

KARADENİZ TEKNİK ÜNİVERSİTESİ * SOSYAL BİLİMLER ENSTİTÜSÜ

EKONOMETRİ ANABİLİM DALI

EKONOMETRİ PROGRAMI

**YAPAY SİNİR AĞLARI İLE İMKB-100 ENDEKSİ
GELECEK DEĞER ÖNGÖRÜSÜ**

YÜKSEK LİSANS TEZİ

Ali AKAY

TEMMUZ - 2009

TRABZON

KARADENİZ TEKNİK ÜNİVERSİTESİ * SOSYAL BİLİMLER ENSTİTÜSÜ

EKONOMETRİ ANABİLİM DALI

EKONOMETRİ PROGRAMI

**YAPAY SİNİR AĞLARI İLE İMKB-100 ENDEKSİ
GELECEK DEĞER ÖNGÖRÜSÜ**

Ali AKAY

Karadeniz Teknik Üniversitesi – Sosyal Bilimler Enstitüsü’nce

Bilim Uzmanı (Ekonometri)

Unvanı Verilmesi İçin Kabul Edilen Tez’dir.

Tezin Enstitüye Verildiği Tarih : 01.07.2009

Tezin Sözlü Savunma Tarihi : 07.08.2009

Tezin Danışmanı : Yrd. Doç. Dr. Tuba YAKICI AYAN

Jüri Üyesi : Prof. Dr. Mustafa KÖSEOĞLU

Jüri Üyesi : Doç. Dr. Birdoğan BAKİ

Enstitü Müdürü : Doç. Dr. Haydar AKYAZI

Temmuz - 2009

TRABZON

0. SUNUŞ

00. Önsöz

Bu tez çalışması Karadeniz Teknik Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri anabilim dalı kapsamında yürütülmüştür. Çalışmada, İstanbul Menkul Kıymetler Borsası ulusal 100 endeksi (İMKB-100) üzerinde aylık gelecek değer tahmini için Peltarion Synapse paket programı ile oluşturulan iki farklı yapay sinir ağı modeli kullanılmıştır. Ayrıca modellerden elde edilen verilere göre modellerin endeks hareket yönü tahminleri ve bu tahminlere bağlı Al-Tut-Sat sinyalleri üretilmiş ve üretilen sinyallere göre de getiri endeksleri hesaplanmıştır. Çalışmada öncelikli olarak makro ekonomik değişkenlerin İMKB-100 endeksi üzerindeki etkisinin ve buna bağlı olarak endeksin bu verilerle tahmin edilebilirliğinin araştırılması amaçlanmıştır. Bu amaçla birçok makro ekonomik değişken incelenmiş ve bunlardan istatistiksel olarak anlamlı olan değişkenler modellerde girdi değişkenleri olarak kullanılmıştır. Bağımsız değişkenlerin seçiminde adımsal regresyon yöntemi uygulanmıştır. İncelenen dönemde enflasyon ve kapasite kullanım oranı, istatistiksel olarak anlamlı çıkmadığından modellere dâhil edilmemiştir. Testler sonucunda külçe altın aylık ortalama fiyatı, dar para arzı (M1), dolar kuru ve 6 aylık mevduat faiz oranı bağımsız değişkenler olarak seçilmiştir. Yapılan testlerden sadece modellerde kullanılan değişkenlere ilişkin olanlar çalışmada gösterilmiştir.

Bu çalışmada yardım ve desteğini esirgemeyen ve tez danışmanlığımı üstlenen değerli hocam Sayın Yrd. Doç. Dr. Tuğba YAKICI AYAN'a ve çalışmanın başında beni yönlendiren ve değerli bilgilerini paylaşan hocam Sayın Öğr. Gör. Aykut KARAKAYA'ya katkılarından dolayı teşekkür ederim. Ayrıca her anımda yanımda olan sevgili eşim Fatma'ya ve sevgili oğlum Mirza Hasancan'a sonsuz şükranlarımı sunarım.

Trabzon, Temmuz 2009

Ali AKAY

01. İçindekiler

	<u>Sayfa Nr.</u>
0. SUNUŞ	II
00. Önsöz.....	II
01. İçindekiler.....	III
02. Özet	VI
03. Summary	VII
04. Tablolar Listesi	VIII
05. Şekiller Listesi	IX
06. Grafikler Listesi	X
07. Kısaltmalar Listesi	XII
GİRİŞ.....	1-2

BİRİNCİ BÖLÜM

1. İSTANBUL MENKUL KIYMETLER BORSASI (İMKB).....	3-17
10. Kısa Tarihçe.....	3
11. Kuruluş ve Gelişme.....	3
12. İMKB'ye Etki Eden Değişkenler.....	7
120. Enflasyon	7
121. Döviz Kuru.....	9
122. Faiz Oranları.....	10
123. Para Arzı	12
124. Değerli Maden (Altın) Fiyatları	13
125. Ekonomik Faaliyet Göstergeleri.....	14
126. Gayrisafi Milli Hâsıla	15
127. Yatırımlar	15
128. Küresel Durum	15
129. Siyasal ve Psikolojik Faktörler – Siyasi Belirsizlikler ve İstikrar	16

İKİNCİ BÖLÜM

2. YAPAY SİNİR AĞLARI	18-46
20. Yapay Zekâ Kavramı	19
21. Yapay Sinir Ağlarının Gelişimi	19
210. 1970 Öncesi.....	19
211. 1970 Sonrası.....	20
22. Yapay Sinir Ağlarının Sınıflandırılması	21
23. Yapay Sinir Ağlarının Yapısı	21
24. Yapay Sinir Ağlarının En Çok Kullanılan Modelleri	28
240. Tek Katmanlı Algılayıcılar	28
241. Basit Algılayıcı	28
242. ADALINE / MADALINE Modeli	29
243. Çok Katmanlı Algılayıcılar.....	29
25. Diğer Yapay Sinir Ağı Modelleri	36
250. LVQ Ağları.....	36
251. ART Ağları	37
252. Geri Dönüşümlü Ağlar ve Eleman Ağı	37
26. Yapay Sinir Ağlarının Uygulama Alanları.....	37
27. Yapay Sinir Ağları ile Yapılan Borsa Endeks Tahmini Uygulamaları	39

ÜÇÜNCÜ BÖLÜM

3. YAPAY SİNİR AĞLARI İLE İMKB-100 ENDEKSİNİN TAHMİNİ UYGULAMASI	47-84
30. Uygulamada Kullanılan Bağımlı Değişken.....	47
31. Uygulamada Kullanılan Bağımsız Değişkenler.....	47
32. Uygulama Modeli	51
320. Gecikmesiz Model.....	51
321. Gecikmeli Model.....	52
33. Modellerden Elde Edilen Sonuçlar	53
330. Gecikmesiz Model Sonuçları	53
331. Gecikmeli Model Sonuçları	60

34. Sonuların Deęerlendirilmesi	67
340. Birinci Ařamada Modellerin Endeks Kapanıř Deęerleri Tahmin Performanslarının Karřılařtırılması	71
341. İkinci Ařamada Modellerin Endeks Kapanıř Deęerleri Tahmin Performanslarının Karřılařtırılması	77
342. Modellerin Endeks Hareket Yönu Tahmin Performanslarının Karřılařtırılması	83
4. SONU ve ÖNERİLER	85-87
YARARLANILAN KAYNAKLAR	88-100
ALIřMADA KULLANILAN VERİLER	101-106
ÖZGEMİř	107

02. Özet

Bu çalışmada, İstanbul Menkul Kıymetler Borsası Ulusal 100 endeksi (İMKB-100), mevduat faiz oranları, para arzı, altın fiyatları ve dolar kuru değişkenleri ile tahmin edilmeye çalışılmıştır. Çalışmada Şubat 1991 – Mayıs 2009 tarihleri arasındaki değerler aylık olarak ele alınmıştır.

Tahminler için yapay sinir ağı modellerinden çok katmanlı algılayıcılar kullanılmıştır. Peltarion Synapse programı ile iki farklı model oluşturulmuş ve ikinci modele İMKB-100 endeksinin gecikmeleri eklenmiştir.

Elde edilen tahmin değerleri küresel kriz öncesi ve sonrası olarak iki aşamada incelenerek karşılaştırılmıştır.

Çalışma sonucunda gecikmeli modelin daha iyi öğrendiği sonucuna varılmıştır. Modellerin tahmin performanslarının normal dönemde farklı olmadığı ancak kriz döneminde gecikmeli modelin daha iyi tahminler yaptığı gözlenmiştir.

03. Summary

In this study, Istanbul Stock Exchange National 100 index (ISE-100), were estimated with the variables set of deposit interest rates, money supply, gold prices and the dollar. Study have been discussed the values between in February 1991 - May 2009 dates on monthly basis.

Multi-layer perceptron model of the artificial neural network models, is used for estimates. Created two different models with Peltarion Synapse program and the delays of ISE-100 index were added to the second model.

Obtained estimate values, were compared by examined in two stages as before and after the global crisis.

Study results concluded that the delay learned model was better. Estimate performance of models, were not different in normal periods. However, in the period of crisis, the delay model has been better than other model.

04. Tablolar Listesi

<u>Tablo Nr.</u>	<u>Tablonun Adı</u>	<u>Sayfa Nr.</u>
1	Toplama Fonksiyonları	25
2	Aktivasyon Fonksiyonları	26
3	Mevduat Faiz Oranları Adımsal Regresyon Testi Sonuçları	48
4	Para Arzı Adımsal Regresyon Testi Sonuçları.....	49
5	İMKB-100 Gecikmeleri Adımsal Regresyon Testi Sonuçları	50
6	Gecikmesiz Model Tahmin ve Hata Değerleri.....	54
7	Gecikmesiz Model Endeks Yönü Tahmini ve Kazanç Değerleri.....	55
8	Gecikmeli Model Tahmin ve Hata Değerleri.....	61
9	Gecikmeli Model Endeks Yönü Tahmini ve Kazanç Değerleri.....	62
10	Endeks Değeri Tahmin Sonuçları Karşılaştırma Tablosu.....	68
11	Endeks Yönü Tahmin Sonuçları Karşılaştırma Tablosu.....	68

05. Şekiller Listesi

<u>Şekil Nr.</u>	<u>Şekil Adı</u>	<u>Sayfa Nr.</u>
1	Sinir Hücresi Yapısı	22
2	Sinir Hücrelerinin Bağlantıları.....	22
3	Yapay Sinir Hücresi Bağlantıları	23
4	Temsili Yapay Sinir Ağı.....	23
5	Yapay Sinir Ağı Hücresi.....	24
6	Basit Algılayıcı.....	28
7	MADALINE Modeli	29
8	Çok Katmanlı Algılayıcı.....	30
9	Çok Katmanlı Algılayıcı Yapay Sinir Ağı Yapısı.....	31
10	Gecikmesiz Model için Çok Katmanlı Algılayıcı Yapay Sinir Ağı Yapısı.....	52
11	Gecikmeli Model için Çok Katmanlı Algılayıcı Yapay Sinir Ağı Yapısı.....	53

06. Grafikler Listesi

<u>Grafik Nr.</u>	<u>Grafik Adı</u>	<u>Sayfa Nr.</u>
1	Gecikmesiz Model Eğitim Seti Hesaplanan Değer ve Gerçek Değer Grafiği.....	56
2	Gecikmesiz Model Eğitim Seti Hata Dağılımı Grafiği	57
3	Gecikmesiz Model Hesaplanan Tahmin Değerleri ve Gerçek Değerler Grafiği.....	58
4	Gecikmesiz Model Tahmin Değerleri Hata Dağılımı Grafiği	59
5	Gecikmeli Model Eğitim Seti Hesaplanan Değer ve Gerçek Değer Grafiği ..	63
6	Gecikmeli Model Eğitim Seti Hata Dağılımı Grafiği.....	64
7	Gecikmeli Model Hesaplanan Tahmin Değerleri ve Gerçek Değerler Grafiği.....	65
8	Gecikmeli Model Tahmin Değerleri Hata Dağılımı Grafiği	66
9	Gecikmeli ve Gecikmesiz Model, Eğitim Seti için Karşılaştırmalı Hata Grafiği.....	69
10	Gecikmeli ve Gecikmesiz Model, Eğitim Seti için Karşılaştırmalı Yüzdesele Hata Grafiği	70
11	Gecikmesiz Model 1. Aşama Hesaplanan Tahmin Değerleri ve Gerçek Değerler Grafiği	72
12	Gecikmesiz Model 1. Aşama Tahmin Değerleri Hata Dağılımı Grafiği.....	73
13	Gecikmeli Model 1. Aşama Hesaplanan Tahmin Değerleri ve Gerçek Değerler Grafiği	74
14	Gecikmeli Model 1. Aşama Tahmin Değerleri Hata Dağılımı Grafiği	75

15	Gecikmeli ve Gecikmesiz Model, 1. Aşama Tahmin Değerleri için Karşılaştırmalı Hata Grafiği.....	76
16	Gecikmesiz Model 2. Aşama Hesaplanan Tahmin Değerleri ve Gerçek Değerler Grafiği	78
17	Gecikmesiz Model 2. Aşama Tahmin Değerleri Hata Dağılımı Grafiği	79
18	Gecikmeli Model 2. Aşama Hesaplanan Tahmin Değerleri ve Gerçek Değerler Grafiği	80
19	Gecikmeli Model 2. Aşama Tahmin Değerleri Hata Dağılımı Grafiği	81
20	Gecikmeli ve Gecikmesiz Model, 2. Aşama Tahmin Değerleri için Karşılaştırmalı Hata Grafiği.....	82
21	Gecikmeli Model Çıktı Değişkeninin Girdi Değişkenlerine Duyarlılık Grafiği.....	84

07. Kısaltmalar Listesi

AB	: Avrupa Birliđi
ABD	: Amerika Birleşik Devletleri
ADALINE	: Adaptive Linear Neuron
ART	: Adaptive Resonans Theory
ARCH	: Autoregressive Conditional Heteroskedasticity
ARMA	: Autoregressive Moving Average
BP	: Backpropagation
BYF	: Borsa Yatırım Fonları
ÇKA	: Çok Katmanlı Algılayıcılar
DAX	: Deutscher Aktienindex
DJIA	: Dow Jones Industry Average
DPT	: Devlet Planlama Teşkilatı
FTSE-100	: Financial Times London Stock Exchange
GSMH	: Gayri Safi Milli Hâsıla
GSYİH	: Gayri Safi Yurtiçi Hâsıla
HSI	: Hang Seng Index
NASDAQ	: National Association of Securities Dealers Automated Quotations
ISE	: İstabil Stock Exchange
İMKB	: İstanbul Menkul Kıymetler Borsası
İMKB-100	: Ulusal 100 Endeksi
LVQ	: Linear Vector Quantization
M1	: Dar Para Arzı
M2Y	: Geniş Para Arzı
MLP	: Multi Layer Perceptron
NYSE	: New York Stock Exchange
SE	: Sum of Errors
SOM	: Self Organising Feature Maps
S&P-500	: Standarts & Poor 500 Index

STI	: Straits Times Index
TBMM	: Türkiye Büyük Millet Meclisi
v.b.	: ve benzeri
YSA	: Yapay Sinir Ağları
YTL	: Yeni Türk Lirası

GİRİŞ

Finansal tahminler üzerinde birçok arařtırmacı uzun yıllardır alıřmaktadır. Bu alıřmalarda hedeflenen ama, bir finansal deęerin gelecekteki deęerinin nceden ngrlebileceęi tezini doęrulamaktır. Buna raęmen bazı arařtırmacılar, zellikle insan faktrnn etkili olduęu deęiřkenlerde bu tezin doęru olmadıęını savunmuřlardır (Etkin Piyasa Hipotezi). Bir yandan bu tartiřmalar teorik tabanda devam ederken, dięer yandan yapılan deneysel alıřmalarda bazı makro ekonomik ve finansal deęiřkenler bařarılı bir Őekilde tahmin edilebilmiřtir.

nceleri matematiksel ve istatistiksel yntemlerle yapılan tahmin denemeleri, zellikle bilgisayar teknolojisinin geliřimiyle birlikte ortaya ıkan sezgisel yntemlerin de kullanılmaya bařlamasıyla daha bařarılı sonular vermiřtir. Son yıllarda geliřen yapay zek kavramı ve ęrenmeye dayalı algoritmalar bu srece nemli katkılar saęlamıřtır. zellikle son on yılda yoęunlařan yapay sinir aęları modellerinin finansal tahminlerde kullanımı ve alınan olumlu sonular arařtırmacıların bu alana olan ilgisini artırmıřtır.

Finansal tahmin alıřmalarında kullanılan istatistiksel yntemlerden en bilineni ok Deęiřkenli Regresyon Analizi yntemidir. Ancak son yıllarda geliřtirilen yeni modeller, istatistiksel tahminlerin gcn artırmıřtır. zellikle Box-Jenkins modelleri olarak bilinen Otoregresif Hareketli Ortalamalar (ARMA) yntemi ve bu yntemin trevleri olarak geliřtirilen Entegre (Integrated) ARMA (ARIMA), mevsimsel (Seasonal) ARIMA (SARIMA), vektrel ARIMA (VARIMA) v.b. yntemler ile yapılan alıřmalar son derece bařarılı sonular vermiřtir. Ayrıca Robert Fry ENGLE tarafından geliřtirilen Autoregressive Conditional Heteroskedasticity (ARCH) modeli ve bu modelin eřitli trevleri de (GARCH, PARCH, EGARCH gibi...) finansal tahminler iin kullanılan istatistiksel yntemlerdir.

Yapay sinir aęları ile yapılan finansal tahmin alıřmalarında ise en sık kullanılan model ok Katmanlı Algılayıcılar (.K.A) modelidir. .K.A. modeli, ileri beslemeli (Feed

Forward) bir modeldir. Bu model Geriye Yayılma Algoritması (Backpropagation Algorithm) veya bu algoritmanın çeşitli türevleri kullanılarak eğitilmektedir. En küçük karelerin ortalaması yöntemini temel alan Genelleştirilmiş Delta Kuralı, geriye yayılma algoritmasının en yaygın kullanılan türüdür. ÇKA ağının eğitilmesinde bununla birlikte uygulamalarda Geriye Yayılma Algoritmasına alternatif öğrenme yöntemleri de kullanılmaktadır. Alternatif yöntemler arasında en sık kullanılanlar Swarm Optimizasyonu, Genetik Algoritmalar, Bulanık Mantık algoritmalarıdır. Özellikle YSA ile son yıllarda yapılan finansal tahminlerde, çeşitli yöntemlerin birlikte kullanıldığı melez modeller ağırlık kazanmıştır. Bunların yanında istatistiksel yöntemlerle yapay zekâ yöntemlerinin birlikte kullanıldığı modeller de araştırmacılar tarafından finansal tahminlerde yaygın olarak kullanılmaktadır.

Bu çalışmada da yapay sinir ağlarının çok katmanlı algılayıcılar modeli kullanılarak İMKB-100 endeksi üzerinde aylık tahminler yapılmış ve tahminlerin başarısını artırmak için çeşitli önerilerde bulunulmuştur. Çalışmada öğrenme algoritması olarak geriye yayılma algoritması kullanılmıştır.

Çalışma dört bölümden oluşmaktadır. Birinci bölümde İMKB'nin tarihçesi ile birlikte Türkiye ve dünyada borsa endekslerine etki eden faktörlere ve bu konudaki bilimsel çalışmalara yer verilmiştir. İkinci bölümde YSA ve özellikle ÇKA ile ilgili teorik bilgilere ve Türkiye ve dünyada YSA ile yapılan borsa endeks tahmini uygulamalarına değinilmiştir. Üçüncü bölümde, bu çalışma kapsamında geliştirilen İMKB-100 endeksi gelecek değer tahmini için oluşturulan modeller ve bu modellerden elde edilen sonuçlar ayrıntılı olarak ele alınmıştır. Dördüncü bölümde ise ilgili model sonuçları değerlendirilmiş ve bu sonuçlara bağlı olarak çeşitli çıkarımlar yapılmış ve öneriler sunulmuştur.

BİRİNCİ BÖLÜM

1. İSTANBUL MENKUL KIYMETLER BORSASI (İMKB)

10. Kısa Tarihçe

İMKB'nin tarihçesi kısaca şöyledir (DURUKAN, 1999, ss. 19):

İMKB'de hisse senetleri 3 Ocak 1986'da işlem görmeye başlamış olmasına rağmen, ilk hisse senedi piyasası 1866'da Osmanlı İmparatorluğu'nda kurulmuştur. Türkiye Cumhuriyeti Devletinin kurulmasını takiben 1929'da hisse senedi piyasası "İstanbul Hisse Senetleri ve Döviz Borsası" adı altında yeniden düzenlenmiştir. Ancak, 1981'de Sermaye Piyasası Kanununun çıkması ve bu kanun ile Sermaye Piyasası Kurulu'nun oluşturulması borsanın tarihinde atılan önemli bir adım olmuştur. Bu adımı takiben 1985'in sonunda resmi olarak kurulan İMKB, 1986'nın başında faaliyete geçmiştir.

1989 yılında yabancı yatırımcılara İMKB'de işlem yapma izninin verilmesi ile İMKB, özellikle, uluslararası düzeyde varlığını hissettirici bir gelişme göstermiştir. İMKB'nin uluslararası düzeyde yerini almak amacı ile atılan adımların yanında, borsanın işleyişini etkinleştirici birçok yenilik de getirilmiştir. Özellikle, 1994'te günlük işlem süresi, birinci seans 10.00 -12.00 ve ikinci seans 14.00 - 16.00 arasında olmak üzere, iki saatten dört saate çıkarılmıştır. Ek olarak, aynı yıl tüm işlemlerde otomasyona geçilmiştir. İMKB'de gerçekleştirilen işlemler ile ilgili bilgiler ise, Reuters, ulusal televizyon kanalları ve İnternet aracılığı ile kamuya aktarılmaktadır.

11. Kuruluş ve Gelişme

İMKB'nin kuruluş ve zaman içindeki gelişimi ise şu şekilde özetlenebilir (SONGUR, 2009, ss. 5-9) :

Modern zamanlarda, İstanbul Menkul Kıymetler Borsası'nın resmen kurulması 26 Aralık 1985 tarihinde olmuştur. Ancak bu Türkiye'deki ilk menkul kıymetler piyasası değildir. İlk borsa 1866 yılında Osmanlı İmparatorluğu zamanında kurulmuş olan Dersaadet Tahvilat Borsası'dır. 1929 yılında çıkartılan 1447 sayılı "Menkul Kıymetler ve Kambiyo Borsaları Kanunu" ile sermaye piyasalarının, o zamanki ismiyle "İstanbul Menkul Kıymetler ve Kambiyo Borsası" adı altında organize olması sağlanmıştır. Borsa kısa sürede gelişim göstermiş ve girişimcilerin fon ihtiyaçlarının karşılanmasına katkıda bulunmuştur. 1929 Dünya Ekonomik Bunalımı ve İkinci Dünya Savaşı, Borsa'nın gelişimini olumsuz yönde etkilemiştir. Dahası, ileriki yıllarda gelişen endüstriye paralel olarak hisse senetlerini halka arz eden anonim şirketlerin sayısı da artmış ve çoğu bireysel olan yatırımcılardan yüksek oranda talep görmüştür.

Türkiye 1980'de uzun yıllar takip ettiği ithal ikameci büyüme modelini bir yana bırakarak liberalizmi iktisadi politika olarak benimsemiştir. 24 Ocak kararları olarak bilinen ve finansal derinleşmeyi yaratacağı ileri sürülen politikalar uygulamaya konulduktan kısa bir süre sonra iflas etmiş ve bankerler krizi olarak bilinen krizde ülkeyi ciddi kayıplara uğratmıştır. Sermaye hareketliliğinin hukuki ve kurumsal alt-yapı olmadan serbest rekabetçi piyasa koşullarında büyük ölçüde artması kriz dinamiklerini de tetiklemiş, sermayenin maliyetini arttırmıştır. Artan sermaye hareketliliğinin sağlıklı bir şekilde işlemesi için mevzuat değişikliklerine gidilmiş ve kurumlar oluşturulmuştur.

Bu çerçevede, 1981 yılında çıkartılan Sermaye Piyasası Kanunu'nu 1982'de menkul kıymetler piyasasını düzenleyen ve denetleyen kuruluş olan Sermaye Piyasası Kurulunun kurulması izlemiştir. 1982 krizi sonrasında daha ciddiyetle ele alınan bu çalışmalar sonucunda, 1984 yılında Resmi Gazete'de Menkul Kıymet Borsalarının Kuruluşu ve Çalışma Esasları yayınlanmıştır. Takip eden yıl bu esaslara ilişkin mevzuatın TBMM'de kabul edilmesinin ardından İMKB resmen kurulmuş ve 1986 yılında Karaköy - Tophane'de faaliyetlerine başlamıştır. Türkiye'de yaygın finansal anlayışın ve hukuki, kurumsal çerçevenin sığ olması yüzünden, İMKB'nin kurulması ve fonksiyonel hale gelmesi görüldüğü gibi bir hayli gecikmiştir.

İMKB verilerine göre, kuruluşundan 2007 yılı sonuna kadar geçen süre içerisinde İMKB'nin ekonomiye aktardığı kaynak tutarı \$37 milyar tutarını aşmıştır. Aynı süre

içerisinde Borsa pazarlarında işlem gören şirket sayısı 1986 yılındaki 80 seviyesinden 2007 yılı sonunda 319'a çıkmış bulunmaktadır. Bu şirketlerin yanı sıra 8 Borsa Yatırım Fonu'nun katılma belgeleri de İMKB'de işlem görmektedir. 2007 sonu itibari ile İMKB'de ki şirketlerin senetlerden 292'si Ulusal Pazar'da, 14 tanesi İkinci Ulusal Pazar'da, 3 tanesi Yeni Ekonomi Pazarı'nda ve 10 tanesi de Gözaltı Pazarı'nda işlem görmektedir.

İMKB Hisse Senetleri Piyasasında gerçekleşen işlem hacmi tutarı kuruluşundan itibaren artmış, 1986 yılında \$13 milyon seviyesinde iken, kuruluşundan on yıl sonra 1996 yılında \$36,7 milyar seviyesine yükselmiştir. Artışına devam eden işlem hacmi tutarı 2007 yılında ise \$300,8 milyar olarak gerçekleşmiştir. Bu artışı, aynı dönem içinde ekonomiye aktarılan kaynak ile karşılaştırdığımızda, İMKB'nin beklenenden çok daha düşük oranda tasarruf – yatırım ekseninde arabuluculuk yaptığı ortaya çıkar. Bu veriler ışığında, İMKB'nin daha çok Keynesyen spekülative motivasyona açık olarak işlediği ileri sürülebilir.

Ayrıca, bu işlem hacminin İMKB pazarlarındaki dağılımı tetkik ettiğimizde işlemlerin büyük bir kısmının ulusal pazar da gerçekleştiği görülmektedir. 2007 yılında gerçekleştirilen Hisse Senetleri Piyasası işlem hacminin %97'si Ulusal Pazar da gerçekleştirilmiştir. Ulusal Pazar'da gerçekleştirilen toplam işlem hacmi tutarı \$291,4 milyar olmuştur. 2007 yılında, İMKB'nin diğer pazarları olan İkinci Ulusal Pazar'da \$3,4 milyar, Yeni Ekonomi Pazarı'nda \$0.43 milyar ve Gözaltı Pazarı'nda ise \$0.13 milyar tutarında işlem gerçekleştirilmiştir. 2007 yılında gerçekleştirilen açığa satış işlemlerinin toplam hacmi ise \$13,57 milyar olmuştur. Başka bir deyişle, İMKB'de 2007 yılında gerçekleşen işlem hacminin yaklaşık %4,5'i sahip olunmayan hisse senetlerinin ödünç alınması ile gerçekleşmiştir. Açığa satış işlemlerinin spekülasyon amacıyla yapıldığı göz önünde alınırsa, bu işlemlerin tamamen bir “casino” mantığını yansıttığı öne sürülebilir. Öte yandan, İMKB Hisse Senetleri Piyasası günlük ortalama işlem hacmi, 2007 yılında \$1,2 milyar olarak gerçekleşmiştir.

Ulusal Pazar'da kotasyon kriterleri İMKB kotasyon yönetmeliğinin 13'üncü maddesinde düzenlenmiştir. Bu maddeye göre şirket halka arzdan önceki son iki yılda vergi öncesi kar etmiş olmalı, yine bağımsız olarak denetlenmiş bilançosunda özsermayesi 14 milyon YTL olmalıdır. Dahası, şirketin halka arz edilen hisse senetlerinin piyasa değeri

en az 21 milyon YTL olmalı ve nominal değerinin ödenmiş olması gerekmektedir. Katı bir yapı sergileyen bu kuralların, firmaların borsanın en geniş tabanlı finansman imkânını elde edebilecekleri Ulusal Pazar'a kotalanmasını zorlaştırıcı bir yapıda olduğu öne sürülebilir. Öte yandan, firmaların Ulusal Pazar'da işlem görme şartları bu kadar katı iken, İMKB'deki işlem hacminin %97'sinin bu pazarda gerçekleşmesi küçük ve orta ölçekli firmaların finansman bulması amacıyla oluşturulan İkinci Ulusal Pazar'ın yeterince etkin olmadığını ortaya koymaktadır.

