz tarafından İşletme Anabilim dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Başkan

Yrd. Doç. Dr. İnci PARLAKTUNA

Üye

Yrd. Doç.Dr. Birol YILDIZ

(Danışman)

Üye

Yrd. Doç. Dr. Nurullah UÇKUN

ONAY

.. / .. / 2006

Enstitü Müdürü

Prof. Dr.F. Münevver YILANCI

ÖZET

DÖVİZ KURU TAHMİNİNDE YAPAY SİNİR AĞLARININ KULLANIMI

YILDIZ, ÖMÜR

Yüksek Lisans – 2006

İşletme Bilim Dalı

Danışman: Yrd. Doç.Dr. Birol YILDIZ

Bu tez çalışmasının amacı, günümüzün umut verici yapay zekâ tekniklerinden birisi olan Yapay Sinir Ağlarının ekonomi ve finans alanında bir uygulamasını gerçekleştirmektir. Gerçekleştirilen uygulamada, döviz kurlarının gelecekteki değerinin ve yönünün yüksek doğruluk oranı ile öngörülmesine çalışılmıştır.

Bu çalışmada kullanılan veriler, T.C. Merkez Bankası'nın web sitesinden elde edilmiştir. USD'nin değerine etki ettiği düşünülen 41 değişik ekonomik parametre ve değişkene dair 4 Ocak 1999 ile 28 Şubat 2006 tarihleri arasında toplam 1867 günlük veri kullanılmıştır.

Araştırma ve uygulama sonucunda, yapay sinir ağlarının mimarileri, katman sayıları ve katmanlardaki hücre sayıları, eğitim yöntemleri gibi parametrelerin ağın doğru çözüme yaklaşmasında ne kadar etkili olduğu gözlemlenmiştir. Dövizin gelecekteki değerinin ne olacağının, yükselip düşeceğinin öngörülmesinde YSA'ların bir karar destek aracı olabileceği saptanmıştır.

ABSTRACT

USING ARTIFICIAL NEURAL NETWORKS

FOR

FORECASTING USD EXCHANGE RATES

YILDIZ, ÖMÜR

Master Thesis – 2006

Business Administration

Advisor: Birol YILDIZ, Assistant Professor

The purpose of this study was to perform an application of Artificial Neural Networks (ANN) which are one of the promising Artificial Intelligence techniques nowadays, on economical and financial sectors.

Data were collected from the official web site of Central Bank of the Republic of Turkey. 41 economical parameters and variables which affect the fluctuations of the USD were used in this study. 1867 days of data between 4 January 1999 and 28 February 2006 used in this study.

As a result of this study we determined how affects these parameters such as the structure of ANN, number of layers in the ANN and artificial neurons in the layers, the training methods to reach the best solution. We have decided that ANNs can be used as a supplementary tool to predict future value and trend of the USD.

İÇİNDEKİLER

Sayfa No

ÖZET	iii
ABSTRACT	iv
İÇİNDEKİLER	v
ŞEKİLLER DİZİNİ.....	vii
TABLolar DİZİNİ	ix
EKLER LİSTESİ	xi
KISALTMALAR	xii
ÖNSÖZ	xiv
GİRİŞ	1

BÖLÜM I

1 DÖVİZ KURU VE DÖVİZ KURUNUN TAHMİNİ.....	5
1.1 DÖVİZ KURU	5
1.2 DÖVİZ KURUNUN BELİRLENMESİNE YÖNELİK YAKLAŞIMLAR	8
1.2.1 Satın Alma Gücü Paritesi	9
1.2.2 Parasal Yaklaşım	10
1.2.3 Çağdaş Parasal Yaklaşım	10
1.2.4 Portföy Yaklaşımı	11
1.3 DÖVİZ KURU SİSTEMLERİ.....	12
1.3.1 Serbest Kur Sistemi (Free Float).....	12
1.3.2 Gözetimli Dalgalanma (Managed Float).....	13
1.3.3 Aralık İçinde Dalgalanma (Floating within a Band).....	13
1.3.4 Kayan Aralık (Sliding Band)	13
1.3.5 Yönlendirilmiş Sabit Aralık (Crawling Band)	14
1.3.6 Yönlendirilmiş Sabit Parite (Crawling Peg System).....	14
1.3.7 Ayarlanabilir Sabit Kur Sistemi (Bretton Woods System)	14
1.3.8 Sabit Kur	15
1.3.9 Yabancı Ülke Parasının Kullanılması(Resmi Dolarizasyon).....	16
1.4 DÖVİZ KURUNU TAHMİN ETME YÖNTEMLERİ	16
1.4.1 Analiz Yöntemleri	17
1.4.2 Tahmin Yöntemleri	18
1.4.3 Tahmin Yöntemlerinin Doğruluğu (Performanslarının Ölçülmesi),.....	30
1.4.4 Zaman Serilerinin Finans Alanında Kullanımı İçin Çözümlemesinde Karşılaşılan Zorluklar.....	33

BÖLÜM II

2 YAPAY SİNİR AĞLARI; EKONOMİ VE FİNANSTA KULLANIMI.....	35
2.1 YAPAY ZEKÂYA GENEL BAKIŞ	35
2.1.1 Yapay Zekânın Gelişimi	37
2.1.2 Turing Testi.....	38
2.1.3 Yapay Zekâ Teknikleri.....	38
2.2 SİNİR HÜCRELERİ VE SİNİR AĞLARI	46
2.2.1 İnsan Beyni	46
2.2.2 Biyolojik Sinir Hücreleri	49
2.2.3 Yapay Sinir Hücreleri	52
2.3 YAPAY SİNİR AĞLARI (YSA).....	59
2.3.1 YSA'nın Gelişimi	59
2.3.2 Yapay Sinir Ağlarının Yapısı.....	63
2.3.3 Yapay Sinir Ağlarında Öğrenme Kuralları	71
2.3.4 Yapay Sinir Ağlarında Öğrenme Stratejileri.....	73
2.3.5 Bir YSA Modellemesinde Dikkat Edilecek Hususlar.....	76
2.3.6 Yapay Sinir Ağlarının Genel Özellikleri.....	78
2.3.7 Yapay Sinir Ağlarının Dezavantajları.....	81
2.3.8 Yapay Sinir Ağlarının Uygulama Alanları	83
2.4 GERİYE YAYILIM (BACK PROPOGATION) ALGORİTMASI (GYA)..	88
2.4.1 GYA'da Karşılaşılan Sorunlar	91
2.4.2 GYA'nın İşlem Adımları	95
2.5 YSA'NIN EKONOMİ VE FİNANS ALANINDA KULLANIMI.....	98
2.5.1 ÖNGÖRÜDE KULLANILACAK BİR YSA MODELLEMENİN İÇİN GEREKLİ İŞLEM ADIMLARI.....	100

BÖLÜM III

3 UYGULAMA	110
3.1 GİRİŞ	110
3.2 VERİ	111
3.3 YÖNTEM.....	111
3.4 BULGULAR.....	115
3.4.1 ACXY. M Grubunda Denenen YSA'lar	115
3.4.2 Kriz Sonrasındaki Verilerle Yapılan Denemeler	122
3.4.3 Döviz Kurunun Yönünün Belirlenmesine Dair Yapılan Çalışmalar.....	123
3.4.4 BDFY. M Grubunda Denenen YSA'lar.....	126
3.4.5 Elman Ağları İle Yapılan Denemeler.....	128

BÖLÜM IV

4 SONUÇ VE ÖNERİLER	129
5 KAYNAKLAR	134
6.EKLER.....	148

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1 – Bir uzman sistemin genel yapısı	42
Şekil 2 – Üyelik fonksiyonlarına örnekler	44
Şekil 3 – İnsan beyni ve fonksiyonları	47
Şekil 4 – Bir kaç tane sinir hücresinden oluşan bir sinir ağı	49
Şekil 5 – Yaklaşık 4 mikron büyüklüğünde olan bir sinir hücresi	50
Şekil 6 – Sinir hücresi ve organelleri	51
Şekil 7 – Matematiksel modelleme ile elde edilen bir Yapay Sinir Hücresi	52
Şekil 8 – Lineer aktivasyon fonksiyonu	54
Şekil 9 – Step aktivasyon fonksiyonu	55
Şekil 10 – Eşik değer aktivasyon fonksiyonu	55
Şekil 11 – Hiperbolik tanjant aktivasyon fonksiyonu	55
Şekil 12 – Sigmoid aktivasyon fonksiyonu	56
Şekil 13 – Gauss aktivasyon fonksiyonu	56
Şekil 14 – Yapar sinir hücresi	58
Şekil 15 – Yapay bir sinir ağına genel bir örnek	63
Şekil 16 – MATLAB’de yapay sinir ağının gösterimi	64
Şekil 17 – Tek katmanlı bir YSA	66
Şekil 18 – Çok katmanlı bir YSA	67
Şekil 19 – Radyal tabanlı bir YSA	68
Şekil 20 – Elman Yapay Sinir Ağı	69
Şekil 21 – Hopfield Yapay Sinir Ağı	69
Şekil 22 – YSA modellemesi akış şeması	76
Şekil 23 – Bir GYA ağı modeli	89
Şekil 24 – Hata değerlerinin seyri	93
Şekil 25 – Ağın yerel minimuma takılmasının sonucu	115
Şekil 26 – ACF01 kodlu YSA’nın ürettiği grafikler	117
Şekil 27 – ACF04 kodlu YSA’nın ürettiği grafikler	120
Şekil 28 – ACE01 kodlu YSA’nın ürettiği grafikler	160
Şekil 29 – ACF01 kodlu YSA’nın ürettiği grafikler	161
Şekil 30 – ACG01 kodlu YSA’nın ürettiği grafikler	162
Şekil 31 – ACH01 kodlu YSA’nın ürettiği grafikler	163
Şekil 32 – ACI01 kodlu YSA’nın ürettiği grafikler	164
Şekil 33 – ACJ01 kodlu YSA’nın ürettiği grafikler	165
Şekil 34 – ACK01 kodlu YSA’nın ürettiği grafikler	166
Şekil 35 – ACL01 kodlu YSA’nın ürettiği grafikler	167
Şekil 36 – ACM01 kodlu YSA’nın ürettiği grafikler	168
Şekil 37 – ACN01 kodlu YSA’nın ürettiği grafikler	169
Şekil 38 – ACO01 kodlu YSA’nın ürettiği grafikler	170
Şekil 39 – ACP01 kodlu YSA’nın ürettiği grafikler	171
Şekil 40 – ACE04 kodlu YSA’nın ürettiği grafikler	172
Şekil 41 – ACF04 kodlu YSA’nın ürettiği grafikler	173

Şekil 42 – ACG04 kodlu YSA'nın ürettiği grafikler	174
Şekil 43 – ACH04 kodlu YSA'nın ürettiği grafikler	175
Şekil 44 – ACI04 kodlu YSA'nın ürettiği grafikler	176
Şekil 45 – ACJ04 kodlu YSA'nın ürettiği grafikler	177
Şekil 46 – ACK04 kodlu YSA'nın ürettiği grafikler	178
Şekil 47 – ACL04 kodlu YSA'nın ürettiği grafikler	179
Şekil 48 – ACM04 kodlu YSA'nın ürettiği grafikler	180
Şekil 49 – ACN04 kodlu YSA'nın ürettiği grafikler	181
Şekil 50 – ACO04 kodlu YSA'nın ürettiği grafikler	182
Şekil 51 – ACP04 kodlu YSA'nın ürettiği grafikler	183
Şekil 52 – ACF02 kodlu YSA'nın ürettiği grafikler	184
Şekil 53 – ACF03 kodlu YSA'nın ürettiği grafikler	185
Şekil 54 – ACF05 kodlu YSA'nın ürettiği grafikler	186
Şekil 55 – ACF06 kodlu YSA'nın ürettiği grafikler	187
Şekil 56 – ACF07 kodlu YSA'nın ürettiği grafikler	188
Şekil 57 – ACF08 kodlu YSA'nın ürettiği grafikler	189
Şekil 58 – ACF09 kodlu YSA'nın ürettiği grafikler	190
Şekil 59 – ACF10 kodlu YSA'nın ürettiği grafikler	191
Şekil 60 – ACF11 kodlu YSA'nın ürettiği grafikler	192
Şekil 61 – ACF12 kodlu YSA'nın ürettiği grafikler	193
Şekil 62 – ADF01 kodlu YSA'nın ürettiği grafikler	194
Şekil 63 – ADF11 kodlu YSA'nın ürettiği grafikler	195
Şekil 64 – ELMCF01 kodlu YSA'nın ürettiği grafikler	196
Şekil 65 – ELMCF11 kodlu YSA'nın ürettiği grafikler	197

TABLOLAR DİZİNİ

Sayfa No

Tablo 1 – Yapay Zekâ ile Doğal Zekânın karşılaştırılması	45
Tablo 2 – Beynin bölgelere göre fonksiyonları.....	47
Tablo 3 – Beyin ile bilgisayarın basitçe karşılaştırılması	48
Tablo 4 – Sinir hücrelerini oluşturan organeller ve görevleri	51
Tablo 5 – Toplayıcı fonksiyonları	54
Tablo 6 – MATLAB’de kullanılan aktivasyon fonksiyonları ve komutları.....	57
Tablo 7 – XOR fonksiyonu	61
Tablo 8 – XOR probleminin YSA ile çözümünün grafiksel gösterimi	62
Tablo 9 – YSA türleri ve uygulama alanları	70
Tablo 10 – Öğrenme algoritmaları ve kullanım alanları	75
Tablo 11 – Uzman Sistemler ile YSA’ların karşılaştırılması	81
Tablo 12 – ACx01 grubunda çalıştırılan ağlara ait veriler	116
Tablo 13 – ACx04 grubunda çalıştırılan ağlara ait veriler	119
Tablo 14 – ACF grubunda çalıştırılan ağlara ait veriler	121
Tablo 15 – ADF grubuna ait veriler	122
Tablo 16 – B2CF01 ağına ait veriler	124
Tablo 17 – B2CF11 ağına ait veriler	125
Tablo 18 – B2DF01 ağına ait veriler	126
Tablo 19 – B2DF11 ağına ait veriler	127
Tablo 20 – Elman ağına ait veriler	128
Tablo 21 – ACE01(trainbfg) ağına ait veriler	160
Tablo 22 – ACF01(trainbr) ağına ait veriler	161
Tablo 23 – ACG01(traicgb) ağına ait veriler	162
Tablo 24 – ACH01(traicgf) ağına ait veriler	163
Tablo 25 – ACI01(traicgp) ağına ait veriler	164
Tablo 26 – ACJ01(traingd) ağına ait veriler	165
Tablo 27 – ACK01(traingdm) ağına ait veriler	166
Tablo 28 – ACL01(traingdx) ağına ait veriler	167
Tablo 29 – ACM01(trainlm) ağına ait veriler	168
Tablo 30 – ACN01(trainoss) ağına ait veriler	169
Tablo 31 – ACO01(trainrp) ağına ait veriler	170
Tablo 32 – ACP01(trainscg) ağına ait veriler	171
Tablo 33 – ACE04(trainbfg) ağına ait veriler	172
Tablo 34 – ACF04(trainbr) ağına ait veriler	173
Tablo 35 – ACG04(traicgb) ağına ait veriler	174
Tablo 36 – ACH04(traicgf) ağına ait veriler	175
Tablo 37 – ACI04(traicgp) ağına ait veriler	176
Tablo 38 – ACJ04(traingd) ağına ait veriler	177
Tablo 39 – ACK04(traingdm) ağına ait veriler	178
Tablo 40 – ACL04(traingdx) ağına ait veriler	179
Tablo 41 – ACM04(trainlm) ağına ait veriler	180

<i>Tablo 42 – ACN04(trainoss) ağına ait veriler</i>	<i>181</i>
<i>Tablo 43 – ACO04(trainrp) ağına ait veriler</i>	<i>182</i>
<i>Tablo 44 – ACP04(trainscg) ağına ait veriler</i>	<i>183</i>
<i>Tablo 45 – ACF02 ağına ait veriler</i>	<i>184</i>
<i>Tablo 46 – ACF03 ağına ait veriler</i>	<i>185</i>
<i>Tablo 47 – ACF05 ağına ait veriler</i>	<i>186</i>
<i>Tablo 48 – ACF06 ağına ait veriler</i>	<i>187</i>
<i>Tablo 49 – ACF07 ağına ait veriler</i>	<i>188</i>
<i>Tablo 50 – ACF08 ağına ait veriler</i>	<i>189</i>
<i>Tablo 51 – ACF09 ağına ait veriler</i>	<i>190</i>
<i>Tablo 52 – ACF10 ağına ait veriler</i>	<i>191</i>
<i>Tablo 53 – ACF11 ağına ait veriler</i>	<i>192</i>
<i>Tablo 54 – ACF12 ağına ait veriler</i>	<i>193</i>
<i>Tablo 55 – ADF01 ağına ait veriler</i>	<i>194</i>
<i>Tablo 56 – ADF01 ağına ait veriler</i>	<i>195</i>
<i>Tablo 57 – ELMCF01 ağına ait veriler</i>	<i>196</i>
<i>Tablo 58 – ELMCF11 ağına ait veriler</i>	<i>197</i>

EKLER LİSTESİ

	<u>Sayfa No</u>
EK-1 Döviz Kuru Tahmininde Kullanılan Parametreler	148
EK-2 Örnek MATLAB Kodları	151
EK-3 Geliştirilen MATLAB Dosyalarının İsim Tablosu	159
EK-4 ACx01 Grubunda Elde Edilen Diğer Sonuçlar	160
EK-5 ACx01 Grubunda Elde Edilen Diğer Sonuçlar	172
EK-6 Bayesian Regularization (trainbr) Algoritmasının Diğer Mimarilerde Kullanımı (ACFy)	184
EK-7 Kriz Sonrasındaki Verilerle Yapılan Denemeler	194
EK-8 Elman Ağları ile Yapılan Denemeler	196

KISALTMALAR

<u>Kısaltmalar</u>	<u>Açıklama</u>
ADALINE	ADaptive LInear NEuron
AHO	Ağırlıklı Hareketli Ortalama
AI	Artificial Intelligence
ANN	Artifical Neural Networks
AO	Aritmetik Ortalama
AR	Auto Regressive
ARIMA	Auto Regressive Integrated Moving Average
ARMA	Auto Regressive Moving Average
BBC	British Broadcasting Corporation
BVAR	Bayesian Vector Auto Regressive
CG	Conjugate Gradient
EUR	Euro
GA	Genetik Algoritma
GD	Gradient Descent
GSMH	Gayri Safi Milli Hâsıla
GYA	Geriye Yayılım Algoritması
HO	Hareketli Ortalama
IMF	International Money Fund
İMKB	İstanbul Menkul Kıymetler Borsası
İTO	İstanbul Ticaret Odası
JPY	Japon Yeni
LMS	Least Mean Square
MAD	Mean Absolute Deviation
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MEAN	Prediction Mean
MIT	Massachusetts Institue of Technology

MSE	Mean Squared Error
MSPE	Mean Squared Prediction Error
NMSE	Normalized Mean Squared Error
NN	Neural Network
NRMSE	Normalized Root Mean Squared Error
NSF	National Science Foundation
OCR	Optical Character Recognition
RAM	Random Access Memory
RMSE	Root Mean Squared Error
RMSPE	Root Mean Square Prediction Error
RNN	Recurrent Neural Network
SOM	Self Organizing Maps
STD	Prediction Standard Deviation
TCMB	Türkiye Cumhuriyeti Merkez Bankası
TEFE	Toptran Eşya Fiyat Endeksi
TNN	Time delayed Neural Network
TÜİK	Türkiye İstatistik Kurumu
USD	United States Dollar
ÜFE	Üretici Fiyatları Endeksi
VAR	Vector Auto Regressive
YSA	Yapay Sinir Ağı, Yapay Sinir Ağları
YTL	Yeni Türk Lirası
YZ	Yapay Zekâ

ÖNSÖZ

Eskişehir Osmangazi Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilimdalı, İşletme Bölümü Yüksek Lisans Tezi kapsamında “**Döviz Kuru Tahmininde Yapay Sinir Ağlarının Kullanımı**” konulu bu çalışmada döviz kurunun gelecekteki değerini ve yönünü tahmin edebilmek maksadıyla yapay sinir ağlarından faydalanılmıştır. İleride benzer uygulamalar yapacak olan araştırmacıların çalışmalarına katkıda bulunmak ve çalışmalarını hızlandırmak düşüncesiyle; böyle bir uygulamada hangi algoritmaların ve mimarilerin kullanılabileceği konusunda da yol gösterilmeye çalışılmıştır.

Bu çalışmaya ve bana olan güvenini kaybetmeyerek en büyük desteği veren değerli hocam Sn. Birol YILDIZ’a; yorum ve önerileri ile bu çalışmaya önemli katkılarda bulunan değerli hocalarım Sn. İnci PARLAKTUNA ve Sn. Nurullah UÇKUN’a teşekkürlerimi sunarım.

Ömür YILDIZ

Temmuz 2006 / Eskişehir

GİRİŞ

Ekonomide gerek kişisel yatırım ve gerekse işletmelerin geleceklerini planlamaları açısından geleceğin öngörülebilmesi çok önemli bir gereksinimdir. Özellikle son yıllarda dünyada ve ülkemizde yaşanan ekonomik krizlerden ve politik gelişmelerden dolayı meydana gelen piyasalardaki şiddetli dalgalanmalar, yatırım araçlarının ve döviz kurlarının gelecekteki alacağı değerin öngörülebilmesi durumunda çok önemli avantajlar ve fırsatlar elde edilebileceğini ortaya koymuştur. Diğer bir yandan madalyonun öteki yüzüne de bakılacak olursa, geleceğini doğru öngöremeyen, yatırımlarını yanlış şekilde değerlendiren kişiler ve işletmeler çok zor durumda kalmışlardır.

Uluslararası piyasalarda alışveriş ve bir yatırım aracı olarak kullanılan dövizin, özellikle de Amerikan Dolarının (USD) önemi, işlerini USD üzerinden gerçekleştiren işletmeler için daha fazladır. Döviz kurlarının ve dolayısı ile USD'nin aldığı değerler bir zaman serisi şeklinde düzenlenebilir. Ekonomide geleceği öngörebilmek önemli olduğundan son yıllarda bu konuda sayısız çalışma ortaya konmuş ve dolayısı ile zaman serilerini çözümleyerek geleceği tahmin edebilmek için onlarca değişik yöntem geliştirilmiştir. Esasen geleceği bilebilmek, gelecekte olacak olayları önceden görebilmek tarih boyunca insanların en büyük hayallerinden birisi olmuştur. Bu nedenle eski çağlarda geleceği tahmin edebilmek maksadıyla kimi zaman yıldızlardan kimi zaman da yere atılan taşlardan yararlanılmaya çalışılmıştır. Elbette matematiksel yöntemlerin ve özellikle çok hızlı bir hesaplama aracı olan bilgisayarların geliştirilmesi ile hiçbir bilimsellik içermeyen eski yöntemlerin yerini üzerinde binlerce kişinin yıllarca emek sarf ederek ortaya koyduğu karmaşık hesaplama modelleri almıştır.

Yapay Zekânın (Artificial Intelligence) bir uygulaması olan Yapay Sinir Ağları (YSA – Artificial Neural Network) son yıllarda geleceği öngörmede; özellikle döviz kuru gibi lineer olmayan (non-lineer), birçok değişkene bağımlı zaman serilerinin tahmin edilmesinde önemli bir araç olmuştur. YSA'lar sadece zaman

serilerinin tahmininde değil; öğrenebilme, genelleme yapabilme, eksik veriler ile dahi çalışabilme yetenekleri ile sınıflandırma, optimizasyon ve örüntü tanıma işlemlerinde de oldukça başarılı bir yöntemdir¹. YSA'lara olan ilginin her geçen gün artması ve hemen hemen her türlü mühendislik alanında da kolaylıkla uygulanabilmeleri nedeniyle YSA'lar günümüzün en umut verici yapay zekâ uygulaması durumundadır².

Yapay Sinir Ağları, isminin de işaret ettiği üzere insan beyninde doğal olarak var olan sinir hücrelerinin matematiksel olarak taklit edilmesi ile üretilmiş matematiksel bir modeldir. Henüz bir insan beyninin, değil tamamını küçük bir kısmını dahi tam manasıyla taklit edebilmekten uzaktır. Buna rağmen elektro-kimyasal olarak çalışan doğal sinir hücrelerinden çok daha hızlı çalışabilmesi ve yorulmaması gibi avantajları nedeniyle, odaklanmış olduğu bir problem için sonuç üretmede çok daha başarılıdır. YSA'lar da taklit etmeye çalıştığı insan beyni gibi örnekleri görerek, hata yaparak öğrenir ve her hatasından da ders alıp hatasını azaltır. Bir problem için bir kez eğitildikten sonra da çok hızlı bir şekilde sonuca ulaşırlar.

Tezimizin ilk bölümünde; döviz ve döviz kuru hakkında genel bir bilgi verildikten sonra döviz kurunu tahmin etmede kullanılan yöntemlerden bahsedilmiştir. Analiz yöntemlerinden teknik ve temel analize kısaca değinildikten sonra tahmin yöntemleri yargısal ve sayısal olarak iki ana başlık altında açıklanmaya çalışılmıştır. İkinci bölümde ise yapay zekâ ve yapay zekâ teknolojileri kısaca açıklandıktan sonra yapay sinir ağları ayrıntılı olarak ele alınmıştır. Tezimizde YSA'lara ayrıntılı olarak geçmeden hemen önce örnek alındığı insan beyni ve daha da kapsamlı olarak da beyni oluşturan doğal (biyolojik) sinir hücreleri hakkında bilgi verilmiştir. Daha sonra matematiksel olarak modellenen yapay sinir hücreleri tanıtılmıştır. Tezimizde ayrıntılı olarak da bahsedildiği üzere yapay sinir hücreleri ile oluşturulan YSA'ların mimarileri tanıtıldıktan sonra öğrenme kuralları

¹ KAASTRA Iebling, BOYD Milton: “*Designing a neural network for forecasting financial and economic time series*”, Neurocomputing, 31 August 1994

² KLINE Douglas M.: “*Methods for Multi-Step Time Series Forecasting with Neural Networks*”, “*Neural Networks in Business Forecasting*” ZHANG G.Peter, 2004, Idea Group Publishing

açıklanmıştır. Konunun sonunda YSA'ların avantajları, dezavantajları ve kullanım alanlarından bahsedilmiştir. Literatürde birçok öğrenme yöntemi olmasına karşın finansal zaman serilerinin neredeyse tamamında kullanılan Geriye Yayılma Algoritması (GYA – Back Propagation) biraz daha ayrıntılı olarak ele alınmaya çalışılmıştır. Deneysel çalışmamızda da uyguladığımız gibi, YSA'ların ekonomi ve finans alanındaki problemlere uyarlanması konusuna geniş bir şekilde değinildikten sonra YSA'ların finans alanında kullanılmasında karşılaşılan zorluklardan bahsedilmiştir. Nihayet son bölümde deneysel çalışmaya yer verilmiş olup elde edilmiş sonuçlar ve tahmin performansı sunulmuştur.

Çalışmamızın temel amacı; döviz kurlarından USD'nin gelecekteki değerinin ve yönünün yüksek bir başarı oranı ile öngörülmesidir. YSA'ların ürettiği sonuçların finansal değerlerin alım satım kararlarının verilmesinde bakılacak tek yer olmadığının göz ardı edilmemesi gerekir; YSA'lar kararları destekleyici bir araç olarak kullanılmalıdır. Ayrıca, kâğıt üzerindeki başarı ile gerçek hayattaki başarıyı birbirine karıştırmamak gerekir. Akademik çalışmalarda %100 doğru sonuç için uğraşılırken endüstride ve/veya piyasalarda %60'lık bir öngörü oldukça başarılı bir sonuçtur³. Çalışmamızda öngörü performansının yüksek olması için çaba sarf ettik. Zira %50 den düşük performans üreten bir yöntemi kullanmaktansa yazı tura atmak daha başarılı ve kolay bir seçenektir. Yüksek bir performans elde etmek, dolayısı ile geliştirmiş olduğumuz yöntemin bir karar destek aracı olarak kullanılması sonucunda elde edilecek kazançlar ve/veya zarardan kurtulabilme düşüncesi en büyük isteklendirme (motivasyon) kaynağımız olmuştur.

Tez çalışmamızda da, USD'nin gelecekteki değerinin tahmin edilebilmesi için Yapay Sinir Ağları ile oluşturulan bir model kullanılmıştır. Modele girdi olarak ise T.C. Merkez Bankası tarafından günlük olarak açıklanan ekonomik değişkenlerden 41 adet bağımsız parametre⁴ kullanılmıştır ve USD'nin ertesi günkü değeri bu parametrelerin gün sonu değerlerinden yola çıkılarak elde edilmeye çalışılmıştır.

³ YAO Jing Tao, TAN Chew Lim: “Guidelines for Financial Forecasting with Neural Networks”, Nisan 2001

⁴ Bakınız: EK-1

Dolayısı ile bir değişkenin gelecekteki değerini tahmin edebilmek için aynı değişkenin geçmişteki değerinin kullanıldığı teknik analiz yöntemi yerine, değişkeni etkileyen diğer değişkenlerin dikkate alındığı temel analiz yöntemi uygulanmıştır. Ağın kurulmasında, çalıştırılmasında, sonuçların elde edilmesinde ve grafiksel olarak gösterilmesinde Mathworks firmasının ürünlerinden olan MATLAB yazılımının 7.0 sürümü ve beraberinde gelen Neural Network Toolbox'ın 4.0 sürümü kullanılmıştır. Geliştirilen kodlar da tezimizin ekinde verilmiştir.⁵

⁵ Bakınız: EK-2

BÖLÜM I

1 DÖVİZ KURU VE DÖVİZ KURUNUN TAHMİNİ

1.1 DÖVİZ KURU

Bir ülkenin kendine özgü para biriminin olması o ülkenin tam bağımsızlığının en önemli göstergelerinden birisidir. Yabancı ülkelerin parasına genel bir tanımlamayla “döviz” denmektedir. Türk Parasını Koruma Kanunu Hakkında 32 sayılı Kararda döviz (Kambiyo) “Efektif dâhil yabancı parayla ödemeyi sağlayan her nevi hesap, belge ve araçlar” olarak ifade edilmektedir. Efektif döviz ise nakit şeklindeki döviz demektir. Esasen, bankacılık uygulamalarında nakit işlemleri çok küçük bir yer kaplar. Asıl döviz işlemleri, yabancı bankalarda tutulan döviz çekleri, ödeme emirleri, yabancı mevduat sertifikaları gibi araçlarla olmaktadır.

Bir ülkenin para biriminin başka bir ülkenin para birimine göre değerine de “döviz kuru” adı verilmektedir¹. Dövizin nakit olarak kullanıldığı en belirgin yer turizmdir. Yurt dışından gelenlerin ya da yurtdışına gidenlerin kendi paralarını geldikleri ya da gittikleri yerde kullanması ile döviz dolaşımı yapılır. Bu durumda gerçekleştirilen döviz kuru kavramı iki para biriminin birbirine göre nispi fiyatı anlamına gelen “nominal döviz kuru”dur².

Döviz kurunda karşılaşılan diğer bir kavram da “reel döviz kuru”³ kavramıdır. Fiyatlardaki değişimler dikkate alındığında elde edilen döviz kuruna reel döviz kuru denir. Reel döviz kuru, nominal döviz kurunun ülkenin enflasyon oranları dikkate alınarak düzeltilmesidir. Reel döviz kuru, yabancı ülkelerde üretilen malların yurtiçinde üretilen mallar cinsinden göreceli fiyatını yansıtan ve uluslararası rekabeti

¹ DİNÇER Nazire Nergiz: “Döviz Kuru Dalgalanmalarının Asimetrik Etkileri: Türkiye Örneği”, DPT Uzmanlık Tezleri, Şubat 2005

² PARASIZ İlker, “Para Banka ve Finansal Piyasalar”, Ezgi Kitabevi, 7. Baskı, Ocak 2000

³ MÜSLÜMOV Alövsat, HASANOV Mübariz, ÖZYILDIRIM Cenktan: “Döviz Kuru Sistemleri ve Türkiye’de Uygulanan Döviz Kuru Sistemlerinin Ekonomiye Etkileri”, Scala Basım Yayım, 2003

ölçmek için yaygın olarak kullanılan bir ekonomik göstergedir.⁴ Reel döviz kuru, ekonomik birimlerin üretim ve tüketim kararlarının yurtiçinde ve yurtdışında üretilen mallar arasında dağılımını etkileyerek, cari işlemler dengesi üzerinde belirleyici rol oynamaktadır.⁵

$$\text{Reel Döviz Kuru} = \frac{\text{Nominal Döviz Kuru} \times \text{Yerli Malın Fiyatı}}{\text{Yabancı Malın Fiyatı}} \quad (2.1)$$

Diğer bir şekilde formüle edilirse;

$$RDK = E(P / P^*) \text{ dir.}^6 \quad (2.2)$$

Burada;

E : Nominal Döviz Kuru,

P : Ülkedeki fiyat düzeyi ve

P* : Yabancı ülkedeki fiyat düzeyidir.

Reel döviz kuru, ülkelerin uluslar arası ticaretteki rekabet edebilirliğinin bir göstergesidir. Diğer koşullar sabitken reel döviz kurunun artması, ülkenin uluslar arası ticarete rekabet gücünü artırır.

ABD doları (USD) için örnekleyecek olursak; eğer ABD fiyatlar genel düzeyi ile ölçülen ABD enflasyon oranı artarsa bu durum Türk mallarına talebi artırır. Bu da ABD'ye yapılan ihracatı arttırırken ithalatı azaltmış olur.

Reel döviz kurundaki artışın bir diğer nedeni de, Türkiye fiyatlar genel düzeyindeki azalış da olabilir. Eğer bu nedenle reel YTL/USD döviz kuru artarsa, bu artış da yukarıdaki sonuca benzer bir sonuç üretir⁷.

⁴ İNANDIM Şeyda, “Kısa Vadeli Sermaye Hareketleri ile Reel Döviz Kuru Etkileşimi: Türkiye Örneği”, Uzmanlık Yeterlilik Tezi, TCMB – Piyasalar Genel Müdürlüğü, Kasım 2005

⁵ “Reel Efektif Döviz Kuru Hesaplaması”, TCMB e-kütüphanesinden, www.tcmb.gov.tr

⁶ PARASIZ İlker, “Para Banka ve Finansal Piyasalar”, Ezgi Kitabevi, 7. Baskı, Ocak 2000

Reel döviz kurundaki artışın son nedeni, nominal döviz kurunun artması olabilir. Nominal döviz kurundaki artıştan dolayı ithalat daha pahalı hale gelirken artık Türk malları yabancılara daha ucuz geleceğinden ihracatı da arttırır.

Reel döviz kuru, uluslar arası ticarete rekabet edebilirliğin bir göstergesi olduğu kadar aynı zamanda ülkenin yabancı bir ülkeye oranla asgari geçim düzeyinin de bir ölçütü olabilir. Örneğin, reel YTL/USD döviz kurundaki bir artış ABD’de asgari geçim düzeyindeki nispi artışı gösterir. Buna karşın reel YTL/USD döviz kurundaki bir azalış da Türkiye’de yaşamının maliyetinin ABD’ye oranla nispeten arttığını gösterir.⁸

Bir ülke genellikle uluslar arası piyasalarda birden fazla ülke ile hem rekabet hem de ticaret ilişkisi içinde olduğundan reel döviz kurunun bu gerçeği yansıtan efektif endeks olarak hesaplanması gerekir. Bu amaç doğrultusunda hesaplanan gösterge “reel efektif döviz kuru” olarak tanımlanmaktadır. Reel efektif döviz kuru, nominal efektif döviz kurunun fiyat endeksleriyle deflate edilmiş hali olup, uluslar arası fiyat rekabetinin önemli bir göstergesidir. Uluslar arası Para Fonu (IMF), tarafından da kullanılan bu tanıma göre reel efektif döviz kuru, ilgili ülkenin fiyat düzeyinin dış ticaret yaptığı ülkelerin fiyat düzeylerine oranının ağırlık geometrik ortalaması olarak hesaplanmaktadır. Bu yöntem aşağıda gösterildiği şekliyle formüle edilmektedir:⁹

$$REDK = \prod_{j \neq i} \left[\frac{P_i R_i}{P_j R_j} \right]^{w_{ij}} \quad (2.3)$$

⁷ ÖZER Mustafa: “Türkiye’de Reel Döviz Kurunun Zaman Serisi Analizi (1975–1991)”, Eskişehir Anadolu Üniversitesi, 1992

⁸ A.G.E.

⁹ “Reel Efektif Döviz Kuruna İlişkin Yöntemsel Açıklama”, TCMB e-kütüphanesinden, www.tcmb.gov.tr

Burada;

P_i : Türkiye'nin fiyat endeksi,

R_i : YTL'nin USD karşılığı,

P_j : j ülkesinin fiyat endeksi,

R_j : j ülkesi parasının USD karşılığı,

W_{ij} : Türkiye için j ülkesinin ağırlığıdır.

Reel efektif döviz kuru endekslerindeki artış, Yeni Türk Lirası'nın reel olarak değer kazandığını gösterirken, azalış Yeni Türk Lirası'nın reel olarak değer kaybettiğini ifade etmektedir.

1.2 DÖVİZ KURUNUN BELİRLENMESİNE YÖNELİK YAKLAŞIMLAR

Literatürde döviz kurunun belirlenmesine yönelik çeşitli teoriler ve yaklaşımlar vardır. Bunlardan bazıları:

- a. Satın Alma Gücü Paritesi,
- b. Parasal Yaklaşım,
- c. Çağdaş Parasal Yaklaşım,
- d. Portföy Yaklaşımı,
- e. Üretkenliği Baz Alan Yaklaşım,
- f. Ödemeler Dengesi Yaklaşımı,
- g. Kamin ve Rogers Modeli,
- h. Erken Keynezyen Yaklaşımı,
- i. Yeni Keynezyen Yaklaşımı,
- j. Para İkamesi Yaklaşımı

Bu yaklaşımlardan en kabul görmüş olanları şunlardır:

1.2.1 Satın Alma Gücü Paritesi

Satın alma gücü paritesi teorisi ile döviz kurları arasında yakın bir ilişki vardır. her şeyden önce satın alma gücü paritesi teorisi, döviz kuru belirlenmesinin modern ekonomik analizinde en önemli öğelerden birisini oluşturmaktadır.¹⁰ Bu hipotez Gustav Cassel (1922) tarafından ortaya atılmıştır. Satın alma gücü paritesi teorisi “dünyada benzer malların benzer fiyatlardan satılması” ilkesini temel almaktadır. Bir başka deyişle döviz kuru dünyadaki fiyat farklılaşmalarını ortadan kaldıracak şekilde uyumlaşmalıdır¹¹. Satın alma gücü paritesi teorisinin reel döviz kurları açısından en önemli varsayımı “uzun dönemde satın alma gücü paritesi geçerli ise, reel döviz kurlarının değişmeyeceği” varsayımıdır.

Mutlak satın alma gücü paritesi aşağıdaki gibi formüle edilebilir:

$$P = P^* \times E \quad (2.4)$$

Burada;

P : Yerel Fiyatları,

P^* : Yabancı Fiyatları ve

E : Nominal Döviz Kurunu ifade etmektedir.

¹⁰ YILDIRIM Oğuz, “Döviz Kurları Çerçevesinde Satınalma Gücü Paritesinin Zaman Serisi Analizi ve Türkiye Ekonomisine Uygulaması”, Bankacılar Dergisi, Sayı:44, 2003

¹¹ DİNÇER Nazire Nergiz: “Döviz Kuru Dalgalanmalarının Asimetrik Etkileri: Türkiye Örneği”, DPT Uzmanlık Tezleri, Şubat 2005

1.2.2 Parasal Yaklaşım

Döviz kurunun belirlenmesi yaklaşımlarından birisi olan parasal yaklaşım satın alma gücü paritesi ve miktar teorisinin bir uzantısıdır. Bu yaklaşım 1960 yılların sonlarına doğru Robert Mundell ve Harry Johnson tarafından başlatılmıştır. Marina Whitman (1975), Jacob Frenkel ve Harry Johnson (1976) tarafından geliştirilmiştir. Satın alma gücü paritesi teorisi, kuru iki mal arasındaki nispi fiyat olarak belirlerken, parasal yaklaşım iki para arasındaki nispi fiyat olarak kabul eder.¹² Bu yaklaşımın en temel varsayımı, ülkeler arasında mal ve hizmet akışının tam olduğu varsayımdır. Bu varsayıma göre mallar, ülkeler arasında hiçbir sınırlamayla ve engellemeyle karşılaşmaksızın mübadele edilebilmektedir. Bu durumda, malların fiyatı tüm ülkelerde de eşit olacaktır¹³.

1.2.3 Çağdaş Parasal Yaklaşım

Bu tür yaklaşımda, mal piyasalarının yanı sıra, tahvil piyasaları ve beklentileri de hesaba katılır. “Tahvillerinde hesaba katılmasıyla, faiz oranları arasındaki fark, döviz kurunun belirlenmesinde önemli rol oynamaktadır. Çağdaş parasal yaklaşım çerçevesinde geliştirilen modeller, klasik iktisat gelenekleri kapsamında görülebilir. Bu modeller, klasik gelenekte olduğu gibi, işgücü piyasalarının dengede olduğu, dolayısıyla üretimin arz yönlü olarak belirlendiği, fiyatlar genel düzeyinin para piyasalarında belirlendiği ve reel döviz kurunun sabit olduğunu, dolayısıyla da satın alma gücü paritesinin geçerli olduğunu kabul etmektedir. Bu modeller arasındaki temel fark, beklentilerin oluşumuna yönelik farklardır”.¹⁴

¹² DİNÇER Nazire Nergiz: “Döviz Kuru Dalgalanmalarının Asimetrik Etkileri: Türkiye Örneği”, DPT Uzmanlık Tezleri, Şubat 2005

¹³ MÜSLÜMOV Alövsat, HASANOV Mübariz, ÖZYILDIRIM Cenktan: “Döviz Kuru Sistemleri ve Türkiye’de Uygulanan Döviz Kuru Sistemlerinin Ekonomiye Etkileri”, Scala Basım Yayım, 2003

¹⁴ A.G.E.

1.2.4 Portföy Yaklaşımı

Parasal yaklaşımda yerli ve yabancı tahvillerin birbirlerine tam ikame ettikleri varsayılır. Portföy yaklaşımında ise durum tam tersidir; yani yurtiçi ve yurtdışı para dışı varlıkların tam ikame olmadığı varsayımı kabul edilir.

Bu yaklaşıma göre bireyler, yurtiçi ve yurtdışı varlıklar arasından bir portföy oluştururlar. Portföyü oluşturan varlıklara talep sadece ilgili varlıkların getirisi ile değil diğer ikame varlıkların getiri oranlarıyla belirlenmektedir. Doğal olarak bireyler portföyünde getirisi en yüksek olan varlıkları tercih edeceklerdir. Dolayısı ile herhangi bir varlığa olan talep, kendisinin faiz oranı ile doğru, diğer varlıkların getirisi ile ters orantılı olarak değişmektedir. Herhangi bir varlığın getirisindeki değişiklik, varlığın portföydeki oranının da değişmesine neden olmaktadır.

Portföy yaklaşımının uygulamada iki önemli metodolojik sorun mevcuttur¹⁵. İlki verilerin kısıtlı olmasıdır. Bireylerin portföylerindeki finansal varlıkları para birimine göre incelemek oldukça zordur. İkinci sorun ise; durağan bir varlık talebi fonksiyonu elde etmenin güçlüğüdür. Frankel mikro temelli bir “sermaye varlığını fiyatlandırma modeli” kurulabileceğini savunmaktadır. Fakat bu modelin makroekonometrik bir çerçevede kullanmanın, uluslar arası uyumlaşmanın sağlanması için beklenen getirilerdeki değişikliklerin gerekliliği nedeniyle doğru olmayacağı eleştirisini getirmektedir. Bu nedenlerden dolayı portföy yaklaşımı ampirik çalışmalar tarafından desteklenmemektedir.

