

**T.C.
BOZOK ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI**

Yüksek Lisans Tezi

**YATIRIM FONLARI NET VARLIK
DEĞERLERİNİN YAPAY SİNİR AĞLARI
YÖNTEMİYLE TAHMİN EDİLMESİ**

Fikriye KARACAMEYDAN

Tez Danışmanı

Yrd. Doç. Dr. Veli AKEL

Yozgat 2009

T.C.
BOZOK ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI

Yüksek Lisans Tezi

YATIRIM FONLARI NET VARLIK
DEĞERLERİNİN YAPAY SİNİR AĞLARI
YÖNTEMİYLE TAHMİN EDİLMESİ

Hazırlayan

Fikriye KARACAMEYDAN

Tez Danışmanı

Yrd. Doç. Dr. Veli AKEL

Yozgat 2009

T.C.
BOZOK ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

TEZ ONAYI

Enstitümüzün İşletme Anabilim Dalı 8011010009 numaralı öğrencisi Fikriye Karacameydan'ın hazırladığı "Yatırım Fonları Net Varlık Değerlerinin Yapay Sınır Ağları Yöntemi ile Tahmin Edilmesi" başlıklı YÜKSEK LİSANS tezi ile ilgili TEZ SAVUNMA SINAVI, Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği uyarınca 24/11/2009 günü saat 11:00'de yapılmış, tezin onayına OY BİRLİĞİYLE karar verilmiştir.

Başkan

Prof. Dr. Emine KILAVUZ

Üye

Yrd. Doç. Dr. Veli AKEL (Danışman)

Üye

Yrd. Doç. Dr. Tansel HACIHASANOĞLU

ONAY:

Bu tezin kabulü, Enstitü Yönetim Kurulu'nun 01.12.09 tarih ve ..29.....sayılı kararı ile onaylanmıştır.

01.12.2009
Prof. Dr.
Hayrettin RAYMAN

ÖNSÖZ

Bu çalışmada, 6 adet makro ekonomik değişkenden yararlanarak, Ocak 2001-Aralık 2008 döneminde Türkiye’de faaliyet gösteren 19 adet A tipi ve 19 adet B tipi yatırım fonunun net varlık değerlerinin YSA tekniği ve regresyon analizi yöntemleriyle tahmin edilmesi ve bu iki yöntemden elde edilen tahmin sonuçlarının karşılaştırılması amaçlanmıştır.

Çalışmanın hazırlanması boyunca benden hiçbir desteğini ve katkısını esirgemeyen tez danışmanım Yrd. Doç. Dr. Veli AKEL’e göstermiş olduğu ilgi ve katkılardan dolayı teşekkür ederim.

Çalışmamın uygulama kısmında yapmış olduğu katkılardan dolayı Yrd. Doç.Dr. Funda YURDAKUL, Yrd. Doç.Dr. Murat ÇETİN ve Yrd. Doç.Dr. Şenol ALTAN’a ve ayrıca tezimin son şeklini almasında değerli katkıları olan Arş. Gör. Yunus Emre AKDOĞAN’a ayırmış oldukları zamandan dolayı teşekkür ederim.

Son olarak, sevgili eşim Edip’e, kızım Doğa’ya ve canım anneme göstermiş oldukları maddi ve manevi desteklerden dolayı teşekkürü bir borç bilirim.

ÖZET

Yüksek Lisans Tezi

Yatırım Fonları Net Varlık Değerlerinin Yapay Sinir Ağları Yöntemi İle Tahmin Edilmesi

Fikriye Karacameydan

Bozok Üniversitesi

Sosyal Bilimler Enstitüsü

İşletme Anabilim Dalı

2009: 165 Sayfa

Bu tez çalışmasının amacı, Türkiye'deki yatırım fonlarının net varlık değerlerinin, Yapay Sinir Ağları (YSA) yöntemiyle tahmin edilmesidir.

19 adet A tipi ve 19 adet B tipi olmak üzere toplam 38 adet yatırım fonunun net varlık değerlerinin tahmin edilmesi için 6 adet makro ekonomik değişkenden yararlanılmıştır. Bu makro ekonomik değişkenler Aktif Tahvilin Faiz Oranı (ATFAİZ), ABD Doları/TL Kuru (DK), İMKB-100 Endeksi (İMKB100), Para Arzı (M2), Sanayi Üretim Endeksi (SUE) ve Toptan Eşya Fiyat Endeksi (TEFE)'dir.

Çalışma Ocak 2001- Aralık 2008 dönemine ait, tüm değişkenler için aylık kapanış fiyatlarından oluşmaktadır. Bu çalışmada yatırım fonu net varlık değeri hem yapay sinir ağları hem de regresyon modeli çerçevesinde öngörülmüş ve her iki yöntem için elde edilen sonuçların öngörü performansları karşılaştırılmıştır.

Analiz sonuçları, yatırım fonları net varlık değerlerini tahmin etmek için geliştirilen YSA modellerinin çok düşük hata düzeyinde ve regresyon yönteminden daha başarılı sonuçlar verdiğini ortaya koymuştur.

Anahtar Kelimeler: Yatırım Fonları, Net Varlık Değeri, YSA, Finansal Tahmin

ABSTRACT

MSc. Thesis

Forecasting Mutual Fund Net Asset Values Using Artificial Neural Networks

Fikriye Karacameydan

Bozok University

Institute of Social Sciences

Department of Business

2009: 165 Pages

The purpose of this study is to forecast net asset values of Turkish mutual funds using Artificial Neural Networks (ANN) method. In order to forecast net asset values of 38 mutual funds (19 A type and 19 B type), 6 macro economic variables are used. These variables are Active Bond Interest Rate, USD/TL Exchange Rate, ISE National 100 Index, M2 Money Supply, Industrial Production Index and Wholesale Price Index.

The forecasting period consists of monthly closing prices for these variables in the period of January 2001-December 2008. In this study, net asset values of mutual funds have been forecasted within the frame of both Artificial Neural Networks and regression model and forecasting performances of the results obtained from two methods have been compared.

Analysis results reveal that ANN method is capable of forecasting net asset values of mutual funds at a very low error level. Furthermore, forecasting capability of ANN is compared with regression method and ANN method seems to outperform regression method.

Keywords: Mutual Funds, Net Asset Value, Artificial Neural Network, Financial Forecasting

İÇİNDEKİLER

	<u>Sayfa</u>
ÖNSÖZ.....	iv
ÖZET.....	v
ABSTRACT	vi
TABLolar LİSTESİ.....	xi
ŞEKİLLER LİSTESİ.....	xiii
GRAFİKLER LİSTESİ	xiv
KISALTMALAR LİSTESİ.....	xv
GİRİŞ	1

BİRİNCİ BÖLÜM

MENKUL KIYMET YATIRIM FONLARI

1.1. Yatırım Fonu Kavramı ve Özellikleri.....	3
1.2. Yatırım Fonlarının Fonksiyonları.....	6
1.2.1. Ölçek Ekonomisi.....	7
1.2.2. Çeşitlendirme.....	7
1.2.3. Profesyonel Portföy Yönetimi	8
1.3. Yatırım Fonlarının Sınıflandırılması	9
1.3.1. Pay Senedinin Değişebilirliğine Göre Yatırım Fonları	9
1.3.1.1. Açık Uçlu (Open-Ended) Yatırım Fonları	9
1.3.1.2. Kapalı Uçlu (Closed-Ended) Yatırım Fonları	10
1.3.2. Portföyün Niteliğine Göre Yatırım Fonları	10
1.3.2.1. Hisse Senedi Fonu	10
1.3.2.2. Tahvil Fonları.....	11
1.3.2.3. Para Piyasası Fonları	11
1.3.3. Kar Dağıtımına Göre Yatırım Fonları	11
1.3.3.1. Kar Dağıtan Fonlar	11
1.3.3.2. Kar Dağıtmayan Fonlar	12
1.3.4. Yatırım Hedeflerine Göre Yatırım Fonları	12
1.4. Türkiye’de Yatırım Fonları.....	12
1.4.1. Yasal Çerçevesi.....	12

1.4.2.	Fon Tür ve Tipleri.....	13
1.4.3.	Katılma Belgesi.....	17
1.5.	Yatırım Fonlarının Yatırımcılara ve Sermaye Piyasasına Sağladığı Katkılar.....	18
1.5.1.	Tasarrufçu Açısından Sağladığı Katkılar.....	18
1.5.2.	Kurucu Açısından Sağladığı Katkılar.....	19
1.5.3.	Ekonomi Açısından Sağladığı Katkılar.....	19
1.6.	Yatırım Fonlarının Tarihsel Gelişimi.....	20
1.6.1.	Yatırım Fonlarının Dünyadaki Gelişimi.....	20
1.6.2.	Yatırım Fonlarının Türkiye'deki Gelişimi.....	26
1.7.	Genel Değerlendirme.....	30

İKİNCİ BÖLÜM

YAPAY SİNİR AĞLARI

2.1.	Literatürdeki YSA Tanımları.....	34
2.2.	Yapay Sinir Ağları Yönteminin Tarihçesi.....	36
2.3.	Biyolojik Sinir Sistemi.....	40
2.4.	Yapay Nöron.....	41
2.4.1.	Girdiler.....	43
2.4.2.	Ağırlıklar.....	43
2.4.3.	Toplama (Birleştirme) Fonksiyonu.....	43
2.4.4.	Aktivasyon Fonksiyonu.....	44
2.4.5.	Hücrenin Çıktısı.....	46
2.5.	Yapay Sinir Ağlarının Genel Yapısı.....	46
2.6.	Yapay Sinir Ağlarının Sınıflandırılması.....	48
2.6.1.	Yapay Sinir Ağlarının Bağlantı Yapılarına Göre Sınıflandırılması.....	48
2.6.1.1.	İleri Beslemeli Ağlar.....	48
2.6.1.2.	Geri Beslemeli Ağlar.....	50
2.6.2.	Yapay Sinir Ağlarının Öğrenme Şekillerine Göre Sınıflandırılması.....	51
2.6.2.1.	Danışmanlı Öğrenme.....	52
2.6.2.2.	Danışmansız Öğrenme.....	53
2.6.2.3.	Destekleyici Öğrenme.....	53
2.6.3.	Yapay Sinir Ağlarının Katman Sayısına Göre Sınıflandırılması.....	54
2.6.3.1.	Tek Katmanlı Ağlar.....	54

2.6.3.2. Çok Katmanlı Yapay Sinir Ağları.....	55
2.7. Öğrenme Algoritması	58
2.8. Öğrenme Kuralları.....	64
2.9. Yapay Sinir Ağlarının Uygulama Alanları	65
2.10. Yapay Sinir Ağlarının Özellikleri	66
2.11. Yapay Sinir Ağlarının Tasarımı	69
2.11.1. Yapay Sinir Ağlarının Eğitimi ve Testi.....	69
2.11.2. Ağ Yapısının Seçimi	74
2.11.3. Girdi Nöronu ve Çıktı Nöron Sayısının Belirlenmesi	74
2.11.4. Gizli Katman ve Gizli Nöron Sayısının Belirlenmesi	75
2.11.5. Veri Normalleştirme.....	76
2.11.6. Yapay Sinir Ağı Performansının Belirlenmesi	77
2.11.7. Durdurma Kriterinin Belirlenmesi	78
2.11.8. Öğrenme Algoritmasının Seçimi	78
2.12. Yapay Sinir Ağları Uygulamalarının Avantajları.....	79
2.13. Yapay Sinir Ağları Uygulamalarının Dezavantajları.....	80

ÜÇÜNCÜ BÖLÜM

LİTERATÜR İNCELEMESİ

3.1. Yatırım Fonları Performansı Üzerine Yapılan Çalışmalar.....	82
3.2. Sermaye Piyasalarında Yapay Sinir Ağları Yönteminin Kullanımı	91

DÖRDÜNCÜ BÖLÜM

TÜRKİYE'DEKİ YATIRIM FONLARI NET VARLIK DEĞERİNİN TAHMİN EDİLMESİ ÜZERİNE AMPİRİK BİR UYGULAMA

4.1. Çalışmanın Amacı	97
4.2. Çalışmanın Önemi	97
4.3. Çalışmanın Kapsamı ve Veri Seti.....	97
4.3.1. Çalışma Kapsamında İncelenen Fonlar	98
4.3.2. Uygulamada Kullanılan Veri Seti ve Yöntem	101
4.4. Regresyon Modeli	102
4.4.1. Ampirik Uygulama	110
4.4.1.1. A Tipi Yatırım Fonlarına İlişkin Analiz Sonuçları.....	110

4.4.1.2. B Tipi Yatırım Fonlarına İlişkin Analiz Sonuçları.....	114
4.5. Yapay Sinir Ağı Modeli.....	118
4.5.1. Çalışmada Kullanılan Verilerin Önışlemesi	118
4.5.2. Çalışmada Kullanılan Ağ Mimarisi.....	119
4.5.3. Ağın Eğitim ve Test Aşaması	121
4.5.3.1. A Tipi Yatırım Fonlarının Eğitim ve Test Aşamasına İlişkin Sonuçlar ..	124
4.5.3.2. B Tipi Yatırım Fonlarının Eğitim ve Test Aşamasına İlişkin Sonuçlar...	133
4.6. Öngörü Modellerinin Karşılaştırılması.....	144
SONUÇ.....	149
KAYNAKÇA.....	152
ÖZGEÇMİŞ	165

TABLolar LİSTESİ

	<u>Sayfa</u>
Tablo 1.1 : Türkiye’de A Tipi Yatırım Fonları.....	16
Tablo 1.2 : Türkiye’de B Tipi Yatırım Fonları.....	17
Tablo 1.3 : Avrupa Yatırım Fonu Sektörünün Net Varlık Değerleri ve Değişimleri.....	22
Tablo 1.4 : Seçilmiş Bazı Ülkelerdeki Yatırım Fonlarının Portföy Değerleri (Milyon \$).....	25
Tablo 1.5 : Seçilmiş Bazı Ülkelerdeki Yatırım Fonlarının Sayısı.....	25
Tablo 1.6 : Türkiye’deki Yatırım Fonu Sektörünün Büyüklükleri (2008).....	26
Tablo 1.7 : Türkiye Faaliyet Gösteren Yatırım Fonlarının Portföy Yapıları	27
Tablo 1.8 : Türkiye’deki Yatırım Fonu Sektörünün Gelişimi (Bin TL)	28
Tablo 1.9 : Türkiye’deki Yatırım Fonu Kurucularının Piyasa Payları (2008)	29
Tablo 2.1 : Toplama Fonksiyonu Örnekleri	44
Tablo 2.2 : Bazı Aktivasyon Fonksiyonları.....	45
Tablo 2.3 : Ağ Türleri ve Başarılı Oldukları Alanlar.....	74
Tablo 4.1 : Çalışmada Kullanılan A ve B Tipi Yatırım Fonları	99
Tablo 4.2 : 2008 Yılı Sonu İtibariyle Çalışmada Kullanılan A Tipi Fonların Toplam A Tipi Fonlar İçindeki Oranı	100
Tablo 4.3 : 2008 Yılı Sonu İtibariyle Çalışmada Kullanılan B Tipi Fonların Toplam B Tipi Fonlar İçindeki Oranı.....	101
Tablo 4.4 : Bağımsız Değişkenlerin ve A Tipi Fonların ADF Birim-Kök Testi Sonuçları.....	106
Tablo 4.5 : B Tipi Fonların ADF Birim-Kök Testi Sonuçları	107
Tablo 4.6 : Bağımsız Değişkenler Arasındaki Korelasyon Katsayıları	108
Tablo 4.7 : Tahmin Edilen Modellerde Otokorelasyon ve Değişen Varyans Testi Sonuçları (A Tipi Fonlar).....	111
Tablo 4.8 : A Tipi Fonlar İçin Regresyon Yöntemi Tahmin Sonuçları	112
Tablo 4.9 : A Tipi Fonlar İçin Regresyon Yöntemi Tahmin Sonuçları	113
Tablo 4.10: Tahmin Edilen Modellerde Otokorelasyon ve Değişen Varyans Testi Sonuçları (B Tipi Fonlar).....	115
Tablo 4.11: B Tipi Fonlar İçin Regresyon Yöntemi Tahmin Sonuçları	116
Tablo 4.12: B Tipi Fonlar İçin Regresyon Yöntemi Tahmin Sonuçları	117

Tablo 4.13: A Tipi Fonlar İçin En Uygun YSA Modellerine İlişkin Parametreler	122
Tablo 4.14: B Tipi Fonlar İçin En Uygun YSA Modellerine İlişkin Parametreler	123
Tablo 4.15: A Tipi Fonlar İçin Eğitim ve Test Aşaması Performans Göstergeleri.....	132
Tablo 4.16: B Tipi Fonlar İçin Eğitim ve Test Aşaması Performans Göstergeleri.....	142
Tablo 4.17: A Tipi Fonlar İçin Öngörü Doğruluk Ölçütleri.....	145
Tablo 4.18: B Tipi Fonlar İçin Öngörü Doğruluk Ölçütleri.....	147

ŞEKİLLER LİSTESİ

	<u>Sayfa</u>
Şekil 2.1: Biyolojik Sinir Hücresinin Yapısı.....	41
Şekil 2.2: Yapay Nöronun Genel Yapısı.....	42
Şekil 2.3: Bir Yapay Sinir Ağının Genel Yapısı.....	47
Şekil 2.4: İleri Beslemeli Ağ Yapısı	49
Şekil 2.5: Geri Beslemeli Ağ Yapısı.....	51
Şekil 2.6: Danışmanlı Öğrenme Algoritması	53
Şekil 2.7: Tek Katmanlı Yapay Sinir Ağı	54
Şekil 2.8: Çok Katmanlı Yapay Sinir Ağı.....	57
Şekil 2.9: Öğrenmenin Hata Uzayındaki Gösterimi	71
Şekil 2.10: Çok Boyutlu Hata Uzayı.....	72
Şekil 4.1: YSA Tahmin Modeli	121

GRAFİKLER LİSTESİ

	<u>Sayfa</u>
Grafik 1.1: Dünya Yatırım Fonu Büyüklükleri (Trilyon \$).....	23
Grafik 1.2: Dünya Yatırım Fonu Sektörünün Portföy Yapısı (2008)	24
Grafik 1.3: Dünya Yatırım Fonu Sektöründe Bazı Ülkelerin Payı.....	24
Grafik 1.4: Türkiye’deki Yatırım Fonlarının Toplam Portföy Değeri (Bin TL)	28
Grafik 4.1: Bağımsız Değişkenlerin Orijinal Grafikleri.....	105
Grafik 4.2: Normalleştirilmiş Bağımsız Değişken Serilerinin Grafikleri	119
Grafik 4.3: Eğitim Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Eğitim Hatalarının Grafikleri (A Tipi Fonlar).....	125
Grafik 4.4: Eğitim Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Eğitim Hatalarının Grafikleri (A Tipi Fonlar).....	126
Grafik 4.5: Eğitim Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Eğitim Hatalarının Grafikleri (A Tipi Fonlar).....	127
Grafik 4.6: Test Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Test Hatalarının Grafikleri (A Tipi Fonlar).....	129
Grafik 4.7: Test Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Test Hatalarının Grafikleri (A Tipi Fonlar).....	130
Grafik 4.8: Test Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Test Hatalarının Grafikleri (A Tipi Fonlar).....	131
Grafik 4.9: Eğitim Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Eğitim Hatalarının Grafikleri (B Tipi Fonlar).....	135
Grafik 4.10: Eğitim Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Eğitim Hatalarının Grafikleri (B Tipi Fonlar).....	136
Grafik 4.11: Eğitim Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Eğitim Hatalarının Grafikleri (B Tipi Fonlar).....	137
Grafik 4.12: Test Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Test Hatalarının Grafikleri (B Tipi Fonlar).....	139
Grafik 4.13: Test Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Test Hatalarının Grafikleri (B Tipi Fonlar).....	140
Grafik 4.14: Test Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Test Hatalarının Grafikleri (B Tipi Fonlar).....	141

KISALTMALAR LİSTESİ

AB	: Avrupa Birliđi
ABD	: Amerika Birleşik Devletleri
ADALINE	:Adaptif Doğrusal Eleman Modeli (Adaptive Linear Elements)
ADF	:Augmented Dickey-Fuller Testi
AIC	:Akaike Information Criterion
ARIMA	:Autoregressive Integrated Moving Average
ART	:Adaptif Rezonans Teorisi
CAPM	:Sermaye Varlıklarını Fiyatlandırma Modeli (Capital Asset Pricing Model)
CML	:Sermaye Piyasası Doğrusu (Capital Market Line)
ÇKA	:Çok Katmanlı Algılayıcı Modeli
DW	:Durbin-Watson d istatistiđi
EFAMA	:Avrupa Yatırım Fonları ve Portföy Yönetimi Birliđi (European Fund and Asset Management Association)
EPT	:Etkin Pazar Teorisi
GRNN	:Genel Regresyon Ağları
GSMH	:Gayri Safi Milli Hâsıla
GSYH	:Gayri Safi Yurtiçi Hâsıla
HKOK	:Hata Kareleri Ortalamasının Karekökü
HKO	:Hata Kareler Ortalaması
HKT	:Hata Kareler Toplamı
ICI	:Yatırım Şirketleri Enstitüsü (Investment Company Institue)
IEEE	:Elektrik ve Elektronik Mühendisleri Enstitüsü
İMKB	:İstanbul Menkul Kıymetler Borsası
KYK	:Kolektif Yatırım Kuruluşu
LMS	:En Küçük Ortalama Kareler (Least Mean Squares)
LVQ	:Doğrusal Vektör Parçalama Modeli (Linear Vector Quantization)
MAE	:Ortalama Mutlak Hata
MAD	:Ortalama Mutlak Hata
MADALINE	:Çoklu Adaptif Doğrusal Eleman Modeli (Multiple Adaptive Linear Elements)
MAPE	:Ortalama Mutlak Yüzde Hata

MPT	:Modern Portföy Teorisi
PNN	:Parabolistik Ağlar
RBF	:Radyal Tabanlı Fonksiyonlar (Radial Basis Functions)
SML	:Menkul Kıymet Piyasa Doğrusu (Security Market Line)
SPK	:Sermaye Piyasası Kurulu
OM	:Kendiliğinden Organize Olabilen Nitelik Haritaları (Self-Organizing Feature Maps)
TCMB	:Türkiye Cumhuriyeti Merkez Bankası
TEFE	:Toptan Eşya Fiyat Endeksi
TKYD	:Türkiye Kurumsal Yatırımcı Yöneticileri Derneği
TSPAKB	:Türkiye Sermaye Piyasası Aracı Kurumlar Birliği
TÜİK	:Türkiye İstatistik Kurumu
TÜFE	:Tüketici Fiyat Endeksi
UCITS	:Devredilebilir Menkul Kıymet Müşterek Yatırım Fonu Girişimleri (Undertaking for Collective Investment in Transferable Securities)
YSA	:Yapay Sinir Ağı (Artificial Neural Networks)
YZ	:Yapay Zeka (Artificial Intelligence)

GİRİŞ

Yatırım fonları, diğer yatırım araçlarından oluşan karma bir sepet olarak karşımıza çıkan, yatırımcıya her türlü araca ulaşma imkânını veren ve likit olması sebebiyle atıl durumda olan fonların değerlendirilmesine olanak sağlayan bir yatırım aracıdır. Hızla küreselleşen dünyada bütün sektörlerde olduğu gibi yatırım fonları piyasasında da gelişmeler ve değişimler yaşanmış ve yatırım fonu sermaye piyasalarında her geçen gün önemi artan yatırım aracı haline dönüşmüştür. Çünkü yatırım fonları, tasarrufçu ve yatırımcıyı çekebilme özelliğine sahip ve doğru biçimde kullanıldığında elde edilebilecek getirileri çok fazla olan bir kaynaktır.

Son yıllarda dünyada ve ülkemizde yaşanan ekonomik krizlerden ve politik gelişmelerden dolayı finansal piyasalarda şiddetli dalgalanmalar meydana gelmektedir. Bu durum ekonomik karar birimlerinin, sermaye piyasası araçlarının ve yatırım fonlarının fiyatlarının gelecekte alacağı değeri tahmin edilebilmeleri halinde çok önemli avantajlar ve fırsatlar elde edilebileceklerini göstermiştir.

Doğru tahmin (veya öngörü) yapabilmenin başarılı sonuçları beraberinde getireceği ve böylece fayda fonksiyonunun en üst düzeye çıkarılabileceği gerçeği öngörü modellemesine olan ilgiyi artırmış ve yeni öngörü tekniklerinin doğmasına neden olmuştur. Bu yeni tekniklerden; öğrenebilme, genelleme yapabilme, eksik verilerle çalışabilme yeteneği olan, sınıflandırma, optimizasyon, örüntü tanıma işlemlerinde ve özellikle doğrusal olmayan zaman serilerini tahmin etmede oldukça başarılı bir yöntem olan Yapay Sinir Ağları (YSA) yöntemi ön plana çıkmaktadır.

Yapay sinir ağları, insan beyninin çalışma mekanizmasını taklit ederek beynin öğrenme, hatırlama, genelleme yapma yolu ile yeni bilgiler üretebilme gibi yetenekleri herhangi bir yardım almaksızın gerçekleştirmek üzere geliştirilen bilgisayar yazılımları olarak tanımlanabilir. YSA modelleri, endüstri, iş, finans, eğitim, askeri, savunma ve sağlık gibi birçok alanda başarıyla uygulanmaktadır. Yapay sinir ağları, doğrusal yapıda olmamaları nedeniyle yine doğrusal yapıda olmayan zaman serileri analizinde oldukça başarılı sonuçlar elde edebilmişlerdir.

Bu özellikleri nedeniyle oldukça önemli avantajlar sağlayan YSA tekniği diğer alanlarda olduğu gibi zaman serileri öngörü modellemesi alanında da yaygın biçimde kullanılmaktadır.

Bu çalışmada, YSA tekniği incelenmekte ve ekonometride çok kullanılan yöntemlerden biri olan doğrusal regresyon yöntemi ile karşılaştırılmaktadır. Bu çalışma, giriş ve sonuç bölümleri dışında dört bölümden oluşmaktadır. Çalışmanın birinci bölümünde, çalışmanın ana konusunu oluşturan yatırım fonları kavramı ve özellikleri, fonksiyonları, yatırım fonu türleri ve tipleri, yasal çerçevesi, portföy yapısı, yatırım fonlarının yatırımcıya ve ülkeye sağladığı faydalar ile yatırım fonlarının Dünya'daki ve Türkiye'deki gelişiminden bahsedilmektedir.

İkinci bölümünde, yatırım fonları performansı üzerine yapılan çalışmaları ve sermaye piyasalarında yapay sinir ağları yönteminin kullanımına ilişkin çalışmaları içeren geniş bir literatür incelemesine yer verilmektedir.

Üçüncü bölümde, öncelikle yapay sinir ağları teorik olarak incelenmekte, yapay sinir ağlarının; tanımına, tarihçesine, genel yapısına, çeşitlerine, öğrenme algoritması ve öğrenme kurallarına yer verilmektedir. Daha sonra bir yapay sinir ağı modeli tasarımının nasıl yapılması gerektiğini gösteren adımlardan; ağı giridi, çıktı ve gizli katmanlarının ve bu katmanlardaki nöron sayılarının nasıl belirleneceği, veri girişinin nasıl yapılacağı, ağı parametrelerinin nasıl belirleneceği, başka bir deyişle ağı yapısının nasıl oluşturulabileceği hakkındaki bilgilere yer verilmektedir. Ayrıca yapay sinir ağlarının uygulanma alanları, avantajları ve dezavantajlarına da bu bölümde yer verilmektedir.

Dördüncü ve son bölümde, çalışmanın amacı, kapsamı ve veri seti belirtilmiştir. Analiz tekniklerin uygulanacağı yatırım fonu net varlık değeri tahmin modelleri kurularak regresyon analizi ile aynı modellere oluşturulan YSA tasarımı yapıldıktan sonra YSA tekniği uygulanmıştır. Çalışmanın amacı çerçevesinde bir performans değerlendirilmesine yer verilmiş ve öngörüde kullanılan modellere ilişkin öngörü sonuçları karşılaştırmalı olarak sunulmuştur.

BİRİNCİ BÖLÜM

MENKUL KIYMET YATIRIM FONLARI

Bu bölümde yatırım fonunun tanımı, kapsamı, özellikleri, çeşitleri ve katkıları gibi konularda genel bilgilere yer verilirken, dünyada ve Türkiye’de yatırım fonu sektörünün gelişimine de değinilecektir.

1.1. Yatırım Fonu Kavramı ve Özellikleri

Bir ekonomik sistemde, yatırım yapmak isteyen işletmelerin yeterli fona sahip olmadıkları, bazı kişi ve kuruluşların ise fon fazlasına sahip oldukları görülmektedir. Mevcut kaynakların etkin bir şekilde kullanılarak yatırımlara kanalize olması için fon fazlasına sahip olan kesim ile fon açığı olan kesimin karşı karşıya geleceği bir piyasaya ihtiyaç duyulmaktadır. Fon fazlası olan kesimden fon açığı olan kesime kaynak aktarımı ya da tasarrufların yatırıma dönüştürülmesi işlevi mali piyasalar (para ve sermaye piyasaları) ve bu piyasadaki mali araçlar yoluyla yerine getirilmektedir (Kılıç, 2002, 3-4). Mali piyasalarda fon talep edenler özel işletmeler ve kamu kesimidir. Fon arz edenler ise fon fazlası olan bireysel ve kurumsal yatırımcılardır. Bireysel yatırımcılar kendi imkânlarıyla yatırım yapan hane halklarından oluşurken, kurumsal yatırımcılar; sosyal güvenlik kuruluşları, sigorta şirketleri, özel emeklilik kurumları ve kolektif yatırım kuruluşları (KYK - yatırım fonları ve yatırım ortaklıkları) gibi kuruluşlardan oluşmaktadır. Sermaye piyasasının temel amacı olan kaynak aktarımına önemli katkısı bulunan kurumsal yatırımcılar, bireysel yatırımcılardan farklı olarak büyük tutarda yatırım yaptıkları, ölçek ekonomilerinden yararlandıkları, profesyonel yönetici çalıştırdıkları için daha akılcı ve etkin yatırım yapma imkânına sahiptirler (Karacabey, 1998, 40-41).

Bir KYK olarak yatırım fonları ise diğer kurumsal yatırımcılar gibi, bireysel yatırımcıların küçük tasarruflarını bir havuzda toplayıp uzman portföy yöneticileri ile bu fonları sermaye piyasası araçlarına yatırarak riskin dağıtılması esasına göre değerlendiren finansal kurumlardır (Karacabey, 1998, 45). Hem fon arz eden ve hem de fon talep eden yatırım fonları sermaye piyasasının en önemli kurumlarından birisidir. Dünyadaki toplam tasarrufların yaklaşık %25’inin yatırım fonlarına

yönelmesi bunun en önemli göstergelerinden birisi olarak nitelendirilmektedir (Kılıç, 2002, 4).

ABD'nin sermaye piyasaları ile ilgili en yetkili otoritesi olan SEC (Securities and Exchange Commission)'in web sayfasında yer alan tanıma göre yatırım fonları; *çok sayıda yatırımcının tasarruflarını bir havuzda toplayan ve bu tasarrufları hisse senetleri, tahviller, kısa vadeli para piyasası araçlarına ya da diğer menkul kıymetlere yatıran firmalardır* (<http://www.sec.gov/investor/pubs/inwsmf.htm>, Erişim Tarihi: 13.02.2009).

Türkiye'de yatırım fonları, 2499 sayılı Sermaye Piyasası Kanunu'nun 37. ve 38. maddelerine dayanılarak "Yatırım Fonlarına İlişkin Esaslar Tebliği"nde aşağıdaki şekilde tanımlanmıştır: Yatırım fonları; *Sermaye Piyasası Kanunu hükümleri uyarınca halktan katılma belgeleri karşılığında toplanan paralarla, belge sahipleri hesabına, riskin dağıtılması ilkesi ve inancılı mülkiyet esaslarına göre, aşağıda belirtilen varlıklardan oluşan portföyü işletmek amacıyla kurulan mal varlığıdır* (Seri: VII, No:10, SPK Tebliği). Yatırım fonları portföyünü oluşturabilecek mal varlıkları bu tebliğde detaylı olarak verilmiştir. Bu varlıklar:

a) Özelleştirme kapsamına alınanlar dâhil Türkiye'de kurulan ortaklıklara ait hisse senetleri, özel ve kamu borçlanma senetleri,

b) Türk Parasının Kıymetini Koruma Hakkındaki 32 sayılı Karar hükümleri çerçevesinde alım satımı yapılabilen, yabancı özel ve kamu borçlanma senetleri ve hisse senetleri,

c) Ulusal ve uluslararası borsalarda işlem gören altın ve diğer kıymetli madenler ile bu madenlere dayalı olarak ihraç edilmiş ve borsalarda işlem gören sermaye piyasası araçları,

d) Seri: VII, No:11, SPK Tebliği ile Kurul'ca uygun görülen diğer sermaye piyasası araçları, repo, ters repo, future, opsiyon ve forward sözleşmeleri,

e) İMKB Takas ve Saklama Bankası A.Ş. nezdindeki borsa para piyasası işlemleri (Seri: VII, No:24, SPK Tebliği).

Fonlar, yukarıda sayılan varlıklardan oluşan portföyü işletmek amacı dışında herhangi bir işle uğraşamazlar. Tebliğde ayrıca nitelikli yatırımcı ve garantör tanımları yapılmıştır. Buna göre;

Nitelikli yatırımcı; yerli ve yabancı yatırım fonları, emeklilik fonları, yatırım ortaklıkları, aracı kurumlar, bankalar, sigorta şirketleri, portföy yönetim şirketleri, ipotek finansmanı kuruluşları, emekli ve yardım sandıkları, vakıflar, 506 sayılı Sosyal Sigortalar Kanununun geçici 20. maddesi uyarınca kurulmuş olan sandıklar, kamuya yararlı dernekler ile nitelikleri itibariyle bu kurumlara benzer olduğu kurulca belirlenecek diğer yatırımcılar ve fon katılma paylarının halka arz tarihi itibariyle en az 1 milyon TL tutarında Türk ve/veya yabancı para ve sermaye piyasası aracına sahip olan gerçek ve tüzel kişileri (Seri: VII, No:29, SPK Tebliği),

Garantör; garantili yatırım fonları tarafından içtüzüklerinde belirlenen esaslar çerçevesinde yatırımcılara geri ödeneceği taahhüt edilen yatırım tutarının Fon tarafından karşılanamayan kısmının yatırımcılara geri ödenmesini bir garanti sözleşmesiyle fona garanti eden ve tebliğde belirlenen nitelikleri haiz; 5411 sayılı Bankacılık Kanunu'nda tanımlanan bankalar ve sigorta şirketleri ile tabi oldukları mevzuat hükümleri saklı kalmak kaydıyla yurtdışında yerleşik bankaları ve sigorta şirketlerini (Ek: Seri: VII, No:33; Seri: VII, No:35, SPK Tebliği) ifade etmektedir.

Yatırım fonlarının kurulması ve faaliyete geçmesi ile faaliyetlerini gerçekleştirirken uyması gereken kurallar, Sermaye Piyasası Kanunu ile Kanunun verdiği yetkiye dayanarak Sermaye Piyasası Kurulu tarafından belirlenmektedir.

Yatırım fonlarının en önemli özellikleri şunlardır (Özdemir, 2007, 13):

- Yatırım fonlarının tüzel kişiliği yoktur ve mal varlığı kurucunun mal varlığından ayrıdır.
- Fon katılma belgeleri gerçek ve tüzel kişilerin fondaki haklarını gösteren belgelerdir.
- Yatırım fonlarının mal varlıklarının korunmasından ve fonların katılımcıların haklarını koruyacak bir şekilde yönetilip yönetilmediğinin

(riskin dağıtılması ve inançlı mülkiyet esaslarına göre) denetlenmesinden kurucu sorumludur.

- Yatırım fonları belli amaçla kurulup profesyonel portföy yöneticileri tarafından yönetilen, bünyesinde değişik menkul kıymetleri barındıran, günlük olarak alınıp satılabilme ve fiyatlandırılabilme özelliklerine sahip olan yatırım araçlarıdır.

1.2. Yatırım Fonlarının Fonksiyonları

Tasarruflarını sermaye piyasasında değerlendirmek isteyen yatırımcının iki seçeneği vardır. Birincisi, bir uzmandan yardım almadan fonlarını hangi yatırım aracına yatıracığına kendisinin karar vermesidir. Fakat bu durum, piyasa konusunda yeterli bilgisi olmayan bir yatırımcının oluşturacağı portföyün getirisi açısından oldukça risklidir. İkinci seçeneği ise portföy yönetiminde uzman olan yatırımcı kolektif yatırım kuruluşlarının hizmetlerinden faydalanmasıdır. Bunun için de yatırımcının, bu kuruluşlardan biri olan yatırım fonlarını çok iyi tanınması, avantajlarını ve dezavantajlarını çok iyi bilmesi gerekmektedir.

Bunların yanı sıra hem çeşitlendirme hem likidite, hem de özel sektör veya kamu sektörü tahvillerine yatırım yapmak isteyen yatırımcıların seçenekleri ise elbette ki sınırlı olacaktır. Eğer yatırımcı çeşitlendirmeyi sağlayacak kadar büyük bir portföye sahip değilse tahvil konusunda uzmanlaşmış bir yatırım fonuna yatırım yapmayı tercih edecektir. Ancak dolaylı ve dolaysız yatırım kararına etkide bulunabilecek etkenler bu kadar belirgin değilse avantaj ve dezavantajların daha iyi bilinmesi gerekmektedir. Kolektif yatırım kurumları içerisinde ele alınan yatırım fonlarının fonksiyonları bu çerçevede dâhilinde şu alt başlıklar altında incelenebilir (Karacabey, 1998, 47-48).

- Ölçek Ekonomisi,
- Çeşitlendirme,
- Profesyonel Portföy Yönetimi.

1.2.1. Ölçek Ekonomisi

İktisat biliminde, ölçeğin artması sonucunda (üretimin artması) uzun dönem maliyetlerinin azalarak artması dolayısıyla ölçeğe göre verimin veya ölçeğe göre getirinin artması durumu ölçek ekonomileri olarak adlandırılır. Başka bir ifadeyle, ölçek ekonomisi, üretim düzeyleri arttıkça azalan marjinal maliyetle çalışan firmalar için kullanılan bir kavramdır (Hansen ve Altınkılıç, 2000, 195). Bu durumda bir birim daha üretmenin maliyeti üretim seviyesi arttıkça düşmektedir. Böylece etkinlik ve verimlilik artmaktadır. Yatırım fonları bağlamında ölçek ekonomisi ise kullanılan veya yönetilen fon miktarının artmasıyla birim fon başına maliyetlerin düşmesi olarak tanımlanabilir.

Fama (1970) mevcut bilgilerin tamamının hisse senedi fiyatlarına yansıtıldığı piyasaları, etkin piyasa olarak tanımlanmıştır ve piyasaları bilgi girişindeki farklılıklara bağlı olarak zayıf, yarı güçlü ve güçlü formda etkin piyasalar olarak gruplandırmıştır. Sermaye piyasalarının etkin olup olmadığı sorusuna cevap arayan birçok ampirik çalışmada genellikle piyasaların ya etkin olmadığı ya da zayıf formda bir piyasa etkinliğine sahip olduğu sonucuna ulaşılmıştır.

Genellikle sermaye piyasalarının güçlü formda piyasa etkinliği göstermemelerinden başka bir ifadeyle zayıf formda piyasa etkinliğine sahip olmalarından dolayı küçük yatırımcılar, tasarruflarını sermaye piyasasında değerlendirmek istediklerinde; bilgi toplama maliyeti, aracı kuruluşlara ödeyecekleri komisyon ve tasarruf miktarlarının sınırlı olması nedeniyle riski minimize edebilecek çeşitlendirmeyi yapamamaktan doğan fırsat maliyeti gibi maliyetlerle karşı karşıya kalmaktadırlar. Bu maliyetler küçük yatırımcı için önemli olabilecekken birden çok yatırımcının bir araya gelerek oluşturacağı yatırım fonları havuzunun portföy büyüklüğü düşünüldüğünde, birim fon maliyetlerinin azımsanmayacak ölçüde düştüğü görülecektir (Karacabey, 1998, 47-48).

1.2.2. Çeşitlendirme

Portföy, riski azaltmak ve üstlenilen riske göre en yüksek getiriye sağlamak amacıyla en az iki çeşit menkul kıymetten oluşan bir havuzdur (Ercan ve Ban, 2005, 188). Geleneksel portföy yaklaşımı, portföy içindeki menkul kıymet sayısının artırılması suretiyle riskin dağıtılabileceğini ileri sürmektedir. Modern portföy

teorisinin babası olarak bilinen Harry Markowitz ise risk dağıtımında sadece portföydeki menkul kıymet sayısının artırılmasının yeterli olmayacağını, portföye alınan menkul kıymet getirilerinin de son derece önemli olduğunu göstermiştir (Canbaş ve Doğukanlı, 1997, 292-293). Çünkü portföye alınan menkuller arasında negatif korelasyon varsa belirli bir getiri düzeyinde risk azaltılabilir.

O halde yatırımcılar portföylerini çeşitlendirerek kayıp ve kazançlarını dengeleyebilecek ve risklerini dağıtabileceklerdir. Bu hizmeti fon yöneticileri profesyonelce yerine getirmektedir. Oysa yatırımcıların kendi başlarına böyle çeşitlendirilmiş bir portföyü oluşturmaları hem zor hem de pahalıdır. Böylece, yatırım fonları, büyük mali kurumlar ve zengin yatırımcılar için mevcut olan yatırım çeşitlendirmesi ve profesyonel yönetim imkânını küçük yatırımcılara da sunmuş olacaktır (Kılıç, 2002, 7-8).

1.2.3. Profesyonel Portföy Yönetimi

Birden fazla finansal varlığı bir araya getirmek suretiyle oluşturulan portföyün esas amacı riskin dağıtılmasıdır. Profesyonel portföy yönetimi ise yatırımcıların elindeki fonların, mevcut menkul kıymetler arasında minimum risk ve maksimum getiri sağlayacak şekilde dağıtılmasıdır (Pekkaya, 2005, 519). Yatırım fonları, bu hizmeti, bu alanda eğitim görmüş ve bu piyasada çalışmış kişileri istihdam etmek suretiyle, katılma belgesi satın alan yatırımcılara sağlamaktadır (Karacabey, 1998, 48). Ayrıca, yatırım fonlarının başlıca görevi, belirli beklenen getiri oranı ve risk düzeyinde yatırımcının parasını fonlar arasında paylaşırabilmek için etkin portföyleri seçmektir.

Son yıllarda bilgisayar teknolojisindeki, piyasa ve yatırımcı yapısındaki gelişmelerle portföy yönetimi daha karmaşık ve rekabetçi bir hal almıştır. Ayrıca, Sermaye Piyasası Kurulu'nun Seri: VII, No:10, 19.12.1996, S:22852 sayılı Resmi Gazete'de yayınlanan tebliğinin 43. Maddesinin birinci fıkrasının (b) bendi ile ve yine Sermaye Piyasası Kurulu'nun, Seri: VII, No:37, 21.01.2009, S:27117 sayılı "Yatırım Fonlarına İlişkin Esaslar Tebliğinde Değişiklik Yapılmasına Dair Tebliğ" ile fon portföyünün kapsamı ve amacı aşağıdaki biçimde genişletilmiştir (Seri: VII, No:37, SPK Tebliği):

“Fon portföyüne riskten korunma ve/veya yatırım amacıyla döviz, kıymetli madenler, faiz, finansal göstergeler ve sermaye piyasası araçları üzerinden düzenlenmiş opsiyon sözleşmeleri, forward, finansal vadeli işlemler ve vadeli işlemlere dayalı opsiyon işlemleri dahil edilebilir. Vadeli işlem sözleşmeleri nedeniyle maruz kalınan açık pozisyon tutarı fon toplam değerini aşamaz. Portföye alınan vadeli işlem sözleşmelerinin fonun yatırım stratejisine ve karşılaştırma ölçütüne uygun olması zorunludur. Karşılaştırma ölçütü belirlemeksizin opsiyon sözleşmeleri ve mala dayalı vadeli işlem sözleşmeleri garantili yatırım fonlarının ve koruma amaçlı yatırım fonlarının portföyüne hem **koruma** hem de **yatırım** amaçlı olarak alınabilir”.

1.3. Yatırım Fonlarının Sınıflandırılması

Yatırım fonları literatürde farklı şekillerde sınıflandırılmaktadır. Bu çeşitli sınıflandırma şekillerinden ortak noktalar bir araya getirilerek aşağıdaki sınıflandırma biçimi oluşturulabilir (Yalçınkaya, 2006, 3-12; Bolat, 2006, 41-48; Odabaşı, 2007, 31-35; Karacabey, 1998, 50-58):

- Pay Senedinin Değişebilirliğine Göre Yatırım Fonları
- Portföyün Niteliğine Göre Yatırım Fonları
- Kar Dağıtımına Göre Yatırım Fonları
- Yatırım Hedeflerine Göre Yatırım Fonları

1.3.1. Pay Senedinin Değişebilirliğine Göre Yatırım Fonları

Pay senedinin değişebilirliğine göre yatırım fonları açık uçlu yatırım fonları ve kapalı uçlu yatırım fonları olarak ikiye ayrılmaktadır.

1.3.1.1. Açık Uçlu (Open-Ended) Yatırım Fonları

Pay sayısı sabit olmayan, talebin seviyesine göre pay sayısı artırılabilen veya azaltılabilen fonlar açık uçlu (open-ended) yatırım fonları olarak tanımlanabilir. Açık uçlu yatırım fonlarının katılma belgeleri için ikincil bir piyasa söz konusu değildir. Yatırımcı fondan pay almak veya fondaki paylarını satmak isterse fon yönetimi ile alışveriş içine girmek zorundadır (Karacabey, 1998, 51).

Talebin seviyesine göre belge sayısı arttırılabilen veya azaltılabilen bu fonlar, istenildiği an paraya çevrilebilme özelliğinden dolayı küçük ve deneyimsiz yatırımcılar tarafından tercih edilmektedir. Yatırımcı istediği an katılma belgesi satın alarak bu fona katılabilmekte veya fona geri satabilmektedir. Açık uçlu yatırım fonlarının fiyatları da, portföylerinin içerdiği menkul kıymetlerin piyasadaki değeriyle ve katılma belgesi sayısına bağlı olmaktadır (Beyazoğlu, 2002, 7). Fon paylarının istendiği anda kolayca alınıp satılabilmesi ve pay fiyatı ayarlaması yapılabilmesi açık uçlu yatırım fonlarının en önemli iki özelliğidir (Tevfik, 1995, 6).

1.3.1.2. Kapalı Uçlu (Closed-Ended) Yatırım Fonları

Yatırımcılar tarafından istenildiğinde pay sayısı artırılmayan, yatırımcılar tarafından fona iade edilemeyen, dolayısıyla pay sayısı azaltılmayan fonlardır (Tevfik, 1995, 6-7).

Kapalı uçlu fonlar, ihraç ettikleri katılma belgelerini geri satın almayan ve sabit sermayeli olarak kurulan fonlardır. Katılım payı bellidir ve payların ihraççı tarafından geri satın alınıp itfa edilmesi söz konusu olmadığı için talep doğrultusunda pay sayısında arttırma veya azaltma yapılmamaktadır. Bu nedenle, katılma belgesi satmak isteyen yatırımcının, borsada ya da tezgah üstü piyasalarda alıcı bulması gerekmektedir (Beyazoğlu, 2002, 7).

1.3.2. Portföyün Niteliğine Göre Yatırım Fonları

Yatırım fonları portföyüne aldıkları menkul kıymetlerin türüne göre hisse senedi fonları, tahvil fonları ve para piyasası fonları olarak sınıflandırılmaktadır (ICI, Mutual Funds Fact Book, 2001; <http://www.sec.gov/investor/pubs/inwsmf.htm>, Erişim Tarihi: 13.02.2009).

1.3.2.1. Hisse Senedi Fonu

Hisse senedi fonları, portföylerinin tamamı ya da büyük bir kısmı yerli ve/veya yabancı şirketlerin hisse senetlerinden oluşan yatırım fonlarıdır. Bu fonlar genel olarak tahvil ve para piyasası fonlarından daha fazla risk içermekte, ancak bunlara oranla daha yüksek getiri sağlamaktadır. Hisse senedi fonları içerisinde en çok kullanılan fonlar; tamamı hisse senedinden oluşan yatırım fonları, melez (hybrid) fonlar, özel fonlar ve sektör fonlarıdır.

1.3.2.2. Tahvil Fonları

Tahvil fonları, portföylerinin tamamını veya büyük bir kısmını tahvil ve bono gibi sabit getirili menkul kıymetlere yatırım yapan fonlardır. Bu fonlar, para piyasası fonlarından yüksek, hisse senedi fonlarından ise daha düşük riske sahiptir. Tahvil fonları; şirket tahvillerine yatırım yapan fonlar, yabancı tahvillere yatırım yapan fonlar, devlet borçlanma araçlarına yatırım yapan fonlar ve belediye borçlanma araçlarına yatırım yapan fonlar gibi alt ayrımlara tabi tutulmaktadır.

1.3.2.3. Para Piyasası Fonları

Para piyasası fonları, portföylerinin tamamı veya büyük bir kısmı para piyasası araçlarında oluşan yatırım fonlarıdır. Bu fonlar daha çok hükümetler, belediyeler ve şirketler tarafından ihraç edilen kısa vadeli ve yüksek kaliteli menkul kıymetleri (90 gün ve daha az vadeli araçlar, mevduat sertifikaları, finansman bonoları gibi) portföylerine almaktadır. Dolayısıyla, bu fonlar diğer fonlarla karşılaştırıldığında en düşük riske sahip olan fonlardır.

Bu fonların yatırım fonlarının en güvenlisi olduğu düşünülür. Çünkü bu fonlar yüksek kaliteli, kısa vadeli menkul kıymetlere yatırım yaparlar. Para piyasası yatırım fonları, yatırım fonlarının en yaygın çeşitleridir. Diğer yatırım fonu tipinden çok fazla sayıda para piyasası fonu bulunur. Bu kadar yaygın olmalarının sebebi, güvenilir ve esnek oluşları ve üzerine çek keşide edilebilmesi gibi çeşitli kolaylıklar sağlamasıdır (Tevfik, 1995, 13).

1.3.3. Kar Dağıtımına Göre Yatırım Fonları

Kar dağıtımına göre yatırım fonları kar dağıtan ve kar dağıtmayan yatırım fonları olmak üzere iki gruba ayrılırlar (Karacabey, 1998, 56).

1.3.3.1. Kar Dağıtan Fonlar

Kar dağıtan yatırım fonlarını yöneten kuruluş her yılsonunda değer artışı, tahsil edilen temettü ve faiz tutarı olarak fonun karını hesaplar ve iç tüzüğe göre, belli bir miktarı katılma belgesi sahiplerine kar payı olarak öder.

1.3.3.2. Kar Dağıtmayan Fonlar

Portföydeki menkul kıymetlerin kupon ödeme zamanı geldiğinde tahsil edilen kupon bedelleri, dağıtılmayıp fona eklenir ve bunlarla yeniden menkul değer satın alınması suretiyle fon portföyünün büyütülmesi ve katılma belgelerinin değerinin arttırılması yolu izlenir.

1.3.4. Yatırım Hedeflerine Göre Yatırım Fonları

Fon portföyleri oluşturulurken belli amaçlar dikkate alınır. Bu amaçlar üç gruba ayrılır (Karacabey, 1998, 56):

- Gelir elde etmek,
- Sermaye kazancı elde etmek,
- Gelir ve sermaye kazancı elde etmek.

ABD Yatırım Fonları Kurumu (ICI, Investment Company Institute), fonun hedefi ile yatırımcının hedefi arasındaki uyumu, fonun elde tutulma süresini, fon performans tahminini, potansiyelini, borsa endekslerine göre gelişimini dikkate alarak yatırım hedeflerine göre fonları 23 çeşide ayırmaktadır.

1.4. Türkiye’de Yatırım Fonları

Bu başlık altında, yatırım fonlarının yasal çerçevesinden, fon tip ve türlerinden ve katılım belgesinden bahsedilecektir.

1.4.1. Yasal Çerçevesi

Yatırım fonları ilk olarak 30.7.1981 tarih ve 17416 sayılı Resmi Gazete’de yayımlanan 2499 sayılı Sermaye Piyasası Kanunu ile sermaye piyasasının yardımcı kuruluşu olarak Türk hukuk sistemine girmiştir. SPK bu kanunun kendisine verdiği yetkiye dayanarak 12.12.1986 tarih ve 19310 sayılı Resmi Gazete’de, Seri: VII, No:1 “Menkul Kıymetler Yatırım Fonu Katılma Belgelerinin İhracına ve Halka Arzına Dair Esaslar Tebliği”ni yayımlayarak konuya ilişkin ilk kapsamlı düzenlemeyi yapmıştır (Seri: VII, No:1, SPK Tebliği; Kılıç, 2002, 14). Bu düzenlemenin ardından ilk yatırım fonu ise T.C. Hazine ve Dış Ticaret Müsteşarlığı’nın 16.10.1986 tarihli izni ile Türkiye İş Bankası A.Ş. tarafından kurulmuştur.

Yatırım fonlarının kapsamında sermaye piyasasında meydana gelen deęişmelere göre; 1992, 1996, 1998, 2001, 2002, 2004 ve en son 21.01.2009 tarihli ve 27117 sayılı Resmi Gazete’de yayımlanan Seri: VII, No:37 sayılı “Yatırım Fonlarına İlişkin Esaslar Tebliğinde Deęişiklik Yapılmasına Dair Tebliğ” ile deęişiklikler yapılmış ve yeni düzenlemelere gidilmiştir.

1.4.2. Fon Tür ve Tipleri

Yatırım fonları, Seri VII, No: 10 “Yatırım Fonlarına İlişkin Esaslar Tebliği” 5. maddesinde fonların türleri sıralanmıştır. Bunlar içtüzüklerinde belirtmek koşuluyla;

Fon portföyünün en az %51'ini devamlı olarak;

1. Kamu ve/veya özel sektör borçlanma araçlarına yatırılan fonlar, **Tahvil ve Bono Fonu,**

2. Özelleştirme kapsamına alınanlar dâhil Türkiye’de kurulmuş ortaklıkların hisse senetlerine yatırılan fonlar, **Hisse Senedi Fonu,**

3. Belirli bir sektörü oluşturan ortaklıkların menkul kıymetlerine yatırılan fonlar, **Sektör Fonu,**

4. Fon kurucusunun iştiraklerinin çıkardığı menkul kıymetlere yatırılan fon, **İştirak Fonu,**

5. Belli bir topluluğun menkul kıymetlerine yatırılan fonlar, **Grup Fonu,**

6. Yabancı özel ve kamu sektörü menkul kıymetlerine yatırılan fonlar, **Yabancı Menkul Kıymet Fonu,**

7. Ulusal ve uluslararası borsalarda işlem gören altın ve diğer kıymetli madenler ile bu madenlere dayalı sermaye piyasası araçlarına yatırılan fonlar, **Altın ve Diğer Kıymetli Madenler Fonu,**

Portföyünün tamamı;

8. Hisse senetleri, borçlanma senetleri, altın ve diğer kıymetli madenler ile bunlara dayalı sermaye piyasası araçlarından en az ikisinden oluşan ve her birinin değeri fon portföy değerinin %20'sinden az olmayan fonlar, **Karma Fon,**

9. Devamlı olarak, portföyünde vadesine en fazla 180 gün kalmış likiditesi yüksek sermaye piyasası araçları yer alan ve portföyünün ağırlıklı ortalama vadesi en fazla 45 gün olan fonlar, **Likit Fon**,

10. Portföy sınırlamaları itibariyle yukarıdaki türlerden herhangi birine girmeyen fonlar, **Değişken Fon**,

Portföyünün en az %80'i devamlı olarak;

11. Bu Tebliğ'in 3 numaralı ekinde yer alan formüle uygun olarak yapılan hesaplama çerçevesinde, baz alınan ve Kurul tarafından uygun görülen bir endeksin değeri ile fonun birim pay değeri arasındaki korelasyon katsayısı en az %90 olacak şekilde, endeks kapsamındaki menkul kıymetlerin tümünden ya da örnekleme yoluyla seçilen bir kısmından oluşan fonlar, **Endeks Fon**,

12. Diğer yatırım fonlarının ve borsa yatırım fonlarının katılma paylarından oluşan fonlar, **Fon Sepeti**,

13. Katılma belgeleri önceden belirlenmiş kişi veya kuruluşlara tahsis edilmiş fonlar, **Özel Fon**,

14. Katılma payları sadece nitelikli yatırımcılara satılmak üzere kurulmuş olan fonlar ise **Serbest Yatırım Fonları (Hedge Funds)** olarak adlandırılır (Ek fıkra: Seri: VII, No:29, SPK Tebliği).

Fon katılma belgelerinin hisse senetleri gibi borsada işlem görebilmelerini sağlayan "**Borsa Yatırım Fonları**" 13.04.2004 tarihli 25432 sayılı Borsa Yatırım Fonlarına İlişkin Esaslar Tebliği ile düzenlenmiştir. Tebliğin 4. maddesine göre, *borsa yatırım fonu*, katılma belgeleri borsa pazarlarında işlem gören, fonun oluşturulma sürecine doğrudan katılan yetkilendirilmiş katılımcıların fon portföyünün kompozisyonunu yansıtacak şekilde, portföyde yer alan menkul kıymet ve nakdi bir araya getirerek karşılığında fon katılma belgesi alabildiği ya da söz konusu kurumların en az asgari işlem birimine tekabül eden fon katılma belgelerini saklamacı kuruluşa iade edip karşılığında fonun içindeki menkul kıymetlerin payına düşen kısmını alabildiği, riskin dağıtılması ilkesi ve inançlı mülkiyet esaslarına göre portföy işletmek amacıyla kurulan malvarlığıdır (Seri VII, No:23, SPK Tebliği)

21.01.2009 tarihli ve 27117 sayılı Resmi Gazete’de yayımlanan Seri: VII, No:37 sayılı “Yatırım Fonlarına İlişkin Esaslar Tebliğinde Değişiklik Yapılmasına Dair Tebliğ” ile 19.12.1996 tarihli ve 22852 sayılı Resmî Gazete’de yayımlanan Seri: VII, No:10 sayılı “Yatırım Fonlarına İlişkin Esaslar Tebliği”nin 3. maddesine aşağıdaki fıkralar eklenmiştir (Seri: VII, No:37, SPK Tebliği):

15. Payları tek bir içtüzük kapsamında ihraç edilen tüm alt fonları kapsayan fonlar, **Şemsiye Fon,**

16. Bir şemsiye fon içtüzüğüne bağlı olarak her katılma payı ihracı için ayrı bir izah name ve sirküler düzenlenmesi gereken fonları, **Alt Fon** olarak tanımlanmıştır.

Aynı tebliğin 5. maddesinin birinci fıkrasının (iv) bendi ve aynı maddenin ikinci fıkrası aşağıdaki şekilde değiştirilmiştir.

Alt fonları *asgari olarak altı ay vadeli* kurulmak kaydıyla;

- Yatırımcının başlangıç yatırımının belirli bir bölümünün, tamamının ya da başlangıç yatırımının üzerinde belirli bir getirinin izah namede belirlenen esaslar çerçevesinde belirli vade ya da vadelerde yatırımcıya geri ödenmesinin, uygun bir yatırım stratejisine ve garantör tarafından verilen garantiye dayanılarak taahhüt edildiği ve şemsiye fon şeklinde kurulan fonlar, **Garantili Fon,**
- Yatırımcının başlangıç yatırımının belirli bir bölümünün, tamamının ya da başlangıç yatırımının üzerinde belirli bir getirinin izah namede belirlenen esaslar çerçevesinde belirli vade ya da vadelerde yatırımcıya geri ödenmesinin, uygun bir yatırım stratejisine dayanılarak en iyi gayret esası çerçevesinde amaçlandığı ve şemsiye fon şeklinde kurulan fonlar, **Koruma Amaçlı Fon,** olarak adlandırılır.

Ayrıca fon içtüzüklerinde belirtmek suretiyle, portföy değerinin aylık ağırlıklı ortalama bazda en az %25’ini, devamlı olarak, Türk şirketlerinin hisse senetlerine yatırmış plan fonlar **A Tipi**; A Tipi yatırım fonu özelliğinde olmayan ve portföylerinin oluşumunda herhangi bir sınırlama bulunmayan yatırım fonları da **B Tipi** fon olarak adlandırılmaktadır. B Tipi fon portföyü, devlet tahvili, hazine bonusu

ve ters repo ağırlıklı olmak üzere sabit getirili menkul kıymetlerden oluşmaktadır (http://www.tkyd.org.tr/T/yatirim_fonlari_k.aspx, Erişim Tarihi: 11.02.2009).

Türkiye’de 2001-2008 yılları arasında yıllar itibariyle, ayrı ayrı A tipi ve B Tipi yatırım fonlarının; toplam büyüklükleri, fon sayısı, yatırımcı sayısı ve portföy içindeki fon çeşitlerinin büyüklükleri Tablo 1.1 ve Tablo 1.2’de verilmektedir.