2005 yılından itibaren İMKB Ulusal Pazar'da işlem gören Borsa Yatırım Fonları (BYF) önemli gelişmeler kaydetmiştir. BYF'nin bir kısmı bazı sektörel ve genel endeksleri yansıtırken, diğer bir kısmı da devlet iç borçlanma senetleri fiyatlarına dayalı durumdadır. BYF'nin 2005 yılında \$1,67 milyar olan işlem hacmi, 2007 yılında \$5,45 milyara yükselmiştir. Bazı sektörel ve genel endeksleri gösteren BYF'nin yanında, işlem görmeye başlayan devlet iç borçlanma senetleri fiyatlarına dayalı BYF alternatif yatırım olanakları durumundadır. BYF'lerdeki işlem hacmindeki yüksek artış dikkat çekicidir.

İMKB de işlem gören şirketlerin toplam piyasa değeri (kapitalizasyon değeri) ilk hesaplandığı 1986 yılından 2007 yılı sonuna kadar büyük oranda artmış bulunmaktadır. 1986 yılı sonunda \$938 milyon seviyesindeki kapitalizasyon değeri 2007 yılı sonunda \$290 milyar seviyesine yükselmiştir. Başka bir deyişle, borsanın kapitalizasyon değeri yirmi bir yıllık süreç içerisinde 309 kat artmış bulunmaktadır. Dahası, İMKB endeksi 2002 yılından 2007 yılının sonuna kadar geçen sürede ABD Doları bazında 7,6 kat artış gerçekleştirmiştir. Aynı dönem de Türkiye'nin sabit fiyatlarla hesaplanan Gayri Safi Yurtiçi Hâsıla (GSYİH)' sı ise kümülatif olarak % 48 artmış bulunmaktadır. Dolayısıyla İMKB' deki şirket değerlerindeki artış GSYİH çok üzerinde gerçekleşmiştir.

Türkiye özellikle 2003 yılından itibaren gerek özelleştirmeler, gerekse özel kesimin sermaye açılımları sonucunda ciddi miktarda yabancı sermaye çekmeyi başarmıştır. Bu doğrultuda, yabancı yatırımcıların da İMKB hisse senetleri piyasasına olan ilgisi oldukça yoğun olmuştur. 2007 yılı sonu itibari ile yabancı yatırımcıların halka açık hisse senetleri içerisindeki payları %72 seviyelerine ulaşmıştır. Yine yabancı yatırımcıların 2007 yılı işlem hacmi içerisindeki payları da %24 olmuştur. İMKB böylece devletin özelleştirmeler yoluyla bütçe finansmanına yardımcı olan bir özellik arz etmeye başlamıştır. Öte yandan

bu gelişmeler İMKB'yi kendi inisiyatifinin erişemeyeceği dış piyasalardaki dalgalanmalara açmış, böylece borsa sıcak paranın yoğunluklu olarak dalgalandığı bir “casino” haline dönüşmüştür. Bir noktada devlet bütçe finansmanının belli bir bölümünü bu “casino”dan yapmıştır.

Bu şekilde işlem hacmi artmış, yabancılara açılmış ve derinleşmeye başlamış olan İMKB'nin içinde yaşanan krizden nasıl etkileneceği ve bu krize nasıl karşı durabileceği onun faaliyetlerini düzenleyen kurallarla ilgilidir. Bir sonraki bölüm İMKB'nin işleyişini düzenleyen kuralları, halka arz sürecini ve koşullarını incelemektedir.

12. İMKB'ye Etki Eden Değişkenler

120. Enflasyon

Teorik olarak genel fiyat seviyesindeki artış olarak ifade edilen enflasyon, hisse senedi fiyatlarını aynı doğrultuda etkilemektedir. Enflasyon oranındaki artış milli paranın değerini düşüreceğinden hisse senetlerinin fiyatında bir artış olacaktır. Bu bakış açısı ile teoride enflasyon ile hisse senedi fiyatları arasında pozitif yönlü bir ilişki beklenir (KARAMUSTAFA - KARAKAYA, 2004, s.23).

Fama - Schwert (1977), 1953-1971 dönemini kapsayan çalışmalarında beklenen ve beklenmeyen enflasyon oranının hisse senedi getirilerini negatif yönde etkilediği sonucuna varmışlardır.

Fama (1981), diğer bir çalışmasında ise hisse senedi getirileri ile enflasyon arasındaki negatif ilişkinin, enflasyonun harcamalar ve sermaye ve üretimdeki ortalama reel getiri oranı gibi reel aktiviteler üzerindeki olumsuz etkisinden kaynaklandığını öne sürmüştür (Proxy Etkisi Hipotezi).

Adrangi - Chatrath (2002), Bordo ve diğerleri (2008) ve Shanmugamand - Misra (2008)'nin de aralarında bulunduğu birçok araştırmacı, Fama'nın Proxy Hipotezini destekleyici olarak hisse senedi fiyatları ile enflasyon oranı arasında negatif bir ilişki olduğunu savunmaktadırlar.

Kool - Hafer (1986) ise Fama'nın savını test etmek için yaptığı çalışmada 1950 öncesi enflasyon ile hisse senedi getirileri arasındaki ilişkinin bu teoriye uygun olmadığını söylemiştir.

Fitzpatrick (1994) ve Alexakis ve diğerleri (1996) bu savı bir adım daha ileri götürerek, negatif etkiye neden olan faktörün enflasyonda beklenmeyen artış olduğunu öne sürmektedirler (DURUKAN 1999).

Abdullah - Hayworth (1993) ise enflasyonun olduğu durumlarda, hisse senedinin firmalara borcun getirdiği yükümlülükleri getirmemesi nedeni ile daha avantajlı olmasından dolayı, hisse senetleri fiyatları ile enflasyon arasında pozitif yönlü bir ilişki bulunduğunu öne sürmektedir (DURUKAN, 1999).

Karamustafa - Karakaya (2004), literatürdeki uzun dönemdeki ters yönlü anlamlı ilişkinin Türk hisse senedi piyasası açısından da kısmen geçerli olduğu sonucuna varmıştır. Bu doğrultuda kısa ve uzun dönem ilişkilerinin birlikte ele alındığı hata düzeltme modelinde enflasyonun işlem hacmi ve işlem miktarı üzerinde ters yönlü etkisinin olduğu ortaya konmuştur. Ancak kısa dönem ilişkiler ele alındığında, enflasyonun işlem hacmi ile pozitif yönlü ilişkisinin olduğu, işlem miktarı üzerinde ise herhangi bir etkisinin olmadığı görülmüştür. İşlem gören şirket sayısı açısından ise, uzun ve kısa dönemde enflasyon eğiliminin etkili olmadığı çalışmadan elde edilen diğer bir sonuçtur.

Durukan (1999) ise yaptığı çalışmada enflasyon ile borsa endeksi arasındaki ilişkinin istatistiksel olarak anlamlı olmadığı sonucuna ulaşmıştır.

Akkum - Vuran (2005) ise enflasyon oranının hisse senedi fiyatlarında etkili olduğunu savunmuşlar ve çalışmalarında, enflasyon oranları ile getiriler arasında genelde pozitif ilişkinin var olduğunu göstermişlerdir.

Zügül - Şahin (2009) de enflasyon oranı ile İMKB 100 endeksi arasında pozitif yönlü bir ilişki saptamışlardır.

Atan ve diğeri (2004) çalışmalarında, analize dâhil edilen 29 hisse senedinden 20 hisse senedinin enflasyon oranına ait β katsayısını istatistiksel olarak anlamlı bulmuşlardır. 29 hisse senedinden 14 tanesinin (%48) β katsayısı pozitif değer almıştır. Bu senetlerin getirileri Tüketici Fiyatları Endeksi ile aynı yönde hareket etmektedir.

121. Döviz Kuru

Alexakis ve diğeri (1996), Adjasi ve diğeri (2008) gibi birçok araştırmacı teorik olarak gelişmekte olan piyasalarda yatırımcıların, döviz alternatif bir yatırım aracı olarak görmelerinden dolayı, döviz kuru ile borsa endeksi arasındaki ilişkinin negatif olacağını söylemişlerdir. Ayrıca Abdullah - Hayworth (1993)'da göre ulusal paranın değerinin düşeceği yönündeki beklenti ve bu durumda yabancıların hisse senedine yapacakları yatırımlarında döviz kurundan kaynaklanacak kayıplarla karşılaşması, hisse senedi fiyatlarında negatif bir etki yaratacaktır (DURUKAN, 1999, s.28).

Yücel - Kurt (2003) ise, döviz kurunun hisse senedi fiyatları üzerindeki etkisinin firmaların ihracatçı olup olmadığına göre değişeceğini ve negatif ilişkinin ihracatçı firma değerleri üzerinde etkin olduğunu savunmuşlardır.

Akkum - Vuran (2005) merkez bankası döviz sepetini kullanarak yaptıkları çalışmada çoğu mali sektör firmalarının denklemlerinde belirlenen döviz sepeti değişkeni ile hisse senedi getirileri arasında beklendiği şekilde negatif ancak zayıf ilişkiler olduğu belirtmişlerdir.

Zügül - Şahin (2009) de döviz kurları ile İMKB 100 endeksi arasında negatif yönlü bir ilişki olduğunu göstermişlerdir.

Chi ve diğeri (2007), Li - Huang (2008), Rahman - Uddin (2009)'nin aralarında bulunduğu birçok araştırmacı ise çalışmalarında döviz kuru ile hisse senedi fiyatları arasındaki ilişkinin istatistiksel olarak anlamlı olmadığını sonucuna ulaşımlardır.

Bazı deneysel çalışmalarda döviz kuru ile hisse senedi fiyatları arasında pozitif ilişkiler elde edilmiştir. Nitekim Sevüktekin - Nargeleçekenler (2007), deneysel çalışmalarında,

döviz kuru ve borsa endeksi arasında uzun dönemde pozitif yönlü bir ilişki olduğunu ortaya koymuşlardır. Çalışma 01.1986 – 12.2006 dönemini kapsayan aylık veriler kullanılarak yapılmıştır.

Durukan (1999) da döviz kuru ve borsa endeksi arasındaki ilişkiyi pozitif olarak bulmuştur.

Atan ve diğerleri (2004), çalışmalarında analize dâhil edilen 29 hisse 14 hisse senedinin ortalama döviz kuru sepeti değişkenine ait β katsayısı istatistiksel olarak anlamlı bulunmuştur. 29 hisse senedinden 18 tanesinin (%62) β katsayısı pozitif değer almıştır. Bu senetlerin getirilerinin Ortalama Döviz Kuru Sepeti ile aynı yönlü hareket etmektedir. Ortalama Döviz Kuru Sepetinin artması bu hisse senetlerinin getirilerinin de artmasına sebep olmaktadır.

122. Faiz Oranları

Faiz oranları hisse senedi fiyatları üzerinde dolaylı ve dolaysız olarak iki tür etkiye sahiptir. Yatırımcılar, yatırımlarından elde edecekleri getiri oranının en az piyasadaki faiz oranı kadar olmasını beklerler. Dolayısı ile bu oranı yatırımlarından bekledikleri nakit akışlarının bugünkü değerini belirlerken iskonto oranı olarak kullanırlar. Faiz oranının gerçek değerini hesaplanmasında kullanımı, faiz oranının yatırımcının al/sat kararında dolaysız olarak etkin bir rol oynamasına neden olur. Al/sat kararı da hisse senedi fiyatlarında belirleyici etkindir (DURUKAN, 1999, s.19).

Faiz oranının değer belirleyici rolünün yanında, Fitzpatrick (1994) ve Abdullah - Hayworth (1993) izlenerek, yatırım aracı olarak hisse senetlerine alternatif olan tahvillerin faiz oranlarının da hisse senedine talebi etkileyerek, hisse senedi fiyatları üzerinde dolaylı olarak etkili olacağı öne sürülebilir. Faiz oranlarındaki artış, yatırımcıları hisse senetlerinden tahvile yönlendirerek, hisse senedi fiyatlarında düşüşe neden olacaktır. Ayrıca, faiz oranlarındaki artış, firmaların finansman maliyetlerini artırarak, firmaların beklenen kazançlarında düşüşe neden olabilir. Bu durum ekonomide durgunluk olacağı beklentisini artırarak, hisse senedi fiyatlarında düşürücü bir etki yapar (DURUKAN, 1999, s.19).

Drakos (2001) ve Zafar ve diğeri (2008) de yaptıkları çalışmalarda faiz oranları ile hisse senedi fiyatları arasındaki negatif yönlü ilişkiyi ortaya koymuşlardır.

Léon (2008) ise, getirilerin koşullu varyanslarının faiz oranları ile pozitif ve anlamsız ilişkisi varken, getiriler ile faiz oranları arasında ilişkinin negatif ve anlamlı olduğunu söylemiştir.

Durukan'nın (1999) elde ettiği sonuçlara göre test edilen tüm değişkenler arasında yalnızca faiz oranı değişkeni, kuramsal beklentilere uygun olarak, tüm regresyon denklemlerinde negatif ve istatistiksel olarak anlamlı katsayıya sahiptir.

Zügül - Şahin'nin (2009) görüşü de faiz oranları ile İMKB 100 endeksi arasında negatif yönlü bir ilişki olduğunu yönündedir.

Akkum - Vuran (2005), piyasa faiz oranlarına ilişkin bulguların enflasyon oranı bulguları ile tutarlı çıktığını söylemişlerdir. Getiriler ile faiz oranları arasında beklenen negatif ilişkilerin genelde görülmemesi, araştırma döneminde faiz oranlarında oluşan yükselmenin, teorik olarak beklenenin tersine, hisse senedi değerlerinde düşüş yaratmadığını ve yine teorik olarak beklenenin ve tahminlerin tersine, Türkiye'de devlet iç borçlanma senetlerinin yatırımcıların portföylerinde hisse senetlerine alternatif olmadıklarını göstermiştir.

Albeni - Demir (2005) ise, makro ekonomik faktörlerden biri olarak mevduat faiz oranlarının yönünün yaptıkları çalışmada beklentiler doğrultusunda çıktığını belirtmişlerdir. Buna göre mevduat faiz oranları mali sektör hisse senetlerine alternatif önemli bir yatırım aracı olarak karşımıza çıkmaktadır. Çünkü mevduat faiz oranlarındaki % 1'lik bir artış, mali sektör hisse senedi fiyatlarında % 2'lik bir azalmaya neden olmaktadır. Yüksek faizler, mali sektör hisse senetlerine yatırım yapmak yerine alternatif yatırımlarda bulunmayı teşvik etmektedir. Faiz oranlarının yükselmesi, hisse senetlerinden elde edilecek olan gelirlerin cari değerini azaltmakta ve bu da mali sektör hisse senedi fiyatlarının düşmesine sebep olmaktadır. Yatırımcılar faiz oranlarındaki yükselmeden kaynaklanan mali sektör hisse senedi fiyatlarındaki düşüşün yaygınlaşması korkusu ile

daha fazla zarar etmek istememekteler ve sahip oldukları hisse senetlerini ellerinden çıkarmaktadırlar. Böyle bir durum söz konusu olduğunda hisse senetlerine olan talep düşmektedir. Hisse senetlerinin daha az talep edilmesi ise, bu menkul kıymetlerin değerinde düşmelere sebep olmakta ve sonuçta hisse senedi fiyatları düşük olarak belirlenmektedir.

123. Para Arzı

Para arzı ile hisse senedi fiyatları arasındaki ilişki hususundaki genel kanı, para arzındaki artışların hisse senedi fiyatlarında artışlara neden olduğu yönündedir (BADARUDDIN-ARIFF, 2007; MASKAY, 2007; LI-WU, 2008).

Para arzındaki değişimler genel ekonomi üzerindeki dolaysız etkilerinden dolayı, öncelikle, finansal piyasaları etkilemektedirler. Para arzındaki artış oranı yüksek ise, kredi olarak borç verilebilecek para miktarındaki fazlalıktan dolayı piyasa faiz oranları düşecektir. Ayrıca, para arzındaki yüksek artış oranı firmaların faaliyetlerinde artış ve ekonomik büyümeye neden olarak, hisse senedi fiyatlarını artırıcı rol oynayacaktır. Bu etkilerin ötesinde, yüksek para arzı artışı enflasyona neden olarak faiz oranlarını artıracaktır (DURUKAN, 1999, ss. 27).

Maskay (2007), bu görüşlere ek olarak para arzındaki beklenen artışın hisse senedi fiyatlarını belirlemede beklenmeyen artıştan daha önemli olduğunu savunmuştur.

Davidson - Froyen (1982), Abdullah - Hayworth (1993), Fitzpatrick (1994), Alexakis ve diğerleri (1996), analizlerinde para arzı ölçütü olarak dar para arzı kullanmışlarken Fosback (1991), hisse senedi fiyatlarının en iyi göstergesinin enflasyona göre düzeltilmiş geniş para arzı olarak tanımlanan reel M2 olduğunu savunmaktadır. Maskay (2007), Badaruddin - Ariff (2007) de bu görüşe uygun olarak çalışmalarında M2 para arzını kullanmışlardır.

Durukan (1999) ise çalışmasında kullandığı modellerde, para arzı değişkenlerinin (M1, M2, M2Y) enflasyon oranı değişkenine benzer davranış göstererek istatistiksel olarak anlamlı ve tüm denklemlerde negatif işaretli olduğu sonucuna varmıştır.

Akkum - Vuran (2005) da Durukan'ın bulduđu sonuçları destekleyici olarak çalışmalarında elde ettikleri bulgulara bađlı olarak, para arzı ile getiriler arasında beklenen pozitif ilişkinin genelde görülemediđini göstermiştir. Bu husus Türkiye'de araştırma döneminde para arzında yaşanan bir genişlemenin toplam talebe etkisi nedeniyle hisse senedi fiyatlarında artış yaratmadıđını ortaya koymaktadır.

Benzer şekilde Zügül - Şahin'nin (2009) çalışmalarında ortaya çıkan M1 para arzı ile İMKB 100 endeksi arasındaki negatif yönlü ilişki, teorik beklentilere uymamaktadır.

Atan ve diđerleri (2004) ise, çalışmalarında analize dâhil ettikleri 29 hisse senedinden 11 hisse senedinin β katsayısı nı istatistiksel olarak anlamlı bulmuşlardır. 29 hisse senedinden 15 tanesinin (%52) β katsayısı pozitif deđer almıştır. Dolayısı ile bu senetlerin getirilerinin Para arzı (M2Y) ile aynı yönlü hareket etmektedir.

Çıtak (2003), para arzının gecikmeleri ile oluşturduđu modelde deđişkenin gecikmeli deđerlerinin katsayılarının istatistiksel olarak anlamlı olmadığı sonucuna ulaşmıştır. Araştırmacı, bu sonucu ise "para arzını geçmiş deđerleri İMKB 100 Endeksi'nin bugünkü deđerini etkilemediđine göre, geçmiş para arzı bilgileri zamanında hisse senedi fiyatlarına yansımış demektir." şeklinde yorumlamıştır.

124. Deđerli Maden (Altın) Fiyatları

Türkiye'de altın hala önemli bir yatırım aracı olma özelliđini korumaktadır. Her eğitim düzeyinden ve toplumsal sınıftan insanın tanıdıđı ve zaman zaman tasarrufunu altına yatırdıđı söylenebilir. Hisse senetleri ile altın fiyatları arasında alternatif yatırım aracı olma özelliđinden kaynaklanan ters yönlü bir ilişki beklenebilir (ÖZÇAM, 1990, ss. 172).

Atan ve diđerleri (2004) çalışmalarında, analize dâhil ettikleri 29 hisse senedinden 14 tanesinin (%48) β katsayısı nı pozitif deđerli bulmuşlardır. Bu senetlerin getirileri altın fiyatları ortalaması ile aynı yönlü hareket etmektedir.

Albeni - Demir (2005) de teorinin aksine çalışmalarında Cumhuriyet altınının mali sektör hisse senetlerine alternatif bir yatırım aracı olarak görülmediği sonucuna varmışlardır. Çünkü cumhuriyet altınındaki %1'lik bir artış mali sektör hisse senedi fiyatlarında %4,5 oranında bir artışa neden olmaktadır. Bu bulgu, cumhuriyet altınının mali sektör hisse senetlerine alternatif bir yatırım aracı olduğu beklentisi ile çelişmektedir. Bir diğer deyişle, yatırımcılar altını fiyat hareketlerine bağlı bir kazanç aracı olarak görmemektedirler.

125. Ekonomik Faaliyet Göstergeleri

Ekonomik faaliyetlerin firma kazançları üzerindeki etkilerinden dolayı hisse senedi fiyatlarını etkilediği savunulmaktadır. Başka bir anlatımla; artan üretim beklenen nakit akışlarını artırarak hisse senedi fiyatlarını artırıcı etkiye sahip olmaktadır (DURUKAN, 1999, ss. 20)

Atan ve diğerleri (2004) çalışmalarında, analize dâhil ettikleri 29 hisse senedinden 16 tanesinin (%55) β katsayısı değerini pozitif bulmuşlardır. Bu senetlerin getirileri Kapasite Kullanım Oranı ile aynı yönlü hareket etmektedir. Kapasite Kullanım Oranının artması bu hisse senetlerinin getirilerinin de artmasına sebep olmaktadır. Ayrıca yine 29 hisse senedinden 14 tanesinin (%48) β katsayısı pozitif değer almıştır. Bu senetlerin getirileri de Sanayi Üretim Endeksi ile aynı yönlü hareket etmektedir. Sanayi Üretim Endeksinin artması bu hisse senetlerinin getirilerinin de artmasına sebep olmaktadır.

Durukan'nın (1999) çalışmasında ise ekonomik aktivite değişkeni, kademeli eleme yöntemi sonucu elde edilen regresyon denklemlerinde istatistiksel anlamlılığa sahip pozitif katsayı ile belirirken, diğer tüm denklemlerde negatif katsayıya sahip fakat istatistiksel olarak anlamlı çıkmamıştır. Ekonomik aktivite değişkeninin, kuramsal bekleyişlere uygun olmayan sonuçları, bu denklemlerde yer alan diğer bağımsız değişkenlerle arasında çoklu doğrusal bağlantı (Multicollinearity) olması ile açıklanabilir. Enflasyon oranı, döviz kuru ve para arzı değişkenlerinin testlerde yer almaması durumunda, ekonomik aktivite değişkeni kuramsal bekleyişlere uygun olarak istatistiksel anlamlılığa sahip ve pozitifdir.

126. Gayrisafi Milli Hâsıla

GSMH'nin artış gösterdiği, ekonominin büyüdüğü dönemlerde hisse senedi fiyatlarının da aynı eğilim içinde olduğu görülür. Eğer ekonomik tahminler GSMH'ya göre enflasyon oranında daha hızlı bir artış olacağı şeklinde ise reel büyüme çok düşük olacağından yatırımcılar, kapitalizasyon oranını yükseltir ve hisse senedi fiyatları düşmeye başlar (GÜMÜŞ, 1994, ss. 87).

127. Yatırımlar

Kamu ve özel sektöre yapılan yatırımlar ekonominin gelişmesine büyük katkı sağlar. Normal olarak her yatırım, bir harcama ve gelir akımına neden olmaktadır. Yatırımla ilgili olan tüm kesimlerin geliri ve satın alma gücü artmakta, dolayısıyla yeni yatırımların ortaya çıkması söz konusu olmaktadır. Böylece ekonomide işsizlik azalma eğilimi gösterirken faktör gelirleri birbirini izleyen aşamalarda artar ve sonuçta gelirlerin toplamı yapılan yatırımın birkaç katına ulaşır. Toplam gelir artarken milli gelir de artmaya başlar ve milli gelirdeki bu artışla birlikte hisse senedine olan talep de artarak hisse senedi fiyatları yükselir (DEMİR, 2001, ss. 190).

128. Küresel Durum

Günümüzde finansal piyasaların küreselleşmesi özellikle kriz dönemlerinde finansal piyasaların birçoğunun aynı yönde hareket etmesine neden olmaktadır. 1998 yılının Ağustos ayında Rusya'da ortaya çıkan ekonomik krizden tüm dünya borsaları aynı yönde etkilenmiş, Amerika Dow Jones, Tokyo, Nikkei ve İMKB tarihi düşüşler yaşamıştır (DEMİR, 2001, ss. 190).

Dünya ekonomisinin mortgage şirketlerinin, yatırım ve mevduat bankalarının batmaya başlamasıyla kendini gösteren ve 1929 büyük buhranından bu yana yaşanan en şiddetli kriz olarak adlandırılmaya başlanan bir düzlemde bulunduğu açıkça ortadadır. Etkilerinin önümüzdeki birkaç yıl hissedileceği tahmin edilen krizden İMKB'de büyük ölçüde etkilenmiş durumdadır (SONGUR, 2009, ss. 16).

129. Siyasal ve Psikolojik Faktörler – Siyasi Belirsizlikler ve İstikrar

Ülke içinde ve dışında yaşanan siyasi gelişmeler hisse senedi piyasalarını olumlu ya da olumsuz etkileyebilir. Hükümet değişimleri, seçimler, önemli bir siyasi liderin vefatı, savaş terör v.b. durumlar ekonomide bir dönem belirsizliğe yol açacağından hisse senedi piyasalarını olumsuz etkileyecektir (KARAATLI, 2003, ss. 49).

Akmut ve diğerlerinin (2006) yapıları analiz sonuçlarına göre, ülke gündemini meşgul eden başka olayların olmadığı dokuz günden dört tanesinde endeks getiri oranlarında istatistiksel olarak anlamlı tepkiler gözlemlenmiştir. Bu tepkilerin yönü kararların içeriklerine bağlı olarak oluşabilecek beklentilere uygundur. Kalan beş gün için ise getiri oranlarında anlamlı bir tepki bulunmamaktadır. Dolayısıyla, İMKB'deki hisse senetleri getiri oranlarının AB'den gelen haberlere karşı hassas olmadığını ve istatistiksel olarak anlamlı tepkiler vermediğini söyleyebilmek mümkün değildir.

Hisse senedi getirilerinin tahmin edilebilirliği, finans çevrelerinde sık araştırılan bir konudur. Hisse senedi getirilerini tahmin etmeyi ve açıklamayı amaçlayan çok sayıda teori geliştirilmiştir. Bu teorilerin bir kısmı yatırımcıları etkileyen psikolojik faktörleri dikkate almazken; Kahneman - Tversky (1979) ile başlayan bir dizi çalışma yatırımcı psikolojisinin de hisse senedi fiyatlarının oluşumunda rolü bulunabileceğini ortaya koymuştur. İzleyen yıllarda yatırımcı psikolojisinin finans piyasalarına etkilerini inceleyen üç temel teori geliştirilmiştir. Bunlar, zihinsel muhasebe teorisi, sürü davranışı teorisi ve yatırımcı duyarlılığı teorisidir. Zihinsel muhasebe, bireylerin, işletmelere benzer biçimde kararlarını ayrı zihinsel hesaplara kaydetmelerini ifade etmektedir. Bir karar probleminde, herhangi bir yatırım seçeneğine ait olan bir sonuç, zihinsel hesaba kaydedildikten sonra, o sonucun değerlendirilmesini etkilemektedir. Sürü davranışı, yatırımcıların kendi sahip oldukları bilgilere göre işlem yapmayı başkalarının işlemlerini taklit etmeleri durumunda ortaya çıkmaktadır. Finansal piyasalarda işlem yapan tüm yatırımcılar rasyonel olmadığından, yatırımcılar, bazen bilgi yerine söylentilere göre işlem yapmakta, bazen de piyasaya ilişkin bilgilere gerekenden az veya fazla reaksiyon göstermektedirler. Bu duygusal davranışlar sistematik bir hale geldiğinde finans piyasalarında ekstra bir risk

kaynağı haline gelebilmekte ve bu riskin yatırımcıların duyarlılığından kaynaklandığı kabul edilmektedir (CANBAŞ - KANDIR, 2008, ss. 240-241).

Canbaş - Kandır'a (2008) göre yaptıkları analiz sonuçları, yatırımcı duyarlılığının hisse senedi getirilerini tahmin edebildiğini ortaya koymaktadır. Yatırımcı duyarlılığını temsil eden değişkenlerin tümü, İMKB sektör endeksleri getirilerini önemli ölçüde tahmin edebilmektedir. Yatırım ortaklıkları iskontosu, yatırım fonları fon akışı ve özellikle yabancı yatırımcıların yatırım davranışları, hisse senedi getirilerinin ne yönde ve ne derecede hareket edeceğini önemli ölçüde göstermektedir. Bu bulgu, üç sektörün getirileri için de geçerlidir. Buna göre, yatırımcı duyarlılığı, sektörüne bağlı olmaksızın tüm şirketlerin hisse senedi getirilerini etkilemektedir. Üstelik söz konusu üç yatırımcı duyarlılığı temsilcisine ilişkin bulgular, modele ekonomik değişkenler ilave edildiğinde de geçerliliğini korumuştur. Böylece, yatırımcı duyarlılığının, ekonomik gelişmelerin yansımından başka bir şey olmadığı yönündeki iddiaların doğru olmadığı belirlenmiştir. Özellikle, yabancı yatırımcıların yatırım davranışlarının, hisse senedi getirileri üzerinde oldukça önemli bir etkisi bulunmaktadır. Yabancı yatırımcıların yatırım faaliyetlerindeki çok küçük bir değişme dahi hisse senedi getirilerinde önemli değişiklikler olacağına işaret etmektedir. Yabancı yatırımcıların Türkiye'deki hisse senedi yatırımlarını artırması veya azaltması, yerel hisse senedi yatırımcılarının eğilimlerini büyük ölçüde etkilemektedir. Böylece, yabancı yatırımcıların İMKB hisse senedi piyasası üzerinde olduğu iddia edilen ancak rakamlaştırılmayan yönlendirici etkisinin varlığı somut bir biçimde ortaya konulmuş olmaktadır. Benzer biçimde, davranışsal finans literatüründe sıklıkla yer bulan yatırım ortaklıkları iskontosunun ve yatırım fonları fon akışlarının yatırımcı duyarlılığını yansıttığı bulguları Türkiye için de elde edilmiştir. Yatırım ortaklıkları iskontosu ve yatırım fonlarının ortalama fon akışı, tüm İMKB şirketlerinin hisse senetlerinin getirilerini tahmin edebilmektedir.