¹⁵ DİNÇER Nazire Nergiz: “Döviz Kuru Dalgalanmalarının Asimetrik Etkileri: Türkiye Örneği”, DPT Uzmanlık Tezleri, Şubat 2005

1.3 DÖVİZ KURU SİSTEMLERİ

Döviz kurunun belirlenmesi için temelde 3 değişik kur politikası vardır. Aşağıda kısaca bahsedilmiş olan bu üç temel kur politikasının değişik bileşimlerle uygulanmasıyla çok daha fazla çeşitte kur politikası uygulamaları da görülmektedir¹⁶.

- a. **Serbest Kur Sistemi;** yani ülke para biriminin diğer tüm para birimlerine karşı kontrolsüz bırakılması.
- b. **Sabit Kur Sistemi;** yani para birimi değerinin başka bir ülkenin para birimine ya da bir araca sabitlenmesi.
- c. **Karma Sistem;** yani para birimi değerinin serbest dalgalanmasına izin verilirken aşırı dalgalanmalarda müdahale edilmesi.

1.3.1 Serbest Kur Sistemi (Free Float)¹⁷

Döviz kurlarına hükümetin herhangi bir müdahalesinin olmadan piyasanın arz ve talebine bağlı olarak serbestçe değişebildiği kur sistemidir. Esnek Kur Sistemi, Dalgalı Kur Sistemi ya da Değişken Kur Sistemi olarak da bilinir.

Serbest kur sisteminde döviz fiyatları günlük hatta anlık olarak değişebilir. Bu kur sistemi ile dış ödemeler dengesi rahatlıkla sağlanabilir ve resmi mercilerin para politikaları üzerinde daha fazla söz sahibi olmasına olanak tanınır. Çünkü spekülasyonlar sonucu oluşması ani değerlenme ya da değer kayıplarından dolayı ülkenin rezervlerinde artış ya da alışın olması söz konusu değildir. Dolayısıyla ülkeler bağımsız mali ve para politikaları uygulayabilirler.

¹⁶ MÜSLÜMOV Alövsat, HASANOV Mübariz, ÖZYILDIRIM Cenktan: “Döviz Kuru Sistemleri ve Türkiye’de Uygulanan Döviz Kuru Sistemlerinin Ekonomiye Etkileri”, Scala Basım Yayım, 2003

¹⁷ ARAT Kürşad: “Türkiye’de Optimum Döviz Kuru Rejimi Seçimi ve Döviz Kurlarından Fiyatlara Geçiş Etkisinin İncelenmesi”, Uzmanlık Yeterlilik Tezi, TCMB, Temmuz 2003

Sistemin dezavantajları da mevcuttur. Sabit kur sistemleri dış ticarete belirsizlik, yüksek enflasyona ya da ülke parasının aşırı değerlenmesine neden olabilir. Döviz fiyatlarının sabit olmamasından dolayı oluşan belirsizlik ihracat yapacakları ve yatırımcıları ürkütür.

1.3.2 Gözetimli Dalgalanma (Managed Float)¹⁸

Döviz kuruna resmi mercilerin daha önceden belirlenmiş olmayan para politikalarına göre değil de o anki piyasa durumuna göre müdahalesine denmektedir. Böylece serbest kurun dezavantajları da kısmen önlemiş olur.

1.3.3 Aralık İçinde Dalgalanma (Floating within a Band)

Bu tip kur sisteminde döviz kurlarının belirli bir aralıkta dalgalanmasına müsaade edilir. Serbest kur ile sabit kurun birleşimi gibi de düşünülebilir. Böylece her iki sistemin avantajlarından yararlanılmaya çalışılır. Kurların belirlenen aralıkta kalması için devletin sürekli olarak müdahalesi gerekiyorsa ülkenin para politikalarında bazı sorunlar var demektir. Bu durumda sistemin avantajları da ortadan kalkar.¹⁹

1.3.4 Kayan Aralık (Sliding Band)

Bu sistemde aralık içinde dalgalanmadan farklı olarak aralığın ortalama değeri sabitlenmiştir. Genellikle yüksek enflasyonist ortamlarda kullanılır. Bu sistemle kurun aşırı değerlenmesi engellenir. Fakat kurun ortalama değerini sabit tutabilmek için ne zaman müdahale edileceğinin bilinmiyor olması piyasalarda belirsizlik yaratabilir.

¹⁸ YILDIRIM Oğuz, “Kura Dayalı İstikrar Politikası (Teori ve Ülke Uygulamaları)”, T.C. Başbakanlık Hazine Müsteşarlığı Ekonomik Araştırmalar Genel Müdürlüğü, Şubat 2003

¹⁹ ÖZDEMİR K. Azim, ŞAHİNBEYOĞLU GÜLBİN: “Alternatif Döviz Kuru Sistemleri”, Eylül 2000

1.3.5 Yönlendirilmiş Sabit Aralık (Crawling Band)

Bu kur sisteminde ülke parasının değeri daha önceden açıklanmış olan sabit bir değere göre belirli limitler içinde dalgalanmaktadır. Sabit kur sistemine kıyasla daha esnekler. Farkı ise, sabit kur üzerindeki baskı arttığında ayarlamaların bir anda değil belirli aralıklarla ve sıklıkla yapıyor olmasıdır²⁰.

1.3.6 Yönlendirilmiş Sabit Parite (Crawling Peg System)

Yönlendirilmiş sabit parite sisteminde ülke parasının değeri sabitlenmiştir. Sabitlenmiş olan bu değer, ülkenin ekonomik göstergelerine ve ödemeler dengesindeki değişikliklere göre ayarlanabilmektedir. Bu sistemde döviz kurları önceden ilan edilen miktarda ya da yüzdede sık sık ve açıkça belirlenen aralıklarda ayarlanır²¹. Ülkede örneğin %8 devalüasyon gerekiyorsa bunu bir kerede yapmak yerine 4 aya bölerek her ay %2 oranında devalüasyon yapılabilir. Yönlendirilmiş Sabit Aralık sistemine göre daha katıdır fakat sabit kur sistemlerine göre de daha esnekler.

1.3.7 Ayarlanabilir Sabit Kur Sistemi (Bretton Woods System)²²

Belirlenen döviz kurunun periyodik olarak değiştirilebildiği bir sistemdir. Temel dengesizliklerle karşılaşıldığında döviz kurunun yeniden ayarlanmasına olanak tanıyan ayarlanabilir bir sabit kur sistemidir. Temel dengesizlik olarak, üst üste birkaç yıl gerçekleşen cari açık ya da fazlanın yaşanması gösterilebilir. Sürekli bir devalüasyon ya da revalüasyon beklentisinin olması piyasalarda belirsizliğe neden olacağından ekonomik krize de yol açabilmektedir.

²⁰ MÜSLÜMOV Alövsat, HASANOV Mübariz, ÖZYILDIRIM Cenktan: “Döviz Kuru Sistemleri ve Türkiye’de Uygulanan Döviz Kuru Sistemlerinin Ekonomiye Etkileri”, Scala Basım Yayım, 2003

²¹ ARAT Kürşad: “Türkiye’de Optimum Döviz Kuru Rejimi Seçimi ve Döviz Kurlarından Fiyatlara Geçiş Etkisinin İncelenmesi”, Uzmanlık Yeterlilik Tezi, TCMB, Temmuz 2003

²² DİNLER Zeynel, “İktisada Giriş”, Ekin Kitabevi, 6. Basım, Bursa 2000

1.3.8 Sabit Kur²³

Bu sistemde döviz kurları bir kez sabitlendikten sonra piyasadaki arz ve talebe bakılmaksızın merkez bankasının alışı ya da satışı ile kurların istikrarı sağlanır.²⁴ Bu sistemi uygulamak için merkez bankasının rezervlerinde yeterli miktarda döviz ve altın stokunun olması gerekir. Döviz fiyatı arttığında merkez bankası piyasaya döviz satar yani ulusal parayı piyasadan döviz karşılığı satın alır. Döviz fiyatı sabitlenen değerden düştüğünde de piyasaya ulusal paradan vererek döviz satın alır.

Bu sistemde ekonominin geleceği rahatlıklar öngörülebilir. Riskler ve belirsizlikler azalacağından piyasa rahat çalışabilir. Enflasyon önenebilir.

Buna rağmen ekonomistler arasında özellikle gelişmekte olan ülkelerde sabit kurların pek başarılı olmadığı görüşü hâkimdir. Muhtemel spekülasyonlara karşı sabit kuru korumak amacıyla hükümetler faizleri arttırmak ve ekonomiyi yavaşlatmak zorunda kalabilirler. 1997 yılında yaşanan Asya krizinden sonra özellikle yükselen pazar ekonomileri sabit kur uygulamalarından vazgeçerek diğer sistemleri kullanmaya başlamışlardır. Örneğin Türkiye’de de Şubat 2002 krizine kadar sabit kur uygulanmakta ve döviz fiyatları çok küçük bir bant aralığında seyir etmekteydi. Krizden sonra kurun serbest bırakılması ile döviz fiyatları bir anda 2 katına kadar çıkmıştır. Bu krizin etkileri henüz atlatılabilmiş değildir. Asya krizinde sabit kur yerine değişik şekillerde de olsa serbest kur sistemi uygulayan ekonomiler krizden daha az etkilenmişlerdir.

²³ MÜSLÜMOV Alövsat, HASANOV Mübariz, ÖZYILDIRIM Cenktan: “Döviz Kuru Sistemleri ve Türkiye’de Uygulanan Döviz Kuru Sistemlerinin Ekonomiye Etkileri”, Scala Basım Yayım, 2003

²⁴ PARASIZ İlker, “Para Banka ve Finansal Piyasalar”, 7. Baskı

1.3.9 Yabancı Ülke Parasının Kullanılması(Resmi Dolarizasyon)²⁵

Bu sistemi uygulayan ülkeler tam bağımsızlığın önemli bir göstergesi olan kendi para birimini terk ederek başka bir ülkenin para birimini kullanırlar. Bu sistemi uygulayan ülkeler bağımsız para politikası uygulama imkânlarını tamamen yitirmektedirler. Merkez bankaları, başka bir ülkenin parasını basamayacakları için, para politikasını bağımsız bir şekilde uygulayamazlar.

1.4 DÖVİZ KURUNU TAHMİN ETME YÖNTEMLERİ

Bilgisayar gibi güçlü hesaplama araçlarının kullanılmaya başlamasından önce insanlar bir mal, ürün alırken ya da yatırım yaparken sadece kendi sezgilerine güvenmekteydi. Dünyanın küçülmesi; rekabetin, üretimin ve tüketimin artması sonucunda yapılan alışverişlerde ve yatırımlardaki kazançların artırılması, risklerin en aza indirilmesi son derece önem kazandığı için onlarca yeni yöntem ve araç geliştirilmiştir. İstatistik, teknik analiz, temel analiz, lineer regresyonlar piyasanın yönünü ve yatırım araçlarının gelecekteki değerini tahmin etmeye çalışmakta kullanılan yöntemlerden sadece birkaçıdır. Gerçek hayatta geleceği tahmin etmek için kesin ve tek bir yöntemin bulunduğunu söyleyebilmek ne yazık ki mümkün değildir.

Piyasanın geleceğini tahmin etmek neden önemlidir? Geleceği tahmin edebilmek kişisel planlama açısından da önemli olmasına rağmen, iş hayatında ve devletin ekonomik politikaları²⁶ açısından son derece önemlidir. Piyasanın ve pazarın gelecekte nasıl olabileceğini tahmin edebilen bir yatırımcı yeni yatırımlarını buna göre düzenler. Hangi sektöre gireceğini, ne kadar çalışana ihtiyacı olacağını, ne kadar geliri ve gideri olacağını planlarken; parasını hangi araca yatıracağına ve/veya

²⁵ ARAT Kürşad: “Türkiye’de Optimum Döviz Kuru Rejimi Seçimi ve Döviz Kurlarından Fiyatlara Geçiş Etkisinin İncelenmesi”, Uzmanlık Yeterlilik Tezi, TCMB, Temmuz 2003

²⁶ KAYIM Halil: “İstatistiksel Ön Tahmin Yöntemleri”, Hacettepe Üniv. İİBF Yayınları NO:11, Ankara 1985

elindeki yatırımının değer kaybedip kaybetmeyeceğine karar verirken geleceği yüksek doğruluk oranı ile tahmin edebilmek özellikle işletmeler için hayati derecede önemlidir.

1.4.1 Analiz Yöntemleri

1.4.1.1 Teknik Analiz

Gelecekteki fiyat hareketlerini tahmin edebilmek için geçmişteki fiyat hareketlerinin incelenmesine Teknik Analiz denir.²⁷ Temel olarak teknik analiz, geçmişteki hareketlerin gelecekte de tekrarlanacağı varsayımına dayanır. Teknik analizin yapı taşlarını şu kabuller oluşturur:

- Piyasa her şeyi hesaba katar,
- Fiyatlar trendlere göre hareket eder,
- Geçmiş kendini tekrarlar.

Trendin yönünü tahmin etmek için büyük oranda fiyat grafiklerinden yararlanılır. Trend genel kabul gördüğü gibi arz ve talebe göre hareket eder. Grafikleri incelerken birçok değişik teknik gösterge vardır. Filtre, momentum, hacim göstergeleri; eğilim (trend) çizgisi, dalga ve örüntü analizleri örnek olarak verilebilir. Gelecekteki fiyatları tahmin etmek için grafikler kullanıldığı için teknik analizciler kural olarak, fiyatların neden düştüğüyle ya da yükseldiğiyle ilgilenmezler. Sadece grafikler ve göstergeler yardımıyla trendin yönünü tahmin etmeye çalışırlar.

²⁷ ÖGEL Serdar:“*Teknik Analizde Kullanılan Kısa Vadeli Göstergelerin Analiz Edilmesi (İMKB-30 İçin Bir Uygulama)*”, Anadolu Üniv., Yüksek Lisans Tezi, 2002

1.4.1.2 Temel Analiz

Bir yatırım aracının gerçek değerinin belirlenmesine yönelik analizdir²⁸. Temel analiz yönteminde analizciler fiyatı etkileyebileceğini düşündükleri tüm ekonomik değişkenleri değerlendirirler. Örneğin; Gayri Safi Milli Hâsıla (GSMH), istihdam, enflasyon, merkez bankası rezervleri, işlem hacimleri, faiz oranları, alım gücü endeksleri, bütçe açıkları, vb. tüm ekonomik göstergeler değerlendirilerek yatırım aracının gerçekteki değeri bulunmaya çalışılır. Temel analizin avantajı, daha fiyatlar grafiklere yansımada önce fiyatlardaki değışikliğı tahmin etmek için eldeki ekonomik göstergeleri sistematik olarak kullanmasıdır.

Teknik analizciler piyasa hareketlerinin grafiksel olarak incelenmesi üzerine yoğunlaşırken temel analizciler ise fiyatları etkileyen ekonomik göstergelerin incelenmesine odaklanır. Teknik analizci, sonuçları ortaya çıkaran nedenleri bilmektense sadece sonuçları bilmesinin yeterli olduğuna inanırken temel analizci mutlaka nedenleri bilmek zorundadır. Kaba bir tabirle teknik analizin %90'ı hissi (psychological) temel analizin %90'ı mantıksaldır (logical)²⁹.

1.4.2 Tahmin Yöntemleri

1.4.2.1 Yargısal Yöntemler (Kalitatif – Niteliksel - Qualitative)³⁰

Verilere dayanarak bilimsel yöntemler yerine hissi, kişisel yani yargısal olarak yapılan tahminlerdir. Tahmin etme yöntemi bilimsel verilere dayanmaması nedeniyle tahmin performansı düşüktür. Gelecek hakkındaki tahminler özellikle bir işletme için geleceğı doğrudan ilgilendiren kararların verilmesinde çok önemlidir. Bu başlık

²⁸ KALYVAS Efstathios: "Using Neural Networks And Genetic Algorithms To Predict Stock Market Returns", Master of Science Thesis, University of Manchester, Ekim 2001

²⁹ LAWRENCE Ramon: "Using Neural Networks to Forecast Stock Market Prices", Department of Computer Science University of Manitoba, 12 December 1997

³⁰ ATAY Önkale Dilek, "Tahmin Yöntemleri" isimli sunuşundan, Temmuz 2001

altında bahsedilen tahmin yöntemleri özellikle bir işletmenin karar vermesi ile ilgilidir.

1.4.2.1.1 Yöneticilerin Görüşlerinin Esas Alınması

Mali işler, satın alma, üretim, yönetim kurulu gibi kurullardaki idari görevlilerin ve yöneticilerin tecrübelerine ve bilgilerine dayanılarak yapılan tahminlerdir. Bazı dönemlerde özellikle kısa zamanda karar verilmesi gerekiyorsa verilerle ve formüllerle uğraşmaktansa bu yöntem kullanılabilir. Elbette sorumluluk kararı birlikte verenlerin olacaktır.

1.4.2.1.2 Kilit Personelin Kararı

Özellikle taleplerin tahmininde ya da yeni bir tesis yapılmasında kilit personelin yani o konudaki uzman personelin görüşü gelecek için karar vermede kullanılabilir.

1.4.2.1.3 Anketler

Yukarıdaki maddede olduğu gibi özellikle yeni bir tesis yapılırken, yeni bir ürünün üretimine karar verilirken, talebin tahmin edilmesi sırasında işletmedeki deneyimli personelin kararının yanı sıra piyasa araştırması maksadıyla anketlerin yapılması yöntemidir. Anketler ile toplanan veriler istatistiksel yöntemlerle değerlendirilerek gelecek hakkında karar verilmeye çalışılır.

1.4.2.1.4 Delphi Yöntemi³¹

Delphi metodunu ilk kez Rand Corporation tarafından Air Force projesinde kullanılmıştır. En iyi bilinen yargısal yöntemlerdendir. Bu yöntemde gelecek

³¹ DeLurgio Stephen: “*Forecasting Principles and Applications*”, Syf: 636, McGraw-Hill, 1998

hakkında karar vermeye çalışan kişileri, tahmin egzersizlerinde görüşlerini oybirliği ve bir aracı ile açıklamaya zorlar. Aracı kişi, katılımcılara geri bildirim yapar ve her aşamada gelen tepkileri analiz etmede bir kontrol merkezi olarak çalışır. Böylelikle verilecek kararda uzlaşılmasını sağlar.

Delphi metodunda iki varsayım vardır. İlki, ilgili oldukları alanda çok bilgili ve deneyimli olan kişilerin en mantıklı tahmini yaptıklarıdır. Diğeri ise farklı insanların bilgilerinin birleştirilmesi ile mantıklı tahminin yapılacağıdır.

1.4.2.2 Sayısal Yöntemler (Kantitatif – Niceliksel - Quantative)

Belirli bir zaman aralığına göre dizilmiş ve arka arkaya toplanmış gözlem değerlerine “Zaman Serileri” denir.³² Gözlem değerleri birbiri ile bir şekilde ilişkilidir buna iç bağıllık denir³³. Zaman serilerini bağımsız gözlem değerlerinden ayıran en büyük özellik de budur. Bu özellik sayesinde üzerinde çalıştığımız bir değişkene ait zaman serisinin geçmişteki değerlerini kullanarak o değişkenin gelecekteki değerini tahmin edebilme şansımız olur.

Gözlem yapılabilen her alanda her türlü değişken için zaman serileri oluşturulabilir. Hava durumu, yağış miktarı, borsada işlem gören hisse senedi fiyatları, döviz kurları, enflasyon oranları, bir üniversiteye kayıt olan ve üniversiteden mezun olan öğrenci sayısı, nüfus sayımı, doğum ve ölüm oranları, enerji sarfiyatı, barajlardaki su miktarı gibi her alanda zaman serisi oluşturulabilir ve bu serilerin üzerinde çeşitli işlemler yapılabilir.

Kullanılan zaman serisine de bağlı olarak, serinin seyrinde bazen dalgalanmalar olabilir. Dalgalanmalar ekonomik, sosyal, psikolojik, konjonktürel, mevsimsel, vb. gibi birçok sebepten kaynaklanabilir. Zaman serisini kullanarak

³² KAYIM Halil: “İstatistiksel Ön Tahmin Yöntemleri”, Hacettepe Üniv. İİBF Yayınları NO:11, Ankara 1985

³³ ÖZMEN Ahmet: “Zaman Serilerinde Tutarlı Kestirimler İçin İstatistiksel Yöntem Uyarlaması”, Anadolu Üniv. Fen-Edebiyat Fakültesi Dergisi, Kasım 1988, Cilt 1, Sayı 1, Syf. 69-80

tahmin yapılmak istendiğinde, seriyi oluşturan değerleri etkileyen unsurları iyi anlamak gerekir. Seriyi etkileyen unsurların belirlenmesi çalışmalarına da “zaman serisi çözümlemesi” denmektedir. Zaman serisinin iyi çözümlenmesi tahmin doğruluğunu hiç şüphesiz ki iyi yönde etkileyecektir.

Zaman serilerini kullanan birçok tahmin yöntemi vardır³⁴. Her bir yöntemin de kendine göre avantajı, dezavantajı ve uygulama özelliği vardır. Dolayısı ile tahminde kullanılmak üzere gösterilebilecek tek bir yöntem yoktur. Kullanılacak yönteme karar verilirken şu faktörlerin göz önünde bulundurulması gerekir:

- Veri sayısı,
- Tahmin edilmeye çalışılan dönemin uzunluğu,
- Yapılacak tahminin tutarlılığı,
- Tahminin maliyeti,
- Zaman serisinin çözümlenmesi için ayrılacak süre,
- Daha önceki uygulamalardan edinilen tecrübeler.

1.4.2.2.1 Aritmetik Ortalama Yöntemi

Zaman serileri ile geleceği tahmin etmede kullanılan en basit yöntem aritmetik ortalama yöntemidir³⁵. Kısaca, gözlemlenen değişkenin gelecekteki değeri geçmişteki değerlerinin ortalamasına yakınsayacağı varsayımına dayanmaktadır. Buna göre geçmişteki değerler tek tek toplanıp ortalaması alınır. Aşağıdaki gibi formüle edilebilir.

$$AO = \frac{\sum_{t=1}^n y_t}{n} \quad (2.3)$$

³⁴ KALYVAS Efstathios: "Using Neural Networks And Genetic Algorithms To Predict Stock Market Returns", Master of Science Thesis, University of Manchester, Ekim 2001

³⁵ SERPER Özer, "Uygulamalı İstatistik 2", Ezgi Kitabevi, Bursa 2000

1.4.2.2 Hareketli Ortalama Yöntemi

Hareketli ortalama yöntemi yaygın olarak kullanılan bir tahmin yöntemidir. Tekniğin esası, serinin değerlerini belirli büyüklükteki (n) kümeler halinde toplayıp her kümenin aritmetik ortalamasını hesaplamak ve bu ortalamaları ilgili kümenin tam ortadaki değerinin yerine koymaktır³⁶. Geçmişteki tüm değerlerin ortalamasını almak yerine yakın geçmişten belirli bir süre ile ilgilenilir. Örneğin geçmiş dönem verilerinin üçü, dördü ya da beşi alınarak en son gerçekleşen dönem bunlara ilave edilerek ortalama alınır. Bu yöntem ile döngüsel dalgalanmalar (konjonktürel ve mevsimsel) yok edilmeye çalışılır. Hareketli ortalama yöntemi aşağıdaki gibi formüle edilebilir.

$$HO(n) = \frac{y_t + y_{t-1} + \dots + y_{t-n+1}}{n} \quad (2.4)$$

Buradaki n geçmişten alınacak veri sayısıdır. Sonuç seçilen n sayısına göre, “n’lik hareketli ortalama” diye adlandırılır.

1.4.2.2.3 Ağırlıklı Hareketli Ortalama Yöntemi

Ağırlıklı hareketli ortalama yöntemi aslında hareketli ortalama yönteminin bazı sakıncalarını gidermek amacıyla türetilmiş bir yöntemdir. Bu yöntemde geçmişten seçilen verilere ağırlıklar verilir. Bu sırada en yakın veriye en büyük ağırlık en uzak veriye ise en küçük ağırlık verilir. Aşağıdaki gibi formüle edilebilir.³⁷

$$AHO(n) = w_1 y_t + w_2 y_{t-1} + \dots + w_n y_{t-n+1} \quad (2.5)$$

Burada w ağırlıktır.

³⁶ CHATFIELD Chris: “*Time Series Forecasting*”, Chapman&Hall/CRC, 2000

³⁷ DeLurgio Stephen: “*Forecasting Principles and Applications*”, Syf: 636, McGraw-Hill, 1998

1.4.2.2.4 Üssel Düzeltme Yöntemi

Üssel düzeltme yöntemi, serideki tüm verileri göz önünde bulundurur. Ancak, en eski veriye doğru gidildikçe daha az ağırlık verir. Hareketli ortalama yönteminde, eski dönemdeki veriler bütünüyle görmezden gelinmekte, yalnızca belirli bir süre kadar eski verilere eşit ağırlık verilmektedir. Üssel düzeltme yöntemi, bir bakıma, tüm verilerin hareketli ortalaması olmaktadır. Üssel düzeltme yönteminin kullanılmasındaki temel düşünce gözlemlenen değişkendeki tesadüfî dalgalanmaların etkilerini gidererek genel yönelime uygun bir tahminde bulunabilmektir.

Üssel düzeltme yönteminde kullanılan formüller aşağıdaki gibidir³⁸:

$$F_{t+1} = F_t + \alpha(y_t - F_t) \quad (2.6)$$

ya da başka bir gösterimle

$$F_{t+1} = \alpha y_t + (1 - \alpha)F_t \quad (2.7)$$

F_{t+1} : Yeni tahmin

F_t : Bir önceki tahmin

α : Düzeltme faktörü

y_t : Gerçek değer

Düzeltme faktörü olan (α) , geçmiş göz önünde bulundurularak, 0 ile 1 sınırları içinde keyfi olarak seçilir.

³⁸ KAYIM Halil: “İstatistiksel Ön Tahmin Yöntemleri”, Hacettepe Üniv. İİBF Yayınları NO:11, Ankara 1985

1.4.2.2.5 En Küçük Kareler (Regresyon) Yöntemi³⁹

Geleceği tahmin etmede kullanılan yöntemlerden en güvenilir olanlarından birisi En Küçük Kareler Yöntemidir. Eldeki veriler elverişli olduğu takdirde trendin tahmininde en çok kullanılan yöntemdir.

Bu yönteme göre, bir zaman serisi ile en iyi şekilde örtüşen doğru veya eğri, geçmiş yıllara ait gözlem değerleri ile formülün uygulanması ile bulunacak teorik değerler arasındaki farkların karelerinin toplamını (sapmaların kareleri toplamını) minimum yapan doğru veya eğridir. Temel amaç hataların karelerinin toplamını yani $\sum (Y_i - X_i)^2$ eşitliğini minimum yapabilmektir.

Zaman serisinin göstermiş olduğu eğilim, doğrusal olabileceği gibi, bir eğri şeklinde de olabilir. Bu nedenle, zaman serilerinde eğilimi ortaya koymak için en çok kullanılan denklemler⁴⁰,

$$Y = a_0 + a_1 X \quad (\text{Doğru denklemi}) \quad (2.8)$$

$$Y = a_0 + a_1 X + a_2 X^2 \quad (\text{Parabol denklemi}) \quad (2.9)$$

$$Y = a_0 a_1 X \quad (\text{Yarı logaritmik eğri denklemidir}) \quad (2.10)$$

Burada;

Y : Seriden alınan değerler,

X : Seriden alınan değerlerin sıra sayısı.

³⁹ SERPER Özer, “Uygulamalı İstatistik 2”, Ezgi Kitabevi, Bursa 2000

⁴⁰ SERPER Özer, “Uygulamalı İstatistik 2”, Ezgi Kitabevi, Bursa 2000

Bir zaman serisinin hangi formülle daha iyi örtüşeceğini anlayabilmek için serinin değerlerinin grafiğini çizmek gerekir. Serideki veriler doğruya mı, parabole mi daha uygun olacağı grafikten de anlaşılamaz ise tüm formüller denenmelidir. En az hata hangi formül ile elde edilirse o formül tercih edilmelidir.

$Y = a + bX$ regresyon doğrusu denklemindeki a ve b katsayıları bilinirse, herhangi bir X değeri için Y 'nin alacağı değer hesaplanır ve böylece gelecek dönemlerin tahminleri yapılabilir. “ a ” ve “ b ” katsayıları aşağıdaki formüllerle bulunabilir.

$$a = \frac{\sum Y}{n} - b \frac{\sum X}{n} \quad (2.11)$$

$$b = \frac{n \sum XY - \sum X \sum Y}{n \sum X^2 - (\sum X)^2} \quad (2.12)$$

1.4.2.2.6 Box – Jenkins Tahmin Yöntemi⁴¹

Box – Jenkins yöntemi zaman serileri kullanarak geleceği tahmin etmek için kullanılan tek değişkenli bir modeldir. Kısa dönem tahminlerinde oldukça başarılı bir yöntemdir. Eşit zaman aralıklarıyla yapılan gözlemlerden elde edilen serinin kesikli ve durağan olması bu yöntemin önemli bir varsayımdır. Box – Jenkins yöntemi, gözlem değerlerinin zamana bağlı tesadüfi olduğunu ve serinin de stokastik bir süreç olduğunu varsayar.⁴²

⁴¹ KAYIM Halil: “İstatistiksel Ön Tahmin Yöntemleri”, Hacettepe Üniv. İİBF Yayınları NO:11, Ankara 1985

⁴² BİRCAN Hüdaverdi, KARAGÖZ Yalçın: “Box-Jenkins Modelleri ile Aylık Döviz Kuru Tahmini Üzerine Bir Uygulama”, Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi (6), 2003 /2:49-62

a. Doğrusal Durağan Stokastik Modeller

Bu modeller istatistiksel bir dengeyi ifade etmektedir. Gözlem değerlerinin sabit bir ortalama etrafında hareket ettiğini gösterir.

Otoregresif Hareketli Ortalama Modeli (Auto Regressive Moving Averages – ARMA)⁴³

“Zaman serisi modellerinde esneklik sağlamak için en az sayıda parametre kullanma ilkesini gerçekleştirmek amacıyla bazı hallerde modele hem otoregresif hem de hareketli ortalama parametrelerinin alınması birçok faydalar sağlamaktadır. Bu düşünce ARMA modelini ortaya çıkarmıştır.⁴⁴

Bu modelin, bir zaman serisinin herhangi bir t dönemine ait x_t gözlem değeri, ondan önceki belirli sayıda $x_{t-1}, x_{t-2}, \dots, x_{t-p}$ gözlem değerlerinin ve $a_t, a_{t-1}, a_{t-2}, \dots, a_{t-q}$ hata terimlerinin doğrusal birleşiminden meydana gelmektedir. ARMA modelinin genel ifadesi

$$x_t = \Phi_1 x_{t-1} + \Phi_2 x_{t-2} + \dots + \Phi_p x_{t-p} + a_t - \Theta_1 a_{t-1} - \Theta_2 a_{t-2} - \dots - \Theta_q a_{t-q} \quad (2.13)$$

$$x_t - (\Phi_1 x_{t-1} + \Phi_2 x_{t-2} + \dots + \Phi_p x_{t-p}) = a_t - \Theta_1 a_{t-1} - \Theta_2 a_{t-2} - \dots - \Theta_q a_{t-q} \quad (2.14)$$

şeklinde yazılır.

⁴³ CHATFIELD Chris: “Time Series Forecasting”, Chapman&Hall/CRC, 2000

⁴⁴ KAYIM Halil, “İstatistiksel Ön Tahmin Yöntemleri”, H.Ü.İkt.ve İdr.Bil.Fak.Yayınları, No:11, Ankara 1985

b. Durağan Olmayan Doğrusal Stokastik Modeller (Auto Regressive Integrated Moving Averages – ARIMA)⁴⁵

“Durağan olmayan bir zaman serisini durağan hale getirmek için ihtiyaç durumuna göre serinin genellikle 1 veya 2 defa farkı alınır ve d ile gösterilir.

Durağan olmayıp farkı alınarak durağan hale getirilmiş serilere uygulanan modellere durağan olmayan doğrusal stokastik modeller veya kısaca entegre modeller denir.

Bu entegre modeller belirli sayıda farkı alınmış serilere uygulanan otoregresif (Auto Regressive – AR) ve hareketli ortalama (Moving Average – MA) modellerinin birleşimidir. Eğer AR modelinin derecesi p, MA modelinin derecesi q ve serinin d defa farkı alınmışsa bu modele (p,d,q) dereceden otoregresif entegre hareketli ortalama modeli denir ve ARIMA(p,d,q) şeklinde gösterilir. Modelin genel ifadesi

$$w_t = \Phi_1 w_{t-1} + \Phi_2 w_{t-2} + \dots + \Phi_p w_{t-p} + a_t - \Theta_1 a_{t-1} - \Theta_2 a_{t-2} - \dots - \Theta_q a_{t-q} \quad (2.15)$$

şeklindedir.”⁴⁶

1.4.2.2.7 Vektör Oto Regresyon Tahmin Yöntemi (Vector Auto Regression - VAR)

Sims tarafından 1980 yılında geliştirilen Vektör Oto Regresyon (Vector Auto Regression – VAR) yönteminde; sistem içindeki her bir değişken, o değişkenin ve sistemdeki diğer bütün değişkenlerin geçmişteki hareketlerine bağlı değerlerin yer

⁴⁵ DeLurgio Stephen: “*Forecasting Principles and Applications*”, Syf: 636, McGraw-Hill, 1998

⁴⁶ BİRCAN Hüdaverdi, KARAGÖZ Yalçın: “*Box-Jenkins Modelleri ile Aylık Döviz Kuru Tahmini Üzerine Bir Uygulama*”, Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi (6), 2003 /2:49-62

aldığı eşitliklerin dinamik bir sistemidir⁴⁷. Bu sisteme göre tüm içsel ve dışsal değişkenler kendi gecikmeleri ve diğer değişkenlerin gecikmeli değerleri ile açıklanır. Diğer tahmin yöntemlerinden farklı olarak ekonominin temel yapısı hakkında sadece birkaç varsayım yapar ve tamamen ekonomik değişkenler arasında geçmişteki etkileşimlerin istatistiksel bir modelini elde etmeye odaklanmak yerine, modeli verilerin belirlemesini sağlar. Sims'e göre yapısal modellerdeki değişkenlerin içsel-dışsal diye ayrılması yanlıştır, hepsi aynı formüle dâhil edilmelidir.

VAR modeli matematiksel olarak aşağıdaki gibi ifade edilebilir.

$$X_t = \alpha_0 + \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \dots + \alpha_p X_{t-p} + \beta_0 A_t + \varepsilon_t \quad (2.16)$$

Burada,

- X_t : (n x 1) içsel değişkenler vektörü,
- $X_{t-1}, \dots, X_{t-p}$: (n x 1) gecikmeli içsel değişkenler vektörü,
- A_t : (n x 1) dışsal değişkenler vektörü,
- α_0 : (n x 1) sabit terim vektörü,
- $\alpha_1, \dots, \alpha_p$: gecikmeli içsel değişkenler (n x n) katsayı matrisi,
- β_0 : gecikmeli dışsal değişkenler (n x 1) katsayı vektörü,
- ε_t : (n x 1) hata terimi vektörü.

VAR modellerinde kullanılan değişkenlerin ekonomik önemi, sistemden elde edilen katsayıların büyüklüğü ve beklenmeyen şokların makro değişkenler üzerindeki etkilerini incelemek amacıyla oluşturulan etki-tepki analizi ile varyans

⁴⁷ DİNÇER Nazire Nergiz: “Döviz Kuru Dalgalanmalarının Asimetrik Etkileri: Türkiye Örneği”, DPT Uzmanlık Tezleri, Şubat 2005

ayrıştırılmaları yardımıyla yorumlanabilmektedir. Varyans ayrıştırması, k dönem sonra bir değişkenin başka bir değişkende meydana gelen şoka karşı gösterdiği yüzde değişimi vermektedir. Etki-tepki analizi ise sistemdeki her bir değişkenin sistemdeki diğer değişkenlerde meydana gelen bir standart sapma büyüklüğündeki şoka belirli bir dönem boyunca verdiği tepkinin ölçülmesini sağlamaktadır.⁴⁸

1.4.2.3 Diğer Bilgisayar Destekli Tahmin Yöntemleri

Gelecek tahmini yapabilmek için bilgisayar destekli birçok yöntem geliştirilmiştir. Bilgisayar destekli grafikler ile analiz yöntemleri, uzman sistemler, bulanık mantık ve yapay sinir ağları yöntemlerden birkaçıdır.⁴⁹

Tezimizin de konusunu oluşturduğu gibi özellikle son yıllarda yapay sinir ağları zaman serilerinin analizinde ve gelecekteki değerinin tahmininde sıklıkla kullanılan bir yöntem olmuştur.⁵⁰ YSA zaman serilerinin gelecekteki değerinin tahmin edilmesinde gelişmekte olan ve ulaştığı başarılı sonuçlardan dolayı umut vadeden bir yöntemdir. Zaman serileri çoğunlukla lineer bir modelle ifade edilemeyen yani non-lineer modellerdir. YSA'nın avantajı işte bu noktadadır. Çünkü YSA ile yapılan non-lineer modellemeler gerçek gözlem değerlerinden oluşan seri ile daha fazla örtüşebilmektedir⁵¹.

Yapay Sinir Ağlarından ve zaman serilerinin tahmininde kullanımından bir sonraki bölümde ayrıntılı bir şekilde değinilecektir.

⁴⁸ TUTAR Eser, “Enflasyon Hedeflemesinin Önkoşulları: Türkiye’de Para Politikası Araçları İle Enflasyon Arasındaki İlişkinin İncelenmesi”, Uzmanlık Yeterlilik Tezi, Syf: 41, TCMB Piyasalar Genel Müdürlüğü, Ankara, Ağustos 2005

⁴⁹ JANUSKEVICIUS Marius: “Testing Stock Market Efficiency Using Neural Networks Case of Lithuania”, Mayıs 2003

⁵⁰ KAASTRA Iebeling, BOYD Milton: “Designing a neural network for forecasting financial and economic time series”

⁵¹ LAWRENCE Ramon: “Using Neural Networks to Forecast Stock Market Prices”, Department of Computer Science University of Manitoba, 12 December 1997

1.4.3 Tahmin Yöntemlerinin Doğruluğu (Performanslarının Ölçülmesi)^{52, 53}

Hangi yöntem kullanılırsa kullanılsın %100 kesin bir tahmin yoktur gelecek %100 biliniyorsa zaten bu “tahmin” değildir. Bu sebeple belirli bir hata oranını baştan kabul etmek gerekir. Gelecekteki hareketleri tahmin edebilmek için geliştirilmiş olan onlarca değişik model vardır. Her bir modelin kendine has ve uygulama yerine göre avantajları aynı zamanda da dezavantajları vardır. Ekonomi ve finansal alanda kullanılan tüm tahmin yöntemlerinde temel amaç gelecekteki hareketlenmeleri daha önceden öngörerek riskleri ve zararları en aza indirirken getirileri arttırabilmektir.

Kullanılan yöntemlerden teknik analiz tarihin tekerrür ettiğini varsayar ve bunu verilerin grafiklerinden bulmaya çalışır. Temel analiz, fiyatların birçok parametreye bağlı olarak etkilendiğini varsayar ve tüm ekonomik ve finansal değişkenlerin tahmin edilmeye çalışılan değişkene olan etkisini anlamaya çalışır. İstatistiksel ve regresyon yöntemleri, geçmişteki gözlem değerlerinden bir formül üretmeye çalışır. Kaos teorisi, piyasanın rasgele hareketlerinin tam olarak anlaşılması neredeyse imkânsız olduğunu, birçok dinamik değişkene bağlı olup non-lineer olarak hareket ettiğini varsayar. Son yıllarda oldukça popüler olan YSA ise non-lineer bir yapıya sahip olan bir zaman serisinin girdileri ile çıktıları arasında bir ilişki kurmaya çalışır. Bu ilişkiyi kurarken daha önceki verileri kullanarak öğrenme işlemini gerçekleştirir.

Sonuçta doğru bir model, doğru bir yöntem diye bir şey vardır diyebilmek çok zordur. Her yöntemin destekleyicileri ve karşı çıkanları vardır.

Genel olarak bir tahminin ayrıntı ve doğruluk seviyesi aşağıdakilere dayanmalıdır:

⁵² KAYIM Halil: “İstatistiksel Ön Tahmin Yöntemleri”, Hacettepe Üniv. İİBF Yayınları NO:11, Ankara 1985

⁵³ CHATFIELD Chris: “Time Series Forecasting”, Chapman&Hall/CRC, 2000

- Tahmin edilmeye çalışılan değişkenin tahmin edilebilirliği,
- Kullanılan yöntem ve teknik,
- Tahmin etmeye çalışan uygulayıcının özellikleri ve tecrübesi,
- Çalışmaya ayrılacak zaman, kaynak ve emek,
- Bahsedilen tahminin çalışma sonuçlarına hassaslığı.

Tahmin etmenin maliyeti tahminin kavramsaldan daha ayrıntılıya gidildikçe artar. Dolayısı ile daha pahalıya mal olmuş daha fazla kaynak ayrılmış ve üzerinde daha çok çalışılmış bir tahmin modeli daha başarılıdır diyebiliriz.

Literatürde birçok performans ölçüm yöntemi vardır. Örneğin^{54,55,56}

- Correlation(CORR- Korelasyon),
- Mean Absolute Error (MAE – Ortalama Mutlak Hata),
- Mean Absolute Percentage Error (MAPE – Ortalama Mutlak Hata Yüzdesi),
- Mean Squared Error (MSE – Hata Kareleri Ortalaması),
- Mean Squared Prediction Error (MSPE – Tahminin Hata Kareleri Ortalaması),
- Normalized Mean Squared Error (NMSE – Normalize Edilmiş Hata Kareleri Ortalaması),
- Normalized Root Mean Squared Error (NRMSE – Normalize Edilmiş Hata Karelerinin Ortalamasının Kökü),
- Root Mean Squared Error (RMSE – Hata Karelerinin Ortalamasının Kökü),
- Root Mean Square Prediction Error (RMSPE – Tahminin Hata Karelerinin Ortalamasının Kökü),

⁵⁴ Yöntemlerin isimleri literatürde geçtiği gibi orijinal haliyle bırakılmıştır.

⁵⁵ KOSKIVAARA Eija: “*Different Pre-Processing Models for Financial Accounts when Using Neural Networks for Auditing*”, Turku Centre for Computer Science TUCS, Turku - Finland, Kasım 2004

⁵⁶ THAWORNWONG Suraphan, ENKE David: “*Forecasting Stock Returns with Artificial Neural Networks*”, “*Neural Networks in Business Forecasting*”, ZHANG G.Peter, 2004, Idea Group Publishing, Chapter 3

- Prediction Mean (MEAN – Tahmin Ortalaması),
- Mean Absolute Deviation (MAD – Mutlak Sapmaların Ortalaması)
- Prediction Standard Deviation (STD – Tahmin Standart Sapma)

Bu yöntemlerden en çok kullanılanların formülleri aşağıda verilmiştir.

- Hata Kareleri Ortalaması (MSE - Mean Squared Error)⁵⁷

$$MSE = \frac{\sum_{i=1}^K (y_i - F_i)^2}{K} \quad (2.17)$$

- Ortalama Mutlak Hata Yüzdesi (MAPE - Mean Absolute Percentage Error)⁵⁸

$$MAPE = 100 \times \frac{\sum_{i=1}^K |y_i - F_i| / y_i}{K} \quad (2.18)$$

⁵⁷ KAYIM Halil: “İstatistiksel Ön Tahmin Yöntemleri”, Hacettepe Üniv. İİBF Yayınları NO:11, Ankara 1985

⁵⁸ CHATFIELD Chris: “Time Series Forecasting”, Chapman&Hall/CRC, 2000

1.4.4 Zaman Serilerinin Finans Alanında Kullanımı İçin Çözümlemesinde Karşılaşılan Zorluklar

Makroekonomik modellemelerde ve tahmin çalışmalarında karşılaşılan bazı zorluklar ise şunlardır⁵⁹:

1.4.4.1 Kesin Bir Modelin Olmaması

Ekonomik modellerde kesin ve tatmin edici bir model henüz yoktur ve olması da mümkün değildir. Çünkü ekonomi kontrol ve tahmin edilemez yüzlerce, binlerce parametreye bağlıdır. Örneğin ölçülmesi mümkün olmayan psikolojik ve sosyolojik faktörler dahi ekonomiyi çok rahat etkileyebilmektedir. Ekonomistlerin makroekonomiyi modellemede yakınsadıkları iki çözüm vardır: Ekonometri modeli ve zaman serileri modeli.