Tablolara göre; Türkiye’de 2001-2008 dönemi arasında A tipi fon sayısının değişiklik göstermediğini, 126 adet olarak kaldığını, buna karşılık B tipi fonların yıllar itibariyle arttığını ve 2008 yılında 209 adede ulaştığını görmekteyiz. Ayrıca yatırımcı sayısı her iki fon tipinde de yıllar itibariyle artmaktadır. Toplam portföy değeri, A tipi ve B tipi yatırım fonlarında 2005 yılında en yüksek değere ulaşmış, A tipi 1.033.635.000 TL, B tipi 28.340.487.000 TL olmuştur. *Ancak yaşanan finansal krizin etkisiyle bu yıldan sonra düşüşler meydana gelmiştir.* Buna rağmen, tablodaki verilere göre B tipi yatırım fonlarında istikrarlı denebilecek portföy büyüklüğü vardır denilebilir.

Tablo 1.1: Türkiye’de A Tipi Yatırım Fonları

Yıllar	Fon Sayısı	Top. Değ. (TL)	Yatırımcı Sayısı	HS %	KB %	ÖT %	TR %	BBP %	YMK %	Diğer %
2001	162	568.737	62.469	61.77	15.78	0.00	22.44	0	0.01	0.00
2002	132	434.884	71.322	54.46	13.11	0.00	32.37	0	0.07	0.00
2003	134	743.863	105.816	63.95	17.57	0.00	18.36	0	0.12	0.00
2004	123	780.370	105.275	67.78	20.44	0.00	10.87	0.51	0.39	0.00
2005	126	1.033.635	142.794	70.44	15.83	0.00	12.29	0.88	0.54	0.02
2006	126	831.518	133.503	64.76	17.88	0.00	15.53	0.85	0.70	0.28
2007	129	919.383	165.311	68.16	16.03	0.55	14.96	0.28	0.27	0.30
2008	126	596.212	177.536	58.30	28.17	0.00	13.16	0.16	0.18	0.04
HS % : Hisse Senedi Oranı KB % : Kamu Borçlanma Araçları Oranı ÖT % : Özel Sektör Tahvil Oranı				TR % : Ters Repo Oranı BBP % : Borsa Para Piyasası Araçları Oranı YMK % : Yabancı Menkul Kıymet Oranı						

Kaynak: SPK Aylık İstatistik Bülteni/Aralık 2008; www.tspakb.org.tr. (Erişim Tarihi: 01.04.2009).

Tablo 1.2: Türkiye’de B Tipi Yatırım Fonları

Yıllar	Fon Sayısı	Top. Değ. (TL)	Yatırımcı Sayısı	HS %	KB %	ÖT %	TR %	BBP %	YMK %	Diğer %
2001	115	4.187.045	729.088	0.05	35.27	0.00	64.50	0.00	0.12	0.06
2002	109	8.911.788	1.094.925	0.03	51.04	0.00	48.81	0.00	0.10	0.02
2003	108	19.114.297	2.133.162	0.04	68.90	0.00	30.97	0.00	0.09	0.00
2004	130	23.663.404	2.527.187	0.06	68.71	0.00	28.32	2.91	0.00	0.00
2005	149	28.340.487	2.816.779	0.05	72.26	0.00	26.53	1.15	0.01	0.00
2006	163	21.180.058	2.337.406	0.26	39.07	0.00	59.18	1.41	0.06	0.01
2007	168	25.461.778	2.833.143	0.16	38.69	0.08	57.78	3.07	0.05	0.25
2008	209	23.376.136	2.761.368	0.08	44.13	0.00	50.33	4.93	0.04	0.50
HS % : Hisse Senedi Oranı				TR % : Ters Repo Oranı						
KB % : Kamu Borçlanma Araçları Oranı				BBP % : Borsa Para Piyasası Araçları Oranı						
ÖT % : Özel Sektör Tahvil Oranı				YMK % : Yabancı Menkul Kıymet Oranı						

Kaynak: SPK Aylık İstatistik Bülteni/Aralık 2008; www.tspakb.org.tr. (Erişim Tarihi: 01.04.2009).

Bunların yanı sıra A tipi yatırım fonu portföyünde Hisse Senetleri oranı %58.3’tür. B tipi yatırım fonlarında ise Ters Repo oranı (%50.33) ve Kamu Borçlanma Araçları (%44.13) büyüklükleri göze çarpmaktadır.

Türkiye’de Aralık 2008 yılı sonu itibariyle, 126 adet A tipi, 209 adet B tipi yatırım fonu bulunmaktadır. Aynı dönemde A ve B tipi fonların toplam portföy büyüklüğü 23.972.348.000 TL’dir.

1.4.3. Katılma Belgesi

Yatırım fonlarında, gerçek ve tüzel kişilerin katılma paylarını gösteren belgeye “Katılma Belgesi” denir (Canbaş ve Doğukanlı, 1997, 67). Katılma belgesi, belge sahibinin kurucuya karşı sahip olduğu hakları taşıyan ve fona kaç pay ile katıldığını gösteren kıymetli evrak niteliğinde bir senet olup, kaydi değer olarak tutulur. İçtüzüğünde kurucu dışındaki aracı kuruluşlarca serbestçe alım satımı öngörülen A tipi yatırım fonlarının katılma belgeleri menkul kıymet sayılır (md.35). Katılma belgelerinin itibari değerleri yoktur; fon pay değeri fon toplam değerinin toplam pay sayısına bölünmesiyle bulunur (md.36) (Menkul Kıymetler ve Diğer Sermaye Piyasası Araçları Lisanslama Eğitim Kılavuzu, Sermaye Piyasası Faaliyetleri İleri Düzey Lisansı Eğitimi, Ekim 2008, 42; Seri: VII, No:10, SPK Tebliği).

1.5. Yatırım Fonlarının Yatırımcılara ve Sermaye Piyasasına Sağladığı Katkılar

Yatırım fonlarının sağladığı katkılar, tasarrufçu, kurucu ve ekonomi açısından incelenebilir.

1.5.1. Tasarrufçu Açısından Sağladığı Katkılar

Yatırım fonlarının yatırımcılar tarafından tercih edilmesinin nedenleri aşağıda sıralanmıştır (SPK Tanıtım Rehberi, <http://www.spk.gov.tr/indexpage.aspx?pageid=253>, Erişim Tarihi: 13.02.2009). Bu avantajların bir kısmı aynı zamanda yatırım fonlarında geçerli olan ilkeleri de oluşturmaktadır.

- Tasarrufçunun ortaya koyduğu sermayesi veya tasarrufu, profesyonel ve güvenilir yöneticiler tarafından yönetilmektedir.
- Yatırım fonu portföyüne alınabilecek menkul kıymetlerin sabit getirili, dövizde endeksli ve hisse senedi gibi araçlarla çeşitlenmesi nedeniyle riskin en aza indirilmesi mümkün olabilmektedir.
- Menkul kıymetlerin değerlendirilmesi ve kontrolü ile kupon, faiz ve temettü tahsili fon yönetiminde yapılacağından vade takibi, tahsil etme gibi zaman ve kaynak kullanımını gerektiren işlemlerden korunabilmektedir.
- Küçük tasarruflarla temin edilemeyecek kazanç potansiyeli yüksek menkul kıymetlere yatırım yapılmasına olanak sağlamaktadır.
- Fon portföyündeki değer artışlarının portföy değerine günlük olarak yansıtılması nedeniyle işlemiş gelir ile birlikte gerek ihtiyacı kadar gerekse tamamını istendiği anda paraya çevirebilmektedir (Likidite faydası) (<http://www.sec.gov/investor/pubs/inwsmf.htm/> Erişim Tarihi:13.02.2009).
- Portföye büyük tutarlı alım satımlar nedeniyle zaman ve para tasarrufu sağlamaktadır.
- Bazı yatırım fonları, katılma belgesi üzerinden çek yazabilme imkanı sağlamaktadırlar.

1.5.2. Kurucu Açısından Sağladığı Katkılar

Yatırım fonu kurucuları, bu fonlar sayesinde aşağıdaki faydaları sağlarlar (Ertaş ve Diğ., 1997, 17-18; Kahraman, 2006, 18, 34-35):

- *Fon Yönetim Ücreti Olarak Gelir Elde Etme*: Fon kurucuları, fon içtüzüğüne koydukları hüküm çerçevesinde, fona sağladıkları eleman ve donanım ile fonun yönetim ve temsili karşılığında fon yönetim ücreti alırlar.
- *Ürün Çeşitlendirme*: Yatırım fonu kurucuları, rekabet ortamında faaliyet gösterdiklerinden, kendi ürün çeşitliliklerini artırarak iş riski düzeylerini azaltmaktadırlar.
- *İştiraklerince Çıkarılmış Menkul Kıymetlere Yatırım Yapma*: Kurucular, fonlar aracılığı ile doğrudan veya dolaylı iştiraklerince çıkarılmış menkul kıymetlere, belirli sınır dâhilinde yatırım yapabilmektedir.
- *Kurucusu Oldukları Fonların Katılma Belgelerine Yatırım Yapma*: Seri VII No:10 Yatırım Fonlarına İlişkin Esaslar Tebliği'nin 42'inci maddesinin (g) bendi uyarınca kurucular, içtüzüklerde belirtilmek koşuluyla, fonlar aracılığı ile belirli sınırlamalar dâhilinde kurucusu oldukları farklı türlerdeki yatırım fonlarının ve borsa yatırım fonlarının katılma belgelerine yatırım yapabilmektedirler (Seri: VII, No:10, SPK Tebliği).
- *Hisse Senedi Ağırlıklı Fonlarla Borsada Piyasa Yapıcı Olma*: Hisse senedi ağırlıklı fonlarda, kurucuların fonun portföyünde bulunan hisse senetleri ile borsada piyasa yapıcı görevini alması mümkün olabilmektedir.
- *Reklam ve Prestij Kaynağı Olma*: Menkul kıymet yatırım fonları kurucuları için önemli bir reklam aracı olmanın yanında prestij kaynağıdır.

1.5.3. Ekonomi Açısından Sağladığı Katkılar

Yatırım fonlarının ekonomiye sağladığı katkıları üç başlık altında inceleyebiliriz (Kahraman, 2006, 18; Ertaş ve Diğ., 1997, 18):

- *Sermaye Birikimine Katkı Sağlama*: Yatırım fonları küçük miktardaki fonların birleşerek büyük fon kaynaklarına dönüşmesini ve böylece ülke ekonomisinin gelişmesi için gerekli olan sermaye birikimini sağlarlar. Bu

fonlar gelişmiş ekonomilerde uzun vadeli fon kaynağı, Türkiye gibi gelişmekte olan ülkelerde ise kısa vadeli fon kaynağı olma özelliği gösterirler. Bu anlamda ülkedeki yatırım fonları çeşit ve sayısının artırılması borsanın derinleşmesini sağlayacak ve sermaye birikime katkıda bulunacaktır.

- *Verimli Sanayi ve Ticari Alanlara Finansman Kaynağı Sağlama:* Yatırım fonları oluşturdukları büyük hacimli fonlarla, sanayi ve ticari işletmelerin ihtiyaç duyduğu ucuz ve uzun vadeli finansmanla uygun borçlanma imkânlarına kavuşabilmelerini sağlamaktadır. Böylece işletmeler banka borçlanmasında daha uygun finansman olanağı sağlayacaklardır.
- *Kamu Açığının Finansmanına Katkıda Bulunma:* Yatırım fonları, devlet borçlanma araçlarına yatırım yaparak, kamu açıklarının finansmanına katkıda bulunmaktadır. Türkiye'deki yatırım fonları daha yoğun olarak kamu borçlanma senetlerine yatırım yaptığından bu faydanın Türkiye için önemi daha büyük olduğu söylenebilir. Ancak, Türkiye'de kamu borçlanmasının hiçbir rekabete imkân tanımayan dışlama (crowding out) etkisi göz ardı edilmemelidir.

1.6. Yatırım Fonlarının Tarihsel Gelişimi

Sermaye piyasaları, tasarrufların yatırımlara dönüşmesini sağlayarak ekonomik kalkınmada önemli rol oynamaktadır. Sermaye piyasalarının bu fonksiyonlarını yerine getirebilmeleri finansal araçların çeşitliliğine, piyasanın derinliğine ve tasarrufların profesyonel yönetimle optimal kaynak tahsisine bağlıdır. Yatırım fonları da bu noktada sermaye piyasasında önemli roller üstlenmektedir. Küçük tasarruf sahiplerinin tasarruflarını bir havuzda toplayan yatırım fonları, bu fonları farklı menkul kıymetlere yatırıp portföy oluşturarak fonların etkin yönetimini ve kullanılmasını sağlamaktadırlar.

1.6.1. Yatırım Fonlarının Dünyadaki Gelişimi

Yatırımcıların yatırım amacıyla bir araya gelip, fonlarını birleştirdikleri bir havuz yoluyla yatırımlarını gerçekleştirmeleri fikri Avrupa'da 1800'lü yıllarda ortaya çıkmıştır. İlk yatırım fonunun kuruluşu 1868 yılında Londra'da

gerçekleşmiştir. Yatırım fonlarının Amerika'da gelişimi ise 1920'lerin başına rastlamaktadır. 1924 yılında kurulan Massachusetts Investors Trust Fonu Amerika'nın ilk resmi yatırım fonu olmuştur.

Sadece hisse senetlerine yatırım yapan ilk yatırım fonları 1920'li yıllarda finans dünyasında önemli bir yere sahip olmalarına rağmen, borsalarda önemli bir etkiye sahip olamamışlardır. Öte yandan tahvil fonları toplam fonlar içinde çok küçük bir paya sahip olmuş, vergiden muaf fonların ve para piyasası fonlarının ortaya çıkışı ise 1970'leri bulmuştur (Tevfik, 1995, 3).

Belediyeler ve yeni kurulan kamu kuruluşlarının finansmanında büyük rol oynayan bu fonlar aynı zamanda ABD hazine bonolarına yatırım yapmak yoluyla da kamu açığının finansmanına yardımcı olmuştur. Ayrıca, portföylerine ipoteğe dayalı menkul kıymet almaları dolayısıyla konut ipoteği piyasasına yeni kaynak girmesini sağlamışlardır. Yatırım fonları, yüksek getirili tahvillere ve finansman bonolarına yatırım yaparak kurumların borçlanma maliyetinin düşmesine de yardımcı olmuştur (Tevfik, 1995, 3).

Gelişmiş sermaye piyasalarında önemi giderek artan yatırım fonlarının yönettikleri portföy hacimleri dünya genelinde yıllar itibariyle istikrarlı olarak artış göstermektedir. Portföy değerleri, 2005 yılında 17.7, 2006 yılında en yüksek değer olan 26.1 ve 2008 yılı üçüncü çeyreğinde 21.6 trilyon dolardır (Grafik 1.1). Gelişmiş borsalarda hisse senedi piyasasına yapılan yatırımların önemli bir kısmını fonlar gerçekleştirmektedir. Tüm dünyada en çok yatırım fonuna sahip ülke ABD'dir. Yine tüm dünya yatırım fonu portföyünün %50.4'ü ABD yatırım fonlarına aittir (Efama, International Statistical Release, 2008:Q4, 6; ICI, Worldwide Mutual Fund Assets and Flows Fourth Quarter, 2008).

2008 yılının son çeyreğinde tüm dünya finansal piyasalarının 1929 krizinden beri gördüğü en kötü dönemlerden biri yaşanmıştır. ABD'de kredi piyasalarında başlayan çöküş, dalga dalga tüm dünya piyasalarına yayılarak küresel ekonomik krize dönüşmüştür. Dünyanın en büyük yatırım bankalarından biri olan Lehman Brothers'ın batması ve ardından ABD'nin bazı büyük finans kuruluşlarının el değiştirmesi veya ABD hazinesi tarafından devralınması, krizin etkilerini artırarak

başta Avrupa olmak üzere küresel piyasalara da yansımıştır (TKYD Aralık 2008 Bülteni).

EFAMA (Avrupa Yatırım Fonları ve Portföy Yönetimi Birliği)'nin Avrupa fonları için yayınladığı 2008 yılsonu istatistiklerine göre, 2007 yılsonu ile karşılaştırıldığında Avrupa Yatırım Fonları Sektörü, toplamda %22.3 küçülmüştür. Net aktif değer 1.8 trilyon Euro düşüşle 2008 sonunda 1.6 trilyon Euro'ya gerilemiştir.

Tablo 1.3: Avrupa Yatırım Fonu Sektörünün Net Varlık Değerleri ve Değişimleri

Yıllar	Bütün Fonlar	Değişim %	UCIT Fonlar	UCITS Olmayan
2001	4.619	-	3.619	1.000
2002	4.296	-7.52	3.346	950
2003	4.835	11.14	3.785	1.050
2004	5.373	10.01	4.212	1.161
2005	6.615	18.77	5.191	1.424
2006	7.566	1.25	5.956	1.611
2007	7.909	4.53	6.160	1.749
2008	6.142	-22.3	4.593	1.549


Kaynak: EFAMA, *Quarterly Statistical Release*, February 2008, N 36.

Avrupa'da dolaşım hakkını kazanmak için Avrupa Parlamentosu ve Konseyi'nin 1985'te çıkardığı UCITS (Undertaking for Collective Investment in Transferable Securities, *Devredilebilir Menkul Kıymet Müşterek Yatırım Fonu Girişimleri*) kurallarında 2001 ve 2002 yıllarında değişiklikler yapılarak, 2006 yılında AB ülkelerinde uygulanmaya başlanan "UCITS III Directives" (Direktifin tam adı: *Devredilebilir Menkul Kıymetlere Yatırım Yapan Kolektif Yatırım Kuruluşlarına İlişkin Kanun*) kuralları tüm Avrupa piyasalarında işlem görmek isteyen fonların uymak zorunda olduğu minimum standartların çerçevesini belirlemiştir. Bu kurallar çerçevesinde bütün Avrupa piyasalarında işlem görebilmek sadece UCITS sertifikalı fonlar için mümkün olabilmektedir. Bu fonların temel amacı; yatırım fonlarının başka ülkelerdeki bireysel yatırımcılara sunumunu kolaylaştırmak, yatırım fonları için AB çapında uyumlaştırılmış bir yasal çerçeve oluşturmak ve yatırımcıların haklarının korunmasını sağlamaktır. Türkiye'de UCITS direktiflerine henüz tam olarak uyum sağlanamamıştır. Ancak, en son SPK

tarafından Ağustos 2006 yılında bir kanun taslağı yayımlanmıştır (worldbank_UCITS_presentation_06[1] 06.06_TUR_/Erişim Tarihi: 17.02.2009). UCITS ve UCITS olmayan fonlar 2007 yılına kadar artış göstermiş, 2008 yılında ise bu fonların portföy değerlerinde büyük düşüşler yaşanmıştır.

ABD Yatırım Fonları Enstitüsü (*Investment Company Institute*, ICI) tarafından hazırlanan uluslararası yatırım fon endüstrisi istatistiklerine göre, 2008 yılı 4. çeyrekte, dünya genelinde yatırım fonu sektörü %12.4'lük düşüşle 18.97 trilyon Dolar'a gerilemiştir. Grafik 1.1'de görüldüğü gibi istikrarlı artış, 2007 yılına kadar sürmüştür ve bu yılda 26.15 trilyon dolar değerine ulaşmıştır. 2008 yılında ise bu artış yerini azalmaya bırakmıştır. Aslında bu azalma sinyallerini 2008 yılı ilk çeyreğinde göstermiştir. Bu azalışın nedeni ise daha önce de belirtildiği gibi yaşanan küresel ekonomik krizin etkileridir.

Grafik 1.1: Dünya Yatırım Fonu Büyüklükleri (Trilyon \$)




Kaynak: ICI, *Investment Company Fact Book*, Mutual Fund Trends, 2008:Q4, 44 ülkeyi kapsayan değerlerdir.

Dünya yatırım fonlarında en fazla düşüş %22.2 ile Hisse Fonlarda (4.68 trilyon Euro) gerçekleşirken, Karma Fonlar %15.2 (1.27 trilyon Euro) ile ikinci sırada yer almaktadır. Bono Fonlar da %7.9'luk (2.44 trilyon Euro) düşüş yaşanırken, Likit Fonlar %9.7 (4.16 trilyon Euro) oranında yükselmiştir. 2008 yılı içerisinde ise Hisse Fonlar %44.5, Karma Fonlar %29.3, Bono Fonlar %15.5 gerilerken, Likit Fonlar %23.6 oranında yükselmiştir. Bu dönemde, tüm fonlardan 82 milyar Euro çıkış olmuştur. Bu fon çıkışının nedeni yine yaşanan global finansal krizdir.

Aynı dönem verilerini gösteren Grafik 1.2'ye göre, dünya genelinde bulunan toplam 69 bin 477 fonun; %35'i Hisse Fonlar, %31'ini Likit Fonlar, %18'i Bono Fonlar, %9'unu Karma Fonlar oluştururken kalan %7'lik pay da diğer fonlardan oluşmaktadır (EFAMA, *International Statistical Release*, 2008:Q4).

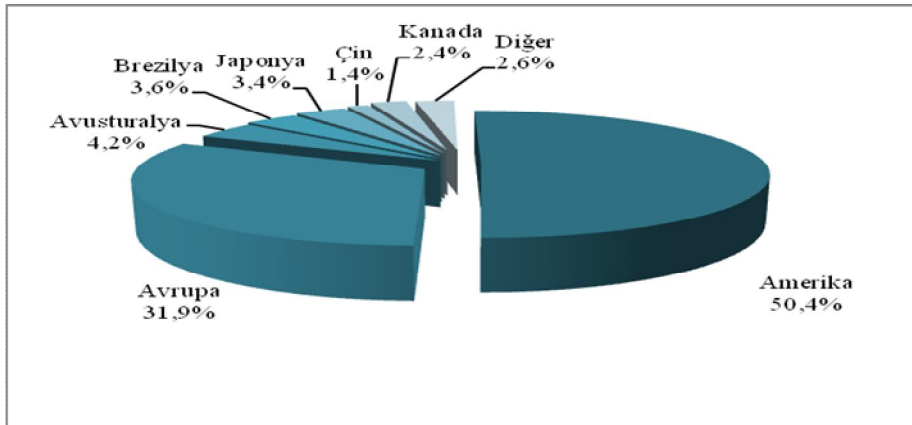
Grafik 1.2: Dünya Yatırım Fonu Sektörünün Portföy Yapısı (2008)



Kaynak: EFAMA, *International Statistical Release*, 2008:Q4.

Dünya yatırım fonu sektörüne ülkeler bazında baktığımızda ise ABD ve Avrupa'nın Yatırım Fonu Endüstrisi'nden en büyük payı aldığını görmekteyiz. Grafik 1.3'e göre; 2008 yılında, ABD'nin toplam fon endüstrisindeki payı %50.4 iken, Avrupa'nın payı %31.9 seviyesinde bulunmaktadır. Diğer %17.7'lik pay ise Kanada, Japonya, Avustralya, Brezilya, Çin ve diğer ülkeler arasında değişik oranlarda paylaşılmış bulunmaktadır.

Grafik 1.3: Dünya Yatırım Fonu Sektöründe Bazı Ülkelerin Payı



Kaynak: EFAMA, *International Statistical Release*, 2008:Q4.

Tablo 1.4'e, 2000-2008 dönemi arasında dünyadaki bazı ülkelerin toplam yatırım fonu portföy büyüklüklerine bakıldığında, en yüksek payı Amerika'nın, 9.601.090 milyon dolarla aldığı görülmektedir. İkinci sırada ise Avrupa 6.288.138 milyon dolarla yer almaktadır. Ancak bu rakamların 2007 yılına göre oldukça düşük olduğuna dikkat edilmelidir. Portföy değerleri yıllar itibariyle artma eğiliminde iken 2008 yılında dünya genelinde belirgin bir düşüş görülmektedir. Bunun nedeni, tüm dünyayı kasıp kavuran küresel ekonomik krizin yatırım fonu sektörüne yansımalarıdır.

Tablo 1.4: Seçilmiş Bazı Ülkelerdeki Yatırım Fonlarının Portföy Değerleri (Milyon \$)

Ülkeler	2000	2001	2002	2003	2004	2005	2006	2007	2008
Kanada	279.511	267.863	248.979	338.369	413.772	490.518	566.298	698.397	416.031
A.B.D.	6.964.634	6.974.913	6.390.358	7.414.401	8.106.939	8.904.822	10.412.458	12.020.895	9.601.090
Avrupa	3.296.016	3.167.965	3.463.000	4.682.836	5.640.450	6.002.261	7.803.906	8.934.864	6.288.138
Rusya	177	297	372	851	1.347	2.417	5.659	7.175	2.026
TÜRKİYE	2.870	3.271	6.002	14.157	18.112	21.761	15.463	22.609	15.404
Afrika	16.921	14.561	20.983	34.460	54.006	65.594	78.026	95.221	69.417
Dünya	11.871.028	11.654.868	11.324.128	14.048.311	16.164.795	17.771.025	21.823.455	26.199.448	18.974.521

Kaynak: *Mutual Fund Fact Book*, The Investment Company Institute (ICI), 2009, s.167.

Yatırım fonu sayısı bakımından dünya fon miktarında 2001- 2008 döneminde artış yaşanmıştır ve 2008 yılında 69.032 adet olmuştur. Avrupa'da işlem gören yatırım fonları sayısı 36.780 adet ile ilk sırayı alırken, ABD'deki yatırım fonu sayısı 16.459 adet ile ikinci sırada yer almaktadır.

Tablo 1.5: Seçilmiş Bazı Ülkelerdeki Yatırım Fonlarının Sayısı

Ülkeler	2001	2002	2003	2004	2005	2006	2007	2008
Amerika	13.449	13.884	13.921	14.064	13.764	14.475	15.462	16.459
Avrupa	27.343	28.972	28.541	28.764	30.060	33.151	35.210	36.780
Asya ve Pasifik	12.153	10.794	11.641	11.617	12.427	13.479	14.847	14.909
Afrika	426	460	446	537	617	750	831	884
Dünya	53.371	54.110	54.569	54.982	56.868	61.855	66.350	69.032

Kaynak: *Mutual Fund Fact Book*, The Investment Company Institute (ICI), 2009, s.168.

Sert düşüşlerin yaşandığı 2008'in son ayları ve 2009 ilk çeyreğine göre iyimserliğin ve risk iştahının arttığı piyasalarda yükselme eğilimi olmakla birlikte, uluslararası kredi piyasalarındaki sorunların devam etmesi nedeniyle ekonomik göstergelerde somut bir iyileşme gözlenmemektedir (TKYD Nisan 2009 Bülteni).

Bütün bu bilgiler ışığında dünya yatırım fonu sektörünün finans piyasalarında öneminin giderek arttığı ve artmaya devam edeceği söylenebilir. Ancak, dünyada yaşanan ekonomik krizlerin yatırım fonu sektörüne etkileri de göz ardı edilmemelidir.

1.6.2. Yatırım Fonlarının Türkiye'deki Gelişimi

Türkiye sermaye piyasasına ilk kez 1987 yılında giren ancak sayılarında ve portföy büyüklüklerinde 1993 yılında önemli artışlar görülen yatırım fonları, vadesiz ve likit olmaları ve istikrarlı kazanç sağlamalarından dolayı küçük tasarruf sahiplerinin fonlarının sermaye piyasasına aktarılmasını sağlayarak hızlı bir gelişim göstermiştir.

İlk yatırım fonunun halka arz edildiği 1987 yılı sonunda 7 adet olan fon sayısı 2008 yılı sonunda 335 adede yükselmiştir. Tablo 1.6'da yer alan SPK verilerine göre, 2008 yılının Aralık ayında yatırım fonlarının net aktif değeri, bir önceki aya göre azalarak 23.972 milyar TL (Kasım 2008, 24.7 milyar TL) olarak gerçekleşmiştir. Aralık 2008'de net aktif değer, A Tipi fonlarda 596.212 milyon TL (Kasım 2008, 602 milyon TL)'ye, B Tipi fonlar 23.376 milyar TL (Kasım 2008, 24.1 milyar TL)'ye gerilemiştir. 2007 yılı sonu ile karşılaştığımızda, yatırım fonlarının net aktif değeri %10 düşerek 26.4 milyar TL'den 23.376 milyar TL'ye gerilemiştir. Yatırımcı sayısına baktığımızda ise yatırım fonlarında toplam yatırımcı sayısı Aralık 2008'de, 2007 Aralık'a göre 59.550 kişi düşüşle 2.938.904 kişi olmuştur. 2007 ile 2008 yılları karşılaştırıldığında görülen bu düşüşler dünyada yaşanan ekonomik krizin Türkiye'deki yansımalarıdır.

Tablo 1.6: Türkiye'deki Yatırım Fonu Sektörünün Büyüklükleri (2008)

Fon Türü	Fon Sayısı	Portföy Değeri (TL)*	Portföy Değeri (USD)	Yatırımcı Sayısı
A Tipi	126	596.212	389.885	177.536
B Tipi	209	23.376.136	15.288.513	2.761.368
Toplam	335	23.972.348	15.676.398	2.938.904

*1 USD= 1,5292 TL/Aralık 2008; *:Milyar TL.*

Kaynak: SPK Aylık İstatistik Bülteni/Aralık 2008.

Yatırım fonları portföyünde bulunan menkul kıymetlerin toplam fon portföy içindeki payları Tablo 1.7'de gösterilmiştir.

Tablo 1.7: Türkiye Faaliyet Gösteren Yatırım Fonlarının Portföy Yapıları

Yıllar	Fon Sayısı	Top. Değ. (TL)	Yatırımcı Sayısı	HS (%)	KB (%)	ÖT (%)	TR (%)	BBP (%)	YMK (%)	Diğer (%)
1999	216	1.219.444	471.218	13.55	26.01	0.00	60.07	0.00	0.16	0.22
2000	270	1.937.611	480.543	12.40	12.72	0.00	74.63	0.00	0.18	0.06
2001	277	4.755.782	997.759	7.43	32.94	0.00	59.47	0.00	0.11	0.05
2002	241	9.346.672	1.473.912	2.56	49.28	0.00	48.04	0.00	0.10	0.02
2003	242	19.858.160	2.204.924	2.43	66.98	0,00	30.50	0.00	0.09	0.00
2004	253	24.443.774	2.632.462	2.22	67.17	0.00	27.77	2.83	0.02	0.00
2005	275	29.374.122	2.959.573	2.52	70.27	0.00	26.03	1.14	0.03	0.00
2006	289	22.011.576	2.470.909	2.70	38.27	0.00	57.53	1.39	0.09	0.02
2007	297	26.381.161	2.998.454	2.53	37.90	0.00	56.29	2.97	0.05	0.25
2008	335	23.972.348	2.938.904	1.51	43.74	0.00	49.42	4.81	0.04	0.48
HS % : Hisse Senedi Oranı				TR % : Ters Repo Oranı						
KB % : Kamu Borçlanma Araçları Oranı				BBP % : Borsa Para Piyasası Araçları Oranı						
ÖT % : Özel Sektör Tahvil Oranı				YMK % : Yabancı Menkul Kıymet Oranı						

Kaynak: SPK Aylık İstatistik Bülteni/Aralık 2008.

1999 yılından bu yana en büyük paya sahip olan Ters Repo ve Kamu Borçlanma Senetleri oranı 2008 yılı itibariyle sırasıyla %49.42 ve %43.74 olarak gerçekleşirken, Hisse Senedi oranı %1.51, Yabancı Menkul Kıymetler %0.04, Borsa Para Piyasası oranı %4.81, Diğer Kıymetler %0.48, Özel Sektör Tahvil Oranı ise %0.0 olarak gerçekleşmiştir. Ayrıca yıllar itibariyle toplam portföy değerinin arttığı, Kamu Borçlanma Senetleri ve Ters Repo'nun toplam yatırım fonu içindeki paylarının sürekli arttığı görülmektedir.

Türkiye'de 2000-2008 yılları arasındaki 9 yıllık dönemde yatırım fonları sektörünün gelişimi Tablo 1.8 ve Grafik 1.4' de verilmiştir. Tablo 1.8'e göre, yatırım fonları 9 yıllık dönemde ortalama %42.6 büyüme göstermiştir. Aynı dönemde A Tipi fonlar %5.6 B Tipi fonlar ise %50.3 büyüme göstermiştir. Yıllar itibariyle sektörün gelişimine bakıldığında, Kasım 2000 ve Şubat 2001 likidite krizlerinin etkisiyle A Tipi fonlarda azalma eğilimi dikkati çekmektedir. 2003 yılında toparlanma gözlenirken 2004 yılında yaşanan fiyat hareketliliği A ve B tipi fon sektörünün büyümesini ciddi ölçüde yavaşlatmış, 2005 yılında ise bir sıçrama gözlenmiştir. Ancak yine 2006 yılında sıcak paraya dayanan likidite krizinin etkileri ile sektörde büyüme rakamları eksilere düşmüştür. 2002 yılında olduğu gibi sektörün ciddi biçimde gerilediği görülmüştür. 2007 yılında sektör kendisini toparlarken 2008 yıllarında tekrar azalma yaşanmıştır. Bunun en önemli nedeni 2006'da ortaya çıkan

ve tam etkilerini 2008 yılı son çeyreğinde bütün dünyada gösteren küresel ekonomik krizdir.


Tablo 1.8 ve Grafik 1.4' ya göre, 2000-2008 döneminde Türkiye yatırım fonu sektörünün, dünyada yaşanan ekonomik krizlerin etkisiyle ve özellikle ülkemizde yaşanan istikrarsızlıklar ve volatiliteler nedeniyle yükselme, düşme ve toparlanma aşamalarından geçerek gelişme sürecinin engellendiği görülmektedir. Buna rağmen 9 yıllık dönemde sektörün %42.6 oranında büyüdüğü görülmektedir.

Tablo 1.8: Türkiye'deki Yatırım Fonu Sektörünün Gelişimi (Bin TL)

Yıllar	A Tipi		B Tipi		Toplam	
	Port. Değeri	Büyüme (%)	Port. Değeri	Büyüme (%)	Port. Değeri	Büyüme(%)
2000	520.294	-	1.417.318	-	1.937.611	-
2001	568.737	9.3	4.187.045	195.4	4.755.782	145.4
2002	434.884	-23.5	8.911.788	112.8	9.346.672	96.5
2003	743.863	71.0	19.114.297	114.5	19.858.160	112.5
2004	780.370	4.9	23.663.404	23.8	24.443.774	23.1
2005	1.033.635	32.5	28.340.487	19.8	29.374.122	20.2
2006	831.518	-19.6	21.180.058	-25.3	22.011.576	-25.1
2007	919.383	10.6	25.461.778	20.2	26.381.161	19.9
2008	596.212	-35.2	23.376.136	-8.2	23.972.348	-9.1
Ortalama Büyüme		5.6		50.3		42.6

Kaynak: SPK Aylık İstatistik Bülteni/Aralık 2008.

Grafik 1.4: Türkiye'deki Yatırım Fonlarının Toplam Portföy Değeri (Bin TL)



Kaynak: SPK Aralık 2008, Aylık İstatistik Bülteni dikkate alınarak hazırlanmıştır.

Türkiye'de yatırım fonu sektörünün gelişimi konusunda dikkati çeken diğer bir nokta da sektörde faaliyet gösteren yatırım fonu sayısının A tipi ve B tipi olarak

dengeli dağılmasına rağmen, gerek portföy değeri gerekse yatırımcı sayısı bakımından sektörün B tipi yatırım fonları ağırlıklı olduğudur. Bu durumu A ve B tipi yatırım fonu sayısındaki yıllar itibariyle yaşanan gelişmeler de yansıtmaktadır.

Finansal sistemin dolayısıyla sermaye piyasalarının gelişimi açısından kurumsal yatırımcıların önemi dikkate alındığında, henüz çok genç olan ülkemiz yatırım fonu sektörünün, var olan birçok eksikliklere rağmen, şimdiye kadar göstermiş olduğu gelişme trendi ile kendisine yüklenen ağır görevleri yerine getirebilecek kapasitede olduğu söylenebilir (Karacabey, 1998, 56). ABD'deki yatırım fonları yapısına benzerlik gösteren Türkiye'deki yatırım fonları da yatırım fonları katılma belgesi karşılığı fon toplamakta ve topladığı fonları yönetmektedir. Yatırım fonları SPK'nın yanı sıra bağımsız denetim kuruluşlarınca da denetlenmektedir.

Türkiye'de yatırım fonları sektörünün en belirgin özelliği ise fon kurucularının büyük kısmının bankalardan oluşmasıdır. Fon kurucuların yönettiği fonların portföy değerleri ve piyasa payları Tablo 1.9' da verilmiştir.

Tablo 1.9: Türkiye'deki Yatırım Fonu Kurucularının Piyasa Payları (2008)

	Fon Kurucuları	Portföy Değeri (TL)	Piyasa Payı (%)
1.	T. İş Bankası A.Ş.	5.159.741.855	21.52
2.	Yapı ve Kredi Bankası A.Ş.	3.969.816.918	16.56
3.	T.Garanti Bankası A.Ş.	3.378.134.123	14.09
4.	Akbank T.A.Ş.	3.299.170.593	13.76
5.	T.C. Ziraat Bankası A.Ş.	1.282.792.840	5.35
İlk 5 Fon Kurucusunun Piyasa Payları			71.28
6.	Türkiye Vakıflar Bankası T.A.O.	1.109.165.907	4.63
7.	HSBC Bank A.Ş.	923.950.559	3.85
8.	Türk Ekonomi Bankası A.Ş.	873.621.816	3.64
9.	Finansbank A.Ş.	572.586.035	2.39
10.	ING Bank A.Ş.	507.355.223	2.12
İlk 10 Fon Kurucusunun Piyasa Payları			87.91

Kaynak: SPK Aralık 2008, Aylık İstatistik Bülteni dikkate alınarak hazırlanmıştır.

Yatırım fonları kurucusu olan ilk 5 banka piyasa toplamının %71.28'ini oluşturmakta ve ilk 10 kurucu ise %87.91'ini oluşturmaktadır. Neredeyse piyasanın tamamı bu 10 kurucu tarafından yönetilmektedir. Aralık 2008 itibariyle, Türkiye'de 65 tane fon kurucu vardır. İlk 10 fon kurucusu piyasa payı %87.91 olduğuna göre kalan %12.09'luk kısmı 55 adet fon kurucusu paylaşmaktadır.

1.7. Genel Değerlendirme

Amerika ve Avrupa’da kurumsal yatırımcıların toplam finansal varlıklarının büyük çoğunluğu emeklilik fonları ile sigorta şirketlerinde bulunmaktadır. Ülkemizde finansal liberalizasyon sürecine kamu borçlanma sisteminde kalıcı reformlar yapılarak başlanılmaması, ülke çapında üretilen kaynakların devlet tarafından absorbe edilmesi, yurtdışından ülkemize aktarılan kaynakların genelde kısa vadeli ve sıcak para olarak tabir edilen fonlar olması gibi faktörler, ülkemizde sıklıkla piyasa anomalilerinin ve volatilitelerin görülmesine yol açmıştır (Beyazoğlu, 2002, 20). Bu durum da sermaye piyasasının gelişmesini ve piyasa araçlarının çeşitlenmesini engellemiştir.

Piyasanın istikrarına katkısı olan ve piyasaların en büyük oyuncularını olması gereken kurumsal yatırımcıların portföy büyüklüklerinin GSYH’ya oranı, ülkedeki kurumsal yatırımcı tabanının gelişmişliğinin ve ülkenin sermaye piyasasının derinliğinin bir göstergesidir. Türkiye’de bu oran 2002-2008 döneminde %3-%5 arasında seyrederken gelişmiş ülkelerde %70-100'lere varmaktadır. Bu oranın yüksek seviyelere ulaşması reel sektörün ihtiyaç duyduğu kaynağın çok düşük maliyetle sağlanmasını mümkün kılacaktır. Ancak güçlü ve istikrarlı bir ekonomiye sahip olan ülkenin, finans merkezi haline gelebileceği veya finans piyasasının gelişebileceği de göz ardı edilmemelidir.

Türkiye ekonomisinde yaşanan istikrasızlıklar ve volatilitelerin yatırım fonu piyasasının gelişme sürecini engellemesine rağmen, yatırım fonu piyasasında önemli gelişmeler yaşandığı ve piyasanın genişleyerek büyüdüğü söylenebilir. Ekonomik büyüme ve ona bağlı olarak yerli yatırımcının risk iştahının gelişmesi, yatırım fonları piyasasını da etkilemiştir.

Türkiye’nin son 20 yıllık yatırım fonu gelişme sürecine bakıldığında fonlara ilişkin talep yapısıyla ilgili bir sorun göze çarpmaktadır. Bu sorun, likit fonların tüm yatırım fonları içindeki payının son derece yüksek olması (%80) ve likit fon portföylerinin tamamına yakınının kamu kesimi borçlanma senetleri ve repodan oluşmasıdır. Başka bir ifadeyle, profesyonel portföy yönetiminin geçerli olduğu yatırım fonlarının mevcut görünümü ideal yapının oldukça gerisinde kaldığını göstermektedir. Bu durum, temel felsefesi çeşitlendirme (diversification) yaparak

piyasadaki alternatif yatırım araçlarının herhangi birinin getirisinden daha fazla getiriye ulaşmak olan yatırım fonlarının kuruluş amacı ile çok da örtüşmemektedir.

Türkiye yatırım fonu piyasasını, 2003 yılının son çeyreğinde *Emeklilik Yatırım Fonlarının* faaliyete geçmesiyle başlayan çeşitlendirme süreci, Nisan 2004 yılında SPK'nın yayınladığı bir tebliğ ile hukuki çerçevesi çizilen *Borsa Yatırım Fonlarının* 2005 yılında İMKB'de halka arz edilmesiyle devam etmiştir. Yine, 2007 yılında SPK'nın Yatırım Fonlarına İlişkin Esaslar Tebliği'ne yapılan ekleme ile *Fon Sepetleri ve Koruma Amaçlı Yatırım Fonları* uygulama alanı bulmuştur. 2007 yılı yatırım fonları piyasası için olumlu geçmiş ve toplam portföy büyüklüğü %25'lik bir büyüme ile 31 milyar TL'ye yükselmiştir. A tipi fonlarda %11'lik ve B tipi fonlarda %20'lik artış olmuştur. Son dönemlerde ise SPK tarafından yapılan düzenlemelerle mevzuat engellerini aşan ve Türkiye'deki piyasa yatırım fonu toplamının %71.28'ini oluşturan bankalar, farklı müşteri profillerine yönelik olarak yatırım fonlarını çeşitlendirmişlerdir. Örneğin, Finansbank İMKB 30 endeksine dayalı borsa yatırım fonunun ardından, *banka yatırım fonunu* halka arz etmeye hazırlanmaktadır. Fortis Bank ise *altına dayalı ana koruma amaçlı yatırım fonunu* kurmuştur (<http://www.capital.com.tr.haber.aspx?HBR KOD=4133/> Erişim Tarihi: 01.04.2009).

2006 yılında başlayan ve 2008 son çeyreğinde ABD'nin 10 trilyon dolarlık büyüklüğü olan mortgage piyasasında yaşanan kredi krizini takip ederek likidite krizine dönüşen, tüm dünya finansal piyasalarını kasıp kavuran, dünyada 1929 büyük bunalımından beri görülen en büyük bunalım olarak nitelendirilen, bir ülkenin (İzlanda) iflasına yol açan ve yüzyılın krizi olarak nitelendirilen bu kriz; sigorta, gayrimenkul, inşaat, madencilik ve finans sektörlerinin büyüme hızını yavaşlatmış, özellikle sermaye piyasalarındaki dengeleri de alt üst etmiştir. Ülkeler bir araya gelerek faiz düşürmek biçiminde önlemler almaya çalışmışlardır. Türkiye'de de mali ve reel kesim, Dünyada yaşanan bu olumsuz gelişmelerden ve şoklardan önemli ölçüde etkilenmiştir. Merkez Bankası'nın faiz indirimleriyle birlikte, mevduat faizlerinde hızlı düşüş, bono faizlerindeki hızlı dalgalanma ile gerçekleşen yüksek fon kazançları, yatırımcıları da uzun vadeli ürünlerden çok daha likit bir enstrüman olan yatırım fonlarına yönelmesine yol açmıştır.

Sonu olarak, Trkiye yatırım fonu sektrnn yeniden yapılanması ve geliřmiř lkelerdeki gibi otomatik istikrar saęlayıcı zellięe kavuřması, dolayısıyla her aıdan geliřebilmesi iin, ncelikle ekonomik istikrarın saęlanması daha sonra yatırım fonlarının sınıflandırılması, denetlenmesi, eřitlendirilmesi ve vergi/mevzuata ynelik alıřmaların yapılması gerektięi sylenebilir.

İKİNCİ BÖLÜM

YAPAY SİNİR AĞLARI

Bu bölüm, çalışmanın temel konusunu oluşturan Yapay Sinir Ağları teknolojisine ait temel ve teorik bilgileri kapsamaktadır. Teknolojik gelişmenin önemli boyutlara ulaştığı günümüzde, insanoğlunun kendisini tanımaya yönelik çalışmaları da önemli aşamalar kaydetmiştir. Yapay zeka (artificial intelligence) kavramı ile insanın en önemli özellikleri olan düşünebilme ve öğrenebilme yetenekleri en önemli araştırma konuları durumuna gelmiştir. Özellikle son yıllarda bilgisayar kullanımının hızla yaygınlaşması sonucunda yapay zeka çalışmaları da bir ivme kazanmıştır.

İnsanın düşünme yapısını anlamak ve bunun benzerini ortaya çıkaracak bilgisayar işlemlerini geliştirmeye çalışmak olarak tanımlanan *yapay zeka*, aslında programlanmış bilgisayarlara düşünme yeteneği sağlama girişimidir. İnsan gibi düşünen ve davranan sistemlerin geliştirilmesine yönelik olarak 1950’li yıllardan beri süren yapay zeka çalışmaları, bir noktada insanı taklit etmeye yönelik olduğundan mühendislik, nöroloji ve psikoloji gibi alanlara da yayılmıştır. İnsan gibi düşünebilen ve davranabilen sistemlerin geliştirilmesi için yapılan çalışmalarda bugün gelinen nokta, henüz yapay zekanın tam olarak geliştirilememiş olmasıdır. Yapay zekanın mümkün olabilirdiği tartışmaları bir yana bırakılırsa bu konudaki çalışmalar bu alanı destekleyen farklı alanlardaki çalışmalarla birlikte devam etmektedir.

Yapay zeka çalışmaları kapsamında ortaya çıkan ve bir noktada yapay zeka çalışmalarına destek sağlamakta olan farklı alanlardan bir tanesi de Yapay Sinir Ağları Teknolojisi’dir. Dolayısıyla, yapay zeka alanının bir alt dalını oluşturan YSA teknolojisi öğrenebilen sistemlerin temelini oluşturmaktadır. İnsan beyninin temel işlem elemanı olan nöronu (neuron) şekilsel ve işlevsel olarak basit bir şekilde taklit eden YSA’lar, bu yolla biyolojik sinir sisteminin basit bir simülasyonu için oluşturulan programlardır. Bu şekilde, insanoğluna özgü deneyerek (yaşayarak) öğrenme yeteneğini bilgisayar ortamına taşıyabildiği düşünülen YSA teknolojisi bir bilgisayar sistemine inanılmaz bir “girdi veriden öğrenme” kapasitesi sağlamakta ve birçok avantajlar sunmaktadır. Çeşitli avantajlar sunan ve gün geçtikçe gelişen bu

teknolojiden, günümüzde pek çok alanda olduğu gibi ekonomi ve istatistik alanlarında da faydalanılmaktadır. Özellikle, “Evrensel Fonksiyon Yakınsayıcı Yöntem (Universal Function Approximators)” olarak tanınmalarından dolayı tahmin ve öngörü gibi verinin içerdiği yapının tanımlanmasını gerektiren alanlarda sıkça kullanılmaktadırlar (Yurtoğlu, 2005, 4).

Teknik olarak bir yapay sinir ağının en temel görevi, kendisine gösterilen bir girdi setine karşılık gelebilecek bir çıktı seti belirlemektir. Bunu yapabilmesi için ağ, ilgili olayın örnekleri ile eğitilerek genelleme yapabilecek yeteneğe kavuşturulur. Yapay sinir ağları, *bağıntılı ağlar*, *paralel dağıtılmış ağlar* ve *nuromorfik sistemler* olarak da adlandırılmaktadır (Öztemel, 2006, 30).

2.1. Literatürdeki YSA Tanımları

Yapay Sinir Ağları için üzerinde fikir birliği sağlanmış tek bir tanım yoktur. Geniş ya da dar kapsamda birçok tanımla karşılaşılabilir. Hatta bazı araştırmacılar YSA için genel bir tanım vermek yerine, YSA türlerinin kendi içinde tanımlanması gerektiğini savunmaktadır. Bununla birlikte, YSA ile ilgili literatürde yer alan bazı tanımlardan bazıları şu şekildedir:

YSA, insan beyninin çalışma mekanizmasını taklit ederek beynin öğrenme, hatırlama, genelleme yapma yolu ile yeni bilgiler türetebilme gibi temel işlevlerini gerçekleştirmek üzere geliştirilen mantıksal bir yazılımdır (Yazıcı ve Diğ., 2007, 65).

Yapay Sinir Ağları, teknik detaya girilmeksizin en kısa ve basit şekilde, bir örnekler kümesi yardımıyla parametrelerin uyarlanabilmesini sağlayacak bir matematiksel formül için yazılan bilgisayar programı olarak tanımlanabilir. (Anderson ve McNeill, 1992, 4).

Yapay sinir ağı, özünde insan beyninin çalışma biçimini taklit eden, basit bir işlem elemanı olan nöronların değişik şekillerde birbirine bağlanmasıyla oluşan bir sistemdir. Her bir nöron diğer nöronlardan veya dışarıdan gelen sinyalleri alır, bunları birleştirir, dönüştürür ve sayısal sonuç ortaya çıkarır (Zhang, Patuwo ve Hu, 1998, 37; Indro ve Diğ., 1999, 374). İnsan beyninin biyolojik çalışma sisteminden esinlenerek geliştirilen bu model, süreç ve örnekleri tanımlayan bir bilgi işlem

modelidir. YSA, katmanlar içinde birbirine yüksek derecede bağı ve organize olan nöronların birleşmesinden oluşan bir ağıdır (Zhang, 2004, 3).

Yapay sinir ağı literatüründe çok tanınan Kohonen'nin yaptığı yapay sinir ağı tanımına göre, “Yapay sinir ağları, paralel olarak bağlantılı ve çok sayıda basit elemanın, gerçek dünyanın nesnelere biyolojik sinir sisteminin benzeri yolla etkileşim kuran, hiyerarşik bir organizasyondur (Kohonen, 2001, 71-72; <http://books.google.com.tr/> Erişim Tarihi:18.03.2009).

Yapay sinir ağları Darpa tarafından ise şu şekilde tanımlanmıştır: “Bir YSA, birbirlerine paralel olarak çalışan birçok basit işlem elemanından oluşan ve fonksiyonu, ağı yapısı, bağlantı ağırlıkları ve elemanlarda gerçekleştirilen işlemler tarafından belirlenen bir sistemdir.” Her bir nöron, dışarıdan veya diğer nöronlardan gelen sinyallere karşılık verir ve belli bir fonksiyon ile bu sinyalleri çıktıya dönüştürür (ECB, Working Paper Series, No.571, 2006, 1).

YSA, ağırlıklandırılmış biçimde, tek yönlü sinyal kanalları ile birbirlerine bağlanmış birçok basit işlem elemanından oluşan, paralel ve dağınık, tek veya çok katmalı bilgi işlem sistemidir (Kamruzzman, Beggand ve Saker, 2006, 3). Yapay sinir ağı dışarıdan gelen girdilere dinamik olarak yanıt oluşturma yoluyla bilgi işleyen, birbiriyle bağlantılı nöronlardan oluşan bilgi işlem sistemidir (Sahoo ve Hathy, 2007, 5).

Haykin tarafından 1998 yılında yapılan daha kapsamlı ve genel kabul gören bir tanım ise “Bir sinir ağı, basit işlem birimlerinden oluşan, deneyimsel bilgileri biriktirmeye yönelik doğal bir eğilimi olan ve bunların kullanılmasını sağlayan yoğun bir şekilde paralel dağıtılmış bir işlemcidir (Haykin ve Diğ., 2001, 1-2; <http://books.google.com.tr.>, Erişim Tarihi:18.03.2009)”. Bu işlemci iki şekilde beyin ile benzerlik göstermektedir:

- Bilgi, ağ tarafından bir öğrenme süreciyle çevreden elde edilir.
- Elde edilen bilgileri biriktirmek için sinaptik ağırlıklar olarak da bilinen nöronlar arası bağlantı güçleri kullanılır.

2.2. Yapay Sinir Ağları Yönteminin Tarihçesi

Yapay sinir ağlarının tarihçesi nörobiyoloji konusuna ilgi duyulması ve elde edilen bilgilerin bilgisayar bilimine uyarlanması ile başlamaktadır. YSA'lara ilişkin çalışmalar incelendiğinde, yapılan araştırmaların çoğunun birbirinin devamı niteliğinde olduğu görülmektedir. Diğer bir deyişle, geliştirilmiş olan en eski YSA yapıları ve öğrenme algoritmaları günümüzde hala kullanılmaktadır ve bu alandaki gelişmeler önceki gelişmelerle güçlü bir biçimde ilişkilidir. Bu araştırmaların birbirini takip etmesi nedeniyle YSA çalışmaları hızla gelişmiştir, ancak daha sonraları yapılan bazı çalışmalar önceki çalışmaların yetersiz olduğunu göstermiş ve bu sorunlar giderilene kadar YSA alanındaki çalışmaların ve bu çalışmalara yapılan desteklerin duraksamasına sebep olmuştur (Öztemel, 2006, 37).

İnsan beyninin nasıl çalıştığı ve fonksiyonları uzun yıllar araştırılmıştır. Beyin fonksiyonları konusunda bilgi veren ilk eser 1890 yılında yayınlanmıştır. 1940 yılından önceyse Helmholtz, Pavlov, Poincare gibi bazı bilim adamlarının YSA kavramı üzerinde çalıştıkları bilinmektedir. Fakat bu çalışmaların mühendislik değeri olduğu söylenemez (Öztemel, 2006, 37). Yapay sinir ağlarının ilk temelleri 1940'ların başında araştırmalara başlayan nöropsikolojist olan McCulloch ile matematikçi olan Pitts'in 1943 yılında yayınladıkları bir makaleyle atılmıştır. McCulloch ve Pitts, biyolojik nöronun basit matematiksel gösterimi biçiminde bir modelleme yapmışlardır (Zurada, 1992, 30). Böylece insan beyninin hesaplama yeteneğinden esinlenerek ilk nöron modeli veya basit bir sinir ağı modellenerek, yapay sinir sisteminin ilk matematiksel modeli geliştirilmiştir. Hücrelerin birbirleri ile paralel çalıştığını ortaya koyarak öğrenme kurallarını belirlemeye çalışmışlardır (McCulloch ve Pitts, 1943, 118).

1949 yılında McGill Üniversitesi'nde bir psikolog olan Donald Hebb, "The Organization of Behaviour" isimli kitabında, yapay hücrelerden oluşan bir YSA'nın ağırlık değerlerini geliştiren bir öğrenme kuralını açıklamıştır (Hebb, 1949, 60-78). Hebb Öğrenme Kuralı denilen bu kural, günümüzde de birçok öğrenme kuralının temelini oluşturmaktadır (Öztemel, 2006, 37). Farelly ve Clark tarafından 1954 yılında rassal ağlar ile adaptif tepki üretme kavramı ortaya atılmıştır (Anderson ve McNeill, 1992, 17). Bu kavram, 1958 yılında Rosenblatt ve 1961 yılında Caianiello

tarafından geliştirilmiştir. Özellikle Rosenblatt tarafından geliştirilen algılayıcı (perceptron) model, daha sonraları geliştirilerek yapay sinir ağlarında devrim niteliğinde olan çok katmanlı algılayıcıların temelini oluşturmuştur (Zurada, 1992, 19).

1950’li yıllarda bilgisayarların gelişmesiyle birlikte, insanın düşünce yapısıyla ilgili teorilerin temellerinin modellenmesi olanaklı hale gelmiştir. IBM araştırma laboratuvarları araştırmacılarından Nathaniel Rochester, bir sinir ağı simülasyonu oluşturma çabalarına öncülük etmiştir. İlk girişim başarısız olmasına rağmen sonraki girişimler başarılı olmuştur. Bu aşamadan sonra, geleneksel hesaplama yöntemlerinin araştırılması yerini sinirsel hesaplama yöntemlerinin araştırılmasına bırakmıştır (Anderson ve McNeill, 1992, 17). Rochester ve ekibi, o zamana kadar “düşünen makineleri” kendi çalışmalarını kanıt göstererek savunmaktaydılar. 1956 yılında yapılan ve daha sonraları Yapay Zeka (YZ) ve YSA (Yapay Sinir Ağları) üzerine konuşmaların ve dolayısıyla kanıtların artmasını sağlamış olan “Yapay Zeka Dartmouth Yaz Araştırma Projesi” yapılmıştır. Bu araştırmanın sonuçlarından biri, hem YZ ve hem de YSA araştırmalarına ilgi gösterilmesini teşvik etmesidir (Anderson ve McNeill, 1992, 17).

1957 yılında, Cornell Üniversitesinde bir nörobiyolog olan Frank Rosenblatt ise YSA çalışmalarının hem gelişiminde hem de duraklamasında önemli bir paya sahip olacak Basit Algılayıcı Modeli (Perceptron)’ni geliştirmiştir. Rosenblatt, bir sineğin göz işlemleriyle ilgilenmiştir. Bir sineğe kaçmasını söyleyen işlemlerin çoğunun sineğin beyni yerine gözünün içinde yapıldığından esinlenerek, *Algılayıcı* diye adlandırılan, bir donanım kurulmuş ve günümüzün en eski YSA modeli olan ağ yapısını geliştirmiştir (Anderson ve McNeill, 1992, 17). Rosenblatt tarafından geliştirilen Algılayıcı, YSA tarihinde önemli bir gelişmeye öncülük etmiştir. Çünkü bu model, daha sonraları geliştirilecek ve YSA’larında devrim niteliğinde olacak olan Çok Katmanlı Algılayıcı (ÇKA)’ların temelini oluşturmaktadır ve oluşturulan bu basit algılayıcı model günümüzde de hala kullanılmaktadır (Zurada, 1992, 19).

1959 yılında Stanford Üniversitesi’nden Bernard Widrow ve öğrencisi Marcian Hoff, ADALINE (Adaptive Linear Elements) ve MADALINE (Multiple Adaptive Linear Elements) olarak isimlendirdikleri Algılayıcıya benzeyen iki model

geliştirmişlerdir (Anderson ve McNeill, 1992, 17-18). Bu sistemde en küçük ortalama kareler (LMS, Least Mean Squares) öğrenme kuralı kullanılmıştır (Öztemel, 2006, 38).

Marvin Minsky ve Seymour Papert tarafından 1969 yılında yapılan çalışmalar “Perceptrons (Algılayıcılar)” isimli kitaba dönüşmüştür. Bu kitapta yazarlar özellikle, yapay sinir ağlarına dayalı algılayıcıların bilimsel bir değerinin olmadığını ve doğrusal olmayan problemlere çözüm üretmediğini iddia etmişler, tezlerini kanıtlamak için de XOR* mantık probleminin çözülmemesini örnek göstermişlerdir. Bu durum yapılan yapay sinir ağları çalışmalarının duraklama dönemine girmesine neden olmuştur. Çalışmaların 1969 yılında sekteye uğramasına ve gerekli finansal desteklerin kesilmesine rağmen bazı bilim adamları çalışmalarına devam etmişlerdir. Özellikle Shun-Ichi Amari, Stephen Grossberg, Gail A. Carpenter, Teuvo Kohonen ve James A. Anderson gibi araştırmacıların çalışmaları 1980’li yıllara gelindiğinde meyvelerini vermiş ve YSA’lara ilişkin yeni çalışmalar ortaya koyulmaya başlanmıştır. 1976 yılında Grossberg ve Carpenter tarafından geliştirilen, Adaptif Rezonans Teorisi (ART), öğretmensiz öğrenme konusunda zamanın geliştirilmiş en karmaşık yapay sinir ağı olmuştur (Zurada, 1992, 19; Öztemel, 2003, 39).

1982 ve 1984 yılında Hopfield tarafından yapılan çalışmalar, yapay sinir ağlarının geliştirilebileceği ve özellikle geleneksel bilgisayar programlama ile çözülmesi zor olan problemlere çözüm üretebileceğini göstermiştir. Hopfield, 1972 yılında farklı disiplinlerde çalışan elektrik mühendisi Kohonen ve nöropsikolojist Anderson’un birbirinden habersiz oluşturdukları benzer çalışmaları kullanmıştır. Yaptığı çalışmalarla optimizasyon gibi teknik problemleri çözmek için doğrusal olmayan dinamik Hopfield ağını ve Kohonen eğitimsiz öğrenen bir ağ olan “Kendiliğinden Organize Olabilen Nitelik Haritaları (SOM, Self-Organizing Feature Maps)” ağını geliştirmiştir (Hopfield, 1982, 2554-3092). Hopfield, bu çalışmalarda ayrıca YSA’ların matematiksel temellerini ortaya koymuştur (Anderson ve McNeill, 1992, 18). Bu çalışmalar, daha sonraları geliştirilecek olan danışmansız öğrenme kurallarının temelini oluşturmuştur.

* XOR (Executive OR) mantık problemi, birim hiperküpteki noktaların sınıflandırılması probleminin özel bir durumu olarak tanımlanabilir. Hiperküpteki her bir nokta, 1 ya da 0 sınıflarından birine aittir. Ayrıntılı bilgi için bkz. (Zurada, 1992).