İKİNCİ BÖLÜM

2. YAPAY SİNİR AĞLARI

İnsanlık tarihi boyunca, doğal yaşamda gözlenen birçok işleyiş, bilim insanlarının icatları için esin kaynağı olmuştur. Günlük hayatta karşılaşılan problemler, doğadaki ve özellikle canlılardaki benzer işleyişe sahip sistemlerin gözlemlenmesi ve bu sistemlerin mevcut problemlere adapte edilmesi ile çözüm bulmuştur. Teknolojinin gelişimine paralel olarak insanlık, doğal işleyişi her geçen gün daha derinlemesine ve ayrıntılı inceleme fırsatı bulmuş ve bu sayede önceleri çözümü mümkün olmayan problemleri çözmek mümkün olmuştur.

Geçtiğimiz yüzyıl ortalarından itibaren, biyolojik sinir sistemleri ve özellikle insan beyni üzerinde yoğunlaşan araştırmalar, biyolojik sistemlerin öğrenme, yorumlama ve karar verme gibi yetenekleri ve bu yeteneklerin işleyişleri ile ilgili önemli bilgilerin elde edilmesine olanak sağlamıştır. Bu bilgiler, tıp alanında, hastalıkların tedavisi için yeni tekniklerin geliştirilmesine yardımcı olduğu gibi değişik disiplinlerde de sistem davranışlarının açıklanması, yorumlanması, öğrenme ve karar verme süreçlerinde yeni tekniklerin doğmasına imkân vermiştir. Bu disiplinlerden biri de “Yapay Zekâ”dır.

Yapay zekâ alanında kullanılan algoritmaların birçoğu biyolojik sistemlerin taklit edilmesi ile geliştirilmiş algoritmalar. Genetik algoritmalar, yapay sinir ağları algoritmaları, biyolojik sistemlerin taklit edilmesi ile geliştirilmiş algoritmalara örnek olarak verilebilir.

20. Yapay Zekâ Kavramı

Yapay Zekâ (Artificial Intelligence) kavramı ilk kez 1956 yılında Dartmouth Collage'de on bilim insanının iki aylık çalışmaları sonucu John McCarthy tarafından ortaya atılmış ve bir araştırma disiplini olarak benimsenmiştir (AKPINAR, 1994, ss. 41).

McCarthy (2007), yapay zekâyı, “akıllı makineler ve özellikle bilgisayar programları yapma bilimi ve mühendisliği” olarak tanımlamıştır.

21. Yapay Sinir Ağlarının Gelişimi

Yapay sinir ağı ile ilgili çalışmaları 1970 öncesi ve sonrası diye ikiye ayırmak gerekmektedir. Çünkü 1970 yılında bu bilimin tarihinde önemli bir dönüm noktası başlamış ve o zamana kadar olmaz diye düşünülen birçok sorun çözülmüş ve yeni gelişmeler başlamıştır (ÖZTEMEL, 2003, ss. 37).

210. 1970 Öncesi

1970 öncesi Yapay Sinir Ağları alanındaki önemli gelişmeler şu şekildedir (ÖZTEMEL, 2003, ss. 37-38):

1940'lı yıllardan sonra Hebb, McCulloch ve Pitts gibi bilim adamları, yapay sinir ağları konusunda daha önce yapılan araştırmaları mühendislik alanlarına kaydırmaya ve günümüz yapay sinir ağlarının temellerini oluşturmaya başladılar. İlk yapay sinir hücresinin yapısını oluşturdular. Yapay sinir ağları ile her türlü mantıksal ifadeyi formüleştirmenin mümkün olduğunu gösterdiler. Hücrelerin birbirine paralel çalışması gerektiği fikrini ortaya atarak öğrenme kurallarını belirlemeye başladılar. 1949 yılında Donald Hebb, yapay sinir ağının değerlerini değiştiren bir öğrenme kuralı geliştirdi. Hebbian öğrenme kuralı denilen bu kural günümüzde birçok öğrenme kuralının temelini oluşturmaktadır. 1951 yılında ilk neuro-bilgisayar üretildi. 1954 yılında Farley - Clark tarafından rassal ağlar ile adaptif tepki üretme kavramı ortaya atıldı ve bu kavram 1958 yılında Rosenblatt ve 1961 yılında Caianiello tarafından geliştirildi. Özellikle Rosenblatt

tarafından geliştirilen algılayıcı (Perceptron) yapay sinir ağı tarihi tarihinde önemli bir gelişmeye öncülük etmiştir.

Benzer şekilde Widrow - Hoff, ADALINE (Adaptive Linear Neuron) modelini ortaya attılar. Bu, yapay sinir ağlarının mühendislik uygulamalarında kullanılmaya başlanması açısından ilk adımlardan sayılmaktadır. Adaptif öğrenmenin temellerinden olan ve 1970'li yılların sonlarında ortaya çıkan MADALINE modelleri bu çalışmaların sonucunda ortaya çıkmıştır.

Yapay sinir ağlarının tarihinde bir duraklama devrine neden olan ise yapay zekâ biliminin o dönemdeki önde gelen isimlerinden Minsky - Pappert tarafından yazılan Algılayıcılar başlıklı kitap oldu. Bu kitapta yazarlar özellikle yapay sinir ağlarına dayalı algılayıcıların bilimsel bir değerinin olmadığı ve doğrusal olmayan problemlere çözüm üretemediklerini iddia ettiler. Tezlerini kanıtlamak için ise meşhur XOR probleminin çözülememesini örnek gösterdiler.

211. 1970 Sonrası

1970 sonrası gelişmeler ise şu şekilde özetlenebilir (ÖZTEMEL, 2003, ss. 39-40):

1972'lerde farklı disiplinlerde çalışan elektrik mühendisi Kohonen ve nöropsikolojist Anderson çağrışımlı bellek (Associative Memory) konusunda hemen hemen birbirinin aynı çalışmalar yayınladılar. Bu çalışmalar daha sonraları geliştirilerek öğretmensiz öğrenmenin temelleri oldu. Kohonen daha sonra 1982 yılında kendi kendine öğrenme netlik haritaları (Self Organising Feature Maps - SOM) konusundaki çalışmasını yayınladı. 1970'lerin sonuna doğru Fukushima görsel şekil ve örüntü tanıma amaçlı geliştirdiği Neocognitron modelini tanıttı. 1982 ve 1984 yıllarında Hopfield tarafından yayınlanan çalışmalar sonucu Hinton ve arkadaşları Boltzman makinesi geliştirdi. Aynı zamanda Rummelhart ve arkadaşları çok katmanlı algılayıcıları geliştirdiler. Çok katmanlı algılayıcılar, önceki yapay sinir ağı modellerinin çözemediği XOR problemi çözerek araştırmacıların ilgisini yapay sinir ağlarına yeniden çekmeyi başarmıştır. Ayrıca, Çok Katmanlı Algılayıcılar Hopfield ve Boltzman makinelerinin sınırlamalarını da çözmüştü. 1988'de Broomhead -

Lowe, radyal tabanlı fonksiyonlar modelini geliřtirdi. Daha sonra Specht bu ađların daha geliřmiři olan olasılıklı ađlar ve genel regresyon ađları modellerini geliřtirmiřtir.


22. Yapay Sinir Ađlarının Sınıflandırılması

Yapay sinir ađları literatürde genel olarak řu řekilde sınıflandırılmaktadır (SAĐIROĐLU, 2001, ss. 10).

- Mimari yapılarına göre
 - Geri beslemeli (Eleman, Jordan)
 - İleri beslemeli (MLP, LVQ)
- Öğrenme yaklařımlarına göre
 - Danıřmanlı öğrenme (MLP-BP)
 - Danıřmansız öğrenme (ART, SOM)
 - Takviyeli öğrenme (LVQ)

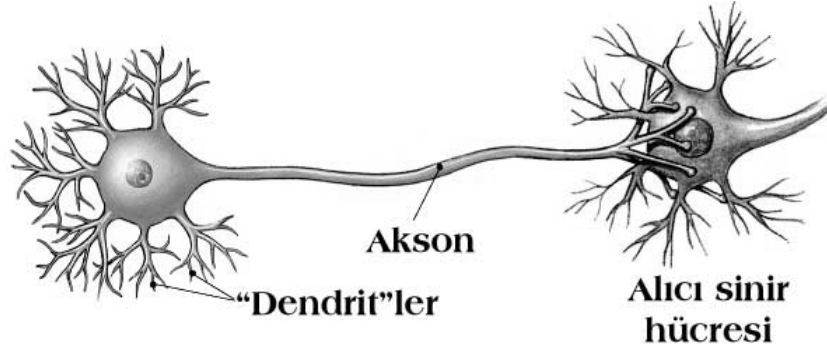
23. Yapay Sinir Ađlarının Yapısı

Yapay sinir ađları, biyolojik sinir sistemindeki sinir hücrelerinden (Neuron) esinlenilerek geliřtirilmiřtir. Biyolojik sinir hücreleri, girdi sinyallerini alarak (Dentrit) iřler (Çekirdek) (řekil 1). İřlenen sinyaller, çıktı sinyallerine dönüřtürölür (Akson) ve bađlantılar yardımı ile diđer sinir hücrelerine aktarılır (řekil 2).



Şekil : 1
Sinir Hücresi Yapısı

Kaynak: YURTOĞLU, 2005, ss. 13




Şekil : 2
Sinir Hücrelerinin Bağlantıları

Kaynak: http://www.tiptr.com/dizaynline/brain_anatomy/sekil7.jpg


Yapay sinir ağları da sinir hücrelerine benzeyen düğümler (Şekil 3, 4) ve bu düğümler arasındaki bağlantılardan oluşur. Bir yapay sinir hücresi dış ortamdan veya başka bir yapay

sinir hücresinden aldığı veriyi işleyerek bir çıktı üretir ve bu çıktıyı diğer yapay sinir ağına da dış ortama gönderir (Şekil 5).

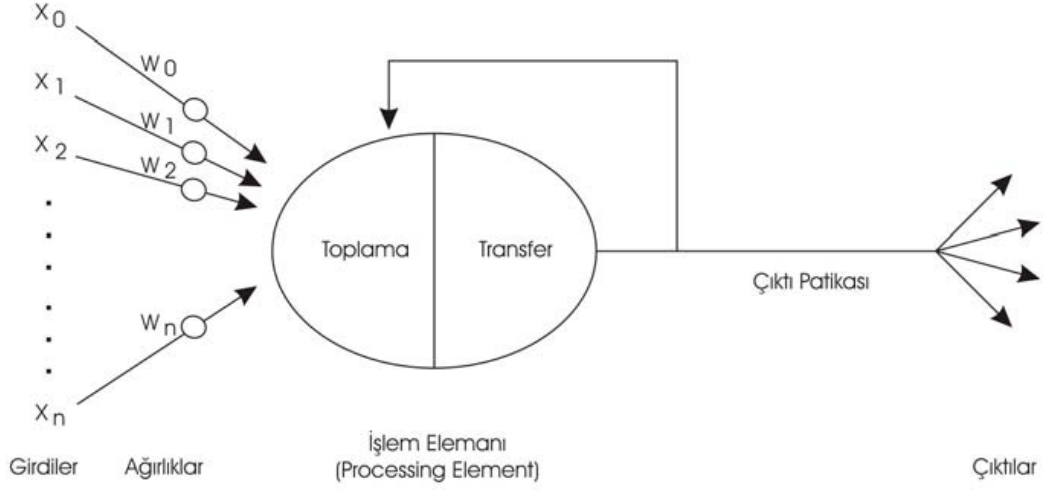


Şekil : 3
Yapay Sinir Hücresi Bağlantıları

Kaynak: YURTOĞLU, 2005, ss. 13



Şekil : 4
Temsili Yapay Sinir Ağı



Şekil : 5
Yapay Sinir Ağı Hücresi

Kaynak: YURTOĞLU, 2005, ss. 14

Bağlantı ağırlıkları başlangıçta rastgele olarak belirlenir.

Toplayıcı Fonksiyon

Yapay sinir hücreleri arasındaki bağlantılar, bir yapay sinir hücresi çıktısının, bağlı olduğu yapay sinir hücresinin toplayıcısında hangi ağırlıkta temsil edileceğini belirler (Şekil 4, 5). Her bir yapay sinir hücresi, bağlı olduğu yapay sinir hücresindeki çıktıyı bağlantı ağırlığı ile etkiler ve çıktılar en son yapay sinir hücrelerine kadar ilerlerler. Son hücrelerin çıktısı ise ağırlık çıktısını oluşturur. Bu işlem ileri besleme işlemidir.

İleri besleme işleminde araştırmacılar farklı toplama fonksiyonları kullanmışlardır. Bu fonksiyonlardan bazıları Tablo 1’de verilmiştir.

Tablo : 1
Toplama Fonksiyonları

Net Girdi	Açıklama
Çarpım, Net Girdi = $\prod_i I_i x W_i$	Ağırlık değerleri (W_i) girdi değerleri (I_i) ile çarpılır daha sonra bulunan değerler de birbirleri ile çarpılır.
Maksimum, Net Girdi = $\text{Max}(I_i x G_i)$	Ağırlıklar girdi değerleri ile çarpılarak bu çarpımların en büyüğü yapay sinir hücresinin net girdisi olarak belirlenir.
Minimum, Net Girdi = $\text{Min}(I_i x G_i)$	Ağırlıklar girdi değerleri ile çarpılarak bu çarpımların en küçüğü yapay sinir hücresinin net girdisi olarak belirlenir.
Çoğunluk, Net Girdi = $\sum_i \text{sgn}(I_i x W_i)$	Girdi değerleri ile ağırlıklar çarpıldıktan sonra pozitif ve negatif çarpım sonucu sayılarından büyük olan sayı net girdi olarak belirlenir.
Toplam, Net Girdi = $\sum_i I_i x W_i$	Ağırlıklar, girdi değerleri ile çarpılarak çarpımlar toplanır ve sonuç net girdi olarak belirlenir.
Kümülatif Toplam, Net girdi = $\text{Net}(\text{Eski}) + \sum_i I_i x W_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır ve daha önce gelen bilgilere eklenerek hücrenin net girdisi bulunur.

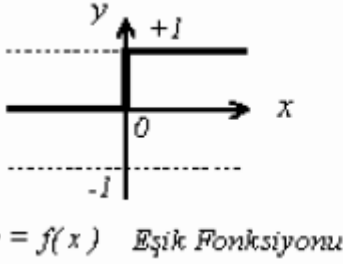
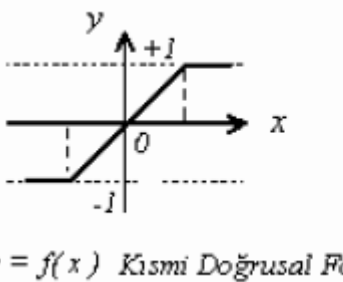
Kaynak: ÖZTEMEL, 2003, s.50.

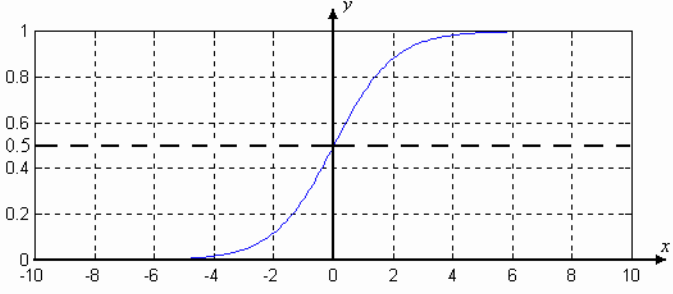
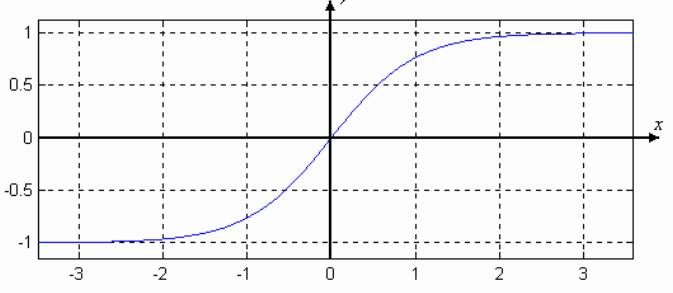
Çıktı (Aktivasyon) Fonksiyonu

Toplayıcı fonksiyonun ağırlık net girdisini belirlemesinden sonra bu değer çıktı fonksiyonuna verilerek yapay sinir hücresinin çıktısı hesaplanır.

Yaygın olarak kullanılan aktivasyon fonksiyonları şunlardır:

Tablo : 2
Aktivasyon Fonksiyonları

Aktivasyon Fonksiyonu	Açıklama
Lineer Fonksiyon, $F(\text{Net}) = \text{Net}$	Hücrenin net girdisi olduğu gibi çıktı olarak kabul edilir.
Step Fonksiyonu, $F(\text{Net}) = \begin{cases} 1, & \text{Net} > \text{Eşik Değer} \\ 0, & \text{Net} \leq \text{Eşik Değer} \end{cases}$	 $f(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases}$ <p>$y = f(x)$ Eşik Fonksiyonu</p> <p>Hücre, Net girdinin belli bir eşik değerinin üstünde olması durumunda 1 diğer durumda 0 değerini çıktı olarak üretir.</p>
Eşik Değer Fonksiyonu, $F(\text{Net}) = \begin{cases} 0, & \text{Net} \leq 0 \\ \text{Net}, & 0 < \text{Net} < 1 \\ 1, & \text{Net} \geq 1 \end{cases}$	 $f(x) = \begin{cases} 1 & x \geq 1/2 \\ x & 1/2 > x > -1/2 \\ 0 & x \leq -1/2 \end{cases}$ <p>$y = f(x)$ Kısmi Doğrusal Fonksiyon</p> <p>Net girdinin değerine göre, çıktının [0, 1] aralığında olması sağlanır. 0'dan küçük tüm girdi değerleri 0'a; 1'den büyük tüm girdi değerleri de 1'e eşitlenir.</p>
Sinüs Fonksiyonu, $F(\text{Net}) = \text{Sin}(\text{Net})$	Öğrenilmesi istenilen verilerin sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır.

<p>Sigmoid Fonksiyonu, $F(\text{Net}) = \frac{1}{1 + e^{-\text{Net}}}$</p>	 <p><i>Lojistik Sigmoid Fonksiyonu</i> $y = f(x)$ $f(x) = \frac{1}{1 + e^{-x}}$</p> <p>Doğrusal ve doğrusal olmayan davranışlar arasında denge sağlayan sürekli artan bir fonksiyon olarak tanımlanır.</p>
<p>Hiperbolik Tanjant Fonksiyonu $F(\text{Net}) = \frac{e^{\text{Net}} - e^{-\text{Net}}}{e^{\text{Net}} + e^{-\text{Net}}}$</p>	 <p><i>Hiperbolik Tanjant Fonksiyonu</i> $y = f(x)$ $f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$</p> <p>Hiperbolik tanjant fonksiyonu da sigmoid fonksiyon örneğidir.</p>

Kaynak: ÖZTEMEL, 2003, s.50.

Ağın Eğitilmesi

Bir yapay sinir ağında elde edilen çıktılar ile beklenen çıktılar arası farklar hata terimlerini oluşturur. Oluşan hatalar, yapay sinir hücreleri ağırlıkları arasında dağıtılarak her bir ağırlık yeniden hesaplanır. Bu geri besleme işlemidir. Geri beslemenin ardından çıktılar yeniden hesaplanır ve hata terimleri bulunur. Bu işlem ağ, istenilen çıktıyı ya da buna en yakın çıktıyı üretene kadar devam eder.

Yapay sinir ağları belli sayıda bir örnek seti ile ileri ve geri besleme işlemlerine tabi tutularak ağın, her bir örnek seti için doğru çıktıları üretecek ağırlıklara sahip olması sağlanır. Böylece ağ, girdi değerlerini öğrenerek verilen örnek seti için kabul edilebilir bir hata ile doğru çıktılar üretebilir. Böylece ağın eğitilmesi işlemi tamamlanmış olur.

Test İşlemi

Ağın eğitim tamamlandıktan sonra ağ performansını test etmek için ağın öğrenmesi sırasında kullanılmayan örnekler kullanılır. Bu işlemler esnasında bağlantı ağırlıkları değiştirilmez. Elde edilen çıktılar, beklenen çıktılarla karşılaştırılarak ağın öğrenmesi test edilir.


24. Yapay Sinir Ağlarının En Çok Kullanılan Modelleri

240. Tek Katmanlı Algılayıcılar

Tek katmanlı algılayıcılar, Yapay Sinir Ağlarının temellerini oluşturur. Sadece girdi ve çıktı katmanlarından oluşurlar. Çıktı fonksiyonları doğrusaldır.

241. Basit Algılayıcı

Tek bir algılayıcının birden fazla girdi değeri ile çıktı üretmesi prensibine dayalıdır. Çıktı fonksiyonu olarak eşik değer fonksiyonu kullanır. 1958 yılında Rosenblatt tarafından şekil sınıflandırma amacı ile geliştirilmiştir.



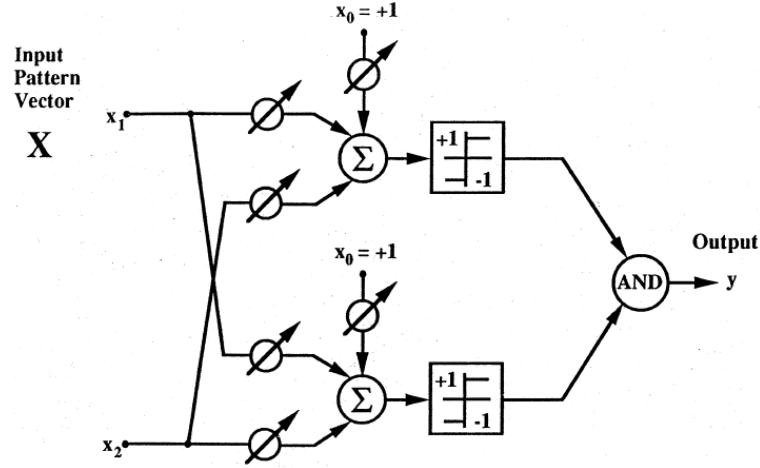
Şekil : 6
Basit Algılayıcı

Kaynak: VURAL, 2007, ss. 18

242. ADALINE / MADALINE Modeli

ADALINE modeli, Widrow - Hoff tarafından 1959 da geliştirilmiştir. Öğrenme kuralı en küçük karelerin ortalaması yöntemine dayanır (Delta Kuralı). Ağ bağlantı ağırlıkları, hataların en aza indirgenmesi için Delta Kuralı ile belirlenir. Basit algılayıcıda olduğu gibi bir algılayıcıya sahiptir.

MADALINE modeli ise birden fazla ADALINE ünitesinin bir araya gelmesi ile oluşturulur. Her ADALINE ünitesinin çıktısı AND veya OR işleci ile birleştirilerek ağın çıktısı belirlenir.



Şekil : 7

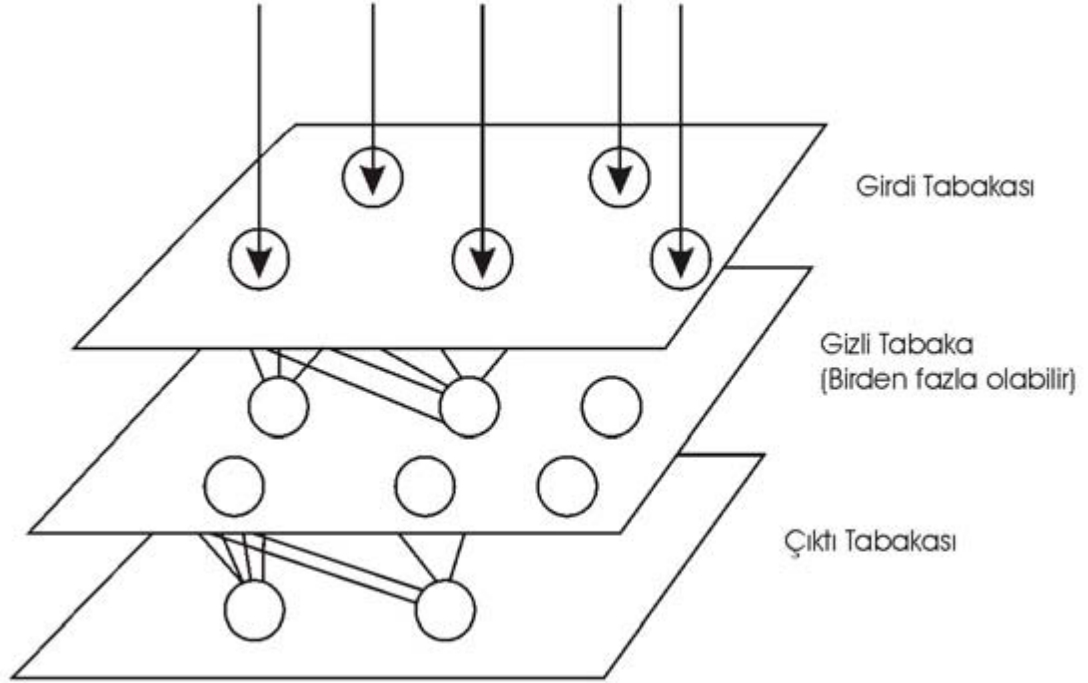
MADALINE Modeli

Kaynak: ARBIB, 2002, pp. 720

243. Çok Katmanlı Algılayıcılar

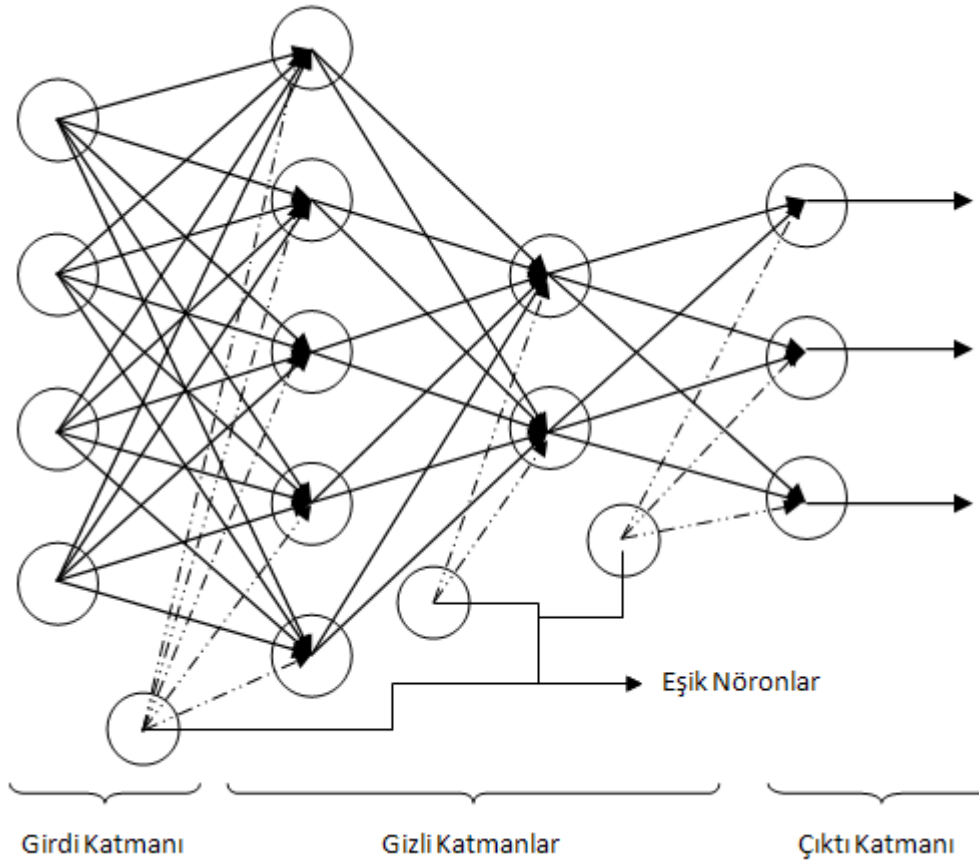
Doğrusal olmayan (Non-Linear) problemlerde tek katmanlı algılayıcılar, çözüm üretemezler. XOR problemi bu türden problemlerin en bilinenidir. Basit algılayıcıların doğrusal olmayan problemleri çözmemesi sonucu yapay sinir ağları üzerine yapılan araştırmalar bir süre durmuş ve XOR probleminin çok katmanlı algılayıcılar ile çözümü sayesinde yeniden canlanmıştır.

Çok katmanlı algılayıcılar, girdi ve çıktı katmanları arasında bir ya da daha fazla gizli katmana sahiptirler.