- a. **Ekonometrik model:** Bu modele göre ekonomi yüzlerce hatta ve hatta binlerce değişkene bağlıdır. Bu model ekonominin niteliklerinin nasıl çalıştığını anlamak için kullanılabilirken niceliksel tahminler yapma konusunda kötü bir üne sahiptir.
- b. **Zaman serileri modeli:** Ekonometri modelinin geleceği tahmin etmede kötü bir performans sergilemesinden ötürü birçok ekonomist standart zaman serileri modeli ile ekonomik aktiviteleri analiz ve tahmin etmeye yönelmiştir. Literatürde onlarca zaman serisi modeli vardır⁶⁰. Son yıllardaki en popüler ve en güvenilir model Bayesian Vector Autoregressive (BVAR) modelidir⁶¹.

⁵⁹ MOODY John: “*Economic Forecasting: Challenges and Neural Network Solutions*”, Keynote talk presented at the International Symposium on Artificial Neural Networks, Hsinchu, Taiwan, Aralık 1995

⁶⁰ DeLurgio Stephen: “*Forecasting Principles and Applications*”, McGraw-Hill, 1998

⁶¹ ZHANG G. Peter: “*Neural Networks in Business Forecasting*”, Idea Group Publishing, 2004

1.4.4.2 Gürültü (İlgisiz Veriler)

Makroekonomik zaman serileri özünde çok gürültülüdür. Yani ani düşme ve yükselmelere sahiptir⁶². Gürültünün sebebi ise tahmin edilemeyen etmenler ve ekonomiyi etkileyen verilerin toplanmasındaki tekniklerdir.

1.4.4.3 Durağan Olmaması

Makroekonomik zaman serileri kesinlikle durağan ya da sabit değildirler⁶³. Makroekonomik serilerin dinamikleri periyodik olarak değişir. Değişen sadece ekonominin dinamikleri değildir. Aynı zamanda gürültü miktarı ve oranı da değişmektedir. Günlük yaşamda ekonomik modelde gürültü sabit ya da periyodik değildir.

1.4.4.4 Lineer Olmaması

Geleneksel makroekonomik zaman seri modelleri lineerdir. Bununla beraber, birçok ekonomist araştırmacı geleceğin öngörülmesinde lineer olmayan (non-lineer) modellerin kullanılmasını önermektedir. Bu durumda lineer olmayan serilerin öngörülmesindeki başarısından dolayı yapay sinir ağlarının kullanımı akla gelmektedir⁶⁴.

⁶² ÖZMEN Ahmet: “Zaman Serilerinde Tutarlı Kestirimler İçin İstatistiksel Yöntem Uyarlaması”, Anadolu Üniv. Fen-Edebiyat Fakültesi Dergisi, Kasım 1988, Cilt 1, Sayı 1, Syf. 69-80

⁶³ KAYIM Halil: “İstatistiksel Ön Tahmin Yöntemleri”, Hacettepe Üniv. İİBF Yayınları NO:11, Ankara 1985

⁶⁴ LENDASSE A., DE BODT E.: “Non Linear Financial Time Series Forecasting – Application to the Bel 20 Stock Market Index”, European Journal of Economic and Social Systems 14 No1 (2000), Syf:81-91

BÖLÜM II

2 YAPAY SİNİR AĞLARI; EKONOMİ VE FİNANSTA KULLANIMI

2.1 YAPAY ZEKÂYA GENEL BAKIŞ

Son teknoloji diye adlandırdığımız birçok ürünün doğada milyonlarca yıldır zaten var olduğunu çoğu zaman göz ardı ederiz. Birçok teknolojik yenilik doğayı taklit ederek üretilmiştir. Doğadaki örnekler genellikle daha küçük, hafif, verimli ve daha zekidir. Evet zekilik, zekâ da doğanın canlılara bahsettiği bir nimettir. İnsanoğlu zekânın kaynağını binlerce yıldır araştırmıştır. Araştırdıklarından öğrendiklerini de kendisi yapmaya çalışmıştır. Bunun sonucunda da günümüzde “Yapay Zekâ” ismini verdiğimiz bir kavram ortaya çıkmıştır.

BBC ile bir söyleşisinde MIT Bilgisayar Bilimleri laboratuvarı yöneticilerinden Edward Fredkin “Tarihte üç büyük olay vardır. Bunlardan ilki, evrenin oluşumudur. İkincisi, yaşamın başlangıcıdır. Bu ikisiyle aynı derecede önemli olan üçüncüsüye, yapay zekânın ortaya çıkışıdır.” demiştir.¹ Bu sözler sadece bilgisayar bilimcilerinin kendi dünyalarında geçerli, abartılı ve destek görmeyen bir iddia değil. “Yapay Zekâ” (AI - Artificial Intelligence) teriminin 1956’da ilk kez² kullanılmasından bu yana makineler ve bilgisayarlar beynin çalışmasını benzetmeye (simüle etmeye) çalışmaktadır. Bu çaba ilk başlarda beyine kıyasla çok ama çok basit de kalsa günümüzde çok hızlı ve yüksek kapasiteli bilgisayarların da yardımıyla yapay zekâ çalışmalarında bir hayli yol alınmıştır. Gelişen teknolojinin desteğiyle tıp alanında yapılan büyük keşifler sayesinde beyin üzerinde yapılan ayrıntılı araştırmalar da beynin çalışmasının daha iyi anlaşılmasına yol açmıştır. İnsanoğlu beynin çalışma yöntemini anladıkça onu taklit etmeye daha da yaklaşmaya başlamıştır. Buna rağmen insanoğlunun kendi beynini kullanarak yine kendi beynini üretmesi için daha kat edilecek çok ama çok fazla mesafe vardır.

¹ “Yapay Zeka” Bilim ve Teknik, Aralık 2001

² ALTUNTAŞ Erhan, ÇELİK Tuncay, “Yapay Zekâ”, E-Book, 2003

Mühendislik açısından, yapay zekâ ile ulaşılmak istenen şey aslında bir makinenin ya da bilgisayarın insan gibi düşünmesini, karar vermesini, tahminde bulunmasını ve insanımsı davranışlar sergilemesini sağlayabilmektir.³

Temel olarak bir yapay bir sistemin yani bir bilgisayarın, bir makinenin, insanı andıran zekice davranışlar sergileyebilmesi için en azından aşağıdaki temel bileşenlere sahip olması gerekmektedir⁴:

- Algılama
- Kavrama/idrak
- Eylem

Ayrıca, bu her bir bileşenin de "zeki" diye vasıflandırılabilen niteliklere sahip olması gerekir. Zeki bir etmen, algılamasını gerçek zamanda, seçimli, öncelikli ve bağımsız olarak yapabilmelidir. Aynı şekilde, kavrama bileşeni de benzer özelliklere sahip olmalı, olayların gelişimine göre algılama bileşeninden gelen verilerden ve kendi içinde oluşturduğu modellerden gerçek zamanda durum tespiti ve değerlendirmesi yapabilmeli, hafıza, anlama, problem çözme, öğrenme, planlama ve kontrol gibi özelliklere sahip olmalıdır. Eylem bileşeni de aynı şekilde zeki özelliklere sahip olmalı ve düşünme bileşeninden gelen kararları gerçek zamanda uygulayabilmelidir. Aynı zamanda bu üç bileşen özellikle hızlı hareketi gerektiren durumlarda birbirleriyle tam bir uyum içinde olmalıdır.

³MACY B.Robert, PANDYA S. Abhijit; “*Pattern Recognition with Neural Networks in C++*”, CRC Press, 1995

⁴ ÖZTEMEL Ercan: “*Yapay Sinir Ağları*”, Papatya Yayıncılık, Ağustos 2003

2.1.1 Yapay Zekânın Gelişimi

Yapay zekâ konusunun iyi anlaşılabilmesi, felsefeden bilgisayar bilimine, psikolojiden beynin anatomik yapısına kadar geniş bir yelpaze içinde çeşitli bilim dallarında yapılan çalışmaların izlenmesi ile mümkündür.

Descartes ve onu izleyen düşünörlere göre varlık, ruh ve madde olmak üzere iki cevherden oluşmuştur. Bu yaklaşım maddi cevherle ilgili elemanların tamamen maddi, hatta mekanik bir yoldan açıklanabileceğı düşöncesini ortaya koymaktadır. Zihni işlemlerin kendine özgü bir varlığı ve kendi kanunlarının geçerli olduğunu belirten bu düşönce, bilgi kuramı (Epistemology), psikoloji gibi dallarla birlikte yapay zekânın da başlangıç kuramını oluşturmuştur.⁵

Ruh ve maddenin birbirinden ayrılması düşöncesi sonucunda, düşünörlöer insanın oluşumu için gerekli bu iki varlığın nasıl birlikte hareket ettiğinin açıklamaya çalışmışlardır. Bu konuda ileri sürölen varsayımlar içerisinde, İskoç düşünörü David Hume'un "Cognition is computation" ifadesi ile açıkladığı, zihni işlemlerin de fiziksel işlemler gibi matematik yoluyla ifade edilebileceğı fikri, geniş kabul görmüştür. Düşönmöenin bir hesaplama işlemi olduğu kabul edildikten sonra, bu işlemin nasıl ifade edilebileceğı ve çözülebileceğı konusundaki çalışmalar önem kazanmıştır⁶.

1956 yılında John McCarthy tarafından "Artificial Intelligence" ismi ilk kez kullanılmış ve yapay zekâ bir araştırma konusu olarak incelenmeye başlanılmıştır⁷.

⁵ LUGER George, STUBBLEFIELD William, "Artificial Intelligence and the Design of Expert Systems", The Benjamin/Cummings Publishing Company, 1980

⁶ AKPINAR Haldun; "Yapay Sinir Ağları ve Kredi Taleplerinin Değerlendirilmesinde Bir Uygulama Önerisi", Mayıs 1993

⁷ ALTUNTAŞ Erhan, ÇELİK Tuncay, "Yapay Zekâ", E-Book, 2003

2.1.2 Turing Testi

Turing testi, “Makineler düşünebilir mi?” sorusuna yanıt verebilmek için İngiliz matematikçi Alan Turing tarafından 1950 yılında yayınlanan bir makale ile getirilen felsefi bir yaklaşımdır.⁸ Özetle Turing Testi için, bir bilgisayar oyunu ya da yapay zekâ içeren sohbet (chat) programıdır denilebilir. Genel anlamda, bu bilgisayar yazılımı ile sohbet eden kişi karşısındakinin bir bilgisayar mı yoksa insan mı olduğunu ayırt edemezse makineler de bir insan kadar zihinsel yeteneğe sahip olmuştur demektir. Bu testte bir kullanıcı ve bir bilgisayar deneyi yapan kişiden gizlenir. Deneyi yapan kişi yazılı olarak istediği soruyu sorar karşısındaki de yanıtlarını bilgisayar ekranında gösterir. Eğer deneyi yapan kişi karşısındakinin başka bir insan mı yoksa bir bilgisayar mı olduğunu kesin olarak söyleyemezse o zaman bilgisayar Turing testini geçer.

İnternet ortamında bu tür sanal karakterleri bulmak mümkündür⁹. Turing’in 1950’de yayınladığı makaleden günümüze kadar bilgisayarlar ve algoritmalar oldukça gelişmiş olduğundan bu sanal karakterler sorulara oldukça gerçekçi yanıtlar verebilmektedir. İnsanı şaşırtacak kadar mantıklı yanıtlar verebilmesine ve hatta zaman zaman acaba karşımda birisi mi var diye düşündürmesine rağmen zekice sorulmuş sıralı sorular ile sohbet programının açığını yakalayabilmek mümkündür. Yani bilgisayarların Turing testini geçebilmesi için vakit henüz erkendir.

2.1.3 Yapay Zekâ Teknikleri

Yapay Zekâ kavramın gündeme gelmesinden sonra, değişik tipteki problemler ve günlük olaylar için değişik teknolojiler ve uygulamalar geliştirilmiştir¹⁰. Nasıl ki bir olaya dünyanın değişik yörelerindeki insanlar, kendi kültürlerine, eğitimlerine, çevresine, vs. bağlı olarak değişik tepkiler vermekte ise insan beynini taklit etmeye

⁸ NABİYEV Vasif V.; “Yapay Zekâ – Problemler, Yöntemler, Algoritmalar”, Seçkin Yayınevi, Birinci Basım, Ekim 2003

⁹Örneğin : www.alicebot.com

¹⁰ TEKTAŞ Mehmet, AKBAŞ Ahmet, TOPUZ Vedat: “Yapay Zekâ Tekniklerinin Trafik Kontrolünde Kullanılması Üzerine Bir İnceleme”, Marmara Üniversitesi, Teknik Bilimler MYO, 1997

çalışarak üretilen yapay zekâ teknolojileri de geliştirildiği çevreye göre çok farklılık ve çeşitlilik içermektedir.

Genel olarak en bilinen yapay zekâ teknolojileri şu şekilde sıralanabilir:

2.1.3.1 Genetik Algoritmalar (Genetic Algorithms)

Özellikle karmaşık optimizasyon problemlerinin çözülmesinde kullanılan bir yapay zekâ teknolojisidir. Evrim teorisi fikrinden esinlenerek geliştirilen genetik algoritmalar ile en iyi çözümü koruyarak doğal seçim ile daha iyi sonuçlar elde etmeye çalışan bir yazılım algoritmasıdır¹¹. Genetik Algoritmalar (GA) üzerine ilk çalışmalar 70’li yılların başında Michigan Üniversitesinde John Holland ve arkadaşları tarafından gerçekleştirilmiştir.¹² Holland 1975’de yayınladığı “Doğal ve Yapay Sistemlerin Uygulanması” adlı kitabında Darwin’in evrim teorisinden esinlenerek; sadece bir tane mekanik yapının öğrenme yeteneğinin geliştirilmesi yerine, böyle yapılardan oluşan bir topluluğun çoğalma, çiftleşme, değişim gibi genetik süreçlerden geçirilerek, başarılı yeni bireylerin oluştuğunu göstermiştir. Kitap ve yöntem yayınlandığı dönemde GA’ların pratikte pek yararı olmadığı düşünülmesine rağmen, bir inşaat mühendisi olan Goldberg, gaz borusu hatlarının denetimi üzerine yaptığı çalışma sonucunda GA’ların pratik kullanımının da olduğunu ispatlanmış ve bir de “NSF Presidential Young Investor Award (National Science Foundation Genç Araştırmacı Ödülü)”¹³ ödülünü kazanmıştır.¹⁴

¹¹ BLANCO A., DELGADO M., PEGALAJAR M.C.: “ A Genetic Algorithm to Obtain the Optimal Recurrent Neural Network”, International Journal of Approximate Reasoning 23 (2000) 67 – 83

¹² KORUKOĞLU Serdar, İŞÇİ Öznur; “Genetik Algoritma Yaklaşımı ve Yöneylem Araştırmasında Bir Uygulama”, Celal Bayar Üniversitesi İ.İ.B.F, Yönetim Ve Ekonomi, Yıl: 2003 Cilt:10 Sayı:2

¹³ GOLDBERG E. David, “<http://www-illigal.ge.uiuc.edu/goldberg/d-goldberg.html>” Kişisel Web Sayfası (Mayıs 2006)

¹⁴ TURGUT Paki, ARSLAN Abdussamet, “Sürekli Bir Kirişte Maksimum Momentlerin Genetik Algoritmalar ile Belirlenmesi”, DEÜ Mühendislik Fakültesi, Fen ve Mühendislik Dergisi, Ekim 2001 Cilt:3 Sayı:3 sh.1-9

GA’da başlangıç değerleri rasgele olarak alınır ve en iyi sonuç elde edilinceye yani hata en aza ininceye kadar sonuçlar mutasyona uğratılır, çaprazlanır ve işlem tekrarlanır. Genel olarak GA işlem adımları aşağıdaki gibidir¹⁵.

1. **Başlangıç:** Rasgele bir başlangıç topluluğu üret
2. **Uygunluk:** Topluluktaki her bireyin (kromozomun) uygunluk değerini hesapla
3. **Yeni Topluluk:** Yeni bir topluluk elde edilene kadar aşağıdaki adımları yinele
 - a. **Seçim:** Topluluktan 2 çift birey(kromozom) seç.
 - b. **Çaprazlama:** Çiftleri çaprazlayarak yeni bir ürün (evlat) oluştur.
 - c. **Mutasyon:** Yeni üründe (evlatta) mutasyon ile rasgele bir değişiklik meydana getir.
 - d. **Kabul:** Yeni evladı yeni topluluğa dâhil et.
4. **Yer Değiştirme:** Bundan sonra elde edilmiş olan yeni topluluğu kullan.
5. **Test:** Ulaşılmak istenen sonuç için yeterli performans elde edildi ise işlemi durdur.
6. **Geri Dön:** 2. adıma geri dön.

İşlem adımlarından da anlaşılabilceği gibi önce rasgele bir topluluk oluşturulur. Topluluğu oluşturmak için belirli bir sayı yoktur. Yapılan işin karmaşıklığına ve aramanın derinliğine bağlı olarak 100 – 300 aralığında¹⁶ olabilir. İlk topluluk oluşturulurken, çözüme daha hızlı ulaşabilmek için bireylerin mümkün olduğu kadar birbirine benzememesine dikkat edilir. Sonrasında topluluk içinden bir çift seçilir. Seçme işlemini yapabilmek için rulet tekerleği seçimi (Roulette Wheel Selection), turnuva seçimi (Tournament Selection) gibi seçme yöntemleri vardır. Seçilen bireyler ikili sayı şeklinde (binary) ifade edilirler. Daha sonra ikili sistemde gösterilen bireyler bit bazında belirlenen çaprazlama oranı ve şekline göre

¹⁵ OBITKO Marek, “Introduction to Genetic Algorithms”,
“<http://cs.felk.cvut.cz/~xobitko/ga.index.html>”, Mayıs 2006

¹⁶ NABİYEYEV Vasif V.; “Yapay Zeka – Problemler, Yöntemler, Algoritmalar”, Seçkin Yayınevi, Birinci Basım, Ekim 2003

çaprazlanır. Daha sonra ikili sayılar bit bazında yine belirlenen mutasyon oranı ve şekline göre mutasyona uğrattılır. Tüm bu işlemler sonucu artık yeni bir topluluk oluşturulmuş olur.¹⁷ Oluşturulan yeni topluluktaki en iyi birey seçilerek en iyi bireylerin yer aldığı topluluğa dâhil edilir. Son adımda da, hedeflenen sonuca belli bir oranda yaklaşmış olan iyi bireylerin yer aldığı tablodaki en iyi birey seçilerek işlem tamamlanır.

İstenilen düzeyde bir başarı elde edilene kadar veya topluluk başarıda artış sağlayamaz duruma gelinceye kadar veya önceden belirlenmiş bir sayı kadar döngü gerçekleştirilince işlemler durdurulur.¹⁸

2.1.3.2 Uzman Sistemler (Expert Systems)


Belirli bir sorunu çözebilmek için o konunun uzmanları gibi düşünüp yorumlayarak karar vermeye çalışan bir yapay zekâ teknolojisidir. Uzmanlar, uzmanlık alanındaki bir sorunu çözmek için bilgi ve deneyimlerinden yararlanır. Uzman sistemler de bir sorunu çözebilmek için o konunun uzmanından yararlanılarak oluşturulan bir veri tabanından yararlanır. Bir uzman sistemin performansı, bilgi tabanının etkililiği ile doğru orantılıdır.¹⁹ Uzman sistemler alanındaki gelişmeler özellikle 1965 yılından sonra yaşanmıştır²⁰. Yapay zekânın bu alanı, uzmanlık gerektiren bir konuda yüksek performans gösteren programlar oluşturmak üzere odaklanmıştır.

¹⁷ TOPRAK Şükrü, GANİZ Can Murat; “Genetik Algoritmalarla Makine Öğrenmesi İçin Tıbbi Verilerden Hipotez Uzayı Oluşturulması”, Selçuk Üniversitesi, Müh.Mim.Fak. Bilgisayar Müh. Bölümü, Akademik Bilişim 2003

¹⁸ TURĞUT Paki, ARSLAN Abdussamet, “Sürekli Bir Kirişte Maksimum Momentlerin Genetik Algoritmalar ile Belirlenmesi”, DEÜ Mühendislik Fakültesi, Fen ve Mühendislik Dergisi, Ekim 2001 Cilt:3 Sayı:3 sh.1-9

¹⁹ AKDOĞAN Erhan: “Kavşak Trafiğinin Kontrolü İçin Bir Sinyal Zamanlama Algoritması ve Uzman Sistem Yaklaşımında Kullanılması”, Marmara Üniversitesi Teknik Bilimler MYO, 2002

²⁰ BAYKOÇ Ömer Faruk, ÖZ Erçetin; “Tedarikçi Seçimi Problemine Karar Teorisi Destekli Uzman Sistem Yaklaşımı”, Gazi Üniv. Müh.Mim.Fak.Der. Cilt:19, No:3, 275-286, 2004



Şekil 1 – Bir uzman sistemin genel yapısı²¹

Uzman sistemleri oluşturan birimler şöyledir²²:

- **Bilgi Tabanı (Knowledge Base):** Bir problemin anlaşılması, çözülmesi için gerekli bilgileri içerir. Olaylar ve durumlar hakkında bilgi ve bunlar arasındaki ilişki yapılarını ihtiva eder.
- **Mantıksal Çıkarım Mekanizması (Inference Engine):** Uzman sistemin yorum yapan kısmı yani bir anlamda beynidir. Sistemin veri tabanındaki verileri nasıl kullanacağını yorumlayan birimdir.
- **Kullanıcı Arabirimi (User Interface):** Kullanıcının sisteme soruları ve verileri girmesini sağlayan birimdir. Sistem bir bilgisayar yazılımı şeklinde tasarlanmış ise kullanıcının kolaylıkla verileri gireceği şekildedir.
- **Bilgiyi Alma Ünitesi (Knowledge Acquisition):** Kullanıcının veri tabanındaki verileri alma, ekleme, çıkarma, silme gibi işlemlerin yapmasına olanak tanıyan birimdir.²³

²¹ NABİYEYEV Vasif V.; “Yapay Zeka – Problemler, Yöntemler, Algoritmalar”, Seçkin Yayınevi, Birinci Basım, Ekim 2003

²² GÜLESİN Mahmut, ÖZKAN Murat Tolga, “Uzman Sistem Yaklaşımı ile Cıvata ve Dişli Çark Seçimi”, Türk J Engin Environ Sci. 25 (169 – 177) , TÜBİTAK 2001

²³ GÜLESİN Mahmut, ÖZKAN Murat Tolga, “Uzman Sistem Yaklaşımı ile Cıvata ve Dişli Çark Seçimi”, Türk J Engin Environ Sci. 25 (169 – 177) , TÜBİTAK 2001

- **Açıklama Ünitesi:** Kullanım sırasında kullanıcıya açıklamaların yapıldığı, çeşitli yardımların verildiği birimdir. Ayrıca çalışma anında bazı sorular sorarak kullanıcıyı yönlendiren; kullanıcıya neden bu soruyu sorduğunu açıklayan birimdir.²⁴

2.1.3.3 Bulanık Mantık (Fuzzy Logic)


Bilgisayarlar “binary logic” ismi verilen, temeli iki olasılığı olan Aristo mantığına dayanan, ikili mantık sistemine göre üretilmişlerdir. Bir bilgisayar için sonuç ya 1 ya da 0’dır. Bu 1 ve 0’ı konuşma diline dökersek ya “var”dır ya da “yok”dur, ya “genç”tir ya da “yaşlı”dır, ya “soğuk”tur ya da “sıcak”. Örnekler genişletilebilir. Görüldüğü gibi klasik mantıkta her şey kesindir. Ya bir şey soğuktur ya da sıcaktır, ılık yoktur. Hâlbuki günlük hayatta sıcak, soğuk, serin, ılık, çok soğuk, çok sıcak gibi kavramlar da vardır. Klasik mantıkta soğuk ve sıcak nerede başlar nerede biter tanımlıdır, sıcaklık değeri hangi kümeye giriyorsa sonuç kati olarak olur. Örneğin 0-15 °C arası soğuk yukarısı sıcak ise 1 °C de, 14.5°C de soğuktur. Bulanık mantıkta ise geçişler bu kadar kesin değildir, sıcaklık değerine göre şu kadar sıcak şu kadar soğuk deme şansımız vardır.

Bulanık mantık teorisi, dereceli üyelik tanımı ile birlikte ilk defa 1965 yılında California Berkeley Üniversitesinden Dr.Lotfi A. Zadeh tarafından bilim dünyasına tanıtılmıştır²⁵.

Bulanık mantık kullanan yapay zekâ sistemleri kısmen de olsa insanlar gibi yorum yapabilme yeteneğine sahip olduğundan sonuçlar kati olmak yerine doğala daha yakın olmaktadır.

²⁴ Winstanley G.; “*Artificial Intelligence in Engineering*”, New York, 1991

²⁵ ÇELİK Ş. Abdurrahman, KAYACAN M. Cengiz, “*Tornalama İşlemlerinde Kesici Takım Aşınmasının Bulanık Mantık İle Modellenmesi*”, Mühendis ve Makine, Sayı 526, Kasım 2003



Şekil 2 – Üyelik fonksiyonlarına örnekler²⁶

2.1.3.4 Yapay Sinir Ağları (Artificial Neural Networks)

İnsan beynini taklit ederek insan gibi yorum yapabilmeye çalışan yapay zekâ yöntemidir. Tezimizde kullanılan yapay zekâ yöntemi Yapay Sinir Ağları olduğu için bu konuya daha ayrıntılı olarak yer verilecektir.

²⁶ NABİYEYEV Vasif V.; “Yapay Zekâ – Problemler, Yöntemler, Algoritmalar”, Seçkin Yayınevi, Birinci Basım, Ekim 2003

Özellik	Yapay Zekâ	Doğal Zekâ
Kalıcılık	Kalıcıdır. Programlarda ve veri tabanında değişiklik yapılmadıkça silinmez.	Zamanla unutulabilir.
Kopyalanabilme	Sayısal bilgi olduğu için kolaylıkla kopyalanabilir ve başka yerlere transfer edilebilir.	Bir insanın kendi uzmanlığını, kendi zekâsı ile öğrendiğini başkasına aktarması kolay değildir. Bir eğitim süreci sonunda eğitilenin kapasitesi kadar aktarılabilir.
Maliyet	Sayısal bilginin ilk defa üretilmesi maliyetli olabilir fakat kopyalanma maliyeti çok düşüktür.	Bilgiler sayısal olmadığı, insana bağlı olduğu için herkese ayrı ayrı öğretmek maliyetlidir.
Tutarlılık	Tutarlıdır, aynı koşullarda sonuç hep aynı olur.	Kişinin ruh haline göre bile varacağı kararlar farklı olabilir.
Yaratıcılık	Yoktur. Ne öğrendiyse, parametreler ne ise sadece ona göre yanıt verir.	Yaratıcılık ve bir şeyden yararlanarak başka şeyleri de üretebilme öğrenebilme yeteneği vardır.
Muhakeme Gücü	Öğrendiği kadarı ile dar bir alanda çalışır.	Muhakeme gücü vardır. Bir konudaki problemi çözmek için başka konulardaki tecrübelerinden de yararlanabilir.

Tablo 1 – Yapay Zekâ ile Doğal Zekânın karşılaştırılması²⁷

²⁷ NABİYEYEV Vasif V.: “Yapay Zekâ – Problemler, Yöntemler, Algoritmalar”, Seçkin Yayınevi, Birinci Basım, Ekim 2003

2.2 SİNİR HÜCRELERİ VE SİNİR AĞLARI

Yapay Sinir Ağları (YSA) isminden de anlaşılacağı gibi beyni oluşturan sinir hücrelerini (nöron) matematiksel olarak taklit ederek akıllı bir sistem oluşturmaya çalışan bir yapay zekâ yöntemidir. YSA başka bir deyişle biyolojik sinir ağlarını taklit eden bilgisayar programlarıdır²⁸. Fakat yapay sinir ağları henüz biyolojik olarak beyni tam anlamıyla taklit etmekten bir hayli uzaktır. Buna rağmen sinir hücreleri kimyasal olarak çalıştıklarından tepki hızları elektriksel olarak çalışan günümüz bilgisayarlarına göre oldukça yavaştır. Bu da bilgisayarların özellikle belirli bir konuda sonuca ulaşmada ve hesaplamalarda insan beynine göre üstün olduğu bir durumdur.


İnsan beyninin yapısı tam olarak keşfedilememiş ve nasıl çalıştığı henüz kesin olarak tespit edilememiş olmasına rağmen beyni oluşturan hücreleri yani nöronların çalışma şeklinin matematiksel olarak taklit edilmesiyle Yapay Sinir Ağları geliştirilmiştir.

2.2.1 İnsan Beyni

Sinir hücrelerini tanımaya geçmeden önce milyarlarca sinir hücresinden oluşan beynimiz hakkında genel bir bilgi sahibi olmakta yarar vardır.

İnsan beyni henüz tam olarak keşfedilebilmiş değildir. Yapılan çalışmalarla beynin hangi bölgesinin hangi göreve sahip olduğu yaklaşık olarak bulunmuştur.

²⁸ ELMAS Çetin, “Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)”, Seçkin Yayıncılık, Ankara 2003



Şekil 3 – İnsan beyni ve fonksiyonları²⁹

Bölge	Fonksiyonu
1	<i>Prefrontal Korteks:</i> Zekâ, öğrenme, kişilik
2	<i>Motor Bölge:</i> Karmaşık hareketlerin eşgüdümü ve istemli hareketler
3	<i>Duyusal Bölge:</i> Dokunma duyusu bilgilerinin işlenmesi
4	Tat bölgesi
5	Görme bölgesi
6	<i>Beyincik:</i> Denge bölgesi
7	Genel yorumlama bölgesi
8	<i>Omurilik</i>
9	<i>Dil Bölgesi:</i> Dil anlayışından sorumlu Wernicke Bölgesi buradadır
10	İşitsel bölge
11	<i>Konuşma Merkezi:</i> Konuşmanın üretiminden sorumlu Broca Bölgesi buradadır.

Tablo 2 – Beynin bölgelere göre fonksiyonları

²⁹ Bilim ve Teknik Dergisi web sitesi, www.bilimteknik.com, Nisan 2006

Beynin bu fonksiyonları, beyin üzerine yapılan ayrıntılı tomografik taramalar ve başının bir bölgesinden hasar alan insanlardaki değişikliklerin gözlemlenmesi ile belirlenmiştir. Elbette beyin her santimetreküpünün ne gibi bir göreve sahip olduğunu ve birbirleri ile olan ilişkilerini tam olarak anlayabilmek henüz mümkün değildir.

İnsan beyni ortalama olarak 1,5 kg ağırlığındadır³⁰. Eğer bir insanın 60 yıl yaşadığını ve her saniye 600 bitlik **yeni** bilgi kayıt ettiğini düşünsek ki bu da saatte yaklaşık 265 Kbyte günde de yaklaşık 6,5 Mbyte eder, insan beyninin kapasitesi yine de dolmaz. Araştırmalara göre insan beyni ile aynı kapasiteye sahip bir bilgisayar yapılacak olsa 300 trilyon dolardan fazlaya mal olacaktır.³¹ Yine bu makinenin çalışabilmesi için 1 trilyon wattlık enerjiye ihtiyaç olacaktır ve hacmi de elbette kafatasından binlerce kat büyük olacaktır...

	Beyin	Bilgisayar
İşlem Gücü	Yavaş, basit fakat çok çok fazla işlemci	Hızlı, karışık fakat çok az işlemci
Hafıza	İşlemcilerle bütünleşik, içeriği adreslenebilir	İşlemciden ayrı, Rasgele Erişimli Hafıza türü (RAM)
Hesaplama	Paralel, dağınık ve her biri kendi başına çalışabilir	Sıralı (seri), merkezi hesaplama
Güvenilirlik	Güvenilir, eksik bilgiler onarılabilir, sağlam	Kolay bozulabilir, bozulan verileri kurtarmak zordur


Tablo 3 – Beyin ile bilgisayarın basitçe karşılaştırılması

³⁰ Bilim ve Teknik, Yeni Ufuklara – “Beynin Gizemi”, Eylül 2003

³¹ “The Hows, Whats and Whos of Neuroscience”, <http://faculty.washington.edu/chudler/what.html> , Nisan 2006

2.2.2 Biyolojik Sinir Hücresi

Yapay Sinir Ağları, beynin tamamını olmasa da sinir hücrelerini modelleyerek çalıştığı için önce bir biyolojik sinir hücresini tanımakta yarar vardır.



Şekil 4 – Bir kaç tane sinir hücresinden oluşan bir sinir ağı³²


Sinir sisteminin bir parçası olan ve ortalama 1,5 kg ağırlığındaki insan beyinde, tahminen 100 milyar kadar sinir hücresi ve 60×10^{12} (60 trilyon) synapse bulunmaktadır.³³ Bu rakamın ne kadar büyük olduğunu örnekleyecek olursak, kafatasımızın içindeki sinir hücrelerinin sayısı yaklaşık olarak Samanyolu’ndaki yıldız sayısı kadardır. Öğrenme, hatırlama, düşünme algılama gibi tüm bilişsel davranışları da içeren, her türlü insan davranışının temelinde nöron hücreleri bulunmaktadır.³⁴ Nöron sinir sisteminin temel işlem elemanıdır. Sinir hücresi; çekirdek (nucleus), dendritler, aksonlar (axon) ve sinapsler (synapse) olmak üzere 4 temel bileşenden meydana gelir. Dendritler, diğer hücrelerden aldığı bilgileri

³² http://www.colinfahey.com/2003apr20_neuron/2003apr20_neuron.htm adresinden, Mart 2006

³³ FREEMAN James, SKAPURA David: “*Neural Networks Algorithms, Applications, and Programming Techniques*”, Addison-Wesley Publishing Company, 1991

³⁴ KANDEL Eric R; “*Principles of Neural Science, Elsevier Science Publishing Co*”. 1991

hücresinin çekirdeğine iletir. Aksonlar ise elektriksel darbeler şeklindeki bilgiyi hücreden dışarı taşıyan organeldir. Aksonların bitimi, ince yollara ayrılabilir ve bu yollar, diğer hücreler için dendritleri oluşturur. Buradaki bağlantı elemanına da sinaps (synapse) denir.³⁵




Şekil 5 – Yaklaşık 4 mikron büyüklüğünde olan bir sinir hücresi³⁶

Sinir sistemindeki hücrelerin tamamı vücudun diğer sistemlerindeki hücrelerin aksine doğuştan mevcuttur ve yaşam süresince de yenilenmemektedir. Bu yüzden beyin hücreleri zarar görmüş insanlarda çeşitli fonksiyon bozuklukları görülebilmektedir. Yaşlılardaki “bunama” diye adlandırılan davranışlar ve unutkanlıklar, Alzheimer gibi hastalıklar beyin hücrelerinin zarar görmesinden ya da bir bölümünün ölmesinden kaynaklanmaktadır.

³⁵ FIRAT Mahmut, GÜNGÖR Mahmut:“Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi”, İMO Teknik Dergi, 2004, 3267-3282, Yazı 219

³⁶ http://www.colinfahey.com/2003apr20_neuron/2003apr20_neuron.htm adresinden, Mart 2006



Şekil 6 – Sinir hücresi ve organelleri³⁷

Organel	Görevi
Nucleus	Sinir hücresinin çekirdeğidir
Axon	Hücresinin diğer hücrelere kimyasal iletimde bulunduğu uçudur. Bir hücre sadece 1 adet axona sahip olmasına rağmen her axonun birden fazla ucu vardır. Boyları bir milimetreden küçük olabileceği gibi bir metreden de büyük olabilir. ³⁸
Dendrit	Hücresinin alıcısıdır. Kimyasal olarak algılama işlemi yapar. Bir sinir hücresi birden fazla dendrite sahiptir ve her dendritin de birden fazla ucu vardır.
Synapse	İki sinir hücresinin daha doğrusu birisinin axonu ile diğerinin dendritini birbirine bağlayan bağlantı elemanıdır.

Tablo 4 – Sinir hücresini oluşturan organeller ve görevleri³⁹

³⁷ <http://www.medicine.mcgill.ca/physio/cooperlab/cooper.htm> adresinden, Nisan 2006.


³⁸ NABİYEYEV Vasif V.; “Yapay Zeka – Problemler, Yöntemler, Algoritmalar”, Seçkin Yayınevi, Birinci Basım, Ekim 2003

³⁹ PETRIU Emil M., “Neural Networks: ”Basic”, University of Ottawa School of Information Technology, Ekim 2004

Sinir hücreleri arasındaki iletişim sinapslar yardımıyla elektro-kimyasal olarak gerçekleştirilir. Alıcı durumunda bulunan sinir hücresindeki kimyasal faaliyet, bazı iyonların daha kolay geçmesini sağlayacak şekilde zarın geçirgenliğini değiştirir. Uyarıcı durumda, hücre zarının geçirgenliğinin değişmesi sonucunda hücre içersine daha kolay akan pozitif iyonlar, sinir hücresinin depolarize olmasını sağlayıp, bu hücrede de sinirsel bir akımın başlamasına yol açar. Engelleyici durumda ise, negatif iyonlar sinir hücresini daha da polarize ederek sinirsel akımın durmasını sağlarlar.⁴⁰

2.2.3 Yapay Sinir Hücresi

Gerçek bir sinir hücresinin birimlerine eşdeğer bileşenlerle modellenen yapay sinir hücresi aşağıdaki şekilde gösterilmiştir. Gövdenin giriş birimi olan bağlantıların her birinin kendine ait bir ağırlık çarpanı vardır. Ağırlık değeri pozitif veya negatif olabilir. Uygulanan sinyallerin ağırlık değeriyle çarpımları, iki kısımdan oluşan gövdenin ilk kısmında toplanır. Bu toplam, ikinci kısmı tanımlayan aktivasyon fonksiyonunun argümanı olur.



Şekil 7 – Matematiksel modelleme ile elde edilen bir Yapay Sinir Hücresi

⁴⁰ AKPINAR Haldun; “Yapay Sinir Ağları ve Kredi Taleplerinin Değerlendirilmesinde Bir Uygulama Önerisi”, Mayıs 1993

2.2.3.1 Girdiler ($X_1, X_2, \dots, X_n$)

Yapay sinir hücresine dış dünyadan verilerin girildiği noktalar. Bazı durumlarda ağından kendisinden gelen geri besleme bilgileri de buralara uygulanır.

2.2.3.2 Ağırlıklar ($W_1, \dots, W_n$)

Yapay sinir hücresine giren her bir verinin hücre içinde hangi oranda hangi ağırlıkta değerlendirileceğini belirleyen değerlerdir. Ağırlıkların sayısal değerinin negatif ya da pozitif olması ağına etkisinin negatif ya da pozitif yönde olduğunu işaret eder⁴¹. Bir hücrenin ağırlığı sabit olabileceği gibi değişken de olabilir. Eğitim sırasında hücrenin ve / veya tüm ağı ağırlıkları yeniden belirlenir.

2.2.3.3 Toplama Fonksiyonu (Toplayıcı)

Hücreye giren verilerin ağırlıklarının uygulanmasından sonra toplanması işlemini gerçekleştirir. Toplam fonksiyonu ($\sum$) en çok kullanılan fonksiyondur. Her girdi değeri kendine ait olan ağırlık ile çarpıldıktan sonra toplanarak ağına uygulanan net girdi elde edilmiş olur.

Net Giriş	Açıklama
Toplam $\text{Net Girdi} = \sum_i^n X_i W_i \quad (3.1)$	Girdiler kendilerine ait ağırlıklar ile çarpılıp daha sonra hepsi toplanır.
Çarpım $\text{Net Girdi} = \prod_i X_i W_i \quad (3.2)$	Girdiler kendilerine ait ağırlıklar ile çarpılıp daha sonra da birbirleri ile çarpılır.
Maksimum $\text{Net Girdi} = \text{Max}(X_i W_i), i = 1 \dots j \quad (3.3)$	Tüm girdiler kendilerine ait ağırlıklar ile çarpıldıktan sonra aralarından en büyük değer alınır.
Minimum $\text{Net Girdi} = \text{Min}(X_i W_i), i = 1 \dots j \quad (3.4)$	Tüm girdiler kendilerine ait ağırlıklar ile çarpıldıktan sonra aralarından en küçük değer alınır.

⁴¹ ÖZTEMEL Ercan: “Yapay Sinir Ağları”, Papatya Yayıncılık, Ağustos 2003


Çoğunluk $\text{Net Girdi} = \sum_i \text{sgn}(X_i W_i) \quad (3.5)$	Tüm girdiler kendilerine ait ağırlıklar ile çarpıldıktan sonra pozitif ve negatif olanların sayısı bulunur. Hangisi daha çok ise hücrenin net girdisi o kabul edilir.
Kümülatif Toplam $\text{Net Girdi} = \text{Net}(\text{eski}) + \sum_i X_i W_i \quad (3.6)$	Hücreye uygulanan tüm girdiler toplanır ve daha önceki toplama eklenir.

Tablo 5 – Toplayıcı fonksiyonları⁴²

2.2.3.4 Aktivasyon Fonksiyonu

Matematiksel olarak modellenmiş bir yapay sinir hücresinin çıktısının büyüklüğünü sınırlandıran fonksiyondur⁴³. Sıkıştırma, transfer, işlemci veya eşik fonksiyonu olarak da isimlendirilebilir. Bir ağdaki tüm hücrelerin aktivasyon fonksiyonu birbirinden farklı olabilir. En çok kullanılan aktivasyon fonksiyonları aşağıda gösterilmiştir.⁴⁴

a. Lineer Fonksiyon: Hücreye gelen veriler bir α katsayısı ile çarpılarak sonuç üretilir. $\alpha=1$ ise girdiler olduğu gibi çıkar.



Şekil 8 – Lineer aktivasyon fonksiyonu


b. Step Fonksiyonu: Gelen veri belirlenen bir eşik değerinin üstünde ya da altında olmasına göre 1 ya da 0 değerlerini alır.

⁴² ÖZTEMEL Ercan; “Yapay Sinir Ağları”, Papatya Yayıncılık, Ağustos 2003

⁴³ MANDIC Danilo P. ,CHAMBERS Jonathon A.: “Recurrent Neural Networks For Prediction - Learning Algorithms,Architectures And Stability”, John Wiley & Sons Ltd, 2001


⁴⁴ DEMUTH Howard, BEALE Mark: “Neural Network Toolbox For Use with MATLAB”,Eylül 2000

$$f(net) = \begin{cases} 0 & \text{if } net \leq 0 \\ 1 & \text{if } net > 0 \end{cases}$$



Şekil 9 – Step aktivasyon fonksiyonu


c. **Eşik Değer Fonksiyonu:** Gelen verilerin belirlenen değerler arasında veya değerden **büyük** ya da küçük olmasına göre değer alırlar. Belirlenen değerler arasında ise gelen değerin kendisi çıktı olur.