1986 yılında David Rumelhart ve James McClelland, “Paralel Distrubuted Processing” adlı eserlerinde ileri beslemeli modellerde yeni öğrenme modeli olan hatanın Geriye Yayılma Algoritmasını (Back Propagation Algorithm) geliştirerek bu konuda daha önce iddia edilen aksaklıkların aşılabileceğini göstermişlerdir. Çünkü tek katmanlı algılayıcının çözemediği XOR problemi, çok katmanlı algılayıcıların bulunmasıyla çözülmüştür. Bugün birçok alanda bu öğrenme yönteminin farklı sürümleri kullanılmaktadır (Rumelhart ve McClelland, 1986, 283). Halen en çok kullanılan eğitim algoritmalarından biri olan bu algoritmanın geliştirilmesi YSA alanında çığır açmıştır (Zurada, 1992, 20). Bu gelişmeler YSA’larına olan ilginin artmasına neden olmuştur.

YSA’lara olan ilginin artması sonucunda bu konuyla ilgili olarak çeşitli konferanslar düzenlenmiştir. Bu konferanslardan biri de Kyoto’da Japon ve Amerikalı katılımcılar tarafından düzenlenen “US-Japan Joint Conference on Cooperative/Competitive Neural Networks” konferansıdır. Konferans boyunca Japonlar beşinci nesil araştırmalarını sunmuşlardır. Bunun üzerine Amerikalılar arasında Japonya’nın gerisinde kalındığı korkusu oluşmuştur. Bu korku nedeniyle ABD’de kısa bir sürede, fonlar yeniden YSA araştırmalarına aktarılarak, YSA’ların belirli aralıklarla geliştirilmesi söz konusu olmuştur (Anderson ve McNeill, 1992, 18).

1985 yılına gelindiğinde, Amerikan Fizik Enstitüsü “Bilgi İşleme İçin Yapay Sinir Ağları (Neural Networks for Computing)” konulu yıllık toplantılar düzenlemeye başlamıştır (Anderson ve McNeill, 1992, 18). 1987 yılında Elektrik ve Elektronik Mühendisleri Enstitüsü (IEEE) tarafından yapılan 1. Uluslar arası Yapay Sinir Ağları Konferansı (1. International Conference on Neural Networks) ile YSA alandaki çalışmalar tüm dünyada yaygınlaşmaya başlamıştır.

1988 yılında çok katmanlı algılayıcılara alternatif olarak, Broomhead ve Lowe, Radyal tabanlı fonksiyonlar (Radial Basis Funcitons, RBF) modelini geliştirmişler ve özellikle filtreleme problemlerine oldukça başarılı sonuçlar üretmişlerdir. Daha sonra Specht, bu ağların daha gelişmiş şekli olan Parabolistik Ağlar (PNN) ve Genel Regresyon Ağları (GRNN) geliştirmiştir. 1987 yılından bu yana da değişik sempozyum ve konferanslarla YSA tartışılmakta yeni öğrenme teknikleri ve

modeller ortaya atılmaktadır (Öztemel, 2006, 40). YSA 1950'li yıllarda ortaya çıkmasına rağmen, ancak 1980'li yılların ortalarında genel amaçlı kullanım için yeterli seviyeye gelmişlerdir.

Günümüzde, bilgisayarların boyutlarının küçülüp kapasitelerinin artmasıyla birlikte, YSA teorik ve laboratuvar çalışmaları olmaktan çıkıp günlük hayatta kullanılan sistemler oluşturmaya ve pratik olarak insanlara faydalı olmaya başlamıştır (Öztemel, 2003, 40).

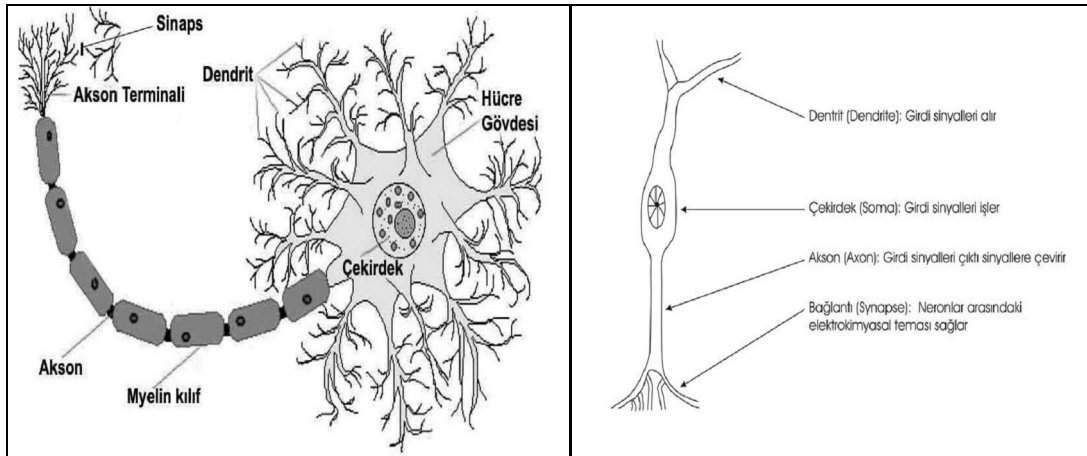
YSA'nın finans alanında kullanımının yaygınlaşması ise Rumelhart ve McClelland'ın geri yayılım algoritmasını geliştirmeleriyle paralellik göstermektedir. Finansal problemlerin doğrusal yapının yanı sıra doğrusal olmayan bir yapıyı da içermeleri nedeniyle, finansal problemlerin çözümünde çok katmanlı ağlara ihtiyaç duyulmuştur. Daha önceleri geliştirilmiş olan çok katmanlı ağlar olmasına rağmen bu ağların eğitiminin yapılamaması söz konusu olmuştur. Ancak Rumelhart ve McClelland'ın geliştirmiş olduğu bu algoritma ile bu sorunun üstesinden gelinerek YSA'nın finans alanında büyük ilgi görmesi sağlanmıştır. Bugün YSA, finansal endekslerin öngörüsü, hisse senedi fiyatlarının öngörüsü, portföy çeşitlendirmesi, tahvil değerlendirme, kredilerin geri ödenme oranlarının öngörüsü, gayrimenkul fiyatlarının öngörüsü ve işletmelerin iflas öngörüsü gibi finansal öngörülerin yapılmasında etkin şekilde uygulanmaktadır.

2.3. Biyolojik Sinir Sistemi

İnsan sinir sistemi çok kompleks bir ağdır. Beyin bu sistemin merkezi elemanıdır ve birbirlerine alt ağlarla bağlı yaklaşık 10^{10} adet nöron (sinir hücresi) ve bunların da 6×10^{13} ten fazla sayıda bağlantısının olduğu tahmin edilmektedir. Sinir hücreleri elektrokimyasal bir işlemle bilgi taşımak için özelleşmiş hücrelerdir. Bu sinir hücreleri değişik şekil ve büyüklükte dirler. Bazıları sadece 4 mikron (4/1000 milimetre) genişliğinde iken 100 mikron genişliğinde olanlar da vardır. Her ne kadar değişik tipteki sinir hücrelerinin şekil ve işlev açısından farklılıkları bulunsa da Şekil 2.1'de gösterildiği gibi hepsi, dentrit (dendrite), çekirdek (soma), akson (axon) ve bağlantı veya sinaps (synapse) olmak üzere 4 farklı bölgeden oluşmaktadırlar (Anderson ve McNeill, 1992, 3).

Sinapslar sinir hücreleri arasındaki bağlantılar olarak görülebilir. Bunlar fiziksel bağlantılar olmayıp bir hücreden diğerine elektrik sinyallerinin geçmesini sağlayan boşluklardır. Bu sinyaller somaya gider ve soma bunları işleme tabi tutar, sinir hücresi elektrik sinyali oluşturur ve axon aracılığıyla dendrite'lere gönderir (Öztemel, 2006, 47). Dendritler, bir hücre için girdi kanallarını oluştururlar. Dendritler bu sinyalleri küçük elektriksel akımlara çevirerek hücre gövdesine iletirler. Hücre gövdesi, dendritler aracılığıyla gelen sinyalleri işleyerek çıktıya dönüştürür. Hücre gövdesinin ürettiği bu çıktılar ise aksonlar aracılığıyla diğer nöronlara girdi olmak üzere gönderilir (Anderson ve McNeill, 1992, 4).

Şekil 2.1: Biyolojik Sinir Hücresinin Yapısı



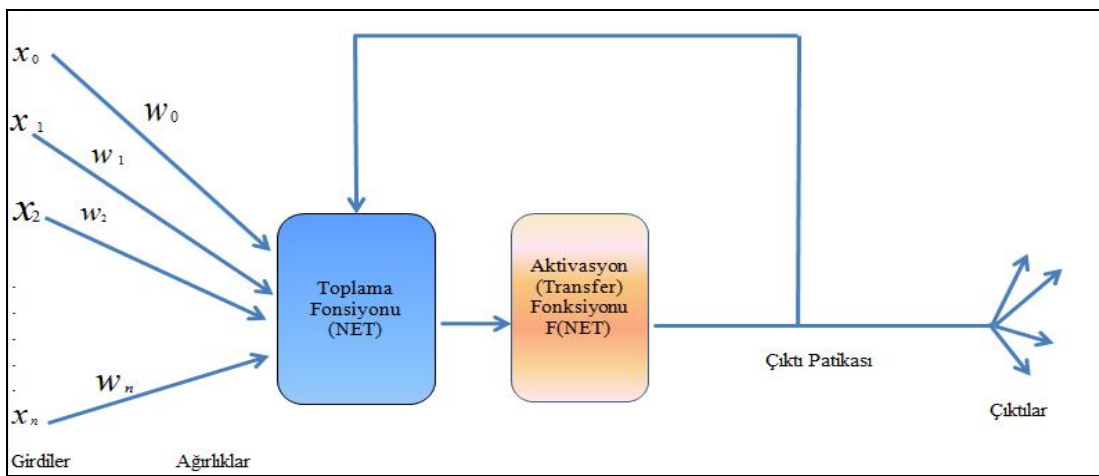
Kaynak: Dave Anderson, George McNeill (1992); *“Artificial Neural Networks Technology”*, Kaman Science Corporation, New York, USA, p.3; J. M. Zurada (1992), *“Introduction to Artificial Neural Systems”*, West St. Paul, p.28.

2.4. Yapay Nöron

Bir YSA, nöron, birim, hücre, düğüm, işlem elemanı veya proses elemanı olarak adlandırılan çok sayıdaki basit işlem birimlerinden oluşmaktadır (Bundan sonra işlem birimi yerine, nöron sözcüğü kullanılacaktır). Biyolojik sinir ağlarının sinir hücreleri olduğu gibi yapay sinir ağlarının da yapay sinir hücreleri vardır. Yapay sinir ağları, basit biyolojik sinir sisteminin çalışma şeklini simüle etmek için tasarlanan bir programdır. Yapay sinir ağları simüle edilen sinir hücrelerini içerir ve bu hücreler değişik şekillerde birbirine bağlanarak ağı oluştururlar. Şekil 2.2’de genel bir yapay sinir hücresinin yapısı sunulmaktadır (Kamruzzman, 2006, 3; Yurtoğlu, 2005, 14).

Şekil 2.2’de girdi değerleri $x(i)$ ve $i=0,1,2,\dots,n$, ağırlık değerleri ise $w(j)$ $j=0,1,2,\dots,n$ olmak üzere, matematiksel sembolleri ile gösterilmiştir. Bu girdi değerlerinin her biri bir bağlantı ağırlığıyla çarpılmaktadır. En basit yapıda, bu çarpımlar toplanarak bir transfer fonksiyonuna gönderilir ve sonuç üretilir. Bu sonuç daha sonra bir çıktıya dönüştürülür. Burada, girdi vektörü $\{x_1, x_2, \dots, x_n\}$ olarak ve uygun ağırlıklar vektörü ise $\{w_{j1}, w_{j2}, \dots, w_{jn}\}$ olarak gösterilmektedir.

Şekil 2.2: Yapay Nöronun Genel Yapısı



Kaynak: Kamruzzman Joarder, Rezaul K. Beggand and Ruhul A. Sarker (2006); “*Artificial Neural Networks in Finance and Manufacturing*”, İdea Group Publishing, p.3; Hasan Yurtoğlu (2005); “*Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği*”, DPT Uzmanlık Tezi, Ankara, s.14.

Biyolojik sinir sisteminden esinlenerek geliştirilen, yapay sinir ağları öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler. Biyolojik sinir sistemleri nasıl sinir hücrelerinden oluşuyorsa yapay sinir ağları da yapay sinir hücrelerinden oluşmaktadır. Yapay bir sinir, biyolojik sinirin temel işlevlerini taklit eden basit bir yapıdır. Ağ içinde yer alan nöronlar bir veya birden fazla girdi alırlar ve bir tek çıktı verirler. Bu çıktı, yapay sinir ağının dışına verilen bir çıktı olabileceği gibi diğer nöronlara girdi olarak da kullanılabilir. Yapay sinir hücreleri mühendislik biliminde *proses elemanları (nöron)* olarak adlandırılmaktadır. Geliştirilen hücre modellerinde farklılıklar olmakla birlikte, genel olarak her proses elemanı, girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve hücre çıktısı olmak üzere 5 temel bileşenden oluşmaktadır (Öztemel, 2006, 48-51). Bu bileşenler şu şekilde açıklanabilir:

2.4.1. Girdiler

Bir yapay sinir hücresine dış dünyadan veya diğer hücrelerden gelen bilgilerdir. Bu girdiler ağın öğrenmesi istenen örnekler tarafından belirlenir. Yapay sinir hücresine dış dünyadan olduğu gibi diğer hücrelerden veya kendi kendisinden de bilgiler gelebilir. Bir nöron genellikle eşanlı olarak çok sayıda girdi alabilir. Her girdinin kendi nispi ağırlığı vardır.

2.4.2. Ağırlıklar

Ağırlıklar, bir yapay sinir hücresine gelen bilginin önemini ve hücre üzerindeki etkisini gösterirler. Şekil 2.2'deki ağırlık 1 (w_1), girdi 1 (x_1)'in hücre üzerindeki etkisini göstermektedir. Ağırlıkların büyük ya da küçük değerler alması önemli veya önemsiz olduğu anlamına gelmez. Ağırlık değerinin sıfır olması o ağ için en önemli olay olabilir. Artı veya eksi olması, etkisinin pozitif veya negatif olduğunu gösterir. Sıfır olması ise herhangi bir etkinin olmadığını gösterir. Ağırlıklar değişken veya sabit değerler olabilirler. Yapay sinir ağı içinde girdilerin nöronlar arasındaki iletimini sağlayan tüm bağlantıların farklı ağırlık değerleri bulunmaktadır. Böylelikle ağırlıklar, her nöronun her girdisi üzerinde etki yapmaktadır.

2.4.3. Toplama (Birleştirme) Fonksiyonu

Toplama fonksiyonu, bir hücreye gelen net girdiyi hesaplayan bir fonksiyondur. Bunun için değişik fonksiyonlar kullanılmakla beraber en yaygın olanı ağırlıklı toplamı bulmaktır. Burada her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır. Böylece net gelen girdi bulunmuş olur. Ancak bazı durumlarda toplama fonksiyonu bu kadar basit bir işlem olmayabilir. Bunun yerine, en az (min), en çok (max), mod, çarpım, çoğunluk veya birkaç normalleştirme fonksiyonu gibi çok daha karmaşık olabilir. Girdileri birleştirecek olan algoritma, genellikle seçilen ağ mimarisine de bağlı olarak belirlenir. Bu fonksiyonlar farklı şekilde değerler üretebilir ve bu değerler ileri doğru gönderilir. Herhangi bir nöronunun toplam girdisi, diğer nöronlardan gelen değerlerin ağırlıklı toplamı ile eşik değerinin toplamına eşittir (Kamruzzman, 2006, 3).

$$NET = w_{ji} x_i + \theta_j \quad (2.1)$$

Biçiminde ifade edilen toplama fonksiyonunda:

NET : nöronunun net girdisini,

w_{ji} : j ve i nöronları arasındaki bağlantının ağırlığını,

x_i : i nöronunun çıktısını,

θ_j : eşik değeri ifade etmektedir.

Tablo 2.1’de literatürde yapılan araştırmalarda kullanılan değişik toplama fonksiyonları verilmektedir.

Tablo 2.1: Toplama Fonksiyonu Örnekleri

Toplam	$NET = \sum_i^n w_{ij} x_i + \theta_j$
Çarpım	$NET = \prod_i w_{ij} x_i$
Minimum	$NET = \text{Min} (w_{ij} x_i)$
Maksimum	$NET = \text{Max} (w_{ij} x_i)$
Çoğunluk	$NET = \sum_i^n \text{Sgn} (w_{ij} x_i)$

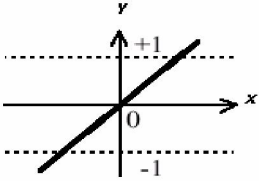
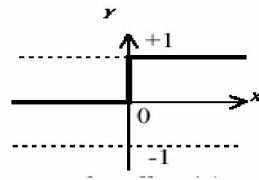
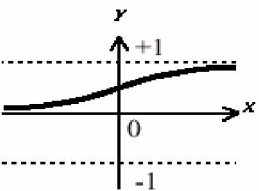
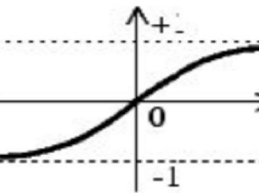
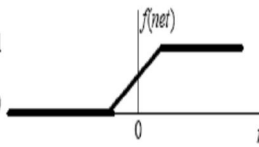
Kaynak: Ercan Öztemel (2006); “*Yapay Sinir Ağları*”, Papatya Yayıncılık, 2. Basım, İstanbul, s.50.

Genellikle deneme yanılma yolu ile en iyi toplama fonksiyonu belirlenmektedir. Bunun yanı sıra toplama fonksiyonunu belirleme tamamen tasarımcının kendi öngörüsüne bağlıdır.

2.4.4. Aktivasyon Fonksiyonu

Toplama fonksiyonu ile elde edilen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirleyen fonksiyondur. Aktivasyon fonksiyonunun kullanım amacı, zaman söz konusu olduğunda toplama işlevinin çıkışının değişmesine izin vermesidir. Hücrenin gerçekleştireceği işleve göre çeşitli tipte aktivasyon fonksiyonları kullanılabilir. Mesela çok katmanlı algılayıcı modellerinde aktivasyon fonksiyonunun türevi alınabilir bir fonksiyon olması gerekmektedir.

Tablo 2.2: Bazı Aktivasyon Fonksiyonları

Aktivasyon Fonksiyonu	Matematiksel Gösterimi	Matematiksel Gösterimi
Lineer Fonksiyon	$F(\text{NET}) = \text{NET}$	
Step Fonksiyonu	$F(\text{NET}) = \begin{cases} 1 & \text{eğer } \text{NET} \geq \theta \\ 0 & \text{eğer } \text{NET} < \theta \end{cases}$	
Sigmoid Fonksiyonu	$F(\text{NET}) = \frac{1}{1 + e^{-\text{NET}}}$	
Hiperbolik Tanjant Fonksiyonu	$F(\text{NET}) = \frac{e^{\text{NET}} + e^{-\text{NET}}}{e^{\text{NET}} - e^{-\text{NET}}}$	
Eşik Değer Fonksiyonu	$F(\text{NET}) = \begin{cases} 0 & \text{eğer } \text{NET} \leq 0 \\ \text{NET} & \text{eğer } 0 < \text{NET} < 1 \\ 1 & \text{eğer } \text{NET} \geq 1 \end{cases}$	

Kaynak: Howard Demuth and Mark Beale (2004); “*Neural Network Toolbox User’s Guide*”, The Math Works, Inc., Chapter 2, p.1-7; Kamruzzman Joarder, Rezaul K. Beggand and Ruhul A. Sarker (2006); “*Artificial Neural Networks in Finance and Manufacturing*”, İdea Group Publishing, p.4.

Aktivasyon fonksiyonunun seçimi, büyük ölçüde yapay sinir ağının verilerine ve ağın neyi öğrenmesinin istendiğine bağlıdır. Genelde seçilen aktivasyon fonksiyonu, doğrusal değil, doğrusal olmayan bir fonksiyondur. Çünkü doğrusal fonksiyonlarda çıktı, girdi ile orantılıdır. Bir problem için en uygun fonksiyon tasarımcının denemeleri sonucunda belirlenmektedir. Tablo 2.2’de literatürde kullanılan bazı

aktivasyon fonksiyonları verilmektedir. Günümüzde en yaygın olarak kullanılan Çok Katmalı Algılayıcı modelinde ise aktivasyon fonksiyonu olarak Sigmoid Fonksiyonu veya hiperbolik tanjant fonksiyonu tercih edilmektedir.

2.4.5. Hücrenin Çıktısı

Aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Üretilen çıktı dış dünyaya veya başka bir hücreye gönderilir. Hücre kendi çıktısını kendisine girdi olarak da gönderebilir. Aslında bir nöronun çıkan tek bir çıktı değeri vardır. Aynı değer birden fazla nörona girdi olarak gitmektedir.

2.5. Yapay Sinir Ağlarının Genel Yapısı

Milyonlarca biyolojik sinir hücresinin (nöronun) bağlantılar aracılığıyla birleşerek beyni oluşturdukları gibi, birçok yapay sinir hücresinin birleşmesinden de yapay sinir ağları oluşmaktadır. Başka bir deyişle, nöronların aynı doğrultu üzerinde bir araya gelmesiyle katmanlar ve bu birkaç katmanın birleşmesiyle de yapay sinir ağları oluşmaktadır. Bu yapıdaki bazı nöronlar girdileri almak için, bazıları ise çıktılarını iletmek için dış mekan ile bağlantı halindedir. Diğer tüm nöronlar ise gizli katmanlardır. Bu durumda, katmanların değişik biçimlerde birbirine bağlanması değişik ağ mimarilerinin doğmasına neden olmaktadır. Bazı araştırmacılar, yapay sinir ağlarının ilk yıllarında, nöronlar arasındaki bağlantıları rassal olarak oluşturmuşlar ve olumsuz sonuçlarla karşılaşmışlardır (Yurtoğlu, 2005, 20).

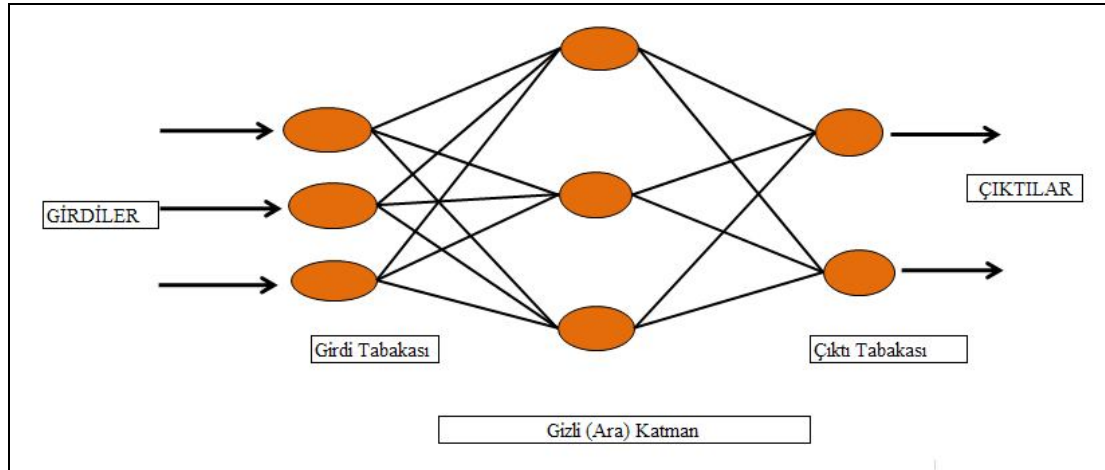
Bir yapıyı dizayn etmenin en kolay yolu elemanları katmanlandırmaktır. Burada katmanlandırmanın üç bölümü vardır. Bunlar, nöronları katmanlar halinde gruplandırmak, katmanlar arasındaki bağlantıları gruplandırmak ve son olarak ise toplama ve transfer fonksiyonlarını gruplandırmaktır. Bu durum Şekil 2.3'te ayrıntılı biçimde gösterilmektedir. Başka bir deyişle, sinir hücrelerinin bir araya gelmesi rastgele olamaz. Genel olarak girdi katmanı, gizli katman veya ara katmanı ve çıktı katmanı olmak üzere 3 katman halinde ve her katman içinde paralel biçimde bir araya gelerek ağı oluştururlar (Öztemel, 2006, 52). Bu katmanlar:

- **Girdi Katmanı:** Bu katmandaki nöronlar, dış dünyadan bilgileri alarak gizli katmanlara transfer ederler. Bazı ağlarda girdi katmanında herhangi bir bilgi işleme olmaz. Sadece girdi değerlerini bir sonraki

katmana iletirler. Bu nedenle bazı arařtırmacılar, bu katmanı ađların katman sayısına ilave etmezler.

- **Gizli (Ara) Katman:** Girdi katmanından gelen bilgiler işlenerek çıktı katmanına gönderilir. Bu bilgilerin işlenmesi gizli katmanlarda gerçekleştirilir. Bir ađ içinde girdi ve çıktı katmanı tek katmandan oluşurken, gizli katman birden fazla katmandan oluşabilir. Gizli tabakalar çok sayıda nöron içerirler ve bu nöronlar diđer nöronlarla tamamen bağlantılıdır. Ađın büyüklüğünün tanımlanması ve performansın bilinmesi açısından gizli katmanda bulunan nöronların sayısının seçimi oldukça önemlidir. Ayrıca gizli katmandaki nöronların ve katmanların sayısının artırılması veya azaltılması ađın basit veya karışık yapıda olmasını etkilemektedir.
- **Çıktı Katmanı:** Bu katmandaki nöronlar, gizli katmandan gelen bilgileri işleyerek ađın girdi katmanından sunulan girdi seti (örnek) için üretmesi gereken çıktıyı üretirler. Üretilen çıktı dış dünyaya gönderilir.

Şekil 2.3: Bir Yapay Sinir Ađının Genel Yapısı



Kaynak: Ercan Öztemel (2006); “Yapay Sinir Ađları”, Papatya Yayıncılık, 2. Basım, İstanbul, s.53.

Bu üç katmandan her birinde bulunan nöronlar ve katmanlar arası ilişkiler Şekil 2.3’te gösterilmiştir. Şekildeki yuvarlak şekiller nöronları göstermektedir. Her katmanda birbirine paralel elemanlar ve bu elemanları birbirine bağlayan çizgiler ise ađın bağlantılarını göstermektedir. Nöronlar ve bunların bağlantıları bir yapay sinir

ağını oluşturmaktadır. Bu bağlantıların ağırlık dereceleri ise öğrenme sırasında belirlenmektedir.

2.6. Yapay Sinir Ağlarının Sınıflandırılması

Genel olarak, YSA'ları üç ana kritere göre sınıflandırılmaktadır. Bu kriterlerden biri, yapay sinir ağlarının bağlantı yapısıdır ve buna ağın mimarisi de denilmektedir. Yapay sinir ağının bağlantı yapısı, sinirler arasındaki bağlantıların yönlerine göre veya ağ içindeki işaretlerin akış yönlerine göre birbirlerinden ayrılmaktadır. Bazı ağlar ileri besleme şeklinde yapılandırılırken, bazı ağlar ise geri beslemeli ağ yapısı içermektedirler.

İkinci sınıflandırma kriteri, öğrenme şekillerine göre olandır. Bu kritere göre üç temel öğrenme şekli vardır. Bunlar danışmanlı (öğretmenli) öğrenme, danışmansız (öğretmensiz) öğrenme ve destekleyici öğrenmedir.

Üçüncü sınıflandırma kriteri ise katman sayılarına göre yapılan sınıflandırmadır. Bu sınıflandırmaya göre ağlar, tek katmanlı ve çok katmanlı ağlar olarak ikiye ayrılmaktadırlar.

2.6.1. Yapay Sinir Ağlarının Bağlantı Yapılarına Göre Sınıflandırması

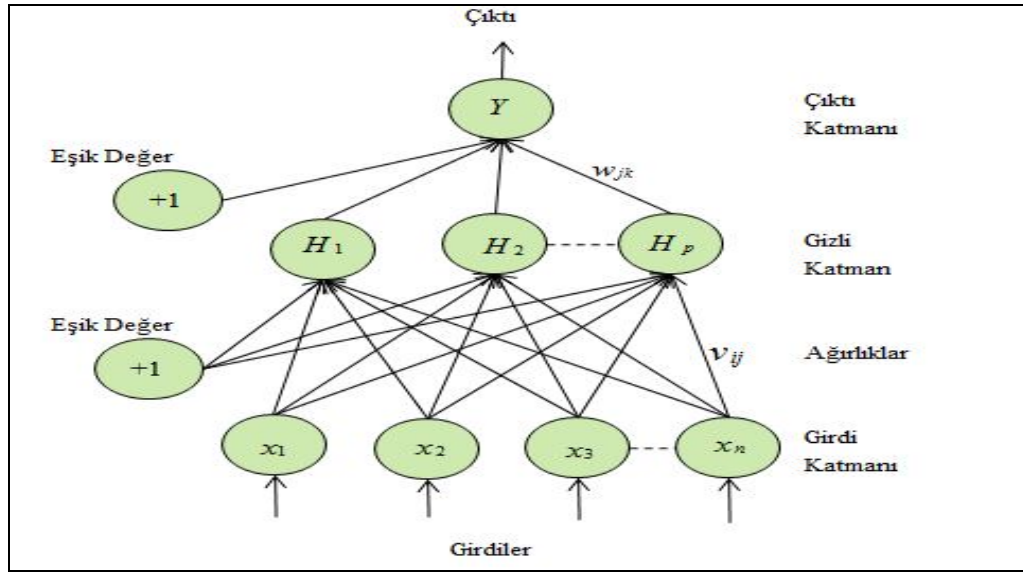
Yapay sinir ağlarında, bazı ağlar ileri besleme şeklinde yapılandırılırken, bazı ağlar ise geri besleme yapısı içermektedir. İleri beslemeli sinir ağlarında, nöronlar arasındaki bağlantılar bir döngü oluşturmazlar ve bu ağlar girdi veriye genellikle hızlı bir şekilde karşılık üretirler. Geri beslemeli ağlarda ise bağlantılar döngü içerirler ve her döngü seferinde yeni veri kullanabilmektedirler. Bu ağlar, döngü sebebiyle girdinin karşılığını yavaş bir şekilde oluştururlar. Bu yüzden, bu tür ağların eğitime süreci daha uzun olmaktadır. Ayrıca, hem ileri besleme hem de geri yayılma olarak tanımlanabilecek ağ yapıları da mevcuttur (Yurtoğlu, 2005, 28). Bu iki tür ağ aşağıda ayrıntılı biçimde incelenmektedir.

2.6.1.1. İleri Beslemeli Ağlar

İleri beslemeli (feedforward) ağda nöronlar, genellikle katmanlara ayrılmıştır. Her bir katmandaki nöronlar bir sonraki katmandaki nöronlar ile bağlantı ağırlıkları vasıtasıyla ilişkilidir. Ancak tabakaların kendi aralarında herhangi bir bağlantısı

yoktur. İleri beslemeli ağlarda bilgi akışı, girdi katmanından çıktı katmanına doğru geri besleme olmaksızın tek yönde yapılmaktadır (Zhang, 2003, 4-5). Buna aktivasyon yönü de denilir. Bu tür yapay sinir ağına örnek olarak tek ve çok katmanlı perceptron (algılayıcı) verilebilir. Bu tür ağlar, danışmanlı öğrenme tekniği kullanılarak eğitilirler.

Şekil 2.4: İleri Beslemeli Ağ Yapısı



Kaynak: Iebeling Kaastra ve Milton Boyd (1996); “*Designing a Neural Network for Forecasting Financial and Economic Time Series*”, Neurocomputing, Vol. 10, 215–236.p.218.

Şekil 2.4’te ileri beslemeli ağ yapısı verilmektedir. Bu tür ağ yapılarında geri besleme söz konusu değildir. $\{x_1, x_2, \dots, x_n\}$ girdi nöronlarını, $\{H_1, H_2, \dots, H_p\}$ gizli nöronları, Y çıktı nöronunu, v_{ij} , i girdi nöronundan j gizli nöronuna olan bağlantının ağırlığını ve w_{jk} , j gizli nöronundan k çıktı nöronuna olan bağlantının ağırlığını göstermektedir. +1 olarak gösterilen birimler ise eşik değerleridir.

Girdi katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan gizli katmandaki nöronlara iletir. Bu bilgi, girdi katmanı ve çıktı katmanında işlenerek ağ çıkışı belirlenir. Bu yapı ile ağlar, doğrusal olmayan statik bir işlevi gerçekleştirir. En çok bilinen geriye yayılım öğrenme algoritması, bu tip yapay sinir ağlarının eğitiminde etkin olarak kullanılmakta ve bazen bu ağlara geriye yayılım ağları da denilmektedir (Yurtoğlu, 2005, 29).

İleri beslemeli geri yayılım mimarisi 1970'li yıllarda geliştirilmiştir. Genel itibariyle bir geri yayılım ağında, bir girdi katmanı, bir çıktı katmanı ve en az bir gizli katman vardır. Gizli katmanların sayısı için herhangi bir kısıtlama yoktur, fakat genellikle bir ya da iki gizli katman kullanılmaktadır (Yurtoğlu, 2005, 29-30).

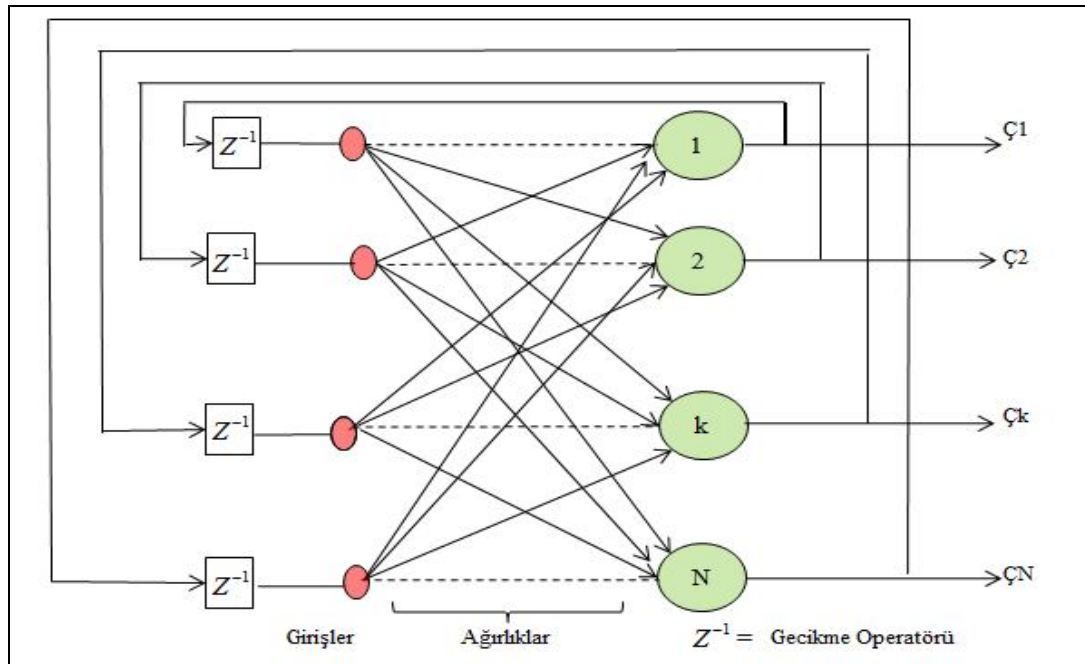
Geri yayılım ağlarında katman sayısı ve her katmanda bulunan nöron sayısının seçimi ağın performansını etkilemesi bakımından önemli kararlardır. Bu sayıların ne olacağı hakkında net bir seçim kriteri bulunmamaktadır. Ancak takip edilmesi gereken genel kurallar bulunmaktadır. Bu kurallar şu şekilde ifade edilebilir:

- Girdi verisi ile çıktı arasındaki ilişki daha da karmaşıklaştığında gizli katmanlardaki nöron sayısı da artmaktadır.
- Eğer ele alınan konu birçok aşamaya ayrılabilirse, katman sayısının artırılması gerebilir.
- Ağda kullanılan eğitim verisinin miktarı, gizli katmanlarda işleme sayısı için üst limit kriteri oluşturur.

2.6.1.2. Geri Beslemeli Ağlar

Geri beslemeli (recurrent) bir sinir ağı, çıktı katmanı ve gizli katmanlardaki çıkışların, giriş birimlerine veya önceki ara katmanların geri beslendiği bir ağ yapısıdır. Bu ağda nöronlar arasında dönüşler veya geri besleme bağlantıları bulunmaktadır ve bundan dolayı da dinamik hafızaya sahip oldukları söylenir. Geri beslemeli ağlarda herhangi bir hücrenin çıktısı direkt olarak girdi katmanına gönderilerek tekrar girdi olarak kullanılabilir (Zhang, 2004, 5). Geri besleme, bir tabakadaki hücreler arasında olduğu gibi, tabakalar arasındaki nöronlar arasında da olabilir. Geri beslemeli yapay sinir ağları, doğrusal olmayan dinamik bir davranış gösterir. Bu ağlara örnek olarak; Hopfield, Elman ve Jordan ağları verilebilir. Şekil 2.5'te, geri beslemeli bir YSA yapısı gösterilmektedir.

Şekil 2.5: Geri Beslemeli Ağ Yapısı



Kaynak: J.J. Hopfield (1984); “Neurons With Gradedresponse Have Collective Computational Properties Like Those of Two Stateneurons”, Proc.Natl.Acad.Sci., 81, p. 3089; Ercan Öztemel (2006); “Yapay Sinir Ağları”, Papatya Yayıncılık, 2. Basım, İstanbul, s.171.

Geri beslemeli YSA’lar, ileri beslemeli YSA’lara göre daha zengin dinamiklere sahip modeller geliştirilebilir. Ancak, akademik ve pratik alanda ileri beslemeli ağlar, geri beslemeli ağlara göre daha çok uygulanmaktadır. Bunun nedeni, geri beslemeli ağların pratikte uygulanabilirliğinin zor olmasıdır. Özellikle, geri beslemeli ağların birçok farklı yapıyla oluşturulabilmesi, belirli bir model yapısında uzmanlaşılmasını engelleyebilmekte ve eğitim algoritmalarının tutarsız olması nedeniyle eğitim aşamasının zor olmasına neden olabilmektedir (Zhang, 2003a, 5). Ayrıca geri beslemeli ağların eğitimi uzun zaman almaktadır. Özellikle, eğitim kümesindeki veri sayısı arttıkça eğitim süresinin daha da uzamaktadır. Bu nedenle, çok değişkenli ve uzun zaman serilerine ilişkin problemlerin çözümü için ileri beslemeli ağ yapısı tercih edilmektedir.

2.6.2. Yapay Sinir Ağlarının Öğrenme Şekillerine Göre Sınıflandırması

Yapay sinir ağlarının temel özelliği öğrenme yeteneğidir. Öğrenmenin temel felsefesi, bir olay hakkındaki gerçekleşmiş örnekleri kullanarak olayın girdi ve çıktıları arasındaki ilişkileri öğrenmek ve bu ilişkiye göre daha sonra oluşacak olan

yeni örneklerin çıktılarını belirlemektir. Burada bir olay ile ilgili örneklerin girdi ve çıktıları arasındaki ilişkinin olayın genelini temsil edecek bilgiler içerdiği kabul edilmektedir (Öztemel, 2006, 23-24).

Bir yapay sinir ağına ait nöronların bağlantılarının ağırlık değerlerinin belirlenmesi işlemine *ağın eğitilmesi* denir. Bu ağırlık değerleri başlangıçta rastgele verilerek öğrenme işlemi başlatılır. Belirlenen örnekler ağa tanıtıldıkça ağın ağırlık değerleri değişir ve bu sürece ağ, istenen çıktıları üretene kadar devam eder. Ağın eğitimi, ağ, istenen çıktıları üretip temsil ettiği olaylarla ilgili genellemeler yapacak duruma geldiğinde tamamlanmış olur. Buna da ağın öğrenmesi denilmektedir. Problemin çözümü sırasında en iyi ağırlık kümesini bulmayı sağlayan öğrenme şekilleri, danışmanlı (öğretmenli), danışmansız (öğretmensiz) ve destekleyici öğrenme olmak üzere üçe ayrılmaktadır (Öztemel, 2006, 25).

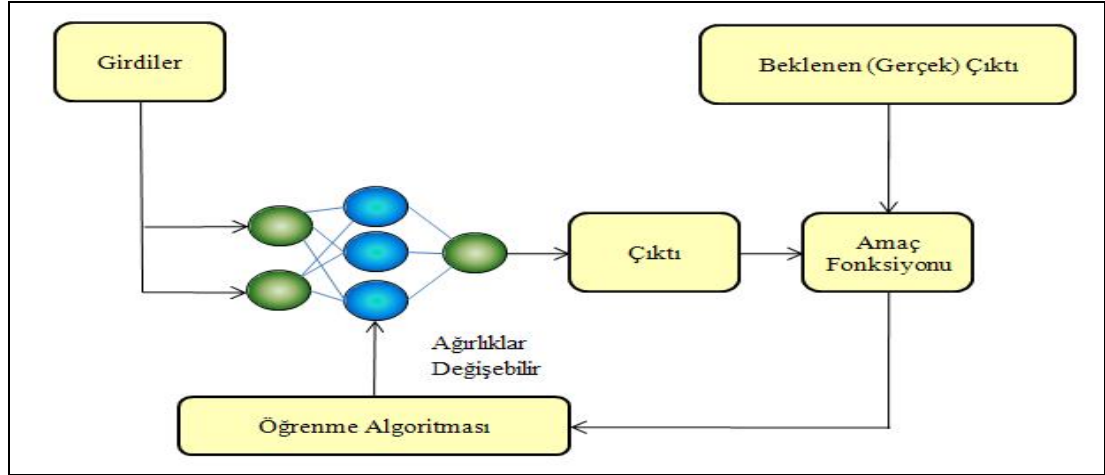
2.6.2.1. Danışmanlı Öğrenme

Danışmanlı öğrenme şeklinde, öğrenen sistemin olayı öğrenebilmesine bir öğretmen veya danışman yardımcı olmaktadır. Danışman sisteme öğrenilmesi istenen olay ile ilgili örnekleri Girdi/Çıktı seti olarak verir. Başka bir deyişle, her örnek için hem girdiler hem de o girdiler karşılığında oluşturulması gereken çıktılar sisteme gönderilir. Sistemin görevi, girdileri danışmanın belirlediği çıktılara uygun haritalama yapmaktır. Bu sayede olayın girdileri ile çıktıları arasındaki ilişkiler öğrenilmektedir.

Bu öğrenmede ağın ürettiği çıktılar ile hedef çıktılar arasındaki fark, hata olarak ele alınır ve bu hata minimize edilmeye çalışılır. Bu işlem, kabul edilebilir doğruluğa ulaşıncaya kadar devamlı olarak denenir. Bu denemelerde bağlantıların ağırlıkları en uygun çıkışı verecek şekilde değiştirilir. Eğer verilen girişe karşılık, amaçlanan çıkış üretilemiyorsa, ağın çıkış değerindeki hatayı minimum yapacak şekilde bağlantı ağırlıklarının değiştirilmesi gerekir. Bu sebeple danışmanlı öğrenme şeklinin bir danışmana ihtiyacı vardır. Danışman, kontrolün performansını değerlendirir ve performansı, dereceli olarak artıracak şekilde öğrenme işlemini yönlendirir. Danışmanlı öğrenme algoritmalarında, OMH (Ortalama Mutlak Hata) ve HKOK (Hata Kareleri Ortalamasının Karekökü) performans ölçütleri kullanılır

(Çanakçı, 2006, 27). Şekil 2.6’da danışmanlı öğrenme algoritmasının işleyişi gösterilmiştir.

Şekil 2.6: Danışmanlı Öğrenme Algoritması



Kaynak: Mehmet Fatih Bayramoğlu (2007); “*Finansal Endekslerin Öngörüsünde YSA Modellerinin Kullanılması: İMKB Ulusal 100 Endeksinin Gün İçi En Yüksek ve En Düşük Değerlerinin Öngörüsü Üzerine Bir Uygulama*”, T.C. Zonguldak Karaelmas Üniversitesi S.B.E. İşletme Anabilim Dalı Yayınlanmamış Yüksek Lisans Tezi, Zonguldak, s.58.

Danışmanlı öğrenme algoritmalarına örnek olarak; Wihrow-Hoff’un Delta Kuralı (Delta Rule) ve Rumelhart ve McClelland’ın Genelleştirilmiş Delta Kuralı (Generalized Delta Rule) veya geriye yayılım algoritması verilebilir.

2.6.2.2. Danışmansız Öğrenme

Danışmansız öğrenmede, sistemin öğrenmesine yardımcı olan herhangi bir öğretmen yoktur. Sisteme sadece girdi değerleri gösterilir. Örneklerdeki parametreler arasındaki ilişkileri sistemin kendi kendisine öğrenmesi beklenir. Bu, daha çok sınıflandırma problemleri için kullanılan bir algoritmadır. Yalnız sistemin öğrenmesi bittikten sonra çıktıların ne anlama geldiğini gösteren etiketlendirmenin kullanıcı tarafından yapılması gerekmektedir. Bu tür öğrenmeye örnek olarak, Hebb, Hopfield ve Kohonen öğrenme algoritmaları ve ART ağırları verilebilir.

2.6.2.3. Destekleyici Öğrenme

Bu tür öğrenmede, ağı bir öğretmen yardımcı olur. Fakat danışman her girdi seti için üretilmesi gereken çıktı setini sisteme göstermek yerine, sistemin kendisine gösterilen girdilere karşılık çıktısını üretmesini bekler ve üretilen çıktının doğru veya yanlış olduğunu gösteren bir sinyal üretir. Sistem, danışmandan gelen bu sinyali

dikkate alarak öğrenme sürecini devam ettirir. Bu öğrenme yönteminin kullanıldığı ağlara örnek olarak; Doğrusal Vektör Parçalama Modeli (Linear Vector Quantization, LVQ) verilebilir.

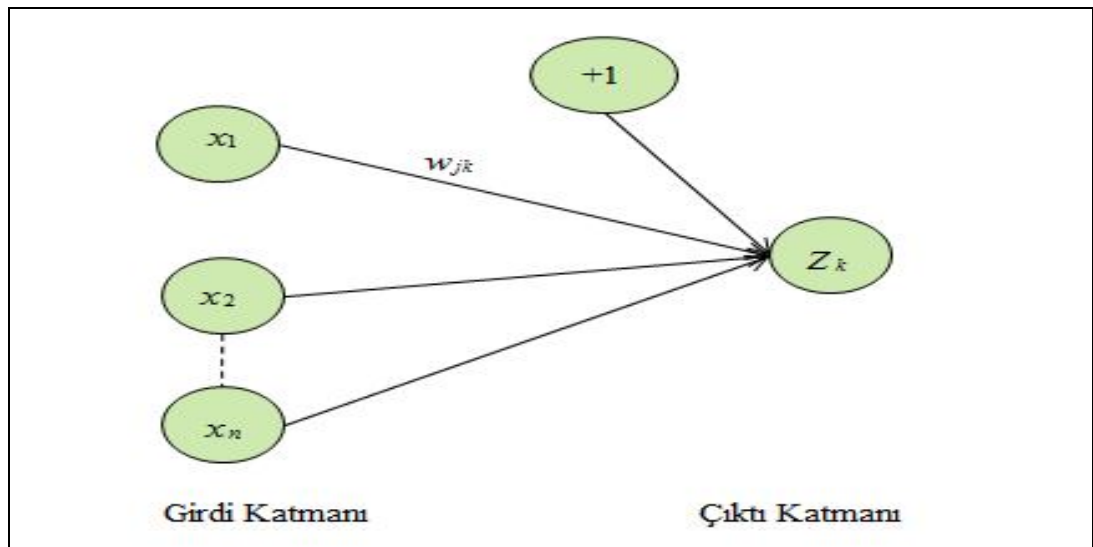
2.6.3. Yapay Sinir Ağlarının Katman Sayısına Göre Sınıflandırılması

Katman sayısına göre YSA'lar, tek katmanlı YSA'lar (single layer neural networks) ve çok katmanlı YSA'lar (multilayer neural networks) olmak üzere ikiye ayrılmaktadırlar.

2.6.3.1. Tek Katmanlı Ağlar

Tek katmanlı YSA'lar, sadece girdi ve çıktı katmanlarından oluşur. Her ağın bir veya daha fazla girdisi ve çıktısı vardır. Çıktı üniteleri bütün girdi ünitelerine bağlanmaktadır. Her bağlantının bir ağırlığı vardır. Bu ağlarda nöronların değerlerinin ve dolayısıyla ağın çıktısının sıfır olmasını önleyen bir de eşik değeri (θ) vardır. Eşik değerin girdisi daima +1'dir. Eğriselliği sağlayacak gizli tabakanın bulunmaması sebebiyle bu türden ağlar daha çok doğrusal problemler için kullanılır. Tek katmanlı ağlarda her ağın bir veya daha fazla girdisi ($x_i; i=1,2,\dots,n$) ve sadece bir çıktısı ($z_k; k=1$), her bağlantının bir ağırlığı ($w_{ik}; i=1,2,\dots,n; k=1$) ile gösterilmektedir. Şekil 2.7'deki YSA modeli tek katmanlı yapıya sahiptir.

Şekil 2.7: Tek Katmanlı Yapay Sinir Ağı



Kaynak: Sandy D. Balkin (1997); "Using Recurrent Neural Networks for Time Series Forecasting", Working Paper Series, No:97-11, International Symposium on Forecasting, p.10.

Ağın çıktısı ağırlıklandırılmış girdi değerlerinin eşik değeri (θ) ile toplanması sonucu bulunur. Bu girdi değeri, bir transfer fonksiyonundan geçirilerek ağın çıktısı hesaplanır. Bu işlem, şu şekilde formüle edilmektedir (Öztemel, 2006, 59-60):

$$\zeta = f\left(\sum_{i=1}^m w_i x_i + \theta\right) \quad (2.2)$$

Tek katmanlı algılayıcılarda çıktı fonksiyonu doğrusal fonksiyondur. Başka bir ifadeyle ağa gösterilen örnekler iki sınıf arasında paylaştırılarak iki sınıfı birbirinden ayıran doğru bulunmaya çalışılır. Bu nedenle eşik değer fonksiyonu kullanılmaktadır.

Tek katmanlı YSA'lerden en önemlileri Basit Algılayıcı Modeli (Perceptron), Adaptif Doğrusal Eleman Modeli (Adaptive Linear Element, ADALINE) ve Çoklu Adaptif Doğrusal Eleman Modeli (Multiple Adaptive Linear Element, MADALINE)'dir.

Basit Algılayıcı Modeli, ilk defa 1958 yılında Rosenblatt tarafından belirli bir üzen içinde birbirini takip eden işlemleri sınıflandırmak amacıyla geliştirilmiştir. Beyin işlevlerini modelleyebilmek amacıyla yapılan çalışmalar sonucunda ortaya çıkan tek katmanlı, eğitilebilen ve tek çıkışa sahip olan bir model olup bir sinir hücrelerinin birden fazla girdiyi alarak bir çıktı üretmesi prensibine dayanmaktadır. Ağın çıktısı bir veya sıfırdan oluşan mantıksal değerdir. Çıktının değerinin hesaplanmasında eşik değer fonksiyonu kullanılır (Öztemel, 2006, 61).

Eğitilebilme niteliğini taşıyan ilk yapay sinir ağıdır. Basit algılayıcı modelinde, girişler ile onlara karşılık gelen ağırlık değerlerinin çarpımlarının toplamından oluşan net değeri, eşik değerini aştığı zaman çıkış değeri türetilir. YSA'nın öğrenmesi ise bu ağırlıkların değiştirilmesi ile mümkündür. Basit algılayıcı modelin en önemli özelliği, problemin çözümünün varlığı durumunda ağa girilen girdi değişkenlerinden doğru ağırlıkları yakınsama özelliğine sahip olmasıdır (Bayramoğlu, 2007, 62). Basit algılayıcı model, daha sonraları geliştirilecek ve YSA modelleri için devrim niteliğinde olacak olan ÇKA'ların temelini oluşturmaktadır (Öztemel, 2006, 37).

2.6.3.2. Çok Katmanlı Yapay Sinir Ağları

Çok katmanlı YSA, birçok nöronun birbiriyle bağlanarak meydana getirdikleri birkaç katmandan oluşan tipik bir ağıdır. Çok katmanlı YSA'larda, girdi katmanı,


çıktı katmanı ve bu iki katman arasında da bir veya birden fazla gizli katman bulunmaktadır. Bu özellik çok katmanlı YSA'ları tek katmanlı YSA'larından ayıran temel özelliktir. Çok katmanlı YSA'ları karmaşık problemlerin çözümünde, özellikle de tahminlerde kullanılmaktadır. Çünkü bu ağ, yapısında bulunan gizli katmanda yapılan bir dizi işlem ile kendiliğinden doğrusal olmayan bir yapıya dönüşebilme yeteneğine sahiptir (Zhang ve Diğ., 1998, 37-38).

Tek katmanlı algılayıcıların doğrusal problemleri çözmekte yetersiz kalmaları YSA'larının çalışmadığı düşüncesine yol açmıştır. Ancak, XOR problemini çözmek için yapılan çalışmalar sonucu geliştirilen, çok katmanlı algılayıcılar YSA'larının tarihsel gelişimi bakımından önemli bir adım olmuştur. Yapılan araştırmalar, ÇKA'ların ve onun öğrenme kuralı olan geriye yayılım algoritmasının ortaya çıkmasıyla sonuçlanmıştır. Çok Katmanlı Algılayıcı Modeli'ne (ÇKA), "*Hata Yayma Modeli*" veya "*Geriye Yayım Modeli*" de denmektedir.

ÇKA'lar ve geriye yayılım algoritması ile doğrusal olmayan problemlerin çözümünde başarılı sonuçlar elde edilmesi, işletme bilimi dahil birçok alanda kullanımının artmasına yol açmıştır. ÇKA'lar, özellikle sınıflandırma, tanıma ve genelleme yapmayı gerektiren problemler için çok önemli bir çözüm aracıdır. Temel amacı, ağın beklenen çıktısı ile ürettiği çıktı arasındaki "hatayı" en aza indirmektir (Öztemel, 2006, 76). Doğrusal Vektör Parçalama Modeli (Linear Vector Quantization, LVQ) ve Çok Katmanlı Algılayıcı (Multilayer Perceptron) Modeli çok katmanlı YSA'larına örnek olarak verilebilir.

Şekil 2.8'de çok katmanlı yapay sinir ağı yapısı verilmektedir. YSA, bir ÇKA'nın yapısına sahiptir. ÇKA'ların ilk katmanı girdi katmanıdır. Son katmanı ise çıktı katmanıdır. Girdi katmanı ile çıktı katmanı arasında ise gizli nöronların yer aldığı en az bir tane gizli katman bulunmaktadır. Gizli katmandaki her nöron, doğrusal olmayan bir transfer fonksiyonuna sahiptir ve bu fonksiyonlar aracılığıyla elde edilen sonuçlar bir sonraki nöronlara girdi sağlamaktadır (Smith, 2002, 5). ÇKA'larda en çok kullanılan transfer fonksiyonları sigmoid fonksiyonu ve hiperbolik tanjant fonksiyonudur.

Şekil 2.8: Çok Katmanlı Yapay Sinir Ağı



Kaynak: G. Peter Zhang (2004); *"Business Forecasting with Artificial Neural Networks: An Overview, Neural Networks in Business Forecasting"*, Idea Group Inc, USA, p.4.

Şekilde, bir girdi katmanı, bir gizli katman ve bir çıktı katmanını içeren bir geri yayılma ağ yapısı örneklenmektedir. Katmanlar halinde düzenlenmiş daireler işlem elemanlarını veya nöronları temsil etmektedir. Giriş katmanında üç nöron bulunmaktadır ve ağa girdi olarak üç değişken tanıtılmaktadır. Bunun dışında gizli katmanda üç nöron, çıktı katmanında ise üç nöron bulunmaktadır. Dolayısıyla, ağdan üç değişken olarak çıktı alınmaktadır. Giriş katmanından, gizli katmana iletilen değerler ile gizli katmandan çıktı katmanına iletilen değerler ağırlık seti ile ağırlıklandırılmaktadır. Ağ yapısında, kalın oklar anımsama sırasındaki bilgi akışını simgelemektedir. Anımsama, eğitilmiş bir ağa yeni girdi verilerin sunulması ve çıktısının alınması işlemidir. Bu yüzden, anımsama işlemi sırasında geri yayılma işlemi kullanılmaz. Geri yayılma sadece eğitime sürecinde kullanılır, dolayısıyla eğitime sürecindeki bilgi akışı şekildeki tüm oklar ile gösterilmektedir (Yurtoğlu, 2005, 30).

ÇKA, danışmalı (öğretmenli) öğrenme stratejisine göre çalışırlar. Bu ağlara eğitim sırasında hem girdiler hem de o girdilere karşılık üretilmesi gereken çıktılar gösterilir. Öğrenme kuralı ise en küçük kareler yöntemine dayalı Delta Öğrenme Kuralı'nın genelleştirilmiş halidir (Öztemel, 2006, 77).

2.7. Öğrenme Algoritması

Bir ÇKA'nın, öngörü için kullanılabilmesi için öncelikle eğitilmesi gerekmektedir. ÇKA'larda eğitim aşamasında beklenen çıktının hesaplanmasına olanak sağlayan bağlantı ağırlıkları belirlenmektedir (Öztemel, 2006, 82). Doğrusal bir regresyonda, hesaplama işlemleri hata karelerinin toplamının bulunmasıyla kolaylıkla yapılabilmektedir. Ancak YSA'ların doğası gereği doğrusal olmayan optimizasyon içermeleri, eğitim sürecinin doğrusal regresyona göre daha zor ve karmaşık olmasına yol açmaktadır. Literatürde geliştirilmiş birçok eğitim algoritması bulunmakla birlikte bu algoritmalar içerisinde en çok kullanılanı Werbos (1974)'un ve Rumelhart (1986) ve arkadaşlarının geliştirmiş oldukları geriye yayılım algoritmasıdır (Zhang, 2004, 5).

Geri yayılım algoritması, yapay sinir ağları tarihindeki en önemli gelişmelerden birisi olmuştur. Bu algoritma, sürekli, türevi alınabilir aktivasyon fonksiyonuna sahip nöronlardan meydana gelen çok katmanlı algılayıcılarda uygulanabilmektedir. Geriye yayılım algoritması, dereceli azaltma veya eğim inişi (gradient descent) yaklaşımıyla ağırlıkları ayarlayarak toplam hatayı minimize etmektedir (Zhang, 2003a, 5). Geriye yayılım ağının öğrenme kuralı en küçük kareler yöntemine dayalı Delta öğrenme kuralının genelleştirilmiş halidir. Bu nedenle öğrenme kuralına "Genelleştirilmiş Delta Kuralı" da denilmektedir (Öztemel, 2006, 77).

Geri yayılım algoritması, verilen eğitim seti için en uygun çözümü üretecek ağırlıkları bulmayı sağlar. Geri yayılım algoritması iki aşamadan oluşur:

- İleri doğru hesaplama,
- Geriye doğru hesaplama.

İleri doğru hesaplama aşaması, ağın çıktısını hesaplama aşamasıdır. Geri doğru hesaplama aşamasında ise çıkışlarda oluşan hatalardan yola çıkılarak, modeldeki ağırlıkların yeniden düzenlenmesi aşamasıdır. Bu algoritma ağa sunulan eğitim seti için en uygun ağırlık değerlerini bulmayı sağlar. Eğim inişine dayanarak ağırlıklar düzenlenir.

Tek gizli katmanlı ve ileri beslemeli bir ÇKA'nın geri yayılım algoritmasının uygulama süreci aşağıdaki gibidir (Öztemel, 2006, 78-80; Smith, 2002, 6):

- 1. Adım:** Örnekler toplanır, ağın topolojik yapısı ve öğrenme parametreleri belirlendikten sonra ağırlıkların başlangıç değerleri rastgele olarak atanır.
- 2. Adım:** Eğitimin durması için gerekli koşul sağlanıncaya kadar 3. adım ile 9. adım arası tekrarlanır.
- 3. Adım:** Her eğitim kümesi verisi için 4. adım ile 8. adım arası uygulanır.

İleri Doğru Hesaplama

4. Adım: Ağın girdi katmanına, eğitim setinden seçilen bir örnekten girdilerin (G_1, G_2, \dots) gösterilmesiyle başlar. Girdiler herhangi bir işleme uğramadan ara katmana iletilir. Yani girdi katmanındaki k. nöronun çıktısı C_k^i ;

$$C_k^i = G_k \text{ biçiminde olur.} \quad (2.3)$$

5. Adım: Gizli katmandaki nöronlara gelen her bir girdi ağırlıklarla $\{w_1, w_2, \dots, w_n\}$ çarpılarak net girdi aşağıdaki biçimde hesaplanır.

$$NET_j^a = \sum_{k=1}^n w_{kj} C_k^i \quad (2.4)$$

w_{kj} : k. girdi katmanı elemanını j. gizli katman elemanına bağlayan ağırlık değerini gösterir.