Şekil : 8
Çok Katmanlı Algılayıcı

Kaynak: ANDERSON – McNEILL, 1992, pp. 8.



Şekil : 9

Çok Katmanlı Algılayıcı Yapay Sinir Ağı Yapısı

Çok Katmanlı Algılayıcıların Öğrenme Kuralı

Çok katmanlı algılayıcılar, delta kuralının geliştirilmiş şeklini kullanarak öğrenme işlemini gerçekleştirirler. Bu nedenle çok katmanlı ağların öğrenme kuralına Genelleştirilmiş Delta Kuralı da denir (ÖZTEMEL, 2003, ss. 77).

Çok Katmanlı Algılayıcıların öğrenmesi iki aşamada gerçekleşir (BURRASCANO, 1990).

1. İleri Besleme (Feed Forward)
2. Geriye Yayılma (Backpropagation)

İleri Besleme Aşaması

Bu aşama, ağı eğitiminde kullanılacak örnekler setinden ilk örneğin ağı gösterilmesi ile başlar.

Ağın girdi değerlerini işleyebilmesi için bu değerlerin nümerik olması zorunluluğu vardır. Nümerik olmayan girdilerin, uygun bir biçimde nümerik şekle dönüştürülmesi ise ayrı bir problemdir. Bu işlem için genel bir kural yoktur. Bu sebeple, kullanılan değişkenin türüne göre daha önce yapılmış araştırmalarda kullanılan uygun bir yöntem tercih edilmeli ya da araştırmacı tarafından geliştirilecek ve uygun olabilecek yeni bir yöntem kullanılmalıdır.

Tüm girdi değerlerinin nümerik olması durumunda da örnek setindeki her bir değer farklı ölçekte bir ortamdan alınmış olabilir. Buna ek olarak örnek setinde hatalı girilmiş çok büyük ya da çok küçük değerler de olabilir. Bu tür değerler ağın çıktısını etkileyerek ağın yanlış öğrenmesine sebep olur ve ağ performansını doğrudan etkiler. Bu sebeplerle araştırmacılar girdi değerlerini ölçeklendirerek (Scaling) ağı gösterirler.

Ölçeklendirme işlemi genellikle girdi vektörünün normalize edilmesi ile gerçekleştirilir. Normalizasyon işlemi, her bir girdi değerinin girdi vektörü değerine bölünmesidir (Denklem 1).

Denklem 1 - Normalizasyon

$$X' = \frac{X}{|X|}$$

Ölçeklendirme işlemi için farklı yöntemler kullanılabilir. Örneğin zamana bağlı bir değişken için belli bir zamandaki değer yerine bir önceki değere göre değişim miktarı kullanılabilir. Bunun yanı sıra bazı araştırmacılar ölçeklendirme için (Denklem 2) formülünü kullanmışlardır.

Denklem 2 - Ölçeklendirme

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}}$$

Girdi değerlerinin ağa gösterilecek şekle dönüştürülmesinden sonra, girdi katmanı bu değerleri değiştirmeden bağlı olduğu gizli katmana gönderir. Girdi katmanındaki tüm nöronlar, ilk gizli katmandaki nöronların tamamıyla bağlantılıdır.

Gizli katmandaki her nöron, kendisine gelen girdi değerlerini, her bir değeri gönderen girdi nöronun ağırlıkları ile işleme sokarak Net Girdi değerini hesaplar. Bu işlem genellikle ağırlıklı toplam formülü ile yapılır (Denklem 3).

Denklem 3 – Ağırlıklı Toplam

$$Net_j^L = \sum_i O_i^{L-1} \cdot W_{i,j}^{L-1}$$

Burada Net_j^L , L katmanındaki j. Nöronun net girdisi; O_i^{L-1} , L-1 katmanındaki i. nöronun çıktısı; $W_{i,j}^{L-1}$, ise L-1 katmanındaki i. nöronun bağlı olduğu j. Nöron ile bağlantı ağırlığıdır.

Net girdisi hesaplanan nöronun, bu değeri aktivasyon fonksiyonuna sokularak çıktısı hesaplanır. Çok katmanlı algılayıcılarda genellikle Sigmoid (Denklem 4) ya da onun bir türü olan Hiperbolik Tanjant (Denklem 5) fonksiyonu kullanılır.

Denklem 4 – Sigmoid

$$O_j^L = \frac{1}{1 + e^{-Net_j^L}}$$

Denklem 5 – Hiperbolik Tanjant

$$O_j^L = \frac{e^{Net_j^L} - e^{-Net_j^L}}{e^{Net_j^L} + e^{-Net_j^L}}$$

Burada, eşik nöronların çıktısı hesaplanmamalı ve daima 1 olarak kabul edilmelidir. Zaten dikkat edilirse eşik nöronlar bir önceki katman ile bağlantılı değildir. Ayrıca girdi katmanı için her nöronun çıktı değeri bir işleme tabi tutulmadan girdi değerine eşit olmalıdır. Yani I_j , j. girdi değeri olmak üzere $O_j^{input} = I_j$ 'dir.

Geriye Yayılma Aşaması

İleri besleme işlemi, her katmandaki her nörona uygulanarak çıktı katmanındaki nöronların çıktı değerleri hesaplanır ve hesaplanan bu değerler, ağın çıktıları olur. Bu şekilde örnek setinden bir örnek ağa gösterildiğinde ağın o örnek için çıktısı elde edilir. Örnek setindeki çıktı değişkenlerinin gerçek değerleri ise beklenen çıktı değerleri olarak adlandırılır. Ağın her çıktısı için çıktı değeri ile beklene değer arasındaki fark hata terimlerini oluşturur. i. çıktı için hata terimi - R_i çıktının beklenen değeri olmak üzere -:

Denklem 6 – Hata Terimi

$$E_i = R_i - O_i$$

şeklinde olacaktır. Burada kullanılan aktivasyon fonksiyonuna göre beklenen çıktı değerlerinin de ölçeklendirilmesi gerekmektedir. Örneğin, aktivasyon fonksiyonu olarak Sigmoid fonksiyonunun kullanılması durumunda ağın çıktıları [0,1] aralığında olacaktır. Bu durumda beklenen çıktı değerlerinin de bu aralıkta ölçeklendirilmesi gerekir.

Birden fazla çıktısı olan ağlarda, ağın toplam hatasını (SE) bulmak için hataların toplanması gerekir. Bu durumda bazı hataların negatif bazılarının ise pozitif olabileceği düşüncesiyle, toplamın 0 (sıfır) olmasını önlemek için hataların kareleri toplanarak sonucun karekökü alınır. Bu durumda toplam hata formülü şu şekilde olur:

Denklem 7 – Toplam Hatalar

$$SE = \frac{1}{2} \sum_i E_i^2$$

Ağın öğrenmesinde amaç, bu hatayı kabul edilebilir bir değere kadar küçültmektir. Bunun için ağın bağlantı ağırlıklarının değiştirilmesi gerekir. “Genelleştirilmiş Delta

Kuralı'na göre elde edilen toplam hata ağırlıklara dağıtılarak, hata değerinin küçülmesi sağlanır. Bu işlem hata değeri kabul edilebilir bir değere ulaşıncaya kadar tekrar eder. Bazı araştırmacılar ise bu işlemi belli sayıda tekrar ederek son aşamadaki hatayı ağırlık performansı olarak kabul ederler.

Herhangi bir t. iterasyonda ağırlıklardaki değişim Denklem 8'deki formülle hesaplanır.

Denklem 8 – Ağırlık Değişimi

$$\Delta W_{ij}^L(t) = \lambda \delta_j O_i^L + \alpha \Delta W_{ij}^L(t-1)$$

Denklem 8' deki λ , öğrenme katsayısıdır. “Öğrenme katsayısı ağırlıkların değişim miktarını belirlemektedir. Eğer büyük değer seçilirse ağırlık yerel çözümler arasında dolaşması ve salınım yaşaması söz konusudur. Küçük değerlerin seçilmesi ise öğrenme zamanını artırmaktadır” (ÖZTEMEL, 2003, ss. 99).

Denklem 8'deki α ise, momentum katsayısıdır. “Öğrenme katsayısına benzer şekilde momentum katsayısı da ağırlık performansını etkiler. Momentum katsayısı bir önceki iterasyondaki değişimin belli bir oranda yeni değişime eklenmesi olarak görülmektedir. Bu özellikle yerel çözümlere takılan ağırlıkların bir sıçrama ile daha iyi sonuçlar bulmasını sağlamak amacı ile önerilmiştir. Bu değer küçük olması yerel çözümlerden kurtulmayı zorlaştırabilir. Çok büyük değerler ise tek bir çözüme ulaşmada sorunlar yaşatabilir” (ÖZTEMEL, 2003, ss. 99).

Denklem 8' deki δ_j , gizli katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesi durumunda Denklem 9'daki gibi hesaplanır.

Denklem 9

$$\delta_j = f'(Net) E_j$$

Aktivasyon fonksiyonu olarak Sigmoid fonksiyonunun kullanılması durumunda δ_j Denklem 10'daki gibi olacaktır.

Denklem 10

$$\delta_j = O_j^{Output} (1 - O_j^{Output}) E_j$$

Gizli katmanlar arası ya da girdi katmanı ile gizli katman arasındaki ağırlıklar değiştirilirken ise δ_j , Denklem 11'deki gibi hesaplanır.

Denklem 11

$$\delta_j = f'(Net) \sum_k \delta_k W_{jk}^L$$

Ağın tüm ağırlıkları yeniden hesaplandıktan sonra ileri besleme işlemi ile çıktılar ve hata terimleri de yeniden hesaplanarak iterasyon devam eder. Böylece ağın bir örnek için hatası kabul edilebilir değere ulaşır. Bu işlemler örnek setindeki tüm örnekler için tekrar edilir. Her örnek ağa gösterilirken ağırlıklar değişeceğinden, yani ağırlıklarla önceki örneklerin hataları da değişecektir. Bu durumdan dolayı araştırmacılar örneklerin ağa gösterilmesinde ve ağırlıkların değiştirilmesi zamanında farklı yöntemler uygulamaktadır. Örnekler ağa sıralı bir şekilde gösterilebileceği gibi rastgele seçilerek de gösterilebilir. Örneklerin rastgele seçilmesi durumunda seçilen örnek, örnek setinden çıkarılmadan örneğe yeniden seçilme şansı da verilebilir. Ağırlıkları değiştirilmesi ise her örnek ağa gösterildiğinde yapılabileceği gibi bir grup örnek ağa gösterildikten sonra ortalama hatanın ağırlıklara dağıtılması ile de yapılabilir.. Bu yöntemler tamamen çalışılan probleme göre araştırmacılar tarafından tercih edilir. Hangi problemlerde hangi yönetim kullanılmasının uygun olacağına dair bir kural yoktur.

25. Diğer Yapay Sinir Ağı Modelleri**250. LVQ Ağları**

LVQ ağları genel olarak sınıflandırma problemleri için kullanılır. Destekleyici öğrenme stratejisine göre öğrenirler. Çıktılarının bir tanesi 1 diğerleri 0 değerini alır. Değeri 1 olan çıktı, girdinin ait olduğu sınıfı gösterir. Sınıflandırma en yakın komşu kuralına göre yapılır. Çıktı değerleri kazanan her şey i alır (Winner Takes All) ilkesine göre üretilir. Ağ

eğitilirken yalnızca çıktının doğru olup olmadığına bakılarak sadece girdi vektörüne en yakın vektörün ağırlıkları değiştirilir.

251. ART Ağları

ART ağları, öğretmensiz öğrenme stratejisine göre öğrenirler. Genel olarak iki katmana sahiptirler. F1 katmanı girdilerin özelliklerini gösterirken F2 katmanı kategorileri gösterir. F1 katmanından gelen bilgiler F2 katmanındaki kategorilerle eşleştirilir. Eğer eşleşme sağlanmazsa ağ yeni bir kategori oluşturur. Kısa ve uzun dönemli hafızaya sahiptirler.

ART ağları diğer yapay sinir ağları modellerinden farklı olarak dinamik bir yapıya sahiptirler ve gerçek zamanlı olaylardaki değişiklikler kolayca adapte olabilirler. Bu ve buna benzer birçok özellikleri onları diğer modellerden ayırır.

252. Geri Dönüşümlü Ağlar ve Eleman Ağı

Eleman ağı çok katmanlı algılayıcıların öğrenme kuralına göre öğrenir. Çok katmanlı algılayıcılardan farklı olarak ara katman elemanlarının çıktılarını girdi katmanındaki içerik elemanlarına göndererek, ara katmanda üretilen çıktılarının bir sonraki çıktıda kullanılması sağlanmaktadır.

“Eleman ağı özellikle birinci dereceden doğrusal sistemleri modellemede başarılı bir şekilde uygulanmaktadır. Bu ağlar, zamana bağlı olayları işleyebilme ve önceki zamanlarda elde edilen sonuçları bir sonraki zamana taşıyabilme yeteneği ile özellikle konuşma anlama ve ses tanıma problemlerinde etkin olarak kullanılmaktadırlar” (ÖZTEMEL, 2003, ss. 170).

26. Yapay Sinir Ağlarının Uygulama Alanları

Yapay sinir ağlarının uygulama alanları aşağıdaki gibidir (BAHADIR, 2008, ss. 39-40):

Mühendislik Bilimleri: Yapay zekânın ortaya çıkışı bilim dünyası için çok önemli bir adımdır. İdealize edilmiş bir yaklaşıma göre yapay zekâ, insan zekâsına özgü olan,

algılama, öğrenme, çoğul kavramlar arasında ilişki kurma, düşünme, fikir yürütme, sorun çözme, iletişim kurma, çıkarsama yapma ve karar verme gibi fonksiyonları veya otonom davranışları sergilemesi beklenen yapay bir işletim sistemidir. Bu sistem aynı zamanda düşüncelerinden tepkiler üretebilmeli ve bu tepkileri fiziksel olarak dışa vurabilmelidir. Uzman sistemler gibi yapay zekânın bir alt dalı olan YSA, görüntü ve ses tanıma ile tahmin ve kestirim için sıkça kullanılan araçlardan biridir.

Finans ve Ekonomi Alanı: YSA, son yıllarda en sık başvuru alanı menkul kıymet gelecek değer tahmini araçlarından biridir. Teknik analiz yöntemleri ile birlikte kullanıldıklarında çok önemli sonuçlar verebilen YSA, analistlerin ve araştırmacıların borsadaki en önemli yardımcılarından biridir. Bu konudaki çalışmalarda, gerçekten çok başarılı sistemler kurulabilmiştir.

Arıza Analizi ve Tespiti: Bir sistemin, cihazın ya da elemanın düzenli ve doğru çalışma şeklini öğrenen YSA yardımıyla, bu sistemlerde meydana gelebilecek arızaların tanımlanma olanağı vardır. Bu amaçla YSA; elektrik makinelerinin, uçakların ya da bileşenlerinin, bütünleşik devrelerin v.b. arıza analizinde kullanılmıştır.

Tıp Alanı: YSA tıp alanında; tıbbi sinyallerin analizi, kanserli hücrelerin analizi, protez tasarımı, transplantasyon zamanlarının optimizasyonu ve hastanelerde giderlerin optimizasyonu v.b. gibi uygulama yeri bulmuştur.

Savunma Sanayi: Silahların otomasyonu ve hedef izleme, nesnelere/görüntüleri ayırma ve tanıma, yeni algılayıcı tasarımı ve gürültü önleme v.b. gibi alanlara uygulanmıştır.

Haberleşme: Görüntü ve veri sıkıştırma, otomatik bilgi sunma servisleri, konuşmaların gerçek zamanda çevirisi v.b. gibi alanlarda uygulama örnekleri vardır.

Üretim: Üretim sistemlerinin optimizasyonu, ürün analizi ve tasarımı, ürünlerin (bütünleşik, kâğıt, kaynak v.b.) kalite analizi ve kontrolü, planlama ve yönetim analizi v.b. alanlarına uygulanmıştır.

Otomasyon ve Kontrol: YSA uçaklarda otomatik pilot sistemi otomasyonu, ulaşım araçlarında otomatik yol bulma/gösterme, robot sistemlerin kontrolü, doğrusal olmayan sistem modelleme ve kontrolü, elektrikli sürücü sistemlerin kontrolü v.b. gibi yaygın uygulama alanları bulmuştur.

27. Yapay Sinir Ağları ile Yapılan Borsa Endeks Tahmini Uygulamaları

Yapay sinir ağları ile finansal tahmin uygulamaları son on yılda ivme kazanmıştır. Başlangıçta YSA modelleri ile gerçekleştirilen tahminler, istatistiksel yöntemlerle karşılaştırılarak, YSA modellerinin başarısı ortaya konulmuş, sonraki çalışmalarda ise YSA modelleri başka tekniklerle birleştirilerek modellerin tahmin gücü artırılmaya çalışılmıştır.

Kuo ve diğerleri (1996), Taiwan hisse senedi piyasası üzerinde yaptıkları çalışmada, iki farklı YSA modeli oluşturmuşlardır: Birinci model ileri beslemeli YSA'dır. Bu modelde teknik göstergelerin yanı sıra ulusal bazı borsa endeksleri de girdi değerleri olarak kullanılmıştır. Birinci modelde, bazı değişkenlerin bir günlük gecikmeleriyle birlikte toplam 42 girdi değeri vardır. İkinci modelde ise klasik anlayıştan farklı olarak birinci modelde kullanılan girdi değişkenlerine ilaveten nicel faktörlerin de etkisini hesaplayabilmek amacıyla borsa uzmanlarıyla yapılan anket sonucu elde edilen veriler de kullanılmıştır. Bu veriler, bulanık Delphi modeli ile oluşturulan bir sinir ağına tabi tutularak iki çıktı üretilmiştir. Standart ağı ürettiği çıktı ile bulanık ağı ürettiği çıktılar, ayrıca oluşturulan bir sinir ağına girdi olarak verilerek standart ağı tahmin gücü artırılmaya çalışılmıştır. Sonuçta birinci modelde yapılan tahminlerin kabul edilebilir düzeyde olmasına karşın, ikinci modelde yapılan tahminlerin daha başarılı olduğu görülmüştür.

Bengoechea ve diğerleri (1996), Şili Santiago borsa endeksi günlük kapanış değerlerini YSA ile tahmin etmeye çalışmışlardır. Çok katmanlı mimaride oluşturdukları modelde aktivasyon fonksiyonu olarak hiperbolik tanjant fonksiyonu kullanmışlardır. Modelin öğrenme algoritması ise geri yayılma algoritmasının geliştirilmiş bir türü olan genelleştirilmiş delta kuralıdır. Öğrenme katsayısı 0,01 ile 0,5, momentum katsayısı ise 1 ile 0,2 aralığında ağ tarafından seçilmiştir. Girdi değerleri olarak günlük kapanış değerleri,

günlük işlem adedi ve bu değerlerin 10 güne kadar gecikmeleri (toplam 20 değişken) kullanılmıştır. Gizli katmanda iki ana blok oluşturulmuştur. Birinci blokta tam bağlantılı olarak üç gizli katman ve bir çıktı katmanı bulunmaktadır. Bu katmanlardan ikinci gizli katmandan birinci gizli katmana geri besleme yapılmıştır. İkinci blokta ise tam bağlantılı olarak bir girdi, iki gizli ve bir çıktı katmanı vardır. Bu katmanda da ilk gizli katmanla girdi katmanı arasında geri besleme yapılmıştır. Ayrıca tüm modelin çıktı katmanı, gizli katman bloklarının çıktıları ve ağ girdi katmanı ile bağlantılıdır. Çıktı katmanında bulunan bir eleman gelecek gün değerini üretmektedir. Ağ performansı için endeksin yükseliş sinyalleri ve düşüş sinyalleri ayrı ayrı değerlendirilmiştir. Çalışma sonucunda endeksin yükseliş sinyalleri %63,3, düşüş sinyalleri ise %74,7 doğrulukla tahmin edilmiştir.

Schierholt – Dağlı (1996), S&P500 endeksi günlük kapanış değerleri üzerinden endeks hareket yönünü, Çok Katmanlı Algılayıcılar ve Olasılıklı Sinir Ağları ile tahmin etmeye çalışmışlardır. Şubat 1994 ile Eylül 1995 tarihleri arasındaki verileri kullanarak yapıları çalışmada girdi değerleri olarak Japon Yeni, İngiliz Paundu ve Alman Markını kullanmışlardır. Birinci modelde sigmoid aktivasyon fonksiyonu ile çok katmanlı algılayıcı modeli geri yayılma algoritması ile eğitilmiştir. Modelde bir gizli katman kullanılmıştır. Çıktı katmanında üç eleman bulunmakta ve her bir eleman al, sat ve tut sinyalleri üretmektedir. 20000 döngü sonucunda model eğitim setinde %75 başarı sağlamıştır. Araştırmacılar farklı sayıda döngü için eğitim ve test verilerindeki başarıyı gözleyerek en iyi sonucun alındığı döngü sayısını bulmayı amaçlamış ve 1500 ile 2500 döndü aralığında en iyi sonucun alındığını gözlemlemişlerdir. Algılayıcı mimarisine ikinci bir gizli katman eklenince öğrenmenin çok hızlandığı ve hata değerinin küçüldüğü görülmüştür. İki gizli katmanlı mimaride en iyi performansın 5400 döngü ile elde edildiği gözlemlenmiştir. Olasılıklı sinir ağı modelinde ise ağırlıklandırma için Gaussian fonksiyonu kullanılmıştır. Bu modelin test sonuçlarında, endeksin artış gösterdiği ilk yarıda tahmin değerleri çok başarılı olmasına rağmen, endeksin düştüğü ikinci yarıda tahmin değerleri artmaya devam etmektedir. Çalışma sonucunda genel olarak çok katmanlı algılayıcının tahminlerine göre yapılan al-sat işlemleri tek gizli katmanlı mimaride %6,10 iki katmanlı mimaride ise %7,21 getiri sağlanmıştır. Olasılıklı yapay sinir ağı modeli ise %8,3 getiri ile çok katmanlı algılayıcıya göre nispeten daha başarılı olmuştur.

Atiya ve diğerleri (1997) S&P 500 endeksi bileşenleri temel analiz göstergeleri üzerinde yaptıkları çalışmada 4 farklı eğitim ve test veri seti ve 4 farklı strateji ile 16 model oluşturmuşlardır. Birinci strateji al ve tut stratejisidir. Bu stratejiye göre test setindeki tüm hisseler alınır ve 12 ay boyunca elde tutulur. İkinci strateji ise alınan hisselerden %20 kar veya %20 zarar edenlerin satılması diğerlerinin ise tutulmasıdır. Üçüncü ve dördüncü stratejilerde, hisse senedi alım kararı, sinir ağı tarafından verilir ve alınan hisse senetlerine sırasıyla birinci ve ikinci strateji uygulanır. Bu şekilde oluşturulan tüm modellerde, alım kararlarının sinir ağı tarafından verildiği modeller diğer modellere göre açık bir farkla daha yüksek getiri elde edilmesini sağlamıştır.

Rast (1999), DAX endeksi üzerinde teknik gösterge verileri ile klasik çok katmanlı algılayıcılar ve bulanık sinir ağları modellerinin iki farklı dönemdeki tahminlerini karşılaştırmıştır. Rast, ilk dönem aralığını seçerken 1998'in ikinci yarısında yaşanan Rusya ve Asya kökenli krizi temel almış ve fiyatların yükseliş periyodunu eğitim; alçalış periyodunu ise doğrulama için kullanmıştır. İkinci dönemde ise 1987 kırılması incelenmiştir. İki modelde de endeks değerindeki yüzde değişim, bugünkü değer, bir gün önceki değer ve bir günlük hareketli ortalama girdileri ile tahmin edilmeye çalışılmıştır. Modellerin performansı ise tahmin değerlerinin yükselişe işaret etmesi durumunda al; alçalışa işaret etmeleri durumunda sat sinyali olarak değerlendirilmesiyle hesaplanan getiriye göre belirlenmiştir. Birinci dönemde klasik sinir ağının bulanık ağa göre daha yüksek getiri sağladığı görülmüştür. Bu sonuca göre Rast, bulanık ağın değişimlere daha az duyarlı olmasına karşın klasik ağa göre daha istikrarlı olduğunu belirtmiştir. İkinci dönemde ise farklılığın birinci döneme göre daha az olduğu gözlenmiştir.

Kim ve diğerleri (2000), Kore hisse senedi fiyat endeksi üzerinde yaptıkları tahminde, Ocak 1987- Ağustos 1996 tarihleri arasındaki haftalık verileri kullanmışlardır. Çalışmada girdi değişkenleri olarak 13 teknik gösterge seçilmiştir. Oluşturulan ilk YSA modelinde kullanılacak değişkenlerin seçimi, gizli katmandaki işlem elemanı sayısı ve bağlantı ağırlıkları genetik algoritmalar ile belirlenmiştir. İkinci modelde ise değişim noktalarının tahmini için geri yayımlı YSA kullanılmıştır. Bu modelde de YSA, genetik algoritma ile eğitilmiştir. Üçüncü ve tavsiye edilen modelde ise ağ yapısı optimizasyonu ve ağırlıkların belirlenmesine ek olarak değişim noktası tespiti için de genetik algoritma kullanılmıştır.

Uygulama sonucunda üçüncü modelin diğer modellere göre daha iyi tahminler yaptığı sonucuna ulaşılmıştır.

Chan ve diğerleri (2000), geri yayılma algoritmasının yavaşlığı ve parametrelerin belirlenmesindeki zorluğu ortadan kaldırmak için eşlenik gradyant algoritmasını ve başlangıç ağırlıklarının atanması için çoklu doğrusal regresyon modelini önermiştir. Shanghai Borsası 1994-1996 yılları arasındaki günlük veriler üzerinden teknik göstergeleri kullanarak yapılan çalışmada başarılı sonuçlar elde edilmiştir. Çalışmada oluşturulan yapay sinir ağı modeli 10 girdi elemanına sahip girdi katmanı, 5 elemanlı bir gizli katman ve bir elemanlı bir çıktı katmanından oluşmaktadır.

Liu - Yao (2001), Hang Seng endeksi üzerinde yaptıkları çalışmada evrimsel sinir ağlarının tahmin başarısını test etmiş ve modelin başarısından şu sonuçları çıkarmışlardır: İlk olarak evrimsel yöntem, ağı optimum yapısını evrim süreci içerisinde belirleyebilmektedir. Bu yapay sinir ağlarının zayıf bir yönü olan ağ yapısı seçimine bir çözüm olarak sunulmaktadır. Evrimsel sinir ağının başka bir faydası ise geri yayılma algoritmasındaki yavaşlığı ortadan kaldırması ve genel optimum çözümü bulamama riskini azaltması olarak belirtilmiştir.

Zorin – Borisov (2002) tarafından Dow Jones Riga endeksi üzerinde yapılan çalışmada endeksin 2000 yılı günlük kapanış verileri eğitim seti olarak 2001 Ocak ayı ise test dönemi olarak kullanılmıştır. Tek gizli katmana sahip YSA modelinde 59 girdi kullanılmıştır. Öğrenme ve momentum katsayıları 0,1 olarak belirlenmiş ve başlangıç ağırlıkları 0 ile 0,01 arasında rastgele seçilmiştir. Oluşturulan YSA modelinin sonuçları ARMA tahmin sonuçları ile karşılaştırılmış ve YSA modelinin ARMA modeline göre daha başarılı sonuçlar ürettiği görülmüştür.

Phua ve diğerleri (2003), beş farklı borsa endeksi (DAX, DJIA, FTSE-100, HSI ve NASDAQ) üzerinde, endeksi oluşturan bileşenlerin 4 Ocak 1994 - 30 Kasım 2002 tarihleri arasındaki günlük değerlerini kullanarak tahminlerde bulunmuşlardır. Araştırmacılar, oluşturdukları farklı yapay sinir ağı modellerinden güven aralığı metodunun diğer modellere göre daha başarılı tahminler ürettiği sonucuna varmışlardır. Çalışmada, kullanılan beş endeksin değişim işareti, %60'ın üzerinde bir başarı ile tahmin edilmiştir.

Liu ve diğeri (2004), 19 Ağustos 2002 ve 6 Kasım 2003 tarihleri arasındaki Tokyo Borsası günlük teknik gösterge verilerini kullanarak, çok katmanlı ileri beslemeli sinir ağları modeli ile al, sat ve tut sinyalleri üretmişlerdir. Modelde, girdi katmanında 10 girdi elemanı; bir gizli katman ve bu katmanda 10 gizli eleman; çıktı katmanında ise 3 eleman vardır. Üç çıktı elemanının her biri sırasıyla al, tut ve sat sinyalleri üretirler. Çıktı elemanlarından biri 1 değeri ürettiğinde diğeri 0 değeri üretir. Çalışma sonucunda sistemin, al ve sat sinyallerinde, istatistiksel yöntemlere göre daha başarılı olduğu sonucuna ulaşılmıştır.

Jun - Xiong (2005), Shanghai borsasının 15 Mart 2005-15 Mart 2005 tarihleri arasındaki günlük verilerini kullanarak bulanık sinir ağı modeli ile endeks tahmininde bulunmuşlardır. Modelde girdi olarak endeksin 1, 2, 3, 4 ve 5 günlük gecikmeleri kullanılmıştır. Model, %5'in altında bir hata ile endeksin günlük kapanış değerlerini tahmin edebilmiştir.