Şekil 10 – Eşik değer aktivasyon fonksiyonu

d. **Hiperbolik Tanjant Fonksiyonu:** Çıktı değeri hücreye gelen verilerin tanjant fonksiyonuna tabi tutulmasıyla hesaplanır.⁴⁵

$$f(net) = \frac{e^{net} - e^{-net}}{e^{net} + e^{-net}} \quad (3.7)$$




Şekil 11 – Hiperbolik tanjant aktivasyon fonksiyonu

⁴⁵ ŞEN Zekai: “Yapay Sinir Ağları İlkeleri”, Su Vakfı İstanbul, 2004

e. **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.⁴⁶


$$f(net) = \frac{1}{1 + e^{-net}} \quad (3.8)$$



Şekil 12 – Sigmoid aktivasyon fonksiyonu

f. **Gauss Fonksiyonu:**

$$f(net) = \exp\left(-\frac{net^2}{\sigma^2}\right) \quad (3.9)$$



Şekil 13 – Gauss aktivasyon fonksiyonu


⁴⁶ FIRAT Mahmut, GÜNGÖR Mahmut:“Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi”, İMO Teknik Dergi, 2004, 3267-3282, Yazı 219

İsim	Formül	MATLAB'deki gösterim şekli	MATLAB'deki komut
Hard limit	$a = 0 \quad n < 0$ $a = 1 \quad n \geq 0$		hardlim
Symmetrical Hard Limit	$a = -1 \quad n < 0$ $a = +1 \quad n \geq 0$		hardlims
Linear	$a = n$		purelin
Saturating Linear	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n \leq 1$ $a = 1 \quad n > 1$		satlin
Symmetrical Saturating Linear	$a = -1 \quad n < -1$ $a = n \quad -1 \leq n \leq 1$ $a = 1 \quad n > 1$		satlins
Log-Sigmoid	$a = \frac{1}{1 + e^{-n}}$		logsig
Hyperbolic Tangent Sigmod	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$		tansig
Positive Linear	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n$		poslin
Competitive	$a = 1 \quad \text{neuron with max } n$ $a = 0 \quad \text{all other neurons}$		compet
Radial Basis	$\exp(-n^2)$		radbas
Triangular	$a = 1 - \text{abs}(n), \text{ if } -1 \leq n \leq 1$ $a = 0, \text{ otherwise}$		tribas

Tablo 6 – MATLAB’de kullanılan aktivasyon fonksiyonları ve komutları⁴⁷

⁴⁷ MATLAB, www.mathworks.com, Nisan 2006

2.2.3.5 Yapay Sinir Hücresinin Çalışmasına Bir Örnek



Şekil 14 – Yapay sinir hücresi

Örneğimizde

$X_1 = 0.9$, $X_2 = 1.4$, $X_3 = 2.6$ ve $w_1 = 0.2$, $w_2 = 0.4$, $w_3 = 0.6$ olsun.

Bu durumda sigmoid olarak belirlemiş olduğumuz aktivasyon fonksiyonuna girecek değer:

$\Sigma = 0.9 \times 0.2 + 1.4 \times 0.4 + 2.6 \times 0.6 = 2.3$ olacaktır. Hücremizin ürettiği sonuç olan y ise:

$$y = f(2.3) = \frac{1}{1 + e^{-2.3}} \cong 0.90 \text{ olur.}$$

2.3 YAPAY SİNİR AĞLARI (YSA)

2.3.1 YSA'nın Gelişimi⁴⁸

1943 yılı Yapay Sinir Ağları (YSA) için ilk çalışmaların başladığı yıldır. McCulloch ve Pitts ilk olarak bir yapay sinir hücresi modeli geliştirdiler. Yaptıkları çalışmada sinir hücrelerini sabit eşik değerli mantıksal elemanlar olarak modellediler.

1949 yılında Hebb, bugün hala geçerli olan öğrenme kurallarından birçoğunu da teşkil eden kendi ismiyle de anılan bir öğrenme modelini geliştirmiştir.⁴⁹

1950'li yıllarda çalışmalar hız kazandı ve 1951 yılında ilk yapay sinir ağı temelli bilgisayar olan SNARC, MIT'de Minsky ve Edmons tarafından üretildi⁵⁰. Daha sonra silikon teknolojisinin keşfi ile özellikle bilgisayarların boyutları ve çalışma hızları konusunda önemli gelişmeler kaydedildi. 1958 yılında Rosenblatt tekli doğrusal algılayıcı yani perseptron (Perceptron) modelini geliştirdi.⁵¹ Bu model YSA çalışmalarında devrim niteliğindeydi. Çünkü bu model ile daha sonra geliştirilecek olan çok katmanlı algılayıcıların temeli atılmış oldu. Fakat tekli doğrusal algılayıcı modeli sadece doğrusal olan çok boyutlu düzlem ile ayrılabilen sorunları çözümleyebilmektedir.

Widrow ve Hoff 1960 yılında ADALINE⁵² (ADaptive LInear NEuron) modelini dünyaya tanıttılar. Bu modelin en büyük özelliği LMS (Least Mean Squares – En küçük kareler ortalaması) ile eğitim boyunca hatayı en aza indirmeye çalışmasıdır.

⁴⁸ FAUSETT Laurene: “*Fundamentals of Neural Networks - Architectures, Algorithms, and Applications*”, Prentice Hall, Şubat 1994

⁴⁹ ŞEN Zekai: “*Yapay Sinir Ağları İlkeleri*”, Su Vakfı İstanbul, 2004

⁵⁰ http://tr.wikipedia.org/wiki/Yapay_zeka, Nisan 2006

⁵¹ ŞEN Zekai: “*Yapay Sinir Ağları İlkeleri*”, Su Vakfı İstanbul, 2004

⁵² FREEMAN James, SKAPURA David: “*Neural Networks Algorithms, Applications, and Programming Techniques*”, Addison-Wesley Publishing Company, 1991

60'lı yılların sonunda matematikçi Minsky ve Papert algılayıcıların (perceptron) karmaşık mantıksal işlemler için kullanılamayacağını ispatladılar. Yayınladıkları bir kitap ile meşhur XOR probleminin algılayıcı ile çözülemeyeceğini matematiksel olarak kanıtladılar⁵³. Bu örnekten sonra YSA üzerine yapılan çalışmalar duraklama dönemine girdi. Hatta birçok araştırmacının YSA'ya olan güveni sarsıldı, araştırmalar ve yatırımlar kesildi. Bu durum 80'li yılların başına kadar devam etti.

XOR probleminin tekli doğrusal algılayıcılar ile çözülemeyeceğinin matematiksel olarak ispatlanmasından dolayı durma noktasına gelen YSA çalışmaları birkaç araştırmacının ısrarlı çalışmaları sayesinde 1982 yılından sonra yeniden canlanmıştır. 1982 yılında bir fizikçi olan Hopfield YSA'nın genelleştirilebileceğini ve özellikle geleneksel bilgisayar programlama ile çözülmesi zor olan problemlere bile çözüm üretilebileceğini gösterdi.⁵⁴ Gezgini satıcı problemini çözmesi bunun en güzel örneği olu. Çalışmasını mühendislerin kolaylıkla anlayabileceği şekilde sunduğundan YSA'ya ilgi yeniden kurulmaya başlandı. Çalışmaların neticesi Hinton ve arkadaşlarının geliştirdikleri Boltzman makinesinin doğmasına yol açıyordu.⁵⁵ Tekli doğrusal algılayıcılar ile çözülemeyen XOR problemi çok katmanlı algılayıcılar ile çözülmüş ve YSA'nın işe yaramadığını söyleyen bütün tezler çürütülmüş oldu.

1982–1984 yıllarında Kohonen kendi adıyla anılan eğitimcisiiz öğrenebilen (Self Organizing Map) ağırları geliştirdi.⁵⁶

1986 yılında Rumelhart Geriye Yayılım Algoritmasını (Back Propagation) geliştirdi.⁵⁷ Halen en çok kullanılan ağı eğitime yöntemlerinden birisi olan bu

⁵³ ÖZTEMEL Ercan: “Yapay Sinir Ağları”, Papatya Yayıncılık, Ağustos 2003

⁵⁴ “Neural Networks and Physical Systems with Emergent Collective Computational Abilities – YSA ve Gelişen Kolektif Hesapsal Yetenekli Fiziksel Sistemler” isimli kitabında.

⁵⁵ ÖZTEMEL Ercan, “Yapay Sinir Ağları” , Syf. 40

⁵⁶ YOUSEFIZADEH Hooman, ZILOUCHIAN Ali: “Neural Network Architecturer”, CRC Press LLC, Chapter 3, 2001

⁵⁷ TEBELKIS Joe: “Speech Recognition using Neural Networks”, School of Computer Science Carnegie Mellon University, Pennsylvania, Doctor of Philosophy Thesis, Mayıs 1995

algoritma çok karmaşık matematiksel esaslara dayanmaktadır. Genellikle öngöründe bulunmaya çalışan YSA’da geriye yayılım algoritması kullanılmaktadır. (Bu çalışmamızda da geriye yayılım algoritmasını kullanarak ağıımızı eğiteceğiz.) Geriye yayılım algoritmasıyla eğitilecek ağı ileri beslemeli ve çok katmanlı olması gerekir.

Yapay sinir ağlarına ilginin yeniden artmasıyla birlikte bu konuda birçok araştırmalar yapılmaya başlanmıştır. Günümüzde onlarca değişik YSA modeli ve eğitme algoritması geliştirilmiş durumdadır. YSA kullanılarak gerçekleştirilen her konudaki çözümlere dair yayınlar çığ gibi büyümektedir.

XOR Problemi⁵⁸

XOR probleminin tekli doğrusal algılayıcılar ile çözülemeyeceğinin ispatlanmasından sonra YSA çalışmaları durma noktasına gelmiştir. Önemini yitirmesine rağmen YSA üzerine çalışmalarına ısrarla devam eden birkaç kişinin sayesinde XOR problemi çok katmanlı yani gizli katmanlar da kullanan YSA ile çözülebilmektedir. Bunda sonra da YSA üzerine yapılan çalışmalar yeniden hızlanmış ve bir çığ gibi büyümüştür. Bu nedenle XOR problemi YSA için önemli bir kilometre taşıdır.







Giriş 1	Giriş 2	Çıkış
0	0	0
0	1	1
1	0	1
1	1	0

Tablo 7 – XOR fonksiyonu

Tek katmanlı doğrusal algılayıcılar gizli nöron içermediğinden sadece çıktı katmanına sahiptir. Bu sebeple doğrusal olarak ayrıştırılamayan girdilere göre sınıflandırma yapamaz. Touretzky ve Pomerlau 1989’da XOR probleminin

⁵⁸ ZHOU Yong-Quan, HE Deng-Xu, NONG Zheng: “*Application of Functional Network to Solving Classification Problems*”, Transactions on Engineering, Computing and Technology, Ağustos 2005

YSA’larda gizli nöronlar kullanılarak yani çok katmanlı ağlar yardımıyla aşılabildiğini göstermişlerdir. Bu şekilde YSA ile doğrusal olmayan yapılar da sınıflandırılabilir. ⁵⁹

Yapı	XOR (Exclusive –OR)
Tek Katmanlı 	
Çift Katmanlı 	
Üç Katmanlı 	


Tablo 8 – XOR probleminin YSA ile çözümünün grafiksel gösterimi ⁶⁰

⁵⁹ YURTOĞLU Hasan, “YSA Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği”, Şubat 2005

⁶⁰ Anil K.Jain, Jianchang Mao, “Artificial Neural Networks: A Tutorial”, Theme Feature, March 1996, Syf.31


2.3.2 Yapay Sinir Ağlarının Yapısı

Yapay sinir ağları, aynen milyarlarca biyolojik sinir hücresinin birleşerek beyni oluşturduğu gibi, birden fazla yapay sinir hücresinin birleşiminden oluşur. Sinir hücreleri genellikle birkaç katman halinde dizilerek bir yapay sinir ağını meydana getirirler. Başka bir anlatımla, genellikle bir yapay sinir ağı birden fazla katmandan ve birden fazla yapay sinir hücresinden meydana gelir. İlk katman genellikle **giriş katmanı**dır. **Çıkış katmanı** ise son katmandır. Aradaki diğer katmanlar ise **gizli katman** ya da **ara katman** olarak adlandırılırlar. Bir ağda birden fazla gizli katman olabilir.



Şekil 15 – Yapay bir sinir ağına genel bir örnek⁶¹

⁶¹ FREEMAN James, SKAPURA David: “*Neural Networks Algorithms, Applications, and Programming Techniques*”, Addison-Wesley Publishing Company, 1991



Şekil 16 – MATLAB’de yapay sinir ağının gösterimi

Yapay Sinir Ağları verilen girdilere göre çıktılar üreten akıllı bir kara kutu modeli olarak da nitelendirilebilir⁶². Yapay sinir ağları sahip olduğu özelliklerden dolayı alışlagelmiş bilgi işleme yöntemlerinden farklılık göstermektedir. Bu özelliklerden bazıları paralellik, hata toleransı, öğrenilebilirlik ve gerçekleştirme kolaylığı olarak tanımlanabilir. Bu özellikleri itibari ile de diğer alışlagelmiş hesaplama yöntemlerine göre daha başarılı sonuçlar üretebilir⁶³.

Yapay sinir ağlarında bilgilerin işlenmesi paralel olarak gerçekleştirildiği için taşınan bilgiler birbirinden bağımsızdır. Ayrıca aynı tabakadaki bağlantılar arasında zaman bağımlılığı olmadığından tamamı ile eşzamanlı çalışabilmekte dolayısıyla da bilgi akış hızı artmaktadır. Paralel çalışma prensibinden dolayı herhangi bir birimde meydana gelen hata tüm sistemde belirgin bir hataya neden olmamaktadır. Sadece hücrenin ağırlıkları oranında bir etkilenme gerçekleşmektedir. Böylece genel sistem yerel hatalardan en az bir şekilde etkilenmektedir.

Yapay sinir ağlarında öğrenme ise bağlantı ağırlıklarının yenilenmesi şeklinde gerçekleşmektedir.⁶⁴ Öğrenme sonucu elde edilen bilgiler bağlantı ağırlıklarında saklanır. Bu sayede elde edilen bilginin uzun süre saklanması mümkündür. Ayrıca

⁶² TENTI Paolo, “Forecasting Foreign Exchange Rates Using Recurrent Neural Networks”, Applied Artificial Intelligence, 10:567-581, 1996

⁶³ TERZİ Özlem, KESKİN M.Erol:“Yapay Sinir Ağı Yaklaşımı Kullanarak Günlük Tava Buharlaşması Tahmini”, İMO Teknik Dergi, 2005 3683 – 3693, Yazı 243

⁶⁴ ÖZTEMEL Ercan: “Yapay Sinir Ağları”, Papatya Yayıncılık, Ağustos 2003

öğrenme yeteneği sayesinde tam tanımlı olmayan problemlerin yapay sinir ağlarıyla çözülebilmesi de mümkündür. Paralel çalışan bir yapay sinir ağı modeli karışık fonksiyonlarla yapılan işlemler yerine basit işlemler içerdiğinden ve karmaşık olmayan bir mimari yapıya sahip olduğundan birçok sorunun çözümlenmesinde tercih sebebidir.

Bir yapay sinir ağı için eldeki verilerin türüne ve istenilen hedefe karar verdikten sonra beklenen çıktıları girdilerden elde etmek için bu şebekede bilinmeyen bağlantı değerleri ardışık yaklaşımlarla eğitilerek tespit edilir. İlk hesaplamalarda elde edilen çıktılar beklenen çıktılar ile kıyaslandıktan sonra birbirlerine kabul edilebilir hata sınırları içinde bir yaklaşıklık gösterdiği zaman ağın eğitilmesine son verilir. Aksi takdirde eğitime devam edilir. Böylece eğitim ve öğretme ile güdümlenebilen bir şebeke akışı söz konusudur.


Şebeke bağlantı ağırlıkları sabit katkısı çıktı verileri (beklenen değerler) ile ağın çıktıları arasındaki hata miktarlarına göre geri besleme yolu ile eğitilerek değiştirilir. Her eğitim bir öncekini daha da iyileştirecek biçimde ardışık yenileme ve yinelemeli olarak yapılır. Bu tür ardışık iyileştirme işlemine bazen 'anlık' veya 'yenilenen' eğitim adı verilir. Bugün klasik bilgisayarlar insanların çözebileceğinden daha da karmaşık olan modellemeler yapay sinir ağları ile yapılabilmektedir.

Genellikle öğretmenli eğitim yöntemleri kullanılmasının yanında bazı yapay sinir ağları şebekelerinin eğitiminde öğretmensiz eğitim teknikleri veya doğrudan tasarım yöntemleri kullanılır. Mesela, öğretmensiz eğitim yaklaşımları verilerin gruplara ayrılması için kullanılır. Bazı doğrusal ağlar, özellikle de Hopfield tarafından geliştirilen yapay sinir ağları, öğretmensiz olarak eğitilebilirler.⁶⁵

⁶⁵ TEBELKIS Joe: “*Speech Recognition using Neural Networks*”, School of Computer Science Carnegie Mellon University, Pennsylvania, Doctor of Philosophy Thesis, Mayıs 1995

2.3.2.1 Tek Katmanlı – İleri Beslemeli Yapay Sinir Ağları (Feed Forward)

Tek katmanlı ileri beslemeli yapay sinir ağı en basit ağı yapısıdır. Bir giriş katmanı ve bir çıkış katmanı vardır. Bu tip bir ağda bilgi girişten çıkışa doğru ilerler yani ağı ileri beslemelidir. Tek katmanlı olarak isimlendirilmesinin sebebi, giriş katmanının veri üzerinde hiçbir işlem yapmadan veriyi çıkış katmanına iletmesidir.




Şekil 17 – Tek katmanlı bir YSA⁶⁶

2.3.2.2 Çok Katmanlı – İleri Beslemeli Yapay Sinir Ağları

Bu tip yapay sinir ağları bir veya daha fazla gizli katman içerir. Gizli katmanların amacı giriş ve çıkış katmanları arasında gerekli bir takım işlemler yapmaktır. Giriş katmanı geniş olduğu zaman gizli katmanlar sayesinde yüksek dereceli istatistiksel veri elde edilebilir. Çok katmanlı yapılarda (n) . katmanın çıkış sinyalleri $(n+1)$. katmanın giriş sinyalleri olarak kullanılır. m adet giriş düğümü, ilk gizli katmanında h_1 adet nöron, ikinci gizli katmanında h_2 adet nöron ve çıkış katmanında q adet nöron bulunan bir çok katmanlı ileri besleme ağı $m-h_1-h_2-q$ ağı

⁶⁶ DEMUTH Howard, BEALE Mark: “Neural Network Toolbox For Use with MATLAB”, Eylül 2000

olarak adlandırılır. Eğer her katmanda bulunan nöronlar bir sonraki katmanın tüm nöronlarına bağlı ise bu tip ağa tam bağlantılı ağ denir. Eğer bu sinaptik bağlantılardan bazıları eksikse ağ, kısmi bağlantılı ağ adını alır.




Şekil 18 – Çok katmanlı bir YSA⁶⁷

2.3.2.3 Radyal Tabanlı Yapay Sinir Ağları (Radial Basis)⁶⁸

Radyal tabanlı yapay sinir ağları, duyarlı almaç bölgelerinin olduğu giriş tabakası, radyal tabanlı nöronları içeren gizli tabaka ve çoğunlukla doğrusal aktivasyon fonksiyonlu nöronlardan ibaret çıkış tabakasından oluşur. Radyal tabanlı ağlar, geri yayılım algoritmali ileri beslemeli ağlardan daha fazla nöron kullanımına ihtiyaç duyabilirse de eğitim süresi çok daha kısadır. Yoğun eğitim verisiyle daha iyi sonuçlar verir.

⁶⁷ DEMUTH Howard, BEALE Mark: “Neural Network Toolbox For Use with MATLAB”, Eylül 2000

⁶⁸ SARLE Warren S.: “Neural Networks and Statistical Models”, Proceedings of the Nineteenth Annual SAS Users Group International Conference”, N.C. USA, Nisan 1994



Şekil 19 – Radyal tabanlı bir YSA⁶⁹

2.3.2.4 Geri Dönümlü Yapay Sinir Ağları (Recurrent)

Geri dönüşlü yapay sinir ağlarının ileri beslemeli ağlardan farkı en az bir adet geri besleme çevriminin olmasıdır. Geri dönüşlü yapay sinir ağlarından en basiti ve kullanımı en kolay olanı **Elman** ağıdır⁷⁰. **Hopfield**, **Counterpropagation**, **Cognitron**, **Kendini Ayarlayan Haritalı Ağlar**(**SOM - Self Organizing Maps**), **Boltzman Makinesi** gibi birkaç tane daha geri dönüşü YSA modeli daha vardır.⁷¹ Bu modellerin çoğu birbirlerine benzemekte ya da birkaç tanesinin aynı anda kullanılması ile meydana gelmektedir.



Geri dönüşlü YSA'lar özellikle birinci dereceden doğrusal sistemleri modellemekte oldukça başarılıdırlar. Zamana bağlı olayları işlemede, daha önce elde edilen sonuçları değerlendirmedeki başarılı çıktıları ile özellikle ses ve karakter tanıma problemlerinde etkin olarak kullanılmaktadır.⁷²

⁶⁹ DEMUTH Howard, BEALE Mark: “*Neural Network Toolbox For Use with MATLAB*”, Eylül 2000

⁷⁰ LAWRENCE Steve, GILES C. Lee, FONG Sandiway: “*Natural Language Grammatical Inference with Recurrent Neural Networks*”, IEEE Transactions on Knowledge and Data Engineering, Volume 12, Number 1, Syf. 126–140, 2000

⁷¹ ÖZTEMEL Ercan: “*Yapay Sinir Ağları*”, Papatya Yayıncılık, Ağustos 2003

⁷² DEMUTH Howard, BEALE Mark: “*Neural Network Toolbox For Use with MATLAB*”, Eylül 2000

Şekil 20 – Elman Yapay Sinir Ağı⁷³Şekil 21 – Hopfield Yapay Sinir Ağı⁷⁴

⁷³ DEMUTH Howard, BEALE Mark: “Neural Network Toolbox For Use with MATLAB”, Chapter 9, Eylül 2000

⁷⁴ DEMUTH Howard, BEALE Mark: “Neural Network Toolbox For Use with MATLAB”, Chapter 9, Eylül 2000

AĞIN TÜRÜ	ÖĞRENME YÖNTEMİ	KULLANIM ALANLARI
Öngörü	• Geriye Yayılım • Delta –Bar-Delta • Geniştirilmiş Delta – Bar-Delta • Yönlendirilmiş Rasgele Arama • Yüksek Dereceli Sinir Ağları	Önceki verilere dayanarak gelecekteki değerlerin tahmin edilmesi. (Ekonomik göstergeler, hava tahmini, vb)
Sınıflandırma	• Savaşlı Yayılma • Olasılıklı Sinir Ağları • Vektör Kuantalama Öğrenmesi	Girdilerin sınıflandırılması
Verilerin İlişkilendirilmesi	• Hopfield • Boltzman makinesi • Çok Yönlü Çağrışımsal Bellek • Hamming Ağı • Şekil Tanıma	Eksik verilerle dahi sınıflandırma yapmada. (OCR, Optical Character Recognition gibi)
Verilerin Kavramsallaştırılması	• Uyumlu Rezonans Ağı • Öz Denetimli Harita	Verilerin analiz edilmesi ve bir gruba ilişkin olanların belirlenmesi
Filtreleme	• Yeniden Döngüselleştirmeli Ağ	Giriş verilerinin düzgünleştirilmesinde
Optimizasyon	• Hopfield	Optimizasyon çözümlerinde.

Tablo 9 – YSA türleri ve uygulama alanları⁷⁵

⁷⁵ ? : Kaynağın ve yazarın adına ulaşılammıştır.

2.3.3 Yapay Sinir Ağlarında Öğrenme Kuralları

Yapay sinir ağlarının mimarisi kadar ağın eğitilmesinde yani ağın öğrenmesinde kullanılacak yöntem de çok önemlidir. Genel olarak ifade etmek gerekirse YSA'lar da bir bebeğin beyninin öğrenmesi gibi deneme yanılmayla, hata yapa yapa öğrenir.⁷⁶ Eğitim sırasındaki amaç bulunması gereken doğru sonuçlara en yakın çıktıyı üretebilmektir. Bu sebeple ağ verilen girdilere göre kendi mimarisine de uygun olarak işlem yaptıktan sonra bir çıktı üretir. Çıktı ile hedef değerler arasındaki fark **hata**dır. Ağ bu hatayı kabul edilebilir sınırlara arasına indirebilmek için işlemi tekrarlar. Eğitim setinin ağ içinde bir kez işleminden geçirilmesine **devir (epoch)** denir⁷⁷. Devir sayısının çok olması ağın öğrenme sürecinde önemli bir etkidir. Fakat devir sayısının yüksek seçilmesi de performansı düşüren bir etkidir. Bu durumda ağın mimarisi, aktivasyon fonksiyonu, öğrenme yöntemi ve devir sayısı seçilirken optimizasyonun iyi bir şekilde yapılması gerekir.

En bilinen ve en yaygın olarak kullanılan öğrenme kuralları şunlardır:

2.3.3.1 Hebb Kuralı (1949)

Diğer öğrenme kurallarının da temelini oluşturan bu kurala göre, bir sinir hücresi diğer bir hücreden bilgi alırsa ve eğer her ikisi de matematiksel olarak aynı işareti taşıyorsa yani aktif ise bu iki hücre arasındaki bağlantı kuvvetlendirilmelidir. Tersisi durumda ise zayıflatılmalıdır⁷⁸.

⁷⁶ KELEŞOĞLU Ömer, Ekinci Cevdet Emin, FIRAT Adem, “The Using Artificial Neural Networks in Insulation Computations”, Journal of Engineering and Natural Sciences, Mart 2005

⁷⁷ http://www.geniussys.com/ysa_files/filelist.xml , Ocak 2005

⁷⁸ DAZSI Brian Adam, ENBODY:“Artificial Neural Networks For Branch Prediction”, Master Science Thesis, Department of Electrical and Computer Engineering - Michigan State University”, 2001

2.3.3.2 Hopfield Kuralı (1982)

Bu kural Hebb kuralına benzemektedir. Diğerinden farklı olarak YSA elemanlarının bağlantılarının ne kadar kuvvetlendirilmesi ya da zayıflatılması gerektiğini de belirler. Eğer beklenen çıktılar ve girdilerin her ikisi de aktif/pasif ise öğrenme katsayısı kadar ağırlık değerlerini de kuvvetlendirir/zayıflatır. Ağırlıkların kuvvetlendirilmesi ya da zayıflatılması öğrenme katsayısı yardımıyla gerçekleştirilir. Bu katsayı genellikle 0 ile 1 arasında kullanıcı tarafından belirlenen sabit bir pozitif değerdir.⁷⁹

2.3.3.3 Delta Kuralı

Bu kurala göre hedef çıktı ile elde edilen çıktı arasındaki farkı azaltmak için YSA elemanlarının bağlantılarının ağırlık değerleri sürekli yeniden hesaplanır. Amaç hedef çıktı ile elde edilen çıktı arasındaki hata karelerinin ortalamasını en aza indirebilmektir. Hatalar en son katmandan geriye doğru ardışık iki katman arasındaki bağlantı ağırlıklarına dağıtılır. Bu işleme hatanın geriye dağıtılması anlamında geri besleme işlemi denir. İleride daha ayrıntılı bahsedilecek olan geriye yayılım algoritması bu kurala göre çalışmaktadır.⁸⁰

2.3.3.4 Kohonen Kuralı (1998)

Bu kural biyolojik sinir hücrelerinin öğrenme kurallarından esinlenerek oluşturulmuştur⁸¹. Bu kuralda sinir hücreleri ağırlıkları değiştirmek için birbirleri ile yarışır. En büyük çıktıyı üreten hücre kazanan hücre olur ve bağlantı ağırlıklarını değiştirir. Kazan hücre yakınındaki hücrelere göre daha kuvvetli hale gelmektedir.

⁷⁹ TEBELKIS Joe: “*Speech Recognition using Neural Networks*”, School of Computer Science Carnegie Mellon University, Pennsylvania, Doctor of Philosophy Thesis, Mayıs 1995

⁸⁰ ÇORUMLUĞLU Ö., ÖZBAY Y., vd.: “*GPS Yüksekliklerinden Ortometrik Yüksekliklerin Elde Edilmesinde Yapay Sinir Ağı (YSA) Tekniğinin Kullanımı*”, Har. ve Kad. Müh.Odası, Mühendislik Ölçmeleri STB Komisyonu 2. Mühendislik Ölçmeleri Sempozyumu, Kasım 2005, İTÜ

⁸¹ ŞEN Zekai: “*Yapay Sinir Ağları İlkeleri*”, Su Vakfı İstanbul, 2004

Bu kuralda bir hedef değerler dizisi olmasına gerek yoktur. Bu nedenle kendi kendine yani öğretmensiz olarak eğitimini tamamlar.⁸²

2.3.4 Yapay Sinir Ağlarında Öğrenme Stratejileri⁸³

2.3.4.1 Öğretmenli Eğitim⁸⁴

Öğretmenli eğitimde, verilen giriş değerlerine karşılık gelen hedef çıktı değerleri vardır. Ağın görevi verilen değerlere göre hedef çıktıyı üretebilmektir. Ağın çıktıları sanki bir öğretmen varmışçasına hedef değerlerle kıyaslanır ve kabul edilebilir değerler arasında olup olmadığına göre eğitime devam edilir. Hedef değerler ile elde edilen değerler arasındaki farkın yani hatanın karelerinin ortalaması en küçük olacak şekilde ağırlıklar sürekli olarak güncellenir ve işlemlere devam edilir.

Bu yöntemde ağa hedef çıktılar ile elde edilen verilerin arasındaki farkın verilebileceği gibi ağa sadece sonucun doğru mu yoksa yanlış mı olduğu da söylenebilir. İkinci yöntem destekleyicili öğrenme olarak da adlandırılır.

Delta Kuralı⁸⁵, Genelleştirilmiş Delta Kuralı⁸⁶, Rastsal öğrenme Kuralı, Takviyeli Öğrenme Kuralı öğretmenli eğitimin kurallarından bazılarıdır.

2.3.4.2 Öğretmensiz Eğitim

Bu tip eğitimde hedef çıktı değerleri yoktur. Ağ sadece giriş değerleri verilir. Örneklerdeki parametreler arasındaki ilişkileri ağın kendi kendine öğrenmesi

⁸² ÖZTEMEL Ercan, “Yapay Sinir Ağları”, Syf. 40

⁸³ “GÜNGÖR İbrahim, ÇUHADAR Murat: “Antalya İline Yönelik Alman Turist Talebinin Yapay Sinir Ağları Yöntemi ile Tahmini”, Ticaret ve Turizm Eğitim Fakültesi Dergisi Yıl:2005, Sayı:1

⁸⁴ ŞEN Zekai: “Yapay Sinir Ağları İlkeleri”, Su Vakfı İstanbul, 2004

⁸⁵ ÇORUMLUĞLU Ö., ÖZBAY Y., vd.: “GPS Yüksekliklerinden Ortometrik Yüksekliklerin Elde Edilmesinde Yapay Sinir Ağı (YSA) Tekniğinin Kullanımı”, Har. ve Kad. Müh.Odası, Mühendislik Ölçmeleri STB Komisyonu 2. Mühendislik Ölçmeleri Sempozyumu, Kasım 2005, İTÜ

⁸⁶ FREEMAN James, SKAPURA David: “Neural Networks Algorithms, Applications, and Programming Techniques”, Addison-Wesley Publishing Company, 1991

beklenir. Daha çok sınıflandırma problemlerinde kullanılan bir eğitim yöntemidir. Sınıflandırma işleminde hedef mümkün olduğunca farklı sayıda sınıflandırma yapabilmektir. Daha sonra kullanıcının elde edilen sınıfların ne anlama geldiğini kendisinin yapması gerekir.

Signal Hebbian Öğrenme Kuralı ve Diferansiyel Hebbian Öğrenme Kuralı öğretmensiz eğitim kurallarına örnek olarak verilebilir⁸⁷.

2.3.4.3 Karma Eğitim

Yukarıda bahsedilen yöntemlerin birkaçını birlikte kullanarak yapılan eğitim işlemidir. Yani ağ, kısmen öğretmenli kısmen de öğretmensiz olarak öğrenme işlemini gerçekleştirir. Radyal tabanlı YSA'lar ve olasılık tabanlı ağlar bunlara örnek verilebilir.

⁸⁷ ŞEN Zekai: “Yapay Sinir Ağları İlkeleri”, Su Vakfı İstanbul, 2004

Öğrenme Yöntemi	Öğrenme Kuralı	Ağın Mimarisi	Öğrenme Algoritması	Kullanıldığı Yerler
Öğretmenli	Hata Düzeltme	Tek ya da çok katmanlı	Perseptron Geriye Yayılım Adaline ve Madaline ⁸⁸	Örüntü tanıma Tahmin Kontrol
	Boltzmann	Geri Dönüştü	Boltzmann öğrenmesi	Örüntü sınıflandırma
	Hebbian	Çok katmanlı ileri beslemeli	Lineer diskriminant	Veri analizi Örüntü sınıflandırma
	Rekabetli	Rekabetli	Vektör kuantalama öğrenmesi	Veri sıkıştırma Sınıflandırma
		ART ağı	ART Haritalaması	Örüntü sınıflandırma Sınıflandırma
Öğretmensiz	Hata Düzeltme	Çok katmanlı ileri beslemeli	Sammon projeksiyonu	Veri analizi
	Hebbian	İleri beslemeli rekabetçi	Principal Component Analizi	Veri analizi Veri sıkıştırma
		Hopfield Ağı	Associative Memory Öğrenmesi	Associative Memory
	Rekabetli	Rekabetli	Vektör Kuantalaması	Sınıflandırma Veri sıkıştırma
		Kohonen SOM	Kohonen SOM	Sınıflandırma Veri analizi
		ART ağı	ART1, ART2	Sınıflandırma
Karma	Hata Düzeltme ve Rekabetli	Radyal Tabanlı	Radyal Tabanlı Öğrenme	Sınıflandırma Örüntü tanıma Fonksiyon yaklaşımı Tahmin Kontrol


Tablo 10 – Öğrenme algoritmaları ve kullanım alanları⁸⁹

⁸⁸ FREEMAN James, SKAPURA David: “*Neural Networks Algorithms, Applications, and Programming Techniques*”, Addison-Wesley Publishing Company, 1991

⁸⁹ JAIN Anil K, MAO Jianchang “*Artificial Neural Networks: A Tutorial*”, Theme Feature, March 1996, Syf.38

2.3.5 Bir YSA Modellemesinde Dikkat Edilecek Hususlar

Bir problemi yapay sinir ağı kullanarak çözmek istediğimizde aşağıdaki süreci uygulamamız gerekir.



Şekil 22 – YSA modellemesi akış şeması⁹⁰

⁹⁰ HAYKIN Simon; “*Neural Networks : A Comprehensive Foundation*”, 2nd ed. – Upper Saddle River, N.J., Prentice Hall, 1999

1. Ağın eğitiminde ve testinde kullanılacak olan veriler toplanır. Kaç değişkenin girdi ve kaçının çıktı olacağına karar verilmelidir. Böylece giriş ve çıkış katmanında kaçar hücre olacağı da belirlenmiş olur.
2. Toplanan veriler problemin türüne verilere de bağlı olarak eğitim ve test için ayrıştırılır. Belirli bir oran olmamasına rağmen veriler genellikle %70, %20 ve %10 luk paketlere ayrılır⁹¹. Eğer veri dizisinde sıra önemli değilse ayrıştırma rasgele yapılırsa yani örnekler veri setinin her yerinden alınırsa eğitim daha başarılı olur.
3. Problemin türüne göre ağı yapısına karar verilir.⁹²
4. Problemin türüne göre öğrenme yöntemi seçilir.⁹³
5. Ağa uygulanacak ilk değerler verilir.
6. Veriler ağı verilecek şekilde uyarlanır ve ağı giriş katmanına uygulanır.
7. Eğitime başlanır, hatayı en aza indirmek için ağırlıklar sürekli gözden geçirilir.
8. Hata kabul edilebilir sınırlar arasına girdiğinde eğitim durdurulur ve ağı test edilir. Ayrıştırılan verinin ilk paketi ile eğitim gerçekleştirildikten sonra elde edilen ağırlıklar ile ikinci paket veri ağı uygulanır. Eğer ikinci eğitimden (onaylama - validation) sonra ağırlıklardaki değişimler ihmal edilebilir düzeyde ise ağı test edilmeye hazır demektir.

⁹¹ YAO Jing Tao, TAN Chew Lim: “*Guidelines for Financial Forecasting with Neural Networks*”, Nisan 2001

⁹² Bakınız: Tablo 9

⁹³ Bakınız: Tablo 10

Bu aşamadan sonra, sonuçlar tatmin edici ise ağıımız kullanıma hazır demektir. Eğer testlerde kabul edilebilir sonuçları elde edemediysek:

1. Eğitim için daha fazla ve daha uygun veriler toplanarak ağa uygulanabilir,
2. Eğitim ve test için ayrılan veriler yeniden düzenlenebilir,
3. Ağın yapısı değiştirilebilir ya da başka bir model YSA kullanılabilir,
4. Öğrenme algoritması değiştirilebilir,
5. Başlangıç değerleri yenilenerek ağ yeniden eğitilebilir.

2.3.6 Yapay Sinir Ağlarının Genel Özellikleri

Çok değişik amaçlar için çok sayıda sinir ağı geliştirilmiştir. Yapısı, çalışması ve işlem prensibi bakımından farklılık göstermekle birlikte bazı özellikleri ortaktır.

Genel anlamda YSA tümüyle birbirine bağlantılı pek çok sayıda sinyal ya da bilgi işleme birimlerinden oluşmuş bir hesaplama sistemidir ve aşağıdaki özelliklere sahiptir^{94, 95}:

- a. **Paralel çalışma:** Yapay sinir ağlarında tüm işlem elemanları eş zamanlı çalıştıkları için çok hızlı çıktı üretirler.

⁹⁴ ERGEZER Halit, DİKMEN Mehmet, ÖZDEMİR Erkan: “Yapay Sinir Ağları ve Tanıma Sistemleri”, Başkent Üniv. İİBM, Pivolka, Yıl:2, Sayı:6, Nisan 2003

⁹⁵ TEBELKIS Joe: “Speech Recognition using Neural Networks”, School of Computer Science Carnegie Mellon University, Pennsylvania, Doctor of Philosophy Thesis, Mayıs 1995

- b. Doğrusal olmama:** YSA'nın temel işlem elemanı olan hücre doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen YSA da doğrusal değildir ve bu özellik tüm ağa yayılmış durumdadır. Bu özelliği ile YSA, doğrusal olmayan karmaşık problemlere çözüm getirmektedir.
- c. Genelleme:** YSA, ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de belirtilen tepkiyi üretme kabiliyetine sahiptir. Örneğin, karakter tanıma amacıyla eğitilmiş bir YSA, bozuk karakter girişlerinde de doğru karakteri verirler. Eğitilmiş bir ağa girişin sadece bir kısmı verilse bile, ağ hafızadan bu girişe en yakınına seçerek tam bir giriş verisi alıyormuş gibi kabul eder ve buna uygun bir çıkış değeri üretir. Veri YSA'ya, eksik, bozuk veya daha önce hiç karşılaşmadığı şekilde verilse bile, ağ kabul edilebilir en uygun çıkışı üretecektir. Bu özellik ağın genelleştirme özelliğidir.⁹⁶
- d. Öğrenme:** YSA ile bilgisayarlar ve/veya makineler öğrenebilir. Olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışırlar. Böylelikle kendisine gösterilen örneklerden genellemeler yaparak daha önce görmediği örnekler hakkında bilgiler üretebilirler.
- e. Bilginin saklanması:** YSA'larda bilgi ağın bağlantılarında saklanmaktadır. Diğer programlarda ise bir veri tabanında ya da programın içerisinde gömülü olarak bulunur⁹⁷.
- f. Hata toleransı:** YSA'lar, çok sayıda işlemci elemanların bağlantısı paralel dağılmış bir yapıya sahiptir ve ağın sahip olduğu bilgi, ağdaki tüm bağlantılara dağılmıştır. Giriş verisinde bulunabilecek herhangi bir gürültü, bütün ağırlıklar üzerine dağıldığından dolayı, gürültü etkisi tolere edilebilir.

⁹⁶ TEBELKIS Joe: "Speech Recognition using Neural Networks", School of Computer Science Carnegie Mellon University, Pennsylvania, Doctor of Philosophy Thesis, Mayıs 1995

⁹⁷ ERDEM O. Ayhan, UZUN Emre: "Yapay Sinir Ağları ile Türkçe Times New Roman, Arial ve El Yazısı Karakterleri Tanıma", Gazi Üniv.Müh.Mim.Fak.Der. Cilt:20, No:1, 13-19, 2005

Girişlerde eksik bir bilgi sistemin tamamının çalışmasını engellemez. Geleneksel yöntemlere göre hatayı tolere etme yetenekleri daha fazladır.

- g. Uyarlanabilirlik:** YSA ağırlıkları, uygulanan probleme göre değiştirilir. 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, işaret işleme, sistem tanımlama ve denetim gibi alanlarda etkin olarak kullanılır.⁹⁸
- h. Kendi ilişkisini oluşturma:** Yapay sinir ağları verilere göre kendi ilişkilerini kendisi oluşturabilir. Bünyesinde sabit bir denklem içermez⁹⁹.
- i. Sınırsız sayıda değişken ve parametre kullanımı:** Yapay sinir ağları sınırsız sayıda değişken ve parametre ile çalışabilir. Bu sayede çok başarılı bir tahmin ve genel çözümler üretebilmektedir.
- j. Algılamaya yönelik olaylarda kullanılabilirlik:** Yapay sinir ağları daha çok algılamaya dönük bilgileri işlemede kullanılırlar. Bilgiye dayalı işlemlerde genellikle uzman sistemler kullanılır. Bazı durumlarda bu iki sistem birleştirilerek daha başarılı sonuçlar üreten bir sistem elde edilebilir.

⁹⁸ ÖZTEMEL Ercan: “Yapay Sinir Ağları”, Papatya Yayıncılık, Ağustos 2003

⁹⁹ AYDOĞMUŞ Zafer, ÇÖTELİ Resul: “Yapay Sinir Ağları Yardımıyla İzolatör Yüzeyinde Potansiyel Tahmini”, F.Ü.Fen ve Müh.Bil.Dergisi, 17(2), 239-246, 2005

Karakteristik	Uzman Sistemler	Yapay Sinir Ağları
Yaklaşım	Sembolik	Sayısal
Nedensellik	Mantıksal	İlişkisel
Operasyon	Mekanik	Biyolojik, doğaya uygun
Açıklama	Mümkün	Mümkün değil
İşlem	Sıralı	Paralel
Sistem	Kapalı	Kendi kendine ayarlanabilir
Doğrulama ve onaylama	Yavaş	Hızlı
Neyle sürülür?	Bilgi / Tecrübe ile	Veriler ile
Tamiri	Zor	Kolay

Tablo 11 – Uzman Sistemler ile YSA’ların karşılaştırılması

k. Dereceli bozulma: Hatalara karşı toleranslı oldukları için sistemin bozulması da dereceli olur. Yani klasik programlarda sistemde bir hata var ise sistem tamamen çalışamaz duruma geçer, yorum yapamayacağı için kısmi de olsa bilgi üretemez. Fakat YSA’lar eldeki verilerle, sağlam olan hücrelerle bilgi üretmeye çalışırlar.

2.3.7 Yapay Sinir Ağlarının Dezavantajları

Bir önceki başlık altında bahsedilen özelliklerinin ve avantajlarının yanı sıra YSA’lar da kusursuz değildirler. YSA’ların da önemli dezavantajları mevcuttur^{100, 101}.

a. Yapay sinir ağları üzerlerinde çalışacağı donanıma aşırı derecede bağımlıdırlar. Özellikle paralel işlem yapmalarından dolayı çok hızlı çalışan paralel işlemcilerle ihtiyaç duyarlar.

¹⁰⁰ SWINGLER Kevin: “*Financial Prediction, Some Pointers, Pitfalls, and Common Errors*”, Center for Cognitive and Computational Neuroscience, Stirling University, Temmuz 1994

¹⁰¹ ÖZTEMEL Ercan: “*Yapay Sinir Ağları*”, Papatya Yayıncılık, Ağustos 2003

- b. YSA'lar her türlü problemin çözülmesi için hemen kullanılabilecek bir yöntem değildirler. Probleme göre ağ yapısında, verilerin girilmesinde değişikliğe gitmek gerekebilir. Bu yapılmadan kullanıldığında ilgisiz ve kabul edilemez sonuçlar üretebilirler.
- c. Probleme uygun ağ yapısının belirlenmesi genellikle deneme yanılma yöntemi ile yapılmaktadır. Dolayısı ile doğru ağ modeli kullanılmazsa performansı düşük sonuçlar elde edilebilir.
- d. İstatistiksel çözümlerle fazla yoruma ve açıklamaya ihtiyaç bırakmayan sonuçlar elde edilebilmesine rağmen YSA'nın ürettiği sonuçlardan ağırlıkların yorumlanması o kadar kolay değildir. Dolayısı ile YSA ile ulaşılan sonuçlarda model kapalı bir kutu gibi düşünülebilir.¹⁰²
- e. Ağın davranışlarını açıklamak kolay değildir. Bu durum ağa olan güveni azaltmaktadır. Özellikle hayati önem taşıyan konularda ürettiği sonucun nedeninin açıklanamaması kullanım alanını sınırlamaktadır.
- f. Ağı eğitmek de önemli bir problemdir. YSA'lar sadece sayısal bilgiler ile çalışabilirler. Dolayısı ile tüm veriler ağa girilmeden önce sayısallaştırılmalı ve ölçeklendirilmelidirler. Sayısallaştırma işlemi ise kullanıcının tecrübesiyle ve başarısıyla doğru orantılıdır.
- g. Ağın ne kadar eğitileceğinin bilinmemesi de ayrı bir dezavantajdır. Genellikle hatanın kabul edilebilir değerler içerisinde kalmasıyla eğitim tamamlanmış olarak kabul edilebilir. Fakat bunun doğru bir çözüm olacağı garanti edilemez. Bazı zamanlar ağın takılması ya da ezberlemesi de bir dezavantaj yaratmaktadır.