Aktivasyon fonksiyonu olarak sigmoid fonksiyonu, burada önemli olan türevi alınabilir bir fonksiyon kullanmaktır, kullanıldığı zaman çıktı aşağıda verildiği gibidir. Bu eşitlikteki β_j gizli katmanda bulunan j. elemana ait eşik değerinin ağırlığıdır.

$$C_j^a = \frac{1}{1 + e^{-(NET_j^a + \beta_j)}} \quad (2.5)$$

Bütün nöronlarda bu hesaplamalar yapıp en son olarak çıktı katmanına ait çıktı değerleri bulununca ileri doğru hesaplama aşaması sona erer. Gizli katmandaki aktivasyon fonksiyonu ile çıktı katmanındaki aktivasyon fonksiyonu aynı olmak

zorunda değildir. Bunlardan birisi sigmoid fonksiyon olurken diğeri tanjant fonksiyonu veya başka bir fonksiyon olabilir (Öztemel, 2006, 50).

Geriye Doğru Hesaplama

6. Adım: Ağa sunulan girdi için ağın ürettiği çıktı ile beklenen çıktılar (B_1, B_2, \dots) karşılaştırılarak aradaki fark, başka bir deyişle hata değeri, ağın ağırlık değerlerine dağıtılarak bir sonraki iterasyonda hatanın azaltılmasına çalışılır. Çıktı katmanındaki m. nöron için hata (e_m);

$$e_m = B_m - C_m \quad (2.6)$$

Bu değer bir işlem elemanı (nöron) için elde edilen hatadır. Çıktı katmanı için oluşan toplam hatayı (TH) bulmak için bütün hataların toplanması gerekir. ÇKA ağının eğitilmesindeki temel amaç bu hatayı minimize etmektir. TH şu şekilde formüle edilir:

$$TH = \frac{1}{2} \sum_m e_m^2 \quad (2.7)$$

Toplam hatayı minimize etmek için hata nöronlara dağıtılır. Bu işlem nöron ağırlıkları değiştirilerek olur. Bu ise gizli katman ile çıktı katmanı arasındaki ve gizli katmanlar arası veya gizli katman girdi katmanı arasındaki ağırlıkların değiştirilmesiyle sağlanır.

7. Adım: Ara katmanın j.nöronunu çıktı katmanındaki m. nörona bağlayan bağlantı ağırlıklarındaki değişim miktarına Δw^a dersek t. iterasyonda ağırlığın değişim miktarı aşağıdaki gibi hesaplanır:

$$\Delta w_{jm}^a(t) = \lambda \delta_m C_j^a + \alpha \Delta w_{jm}^a(t-1) \quad (2.8)$$

Bu eşitlikteki λ öğrenme katsayısı, α da momentum katsayısıdır. Öğrenme katsayısı ağın performansında etkilidir. Eğitime süresini, küçük öğrenme katsayısı uzatırken, büyük öğrenme katsayısı kısaltır. Ancak çok büyük öğrenme katsayısı yakınsamayı engeller. Momentum katsayısı ise ağın öğrenim esnasında yerel bir minimum noktaya takılıp kalmamasında etkilidir. Ağırlık değişim değerinin belli bir oranda bir sonraki değişime eklenmesini sağlar ve toplam hata sıfıra daha fazla bir eğilimle yaklaşır. Eşitlikteki δ_m ise m. çıktı ünitesinin hatasıdır.

$$\delta_m = f'(NET) \cdot e_m \quad (2.9)$$

Burada, $f'(NET)$ aktivasyon fonksiyonun türevidir. Sigmoid aktivasyon fonksiyonu kullanıldığı zaman bu eşitlik;

$$\delta_m = \zeta_m (1 - \zeta_m) \cdot e_m \quad (2.10)$$

biçimindedir.

8. Adım: Değişim miktarı hesaplandıktan sonra ağırlıkların t . iterasyondaki yeni değerleri şöyle olacaktır:

$$w_{jm}^a(t) = w_{jm}^a(t-1) + \Delta w_{jm}^a(t) \quad (2.11)$$

eşitliği ile hesaplanır. Ayrıca eşik değerinin ağırlıkları da değiştirilir. Çıktı katmanındaki nöronların eşik değer ağırlıkları θ^c ile gösterilirse eşik değer çıktısı sabit ve 1 olduğu için değişim miktarı;

$$\Delta \theta_m^c(t) = \lambda \delta_m + \alpha \Delta \theta_m^c(t-1) \quad (2.12)$$

biçimindedir. Eşik değerinin t . iterasyondaki yeni ağırlık değeri ise aşağıdaki biçimde olur.

$$\theta_m^c(t) = \theta_m^c(t-1) + \Delta \theta_m^c(t) \quad (2.13)$$

İkinci durumda ise girdi katmanı ile ara katman veya iki ara katman arasındaki ağırlıklar değiştirilirken çıktı katmanındaki tüm elemanlara ait hataların hesaba katılması gerekir. Bu ağırlık değişimi örneğin girdi katmanı ile ara katman arasındaki Δw^i ile gösterilirse değişim miktarı;

$$\Delta w_{kj}^i(t) = \lambda \delta_j^a \zeta_k^i + \alpha \Delta w_{kj}^i(t-1) \quad (2.14)$$

δ^a faktörü ise;

$$\delta_j^a = f'(NET) \sum_m \delta_m w_{jm}^a \quad (2.15)$$

şeklindedir ve sigmoid fonksiyonu kullanıldığında;

$$\delta_j^a = \zeta_j^a (1 - \zeta_j^a) \sum_m \delta_m w_{jm}^a \quad (2.16)$$

eşittir. Ağırlıkların yeni değerleri ise;

$$w_{kj}^i(t) = w_{kj}^i(t-1) + \Delta w_{kj}^i(t) \quad (2.17)$$

Ara katman esik değer ağırlıkları θ^a ile gösterilirse değişim miktarı;

$$\Delta \theta_j^a(t) = \lambda \delta_j^a + \alpha \Delta \theta_j^a(t-1) \quad (2.18)$$

Ağırlıkların yeni değerleri ise t. iterasyon için,

$$\theta_j^a(t) = \theta_j^a(t-1) + \Delta \theta_j^a(t) \quad (2.19)$$

eşitliği ile sağlanır. Böylece ileri ve geri hesaplama aşamaları bir iterasyon için yapılmış olur. Ağırlıkların hepsi yeniden düzenlenerek sonlandırma kriteri sağlanıncaya kadar ağırlıkları düzenleme işlemine devam edilir.

9. Adım: Eğer hata, önceden belirlenen hata toleransına ulaşmışsa veya sonlandırma kriteri sağlanmışsa eğitim durdurulur. Aksi halde 4. Adımdan başlayarak işlem tekrarlanır.

Yukarıda ifade edilen basamaklar çok katmanlı algılayıcıların öğrenmesi tamamlanıncaya kadar, yani gerçekleşen çıktılar ile beklenen çıktılar arasındaki hataların kabul edilebilir bir düzeye inmesine kadar devam eder. Ağın öğrenmesi için bir durdurma kriterinin olması gerekmektedir. Bu durum ise genellikle hatanın belirli bir düzeyin altına düşmesi olarak alınır.

Cerny (2001)'e göre, ileri beslemeli bir ağı, geri yayılım algoritmasıyla eğitme süreci basitleştirilmiş olarak aşağıdaki gibidir (Cerny, 2001, 4):

- Girdi verileri ağa sunularak çıkış katmanına ulaşana kadar ağ boyunca yayılır. İleriye doğru gerçekleşen bu süreç hesaplanan çıktıyı üretir.
- Hesaplanan çıktı, hedef çıktıyla karşılaştırılarak ağ için bir hata değeri hesaplanır.
- Ağı eğitmek için, denetimli öğrenme algoritmalarından geri yayılım algoritması kullanılır. Bu algoritma, çıkış katmanı nöronları ile en son gizli katman nöronları arasındaki ağırlıklardan başlamak üzere ağ boyunca geriye doğru yayılır.

- Geri yayılım bittiğinde, ileri doğru süreç tekrar başlar ve bu döngü hesaplanan çıktı ile hedef çıktı arasındaki hata minimize edilene kadar devam eder.

Öğrenme algoritması olarak geri yayılım algoritması seçildiğinde iki parametre önem kazanmaktadır. Bunlardan ilki öğrenme oranı (λ), diğeri ise momentum katsayısı (α)'dır. Bu iki parametre aşağıda kısaca tanımlanacaktır.

Öğrenme Oranı (λ): Öğrenme oranı, ağıın performansı üzerinde önemli bir etkiye sahiptir ve bağlantıların ağırlık değerlerindeki değişim miktarını belirlemektedir. Bu katsayısı genellikle 0 ile 1 arasında bir değer almaktadır. Öğrenme oranının küçük değerler aldığı durumda eğitime işlemi uzun zaman alırken, bu değerlerin büyümesi ile eğitime işlemi daha kısa zamanda gerçekleşmektedir. Öğrenme oranının çok küçük değerleri öğrenme sürecinin kabul edilemeyecek şekilde yavaşlamasına sebep olurken, öğrenme oranının çok büyük değerleri de kararsızlığa sebep olmaktadır. Öğrenme oranının 1'den büyük olduğu bir durumda ise ağı, yerel minimumların arasında salınır ve bir yakınsama olayı meydana gelmez. Ayrıca, bu oranın çok düşük olması minimumu bulma imkanı vermeyebilir. (Zhang, 1998, 48; Öztemel, 2006, 99).

Momentum Katsayısı (α): Ağıın öğrenme performansını etkileyen bu katsayı, bir önceki iterasyondaki değişimin belirli bir oranının yeni değişim miktarına eklenmesi biçiminde tanımlanmaktadır (Öztemel, 2006, 99). Bu katsayı özellikle yerel çözümlere takılan ağların bir sıçrama ile daha iyi sonuçlar bulmasını sağlamak amacıyla önerilmiştir ve ağıın daha hızlı toparlanmasına yardım eden bir faktördür. 0 ile 1 arasında değerler alan momentum katsayısının hesaba katılması, adım sayısında ve toplam ağı hatasında bir düşüş meydana getirmektedir (Zhang, 1998, 48). Momentum katsayısı, büyük öğrenme oranıyla eğitim sürecinin hızlanmasını sağlarken, salınma eğilimini de en aza indirmeye yardımcı olmaktadır (Rumelhart, 1986, 284).

Optimal öğrenme oranı ve momentum katsayısının belirlenmesi, büyük ölçüde deneysel ve sezgisel bir özellik taşımaktadır. Ayrıca bu parametreler büyük ölçüde ilgilenilen sorun alanına bağlı olarak değişiklik gösterir.

2.8. Öğrenme Kuralları

Yapay sinir ağları literatüründe, öğrenme sistemlerinde kullanılan çok sayıda öğrenme kuralı vardır. Bu öğrenme kurallarının büyük çoğunluğu en eski ve en çok bilinen Hebb Öğrenme Kuralı'na dayanmaktadır. Kullanılmakta olan bazı önemli öğrenme kuralları aşağıda verilmiştir.

Hebb Kuralı: 1949 yılında Kanadalı psikolog Donald Hebb tarafından biyolojik temele dayalı olarak geliştirilen en eski ve en ünlü öğrenme kuralıdır. Bu kurala göre, bir nöron başka bir nörondan girdi alırsa ve iki nöron da yüksek derecede aktifse (yani matematiksel olarak aynı işarete sahipse) nöronlar arasındaki bağlantının ağırlığı artırılmalıdır. Diğer bir ifadeyle bir hücrenin kendisi aktifse bağlı olduğu hücreyi aktif yapmaya, pasif ise pasif yapmaya çalışmaktadır (Hebb, 1949, 60-78).

Hopfield Kuralı: Hebb kuralına benzerlik gösteren bu kural ile yapay sinir ağı elemanlarının bağlantılarının ne kadar kuvvetlendirilmesi veya zayıflatılması gerektiği belirlenmektedir. Temel farklılık ise bağlantı ağırlığında yapılacak değişikliğin büyüklüğünü de belirlemesidir. Buna göre, girdi ve istenilen çıktının ikisi de aktifse veya ikisi de aktif değilse, bağlantı ağırlığı öğrenme katsayısı kadar artırılır, aksi durumda ise öğrenme katsayısı kadar azaltılır (Hopfield, 1982, 2556). Ağırlıkların kuvvetlendirilmesi veya zayıflatılması öğrenme oranı yardımı ile gerçekleştirilmektedir. Öğrenme katsayısı genel olarak 0-1 arasında değer alan, kullanıcı tarafından atanan, sabit ve pozitif bir değerdir (Öztemel, 2006, 26).

Delta Kuralı: En çok kullanılan öğrenme kurallarından birisi de Delta Kuralıdır. Bu kural Hebb kuralının geliştirilmiş bir şeklidir. Widrow ve Hoff (1960) tarafından geliştirilmiştir. Arzu edilen çıktı ile işlem biriminin gerçek çıktısı arasındaki farkın (delta) azaltılması amacı ile giriş bağlantılarının değiştirilmesi temeline dayanır. Bu nedenle de bu algoritma en küçük kareler kuralı olarak da bilinmektedir. Hata aynı anda bir katmandan bir önceki katmanlara geri yayılarak azaltılır. Ağın, hatalarının düşürülmesi işlemi çıkış katmanından giriş katmanına ulaşıncaya kadar devam eder (Anderson, McNeill, 1992, 30).

Eğimli İniş (Gradient Descend) Kuralı: Bu kural Delta kuralına benzerlik gösterir. Ağırlıkların düzenlenmesi işlemi, bir işlem birimi için arzu edilen çıktı ile gerçek çıktı arasındaki hatanın birinci türevine (gradient) orantılı bir şekilde gerçekleştirilebilir. Amaç, hata fonksiyonunu azaltarak yerel minimumdan kurtulmak ve genel minimumu yakalamaktır (Yurtoğlu, 2005, 100).

Kohonen Öğrenme Kuralı: Bu kural, Teuvo Kohonen (1982) tarafından biyolojik sistemlerdeki öğrenmeden esinlenerek geliştirilmiştir. Nöronların, ağırlıklarını ayarlamak (öğrenmek) için rekabet ettikleri düşünülmektedir. Bu kurala göre ağırlık elemanları, ağırlıklarını değiştirmek için birbirleriyle yarışır. En büyük çıktıyı üreten hücre, kazanan çıktı olmakta ve bağlantı ağırlıkları değiştirilmektedir. Bu, o hücrenin yanındaki hücrelere göre daha kuvvetli hale gelmesi demektir. Hücre, yanındakileri uyarma ve yasaklama kapasitesine sahiptir. Kohonen kuralı hedef çıkışa gereksinim duymaz. Bu nedenle de danışmansız bir öğrenme metodudur. Kendi kendine öğrenme (self-organizing) olarak da bilinen bu kural özellikle dağılımlara yönelik çalışmalarda kullanılmaktadır. Ancak teorik alt yapısının tam gelişmemiş olmasından dolayı uygulamada henüz yaygınlık kazanmamıştır (Kohonen, 2001, 71-72; Anderson, McNeill, 1992, 30).

2.9. Yapay Sinir Ağlarının Uygulama Alanları

Gerçek hayatta karşılaşılan problemlerde oldukça geniş bir uygulama alanı kazanan YSA'ları, son yıllarda özellikle çözümü zor ve karmaşık olan çok farklı alanlardaki problemlerin çözümünde kullanılmış ve genelde çok başarılı sonuçlara ulaşılmıştır. Günümüzde birçok endüstride kullanılmaktadır. Uygulama alanı için bir sınır yoktur. Fakat öngörü, modelleme ve sınıflandırma gibi bazı alanlarda ağırlıklı olarak kullanılmaktadır. 1950'li yıllarda ortaya çıkan YSA'ları ancak 1980'li yıllarda genel amaçlı kullanım için yeterli seviyeye gelmiştir. Verideki trend veya yapıyı en iyi tanımlayan yöntem olması dolayısıyla tahmin ve öngörü işlemleri için çok uygundur. YSA'larının gerçek hayattaki yaygın kullanım alanlarına şu örnekler verilebilir (Yurtoğlu, 2005, 9; Öztemel, 2006, 203).

- Endüstriyel uygulamalar (kalite kontrol, denetim, sistem modelleme vb.),

- Finansal uygulamalar (ekonomik ve finansal öngörü, kredi derecelendirme, makro ekonomik tahminler, risk analizleri, vb.),
- Askeri ve savunma uygulamaları (hedef tanıma ve takip sistemleri, vb.),
- Sağlık uygulamaları (tıbbi resim işleme, üroloji uygulamaları, vb.),
- Diğer alanlardaki uygulamalar (petrol ve gaz araması, el yazısı tanıma, vb.).

YSA'ları yoğun bağlantılı ve komplike işlem yapıları nedeniyle çalışabilecekleri özel ortamlara ihtiyaç duymaktadırlar. Bu yüzden, YSA'lar, bu amaca yönelik olarak hazırlanmış özel yazılımlar ile bilgisayarlarda çalıştırılmaktadırlar. Günümüzde ise gittikçe artan oranda yoğun ve karmaşık sinir ağlarını çalıştırabilmek ve daha hızlı işlem yapabilmek için özel donanımlar geliştirilmektedir (Yurtoğlu, 2005, 10).

2.10. Yapay Sinir Ağlarının Özellikleri

Yapay sinir ağları, öğrenme, ilişkilendirme, sınıflandırma, genelleme, tahmin, özellik belirleme ve optimizasyon işlemlerini gerçekleştirerek, bir müdahale yapılmaksızın elinde bulunan bilgilere göre sonuç üretebilirler. YSA'ları öğrenme işlemi sırasında verilen bilgiler ile kendini düzenleyerek daha sonraki girdiler için doğru kararlar verebilme yeteneğine sahiptir. Günümüzde birçok alanda kullanılan YSA'ları aşağıdaki genel özellikleri nedeniyle günümüzde birçok alanda etkin bir şekilde kullanılmaktadır (Öztemel, 2006, 31).

Yapay sinir ağları makine öğrenmesi gerçekleştirirler: Ağların temel işlevi bilgisayarların öğrenmesini sağlamaktır. Olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışır.

Programları çalışma stili bilinen programlama yöntemlerine benzemektedir: Geleneksel programlama ve yapay zeka yöntemlerinin uygulandığı bilgi işleme yöntemlerinden farklı bilgi işleme yöntemi vardır.

Bilginin saklanması: Yapay sinir ağlarında bilgi, ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır.

Doğrusal olmama: YSA'larının temel işlem elemanı olan nöron doğrusal değildir. Dolayısıyla nöronların birleşmesinden meydana gelen YSA da doğrusal değildir. Bununla birlikte kullanılan aktivasyon fonksiyonunun doğrusal bir fonksiyon olmaması da YSA'yı doğrusal olmayan bir yapıya dönüştürmektedir. Bu nedenle YSA, gerçek hayatta doğrusal olmayan problemlerin çözümünde kullanılabilir.

Öğrenme: YSA'ları gerçekleştirmiş olaylar olan örnekleri kullanarak öğrenirler ve problemleri çözerler. Olayları öğrenebilmesi için o olay ile ilgili örneklerin belirlenmesi gerekir. Örnekleri kullanarak olay hakkında genellemeler yapabilecek yeteneğe kavuşur. YSA'nın arzu edilen davranışı gösterebilmesi için amaca uygun olarak programlanması gerekir. Başka bir ifadeyle, nöronlar arasında doğru bağlantılar yapılmalı ve bağlantılar uygun ağırlıklara sahip olmalıdır. YSA'nın karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlı olarak verilemez ya da tasarlanamaz. Bu nedenle YSA, istenen davranışı gösterecek şekilde ilgilendiği problemten aldığı eğitim örneklerini kullanarak problemi öğrenmelidir.

YSA'larının güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekmektedir: Ağın eğitilmesi demek, mevcut örneklerin tek tek ağa gösterilmesi ve ağın kendi mekanizmalarını çalıştırarak örnekteki olaylar arasındaki ilişkileri belirlemesi demektir. Örnekler eğitim ve test seti olmak üzere iki sete bölünürler. Her ağ önce eğitim seti ile eğitilir ve ağ bütün örneklere doğru cevaplar vermeye başlayınca da eğitim işi tamamlanmış olur.

Görülmemiş örnekler hakkında bilgi üretebilme: Ağ kendisine gösterilen örneklerden *genellemeler* yaparak görmediği örnekler hakkında bilgiler üretebilir.

Algılamaya yönelik olaylarda kullanılabilme: Ağlar daha çok algılamaya yönelik bilgileri işlemede kullanılırlar.

Örüntü ilişkilendirme ve sınıflandırma: Ağların çoğunun amacı, kendisine örnekler halinde verilen örüntülerin kendisi veya diğerleri ile ilişkilendirilmesidir. Diğer amaç ise sınıflandırmadır.

Kendi kendine organize etme ve öğrenebilme yeteneği: Ağın, örnekler ile kendisine gösterilen yeni durumlara adapte olması ve sürekli yeni olayları öğrenebilmesi mümkündür.

Eksik bilgi ile çalışabilme: Ağlar kendileri eğitildikten sonra eksik bilgiler ile çalışabilir ve gelen yeni örneklerde eksik bilgi olmasına rağmen sonuç üretebilirler. Bu durum performanslarını düşürmez. Hangi bilginin önemli olduğunu ağın kendisi eğitim sırasında öğrenebilmektedir.

Hata toleransına sahip olma: Ağların eksik bilgilerle çalışabilme yetenekleri hatalara karşı toleranslı olmalarını sağlamaktadır. YSA, çok sayıda nöronun çeşitli şekillerde bağlanmasından oluştuğundan paralel dağılmış bir yapıya sahiptir ve ağın sahip olduğu bilgi, ağdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir YSA'nın bazı bağlantılarının hatta bazı nöronların etkisiz hale gelmesi, ağın doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, diğer yöntemlere göre hatayı giderme yetenekleri yüksektir.

Belirsiz tam olmayan bilgileri işleyebilme: Olayları öğrendikten sonra belirsizlikler altında ağlar öğrendikleri olaylar ile ilgili ilişkileri kurarak karar verebilirler.

Dereceli bozulma: Ağların hatalara karşı toleranslı olmaları bozulmalarının da dereceli olmasına yol açar. Bir ağ zaman içinde yavaş yavaş ve nazik bir şekilde bozular. Bu, eksik bilgidен veya nöronların bozulmasından kaynaklanır. Ağlar bir problem ortaya çıkar çıkmaz bozulma göstermezler dereceli olarak bozulurlar.

Dağıtılmış bellek: YSA'larda, bilgi ağa yayılmış durumdadır. Nöronların birbirleriyle bağlantılarının değerleri ağın bilgisini gösterir. Tek bir bağlantının anlamı yoktur. Ağın tamamı öğrendiği olayın bütünü karakterize etmektedir. Bu nedenle bilgiler ağa dağıtılmış durumdadır. Bu da dağınık bir belleğin doğmasına neden olmaktadır.

Sadece nümerik bilgiler ile çalışabilme: Sembolik ifadelerle gösterilen bilgilerin, yorumlanabilmesi ve çözümlerin üretilmesi için nümerik gösterime çevrilmesi gerekmektedir.

Donanım ve Hız: Yapay sinir ağları, paralel yapısı nedeniyle büyük ölçekli entegre devre (VLSI) teknolojisi ile gerçekleştirilebilir. Bu özellik, yapay sinir ağının hızlı bilgi işleme yeteneğini artırır ve gerçek zamanlı uygulamalarda arzu edilir (Çanakçı, 2006, 32).

2.11. Yapay Sinir Ağlarının Tasarımı

Çalışmanın bu bölümünde yapay sinir ağlarının tasarımının nasıl yapılacağı, ağ mimarisinin oluşturulması sırasında hangi kriterlerin göz önüne alınacağı hakkında bilgiler verilecektir. Yapay sinir ağlarında bulunan katman sayıları, bu katmanların kaç tane nörondan oluşacağı, nöronların birbirine göre konumunun nasıl olması gerektiği ve nöronlar arası sinyallerin akış yönleri, yapay sinir ağları yapısını belirlemektedir.

YSA yapıları arasında performans ve karakteristik özellikleri bakımından farklılıklar vardır. YSA'larının yapıları, özellikle ağın modelleme yeteneğini belirledikleri için oldukça önemlidirler. Yapay sinir ağının tasarımı aşamasında bu ağ yapıları arasından uygulamaya en elverişli olanı seçilir. Optimal ağ mimarisinin belirlenmesinde, önerilen bazı teknikler olmasına rağmen, bu metotlar oldukça karmaşıktır ve bu metotların uygulanması oldukça zordur. Ayrıca, bu metotlardan hiçbirisi gerçek tahmin problemleri için optimal çözümü garanti etmemektedir. Kısacası, bu parametrelerin belirlenmesinde kesin ve açık şekilde uygulanan metotlar yoktur. Bu nedenle bir yapay sinir ağı tasarımı bir bilimden ziyade, bir sanattır (Zhang, 1998, 42).

2.11.1. Yapay Sinir Ağlarının Eğitimi ve Testi

YSA'larında nöronların bağlantılarının ağırlık değerlerinin belirlenmesi işlemine “ağın eğitilmesi” denir. Başlangıçta bu değerler rastgele atanır. Ağlar kendilerine örnekler gösterildikçe bu ağırlık değerlerini değiştirirler. (Öztemel, 2006, 55).


YSA tahmincisinin kurulumu aşmasında örnek veri seti, ağın eğitim ve test işlemleri için iki veri setine ayrılır. Verileri ayırma işleminde genel bir kural yoktur. Ancak veri tipi, veri miktarı ve problemin karakteristiği veri setini ayırma işleminde önemli etkenlerdir. Eğitim ve test veri setinin seçimindeki yanlışlıklar ağın

performansını etkileyecektir (Zhang, 1998, 50). Seçilen veri kümeleri örnek uzayını tanımlayabilecek düzeyde olmalıdır. Literatürde eğitim ve test setlerinin belirlenmesine yönelik az da olsa bir öneri bulunmaktadır. Birçok araştırmacı veri sayısının %90'ını eğitim veri seti olarak kullanırken, geriye kalan %10'luk kısmı ise test veri seti olarak kullanmaktadır. Aynı şekilde %80, %20 ya da %70, %30 oranları da verileri dönemlere ayırmak için literatürde sıklıkla kullanılan oranlardır (Zhang, 1998, 50). Bu kurala göre ayrılan verilerden eğitim örnekleri yapay sinir ağı modelini geliştirmek için kullanılırken, test örnekleri ise geliştirilen modelin tahmin yeteneğinin değerlendirilmesinde kullanılır.

Öğrenme sürecinde, başlangıçta ağırlıklar rastgele atanır ve seçilen öğrenme yaklaşımına göre örnekler ağı gösterildikçe ağırlık değerleri değişir. Burada amaç, ağı gösterilen örnekler için doğru çıktıları üretecek ağırlık değerlerini bulmaktır. Doğru ağırlık değerlerine ulaşan ağ, örneklerin temsil ettiği olay hakkında genellemeler yapabilir duruma gelmiştir ve ağ öğrenmesini tamamlamıştır.

Çalışmamızda da dikkate alınacak model olan ÇKA'ların eğitilmesi felsefesi diğer yapay sinir ağlarından farklı değildir. Bu nedenle burada ÇKA'ların eğitimi ve eğitiminde karşılaşılan sorundan bahsedilecektir. Ağın eğitim sürecinde önemli olan nokta, problem uzayında en az hatayı verecek ağırlık değerlerinin bulunmasıdır. Hatanın en aza indirilmesini açıklayabilmek için basit bir problem düşünülürse, ağın öğrenmesi istenen olayın (problem uzayının) Şekil 2.9'da gösterildiği gibi bir hata uzayının olduğu varsayalım. Şekildeki W^* en az hatanın olduğu ağırlık vektörünü göstermektedir. ÇKA'ların W^* değerine ulaşması istenmektedir. Bu ağırlık değeri problem için hatanın en az olduğu noktadır. Bu nedenle her iterasyonda ΔW kadar değişim yaparak hata düzeyinde ΔE kadar bir hatanın düşmesi sağlanmaktadır.

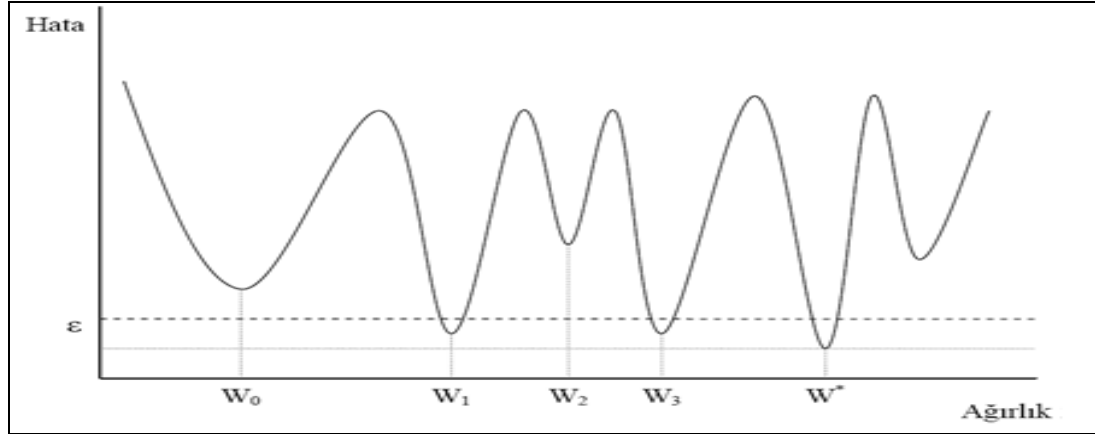
Şekil 2.9: Öğrenmenin Hata Uzayındaki Gösterimi



Kaynak: Ercan Öztemel (2006); “*Yapay Sinir Ağları*”, Papatya Yayıncılık, 2. Basım, İstanbul, s.82.

Problemin hata düzeyinin her zaman Şekil 2.9’da görüldüğü gibi basit ve iki boyutlu olmayacağına dikkat çekmek gerekir. Gerçek hayattaki karmaşık problemlerin hata düzeyinde birçok minimum ve maksimum noktaları bulunmaktadır. Minimum noktaları sadece bir seviyede W^* minimum ağırlık vektörünü veya *global minimum noktasını* (Franses ve Dijk, 2003, 221) verecektir. Şekil 2.9’dan görüleceği üzere en az hata düzeyini veren ağırlık vektörü W^* olmasına rağmen bu noktayı yakalamak her zaman mümkün olmayabilir. Bu çözüm, ağırlık vektörü sahip olabileceği *en iyi çözümdür*. Ağ eğitimi sırasında bu çözüme ulaşmaya çalışır. Ancak ÇKA’ların eğitimi sürecinin en iyi çözüm noktası olan global minimumda durdurulması yerine, daha yüksek bir hata oranını verecek ağırlık değerlerine sahip minimum noktasında (W_1, W_3) durdurulması olasılığı da vardır (Zurada, 1992, 206-207). Bu durumda ÇKA’nın eğitimi sırasında *yerel minimum tuzağına* düştüğü söylenir (Kamruzzman ve Diğ., 2006, 131). Yerel minimum noktası, global minimum seviyesinden oldukça yüksek bir seviyede olabileceği gibi bu seviyeye yakın bir seviyede de olabilmektedir (Öztemel, 2006, 83).

Şekil 2.10: Çok Boyutlu Hata Uzayı



Kaynak: Jacek M. Zurada (1992), "Introduction to Artificial Neural Systems", West Publishing Company, St. Paul, USA, p.207.

Şekil 2.10'da görüldüğü gibi, problemin çözümü için en az hatayı veren ağırlık vektörü W^* olmasına rağmen pratikte bu hata değerini yakalamak çoğu zaman mümkün olmamaktadır. ÇKA, eğitim sırasında W^* çözümünü yakalamaya çalışmaktadır. Bazen farklı bir çözüme (yerel minimuma) takılabilmekte ve performansı daha iyi bir duruma getirmek mümkün olamamaktadır. Bu nedenle kullanıcılar, ağların performanslarında bir tolerans değeri (ϵ) belirleyerek, belirli bir seviyeye kadar hata payı kabul etmektedirler. Tolerans değeri altındaki her hangi bir noktada problem öğrenilmiş kabul edilmektedir. Şekil 2.10'daki W_0 ve W_2 çözümlerinin hataları kabul edilebilir hata seviyesinin üzerinde olduğundan bu çözümler kabul edilemez çözümlerdir. Bunlara yerel çözümler denilmektedir. W_1 , W_3 çözümleri en iyi çözümler olmamalarına rağmen kabul edilebilir hata düzeyinin altında bir hataya sahiptirler. Bunlar da yerel çözümler olmalarına rağmen kabul edilebilir çözümlerdir. Görüldüğü gibi bir problem için birden fazla çözüm üretilebilmektedir. Bu nedenle ÇKA'ların her zaman en iyi çözümü ürettikleri söylenemez. Kabul edilebilir bir çözüm ürettiklerini söylemek daha doğrudur. Üretilen çözüm en iyi çözüm olsa bile bunun bilinmesi zordur. Hatta çoğu durumda bilinmesi mümkün değildir (Öztemel, 2006, 82-83).

Şekil 2.10, aynı zamanda neden en iyi sonuç bulunamadığının aşağıda belirtilen başka muhtemel nedenlerini de göstermektedir (Öztemel, 2006, 83):

- Problem eğitilirken ağa sunulan eğitim seti, problem uzayını %100 oranında temsil etmeyebilir.
- Oluşturulan ÇKA için doğru parametreler seçilmemiş olabilir.
- Ağın ağırlıkları başlangıçta tam istenildiği şekilde belirlenmemiş olabilir.
- Ağın topolojisi yetersiz seçilmiş olabilir.

Bu ve benzeri nedenlerden dolayı ÇKA, eğitim sırasında, hatayı belirli bir değerin altına düşüremeyebilir. Mesela, W_1 ağırlıklarını bulur ve hatayı daha aşağıya düşüremez. Ancak W_1 aslında en iyi çözüm değil, yerel bir çözümdür. W_1 vektörü için hata kabul edilebilir düzeye indiğinden yerel en iyi çözüm olarak görülebilir. Global çözümün bulunmaması da mümkün olabilir. Bu tamamen ağın tasarımına, örneklerin niteliğine ve eğitim sürecine bağlıdır.

ÇKA'ların eğitiminde karşılaşılan başka bir sorun da, ağın öğrenmek yerine ezberlemesidir. Bu durumda, eğitilen ÇKA eğitim setindeki tüm örneklerde doğru cevap üretmesine rağmen test setindeki örneklere doğru cevaplar üretememektedir. Başka bir deyişle, ağ örnek girdiyi ezberleyerek global minimumu yakalamış izlenimi verir. Ağ aslında öğrenmemiş, sadece sunulan örnek girdi setini ezberlemiştir. Böyle bir ağ, test sürecinde eğitimin performansına oldukça uzak sonuçlar üretecektir. Bu tip bir sorunla karşılaşan kullanıcı, bu durumun sebebini araştırmalıdır (Kaastra ve Boyd, 1996, 229-231).

Ağın eğitimi tamamlandıktan sonra öğrenip öğrenmediğini (performansını) ölçmek için yapılan denemelere *ağın test edilmesi* denmektedir. Test etmek için, ağın öğrenme sırasında görmediği örnekler yani test seti kullanılır. Test etme sırasında ağın ağırlık değerleri değiştirilmez. Test setindeki girdiler, yapay sinir ağı modeline verilir ve yapay sinir ağının çıktı değeri ile istenilen çıktı değeri karşılaştırılır. Yapılan bu işlemde amaç, YSA modelinin yeterli bir genelleme yapıp yapamadığını görmektir. Eğitim ve test aşamalarında istenilen başarı elde edilirse YSA modeli kullanılabilir.

2.11.2. Ağ Yapısının Seçimi

Bir YSA modeli oluşturulurken, ağın yapısının ve yapı özelliklerinin belirlenmesi, nörondaki fonksiyonların özelliklerinin belirlenmesi ve öğrenme algoritmasının seçilerek parametrelerinin belirlenmesi aşamaları dikkatle ve uygulanacak problemin özelliğine bağlı olarak yapılmalıdır. Çünkü bu aşamalar elde edecek sonuçların başarısı için çok önemlidir. Ağda kullanılacak öğrenme algoritması seçildiğinde bu algoritmanın gerektirdiği yapı da kendiliğinden seçilmiş olacaktır.

Kullanım amacına göre başarılı olan ağ türleri aşağıdaki biçimde gösterilebilir.

Tablo 2.3: Ağ Türleri ve Başarılı Oldukları Alanlar

Kullanım Amacı	Ağ Türü	Ağın Kullanımı
Tahmin	• Çok Katmanlı Algılayıcılar (ÇKA)	Ağın girdilerinden bir çıktı değerinin tahmin edilmesi.
Sınıflandırma	• Vektör Kuantizasyon Modelleri (LVQ) • Adaptif Rezonans Teorisi Modelleri (ART) • Olasılıklı Sinir Ağları (PNN) • Counterpropagation	Girdilerin hangi sınıfa ait olduklarının belirlenmesi
Veri Şekillendirme	• Hopfield Ağları • Boltzman Makinesi • Bidirectional Associative Memory (BAM)	Girdilerin içindeki hatalı bilgilerin bulunması ve eksik bilgilerin tamamlanması

Kaynak: Ercan Öztemel (2006); “Yapay Sinir Ağları”, Papatya Yayıncılık, 2. Basım, İstanbul, s.207.

2.11.3. Girdi Nöronu ve Çıktı Nöron Sayısının Belirlenmesi

Yapay sinir ağlarında, sebep-sonuç ilişkisine dayalı olarak yapılan tahmin problemlerinde, girdi nöron sayısını belirlemek kolaydır. Bu tür çalışmalarda girdi nöronu sayısı, girdi vektöründeki değişken sayısına bağlı olarak belirlenir. Bu durumda girdi nöronu sayısı, değişken sayısına eşittir. Zaman serisi tahmin problemlerinde ise girdi nöron sayısı, gecikme sayısı ile ilişkilidir. Ancak bu durumun neye göre belirleneceği konusunda kesin bir yol bulunmamaktadır.

Çıktı nöron sayısını belirlemek, diğer tabakalardaki nöron sayılarını belirlemeye göre daha kolaydır. Bir zaman serisinin geleceği tahmin problemlerinde çıktı nöronu sayısı tahmin döneminin uzunluğuna eşittir. Tek dönemlik tahminde çıktı nöron sayısı bire eşitken, çok dönemlik tahmin söz konusu olduğunda ise tahmin iki yolla yapılabilir. Tek dönemlik tahmin iteratif tahmindir. Tahmin edilen dönem değeri, bir sonraki dönem için girdi olarak kullanılır. Bu durumda tek çıktı

nöronu yeterlidir. Çok dönemlik tahminde ise birden fazla dönemin aynı anda tahmin edildiği doğrudan yöntem olarak adlandırılan durumdur. Bu durumda çıktı nöron sayısı, tahmin edilmek istenen dönem sayısına eşittir (Zhang, 1998, 44-46).

2.11.4. Gizli Katman ve Gizli Nöron Sayısının Belirlenmesi

Gizli katman ve bu katmandaki gizli nöronlar, yapay sinir ağlarının başarısında büyük bir önem taşımaktadır (Zhang, 1998, 42). Gizli katman sayısı probleme, veri miktarına ve tasarıma bağlı olarak değişmektedir. Genellikle bir ya da iki gizli katman (ara katman) yeterlidir. Daha fazla gizli katman kullanmak ağın hızını ciddi oranda düşürmektedir. Ayrıca ağı öğrenmek yerine ezberlemesine de sebep olabilmektedir. Tercihen üç katmanlı, giriş-gizli-çıkış katmanlarından oluşan, bir yapı kullanılabilir. Sonuç tatmin edici değilse sonradan 2 ya da 3 ara katman denenebilir. Bazı çalışmalar, birçok tahmin problemini çözmede 2'den fazla gizli katmanlı yapılara ihtiyaç olmadığını göstermiştir (Zhang, 1998, 44). Ayrıca, uygulamalar göstermiştir ki, toplamda 4 katmandan fazlası ağı başarı performansını ters yönde etkilemektedir (Kaastra ve Boyd, 1996, 225). Gizli katman sayısının artması, ağıdaki tüm işlem elemanları arasındaki bağlantı sayısını artıracığından ağı hesaplama süresinin artmasına ve zayıf öngörü sonuçlarının elde edilmesine yol açan ezberleme riskini artırır. Bu nedenle gizli katman sayısının belirlenmesinde veri adedi de göz önüne alınarak, deneme yanılma yöntemiyle en uygun gizli katman sayısı bulunmalıdır.

Benzer şekilde gizli nöron sayısı için de sihirli bir formül yoktur. Bu konuda da görev tasarımcının yeteneğine düşmektedir. Genellikle az sayıda gizli nöron ile çalışma tercih edilir. Çünkü genelleştirme yetenekleri daha yüksektir. 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 nöron sayısı $\sqrt{n \times m}$ kadar olabilir. Gizli katmandaki nöron 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 (Kaastra, 1996, 225). Gizli katmandaki nöron sayısının belirlenmesi konusunda kesin kural olmamakla beraber, kesin sayı ağı yapısına,

verinin miktarına, problemin türüne, tasarımcının tecrübesine kalmıştır. Deneme yanılma yoluyla belirlenmektedir.

2.11.5. Veri Normalleştirme

Yapay sinir ağlarında doğrusal olmama özelliğini sağlayan en önemli etken verilerin normalize edilmesidir. Veriler normalize edilerek aşırı uç değerlerden kurtarılabilen ve böylece eldeki veriler daha iyi biçimde modellenmektedir. Ayrıca, verilerin normalleştirilmesinde seçilecek yöntem, ağın performansını da etkilemektedir. Veri normalleştirme, işlem süreci sırasında kullanılan verilerin kümülatif toplamların oluşturacağı olumsuzlukların engellenmesini sağlamaktadır. Veri normalleştirme aralığını belirleyen gizli ve çıktı katmanda kullanılan aktivasyon fonksiyonları bir nöronun çıktısını $[0,1]$ veya $[-1,1]$ aralığına sıkıştırma rolünü üstlenmektedirler. Veri normalleştirme işlemi, eğitim süreci başlamadan yapılır. Veri normalleştirme yaklaşımlarında sıklıkla kullanılan formüller aşağıdaki gibidir (Zhang, 1998, 49):

1. $[0, +1]$ aralığında doğrusal dönüşüm:

$$x_n = (x_0 - x_{\min}) / (x_{\max} - x_{\min}) \quad (2.20)$$

2. $[a,b]$ aralığında doğrusal dönüştürme:

$$x_n = (b-a)(x_0 - x_{\min}) / (x_{\max} - x_{\min}) + a \quad (2.21)$$

3. İstatiksel normalizasyon:

$$x_n = (x_0 - \bar{x}) / s \quad (2.22)$$

4. Basit normalizasyon:

$$x_n = x_0 / x_{\max} \quad (2.23)$$

Formüllerdeki x_n ve x_0 normalleştirilmiş ve orijinal veriyi, x_{\min} , x_{\max} , \bar{x} , s satır veya sütun boyunca sırasıyla minimum, maksimum, ortalama ve standart sapma değerlerini ifade etmektedir.

Veri normalleştirilmesinin yapay sinir ağlarının öğrenmesinde ne kadar önemli olduğu konusunda araştırmalar yapılmış ve normalleştirilmesinin faydalı olduğu, ancak örnek büyüklüğü arttığında bu faydanın azaldığı sonucuna ulaşmışlardır.

Genellikle girdilerin normalleştirilmesi ve hedeflenen çıktı değerlerinin normalleştirilmesinden bağımsızdır. Zaman serileri ile öngörü problemlerinde, girdilerin ve hedeflenen çıktılarının normalleştirilmesi ise birlikte yapılır. Normalleştirme aralığının seçimi, çıktı katmanındaki nöronların transfer fonksiyonuna bağlıdır. Eğer çıktı katmanında Sigmoid fonksiyonu kullanılmış ise normalleştirme aralığı $[0,1]$, hiperbolik tanjant fonksiyonu kullanılmış ise normalleştirme aralığı $[-1,1]$ olarak seçilir. Ancak çıktı katmanındaki nöronların transfer fonksiyonu olarak doğrusal bir fonksiyon olan özdeşlik fonksiyonu kullanılmış ise bu durumda normalleştirme aralığının seçimi gizli katmandaki işlem elemanlarının transfer fonksiyonuna göre yapılır. Hedeflenen çıktı değerleri, normalleştirilmesinin bir sonucu olarak, gözlemlenen ağ çıktılarının normalleştirme aralığı ile uyumlu olmalıdır. Ağdan alınan sonuçların yorumlanması, çıktıların orijinal aralığa dönüştürülmesinden sonra olabilir. Ağın ürettiği değerlerin doğruluğu orijinal veri seti temel alınarak hesaplanmalıdır. Performans ölçütü de, çıktıların orijinal aralığa dönüştürülmesinden sonra hesaplanmalıdır (Zhang, 1998, 50; Bayramoğlu, 2007, 97).

2.11.6. Yapay Sinir Ağı Performansının Belirlenmesi

Bir yapay sinir ağı tahmincisi için, modelleme zamanı veya eğitim zamanı gibi birçok performans ölçütü olmasına rağmen, en iyi ve en önemli performans ölçütü tahminin doğruluğudur. Doğruluk ölçütü, gerçek değer ile tahmin edilen değerler arasındaki fark olarak tanımlanır. Bu fark, tahmin hatası olarak adlandırılır (Zhang, 1998, 51).

Bir modelin performansının belirlenmesi demek, öngörü modellemesinin doğruluğunu ölçmek demektir. İyi öngörüler iyi kararlar alınmasına yol açmaktadır. Bir yapay sinir ağının performansı denilince de öğrenme yeteneğinin ölçülmesi anlaşılır. Başka bir deyişle, YSA modelinin verileri iyi öğrenip öğrenmediği

ölçülmektedir. En çok kullanılan öngörü doğruluk ölçütleri aşağıdaki gibidir (Gujarati, 2004, 77; Zhang, 1998, 51):

- Ortalama Mutlak Hata (MAE, MAD) $= \sum |e_t| / N$, (2.24)

- Hata Kareleri Toplamı (SSE) $= \sum (e_t)^2$, (2.25)

- Ortalama Hata Kareler (MSE) $= \sum (e_t)^2 / N$, (2.26)

- Karekök Ortalama Hata Kareler (RMSE) $= \sqrt{MSE}$, (2.27)

- Ortalama Mutlak Yüzde Hata (MAPE) $= (1/N) \sum |e_t / y_t| (100)$, (2.28)

Burada;

e_t kestirim hatasını,

y_t t dönemi gözlem değerini,

N ise hata terimleri sayısını ifade etmektedir.

Bu öngörü doğruluk ölçütleri içinde en yaygın şekilde kullanılanı MSE'dir. Bu ölçütün önemli bir özelliği, öngörü hatasının varyans toplamalarına ayrıştırılabilmesidir. Bu özellik, MSE ölçütünün sadece gerçekleşme ve öngörülere ait birleşik dağılımın ikinci momentine bağlı olduğunu göstermektedir. Dolayısıyla, yararlı bilgiler sağlayan bir ölçüdür. Bununla beraber, gerçek dağılımla ilgili tam bilgi sağlayamadığı da belirtilmelidir (Zhang, 1998, 52).

2.11.7. Durdurma Kriterinin Belirlenmesi

Durdurma kriteri, hatanın belirli bir değer altına düşmesi veya araştırmacıya göre belirlenen kabul edilebilir bir hatanın altına düşmesi durumunda ve ağı belirlenen iterasyon sayısını tamamlaması durumunda ağı eğitiminin durdurulması biçiminde olmak üzere iki şekilde belirlenebilir.

2.11.8. Öğrenme Algoritmasının Seçimi

Yapay sinir ağı uygulama başarısını belirleyen en önemli faktörler ağı yapısının seçimi ve öğrenme algoritmasının seçimidir. Ağ yapısı ise öğrenme algoritmasının seçiminde belirleyici rol oynar. Yapay sinir ağının geliştirilmesinde kullanılacak çok sayıda öğrenme algoritması bulunmaktadır. Bunlar içinde bazı

algoritmaların bazı uygulamalar için daha uygun olduğu bilinmektedir. En çok kullanılan algoritma ise geri yayılım algoritmasıdır (Zhang, 1998, 47-48).

2.12. Yapay Sinir Ağları Uygulamalarının Avantajları

YSA'ların avantajları, doğrusal olmayan yapılarından ve kendine özgü eğitim sürecinden kaynaklanmaktadır. Genel olarak; YSA'ların diğer modellere göre güçlü yanları; doğrusal olmayan yapıyı modelleyebilme yeteneği, genelleştirme yapabilme yeteneği, uyarlanabilirlik ve esneklik, bilginin saklanması, hata toleransına sahip olması ve istatistikî veya başka modelleme tekniklerindeki ön şart ve kabullerin bulunmayışıdır (Zhang, 2003b, 160).

Gerçek hayattaki olaylar ve bu olayların arkasındaki faktörlerin birbirleriyle ilişkileri doğrusal olmaz ve bu ilişkileri modellemek de oldukça zordur. Ancak, yapay sinir ağları, matematiksel olarak modellenmesi zor ve karmaşık olan modelleri daha rahat modelleyerek çözebilmektedir (Öztemel, 2006, 207). YSA'ları, kullandıkları transfer fonksiyonu sayesinde doğrusal olmayan yapıdaki problemlere model üretebilmekte ve etkin öngörü modellemesi yapabilmektedir. Bu nedenle, YSA'ları geleneksel öngörü yöntemlerine göre etkin bir öngörü aracı olarak tercih edilmektedir (Gonzalez, 2000, 27).

YSA'ları öğrenme yeteneği sayesinde bilinen örnekleri kullanarak daha önce karşılaşmadığı durumlar hakkında genelleme yapabilmektedir. Öğrenme aşamasında veriler kullanılarak girdi ile çıktı arasındaki hata minimum yapılmakta ve girdi-çıkta değişkenleri arasında en az hatayı veren YSA modeli kurulabilmektedir (Zhang ve Diğ., 1998, 36).

Uyarlanabilirlik ve esneklik özelliği sayesinde YSA'ları yeni bilgilerin ortaya çıkması ve ortamda değişiklik olması durumunda bağlantı ağırlıklarını değiştirerek ağı yeniden eğitebilirler. Bu da YSA'larını geleneksel istatistik yöntemlerinden ayıran en temel özelliklerdendir (Zhang ve Diğ., 1998, 36).

YSA'larda bilgi, ağı bağlantılarının değeri ile ölçülmekte ve bağlantılarda saklanmaktadır. Diğer programlarda olduğu gibi veriler bir veri tabanında veya programın içinde gömülü değildir. Bu sayede YSA'lar diğer modellere kıyasla bilgiyi saklayabilme gücüne de sahiptirler (Öztemel, 2003, 31).

Birbirine yoğun biçimde bağlanmış nöronlardan oluşan YSA'larının eksik bilgiyle çalışabilmeleri hatalara karşı toleranslı olmalarını sağlamaktadır.

Box-Jenkins, ARIMA, hareketli ortalama ve doğrusal model gibi geleneksel ekonometrik modelleme teknikleri ile modelleme yapılırken getirilmesi gereken sınırlandırmalar vardır. Ayrıca durağanlaştırma yapılması gerektiğinden bilgi kaybı olmaktadır. Ancak, YSA modellemesinde ise bu sınırlamalar yoktur (Abraham ve Diğ., 2004, 1-17).

Yapay sinir ağlarını kullanarak problemi başarılı bir biçimde çözebilmek için problemin iyi modellenmesi gerekmektedir. Yapay sinir ağları, modelleme için örneklerin dışında herhangi bir ön bilgiye ihtiyaç duymaz. Yapay sinir ağları uygulamaları hem pratiktir hem de maliyeti bakımından daha ucuzdur. Sadece örneklerin belirlenmesi ve basit bir program problemi çözmek için yeterli olabilmektedir. Yapay sinir ağlarının paralel çalışabilmeleri onların gerçek zamanlı kullanımlarını kolaylaştırmaktadır.

2.13. Yapay Sinir Ağları Uygulamalarının Dezavantajları

Yapay sinir ağlarının kullanımı ile sağlanan avantajları dışında, göz önünde bulundurulması gereken bazı dezavantajları da bulunmaktadır (Öztemel, 2006, 34).

Yapay sinir ağlarının donanım bağımlı çalışmaları önemli bir sorundur. Günümüzdeki makinelerin çoğu seri işlemcilerle sahiptir. Ağların varoluş nedeni paralel işlemcilerle çalışabilmektir. YSA'lar özellikle paralel işlem yapmalarından dolayı çok hızlı çalışan paralel işlemcilerle ihtiyaç duyarlar. Paralel işlemleri seri makinelerde yapmak ise zaman kaybına yol açar. Her problem için farklı bir yapay sinir ağı yapısı geliştirilmelidir. Bu da deneme yanılma yoluyla olmaktadır. YSA'lar aynı zamanda bulunan çözümün en iyi çözüm olduğunu da garanti etmez.

YSA'larının oluşturulmasında, model seçiminde ve ağın topolojisinin belirlenmesinde, katman sayısının belirlenmesinde, öğrenme oranı ve her katmanda yer alması gereken nöron sayısı gibi parametrelerin belirlenmesinde belli kurallar seti bulunmamaktadır. Tamamen araştırmacının tecrübesine dayalı olarak belirlenmektedir. Bu da önemli bir dezavantajdır. Ağın eğitiminin ne zaman sona ereceğine ilişkin herhangi bir yöntem de bulunmamaktadır. Ağın örnekler üzerinde

bulunan hatasının belirli bir deęerin altına indirilmesi, eęitimin tamamlanması için yeterli görölmektedir. Yine de optimum eęitmenin saęlandığı söylenememektedir. Bu durumda eęitimin geręekleşmesi uzun zaman alabilmektedir.

Bir yapay sinir aęı, herhangi bir girdi vektörünü çıktı vektörüne nasıl dönüştürdüęü konusunda bir bilgi vermez. Mühendislik açısından bakıldığında YSA'lar "kara kutu" gibi görülebilirler. Kara kutu, dışarıdan bilgileri alıp, dışarıya ürettięi çıktıları vermektedir. İçeride neler olduęu ise bilinmemektedir (Franses ve Dijk, 2003, 206). Başka bir deyişle, girdi ile çıktı arasındaki baęlantının genel kuralı veya koşulu aę tarafından bilinmemektedir ve aęın bunu açıklama yeteneęi yoktur (Chen ve Dię., 2005, 404). Bu durum, elde edilen aęa karşı güveni azaltırken başarılı uygulamalar YSA'lara olan ilgiyi artırmaktadır. Örneklerin bulunmasının güç olduęu ya da problemi doęru temsil edebilen örneklerin bulunamadığı durumlarda, problemlere saęlıklı çözümler üretebilmek mümkün olamamaktadır.

Bütün bu dezavantajlarına raęmen YSA ile birçok problem için çözüm üretilebilmekte ve başarılı uygulamalar oluşturmak mümkün olabilmektedir. YSA'ların bu dezavantajlardan kurtularak problemlere çözüm üretebilmesi için aęların oluşturulmasını titizlik ile gerçekleştirmek gerekmektedir. Hem çözülecek olan problemler hem de YSA'lar konusunda yeterli oranda bilgi sahibi olmak başarılı sonuçlar elde edilmesini saęlayabilir. YSA yöntemi ile problemlere çözüm aranmasında bu gerçek göz ardı edilmeden bir aę oluşturmanın mümkün olabileceęi fakat bunun kolay bir süreç olmadığının da bilinmesi gerekmektedir (Öztemel, 2006, 35).

ÜÇÜNCÜ BÖLÜM

LİTERATÜR İNCELEMESİ

Bu bölümde ilk olarak yatırım fonları performansı konusunda literatürde bulunan ampirik çalışmalar incelemesi yapılmaktadır. İkinci olarak, varlık fiyatları ile makro ekonomik değişkenler arasındaki ilişkileri inceleyen çalışmalara yer verilmektedir. Son kısımda ise çalışmanın uygulamasına paralel biçimde özellikle yatırım fonu net varlık değerine ilişkin YSA modelleriyle yapılan çalışmalar olmak üzere, YSA'ların çeşitli finansal alanlarda kullanımına ilişkin literatür incelemesine yer verilmektedir.

3.1. Yatırım Fonları Performansı Üzerine Yapılan Çalışmalar

Yatırım fonları verilerinin çokluğu ve ulaşılabilir olması, portföy performansı konusunda ve varlıkların fiyatları ile ekonomik değişkenler arasındaki ilişkilerin incelenmesi konusunda yapılan ampirik çalışmaların birçoğunda kullanılmasına neden olmuştur. Yatırım fonları performansı konusunda yapılan çalışmalar, portföy performansını ölçecek yöntem ve tekniklerin geliştirilmesi, etkin pazar hipotezinin araştırılması, fon performansının belirlenmesi ve yatırım fonu performansına etki eden faktörlerin belirlenmesi amacını taşımaktadırlar. Yatırım fonları fiyatları ile ekonomik değişkenler arasındaki ilişkileri inceleyen sınırlı sayıda çalışmada ise finans teorisinin işaret ettiği gibi, faiz oranları, beklenen ve beklenmeyen enflasyon oranları ve endüstriyel üretim gibi reel piyasa değişkenlerinin sistematik olarak varlık fiyatlarına etki edip etmediğinin tespit edilmesini amaçlamaktadır.

Portföy performansının ölçülmesi konusunda yapılan çalışmalar ve sonuçları aşağıda verilmektedir.

Performans değerlendirme yönteminin temelleri, 1933 yılında Alfred Cowles tarafından ABD'de para yöneticilerinin piyasa zamanlaması üzerine yapılan çalışmaya dayanmaktadır. Bu çalışmaya göre Cowles, fon yöneticilerinin hisse senedi piyasasından daha yüksek bir getiri sağlayamayacakları sonucuna ulaşmıştır (Cowles, 1933, 309-310).

Yatırım fonlarının performans değerlendirmesi konusunda ilk sistematik ve kapsamlı çalışma ise 1953-1958 döneminde 152 adet yatırım fonunun performansını inceleyen, Friend, Brown, Herman ve Wickers tarafından 1962 yılında yapılmış ve yatırım fonlarının bu beş yıllık dönemde ortalama %12,4 getiri sağladığı ortaya koyulmuştur. Ayrıca, fonların aynı dönem için belirlenen performans ölçütünün sağladığı %12,6'lık getiri oranı karşısında daha düşük getiri sağlayarak başarısız oldukları sonucuna ulaşılmıştır (Ippolito, 1993, 43).

Mossin (1966), Lintner (1965) ve Sharpe (1964) tarafından oluşturulan "Sermaye Varlıklarını Fiyatlandırma Modeli (CAPM)" riskli varlıkların fiyatlandırılmasında sık olarak kullanılan bir model olmuştur. CAPM ve Modern Portföy Teorisi'ni kullanarak Treynor (Treynor, 1965, 63-75), Sharpe (1966) ve Jensen (1968) yatırım fonlarının performanslarını değerlendiren, tek parametreden oluşan ve kendi adları ile anılan üç farklı performans değerlendirme modeli geliştirmişlerdir. Sharpe, 1954-1963 yılları arasında faaliyet gösteren 34 adet açık uçlu yatırım fonundan 23 tanesinin gösterge portföyden (Dow Jones Endeksi) düşük, 11 tanesinin yüksek performans gösterdiği sonucuna ulaşırken (Sharpe, 1966, 119-138); Jensen, 1945-1964 yılları arasında faaliyet gösteren 115 adet yatırım fonu performansını, fon yöneticilerinin seçicilik kabiliyetinin göstergesi olan "alfa" ile incelemiş ve fon yöneticilerinin üstün bir performans göstermediği sonucuna ulaşmıştır (Jensen, 1968, 389-416).

Treynor ve Mazuy 1953-1962 döneminde 57 adet yatırım fonunun performansını incelemişler ve fonların piyasa zamanlaması kabiliyeti olduğuna dair bir bulgu elde edememişlerdir (Treynor ve Mazuy, 1966, 131-136).

Carlson (1970), 1948-1967 dönemindeki 82 adet yatırım fonu ile yaptığı çalışmada, hisse senedi yatırım fonlarının performansının devamlılık göstermediğini ve geçmiş performansa bakarak gelecek performansın tahmin edilemeyeceğini tespit etmiştir (Carlson 1970, 22-23).

McDonald (1974), 1960-1969 yılları arasındaki dönemde 123 adet yatırım fonunun aylık getirilerini kullanarak Sharpe, Jensen ve Treynor ölçütlerini hesaplamış, fonların üstlendikleri risk seviyesi arttıkça getirilerinin de arttığı

sonucuna ulaşmıştır (McDonald, 1974, 311-333). Kon ve Jen, 1979 yılında 49 yatırım fonu performansı üzerinde çalışmışlar, fonların risk seviyelerinin sabit olmadığını ve zamanlama yeteneğine sahip olduğunu tespit etmişlerdir (Kon ve Jen, 1979, 457-475).

Fon yöneticilerinin piyasa zamanlaması yetenekleri Kon ve Henriksson tarafından benzer yöntemlerle incelenmiştir. Kon (1983), 37 adet yatırım fonunu Ocak 1960-Haziran 1976 yılları arasında 198 ay boyunca sergiledikleri performansa bağlı olarak ve ekonometrik model kullanarak incelemiştir (Kon, 1983, 323-347). Henriksson (1984) ise 116 adet açık uçlu fonun 1968-1980 dönemindeki performansını parametrik ve parametrik olmayan yöntemler kullanarak (Henriksson, 1984, 73-96) belirlemeye çalışmıştır. Her iki çalışmada da çok az sayıda fonun zamanlama yeteneğine sahip olduğu sonucuna ulaşılmıştır. Yine Lee ve Rahman (1990), 1977-1984 yılları arasında 93 adet yatırım fonu üzerinde aylık veriler ile yaptıkları araştırmada aynı sonuca ulaşmışlardır (Lee ve Rahman, 1990, 261-278).