Mohan ve diğeri (2006), Bombay Borsası, Ocak 1997 ve Aralık 2003 tarihleri arasındaki haftalık kapanış değerlerini kullanarak iki farklı YSA modeli oluşturmuşlardır. İki modelin ortak değişkenleri olarak önceki hafta kapanış değerleri, 52 haftalık hareketli ortalamalar ve 5 haftalık hareketli ortalamalar kullanılmıştır. Birinci modele 10 haftalık momentum; ikinci modele ise 5 haftalık volatilité değerleri eklenmiştir. Ortalama mutlak hata birinci modelde %3,93; ikinci modelde ise %5.52 olarak hesaplanmıştır. Bu sonuca göre momentum değişkeninin tahmin başarısına etkisi volatilitéye göre daha yüksektir.

Avcı (2007), çok katmanlı algılayıcılar ile Ocak 1996-Haziran 2005 tarihleri arasındaki 14 teknik gösterge verilerini kullanarak İMKB-100 endeksi üzerinde günlük ve dönemsel tahminlerde bulunmuştur. Araştırmacı, belirtilen tarih aralığını 8 farklı dönem olarak incelemiş ve her dönem için %70 eğitim, %20 doğrulama ve %10 test verisi olacak şekilde veri setleri oluşturmuştur. Araştırmada geliştirilen ileri beslemeli çok katmanlı algılayıcı model bir gizli katmana sahiptir. Gizli katmandaki eleman sayısı farklılaştırılarak üç YSA modeli oluşturulmuştur. Birinci modelde 7, ikinci modelde 14 ve üçüncü modelde 28 elemanlı bir gizli katman bulunmaktadır. Gizli katmanda hiperbolik tanjant, çıktı katmanında ise doğrusal fonksiyon kullanılmıştır. Çalışmada, oluşturulan modellerin genel olarak günlük tahminlerde daha başarılı olduğu sonucuna varılmıştır.

Lee ve diğeri (2007), Kore hisse senedi fiyat endeksi tahmini için Ocak 1999 ve Mayıs 2006 tarihleri arasındaki verileri kullanarak SARIMA ve YSA ile iki farklı model oluşturmuşlardır. Çalışma sonucunda farklı dönemler üzerinde yapılan tahminlerde SARIMA yönteminin endeks tahmininde YSA modeline göre daha doğru sonuçlar verdiği görülmüştür. Bunun yanında endeks getirisi tahmininde ise YSA modeli daha başarılı tahminler yapmıştır.

Abdelmouez ve diğeri (2007) NYSE, NASDAQ, S&P500 gibi endekslerden elde ettikleri 223 sektör endeksinin, 4 Ocak 1988 ile 31 Temmuz 2001 tarihleri arasındaki değerlerini kullanarak, Box-Jenkins, Çoklu Regresyon ve YSA yöntemleri ile tahmin çalışması yapmışlardır. Çalışmada öncelikle ARMA ve Çoklu Regresyon tahminleri karşılaştırılmış ve ARMA modeli ile yapılan tahminlerin Çoklu Regresyon modeli ile yapılan tahminlerden genel olarak daha başarılı olduğu görülmüştür. Ardından günlük ve haftalık verilerle oluşturulan ARMA ve YSA modelleri karşılaştırılmış ve her iki modelde de YSA tahminlerinin ARMA tahminlerinden daha iyi olduğu görülmüştür. Ayrıca modeller sektörel ve bileşik olarak da test edilmiş ve bileşik modelin sektörel modellere göre tüm testlerde daha başarılı tahminler ürettiği gözlenmiştir. Tek sektör için (S&P500) oluşturulan YSA modelinin 223 sektör verisinin birleştirilmesi ile oluşturulan modele göre daha zayıf tahminler yaptığı görülmüştür. Çalışma sonucunda tek sektör modeline göre belirlenen al-sat stratejisinin yıllık ortalama getirisi %70'in altında olmasına karşın birleşik modelde bu değer %83 civarında olduğu görülmüştür.

Junyou (2007), oluşturduğu yapay sinir ağı modelini geri yayılma algoritması ve Swarm Optimizasyonu ile eğitmiş ve bu iki eğitim tekniğini karşılaştırmıştır. Çalışmada, Straits Times Index (STI) ve California elektrik piyasası fiyat endeksi verileri ile her bir endeks için dörder YSA modeli kurularak oluşturulan 8 model sonuçları değerlendirilmiştir. İlk olarak geri yayılma algoritması ile iki endeks için 4 farklı YSA oluşturmuştur. Her bir model en iyi sonuç için farklı parametrelere sahiptir. STI için oluşturulan geri yayılma algoritması ile öğrenen modelde, girdi değerleri olarak 9 Ocak 2003 ile 9 Ocak 2006 tarihleri arasındaki günlük düzeltilmiş kapanış değerlerinin gecikmeleri kullanılmıştır. Yapılan denemeler sonucunda öğrenme katsayısı 0,5 ve momentum katsayısı 0,9 olan iki model, sonuç karşılaştırması için seçilmiştir. Birinci

modelde, girdi katmanında 2, gizli katmanda 8 nöron bulunmaktadır. İkinci modelde ise girdi katmanında 3 gizli katmanda 9 nöron kullanılmıştır. California elektrik piyasası için geliştirilen geri yayılmalı modellerde ise momentum katsayısı 0,5 olarak tercih edilmiştir. Oluşturulan iki modelin birincisi, 3 girdi 9 gizli; ikincisi ise 4 girdi 13 gizli işlem elemanına sahiptir. Benzer şekilde Swarm optimizasyonu ile eğitilen YSA mimarilerinde ise STI ve California elektrik piyasası için sırasıyla; 2-8-1 ve 3-9-1 elemanlı iki model ve 3-9-1 ve 4-13-1 elemanlı iki model oluşturulmuştur. Çalışma sonucunda elde edilen verilere bağlı olarak Swarm optimizasyonu ile eğitilen ağların tahmin başarısının geri yayılma algoritması ile eğitilen ağlardan daha yüksek olduğu görülmüştür.

Huang (2008), genetik algoritmalar, bulanık mantık ve yapay sinir ağları ile melez bir model geliştirdiği çalışmasında, 15 Haziran 2004 – 15 Haziran 2005 tarihleri arasındaki Shenzhen Borsası China Vanke Co. Ltd. hissesi günlük verilerini kullanmıştır. Belirtilen tarihler arasındaki 238 günlük veriden 200'ü eğitim 28'i doğrulama ve son 10 günlük veri ise test için kullanılmıştır. Karşılaştırma için iki model oluşturmuştur. Birinci model, ileri beslemeli, geri yayılma algoritması ile öğrenen bir gizli katmanlı standart bir sinir ağıdır. İkinci modelde ise geriye yayılma öğrenme algoritması genetik algoritma ile birleştirilmiştir. Model girdi katmanı, bulanıklaştırma katmanı, bulanıklığı çözme katmanı ve çıktı katmanı olarak 4 katmandan oluşmaktadır. İki model sırasıyla her katmanda 10-10-1 ve 10-30-3-1 sayıda işlem elemanı ile eğitilmiştir. Birinci modelde eleman sayıları deneme-yanılma ile ikinci modelde ise genetik algoritmalar ile belirlenmiştir. 2000 döngü ile yapılan eğitim sonunda standart sinir ağı test verilerinde %7'ye yakın bir hata (hata kareleri toplamı: 0,0668) ile tahmin üretmiştir. İkinci modelin hata kareleri toplamı ise 0,0217 olarak hesaplanmıştır. Hisse senedi yönü birinci modelde %76,32; ikinci modelde ise %89,47 doğrulukla öngörülmüştür.

Arisa - Mohamad (2008), Kuala Lumpur bileşik endeksi eğilim yönünü, genelleştirilmiş ileri beslemeli yapay sinir ağları ve çok katmanlı algılayıcılar ile tahmin etmeye çalışmışlardır. YSA modellerinde endeksin açılış, en düşük, en yüksek ve kapanış değerlerinin yanı sıra gün, ay, hafta gibi değişkenleri temsilen 5 kukla değişken kullanmışlardır. Çalışmada esas aldıkları 1 Temmuz 2001 ile 28 Şubat 2003 tarihleri arasındaki verilerinin %90'ını eğitim %10'unu ise test için kullanmışlardır. 1, 2 ve 4 gizli tabakalı yapay sinir ağı modelleri ile yaptıkları tahmin sonuçlarını 5 ve 10 günlük hareketli

ortalama tahminleri ile karşılaştırmışlardır. Çalışma sonucunda her iki YSA modelinin de tek gizli katmanla en iyi sonucu ürettiği görülmüştür. Ayrıca tüm YSA modelleri hareketli ortalamalara göre daha iyi tahminde bulunmuştur.

Buliali ve diğerleri (2009), Jakarta bileşik endeksinin tahmini için Temmuz 1997-Aralık 2007 tarihleri arasındaki günlük endeks değerlerinin teknik analiz göstergelerini kullanarak iki farklı sinir ağı modeli oluşturmuşlardır. İki modelde de geri yayımlı çok katmanlı algılayıcılar kullanılmıştır. Ancak ikinci modelde eğitim verilerinin %50'si Monte Carlo simülasyonu ile üretilmiştir. Başka bir deyişle, ikinci modelde eğitim verileri, Monte Carlo simülasyonu ile iki katına çıkarılmıştır. Modeller 6 aylık ve bir yıllık iki farklı dönemde eğitilmiş ve 3, 6 ve 9 aylık tahminler üretilmiştir. Her iki eğitim periyodunda da melez sistemin tüm tahminlerde daha iyi sonuç ürettiği görülmüştür. Böylece yeterli sayıda verinin olmadığı durumlarda Monte Carlo Simülasyonu ile üretilen verilerin, yapay sinir ağı modellerinin tahmin performansını artırdığı sonucuna ulaşılmıştır.

ÜÇÜNCÜ BÖLÜM

3. YAPAY SİNİR AĞLARI İLE İMKB-100 ENDEKSİNİN TAHMİNİ UYGULAMASI

Uygulama, Şubat 1991- Mayıs 2009 tarihleri arasındaki aylık 220 veri kullanılarak yapılmıştır.

30. Uygulamada Kullanılan Bağımlı Değişken

Uygulamada İMKB-100 endeksi aylık kapanış değerleri bağımlı değişken olarak kullanılmıştır. Değerler Merkez Bankası internet sitesinden alınmıştır.

31. Uygulamada Kullanılan Bağımsız Değişkenler

Mevduat Faiz Oranı

Merkez Bankası internet sitesinden elde edilen 1 ay, 3 ay, 6 ay ve 12 ay vadeli mevduat faiz oranlarının aylık yüzdesel değerleri E-Views programı ile test edilmiştir. Adımsal regresyon ile yapılan test sonuçlarına göre 6 ay vadeli mevduat faiz oranı en etkili değişken olarak seçilmiştir. Test çıktısı Tablo 3'deki gibidir.

Tablo : 3
Mevduat Faiz Oranları Adımsal Regresyon Testi Sonuçları

Dependent Variable: XU100				
Method: Stepwise Regression				
Sample: 1 220				
Included observations: 220				
No always included regressors				
Number of search regressors: 5				
Selection method: Stepwise forwards				
Stopping criterion: p-value forwards/backwards = 0.01/0.01				
	Coefficient	Std. Error	t-Statistic	Prob.*
C	41183.85	1316.747	31.27698	0.0000
_6AY	-594568.8	25613.08	-23.21348	0.0000
R-squared	0.711970	Mean dependent var		13576.22
Adjusted R-squared	0.710649	S.D. dependent var		15583.63
S.E. of regression	8382.650	Akaike info criterion		20.91477
Sum squared resid	1.53E+10	Schwarz criterion		20.94562
Log likelihood	-2298.624	Hannan-Quinn criter.		20.92722
F-statistic	538.8657	Durbin-Watson stat		0.140007
Prob(F-statistic)	0.000000			

Test sonuçlarına bağlı olarak uygulamada 6 ay vadeli mevduat faiz oranlarının aylık yüzdesel değerleri kullanılmıştır.

Altın Fiyatları

Altın fiyatları olarak aylık ortalama altın fiyatları verisi kullanılmıştır.

Para Arzı

Merkez Bankası internet sitesinden elde edilen Dar (M1) ve Geniş (M2) para arzı aylık değerleri E-Views programı ile test edilmiş ve test sonucunda M1 değişkeninin açıklama gücü M2 değişkenine göre daha yüksek bulunmuştur. Test sonuçları Tablo 4’de verilmiştir.

Tablo : 4
Para Arzı Adımsal Regresyon Testi Sonuçları

Dependent Variable: XU100				
Method: Stepwise Regression				
Sample: 1 220				
Included observations: 220				
No always included regressors				
Number of search regressors: 3				
Selection method: Stepwise forwards				
Stopping criterion: p-value forwards/backwards = 0.01/0.01				
Stopping criterion: Number of search regressors = 1				
	Coefficient	Std. Error	t-Statistic	Prob.*
M1	0.000819	1.69E-05	48.38036	0.0000
R-squared	0.849210	Mean dependent var		13576.22
Adjusted R-squared	0.849210	S.D. dependent var		15583.63
S.E. of regression	6051.393	Akaike info criterion		20.25850
Sum squared resid	8.02E+09	Schwarz criterion		20.27393
Log likelihood	-2227.435	Hannan-Quinn criter.		20.26473
Durbin-Watson stat	0.133681			

Test sonuçlarına bağlı olarak uygulamada para arzı değişkeni olarak dar para arzı (M1) kullanılmıştır.

Döviz Kuru

Döviz kuru olarak dolar kurunun aylık kapanış fiyatları verisi kullanılmıştır.

Bağımlı Değişkenin Gecikmesi

Bağımlı değişken üzerindeki diğer faktörleri açıklayabilmesi açısından değişkenin üç gecikmeye kadar değeri E-Views programı ile test edilmiş test sonucunda bağımlı değişkenin bir gecikmesinin en etkin gecikme olduğu görülmüştür. Bu nedenle bağımsız değişken olan İMKB-100 değişkeninin bir gecikmesi bağımsız değişkenlere eklenmiştir. Test sonuçları Tablo 5’de görülmektedir.

Tablo : 5
İMKB-100 Gecikmeleri Adımsal Regresyon Testi Sonuçları

Dependent Variable: XU100				
Method: Stepwise Regression				
Sample: 1 220				
Included observations: 220				
No always included regressors				
Number of search regressors: 4				
Selection method: Stepwise forwards				
Stopping criterion: p-value forwards/backwards = 0.01/0.01				
	Coefficient	Std. Error	t-Statistic	Prob.*
XU100G1	1.001221	0.007023	142.5616	0.0000
R-squared	0.981211	Mean dependent var		13576.22
Adjusted R-squared	0.981211	S.D. dependent var		15583.63
S.E. of regression	2136.076	Akaike info criterion		18.17586
Sum squared resid	9.99E+08	Schwarz criterion		18.19129
Log likelihood	-1998.345	Hannan-Quinn criter.		18.18209
Durbin-Watson stat	2.130856			

32. Uygulama Modeli

Uygulamada iki farklı model kullanılmıştır. Birinci modelde 6 ay vadeli mevduat faiz oranının aylık yüzdesel reel değeri, aylık ortalama altın fiyatları, dar para arzı (M1) ve dolar kuru bağımsız değişkenler olarak seçilmiştir. İkinci modelde ise bağımlı değişken olan İMKB-100 aylık kapanış değerlerinin bir gecikmesi, birinci modelde kullanılan değişkenlere ek olarak modele eklenmiştir.

Uygulama Peltarion Synapse programı ile yapılmıştır.

320. Gecikmesiz Model

Modelde 6 ay vadeli mevduat faiz oranının aylık yüzdesel reel değeri, aylık ortalama altın fiyatları, dar para arzı (M1) ve dolar kuru bağımsız değişkenler olarak seçilmiştir.

Çok katmanlı algılayıcılar ile oluşturulan yapay sinir ağı modelinde bir gizli katman kullanılmıştır. Girdi katmanında seçilen bağımsız değişkenlere bağlı olarak 4 nöron bulunmaktadır. Gizli katmanda ise 6 nöron bulunmaktadır. Gizli katmandaki nöron sayısı program tarafında problemin zorluk parametrelerine göre otomatik olarak belirlenmiştir. Çıktı katmanında ise uygulamadaki bağımsız değişken sayısı bir olduğundan bir nöron bulunmaktadır.

Gizli katmanda ve çıktı katmanında toplama fonksiyonu olarak Ağırlıklı Toplam fonksiyonu kullanılmıştır.


Aktivasyon fonksiyonu olarak ise gizli katmanda hiperbolik tanjant fonksiyonu, çıktı katmanında ise doğrusal fonksiyonu kullanılmıştır.

Modelde öğrenme katsayısı 0,1; momentum katsayısı ise 0,7 olarak uygulanmıştır.

Kullanılan 220 veri setinden %75'i (187 Adet) eğitim için; kalan %15'i (33 Adet) ise tahmin için kullanılmıştır.

Eğitim, 20000 döngü (epoch) ile her döngüde tüm veriler kullanılarak yapılmıştır.

Oluşturulan model Şekil 10'da gösterilmiştir.



Şekil : 10

Gecikmesiz Model için Çok Katmanlı Algılayıcı Yapay Sinir Ağı Yapısı

321. Gecikmeli Model

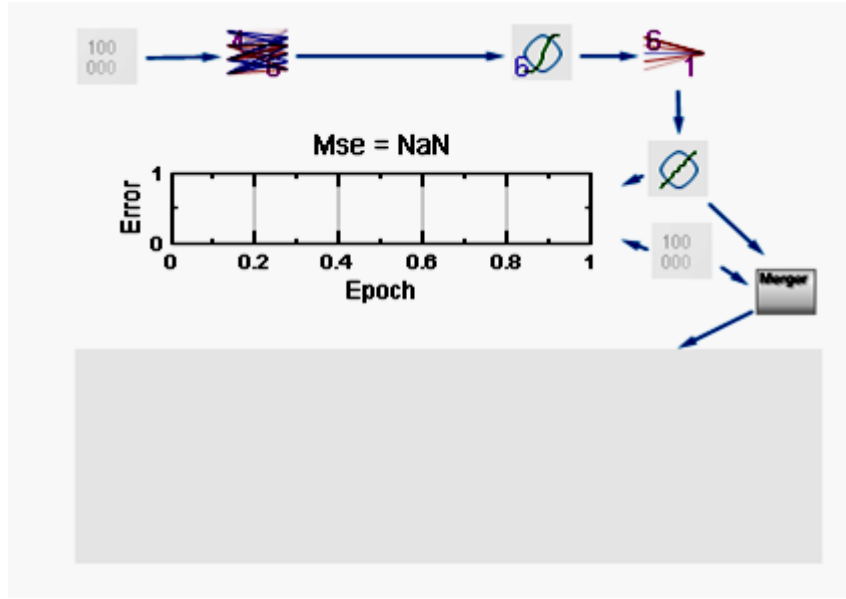
Modelde 6 ay vadeli mevduat faiz oranının aylık yüzdesel reel değeri, aylık ortalama altın fiyatları, dar para arzı (M1) ve dolar kuru ve İMKB-100 endeksinin bir gecikmesi bağımsız değişkenler olarak seçilmiştir.

Modelde gecikmesiz modelle karşılaştırmanın anlamlı olması bakımından, gecikmesiz modelde olduğu gibi bir gizli katman kullanılmıştır. Girdi katmanında seçilen bağımsız değişkenlere bağlı olarak 5 nöron bulunmaktadır. Gizli katmanda ise yine gecikmeli modelde olduğu gibi 6 nöron bulunmaktadır. Çıktı katmanında ise uygulamadaki bağımsız değişken sayısı bir olduğundan bir nöron bulunmaktadır.

Diğer parametreler de gecikmesiz modelde olduğu gibidir. Gizli katmanda ve çıktı katmanında toplama fonksiyonu olarak Ağırlıklı Toplam fonksiyonu kullanılmıştır. Aktivasyon fonksiyonu olarak ise gizli katmanda hiperbolik tanjant fonksiyonu, çıktı

katmanında ise doğrusal fonksiyonu kullanılmıştır. Öğrenme katsayısı 0,1; momentum katsayısı ise 0,7 olarak uygulanmıştır.

Yine gecikmesiz modelde olduğu gibi gecikmeli modelde de kullanılan 220 veri setinden %75'i (187 Adet) eğitim için; kalan %15'i (33 Adet) ise tahmin için kullanılmıştır. Eğitim, 20000 döngü (Epoch) ile her döngüde tüm veriler kullanılarak yapılmıştır. Oluşturulan model Şekil 11'de gösterilmiştir.



Şekil : 11

Gecikmeli Model için Çok Katmanlı Algılayıcı Yapay Sinir Ağı Yapısı

33. Modellerden Elde Edilen Sonuçlar

330. Gecikmesiz Model Sonuçları

Gecikmesiz modelde kullanılan eğitim setinin ve modelin hesapladığı endeks kapanış değerlerinin grafiği Grafik 1'de verilmiştir. Eğitim seti için hata dağılımı ise Grafik 2'deki gibidir.

Tahmin edilen aylık kapanış değerleri ve gerçek değerlerin seyri ise Grafik 3'de gösterilmiştir. Tahmin değerlerine ilişkin hata dağılımı Grafik 4'tedir. Tahmin değerleri ve hata miktarları Tablo 6'da ayrıntılı olarak verilmiştir.

Tablo : 6
Gecikmesiz Model Tahmin ve Hata Değerleri

Tarih	Gerçekleşen	Tahmin	Mutlak Hata	Mutlak Hata (%)
Eyl.06	36924,86	39450,79662	2525,936624	6,84075%
Eki.06	40582,25	40755,8943	173,6443039	0,42788%
Kas.06	38168,53	39025,1706	856,6405983	2,24436%
Ara.06	39117,46	42485,87961	3368,41961	8,61104%
Oca.07	41182,55	40136,8754	1045,674599	2,53912%
Şub.07	41430,99	40715,95945	715,0305505	1,72584%
Mar.07	43661,12	41840,56516	1820,554839	4,16974%
Nis.07	44984,45	45992,92165	1008,471648	2,24182%
May.07	47081,49	47172,5141	91,02410271	0,19333%
Haz.07	47093,67	49664,40694	2570,736941	5,45877%
Tem.07	52824,89	50595,12166	2229,76834	4,22106%
Ağu.07	50198,6	50294,61522	96,01522136	0,19127%
Eyl.07	54044,22	57788,51927	3744,29927	6,92821%
Eki.07	57615,72	60157,49428	2541,774277	4,41160%
Kas.07	54213,82	60476,92593	6263,105928	11,55260%
Ara.07	55538,13	64302,52692	8764,396921	15,78086%
Oca.08	42697,56	62913,43394	20215,87394	47,34667%
Şub.08	44776,88	64088,74589	19311,86589	43,12910%
Mar.08	39015,44	62184,33746	23168,89746	59,38392%
Nis.08	43468,12	63518,52169	20050,40169	46,12668%
May.08	39969,63	65558,51231	25588,88231	64,02081%
Haz.08	35089,53	66383,00361	31293,47361	89,18180%
Tem.08	42200,75	69246,64532	27045,89532	64,08866%
Ağu.08	39844,48	67013,71365	27169,23365	68,18820%
Eyl.08	36051,3	66285,3499	30234,0499	83,86397%
Eki.08	27832,93	55324,65634	27491,72634	98,77410%
Kas.08	25714,98	51577,49862	25862,51862	100,57375%
Ara.08	26864,07	56331,35886	29467,28886	109,69034%
Oca.09	25934,37	47992,61121	22058,24121	85,05409%
Şub.09	24026,59	44704,27264	20677,68264	86,06166%
Mar.09	25764,38	47067,52831	21303,14831	82,68450%
Nis.09	31651,81	52163,77279	20511,96279	64,80502%
May.09	35002,99	54351,38144	19348,39144	55,27640%
Ortalamalar :			13594,39478	0,401753916


Bu sonuçlara ek olarak modelin endeks hareket yönü için tahmin edilen ayın bir önceki ay endeks kapanış değerine göre hareket yönü, tahmini ve gerçek değerler olarak, Tablo 7'deki verilmiştir. Yukarı hareket 1 aşağı hareket ise -1 olarak ifade edilmiştir. Ayrıca


endeksin hareket yönüne göre Al-Tut-Sat sinyalleri oluşturulmuş ve buna göre elde edilen kazanç miktarları hesaplanarak Tablo 7'ye eklenmiştir.

Tablo : 7

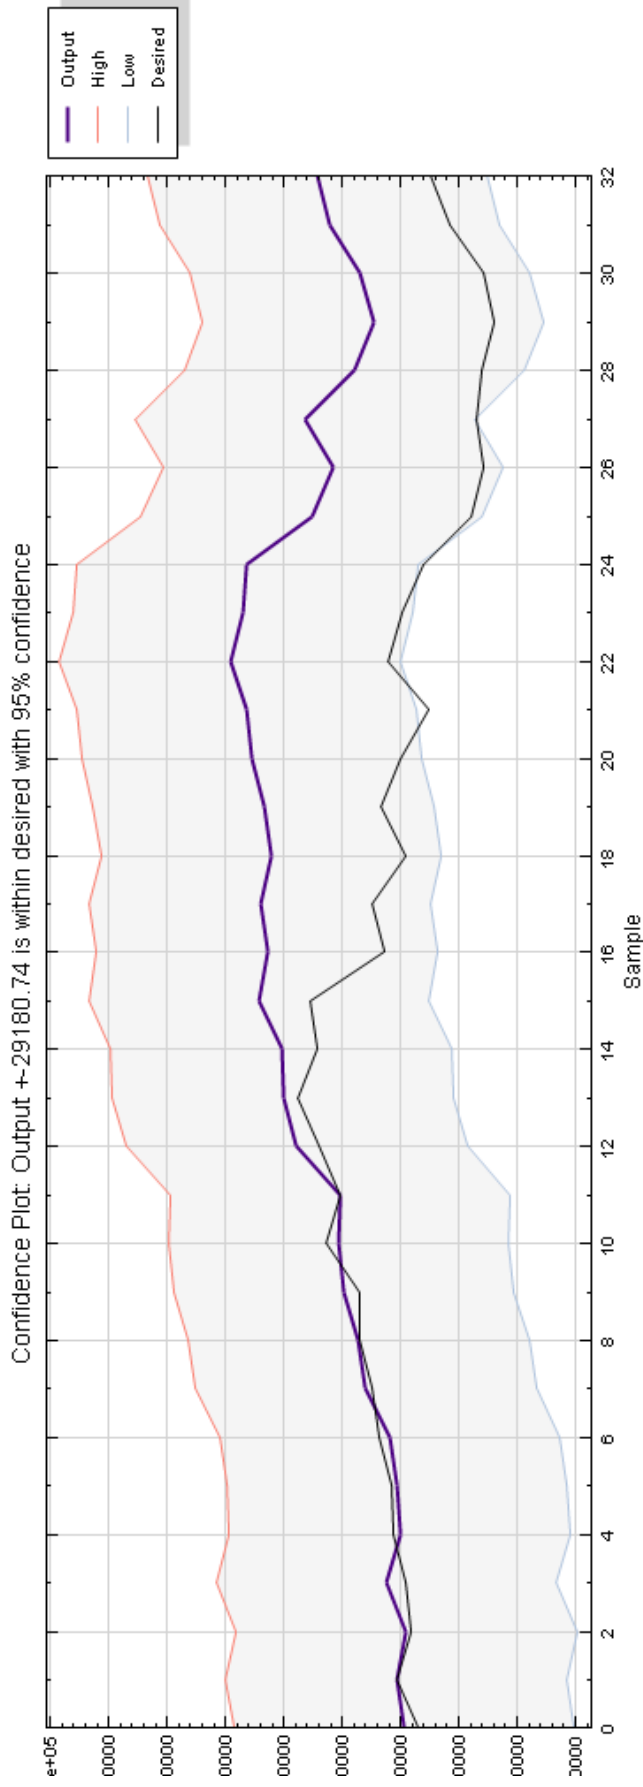
Gecikmesiz Model Endeks Yönü Tahmini ve Kazanç Değerleri

Endeks Yönü			Al-Sat Sinyalleri		Kazanç Değerleri			
Yön	Tahmin		Gerçek	Tahmin	Gerçek		Tahmin	
					% Kazanç	Endeks	% Kazanç	Endeks
-	-	-	-	-	-	100	-	100
1	1	DOĞRU	Tut	Tut	-	100	-	100
-1	-1	DOĞRU	Sat	Sat	0,09905	109,905	0,09905	109,90
1	1	DOĞRU	Al	Al	-	109,905	-	109,905
1	-1	YANLIŞ	Tut	Sat	-	109,905	0,024862	112,637
1	1	DOĞRU	Tut	Al	-	109,905	-	112,637
1	1	DOĞRU	Tut	Tut	-	109,905	-	112,637
1	1	DOĞRU	Tut	Tut	-	109,905	-	112,637
1	1	DOĞRU	Tut	Tut	-	109,905	-	112,637
1	1	DOĞRU	Tut	Tut	-	109,905	-	112,637
-1	-1	DOĞRU	Sat	Sat	0,383991	152,107	0,282701	144,48
1	1	DOĞRU	Al	Al	-	152,107	-	144,48
1	1	DOĞRU	Tut	Tut	-	152,107	-	144,48
-1	1	YANLIŞ	Sat	Tut	0,147756	174,582	-	144,48
1	1	DOĞRU	Al	Tut	-	174,582	-	144,48
-1	-1	DOĞRU	Sat	Sat	0,024428	178,846	0,106368	159,848
1	1	DOĞRU	Al	Al	-	178,846	-	159,848
-1	-1	DOĞRU	Sat	Sat	0,048699	187,556	0,048699	167,632
1	1	DOĞRU	Al	Al	-	187,556	-	167,632
-1	1	YANLIŞ	Sat	Tut	0,114126	208,961	-	167,632
-1	1	YANLIŞ	Tut	Tut	-	208,961	-	167,632
1	1	DOĞRU	Al	Tut	-	208,961	-	167,632
-1	-1	DOĞRU	Sat	Sat	0,202659	251,309	0,081642	181,318
-1	-1	DOĞRU	Tut	Tut	-	251,309	-	181,318
-1	-1	DOĞRU	Tut	Tut	-	251,309	-	181,318
-1	-1	DOĞRU	Tut	Tut	-	251,309	-	181,318
1	1	DOĞRU	Al	Al	-	251,309	-	181,318
-1	-1	DOĞRU	Sat	Sat	0,044686	262,539	0,044686	189,420
-1	-1	DOĞRU	Tut	Tut	-	262,539	-	189,420
1	1	DOĞRU	Al	Al	-	262,539	-	189,420
1	1	DOĞRU	Tut	Tut	-	262,539	-	189,420
1	1	DOĞRU	Tut	Tut	-	262,539	-	189,420
-	-	-	Sat	Sat	0,456844	382,478	0,456844	275,956