¹⁰² YILDIZ Birol, "Finansal Başarısızlığın Öngörülmesinde YSA Kullanımı ve Halka Açık Şirketlerde Ampirik Bir Uygulama", İMKB Dergisi, Cilt 5 Sayı:17, 2001

2.3.8 Yapay Sinir Ağlarının Uygulama Alanları

Yapay sinir ağları henüz yeni bir teknolojidir. Çalışmalar ilk olarak 1940’larda başlamış daha sonra bir duraklama döneminden sonra özellikle son 20–25 yılda hızlı bir şekilde gelişmiştir. YSA özellikle son yıllarda yapılan araştırmalar ve çalışmalar sayesinde birçok alanda kullanılabilir hale gelmişlerdir ve her geçen gün çok farklı YSA uygulaması duyurulmaktadır.

YSA’nın birçok uygulama alanının olmasına rağmen genel olarak listelenecek olursa:

2.3.8.1 Örüntü Tanıma (Pattern Recognition)

- a. **Ses tanıma:** Sesli yanıt sistemlerinde¹⁰³, asansörlerde, otomatik kapılarda ve hatta cep telefonlarında bile kullanılmaktadır¹⁰⁴.
- b. **Veri iletimi:** Verilerin sayısallaştırıldıktan sonra sıkıştırılarak bir yerden başka bir yere transferinde.¹⁰⁵
- c. **Hareket tespiti, yüz tanıma¹⁰⁶, hedef tespiti:** Özellikle askeri uygulamalarda, güvenlik sistemlerinde. Akan görüntülerin içerisinde belirli bir nesnenin tespitinde¹⁰⁷.

¹⁰³ TUNÇKANAT Mehmet, KURBAN Rifat, SAĞIROĞLU Şeref: “Voice Recognition Based On Neural Networks”, International Conference on Signal Processing – ICSP 2003

¹⁰⁴ BOLAT Bülent: “Recognition of the REED Instrument Sounds by Using Statistical Neural Networks”, *Journal of Engineering and Natural Sciences*, Yıldız Teknik Üniv., Şubat 2005

¹⁰⁵ KOPRINSKA Irena, KASABOV Nikola: “An Application of Evolving Fuzzy Neural Network for Compressed Video Parsing”, Department of Information Science, University of Otago, New Zealand, Aralık 2000

¹⁰⁶ ERGEZER Halit, DİKMEN Mehmet, ÖZDEMİR Erkan: “Yapay Sinir Ağları ve Tanıma Sistemleri”, Başkent Üniv. İİBM, Pivolka, Yıl:2, Sayı:6, Nisan 2003

¹⁰⁷ HART Eduardo, CHA Sung-Hyuk, TAPPERT Charles: “Interactive Flag Identification Using a Fuzzy-Neural Technique”, Proceedings of Student/Faculty Research Day, CSIS, Pace University, May 7th, 2004

- d. **Robotik sistemlerde**¹⁰⁸: Robotların öğrenmesinde, göz-el koordinasyonunda¹⁰⁹.
- e. **Karakter, imza, parmak izi tanıma**: El yazısı tanıma, OCR (Optical Character Recognition) yazılımlarında¹¹⁰, parmak izinden ve yüzünden şahıs tanıma¹¹¹, imza analizlerinde.
- f. **Kalite kontrolünde**: Üretilen bir ürünün (kumaş, seramik, karo, resim, vb) istenilen özelliklere uygunluğunun tespitinde.

2.3.8.2 Verilerin Yorumlanması

- a. **Finans alanında**¹¹²: Borsa analizinde¹¹³, döviz kurlarının tahmininde¹¹⁴, şirketlerin başarı ve başarısızlık durumlarının önceden tespitinde¹¹⁵, kredi verilmesi kararlarında.¹¹⁶
- b. **Güvenlik Sistemlerinde**: Özellikle bilgisayarla ağ üzerinden gelen bilgilerin yorumlanarak sisteme bir saldırı olup olmadığının tespitinde¹¹⁷. İstenmeyen elektronik postaların (SPAM) ayıklanmasında.

¹⁰⁸ ÖZTEMELE Ercan: “Reklamlarda Yapay Zeka”, Otomasyon Sayı:128, Ocak 2003

¹⁰⁹ VEELENTURF L.P.J: “Analysis and Applications of Artificial Neural Networks”, Prentice Hall, 1995

¹¹⁰ ERDEM O. Ayhan, UZUN Emre: “Yapay Sinir Ağları ile Türkçe Times New Roman, Arial ve El Yazısı Karakterleri Tanıma”, Gazi Üniv.Müh.Mim.Fak.Der. Cilt:20, No:1, 13-19, 2005

¹¹¹ ROWLEY Henry A., BALUJA Shumeet, KANADE Takeo: “Neural Network-Based Face Detection”, PAMI, IEEE, January 1998

¹¹² McNEILS Paul: “Neural Networks in Finance – Gaininig Predictive Edge in the Market”, Elsevier Academic Press, 2005

¹¹³ KANAS Angelos: “Neural Network Linear Forecasts For Stock Returns”, International Journal Of Finance And Economics, 6:245-254 (2002)

¹¹⁴ McCluskey C.Peter: “Feedforward and Recurrent Neural Networks and Genetic Programs for Stock Market and Time Series Forecasting”, Master Science Thesis, Department of Computer Science at Brown University, June 1993

¹¹⁵ YILDIZ Birol: “Finansal Başarısızlığın Öngörülmesinde YSA Kullanımı ve Halka Açık Şirketlerde Ampirik Bir Uygulama”, İMKB Dergisi, Cilt 5 Sayı:17, 2001

¹¹⁶ AKPINAR Haldun: “Yapay Sinir Ağları ve Kredi Taleplerinin Değerlendirilmesinde Bir Uygulama Önerisi”, Mayıs 1993

¹¹⁷ LIAO Yihao , VEMURI V. Rao, “Use of K-Nearest Neighbor Classifier for Intrusion Detection”, Computers & Security, Vol 21, No 5, pp 439-448, 2002

- c. **Jet ve roket motorlarının geliştirilmesinde:** Yapılan çalışmalarda algılayıcılardan (sensör) toplanan verilerin analizinde.
- d. **Tıbbi araştırmalarda:** Hastalıkları tanımada, daha önceki hastalardan alınan geri bildirimlerle hastalığın teşhisinde¹¹⁸. İntihara meyilli kişilerin tespitinde. Kalp ve beyin grafiklerinin, kan, idrar örneklerinin analizinde.
- e. **Hava durumu tahminlerinde:** O anki rüzgâr, nem, sıcaklık vb. verilerin değerlendirilmesi ile gelecekteki hava durumunun tahmininde¹¹⁹.
- f. **Personel seçiminde.**

2.3.8.3 Optimizasyon İşlemlerinde

Bir çok ticari ve bilimsel konularda incelenen olayın verilen kısıtlar altında hedefin maksimize ya da minimize edilmesi optimizasyon olarak bilinir. Optimizasyon için önceki çalışmalarda klasik birçok yöntem geliştirilmiş olmasına karşılık bunun YSA modellemesi ile yapılması en azından sınırlayıcı matematik kabullerin bulunmaması açısından yararlıdır.¹²⁰

2.3.8.4 Fonksiyon Yaklaşımlarında

Matematiksel fonksiyonu bilinmeyen birçok verinin modellenmesinde.

¹¹⁸ VALAFAR Faramarz: “*Applications of Neural Networks in Medicine and Biological Sciences*”, CRC Press LLC, 2001

¹¹⁹ CİĞİZOĞLU H.Kerem, ALP Murat: “*Farklı Yapay Sinir Ağı Metodları ile Yağış-Akış İlişkisinin Modellenmesi*”, İTÜ Dergisi/d, Mühendislik, Cilt:3, Sayı:1, Şubat 2004

¹²⁰ ŞEN Zekai, “*Yapay Sinir Ağları İlkeleri*”, Sayfa: 18, Su Vakfı İstanbul, 2004

2.3.8.5 Diğer Uygulama Alanları

- a. **Kontrol:** Özellikle endüstriyel uygulamalarda, tren denetim sistemlerinde¹²¹, robotik işlemlerde ve motorların hareketlerinde verilen girdilere göre istenilen bir işlemin yapılmasında YSA kullanılmaktadır.
- b. **Arama çalışmalarında:** Veri madenciliğinde toplanan verilerin içinden istenilene en uygun verilerin bulunmasında.
- c. **Verilerin sınıflandırılması ve kümelendirilmesinde:** Örneğin, cümlelerin gramer kurallarına uygun ya da değil diye ayrılmasında.¹²²
- d. **Verilerin filtrelenmesinde:** Veriler arasından önemli bilgiyi seçip gereksiz bilgilerin ayıklanmasında, örneğin telefon görüşmelerindeki geri plan gürültüsünün süzülmesinde.
- e. **Verilerin taklit edilmesinde:** Eldeki az bir veri ile daha büyük bir verinin elde edilmesinde. Örneğin, bir ses sanatçısının ses kaydından alınacak küçük bir parça ile söylemediği bir şarkının üretilmesi, telefonda başkasının sesinin taklit edilmesi gibi.
- f. Elektrik sarfiyatı tahmininde¹²³, gelecek turist sayısının belirlenmesinde¹²⁴, bazı elektriksel¹²⁵ ve elektroniksel¹²⁶ hesaplamalarda¹²⁹, haritacılık

¹²¹ YAN Wu, LIMING Zhang: “Control Algorithms of Fuzzy Neural Network and Their Application in Automatic Train Control”, Department of Computer Science and Engineering Tongji University, Shanghai 2003

¹²² LAWRENCE Steve, GILES C. Lee, FONG Sandiway: “Natural Language Grammatical Inference with Recurrent Neural Networks”, IEEE Transactions on Knowledge and Data Engineering, Volume 12, Number 1, Syf. 126–140, 2000

¹²³ HAMZAÇEBİ Coşkun, KUTAY Fevzi: “Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini”, Gazi Üniv. Müh.Mim.Fak.Der. Cilt 19, No:3, 227-233, 2004

¹²⁴ GÜNGÖR İbrahim, ÇUHADAR Murat: “Antalya İline Yönelik Alman Turist Talebinin Yapay Sinir Ağları Yöntemi ile Tahmini”, Ticaret ve Turizm Eğitim Fakültesi Dergisi, Sül.Dem.Ünv., Yıl:2005, Sayı:1

¹²⁵ KARADENİZ Mehmet, YÜNCÜ Selma, AYDEMİR M.Timur: “Asenkron Motorlarda Stator Direncinin Yapay Sinir Ağları ile Tahmini”, Gazi Üniv. Müh.Mim.Fak., Şubat 2004

işlemlerinde¹³⁰, trafik kontrol sistemlerinde¹³¹, enerji tasarrufu için enerji yalıtımında¹³², stok yönetiminde¹³³, talep tahmininde¹³⁴ vb...

¹²⁶ İNAN Aslan, KÖROĞLU Selim, İZGİ Ercan: “Dengeli Elektrik Güç Sistemi Verilerini Kullanarak Dengesiz Sistem Kayıplarının Yapay Sinir Ağları İle Belirlenmesi”, Pamukkale Ün. Mühendislik Bilimleri Dergisi, Yıl:2005, Cilt:11, Sayı:1, Sayfa 47-52

¹²⁷ AYDOĞMUŞ Zafer, ÇÖTELİ Resul: “Yapay Sinir Ağları Yardımıyla İzolatör Yüzeyinde Potansiyel Tahmini”, F.Ü.Fen ve Müh.Bil.Dergisi, 17(2), 239-246, 2005

¹²⁸ BOLAT Suna, vd.: “Yapay Sinir Ağı ile Gaz Karışımında Elektrot Açıklığına ve Karışım Yüzdelere Bağlı Olarak Delinme Gerilimlerinin Belirlenmesi”, Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu –İNISTA”, 2004

¹²⁹ BOLAT Bülent, YILDIRIM Tülay: “İyonosfer Radar Yansımasının İstatistiksel Sinir Ağları ile Sınıflandırılması”, Yıldız Teknik Ün. Elektronik ve Haberleşme Müh.Böl., Nisan 2003

¹³⁰ ÇORUMLUĞLU Ö., ÖZBAY Y., vd.: “GPS Yüksekliklerinden Ortometrik Yüksekliklerin Elde Edilmesinde Yapay Sinir Ağı (YSA) Tekniğinin Kullanımı”, Har. ve Kad. Müh.Odası, Mühendislik Ölçmeleri STB Komisyonu 2. Mühendislik Ölçmeleri Sempozyumu, Kasım 2005, İTÜ

¹³¹ TEKTAŞ Mehmet, AKBAŞ Ahmet, TOPUZ Vedat: “Yapay Zeka Tekniklerinin Trafik Kontrolünde Kullanılması Üzerine Bir İnceleme”, Marmara Üniversitesi, Teknik Bilimler MYO, 1997

¹³² KELEŞOĞLU Ömer, Ekinci Cevdet Emin, FIRAT Adem, “The Using Artificial Neural Networks in Insulation Computations”, Journal of Engineering and Natural Sciences, Mart 2005

¹³³ BAYKASOĞLU Adil, ÖZBAKIR Lale: “Yapay Sinir Ağları ile Teslim Tarihi Belirleme”, Yöneylem Araştırması / Endüstri Mühendisliği, XXIV Ulusal Kongresi, Haziran 2004

¹³⁴ GÜNGÖR İbrahim, KAYACAN M.Cengiz, KORKMAZ Mehmet: “Endüstriyel Odun Hammaddesi Talebinin Tahmininde Yapay Sinir Ağlarının Kullanımı ve Bazı Tahmin Yöntemleri İle Karşılaştırılması”, Yöneylem Araştırması ve Endüstri Mühendisliği XXIV. Ulusal Kongresi, Çukurova Üniversitesi ve Gaziantep Üniversitesi, Endüstri Mühendisliği Bölümleri, Adana 2004

2.4 GERİYE YAYILIM (BACK PROPOGATION) ALGORİTMASI (GYA)

Yapay sinir ağlarının gündeme gelmesinden birkaç sene sonra XOR problemi gibi bazı konulara YSA ile çözüm bulunamadığı için çalışmalar uzunca bir süre duraklama dönemine girmiştir. Fakat Rumelhart, Parker ve McClelland tarafından geliştirilen Geriye Yayılım (Back Propagation) Algoritması sayesinde yapay sinir ağlarına olan ilgi yeniden canlanmıştır¹³⁵. Geriye Yayılım Algoritması (GYA) ile daha önceleri çözilemeyen sınıflandırma, tanıma, genelleme gibi birçok problemin YSA'lar ile daha iyi çözümler bulunabilmiştir. Bu model günümüzde mühendislik alanında hemen hemen her türlü problemin çözümü için kullanılabilecek kadar güçlüdür. GYA aslında ADALINE ve tekli basit algılayıcı perseptron modellerinin öğrenme kurallarının geliştirilmiş bir şeklidir. Temel amaç hedef çıktı ile üretilen çıktı arasındaki hatayı en aza indirmektir. Hata, ağdaki ağırlıkların bir fonksiyonu olarak görülür ve hataların karelerinin ortalaması delta algoritmasında olduğu gibi dereceli azaltma (gradient descent¹³⁶) yöntemi kullanılarak minimize edilmeye çalışılır.¹³⁷ Hata azaltma işleminin, hatayı tüm ağa yayarak gerçekleştirdiği için bu ağa “Hatayı Geriye Yayıma – Error Back Propagation” da denmektedir.

GYA ağları öğretmenli öğrenen, ileri sürümlü bir YSA'dır. Birçok uygulamada kullanılan, öğrenmesi ve uygulaması kolay bir modelidir. Günümüzdeki uygulamaların yaklaşık %80'inde kullanıldığı tahmin edilmektedir.¹³⁸ Özellikle de, bu tez çalışmasında da olduğu gibi, finansal zaman serilerinin gelecekteki davranışlarını tahmin etme de tercih edilmektedir. Finansal zaman serilerinin tahmin edilmesinde kullanılan diğer YSA modelleri ise geri dönüşlü ağlar (Recurrent Neural


¹³⁵ ÇETİN Meriç, ALPER Uğur, ŞAHİN Bayzan: “İleri Beslemeli YSA’da Backpropagation (Geriye Yayılım) Algoritmasının Sezgisel Yaklaşımı”

¹³⁶ BURNEY Syed Muhammad Aqil, JILANI Tahseen Ahmed,ARDİL Cemal: “Levenberg-Marquardt Algorithm for Karachi Stock Exchange Share Rates Forecasting”, Transactions on Engineering, Computing and Technology, December 2004 ISSN 1305-5313

¹³⁷ AYDOĞMUŞ Zafer, ÇÖTELİ Resul:“Yapay Sinir Ağları Yardımıyla İzolatör Yüzeyinde Potansiyel Tahmini”, F.Ü.Fen ve Müh.Bil.Dergisi, 17(2), 239-246, 2005

¹³⁸ KAASTRA Iebeling, BOYD Milton: “Designing a Neural Network for Forecasting Financial and Economic Time Series”, Neurocomputing, 31 August 1994

Network - RNN), probabilistik ağlar ve bulanık yapay sinir ağlarıdır¹³⁹ (Neuro-Fuzzy). Örneğin, hisse senetlerinin hareketlerini önceden tahmin ederek getiriye arttırabilmek için yapılan YSA modellemelerinde geri dönüşlü ağlar ve zaman gecikmeli ağlar (Time-Delayed Neural Networks – TNN) daha kullanışlı olabilmektedir.¹⁴⁰



Şekil 23 – Bir GYA ağı modeli¹⁴¹

Bir geri yayımlı ağ modelinde giriş, gizli ve çıkış olmak üzere 3 katman bulunmakla birlikte, problemin ve veri setinin özelliklerine göre gizli katman sayısını ve yapay sinir hücresi sayısını arttırabilmek mümkündür¹⁴². GYA’da gizli katmanda ve çıkış katmanında bir de eşik hücresi (bias neuron) ilave edilmiştir.¹⁴³

¹³⁹ ZHOU Yunfei, LI Shuijin, JIN Rencheng: “A New Fuzzy Neural Network with Fast Learning Algorithm and Guaranteed Stability for Manufacturing Process Control”, Elsevier - Fuzzy Sets and Systems 132 (2002) 201 – 216

¹⁴⁰ THAWORNWONG Suraphan, ENKE David: “Forecasting Stock Returns with Artificial Neural Networks”, “Neural Networks in Business Forecasting”, ZHANG G.Peter, 2004, Idea Group Publishing, Chapter 3

¹⁴¹ FREEMAN James, SKAPURA David: “Neural Networks Algorithms, Applications, and Programming Techniques”, Addison-Wesley Publishing Company, 1991

¹⁴² KELEŞOĞLU Ömer, Ekinci Cevdet Emin, FIRAT Adem, “The Using Artificial Neural Networks in Insulation Computations”, Journal of Engineering and Natural Sciences, Mart 2005

¹⁴³ ARIS Teh Noranis Mohd, vd.: “Parallel Implementation on Improved Error Signal of Backpropagation Algorithm”, Malaysian Journal of Computer Science, Vol. 15 No. 2, December 2002, pp. 1-16

- a. **Giriş katmanı;** dış dünyadan gelen verileri alır hiçbir işleme tabi tutamadan bir sonraki katmana aktarır. Bu katmandaki nöron sayısı giriş veri sayısı kadardır ve her bir giriş nöronu bir veri alır.
- b. **Ara (Gizli) Katmanlar;** asıl işin yapıldığı işlemlerin gerçekleştirildiği katmandır. Her bir katman kendisine gelen verileri işleyerek bir sonraki katmana iletir. Bir ağ yapısında birden fazla ara katman bulunabilir. Hücre sayısının ve katman sayısının uygun olarak belirlenmesi ağın başarısı açısından çok önemlidir. Katman sayısı ve her bir katmandaki hücre sayısı tamamen tasarımcıya bağlıdır.
- c. **Çıktı katmanı;** ara katmanlardan gelen verileri ağın kullandığı aktivasyon fonksiyonu ile işleyerek çıktıları üretir. Bu katmanda elde edilen sonuçlar tüm ağın çözülmeye çalışılan problem için üretmiş olduğu çıktılarıdır.

GYA ağlarında bir katmandan diğer bir katmana aradaki herhangi bir katmanı atlayarak geçmek mümkün değildir. Girişe uygulanan veriler her bir katmandaki sinir hücrelerinde işleme tabi tutulup katmandan katmana aktararak çıktı katmanına kadar iletilir. Sonuçta elde edilen çıktılar hedef çıktılar ile karşılaştırılarak aradaki fark yani “hata” bulunur. Hesaplanan hata değerleri her çıktı düğümüne karşılık gelen katmandaki düğümlere geri gönderilir. Böylece ara katmanlardaki düğümlerin her biri toplam hatanın sadece kendine ait olarak hesaplanan kısmını içerir. Böylece hataya bağlı olarak her katmandaki ağırlıklar yeniden güncellenir. Bu işleme hatanın önceden belirlenmiş olan kabul edilebilir sınırlar içerisinde kalmasına kadar devam edilir ve böylece ağın eğitimi tamamlanmış olur. Katmanlar arasında belirlenen son ağırlıklar ise eğitimi tamamlanmış olan ağdan alınarak test aşamasında kullanılmak üzere saklanır.

2.4.1 GYA'da Karşılaşılan Sorunlar

Geriye yayılım algoritması çok yaygın olarak kullanılmasına rağmen yöntemin uygulamadaki başarısı ve güvenilirliği için bazı ayrıntılara dikkat etmek gerekmektedir.¹⁴⁴

2.4.1.1 Ağın Eğitim Hızı¹⁴⁵

Ağa uygulanan ilk değerlere ve eğitim devir sayısına bağlı olarak eğitim süreci yüzlerce ya da milyonlarca devir sürebilir. Bu konuda kesin bir sayı yoktur. Burada kullanıcının tecrübesi, ağı uygun tasarlaması ve parametreleri uygun seçmesi belirleyici olur. Bir GYA ağının yapısı, eğitim süresi boyunca N parametrelili bir ağ için N+1 boyutlu bir uzayda, N değişkenli bir yüzey üzerinde gezen bir noktanın, hatayı en aza indiren noktayı aramasını gerektirmektedir¹⁴⁶. Ağın içinde yapılan türev işlemlerinin sonucuna göre bazı durumlar için eğitim işlemi çok uzun sürebilmektedir. Bu durumu engellemek için sisteme η öğrenme katsayısı, μ momentum terimi ve her bir hücre için bir eşik değeri (bias) ilave edilir.

$$w_{pq,k}(N+1) = w_{pq,k}(N) - \eta_{p,q} \delta_{pq,k} \Phi_{p,j}(I) + \mu \Delta w_{pq,k}(N) \quad (3.10)$$

Yukarıdaki denklemde;

- w : ağırlık değeri,
- p, q : hücre numarası,
- k : katman sayısı,
- N : devir sayacı,
- H : öğrenme katsayısı,

¹⁴⁴ CİGİZÖĞLU H.Kerem, ALP Murat: “Farklı Yapay Sinir Ağı Metodları ile Yağış-Akış İlişkisinin Modellenmesi”, İTÜ Dergisi/d, Mühendislik, Cilt:3, Sayı:1, Şubat 2004

¹⁴⁵ TEBELKIS Joe: “Speech Recognition using Neural Networks”, School of Computer Science Carnegie Mellon University, Pennsylvania, Doctor of Philosophy Thesis, Mayıs 1995

¹⁴⁶ EFE Önder, KAYNAK Okyay, “Yapay Sinir Ağları ve Uygulamaları”, Syf: 19, Boğaziçi Üniversitesi,2000

- δ : geriye yayılacak hata terimi,
 μ : momentum,
 $\phi(I)$: ağıın bulduğı sonuçtur.

Ağa eklenen eşik (bias) elemanı ağıın öğrenme hızını genelde olumlu yönde etkiler. Giriş elemanlarının eşik değerinin (+1) olmak durumunda olmasına karşın diğer eşik değeri herhangi bir değeri alabilir ve güncellenebilirler.

Momentum değeri ise eğitim sürecinin yönünün korunmasını sağlar. Bunun için ağırlıkların güncellenmesi sırasında önceki ağırlık değışıimiyle orantılı olarak bir momentum değeri ilave edilir¹⁴⁷.


Öğrenme katsayısı pozitif bir değeri olmak zorundadır. Eğer 2’den büyük seçilirse ağıın kararsızlığına neden olur. 1’den büyük seçildiğinde ise ağıın çözüme ulaşması yerine sabit bir aralıkta salınım yapmasına neden olabilir. Öğrenme katsayısı için uygun değeri (0,1) aralığındadır¹⁴⁸. Bu aralıkta seçilecek katsayının büyüklüğüyle öğrenme adım aralığı doğru orantılıdır.

Sigmoid fonksiyonu kullanan bir ağda artan ağırlık değeri sigmoid fonksiyonunun türevinin çok küçük değeri bölgelede işlem yapmasına neden olur. Geriye yayılan hata terimi türevle orantılı olduğundan bu durumda yeterli eğitim gerçekleştirilemez.

¹⁴⁷ TEBELKIS Joe: “*Speech Recognition using Neural Networks*”, School of Computer Science Carnegie Mellon University, Pennsylvania, Doctor of Philosophy Thesis, Mayıs 1995

¹⁴⁸ TEBELKIS Joe: “*Speech Recognition using Neural Networks*”, School of Computer Science Carnegie Mellon University, Pennsylvania, Doctor of Philosophy Thesis, Mayıs 1995

2.4.1.2 Ağın Yerel Minimum Noktasına Takılması



Şekil 24 – Hata değerlerinin seyri

Geriye yayılım algoritmasının en büyük zaafı, türev işlemleri sırasında yerel minimum noktasında takılması ve bu noktayı en iyi çözüm zannetmesidir. Bu durum “ağın ezberlemesi” olarak da adlandırılır.¹⁴⁹ Toplam hata değerinin kabul edilebilir olduğu durumlarda bulunan noktanın yerel ya da bölgesel minimum noktası olması herhangi bir sorun yaratmayabilir ancak henüz toplam hata değeri kabul edilemez bir noktada iken ağın eğitimi kesilirse ağın üreteceği sonuçlar hatalı olacaktır.

2.4.1.3 Başlangıç Değerlerinin Belirlenmesi

Eğitim sürecinin başında, ağırlık değerleri olarak (-0.5 +0.5) aralığında rastsal olarak değerler atamak genel kabul görmüş bir yöntemdir. Ağırlık değerleri başlangıçta çok büyük verilirse ağ yerel minimum noktalarına takılabilir. Çok küçük verilirse de bu sefer ağın uygun ağırlıkları bulması çok uzun zaman alabilir.

¹⁴⁹ ÖZTEMEL Ercan: “Yapay Sinir Ağları”, Papatya Yayıncılık, Ağustos 2003

Ağın öğrenme hızını belirleyen η öğrenme katsayısı genellikle (0.05 – 0.25) arasında seçilir.¹⁵⁰ Bu değer daha düşük seçilirse devir sayısı artar, büyük seçilirse de uygun çözümü bulamamasına neden olabilir.

2.4.1.4 Ağın Boyutları ve Yapısı

Çok katmanlı bir yapıya sahip olan geriye yayımlı yapay sinir ağlarında sadece giriş, ara ve çıkış katmanından oluşan toplam 3 katmanlık bir ağ her zaman yeterli olmayabilir. Katman sayısı ve her katmandaki hücre sayısı yine kullanıcının vereceği bir karardır. Giriş ve çıkış katmanlarındaki düğüm sayısı problemin yapısıyla ilgilidir. Giriş verilerinin eleman sayısı (kaç değişik girdinin olduğu, euro, altın fiyatı, IMKB gibi) giriş katmanının düğüm sayısını ve beklenen sonuç da çıkış katmanının düğüm sayısını belirler. Gizli katmandaki düğüm sayısı ise kullanıcının tecrübesine bağlıdır. Fazladan konulacak her bir düğüm ağın yavaşlamasına neden olur.

2.4.1.5 Eğitim Verilerinin Seçilmesi ve Ağ İçin Uyarlanması

Elde bulunan tüm verileri ağın eğitiminde kullanmak doğru bir yöntem değildir. Genellikle eldeki verilerin %70'i eğitim, %20'si onaylama ve %10'u test için kullanılır.¹⁵¹

Eğitimde kullanılacak olan verilerin problem uzayını doğru temsil etmesi de çok önemlidir. Ağı, çözülmeye çalışılan problemle ilgisi göreceli olarak az verilerle eğitmek ağın başarı oranını ciddi şekilde düşürecektir.

¹⁵⁰ FREEMAN James, SKAPURA David: “*Neural Networks Algorithms, Applications, and Programming Techniques*”, Addison-Wesley Publishing Company, 1991

¹⁵¹ YAO Jing Tao, TAN Chew Lim: “*Guidelines for Financial Forecasting with Neural Networks*”, Nisan 2001

2.4.2 GYA'nın İşlem Adımları

Herhangi bir bilgisayar programlama diliyle ya da MATLAB ile geriye yayılım algoritması kullanan bir yapay sinir ağı kurulmak istendiğinde aşağıdaki adımlar uygulanabilir.

2.4.2.1 Standart Geriye Yayılım Algoritması

1. Giriş, ara ve çıkış katmanları ve katmanların elemanlarının sayısı belirlenerek bir ağ oluşturulur.
2. Tüm ağırlıklar için önce rasgele küçük bir değer atanır.

REPEAT¹⁵²

3. Rasgele bir eğitim seti seçilir.
4. Seçilen girdi değerleri ağıın giriş katmanına uygulanır.
5. Ağıın ara ve çıkış katmanlarındaki aktivasyon fonksiyonları verilen girdi değerlerine ve ağırlıklara göre çalıştırılır.
6. Elde edilen sonuç ile hedeflenen sonuç karşılaştırılarak hata bulunur.
7. Geçerli devirdeki (epoch) ağırlıklara göre bulunan sonuç ve hatalar çıkış katmanından ara katmanlara yayılır.
8. Her bir elemanın ağırlığı hatayı azaltacak şekilde yeniden hesaplanır.

UNTIL (Hata değeri kabul edilebilir değerler arasında ise ya da ağıın ürettiği ağırlıklar artık değişmiyorsa)

¹⁵² repeat – until komut ikilisi, programlama dillerinde döngüyü işaret eder. “until” deki şart sağlanana kadar iki komut arasındaki işlemler tekrarlanır.

2.4.2.2 Basit Geri Dönüslü Geriye Yayılım Algoritması

1. Eleman sayısı (hücre sayısı) ara katmandaki eleman sayısına eşit olan bir adet geri dönüş katmanı içeren bir ağ oluşturulur.
2. Tüm ağırlıklar için önce rasgele küçük bir değer atanır.

REPEAT 1

3. İçerik katmanındaki (context layer) tüm değerler ilk hallerine döndürülür ve ilk döngü dizisi (sequence) başlatılır.

REPEAT 2

4. Geri dönüş katmanındaki içerik elemanları döngünün bir sonraki girdi değeri olarak belirlenir.
5. Ağ standart GYA'da olduğu gibi çalıştırılır ve ağırlıklar ayarlanır.
6. Ara katmanın içeriği 3. adımdaki içerik katmanına tekrar kopyalanır.

UNTIL 2 (Döngü dizisinin sonuna gelindiğinde)

UNTIL 1 (Hata değeri kabul edilebilir değerler arasında ise ya da ağın ürettiği ağırlıklar artık değişmiyorsa)

2.4.2.3 Çoklu Geri Dönüslü Geriye Yayılım Algoritması

1. Eğitilecek her döngü dizisi için eleman sayısı ara katmandaki eleman sayısına eşit olan bir içerik katmanı içeren bir ağ oluşturulur.
2. Tüm ağırlıklar için önce rasgele küçük bir değer atanır.
3. Her döngü dizisi için bir içerik katmanı atanır.

REPEAT

4. İçerik katmanının tüm değerleri döngü dizisinin başladığını işaret etmek için sıfırlanır (ilk değerlerine getirilir – reset)
5. 3. adımda atananlardan rasgele bir döngü dizisi seçilir.
6. İçerik katmanının seçilen döngü dizisindeki bir sonraki elemanı ve hedef çıktılar ağa girdi olarak verilir.
7. Ağ standart GYA’da olduğu gibi çalıştırılır ve ağırlıklar ayarlanır.
8. Ara katmanın içeriği 4. adımdaki içerik katmanına tekrar kopyalanır.
9. Eğer döngü tamamlanmışsa içerik katmanı sıfırlanır ve döngünün başına gidilir.

UNTIL (Hata değeri kabul edilebilir değerler arasında ise ya da ağın ürettiği ağırlıklar artık değişmiyorsa.)

2.5 YSA’NIN EKONOMİ VE FİNANS ALANINDA KULLANIMI

Ekonomik ve finansal değişkenlerin modellenmesi ve öngörülmesi ekonomi ve finans için son derece önemlidir. Ekonomik ve finansal parametrelerin geleceğinin öngörülmesinde istatistiksel araçlar sıklıkla kullanılmaktadır. Özellikle son yıllarda zaman serileri alanında kaydedilen gelişmelerden dolayı ekonomik ve finansal modellemelerde istatistiksel yöntemlerin kullanımı giderek artmaktadır¹⁵³.

Son yıllarda yapay sinir ağları üzerine yapılan araştırmaların artması ile YSA hemen hemen her alanda kendilerine uygulama alanı bulmuşlardır. YSA’lar özellikle sınıflandırmada ve zaman serilerinin öngörülmesinde oldukça başarılı sonuçlar üretebildikleri için istatistik, ekonomi ve finans konularında da yoğun bir şekilde kullanılmaktadırlar¹⁵⁴. Özellikle eksik ve gürültülü bilgilere rağmen genelleştirme ve sonuca ulaşabilme yeteneği sayesinde ekonomik modellemelerde ön plana çıkmaktadır.

YSA’ların, ekonomi ve finans alanında kullanıldığı yerlerin başında tahmin etme yani geleceği öngörme gelmektedir¹⁵⁵. Geleceği tahmin edebilme özellikle işletmeler için planlama, satın alma, strateji geliştirme, yatırım yapma, eleman alımı gibi birçok konu açısından son derece önemlidir. Tahmin yöntemlerinde uzun yıllardır genellikle lineer metotlar kullanılmaktaydı. Lineer yöntemlerin geliştirilmesi ve uygulanması oldukça basit olmasına karşın finans ve ekonomi alanında olduğu gibi lineer olmayan değişkenlerin tahmininde çok zayıf kalmaktadır. Non-linear modeller gerçek hayatı modellemek için daha uygundur. Fakat bu sefer de non-linear bir model geliştirebilmenin zorluğu karşımıza çıkmaktadır. Bir non-linear değişkeni etkileyen onlarca non-linear değişken ve yapı mevcut olabilir. Özellikle son 20–30 yıldır birçok non-linear tahmin yöntemi geliştirilmiştir. Bu modellerden

¹⁵³ YURTOĞLU Hasan: “YSA Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği”, Şubat 2005

¹⁵⁴ KAASTRA Iebling, BOYD Milton: “Designing a Neural Network for Forecasting Financial and Economic Time Series”, Neurocomputing, 31 August 1994

¹⁵⁵ MANDIC Danilo P., CHAMBERS Jonathon A.: “Recurrent Neural Networks For Prediction - Learning Algorithms, Architectures And Stability”, John Wiley & Sons Ltd, 2001

herhangi birisi için “çok iyidir” diyebilmek kolay değildir. Her bir yöntemin kullanıldığı yere göre kendine göre avantajı ve dezavantajı vardır.

Tam da bu noktada YSA ekonomi ve finans alanında geleceği tahmin etmeye çalışanlar için umut vadeden bir yöntem olarak karşımıza çıkmaktadır.¹⁵⁶ Çünkü YSA ile non-lineer değişken serileri için model geliştirmek diğer yöntemlere kıyasla daha kolaydır. YSA’ların esnekliği sayesinde de gerçek hayatta karşılaşılan birçok soruna (ki bunların hemen hemen hepsi non-lineer yapıdadır) YSA ile çözüm üretebilmek mümkündür. YSA’ların bir diğer avantajı da eldeki veriler ile eğitilerek çalışıyor olması ve modellemede kısıtlayıcı kabullenmelere gereksinim duymamasıdır. YSA’ların matematiksel olarak ifade edilebiliyor olması da özellikle zaman serilerinin tahminlerinde çalışanlar için önemli bir avantajdır. Çünkü tahmin yöntemlerinin çoğu tahmin edilmeye çalışılan değişkeni hangi değişkenlerin ve faktörlerin etkilediğini matematiksel olarak gösterebilmektedir.

YSA için sadece non-lineer modellemelerde kullanılır demek doğru olmaz. YSA ile lineer yapıları da modellemek pek tabi mümkündür. Bu konuda pek çok araştırmacı çalışmış ve YSA’nın lineer zaman serilerini de başarılı bir şekilde modelleyebildiğini ispatlamışlardır¹⁵⁷.

Bahsedilen özelliklerden dolayı YSA’lar ekonomi ve finans alanında geleceği tahmin edebilmek için esnek ve genel bir araç olarak rahatlıkla kullanılabilir. Bununla beraber bir YSA modellemek çok da basit bir işlem değildir. Her ne kadar piyasada birçok hazır program olsa da (Örneğin tezimizde kullandığımız gibi MATLAB) başarılı bir YSA modelleyebilmek kullanıcının bilgisine, tecrübesine, elindeki verilere son derece bağlıdır. Bir bakıma YSA modellemek bir bilim ve aynı zamanda da bir sanattır.¹⁵⁸

¹⁵⁶ KLINE Douglas M.: “*Methods for Multi-Step Time Series Forecasting with Neural Networks*”, “*Neural Networks in Business Forecasting*” ZHANG G.Peter, 2004, Idea Group Publishing

¹⁵⁷ Hwang 2001, Medeiros et al. 2001, Zhang 2001. “*Neural Networks in Business Forecasting*”, ZHANG G.Peter, 2004, Idea Group Publishing, Chapter 1

¹⁵⁸ YAO Jing Tao, TAN Chew Lim: “*Guidelines for Financial Forecasting with Neural Networks*”, Nisan 2001

2.5.1 ÖNGÖRÜDE KULLANILACAK BİR YSA MODELLEMEK İÇİN GEREKLİ İŞLEM ADIMLARI

Öngörü yapmak için kullanılacak ağıın tasarımında dikkat edilmesi gereken adımları 8 ana başlık altında şu şekilde toplayabiliriz¹⁵⁹:

1. Adım: Değişkenin seçimi
2. Adım: Verilerin toplanması
3. Adım: Verilerin hazırlanması, bir ön işleminden geçirilmesi
4. Adım: Eğitim, test ve doğrulama verilerinin ayrıştırılması
5. Adım: Yapay Sinir Ağının Tasarlanması
 - a. Gizli katman sayısı
 - b. Gizli nöron sayısı
 - c. Çıkış nöronu sayısı
 - d. Transfer fonksiyonları
6. Adım: Hesaplama Kriterleri
7. Adım: Yapay Sinir Ağının Eğitilmesi
 - a. Eğitim devir (epoch) sayısı
 - b. Öğrenme katsayısı ve momentum
8. Adım: Uygulama

¹⁵⁹ KAASTRA Iebling, BOYD Milton: “*Designing a Neural Network for Forecasting Financial and Economic Time Series*”, Neurocomputing, 31 August 1994

2.5.1.1 Değişkenin Seçimi

Başarılı bir ağ tasarlamamanın yolu öncelikle problemi iyi anlamaktan geçer. Öngörüde bulunulacak ekonomik değeri hangi değişkenlerin etkilediğini iyi tespit etmek gerekir. Fakat YSA'nın başarısını onlarca değişkenden hangisinin etkilediğini bulmak da o kadar kolay değildir. Bu konuda yani hangi göstergelerin öngörüde bulunacağımız değeri doğrudan etkilediğini bulmada ekonomik teoriler bize yardımcı olabilir. Gelecekteki değeri tahmin edilmeye çalışılan ekonomik değişken için kullanılacak teknik ve temel ekonomik değişkenlere karar vermek gerekir. Teknik veriler o değişkenin geçmişteki değerleridir. Temel ekonomik göstergeler ise tahmin edilmeye çalışılan değişkeni etkileyen diğer ekonomik parametrelerdir. Basit yapay sinir ağları değişkenin önceki verilerinden yararlanır. Fakat ağın öngörü başarısını arttırmak için ekonomideki diğer değişkenleri de sisteme dâhil etmek gerekir. Örneğin Euro'nun gelecekteki değerini tahmin etmek için teknik veriler olarak Euro/dolar, Euro/yen paritesi kullanılabilir. Temel ekonomik göstergeler olarak da piyasadaki Euro miktarı, borsaya giren borsadan çıkan Euro miktarı, borsa verileri kullanılabilir.

2.5.1.2 Verilerin Toplanması

Araştırmacı, ilk adımda seçeceği değişkenin verilerine kolayca erişip erişemeyeceğini de hesaba katmalıdır. Teknik verileri istatistiklerden, bankalardan, merkez bankasının internet sayfası gibi yerlerden bulabilmek mümkün iken temel ekonomik değişkenlere ulaşmak o kadar da kolay olmayabilir. Toplanan verilerinde bütünlüğü gözden geçirilmelidir. Arada eksik veriler olmamalıdır. Örneğin gün gün hesaplama yapılırken özellikle borsa kapanış değerleri için hafta sonları, resmi tatiller gibi verilerin olmadığı günler de olabilir. Aradaki eksikliği kapatmak için çeşitli yöntemler uygulanabilir. Eksik gün için bir önceki ya da bir sonraki günün değeri aynen kullanılabilir. Ağı giriş hücrelerinden birisi eksik günler tahsis edilir ve eksik günler olduğunda bu hücreye girdi olarak 0

(sıfır) değeri verilebilir. Bu kararlar tamamen ağı tasarlayan kişinin tecrübesine ve tercihine kalmıştır.

Ağa girdi olarak temel ekonomik göstergeler verilecek ise dikkat edilmesi gereken 4 ana konu vardır:

- a. Seçilen ekonomik göstergeler gerçekten de öngörülmeğe çalışılan değişkenin zaman serisi üzerinde etkisi olmalıdır. Örneğin, kurulan anonim şirket sayısı belki de euronun tahmini için çok da faydalı bir ekonomik bir gösterge olmayabilir.
- b. Seçilen ekonomik göstergenin sadece şu anki değeri değil geçmişteki değerleri de edinilmeli ve ait olduğu zaman diliminde kullanılmalıdır. Örneğin bugünkü enflasyon değeri geçmişteki verilerde uygulanamaz.
- c. Birçok ekonomik göstergenin hesaplanması anlık olmadığı için (örneğin TEFE, ÜFE oranları aylık olarak açıklanmaktadır) eski verileri de kullanmak gerekebilir.
- d. Seçilen temel ekonomik gösterge sürekli olarak temin edilebilecek bir gösterge olmalıdır. Temin etmesi, öğrenilmesi zor olan bir göstergeyi ağda kullanmak doğru olmayacaktır.