Ippolito (1989), 1965-1984 dönemindeki 143 adet yatırım fonunu incelemiş ve fonların yönetim ücretleri ve harcamaları çıkarıldığında piyasadan daha yüksek performans gösterdiği sonucuna ulaşmıştır (Ippolito, 1989, 1-23).

Grinblatt ve Titman (1992), 1975-1984 yılları arasında faaliyet gösteren 279 adet yatırım fonunun performans devamlılığını incelemiş ve yatırım fonlarının performansında pozitif devamlılık olduğu sonucuna ulaşmışlardır (Grinblatt ve Titman, 1992, 1977-1984).

Blake, Elton ve Gruber (1993), fonların hayatta kalma eğilimini dikkate alarak yaptıkları çalışmada, 1979-1989 döneminde faaliyet gösteren 46 adet tahvil yatırım fonunun performansını ölçerken çoklu regresyon analizi yöntemi ile elde edilen alfa katsayılarını kullanmışlardır (Blake, Elton ve Gruber 1993, 371). Malkiel (1995) ise çalışmasında, hisse yatırım fonlarının 1971-1991 yılları arasındaki performansını (Malkiel, 1995, 549-572) ölçmüştür. Her iki çalışmada da, yatırım fonlarının genel olarak örnek portföylerden daha düşük performans gösterdiği ve geçmiş performansın gelecek performansı tahmin edemediği sonucuna ulaşılmıştır.

Graham ve Harvey (1997), 1983-1995 dönemindeki 326 adet yatırım fonunun performansını incelemişler ve yatırım fonları ile piyasa endeksinin risk düzeylerinin aynı seviyeye getirilerek karşılaştırılmasına olanak sağlayan yeni bir yöntem olarak Graham-Harvey Performans Testini geliştirmişlerdir (Graham ve Harvey, 1997, 54-66).

Detzler (1999), 1988-1995 yılları arasında 19 adet global tahvil yatırım fonunun aylık getirilerini kullanılarak risk ve getiri karakteristiklerini incelemiştir. Çoklu regresyon analizinin kullanıldığı çalışmada fonlar karşılaştırıldığı endekslerden daha iyi performans gösterememişlerdir (Detzler, 1999, 1195-1217).

Dahlquist, Engström ve Soderlind (2000), 1993-1997 yılları arasında 210 adet fonun performansını fon getirileri ile çeşitli karşılaştırma ölçütlerinin doğrusal regresyonu ile elde edilen alfa katsayısı ile ölçmüşler ve genel olarak fonların üstün performans göstermediği sonucuna ulaşmışlardır (Dahlquist, Engström ve Soderlind, 2000, 409-423).

Bollen ve Buse (2001), 1985-1995 döneminde 230 adet fon üzerinde yaptıkları çalışmada fonların günlük getirileri ve aylık getirilerinin kullanılması durumunda zamanlama yeteneğinde fark olup olmadığını araştırmışlardır. Yöntem olarak Treynor ve Mazuy (1966) ve Henriksson ve Merton (1981) tarafından geliştirilen regresyon analizleri kullanılmıştır. Treynor ve Mazuy tarafından geliştirilen yöntemde aylık getiriler kullanılması durumunda fonların %11,9'unun, günlük getirilerin kullanılması durumunda ise fonların %34,2'sinin zamanlama yeteneği gösterdiği tespit edilmiştir. Henriksson ve Merton tarafından geliştirilen yöntemde de benzer sonuçlara ulaşılmıştır (Bollen ve Buse, 2001, 1075-1094).

Christensen (2003), Danimarka'da faaliyette bulunan 27 hisse fonu ve 17 adet sabit getirili fonu baz alarak, Ekim 1994-Ocak 2002 yılları arasında yaptığı çalışmada Sermaye Varlıkları Fiyatlama Modeline dayanan tekli ve çoklu indeks modellerini kullanarak, ulusal ve küresel hisse endeksleri ile sabit getirili araçları temsil eden karşılaştırma ölçütleri ile fonların performansını ölçmeye çalışmıştır. Ayrıca kuadratik regresyon yöntemi ile fonların zamanlama yeteneği test edilmiş ve

fonların seçicilik kabiliyetinin ve zamanlama yeteneğinin olmadığı sonucuna ulaşılmıştır (Christensen, 2003).

Papadamou ve Siriopoulos (2004), 1996-2001 döneminde faaliyet gösteren 19 adet Amerikan hisse senedi yatırım fonunun performansını ve devamlılığını ölçmeye çalışmışlardır. Çalışmada, Treynor, Sharpe, Jensen oranları hesaplanmış ve Arbitraj Fiyatlama Teorisine göre fonların performansı belirlenmiştir. Araştırmanın sonuçlarına göre, fon yöneticileri, incelenen dönem içerisinde örnek portföyden daha fazla bir getiri sağlayamamışlar ve kısa dönemde iyi performans gösteren fonlar, bir sonraki dönemde de yüksek performans göstermeye devam etmişlerdir (Papadamou ve Siriopoulos, 2004, 85-97).

Casarin, Pelizzon ve Piva (2005), 1997-2000 yılları arasında faaliyet gösteren 76 adet İtalyan yatırım fonunun haftalık getirilerini ve Morningstar performans derecelendirme yöntemini kullanarak fonların performans devamlılığını ölçmeye çalışmışlardır. Çalışmada, Morningstar derecelendirme sisteminin güçlü bir devamlılık düzeyine sahip performans kriteri olduğu gözlemlenmiştir. Çalışmanın sonuçları, İtalyan yatırım fonlarının genelde zayıf bir performans devamlılığına sahip olduğunu söyleyen çalışmalardan büyük bir farklılık göstermektedir (Casarin, Pelizzon ve Piva, 2005, 297-300). Daha sonraki dönemlerde yapılan çalışmalar da yatırım fonlarının performans devamlılığının ölçülmesi biçiminde olmuştur.

Romacho ve Cortez (2006), Ocak 1996-Aralık 2001 dönemindeki 21 adet Portekiz yatırım fonu performansı üzerinde seçicilik ve pazar zamanlaması kabiliyetinin etkilerini parametrik olmayan Henriksson and Merton (1981) yöntemiyle ölçmüşlerdir. Analizlerinde Portekiz yatırım fonlarını, 8 adet ulusal fon, 7 adet Avrupa Birliği fonları ve 6 adet Uluslararası fon olarak kategorize etmişlerdir. Fon yöneticilerinin ulusal fonlarda daha yüksek performans gösterdiği ve pazar zamanlaması ile seçicilik kabiliyeti arasında da yüksek derecede negatif korelasyon olduğu sonucuna ulaşmışlardır (Romacho ve Cortez, 2006, 348-368).

Huij ve Verbeek (2007), 6429 ABD hisse senedi yatırım fonlarının 1984-2003 dönemini için aylık getiri verilerini kullanarak, fonların kısa dönem performans devamlılığını Bayesian dört faktör modeli (finans literatüründe yer alan birçok

ampirik çalışmada test edilen CAPM modelinin hisse senedi getirilerindeki değişimleri açıklamada yetersiz kalması nedeniyle çoklu faktör modelleri geliştirilmiştir. Bu modellerde, piyasanın getirisi, faiz oranları ve döviz kurları gibi birden fazla risk faktörü dikkate alınmıştır (Canbaş ve Arıoğlu, 2008, 80)) ile ölçmeye çalışmışlardır. Yatırım fonu portföyleri 36 ve 12 aylık sıralama dönemlerine ayrılarak Bayesian alfası hesaplanmıştır. Ayrıca KEKK alfası da hesaplanarak karşılaştırma yapılmıştır. Çalışmada küçük ve büyümekte olan fonlarda, 12 aya göre yapılan sıralamada aylık %0,26 getiri sağladığı ve performans devamlılığı olduğu sonuca ulaşmışlardır (Huij ve Verbeek, 2007, 973-997).

Cuthbertson Nitzsche ve O'Sullivan (2008), 685'i hayatta olan ve 189'u hayatta olmayan fon olmak üzere toplam 935 adet açık uçlu İngiltere hisse senedi yatırım fonlarının, Nisan 1975- Aralık 2002 dönemi için aylık getiri verilerini dört panel veri setine ayırarak ve parametrik olmayan bir tahminleme yöntemi olan *bootstrap metodolojisi* (istatistikte, ana kütleli temsil edecek en iyi örnek serisinin elde edebilmesini sağlayan bilgisayar destekli bir yöntemdir) performanslarının ve performans devamlılığının zamanlama yeteneğinden mi şanstan mı kaynaklandığını araştırmışlardır. Araştırmalarında üç ve dört faktörlü model kullanmışlar ve fon performanslarının iyi şanstan değil doğru piyasa zamanlamasından kaynaklandığı sonucuna varmışlardır (Cuthbertson K. ve Diğ., 2008, 613-634).

Türkiye'de yatırım fonları performansı üzerine yapılan çalışmalar ise şöyledir:

Tevfik (1995), 1993-1994 dönemindeki 22 adet hisse senedinin performansını, Sharpe, Treynor ve Jensen yöntemleriyle ölçmüş ve fonların piyasa ortalama getirisi üzerine çıkamadığı sonucuna ulaşmıştır (Tevfik, 1995).

Karacabey (1998) çalışmasında, 1993-1998 döneminde faaliyet gösteren 31 adet hisse senedi performansının, Treynor-Mazuy ve Henriksson-Merton yöntemlerine göre incelemiş ve genel olarak piyasaya göre üstün performans göstermediği sonucuna ulaşmıştır (Karacabey, 1998). 1999 yılında yaptığı çalışmasında ise 1997-1998 döneminde faaliyette olan 10 adet A tipi hisse senedi fonu performansını zamanlama ve seçicilik kabiliyetine göre değerlendirmiş ve fonların betasının düşük olduğu, portföy performansının negatif olduğu ve alfa

değerlerinin %5 anlamlılık düzeyinde sıfırdan farklı olmadığı başka bir deyişle anlamsız olduğu, seçicilik ve zamanlama kabiliyetlerinin olmadığı sonucuna ulaşmıştır (Karacabey, 1999, 133-149).

Karatepe ve Karacabey (2000), 1997-1999 döneminde 9 adet A tipi yatırım fonu performansını Sharpe, Treynor, Jensen, Graham&Harvey yöntemlerini kullanarak incelemişler ve Graham&Harvey yöntemine göre de yatırım fonlarının piyasadan daha üstün bir performans gösteremediğini tespit etmişlerdir (Karatepe ve Karacabey, 2000, 55-67).

Gürsoy ve Erzurumlu (2001), 1998-2000 dönemindeki 55 adet A ve 77 adet B tipi yatırım fonunun haftalık getirileri kullanılarak Sharpe, Treynor, Jensen ve Graham&Harvey yöntemlerine göre performanslarını incelemişler ve fonların piyasadan daha düşük performans sergilediği sonucuna varmışlardır. Ayrıca, Spearman Sıralı Korelasyon testine göre A ve B tipi yatırım fonları analiz döneminde benzer sonuçlar üretmiştir. Gerek tüm analiz döneminde gerekse alt dönemlerde hazine bonusu en iyi yatırım aracı olurken, onu sırasıyla İMKB 100 endeksi, B Tipi fonlar ve A Tipi fonlar izlemiştir. Fonların, piyasadan daha düşük performans sergilediğini tespit etmişlerdir (Gürsoy ve Erzurumlu, 2001, 43-58).

Kılıç (2002), 1999-2001 döneminde 75 adet A tipi ve 65 adet B tipi yatırım fonları üzerinde tek endeksli modeller, Morningstar ve Henriksson-Merton yöntemlerini kullanarak yaptığı çalışmada, fon yöneticilerinin piyasa yönünün tahmin kabiliyeti olmadığı ve fonların üstün performans göstermedikleri sonucuna ulaşmıştır (Kılıç, 2002, 110). Aynı biçimde Canbaş ve Kandır, 1996-2000 dönemi için tek ve çok kriterli modelleri deneyerek test etmiş ve fonlarda üstün performans görememiştir (Canbaş ve Kandır, 2002, 13-19). Canbaş, Kandır (2004), 1996-2000 tarihleri arasında 29 adet A ve 52 adet B tipi fonun aylık getirilerini kullanarak yaptıkları çalışmada ise Türkiye'deki yatırım fonları performansının devamlılık göstermediği sonucuna ulaşmışlardır (Canbaş ve Kandır, 2004, 64-71).

Doğanay (2004), 2000-2002 döneminde 14 adet A tipi fonun aylık getirilerini dikkate alarak, şartlı ve şartsız performans değerlendirme yöntemlerinin hangisinin fon performansını daha iyi açıkladığını araştırmıştır. Şartlı ve şartsız performans

değerlendirme yöntemleri arasında istatistikî olarak bir fark bulunamamıştır. Ancak, şartlı alfa değerleri, şartsız alfa değerlerine göre fonun gelecekteki performansına ilişkin şartsız alfadan daha iyi bir ölçü olduğu iddia edilmiştir. Şartlı alfanın kullanılması şartsız alfanın kullanılmasından daha yararlı olduğu sonucuna ulaşılmıştır (Doğanay, 2004, 165-179).

Gökgöz (2005), Türkiye’de faaliyet gösteren A tipi karma hisse senedi fonlarının performansını zamanlama ve seçicilik kabiliyetini dikkate alarak performans devamlılığını incelemiş ve genel olarak fonların belirlenen gösterge portföy üzerinde performans sergilediği sonucuna ulaşmıştır. Ancak, 2000-2001 döneminde yaşanan kriz nedeniyle fonların performans devamlılığı gösteremediklerini de tespit etmiştir (Gökgöz, 2005, 75-109).

Teker (2006), B tipi fon kategorisindeki likit, tahvil-bono ve değişken fonlar ile A tipi fon kategorisindeki değişken fonlardan her bir türe ait 5’er adet fon olmak üzere, toplam 20 adet fon için risk odaklı performans değerlemesi yapmış ve yatırım fonlarını performanslarına göre sıralamıştır (Teker, 2006, 89-105).

Akel (2007), Ocak 200-Aralık 2004 döneminde faaliyet gösteren 51 adet A tipi ve 54 adet B tipi yatırım fonlarının performansını zamanlama ve seçicilik kabiliyetini dikkate alarak performans devamlılığını parametrik ve parametrik olmayan yöntemlerle incelemiştir. A tipi fon yöneticilerinin hem seçicilik hem piyasa zamanlaması kabiliyetlerinin olmadığı ve B tipi fon yöneticilerinin de sadece seçicilik kabiliyetlerinin olduğu, Türkiye’deki fonların en azından kısa dönemde performans devamlılığına sahip olduğu sonucuna ulaşmıştır (Akel, 2007, 147-177).

Korkmaz ve Uygurtürk (2007), Türkiye’deki 46 adet emeklilik fonu performansını ve fon yöneticilerinin zamanlama kabiliyetini 2004-2006 dönemi için ölçmeye çalışmışlardır. Fonların performans sıralamasında benzer sonuçlar verdikleri ve sınırlı sayıda fonun yöneticisinin piyasa zamanlama kabiliyetine sahip olduğu sonucuna ulaşmışlardır (Korkmaz ve Uygurtürk, 2007, 66-93).

Finans literatüründe makro ekonomik değişkenlerin varlık fiyatları üzerindeki etkisini inceleyen çalışmaların sayısı giderek artmaktadır. Ancak yapılan çalışmaların çoğunluğu makro ekonomik değişkenlerin hisse senedi getirileri üzerindeki etkilerini tahmin etmeye yöneliktir. Çünkü hisse senetleri sermaye piyasasındaki en riskli yatırım araçları olup ekonomik gelişmelere çok çabuk cevap verebilmektedir. Bu nedenle aşağıda hisse senetleri ile yapılan çalışmalara kısaca değinildikten sonra yatırım fonları net varlık değerlerini tahmin etmeye yönelik sınırlı sayıda olan çalışmalara yer verilmektedir.

Chen, Roll ve Ross (1986), 1958-1984 döneminde, faiz oranları, beklenen ve beklenmeyen enflasyon oranları, risk primi, endüstriyel üretim ve petrol fiyatları gibi ekonomik değişkenlerin hisse senedi getirileri ve menkul değer fiyatları üzerindeki sistematik etkilerini aylık zaman serilerini kullanarak doğrusal regresyon yöntemiyle incelemişlerdir. Hisse senedi getirilerinin sistematik ekonomik haberlerden ve makro ekonomik değişkenlerdeki değişimlerden etkilendiği ve bu etkilere uyumlu bir biçimde fiyatlandığı sonucuna ulaşmışlardır. Ayrıca çalışmalarında, NYSE (New York Stock Exchange) gibi hisse senedi piyasası indekslerinin makro ekonomik değişkenlerle karşılaştırıldığında, varlık fiyatları üzerindeki etkilerinin önemsiz olduğunu tespit etmişlerdir (Chen ve Diğ., 1986, 383-403).

Fama (1990), hisse senedi fiyatlarıyla reel faaliyetler, enflasyon ve para arasındaki etkileşimi incelemiş ve hisse senedi getirileri ile endüstriyel üretim, GSMH, para arzı, faiz oranı ve enflasyonun gecikmeli değerleri gibi reel değişkenler arasında güçlü bir pozitif korelasyon tespit etmiştir (Ray ve Vina, 2004, 2). Bununla birlikte yakın zamanda yapılan çalışmaların çoğunda makro ekonomik değişkenlerle hisse senedi arasındaki kısa dönemli ilişkilere dikkat çekilmiştir.

Wongbangpo ve Sharma (2002) tarafından Endonezya, Malezya, Singapur, Filipinler ve Tayland hisse senedi piyasalarında işlem gören hisse senedi fiyatları üzerinde, GSMH, TÜFE, para arzı, faiz oranı ve döviz kuru değişkenlerinin etkileri incelenmiş ve aralarında nedensellik ilişkisi olduğu sonucuna varmışlardır. Enflasyon ile hisse senedi fiyatları arasında ters yönlü bir ilişki var iken, döviz kuru ve faiz oranlarının etkileri ülkelere göre negatif ve pozitif yönlü olmak üzere farklı biçimde etki göstermiştir. Mukherjee ve Naka (1995) yaptıkları çalışmada hisse senedi

fiyatları ile altı adet makro ekonomik gösterge, döviz kuru, para arzı, enflasyon, endüstriyel üretim, uzun dönem devlet tahvili faiz oranı, vadesiz ödünç faiz oranı ile Tokyo Hisse Senedi Borsası endeksi arasında uzun dönemli ilişki olduğunu tespit etmişlerdir (Zügül ve Şahin, 2009, 146-148).

Boyer ve Zheng (2009), 1952 ile 2004 arasındaki 53 yıllık dönemde, ABD sermaye piyasasındaki yedi adet yatırımcı grubunu seçerek, bu grupların nakit akımları ile hisse senedi getirileri arasında, özellikle yatırım fonları ile yabancı yatırım fonları gruplarında pozitif ve önemli bir ilişki olduğunu tespit etmişlerdir (Boyer ve Zheng, 2009, 87-100).

Ekonomik ve finansal değişkenlerin modellenmesi ve öngörülmesi ekonomi ve finans için son derece önemlidir. Özellikle son yıllarda zaman serileri alanında kaydedilen gelişmelerden dolayı ekonomik ve finansal modellemelerde ekonometrik yöntemlerin kullanımı giderek artmaktadır. Bunun yanında kendine geniş bir uygulama alanı bulan YSA'ları ekonometrik yöntemlere alternatif ve performansı karşılaştırılabilir bir öngörü yöntemi haline gelmiştir. Sınıflandırmada ve zaman serilerinin öngörülmesinde oldukça başarılı sonuçlar üretebildiği için istatistik, ekonomi ve finans konularında da yoğun bir şekilde kullanılmaktadır (Kaastra ve Boyd, 1996, 216).

3.2. Sermaye Piyasalarında Yapay Sinir Ağları Yönteminin Kullanımı

Literatürde finansal değişkenlerin YSA'ları yöntemiyle modellenmesi ve tahmini konusunda birçok çalışma bulunmaktadır. Bu çalışmalar ağırlıklı olarak döviz kuru ve hisse senedi fiyatlarının tahmin edilmesini konu almaktadır. Bu çalışmalara örnek olarak aşağıdaki araştırmalar ve sonuçları verilmektedir.

Yao, Poh ve Jasic (1996), 18 Mayıs 1984-7 Şubat 1995 dönemindeki, ABD doları ile dönemin temel beş para birimi olan, Japon Yen'i, Alman Mark'ı, İngiliz Paund'u, İsviçre Frank'ı ve Avustralya Dolar'ı arasındaki 2.910 günlük kur değerlerini kullanarak döviz kurlarını tahmin etmeye çalışmışlardır. Döviz kurlarını ARIMA ve YSA modellerinden yararlanarak tahmin etmeye çalışmışlar ve döviz kurlarını tahmin etmede YSA modelinin daha etkin sonuçlar verdiğini tespit etmişlerdir (Yao, Poh ve Jasic, 1996, 754-759).

Zhang (2001), doğrusal nitelikli zaman serisi problemlerine YSA'ların uygulanabilirliğini test etmiştir. Zhang, IBM hisse senedi kapanış fiyatlarının öngörüsünde sekiz farklı ARIMA modeli ile doğrusal olmayan çok katmanlı YSA modellerini karşılaştırmıştır. Sonuç olarak, YSA'ların doğrusal olmayan nitelikli problemlerin yanı sıra, doğrusal nitelikli problemlerde de başarılı olduğunu ortaya koymuşlardır (Zhang, 2001, 1183-1202).

Kim, Oh, Sohn ve Hwang (2004), 1997 yılında Güney Kore'de yaşanan finansal krizin Kore'nin ekonomik yapısına olan etkilerini inceleyerek, çok katmanlı YSA modelleri ile bir erken uyarı sistemi geliştirmişlerdir. 1997 yılını 3 Ocak-18 Eylül arasında istikrarlı dönem, 19 Eylül-21 Ekim arasında istikrarsız dönem ve 22 Ekim-27 Aralık dönemini de kriz dönemi olmak üzere üç temel döneme ayırmışlardır. KOSPI hisse senedi endeksini modelde girdi değişkeni olarak kullanmışlar ve endeks volatilitesinin piyasanın yönü hakkında bilgi verdiğini düşünerek, endeksin gün sonu kapanış değerini, günlük getirisini, 10 günlük hareketli ortalamasını, varyansını ve varyans oranını hesaplamışlardır. 1994-2001 yıllarını kapsayan çalışmada, KOSPI endeksinin volatilitesinin krizin habercisi olduğunu ve YSA modellerinin 1997 ekonomik krizinin erken teşhisinde, piyasanın hareketlerini sınıflandırmada ve ekonominin temel trendini takip etmede etkileyici şekilde başarılı olduğunu tespit etmişlerdir. (Kim ve Diğ., 2004, 583-590).

Dutta, Jha, Kumar ve Mohan (2006), Bombay Menkul Kıymetler borsası endeksinin modellenmesinde çok katmanlı YSA yöntemini kullanmışlar ve YSA modelinin endeks değerlerini başarıyla tahmin ettiği sonucuna ulaşmışlardır (Dutta ve Diğ., 2006, 49-61).

Panda ve Narasimhan (2007), Ocak 1994-Haziran 2003 dönemindeki Hint Rupisi/ABD Doları (INR/USD) döviz kurlarının haftalık verilerini kullanarak, doğrusal otoregressif model ve YSA modeli ile döviz kurlarının gelecekteki değerini tahmin etmişlerdir. YSA modelinin döviz kurunu tahmin etmede firma ve yatırımcılar için daha etkin sonuçlar verdiğini tespit etmişlerdir (Panda ve Narasimhan, 2007, 27-236).

Tseng ve diğ erleri (2008), Tayvan Hisse Senedi Endeksi (TXO) fiyatlarının volalitesini çok katmanlı YSA modeli ile tahmin etmişlerdir. Karşılaştırma ölçütü olarak da EGARCH ve Grey-GARCH modellerini kullanmışlardır. YSA modelinin piyasa volatilitisini daha etkin tahmin ettiği sonucuna ulaşmışlardır (Tseng ve Diğ ., 2008, 3192-3200).

Liang ve diğ erleri (2009), 2006-2007 dönemi Hong Kong opsiyon borsası verilerini kullanarak opsiyon fiyatlarını YSA, sonlu fark yöntemi ve Monte Carlo yöntemleriyle tahmin etmişlerdir. Önce geleneksel opsiyon fiyatlandırma yöntemleri kullanarak tahmin yapılmış daha sonra tahmin hatalarını azaltmak için YSA ve destek vektör regresyonu (SVRs) kullanılmıştır. Böylece parametrik ve parametrik olmayan yöntemler kullanarak gelecekteki opsiyon fiyatları tahmin edilmiş ve YSA yönteminin daha üstün bir tahmin performansı gösterdiği sonucuna ulaşmışlardır (Liang ve Diğ ., 2009, 3055-3065).

Türkiye sermaye piyasalarını dikkate alan çalışmalar da YSA modellemesinin diğ er modellere göre daha başarılı sonuçlar ürettiğini ortaya koymaktadır. Yıldız (2001), Türkiye’de 1983-1997 yılları arasındaki dönemlerde SPK’ya tabi ve/veya İstanbul Menkul Kıymetler Borsası’nda (İMKB) işlem gören sanayi, ticaret ve hizmet işletmeleri üzerinde yaptığı çalışmada, finansal başarısızlığı öngörmeye YSA modelinin ayırma analizine göre daha başarılı olduğu sonucuna ulaşmıştır (Yıldız, 2001, 51-67). Diler (2003), İMKB Ulusal-100 Endeksi’nin ertesi gün hangi yönde olacağını hata geriye yayma yöntemi kullanarak YSA modellemesiyle tahmin etmiş ve yöntemin İMKB Ulusal-100 Endeksi’nin ertesi gün değerini %60.81 oranında tahmin edebildiği sonucuna ulaşmıştır (Diler, 2003, 65-81). Benli (2005), 1997-2001 döneminde Tasarruf Mevduat Sigorta Fonuna devredilen 17 adet özel sermayeli ticaret bankası ile 21 adet faaliyetini sürdüren özel sermayeli ticaret bankası verilerini kullanarak, lojistik regresyon ve yapay sinir ağı modeline dayanan mali başarısızlık öngörü modelleri geliştirmiştir. Yapay sinir ağı modelinin mali başarısızlığı öngörme gücünün (%82.4) lojistik regresyon modelinden (%76.5) daha üstün olduğu tespit edilmiştir. Dolayısıyla yapay sinir ağı modelinin tüm bilgi kullanıcıları için mali başarısızlığı öngörmeye bir araç olarak kullanılabileceği saptanmıştır (Benli, 2005, 31-46). Altay ve Satman (2005), İMKB 30 ve İMKB Tüm

endekslerinin getirilerini çok katmanlı YSA ve doğrusal regresyon yöntemi kullanarak tahmin etmeye çalışmışlardır. YSA modellerinin aylık ve günlük getiriler için doğrusal regresyondan daha iyi sonuçlar vermezken endeks getirilerini yönünü tahmin etme konusunda oldukça başarılı olduğu sonucuna ulaşılmıştır (Altay ve Satman, 2005, 18-33). Karaçor ve Alptekin (2006), öncü göstergeler yardımıyla Kasım ve Şubat krizleri engellenebilir miydi? Öncü göstergeler Türkiye ekonomisi için işledi mi? Eğer islediyse olası krizleri önceden tahmin edebilir miyiz? Krizden korunabilir miyiz? Krizi yönetebilir miyiz? sorularına krizin öncü göstergeleri olarak kabul edilen çeşitli makro ekonomik göstergeleri incelemişler ve öncü göstergelerin yaşanan kriz sürecini küçük hatayla tahmin ettiği sonucuna ulaşılmıştır (Karaçor ve Alptekin, 2006, 237-256). Avcı (2007), İMKB-100 endeksinin günlük ve seanslık getirilerini çok katmanlı YSA modeli ile tahmin etmiş ve tahmin performansının güçlü olduğunu ve finansal performans ölçütü olarak kullanılabileceğini tespit etmiştir. Bu çalışma ile YSA modelleme tekniği ile etkin ve güçlü tahminlere ulaşılabilindiği gösterilmiştir. (Avcı, 2007, 128-142). Altan (2008), Ocak 1987-Eylül 2007 dönemindeki döviz kuru (TL/USD) aylık verileri kullanılarak, döviz kuru YSA ve vektör otoregressif (VAR) modeli ile tahmin edilmiştir. Çok katmanlı ileri beslemeli ve geri yayılım metoduyla öğrenen bir YSA mimarisi ile yapılan tahminlerin oldukça etkin sonuçlar verdiği tespit edilmiştir (Altan, 2008, 141-160).

Yatırım fonlarına ilişkin YSA modeliyle tahmin yapan çalışmalar ise şöyledir:

Indro, Jiang, Patuwo ve Zhang (1999), 1993-1995 dönemini kapsayan çalışmada, ABD hisse senedi yatırım fonlarının performansını çok katmanlı ve ileri beslemeli, bir gizli katmanlı bir YSA modeli kullanarak tahmin etmişler ve tahmin sonuçlarını oluşturdukları iki adet doğrusal regresyon model tahminleriyle karşılaştırmışlardır. Yatırım fonları performansını tahmin etmede, YSA modelinin doğrusal modele göre daha başarılı olduğunu tespit etmişlerdir. Analizlerinde hisse senedi yatırım fonları yıllık getiri verilerini kullanarak Jensen alfasını hesaplamışlardır. Karşılaştırma ölçütünü, hata ölçümünü üç sınıfa ayırarak yapmışlar ve ortalama hata, ortalama mutlak hata, standart sapmanın hatası ve ortalama mutlak yüzde hatası olmak üzere dört grupta tanımlamışlardır (Indro ve Diğ., 1999, 373-380).

Ray ve Vani (2004), Hindistan yatırım fonlarının gelecekteki net varlık değerlerini YSA modeli kullanarak tahmin etmeye çalışmışlardır. Veri seti olarak, 1999-2004 döneminde Hindistan'da faaliyet gösteren 10 adet yatırım fonunun aylık net varlık değerleri ile 6 adet makro ekonomik değişken kullanmışlardır. Çalışmada, sanayi üretimi, faiz oranı, enflasyon oranı, döviz kuru, para arzı ve hisse senedi piyasası büyüklüğü gibi makro ekonomik değişkenlerde meydana gelen değişimlerin, yatırım fonları net varlık değerleri üzerindeki etkisini, sigmoid aktivasyon fonksiyonundan yararlanarak geri yayılım algoritması ile eğitilen çok katmanlı YSA modeli kullanarak tahmin etmişlerdir (Ray ve Vani, 2004, SSRN).

Ekonomik ve finansal araştırmalar sermaye piyasası ve reel ekonomi arasında güçlü ilişkilerin var olabileceğine kuşku ile baksalar da doğrusal modellerden elde edilen bulgular bu ilişkiyi doğrular niteliktedir. Ray ve Vani'nin, YSA modelleme tekniği ile yaptıkları tahmin sonucunda ulaştıkları bulgular şu şekilde özetlenebilir (Ray ve Vani, 2004, 8-10):

- Faiz oranı ile yatırım fonu net varlık değerleri arasında iki nedenden dolayı negatif bir ilişki vardır. Birincisi, düşük faiz oranı, düşük sermaye maliyeti ve yüksek kazanç demektir. Dolayısıyla düşük faiz oranlarının varlık fiyatları üzerindeki etkisi pozitiftir. İkincisi, düşük faiz oranları, sürü psikolojisindeki yatırımcı için yüksek ödül demektir ve yatırımcılar borsaya akın eder bu nedenle varlık fiyatları artar.
- Enflasyon oranı ile faiz oranı arasında pozitif bir ilişki vardır ve varlık fiyatlarını olumsuz etkilemektedir. Dolayısıyla enflasyon oranı yüksek olduğunda küçük ve büyük yatırımcılar borsada yatırım fonlarını satma eğiliminde olacaklar (çünkü yatırım fonları fiyatları düşecektir) ve yüksek reel getiri elde edeceklerdir.
- Para arzının yatırım fonu piyasasına etkisi ise belirgin değildir. Bir taraftan, parasal büyümenin enflasyon oranı ile pozitif ilişkisi olduğundan, hisse senedi ve yatırım fonu fiyatlarını olumsuz etkilemektedir. Diğer taraftan, parasal büyüme ekonomiyi uyarmakta, şirket kazançları ve hisse senedi fiyatları dolayısıyla yatırım fonu net varlık değerleri artmaktadır. Ayrıca

para arzı ile faiz oranı arasında ters ilişki olduğundan hisse senedi ile yatırım fonu fiyatları üzerinde negatif etki yapmaktadır. Ayrıca bu etkiyi daha hakim olan faktör belirlemektedir.

Ray ve Vani (2004)'nin çalışmasında, Bombay Menkul Kıymetler Borsası (BSE) endeksi getirileri, yatırım fonlarının net varlık değerlerini belirlemede girdi değişkeni olarak dikkate alınmış ve bu iki değişken arasında pozitif ilişki olduğu sonucuna ulaşılmıştır. Döviz kurları ve sanayi üretim endeksi ile yatırım fonları net varlık değerleri arasında ise ihmal edilebilir düzeyde bir ilişki tespit edilmiştir.

Sahoo ve Hathy (2007)'nin 1980-2000 dönemini kapsayan Hindistan'da yaptıkları çalışmalarında yatırım fonu net varlık değerlerini YSA yöntemi ve doğrusal regresyon yöntemi ile tahmin etmişlerdir. Çalışmada, 21 yıllık dönemde seçilen 5 adet yatırım fonunun aylık net varlık değerlerini geri yayılım algoritmasıyla eğitilen çok katmanlı YSA modelini kullanarak büyük bir başarı ile tahmin etmişlerdir. Ayrıca çalışmada, YSA modeli tahminleri doğrusal regresyon modelinden daha iyi performans göstermiştir. Analizde, veriler eğitim, test ve öngörü seti olmak üzere üç veri setine ayrılmıştır. Verilerin %85'i eğitim seti olarak belirlenmiş, transfer fonksiyonu olarak, lineer ve sigmoid fonksiyonları ve öğrenme kuralı olarak da delta öğrenme kuralı kullanılmıştır. YSA modelinin zaman serileri gibi dinamik yapıların analizinde geleneksel KEKK yöntemine göre daha etkin sonuçlar verdiği sonucuna ulaşmışlardır (Sahoo ve Hathy, 2007, 5-15).

Dünya sermaye piyasasına 1868, Türkiye sermaye piyasasına ise 1987 yılında giren yatırım fonları, hem vadesiz ve çok likit olmaları hem de yatırımcıyı hisse senedi piyasasındaki belirsizliklerden korumaları nedeniyle günümüze kadar hızlı bir değişim göstermiştir. Yatırım fonları, yüksek fiyat hareketlerinden ve piyasa belirsizliklerinden yatırımcıyı koruyarak küçük tasarruf sahiplerinin istikrarlı kazanç sağlayabilmelerinde ve böylece tasarrufların sermaye piyasasına aktarılabilmesinde önemli rol oynamaktadır. Bu nedenle finans literatüründe, yatırım fonlarının performansları, bu performansların devamlılığı, yatırım fonlarının fiyatları, fiyatlarındaki değişimler ve bu değişimlere neden olan faktörler farklı yöntem ve teknikler kullanılan birçok bilimsel çalışmanın temel konusu olmuştur.

DÖRDÜNCÜ BÖLÜM

TÜRKİYE'DEKİ YATIRIM FONLARI NET VARLIK DEĞERİNİN TAHMİN EDİLMESİ ÜZERİNE AMPİRİK BİR UYGULAMA

Bu bölümde çalışma sırasında kullanılan modeller tanıtılmaktadır. Seçilen makro ekonomik değişkenlerde meydana gelecek değişimin, Türkiye'de faaliyette bulunan yatırım fonları net varlık değerlerinde yaratacağı değişmeyi ölçmeye yönelik olarak doğrusal regresyon modeli ve yapay sinir ağı modeli tahmin edilmektedir.

4.1. Çalışmanın Amacı

Bu çalışmanın amacı, Ocak 2001-Aralık 2008 döneminde Türkiye'de faaliyet gösteren, verileri kesintiye uğramayan ve 2008 yılı sonu itibariyle net varlık değeri en yüksek olan A ve B tipi yatırım fonlarının net varlık değerleri ile seçilen makro ekonomik değişkenler arasındaki uzun dönemli ilişkiyi regresyon ve yapay sinir ağları yöntemi ile tahmin etmek ve her iki yöntem için elde edilen sonuçların tahmin performanslarını karşılaştırmaktır.

4.2. Çalışmanın Önemi

Literatürde varlık fiyatlarıyla ekonomik faktörler arasındaki ilişkiyi inceleyen çok sayıda ampirik çalışma olmasına karşın, makro ekonomik değişkenlerin yatırım fonlarının net varlık değerlerinde uzun dönemde herhangi bir etki yapıp yapmadığını doğrusal regresyon yöntemi ve yapay sinir ağları yöntemiyle tahmin eden çalışma yok denilecek kadar azdır.

Böyle bir çalışma ile hem Türkiye'deki reel sektör ve mali sektör arasındaki etkileşimin derecesi ölçülecek hem de yeni bir tahmin yöntemi olan YSA yönteminin klasik ekonometrik yöntemlerden birisi olan doğrusal regresyon modeli ile bir karşılaştırması yapılacaktır.

4.3. Çalışmanın Kapsamı ve Veri Seti

Bu bölümde çalışma kapsamında incelenen yatırım fonları ve veri seti hakkında bilgi verilmektedir.

4.3.1. Çalışma Kapsamında İncelenen Fonlar

Türkiye’de Ocak 2001-Aralık 2008 tarihleri arasındaki 8 yıllık (96 ay) dönemde faaliyet gösteren A ve B tipi yatırım fonları net varlık değerleri ile makro ekonomik değişkenler arasındaki ilişkiyi göstermek için, 19 adet A tipi ve 19 adet B tipi olmak üzere 38 adet menkul kıymet yatırım fonunun aylık net varlık değerleri kullanılmıştır. Aralık 2008 itibariyle piyasada faaliyet gösteren 125 adet A tipi ve 179 adet B tipi yatırım fonu bulunmaktadır. Ancak fonların hayatta kalma sorunu tüm ana kütle ile çalışma yapılmasını mümkün kılmamaktadır.

Türkiye’de yatırım fonu piyasasında meydana gelen gelişmeler sonucunda 2006-2007 yıllarında yeni türde yatırım fonları piyasaya çıkmıştır. Bu fonların 2008 yılı net varlık değerleri yüksek olmasına karşın, çalışmanın yapıldığı 2001-2008 dönemi boyunca kesintisiz veriye sahip değildirler. Ayrıca, çalışmanın amacı belirlenen 6 adet makro ekonomik bağımsız değişkenin Türkiye’de faaliyet gösteren fon türlerinin net varlık değerlerindeki değişimi açıklama gücünü ölçmek olduğundan, analizlerde 2008 yılı itibariyle en yüksek net varlık değerine sahip ve söz konusu dönemde süreklilik arz eden 38 adet yatırım fonunun net varlık değeri bağımlı değişken olarak kullanılmıştır.

Çalışmada tahmin edilen farklı fon kurucularına ait 19 adet A ve 19 adet B tipi olmak üzere toplam 38 adet yatırım fonu örneklem olarak alınmış ve Tablo 4.1’deki gibi bir kodlama yapılmıştır.

Tablo 4.1: Çalışmada Kullanılan A ve B Tipi Yatırım Fonları

Fonun Kodu	Fonun Adı
A Tipi Yatırım Fonları	
A1	ACAR YAT. MEN. DEĞ. A.Ş. A TİPİ DEĞİŞKEN FON
A2	AKBANK T.A.Ş. A TİPİ HİSSE SENEDİ FONU
A3	AKBANK T.A.Ş. A TİPİ SABANCI HOLD. İŞTİRAK FONU
A4	ECZACIBAŞI MEN. DEĞ. A.Ş. A TİPİ DEĞİŞKEN FON
A5	GLOBAL MEN. DEĞ. A.Ş. A TİPİ DEĞİŞKEN FON
A6	İŞ YAT. MEN. DEĞ. A.Ş. A TİPİ DEĞİŞKEN FON
A7	YKB A.Ş. A TİPİ KOÇ-ALLIANZ SİG. ÖZEL FONU
A8	YKB A.Ş. A TİPİ İMKB-100 ENDEKSİ FONU
A9	T.C. ZİRAAT BANKASI A TİPİ DEĞİŞKEN FON
A10	TEB. YAT. MEN. DEĞ. A.Ş. A TİPİ HİSSE SENEDİ FONU
A11	T. GARANTİ BANK. A.Ş. ÖZEL BANK. A T. D. FONU
A12	T. GARANTİ BANKASI A.Ş. ATİPİ İMKB-30 END. FONU
A13	T. İŞ BANK. A.Ş. A TİPİ DEĞİŞKEN FON
A14	T. İŞ BANK. A.Ş. A TİPİ HİSSE SENEDİ FONU
A15	T. İŞ BANK. A.Ş. A TİPİ İŞTİRAK FONU
A16	T. İŞ BANK. A.Ş. A TİPİ İMKB-30 END. FONU
A17	YAPI KRE. YAT. MEN. DEĞ. A.Ş. A TİPİ DEĞ. FON
A18	YAPI VE KREDİ BANK. A.Ş. A TİPİ HİSSE SENDİ FONU
A19	YAPI VE KREDİ BANK. A.Ş. A TİPİ KARMA FON
B Tipi Yatırım Fonları	
B1	AKBANK T.A.Ş. B Tİ. UZUN VAD. TAHVİL VE BONO F.
B2	ATA YATIRIM MEN. KIYM. A.Ş. B TİPİ LİKİT FON
B3	FİNANSBANK A.Ş. B TİPİ LİKİT FON
B4	HSBC BANK A.Ş. B TİPİ LİKİT FON
B5	İŞ YAT. MEN. DEĞ. A.Ş. B TİPİ DEĞİŞKEN FON
B6	T.C. ZİRAAT BANKASI B TİPİ DEĞİŞKEN FON
B7	T.C. ZİRAAT BANKASI B TİPİ LİKİT FON
B8	TEB. A.Ş. B TİPİ LİKİT FON
B9	T.GARANTİ BANKASI A.Ş. B TİPİ FLEXİ DEĞİŞKEN F.
B10	T. GARANTİ BANKASI A.Ş. B TİPİ LİKİT FON
B11	T. GARANTİ BAN. A.Ş. B TİPİ TAHVİL VE BONO FONU
B12	T. İŞ BANK. A.Ş. B TİPİ LİKİT FON
B13	T. İŞ. BANK. B TİPİ TAHVİL VE BONO FONU
B14	T. VAKIFLAR BANKASI T.A.O. B TİPİ DEĞİŞKEN FON
B15	T. VAKIFLAR BANKASI T.A.O. B TİPİ LİKİT FON
B16	YAPI VE KREDİ BANKASI A.Ş. B TİPİ DEĞİŞKEN FON
B17	YAPI VE KREDİ BANKASI A.Ş. B TİPİ LİKİT FON
B18	YAPI KREDİ YAT. MEN DEĞ. A.Ş. B TİPİ LİKİT FON
B19	YAT. FİNS. MEN. DEĞ. A.Ş. B TİPİ LİKİT FON

Tablo 4.1'deki fonlar, 2008 yılı itibariyle toplam yatırım fonu net varlık değeri içinde en yüksek net varlık değerine sahip olan ve Ocak 2001-Aralık 2008 döneminde verileri kesintiye uğramayan fonlardır. Bu kriterlere uygun olarak seçilen fonların ana kütleyi temsil yeteneğinin iyi olup olmadığı A ve B tipi fonlar için hazırlanan aşağıdaki tablolardan görülmektedir.

A tipi fonlar için hazırlanan Tablo 4.2'ye göre, 2008 yılı sonu itibariyle analiz dönemi boyunca süreklilik gösteren A tipi fonların net varlık değeri 151.066.554 TL'dir. Analizde kullanılan fonlardan sadece 7 tanesinin net varlık değeri 114.295.590 TL'dir ve toplam A tipi fonları net varlık değerinin %75.66'sını ifade etmektedir. Bu oran analizde kullanılan A tipi fon örnekleminin ana kütleli temsil yeteneğinin oldukça iyi olduğunu göstermektedir.

Tablo 4.2: 2008 Yılı Sonu İtibariyle Çalışmada Kullanılan A Tipi Fonların Toplam A Tipi Fonlar İçindeki Oranı

Kod	Yatırım Fonu Adı	Yatırım Fonu NVD (TL)	Fon Türü İçindeki Oranı %
A1	ACAR YAT. MEN. DEĞ. A.Ş. A TİPİ DEĞİŞKEN FON	15.432.971	10.22
A2	AKBANK T.A.Ş. A TİPİ HİSSE SENEDİ FONU	3.011.677	1.99
A3	AKBANK T.A.Ş. A TİPİ SABANCI HOLD. İŞTİRAK F.	842.429	0.56
A4	ECZACIBAŞI MEN. DEĞ. A.Ş. A TİPİ DEĞİŞKEN F.	2.640.849	1.75
A5	GLOBAL MEN. DEĞ. A.Ş. A TİPİ DEĞİŞKEN FON	583.873	0.39
A6	İŞ YAT. MEN. DEĞ. A.Ş. A TİPİ DEĞİŞKEN FON	8.037.329	5.32
A7	YKB A.Ş. A TİPİ KOÇ-ALLIANZ SİG. ÖZEL FONU	218.628	0.14
A8	YKB A.Ş. A TİPİ İMKB-100 ENDEKSI FONU	6.14.030	4.05
A9	T.C. ZİRAAT BANKASI A TİPİ DEĞİŞKEN FON	1.606.053	1.06
A10	TEB. YAT. MEN. DEĞ. .Ş. A TİPİ HİSSE SENEDİ FONU	2.578.445	1.71
A11	T. GARANTİ BANK. ÖZEL BANK. A T. D. FONU	311.762	0.21
A12	T. GARANTİ BANKASI A.Ş. A TİPİ İMKB-30 END. FON	18.113.025	11.99
A13	T. İŞ BANK. A.Ş. A TİPİ DEĞİŞKEN FON	9.656.440	6.39
A14	T. İŞ BANK. A.Ş. A TİPİ HİSSE SENEDİ FONU	11.452.940	7.85
A15	T. İŞ BANK. A.Ş. A TİPİ İŞTİRAK FONU	24.063.006	15.93
A16	T. İŞ BANK. A.Ş. A TİPİ İMKB-30 END. FONU	13.884.824	9.19
A17	YAPI KRE. YAT. MEN. DEĞ. A.Ş. A TİPİ D. FON	16.826.738	11.14
A18	YAPI VE KREDİ BANKASI A.Ş. A TİPİ HİSSE SENDİ F.	14.522.086	9.61
A19	YAPI VE KREDİ BANKASI A.Ş. A TİPİ KARMA FON	1.169.449	0.77
Toplam A Tipi Fonlar NVD		151.066.554	
NVD'si Yüksek 7 Fonun NVD		114.295.590	75.66

Kaynak: SPK Aylık Bülteni, Aralık, 2008.

B tipi fonlar için hazırlanan Tablo 4.3'e göre, 2008 yılı sonu itibariyle analiz dönemi boyunca süreklilik gösteren B tipi fonların net varlık değeri 13.902.075.006 TL'dir. Analizde kullanılan fonlardan en yüksek net varlık değerine sahip 5 fonun net varlık değeri 10.720.373.024 TL ile toplam B tipi fonları net varlık değerinin %77.11'ini oluşturmaktadır. Bu oran analizde kullanılan B tipi fon örnekleminin ana kütleli temsil yeteneğinin oldukça iyi olduğunu göstermektedir. Ayrıca 38 adet A ve B tipi fonların net varlık değeri toplamı 14.053.141.560 TL'dir ve net varlık değeri en yüksek A ve B tipi 12 adet fonun net varlık değerleri toplamı ise 10.834.668.614 TL'dir ve ana kütleli temsil etmektedirler. O halde bu örneklem ana kütleli temsil eden ve istatistikî analiz yapılmasını mümkün kılan bir örneklemdir.

Tablo 4.3: 2008 Yılı Sonu İtibariyle Çalışmada Kullanılan B Tipi Fonların Toplam B Tipi Fonlar İçindeki Oranı

Kod	Yatırım Fonu Adı	Yatırım Fonu NVD (TL)	Fon Türü İçindeki Oran %
B1	AKBANK T.A.Ş. B TİPİ UZUN VAD. TAH. VE BONO F.	100.437.085	0.71
B2	ATA YATIRIM MEN. KIYM. A.Ş. B TİPİ LİKİT FON	37.115.951	0.26
B3	FİNANSBANK A.Ş. B TİPİ LİKİT FON	346.224.611	2.46
B4	HSBC BANK A.Ş. B TİPİ LİKİT FON	815.539.083	5.80
B5	İŞ YAT. MEN. DEĞ. A.Ş. B TİPİ DEĞİŞKEN FON	26.311.694	0.19
B6	T.C. ZİRAAT BANKASI B TİPİ DEĞİŞKEN FON	5.257.586	0.04
B7	T.C. ZİRAAT BANKASI B TİPİ LİKİT FON	1.254.518.069	8.92
B8	TEB. A.Ş. B TİPİ LİKİT FON	585.865.600	4.17
B9	T.GARANTİ BANKASI A.Ş. B TİPİ FLEXİ DEĞİŞKEN F.	42.479.683	0.30
B10	T. GARANTİ BANKASI A.Ş. B TİPİ LİKİT FON	1.207.686.947	8.59
B11	T. GARANTİ BANKASI A.Ş. B TİPİ TAHVİL VE BON. F.	80.903.577	0.58
B12	T. İŞ BANK. A.Ş. B TİPİ LİKİT FON	3.803.040.751	27.04
B13	T. İŞ BANK. B TİPİ TAHVİL VE BONO FONU	494.057.345	3.51
B14	T. VAKIFLAR BANKASI T.A.O. B TİPİ DEĞ. FON	12.582.283	0.09
B15	T. VAKIFLAR BANKASI T.A.O. B TİPİ LİKİT FON	1.056.362.377	7.51
B16	YAPI VE KREDİ BANKASI A.Ş. B TİPİ DEĞİŞKEN FON	258.045.478	1.83
B17	YAPI VE KREDİ BANKASI A.Ş. B TİPİ LİKİT FON	3.398.764.881	24.17
B18	YAPI KREDİ YAT. MEN DEĞ. A.Ş. B TİPİ LİKİT FON	313.292.465	2.23
B19	YAT. FİNS. MEN. DEĞ. A.Ş. B TİPİ LİKİT FON	63.589.540	0.45
B Tipi Fonlar NVD		13.902.075.006	
NVD' si Yüksek 5 Fon NVD		10.720.373.024	77.11
A+B Tipi Fon NVD Toplamı		14.053.141.560	
NVD'si En Yüksek 12 Fon (A+B) NVD		10.834.668.614	77.09

Kaynak: SPK Aylık Bülteni, Aralık, 2008.

4.3.2. Uygulamada Kullanılan Veri Seti ve Yöntem

Bu çalışmada kullanılan makro ekonomik değişkenler, Chen, Roll ve Ross (1986) ve Prantik ve Vani (2004) tarafından yapılan çalışmalar dikkate alınarak seçilmiştir. Chen, Roll ve Ross (1986)'in çalışmalarında; uzun ve kısa dönemli faiz oranları, beklenen ve beklenmeyen enflasyon oranları, endüstriyel üretim ve fiyat endeksleri gibi makro ekonomik değişkenlerin sistematik olarak menkul kıymet fiyatlarını dolayısıyla net varlık değerlerini ve getirilerini etkilediğini göstermektedirler. Prantik ve Vani (2004) ise yatırım fonu net varlık değeri ile sanayi üretimi, faiz oranı, enflasyon oranı, döviz kuru, para arzı ve hisse senedi piyasasının büyüklüğü arasında ilişki olduğunu göstermişlerdir.

Kurulan modelde, farklı tipteki Yatırım Fonu Net Varlık Değeri (NVD) bağımlı değişken, altı adet makro ekonomik değişken de bağımsız değişken olarak belirlenmiştir. Modeldeki makro ekonomik değişkenler, yatırım fonları için gösterge (benchmark veya fon karşılaştırma ölçütü) olarak da kullanılmaktadır.

Tüm deęişkenler için, Ocak 2001 - Aralık 2008 dönemine ait aylık veriler kullanılarak oluşturulan yatırım fonu net varlık deęeri öngörü modeli aşığıdaki biçimde tanımlanmıştır:

$$NVD_i = f(NVD, ATFAİZ, DK, TEFE, İMKB100, M2, SUE, \varepsilon_i) \quad (4.1)$$

Burada;

NVD : i. Yatırım Fonu Net Varlık Deęeri (Bin TL),

ATFAİZ : Aktif Tahvilin Faiz Oranı (%),

DK : ABD Doları/TL Kuru,

TEFE : Toptan Eşya Fiyat Endeksi (1997=100),

İMKB100 : İMKB-100 Endeksi,

M2 : Para Arzı (Bin TL),

SUE : Sanayi Üretim Endeksi (1997=100),

ε : Hata Terimini göstermektedir.

Tüm bu deęişkenlere ait zaman serileri T.C. Merkez Bankası üç aylık bültenlerinden, SPK aylık bültenlerinden, TCMB, TÜİK web adreslerinden elde edilmiştir. Bağımlı ve bağımsız deęişkenlere ait Ocak 2001 - Aralık 2008 dönemi zaman serisi verileri En Küçük Kareler Yöntemine göre deęerlendirilmiştir. Verilerin analizinde E-Views 5.1 programından yararlanılırken, YSA modelinde Neuro Solution 5 programı kullanılmıştır.

4.4. Regresyon Modeli

Ekonomik modeller iktisat teorisinde öngörülen denge ilişkileri dikkate alınarak kurulmaktadır. Kurulan modeldeki deęişkenler arasında anlamlı ekonometrik ilişkilerin varlığı da serilerin durağan olmasına bağılıdır. Zaman serileri ise genellikle volatil bir yapı gösterdikleri için durağan deęildirler. Bu nedenle analizde kullanılacak deęişkenlerin ilk olarak durağan hale getirilmesi gerekmektedir. Verilerin durağanlığın tespiti için Genişletilmiş Dickey-Fuller (ADF) birim kök testi kullanılmıştır.

Yatırım fonu net varlık değeri tahmin modelinin fonksiyonel yapısında kullanılan 6 adet bağımsız değişken; Aktif Tahvilin Faiz Oranı (ATFAİZ), ABD Doları/TL Kuru (DK), İMKB-100 Endeksi (İMKB100), Para Arzı (M2), Sanayi Üretim Endeksi (SUE) ve Toptan Eşya Fiyat Endeksi (TEFE)'dir. Çalışmanın konusu olan yatırım fonları ise 2008 yılı sonu itibariyle fon türleri açısından net varlık değerleri en yüksek olan ve analiz döneminde verileri kesintiye uğramamış olan 19 adet A tipi ve 19 adet B tipi olmak üzere toplam 38 adet yatırım fonu olarak tespit edilmiştir. Aktif Tahvilin Faiz Oranı değişkeni için oransal değerler söz konusu olduğundan bu değişkenin logaritması alınmamıştır. Tüm değişkenlerin aylık değerleri kullanılmış ve Aktif Tahvilin Faiz Oranı hariç, doğrusallığın sağlanmasında önemli katkısı olmasından dolayı, tüm değişkenlerin doğal logaritmaları alınmıştır (Hamilton, 1994, 438). Bu yapı ile tahmin edilen regresyon modelinin genel yapısı aşağıdaki gibi gösterilebilir:

$$\begin{aligned} \ln NVD_i = & \beta_0 - \beta_1 \ln ATFAİZ - \beta_2 \ln DK + \beta_3 \ln İMKB100 + \beta_4 \ln M2 + \beta_5 \ln SUE + \beta_6 \ln TEFE + \\ & \beta_7 \ln NVD_{i-1} + \varepsilon_i \end{aligned} \quad (4.2)$$

(4.2) nolu modeldeki değişkenlere ait beklentilerimiz ve değişkenlerin orijinal grafikleri aşağıdaki biçimdedir:

Aktif Tahvilin Faiz Oranı: Faiz, paranın kirası veya fiyatı olarak adlandırılır. Piyasa faiz oranı arttığında tahvil fiyatı azalır. Yatırım fonu da tahvil gibi bir menkul kıymettir. O halde, Aktif Tahvilin Faiz Oranı arttığında yatırım fonu net varlık değerinin düşmesi beklenir. Başka bir deyişle, iki değişken arasında negatif bir ilişki vardır.

Döviz Kuru: Döviz kuru da bir fiyattır ve mal piyasalarıyla ilgilidir. Döviz kurundaki değişmelerin istikrarlı bir çizgi izlemesi ekonomik istikrarı olumlu etkilemektedir. Türkiye, 22 Kasım 2000 de yaşanan likidite krizi ve 19 Şubat 2001 de yaşanan döviz krizinden sonra ayarlanabilir sabit kurlara dayalı dezenflasyon programını terk ederek dalgalı kura geçmek zorunda kalmıştır. Denge döviz kuru, fiyat düzeylerinin oranı ile doğrusal bir ilişkiye sahiptir. Döviz kuru da bazı menkul kıymetler için benchmark olarak tespit edilen bir makro ekonomik değişkendir.

Döviz kuru arttığında yatırımcıların fonları buraya kayacağından yatırım fonu net varlık değeri azalır. Dolayısıyla iki değişken arasında negatif bir ilişki vardır.

İMKB 100 Endeksi: Endeksler fiyatlardan hesaplanmaktadır. İMKB100 endeksi finansal sistem geliştikçe yükselmektedir. Yine diğer yatırım araçları için benchmark (fonun performans ölçütü) olarak kullanılan bu değişken ile yatırım fonu net varlık değeri arasında pozitif ilişki vardır. Çünkü İMKB 100 endeksi içinde yatırım fonu kurucuları olan bankalar yer almaktadır ve banka fonları değer kazandıkça endeks ve dolayısıyla yatırım fonu net varlık değeri de artmaktadır.

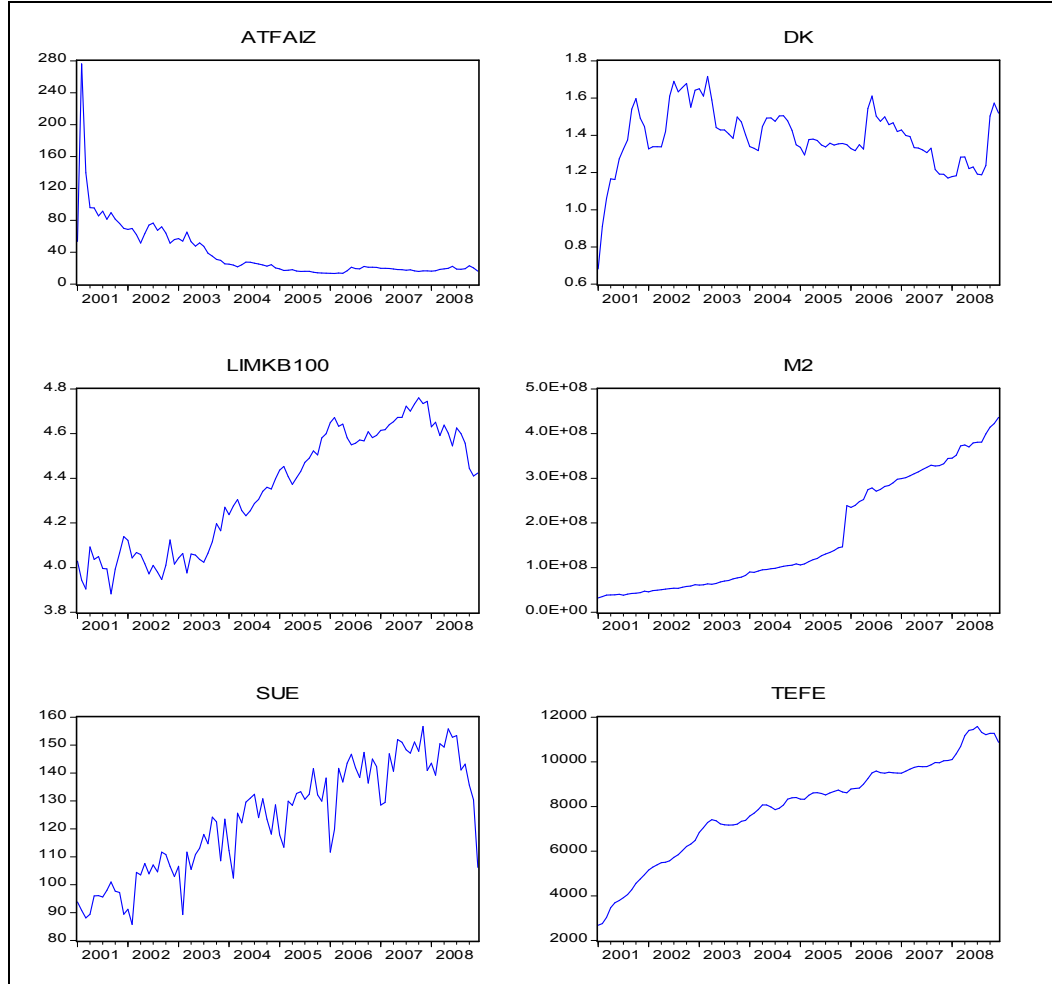
M2: M2/GSMH finansal derinleşmenin göstergesidir. Halkın bankacılık sistemini kullanımını göstermektedir. Para arzı arttığında faiz oranları düşecek ve tahvil fiyatları yükselecektir. Dolayısıyla yatırım fonu net varlık değeri de yükselecektir. O halde iki değişken arasında pozitif bir ilişki vardır.