**Grafik : 1****Gecikmesiz Model Eğitim Seti Hesaplanan Değer ve Gerçek Değer Grafiği**

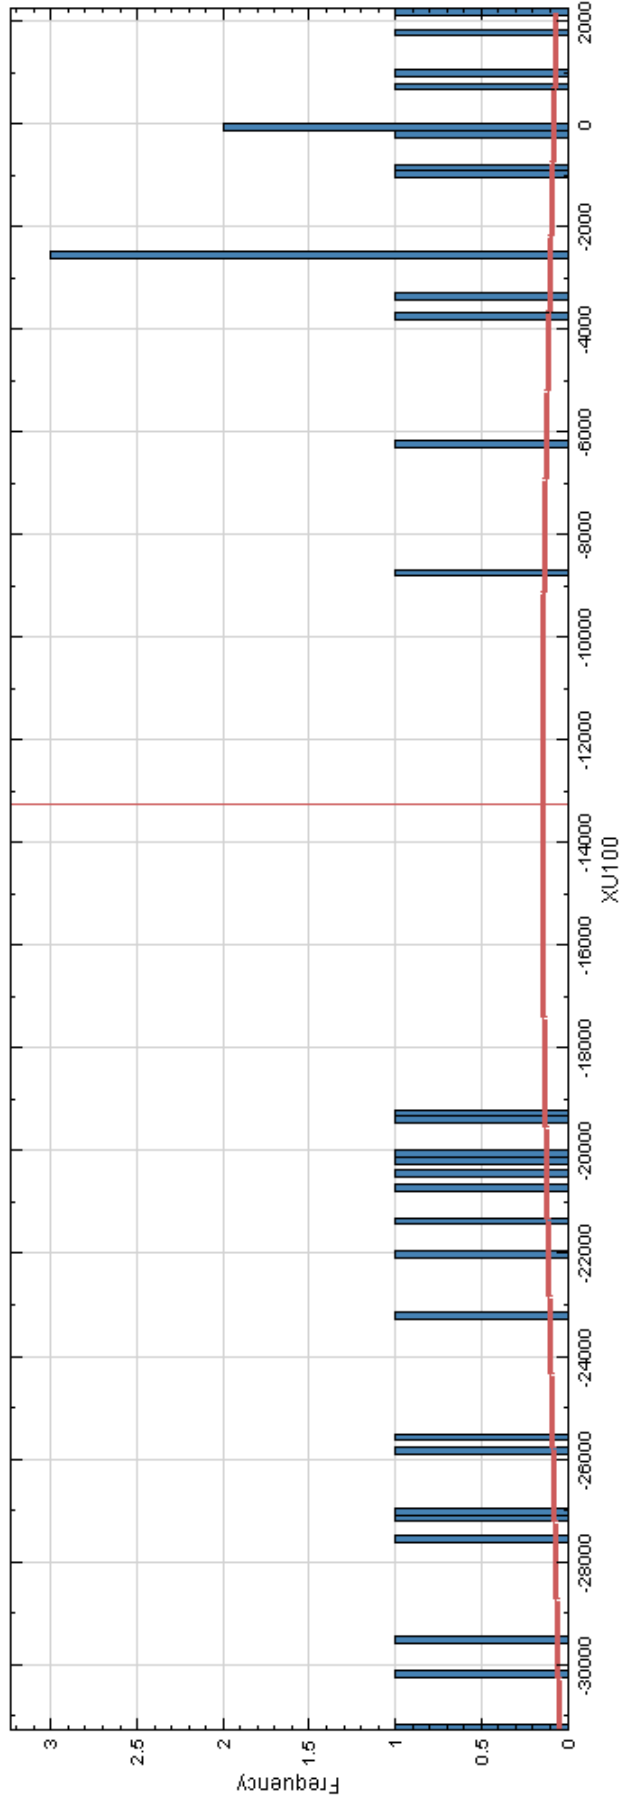


Grafik : 2
Gecikmesiz Model Eğitim Seti Hata Dağılımı Grafığı



Grafik : 3

Gecikmesiz Model Hesaplanan Tahmin Değerleri ve Gerçek Değerler Grafiği



Grafik : 4

Gecikmesiz Model Tahmin Değerleri Hata Dağılımı Grafiği

331. Gecikmeli Model Sonuçları

Gecikmeli modelde kullanılan eğitim setinin ve modelin hesapladığı değerler Grafik 5'de verilmiştir. Eğitim seti için hata dağılımı ise Grafik 6'daki gibidir.

Tahmin edilen değerler ve gerçek değerler ise Grafik 7'de gösterilmiştir. Tahmin değerlerine ilişkin hata dağılımı Grafik 8'dedir. Tahmin değerleri ve hata miktarları Tablo 8'de ayrıntılı olarak verilmiştir.

Gecikmeli model için endeks yönü tahminleri ve bu tahminlere bağlı olarak üretilen Al-Tut-Sat sinyalleri Tablo 9'daki gibidir.

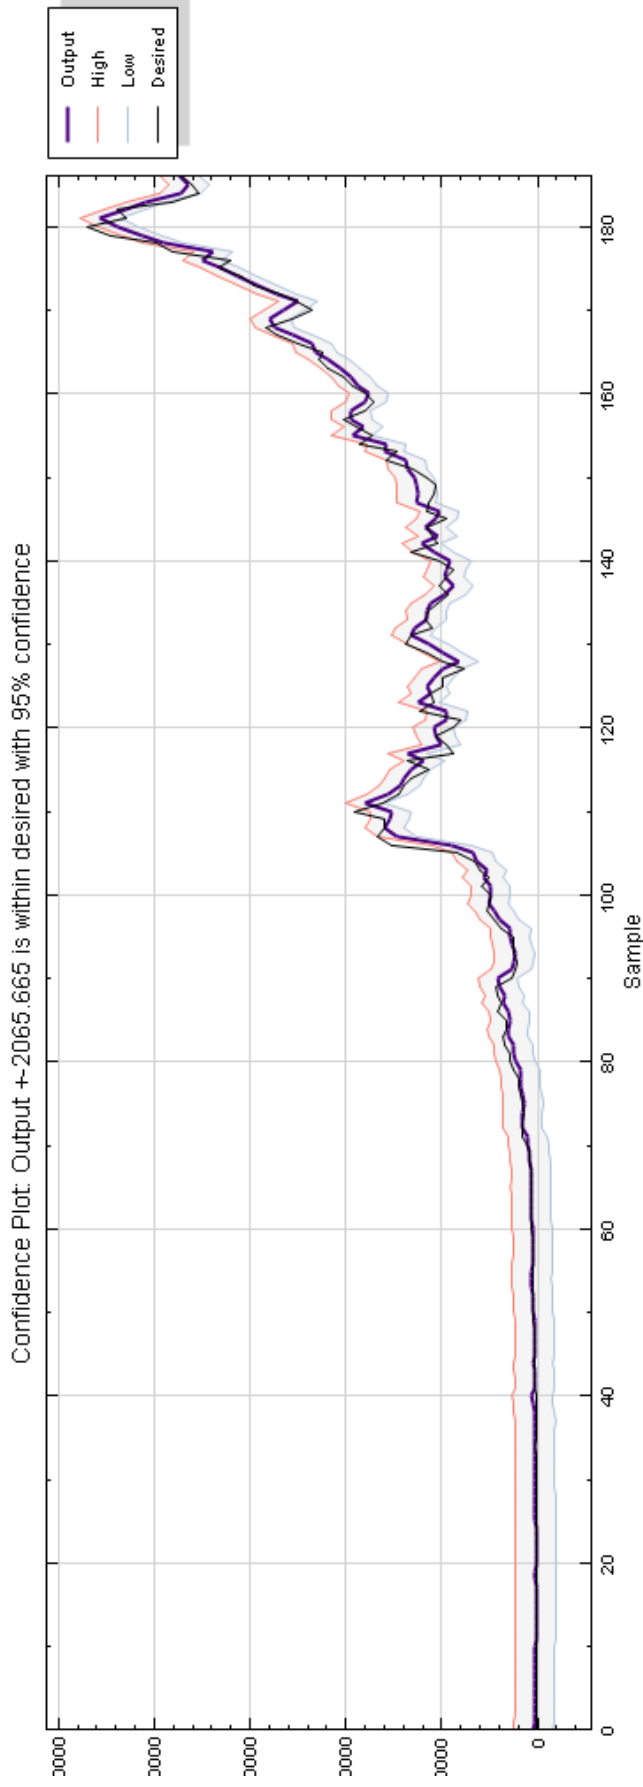
Tablo : 8
Gecikmeli Model Tahmin ve Hata Değerleri

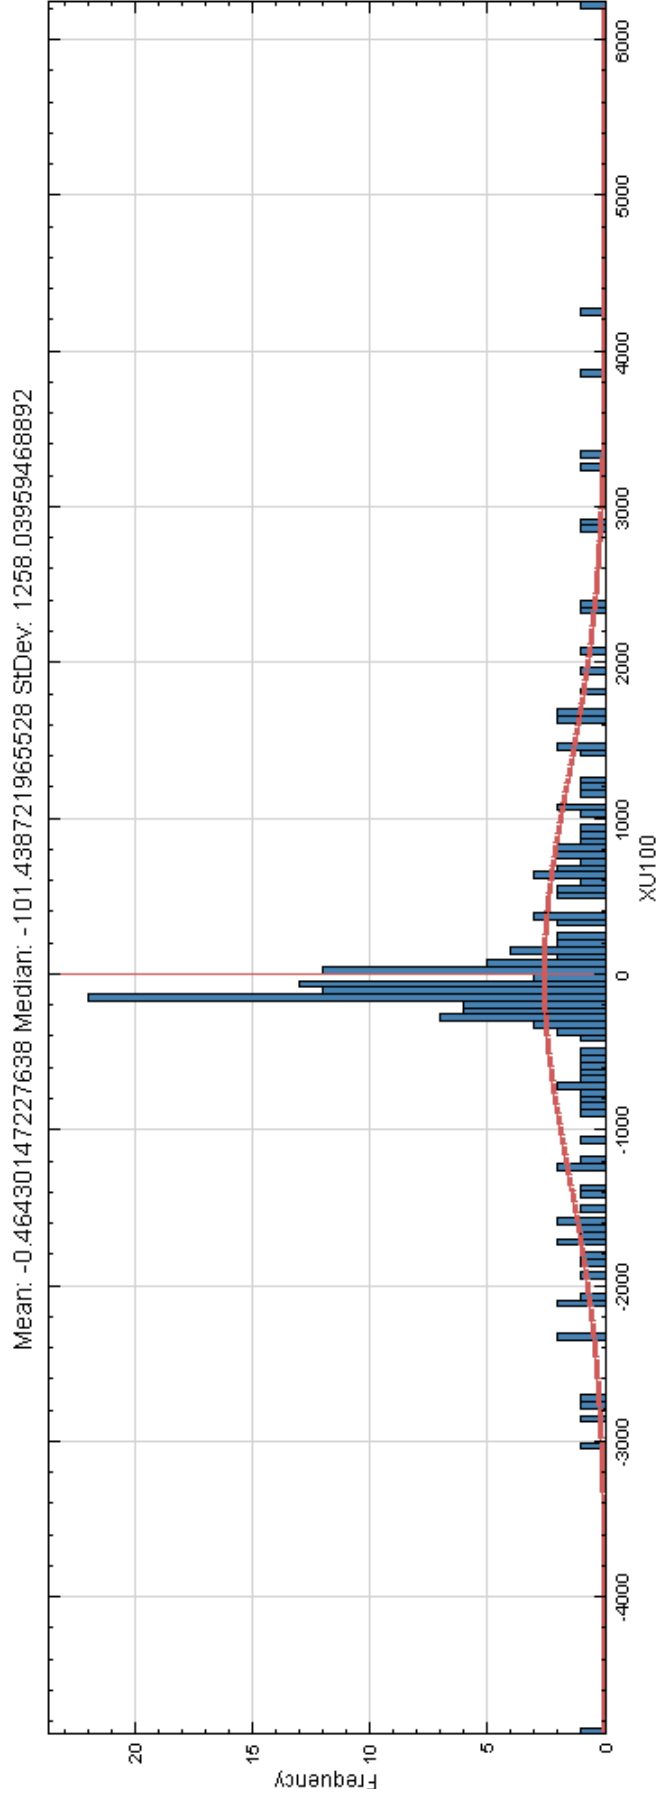
Tarih	Gerçekleşen	Tahmin	Mutlak Hata	Mutlak Hata (%)
Eyl.06	36924,86	38272,26678	1347,406778	3,64905%
Eki.06	40582,25	38540,01403	2042,235972	5,03234%
Kas.06	38168,53	40237,99536	2069,465363	5,42192%
Ara.06	39117,46	39491,54904	374,0890375	0,95632%
Oca.07	41182,55	39483,16131	1699,388694	4,12648%
Şub.07	41430,99	40896,99541	533,9945853	1,28888%
Mar.07	43661,12	41413,56535	2247,554654	5,14773%
Nis.07	44984,45	44227,4521	756,9979011	1,68280%
May.07	47081,49	45880,42851	1201,061487	2,55103%
Haz.07	47093,67	48720,67538	1627,005377	3,45483%
Tem.07	52824,89	49080,72684	3744,163155	7,08788%
Ağu.07	50198,6	53409,40315	3210,803149	6,39620%
Eyl.07	54044,22	53355,87623	688,3437747	1,27367%
Eki.07	57615,72	57119,39703	496,3229658	0,86144%
Kas.07	54213,82	58888,02115	4674,20115	8,62179%
Ara.07	55538,13	58234,0977	2695,967696	4,85426%
Oca.08	42697,56	57435,2776	14737,7176	34,51653%
Şub.08	44776,88	47198,15788	2421,277876	5,40743%
Mar.08	39015,44	48131,88281	9116,442813	23,36624%
Nis.08	43468,12	44388,61875	920,4987515	2,11764%
May.08	39969,63	48769,23531	8799,605311	22,01573%
Haz.08	35089,53	46789,61019	11700,08019	33,34351%
Tem.08	42200,75	43545,44548	1344,695482	3,18643%
Ağu.08	39844,48	49694,19177	9849,711766	24,72039%
Eyl.08	36051,3	48253,5158	12202,2158	33,84681%
Eki.08	27832,93	41774,11646	13941,18646	50,08882%
Kas.08	25714,98	35464,69487	9749,71487	37,91453%
Ara.08	26864,07	35484,25354	8620,183542	32,08815%
Oca.09	25934,37	32594,74773	6660,377725	25,68166%
Şub.09	24026,59	30983,02975	6956,439746	28,95309%
Mar.09	25764,38	30936,44936	5172,069365	20,07450%
Nis.09	31651,81	33032,58559	1380,775589	4,36239%
May.09	35002,99	36765,96354	1762,973544	5,03664%
Ortalamalar :			4689,241459	0,136099119

Tablo : 9

Gecikmeli Model Endeks Yönü Tahmini ve Kazanç Değerleri


Endeks Yönü			Al-Sat Sinyalleri		Kazanç Değerleri			
Yön	Tahmin		Gerçek	Tahmin	Gerçek		Tahmin	
					% Kazanç	Endeks	% Kazanç	Endeks
-	-	-	-	-	-	100	-	100
1	1	DOĞRU	Tut	Tut	-	100	-	100
-1	1	YANLIŞ	Sat	Tut	0,09905	109,905	-	100
1	-1	YANLIŞ	Al	Sat	-	109,905	0,033681	103,368
1	-1	YANLIŞ	Tut	Tut	-	109,905	-	103,368
1	1	DOĞRU	Tut	Al	-	109,905	-	103,368
1	1	DOĞRU	Tut	Tut	-	109,905	-	103,368
1	1	DOĞRU	Tut	Tut	-	109,905	-	103,368
1	1	DOĞRU	Tut	Tut	-	109,905	-	103,368
1	1	DOĞRU	Tut	Tut	-	109,905	-	103,368
1	1	DOĞRU	Tut	Tut	-	109,905	-	103,368
-1	1	YANLIŞ	Sat	Tut	0,383991	152,107	-	103,368
1	-1	YANLIŞ	Al	Sat	-	152,107	0,218929	125,998
1	1	DOĞRU	Tut	Al	-	152,107	-	125,998
-1	1	YANLIŞ	Sat	Tut	0,147756	174,582	-	125,998
1	-1	YANLIŞ	Al	Sat	-	174,582	0,003138	126,393
-1	-1	DOĞRU	Sat	Tut	0,024428	178,846	-	126,393
1	-1	YANLIŞ	Al	Tut	-	178,846	-	126,393
-1	1	YANLIŞ	Sat	Al	0,048699	187,556	-	126,393
1	-1	YANLIŞ	Al	Sat	-	187,556	-0,12867	110,130
-1	1	YANLIŞ	Sat	Al	0,114126	208,961	-	110,130
-1	-1	DOĞRU	Tut	Sat	-	208,961	-0,08048	101,266
1	-1	YANLIŞ	Al	Tut	-	208,961	-	101,266
-1	1	YANLIŞ	Sat	Al	0,202659	251,309	-	101,266
-1	-1	DOĞRU	Tut	Sat	-	251,309	-0,05583	95,6127
-1	-1	DOĞRU	Tut	Tut	-	251,309	-	95,6127
-1	-1	DOĞRU	Tut	Tut	-	251,309	-	95,6127
1	1	DOĞRU	Al	Al	-	251,309	-	95,6127
-1	-1	DOĞRU	Sat	Sat	0,044686	262,539	0,044686	99,8852
-1	-1	DOĞRU	Tut	Tut	-	262,539	-	99,8852
1	-1	YANLIŞ	Al	Tut	-	262,539	-	99,8852
1	1	DOĞRU	Tut	Al	-	262,539	-	99,8852
1	1	DOĞRU	Tut	Tut	-	262,539	-	99,8852
-	-	-	Sat	Sat	0,456844	382,478	0,358581	135,702

**Grafik : 5****Gecikmeli Model Eğitim Seti Hesaplanan Değer ve Gerçek Değer Grafiği**




Grafik : 6

Gecikmeli Model Eğitim Seti Hata Dağılımı Grafiği



Grafik : 7

Gecikmeli Model Hesaplanan Tahmin Değerleri ve Gerçek Değerler Grafiği



Grafik : 8

Gecikmeli Model Tahmin Değerleri Hata Dağılımı Grafiği

34. Sonuçların Değerlendirilmesi

Her iki modelin eğitim setinden elde edilen hata dağılım grafiklerine (Grafik 2 ve Grafik 6) bakıldığında, hataların yaklaşık olarak 0 (sıfır) değeri etrafında bir çan eğrisi oluşturdukları görülmektedir. Bu durum, iki modelde de öğrenmenin kabul edilebilir bir doğrulukla gerçekleştiğini göstermektedir.

İki model eğitim seti için hesaplanan kapanış değeri ve gerçek değerler grafikleri (Grafik 1 ve Grafik 5) karşılaştırıldığında gecikmeli modelin sıçramalara daha duyarlı olduğu görülmektedir. Başka bir deyişle, gecikmeli model, eğitim setini gecikmesiz modele göre daha başarılı bir şekilde öğrenmiştir. Bu durumu iki model eğitim seti için oluşturulan karşılaştırmalı hata grafiğinden de görmek mümkündür (Grafik 9). Grafikte, her iki model için eğitim seti verilerinden hesaplanan değerlerin mutlak hataları ve bu hatalar için üstel eğilim çizgileri gösterilmektedir. Görüldüğü gibi gecikmeli model hataları için oluşturulan eğilim çizgisi, gecikmesiz model için oluşturulan eğilim çizgisinin altında kalmıştır. Ayrıca ortalama mutlak hatalara bakıldığında: gecikmesiz model için ortalama mutlak hata 868,1445; gecikmeli model için ortalama mutlak hata 764,5748 olarak hesaplanmıştır.

Grafik 20'e benzer olarak iki modelin mutlak hataları yüzdesel olarak hesaplanıp Grafik 10 oluşturulmuştur. Grafiğe bakıldığında eğilim çizgilerinin yaklaşık olarak üst üste çıktığı görülmektedir. Bu grafik özellikle bir hususun altını çizmek için verilmiştir. Çok katmanlı algılayıcılarla oluşturulan yapay sinir ağı modelleri, hatayı nominal olarak azaltır. Bu sebeple, maksimum-minimum değerleri arasında büyük farklar olan veri setleri için yüzdesel hatanın, öğrenme performansı değerlendirmesinde kullanılması hatalı çıkarımlara sebep olabilmektedir. Grafik 10'da gösterilen, her iki model için oluşturulan üstel hata eğilim çizgilerine bakıldığında, iki modelin birbirinden farklı olmadığı söylenebilir. Ancak yukarıda da belirtildiği gibi Grafik 1 ve Grafik 5 karşılaştırıldığında bu çıkarımın yanlış olacağı açıkça görülmektedir. Bağımsız değişken değerlerinin genel olarak çok küçük olduğu ilk değerlere bakıldığında, yüzdesel mutlak hataların çok büyük çıkması, bu durum başka bir göstergesidir. Oysa mutlak hataların karşılaştırıldığı grafikte genel eğilime göre daha durağan bir seyir izleyen yaklaşık ilk 80 veride mutlak hatalar incelenen dönemin geri kalan kısmına göre daha küçük çıkmıştır. Bu durum teorik beklentiye de uymaktadır.

Öğrenme süreci ile ilgili sonuç olarak, gecikmeli modelin gecikmesiz modele göre daha başarılı olduğu söylenebilir.

Modellerin tahmin performansı için ise endeks kapanış değeri tahmini hata dağılım grafiklerine (Grafik 4 ve Grafik 8) bakıldığında, hataların analitik olarak anlamlı çıkmadığı söylenebilir. Özellikle tahmin değerleri ile gerçek değerlerin karşılaştırıldığı Grafik 3 ve Grafik 7’deki Kasım 2007 tarihine tekabül eden noktadan sonra her iki modelde de tahmin değerlerinin gerçek değerlerden uzaklaştığı görülmektedir. Kırılmanın gerçekleştiği tarihe dikkat edilecek olursa, bu tarih, Temmuz-Ağustos 2007 tarihinde başlayan küresel finansal krizinin reel sektöre ve Türkiye’ye sıçradığı kabul edilen Kasım-Aralık 2007 tarihidir. Tablo 6 ve Tablo 7’deki değerlere bakıldığında Kasım-Aralık 2007 tarihlerinde kırılmanın kısmen gerçekleştiği; Ocak 2008’den itibaren ise belirginleştiği görülebilir. Bu sebeple modellerin endeks kapanış değerleri tahmin performanslarını iki aşamada değerlendirmek daha anlamlı olacaktır. Birinci aşamada Kasım 2007’ye kadar olan değerler; ikinci aşamada ise Kasım 2007’den sonraki değerler ayrı ayrı karşılaştırılacaktır. Ayrıca iki model için endeks değeri ve endeks yönü tahmin sonuçları sırasıyla Tablo 10-11’de karşılaştırmalı olarak verilmiştir

Tablo : 10


Endeks Değeri Tahmin Sonuçları Karşılaştırma Tablosu

	Gecikmesiz Model		Gecikmeli Model	
	Hata	Hata (%)	Hata	Hata (%)
Genel Sonuçlar	13594,394	40,17%	4689,24	13,61%
Kriz Öncesi (Eyl,2006-Eki,2007)	1627,714	3,59%	1574,202	3,50%
Kriz Dönemi (Kas,2007-May,2009)	22411,95	67,14%	6984,533	21,06%

Tablo : 11

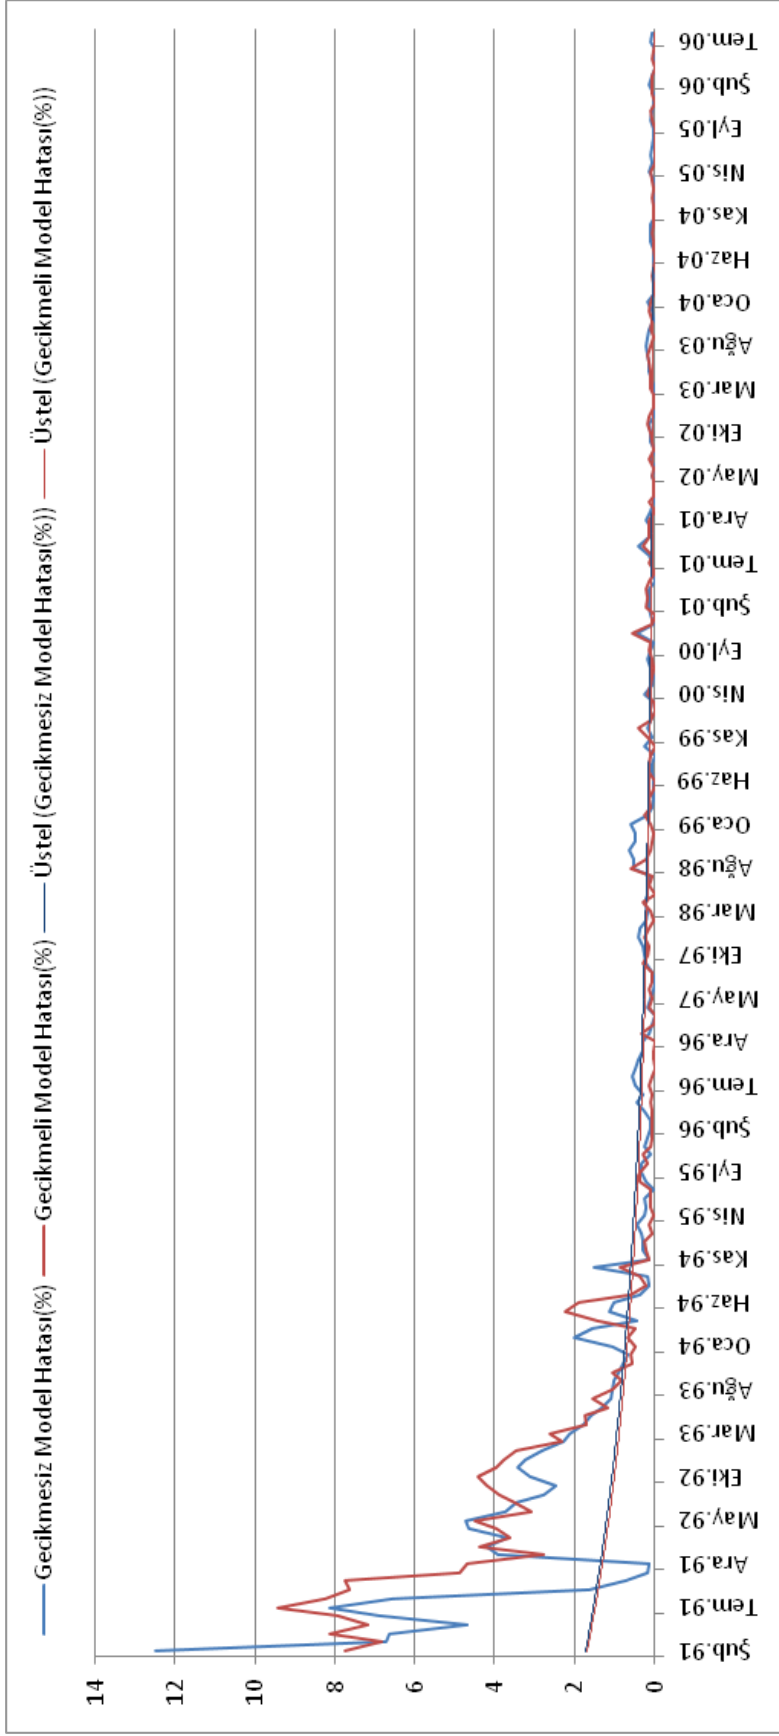
Endeks Yönü Tahmin Sonuçları Karşılaştırma Tablosu

	Gecikmesiz Model	Gecikmeli Model
Genel Sonuçlar	87,50%	56,25%
Kriz Öncesi (Eyl,2006-Eki,2007)	92,31%	61,54%
Kriz Dönemi (Kas,2007-May,2009)	84,21%	52,63%



Grafik : 9

Gecikmeli ve Gecikmesiz Model, Eğitim Seti için Karşılaştırmalı Hata Grafiği




Grafik : 10

Gecikmeli ve Gecikmesiz Model, Eğitim Seti için Karşılaştırmalı Yüzdesele Hata Grafiği


340. Birinci Aşamada Modellerin Endeks Kapanış Değerleri Tahmin Performanslarının Karşılaştırılması

Birinci aşama için modellerin tahmin ve hata dağılımı grafikleri yeniden oluşturulmuştur (Grafik 11, 12, 13, 14). Yeni durumda hata dağılım grafiklerinin (Grafik 12 ve Grafik 14) daha anlamlı olduğu söylenebilir. Öte yandan tahmin grafiklerine bakıldığında hangi modelin daha iyi performans sergilediği net olarak görülememektedir. Bunun için iki modelin karşılaştırmalı mutlak hata dağılımları ve hataların üstel eğilim çizgileri oluşturularak Grafik 15’de gösterilmiştir. Bu grafiğe göre gecikmesiz modelin hata eğilimi gecikmeli modele göre daha düşüktür. Gecikmeli modelin mutlak tahmin hataları ortalaması (1574,20235) gecikmesiz modelin ortalamasına (1627,713637) göre kısmen daha düşük olmasına rağmen, incelenen tarih aralığında gecikmeli model tahminleri, gecikmesiz model tahminlerine göre daha az sapma göstermiştir. Bunların yanında, gecikmeli model tahmin hataları eğilim çizgisinin, gecikmesiz modelin aksine aşağı yönlü olması, sonraki dönem için gecikmeli model tahmin hatalarının iyileşeceğine dair bir işaret olarak görülebilir. Sonuç olarak birinci aşamada iki modelin birbirine kesin bir üstünlüğünden bahsetmek mümkün değildir.