2.5.1.3 Verilerin Bir Ön İşlemden Geçirilmesi

Girdi ve hedef verilerini ağa uygulamadan önce ağın kullanımına uygun bir şekilde analiz etmek ve uyarlamak gerekir¹⁶⁰. Yapay sinir ağları benzerlikleri yakalamaya çalışacağından veriyi ağa iyi ve doğru bir şekilde tanıtmak gerekir. Girdi ve hedef verileri çok nadiren ağa olduğu gibi uygulanır. Genellikle veriler ham

¹⁶⁰ YOUSEFIZADEH Hooman, ZILOUCHIAN Ali: “*Neural Network Architecturer*”, CRC Press LLC, Chapter 3, 2001

olarak değil aktivasyon fonksiyonuna da bağlı olarak (0,1) ya da (0,-1) arasında ölçeklenerek kullanılır. Geleneksel tahminde ve YSA ile yapılan tahmin işlemlerinde genel kabul görmüş olarak kullanılan iki değişik yöntem vardır. Bunlardan ilki değişkenin türevini alma diğeri ise logaritmasını almaktır. Değişkenin birinci türevi alındığında değişkendeki değişiklik miktarı bulunmuş olur. Logaritmanın alınması da verilerin küçük ya da çok büyük değerli olduklarında kullanılan bir yöntemdir.

Uygulamada kullanılması düşünülen girdi değişkenlerini ayrı ayrı test etmek gerekebilir. Yani kullanılacak olan değişkenlerin hepsini birden ağa uygulama yerine bu değişkenleri değişik kombinasyonlar ile parça parça test etmek ve toplamda ağı en az etkileyen ya da hiç etkilemeyen değişkenleri elemek ağı hızlandırmak için uygulanabilecek bir yöntemdir.

2.5.1.4 Eğitim, Test ve Doğrulama Verilerinin Ayrıştırılması

Yapay sinir ağı uygulamalarında genellikle veriler eğitim, test ve doğrulama için üç parçaya bölünür. Hangi oranlarda bölüneceğine dair kesin bir kural olmamasına rağmen genellikle eldeki verilerin %70'i eğitim, %20'si onaylama ve %10'u test için ayrılır¹⁶¹.

Test verileri tüm seri içinden rasgele seçilebileceği gibi eğitim serisinin hemen devamındaki veriler de kullanılabilir. Rasgele seçilen test verileri eğitim setinden çıkarılmamalıdır.

2.5.1.5 Yapay Sinir Ağının Tasarlanması

Bir YSA kurmak için onlarca değişik model seçeneği vardır. Ağı nörö-dinamikleri ve ağı mimarisi (yapısı) ağı tasarımını teşkil ederler. Toplama

¹⁶¹ YAO Jing Tao, TAN Chew Lim: "Guidelines for Financial Forecasting with Neural Networks", Nisan 2001

fonksiyonu, aktivasyon fonksiyonu, ağırlıklar nöro-dinamikleri oluşturur¹⁶². Ağın mimarisini de her katmandaki hücre sayısı, hücrelerin birbirlerin bağlantı şekli (ileri-geri) ve sayısı belirler.

Giriş katmanındaki hücre sayısını tespit etmek çok kolaydır çünkü bağımsız girdi değişkeni sayısı kadardır. Ağın giriş katmanında her bir değişkene ait bir hücre mevcuttur. Aynı şekilde çıkış katmanındaki hücre sayısı da bellidir çünkü o da hedeflenen çıktı sayısı kadardır. Çoğunlukla çıkış sadece bir değişken için olduğundan çıkış katmanında da bir adet hücre bulunur.

Gizli katman sayısı probleme, veri miktarına ve tasarıma bağlı olarak değişmektedir. Genellikle bir ya da iki ara katman (gizli katman) yeterlidir. Daha fazla ara katman kullanmak ağın hızını ciddi oranda düşürecektir. Ayrıca ağın öğrenmek yerine ezberlemesine de sebep olabilmektedir. Tercihen üç katmanlı yani giriş-ara-çıkış katmanlarından oluşan bir yapı kullanılabilir. Sonuç tatmin edici değilse sonradan 2 ya da 3 ara katman denenebilir. Uygulamalar göstermiştir ki toplamda 4 katmandan fazlası ağın başarı performansını ters yönde etkilemektedir.

Benzer şekilde gizli sinir hücresi sayısı için de sihirli bir formül yoktur. Bu konuda da görev tasarımcının yeteneğine düşmektedir. Bununla beraber, bazı kurallar geliştirilmiştir. Bu kurallar kesinlik içermez sadece genelde uygulanan bir yöntemdir. 3 katmanlı, n giriş hücreli ve m çıkış hücreli bir ağ için gizli katmandaki hücre sayısı ***karekök($n \times m$)*** kadar olabilir. Gizli katmandaki hücre sayısı problemin türüne ve veri sayısına göre yukarıdaki formülün 1,5 ila 2 katı arasında değişebilir. Buna geometrik piramit kuralı denmektedir. Baily ve Thompson 3 katmanlı bir ağ için gizli hücre sayısını giriş katmanındaki hücre sayısının %75'i olarak önermektedirler.¹⁶³ Katz ise optimum sayının giriş katmanındaki hücre sayısının 1,5 ila 3 katı olarak kullanılmasını önermektedir. Ersoy ise gizli hücre sayısını ağın

¹⁶² KAASTRA Iebling, BOYD Milton: “*Designing a Neural Network for Forecasting Financial and Economic Time Series*”, Neurocomputing, 31 August 1994

¹⁶³ KAASTRA Iebling, BOYD Milton: “*Designing a Neural Network for Forecasting Financial and Economic Time Series*”, Neurocomputing, 31 August 1994

performansı bozulana kadar ikiye katlayarak denemeyi önermektedir. Anlaşılacağı üzere gizli katmandaki hücre sayısı için kesin bir formül yoktur. Konunun uzmanları ise değişik önerilerde bulunmaktadır. Kesin sayı ağı yapısına, verinin miktarına, problemin türüne, tasarımcının tecrübesine kalmıştır.

Aktivasyon fonksiyonu, hücrenin çıkışı hesapladığı matematiksel formüldür. Aktivasyon fonksiyonu bazı kaynaklarda transfer fonksiyonu, eşik (threshold) fonksiyonu ya da squashing fonksiyonu olarak da adlandırılabilir. Çoğunlukla da sigmoid fonksiyon kullanılır fakat diğer alternatifler de hiperbolik tanjant, adım (step), rampa, ark-tanjant ve lineer fonksiyonlardır. Bunlardan lineer fonksiyon lineer olmayan verilerin haritalanması ve sınıflandırılması için kullanışlı değildir. Zaman serileri için Sigmoid fonksiyonu sıklıkla kullanılır. Çünkü hem nonlinear bir fonksiyon hem de her yerde türevlenebilirdir¹⁶⁴. İkili (binary) değişkenler için ise rampa ve adım fonksiyonları önerilmektedir. Standart geriye yayılım algoritmasında ise çoğunlukla giriş katmanı için lineer aktivasyon fonksiyonu, diğer katmanlar için ise sigmoid fonksiyon kullanılır.

Ham veri genellikle olduğu gibi değil (0,1) ya da (-1,1) aralığında ölçeklendirildikten sonra kullanılır.

Ölçekleme işlemi için ise aşağıdaki formül kullanılabilir:¹⁶⁵

$$SV = TF_{\min} + (TF_{\max} - TF_{\min}) \times \frac{(D - D_{\min})}{(D_{\max} - D_{\min})} \quad (3.11)$$

SV : Ölçeklenmiş değer (Scaled Value)

$TF_{\min}$: Aktivasyon fonksiyonun minimum değeri

¹⁶⁴ TEBELKIS Joe: “*Speech Recognition using Neural Networks*”, School of Computer Science Carnegie Mellon University, Pennsylvania, Doctor of Philosophy Thesis, Mayıs 1995

¹⁶⁵ KAASTRA Iebling, BOYD Milton: “*Designing a Neural Network for Forecasting Financial and Economic Time Series*”, Neurocomputing, 31 August 1994

- $TF_{\max}$: Aktivasyon fonksiyonun maksimum değeri
 D : Kullanılan değişkene ait verinin gerçek değeri
 $D_{\min}$: Verinin minimum değeri
 $D_{\max}$: Verinin maksimum değeri

Alternatif olarak aşağıda verilen bir diğer fonksiyon da verileri [-1,1] aralığında ölçeklendirir¹⁶⁶.

$$SV = \frac{2D - (D_{\max} + D_{\min})}{(D_{\max} - D_{\min})} \quad (3.12)$$

2.5.1.6 Hesaplama Kriterleri

Yapay sinir ağlarında hatayı minimize etmek için çoğunlukla kullanılan fonksiyon hata karelerinin toplamıdır. Diğerleri ise en küçük mutlak sapma, en küçük dördüncü kuvvet, en küçük asimetrik kare ve yüzde farkıdır. Bu hata fonksiyonları tek başına değil beraber de kullanılabilir. Örneğin MAPE (Mean Absolute Percentage Error – Ortalama mutlak yüzde hatası) doğal olarak ağ içinde küçültülemeyeceği için bir başka fonksiyonla birlikte kullanılır.

Borsa, döviz gibi alım satımın yapıldığı piyasalarda ağın öngörüsü, önceden kendisine öğretilen kıstaslara göre **AL** ya da **SAT** şeklinde olacaktır. Örneğin tüm çıkışlar 0.8 ya da 0.9 ise bunu AL olarak; 0.2 ya da 0.1 olursa da SAT olarak değerlendirebiliriz.

¹⁶⁶ YAO Jing Tao, TAN Chew Lim: “Guidelines for Financial Forecasting with Neural Networks”, Nisan 2001

2.5.1.7 Ağıın Eğitilmesi

Ağıın eğitilmesi yani ağa şablonu (pattern) öğretebilmemiz için elimizde veriler ve doğru cevaplar olmalıdır. Ağıın eğitilmesindeki amaç ise ağırlık kümemizdeki global minimum noktasını yani hatayı en aza indiren en uygun ağırlıkları bulabilmektir. Geriye yayılım ağlarında dereceli azaltma (gradient descent) yöntemi kullanılır. Bu yüzden bulunan minimum hata değerleri bazen global değil yerel minimum noktasında olabilir. Bunu engellemek için sisteme bir momentum değeri eklenmiştir. Ayrıca ağırlıklar için 5 ila 10 değişik başlangıç setini denemek de global minimum noktasını yakalamak için şansımızı artırır.

- a. **Eğitimdeki Devir Sayısı (epoch):** Ağıın eğitimi iki şekilde durdurulabilir. Birincisi, belirlenen bir devir sayısından sonra ikincisi ise hatanın kabul edilebilir sınırlar içerisine girmesiyle. Birinci durumda eğer devir sayısı yüksek verilirse ağ hatayı minimize ettiği halde boşu boşuna öğrenmeye çalışmaya devam edebilir. İkinci durumda da, özellikle geriye yayılım ağlarında, ağıımız yerel minimum noktasına takılıp kalabilir. Alternatif olarak, eğitilen ağın çıktıları ve hata oranları monitörde gerçek zamanlı olarak gösterilebilirse kullanıcı ağın performansında değişiklik olmadığını gördüğü an eğitimi bitirebilir.
- b. **Öğrenme Katsayısı(Oranı) ve Momentum¹⁶⁷:** Daha önceden de bahsettiğimiz gibi, geriye yayılım ağları hata yüzeyini tararken dereceli azaltma tekniğini kullanır. Amaç aşağıda formüle edildiği gibi hata kareleri toplamını en aza indirebilmektir.

¹⁶⁷Bu başlık altındaki formüller: KAASTRA Iebling, BOYD Milton: “*Designing a Neural Network for Forecasting Financial and Economic Time Series*” ve FREEMAN James, SKAPURA David: “*Neural Networks Algorithms, Applications, and Programming Techniques*”, Addison-Wesley Publishing Company, 1991

$$E = \frac{1}{2} \sum_h^M E_h = \frac{1}{2} \sum_h^M \sum_i^N (t_{hi} - O_{hi})^2 \quad (3.13)$$

Burada;

E : Ağın toplam hatası

E_h : h örneğinin hata miktarı

h : Girdi verilerinin sayacı

i : Çıkış hücresinin sayısı

t_{hi} : i . çıkış hücresinin h örneğine göre hedeflenen çıktısı

O_{hi} : i . çıkış hücresinin h örneğine göre hesaplanan çıktısı

i ve j hücreleri (nöronları) arasındaki ağırlığı ayarlamak için kullanılan formül ise;

$$\delta_{hi} = (t_{hi} - O_{hi}) O_{hi} (1 - O_{hi}) \quad (3.14)$$

$$\delta_{hi} = O_{hi} (1 - O_{hi}) \sum_k^N \delta_{hk} w_{jk} \quad (3.15)$$

$$\Delta w_{ij}(n+1) = \varepsilon (\delta_{hi} O_{hi}) \quad (3.16)$$

Burada;

n : Geçerli devir sayısı

δ_{hi} : i . hücrenin h örneğine göre hatası

ε : öğrenme katsayısıdır.

Öğrenme katsayısı ε ağırlıkların değiştirilmesinde kullanılan sabit bir sayıdır. Öğrenme katsayısının çok küçük ya da çok büyük seçilmesinin sakıncalarından Geriye Yayılım Algoritması başlığı altında daha ayrıntılı olarak bahsedilmiştir.

Örneğin öğrenme katsayısını çok küçük seçmek eğitim zamanını arttırmaktadır. Bu yüzden ağı hızlandırmak için formüle bir de momentum terimi eklenir.

Momentum terimi, ağırlıktaki önceki değişimlerin geçerli ağırlık değişimini nasıl etkileyeceğini belirler. Formülümüze momentum terimini de eklersek aşağıdaki haline gelir:

$$\Delta w_{ij}(n+1) = \varepsilon(\delta_{hi}O_{hi}) + \alpha\Delta w_{ij}(n) \quad (3.17)$$

Burada α momentum terimidir.

2.5.1.8 Uygulama

Ağımız eğitildikten ve testlerden de başarıyla geçtikten sonra kullanıma hazırdır. Ağı yeni verileri de kullanarak belli aralıklarla eğitilmesi ağı başarısını ve güvenilirliğini arttıracaktır.

Unutmamak gerekir ki yapay sinir ağları özellikle finansal değerlerin alım satım kararlarının verilmesinde tek karar mercii değildir. YSA'lar destekleyici araçlar olarak kullanılmalıdırlar. Ayrıca, kâğıt üzerindeki başarı ile gerçek hayattaki başarıyı birbirine karıştırmamak gerekir. Örneğin akademik çalışmalarda %100 başarılı sonuç için uğraşılırken endüstride veya piyasalarda %60'lık bir öngörü başarısı oldukça iyi bir sonuçtur¹⁶⁸. Çünkü zaten %100 öngörü diye bir şey olamaz. Ne YSA'lar ne de herhangi bir yöntem bunu garanti edemez.

¹⁶⁸ YAO Jing Tao, TAN Chew Lim: "Guidelines for Financial Forecasting with Neural Networks", Nisan 2001

BÖLÜM III

3 UYGULAMA

3.1 GİRİŞ

Tezimizin bu bölümünde, daha önceki bölümlerde anlatılanlar doğrultusunda; bir zaman serisi niteliğinde olan USD'nin gelecekteki değerini tahmin edebilmek ve doğru bir AL / SAT / BEKLE kararı verebilmek için YSA'lerden yararlanacağız. Uygulamaya çalıştığımız işlem için kesin, belirli ve doğru bir yöntem mevcut değildir. Bu nedenle değişik mimarilerde, katman ve nöron sayılarında, değişik eğitim algoritmaları ve aktivasyon fonksiyonları denenerek en uygun ağ yapısı bulunmaya çalışılacaktır.

Ağın tasarımı ve çalıştırılmasında Mathworks firmasının MATLAB yazılımının 7.0 sürümü ve beraberinde gelen Neural Network Toolbox'ın 4.0 sürümü kullanılmıştır. Çalışmalar Pentium IV 2.0 Ghz tabanlı, 512 Mb RAM'e sahip bir PC'de gerçekleştirilmiştir. Bir sonraki başlık altında verilecek olan sonuçları değerlendirirken özellikle de ağın eğitilmesi sırasında geçen süreyi kıyaslarken çalışılan bilgisayarın özellikleri göz önünde bulundurulmalıdır.

Uygulama için MATLAB yazılımında çalıştırılmak üzere programlar geliştirilmiştir¹. Kullanılan veriler ve açıklamaları “VERİ” başlığı altında; kodların çalıştırılması ile elde edilen bulgular da “BULGULAR” başlığı altında sunulmuştur.

¹ Örnek kodlar için bakınız EK-2. Diğer kodları tezin ekinde verilmiş olan CD içerisinde bulabilirsiniz.

3.2 VERİ

Uygulamamızda kullanılan tüm veriler² T.C. Merkez Bankası'nın web sitesinden³ elde edilmiştir. Verilerin başlangıç tarihi 4 Ocak 1999'dur. Son kullanılan veri ise 28 Şubat 2006 tarihli'dir. İki tarih arasında toplam 1867 iş günlük veri kullanılmıştır. Toplamda 42 ayrı değişken için $42 \times 1867 = 78414$ adet değer hesaba katılmıştır.

Çalışmada kullanılan verilerin tamamı ve daha fazlası günlük olarak T.C. Merkez Bankası'nın resmi web sitesinde yayınlanmaktadır. Siteyi kullanarak verileri günlük, aylık gibi değişik şekillerde elde etmek de mümkündür. Bazı veriler aylık olarak yayınlanmaktadır. Bu tipteki verileri günlüğe çevirmek için yine web sitesinin sunduğu imkânlardan faydalanılmıştır. Web sitesinden tüm veriler: İş günü, Doğrusal ve Orijinal Gözlem formatında alınmıştır.

YSA'lar, kendilerine girdi olarak verilen parametre ve değişken sayısı ile doğru orantılı olarak daha başarılı ve hatasız sonuçlar üretirler. Fakat YSA'ların eğitimi sırasında verilerin doğru ve eksiksiz olması gerekir. Çünkü ağ, verileri hiç yorumlamadan kendi eğitiminde kullanacaktır. Yanlış veriler girilirse doğru zannederek öğrendikleri yanlış olacak ve dolayısı ile yanlış sonuçlar üretecektir.

3.3 YÖNTEM

Uygulamamızda USD'nin gelecekteki değerini en doğru şekilde tahmin edebilmek için öncelikle en uygun YSA'nın hangisi olacağı, nasıl bir mimariye sahip olacağını belirlemek gerekir. YSA'nın katman sayısı, katmanlardaki nöron (hücre) sayısı, aktivasyon fonksiyonu, öğrenme kuralı da ağın tasarımında önemli parametrelerdir.

² Kullanılan veriler için EK-1'e bakınız.

³ www.tcmb.gov.tr ve [http://tcmbf40.tcmb.gov.tr/cgi-bin/famecgi?cgi=\\$cbtweb&DIL=TR](http://tcmbf40.tcmb.gov.tr/cgi-bin/famecgi?cgi=$cbtweb&DIL=TR)

Ağımızda, zaman serilerinin tahmin edilmesinde en çok kullanılan yöntem olan geriye yayılım algoritması kullanılmıştır. Ağın çıkış katmanındaki nöron sayısı, tek çıkışımız USD değeri olduğu için 1'dir. Giriş katmanındaki nöron sayısı ise giriş parametresi kadar yani 41 adettir.⁴ Ara katman sayısı ve katmanlardaki hücre sayısı için belirli bir kural yoktur. Tezimizde önceki bölümde de anlatıldığı üzere, bu konuda daha önceden çalışmış olan uzmanların görüşleri doğrultusunda değişik sayılarda katman ve nöron kullanılmıştır. Sonuçlar ve karşılaştırmaları bir sonraki başlık altında değerlendirilecektir.

Kullandığımız veriler ile USD'nin gelecekteki değerini tahmin edebilmek için en uygun, performansı en yüksek YSA'yı bulmak için öncelikle, MATLAB'in sunmuş olduğu eğitim algoritmaları kendi aralarında karşılaştırılmıştır. Bunlar⁵:

- **traingd**: En temel “gradient descent” yani dereceli azaltma algoritmasıdır. Uygulamamızda da tespit ettiğimiz gibi yavaş çalışan bir algoritmadır.
- **traingdm**: “Gradient descent” algoritmasına momentum değişkeninin eklenmiştir. Genellikle traingd algoritmasından daha hızlı çalışır.
- **traingdx**: Temeli traingd algoritmasına dayanır fakat daha hızlıdır. Sadece “batch mode”⁶ eğitimde kullanılır.
- **trainrp**: Bilgisayarlar için daha az hafıza/disk alanı ve işlem gücü gerektiren “batch mode” eğitimde kullanılan oldukça hızlı bir algoritmadır. “Resilient Backpropagation” yani esnek ve hatalarını çabuk telafi eden bir geriye yayılım algoritmasıdır.

⁴ Bakınız EK-1

⁵ Burada kısaca ne olduğu açıklanmaya çalışılan eğitim algoritmalarının ayrıntılarına MATLAB'in kendi yardım dosyalarından ulaşılabilir.

⁶ Batch Mode Eğitim: Eğitim sırasında elde edilen yeni ağırlıkların ve biasların ancak tüm girdilerin ve çıktılarının ağırlıklanmasından sonra güncellendiği algoritmadır. Statik ve dinamik yapay sinir ağlarında kullanılabilir.

- **traincgf**: Fletcher-Reeves tekniğini kullanan “conjugate gradient (CG)⁷” algoritmasıdır. Standart CG algoritmasına göre daha az işlem gerektirir.
- **traincgp**: Polak-Ribiere tarafından geliştirilen CG algoritmasıdır. traincgf’ye göre daha fazla hafıza ve işlem gücü gerektirir. Fakat bazı problemlerin çözümünde çözüme daha hızlı yakınsar.
- **traincgb**: Powell-Beale CG algoritmasıdır. traincgp’den daha fazla hafıza ve işlem gücü gerektirir fakat genellikle çözüme daha hızlı yakınsar.
- **trainscg**: Ölçeklendirilmiş CG algoritmasıdır. (Scaled Conjugate Gradient) Genel amaçlı bir eğitim algoritması olarak kullanılabilir.
- **trainbfg**: BFGS quasi-Newton yöntemidir. CG algoritmasına göre daha fazla işlem gerektirmesine rağmen sonuca daha az devirde (iterasyonda) ulaşır.
- **trainoss**: One Step Secant (Tek Adım Sekant) yöntemidir. CG algoritması ile quasi-Newton algoritmasını birleştiren bir yöntemdir.
- **trainlm**: Levenberg-Marquardt ‘ın geliştirdiği bir algoritmadır. Orta ölçekli ağlar için oldukça hızlı çalışır.
- **trainbr**: Bayesian Regularization yöntemidir. Levenberg-Marquardt eğitim algoritmasından türetilmiştir. Optimum ağ yapısının bulunmasında kolaylıklar sağlar. Hata kareleri toplamı ve ağırlıkların kombinasyonunu minimize etmeye çalışır.

⁷ Standart geriye yayılım algoritması ağırlıkları “steepest descent” yönünde yani hatanın azaldığı yönün tersine doğru ayarlamaya çalışır. Böylece hızlı çalışmış olur fakat gerçek değere yakınsamada çok başarılı olmaz. Conjugate azaltmada ise ağırlıkların ayarlanması işlemi conjugate yönünde yani hata azaltmasının olduğu yöne doğru yapılır. Bu sebeple standart geriye yayılma algoritmasına göre gerçek değere daha fazla yakınsar. Çok az hafıza alanı ve işlem yükü gerektirdiği için büyük ağlarda tercih edilebilir.

Her bir eğitim algoritması değişik ağ mimarilerinde en az 5'er kez çalıştırılarak uygulamamızda kullandığımız veri setimiz ve hedefimiz için en hızlısı ve doğru çözüme en fazla yakınsayarı bulunmaya çalışılmıştır. Karşılaştırma sonucunda bulunan en başarılı ve hızlı algoritma, eğitim algoritması olarak seçilmiş ve kullanılmıştır. Eğitimde, onaylamada ve testte kullanılacak veriler sırasıyla elimizdeki tüm verinin %70'i, %20'si ve %10'u olacak şekilde ayrılmıştır. Ayrılmış bu veriler, MATLAB'in eğitim komutu olan "train" komutuna parametre olarak girilmiştir. Bu komut sayesinde ağıımızı belirli bir devir sayısı kadar (epoch), ya da belirli bir başarı elde edilene kadar, ya da artık eğitime işlemi belirli bir oranın üzerinde katkı sağlamayana kadar eğitebiliriz. Komut aynı zamanda ekranda görsellik sağladığı için istediğimiz bir anda eğitimi de kesmemiz mümkündür. Bu sayede gereksiz yere ağıımızı daha fazla eğitmemize ve dolayısıyla daha fazla zaman harcamamıza gerek kalmamaktadır. Bu işleme "early stopping" yani erken durdurma denilmektedir.⁸


Ağa uygulanan verilerin değerleri geniş bir aralıktadır ve birbirleri arasında da oransızdır. Bu verilerin doğrudan doğruya ağa uygulanması ağın yanlış eğitilmesine ve dolayısı ile yanlış sonuçlar üretmesine neden olur. Bu nedenle veriler ağa uygulanmadan önce MATLAB'in "prestd" komutu ile bir ön işlemden geçirilerek ölçeklendirilmiş ve ağın çıkışında da bu sefer de "poststd" komutu ile ardıl bir işlemden geçirilerek orijinal ölçeğine getirilmiştir.

YSA'ların eğitimi sırasında önemli parametreler olan öğrenme katsayısı ve momentum değerleri yine MATLAB'in komutlarından "init(net)" komutu kullanılarak otomatik olarak rasgele olarak üretilmiş ve ağa uygulanmıştır.

Ağın eğitim sırasında, eğer ağ eğitmek yerine ezberliyorsa ve/veya yerel bir minimuma takılıyorsa aşağıdaki şekilde de görülebileceği gibi hatalı sonuçlar üretecektir. Bu durumda ağın başlangıç değerleri yeniden düzenlenerek eğitim işlemleri tekrarlanmıştır. Aşağıdaki grafikte mavi ile çizilmiş (0.34 değerinden

⁸ DEMUTH Howard, BEALE Mark: "Neural Network Toolbox For Use with MATLAB", Eylül 2000

başlayan) grafik USD'nin gerçek değeri ve kırmızı ile çizilmiş olan (1,5 değerinden başlayan) grafik ise ağıın ürettiği tahmin değerleridir.



Şekil 25 – Ağıın yerel minimuma takılmasının sonucu

3.4 BULGULAR

Uygulamayı gerçekleştirebilmek üzere öncelikle değişik mimarilerde ağların oluşturulması öngörülmüştür. Bu amaçla, MATLAB yazılımı için kodlar yazılarak çalıştırılmıştır⁹. Geliştirilen MATLAB kodlarına EK-3'de verilmiş olan tabloya uygun olarak dosya isimleri verilmiştir¹⁰. Kodların çalıştırılmasıyla elde edilen sonuçlar aşağıda verilmiştir.

3.4.1 ACXY. M Grubunda Denenen YSA'lar

Aynı zamanda MATLAB kod dosyasının da ismi olan ACxy kodlu ağlar:

A: USD'nin ertesi günkü gerçek değerini elde etmeye çalışan,

C: 2001 krizinin verilerini de içeren

⁹ Örnek kodlar için bakınız EK-2. Diğer kodları tezin ekinde verilmiş olan CD içerisinde bulabilirsiniz.

¹⁰ Örnek: ACE01.M dosyası; 2001 krizinin verilerini de içererek ABD dolarının ertesi günkü değerini tahmin etmeyi hedefleyen, trainbfg eğitim algoritmasını kullanan bir geriye yayımlı; 5 adet nörona sahip bir gizli katmanı olan ve sırasıyla tansig-purelin aktivasyon fonksiyonlarını kullanan bir YSA'dır.

yapay sinir ağıdır. Buradaki

X: Eğitim algoritmasının kodunu (E-P arası),

Y: Ağın mimarisini (01–12 arası)

işaret eder.

3.4.1.1 tansig-purelin / 5–1 Yapısı (ACx01)

Bu grupta denenen ağlar 5–1 yapısının da işaret ettiği gibi 1 adet gizli katmana sahiptir ve gizli katmanında da 5 adet nöron ihtiva etmektedir. Katmanlardaki nöronlarda da sırasıyla tansig ve purelin fonksiyonları kullanılmıştır.

Bu yapıdaki tüm ağlar daha önceden kısaca tanıtılmış olan 12 farklı eğitim algoritması ile ayrı ayrı denenerek aşağıdaki sonuçlar elde edilmiştir. Her bir ağ en az 5'er kez çalıştırılarak ortalama bir değer elde edilmiştir.

		Devir (Epoch)	Süre (sn)	Hata Oranı
E	trainbfg	19,8	1,948800	0,003740
F	trainbr	29,0	8,089600	0,000642
G	traincgb	22,0	1,740600	0,011400
H	traincgf	20,6	1,568200	0,002960
I	traincgp	22,8	1,738600	0,005560
J	traingd	1815,6	43,196600	0,026860
K	traingdm	37,2	1,754800	0,052620
L	traingdx	32,8	1,500200	0,037420
M	trainlm	14,6	3,593000	0,005411
N	trainoss	21,2	1,522400	0,031900
O	trainrp	12,8	0,999800	0,021480
P	trainscg	19,6	1,375800	0,007440


Tablo 12 – ACx01 grubunda çalıştırılan ağlara ait veriler

Tablo incelendiğinde eğitim algoritmaları arasında;

En Doğru :trainbr
 En Hızlı :trainrp
 En Hatalı :traingdm
 En Yavaş :traingd

olduğu görülecektir. En hızlı algoritmanın trainrp olmasına karşın elde ettiği başarı oranının düşük olması nedeni ile tercih edilmemiştir. En doğru sonucun öncelikli hedef olduğu denemelerimizde **trainbr** hem yüksek başarı oranı hem de yeterli derecede hızlı olması nedeniyle uygulamamızda tercih edilebilir bir algoritma olarak karşımıza çıkmaktadır.

ACx01 grubunda en başarılı sonucu veren trainbr algoritmasının ürettiği sonuca dair grafik aşağıdaki gibidir.



Şekil 26 – ACF01 kodlu YSA'nın ürettiği grafikler

Şeklin üstteki bölümünde hedef değerleri mavi ile (üstte kalan kısım) tahmin sonucu kırmızı ile (altta kalan kısım) gösterilmiştir. Şeklin sol alt kısmında eğitim sonucunda elde edilen veriler gösterilmektedir. Grafikte; ağın eğitimi sırasında eğitim, onaylama ve test veri gruplarına ne kadar yakınsandığı gösterilmektedir. Şeklin sağ alt bölümünde ise hedef değer ile tahmin değerleri arasındaki farkın grafiği görüntülenmektedir. Dikkat edilirse hata miktarı kriz döneminde ve son dönemde artmaktadır. Kriz dönemindeki USD değerinin ani sıçramalar yapması ve geniş bir aralıkta salınması hata miktarının artmasına etken olmaktadır. Ağımızın tahmin başarısını esasen son dönemdeki yani yaklaşık olarak tüm verinin %10'una denk gelen 1680. günden sonraki 186 günlük veri göstermektedir. Bu dönemde ağın hatasının arttığı grafikten görülebilir. Zaten hedef özellikle bu son dönemdeki hatanın minimize edilmesi ve daha başarılı bir tahmin yapılabilmesidir.

ACx01 grubunda elde edilen diğer sonuçlar EK- 4'de bulunmaktadır¹¹.

¹¹ Tüm denemelere dair sonuçları ve elde edilmiş grafikleri tezimizin ekinde verilmiş olan CD içerisinde AC01.XLS ismi ile kayıt edilmiş Excel dosyasında bulabilirsiniz.

3.4.1.2 logsig-purelin / 5–1 Yapısı (ACx04)

Bu grupta denenen ağırlar da 1 adet gizli katmana sahiptir ve gizli katmanında da 5 adet nöron ihtiva etmektedir. Katmanlardaki nöronlarda da sırasıyla logsig ve purelin fonksiyonları kullanılmıştır. Ağların çalıştırılması sonucunda elde edilen sonuçlara dair veriler aşağıdaki gibidir.

		Devir (Epoch)	Süre (sn)	Hata Oranı
E	trainbfg	29	2,82180	0,00286
F	trainbr	29	8,43640	0,00197
G	traincgb	14	1,62020	0,01496
H	traincgf	17	1,68600	0,00918
I	traincgp	19,2	1,8168	0,00446
J	traingd	248	7,04780	0,03168
K	traingdm	236	7,08040	0,07982
L	traingdx	63	2,39120	0,03320
M	Trainlm	17	4,37720	0,00198
N	trainoss	30	2,13640	0,00508
O	trainrp	23	1,41220	0,00420
P	trainscg	30	2,13500	0,00254

Tablo 13 – ACx04 grubunda çalıştırılan ağırlara ait veriler

Tablo incelendiğinde eğitim algoritmaları arasında;


En Doğru :trainbr
 En Hızlı :trainrp
 En Hatalı :traingdm
 En Yavaş :trainbr

olduğu görülecektir. En hızlı algoritma bu denemede de trainrp olarak tespit edilmiştir. Burada da elde ettiği başarı oranının düşük olması nedeni ile tercih edilmemiştir. En doğru sonucun öncelikli hedef olduğu denemelerimizde **trainbr** hata oranı en düşük algoritma olarak karşımıza çıkmaktadır. Fakat bu denemede trainbr aynı zamanda diğerlerine göre en yavaş algoritma olarak da karşımıza

çıkılmaktadır. Bunun nedeni diğer yöntemlerin (özellikle traingdm'nin) eğitim sırasında yerel minimuma takılarak eğitimden erken çıkmasıdır. Dolayısı ile burada da trainbr en yüksek doğruluk oranını kabul edilebilir bir süre içerisinde yakaladığı için ilerideki uygulamalarda kullanılacak eğitim algoritması olarak tercih edilmiştir.

logsig ve tansig algoritmaları kendi aralarında kıyaslandığında ise, tansig aktivasyon fonksiyonu çok büyük farkla olmasa da daha başarılı sonuçlar alınmasını sağlamıştır. Hız ve doğruluk açısından bakıldığında tansig fonksiyonu kullanan tek gizli katmanlı ağılar, uygulamamızda daha başarılı sonuçlar vermiştir.

ACx04 grubunda en başarılı sonucu veren trainbr algoritmasının ürettiği sonuca dair grafik aşağıdaki gibidir.



Şekil 27 – ACF04 kodlu YSA'nın ürettiği grafikler

ACx04 grubunda elde edilen diğer sonuçlar EK - 5'de bulunmaktadır¹².

¹² Tüm denemelere dair sonuçları ve elde edilmiş grafikleri tezimizin ekinde verilmiş olan CD içerisinde AC04.XLS ismi ile kayıt edilmiş Excel dosyasında bulabilirsiniz.

3.4.1.3 Diğer Mimarilerde trainbr Kullanımı (ACFy)

Uygulamamızda trainbr'nin en başarılı eğitim algoritması olduğunun görülmesinden sonra diğer ağ mimarilerinde de çalıştırılmıştır. Değişik katman ve nöron sayılarına sahip ağlarda elde edilen sonuçlar aşağıda verilmiştir.¹³

		Epoch	Süre	Hata Oranı
1	5-1 / tansig-purelin	29	8,0896	0,000641824
2	9-1 / tansig-purelin	30,6	26,6542	0,001199548
3	30-1 / tansig-purelin	17,4	235,4848	0,000736794
4	5-1 / logsig-purelin	28,8	8,4364	0,001966464
5	9-1 / logsig-purelin	20,8	6,3092	0,000980608
6	30-1 / logsig-purelin	16	208,6862	0,001671422
7	4-9-1 / tansig-tansig-purelin	25	7,8474	0,002951716
8	9-13-1 / tansig-tansig-purelin	20,2	29,3018	0,001348638
9	4-9-1 / logsig-logsig-purelin	16,4	5,8526	0,002322532
10	9-13-1 / logsig-logsig-purelin	20,6	28,9198	0,001736444
11	4-9-1 / tansig-logsig-purelin	23,4	7,6428	0,001114126
12	9-13-1 / tansig-logsig-purelin	23,2	33,1254	0,001279554
	ORTALAMA	22,6167	50,52918	0,001495806

Tablo 14 – ACF grubunda çalıştırılan ağlara ait veriler

Her bir ağ en az 5 kez denenmiş ve ortalama değerleri bu tabloya yazılmıştır. Denemelerin sonuçlarının yazılmış olduğu tabloya göre;

- Aktivasyon fonksiyonu olarak tansig ya da logsig kullanmak arasında fonksiyonu kayda değer bir fark olmamasına rağmen tansig daha başarılı görünmektedir,

- Tek gizli katmanlı ağlarda gizli nöron sayısının artması sonuca olumlu yönde çok fazla katkı yapmamaktadır fakat beklenildiği gibi ağın sonuç üretmesi daha geç olmaktadır,

¹³ Tüm denemelere dair sonuçları ve elde edilmiş grafikleri tezimizin ekinde verilmiş olan CD içerisinde ACF. XLS ismi ile kayıt edilmiş Excel dosyasında bulabilirsiniz.

- Çift gizli katmanlı ağlarda tansig ve logsig fonksiyonunun birlikte kullanılması tek başlarına kullanılmalarına nazaran doğruluk oranını arttırmaktadır,
- Çift katmanlı bir ağ tek katmanlı bir ağa göre avantajlı görünmemektedir.

Her bir denemeye ait bulgular EK-6'da verilmiştir.

3.4.2 Kriz Sonrasındaki Verilerle Yapılan Denemeler

Aynı zamanda MATLAB kod dosyasının da ismi olan ADFy kodlu ağlar:

A: USD'nin ertesi günkü gerçek değerini elde etmeye çalışan,

D: Kriz sonrası verileri içeren

F: Sadece trainbr eğitim algoritmasının kullanıldığı

yapay sinir ağlarıdır. Buradaki

Y: Ağın mimarisini işaret eder. (01 ve 11)

	Epoch	Süre	Hata Oranı
5-1 / tansig-purelin	15,6	3,7754	0,000215158
4-9-1 / tansig-logsig-purelin	13,8	3,7916	0,000199816
ORTALAMA	14,7	3,7835	0,000207487

Tablo 15 – ADF grubuna ait veriler

Sadece kriz sonrası veriler kullanılarak yapılan denemelerde başarı oranı beklenildiği gibi daha yüksek çıkmıştır. Veri sayısı azaldığı için ağın hızlanması da diğer bir beklenen sonuçtur. Tek gizli katmanlı ağ ile çift katmanlı ağ arasında tablodan da görüldüğü üzere kayda değer bir fark bulunmamaktadır.

Her bir denemeye ait bulgular EK-7'de verilmiştir.

3.4.3 Döviz Kurunun Yönünün Belirlenmesine Dair Yapılan Çalışmalar

BCFY.M grubu:

B: USD'nin 5 gün sonra çıkacağını ya da düşeceğini tahmin etmeye çalışan,

C: 2001 krizinin verilerini de içeren

F: Sadece trainbr eğitim algoritmasının kullanıldığı

yapay sinir ağıdır. Buradaki

Y: Ağın mimarisini (01-12 arası)

işaret eder.

Bu YSA grubu ile yapılan denemelerde USD'nin 5 gün sonraki değerinin bugünkü değerinden yüksek mi yoksa düşük mü olacağının tespiti yapılmaya çalışılmıştır. Ağımız; 5 gün sonra USD bugünkü değerinden %1 daha yüksek ise çıktısı (1,0) ve %1 daha düşük ise çıktısı (0,1) olacak şekilde çift çıkış katmanlı olarak kurulmuştur. Eğer doların değerindeki değişiklik %1'den daha az ise ağımızın çıktısı (0,0) olacaktır. Burada;

1,0 : AL

0,1 : SAT

0,0 : BEKLE

şeklinde de değerlendirilebilir. Sürekli al, sat işlemi yaptırmamak doların değerinde %1 değişiklik şartı konmuştur.

3.4.3.1 trainbr / tansig-purelin / 5-2 Yapısı (B2CF01)

2001 krizini de içeren toplam 1863 veri içerisinde;

AL : 460
 SAT : 357
 BEKLE :1046

adet olacak şekilde gerçekleştirilmektedir.

Doğru Bulunan	Epoch	Süre	AL	SAT	BEKLE	Genel Performans	AL Oranı	SAT Oranı	BEKLE Oranı
1	10	7,111	45	46	1002	58,6688	9,783	12,885	95,793
2	13	8,462	44	81	978	59,2056	9,565	22,689	93,499
3	10	6,289	41	22	1017	57,9710	8,913	6,162	97,228
4	9	6,139	18	52	1003	57,5953	3,913	14,566	95,889
5	9	5,959	79	83	952	59,7960	17,174	23,249	91,013
6	11	7,021	56	71	922	56,3070	12,174	19,888	88,145
7	10	6,389	50	38	1007	58,7762	10,870	10,644	96,272
8	8	5,528	23	44	1006	57,5953	5,000	12,325	96,176
9	10	6,720	57	27	1000	58,1857	12,391	7,563	95,602
10	12	7,751	31	54	998	58,1320	6,739	15,126	95,411
ORTALAMA	10	6,7369	44	52	989	58,2233	9,6522	14,5098	94,5029

Tablo 16 – B2CF01 ağına ait veriler

Yapılan 10 başarılı denemenin sonunda ağın performansına bakıldığında, ortalama olarak %58.2233 olarak bulunmuştur. Esasen çok başarılı bir tahmin olarak görünmese de daha önce de belirttiğimiz gibi piyasalarda %60’lık bir öngörü oldukça başarılı bir sonuçtur¹⁴.

¹⁴ YAO Jing Tao, TAN Chew Lim: “Guidelines for Financial Forecasting with Neural Networks”, Nisan 2001

3.4.3.2 trainbr / tansig-logsig-purelin / 4-9-2 Yapısı (B2CF11)

Çift katmanlı ve gizli katmanlarında sırasıyla 4 ve 9 adet gizli nöron bulunan, çift çıkışlı bu ağımla yapılan çalışmaların sonucu aşağıdaki tabloda verilmiştir.

Doğru Bulunan	Epoch	Süre	AL	SAT	BEKLE	Genel Performans	AL Oranı	SAT Oranı	BEKLE Oranı
1	8	6,149	58	3	1033	58,7225	12,609	0,840	98,757
2	13	8,322	63	66	910	55,7703	13,696	18,487	86,998
3	11	7,571	32	7	1004	55,9850	6,957	1,961	95,985
4	10	6,960	2	26	1013	55,8776	0,435	7,283	96,845
5	12	7,631	8	129	948	58,2394	1,739	36,134	90,631
6	9	6,039	48	12	954	54,4283	10,435	3,361	91,205
7	11	7,210	2	17	1043	57,0048	0,435	4,762	99,713
8	10	7,131	51	62	958	57,4879	11,087	17,367	91,587
9	12	7,692	17	99	932	56,2534	3,696	27,731	89,101
10	14	8,973	27	105	970	59,1519	5,870	29,412	92,734
ORTALAMA	11	7,3678	31	53	977	56,8921	6,6957	14,7339	93,3556

Tablo 17 – B2CF11 ağına ait veriler

Bu YSA ile yapılan 10 başarılı denemenin sonunda ağıın performansına bakıldığında, ortalama olarak %56.8921 olarak bulunmuştur. Bir önceki YSA ile kıyaslandığında çift gizli katmanlı ağ kullanmamızın hız ve başarı performansı açısından bir avantaj sağlamadığı hatta daha az başarılı sağladığı söylenebilir.

3.4.4 BDFY. M Grubunda Denenen YSA'lar

B: USD'nin 5 gün sonra çıkacağını ya da düşeceğini tahmin etmeye çalışan,

D: Sadece kriz sonrası verileri içeren,

F: Sadece trainbr eğitim algoritmasının kullanıldığı

yapay sinir ağıdır. Buradaki

Y: Ağın mimarisini (01–12 arası)

işaret eder.

3.4.4.1 trainbr / tansig-purelin / 5–2 Yapısı (B2DF01)

Kriz sonrası toplam 723 veri içerisinde;

AL : 128

SAT : 167

BEKLE : 428

adet olacak şekilde gerçekleştirilmektedir.