$M1 = \text{Dolaşımdaki para} + \text{Vadesiz Mevduat}$

$M2 = M1 + \text{Vadeli Mevduat}$

Sanayi Üretim Endeksi: Sanayi Üretimi/GSMH oranını veren bir endekstir. Sanayinin bütün kollarının üretim sınıflarına göre (imalat %85, elektrik, madencilik olmak üzere) ağırlıklandırılmasından oluşmaktadır. Bu endeks arttığında GSMH da artıyor demektir, yani fiyatlar yükselmiştir. Bu durumda fon net varlık değeri de yükselmektedir. Dolayısıyla aralarında pozitif bir ilişki vardır.

TEFE Endeksi: TEFE endeksi ile fiyat düzeyi ölçülmektedir. Çünkü yurt içinde satışa konu olan mal ve hizmetleri kapsamaktadır. Enflasyonun da bir göstergesidir. TEFE endeksi arttığında fiyatlar arttığından yatırım fonu net varlık değerinin de artması beklenmektedir. Başka bir deyişle iki değişken arasında pozitif bir ilişki vardır.

Grafik 4.1: Bağımsız Değişkenlerin Orijinal Grafikleri

Yukarıdaki grafiklerden (Grafik 4.1) de görüleceği üzere, modelde kullanılan tüm bağımsız ve bağımlı değişkenlerin durağan olmadıkları görülmüştür. Her bir değişkende trend ya da mevsimsel hareketlilik izlenmiştir. Amacımız (4.2) nolu modelde değişkenler arasındaki gerçek ilişkiyi bulabilmek ve sahte regresyonla karşılaşmamak olduğundan, tüm değişkenlerin *logaritmik birinci sıra farkları* alınmış ve (4.2) nolu modele KEKK yöntemi uygulanmıştır. Burada fark serileri ile çalışıldığından, bağımsız değişkenlerin bağımlı değişken üzerinde mutlak değişimi söz konusu olmuştur.

Modeldeki değişkenlere ait ADF Birim-kök testi sonuçları aşağıdaki tablolarda verilmiştir.

Tablo 4.4: Bağımsız Değişkenlerin ve A Tipi Fonların ADF Birim-Kök Testi Sonuçları

<i>Değişkenler</i>	<i>ADF (Düzey)</i>		<i>ADF (Birinci Fark)</i>	
	<i>Gecikme Uzunluğu (k)</i>	<i>ADF İstatistiği</i>	<i>Gecikme Uzunluğu (k)</i>	<i>ADF İstatistiği</i>
<i>ATFAİZ</i>	4	-3.087*	1	-15.600*
<i>DK</i>	1	-2.887	1	-8.225*
<i>İMKB100</i>	1	-1.467	1	-11.359*
<i>M2</i>	1	-0.695	1	-10.757*
<i>SUE</i>	5	-1.738	4	-5.946*
<i>TEFE</i>	2	-2.695	1	-5.010*
A1	2	-1.778	1	-11.339*
A2	2	-2.487	1	-10.243*
A3	1	-2.320	1	-14.822*
A4	2	-0.457	2	-8.532*
A5	3	-0.975	2	-9.106*
A6	1	-2.882	1	-9.043*
A7	1	-2.459	2	-6.757*
A8	2	-1.538	3	-7.713*
A9	1	-1.812	1	-9.158*
A10	1	-2.538	2	-8.884*
A11	1	0.605	1	-9.904*
A12	1	-2.858	1	-10.189*
A13	2	-2.434	1	-11.086*
A14	1	-2.161	1	-11.642*
A15	1	-1.314	1	-8.117*
A16	1	-1.613	1	-10.620*
A17	2	-1.955	1	-11.034*
A18	1	-2.140	1	-9.4445*
A19	1	-1.715	2	-14.514*

*:0.05 anlamlılık düzeyinde serinin durağan olduğunu göstermektedir.

Tablo 4.4’de bağımsız değişkenler ve 19 adet A tipi yatırım fonu net varlık değerlerini temsil eden bağımlı değişkenlere ilişkin test istatistikleri gösterilmektedir. Birim kök denklemleri sabit terim içermekte olup gecikme değerleri (k), Akaike bilgi kriteri (AIC) kullanılarak hesaplanmıştır.

Mc Kinnon kritik değerleri,

$\alpha = 0.01$ için -3.503 ,

$\alpha = 0.05$ için -2.893 ,

$\alpha = 0.10$ için -2.583 ’tür.

Test istatistiklerine bakıldığında ADF katsayılarının tümü $\alpha=0.05$ düzeyinde anlamlıdır. Tüm değişkenlerin (ATFAİZ değişkeni hariç) düzeyde durağan olmadıkları ve birinci farkları alındığında durağan hale geldikleri tespit edilmiştir.

Tablo 4.5: B Tipi Fonların ADF Birim-Kök Testi Sonuçları

<i>Değişkenler</i>	<i>ADF (Düzye)</i>		<i>ADF (Birinci Fark)</i>	
	<i>Gecikme Uzunluğu (k)</i>	<i>ADF İstatistiği</i>	<i>Gecikme Uzunluğu (k)</i>	<i>ADF İstatistiği</i>
B1	1	-2.804	1	-10.180*
B2	2	-2.424	1	-10.614*
B3	4	-2.892	2	-8.868*
B4	3	-2.634	2	-8.794*
B5	1	-1.943	1	-14.324*
B6	3	-1.409	3	-4.991*
B7	4	-2.020	2	-9.124*
B8	1	-2.958	1	-22.556*
B9	1	-2.737	1	-11.734*
B10	1	-2.461	1	-9.545*
B11	4	-2.746	5	-3.211*
B12	2	-2.652	3	-3.330*
B13	3	-1.923	2	-9.171*
B14	3	-2.528	3	-7.267*
B15	3	-2.036	2	-7.778*
B16	1	-1.264	1	-13.303*
B17	3	-2.408	2	-7.751*
B18	2	-2.613	2	-8.330*
B19	3	-2.437	3	-8.447*

*:0.05 anlamlılık düzeyinde serinin durağan olduğunu göstermektedir.

Tablo 4.5’de 19 adet B tipi yatırım fonu net varlık değerlerini temsil eden bağımlı değişkenlere ilişkin test istatistikleri gösterilmektedir. Birim kök denklemleri sabit terim içermekte olup, gecikme değerleri (k), Akaike bilgi kriteri (AIC) kullanılarak hesaplanmıştır.

Test istatistiklerine bakıldığında ADF katsayılarının tümü $\alpha=0.05$ düzeyinde anlamlıdır yani tüm değişkenlerin düzeyde durağan olmadıkları birinci farkları alındığında durağan hale geldikleri tespit edilmiştir. Serilerin birinci dereceden farkları alındığında hepsinin %5 anlamlılık düzeyinde durağan hale geldikleri görülmektedir. Bu nedenle regresyon modelinde kullanılacak değişkenlerin birinci derece farkları alınarak uygulanacaktır.

Bir zaman serisinde belirli bir zaman sürecinde sürekli artma veya azalma olmuyorsa ve veriler zaman boyunca bir yatay eksen etrafında saçılım gösteriyorsa

bu seri durağandır (Sevüktekin ve Nargeleçekenler, 2007, 229). Serilerin durağan olması etkin ve tutarlı tahminler için gerekli olan bir varsayımdır. Oysa ekonomik zaman serileri zaman içinde artma eğilimindedir yani durağan değildirler. Klasik regresyon modeli varsayımları hem bağımlı ve bağımsız serilerin durağan olmasını hem de hataların sıfır ortalama ve sonlu varyansa sahip olmasını gerekli kılmaktadır. O halde durağan olmayan serilerle yapılan regresyon analizi ile sahte regresyonlar ortaya çıkabilir. Sahte regresyonda yüksek R^2 değerleri ve anlamlı t-istatistikleri söz konusu iken parametre tahmin sonuçları ekonomik yorum bakımından anlamsızdır. Fakat değişkenler arasında eşbütünleşme var ise değişkenler tek tek incelendiğinde durağan olmasa bile bu değişkenlerin doğrusal fonksiyonları alındığında serilerin birbirine ait trendi ortadan kaldırarak durağan hale gelmesine ve sahte regresyonun ortadan kalkmasına neden olmaktadır. Eşbütünleşme, durağan olmayan serilerin doğrusal bileşimlerinden elde edilen hata teriminin durağan olmasıdır. Eşbütünleşme olması için tüm serilerin aynı derecede durağan olması ve bu değişkenlerin doğrusal fonksiyonlarından elde edilen hata teriminin de durağan olması gerekir (Ertek, 2000, 392). Bu çalışmada kullanılan seriler aynı derecede (1) durağan ve hata terimlerinin de durağan olmasından dolayı -tahmin sonuçlarında da görüleceği üzere- sahte regresyon söz konusu değildir.

Serilerin durağanlığı belirlendikten sonra regresyon modelinde kullanılan bağımsız değişkenler arasında çoklu doğrusal bağlantı olup olmadığının tespiti için bağımsız değişkenler arasındaki korelasyon katsayıları Tablo 4.6'da gösterilmiştir.

Tablo 4.6: Bağımsız Değişkenler Arasındaki Korelasyon Katsayıları

	ATFAİZ	DK	İMKB100	M2	TEFE	SUE
ATFAİZ	1.000	0.526	-0.145	0.063	0.531	0.009
DK	0.526	1.000	-0.434	0.185	0.315	0.081
İMKB100	-0.145	-0.434	1.000	-0.079	0.098	-0.099
M2	0.063	0.185	-0.079	1.000	-0.033	0.130
TEFE	0.531	0.315	0.098	-0.033	1.000	0.073
SUE	0.009	0.081	-0.099	0.130	0.073	1.000

Tablo 4.6’da görüldüğü gibi bağımsız değişkenler arasındaki korelasyon katsayıları %54’ün altında kalmaktadır. Bu nedenle çoklu doğrusal bağlantı sorunu bulunmamaktadır.

Bu durumda verilerin analize uygun olduğu tespit edildikten sonra regresyon analizine geçilerek (4.2) nolu modele KEKK yöntemi uygulanmıştır. Daha sonra regresyon modeli ile yapılan tahminlerin geçerliliğini sağlayan ekonometrik varsayımların varlığı araştırılmıştır. Bu amaçla, modelde hata terimleri arasında ardışık bağımlılığın olup olmadığı yani *otokorelasyon* varlığının tespiti için Breusch-Godfrey Testi (BG testi, Serial Correlation LM Test) kullanılırken; modelde hata terimi standart sapmasının sabit olup olmadığı yani *değişen varyans* varlığının tespiti için ise White Testi (White General Heteroscedasticity Test) kullanılmıştır.

Çalışmada kullanılan testlerin hipotezleri aşağıdaki şekildedir:

ADF (Augmented Dickey-Fuller) Birim Kök Testi:

$H_0: \delta = 0$ Seri durağan değildir.

$H_1: \delta < 0$ Seri durağandır.

$\alpha=0,05$ anlamlılık düzeyi için, $P < \alpha$ ise H_0 red edilir ve seri durağan bir seridir denilir (Sevüktekin ve Nargeleçekenler, 2007, 344).

F Testi:

$H_0: \beta_1 = \beta_2 = \beta_3 = \beta_4 = \beta_5 = \beta_6 = \beta_7 = \beta_8 = 0$

$H_1: \beta_1 \neq \beta_2 \neq \beta_3 \neq \beta_4 \neq \beta_5 \neq \beta_6 \neq \beta_7 \neq \beta_8 \neq 0$

$\alpha=0,05$ anlamlılık düzeyi için, $F > F_{0,05}(k-1, n-k)$ ise H_0 red edilir, bağımsız değişkenler bağımlı değişkenler üzerinde etkilidir ve regresyon bütünüyle anlamlıdır denilir (Gujarati, 2004, 257). Burada n=örnek için seçilen gözlem sayısını, k=modeldeki değişken sayısını, k-1 ve n-k tablodaki serbestlik derecelerini ifade etmektedir. Modelimizde, n=95, k=7 ve serbestlik derecesi sırasıyla (6,88) olmak üzere F tablo değeri=2.25’dir.

BG (Breush-Godrey Serial Correlation LM Test) Testi:

$H_0: \rho = 0$ Otokorelasyon yoktur.

$H_1: \rho \neq 0$ Otokorelasyon vardır.

$\alpha=0,05$ anlamlılık düzeyi için, $P < \alpha$ H_0 red edilir ve modelde otokorelasyon vardır denilir (Gujarati, 2004, 257).

White (White Heteroskedasticity Test) Testi:

$H_0: \rho = 0$ Değişen varyanslılık yoktur.

$H_1: \rho \neq 0$ Değişen varyanslılık vardır.

$\alpha=0,05$ anlamlılık düzeyi için, $P < \alpha$ ise H_0 red edilir ve modelde değişen varyans sorunu vardır denilir (Ertek, 2000, 240).

4.4.1. Ampirik Uygulama

Bu bölümde, 6 adet makro ekonomik bağımsız değişkenin, 2001-2008 döneminde Türkiye’de faaliyet gösteren 19 adet A ve 19 adet B tipi olmak üzere toplam 38 adet yatırım fonunun net varlık değerlerinin gelecekteki değişimini açıklama gücü doğrusal regresyon yöntemiyle ölçülmektedir.

4.4.1.1. A Tipi Yatırım Fonlarına İlişkin Analiz Sonuçları

Bu bölümde, 19 adet A tipi yatırım fonunun net varlık değerleri ile 6 adet ekonomik değişken arasındaki ilişkiyi gösteren doğrusal regresyon modelleri tahmin edilmiştir. Tahmin edilen modellerde ekonometrik sorunların var olup olmadığının tespiti amacıyla gerekli testler yapılmıştır. Testlerin sonuçlarına göre ekonometrik sorunlar giderilerek modeller yeniden tahmin edilmiştir. Tahmin edilen modeller ve modellerde ekonometrik sorunların var olup olmadığının tespiti amacıyla yapılan testlerin sonuçları aşağıdaki tablolar ile sunulmuştur.

Tablo 4.7: Tahmin Edilen Modellerde Otokorelasyon ve Değişen Varyans Testi Sonuçları (A Tipi Fonlar)

<i>Modeller</i>	<i>Yapılan Testler</i>		<i>Sonuç</i>	
	<i>(BG) LM Testi</i>	<i>White Testi</i>	<i>Otokorelasyon Sorunu</i>	<i>Değişen Varyans Sorunu</i>
A1	1.603 (0.168)	1.053 (0.409)	Yok	Yok
A2	4.375 (0.001)	1.226 (0.279)	Var	Yok
A3	4.118 (0.002)	0.739 (0.709)	Var	Yok
A4	9.035 (0.000)	0.722 (0.725)	Var	Yok
A5	13.299 (0.000)	0.480 (0.920)	Var	Yok
A6	3.188 (0.011)	0.472 (0.925)	Var	Yok
A7	4.484 (0.001)	2.017 (0.032)	Var	Var
A8	4.331 (0.003)	0.337 (0.979)	Var	Yok
A9	4.969 (0.000)	2.594 (0.005)	Var	Yok
A10	8.889 (0.000)	1.582 (0.113)	Var	Yok
A11	0.271 (0.927)	2.881 (0.002)	Yok	Var
A12	0.567 (0.724)	0.508 (0.007)	Yok	Var
A13	10.421 (0.000)	0.922 (0.528)	Var	Yok
A14	1.488 (0.202)	0.492 (0.913)	Yok	Yok
A15	1.248 (0.293)	0.626 (0.813)	Yok	Yok
A16	0.062 (0.997)	0.741 (0.707)	Yok	Yok
A17	6.000 (0.000)	1.178 (0.311)	Var	Yok
A18	4.208 (0.001)	0.970 (0.483)	Var	Yok
A19	4.428 (0.001)	2.288 (0.014)	Var	Var

Parantez içindeki rakamlar F istatistiğine ilişkin olasılık (p) değerlerini ifade etmektedir.
Testler $\alpha=0.05$ anlamlılık düzeyinde yapılmıştır.

Tablo 4.7'ye göre, A tipi fon net varlık değerini tahmin eden modellere yapılan ekonometrik testler (LM ve White) sonucunda, bazı modellerde otokorelasyon, bazı modellerde değişen varyans ve bazı modellerde ise her iki sorun birden tespit edilmiştir. Otokorelasyon sorunu olan tüm modellere bağımlı değişkenin gecikmeli

değerleri alınarak, değişen varyans sorunu olan modellerde ise Newey-West Değişen Varyans düzeltmesi yapılarak modeller yeniden tahmin edilmiştir. A tipi fonlar için yapılan tahmin sonuçları aşağıdaki tablolar ile özetlenmiştir.

Tablo 4.8: A Tipi Fonlar İçin Regresyon Yöntemi Tahmin Sonuçları

	A1	A2	A3	A4	A5	A6	A7*	A8	A9	A10
β_0 (Sabit terim)	0.0005 (0.902) [0.122]	0.011 (0.679) [0.415]	-0.041 (0.240) [-1.182]	-0.042 (0.156) [-1.430]	-0.081 (0.312) [-1.016]	1,001 (0,731) [0,344]	-0.039 (0.548) [-0.601]	-0.025 (0.409) [-0.828]	-0.019 (0.444) [-0.767]	-0.097 (0.587) [-0.545]
β_1 (ATFAİZ)	-0.00021 (0.034) [-2.145]	-0.00083 (0.285) [-1.074]	0.00084 (0.400) [0.845]	0.00070 (0.397) [0.849]	0.00175 (0.441) [0.773]	-0.00051 (0.763) [-0.302]	0.00025 (0.896) [0.130]	0.00099 (0.254) [-1.147]	0.00032 (0.962) [0.046]	0.00136 (0.557) [0.589]
β_2 (DK)	-0.065 (0,645) [-0.461]	-0.360 (0.643) [-0.465]	0.127 (0.900) [0.125]	-0.549 (0.509) [-0.662]	1.980 (0.389) [0.865]	-2.838 (0.108) [-1.622]	-2.477 (0.393) [-0.857]	-0.731 (0.402) [-0.841]	-0.347 (0.633) [-0.479]	-2.001 (0.392) [-0.860]
β_3 (İMKB100)	0.424 (0.000) [7.017]	0.305 (0.356) [0.926]	1.278 (0.003) [3.028]	0.514 (0.135) [1.507]	1.391 (0.138) [1.495]	0.985 (0.173) [1.372]	0.955 (0.022) [2.320]	0.942 (0.010) [2.631]	0.467 (0.115) [1.590]	1.520 (0.121) [1.565]
β_4 (M2)	-0.008 (0.945) [-0.069]	-0.100 (0.874) [-0.158]	0.827 (0.323) [0.993]	0.357 (0.599) [0.527]	1.432 (0.442) [0.772]	0.543 (0.703) [0.381]	0.680 (0.601) [0.523]	-0.169 (0.811) [-0.239]	0.553 (0.338) [0.962]	1.208 (0.524) [0.639]
β_5 (SUE)	0.070 (0.411) [0.826]	0.333 (0.454) [0.751]	-0.353 (0.545) [-0.606]	-0.385 (0.416) [-0.816]	-0.810 (0.535) [-0.621]	-0.683 (0.494) [-0.685]	0.921 (0.292) [0.969]	0.391 (0.438) [0.777]	0.144 (0.725) [0.352]	0.097 (0.942) [0.072]
β_6 (TEFE)	1.158 (0.000) [3.473]	1.620 (0.439) [0.776]	-1.981 (0.466) [-0.732]	-0.541 (0.805) [-0.247]	-6.070 (0.316) [-1.007]	2.573 (0.579) [0.556]	0.403 (0.943) [0.070]	-2.354 (0.308) [-1.023]	0.500 (0.790) [0.267]	-2.657 (0.667) [-0.431]
β_7 (NVDi-1)		-0.427 (0.000) [-4.007]	-0.361 (0.000) [-3.844]	-0.610 (0.000) [-5.910]	-0.660 (0.000) [-6.418]	-0.324 (0.001) [-3.307]	-0.384 (0.014) [-2.494]	-0.390 (0.000) [-3.829]	-0.396 (0.000) [-3.779]	-0.571 (0.000) [-5.432]
B_8 (NVDi-2)		-0.249 (0.025) [-2.274]		-0.279 (0.007) [-2.734]	-0.330 (0.001) [-3.205]			-0.192 (0.058) [-1.916]	-0.139 (0.178) [-1.355]	-0.264 (0.011) [-2.580]
Düzeltilmiş R ²	0.495	0.146	0.217	0.295	0.292	0.136	0.144	0.217	0.106	0.292
F istatistiği	16.390 (0.000)	2.971 (0.005)	4.683 (0.000)	5.811 (0.000)	5.758 (0.000)	3.105 (0.005)	3.246 (0.004)	4.197 (0.000)	2.369 (0.023)	5.759 (0.000)
HKT	0.062	1.544	2.846	1.796	13.570	8.301	17.477	1.974	1.306	14.186
DW	2.207	2.045	2.160	2.116	2.150	2.118	2.189	2.125	2.204	2.139
NVD: Net Varlık Değeri, ATFAİZ: Aktif Tahvilin Faiz Oranı, DK: ABD Doları/TL Kuru, İMKB100: İMKB Ulusal 100 Endeksi, M2: Para Arzı, SUE: Sanayi Üretim Endeksi, TEFE: Toptan Eşya Fiyat Endeksidir.										
*İlgili modellerin katsayıları Newey-West değişen varyansa göre düzeltmeyi yansıtmaktadır.										
Katsayılar %5 anlamlılık düzeyinde istatistik olarak önemlidir.										
Parantez içindeki rakamların ilki ilgili katsayıların olasılık (p) değerini, köşeli parantez içindeki rakamlar ise t istatistik değerlerini ifade etmektedir.										

Tablo 4.9: A Tipi Fonlar İçin Regresyon Yöntemi Tahmin Sonuçları

	A11*	A12*	A13	A14	A15	A16	A17	A18	A19*
β_0 (Sabit terim)	-0.047 (0.036) [-2.123]	-0.003 (0.812) [-0.238]	-0.006 (0.884) [-0.146]	-0.006 (0.131) [-1.522]	-0.001 (0.818) [-0.229]	-0.004 (0.694) [-0.393]	-1,325 (0,518) [-0,521]	0.016 (0.755) [0.312]	-0.012 (0.556) [-0.591]
β_1 (ATFAİZ)	0.00057 (0.036) [2.125]	-0.00004 (0.986) [-0.016]	0.00036 (0.760) [0.305]	0.00007 (0.491) [0.691]	-0.00005 (0.834) [-0.210]	-0.00002 (0.901) [-0.124]	-0.00011 (0.925) [-0.094]	-0.00038 (0.798) [-0.256]	-0.00032 (0.363) [-0.914]
β_2 (DK)	0.141 (0.796) [0.258]	0.428 (0.379) [0.883]	-0.485 (0.684) [-0.408]	0.276 (0.059) [1.909]	0.013 (0.959) [0.051]	0.155 (0.646) [0.460]	-3.705 (0.003) [-3.012]	-0.440 (0.779) [-0.280]	0.394 (0.470) [0.725]
β_3 (İMKB100)	1.488 (0.015) [2.468]	1.044 (0.000) [4.246]	0.641 (0.185) [1.336]	0.761 (0.000) [12.370]	0.616 (0.000) [5.458]	0.965 (0.000) [6.736]	0.019 (0.968) [0.039]	0.948 (0.123) [1.557]	0.396 (0.009) [2.674]
β_4 (M2)	0.580 (0.041) [2.069]	0.118 (0.545) [0.606]	-0.049 (0.958) [-0.051]	0.100 (0.415) [0.817]	0.407 (0.075) [1.801]	0.144 (0.616) [0.502]	0.143 (0.887) [0.142]	0.649 (0.596) [0.532]	0.509 (0.000) [3.503]
β_5 (SUE)	0.113 (0.586) [0.546]	0.335 (0.061) [1.897]	-1.270 (0.070) [-1.830]	0.080 (0.357) [0.924]	-0.068 (0.669) [-0.428]	0.564 (0.006) [2.798]	0.011 (0.987) [0.016]	-1.314 (0.131) [-1.523]	-0.168 (0.660) [-0.441]
β_6 (TEFE)	-1.414 (0.080) [-1.768]	1.134 (0.294) [1.055]	-2.231 (0.478) [-0.712]	-0.612 (0.074) [1.803]	-0.394 (0.528) [-0.632]	0.173 (0.826) [0.219]	2.079 (0.526) [0.635]	1.276 (0.748) [0.321]	1.265 (0.254) [1.146]
β_7 (NVDi-1)			-0.663 (0,000) [-6.408]				-0.418 (0,000) [-4.715]	-0.460 (0,000) [-4.210]	-0.437 (0,047) [-2.008]
B_8 (NVDi-2)			-0.258 (0,011) [-2.581]					-0.198 (0,060) [-1.900]	-0.133 (0,417) [-0.814]
Düzeltilmiş R ²	0.270	0.318	0.347	0.637	0.279	0.375	0.247	0.164	0.155
F istatistiği	6.810 (0.000)	8.308 (0.000)	7.137 (0.000)	28.609 (0.000)	7.074 (0.000)	10.405 (0.000)	5.373 (0.000)	3.261 (0.002)	3.117 (0.003)
HKT	1.141	0.497	3.650	0.064	0.217	0.349	4.146	5.898	0.908
DW	2.055	2.022	2.185	2.064	1.675	1.960	2.265	2.109	2.114
NVD: Net Varlık Değeri, ATFAİZ: Aktif Tahvilin Faiz Oranı, DK: ABD Doları/TL Kuru, İMKB100: İMKB Ulusal 100 Endeksi, M2: Para Arzı, SUE: Sanayi Üretim Endeksi, TEFE: Toptan Eşya Fiyat Endeksidir.									
*İlgili modellerin katsayıları Newey-West değişen varyansa göre düzeltmeyi yansıtmaktadır.									
Katsayılar %5 anlamlılık düzeyinde istatistikî olarak önemlidir.									
Parantez içindeki rakamların ilki ilgili katsayıların olasılık (p) değerini, köşeli parantez içindeki rakamlar ise t istatistik değerlerini ifade etmektedir.									

Tablo 4.8 ve 4.9'da her bir değişken için tahmin edilen katsayı değerleri verilmektedir. Bu katsayıların altındaki parantezlerden ilki ilgili katsayıların olasılık (p) değerini, ikinci parantez içindeki rakamlar ise t istatistik değerlerini ifade etmektedir. Bu modellerin içerdiği denklemlere ait düzeltilmiş R², hata kareleri toplamı (HKT), F istatistik değeri ve Durbin-Watson (DW) d-istatistiği değerlerine yer verilmiştir.

Tablolarda yer alan 19 adet A tipi yatırım fonu regresyon analizi sonuçlarına göre, makro ekonomik değişkenlerin, fonların net varlık değerlerini açıklama

kabiliyetleri önemli farklılıklar göstermiştir. Net varlık değeri denklemlerinin düzeltilmiş R^2 ve HKT değerlerine bakıldığında iki modelde başarılı denebilecek sonuçların elde edildiği görülmektedir. En yüksek düzeltilmiş belirlilik katsayısı (R^2) değeri %63.7 olarak gerçekleşirken diğer düzeltilmiş R^2 değerleri %18 ile %49 değerleri arasında gerçekleşmiştir. R^2 değeri en yüksek olan fon %63.7 ile A14 koduyla anılan T.C. İş Bankası A Tipi Hisse Senedi Fonu'dur. Bu fonun HKT ise 0,064'dür. R^2 değerinin %63.7 olması ise yatırım fonu net varlık değerindeki değişmelerin yaklaşık %63.7'sinin analize alınan bağımsız değişkenlerde meydana gelen değişmelerden tarafından açıklandığını, kalan %36.3'ünün ise modele dâhil edilmeyen diğer değişkenlerin veya hata terimi tarafından açıklandığını ifade etmektedir. Ayrıca modellerin tümünde F değeri anlamlıdır. Modellerdeki katsayılar sıfırdan farklı ve anlamlıdır, yani regresyon modelleri uygun modellerdir.

Makro ekonomik değişkenlerin, yatırım fonu net varlık değerlerini açıklama güçleri ise fonlara göre farklılık göstermiştir. 19 adet A tipi yatırım fonu için yapılan tahmin modellerine bakıldığında genelde, A tipi fonların net varlık değerlerinin, İMKB-100 endeksine ve önceki dönem net varlık değerlerine duyarlı olduğu görülmektedir. Başka bir ifadeyle, β_3 , β_7 ve β_8 katsayıları istatistikî olarak anlamlıdır ve bağımlı değişkendeki değişimleri açıklamaktadır.

Ayrıca, diğer A tipi yatırım fonlarından farklı olarak, A1 koduyla anılan, Acar Yatırım Menkul Değerler A.Ş. A tipi Değişken Fon'unun ATFAİZ ve TEFE'ye ve A17 koduyla anılan Yapı Kredi Yatırım Menkul Değerler A.Ş. A tipi Değişken Fon'unun da DK'ya duyarlı olduğu görülmektedir. Bunun nedeni her iki fon tipinde de fon portföy sepetinde yer alan Hisse Senedi oranı ve sabit getirili menkullerin oranının diğer kıymetlere göre daha yüksek tutulmasıdır.

4.4.1.2. B Tipi Yatırım Fonlarına İlişkin Analiz Sonuçları

Bu bölümde, 19 adet B tipi yatırım fonu net varlık değerleri ile 6 adet ekonomik değişken arasındaki ilişkiyi gösteren doğrusal regresyon modelleri tahmin edilmiştir. Tahmin edilen modellerde ekonometrik sorunların var olup olmadığının tespiti amacıyla gerekli testler yapılmıştır. Testlerin sonuçlarına göre ekonometrik sorunlar giderilerek modeller yeniden tahmin edilmiştir. Tahmin edilen modeller ve

modellerde ekonometrik sorunların var olup olmadığının tespiti amacıyla yapılan testlerin sonuçları aşağıdaki tablolar ile sunulmuştur.

Tablo 4.10: Tahmin Edilen Modellerde Otokorelasyon ve Değişen Varyans Testi Sonuçları (B Tipi Fonlar)

<i>Modeller</i>	<i>Yapılan Testler</i>		<i>Sonuç</i>	
	<i>(BG) LM Testi</i>	<i>White Testi</i>	<i>Otokorelasyon Sorunu</i>	<i>Değişen Varyans Sorunu</i>
B1	7.420 (0.000)	0.545 (0.878)	Var	Yok
B2	7.766 (0.000)	0.735 (0.712)	Var	Yok
B3	10.864 (0.000)	0.689 (0.756)	Var	Yok
B4	9.242 (0.000)	0.676 (0.769)	Var	Yok
B5	4.280 (0.001)	2.740 (0.003)	Var	Var
B6	1.853 (0.111)	2.707 (0.003)	Yok	Var
B7	11.510 (0.000)	0.201 (0.998)	Var	Yok
B8	16.822 (0.000)	1.018 (0.439)	Var	Yok
B9	0.889 (0.492)	0.232 (0.996)	Yok	Yok
B10	0.143 (0.981)	0.211 (0.997)	Yok	Yok
B11	1.335 (0.257)	1.182 (0.309)	Yok	Yok
B12	0.551 (0.736)	2.190 (0.019)	Yok	Var
B13	10.609 (0.000)	1.921 (0.043)	Var	Var
B14	6.403 (0.000)	2.123 (0.023)	Var	Var
B15	12.152 (0.000)	1.469 (0.152)	Var	Yok
B16	2.617 (0.030)	0.989 (0.466)	Var	Yok
B17	8.474 (0.000)	1.941 (0.040)	Var	Var
B18	6.065 (0.000)	1.364 (0.199)	Var	Yok
B19	7.099 (0.000)	0.089 (0.999)	Var	Yok

Parantez içindeki rakamlar F istatistiğine ilişkin olasılık (p) değerlerini ifade etmektedir.

Testler $\alpha=0.05$ anlamlılık düzeyinde yapılmıştır.

Tablo 4.10'a göre, B tipi fon net varlık değerini tahmin eden modellere yapılan ekonometrik testler (LM ve White) sonucunda, bazı modellerde otokorelasyon, bazı modellerde değişen varyans ve bazı modellerde ise her iki sorun birden tespit edilmiştir. Otokorelasyon sorunu olan tüm modellere bağımlı değişkenin gecikmeli değerleri alınarak, değişen varyans sorunu olan modellerde ise Newey-West Değişen Varyans düzeltmesi yapılarak modeller yeniden tahmin edilmiştir. B tipi fonlar için yapılan tahmin sonuçları aşağıdaki tablolar ile özetlenmiştir.

Tablo 4.11: B Tipi Fonlar İçin Regresyon Yöntemi Tahmin Sonuçları

	B1	B2	B3	B4	B5*	B6*	B7	B8	B9	B10
β_0 (Sabit terim)	-0.071 (0.135) [-1.505]	-0.001 (0.919) [-0.100]	-0.012 (0.824) [-0.223]	-0.009 (0.882) [-0.148]	-0.040 (0.266) [-1.119]	0.018 (0.307) [1.025]	-0.008 (0.808) [-0.243]	0.032 (0.697) [0.390]	-0.008 (0.836) [-0.207]	-0.008 (0.820) [-0.227]
β_1 (ATFAİZ)	0.0031 (0.020) [2.358]	-0.0001 (0.729) [-0.346]	0.0008 (0.588) [0.543]	0.0010 (0.588) [0.542]	0.0012 (0.261) [1.130]	-0.0009 (0.162) [-1.409]	0.0008 (0.396) [0.851]	-0.0011 (0.644) [-0.463]	0.00038 (0.665) [0.433]	0.0004 (0.609) [0.512]
β_2 (DK)	-0.677 (0.622) [-0.493]	0.276 (0.610) [0.511]	-0.440 (0.777) [-0.283]	0.575 (0.761) [0.304]	-2.414 (0.104) [-1.641]	0.120 (0.916) [0.105]	-0.443 (0.664) [-0.435]	1.272 (0.598) [0.528]	-1.040 (0.409) [-0.828]	0.514 (0.663) [0.436]
β_3 (İMKB100)	0.808 (0.143) [1.475]	0.433 (0.048) [1.998]	-0.259 (0.681) [-0.412]	-0.537 (0.484) [-0.702]	0.237 (0.364) [0.911]	1.054 (0.053) [1.956]	-0.437 (0.289) [-1.065]	-0.652 (0.508) [-0.664]	0.851 (0.114) [1.595]	-0.112 (0.822) [-0.225]
β_4 (M2)	0.559 (0.613) [0.506]	0.055 (0.899) [0.126]	-0.032 (0.979) [-0.026]	-0.033 (0.982) [-0.022]	-0.086 (0.821) [-0.226]	-0.295 (0.231) [-1.205]	-0.120 (0.883) [-0.147]	-0.843 (0.664) [-0.435]	-0.125 (0.907) [-0.116]	0.062 (0.950) [0.062]
β_5 (SUE)	-0.554 (0.472) [-0.722]	-0.468 (0.129) [-1.529]	0.673 (0.444) [0.768]	0.781 (0.467) [0.729]	-0.383 (0.326) [-0.986]	-0.262 (0.359) [-0.921]	0.151 (0.792) [0.263]	1.207 (0.376) [0.888]	0.627 (0.406) [0.834]	0.114 (0.871) [0.162]
β_6 (TEFE)	-2.954 (0.408) [-0.830]	1.367 (0.341) [0.957]	3.035 (0.456) [0.748]	1.019 (0.837) [0.205]	0.751 (0.717) [0.363]	2.765 (0.119) [1.574]	0.475 (0.858) [0.178]	5.635 (0.374) [0.892]	-0.116 (0.968) [-0.039]	-0.429 (0.876) [-0.155]
β_7 (NVDi-1)	-0.502 (0.000) [-5.104]	-0.549 (0.000) [-5.427]	-0.657 (0.000) [-6.301]	-0.631 (0.000) [-6.093]	-0.439 (0.000) [-3.951]		-0.669 (0.000) [-6.534]	-0.750 (0.000) [-6.768]		
B_8 (NVDi-2)	-0.247 (0.019) [-2.382]	-0.254 (0.012) [-2.565]	-0.336 (0.001) [-3.224]	-0.322 (0.002) [-3.101]			-0.328 (0.01) [-3.208]	-0.115 (0.288) [-1.067]		
Düzeltilmiş R ²	0.232	0.258	0.276	0.268	0.221	0.207	0.289	0.464	0.001	-0.051
F istatistiği	4.486 (0.000)	5.018 (0.000)	5.402 (0.000)	5.231 (0.000)	4.771 (0.000)	5.089 (0.000)	5.691 (0.000)	10.972 (0.000)	1.018 (0.418)	0.073 (0.965)
HKT	4.737	0.749	6.143	9.216	2.020	1.353	2.657	14.872	4.854	4.281
DW	2.117	2.120	2.161	2.128	2.049	2.296	2.179	2.027	2.384	1.969
NVD: Net Varlık Değeri, ATFAİZ: Aktif Tahvilin Faiz Oranı, DK: ABD Doları/TL Kuru, İMKB100: İMKB Ulusal 100 Endeksi, M2: Para Arzi, SUE: Sanayi Üretim Endeksi, TEFE: Toptan Eşya Fiyat Endeksidir.										
*İlgili modellerin katsayıları Newey-West değişen varyansa göre düzeltmeyi yansıtmaktadır.										
Katsayılar %5 anlamlılık düzeyinde istatistikî olarak önemlidir.										
Parantez içindeki rakamların ilki ilgili katsayıların olasılık (p) değerini, köşeli parantez içindeki rakamlar ise t istatistik değerlerini ifade etmektedir.										

Tablo 4.12: B Tipi Fonlar İçin Regresyon Yöntemi Tahmin Sonuçları

	B11	B12*	B13*	B14*	B15	B16	B17*	B18	B19
β_0 (Sabit Terim)	-0.007 (0.679) [-0.414]	-0.007 (0.019) [-2.380]	-0.014 (0.773) [-0.288]	-0.012 (0.817) [-0.231]	-0.011 (0.841) [-0.200]	0.017 (0.749) [0.320]	-0.003 (0.877) [-0.154]	0.031 (0.643) [0.464]	-0.009 (0.792) [-0.263]
β_1 (ATFAİZ)	-0,0001 (0.682) [-0.410]	0.0006 (0.000) [6.036]	0.0009 (0.198) [1.296]	0.00008 (0.959) [0.055]	0.0008 (0.598) [0.527]	0.0004 (0.759) [0.307]	0.0007 (0.054) [1.952]	-0.0005 (0.785) [-0.272]	0.0011 (0.296) [1.050]
β_2 (DK)	-2.290 (0.000) [-3.975]	0.233 (0.013) [2.515]	0.880 (0.558) [0.587]	-0.730 (0.641) [-0.468]	1.384 (0.384) [0.874]	-2.245 (0.153) [-1.441]	1.146 (0.128) [1.534]	1.105 (0.567) [0.574]	0.360 (0.735) [0.338]
β_3 (İMKB100)	0.989 (0.000) [4.044]	-0.046 (0.182) [-1.342]	0.060 (0.808) [0.242]	0.389 (0.477) [0.713]	-0.034 (0.957) [-0.053]	1.069 (0.096) [1.679]	0.072 (0.545) [0.607]	0.255 (0.743) [0.329]	0.097 (0.821) [0.226]
β_4 (M2)	-0.261 (0.595) [-0.532]	-0.001 (0.979) [-0.025]	0.124 (0.758) [0.308]	-0.246 (0.658) [-0.443]	-0.048 (0.970) [-0.037]	0.164 (0.896) [0.130]	0.202 (0.419) [0.811]	-0.252 (0.871) [-0.162]	-0.059 (0.945) [-0.068]
β_5 (SUE)	0.077 (0.823) [0.223]	0.041 (0.465) [0.732]	-0.471 (0.729) [-0.347]	2.318 (0.058) [1.915]	0.052 (0.954) [0.057]	-0.280 (0.753) [-0.315]	-0.183 (0.748) [-0.321]	0.676 (0.540) [0.615]	0.404 (0.512) [0.658]
β_6 (TEFE)	5.118 (0.000) [3.791]	-0.537 (0.109) [-1.617]	-1.030 (0.765) [-0.299]	-0.403 (0.939) [-0.075]	0.516 (0.902) [0.122]	-1.411 (0.732) [-0.343]	-0.197 (0.905) [-0.119]	0.228 (0.964) [0.044]	-2.382 (0.400) [-0.845]
β_7 (NVDi-1)			-0.654 (0.000) [-4.756]	-0.651 (0.000) [-6.370]	-0.638 (0.000) [-6.070]	-0.307 (0.002) [-3,120]	-0.594 (0.000) [-3.853]	-0.450 (0.000) [-4.267]	-0.620 (0.000) [-5.893]
B_8 (NVDi-2)			-0.336 (0.013) [-2.522]	-0.302 (0.004) [-2.940]	-0.305 (0.005) [-2.863]		-0.280 (0.047) [-2.015]	-0.283 (0.008) [-2.685]	-0.255 (0.017) [-2.432]
Düzeltilmiş R ²	0.459	0.598	0.267	0.302	0.275	0.126	0.255	0.138	0.244
F istatistiği	14.292 (0.000)	24.333 (0.000)	5.204 (0.000)	5.998 (0.000)	5.371 (0.000)	2.926 (0.008)	4.937 (0.000)	2.848 (0.007)	4.719 (0.000)
HKT	1.019	0.032	9.970	9.625	6.438	6.555	2.168	9.574	2.973
DW	1.599	1.918	2.109	2.050	2.144	2.061	2.097	2.129	2.084
NVD: Net Varlık Değeri, ATFAİZ: Aktif Tahvilin Faiz Oranı, DK: ABD Doları/TL Kuru, İMKB100: İMKB Ulusal 100 Endeksi, M2: Para Arzu, SUE: Sanayi Üretim Endeksi, TEFE: Toptan Eşya Fiyat Endeksidir.									
*İlgili modellerin katsayıları Newey-West değişen varyansa göre düzeltmeyi yansıtmaktadır.									
Katsayılar %5 anlamlılık düzeyinde istatistikî olarak önemlidir.									
Parantez içindeki rakamların ilki ilgili katsayıların olasılık (p) değerini, köşeli parantez içindeki rakamlar ise t istatistik değerlerini ifade etmektedir.									

Tablo 4.11 ve 4.12’de her değişken için tahmin edilen katsayı değerleri verilmektedir. Bu katsayıların altındaki parantezlerden ilki ilgili katsayıların olasılık (p) değerini, ikinci parantez içindeki rakamlar ise t istatistik değerlerini ifade etmektedir. Bu modellerin içerdiği denklemlere ait düzeltilmiş R², hata kareler toplamı (HKT), F istatistik değeri ve Durbin-Watson (DW) d-istatistiği değerlerine yer verilmiştir.

Tablo 4.11 ve 4.12’ye göre, makro ekonomik değişkenlerin, 19 adet B tipi yatırım fonunun net varlık değerlerini açıklama kabiliyetleri önemli farklılıklar

göstermiştir. Net varlık değerini tahmin eden denklemlerin düzeltilmiş R^2 ve HKT değerlerine bakıldığında iki modelde başarılı denebilecek sonuçların elde edildiği görülmektedir. En yüksek düzeltilmiş belirlilik katsayısı (R^2) değeri %59.8 civarında gerçekleşirken; en düşük düzeltilmiş R^2 değeri %-0.05 olarak gerçekleşmiştir. Düzeltilmiş R^2 değeri en yüksek olan fon %59.8 ile B12 koduyla anılan T.C. İş Bankası B Tipi Likit Fonu'dur. Bu fonun HKT'si ise 0.032'dir. Bu değerinin %59.8 olması, yatırım fonu net varlık değerindeki değişmelerin yaklaşık %60'ının analize alınan bağımsız değişkenlerde meydana gelen değişmelerden tarafından açıklandığını, kalan %40'ının ise modele dâhil edilmeyen diğer değişkenlerin veya hata terimi tarafından açıklandığını ifade etmektedir. Ayrıca modellerin ikisi hariç diğerlerinde F değeri anlamlıdır. Modellerdeki katsayılar sıfırdan farklı ve anlamlıdır, o halde regresyon modelleri uygun modellerdir.

Makro ekonomik değişkenlerin, B tipi yatırım fonlarının net varlık değerlerini açıklama güçleri de farklılık göstermiştir. 19 adet B tipi yatırım fonu için yapılan tahmin modellerine bakıldığında, B tipi fonların net varlık değerlerinin, aktif tahvilin faiz oranına, döviz kuruna, TEFEM'e, İMKB-100 endeksine ve önceki dönem net varlık değerlerine duyarlı olduğu görülmektedir. Yani, β_1 , β_2 , β_3 , β_7 , β_6 ve β_8 katsayıları istatistikî olarak anlamlıdır ve bağımlı değişkendeki değişimleri açıklamaktadır.

4.5. Yapay Sinir Ağı Modeli

Bu çalışmada, seçilen makro ekonomik değişkenlerin yatırım fonu net varlık değerlerini açıklama gücünü ölçmede YSA modelinin nasıl kullanılması gerektiği araştırılmıştır. Yapılan birçok ampirik çalışma, YSA'larının iyi bilinen geleneksel metotlar kadar, hatta onlardan daha iyi sonuçlar verdiğini göstermektedir. Ayrıca YSA'larının özellikle doğrusal olmayan zaman serilerini tahmin edebilmekteki başarısı onun bir tahmin aracı olarak kullanılmasını sağlamıştır (Zhang, 1998, 40).

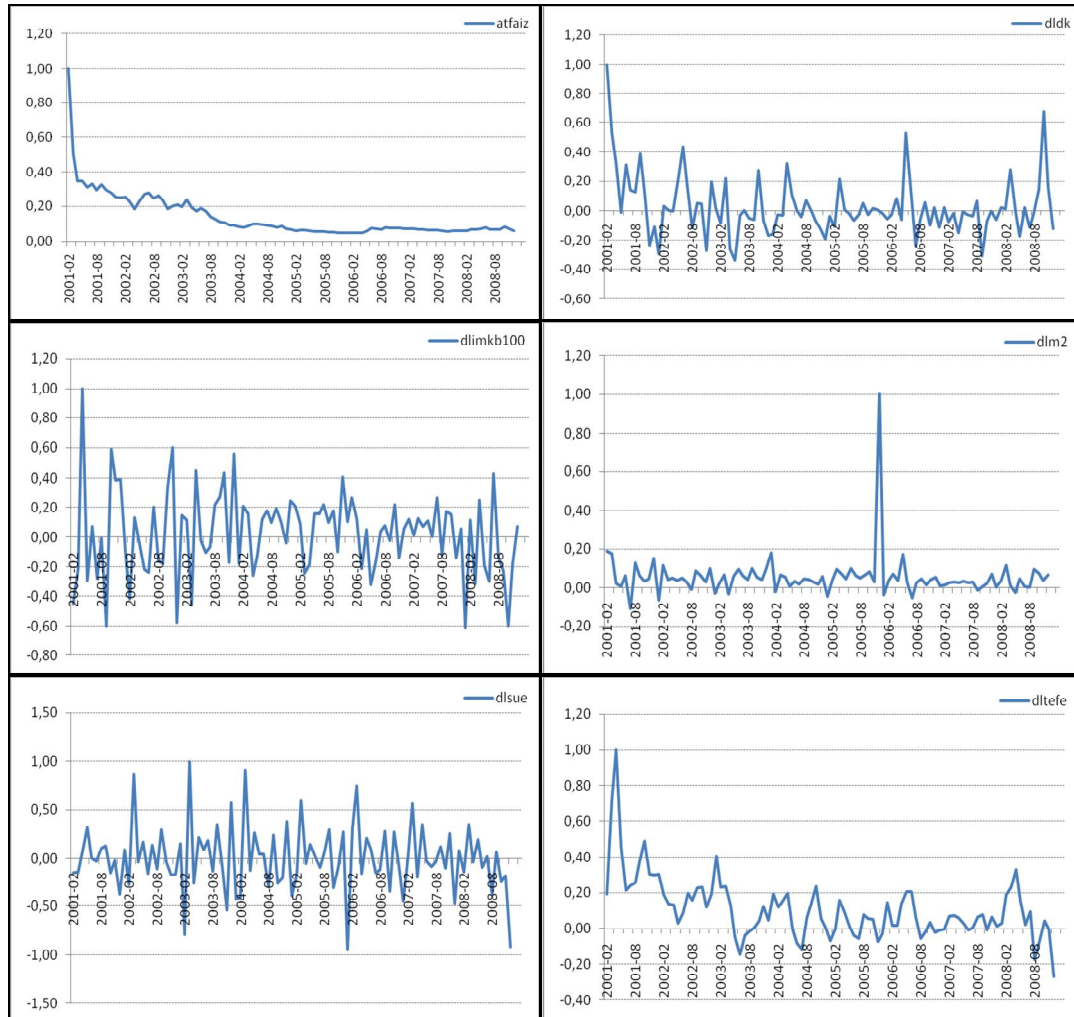
4.5.1. Çalışmada Kullanılan Verilerin Önışlemesi

Verilerin önışlemesi aşaması, eğitim ve test verilerinden oluşan veri gruplarının kurulan yapay sinir ağlarına uygun biçimde normalleştirilmesi demektir. Normalleştirme YSA'nın başarısını belirleyen en önemli etkenlerdendir. Ayrıca

verilerin ham veya işlenmiş halleriyle sisteme girilmesi, araştırmacının probleme dönük amacına göre belirlenmelidir (Kaastra ve Boyd, 1996, 222). Veri normalleştirme işlemi, gizli katman ile çıktı katmanında kullanılan aktivasyon fonksiyonları ile işlem elemanlarının çıktısının $[0,+1]$ veya $[-1,+1]$ aralığına sıkıştırma işlemidir (Zhang, 1998, 49).

Bu çalışmada veriler, doğrusal olmayan, mevsimsel etkiden arındırılmamış, trend içeren 6 adet bağımsız değişken ile A tipi ve B tipi yatırım fonları net varlık değerlerinden oluşan toplam 38 adet bağımlı değişkene ait zaman serilerinden oluşmaktadır. Bu nedenle seriler $(x_n = x_0/x_{max})$ eşitliği kullanılarak normalleştirilmiştir (Altan, 2008, 146) $[-1,1]$ aralığında normalleştirilmiştir. Elde edilen normalleştirilmiş bağımsız değişken serilerinin grafikleri aşağıda verilmiştir.

Grafik 4.2: Normalleştirilmiş Bağımsız Değişken Serilerinin Grafikleri



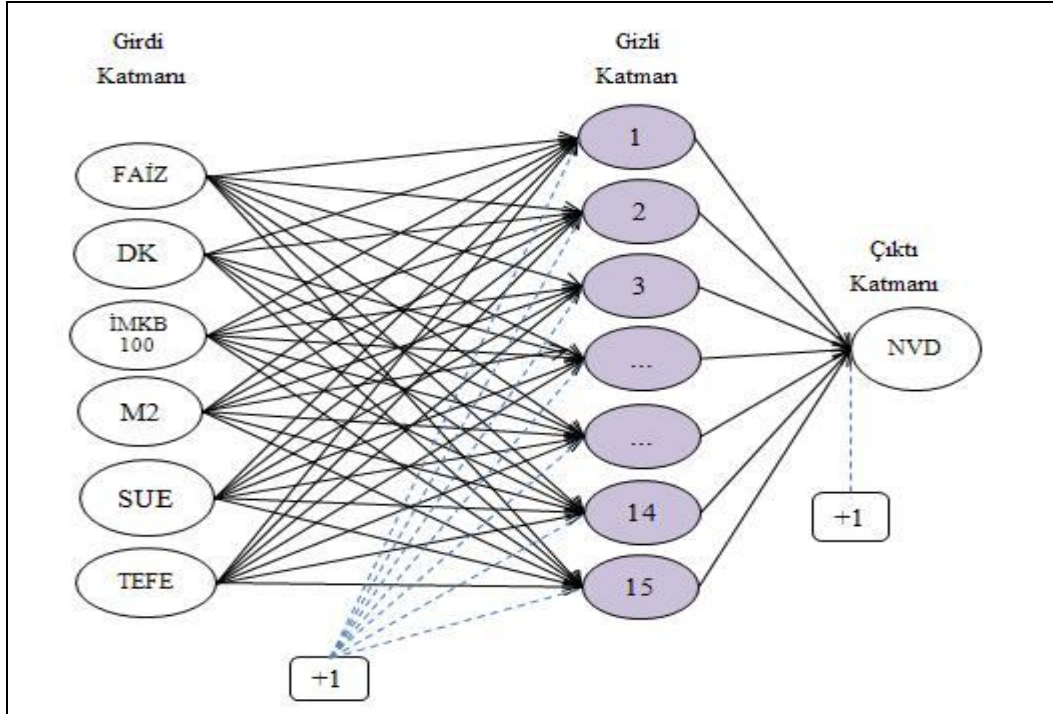
4.5.2. Çalışmada Kullanılan Ağ Mimarisi

Yatırım fonu net varlık değerini belirlemek için kurulan (4.2) nolu modelde girdi veri değeri olarak; Aktif Tahvilin Faiz Oranı (ATFAİZ), ABD Doları/TL Kuru (DK), İMKB-100 Endeksi (İMKB100), Para Arzı (M2), Sanayi Üretim Endeksi (SUE) ve Toptan Eşya Fiyat Endeksi (TEFE) serileri kullanılırken, çıktı veri değeri olarak 38 adet fonun net varlık değeri kullanılmıştır.

Yapay sinir ağı modeli için Neuro Solution 5 programı kullanılmıştır. Modelde (6) adet bağımsız değişken olduğu için, girdi katmanında bağımsız değişkenleri temsil eden (6) adet girdi nöronu kullanılmıştır. Çıktı katmanında ise bir bağımlı değişken olduğundan nöron sayısı (1) adet olarak belirlenmiştir. Değişik sayıda gizli nöronlarla ve gizli katman sayıları ile yapılan denemeler sonunda 9 adet fonda tek katmanlı ağ mimarisi iyi sonuçlar verirken, diğer fonlarda 2, 3 ve 4 katmanlı ağ mimarisinin iyi sonuçlar verdiği gözlemlenmiştir. Bu nedenle gizli katmandaki nöron sayısı fonlara göre değişkenlik göstermiş ve 3-15 adet aralığında belirlenmiştir.

Gizli katmanda ve çıktı katmanında aktivasyon fonksiyonu olarak hiperbolik tanjant ve Sigmoid fonksiyonları kullanılmıştır. Hem gizli katman hem de çıktı katmanı için eşik değer veya rastsal hata terimi kullanılmıştır. Bu terim Şekil 4.1'de kesikli çizgilerle gösterilmiştir. Ayrıca ağın başarısını belirleyen öğrenme algoritması yine her fon için farklı belirlenmiştir. Verilen bu parametrelere dayanarak danışmanlı öğrenme tekniği ile eğitilen, çok katmanlı ve ileri beslemeli (feedforward) yapay sinir ağı mimarisi oluşturulmuştur ve oluşturulan YSA tahmin modellerinin genel yapısı Şekil 4.1'de verilmiştir.

Şekil 4.1: YSA Tahmin Modeli



4.5.3. Ağın Eğitim ve Test Aşaması

Oluşturulan YSA modelinin çözümü için kullanılan veriler eğitim kümesi iken test kümesi ağın eğitim sürecinde görmediği verilerdir. Test kümesi ağın iyi öğrenip öğrenmediğini sınamaktadır. Literatürde eğitim test kümesi verileri %90, %10 veya %80, %20 ya da %70, %30 oranlarına göre belirlenmektedir (Zhang, 1998, 50). Bazı çalışmalarda ise veri seti, eğitim, doğrulama ve test seti olarak üç gruba ayrılmaktadır (Kaastra ve Boyd (1996); Sahoo ve Hathy (2007)).

Bu çalışmada, veri setinin %70'ini oluşturan ve Ocak 2001 - Ağustos 2006 dönemini kapsayan 67 adet veri eğitim seti olarak belirlenirken, %30'unu oluşturan ve Eylül 2006 - Aralık 2008 dönemini kapsayan 28 adet veri ise test seti olarak belirlenmiştir (Zhang (1998); Ray ve Vani (2004)). Test setinin bu aralıkta belirlenmesinin bir nedeni de dünyada 2006 yılında başlayan ve 2009 başlarına kadar etkisini gösteren küresel krizin ve mevsimsel etkilerin model tarafından kavranıp kavranmadığını gösterebilmektir.

Çok katmanlı bir YSA modelinde; gizli katman sayısı, gizli katmanda yer alacak nöron sayısı, gizli katman ve çıktı katmanındaki aktivasyon fonksiyonları ile öğrenme algoritmaları, öğrenme oranı ve momentum katsayısı gibi parametrelerin belirlenmesi ağın performansı açısından oldukça önemlidir. Fakat bu parametrelerin belirlenmesinde kesin bir yöntem olmamasından dolayı parametreler deneme yanılma yoluyla belirlenmiştir (Kaastra ve Boyd, 1996, 220-224). Denemeler sonucunda en iyi eğitim ve test sonuçlarını veren ağ yapılarına ilişkin parametreler A tipi ve B tipi fonlar için aşağıdaki tablolarda verilmektedir.

Tablo 4.13: A Tipi Fonlar İçin En Uygun YSA Modellerine İlişkin Parametreler

Model Parametreleri	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10
Girdi Nöronu Sayısı	6	6	6	6	6	6	6	6	6	6
Gizli Katman Sayısı	1	4	3	1	2	2	4	4	4	2
Gizli Katmandaki Nöron Sayısı	3	11	15	3	10	15	10	10	10	8
Gizli Katmandaki Transfer Fonksiyonu	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan
Öğrenme Algoritması	LM	MO	MO	LM	MO	MO	MO	MO	MO	MO
Çıktı Katmanındaki Nöron Sayısı	1	1	1	1	1	1	1	1	1	1
Çıktı Katmanındaki Transfer Fonksiyonu	Sig	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan
Öğrenme Algoritması	MO	MO	MO	MO	MO	MO	MO	MO	MO	MO
Model Parametreleri	A11	A12	A13	A14	A15	A16	A17	A18	A19	
Girdi Nöronu Sayısı	6	6	6	6	6	6	6	6	6	
Gizli Katman Sayısı	4	4	4	1	3	4	2	1	1	
Gizli Katmandaki Nöron Sayısı	15	10	15	6	15	10	10	3	4	
Gizli Katmandaki Transfer Fonksiyonu	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	
Öğrenme Algoritması	MO	MO	MO	MO	MO	MO	MO	LM	LM	
Çıktı Katmanındaki Nöron Sayısı	1	1	1	1	1	1	1	1	1	
Çıktı Katmanındaki Transfer Fonksiyonu	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	
Öğrenme Algoritması	MO	MO	MO	MO	MO	MO	MO	LM	LM	
Aktivasyon Fonksiyonları: Sig: Sigmoid Fonksiyonu, Tan: Tanjant Fonksiyonu										
Öğrenme Algoritmaları: MO: Momentum, LM: Levenberg-Marquart (Trainlm)										

Tablo 4.14: B Tipi Fonlar İçin En Uygun YSA Modellerine İlişkin Parametreler

Model Parametreleri	B1	B2	B 3	B4	B5	B6	B7	B8	B9	B10
Girdi Nöronu Sayısı	6	6	6	6	6	6	6	6	6	6
Gizli Katman Sayısı	2	4	3	4	4	3	4	4	3	4
Gizli Katmandaki Nöron Sayısı	15	15	15	15	6	15	15	11	14	11
Gizli Katmandaki Transfer Fonksiyonu	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan
Öğrenme Algoritması	MO	MO	MO	MO	MO	MO	MO	MO	MO	MO
Çıktı Katmanındaki Nöron Sayısı	1	1	1	1	1	1	1	1	1	1
Çıktı Katmanındaki Transfer Fonksiyonu	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan
Öğrenme Algoritması	MO	MO	MO	MO	MO	MO	MO	MO	MO	MO
Model Parametreleri	B11	B12	B13	B14	B15	B16	B17	B18	B19	
Girdi Nöronu Sayısı	6	6	6	6	6	6	6	6	6	
Gizli Katman Sayısı	1	3	4	1	2	1	2	3	1	
Gizli Katmandaki Nöron Sayısı	4	15	11	7	15	4	15	10	7	
Gizli Katmandaki Transfer Fonksiyonu	Tan	Tan	Tan	Tan	MO	Tan	MO	Tan	Tan	
Öğrenme Algoritması	LM	MO	MO	LM	1	LM	1	MO	LM	
Çıktı Katmanındaki Nöron Sayısı	1	1	1	1	Tan	1	Tan	1	1	
Çıktı Katmanındaki Transfer Fonksiyonu	Tan	Tan	Tan	Tan	MO	Tan	MO	Tan	Tan	
Öğrenme Algoritması	LM	MO	MO	LM	MO	LM	MO	MO	MO	
Aktivasyon Fonksiyonları: Sig: Sigmoid Fonksiyonu, Tan: Tanjant Fonksiyonu										
Öğrenme Algoritmaları: MO: Momentum, LM: Levenberg-Marquart (Trainlm)										

Kurulan YSA modelinin iyi bir tahmin edici olup olmadığının göstergesi olarak düzeltilmiş R^2 ile bölüm 2.11.5’de hesaplama yöntemlerine ilişkin denklemleri verilen ve ÇKA’ların performans ölçümlerinde sıkça kullanılan performans ölçütleri kullanılmıştır. Bu ölçütler, R^2 , (HKO-Mean Squared Errors) Hata Kareler Ortalaması, (HKT-Sum Squared Errors) Hata Kareler Toplamı ve (HKOK-Root Mean Squared Errors) Karekök Ortalama Hata Kareler gibi performans ölçütleridir. En uygun ağ yapısı, bu performans ölçütleri dikkate alınarak eğitim ve test aşamasındaki bulguların karşılaştırılması yoluyla elde edilmiştir.