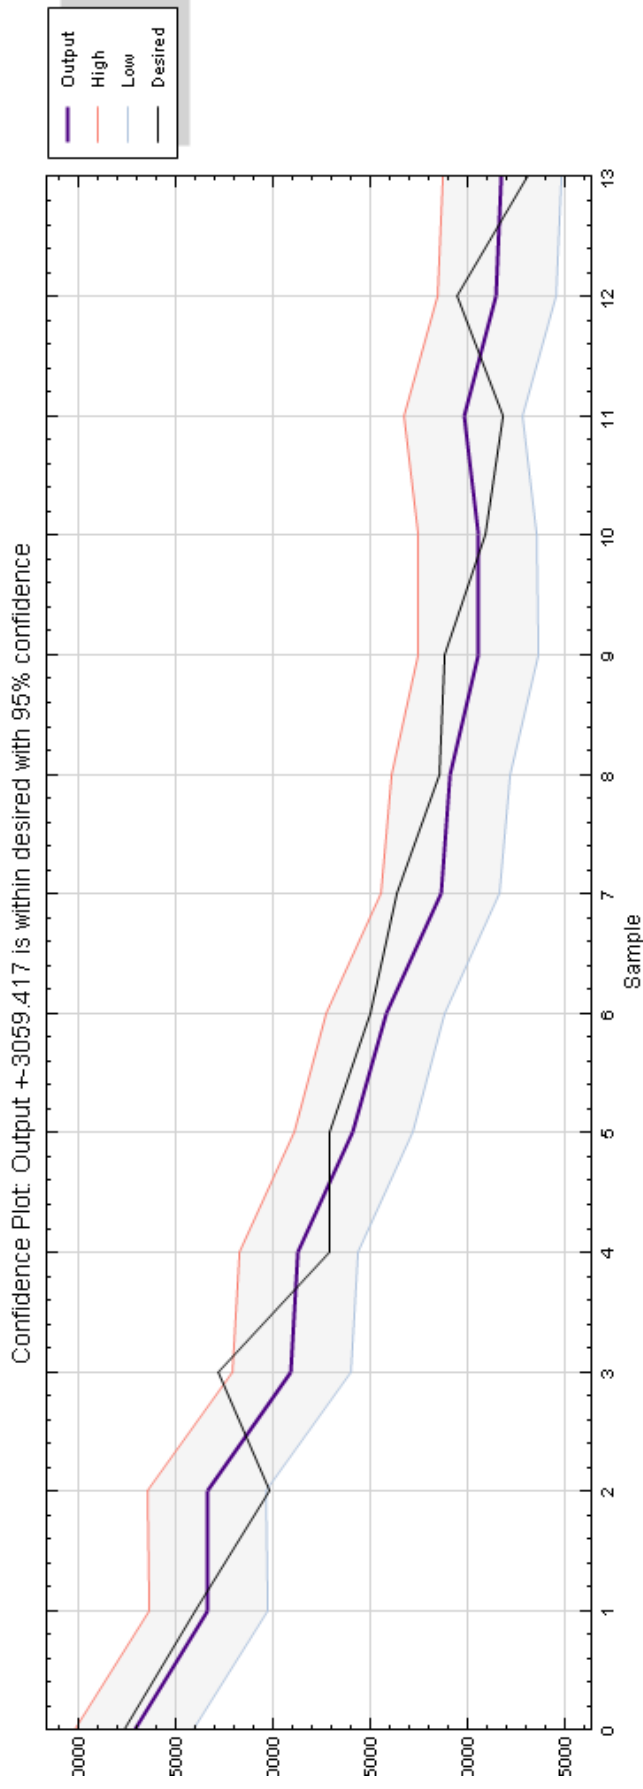
Grafik : 11

Gecikmesiz Model 1. Aşama Hesaplanan Tahmin Değerleri ve Gerçek Değerler Grafiği




Grafik : 12

Gecikmesiz Model 1. Aşama Tahmin Değerleri Hata Dağılımı Grafiği




Grafik : 13

Gecikmeli Model 1. Aşama Hesaplanan Tahmin Değerleri ve Gerçek Değerler Grafiği



Grafik : 14

Gecikmeli Model 1. Aşama Tahmin Değerleri Hata Dağılımı Grafiği




Grafik : 15

Gecikmeli ve Gecikmesiz Model 1. Aşama Tahmin Değerleri için Karşılaştırmalı Hata Grafiği


341. İkinci Aşamada Modellerin Endeks Kapanış Değerleri Tahmin Performanslarının Karşılaştırılması

İkinci aşama için modellerin tahmin ve hata dağılımı grafikleri yeniden oluşturulmuştur (Grafik 16, 17, 18, 19). Hata dağılım grafiklerine bakıldığında, her iki model için de – teorik olarak hata değerlerinin 0 (sıfır) etrafında dağılması beklentisine göre – hata dağılımının anlamsız olduğu söylenebilir. Bu sonuç, iki modelin tahminlerinin de 2. aşama için kötü tahminler olduğunu göstermektedir. Tahmin grafiklerine (Grafik 16 ve Grafik 18) göre gecikmeli model, gecikmesiz modele göre nispeten daha iyi tahminler yapmıştır. Karşılaştırmalı mutlak hata ve hata eğilimleri grafiği (Grafik 20) de durumu desteklemektedir. Ayrıca iki modelin tahmin değerleri mutlak hata ortalamaları arasındaki belirgin farklılık göze çarpmaktadır (Gecikmesiz Model Tahmin Değerleri Mutlak Hata Ortalaması: 22411,949307; Gecikmeli Model Tahmin Değerleri Mutlak Hata Ortalaması: 6984,533435). Hata eğilim çizgileri (Grafik 20) karşılaştırıldığında, gecikmeli model tahminlerinin, gecikmesiz model tahminlerine göre kesin üstünlüğü açıkça görülmektedir. Buna rağmen genel olarak gecikmeli model tahminlerinin de başarılı olduğu söylenemez.



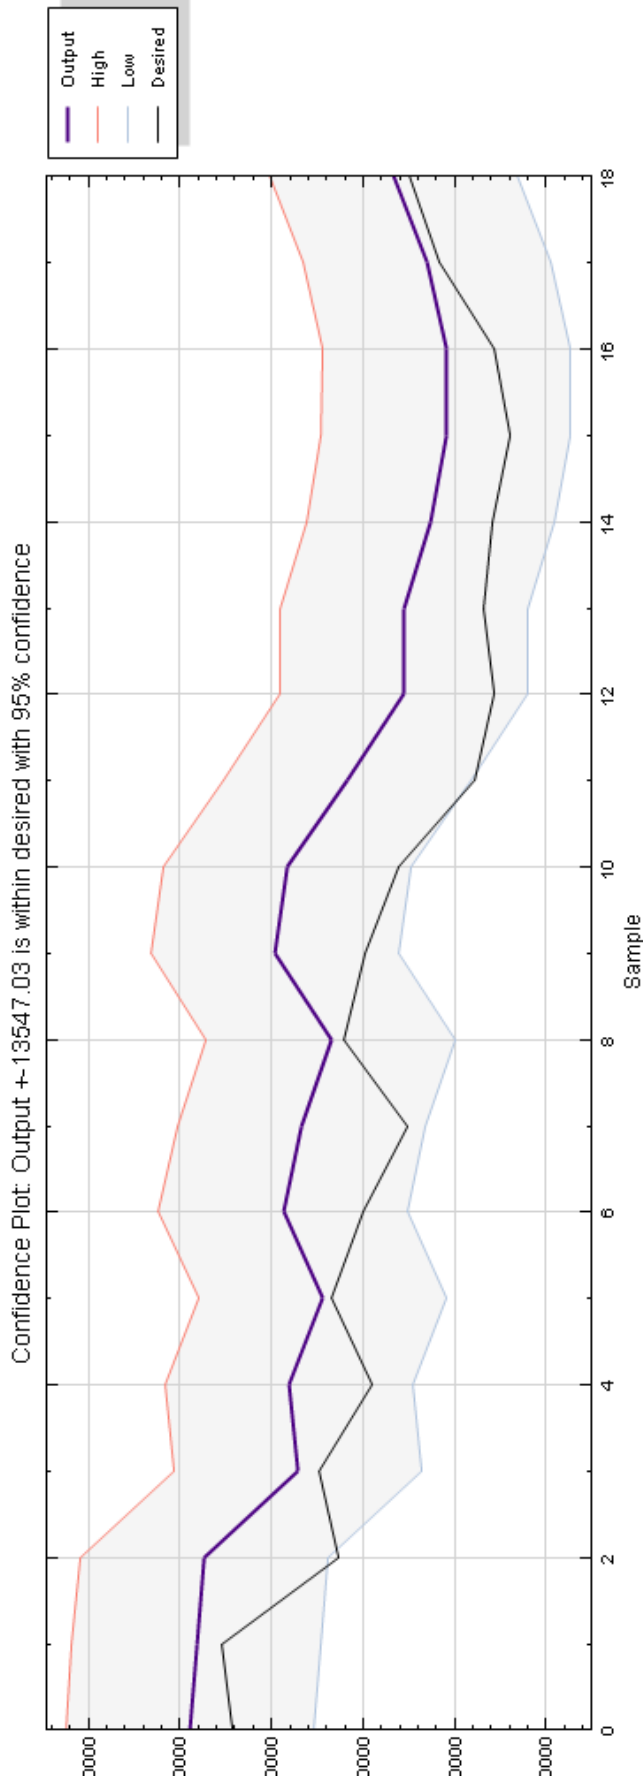
Grafik : 16

Gecikmesiz Model 2. Aşama Hesaplanan Tahmin Değerleri ve Gerçek Değerler Grafiği




Grafik : 17

Gecikmesiz Model 2. Aşama Tahmin Değerleri Hata Dağılımı Grafiği




Grafik : 18

Gecikmeli Model 2. Aşama Hesaplanan Tahmin Değerleri ve Gerçek Değerler Grafiği



Grafik : 19

Gecikmeli Model 2. Aşama Tahmin Değerleri Hata Dağılımı Grafiği




Grafik : 20

Geçikmeli ve Geçikmesiz Model, 2. Aşama Tahmin Değerleri için Karşılaştırmalı Hata Grafiği

342. Modellerin Endeks Hareket Yönü Tahmin Performanslarının Karşılaştırılması

Kriz döneminde gecikmeli modelin gecikmesiz modele göre nispeten daha başarılı kapanış değerleri üretmesine karşın endeks hareket yönü tahminindeki başarısızlığı Tablo 7 ve Tablo 9'da açıkça görülmektedir. Gecikmesiz model endeks yönünü %87,5 doğrulukla tahmin edebilmişken, gecikmeli modelde bu oran %56,25'de kalmıştır. Bu sonucun sebebini anlamak için gecikmeli modelin girdi değişkenlerine duyarlılığını gösteren grafiğe (Grafik 21) bakmak ve özellikle kriz döneminde endeksin volatilitésinin yüksek olmasını göz önünde bulundurmak yeterli olacaktır. Teorik beklentilere uygun olarak modelde çıktı değişkeninin en yüksek duyarlılığa sahip olduğu girdi değişkeni, endeks gecikmesidir (XU100G1). Buna bağlı olarak, incelenen dönemde endeks volatilitésinin yüksek olması yani endeksin tahmin edilen ay kapanış değeri ile bir önceki ay kapanış değeri arasındaki farkın büyük olması, tahmin değerinin de bir önceki aya göre büyük bir farklılık göstereceğine işaret eder. Gecikmeli modelin tahminlerini gösteren Grafik 18 incelendiğinde, modelin endeks de yaşanan yüksek kırılmaları, gecikme ile yakaladığı görülmektedir. Bu durum, modelin endeks yönü tahminini olumsuz etkilemektedir. Tahmin yapılan dönemin sonlarında ise endeksteki belirsizliğin azalması gecikmeli modelin endeks hareket yönündeki tahmin başarısını da artırmaktadır. Kriz döneminden önceki döneme bakıldığında her iki modelin de endeks hareket yönü tahmin başarısı kriz dönemine göre oldukça yüksektir. Gecikmesiz model endeks hareket yönü tahmini başarı oranı, kriz öncesi dönem ve kriz dönemi için sırasıyla %92,3 ve %84,2'dir. Gecikmeli model için ise aynı sırayla %61,5 ve %52,6'dır.

Gecikmesiz modelde elde edilen getiri, modelin endeks hareket yönü tahminindeki başarısına bağlı olarak gecikmeli modele göre oldukça yüksektir. Kriz dönemi göz ardı edilerek yapılan getiri hesaplamasında ise gecikmeli modelin getirisi bu dönemde de fazla olmasına rağmen iki model arasındaki farkın azalması, yukarıda bahsedilen durumu desteklemektedir.



Grafik : 21

Gecikmeli Model Çıktı Değişkeninin Girdi Değişkenlerine Duyarlılık Grafiği

4. SONUÇ ve ÖNERİLER

Bu çalışmada, çok katmanlı algılayıcılar ile oluşturulan yapay sinir ağı modellerinin finansal tahminlerdeki başarısının bir kez daha ortaya konulmasının yanı sıra; İMKB-100 endeksi için özellikle kriz dönemlerinde, bağımlı değişken gecikmelerinin, endeks kapanış değeri tahmini başarısına önemli katkıda bulunduğu söylenebilir. Karaatlı (2003)'nın aylık makroekonomik verileri kullanarak yaptığı çalışmada en iyi grup olarak adlandırdığı grupta bile ortalama yüzdesel mutlak hata %33 civarında iken bu çalışmada oluşturulan gecikmeli modelde %13,6 seviyesindedir. Benzer şekilde, Ulusoy (2001) da endeks gecikmelerini kullanmadan, hatalık verilerle yaptığı çalışmada endeks değerini çok yüksek hatalar ile tahmin edebilmiştir.

Bağımsız değişkenlerin bağımlı değişken üzerindeki etkilerinin, normal dönemler ve kriz dönemlerinde birbirlerinden önemli derecede farklılık göstermeleri olağandır. Örneğin, küresel finansal krizde, makro ekonomik değişkenler genel olarak çok fazla dalgalanmamasına rağmen, finans piyasalarındaki olumsuz beklentiler, dünya borsalarının hızlı bir düşüş eğilimine girmesine sebep olmuştur. Kriz, reel sektörde ancak 4-5 ay sonra hissedilmeye başlanmıştır. Buna bağlı olarak ekonomi çevrelerindeki genel kanı, kriz dönemlerinde, beklentilerin ekonomik göstergeler üzerinde etkisinin, normal dönemlere göre daha yüksek olduğu yönündedir. Bu durumda, söz konusu değişkenler kullanılarak yapılan tahminlerde, kriz dönemlerindeki sonuçların başarısız olmasının ana nedeninin bu değişkenlerin bağımlı değişken üzerinde etkisinin kriz dönemlerinde değişim göstermesi olduğu söylenebilir. Bu başarısızlık, tahmin için oluşturulan modellere, krizin bağımlı değişken üzerindeki etkisini açıklayabilecek bir bağımsız değişken eklenerek, kısmen ya da tamamen önlenebilir. Bunun için ilk akla gelecek yöntem, kriz dönemleri için kukla değişken kullanımınıdır. Ayrıca bu uygulamada kullanılan bağımlı değişken gecikmesinin de kriz dönemlerindeki başarıyı nispeten artırdığı görülmüştür. Kriz dönemlerinin tespiti ise ayrı bir problemdir. Bu sebeple, kriz dönemleri için bağımsız değişken kullanmak yerine verilerin dönem dönem sınıflandırılmasının ve her bir dönemde bağımlı değişken ile bağımsız değişkenler arasındaki ilişkilerin yeniden belirlenmesinin daha gerçekçi ve

çözümüne ulaşılmamasında daha verimli bir yaklaşım olacağı düşünülmektedir. Bu bağlamda, yapay sinir ağı modelleri ile yapılacak finansal tahminlerde, veriler, sınıflandırma modelleri ile sınıflandırıldıktan sonra, her bir sınıf için ayrı bir, çok katmanlı algılayıcı model oluşturularak kurulacak melez modelin, gerek kriz dönemlerinde ve gerekse normal dönemlerde daha başarılı tahminler yapabileceği düşünülmektedir. Bu, bir başka araştırma konusu olarak önerilebilir.

Modellerin endeks hareket yönündeki tahmin başarısı ile ilgili olarak ise bağımlı değişkenin bir gecikmesinin, özellikle volatilitenin yüksek olduğu dönemlerde yanıltıcı olduğu ve tahmin performansını olumsuz olarak etkilediği görülmüştür. Vural (2007), sadece bağımlı değişken gecikmelerini kullanarak günlük verilerle bazı endeks ve hisse senetleri değerlerini %1,4 ile %4,8 arasında değişen mutlak yüzdesel hatalar ile tahmin etmiştir. Ancak söz konusu çalışmadaki tahmin grafiklerine bakıldığında, tüm grafiklerde bağımlı değişken değişimlerinin bu çalışmada oluşturulan gecikmeli modelde olduğu gibi bir sonraki tahmine yansıdığı görülmektedir. Söz konusu çalışmanın günlük verilerle yapıldığı ve tahmini yapılan bağımlı değişkenlerin günlük değişimlerinin aylık döneme göre daha düşük olacağı göz önüne alındığında, bahsedilen çalışmadaki mutlak yüzdesel hatanın bu çalışmada oluşturulan modele göre küçük çıkmasının, kurulan modelin uygunluğu anlamına gelmeyeceği açık bir şekilde ortaya çıkmaktadır. Çünkü, bu çalışmada oluşturulan iki model sonuçlarına bağlı olarak, kriz dönemi dışındaki süreçlerde, gecikmenin, tahmin sonuçlarını belirgin bir şekilde etkilemediği görülmüştür. Ayrıca bağımlı değişkenin yalnızca bir gecikmesinin, endeks yönü tahmini üzerindeki olumsuz etkisi de düşünüldüğünde bu tür modellerin, finansal değerlerin tahmini için uygun olmayacağı söylenebilir. Özellikle günlük ve haftalık verilerin kullanıldığı modellerde, literatüre de uygun olarak bağımlı değişkenin yalnızca bir gecikmesi yerine bu değişkenin geçmiş değerleri üzerinden hesaplanan teknik gösterge değerlerini kullanmak tahmin performansını önemli ölçüde artıracaktır. Bu çalışmada endeksin hareket yönünden çok aylık kapanış değerinin tahmini ve özellikle makro ekonomik göstergelerin endeks üzerindeki etkisinin araştırılması amaçlandığı için modelde, kullanılan verilere göre istatistiksel olarak da anlamlı çıkan, bağımlı değişkenin bir gecikmesi kullanılmıştır. Bununla birlikte modellerin endeks hareket yönü tahmin performanslarının da değerlendirilmesi ile özellikle gecikmesiz modelin tahmin başarısına (%87,5) bağlı olarak bu tür tahminler için literatürde sıklıkla kullanılan teknik analiz göstergelerine alternatif

olarak makro ekonomik göstergelerin de kullanılabileceđi deneysel olarak ortaya konulmuştur. Ancak makro ekonomik deđişkenlerin genelde aylık veriler olması bu verilere bađlı tahminlerin de ancak aylık olarak yapılabilmesine imkân vermektedir. Örneđin bu çalışmada kullanılan bađımsız deđişkenlerden mevduat faiz oranı deđişkeni tüm banka mevduatlarına göre ađırlıklandırılmış 6 aylık faiz oranını göstermektedir ve bu veri merkez bankası tarafından aylık olarak yayınlanmaktadır.

YARARLANILAN KAYNAKLAR

a. Kitaplar

- ANDERSON, Dave
McNEILL, George : Artificial Neural Networks Technology, Data & Analysis
Center for Software, New York, 1992.
- ARBIB, Michael A. : The Handbook of Brain Theority and Neural Networks,
The MIT Press, Cambridge, 2002.
- DEMİR, Yusuf : İMKB’de Hisse Senedi Fiyatlarını Belirleyen Faktörler ve
Mali Sektör Üzerine Bir Uygulama, Yayınlanmamış
Doktora Tezi, Süleyman Demirel Üniversitesi, Sosyal
Bilimler Enstitüsü, Isparta, 2001.
- FOSBACK, Norman G. : Stock Market Logic, Dearborn Financial Publishing,
Florida, 1991.
- GÜMÜŞ, Firuze : Hisse Senedi Fiyatını Etkileyen Unsurlar: Türkiye Örneği,
Yayınlanmamış Yüksek Lisans Tezi, İstanbul Üniversitesi,
Sosyal Bilimler Enstitüsü, İstanbul, 1994.
- KARAATLI Meltem A. : Yapay Sinir Ağları Yöntemi ile Tahmin. İMKB’de Bir
Uygulama, Yayınlanmamış Yüksek Lisans Tezi,
Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü,
Isparta, 2003.

- ÖZÇAM, Mustafa : Hisse Senetlerinin Fiyatlarını Belirleyen Unsurlar ve Türkiye, Sermaye Piyasası Kurulu Yeterlilik Araştırması, Ankara,1990.
- ÖZTEMEL, Ercan : Yapay Sinir Ağları, Papatya Yayınları, 1. Basım, İstanbul, 2003.
- ULUSOY, Tolga : Yapay Sinir Ağları Kullanılarak İstanbul Menkul Kıymetler Borsası Index Öngörüsü, Yayınlanmamış Yüksek Lisans Tezi, Başkent Üniversitesi, Sosyal Bilimler Enstitüsü, Ankara, 2001.
- VURAL, Barış Bilen : Yapay Sinir Ağları ile Finansal Tahmin, Yayınlanmamış Yüksek Lisans Tezi, Ankara Üniversitesi, Sosyal Bilimler Enstitüsü, Ankara, 2007.
- YURTOĞLU, Hasan : Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği, DPT Uzmanlık Tezleri, Ankara, 2005.

b. Makale ve Bildiriler

- ABDELMOUEZ, Ghada ve diğerleri : “Neural Network vs. Linear Models for Stock Market Sectors Forecasting”, **Proceedings of International Joint Conference on Neural Networks**, August 2007, pp. 1-5.
- ABDULLAH, Dewan. A.
HAYWORTH, Steven C. : “Macroeconomics of Stock Price Fluctuations”, **Quarterly Journal of Business And Economics**, Vol. 32, No. 1 (1993) , pp. 50-67.

ADJASI, Charles

HARVEY, Simon K

AGYAPONG, Daniel : “Effect of Exchange Rate Volatility on the Ghana Stock Exchange”, **African Journal of Accounting, Economics, Finance and Banking Research**, Vol. 3, No. 3 (2008), pp. 28-47.

ADRANGI, Bahram

CHATRATH, Arjun

: “Inflation, Output, And Stock Prices: Evidence from Brazil”, **The Journal of Applied Business Research**, Vol. 18, No. 1 (2002), pp. 61-77.

AKKUM, Tülin

VURAN, Bengü

: “Türk Sermaye Piyasasındaki Hisse Senedi Getirilerini Etkileyen Makroekonomik Faktörlerin Arbitraj Fiyatlama Modeli İle Analizi”, **İktisat İşletme ve Finans**, Sayı: 20 (2005), ss. 28-45.

ALBENİ, Mesut

DEMİR, Yusuf

: “Makro Ekonomik Göstergelerin Mali Sektor Hisse Senedi Fiyatlarına Etkisi (İMKB Uygulamalı)”, **Muğla Üniversitesi SBE Dergisi**, Sayı: 14 (2005) http://www.mu.edu.tr/sbe/sbedergi/dosya/14_1.pdf.

ALEXAKIS, Panayotis

APERGIS, Nicholas

XANTHAKIS, Emmanuel : “Inflation Volatility and Stock Prices: Evidence from ARCH Effects”, **International Advances in Economic Research**, Vol. 2, No. 2 (May 1996), pp.101-111.

AKPINAR, Haldun

: “Yapay Sinir Ağları Gelişim ve Yapılarının İncelenmesi”, **İstanbul Üniversitesi İşletme Fakültesi Dergisi**, Sayı: 23 (Nisan 1994), ss.41-77.

AKMUT, Özdemir

YÜKSEL, Aslı

YÜKSEL, Aldın : “Avrupa Birliği Kararlarının İMKB'deki Hisse Senetlerinin Getiri Oranları Üzerine Etkileri”, **Ankara Üniversitesi Siyasal Bilgiler Fakültesi Dergisi**, Cilt: 61, Sayı: 2 (2006), ss. 1-16.

ATAN, Murat ve diğerleri : “Dünya Borsalarının Finansal Göstergelere Göre Dönemlerarası Karşılaştırılmalı Analizi”, **Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi**, Cilt 6, Sayı 2 (2004), ss.1-25.

ATIYA, Amir

TALAAT, Noha

SHAHEEN, Samir : “An Efficient Stock Market Forecasting Model Using Neural Networks”, **International Conference on Neural Networks**, Vol.4 (June 1997), pp. 2112-2115.

ARIS, Zakariah

MOHAMAD, Dzul kifli : “Application of Artificial Neural Networks Using Hijri Lunar Transaction as Extracted Variables to Predict Stock Trend Direction”, **Labuan e-Journal of Muamalat and Society**, Vol. 2 (2008), pp. 9-16.

AVCI, Emin

: “Forecasting Daily and Sessional Returns of the ISE-100 Index with Neural Network Models”, **Doğuş Üniversitesi Dergisi**, Sayı: 8 (2007), ss. 128-142.

BADARUDDIN, Zatul E.

ARIEFF, Mohamed : “Bank Stock Returns And Endogenous Money Supply in the Wake of Financial Deregulation and Crisis: Evidence from United States”, **Financial Management Association International Annual Meeting**, 2007, http://www.fma.org/Orlando/Papers/Bank_stock_returns_and_endogenous_money_supply_in_the_wake_of_financial_deregulation_and_crisis_Evidence_from_United_States.pdf.

BENGOECHEA, A. Glaria

ve diğerleri : “Stock Market Indices in Santiago De Chile: Forecasting Using Neural Networks”, **IEEE International Conference on Neural Networks**, Vol. 4 (June 1996), pp. 2172-2175.

BORDO, Michael D.

DUEKER, Michael J.

WHEELOCK, David C. : “Inflation, Monetary Policy and Stock Market Conditions: Quantitative Evidence from a Hybrid Latent-Variable VAR”, **Federal Reserve Bank of St. Louis Working Paper Series**, Working Paper 2008-012B (May 2008), <http://research.stlouisfed.org/wp/2008/2008-012.pdf>.

BULIALI, Joko Lianto

FATICHAH, Chastine

SUSANTO, Mudji : “Hybrid Neural Network-Monte Carlo Simulation for Stock Price Index Prediction”, **Asian Journal of Information Technology**, Vol. 8 (2009), pp. 1 -7.

BURRASCANO, P.

LUCC, P. : “Smoothing Backpropagation Cost Function By Delta Constraining”, **1990 IJCNN International Joint Conference on Neural Networks**, Vol.3 (June 1990), pp. 75-80.

CANBAŞ, Serpil

KANDIR, Serkan Y. : “Yatırımcı Duyarlılığının İMKB Sektör Getirileri Üzerindeki Etkisi”, **Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi**, Cilt: 22, Sayı: 2 (2007), ss. 219-248.

CHAN, Man-Chung

WONG, Chi-Cheong

LAM, Chi-Chung

: “Financial Time Series Forecasting by Neural Network Using Conjugate Gradient Learning Algorithm and Multiple Linear Regression Weight Initialization”, **Society for Computational Economics, Computing in Economics and Finance**, 2000, <http://fmwww.bc.edu/cef00/papers/paper61.pdf>

CHI, Jing

TRIPE, David

YOUNG, Martin

: “Do Exchange Rates Affect the Stock Performance of Australian Banks?”, **12th Finsia-Melbourne Centre for Financial Studies Banking and Finance Conference, Melbourne**, September 2007, [http://www.melbournecentre.com.au / Finsia_ MCFS / 2007 / JingChi_ DavidTripe.pdf](http://www.melbournecentre.com.au/Finsia_MCFS/2007/JingChi_DavidTripe.pdf).