Doğru Bulunan	Epoch	Süre	AL	SAT	BEKLE	Genel Performans	AL Oranı	SAT Oranı	BEKLE Oranı
1	11	3,063	49	48	319	57,5380	38,281	28,743	74,533
2	9	2,703	43	41	401	67,0816	33,594	24,551	93,692
3	9	2,750	32	23	376	59,6127	25,000	13,772	87,850
4	8	2,422	49	27	370	61,6874	38,281	16,168	86,449
5	9	2,562	41	27	388	63,0705	32,031	16,168	90,654
6	10	2,860	42	46	383	65,1452	32,813	27,545	89,486
7	8	2,422	39	90	322	62,3790	30,469	53,892	75,234
8	10	2,890	30	57	357	61,4108	23,438	34,132	83,411
9	10	2,844	42	35	387	64,1770	32,813	20,958	90,421
10	10	2,875	34	37	368	60,7192	26,563	22,156	85,981
ORTALAMA	9	2,7391	40	43	367	62,2822	31,3281	25,8084	85,7710

Tablo 18 – B2DF01 ağına ait veriler

Yapılan 10 başarılı denemenin sonunda ağın performansı ortalama %62.2822 olarak bulunmuştur. %60'lık bir öngörünün başarılı bir sonuç kabul edildiği düşünülürse ağımızın oldukça başarılı sonuç verdiğini söyleyebiliriz. Başarının yüksek olmasının bir nedeni de 2001 krizinin verilerini içermiyor olmasıdır. Serimizde ani inişler çıkışlar daha az olduğu için ağın öngörü performansı daha yüksek çıkmıştır.

3.4.4.2 trainbr / tansig-logsig-purelin / 4-9-2 Yapısı (B2DF11)

Çift katmanlı ve gizli katmanlarında sırasıyla 4 ve 9 adet gizli nöron bulunan, çift çıkışlı bu ağımızla sadece kriz sonrası verilerle yapılan çalışmaların sonucu aşağıdaki tabloda verilmiştir.

Doğru Bulunan	Epoch	Süre	AL	SAT	BEKLE	Genel Performans	AL Oranı	SAT Oranı	BEKLE Oranı
1	13	3,780	20	16	402	60,5809	15,625	9,581	93,925
2	9	2,937	14	15	415	61,4108	10,938	8,982	96,963
3	11	3,344	8	14	422	61,4108	6,250	8,383	98,598
4	10	3,093	13	8	397	57,8147	10,156	4,790	92,757
5	10	3,063	4	1	425	59,4744	3,125	0,599	99,299
ORTALAMA	11	3,2434	12	11	412	60,1383	9,2188	6,4671	96,3084

Tablo 19 – B2DF11 ağına ait veriler

Bu YSA ile yapılan yüzden fazla denemenin sonucunda ancak 5 adet başarılı sonuç alınmıştır. Başarı performansının %60.1383 gibi yüksek olmasına rağmen ağın eğitimi sırasında çok fazla ezberleme ve yerel minimuma takılma gözlenmiştir. Dolayısı ile bir önceki tek katmanlı YSA'ya göre tercih edilmesini gerektirecek bir avantajı bulunmamaktadır.

3.4.5 Elman Ağları İle Yapılan Denemeler

Geri dönüşlü YSA'lerden olan Elman Ağının performansını denemek için, bir Elman YSA kurularak USD'nin ertesi gün alacağı değer tahmin edilmeye çalışılmıştır. Ağın mimarisi daha önceki uygulamalarda da olduğu gibi tek katmanlı ve çift katmanlı olarak iki farklı şekilde oluşturulmuştur. Çalışmanın sonucunda aşağıdaki bulgular elde edilmiştir.

	Epoch	Süre	Hata Oranı
5-1 / tansig-purelin	29,4	9,3	0,000501534
4-9-1 / tansig-logsig-purelin	18,6	10,397	0,000916436
ORTALAMA	24	9,8485	0,000708985

Tablo 20 – Elman ağına ait veriler

Tablodan da anlaşılabileceği üzere 2 gizli katmanlı bir yapı kullanmanın ağın doğruluk performansını arttırmadığı gibi ağın hızını da yavaşlatmıştır. Daha önceki uygulamalarda da aynı sonucu elde etmiştik. Elman ağının hata oranının GYA kullanan ağlara göre biraz daha düşük olduğu görülmektedir. Bunun nedeni özellikle, doların değerindeki ani iniş çıkışları eğitim sırasında daha iyi tolere edebilmesidir. Ağ, daha önceden karşılaştığı değerlere ilişkin daha başarılı bir tahmin performansı sergilemesine karşın karşılaşmadığı test verilerine göre ürettiği sonuçlarda, hata grafiklerinden de görülebileceği gibi, GYA kullanan YSA'lara göre daha başarılı değildir.

Elman Ağları ile yapılan denemelere dair bulgular EK-8'de verilmiştir.

BÖLÜM IV

4 SONUÇ VE ÖNERİLER

İnsanoğlu bugünkü teknolojiye büyük ölçüde doğayı örnek alıp taklit ederek sahip olmuştur. Yapay Zekâ kavramı da insanoğlunun kendi zekâ yeteneğini taklit etmeye çalışmasından ortaya çıkmıştır. Yapay Sinir Ağları (YSA), insan beyninin çalışmasını taklit eden bir yapay zekâ teknolojisidir. Her ne kadar YSA henüz insan beyninin kapasitesini yakalamaktan çok uzak da olsa günümüzde üzerinde en çok çalışılan konulardan birisidir. YSA finanstan sağlığa, karakter tanımadan hava tahminine, parmak izi okumadan kredi verilmesi kararına kadar birçok alanda uygulanabilmektedir.

Literatürde döviz kurunun tahmini üzerine geleneksel yöntemlerle gerçekleştirilmiş yurtiçinde ve yurtdışında birçok çalışma mevcuttur. YSA'ların non-lineer işlemlerdeki ve zaman serilerinin çözülmesindeki başarısı ekonomi ve finans alanında çalışanları da cezbedtiğinden, her geçen gün YSA'ların ekonomi ve finans alanındaki kullanımı yaygınlaşmaktadır. Buna rağmen YSA'ların kullanıldığı döviz kurunu tahmin etme çalışmaları henüz yeterli sayıda değildir. Geleneksel tahmin yöntemlerinde; daha önceki bölümlerde ayrıntılarını verdiğimiz zaman serilerinin öngörüsü için kesin modelinin olmaması, verilerin gürültü yani ani sıçramalar içermesi, durağan olmaması ve lineer olmamasından kaynaklanan bazı sorunlar vardır. YSA'lar geleneksel tahmin yöntemlerinin bu sorunlarını da büyük ölçüde telafi edebilirler. Ayrıca YSA'ların varsayımlara ihtiyaç duymaması, genelleme yapabilmesi, bir kez eğitildikten sonra eksik verilerle dahi çalışabilmesi, kendi kendine öğrenebilmesi gibi özellikleri nedeni ile de geleneksel tahmin yöntemlerine göre daha avantajlıdırlar. Geleneksel yöntemler ile YSA kullanılarak yapılan döviz kuru tahminlerini kıyaslayan çalışmalar da literatürde mevcuttur. Bu çalışmalar ortaya koymaktadır ki YSA'lar non-lineer olan döviz kurunun gelecekteki değerinin tahmininde oldukça başarılıdır hatta çoğu zaman geleneksel yöntemlerden de başarılıdır.

Bununla beraber, yapay sinir ağıları sihirli değnek de değildirler. Dolayısıyla mucize sonuçlar beklememek gerekir. YSA'lar ile henüz yatırım araçlarının gelecekteki değerlerinin %100 öngörüsü mümkün görünmemektedir. Özellikle Türkiye gibi, ekonomisi değişken olan ülkelerde borsa endeksi, altın, döviz fiyatları gibi değişkenlerin gelecekteki değerlerini tahmin edebilmek çok da kolay değildir. Buna rağmen YSA ile yapılacak analizler yatırım araçlarının seçiminde karar vermeyi destekleyici bir yöntem olarak kullanılabilir.

USD'nin gelecekteki değerinin ve yönünün YSA'lar yardımıyla doğru öngörülmesinin hedeflendiği bu çalışmanın benzer konudaki diğer YSA uygulamalarından en belirgin farkı kullanılan veri setidir. Diğer uygulamalarda genellikle tahmin edilmeye çalışılan değişkenin geçmişteki değerleri kullanılırken -yani teknik analiz yapılırken- bu çalışmada USD'nin değerini doğrudan ya da dolaylı olarak etkilediği düşünülen 41 ayrı parametre kullanılmıştır;¹⁵ yani temel analiz yapılmıştır. Uygulamada kullanılan parametrelerin sayısının artırılıp azaltılması ya da farklı parametrelerin kullanılması ağıın, dolayısıyla da yapılan tahminin performansını doğrudan etkileyecektir. Ayrıca bu çalışmada kullanılan veriler 4 Ocak 1999 ile 28 Şubat 2006 tarihleri arasında günlük olarak alınmıştır. TÜFE, ÜFE gibi aylık olarak açıklanan değişkenlerin değeri oransal olarak günlüğe çevrilerek kullanılmıştır. Diğer çalışmalarda veriler genellikle haftalık ya da aylık olarak kullanılmıştır. Bazı çalışmalarda ağıın tahmin performansının artırılması amacıyla veri setindeki ani düşme ve/veya yükselmeler çeşitli gürültü eleme algoritmaları ile kırpılmış ya da veri setinden uzaklaştırılmıştır. Bu çalışmada kullanılan veriler herhangi bir gürültü eleme işlemine tabi tutulmadan ağı uygulanmıştır.

Bu çalışmada temel olarak, çeşitli Yapay Sinir Ağları kurularak zaman serisi şeklinde olan USD'nin gelecekteki değeri tahmin edilmeye çalışılmıştır. Zaman serilerini öngörmede YSA kullanacak araştırmacılara; ağıın mimarisi, gizli katman

¹⁵ Kullanılan veriler için EK-1'e bakınız

sayısı, katmanlardaki yapay sinir hücresi sayısı, hangi eğitim algoritmalarını ve aktivasyon fonksiyonlarını kullanabilecekleri konusunda yol gösterebilmek bu çalışmanın diğer önemli hedeflerinden birisidir.

Çalışmamız esnasında öncelikle, zaman serilerinin gelecekteki değerinin tahmininde en çok kullanılan YSA algoritması olan Geriye Yayılım Algoritması (GYA) kullanılmıştır.

Elimizdeki verilerle kullanılmaya en uygun ve ulaşmaya çalıştığımız hedefimize yönelik olarak GYA’da performansı en yüksek eğitim algoritmasını bulmak için çeşitli mimarilerde ağlar oluşturulmuş ve denenmiştir. MATLAB’in bize sunmuş olduğu eğitim algoritmaları üzerinde yapılan denemelerin sonucunda, **trainbr (Bayesian Regularization)** eğitim algoritmasının uygulamamızda en başarılı sonucu üreten algoritma olduğu tespit edilmiştir. trainbr en hızlı algoritma olmasa da sonuca ulaşma hızı kabul edilebilir değerlerdedir. Diğer eğitim algoritmalarından traingd, traingdm ve traingdx algoritmalarının, hem yavaşlığı hem de çok sık yerel minimuma takılması nedeniyle uygulamamızda kesinlikle kullanılamayacak olması da elde ettiğimiz sonuçlar arasındadır.

Yapılan denemelerde, birden fazla gizli katman içermesinin başarı oranını arttırmadığı fakat bunun yanında doğal olarak ağın çalışma hızını olumsuz yönde etkilediği tespit edilmiştir. Aynı şekilde, gizli katmanlarda kullanılan nöron sayısının arttırılmasının da ağın hata oranını düşürmediği ama ağın hızını hissedilir şekilde azalttığı görülmüştür.

Değişik katman ve nöron sayılarında kurduğumuz ağlarda, türevlenebildiği için, geriye yayılım algoritmasında kullanılmaya en uygun olan aktivasyon fonksiyonlarından “Hiperbolik Tanjant Sigmoid” ve “Logaritmik Sigmoid” fonksiyonları kullanılmıştır. Denemelerimizde iki fonksiyonun ağlarımızda kullanımında önemli bir fark tespit edilememekle birlikte tansig’in daha başarılı sonuçlar ürettiği gözlemlenmiştir.

Uygulamalarımızda, USD'nin gelecekteki değerinin doğru tahmin edilebilmesi için iki ayrı veri seti ile çalışılmıştır. Bunlardan ilki 2001 krizinin verilerini de içeren 1867 günlük ve diğeri de krizden sonraki 723 günlük veri setleridir. YSA'lar ikinci grup verilerde daha başarılı sonuçlar üretmiştir. Çünkü ilk veri grubunda geniş bir bant içerisinde dalgalanan çok fazla ani inişler ve çıkışlar mevcuttur.

Ağların performansının ölçülmesi amacıyla yapmış olduğumuz diğ er bir uygulama da, doların ertesi günkü gerçek değerinin tespiti yerine 5 gün sonraki değerinin bugünkünden yüksek veya düşük olduğunun araştırılmasıdır. Bu uygulama ile 2 çıkış sinyali üreten YSA'ları deneme imkânımız olmuştur. Denediğimiz ağlar; bugünkü verileri kullanarak doların 5 gün sonraki değerinde artı ya da eksi yönde %1'lik bir değişikliğin olup olmadığını bulmaya çalışmışlardır. Özellikle borsa, döviz, altın, vb kıymetlerin gelecekteki değerine göre hareket etmek isteyen yatırımcıların, kurum ve kuruluşların genellikle tercih ettiğ i yöntem budur. Yani gelecekteki değerinin kati olarak bilinmesinin yerine gelecekte belli bir oranda düşeceğ inin ya da artacağı nın bilinmesi daha başarılı sonuçlar vermektedir. Daha önceki uygulamalardan edinilen tecrübeler e göre; al, sat ya da bekle kararlarına göre hareket edenler ekonominin dalgalanmalarından daha az etkilendikleri ve hatta daha fazla kâr elde ettikleri görülmüştür. Bizim yapmış olduğumuz uygulamada da kurmuş olduğumuz YSA'lar ortalama olarak %60 seviyesinde doğru kararlar üretebilmiştir. Daha önce de bahsettiğimiz gibi %60'lık bir tahmin performansı oldukça iyi bir başarı olarak görülmektedir.

Son uygulama olarak da, zaman serilerinin analizinde pek kullanılmazsa da GYA ile kıyaslayabilmek için Elman Ağı ile de denemeler yapılmıştır. Denemeler sonucunda görülmüştür ki Elman ağları da elimizdeki veriler ve hedefimiz doğrultusunda başarılı sonuçlar üretmiştir. Özellikle eğitim verileri içerisinde bulunan anlık sıçramaları başarılı bir biçimde tolere edebilmiştir. Fakat ağ, daha önce karşılaşmadığı verilerinin öngörülmesinde pek de başarılı olamamıştır. Dolayısı ile

zaman serilerinin analizinde Elman Ağlarının kullanımı GYA kadar başarılı sonuçlar vermeyecektir.

Yapay sinir ağlarının öngörü performanslarının artırılması için halen birçok araştırma ve çalışma sürdürülmektedir. Örneğin özellikle ağı eğitilmesi işlemini hızlandırmak, ağı ezberlemesinin ve yerel minimum noktalarına takılmasının önüne geçmek için kullanılan neuro-fuzzy uygulamaları bunlardan birisidir. İleriki çalışmalarda değişik ağ modellerinin geliştirilmesi, bilgisayarların daha da hızlanmasına paralel olarak katman sayısının ve deneme sayısının artırılması ile başarı oranı daha da yükselecektir.

5 KAYNAKLAR

AHRENS Ralf, REITZ Stefan: “*Chartist Prediction in the Foreign Exchange Market Evidence from the Daily Dolar/DM Exchange Rate*”, Institut Für Kapitalmarktforschung-Center for Financial Studies, January 2000

AKDOĞAN Erhan: “*Kavşak Trafiğinin Kontrolü İçin Bir Sinyal Zamanlama Algoritması ve Uzman Sistem Yaklaşımında Kullanılması*”, Marmara Üniversitesi Teknik Bilimler MYO, 2002

AKPINAR Haldun: “*Yapay Sinir Ağları ve Kredi Taleplerinin Değerlendirilmesinde Bir Uygulama Önerisi*”, Mayıs 1993

ALTUNTAŞ Erhan, ÇELİK Tuncay: “*Yapay Zekâ*”, E-Book, 2003

Anil K.Jain, Jianchang Mao: “*Artificial Neural Networks: A Tutorial*”, Theme Feature, March 1996

ARAT Kürşad: “*Türkiye’de Optimum Döviz Kuru Rejimi Seçimi ve Döviz Kurlarından Fiyatlara Geçiş Etkisinin İncelenmesi*”, Uzmanlık Yeterlilik Tezi, TCMB, Temmuz 2003

ARIS Teh Noranis Mohd, vd.: “*Parallel Implementation on Improved Error Signal of Backpropagation Algorithm*”, Malaysian Journal of Computer Science, Vol. 15 No. 2, December 2002, pp. 1–16

AYDOĞMUŞ Zafer, ÇÖTELİ Resul: “*Yapay Sinir Ağları Yardımıyla İzolatör Yüzeyinde Potansiyel Tahmini*”, F.Ü.Fen ve Müh.Bil. Dergisi, 17(2), 239–246, 2005

BAYKASOĞLU Adil, ÖZBAKIR Lale: “*Yapay Sinir Ağları ile Teslim Tarihi Belirleme*”, Yöneylem Araştırması / Endüstri Mühendisliği, XXIV Ulusal Kongresi, Haziran 2004

BAYKOÇ Ömer Faruk, ÖZ Erçetin: “*Tedarikçi Seçimi Problemine Karar Teorisi Destekli Uzman Sistem Yaklaşımı*”, Gazi Ün. Müh.Mim. Fak. Der. Cilt:19, No:3, Syf.: 275–286, 2004

Bilim ve Teknik - Yeni Ufuklara: “*Beynin Gizemi*”, Eylül 2003

BİRCAN Hüdaverdi, KARAGÖZ Yalçın: “*Box-Jenkins Modelleri ile Aylık Döviz Kuru Tahmini Üzerine Bir Uygulama*”, Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi (6), 2003/2: 49–62

BLANCO A., DELGADO M., PEGALAJAR M.C.: “*A Genetic Algorithm to Obtain the Optimal Recurrent Neural Network*”, International Journal of Approximate Reasoning 23 (2000) 67 – 83

BOLAT Bülent, YILDIRIM Tülay: “*İyonosfer Radar Yansımasının İstatistiksel Sinir Ağları ile Sınıflandırılması*”, Yıldız Teknik Ün. Elektronik ve Haberleşme Müh.Böl., Nisan 2003

BOLAT Bülent: “*Recognition of the REED Instrument Sounds by Using Statistical Neural Networks*”, Journal of Engineering and Natural Sciences”, Yıldız Teknik Ün., Şubat 2005

BOLAT Suna, vd.: “*Yapay Sinir Ağı ile Gaz Karışımında Elektrot Açıklığına ve Karışım Yüzdelere Bağlı Olarak Delinme Gerilimlerinin Belirlenmesi*”, Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu – INISTA”, 2004

BURNEY Syed Muhammad Aqil, JILANI Tahseen Ahmed, ARDİL Cemal: “*Levenberg-Marquardt Algorithm for Karachi Stock Exchange Share Rates Forecasting*”, Transaction on Engineering, Computing and Technology, December 2004 ISSN 1305–5313

CASTIGLIONE Flippo: “*Forecasting Price Increments Using an Artificial Neural Network*”, Center for Advanced Computer Science, University of Cologne, 2000

CAVUTA David J. : “*An Exploration And Development of Current Artificial Neural Network Theory And Applications with Emphasis on Artificial Life*”, The Cooper Union For The Advancement Of Science And Art, Master Thesis, 6 Mayıs 2006

CHATFIELD Chris: “*Time Series Forecasting*”, Chapman&Hall/CRC, 2000

CIĞIZOĞLU H.Kerem, ALP Murat: “*Farklı Yapay Sinir Ağı Metodları ile Yağış-Akış İlişkisinin Modellenmesi*”, İTÜ Dergisi, Mühendislik, Cilt:3, Sayı:1, Şubat 2004

ÇELİK Ş. Abdurrahman, KAYACAN M. Cengiz: “*Tornalama İşlemlerinde Kesici Takım Aşınmasının Bulanık Mantık İle Modellenmesi*”, Mühendis ve Makine, Sayı 526, Kasım 2003

ÇETİN Meriç, ALPER Uğur, ŞAHİN Bayzan: “*İleri Beslemeli YSA’da Backpropagation (Geriye Yayılım) Algoritmasının Sezgisel Yaklaşımı*”, Pamukkale Üniversitesi Bilgisayar Müh. Bölümü

ÇİÇEK Macide: “*Türkiye’de Parasal Aktarım Mekanizması: VAR (Vektör Otoregresyon) Yaklaşımıyla Bir Analiz*”, İktisat İşletme ve Finans, Syf:82–105, Ağustos 2005

ÇORUMLUĞLU Ö., ÖZBAY Y., vd.: “*GPS Yüksekliklerinden Ortometrik Yüksekliklerin Elde Edilmesinde Yapay Sinir Ağı (YSA) Tekniğinin Kullanımı*”, Har. ve Kad. Müh.Odası, Mühendislik Ölçmeleri STB Komisyonu 2. Mühendislik Ölçmeleri Sempozyumu, Kasım 2005, İTÜ

DAMODAR GUJARATI: “*Essential of Econometrics*”, Irwin/McGraw-Hill, 1999

DAZSI Brian Adam, ENBODY: “*Artificial Neural Networks For Branch Prediction*”, Master Science Thesis, Department of Electrical and Computer Engineering - Michigan State University”, 2001

DeLurgio Stephen: “*Forecasting Principles and Applications*”, Syf: 636, McGraw-Hill, 1998

DEMUTH Howard, BEALE Mark: “*Neural Network Toolbox For Use with MATLAB*”, Eylül 2000

DİNÇER Nazire Nergiz: “*Döviz Kuru Dalgalanmalarının Asimetrik Etkileri: Türkiye Örneği*”, DPT Uzmanlık Tezleri, Şubat 2005

DİNLER Zeynel: “*İktisada Giriş*”, Ekin Kitabevi, 6. Basım, Bursa 2000

EFE Önder, KAYNAK Okyay: “*Yapay Sinir Ağları ve Uygulamaları*”, Boğaziçi Üniversitesi, 2000

ELMAS Çetin: “*Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)*”, Seçkin Yayıncılık, Ankara 2003

ERDEM O. Ayhan, UZUN Emre: “*Yapay Sinir Ağları ile Türkçe Times New Roman, Arial ve El Yazısı Karakterleri Tanıma*”, Gazi Ün. Müh.Mim. Fak. Der. Cilt:20, No:1, 13–19, 2005

ERGEZER Halit, DİKMEN Mehmet, ÖZDEMİR Erkan: “*Yapay Sinir Ağları ve Tanıma Sistemleri*”, Başkent Ün. İİBM, Pivolka, Yıl:2, Sayı:6, Nisan 2003

FAUSETT Laurene: “*Fundamentals of Neural Networks - Architectures, Algorithms, and Applications*”, Prentice Hall, Şubat 1994

FIRAT Mahmut, GÜNGÖR Mahmud: “*Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi*”, İMO Teknik Dergi, 2004, 3267–3282, Yazı 219

FREEMAN James, SKAPURA David: “*Neural Networks Algorithms, Applications, and Programming Techniques*”, Addison-Wesley Publishing Company, 1991

FU LiMin: “*Neural Networks in Computer Intelligence*”, McGraw-Hill, Inc. 1994

GILES C. Lee, LAWRENCE Steve, TSOI Ah Chung: “*Noisy Time Series Prediction using Recurrent Neural Networks and Grammatical Inference*”, Machine Learning – 44, 161–183, 2001

GÜLESİN Mahmut, ÖZKAN Murat Tolga: “*Uzman Sistem Yaklaşımı ile Cıvata ve Dişli Çark Seçimi*”, Türk J Engin Environ Sci. 25 (169 – 177) , TÜBİTAK 2001

GÜNGÖR İbrahim, ÇUHADAR Murat: “*Antalya İline Yönelik Alman Turist Talebinin Yapay Sinir Ağları Yöntemi ile Tahmini*”, Ticaret ve Turizm Eğitim Fakültesi Dergisi, Sül.Dem.Ünv., Yıl:2005, Sayı:1

GÜNGÖR İbrahim, KAYACAN M.Cengiz, KORKMAZ Mehmet: “*Endüstriyel Odun Hammaddesi Talebinin Tahmininde Yapay Sinir Ağlarının Kullanımı ve Bazı Tahmin Yöntemleri İle Karşılaştırılması*”, Yöneylem Araştırması ve Endüstri Mühendisliği XXIV. Ulusal Kongresi, Çukurova Üniversitesi ve Gaziantep Üniversitesi, Endüstri Mühendisliği Bölümleri, Adana 2004

HAMZAÇEBİ Coşkun, KUTAY Fevzi:“*Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini*”, Gazi Ünv. Müh.Mim. Fak. Der. Cilt 19, No:3, 227–233, 2004

HART Eduardo, CHA Sung-Hyuk, TAPPERT Charles: “*Interactive Flag Identification Using a Fuzzy-Neural Technique*”, Proceedings of Student/Faculty Research Day, CSIS, Pace University, May 7th, 2004

HAUSLER Stefan: “*Introduction to MATLAB*”, Institute for Theoretical Computer Science, Ocak 2006

HAUSLER Stefan: “*Neural Network Toolbox*”, Institute for Theoretical Computer Science, Ocak 2006

HAYKIN Simon: “*Neural Networks : A Comprehensive Foundation*”, 2nd ed. – Upper Saddle River, N.J., Prentice Hall, 1999

HERBRICH Ralf, KEILBACH Max : “*Neural Networks in Economics Background, Application and New Developments*”, Ocak 1999

HU Yu Hen, HWANG Jenq-Neng: “*Handbook of Neural Network Signal Processing*”, CRC Press, 2001

HYNDMAN Rob J.: “*Box-Jenkins Modelling*”, Mayıs 2001

İNAN Aslan, KÖROĞLU Selim, İZGİ Ercan: “*Dengeli Elektrik Güç Sistemi Verilerini Kullanarak Dengesiz Sistem Kayıplarının Yapay Sinir Ağları İle Belirlenmesi*”, Pamukkale Ünv. Mühendislik Bilimleri Dergisi, Yıl:2005, Cilt:11, Sayı:1, Sayfa 47–52

İNANDIM Şeyda: “*Kısa Vadeli Sermaye Hareketleri ile Reel Döviz Kuru Etkileşimi: Türkiye Örneği*”, Uzmanlık Yeterlilik Tezi, TCMB – Piyasalar Genel Müdürlüğü, Kasım 2005

JANUSKEVICIUS Marius: “*Testing Stock Market Efficiency Using Neural Networks Case of Lithuania*”, Mayıs 2003

KAASTRA Iebeling, BOYD Milton: “*Designing a Neural Network for Forecasting Financial and Economic Time Series*”, Neurocomputing, August 1994

KALYVAS Efstathios: “*Using Neural Networks And Genetic Algorithms To Predict Stock Market Returns*”, M.S. Thesis, University of Manchester, October 2001

KAMRUZZAMAN Joarder, SARKER A. Ruhul: “*Comparing ANN Based Models with ARIMA for Prediction of Forex Rates*”, ASOR Bulletin, Volume 22 Number 2, June 2003

KANAS Angelos: “*Neural Network Linear Forecasts For Stock Returns*”, International Journal Of Finance And Economics, 6:245–254 (2002)

KANDEL Eric R: “*Principles of Neural Science*”, Elsevier Science Publishing Co, 1991

KARADENİZ Mehmet, YÜNCÜ Selma, AYDEMİR M.Timur: “Asenkron Motorlarda Stator Direncinin Yapay Sinir Ağları ile Tahmini”, Gazi Üniv. Müh.Mim.Fak., Şubat 2004

KASMAN Saadet: “*The Relationship Exchange Rates and Stock Prices: A Causality Analysis*”, Dokuz Eylül Üniversitesi, Sosyal bilimler Dergisi, Cilt 5, Sayı:2, 2003

KAYIM Halil: “*İstatistiksel Ön Tahmin Yöntemleri*”, H.Ü.İkt. ve İdr. Bil. Fak. Yayınları, No:11, Ankara 1985

KELEŞOĞLU Ömer, Ekinci Cevdet Emin, FIRAT Adem: “*The Using Artificial Neural Networks in Insulation Computations*”, Journal of Engineering and Natural Sciences, Mart 2005

KLINE Dougles M.: “*Methods for Multi-Step Time Series Forecasting with Neural Networks*”, “*Neural Networks in Business Forecasting*” ZHANG G.Peter, 2004, Idea Group Publishing, Chapter 12

KONUR Umut, OKATAN Ali: “*Time Series Prediction using Recurrent Neural Network Architectures and Time Delay Neural Networks*”, Enformatika-Transactions on Engineering, Computing and Technology V3, December 2004, ISSN 1305–5313

KOPRINSKA Irena, KASABOV Nikola: “*An Application of Evolving Fuzzy Neural Network for Compressed Video Parsing*”, Department of Information Science, University of Otago, New Zealand, Aralık 2000

KORUKOĞLU Serdar, İŞÇİ Öznur: “*Genetik Algoritma Yaklaşımı ve Yöneylem Araştırmasında Bir Uygulama*”, Celal Bayar Üniversitesi İ.İ.B.F, Yönetim Ve Ekonomi, Yıl: 2003 Cilt:10 Sayı:2

KOSKİVAARA Eija: “*Different Pre-Processing Models for Financial Accounts when Using Neural Networks for Auditing*”, Turku Centre for Computer Science TUCS, Turku - Finland, Kasım 2004

LAWRANCE Ramon: *“Using Neural Networks to Forecast Stock Market Prices”*, Department of Computer Science University of Manitoba, 12 December 1997

LAWRENCE Steve, GILES C. Lee, FONG Sandiway: *“Natural Language Grammatical Inference with Recurrent Neural Networks”*, IEEE Transactions on Knowledge and Data Engineering, Volume 12, Number 1, Syf. 126–140, 2000

LENDASSE A., DE BODT E.: *“Non Linear Financial Time Series Forecasting – Application to the Bel 20 Stock Market Index”*, European Journal of Economic and Social Systems 14 No1 (2000) Syf:81-91

LIAO Yihao, VEMURI V. Rao: *“Use of K-Nearest Neighbor Classifier for Intrusion Detection”*, Computers & Security, Vol 21, No 5, pp 439–448, 2002

LOH Ruey Hwa: *“Time Series Forecast With Neural Network and Wavelet Techniques”*, Department of Electrical and Computer Engineering, University of Queensland, October 2003

LUGER George, STUBBLEFIELD William: *“Artificial Intelligence and the Design of Expert Systems”*, The Benjamin/Cummings Publishing Company, 1980

MACY B.Robert, PANDYA S. Abhijit: *“Pattern Recognition with Neural Networks in C++”*, CRC Press, 1995

MANDIC Danilo P. ,CHAMBERS Jonathon A.: *“Recurrent Neural Networks for Prediction - Learning Algorithms, Architectures and Stability”*, John Wiley & Sons Ltd, 2001

McCANN Peter J., KALMAN Barry L.: *“A Neural Network Model for the Gold Market”*, Department of Computer Science Washington University, Kasim 2001

McCLUSKEY C.Peter: *“Feedforward and Recurrent Neural Networks and Genetic Programs for Stock Market and Time Series Forecasting”*, Master Science Thesis, Department of Computer Science at Brown University, June 1993

McNEILS Paul: “*Neural Networks in Finance – Gaininig Predictive Edge in the Market*”, Elsevier Academic Press, 2005

McNEILL George, ANDERSON Dave: “*Artificial Neural Network Technology*”, Ağustos 1992

MOODY John: “*Economic Forecasting: Challenges and Neural Network Solutions*”, Keynote talk presented at the International Symposium on Artificial Neural Networks, Hsinchu, Taiwan, Aralık 1995

MÜSLÜMOV Alövsat, HASANOV Mübariz, ÖZYILDIRIM Cenktan: “*Döviz Kuru Sistemleri ve Türkiye’de Uygulanan Döviz Kuru Sistemlerinin Ekonomiye Etkileri*”, Scala Basım Yayım, 2003

NABİYEV Vasif V.: “*Yapay Zeka – Problemler, Yöntemler, Algoritmalar*”, Seçkin Yayınevi, Birinci Basım, Ekim 2003

ÖGEL Serdar: “*Teknik Analizde Kullanılan Kısa Vadeli Göstergelerin Analiz Edilmesi (İMKB-30 için bir Uygulama)*”, Anadolu Üniversitesi, 2002

ÖZDEMİR K. Azim, ŞAHİNBEYOĞLU GÜLBİN: “*Alternatif Döviz Kuru Sistemleri*”, Eylül 2000

ÖZER Mustafa: “*Türkiye’de Reel Döviz Kurunun Zaman Serisi Analizi (1975–1991)*”, Eskişehir Anadolu Üniversitesi, 1992

ÖZMEN Ahmet: “*Zaman Serilerinde Tutarlı Kestirimler İçin İstatistiksel Yöntem Uyarlaması*”, Anadolu Üniv. Fen-Edebiyat Fakültesi Dergisi, Kasım 1988, Cilt 1, Sayı 1, Syf. 69–80

ÖZTEMEL Ercan: “*Yapay Sinir Ağları*”, Papatya Yayıncılık, Ağustos 2003

ÖZTEMEL Ercan: “*Reklâmlarda Yapay Zekâ*”, Otomasyon Sayı:128, Ocak 2003

PARASIZ İlker: “*Para Banka ve Finansal Piyasalar*”, Ezgi Kitabevi Yayınları, Ocak 2000

PETRIU Emil M.: “*Neural Networks: Basic*”, University of Ottawa School of Information Technology, Ekim 2004

ROWLEY Henry A., BALUJA Shumeet, KANADE Takeo: “*Neural Network-Based Face Detection*”, PAMI, IEEE, January 1998

SARLE Warren S.: “*Neural Networks and Statistical Models*”, Proceedings of the Nineteenth Annual SAS Users Group International Conference, N.C. USA, Nisan 1994

SERPER Özer: “*Uygulamalı İstatistik 2*”, Ezgi Kitabevi, Bursa 2000

SWINGLER Kevin: “*Financial Prediction, Some Pointers, Pitfalls, and Common Errors*”, Center for Cognitive and Computational Neuroscience, Stirling University, Temmuz 1994

ŞEN Zekai: “*Yapay Sinir Ağları İlkeleri*”, Su Vakfı İstanbul, 2004

TEBELKIS Joe: “*Speech Recognition Using Neural Networks*”, School of Computer Science Carnegie Mellon University, Pennsylvania, Doctor of Philosophy Thesis, Mayıs 1995

TEKTAŞ Mehmet, AKBAŞ Ahmet, TOPUZ Vedat: “*Yapay Zekâ Tekniklerinin Trafik Kontrolünde Kullanılması Üzerine Bir İnceleme*”, Marmara Üniversitesi, Teknik Bilimler MYO, 1997

TENTI Paolo: “*Forecasting Foreign Exchange Rates Using Recurrent Neural Networks*”, Applied Artificial Intelligence, 10: 567–581, 1996

TERZİ Özlem, KESKİN M.Erol: “*Yapay Sinir Ağı Yaklaşımı Kullanarak Günlük Tava Buharlaştırması Tahmini*”, İMO Teknik Dergi, 2005 3683 – 3693, Yazı 243

THAWORNWONG Suraphan, ENKE David: “*Forecasting Stock Returns with Artificial Neural Networks*”, “*Neural Networks in Business Forecasting*”, ZHANG G.Peter, 2004, Idea Group Publishing, Chapter 3

TOPRAK Şükrü, GANİZ Can Murat: “Genetik Algoritmalarla Makine Öğrenmesi İçin Tıbbi Verilerden Hipotez Uzayı Oluşturulması”, Selçuk Üniversitesi, Müh.Mim. Fak. Bilgisayar Müh. Bölümü, Akademik Bilişim 2003

TUNÇKANAT Mehmet, KURBAN Rifat, SAĞIROĞLU Şeref: “Voice Recognition Based on Neural Networks”, International Conference on Signal Processing – ICSP 2003

TURĞUT Peki, ARSLAN Abdussamet: “Sürekli Bir Kirişte Maksimum Momentlerin Genetik Algoritmalar ile Belirlenmesi”, DEÜ Mühendislik Fakültesi, Fen ve Mühendislik Dergisi, Ekim 2001 Cilt:3 Sayı:3 sh.1–9

TUTAR Eser: “Enflasyon Hedeflemesinin Önkoşulları: Türkiye’de Para Politikası Araçları İle Enflasyon Arasındaki İlişkinin İncelenmesi”, Uzmanlık Yeterlilik Tezi, TCMB Piyasalar Genel Müdürlüğü, Ankara, Ağustos 2005

VALAFAR Faramarz: “Applications of Neural Networks in Medicine and Biological Sciences”, CRC Press LLC, 2001

VEELEN TURF L.P. J: “Analysis and Applications of Artificial Neural Networks”, Prentice Hall, 1995

WINSTANLEY G.; “Artificial Intelligence in Engineering”, New York, 1991

YAN Wu, LIMING Zhang: “Control Algorithms of Fuzzy Neural Network and Their Application in Automatic Train Control”, Department of Computer Science and Engineering Tongji University, Shanghai 2003

YAO Jing Tao, TAN Chew Lim: “A Case Study on Using Neural Networks to Perform Technical Forecasting of Forex”, School of Computing, National University of Singapore, Haziran 1999

YAO Jing Tao, TAN Chew Lim: “Guidelines for Financial Forecasting with Neural Networks”, Nisan 2001

YILDIRIM Oğuz: “Döviz Kurları Çerçevesinde Satınalma Gücü Paritesinin Zaman Serisi Analizi ve Türkiye Ekonomisine Uygulaması”, Bankacılar Dergisi, Sayı:44, 2003

YILDIRIM Oğuz: “Kura Dayalı İstikrar Politikası (Teori ve Ülke Uygulamaları)”, T.C. Başbakanlık Hazine Müst. Ekonomik Araştırmalar Gn. Müdürlüğü, Şubat 2003

YILDIZ Birol: “Finansal Başarısızlığın Öngörülmesinde YSA Kullanımı ve Halka Açık Şirketlerde Ampirik Bir Uygulama”, İMKB Dergisi, Cilt 5 Sayı:17, 2001

YOUSEFIZADEH Hooman, ZILOUCHIAN Ali: “Neural Network Architecturer”, CRC Press LLC, Chapter 3, 2001

YURTOĞLU Hasan: “YSA Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği”, Şubat 2005

ZHANG G. Peter: “A Combined ARIMA and Neural Network Approach for Time Series Forecasting”, “Neural Networks in Business Forecasting”, ZHANG G. Peter, 2004, Idea Group Publishing, Chapter 11

ZHOU Yong-Quan, HE Deng-Xu, NONG Zheng: “Application of Functional Network to Solving Classification Problems”, Transactions on Engineering, Computing and Technology, Ağustos 2005

ZHOU Yunfei, LI Shuijin, JIN Rencheng: “A New Fuzzy Neural Network with Fast Learning Algorithm and Guaranteed Stability for Manufacturing Process Control”, Elsevier - Fuzzy Sets and Systems, 201 – 216, 2002

ZHANG G. Peter: “Neural Networks in Business Forecasting”, Idea Group Publishing, 2004

YARARLANILAN WEB SAYFALARININ ADRESLERİ

FAHEY Colin P.: “*Artificial Neural Networks*”, Mart 2006

url = http://www.colinfahey.com/2003apr20_neuron/2003apr20_neuron.htm

<http://yapayzeka.hypermart.net/ysa/mimarisi.htm>, Mart 2006

FRÖHLICH Jochen: “*Neural Networks with Java*”, Mart 2006

url = <http://rfhs8012.fh-regensburg.de/~saj39122/jfroehl/diplom//e-12-text.html>

LUNDEEL Simon: “*Neural Networks in MATLAB*”, Nisan 2006

url = http://www.ida.his.se/ida/kurser/ai_ann/kursmaterial/tutorial/node29.html

“*Yapay Zeka*”, Mayıs 2004

url = <http://members.tripod.com/~Bagem/bagem/yz1.html>

GeniusSYS: “*Yapay Sinir Ağı*”, Ocak 2005,

url = http://www.geniussys.com/ysa_files/filelist.xml

O'ROURKE Brian: “*Neural Nets Forecast Futures Prices*”, Ocak 2006,

url = <http://www.fenews.com/fen3/neural.html>

“*Using The MatLab Neural Network Toolbox*”, Ocak 2006

url = <http://www.ces.clemson.edu/~petersj/BioEng/BioTools/BioTools008.html>

<http://www.yapayzeka.org>, Nisan 2006

İstanbul Menkul Kıymetler Borsası: <http://www.imkb.gov.tr>, Nisan 2006

T.C. Merkez Bankası: <http://www.tcmb.gov.tr>, Nisan 2006

<http://yapayzeka.hypermart.net/ysa/mimarisi.htm>, Nisan 2006

GOLDBERG E. David: “*Kişisel Web Sayfası*”

url=<http://www-illigal.ge.uiuc.edu/goldberg/d-goldberg.html>, (Mayıs 2006)

OBITKO Marek: “*Introduction to Genetic Algorithms*”,

url=<http://cs.felk.cvut.cz/~xobitko/ga.index.html> , Mayıs 2006

Bilim ve Teknik Dergisi: www.bilimteknik.com, Nisan 2006

“*The Hows, Whats and Whos of Neuroscience*”,

url=<http://faculty.washington.edu/chudler/what.html> , Nisan 2006

6. EKLER

EK-1. DÖVİZ KURU TAHMİNİNDE KULLANILAN PARAMETRELER

1. Altın Borsası İşlemleri-İstanbul (İş Günü, YTL-USD)
 - a. Altın Piyasası Endeksi
 - b. Günlük Toplam Miktar (Kg)
2. Altın Fiyatları(Ortalama)-Serbest Piyasa (Aylık, YTL)
 - a. 1 Ons Altın Londra Satış Fiyatı (USD/Ons)
 - b. Cumhuriyet Altını Satış Fiyatı (YTL/Adet)
3. Döviz Tevdiat Hesapları Ağırlıklı Faiz Oranları (Aylık)
 - a. 12 Ay USD
 - b. Vadesiz USD
4. Döviz ve Efektif Piyasası İşlemleri (İş Günü, \$)
 - a. Piyasa Toplamı Hacim
 - b. Piyasa Toplamı Adet
5. Fiyat (Toptan Eşya) ve Geçinme (Ücretliler) Endeksleri-İstanbul (İTO) (Aylık)
 - a. İstanbul Ücretliler Geçinme Endeksi (1995=100) (ITO)
6. Fiyat Endeksi(Toptan Eşya) (1968=100) (İTO) (Aylık)
 - a. Genel Endeks (ITO TEFE, 1968=100)
7. Geçinme Endeksi (Ücretliler) (1968=100) (İTO) (Aylık)
 - a. Genel Endeks (ITO, 1968=100)

8. Güven Endeksi-Reel Kesim (MBRKGE) (TCMB) (Aylık)
 - a. Reel Kesim Güven Endeksi
9. İç Borç Stok Verileri (Hazine) (Aylık, Bin YTL)
 - a. Toplam
10. İMKB Endeksi ve Günlük İşlem Hacmi (İş Günü, Bin YTL, Bin Adet)
 - a. (FIYAT) Ulusal 100 Endeks, Kapanış Fiyatlarına Gore(Ocak 1986=1)
 - b. (GETIRI) Ulusal 100 Endeks, Kapanış Fiyatlarına Gore (27-12-1996=976)
 - c. Toplam İşlem Hacmi (Bin YTL)
 - d. Toplam İşlem Miktarı (Bin Adet)
11. Kurlar-Döviz Kurları (Günlük) (YTL dönüşümü yapılmış)
 - a. (EUR) Euro (Döviz Satış)
 - b. (USD) ABD Doları (Döviz Satış)
 - c. (JPY) Japon Yeni (Döviz Satış)
12. Kurlar-Reel Efektif Döviz Kuru Endeksleri(1995=100) (TCMB)(Aylık)
 - a. TUFÉ bazlı reel efektif kur endeksi (1995=100)
 - b. ÜFE bazlı reel efektif kur endeksi (1995=100)
13. Merkez Bankası Haftalık Vaziyeti (Haftalık(Cuma), Bin YTL)
 - a. A1. Altın Mevcudu
14. Merkez Bankası Rezervleri (Haftalık(Cuma), Milyon \$)
 - a. Altın
 - b. Merkez Bankası Brüt Döviz Rezervleri
 - c. Muhabir Açıkları

15. Mevduat Bankalarındaki Mevduat (Haftalık(Cuma), Bin YTL)

- a. Bankalardaki YTL Mevduatlar (A+B)