4.5.3.1. A Tipi Yatırım Fonlarının Eğitim ve Test Aşamasına İlişkin Sonuçlar

YSA modelleri 1000 döngü (epoch) kullanılarak eğitilmiştir. Ağa gösterilen eğitim verileri ile elde edilen 19 adet A tipi yatırım fonu net varlık değerlerinin gerçek değerleri ile eğitim süreci sonrasında elde edilen tahmin değerlerine ve eğitim hatalarına ait grafikler düzenlenmiştir. Aynı biçimde test aşaması için de 19 adet A tipi yatırım fonu net varlık değerlerinin gerçek değerleri ile test süreci sonrasında elde edilen tahmin değerlerine ve test hatalarına ait grafikler düzenlenmiştir.

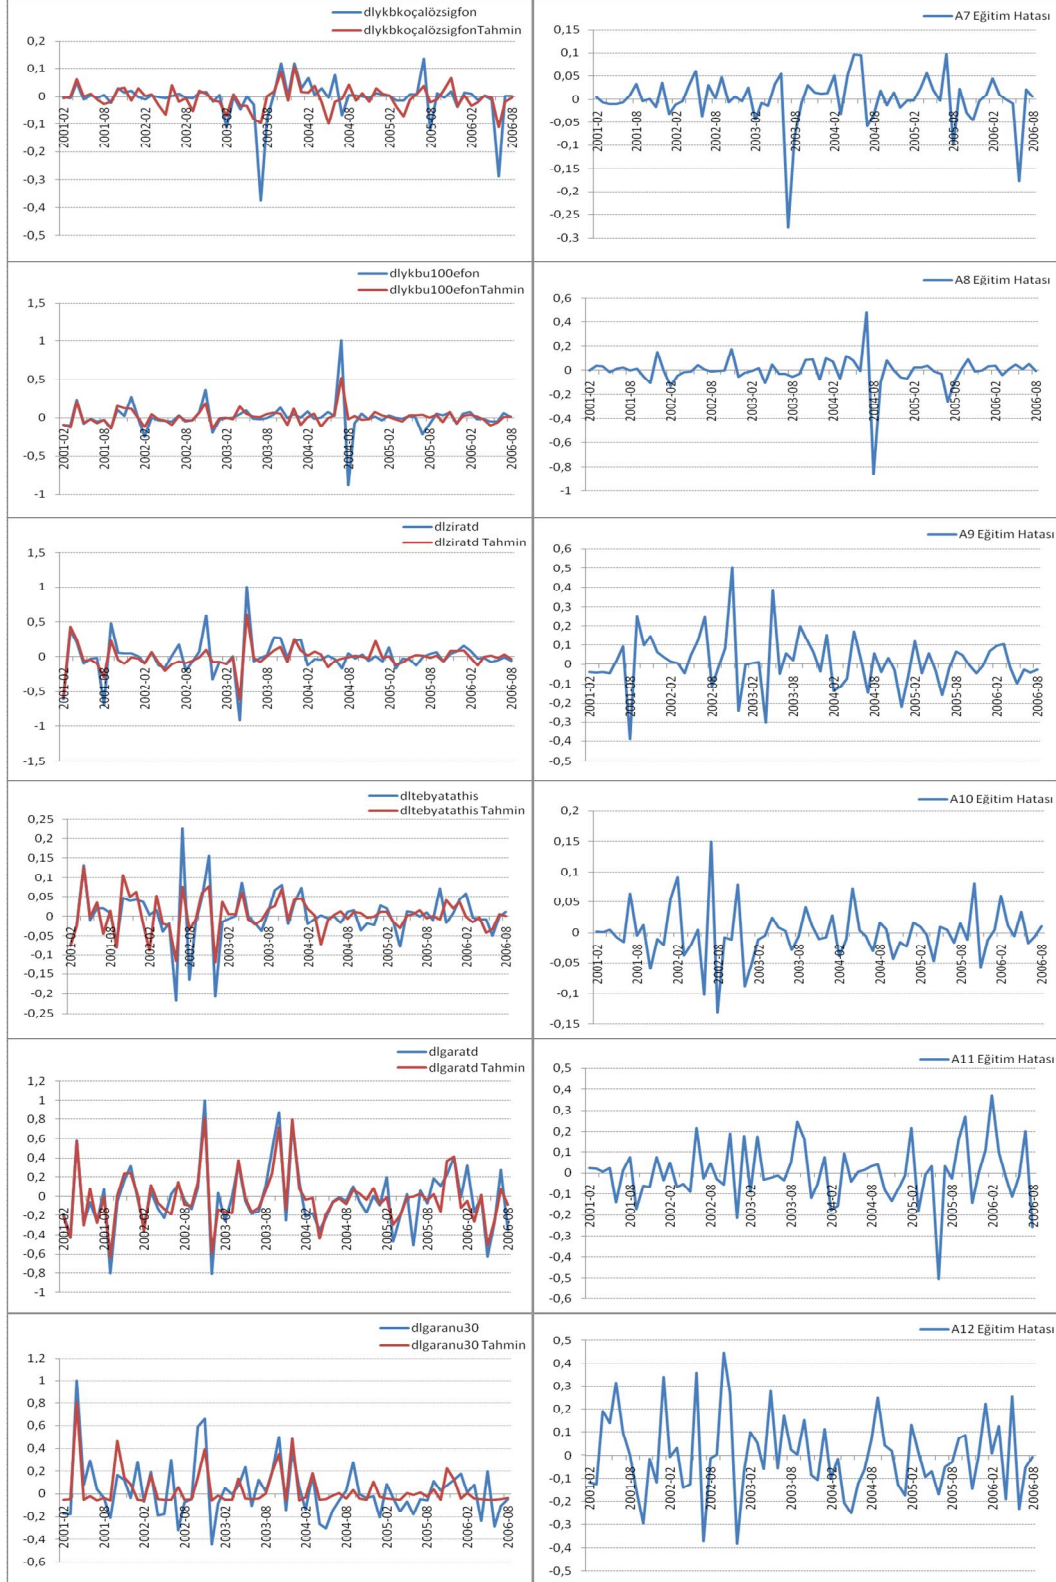
Bu bölümde, elde edilen sonuçların daha net görülebilmesi açısından öncelikle tüm A tipi fonlar için çok katmanlı YSA modelinin eğitim aşamasından sonra ürettiği çıktılara ait grafikler aşağıda verilmiştir. Burada yan yana verilen grafiklerden birincisi, her bir fonun gerçek net varlık değeri ile YSA modelinin eğitim aşamasından sonra elde ettiği tahmin değerlerini, ikincisi ise her bir fon için eğitim aşaması hata değerlerini göstermektedir.

Grafiklere göre, ağlar eğitme işlemini çok küçük hata oranı ile tamamladıklarından A tipi yatırım fonu net varlık değerlerinin gerçek değerleri ile eğitme aşamasından sonra elde edilen tahmin değerleri hemen hemen üst üste gelmektedir. Bu durum, eğitimin başarılı bir biçimde ve oldukça minimum bir hatayla tamamlandığı göstermektedir.

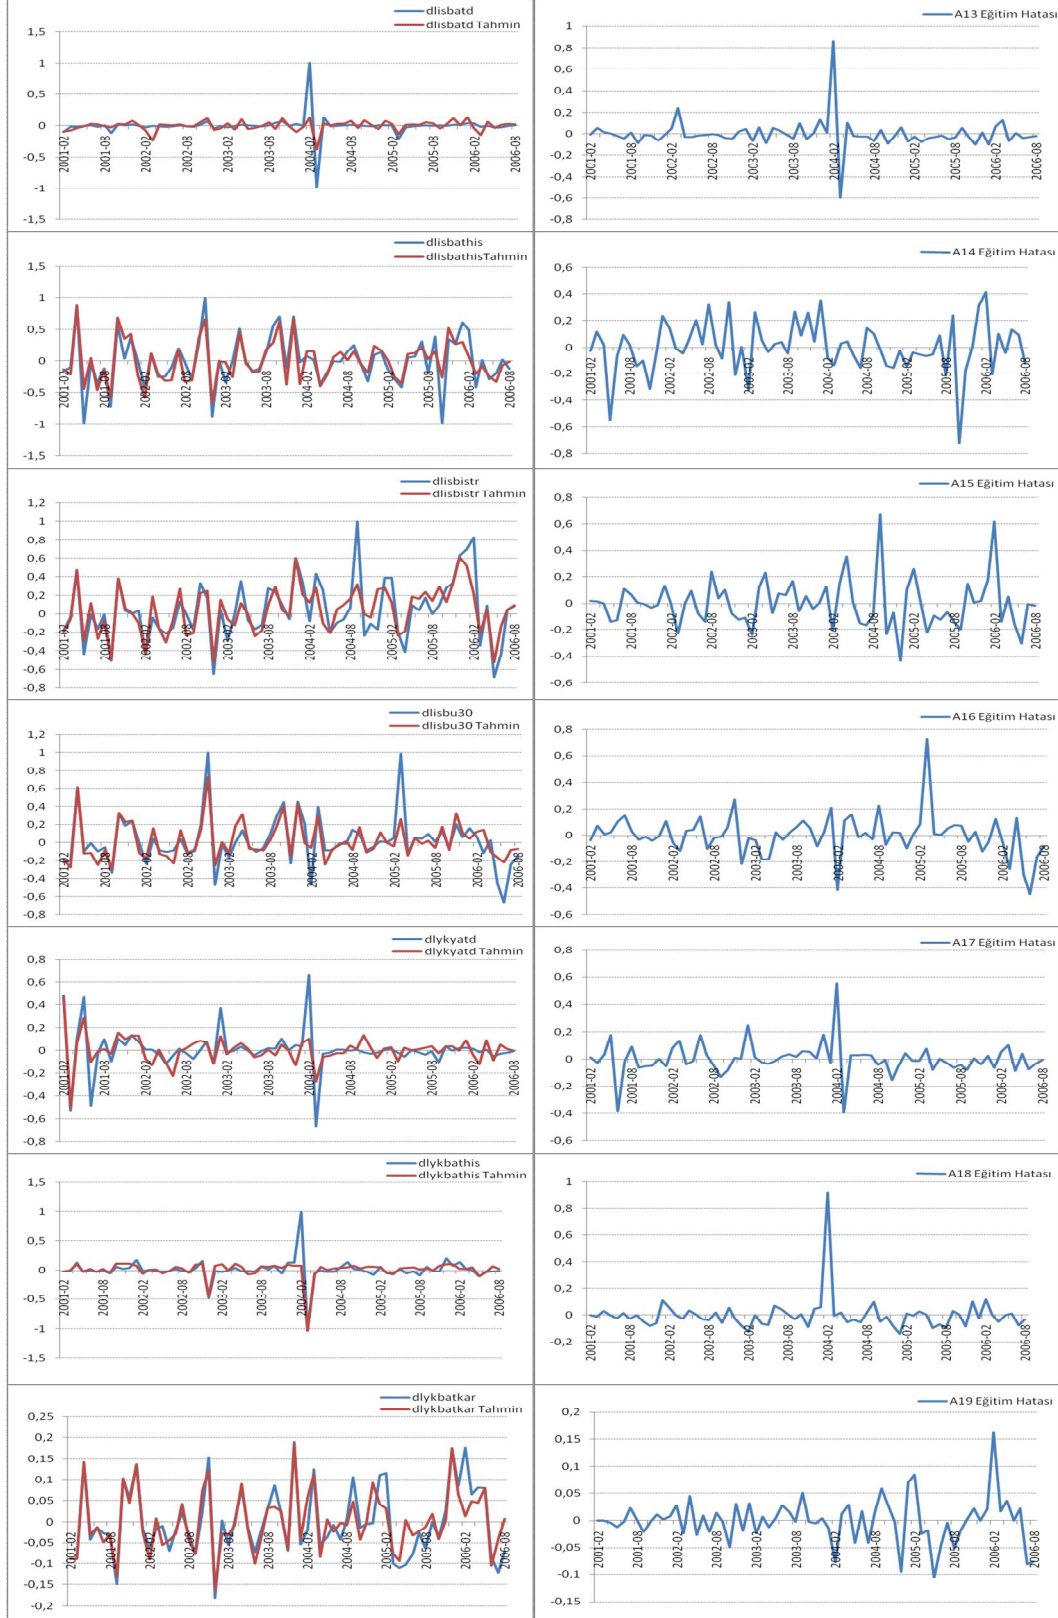
Grafik 4.3: Eğitim Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Eğitim Hatalarının Grafikleri (A Tipi Fonlar)



Grafik 4.4: Eğitim Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Eğitim Hatalarının Grafikleri (A Tipi Fonlar)



Grafik 4.5: Eğitim Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Eğitim Hatalarının Grafikleri (A Tipi Fonlar)

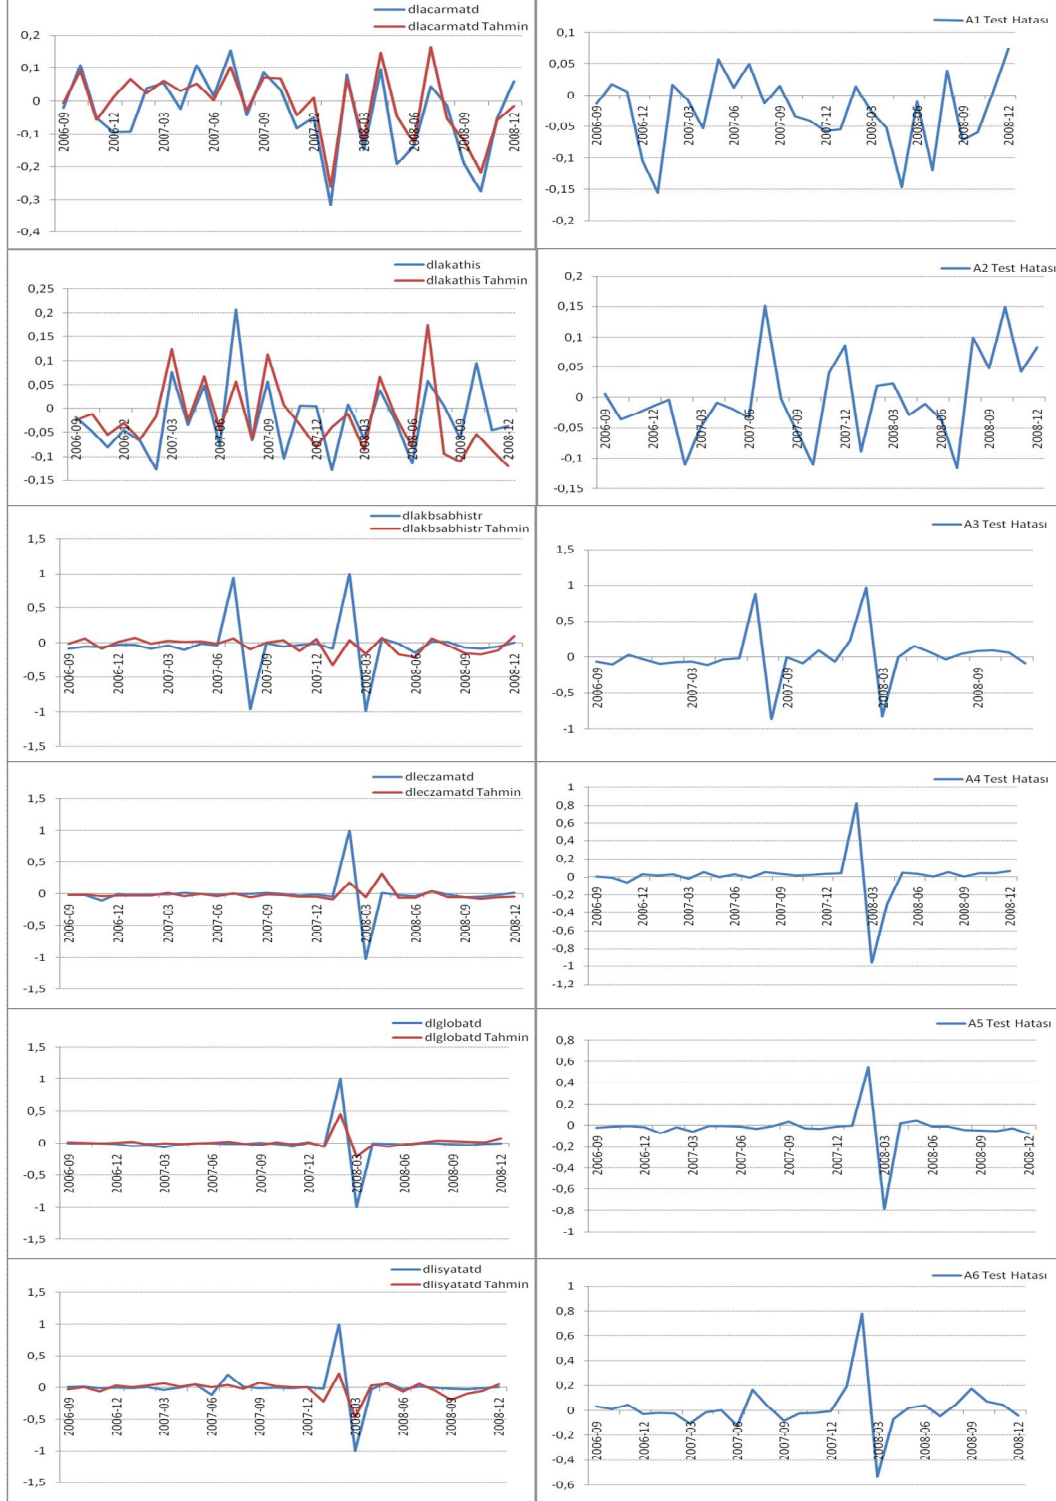


Grafik 4.3, 4.4 ve 4.5’de verilen eğitim hataları grafikleri incelendiğinde, ağların öğrenme işlemini iyi bir biçimde tamamladığı görülmektedir. Eğitim dönemini kapsayan zaman periyodu içerisinde Türkiye’de 2000 yılı Kasım ayında başlayan, Şubat 2001 yılında bir finansal kriz yaşanmış ardından 2004 yılında ise para ve sermaye piyasalarında kısa süreli bir volatilité artışı görülmüştür. İşte bu kriz ve yüksek volatilité dönemlerinde bile A tipi yatırım fonu net varlık değeri üzerindeki etkilerinin ve mevsimsel etkilerin YSA modeli tarafından kavranabildiği tespit edilmiştir. Kriz dönemlerinde de ağlar diğer dönemlerde olduğu gibi fazla bir sapma göstermemişlerdir. Buradan geliştirilen ağların, eğitim aşamasını başarıyla tamamladıkları ifade edilebilir.

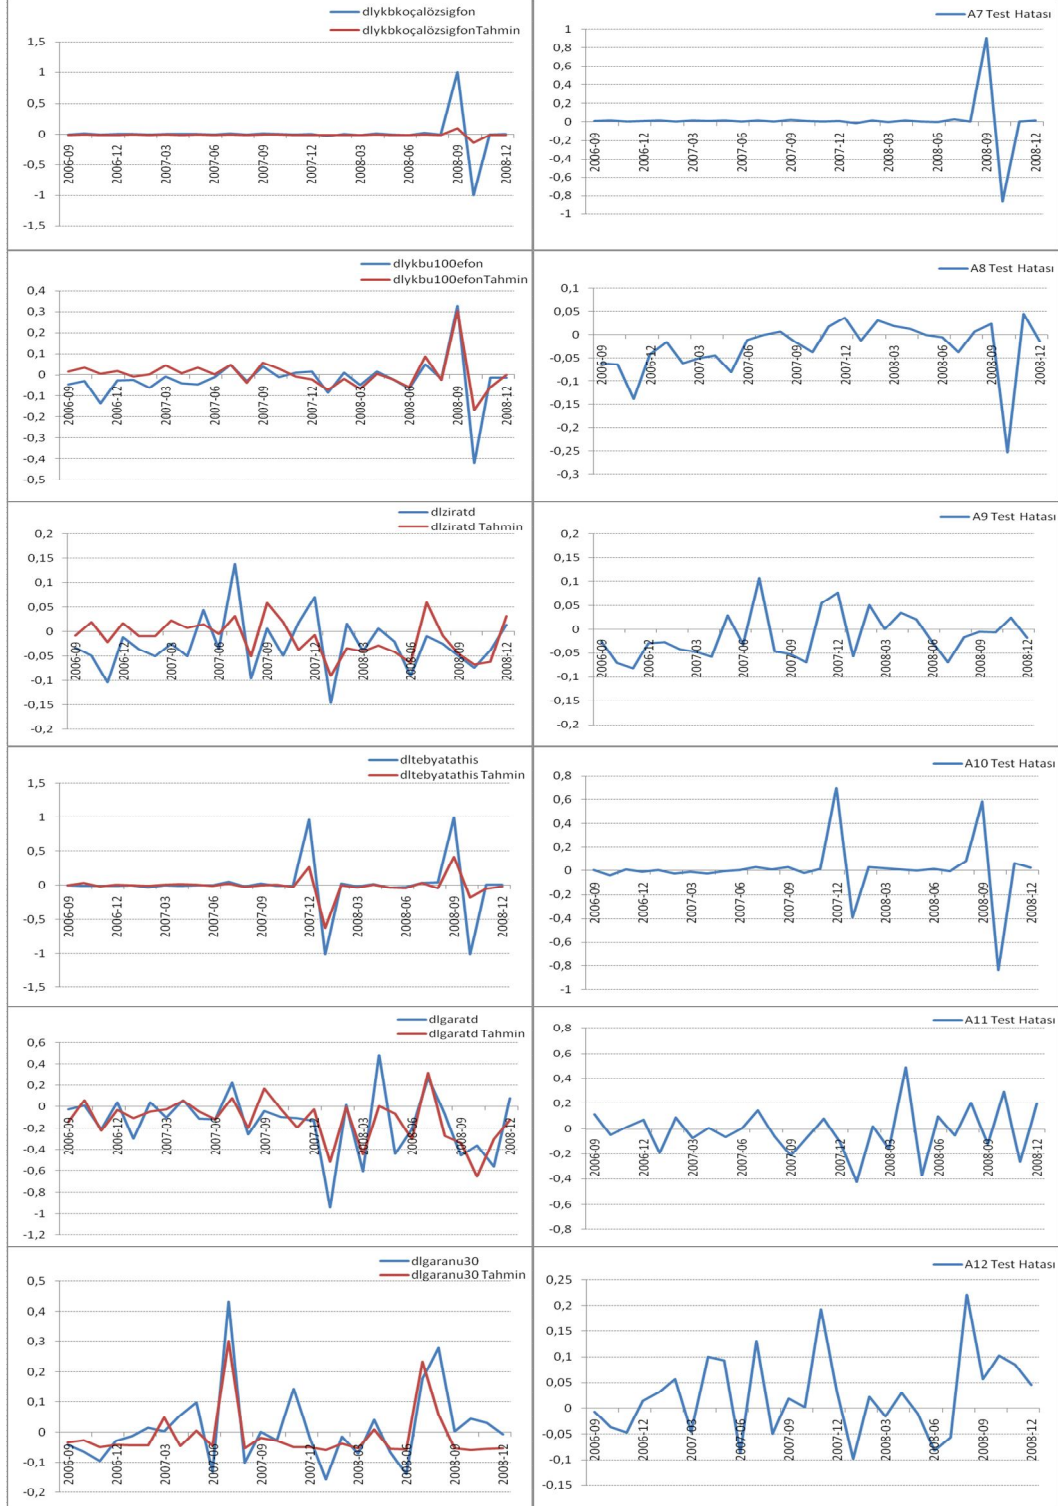
Eğitim aşamasının başarıyla tamamlanmasından sonra bu aşamada elde edilen ağırlıkların önceden ağa gösterilmemiş test verileri yardımıyla tüm YSA modeline genelleştirilmesi işlemi olarak adlandırılan test aşamasına geçilmiştir. Bu aşamada test veri seti olarak ayrılan değerler ve ağırlıklar kullanılarak oluşturulan ağ test edilmektedir.

A tipi fonlar için çok katmanlı YSA modelinin test aşamasından sonra ürettiği çıktılarına ait grafikler aşağıda verilmiştir. Burada yan yana verilen grafiklerden birincisi, her bir fonun gerçek net varlık değeri ile YSA modelinin test aşamasından sonra elde ettiği tahmin değerlerini, ikincisi ise her bir fon için test aşaması hata değerlerini göstermektedir.

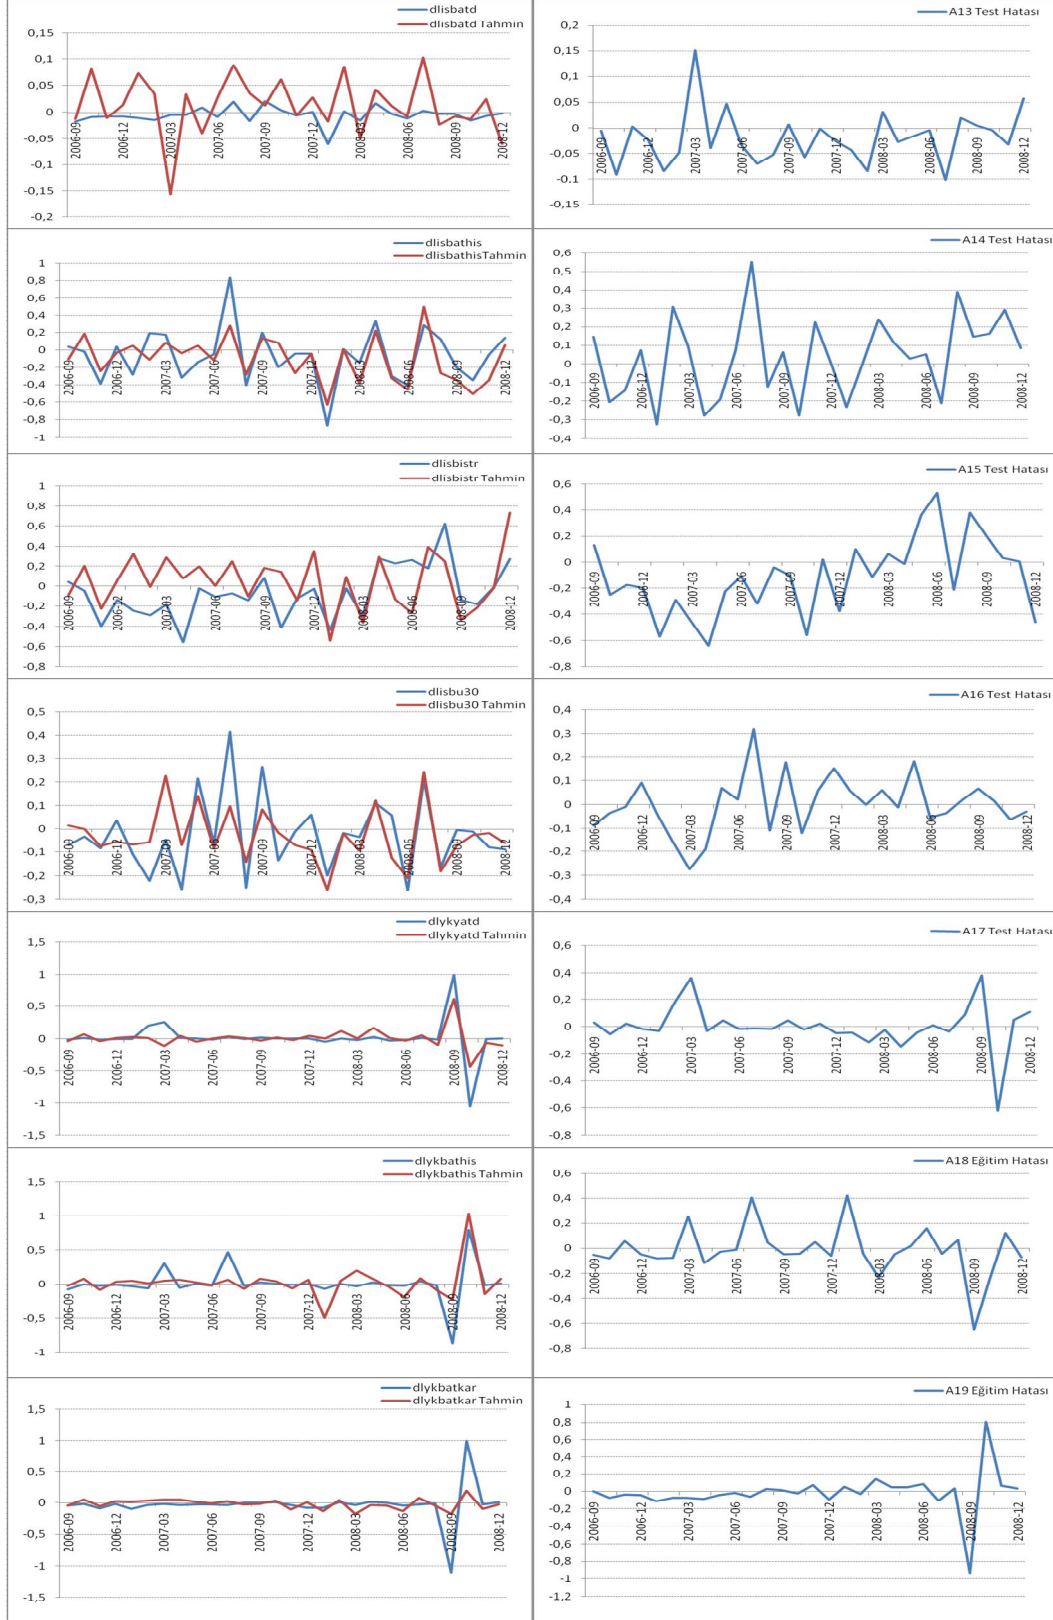
Grafik 4.6: Test Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Test Hatalarının Grafikleri (A Tipi Fonlar)



Grafik 4.7: Test Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Test Hatalarının Grafikleri (A Tipi Fonlar)



Grafik 4.8: Test Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Test Hatalarının Grafikleri (A Tipi Fonlar)



Bir yapay sinir ağının öğrenmesinin yeterli veya doğru olup olmadığı test kümesi ile sınılanmaktadır. Test aşaması sonuçlarını veren Grafik 4.6, 4.7 ve 4.8'e göre test aşaması da başarıyla tamamlanmıştır. Eğitim ve test aşamasından sonra oluşturulan YSA modellerinin tahmin başarısını ölçmek amacıyla R^2 , hata kareler toplamı, hata kareler ortalaması ve karekök ortalama hata kareleri hesaplanarak Tablo 4.15'deki bulgulara ulaşılmıştır.

Tablo 4.15: A Tipi Fonlar İçin Eğitim ve Test Aşaması Performans Göstergeleri

	<i>Eğitim Aşaması Sonrası</i>				<i>Test Aşaması Sonrası</i>			
	R^2	HKT	HKO	HKOK	R^2	HKT	HKO	HKOK
A1	0.93893	0.021498	0.000320	0.017912	0.75898	0.010831	0.000387	0.019667
A2	0.74131	0.820057	0.012239	0.110632	0.55709	0.132794	0.004743	0.068866
A3	0.71731	0.455605	0.006800	0.082462	0.47316	0.513904	0.018354	0.135475
A4	0.63711	0.123956	0.001850	0.043012	0.52812	0.172568	0.006163	0.078505
A5	0.78804	0.135746	0.002026	0.045011	0.57246	0.201485	0.007196	0.084828
A6	0.75327	0.352709	0.005264	0.072555	0.54640	0.463605	0.016557	0.128675
A7	0.74018	0.197293	0.002944	0.054264	0.53108	0.479344	0.017119	0.130841
A8	0.72611	0.193183	0.002883	0.053696	0.61495	0.242742	0.008669	0.093109
A9	0.72344	0.811667	0.012114	0.110065	0.53990	0.066758	0.002384	0.048828
A10	0.75834	0.121987	0.001820	0.042669	0.54289	0.791388	0.028264	0.168118
A11	0.82965	0.793897	0.011849	0.108854	0.74518	0.101136	0.003612	0.060099
A12	0.70545	0.190644	0.005284	0.053342	0.51973	0.393079	0.014039	0.118484
A13	0.60290	0.804814	0.012012	0.109599	0.52401	0.083018	0.002965	0.054451
A14	0.86903	0.771308	0.011512	0.107294	0.72247	0.018029	0.000644	0.025374
A15	0.83107	0.221823	0.003310	0.057539	0.60397	0.269498	0.009625	0.098106
A16	0.82770	0.833302	0.012437	0.111522	0.69938	0.049748	0.001777	0.042151
A17	0.74826	0.946193	0.014122	0.118837	0.53880	0.190898	0.006818	0.082569
A18	0.76803	0.414261	0.006183	0.078632	0.68052	0.104472	0.003731	0.061083
A19	0.86930	0.110294	0.001646	0.040573	0.62789	0.163361	0.005834	0.076382

Tablo 4.15'teki bulgular ile eğitim ve test aşaması sonuçlarını veren grafikler birlikte değerlendirildiğinde, ağların eğitim ve test aşamalarındaki hata paylarının oldukça düşük olduğu ve sifıra yaklaştığı görülmektedir. Başka bir deyişle, örneklem içi (in-sample) ve örneklem dışı (out-of-sample) dönemde çok katmanlı YSA modellerinin oldukça başarılı performans gösterdiği görülmektedir.

Örneklem içi dönemde, A1 koduyla anılan Acar Yatırım Menkul Değerler A.Ş. A Tipi Değişken Fonu'nun net varlık değerini tahmin etmek için geliştirilen çok katmanlı YSA modelinin R^2 değeri %93.89 olurken, HKT değeri ise 0.021498 ile en küçük düzeyde gerçekleşmiştir. En düşük R^2 değeri ise %70.54 A12 koduyla anılan

T. Garanti Bankası A.Ş. A Tipi İMKB-30 Endeks Fonu tahmin modeline aittir. Ancak bu modelin HKT değeri ise 0.190644 ile sıfıra yakın bir düzeyde gerçekleşmiştir.

Öngörü doğruluklarının karşılaştırılmasında örnekleme dışı öngörüler, model tahmininde kullanılmayan yeni verilere ait öngörülerden oluştuğundan daha büyük önem taşımaktadır. Bu durum dikkate alındığında, oluşturulan çok katmanlı YSA modelinin yatırım fonu net varlık değerini en başarılı biçimde tahmin ettiği fonun R^2 değeri %75.89 ile A1 koduyla anılan Acar Yatırım Menkul Değerler A.Ş. A Tipi Değişken Fonu olduğu görülmektedir. Bu fonun HKT değeri ise 0.010831 ile en düşük düzeyde gerçekleşmiştir. Genel olarak, bağımsız değişkenlerle fon net varlık değerleri arasında güçlü ve pozitif bir ilişkinin var olduğu görülmektedir. Değişkenler arasındaki bu ilişkinin tüm fonlarda %50'in üzerinde olduğu ve özellikle HKT'nin oldukça düşük düzeyde gerçekleştiği görülmektedir.

Modellerin oluşturulması sırasında değişkenlerin mevsimsel etkiden arındırılmamasına ve kukla değişkenler kullanılmamasına rağmen, yapay sinir ağı modelleri oldukça başarılı performans göstermişlerdir. Genel olarak geliştirilen yapay sinir ağı modellerinin, 2001'de Türkiye'de yaşanan ekonomik krizle ve 2007 yılı ortalarında ABD'de ortaya çıkan ve ilerleyen dönemlerde tüm dünya ekonomilerini olumsuz olarak etkileyen küresel ekonomik krizin A tipi yatırım fonu net varlık değerleri üzerindeki etkilerini iyi bir şekilde kavradığı tespit edilmiştir.

Tablo 4.15'deki bulgular ve yukarıda verilen eğitim ve test aşaması grafikleri, oluşturulan YSA modellerinin oldukça iyi sonuçlar verdiğini ve ağların eğitim ve test aşamalarını başarıyla tamamlamış olduğunu göstermektedir. Performans göstergelerinin olumlu olması YSA modellerinin öngörü için kullanılabileceğini göstermektedir. Ancak öngörü sonuçları karşılaştırmalı olarak son bölümde sunulacaktır.

4.5.3.2. B Tipi Yatırım Fonlarının Eğitim ve Test Aşamasına İlişkin Sonuçlar

B tipi yatırım fonları net varlık değerlerini tahmin etmek için geliştirilen YSA modelleri 1000 döngü (epoch) kullanılarak eğitilmiştir. Ağa gösterilen eğitim verileri ile elde edilen 19 adet B tipi yatırım fonu net varlık değerlerinin gerçek değerleri ile

eđitim s¼reci sonrasında elde edilen tahmin deęerlerine ve eđitim hatalarına ait grafikler d¼zenlenmiřtir. Test ařaması iin de 19 adet B tipi yatırım fonu net varlık deęerlerinin gerek deęerleri ile test s¼reci sonrasında elde edilen tahmin deęerlerine ve test hatalarına ait grafikler d¼zenlenmiřtir.

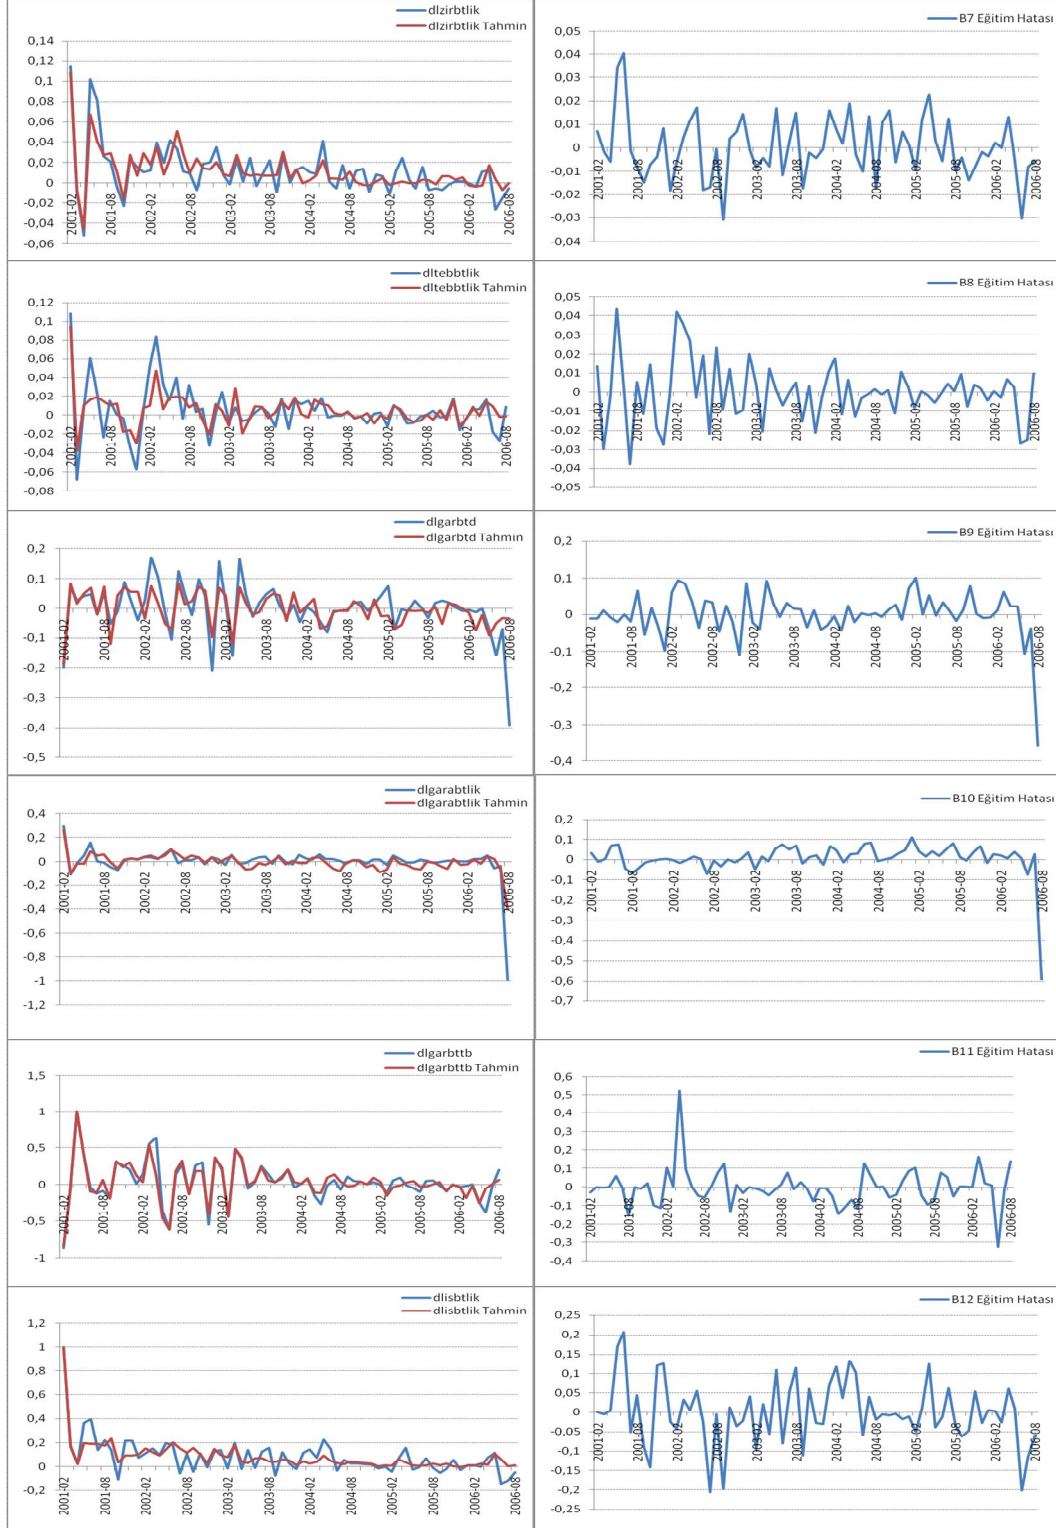
Bu b¼l¼mde, YSA modellemesinden elde edilen sonuların daha net g¼r¼lebilmesi iin ¼ncelikle t¼m B tipi fonlar iin ok katmanlı YSA modelinin eđitim ařamasından sonra ¼rettięi ıktılara ait grafikler ařaęıda verilmiřtir. Burada yan yana verilen grafiklerden birincisi, her bir fonun gerek net varlık deęeri ile YSA modelinin eđitim ařamasından sonra elde ettięi tahmin deęerlerini, ikincisi ise her bir fon iin eđitim ařaması hata deęerlerini g¼stermektedir.

Grafiklerden, geliřtirilen aęların eđitme iřlemine ok k¼¼k hata oranı ile tamamladıklarını ve B tipi yatırım fonu net varlık deęerlerinin gerek deęerleri ile eđitme ařamasından sonra elde edilen tahmin deęerleri hemen hemen ¼st ¼ste geldięi g¼r¼lmektedir. Bu durum, eđitimin bařarılı bir biimde ve olduka minimum bir hata ile tamamlandıęı g¼stermektedir.

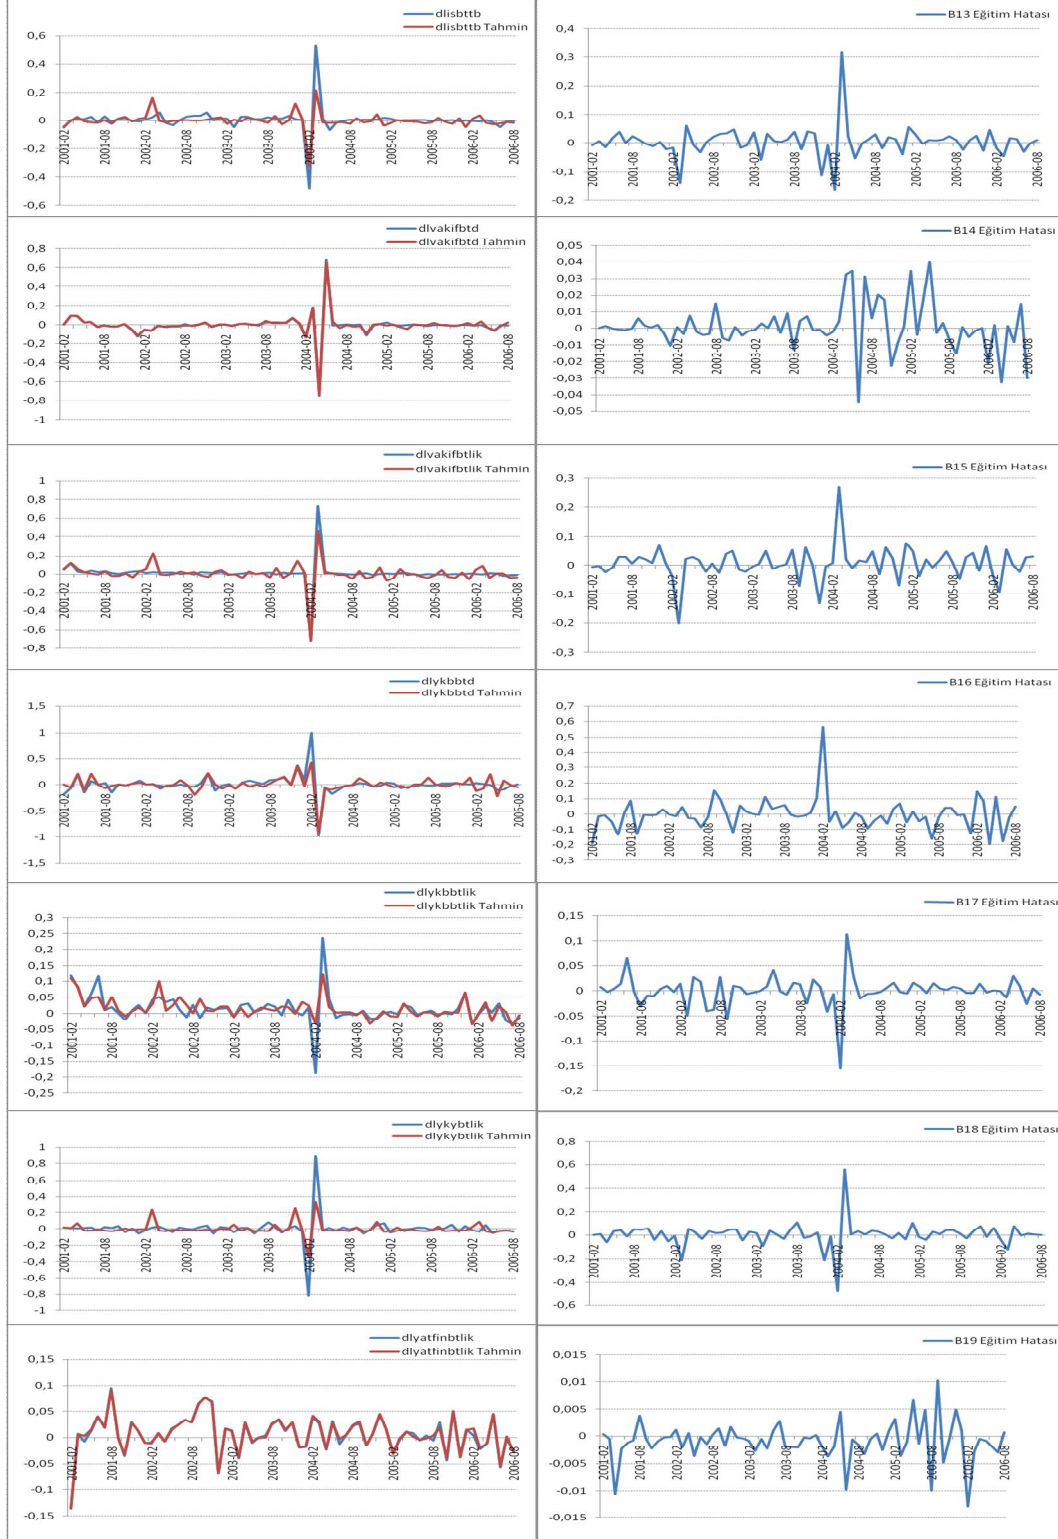
Grafik 4.9: Eğitim Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Eğitim Hatalarının Grafikleri (B Tipi Fonlar)



Grafik 4.10: Eğitim Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Eğitim Hatalarının Grafikleri (B Tipi Fonlar)



Grafik 4.11: Eğitim Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Eğitim Hatalarının Grafikleri (B Tipi Fonlar)

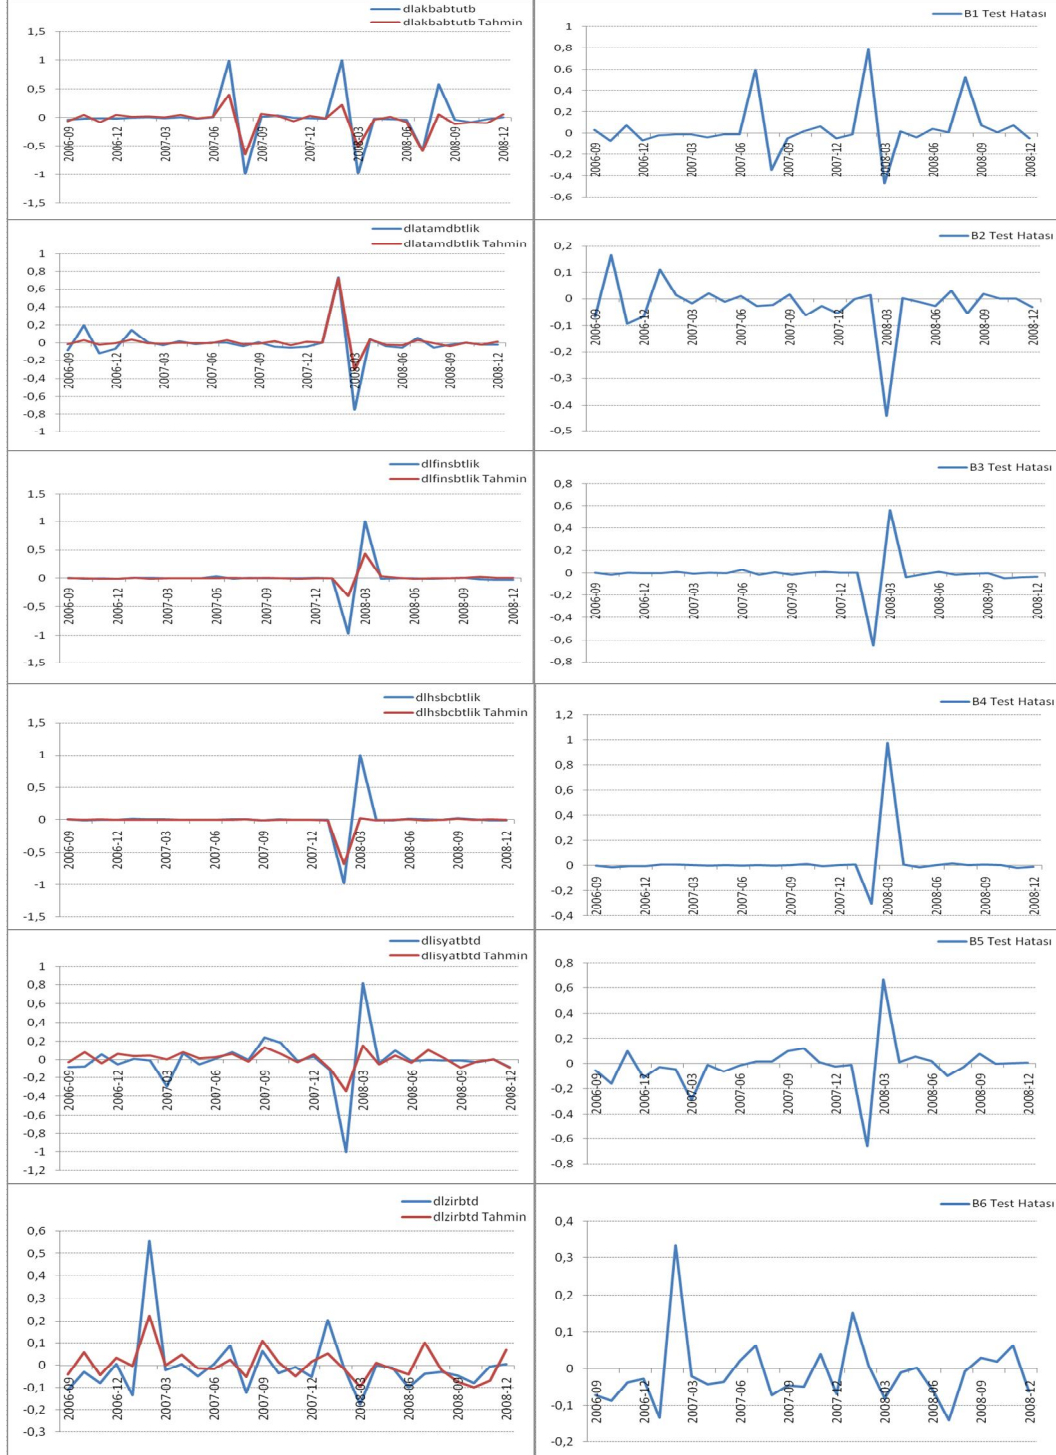


B tipi yatırım fonları için geliştirilen ağların eğitim aşaması grafiklerini veren Grafik 4.9, 4.10 ve 4.11 incelendiğinde, ağların öğrenme işlemini iyi bir biçimde tamamladığı görülmektedir. Ayrıca eğitim dönemi içinde ülkemizde yaşanan krizlerin ve mevsimsel etkilerin YSA modeli tarafından kavranabildiği görülmektedir. Kriz dönemlerinde de ağlar diğer dönemlerde olduğu gibi fazla bir sapma göstermemişlerdir. Bu durumda ağlar, eğitim aşamasını başarıyla tamamlamışlardır.

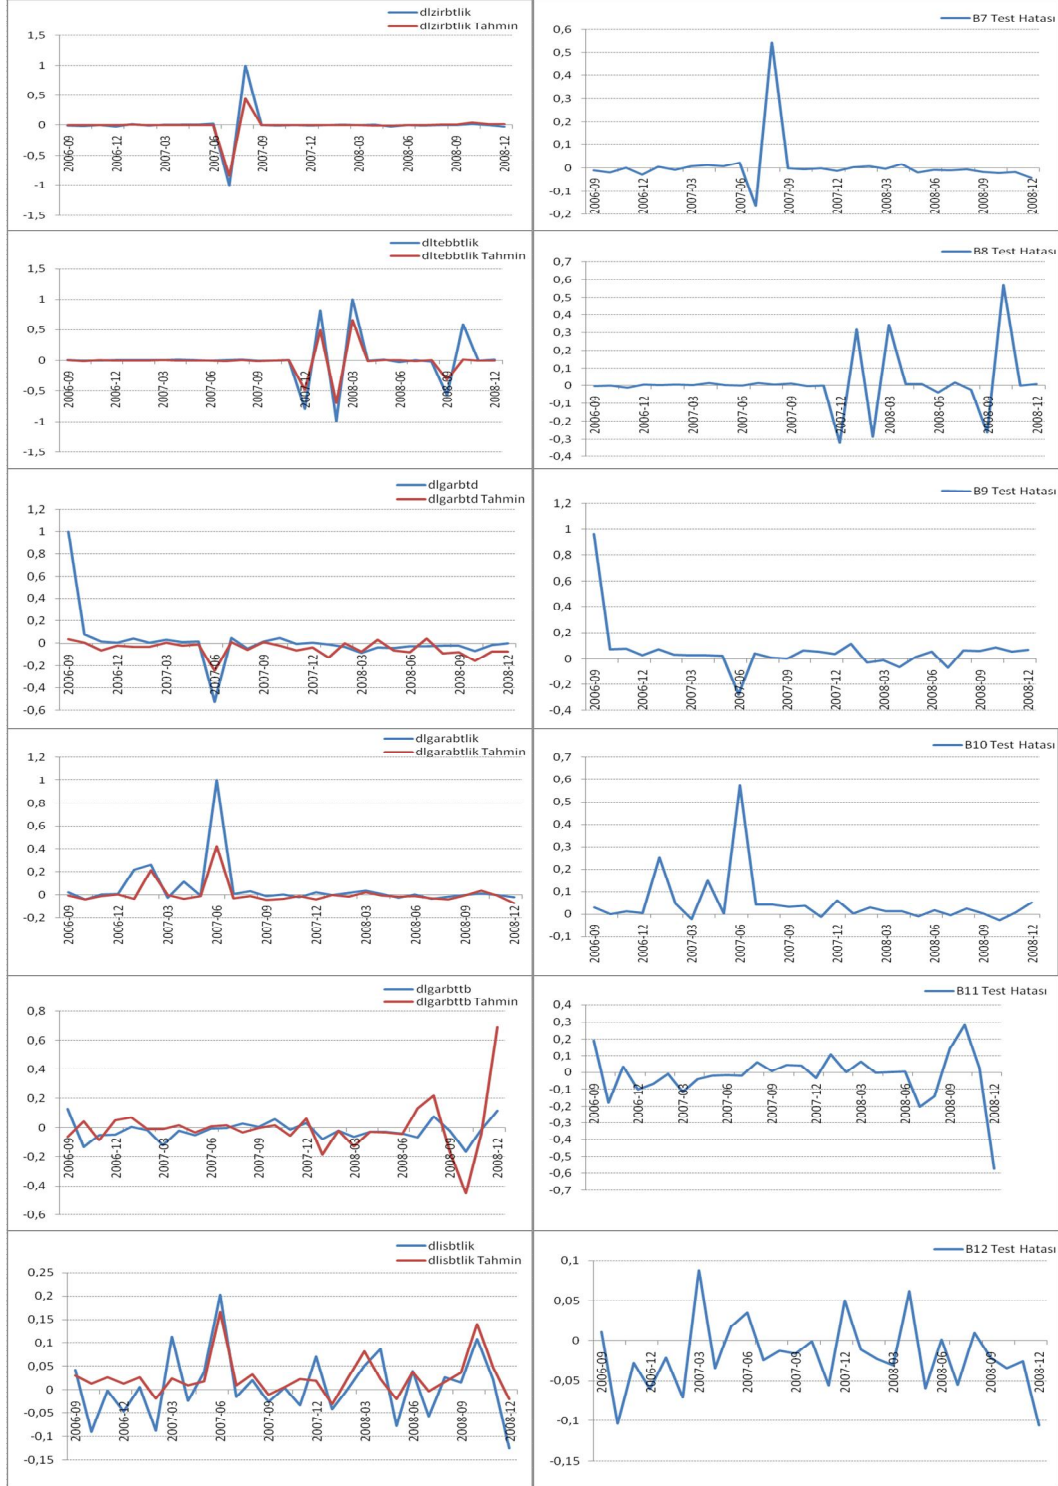
Başarıyla tamamlanan eğitim aşamasından sonra bu aşamada elde edilen ağırlıkların önceden ağa gösterilmemiş test verileri yardımıyla tüm YSA modeline genelleştirilmesi işlemi olarak adlandırılan test aşamasına geçilmiştir. Test aşamasında, test veri seti olarak ayrılan değerler ve ağırlıklar kullanılarak oluşturulan ağ test edilmektedir.

B tipi fonlar için çok katmanlı YSA modelinin test aşamasından sonra ürettiği çıktılarına ait grafikler aşağıda verilmiştir. Burada yan yana verilen grafiklerden birincisi, her bir fonun gerçek net varlık değeri ile YSA modelinin test aşamasından sonra elde ettiği tahmin değerlerini, ikincisi ise her bir fon için test aşaması hata değerlerini göstermektedir.