- ÇITAK, Levent : “Para ve Maliye Politikalarının İMKB Endeksi Üzerindeki Etkilerinin İncelenmesi: İMKB, Makroekonomik Politikalar Açısından Bilgi Etkin midir?” **Dumlupınar Üniversitesi Sosyal Bilimler Dergisi**, Sayı 9 (Aralık 2003), ss. 129-142
- DAVIDSON, Lawrence S.
- FROYEN, Richard T. : “Monetary Policy and Stock Returns: Are Stock Markets Efficient?”, **The Federal Reserve Bank of St. Louis Reviews**, March 1982, pp. 3-12.
- DRAKOS, Konstantinos : “Interest Rate Risk and Bank Common Stock Returns: Evidence from the Greek Banking Sector”, **London Guildhall University Working Paper**, March 2001, pp 1-27.
- DURUKAN, M. Banu : “İstanbul Menkul Kıymetler Borsasında Makroekonomik Değişkenlerin Hisse Senedi Fiyatlarına Etkisi”, **İMKB Dergisi**, Sayı: 11 (Temmuz-Ağustos-Eylül 1999), ss.19-47.
- FAMA, Eugene F. : “Stock Returns, Real Activity, Inflation, and Money”, **The American Economic Review**, Vol. 71, No. 4 (September 1981), pp. 545-565.
- FAMA, Eugene F.
- SCHWERT, G. William : “Asset Returns and Inflation”, **Journal of Financial Economics**, Vol. 5, Issues. 2 (November 1977), pp. 115-146.
- FITZPATRICK, Brian. D. : “Stock Prices and Macroeconomic Data”, **Journal of Applied Business Research**, Vol. 10, Issues 4 (1994), pp. 69-76.

- FU-YUAN, Huang : “Forecasting Stock Price Using a Genetic Fuzzy Neural Network”, **International Conference on Computer Science and Information Technology**, 2008, pp. 549-552.
- JUNYOU, Boo : “Stock Price Forecasting Using PSO-Trained Neural Networks”, **Evolutionary Computation**, 2007, pp. 2879-2885.
- KARAMUSTAFA, Osman
KARAKAYA, Aykut : “Enflasyonun Borsa Performansı Üzerindeki Etkisi”, **Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi**, Sayı: 7 (2004 / 1), ss.23-35.
- KIM, Kyoung-jae
OH, Kyong Joo
HAN, Ingoo : “Neural Network Forecasting of Stock Price Index to Integrate Change-Point Detection with Genetic Algorithms”, **International Conference of Knowledge Management and Information Sharing**, 2000, pp. 141-150.
- KOOL, Clemens J. M.
HAFER, Rik. W. : “Stock Prices, Inflation and Real Activity: A Test of the Fama Hypothesis, 1920-84”, **The Federal Reserve Bank of St. Louis Working Paper Series**, Working Paper 1986-001B, <http://research.stlouisfed.org/wp/1986/1986-001.pdf>.

KUO, R. J.

LEE, L. C.

LEE, C. F. : “Integration of Artificial Neural Networks and Fuzzy Delphi for Stock Market Forecasting”, **IEEE International Conference on Systems, Man, and Cybernetics**, Vol. 2 (1996), pp. 1073-1078.

LEE, Kyungjoo

YOO, Sehwan

JIN, John Jongdae : “Neural Network Model vs. SARIMA Model In Forecasting Korean Stock Price Index (KOSPI)”, **Issues in Information Systems**, Vol. VIII, No. 2 (2007), pp. 372-378.

LÉON, N’dri Konan

: “The Effects of Interest Rates Volatility on Stock Returns and Volatility: Evidence from Korea”, **International Research Journal of Finance and Economics**, Issues 14 (2008), pp. 287-290.

LI, Ming-Way

WU, Pi-Chu

: “The Relationship between Money Supply and Stock Prices”, **Innovative Computing Information and Control**, June 2008, pp. 598-598.

LI, Rong-Jun

XIONG, Zhi-Bin

: “Forecasting Stock Market with Fuzzy Neural Networks”, **Proceedings of the Fourth International Conference on Machine Learning and Cybernetics**, August 2005, pp. 3475-3479.

- LI, Yaqiong
 HUANG, Lihong : “On the Relationship Between Stock Return and Exchange Rate: Evidence on China”, **The Chinese Economic Association (Europe/UK) 2008: China's Three Decades of Economic Reform (1978-2008)**, <http://www.ceauk.org.uk/2008-conference-apers/Yaqiong-Li.pdf>.
- LIU, Qiong ve diğerleri : “Automatic Estimation of Stock Market Forecasting and Generating the Corresponding Natural Language Expression”, **International Conference on Information Technology: Coding and Computing (ITCC'04)**, Vol. 1 (2004), pp.241-246.
- LIU, Yong
 YAO, Xin : “Evolving Neural Networks for Hang Seng Stock Index Forecast”, **Evolutionary Computation**, Vol. 1 (2001), pp. 256-260.
- MASKAY, Biniv : “Analyzing the Effect of Change in Money Supply on Stock Prices”, **The Park Place Economist**, Vol. 15 (2007), pp.72-79.
- McCARTHY, Jhonn : “What Is Artificial Intelligence?”, <http://www-formal.stanford.edu/jmc/whatisai/>, Kasım 2007.
- MOHAN, Neeraj ve diğ. : “Artificial Neural Network Models for Forecasting Stock Price Index in Bombay Stock Exchange”, **Journal of Emerging Market Finance**, Vol. 5, No. 3 (2006), pp. 283-295.

PHUA Paul Kang Hoh

ZHU, Xiaotian

KOH, Chung Haur : “Forecasting Stock Index Increments Using Neural Networks with Trust Region Methods”, **Proceedings of the International Joint Conference on Neural Networks**, Vol. 1 (July 2003), pp. 260- 265.

RAHMAN, Lutfur

UDDIN, Jashim : “Dynamic Relationship between Stock Prices and Exchange Rates: Evidence from Three South Asian Countries”, **International Business Research**, Vol. 2, No. 2 (April 2009), pp. 167-174.

RAST, Martin

: “Forecasting with Fuzzy Neural Networks: A Case Study in Stockmarket Crash Situations”, **Fuzzy Information Processing Society**, Vol. 1 (July 1999), pp. 418-420.

SAĞIROĞLU, Şeref

: “Yapay Sinir Ağları ve Mühendislik Uygulamaları”, **Yapay Sinir Ağları Sempozyumu**, 20-23 Şubat 2001, Kayseri.

SCHIERHOLT, Karsten

DAĞLI, Cihan H.

: “Stock Market Prediction Using Different Neural Network Classification Architectures”, **Computational Intelligence for Financial Engineering**, 1996, pp. 72-78.

SEVÜKTEKİN, Mustafa

NARGELEÇEKENLER, M.: “Türkiye’de İMKB ve Döviz Kuru Arasındaki Dinamik İlişkinin Belirlenmesi”, **8. Ulusal Ekonometri ve İstatistik Sempozyumu**, İnönü Üniversitesi, Mayıs 2007, Malatya, [http : // eisemp8. inonu. edu. tr / bildiri – pdf / sevutekinnargelecekenler. pdf](http://eisemp8.inonu.edu.tr/bildiri-pdf/sevutekinnargelecekenler.pdf).

SHANMUGAM, K R

MISRA, Biswa Swarup : “Stock Returns-Inflation Relation in India”, **Applied Econometrics and International Development**, Vol. 9, Issues 1 (2008), http://www.eaber.org/intranet/documents/112/1602/MSE_Shanmugam_2008.pdf.

SONGUR, Hilmi : “Küresel Krizin İstanbul Borsası Üzerindeki Etkisi, *Maliye Finans Yazıları*, Sayı: 82 (Ocak 2009) http://www.finanskulup.org.tr/Assets/maliyefinans/82/Hilmi_Songur_Kuresel_Krizin_Istanbul_Borsasi_Uzerindeki_Etkisi.pdf.

YÜCEL, Tülay

KURT, Gülüzar : “Foreign Exchange Rate Sensitivity and Stock Price : Estimating Economic Exposure of Turkish Companies”, **European Trade Study Group ETSG2003**, September 2003, <http://www.etsg.org/ETSG2003/papers/yucel.pdf>.

ZAFAR, Nousheen

UROOJ, Syeda Faiza

DURRANI, Tahir Khan : “Interest Rate Volatility and Stock Return and Volatility”, **European Journal of Economics, Finance and Administrative Sciences**, Issues 14 (2008), pp. 135-140.

ZORIN, Alexey

BORISOV, Arkady : “Modelling Riga Stock Exchange Index Using Neural Networks”, **Proceedings of the international conference "Traditional and Innovations in Sustainable Development of Society"**, 2002, pp.312-320.

ZÜGÜL, Muhittin

ŞAHİN, Cumhur

: “İMKB 100 Endeksi İle Bazı Makroekonomik Değişkenler Arasındaki İlişkiyi İncelemeye Yönelik Bir Uygulama”, **Akademik Bakış**, Sayı: 16 (Nisan 2009), ss. 144-159.

ÇALIŞMADA KULLANILAN VERİLER

Tarih	Külçe Altın (gr.)	USD	6AY Vadeli MFO	M1	XU100G1	XU100
Şub.91	0,03910	0,0033	0,045633333	31186,6	42,13	51,03
Mar.91	0,04230	0,0037	0,04935	30899,0476	51,03	45,2
Nis.91	0,04443	0,004	0,050383333	32158,2727	45,2	35,54
May.91	0,04710	0,0041	0,0513	31779,4348	35,54	36,26
Haz.91	0,04644	0,0043	0,050283333	34936,5	36,26	35,87
Tem.91	0,05313	0,0044	0,050491667	35661,3478	35,87	30,41
Ağu.91	0,05267	0,0046	0,050858333	38249,5	30,41	33,01
Eyl.91	0,05297	0,0047	0,0534	39996,5714	33,01	29,38
Eki.91	0,05675	0,0049	0,053991667	42782,6522	29,38	27,47
Kas.91	0,05843	0,005	0,054033333	42303,4762	27,47	40,58
Ara.91	0,05933	0,0051	0,054016667	43749,5	40,58	43,69
Oca.92	0,06198	0,0055	0,058041667	43931,3478	43,69	49,26
Şub.92	0,06605	0,0059	0,057541667	45382,75	49,26	36,64
Mar.92	0,06875	0,0062	0,057491667	47918,0909	36,64	40,77
Nis.92	0,07088	0,0066	0,058158333	49214,9546	40,77	36,86
May.92	0,07440	0,0069	0,058033333	50028,9524	36,86	32,97
Haz.92	0,07690	0,0069	0,058066667	55802,6364	32,97	44,07
Tem.92	0,08000	0,0071	0,057808333	52832,913	44,07	42,64
Ağu.92	0,07867	0,0071	0,057058333	57451,7143	42,64	41,58
Eyl.92	0,08343	0,0073	0,056883333	59543,8182	41,58	39,76
Eki.92	0,08503	0,0078	0,057383333	63182,9546	39,76	36,43
Kas.92	0,08925	0,0083	0,057875	64794,1429	36,43	37,86
Ara.92	0,09182	0,0086	0,057908333	70149	37,86	40,04
Oca.93	0,09428	0,0087	0,057766667	71399,2381	40,04	43,83
Şub.93	0,09825	0,0091	0,057833333	71848,75	43,83	59,24
Mar.93	0,10113	0,0095	0,057741667	79562,9565	59,24	58,64
Nis.93	0,10595	0,0097	0,057816667	79320,0909	58,64	78,08
May.93	0,11978	0,0101	0,057975	85497,8571	78,08	83,76
Haz.93	0,12820	0,0109	0,057975	91257,8636	83,76	107,79
Tem.93	0,14273	0,0115	0,05795	93911	107,79	100,78
Ağu.93	0,14150	0,0118	0,057875	100141,973	100,78	123,57
Eyl.93	0,13925	0,0121	0,057683333	103856,255	123,57	150,8
Eki.93	0,15026	0,013	0,057716667	109342,857	150,8	145,01
Kas.93	0,16403	0,0137	0,057641667	109374,591	145,01	189,77
Ara.93	0,17638	0,0145	0,057541667	116817,783	189,77	206,83
Oca.94	0,20163	0,0172	0,060525	111000,381	206,83	201,05

Şub.94	0,22775	0,0183	0,072125	109214,9	201,05	150,04
Mar.94	0,28575	0,0221	0,073041667	116625,565	150,04	140,87
Nis.94	0,36740	0,0334	0,0887	122572,19	140,87	150,97
May.94	0,37700	0,0317	0,092366667	138944,909	150,97	147,49
Haz.94	0,38125	0,0312	0,095691667	149333,545	147,49	197,66
Tem.94	0,38180	0,031	0,083416667	171454,238	197,66	217,52
Ağu.94	0,39025	0,033	0,062475	191113,609	217,52	252,82
Eyl.94	0,42880	0,034	0,061016667	206523,955	252,82	268,26
Eki.94	0,44300	0,0358	0,055391667	209563,762	268,26	248,9
Kas.94	0,45175	0,0363	0,064866667	205848,591	248,9	281,81
Ara.94	0,45930	0,0384	0,067575	215428,045	281,81	272,57
Oca.95	0,49000	0,0404	0,075408333	206422	272,57	252,29
Şub.95	0,50013	0,0412	0,075683333	229794,75	252,29	291,23
Mar.95	0,51610	0,0419	0,072666667	240620,043	291,23	398,37
Nis.95	0,53613	0,0424	0,065508333	259272	398,37	466,15
May.95	0,53925	0,0425	0,065175	304961,87	466,15	473,71
Haz.95	0,54180	0,0439	0,065275	304823,727	473,71	482,33
Tem.95	0,55775	0,0449	0,061525	326021,476	482,33	519,44
Ağu.95	0,58388	0,0478	0,061316667	349535,87	519,44	451,4
Eyl.95	0,59500	0,0487	0,061558333	364776,143	451,4	417,08
Eki.95	0,62225	0,0508	0,0615	370606,364	417,08	463,25
Kas.95	0,65125	0,0543	0,069241667	371635,045	463,25	391,14
Ara.95	0,71860	0,0611	0,070308333	376147,81	391,14	400,25
Oca.96	0,77775	0,0624	0,0706	355539,087	400,25	494,9
Şub.96	0,84325	0,0655	0,07055	427636,381	494,9	605,47
Mar.96	0,87640	0,0705	0,070258333	418442,952	605,47	670,45
Nis.96	0,92825	0,0742	0,070175	454095	670,45	647,23
May.96	0,97320	0,0778	0,069883333	464071,522	647,23	611,5
Haz.96	0,99575	0,0812	0,070166667	484084,5	611,5	704,89
Tem.96	1,02775	0,083	0,07045	523290,217	704,89	633,66
Ağu.96	1,06880	0,0858	0,070475	588297,727	633,66	645,33
Eyl.96	1,10825	0,0909	0,070533333	606859,81	645,33	724,53
Eki.96	1,15750	0,0953	0,07035	622664,87	724,53	820,06
Kas.96	1,20520	0,1014	0,0706	722675,81	820,06	917,59
Ara.96	1,25100	0,1075	0,070516667	774384,045	917,59	975,89
Oca.97	1,28520	0,1153	0,069316667	824428,304	975,89	1605
Şub.97	1,36000	0,1215	0,068966667	931261	1605	1612
Mar.97	1,42500	0,1263	0,068816667	983003,952	1612	1613
Nis.97	1,46850	0,1346	0,068791667	1081807,82	1613	1427
May.97	1,53140	0,1396	0,068816667	1046825	1427	1595
Haz.97	1,59850	0,1467	0,069066667	1067486,86	1595	1857
Tem.97	1,60675	0,1588	0,068925	1139918,48	1857	1953
Ağu.97	1,71400	0,1657	0,075166667	1119917,48	1953	1980
Eyl.97	1,78450	0,1728	0,075225	1138324,32	1980	2593

Eki.97	1,87560	0,1802	0,075583333	1206220,22	2593	2846
Kas.97	1,86125	0,1935	0,075975	1196857,5	2846	2879
Ara.97	1,86000	0,2048	0,076275	1284919,3	2879	3451
Oca.98	1,97900	0,2142	0,076058333	1470601,18	3451	3547,18
Şub.98	2,16625	0,2285	0,076116667	1489283,25	3547,18	3272,21
Mar.98	2,25500	0,2407	0,076008333	1478110,41	3272,21	3259,06
Nis.98	2,44500	0,2484	0,075075	1667914,68	3259,06	4194,5
May.98	2,46300	0,2558	0,075091667	1647771,33	4194,5	3727,75
Haz.98	2,47875	0,2651	0,072225	1750411,14	3727,75	4100
Tem.98	2,55100	0,2683	0,065416667	1981715	4100	4322,32
Ağu.98	2,52000	0,2766	0,062675	2125420,33	4322,32	2635,14
Eyl.98	2,59375	0,2759	0,070458333	2217909,82	2635,14	2265,94
Eki.98	2,69000	0,2845	0,071191667	2278333,73	2265,94	2196,38
Kas.98	2,83375	0,3012	0,071966667	2226157,67	2196,38	2577,54
Ara.98	2,86875	0,3127	0,071608333	2302041,83	2577,54	2597,91
Oca.99	2,98125	0,3299	0,0707	2575519,86	2597,91	2568,16
Şub.99	3,19750	0,35	0,070625	2510112	2568,16	3890,83
Mar.99	3,36000	0,3656	0,070141667	2678497,3	3890,83	4554,07
Nis.99	3,48700	0,3878	0,070125	2919371,23	4554,07	5354,03
May.99	3,55375	0,4026	0,069591667	2916369,14	5354,03	5069,22
Haz.99	3,48625	0,4182	0,069441667	2941338	5069,22	4950,21
Tem.99	3,54600	0,4259	0,068566667	3198288,95	4950,21	5805,45
Ağu.99	3,64000	0,4432	0,06865	3433613,55	5805,45	5018,28
Eyl.99	3,79250	0,4598	0,064708333	3554786,73	5018,28	6071,12
Eki.99	4,72000	0,4773	0,063075	3747705,19	6071,12	6509,92
Kas.99	4,75750	0,5127	0,0575	3684858,73	6509,92	8459,48
Ara.99	4,82600	0,5401	0,040208333	4135792,52	8459,48	15208,8
Oca.00	5,04125	0,5558	0,030025	4581701,76	15208,78	16715
Şub.00	5,59250	0,573	0,030933333	4784440,24	16715	15946
Mar.00	5,43500	0,5883	0,031558333	5163149,48	15946	15920
Nis.00	5,42125	0,6063	0,034533333	5372933	15920	19206
May.00	5,54125	0,6137	0,032608333	5480860,7	19206	16206
Haz.00	5,67500	0,619	0,03375	5720597,23	16206	14466
Tem.00	5,73000	0,6342	0,030841667	6009422,24	14466	13870
Ağu.00	5,73625	0,6513	0,029225	6152958,22	13870	13132,1
Eyl.00	5,88600	0,6634	0,043516667	6358028,52	13132,06	11350,3
Eki.00	5,91750	0,6821	0,040441667	6248560,64	11350,3	13538,4
Kas.00	5,87125	0,6829	0,042183333	6560957,23	13538,44	8747,68
Ara.00	5,85250	0,6718	0,0577	7565741,05	8747,68	9437,21
Oca.01	5,88250	0,6792	0,046308333	7086030,43	9437,21	10685,1
Şub.01	5,93500	0,9062	0,056116667	7257465,95	10685,07	8791,6
Mar.01	8,00000	1,0565	0,086875	8259000,95	8791,6	8022,72
Nis.01	9,80625	1,1606	0,074525	8441957,19	8022,72	12367,4
May.01	9,83750	1,1565	0,056758333	8620423,22	12367,36	10879,8

Haz.01	10,52000	1,2674	0,055275	9452627,86	10879,83	11204,2
Tem.01	11,46250	1,3199	0,055283333	10014506,1	11204,24	9914,61
Ağu.01	12,51000	1,3686	0,055416667	10501188,7	9914,61	9878,88
Eyl.01	13,81250	1,533	0,055558333	10408858,3	9878,88	7625,87
Eki.01	14,90000	1,5897	0,054033333	9960014,26	7625,87	9848,76
Kas.01	13,58500	1,4846	0,051766667	10028754,6	9848,76	11633,9
Ara.01	12,93750	1,4396	0,051541667	10837016	11633,93	13782,8
Oca.02	12,53750	1,3208	0,049983333	10220412	13782,76	13252,3
Şub.02	12,83333	1,3993	0,049358333	11246411,1	13252,32	11055,7
Mar.02	12,93500	1,3325	0,046391667	10919971,1	11055,67	11679,4
Nis.02	12,95000	1,3315	0,041808333	10836723	11679,43	11441,5
May.02	14,30000	1,4129	0,039933333	11397555,3	11441,5	10413,7
Haz.02	15,82250	1,6027	0,0415	11975127,8	10413,7	9379,92
Tem.02	16,83750	1,6819	0,042141667	12427368,1	9379,92	10236,5
Ağu.02	16,45000	1,6258	0,042008333	12892540	10236,46	9547,3
Eyl.02	16,96250	1,6487	0,042391667	13550991,2	9547,3	8842,24
Eki.02	16,52250	1,6702	0,042183333	13835666,2	8842,24	10251,9
Kas.02	17,03200	1,5435	0,0393	14626663,1	10251,92	13300,4
Ara.02	18,01667	1,6345	0,039116667	15079436,4	13300,4	10369,9
Oca.03	19,95000	1,6422	0,039516667	14667065,6	10369,92	11032
Şub.03	18,80000	1,6028	0,039491667	16276508,3	11032,03	11574,4
Mar.03	18,36250	1,7082	0,040066667	14809439,4	11574,44	9475,09
Nis.03	17,31250	1,5824	0,039125	14854460,1	9475,09	11510
May.03	16,74000	1,4347	0,0361	15793621,8	11509,95	11381,4
Haz.03	15,66250	1,4217	0,033925	16248769,8	11381,41	10884,4
Tem.03	15,36250	1,4218	0,032066667	17711121,2	10884,43	10572
Ağu.03	16,44000	1,401	0,030425	18293068,9	10572,04	11611,8
Eyl.03	16,87500	1,3767	0,027425	18895407,9	11611,84	13055,9
Eki.03	17,66000	1,4914	0,023558333	20573619,4	13055,9	15754,3
Kas.03	18,72500	1,4648	0,02375	21359241,5	15754,34	14617,5
Ara.03	18,93750	1,3958	0,023483333	20917010,1	14617,53	18625
Oca.04	18,36000	1,3332	0,0214	22690186,2	18625,02	17259,3
Şub.04	17,40000	1,3239	0,020475	22071201,3	17259,25	18889,2
Mar.04	17,37500	1,3113	0,019016667	22420272,9	18889,2	20190,8
Nis.04	17,88000	1,4401	0,018991667	23757865,4	20190,83	18022,7
May.04	18,87500	1,4853	0,019508333	24513814,8	18022,69	17081,1
Haz.04	18,98750	1,4859	0,019758333	25305566,5	17081,08	17967,6
Tem.04	18,77000	1,4683	0,020216667	26133266	17967,6	19380,9
Ağu.04	19,31250	1,4972	0,020425	26515956,6	19380,86	20218,4
Eyl.04	19,73750	1,4977	0,019558333	28153397,7	20218,37	21953,5
Eki.04	20,30000	1,4702	0,019341667	27766117,1	21953,52	22889,9
Kas.04	20,60000	1,4194	0,019183333	28100674	22889,89	22486,2
Ara.04	20,00000	1,3421	0,018375	27842194,7	22486,2	24971,7
Oca.05	18,62000	1,3287	0,017541667	28608113	24971,68	27330,4

Şub.05	18,00000	1,2885	0,016633333	27716617,5	27330,35	28396,2
Mar.05	18,28000	1,3706	0,016166667	29626435,3	28396,17	25557,8
Nis.05	19,06000	1,373	0,015825	31437739,2	25557,76	23591,6
May.05	18,73000	1,3656	0,015658333	31120861,5	23591,64	25236,5
Haz.05	18,95000	1,3413	0,016891667	32651927,2	25236,48	26957,3
Tem.05	18,47000	1,3307	0,017183333	34311539,2	26957,32	29615,3
Ağu.05	19,24000	1,3508	0,017158333	35090110,6	29615,29	30908
Eyl.05	19,83000	1,3406	0,01705	37317372,4	30908,02	33333,2
Eki.05	20,48000	1,3473	0,017141667	37636803	33333,23	31964
Kas.05	21,28000	1,3497	0,017208333	37515906,3	31963,99	38088,7
Ara.05	22,17000	1,343	0,017208333	39050786,8	38088,65	39777,7
Oca.06	23,58000	1,3219	0,016433333	41039075	39777,7	44590,2
Şub.06	23,76000	1,3113	0,016333333	37789187,5	44590,22	47015,9
Mar.06	24,19000	1,3427	0,016275	38898042,6	47015,88	42911,3
Nis.06	26,45000	1,3195	0,014725	40698369	42911,32	43880,4
May.06	31,65000	1,5368	0,014691667	43300273,8	43880,43	38132,2
Haz.06	30,66000	1,6029	0,018016667	45524188,3	38132,21	35453,3
Tem.06	31,86000	1,4954	0,019725	44036419,8	35453,31	36037,9
Ağu.06	30,16000	1,4682	0,019825	43884265,8	36037,92	37285,9
Eyl.06	28,95000	1,4919	0,019941667	44326061	37285,94	36924,9
Eki.06	27,91000	1,4501	0,019916667	43928892,7	36924,86	40582,3
Kas.06	29,65000	1,46	0,019883333	42255762,3	40582,25	38168,5
Ara.06	29,32000	1,4131	0,0197	43247313,3	38168,53	39117,5
Oca.07	28,93000	1,4221	0,019666667	41664769,3	39117,46	41182,6
Şub.07	29,61000	1,3922	0,019508333	40551156,1	41182,55	41431
Mar.07	29,76000	1,3861	0,019483333	41211560,7	41430,99	43661,1
Nis.07	29,64000	1,3274	0,019083333	42045231,5	43661,12	44984,5
May.07	28,93000	1,3253	0,019058333	43300581,7	44984,45	47081,5
Haz.07	28,04000	1,3147	0,019091667	45626358,1	47081,49	47093,7
Tem.07	27,85000	1,3006	0,019125	45942613,4	47093,67	52824,9
Ağu.07	28,24000	1,3242	0,019141667	46677857	52824,89	50198,6
Eyl.07	28,88000	1,21	0,019125	47942130	50198,6	54044,2
Eki.07	28,81000	1,1858	0,018766667	49398309,7	54044,22	57615,7
Kas.07	30,56000	1,1846	0,017825	48044463,8	57615,72	54213,8
Ara.07	30,25000	1,1647	0,01785	51946216,7	54213,82	55538,1
Oca.08	32,70000	1,1722	0,017758333	48566458,3	55538,13	42697,6
Şub.08	35,32000	1,1767	0,01775	48707472,8	42697,56	44776,9
Mar.08	38,31000	1,2765	0,017808333	51748435,2	44776,88	39015,4
Nis.08	38,30000	1,2775	0,017766667	53171555,9	39015,44	43468,1
May.08	35,76000	1,2155	0,018091667	52513055,5	43468,12	39969,6
Haz.08	35,80000	1,2237	0,0192	54035390	39969,63	35089,5
Tem.08	37,21000	1,1853	0,019383333	54100722,6	35089,53	42200,8
Ağu.08	32,79000	1,1818	0,019458333	54416804,9	42200,75	39844,5
Eyl.08	32,88000	1,2316	0,019658333	56880579,9	39844,48	36051,3

Eki.08	37,84000	1,4964	0,020708333	57929787,1	36051,3	27832,9
Kas.08	38,90000	1,5655	0,021508333	57648830,5	27832,93	25715
Ara.08	40,13000	1,5123	0,021491667	59462440,7	25714,98	26864,1
Oca.09	44,00000	1,6107	0,016775	56225100,4	26864,07	25934,4
Şub.09	50,18000	1,6813	0,01535	57098457	25934,37	24026,6
Mar.09	51,49000	1,688	0,015208333	59802434,3	24026,59	25764,4
Nis.09	46,06000	1,5968	0,014891667	59685518,4	25764,38	31651,8
May.09	46,54000	1,5623	0,01495	60003753,4	31651,81	35003

ÖZGEÇMİŞ

1977 yılında Trabzon'da doğdu. İlk ve orta ve lise öğrenimini Trabzon'da tamamladıktan sonra 1997 yılında Karadeniz Teknik Üniversitesi, Fen Edebiyat Fakültesi, İstatistik ve Bilgisayar Bilimleri Bölümünü kazanarak lisans eğitimine başladı. 2001 yılında bu bölümden mezun olarak 2002 yılında Karadeniz Teknik Üniversitesi, Enformatik Bölümü'nde öğretim görevlisi olarak çalışmaya başladı. 2007 yılında, çalıştığı bölüm ders kitabı olarak hazırlanan Temel Bilgisayar ve Uygulamalı İleri Excel kitaplarında yazar olarak görev aldı.

AKAY, evli olup İngilizce bilmektedir.