16. Parasal Göstergeler (Haftalık(Cuma) Geçici Veriler, Bin YTL)

- a. (KMK)Devlet Tahvili
- b. Dolaşıma Çıkan Para Emisyon
- c. Dolaşımdaki Para
- d. Döviz Tevdiat Hesabi (USD)
- e. (KMK)Hazine Bonosu
- f. M1
- g. Merkez Bankasındaki Mevduat
- h. Vadesiz Mevduat

17. Sanayi Üretim Endeksi (1997=100)(TÜİK)(Aylık)(Yeni Seri)

- a. Toplam Sanayi Sektörü

18. Şirket İstatistikleri-Açılan-Kapanan (TÜİK)(Aylık)

- a. Açılan Toplam (Adet)
- b. Açılan Toplam (Sermaye YTL)

19. Toplam Otomobil Üretimi (OSD) (Aylık)

- a. (OSD) Binek (Adet)

20. Uluslararası Rezervler (Aylık, Milyon \$)

- a. Altın
- b. Merkez Bankası Brüt Döviz Rezervleri
- c. Net Uluslararası Rezervler

EK-2. ÖRNEK MATLAB KODLARI

ACF01.M

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%   ACF01.M   / trainbr / 5-1 / tansig-purelin %
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%   Geriye Yayılım (Back Propagation) %
%   ABD dolarının ertesi günkü gerçek değerini elde etme %
%   Kriz Dahil (1866 günlük veri) %
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% ekran ve hafızadaki değişkenler silinir.
clc, clear all;

% Daha önceden kayıt edilmiş veriler hafızaya yüklenir.
load P_ErtesiGun;

% Ağın eğitilmesinde kullanılacak olan veriler ortalaması 0 ve
% standart sapma 1 olacak şekilde bir ön işlemde geçirilerek
% Yapay Sinir Ağına uygulanacak şekilde ölçekleniyor

[pn,meanp,stdp,tn,meant,stdt]=prestd(Pall,T);
[pn,meanp,stdp,tn,meant,stdt]=premnmx(Pall,T);

ptrans=pn;
[R,Q]=size(ptrans);

% Tüm seri veriler %70'i eğitim, %20'si onaylama ve %10'u da test için
% kullanılmak üzere parçalara ayrılıyor
iitr=1:round(Q*.7);
iival=round(Q*.7)+1:round(Q*.9);
iitst=round(Q*.9)+1:Q;

% Training (eğitim verileri)
ptr=ptrans(:,iitr);
ttr=tn(:,iitr);

% Validation(onaylama) verileri
val.P=ptrans(:,iival);
val.T=tn(:,iival);

% Test verileri
test.P=ptrans(:,iitst);
test.T=tn(:,iitst);

% Ağıımızı burada oluşturuyoruz.
net=newff([minmax(ptr)],[5 1],{'tansig','purelin'},'trainbr');
net.trainParam.epochs=2500;
net=init(net);
% Ağıımız oluşturuldu ve epoch değeri olarak 2500 verildi, initialize edildi

% Kurulan YSA önceden ayrıştırılmış olan eğitim, onaylama ve test
% değerlerine göre eğitiliyor
% Ağın ne kadar sürede eğitildiğini hesaplamak için sayaç başlatılıyor
tic;
[net,tr,Y1,E,Pf,Af]=train(net,ptr,ttr,[],[],val,test);
% Geçen süre ekranda gösteriliyor
Egitimde_Gecen_Sure=toc

% Eğitim sonunda elde edilen sonuçlar grafiksel olarak gösteriliyor
subplot(2,2,3), plot(tr.epoch,tr.perf,tr.epoch,tr.vperf,tr.epoch,tr.tperf)
TITLE('Ağın Eğitilmesinden Sonra Elde Edilen Değerler');
```

```

legend('Egitim','Onaylama','Test',1);
ylabel('Squared error'); xlabel('Epoch')
grid on;

% Eđitilmiş olan ađ tüm verilere göre ęalıřtırılıyor.
y=sim(net,pttrans);

% Ađın ęıktı deđerleri yeniden geręek deđerlerine uygun olacak řekilde
% yeniden ۆlęekleniyor.
Y=poststd(y,meant,stdt);

% Hedef deđerleri ve Ađın ęıktıları aynı grafikte gۆsteriliyor
j=1:size(T,2);
subplot(2,2,1:2),plot(j,T,j,Y,'r'),grid on;
TITLE('Hedef Degerleri ve Egitilmiř Agin Ciktilari');

% Hata deđerleri hesaplanıyor ve grafiksel olarak gۆsteriliyor
err=T-Y;
subplot(2,2,4),plot(err),grid on;
TITLE('Hata Grafigi');

% Ađın performansı Mean Squared Error ile hesaplanarak ekranda gۆsteriliyor
HataOrani=mse(err)

```

ADF11.M

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%   ADF11.M   / trainbr / 4-9-1 / tansig-logsig-purelin   %
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%   Geriye Yayılım (Back Propagation)   %
%   ABD dolarının ertesi günkü gerçek değerini elde etme   %
%   Kriz Sonrasi (723 günlük veri)   %
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% ekran ve hafızadaki değişkenler silinir.
clc, clear all;

% Daha önceden kayıt edilmiş veriler hafızaya yüklenir.
load P_ErtGun723;

% Ağın eğitilmesinde kullanılacak olan veriler ortalaması 0 ve
% standart sapma 1 olacak şekilde bir ön işlemden geçirilerek
% Yapay Sinir Ağına uygulanacak şekilde ölçekleniyor

[pn,meanp,stdp,tn,meant,stdt]=prestd(Pall,T);
%[pn,meanp,stdp,tn,meant,stdt]=premnmx(Pall,T);

ptrans=pn;
[R,Q]=size(ptrans);

% Tüm seri veriler %70'i eğitim, %20'si onaylama ve %10'u da test için
% kullanılmak üzere parçalara ayrılıyor
iitr=1:round(Q*.7);
iival=round(Q*.7)+1:round(Q*.9);
iitst=round(Q*.9)+1:Q;

% Training (eğitim verileri)
ptr=ptrans(:,iitr);
ttr=tn(:,iitr);

% Validation(onaylama) verileri
val.P=ptrans(:,iival);
val.T=tn(:,iival);

% Test verileri
test.P=ptrans(:,iitst);
test.T=tn(:,iitst);

% Ağımızı burada oluşturuyoruz.
net=newff([minmax(ptr)],[4 9 1],{'tansig','logsig','purelin'},'trainbr');
net.trainParam.epochs=2500;
net=init(net);
% Ağımız oluşturuldu ve epoch değeri olarak 2500 verildi, initialize edildi

% Kurulan YSA önceden ayrıştırılmış olan eğitim, onaylama ve test
% değerlerine göre eğitiliyor
% Ağın ne kadar sürede eğitildiğini hesaplamak için sayaç başlatılıyor
tic;
[net,tr,Y1,E,Pf,Af]=train(net,ptr,ttr,[],[],val,test);
% Geçen süre ekranda gösteriliyor
Egitimde_Gecen_Sure=toc

% Eğitim sonunda elde edilen sonuçlar grafiksel olarak gösteriliyor
subplot(2,2,3), plot(tr.epoch,tr.perf,tr.epoch,tr.vperf,tr.epoch,tr.tperf)
TITLE('Ağın Eğitilmesinden Sonra Elde Edilen Değerler');
legend('Eğitim','Onaylama','Test',1);

```

```

ylabel('Squared error'); xlabel('Epoch')
grid on;

% Eğitilmiş olan ağ tüm verilere göre çalıştırılıyor.
y=sim(net,ptrans);

% Ağın çıktı değerleri yeniden gerçek değerlerine uygun olacak şekilde
% yeniden ölçekleniyor.
Y=poststd(y,meant,stdt);

% Hedef değerleri ve Ağın çıktıları aynı grafikte gösteriliyor
j=1:size(T,2);
subplot(2,2,1:2),plot(j,T,j,Y,'r'),grid on;
TITLE('Hedef Degerleri ve Egitilmis Agin Ciktilari');

% Hata değerleri hesaplanıyor ve grafiksel olarak gösteriliyor
err=T-Y;
subplot(2,2,4),plot(err),grid on;
TITLE('Hata Grafigi');

% Ağın performansı Mean Squared Error ile hesaplanarak ekranda gösteriliyor
HataOrani=mse(err)

```

B2CF01.M

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%   B2CF01.M   / trainbr / 5-2 / tansig-purelin %
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%   Geriye Yayılım (Back Propagation) %
%   ABD dolarının 5 gün sonraki değerine göre AL/SAT/BEKLE kararı üretme %
%   Kriz Dahil (1863 günlük veri) %
%   1 0 = AL, 0 1 = SAT, 0 0 = BEKLE demek %
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

% ekran ve hafızadaki değişkenler silinir.

```
clc, clear all;
```

% Daha önceden kayıt edilmiş veriler hafızaya yüklenir.

```
load P_AlSat;
```

```
T=T_AlSat;
```

% Ağın eğitilmesinde kullanılacak olan veriler ortalaması 0 ve

% standart sapma 1 olacak şekilde bir ön işleminden geçirilerek

% Yapay Sinir Ağıımıza uygulanacak şekilde ölçekleniyor

```
%[pn,meanp,stdp,tn,meant,stdt]=prestd(Pall,T);
```

```
[pn,meanp,stdp,tn,meant,stdt]=premnmx(Pall,T);
```

```
ptrans=pn;
```

```
[R,Q]=size(ptrans);
```

% Tüm seri veriler %70'i eğitim, %20'si onaylama ve %10'u da test için

% kullanılmak üzere parçalara ayrılıyor

```
iitr=1:round(Q*.7);
```

```
iival=round(Q*.7)+1:round(Q*.9);
```

```
iitst=round(Q*.9)+1:Q;
```

% Training (eğitim verileri)

```
ptr=ptrans(:,iitr);
```

```
ttr=tn(:,iitr);
```

% Validation(onaylama) verileri

```
val.P=ptrans(:,iival);
```

```
val.T=tn(:,iival);
```

% Test verileri

```
test.P=ptrans(:,iitst);
```

```
test.T=tn(:,iitst);
```

% Ağıımızı burada oluşturuyoruz.

```
net=newff([minmax(ptr)],[5 2],{'tansig','purelin'},'trainbr');
```

```
net.trainParam.epochs=2500;
```

```
net=init(net);
```

% Ağıımız oluşturuldu ve epoch değeri olarak 2500 verildi, initialize edildi

% Kurulan YSA önceden ayrıştırılmış olan eğitim, onaylama ve test

% değerlerine göre eğitiliyor

% Ağın ne kadar sürede eğitildiğini hesaplamak için sayaç başlatılıyor

```
tic;
```

```
[net,tr,Y1,E,Pf,Af]=train(net,ptr,ttr,[],[],val,test);
```

% Geçen süre ekranda gösteriliyor

```
Egitimde_Gecen_Sure=toc
```

% Eğitilmiş olan ağ tüm verilere göre çalıştırılıyor.

```
y=sim(net,ptrans);
```

```

% Aın ıktı deęerleri yeniden gerek deęerlerine uygun olacak ekilde
% yeniden lekleniyor.
% Y=poststd(y,meant,stdt);

Y=postmmx(y,meant,stdt);
y1=round(Y);

Hit1=0;
Say2=0;
Nereler=0;
for sayac=1:Q,
    if(y1(1,sayac)==T(1,sayac))&(y1(2,sayac)==T(2,sayac))
        Hit1=Hit1+1;
        if(sum(T(:,sayac))>0 %eęer bulunulan yer 0 0 deęilse
            Say2=Say2+1; %Doęru AL/SAT adedi
            Nereler(Say2)=sayac; %demekki AL/SAT
        end
    end
end

AL_Karari=0;
SAT_Karari=0;
for sayac=1:size(Nereler,2),
    if(T(1,Nereler(sayac))==1)&(T(2,Nereler(sayac))==0)
        Str1=sprintf('%d AL\n',Nereler(sayac));
        fprintf(1,Str1);
        AL_Karari=AL_Karari+1;
    end
    if(T(1,Nereler(sayac))==0)&(T(2,Nereler(sayac))==1)
        Str1=sprintf('%d SAT\n',Nereler(sayac));
        fprintf(1,Str1);
        SAT_Karari=SAT_Karari+1;
    end
end

Hit=100*Hit1/Q;
AL_SAT =sum(T,2);
AL_Oran =100*AL_Karari/AL_SAT(1);
Sat_Oran =100*SAT_Karari/AL_SAT(2);
Bekle_Oran=100*(Hit1-Say2)/(Q-sum(AL_SAT));

Str1=sprintf('\n\n%4d doęru AL kararı %9.4g
(Toplam=%4d)\n',AL_Karari,AL_Oran,AL_SAT(1));
Str2=sprintf('%4d doęru SAT kararı %9.4g
(Toplam=%4d)\n',SAT_Karari,Sat_Oran,AL_SAT(2));
Str3=sprintf('%4d doęru BEKLE kararı %9.4g (Toplam=%4d)\n',(Hit1-
Say2),Bekle_Oran,(Q-sum(AL_SAT)));
Str4=sprintf('\nGenel Performans (Hit Sayısı) :%g\n\n',Hit);
fprintf(1,Str1); fprintf(1,Str2); fprintf(1,Str3); fprintf(1,Str4);
Egitimde_Gecen_Sure

```

ELMCF01.M

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%   ELMCF01.M   / trainbr / 5-1 / tansig-purelin   %
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%   Elman   %
%   ABD dolarının ertesi gnk gerek deėerini elde etme   %
%   Kriz Dhil (1866 gnlk veri)   %
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% ekran ve hafızadaki deėiřkenler silinir.
clc, clear all;

% Daha nceden kayıt edilmiř veriler hafızaya yklenir.
load P_ErtesiGun;
%load P_ErtGun723;

% Aėın eėitilmesinde kullanılacak olan veriler ortalaması 0 ve
% standart sapma 1 olacak řekilde bir n iřlemnden geirilerek
% Yapay Sinir Aėımıza uygulanacak řekilde lekleniyor

[pn,meanp,stdp,tn,meant,stdt]=prestd(Pall,T);
%[pn,meanp,stdp,tn,meant,stdt]=premnmx(Pall,T);

ptrans=pn;
[R,Q]=size(ptrans);

% Tm seri veriler %70'i eėitim, %20'si onaylama ve %10'u da test iin
% kullanılmak zere paralara ayrılıyor
iitr=1:round(Q*.7);
iival=round(Q*.7)+1:round(Q*.9);
iitst=round(Q*.9)+1:Q;

% Training (eėitim verileri)
ptr=ptrans(:,iitr);
ttr=tn(:,iitr);

% Validation(onaylama) verileri
val.P=ptrans(:,iival);
val.T=tn(:,iival);

% Test verileri
test.P=ptrans(:,iitst);
test.T=tn(:,iitst);

% Aėımızı burada oluřturuyoruz.
net=newelm([minmax(ptr)],[5 1],{'tansig','purelin'},'trainbr');
net.trainParam.epochs=2500;
net=init(net);
% Aėımız oluřturuldu ve epoch deėeri olarak 2500 verildi, initialize edildi

% Kurulan YSA nceden ayrıştırılmıř olan eėitim, onaylama ve test
% deėerlerine gre eėitiliyor
% Aėın ne kadar srede eėitildiėini hesaplamak iin saya bařlatılıyor
tic;
[net,tr,Y1,E,Pf,Af]=train(net,ptr,ttr,[],[],val,test);
% Geen sre ekranda gsteriliyor
Egitimde_Gecen_Sure=toc

% Eėitim sonunda elde edilen sonular grafiksel olarak gsteriliyor
subplot(2,2,3), plot(tr.epoch,tr.perf,tr.epoch,tr.vperf,tr.epoch,tr.tperf)
TITLE('Aėın Eėitilmesinden Sonra Elde Edilen Deėerler');
legend('Egitim','Onaylama','Test',1);

```

```

ylabel('Squared error'); xlabel('Epoch')
grid on;

% Eğitilmiş olan ağ tüm verilere göre çalıştırılıyor.
y=sim(net,ptrans);

% Ağın çıktı değerleri yeniden gerçek değerlerine uygun olacak şekilde
% yeniden ölçekleniyor.
Y=poststd(y,meant,stdt);

% Hedef değerleri ve Ağın çıktıları aynı grafikte gösteriliyor
j=1:size(T,2);
subplot(2,2,1:2),plot(j,T,j,Y,'r'),grid on;
TITLE('Hedef Degerleri ve Egitilmis Agin Ciktilari');

% Hata değerleri hesaplanıyor ve grafiksel olarak gösteriliyor
err=T-Y;
subplot(2,2,4),plot(err),grid on;
TITLE('Hata Grafigi');

% Ağın performansı Mean Squared Error ile hesaplanarak ekranda gösteriliyor
HataOrani=mse(err)

```

EK-3. GELİŞTİRİLEN MATLAB DOSYALARININ İSİM TABLOSU

A: Ertesi günkü gerçek değeri elde etme, C: 2001 krizi dâhil

	01	02	03	04	05	06	07	08	09	10	11	12
	5-1 tansig- purelin	9-1 tansig- purelin	30-1 tansig- purelin	5-1 logsig- purelin	9-1 logsig- purelin	30-1 logsig- purelin	4-9-1 tansig- tansig- purelin	9-13-1 tansig- tansig- purelin	4-9-1 logsig- logsig- purelin	9-13-1 logsig- logsig- purelin	4-9-1 tansig- logsig- purelin	9-13-1 tansig- logsig- purelin
E trainbf	ACE01	ACE02	ACE03	ACE04	ACE05	ACE06	ACE07	ACE08	ACE09	ACE10	ACE11	ACE12
F trainbr	ACF01	ACF02	ACF03	ACF04	ACF05	ACF06	ACF07	ACF08	ACF09	ACF10	ACF11	ACF12
G trauegb	ACG01	ACG02	ACG03	ACG04	ACG05	ACG06	ACG07	ACG08	ACG09	ACG10	ACG11	ACG12
H trauegf	ACH01	ACH02	ACH03	ACH04	ACH05	ACH06	ACH07	ACH08	ACH09	ACH10	ACH11	ACH12
I trauegp	ACI01	ACI02	ACI03	ACI04	ACI05	ACI06	ACI07	ACI08	ACI09	ACI10	ACI11	ACI12
J trauegl	ACJ01	ACJ02	ACJ03	ACJ04	ACJ05	ACJ06	ACJ07	ACJ08	ACJ09	ACJ10	ACJ11	ACJ12
K traueglm	ACK01	ACK02	ACK03	ACK04	ACK05	ACK06	ACK07	ACK08	ACK09	ACK10	ACK11	ACK12
L traueglx	ACL01	ACL02	ACL03	ACL04	ACL05	ACL06	ACL07	ACL08	ACL09	ACL10	ACL11	ACL12
M traueglm	ACM01	ACM02	ACM03	ACM04	ACM05	ACM06	ACM07	ACM08	ACM09	ACM10	ACM11	ACM12
N traues	ACN01	ACN02	ACN03	ACN04	ACN05	ACN06	ACN07	ACN08	ACN09	ACN10	ACN11	ACN12
O traup	ACO01	ACO02	ACO03	ACO04	ACO05	ACO06	ACO07	ACO08	ACO09	ACO10	ACO11	ACO12
P trauecg	ACP01	ACP02	ACP03	ACP04	ACP05	ACP06	ACP07	ACP08	ACP09	ACP10	ACP11	ACP12

A: Ertesi günkü gerçek değeri elde etme, D: 2001 krizi hariç

	01	02	03	04	05	06	07	08	09	10	11	12
	5-1 tansig- purelin	9-1 tansig- purelin	30-1 tansig- purelin	5-1 logsig- purelin	9-1 logsig- purelin	30-1 logsig- purelin	4-9-1 tansig- tansig- purelin	9-13-1 tansig- tansig- purelin	4-9-1 logsig- logsig- purelin	9-13-1 logsig- logsig- purelin	4-9-1 tansig- logsig- purelin	9-13-1 tansig- logsig- purelin
E trainbf	ADE01	ADE02	ADE03	ADE04	ADE05	ADE06	ADE07	ADE08	ADE09	ADE10	ADE11	ADE12
F trainbr	ADF01	ADF02	ADF03	ADF04	ADF05	ADF06	ADF07	ADF08	ADF09	ADF10	ADF11	ADF12
G trauegb	ADG01	ADG02	ADG03	ADG04	ADG05	ADG06	ADG07	ADG08	ADG09	ADG10	ADG11	ADG12
H trauegf	ADH01	ADH02	ADH03	ADH04	ADH05	ADH06	ADH07	ADH08	ADH09	ADH10	ADH11	ADH12
I trauegp	ADI01	ADI02	ADI03	ADI04	ADI05	ADI06	ADI07	ADI08	ADI09	ADI10	ADI11	ADI12
J trauegl	ADJ01	ADJ02	ADJ03	ADJ04	ADJ05	ADJ06	ADJ07	ADJ08	ADJ09	ADJ10	ADJ11	ADJ12
K traueglm	ADK01	ADK02	ADK03	ADK04	ADK05	ADK06	ADK07	ADK08	ADK09	ADK10	ADK11	ADK12
L traueglx	ADL01	ADL02	ADL03	ADL04	ADL05	ADL06	ADL07	ADL08	ADL09	ADL10	ADL11	ADL12
M traueglm	ADM01	ADM02	ADM03	ADM04	ADM05	ADM06	ADM07	ADM08	ADM09	ADM10	ADM11	ADM12
N traues	ADN01	ADN02	ADN03	ADN04	ADN05	ADN06	ADN07	ADN08	ADN09	ADN10	ADN11	ADN12
O traup	ADO01	ADO02	ADO03	ADO04	ADO05	ADO06	ADO07	ADO08	ADO09	ADO10	ADO11	ADO12
P trauecg	ADP01	ADP02	ADP03	ADP04	ADP05	ADP06	ADP07	ADP08	ADP09	ADP10	ADP11	ADP12

EK-4. ACx01 GRUBUNDA ELDE EDİLEN DİĞER SONUÇLAR


tansig – purelin / 5 – 1 yapısındaki YSA’lar.

E. trainbfg:

Deneme	Epoch	Süre (sn)	Hata Oranı
1	24	2,25300	0,00150
2	19	1,97300	0,00290
3	17	1,71300	0,00770
4	19	1,82300	0,00320
5	20	1,98200	0,00340
ORTALAMA	19,8	1,94880	0,00374

Tablo 21 – ACE01(trainbfg) ağına ait veriler

En iyi sonucun elde edildiği 1. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 28 – ACE01 kodlu YSA’nın ürettiği grafikler

F. trainbr:

Deneme	Epoch	Süre	Hata Oranı
1	30	8,17200	0,000312660
2	31	9,29300	0,000535260
3	26	7,46000	0,000709590
4	30	8,03200	0,000651610
5	28	7,49100	0,001000000
ORTALAMA	29	8,0896	0,000641824

Tablo 22 – ACF01(trainbr) ağına ait veriler

En iyi sonucun elde edildiği 1. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 29 – ACF01 kodlu YSA'nın ürettiği grafikler

G. traincgb:

Deneme	Epoch	Süre	Hata Oranı
1	15	1,4630	0,00580000
2	19	1,4420	0,01240000
3	27	2,1530	0,00100000
4	21	1,6020	0,00930000
5	28	2,0430	0,02850000
ORTALAMA	22	1,7406	0,01140000

Tablo 23 – ACG01(traincgb) ağına ait veriler

En iyi sonucun elde edildiği 3. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 30 – ACG01 kodlu YSA'nın ürettiği grafikler

H. traincgf:

Deneme	Epoch	Süre	Hata Oranı
1	17	1,3820	0,00240000
2	15	1,4120	0,00270000
3	22	1,5620	0,00250000
4	35	2,1530	0,00290000
5	14	1,3320	0,00430000
ORTALAMA	20,6	1,5682	0,00296000

Tablo 24 – ACH01(traincgf) ağına ait veriler

En iyi sonucun elde edildiği 1. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 31 – ACH01 kodlu YSA'nın ürettiği grafikler

I. traincgp:

Deneme	Epoch	Süre	Hata Oranı
1	28	1,9830	0,01200000
2	26	1,8830	0,00130000
3	27	1,9830	0,01010000
4	16	1,4520	0,00260000
5	17	1,3920	0,00180000
ORTALAMA	22,8	1,7386	0,00556000

Tablo 25 – ACI01(traincgp) ağına ait veriler

En iyi sonucun elde edildiği 2. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 32 – ACI01 kodlu YSA'nın ürettiği grafikler

J. traingd:

Deneme	Epoch	Süre	Hata Oranı
1	352	8,9930	0,00360000
2	2500	60,2470	0,00280000
3	2500	59,5460	0,05590000
4	2500	58,4750	0,04440000
5	1226	28,7220	0,02760000
ORTALAMA	1815,6	43,1966	0,02686000

Tablo 26 – ACJ01(traingd) ağına ait veriler

En iyi sonucun elde edildiği 2. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 33 – ACJ01 kodlu YSA'nın ürettiği grafikler

K. traingdm:

Deneme	Epoch	Süre	Hata Oranı
1	65	2,2540	0,07200000
2	15	1,7220	0,07440000
3	27	1,4630	0,05410000
4	26	1,4120	0,04550000
5	53	1,9230	0,01710000
ORTALAMA	37,2	1,7548	0,05262000

Tablo 27 – ACK01(traingdm) ağına ait veriler

En iyi sonucun elde edildiği 2. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 34 – ACK01 kodlu YSA'nın ürettiği grafikler

L. traingdx:

Deneme	Epoch	Süre	Hata Oranı
1	42	1,7020	0,08130000
2	42	1,7630	0,02290000
3	18	1,1210	0,04380000
4	13	1,0320	0,03340000
5	49	1,8830	0,00570000
ORTALAMA	32,8	1,5002	0,03742000

Tablo 28 – ACL01(traingdx) ağına ait veriler

En iyi sonucun elde edildiği 5. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 35 – ACL01 kodlu YSA'nın ürettiği grafikler

M. trainlm:

Deneme	Epoch	Süre	Hata Oranı
1	17	4,1060	0,00190000
2	14	3,4750	0,00095625
3	16	3,9250	0,00150000
4	18	4,2060	0,00180000
5	8	2,2530	0,02090000
ORTALAMA	14,6	3,5930	0,00541125

Tablo 29 – ACM01(trainlm) ağına ait veriler

En iyi sonucun elde edildiği 2. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 36 – ACM01 kodlu YSA'nın ürettiği grafikler

N. trainoss:

Deneme	Epoch	Süre	Hata Oranı
1	10	1,1110	0,04920000
2	17	1,3420	0,06870000
3	9	1,0620	0,02390000
4	23	1,6630	0,00380000
5	47	2,4340	0,01390000
ORTALAMA	21,2	1,5224	0,03190000

Tablo 30 – ACN01(trainoss) ağına ait veriler

En iyi sonucun elde edildiği 4. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 37 – ACN01 kodlu YSA'nın ürettiği grafikler

O. trainrp:

Deneme	Epoch	Süre	Hata Oranı
1	16	1,1220	0,02040000
2	10	0,9120	0,04190000
3	12	0,9410	0,02060000
4	13	1,0620	0,01020000
5	13	0,9620	0,01430000
ORTALAMA	12,8	0,9998	0,02148000

Tablo 31 – ACO01(trainrp) ağına ait veriler

En iyi sonucun elde edildiği 4. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 38 – ACO01 kodlu YSA'nın ürettiği grafikler

P. trainscg:

Deneme	Epoch	Süre	Hata Oranı
1	12	1,1410	0,01830000
2	20	1,2920	0,00810000
3	15	1,2020	0,00500000
4	15	1,2610	0,00290000
5	36	1,9830	0,00290000
ORTALAMA	19,6	1,3758	0,00744000

Tablo 32 – ACP01(trainscg) ağına ait veriler

En iyi sonucun elde edildiği 4. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.



Şekil 39 – ACP01 kodlu YSA'nın ürettiği grafikler

EK-5. ACx04 GRUBUNDA ELDE EDİLEN DİĞER SONUÇLAR


logsig – purelin / 5 – 1 yapısındaki YSA'lar.

E. trainbfg:

Deneme	Epoch	Süre	Hata Oranı
1	37	3,18400	0,001100000
2	41	3,47500	0,003800000
3	27	2,81400	0,001800000
4	27	2,72400	0,002900000
5	15	1,91200	0,004700000
ORTALAMA	29,4	2,8218	0,002860000

Tablo 33 – ACE04(trainbfg) ağına ait veriler

En iyi sonucun elde edildiği 1. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 40 – ACE04 kodlu YSA'nın ürettiği grafikler

F. trainbr:

Deneme	Epoch	Süre	Hata Oranı
1	35	9,79400	0,00450000
2	29	8,64300	0,00300000
3	31	9,12300	0,00070729
4	22	6,77000	0,00100000
5	27	7,85200	0,00062503
ORTALAMA	28,8	8,4364	0,00196646

Tablo 34 – ACF04(trainbr) ağına ait veriler

En iyi sonucun elde edildiği 5. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 41 – ACF04 kodlu YSA'nın ürettiği grafikler

G. traincgb:

Deneme	Epoch	Süre	Hata Oranı
1	9	1,32200	0,035100000
2	26	2,38300	0,002400000
3	9	1,32200	0,018200000
4	15	1,70200	0,003100000
5	11	1,37200	0,016000000
ORTALAMA	14	1,62020	0,014960000

Tablo 35 – ACG04(traincgb) ağına ait veriler

En iyi sonucun elde edildiği 2. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 42 – ACG04 kodlu YSA'nın ürettiği grafikler

H. traincgf:

Deneme	Epoch	Süre	Hata Oranı
1	22	2,00300	0,004000000
2	27	2,37300	0,006100000
3	13	1,43200	0,008400000
4	10	1,34000	0,019400000
5	11	1,28200	0,008000000
ORTALAMA	16,6	1,686	0,00918

Tablo 36 – ACH04(traincgf) ağına ait veriler

En iyi sonucun elde edildiği 1. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 43 – ACH04 kodlu YSA'nın ürettiği grafikler

I. traincgp:

Deneme	Epoch	Süre	Hata Oranı
1	20	1,75300	0,004200000
2	17	1,77300	0,006600000
3	28	2,26300	0,001200000
4	17	1,86300	0,004100000
5	14	1,43200	0,006200000
ORTALAMA	19,2	1,8168	0,00446

Tablo 37 – ACI04(traincgp) ağına ait veriler

En iyi sonucun elde edildiği 3. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 44 – ACI04 kodlu YSA'nın ürettiği grafikler

J. traingd:

Deneme	Epoch	Süre	Hata Oranı
1	317	9,08300	0,011900000
2	189	5,52700	0,032000000
3	129	4,08500	0,082500000
4	301	8,21200	0,023200000
5	303	8,33200	0,008800000
ORTALAMA	247,8	7,0478	0,03168

Tablo 38 – ACJ04(traingd) ağına ait veriler

En iyi sonucun elde edildiği 5. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 45 – ACJ04 kodlu YSA'nın ürettiği grafikler

K. traingdm:

Deneme	Epoch	Süre	Hata Oranı
1	201	6,28900	0,011800000
2	255	7,45100	0,019300000
3	280	8,29200	0,203000000
4	217	6,36000	0,151000000
5	229	7,01000	0,014000000
ORTALAMA	236,4	7,0804	0,07982

Tablo 39 – ACK04(traingdm) ağına ait veriler

En iyi sonucun elde edildiği 1. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 46 – ACK04 kodlu YSA'nın ürettiği grafikler

L. traingdx:

Deneme	Epoch	Süre	Hata Oranı
1	69	2,47300	0,021900000
2	55	2,17300	0,018300000
3	64	2,40300	0,025700000
4	62	2,41300	0,032000000
5	63	2,49400	0,068100000
ORTALAMA	62,6	2,3912	0,0332

Tablo 40 – ACL04(traingdx) ağına ait veriler

En iyi sonucun elde edildiği 2. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 47 – ACL04 kodlu YSA'nın ürettiği grafikler

M. trainlm:

Deneme	Epoch	Süre	Hata Oranı
1	25	6,32900	0,001000000
2	11	3,05500	0,001100000
3	9	2,74400	0,005300000
4	16	4,15000	0,001400000
5	23	5,60800	0,001100000
ORTALAMA	16,8	4,3772	0,00198

Tablo 41 – ACM04(trainlm) ağına ait veriler

En iyi sonucun elde edildiği 1. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 48 – ACM04 kodlu YSA'nın ürettiği grafikler

N. trainoss:

Deneme	Epoch	Süre	Hata Oranı
1	20	1,57000	0,008000000
2	13	1,42200	0,004700000
3	19	1,66200	0,007000000
4	63	3,76500	0,003300000
5	36	2,26300	0,002400000
ORTALAMA	30,2	2,1364	0,00508

Tablo 42 – ACN04(trainoss) ağına ait veriler

En iyi sonucun elde edildiği 5. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 49 – ACN04 kodlu YSA'nın ürettiği grafikler

O. trainrp:

Deneme	Epoch	Süre	Hata Oranı
1	22	1,27200	0,003000000
2	38	1,85300	0,003300000
3	30	1,73200	0,002100000
4	12	1,12200	0,009800000
5	15	1,08200	0,002800000
ORTALAMA	23,4	1,4122	0,0042

Tablo 43 – ACO04(trainrp) ağına ait veriler

En iyi sonucun elde edildiği 3. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 50 – ACO04 kodlu YSA'nın ürettiği grafikler

P. trainscg:

Deneme	Epoch	Süre	Hata Oranı
1	28	2,13300	0,001500000
2	43	2,71300	0,003500000
3	39	2,52400	0,002000000
4	16	1,47200	0,004500000
5	25	1,83300	0,001200000
ORTALAMA	30,2	2,135	0,00254

Tablo 44 – ACP04(trainscg) ağına ait veriler

En iyi sonucun elde edildiği 5. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.



Şekil 51 – ACP04 kodlu YSA'nın ürettiği grafikler

EK– 6. BAYESIAN REGULARIZATION (trainbr) ALGORİTMASININ DİĞER MİMARİLERDE KULLANIMI (ACFy)

01. tansig-purelin / 5–1 (ACF01)


EK-4’de “ACx01 Grubunda Elde Edilen Diğer Sonuçlar” başlığı altında verilmiştir.

02. tansig-purelin / 9–1 (ACF02)

Deneme	Epoch	Süre	Hata Oranı
1	38	33,5280	0,0008797
2	29	24,9960	0,0005032
3	41	34,4490	0,0013000
4	22	19,6580	0,0005149
5	23	20,6400	0,0028000
ORTALAMA	30,6	26,6542	0,0011995

Tablo 45 – ACF02 ağına ait veriler

En iyi sonucun elde edildiği 2. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 52 – ACF02 kodlu YSA’nın ürettiği grafikler

03. tansig-purelin / 30-1 (ACF03)

Deneme	Epoch	Süre	Hata Oranı
1	14	170,51500	0,000720220
2	15	192,58700	0,000983210
3	15	197,19400	0,000807460
4	15	212,64600	0,000547940
5	28	404,48200	0,000625140
ORTALAMA	17,4	235,4848	0,000736794

Tablo 46 – ACF03 ağına ait veriler

En iyi sonucun elde edildiği 4. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.



Şekil 53 – ACF03 kodlu YSA'nın ürettiği grafikler

04. logsig-purelin / 5–1 (ACF04)


EK-5’de “ACx04 Grubunda Elde Edilen Diğer Sonuçlar” başlığı altında verilmiştir.

05. logsig-purelin / 9–1 (ACF05)

Deneme	Epoch	Süre	Hata Oranı
1	28	7,40100	0,001700000
2	12	4,17600	0,000507110
3	16	5,59800	0,000775530
4	24	7,13100	0,001600000
5	24	7,24000	0,000320400
ORTALAMA	20,8	6,3092	0,00098061

Tablo 47 – ACF05 ağına ait veriler

En iyi sonucun elde edildiği 5. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 54 – ACF05 kodlu YSA’nın ürettiği grafikler

06. logsig-purelin / 30-1 (ACF06)

Deneme	Epoch	Süre	Hata Oranı
1	17	215,56000	0,003400000
2	17	221,14800	0,000832170
3	14	183,28400	0,001100000
4	14	185,16600	0,000524940
5	18	238,27300	0,002500000
ORTALAMA	16	208,6862	0,001671422

Tablo 48 – ACF06 ağına ait veriler

En iyi sonucun elde edildiği 4. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 55 – ACF06 kodlu YSA'nın ürettiği grafikler

07. tansig-tansig-purelin / 4-9-1 (ACF07)

Deneme	Epoch	Süre	Hata Oranı
1	39	11,17600	0,007900000
2	15	5,21800	0,000358580
3	24	7,20000	0,002500000
4	28	8,90300	0,001600000
5	19	6,74000	0,002400000
ORTALAMA	25	7,8474	0,002951716

Tablo 49 – ACF07 ağına ait veriler

En iyi sonucun elde edildiği 2. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 56 – ACF07 kodlu YSA'nın ürettiği grafikler

08. tansig-tansig-purelin / 9-13-1 (ACF08)

Deneme	Epoch	Süre	Hata Oranı
1	27	37,60400	0,002700000
2	17	25,08600	0,000712550
3	17	24,82500	0,000396790
4	20	29,59200	0,000533850
5	20	29,40200	0,002400000
ORTALAMA	20,2	29,3018	0,001348638

Tablo 50 – ACF08 ağına ait veriler

En iyi sonucun elde edildiği 2. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 57 – ACF08 kodlu YSA'nın ürettiği grafikler

09. logsig-logsig-purelin / 4-9-1 (ACF09)

Deneme	Epoch	Süre	Hata Oranı
1	16	5,39700	0,000912660
2	30	10,18500	0,002900000
3	11	4,36700	0,001400000
4	11	4,33700	0,005300000
5	14	4,97700	0,001100000
ORTALAMA	16,4	5,8526	0,002322532

Tablo 51 – ACF09 ağına ait veriler

En iyi sonucun elde edildiği 1. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 58 – ACF09 kodlu YSA'nın ürettiği grafikler

10. logsig-logsig-purelin / 9-13-1 (ACF10)

Deneme	Epoch	Süre	Hata Oranı
1	17	23,65400	0,000668240
2	19	26,70900	0,001500000
3	23	32,08600	0,000813980
4	18	26,09800	0,001100000
5	26	36,05200	0,004600000
ORTALAMA	20,6	28,9198	0,001736444

Tablo 52 – ACF10 ağına ait veriler

En iyi sonucun elde edildiği 1. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 59 – ACF10 kodlu YSA'nın ürettiği grafikler

11. tansig-logsig-purelin / 4-9-1 (ACF11)

Deneme	Epoch	Süre	Hata Oranı
1	23	7,22000	0,002200000
2	19	6,36900	0,001400000
3	23	7,77100	0,000503040
4	24	7,95100	0,000714110
5	28	8,90300	0,000753480
ORTALAMA	23,4	7,6428	0,001114126

Tablo 53 – ACF11 ağına ait veriler

En iyi sonucun elde edildiği 3. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 60 – ACF11 kodlu YSA'nın ürettiği grafikler

12. tansig-logsig-purelin / 9–13–1 (ACF12)

Deneme	Epoch	Süre	Hata Oranı
1	23	31,28500	0,002600000
2	24	33,29800	0,001200000
3	22	31,49500	0,000459750
4	24	35,09000	0,001500000
5	23	34,45900	0,000638020
ORTALAMA	23,2	33,1254	0,001279554

Tablo 54 – ACF12 ağına ait veriler

En iyi sonucun elde edildiği 3. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.



Şekil 61 – ACF12 kodlu YSA'nın ürettiği grafikler


EK-7. KRİZ SONRASINDAKİ VERİLERLE YAPILAN DENEMELER

trainbr / tansig-purelin / 5-1 Yapısı (ADF01)

Deneme	Epoch	Süre	Hata Oranı
1	12	3,00400	0,000287490
2	26	5,34800	0,000180340
3	11	3,44500	0,000307330
4	17	3,85600	0,000124290
5	12	3,22400	0,000176340
ORTALAMA	15,6	3,7754	0,000215158

Tablo 55 – ADF01 ağına ait veriler

En iyi sonucun elde edildiği 4. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.




Şekil 62 – ADF01 kodlu YSA'nın ürettiği grafikler

trainbr / tansig-logsig-purelin / 4–9–1 Yapısı (ADF11)

Deneme	Epoch	Süre	Hata Oranı
1	14	3,74600	0,000227150
2	13	3,55600	0,000153140
3	15	4,25600	0,000146400
4	13	3,80500	0,000254560
5	14	3,59500	0,000217830
ORTALAMA	13,8	3,7916	0,000199816

Tablo 56 – ADF01 ağına ait veriler

En iyi sonucun elde edildiği 3. denemenin üretmiş olduğu grafikler aşağıdaki gibidir.



Şekil 63 – ADF11 kodlu YSA'nın ürettiği grafikler

EK-8. ELMAN AĞLARI İLE YAPILAN DENEMELER


trainbr / tansig-purelin / 5-1 yapısı (ELMCF01)

Eğitim algoritması olarak trainbr kullanan, tek gizli katmanında 5 adet gizli nöron bulunan elman ağının ürettiği sonuçlar aşağıdaki gibidir.¹⁶

Deneme	Epoch	Süre	Hata Oranı
1	29	9,46800	0,000316130
2	27	8,48400	0,000458060
3	32	9,73500	0,000625140
4	29	9,48500	0,000425910
5	30	9,32800	0,000682430
ORTALAMA	29,4	9,3	0,000501534

Tablo 57 – ELMCF01 ağına ait veriler

En iyi sonucun elde dildiği 1. denemeye ilişkin grafikler aşağıdaki gibidir.



Şekil 64 – ELMCF01 kodlu YSA'nın ürettiği grafikler

¹⁶ Tüm denemelere dair sonuçları ve elde edilmiş grafikleri tezimizin ekinde verilmiş olan CD içerisinde ELMAN. XLS ismi ile kayıt edilmiş Excel dosyasında bulabilirsiniz


trainbr / tansig-logsig-purelin / 4-9-1 yapısı (ELMCF11)

Eğitim algoritması olarak trainbr kullanan, çift gizli katmanlı ve gizli katmanlarında sırasıyla 4 ve 9 adet gizli nöron bulunan elman ağının ürettiği sonuçlar aşağıdaki gibidir.

Deneme	Epoch	Süre	Hata Oranı
1	26	13,32800	0,000591370
2	14	7,89100	0,002100000
3	17	9,65600	0,000739980
4	18	10,93800	0,000865830
5	18	10,17200	0,000285000
ORTALAMA	18,6	10,397	0,000916436

Tablo 58 – ELMCF11 ağına ait veriler

En iyi sonucun elde dildiği 5. denemeye ilişkin grafikler aşağıdaki gibidir.



Şekil 65 – ELMCF11 kodlu YSA'nın ürettiği grafikler

ÖZGEÇMİŞ

Ömür YILDIZ 01.01.1976 tarihinde Eskişehir’de doğdu. İlk, orta ve lise öğrenimini Eskişehir’de tamamladı. Teknik lisenin elektronik bölümünden mezun olduktan sonra eğitimini yine elektronik üzerine devam ettirmek amacıyla 1994 yılında girdiği Osmangazi Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü’nden 1999 yılında mezun oldu. Yine Osmangazi Üniversitesi’nin Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Kontrol ve Kumanda Sistemleri Bilim Dalı’ndaki öğrenimini 1999 – 2002 yılları arasında tamamlayarak Elektrik-Elektronik Yüksek Mühendisi ünvanını kazandı.

2000 yılında Eskişehir’de özel bir firmada proje mühendisi olarak çalışmaya başladı. Nisan 2003 – Nisan 2004 tarihleri arasındaki askerlik vazifesini Milli Savunma Bakanlığı, İnşaat Emlak ve NATO Enfrastrüktür Dairesi Başkanlığı’nda Yedek Subay olarak tamamladı. Askerlik dönüşünden itibaren aynı özel firmada grup lideri olarak çalışmaktadır.

Yazılım ve bilgisayar donanımı ağırlıklı olarak çalışmakta olduğu savunma sanayi ve demiryolları projeleri ile ilgili “*Demiryolu Çeken Araçlarında Güvenli Ulaşım Teknolojileri ve Uygulamaları*” başlıklı bir yayını bulunmaktadır.