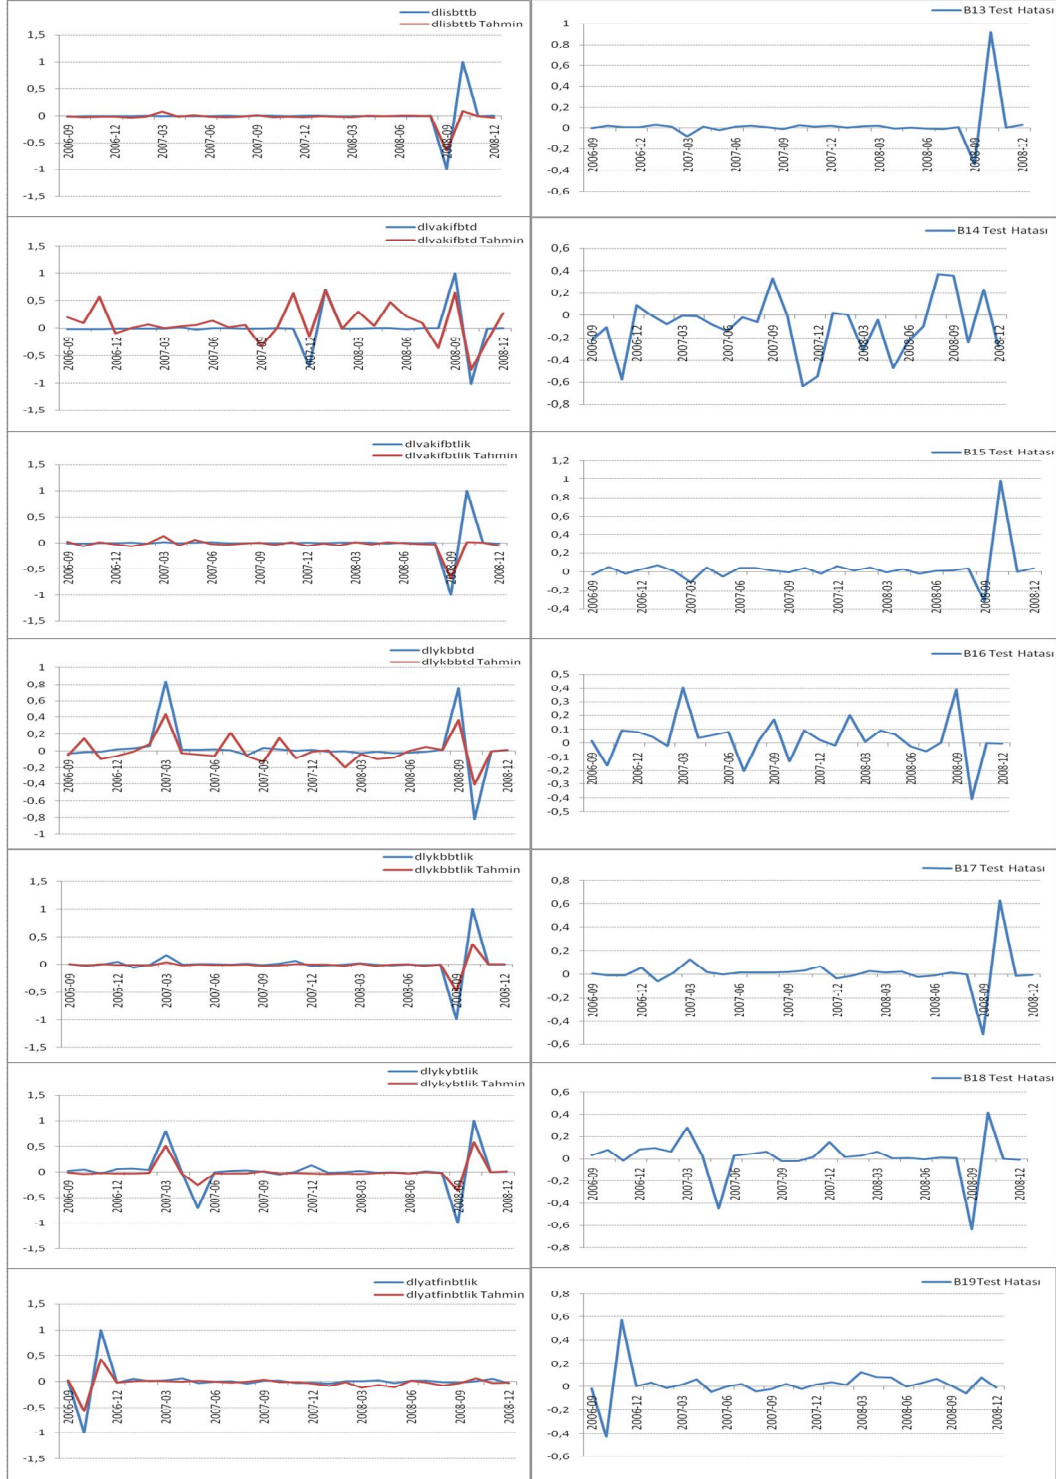
Grafik 4.12: Test Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Test Hatalarının Grafikleri (B Tipi Fonlar)



Grafik 4.13: Test Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Test Hatalarının Grafikleri (B Tipi Fonlar)



Grafik 4.14: Test Aşamasından Sonra Gerçek-Tahmini Değerlerin ve Test Hatalarının Grafikleri (B Tipi Fonlar)



Geliştirilen bir yapay sinir ağı modelinin öğrenmesinin yeterli veya doğru olup olmadığı test kümesi ile sınımlanmaktadır. Test aşaması sonuçlarını veren Grafik 4.12, 4.13 ve 4.14’de göre test aşaması da başarıyla tamamlanmıştır. Eğitim ve test aşamasından sonra oluşturulan YSA modellerinin tahmin başarısını ölçmek amacıyla R^2 , hata kareler toplamı, hata kareler ortalaması ve karekök ortalama hata kareleri hesaplanarak Tablo 4.16’deki bulgulara ulaşılmıştır.

Tablo 4.16: B Tipi Fonlar İçin Eğitim ve Test Aşaması Performans Göstergeleri

	<i>Eğitim Aşaması Sonrası</i>				<i>Test Aşaması Sonrası</i>			
	R^2	HKT	HKO	HKOK	R^2	HKT	HKO	HKOK
B1	0.82390	0.211278	0.003153	0.056155	0.62671	0.043487	0.001553	0.039409
B2	0.77881	0.122055	0.001822	0.042681	0.64736	0.067039	0.002394	0.048931
B3	0.83986	0.018439	0.000275	0.016589	0.51384	0.194974	0.006963	0.083446
B4	0.70781	0.029181	0.000436	0.020869	0.55160	0.471956	0.016856	0.129828
B5	0.75272	0.850604	0.012696	0.112674	0.56964	0.228214	0.008151	0.090280
B6	0.82091	0.822238	0.012272	0.110780	0.62082	0.472146	0.016862	0.129855
B7	0.85697	0.011427	0.000171	0.013059	0.65180	0.200476	0.007165	0.084615
B8	0.80592	0.016300	0.000234	0.015597	0.63187	0.318943	0.011391	0.106727
B9	0.68997	0.260346	0.003886	0.062335	0.59176	0.418524	0.014947	0.122259
B10	0.84452	0.941556	0.014053	0.118545	0.65994	0.123453	0.004409	0.066400
B11	0.93279	0.683211	0.010197	0.100981	0.60628	0.874195	0.031221	0.176694
B12	0.84962	0.441191	0.006585	0.081147	0.77315	0.004047	0.000145	0.012022
B13	0.85696	0.375299	0.005601	0.074843	0.69674	0.196286	0.007012	0.083727
B14	0.98754	0.013847	0.000207	0.014376	0.62103	0.532596	0.019021	0.137917
B15	0.96389	0.007700	0.000115	0.010720	0.68911	0.047913	0.001711	0.041365
B16	0.84390	0.695662	0.010383	0.101897	0.63319	0.19097	0.006823	0.082585
B17	0.75853	0.062772	0.000937	0.030608	0.65285	0.195339	0.006976	0.083524
B18	0.78059	0.113593	0.001695	0.041175	0.65147	0.301825	0.010779	0.103824
B19	0.98921	0.000909	0.000013	0.003684	0.68413	0.552905	0.019747	0.140522

Tablo 4.16’deki bulgular ile eğitim ve test aşaması sonuçlarını veren grafikler birlikte değerlendirildiğinde, ağların eğitim ve test aşamalarındaki hata paylarının oldukça düşük olduğu ve sifıra yaklaştığı görülmektedir. Başka bir deyişle, örneklem içi (in-sample) ve örneklem dışı (out-of-sample) dönemde çok katmanlı YSA modellerinin oldukça başarılı performans gösterdiği görülmektedir.

B19 koduyla anılan Yatırım Finansman Menkul Değerler A.Ş. B Tipi Likit Fonu’nun net varlık değerini tahmin etmek için geliştirilen çok katmanlı YSA modelinin örneklem içi dönemde, R^2 değeri %98.92 olurken, HKT değeri ise 0.000909 ile en küçük düzeyde gerçekleşmiştir. En düşük R^2 değeri ise %68.99 ile

B9 koduyla anılan Türkiye Garanti Bankası A.Ş. B Tipi Flexi Değişken Fonu tahmin modeline aittir. Ancak bu modelin HKT değeri ise 0.260346 ile sifıra yakın bir düzeyde gerçekleşmiştir.

Geliştirilen çok katmanlı YSA modelinin yatırım fonu net varlık değerini en başarılı biçimde tahmin ettiği fonun R^2 değeri %77.31 ile B12 koduyla anılan Türkiye İş Bankası A.Ş. B Tipi Likit Fonu olduğu görülmektedir. Bu fonun HKT değeri ise 0.004047 ile en düşük düzeyde gerçekleşmiştir. Genel olarak, bağımsız değişkenlerle fon net varlık değerleri arasında güçlü ve pozitif bir ilişkinin var olduğu görülmektedir. Değişkenler arasındaki bu ilişkinin tüm fonlarda %50'in üzerinde olduğu ve özellikle HKT'nin oldukça düşük düzeyde gerçekleştiği görülmektedir.

A tipi yatırım fonlarında olduğu gibi B tipi yatırım fonları net varlık değerlerini tahmin etmek için modellerin oluşturulması sırasında değişkenlerin mevsimsel etkiden arındırılmamasına ve kukla değişkenler kullanılmamasına rağmen, yapay sinir ağı modellerinin oldukça başarılı performans gösterdiği görülmüştür. Yapay sinir ağları, 2001 yılında Türkiye'de yaşanan ekonomik kriz ile 2006 yılında başlayıp tüm dünyaya yayılan küresel ekonomik krizin B tipi yatırım fonu net varlık değerleri üzerindeki etkilerini iyi bir şekilde kavramıştır.

Yukarıda verilen eğitim ve test aşaması grafikleri ve Tablo 4.16'daki bulgular geliştirilen YSA modellerinin oldukça iyi sonuçlar verdiğini ve ağların eğitim ve test aşamalarını başarıyla tamamlamış olduklarını göstermektedir. Performans göstergelerinin olumlu olması YSA modellerinin öngörü için kullanılabileceğini göstermektedir. Ancak B tipi yatırım fonları için öngörü sonuçları karşılaştırmalı olarak son bölümde sunulacaktır.

Genel olarak, test dönemi içinde, 2006 yılında başlayan ve 2008 son çeyreğinde ABD kredi piyasasının çökmesine neden olan ve tüm dünyayı kasıp kavurup ülkemizde de etkilerini gösteren küresel ekonomik krizin 2007 ve 2008 yıllarındaki A ve B tipi yatırım fonu net varlık değeri üzerindeki etkilerinin de YSA modeli tarafından kavranabildiği görülmektedir. Ayrıca grafiklerden, YSA modellerinin A tipi fon kapsamında yer alan değişken, hisse senedi ve ulusal endeks

fonlarında daha başarılı sonuçlar ürettiği görülmektedir. YSA modellerinin B tipi fon kapsamında yer alan fon tüm çeşitlerinde ise (değişken, tahvil ve bono fonları ve likit fonlar) A tipi fonlara göre daha başarılı sonuçlar verdiğini görülmektedir. Bu durumda, riskten kaçınan bir yatırımcı A tipi fonlardan, değişken, hisse senedi ve ulusal endeks fonları tercih edebilirken, riski seven bir yatırımcı ise daha çok likit varlıklardan oluşan B tipi yatırım fonlarını tercih edebilecektir.

4.6. Öngörü Modellerinin Karşılaştırılması

Zaman serileri, bir dönemden diğerine değişkenlerin değerlerinin ardışık biçimde gözlemlendiği sayısal büyüklüklere (Sevüktekin ve Nargeleçekenler, 2007, 41). Ekonomik zaman serisinin istatistiksel olarak, trend, mevsimsellik, konjonktürel ve rastsal hareketlerden oluşan yapısı vardır (Kennedy, 1998, 288) ve bu nedenle durağan değildir. Ekonomideki belirsizlikler nedeniyle ekonomik zaman serilerinin gelecekte göstereceği performans ve davranışı kestirebilmek karar vericiler için oldukça önemlidir. Bu durumda gözlemlenen değerlerden hareketlerle bir zaman serisi için kurulan modelin serinin gelecekte (bir gün, bir ay veya bir yıl sonraki) alabileceği muhtemel değerleri tahmin edebilecek bir performansa sahip olması beklenir. Başka bir deyişle, modelin tahmin (öngörü-forecasting) performansının yüksek olması beklenir.

Öngörü modellemesi birçok alanda olduğu gibi ekonomi alanı için de büyük önem taşımakta ve yaygın biçimde kullanılmaktadır. Hem hükümetlerin hem de mikro karar vericiler olarak anılan üretici, tüketici ve finans kesiminin gelecek davranışlarının belirlenmesinde öngörü modellemesi önemli rol oynamaktadır. Özellikle finans alanında doğru kararlar alabilmesinde iyi öngörüler yapılabilmesinin önemi büyüktür. Daha yalın bir biçimde ifade etmek gerekirse, iyi öngörüler iyi kararlar alınmasına neden olur.

Literatürdeki birçok ampirik çalışmada, öngörü modeli olarak ekonometrik modeller kullanıldığı gibi son yıllarda YSA modelleri de gösterdikleri yüksek tahmin performansı nedeniyle, ekonometrik modellerle karşılaştırmalı olarak kullanılmaya başlanmıştır. Bunun nedeni YSA modellerinin doğrusal olmayan, mevsimsellik ve

trend içeren zaman serilerini tahmin etmede klasik modeller kadar ve onlardan daha üstün performans gösterebilmesidir (Zhang ve Qi, 2005, 502).

Geliştirilen YSA modellerinin iyi bir öngörü başarısı sergileyip sergilemediğinin tespit edilebilmesi için öngörü performans ölçütlerinin kullanılması gerekmektedir. YSA modellerinin öngörü başarısını ölçmek için kullanılacak birçok ölçüt vardır. Ancak bu ölçüt analizin konusu ve amacı dikkate alınarak belirlenmelidir. Bu ölçme işlemi için kullanılacak ölçütler daha önce bölüm 2.11.6'da açıklanmıştır. Bu çalışmada, hata kareler toplamı, hata kareler ortalaması ve karekök ortalama hata kareler performans ölçütleri ile R^2 değeri hesaplanmıştır.

Çalışmanın bu kısmında, 19 adet A tipi ve 19 adet B tipinden olmak üzere toplam 38 adet yatırım fonu net varlık değerlerini tahmin etmek için kurulan YSA modellerinden elde edilen öngörü sonuçları ile regresyon analizinden elde edilen öngörü sonuçları Tablo 4.17 ve 4.18'de karşılaştırmalı olarak sunulmaktadır.

Tablo 4.17: A Tipi Fonlar İçin Öngörü Doğruluk Ölçütleri

	<i>REGRESYON</i>				<i>YSA</i>			
	R^2	HKT	HKO	HKOK	R^2	HKT	HKO	HKOK
A1	0.4954	0.062260	0.000655	0.025600	0.7589	0.010831	0.000387	0.019667
A2	0.1465	1.554470	0.016363	0.127917	0.5570	0.132794	0.004743	0.068866
A3	0.2176	2.846315	0.029961	0.173093	0.4731	0.513904	0.018354	0.135475
A4	0.2955	1.796698	0.018913	0.137523	0.5281	0.172568	0.006163	0.078505
A5	0.2923	13.570610	0.142849	0.377953	0.5724	0.201485	0.007196	0.084828
A6	0.1365	8.301429	0.087383	0.295607	0.5464	0.463605	0.016557	0.128675
A7	0.1443	17.477820	0.183977	0.428925	0.5310	0.479344	0.017119	0.130841
A8	0.2176	1.974319	0.020782	0.144161	0.6149	0.242742	0.008669	0.093109
A9	0.1067	1.306475	0.013752	0.117270	0.5399	0.066758	0.002384	0.048828
A10	0.2921	14.186400	0.149331	0.386433	0.5428	0.791388	0.028264	0.168118
A11	0.2701	1.141232	0.012013	0.109604	0.7451	0.101136	0.003612	0.060099
A12	0.3187	0.497608	0.005238	0.072374	0.5197	0.393079	0.014039	0.118484
A13	0.3476	3.650804	0.038430	0.196034	0.5240	0.083018	0.002965	0.054451
A14	0.6378	0.064504	0.000679	0.026057	0.7224	0.018029	0.000644	0.025374
A15	0.2791	0.217329	0.002288	0.047830	0.6039	0.269498	0.009625	0.098106
A16	0.3756	0.349756	0.003682	0.060677	0.6993	0.049748	0.001777	0.042151
A17	0.2478	4.146853	0.043651	0.208928	0.5388	0.190898	0.006818	0.082569
A18	0.1645	5.898520	0.062090	0.249178	0.6805	0.104472	0.003731	0.061083
A19	0.1556	0.908664	0.009565	0.097800	0.6278	0.163361	0.005834	0.076382

Tablo 4.17'deki sonuçlara göre, A tipi yatırım fonu net varlık değerini tahmin etmede kullandığımız öngörü tekniklerinin performans karşılaştırması yapıldığında,

YSA tekniğinin regresyon yöntemine göre daha iyi performans gösterdiği görülmektedir. Özellikle R^2 ve HKT değerleri incelendiğinde YSA tekniğinin performans üstünlüğü göze çarpmaktadır. A9 koduyla anılan T.C. Ziraat Bankası A tipi Değişken Fon'u regresyon yönteminde %10.67 ile en düşük düzeltilmiş R^2 değerine sahip iken YSA tekniği ile elde edilen tahmin modelinde %53.99 ile yüksek ve pozitif bir değere sahip olmuştur. Bu fonun HKT iki yöntem açısından karşılaştırıldığında, regresyon modeli değeri 1.306475 iken YSA modeli HKT'nin 0.066758 değeri ile oldukça düşük ve sifıra yakın bir düzeyde çıktığı görülmektedir.

Regresyon yönteminde, A7 koduyla anılan YKB A.Ş. A Tipi Koç Allianz Sigorta Özel Fonu ile A10 koduyla anılan TEB Yatırım Menkul Değerler A.Ş. A Tipi Hisse Senedi Fonu'nun net varlık değerlerini tahmin eden modeller için HKT değerleri 17.477820 ve 14.186400 ile en yüksek düzeyde gerçekleşmiştir. Bu değerler, YSA modelinde ise oldukça düşük (0.479344 ve 0.791388) düzeylerde gerçekleşmiştir. Bu iki yatırım fonunun net varlık değerini tahmin eden iki farklı tahmin yönteminden hesaplanan değerler, iki farklı tahmin yöntemi için HKT değerleri arasındaki farkın büyüklüğünü gösteren en çarpıcı modellerdir.

Ayrıca diğer A tipi yatırım fonu net varlık değerlerini tahmin eden çok katmanlı YSA modellerinin de regresyon yöntemine göre HKT'nin oldukça minimum düzeye çekildiği görülmektedir. Tablo 4.17'de performans ölçütleriyle elde edilen bulgular da eğitim ve test aşaması sonucu elde edilen grafikleri destekler niteliktedir.

Tablo 4.18: B Tipi Fonlar İçin Öngörü Doğruluk Ölçütleri

	<i>REGRESYON</i>				<i>YSA</i>			
	<i>R²</i>	<i>HKT</i>	<i>HKO</i>	<i>HKOK</i>	<i>R²</i>	<i>HKT</i>	<i>HKO</i>	<i>HKOK</i>
B1	0.2323	4.737949	0.049873	0.22323	0.62671	0.043487	0.001553	0.039409
B2	0.2589	0.749197	0.007886	0.088805	0.64736	0.067039	0.002394	0.048931
B3	0.2765	6.143969	0.064673	0.254310	0.51384	0.194974	0.006963	0.083446
B4	0.2684	9.216522	0.097016	0.311474	0.55160	0.471956	0.016856	0.129828
B5	0.2212	2.020510	0.021269	0.145837	0.56964	0.228214	0.008151	0.090280
B6	0.2075	1.353457	0.014247	0.119360	0.62082	0.472146	0.016862	0.129855
B7	0.2899	2.657104	0.027970	0.167241	0.65180	0.200476	0.007165	0.084615
B8	0.4645	14.872900	0.156557	0.395673	0.63187	0.318943	0.011391	0.106727
B9	0.0012	4.854910	0.051104	0.226063	0.59176	0.418524	0.014947	0.122259
B10	-0.0512	4.281274	0.045066	0.212288	0.65994	0.123453	0.004409	0.066400
B11	0.4599	1.019974	0.010737	0.103617	0.60628	0.874195	0.031221	0.176694
B12	0.5987	0.032106	0.000338	0.018384	0.77315	0.004047	0.000145	0.012022
B13	0.2678	0.970831	0.104956	0.323969	0.69674	0.196286	0.007012	0.083727
B14	0.3023	9.625767	0.101324	0.318314	0.62103	0.532596	0.019021	0.137917
B15	0.2758	6.438327	0.067772	0.260330	0.68911	0.047913	0.001711	0.041365
B16	0.1268	6.555857	0.069009	0.262696	0.63319	0.19097	0.006823	0.082585
B17	0.2555	2.168015	0.022821	0.151067	0.65285	0.195339	0.006976	0.083524
B18	0.1389	9.574163	0.100781	0.317460	0.65147	0.301825	0.010779	0.103824
B19	0.2445	2.973399	0.031299	0.176915	0.68413	0.552905	0.019747	0.140522

B tipi yatırım fonu net varlık değerini tahmin etmede kullandığımız öngörü yöntemlerinin performans karşılaştırması yapılan Tablo 4.18'e göre, YSA tekniğinin regresyon yöntemine göre daha iyi performans gösterdiği görülmektedir. R^2 ve HKT değerleri incelendiğinde YSA tekniğinin performans üstünlüğü göze çarpmaktadır. B10 koduyla anılan T. Garanti Bankası A. Ş. B Tipi Likit Fon'u regresyon yönteminde %-0.0512 ile en düşük ve neredeyse hiçbir ilişkinin olmadığını gösteren bir R^2 değerine sahip iken YSA tekniği ile elde edilen tahmin modelinde %65.99 ile çok yüksek ve pozitif bir değere sahip olmuştur. Bu fonun HKT iki yöntem açısından karşılaştırıldığında, regresyon modeli değeri 4.281274 iken YSA modeli HKT'nin 0.123453 değeri ile oldukça düşük ve sifıra yakın bir düzeyde çıktığı görülmektedir.

HKT regresyon modelinde çok yüksek değerler almış iken YSA modelinde oldukça düşük düzeyde gerçekleşmiştir. Örneğin, B8 koduyla anılan TEB A.Ş. B Tipi Likit Fon ile B14 koduyla anılan T. Vakıflar Bankası T.A.O. B Tipi Değişken Fonu'nun net varlık değerlerini tahmin eden regresyon modelleri için HKT değerleri 14.872900 ve 9.625767 ile en yüksek düzeyde gerçekleşmiştir. Bu değerler, YSA

modelinde ise oldukça düşük olan 0.318943 ve 0.532596 düzeylerinde gerçekleşmiştir. Bu iki yatırım fonunun net varlık değerini tahmin eden iki farklı tahmin yönteminden hesaplanan değerler, iki farklı tahmin yöntemi için HKT değerleri arasındaki farkın büyüklüğünü gösteren en çarpıcı modellerdir.

Diğer B tipi yatırım fonu net varlık değerlerini tahmin eden çok katmanlı YSA modellerinin de regresyon yöntemine göre HKT'nin oldukça minimum düzeye çekildiği görülmektedir. Tablo 4.18'de performans ölçütleriyle elde edilen bulgular da eğitim ve test aşaması sonrasında elde edilen grafikleri destekler nitelikte olduğu görülmektedir.

Tablo 4.17 ve 4.18'deki verilere göre, A tipi ve B tipi yatırım fonlarının net varlık değerlerini tahmin etmek için oluşturulan regresyon ve YSA modellerden hesaplanan performans ölçütleri karşılaştırıldığında, YSA performans göstergelerinin daha iyi sonuçlar verdiği görülmektedir. Ayrıca YSA yönteminin B tipi yatırım fonlarında daha etkin sonuçlar verdiği de görülmektedir. Bağımsız değişkenlerdeki değişmelerin bağımlı değişken üzerindeki etkilerini açıklayan, düzeltilmiş R^2 değerlerinin daha yüksek gerçekleştiği ve en önemli ve en çok kullanılan performans ölçütü olan HKT'nin regresyon yöntemine göre oldukça düşük sifıra yakın düzeylerde gerçekleştiği görülmektedir.

Türkiye'de 2008 yılı itibariyle en yüksek net varlık değerine sahip 38 adet A tipi ve B tipi yatırım fonunun net varlık değerlerini 6 adet makro ekonomik değişken yardımıyla tahmin etmek üzere geliştirilen YSA modelleri ile elde edilen tahmin sonuçları, ikinci bölümde verilen literatür incelemesi ile paralellik göstermektedir. Literatür incelemesinde yer alan tüm çalışmalar YSA'ların, regresyon analizine göre daha başarılı sonuçlar verdiğini ortaya koymaktadır. Bu çalışmada geliştirilen YSA modellerinden elde edilen bulguların, geliştirilen regresyon modellerinden elde edilen bulgulara göre daha başarılı olması, YSA'ları üzerine daha önce yapılan çalışmalarla paralel sonuçların elde edildiğini göstermektedir. Çalışma sonucunda elde edilen bulgular, Türkiye'deki yatırım fonları net varlık değerlerinin uluslararası piyasalarda meydana gelen gelişmelerden doğrudan etkilendiğini göstermektedir.

SONUÇ

Yapay sinir ağları, insan beyninin çalışma mekanizmasını taklit ederek beynin öğrenme, hatırlama, genelleme yapma yolu ile yeni bilgiler üretebilme gibi yetenekleri herhangi bir yardım almaksızın gerçekleştirmek üzere geliştirilen bilgisayar yazılımlarıdır. Bu özelliği nedeniyle YSA modelleri, endüstri, iş, finans, eğitim, askeri, savunma ve sağlık gibi birçok alanda başarıyla uygulanmaktadır. YSA'ların uygulama alanlardan birisi de geleceği tahmin problemleridir. Yapay sinir ağları, doğrusal yapıda olmamaları nedeniyle yine doğrusal yapıda olmayan zaman serileri analizinde oldukça başarılı sonuçlar elde edebilmişlerdir. Bu bakımdan YSA finansın birçok alanında sıkça kullanılan bir yöntem olmuştur. Finans alanında; finansal krizlerin öngörülmesi, döviz kurlarının ve genel fiyat düzeyinin yönünün belirlenmesi ve özellikle hisse senetlerinin performansının ölçülmesi ve seçimi gibi konularını inceleyen birçok çalışmada YSA modelleri uygulanmakla beraber, yatırım fonları net varlık değerlerinin tahmini konusunda sınırlı sayıda çalışma bulunmaktadır.

Doğrusal stokastik regresyon modelleri, değişkenler arasındaki önemli detayları anlayabilir ve açıklayabilirlerse diğer modellere göre avantajlı olabilirler. Ancak üzerinde çalışılan problemdeki değişkenler arasındaki ilişki doğrusal olmadığında doğrusal modeller yetersiz kalmaktadır. Bu noktada, doğrusal olmayan ilişkiler için uygun ağ yapısı belirlendiğinde YSA modelleri başarılı tahminler yapabilmektedir.

Bu çalışmada, doğrusal olmayan tahmin modellerinden biri olan YSA modelleme tekniğinden yararlanarak, Ocak 2001-Aralık 2008 döneminde Türkiye'de faaliyet gösteren 19 adet A ve 19 adet B tipi olmak üzere toplam 38 adet yatırım fonunun net varlık değerlerinin tahmin edilmesi amaçlanmıştır.

Çalışmada öncelikle Türkiye'deki ve dünyadaki yatırım fonu sektörünün büyüklüğü ve gelişimi hakkında genel bilgilere yer verilmiştir. Daha sonra YSA tekniği detaylı olarak incelenmiş ve yapay sinir ağı tasarımı yapılarak uygun bulunan ağ mimarileri ve altı adet makro ekonomik değişken kullanılarak yatırım fonu net varlık değerleri modellenmiştir. Tahmin edilen modeller hem kendi içinde değerlendirilmiş hem de doğrusal regresyon analizi yapılarak performans

karşılaştırmaları yapılmıştır. Regresyon analizinde de her bir yatırım fonu aylık net varlık değeri bağımlı değişken; Aktif Tahvilin Faiz Oranı (ATFAİZ), ABD Doları/TL Kuru (DK), İMKB-100 Endeksi (İMKB100), Para Arzı (M2), Sanayi Üretim Endeksi (SUE) ve Toptan Eşya Fiyat Endeksi (TEFE) olmak üzere altı adet bağımsız değişken kullanılmıştır.

Tahmin edilen YSA modelleri kendi içlerinde tutarlı bir yapı ve iyi bir öngörü performansı göstermişlerdir. Regresyon modeli ile yapılan öngörü karşılaştırmasında ise YSA tekniğinin bu yöntemle göre daha iyi bir performans gösterdiği sonucuna varılmıştır. Ayrıca, örneklem içi ve örneklem dışı dönemde yer alan finansal krizlerin tahmini konusunda YSA yönteminin regresyon yöntemine göre daha başarılı olduğu en dikkat çekici noktadır.

Regresyon analizi ile yapılan öngörülerin gerçek değerlerden büyük sapmalar göstermesi ve mevsimsel etkilerin yapay sinir ağlarına yansıtılmamış olmasına rağmen ağın daha iyi öngörü performansı göstermesi, finansal değişkenler için doğrusal olmayan modellemenin yani yapay sinir ağları yönteminin daha etkili olduğu biçiminde bir genelleme yapılabilmesine neden olmaktadır.

Dünya genelinde yatırım fonlarına ilişkin tahminlerde YSA modellerini kullanan çalışma sayısı oldukça azdır. Türkiye yatırım fonları üzerinde YSA modellerini kullanan çalışma sayısı ise birkaç tanedir ve bu çalışmalar sınırlı sayıda yatırım fonu üzerinde yapılmıştır. Bu çalışmada, YSA modelinin yatırım fonları portföy büyüklüklerinin tahmininde kullanılmasının ve analize dâhil edilen yatırım fonu sayısı ve çeşidinin fazla olmasının çalışmaya *özgünlük* kattığı düşünülmektedir.

Günümüzde iletişim teknolojisi ve finans alanında yaşanan gelişmeler ile ABD kredi piyasasında başlayıp tüm dünya ülkelerinin ulusal piyasalarını etkileyen global ekonomik krizler gibi gelişmeler, uluslararası sermaye piyasalarının ulusal sermaye piyasası kimliği kazandığını göstermiştir. Böyle geniş bir piyasada riskten korunmak ve getiri elde etmek isteyen yatırımcılar için, başarılı öngörüler yapma yeteneği olan ve doğrusal olmayan ilişkileri de modelleyebilen dolayısıyla sermaye piyasasındaki değişimleri açıklayabilme gibi önemli bir avantajı olan YSA modellerinin etkin bir

tahmin aracı olduđu gör÷lmektedir. Bu özellikleri nedeniyle YSA tekniđi finans alanında giderek önemi artan bir problem çözme aracı haline gelmektedir.

Bu çalışmadan hareketle yatırım fonları üzerine ileride yapılabilecek yeni araştırma konuları olarak şunlar önerilebilir. Yatırım fonu net varlık değerini etkileyen makro ekonomik deđişken sepeti genişletilirken çalışılan yatırım fonu türü sınırlı tutulabilir. Başka bir ifadeyle Türkiye'deki belli bir yatırım fonu türü için benzer bir analiz yapılabilir. Türkiye yatırım fonu net varlık değerinin, daha uzun bir dönem için diđer ekonometrik modellerle YSA yöntemi karşılaştırmalı olarak analizi de bir diđer bir çalışma konusu olabilir.

KAYNAKÇA

Akel, Veli (2007); “Türkiye’deki A Tipi Yatırım Fonlarının Performansının Devamlılığının Parametrik ve Parametrik Olmayan Yöntemlerle Değerlendirilmesi”, Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi Cilt:22, Sayı:2, ss:147-177.

Abraham, Ajith, Yuehui Chen, BO Yang ve Jiwen Dong (2004); “Time-Series Forecasting Using Flexible Neural Tree Model”, *Information Sciences*, Vol. 174, pp. 1-17.

Altan, Şenol (2008); “Döviz Kuru Öngörü Performansı İçin Alternatif Bir Yaklaşım: YSA”, *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10/2, ss.141-160.

Altay, E. ve M. H. Satman (2005); “Stock Market Forecasting: Artificial Neural Networks and Linear Regression Comparison in an Emerging Market”, *Journal of Financial Management and Analysis*, Vol. 18(2), pp. 18-33.

Anderson, Dave ve George McNeill (1992); “Artificial Neural Networks Technology”, *Kaman Science Corporation*, New York, USA.

Andreoua, Panayiotis C., Chris Charalambousa ve Spiros H. Martzoukos (2008); “Pricing and Trading European Options by Combining Artificial Neural Networks and Parametric Models with Implied Parameters”, *European Journal of Operational Research*, Vol. 185, pp.1415-1433.

Avcı, Emin (2007); “Forecasting Daily and Sessional Returns of the ISE-100 Index with Neural Networks Models”, *Doğuş Üniversitesi Dergisi*, 8(2), pp. 128-142.

Balkin, Sandy D. (1997); “Using Recurrent Neural Networks for Time Series Forecasting”, *Working Paper Series*, No:97-11, International Symposium on Forecasting.

Bayramoğlu, Mehmet Fatih (2007); “Finansal Endekslerin Öngörüsünde YSA Modellerinin Kullanılması: İMKB Ulusal 100 Endeksinin Gün İçi En Yüksek ve En Düşük Değerlerinin Öngörüsü Üzerine Bir Uygulama”, T.C. Zonguldak Karaelmas Üniversitesi S.B.E. İşletme Anabilim Dalı Yayınlanmamış Yüksek Lisans Tezi, Zonguldak.

Bello, Zakri Y., Vahan Janjigian (1997); “A Re-Examination of the Market-Timing and Security- Selection Performance of Mutual Funds”, *Financial Analysts Journal*, Vol. 53, pp. 24-30.

Benli, Yasemin K. (2005); “Bankalarda Mali Başarısızlığın Öngörülmesi Lojistik Regresyon ve Yapay Sinir Ağı Karşılaştırması”, *Gazi Üniversitesi Endüstriyel Sanatlar Eğitim Fakültesi Dergisi*, 16, pp. 31-46.

Beyazođlu, H. (2002); “Yatırım Fonları Üzerine Bir Deđerlendirme ve Türkiye’de İřtirak Yatırım Fonları”, *SPK Yeterlik Etüdü*, İstanbul.

Bolat, İsmet (2006); “*Sermaye Piyasaları ve Yatırım Fonları Mevcut Durum, Sonuç ve Çözüm Önerileri*”, Kahramanmarař Sütçü İmam Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı Yayınlanmamış Yüksek Lisans Tezi, Kahramanmarař.

Bollen, Nicolas P. B., Jeffrey A. Busse (2001); “On the Timing Ability of Mutual Fund Managers”, *Journal of Finance*, Vol. 56(3), pp. 1075-1094.

Boyer, Brian ve Lu Zheng (2009); “Investor Flows and Stock Market Returns”, *Journal of Empirical Finance*, Vol. 16, pp. 87–100.

Canbař, Serpil ve Hatice Dođukanlı (1997); *Finansal Pazarlar*, Beta Basın Yayım Dađıtım, İstanbul.

Canbař, Serpil ve S. Yılmaz Kandır (2002); “Türkiye’deki Yatırım Fonlarının Performans Deđerlendirmesi”, *İktisat İşletme ve Finans*, Cilt: 17, Sayı:201, ss. 13-19.

Canbař, Serpil ve S. Yılmaz Kandır (2004); “Türkiye’deki Yatırım Fonları Performanslarının Tutarlılıđının İncelenmesi”, *Finans-Politik & Ekonomik Yorumlar*, Cilt: 41, Sayı: 480, Nisan, ss. 64–71.

Carlson, Robert S. (1970); “Aggregate Performance of Mutual Funds, 1948-1967”, *Journal of Financial and Quantitative Analysis*, Vol. 5(1), pp. 1-32.

Casarin, Roberto ve Lorianna Pelizzon; Andrea Piva (2000); “Performance and Performance Persistence of Italian Equity Funds”, *Working Paper*, No: 00.06, Greta Association.

Cerny, Portia A. (2001); “*Data Mining and Neural Networks from A Commercial Perspective*”, The 36th Annual ORSNZ Conference, University of Canterbury, Christchurch, NZ, p.4.

Chen, An-Sing ve Mark T. Leung (2005); “Performance Evaluation of Neural Network Architectures: The Case of Predicting Foreign Exchange Correlations” *Journal of Forecasting*, Vol. 24, 403–420.

Chen, N. F., R. Roll ve S.A. Ross (1986); “Economic Forces and Stock Market”, *The Journal of Business*, Vol. 59, No: 3, pp. 383-403.

Cheng, A.C.S. (1995); “The UK Stock Market and Economic Factors: A New Approach”. *Journal of Business Finance and Accounting*, Vol. 22, 129-142.

Christensen, Michael (2003); “Evaluating Danish Mutual Fund Performance”, *Working Paper*, The Aarhus School of Business.

Cowles, Alfred (1933); “Can Stock Market Forecasters Forecast?”, *Econometrica*, Vol. 3(1), pp. 309-324.

Cuthbertson, Keith, Dirk Nitzsche ve Niall O’Sullivan (2008); “UK Mutual Fund Performance: Skill or Luck?”, *Journal of Empirical Finance*, Vol. 15, pp. 613–634.

Çanakçı, Aylin (2006); “Yapay Sinir Ağlarının Makroekonomik Bir Model Üzerine Uygulanması: Bir Türkiye Örneği”, Gazi Üniversitesi Sosyal Bilimler Enstitüsü Ekonometri Anabilim Dalı Yayınlanmamış Yüksek Lisans Tezi, Ankara.

Dahlquist, Magnus, Stefan Engström ve Paul Söderlind (2000); “Performance and Characteristics of Swedish Mutual Funds”, *Journal of Financial and Quantitative Analysis*, Vol. 35(3), pp. 409-423.

Demuth, Howard ve Mark Beale (2004); *Neural Network Toolbox User’s Guide*, The Math Works, Inc.

Detzler, Miranda Lam (1999); “The Performance of Global Bond Mutual Funds”, *Journal of Banking and Finance*, Vol. 23(8), pp. 1195-1217.

Doğanay, M. M. (2004); “Hisse Senedi Yatırım Fonlarının Şartlı Performans Değerlendirmesi”, *Gazi Üniversitesi, İİBF Dergisi*, Sayı: 1, 165-179.

Diler, Ali İhsan (2003); “İMKB Ulusal-100 Endeksinin Yönünün Yapay Sinir Ağları Hata Geriye Yayma Yöntemi ile Tahmin Edilmesi”, *İMKB Dergisi*, Sayı: 25-26, pp. 65-81.

Dutta, Goutam, Pankaj Jha, Arnab Kumar ve Lha Neeraj Mohan (2006); “Artificial Neural Network Models for Forecasting Stock Price Index in the Bombay Stock Exchange”, *Journal of Emerging Market Finance*, Vol. 5(3), pp. 49-61.

Ellis, Craig ve Patrick J. Wilson (2005); “Can a Neural Network Property Portfolio Selection Process Outperform the Property Market”, *Journal of Real Estate Portfolio Management*, Vol. 11, No:2, pp. 105-121.

Elton, Edwin, Martin Gruber ve Joel Rentzler (1987); “Professionally Managed, Publicly, Traded Commodity Funds”, *Journal of Business*, Vol. 60, pp. 175-199.

Elton, Edwin, Martin Gruber ve Joel Rentzler (1990); “The Performance of Publicly Offered Commodity Funds”, *Financial Analyst Journal*, Vol. 46(4), pp. 23-30.

Elton, Edwin, Martin Gruber, Sanjiv Das ve Matt Hlavka (1993); “Efficiency with Costly Information: A Reinterpretation of Evidence from Managed Portfolios”, *Review of Financial Studies*, Vol. 6(1), pp. 1-22.

Elton, Edwin ve Martin Gruber; Christopher Blake (1996); “The Persistence of Risk-Adjusted Mutual Fund Performance”, *Journal of Business*, Vol. 69(2), pp. 133-157.

Ercan, Metin K. ve Ünsal Ban, (2005); *Değere Dayalı İşletme Finansı Finansal Yönetim*, 2. Baskı, Gazi Kitabevi, Ankara.

Ergin, Burak “Yatırım Ortaklıkları ve Yatırım Fonları”, *İMKB, Sermaye Piyasası ve Borsa Temel Bilgiler Klavuzu*, <http://www.imkb.gov.tr/yayinlar/spkilavuzu.htm>/Erişim Tarihi: 25.03.2008.

Ertaş, Vahdettin, Kürşat Tuncel ve Bahadır Teker (1997); “Yatırım Fonları ve Türkiye Uygulaması” *Sermaye Piyasası Kurulu*, Yayın No: 103.

Ertek, Tümay (2000), *Ekonometriye Giriş*, Genişletilmiş 2. Baskı, Beta Yayın Dağıtım, İstanbul.

Fama, Eugene F. (1970); “Efficient Capital Markets: A Review of Theory and Empirical Work”, *Journal of Finance*, Vol.25, No.2, 383-417.

Fama, Eugene F. (1972); “Components of Investment Performance”, *Journal of Finance*, Vol. 27(3), pp. 551-567.

Franses, Philip Hans ve Dick Van Dijk (2003); *Non-Linear Time Series Model in Empirical Finance*, Cambridge Univ. Press.

Graham John R. ve Campbell R. Harvey (1997); “Grading the Performance of Market-Timing Newsletters”, *Financial Analysts Journal*, pp. 54-66.

Grinblatt, Mark ve Sheridan Titman (1992); “The Persistence of Mutual Fund Performance”, *Journal of Finance*, Vol. 47(5), pp. 1977-1984.

Grinblatt, Mark ve Sheridan Titman (1989); “Portfolio Performance Evaluation: Old issues and New Insights”, *Review of Financial Studies*, Vol. 2(3), pp. 393-421.

Grinblatt, Mark ve Sheridan Titman (1989); “Mutual Fund Performance: An Analysis of Quarterly Portfolio Holdings”, *Journal of Business*, Vol. 62(3), pp. 393-416.

Gonzalez, Steven (2000); “Neural Networks for Macroeconomic Forecasting: A Complementary Approach to Linear Regression Models,” *Working Paper 2000-07*.

Gökgöz, Fazıl ve Yalçın Karatepe (2007); “A Tipi Yatırım Fonu Performansının Değerlendirilmesi ve Performans Devamlılık Analizi”, *Ankara Üniversitesi SBF Dergisi*, Sayı: 62, No: 2, ss. 75-109.

Gujarati, D. N. (2004); *Basic Econometrics*, McGraw-Hill, Inc, 4. Edition.

Gürsoy, C.T. ve Y. Ö. Erzurumlu (2001); "Evaluation of Portfolio Performance of Turkish Investments Funds", *Doğuş Üniversitesi Dergisi*, 4, 43-58.

Hebb, Donald O. (1949); *The Organization of Behavior*, New York Wiley, Introduction and Chapter 4. "The First Stage of Perception: Growth of the Assembly" pp.xi-xix, 60-78.; <http://books.google.com.tr>. Erişim Tarihi: 18.03.2009.

Henriksson, Roy D. ve Robert C. Merton (1981); "On Market Timing and Investment Performance II. Statistical Procedures for Evaluating Forecasting Skills", *Journal of Business*, Vol. 54(4), pp. 513-533.

Henriksson, Roy D. (1984); "Market Timing and Investment Performance: An Empirical Investigation", *Journal of Business*, Vol. 57(1), pp. 73-96.

Hamilton, J. D. (1994); *Time Series Analysis*, Princeton University Press.

Hansen, S. Robert ve Oya Altıncılık (2000); "Are There Economies of Scale in Under writing Fees? Evidence of Rising External Financing Costs", *The Review of Financial Studies Spring*, Vol.13, No:1, pp.191-218.

Haykin, Simon, I. W. Sandberg, J. T. Lo, C. L. Fancourt, J. C. Principe ve S. Katagiri (2001); *Nonlinear Dynamical Systems, Feedforward Neural Network Perspectives*, WileyBlackwell 23, <http://boks.google.com.tr/> Erişim Tarihi: 18.03.2009.

Hopfield, J.J. (1982); "Neural Networks and Physical Systems with Emergent Collective Computational Abilities" *Proceedings of National Academy Sciences*, 79, 2554-3092.

Hopfield, J.J. (1984); "Neurons with Gradedresponse Have Collective Computational Properties Like Those of Two Stateneurons", *Proceedings of the National Academy of Sciences*, Vol. 81, 3088-3092.

Huij, J. ve M. Verbeek (2007); "Cross-Sectional Learning and Short-Run Persistence in Mutual Fund Performance", *Journal of Banking & Finance*, Vol. 31, pp. 973-997.

Indro, D. C., C. X. Jiang, B. E. Patuwo ve G. P. Zhang (1999); "Prediction Mutual Fund Performance Using Artificial Neural Networks", *Omega, International Journal of Management. Science*, Vol. 27, pp. 373-380.

Ippolito, Richard A. (1993); "On Studies of Mutual Fund Performance 1962-1991", *Financial Analysts Journal*, Vol. 49(1), pp. 42-50.

Ippolito, Richard A. (1989); "Efficiency with Costly Information: A Study of Mutual Fund Performance", *Quarterly Journal of Economics*, Vol. 104(1), pp. 1-23.

Jensen, Michael (1967); "The Performance of Mutual Funds in the Period 1945-1964", *Journal of Finance*, Vol. 23(2), pp. 389-416.

Jensen, Michael (1969); "Risk, the Pricing of Capital Assets, and the Evaluation of Investment Portfolios", *Journal of Business*, Vol. 42(2), pp.167-247.

Kaastra, Iebeling ve Milton Boyd (1996); "Designing a Neural Network for Forecasting Financial and Economic Time Series," *Neurocomputing*, Vol. 10, 215-236.

Kahraman, Derya (2006); "Türk A Tipi Menkul Kıymet Yatırım Fonlarında Sona Erme Analizi ve Tahmini" Afyon Kocatepe Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı Doktora Tezi, Afyon.

Kallberg, Jarl G. VE Crocker H. Liu (2000); Charlese Trzcinka; "The Value Added from Investment Managers: An Examination of Funds of REITs", *Journal of Financial and Quantitative Analysis*, Vol. 35(3), pp. 387-408.

Kamruzzman, Joarder, Rezaul K. Beggand ve Ruhul A. Sarker (2006); *Artificial Neural Networks in Finance and Manufacturing*, Idea Group Publishing.

Karacabey, A. Argun (1998); *A Tipi Yatırım Fonları: Performanslarının Analizi ve Değerlendirilmesi*, Mülkiyeliler Birliği Vakfı Yayınları, Tezler Dizisi:5, Ankara.

Karacabey, A. Argun (1999); "Hisse Senedi Fonlarının İşlevselliği Üzerine Yorumlar", *Ankara Üniversitesi SBF Dergisi*, Sayı 54-3, ss. 133-149.

Karacabey, A. Argun; Yalçın Karatepe (2000); "A Tipi Yatırım Fonları Performansının Yeni Bir Yöntem Kullanılarak Değerlendirilmesi: Graham-Harvey Performans Testi", *Ankara Üniversitesi. SBF Dergisi*, Sayı 55-2, ss. 55-67.

Karaçor, Z. ve Alptekin, V. (2006); "Finansal Krizlerin Önceden Tahmin Yoluyla Değerlendirilmesi: Türkiye Örneği", *Yönetim ve Ekonomi*, 13 (2), 237-256.

Kennedy, Peter (1998); *A Guide to Econometrics*, The MIT Press, 4. Ed.

Kılıç, Saim (2002); *Türkiye'deki Yatırım Fonlarının Performanslarının Değerlendirilmesi*, İMKB Yayınları, No:95, Ankara.

Kim, Tae Yoon, Kyong Joo Oh, Insuk Sohn ve Changha Hwang (2004); "Usefulness of Artificial Neural Networks for Early Warning System of Economic Crisis", *Expert Systems with Applications*, Vol. 26, pp. 583-590.

Kocaman, Berna (1995); *Yatırım Teorisinde Modern Gelişmeler*, İMKB Yayınları, Yayın No:5, İstanbul.

Kohonen, Teuvo (2001); *Self Organizing Maps*, Information Sciences, Third Edition, Springer, pp. 71-72; <http://boks.google.com.tr>. Erişim Tarihi: 18.03.2009.

Kon, Stanley J. ve Frank C. Jen (1978); “Estimation of Time-Varying Systematic Risk And Performance for Mutual Fund Portfolios: An Application of Switching Regression”, *Journal of Finance*, Vol. 33(2), pp. 457-475.

Kon, Stanley (1983); “The Market-timing Performance of Mutual Fund Managers”, *Journal of Business*, Vol. 56(3), pp. 323-347.

Korkmaz, Turhan ve Mehmet Pekkaya (2005); *Excel Uygulamalı Finans Matematiği*, Ekin Yayınevi, Bursa.

Korkmaz, Turhan ve Hasan Uygurtürk (2007); “Türkiye’deki Emeklilik Fonlarının Performans Ölçümü ve Fon Yöneticilerinin Zamanlama Yeteneği”, *Akdeniz İ.İ.B.F. Dergisi*, Cilt: 7, Sayı:14, ss. 66-93.

Lee, Cheng Few ve Shafiqur Rahman (1990); “Market Timing, Selectivity, and Mutual Fund Performance: An Empirical Investigation”, *Journal of Business*, Vol. 63(2), pp. 261-278.

Liang, Xun, H. Zhang, J. Xiao ve Y. Chen (2009); “Improving Option Price Forecasts with Neural Networks and Support Vector Regressions”, *Neurocomputing*, Vol:72, pp. 3055-3065.

Maditinos, Dimitrios ve Prodromos Chatzoglou (2008); “The Use of Neural Networks in Forecasting”, *Review of Economic Sciences*, Vol. 6, pp. 161-176.

Malkiel, Burton G. (1995); “Returns from Investing in Equity Mutual Funds 1971 to 1991”, *Journal of Finance*, Vol. 50(2), pp. 549–572.

McCullogh, W. ve Pitts, W. (1943); “A Logical Calculus of the Ideas Immanent in Nervous Activity”, *Bulletin of Mathematical Biophysics*, Vol. 5, 115-133.

McDonald, John G. (1974); “Objectives and Performance of Mutual Funds, 1960-1969”, *Journal of Financial and Quantitative Analysis*, Vol. 9(3), pp. 311-333.

McNellis, Paul D. (2006); *Neural Networks in Finance, Gaining Predictive Edge in the Market*, Elsevier Academic Press, USA.

Odabaşı, Belgi (2007); “Yatırım Fonlarının Performans Değerlendirmesi: A Tipi Karma Fonlar İçin Çok Kriterli Modellerle Türkiye Uygulaması”, Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü İktisat Anabilim Dalı Para Banka Programı Yayınlanmamış Yüksek Lisans Tezi, İzmir.

Özdemir, Eray (2007); “Borsa Yatırım Fonları ve Borsa Yatırım Fonlarının Performanslarının Ölçülmesi Üzerine Bir Uygulama”, T.C. Gazi Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı Yayınlanmamış Master Tezi, Ankara.

Öztemel, Ercan (2006); *Yapay Sinir Ağları*, Papatya Yayıncılık, 2.Basım, İstanbul.

Panda, Chakradhara ve V. Narasimhan (2007); "Forecasting Exchange Rate Better with Artificial Neural Network", *Journal of Policy Modeling*, Vol. 29(2), pp. 227-236.

Ray, Prantik ve Vina Vani (2004); "Neural Network Models for Forecasting Mutual Fund Net Asset Value, Working Paper.

Pekkaya, Mehmet ve Turhan Korkmaz, (2005); *Excel Uygulamalı Finans Matematiği*, Ekin Kitabevi Yayınları, Bursa.

Peter, Kennedy (1998); *A Guide to Econometrics*, Fourth Edition, The MIT Press, Chambridge.

Romacho, J. C. ve M. C. Cortez (2006); "Timing and Selectivity in Portuguese Mutual Fund Performance" *Research in International Business and Finance*, Vol. 20, pp. 348-368.

Rumelhart, D.E. ve J.L. McClelland (1986); "Parallel Distributed Processing, Explorations in the Microstructure of Cognition", Vol.1: Foundations, *MIT Press.*, Cambridge, MA.

Sahoo, Prasant K. ve Priti Ranjan Hathy (2007); "Prediction of Mutual Funds: Use of Neural Network Technique", *The Icfai Journal of Applied Finance*, Vol. 13, No. 11.

Salvatore, Dominick ve Eugene A. Diulio, (1986); *İktisat, İlkeler ve Kavramlar, 385 Çözümlü Problem*, Beta Basın Yayın Dağıtım, 4. Baskı, İstanbul.

Sevüktekin, Mustafa ve Mehmet Nargeleçekenler (2007); *Ekonometrik Zaman Serileri Analizi, EViews Uygulamalı*, Geliştirilmiş 2. Baskı, Nobel Yayın Dağıtım, Ankara.

Sharpe, William. F. (1966); "Mutual Fund Performance", *Journal of Business*, Vol. 39 (2), pp. 119-138.

Smith, Kate A. (2002); *Neural Networks for Business: An Introduction, Neural Networks in Business: Techniques and Applications*, Idea Group Publishing, USA, /http://books.google.com, Erişim Tarihi: 31.03.2009.

Ünsal, Erdal (1998); *Mikro İktisat*, Kutsan Ofset Matbaacılık, Ankara.

Ünver, Özkan (1992); *Uygulamalı İstatistik Yöntemler*, Gazi Üniversitesi. Yayınları No:123, Ankara.

Üstünel, İbrahim Engin (2000); "Durağan Portföy Analizi ve İMKB Verilerine Uygulanması", *İMKB Yayınları*, İstanbul.

Tevfik, Gürman (1995); *Dünya'da ve Türkiye'de Yatırım Fonları Teori ve Uygulama*, İşbankası Yayınları, Ankara.

Treynor, Jack L. (1965); "How to Rate Management Investment of Funds", *Harvard Business Review*, Vol. 43(1), pp. 63-75.

Treynor, Jack. L ve Kay K. Mazuy (1966); "Can Mutual Funds Outguess the Market?", *Harvard Business Review*, Vol. 44, pp. 131-136

Tseng, Chih-Hsiung, Sheng-Tzong Cheng, Yi-Hsien Wang ve Jin-Tang Peng (2008); "Artificial Neural Network Model of the Hybrid EGARCH Volatility of the Taiwan Stock Index Option Prices", *Physica A: Statistical Mechanics and its Applications*, Vol: 387, Issue:13, pp. 3192-3200.

TSPAKB (2008); "Menkul Kıymetler ve Diğer Sermaye Piyasası Araçları Lisanslama Eğitim Klavuzu", *Sermaye Piyasası Faaliyetleri İleri Düzey Lisansı Eğitimi*.

Vuran, B. (2002); "Türkiye'de Yatırım Fonları ve Performans Değerlendirmesi ile İlgili Bir Uygulama", İstanbul Üniversitesi Sosyal Bilimler Enstitüsü Yayınlanmamış Yüksek Lisans Tezi.

Yalçınkaya, Pınar (2006); "Türkiye'de A Tipi Yatırım Fonları ve Performans Değerlendirilmesi (1998-2000)", Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı Yayınlanmamış Yüksek Lisans Tezi, Isparta.

Yao, Jingtao, Hean-Lee Poh ve Teo Jasic (1996); "Foreign Exchange Rates Forecasting with Neural Networks", ICONIP'96 (International Conference on Neural Information Processing), Hong Kong, Sept. 24-27, pp.754-759.

Yazıcı, Ayşe Canan ve Diğ. (2007); "Yapay Sinir Ağlarına Genel Bakış", Türkiye Klinikleri J Med Science, 27:65-71.

Yıldız, Birol (2001); "Finansal Başarısızlığın Öngörülmesinde Yapay Sinir Ağı Kullanımı ve Halka Açık Şirketlerde Ampirik Bir Uygulama", *İMKB Dergisi*, Cilt:5, Sayı: 17, pp. 51-67.

Yurtoğlu, Hasan (2005); "Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği", DPT Uzmanlık Tezi, Ankara.

Zhang, Guoqiang, B. Eddy Patuwo ve Michael Y. Hu (1998); "Forecasting with Artificial Neural Networks: The State of the Art", *International Journal of Forecasting*, Vol.14, pp. 35-62.

Zhang, G. Peter (2001); "An Investigation of Neural Networks for Linear Time-Series Forecasting", *Computers & Operations Research*, Vol. 28, pp. 1183-1202.

Zhang, G. Peter (2003a); *Neural Networks in Business Forecasting*, Hersley, PA, USA, Idea Group Inc., pp. 195.

Zhang, G. Peter (2003b); "Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model", *Neurocomputing*, Vol. 50, pp. 159-175.

Zhang, G. Peter (2004); "*Business Forecasting with Artificial Neural Networks: An Overview, Neural Networks in Business Forecasting*", Idea Group Inc, USA.

Zhang, G. P. ve Min Qi (2005); "Neural Network Forecasting for Seasonal and Trend Time Series", *European Journal Of Operational Research*, Vol. 160, pp. 501-514.

Zivot, Eric (2000); *Introduction to Financial Econometrics: Chapter 4 Introduction to Portfolio Theory*, Department of Economics University of Washington, pp. 1-19.

Zurada, Jacek M. (1992), *Introduction to Artificial Neural Systems*, West Publishing Company, St. Paul, USA.

Zügöl, Muhittin ve Cumhuri Şahin (2009); "İMKB 100 Endeksi ile Bazı Makro Ekonomik Değişkenler Arasındaki İlişkiyi İncelemeye Yönelik Bir Uygulama", *Akademik Bakış*, Sayı:16, ss. 144-159.

TEBLİĞLER ve BÜLTENLER

Borsa Yatırım Fonlarına İlişkin Esaslar Tebliği, Seri: VII, No: 23, 13.04.2004.

International Statistical Release, Efama, 2008:Q4

İstanbul Menkul Kıymetler Borsası (İMKB) Aylık Bültenleri (Ocak 2001-Aralık 2008).

İş Yatırım Menkul Değerler A.Ş. Aylık Analiz Dergisi-Aralık 2008.

Kurumsal Yatırımcılar Derneği (KYD) Aylık Bültenleri (Ocak 2001 – Aralık 2008).

Mutual Fund Fact Book, Investment Company Institute (ICI), 48. Baskı, 2008.

Mutual Fund Fact Book, Investment Company Institute (ICI), 49. Baskı, 2009.

Sermaye Piyasası Kurulu, “Yatırım Fonlarına İlişkin Esaslar Tebliği”, Seri: VII No.10: Resmi Gazete, 19.12.1996, S:22852

Sermaye Piyasası Kurulu (SPK) Aylık Bültenleri (Ocak 2001–Aralık 2008)

Sermaye Piyasası Kurulu (SPK) 2008, Faaliyet Raporu, 2008.

SPK Tanıtım Rehberi.

Quarterly Statistical Release, Efama, N:35-36, 2008.

Tekstilbank Yatırım Fonu Bülteni- Nisan 2008.

Türkiye Sermaye Piyasası Aracı Kurumlar Birliği (TSPAKB), Türkiye Sermaye Piyasası Raporu 2008.

TSPAKB (2004); “Para ve Sermaye Piyasalarının Vergilendirilmesi”, Yayın No: 19.

Worldwide Mutual Fund Assets and Flows Third Quarter, ICI, 2008.

Yatırım Fonlarına İlişkin Esaslar Tebliğinde Değişiklik Yapılmasına Dair Tebliğ, Seri: VII, No: 24, 08.10.2004.

Yatırım Fonlarına İlişkin Esaslar Tebliğinde Değişiklik Yapılmasına Dair Tebliğ, Seri: VII, No: 29, 2.09.2006.

Yatırım Fonlarına İlişkin Esaslar Tebliğinde Değişiklik Yapılmasına Dair Tebliğ, Seri: VII, No: 33, 25.05.2007.

Yatırım Fonlarına İlişkin Esaslar Tebliğinde Değişiklik Yapılmasına Dair Tebliğ, Seri: VII, No: 35, 21.03.2008.

Yatırım Fonlarına İlişkin Esaslar Tebliğinde Değişiklik Yapılmasına Dair Tebliğ, Seri: VII, No: 37, 21.01.2009.

WEB SAYFALARI

<http://www.akportfoy.com.tr> Erişim Tarihi: Ocak 2008

<http://www.fonbul.com>, Erişim Tarihi: Aralık 2007

<http://www.kyd.org.tr>, Erişim Tarihi: Aralık 2007

<http://www.spk.gov.tr>, Erişim Tarihi: Aralık 2007

<http://www.imkb.gov.tr> Erişim Tarihi: Ocak 2008

<http://www.tcmb.gov.tr> Erişim Tarihi: Aralık 2007

<http://www.işyatirim.com.tr>. Erişim Tarihi: Aralık 2007

<http://www.efama.org>. Erişim Tarihi: Şubat 2008

www.tspakb.org.tr. Erişim Tarihi: Şubat 2008

www.tspakb.org.tr.(Erişim Tarihi:01.04.2009).

http://www.capital.com.tr/haber.aspx?HBR_KOD=4133./ErişimTarihi:
01.04.2009.

<http://www.sec.gov/investor/pubs/inwsmf.htm/1>/Erişim Tarihi: Haziran 2009

<http://www.imkb.gov.tr/yayinlar/spkilavuzu.htm>/Erişim Tarihi: 25.03.2008.

<http://www.gedikyatirim.com.tr> ./Erişim Tarihi: Haziran 2009.

[http://siteresources.worldbank.org
worldbank_UCITS_presentation_06\[1\]06.06_TUR_](http://siteresources.worldbank.org/worldbank_UCITS_presentation_06[1]06.06_TUR/)/Erişim Tarihi: 17.02.2009.

ÖZGEÇMİŞ

1975 yılında Ankara'da doğan Fikriye Karacameydan, orta ve lise öğrenimini sırasıyla Peyamitepe İlköğretim Okulu ve Gazi Lisesinde tamamlamıştır. 1993 yılında kazandığı Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Ekonometri bölümünü 1997 yılında başarıyla bitirmiştir.

2007 yılında yüksek lisans eğitimine Bozok Üniversitesi Sosyal Bilimler

Enstitüsü İşletme/Finansman Bilim dalında başlayan Fikriye Karacameydan, evli ve bir çocuk annesidir.

İletişim Bilgileri

Adres:

TOKİ Emniyet Müdürlüğü Lojmanları

Şeyh Osman Mahallesi

TOKİ 2. Bölge D34 Blok No:1/3

66100 YOZGAT

Telefon:

(505) 384 68 33

E-posta:

fikriyedip@gmail.com



