T.C.
GEBZE YÜKSEK TEKNOLOJİ ENSTİTÜSÜ
SOSYAL BİLİMLER ENSTİTÜSÜ

102135

YAPAY SİNİR AĞLARI KULLANARAK FİNANSAL TAHMİNLERDE BULUNMA

Fatih KILIÇ

YÜKSEK LİSANS TEZİ
İŞLETME ANABİLİM DALI

102135

TEZ DANIŞMANI
Prof.Dr.Erol EREN

GEBZE
2000

T.C. YÜKSEKÖĞRETİM KURULU
DOKÜMANTASYON MERKEZİ

Fatih KILIÇ'ın Tez çalışması, G.Y.T.E. Sosyal Bilimler Enstitüsü Yönetim Kurulu'nun 08/08/2000...tarih ve 2000/19.. sayılı kararıyla oluşturulan jüri tarafından İŞLETME Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

JÜRİ

ÜYE : Prof.Dr.Erol EREN
(Tez Danışmanı)

ÜYE : Doç.Dr.Oya ERDİL

ÜYE : Y.Doç.Dr.Gökhan ÖZER

ONAY

G.Y.T.E. Sosyal Bilimler Enstitüsü Yönetim Kurulu'nun 11/09/2000 . tarih ve 2000/22 sayılı kararı

İmza/Mühür

ÖZET

Yapay sinir ağları bilgisayar dünyasındaki teknolojik gelişimlere paralel olarak gelişim gösteren ve insan beyninin çalışma mekanizmasını taklit etmeye çalışan bir programlama mantığıdır.İnsan beyni yaşadığı olayları hafızasında tutarak bu olaylar sırasında öğrendikleriyle daha sonra karşılaştığı benzer durumlarda geçmiş tecrübelerinden yararlanarak ileride ne gibi bir durumla karşılaşabileceğini tahmin edebilmektedir.Yapay sinir ağlarının da izlediği yöntem budur ve yapay sinir ağlarını diğer programlama mantıklarından farklı yapan bu özelliğidir.Kısaca , yapay sinir ağları kendisine verilen örnek giriş değerleri ile eğitilerek benzer yeni girişler için gelecek ile ilgili çıkış değerleri tahminlerinde bulunabilmektedir.

Yapay sinir ağlarının uygulanabileceği alanlardan birisi de finansal tahminlerdir. Ekonomik ve finansal alanda geleceğe yönelik tahminlerde bulunmak çok önemlidir. Kesin değerler alınamasa bile sadece geleceğe dair trendi gösteren tahminler bile çok büyük önem taşımaktadır.Bir uygulamanın yapay sinir ağlarına uygulanabilir bir uygulama olabilmesi için öncelikle matematiksel olarak ifade edilebilen giriş değerleri ve bu giriş değerlerine karşılık gelecek matematiksel olarak ifade edilebilen çıkış büyüklüklerinin bulunması gerekmektedir.Benzer şekilde yapay sinir ağları ile finansal tahminlerde bulunabilmek için finansal uygulamanın matematiksel büyüklükler şeklinde ifade edilebilen giriş ve çıkış değelerinin bulunması gerekmektedir.Bu şartları yerine getirebilen finansal bir uygulama yapay sinir ağları için uygun formata getirildikten ve yapay sinir ağlarının eğitimi tamamlandıktan sonra yeni giriş değerlerinin gelecekle ilgili çıkış değerlerinin tahmini için kullanılabilir.

Bu tezin amacı yapay sinir ağları ile finansal tahmin'in ne derece etkili ve uygulanabilir olduğunun ve ne derecede başarılı sonuçlar verebildiğinin gösterilmesidir.Bu tezde öncelikle insan beyninin çalışma mekanizması ile birlikte yapay sinir ağları hakkında tarihsel gelişimi ile birlikte genel bir bilgi verilmiştir.

Daha sonra finansal uygulamaların yapay sinir ağlarına uygulanabilmesi için taşıması gereken özellikleri,uygulamanın yapay sinir ağı için uygun hale getirilmesi için gerekenler ve dikkat edilmesi gereken konular anlatılmıştır.Konunun daha iyi anlaşılabilmesi için örnek bir finansal uygulama alınmış ve tüm bu adımlar bu uygulama üzerinden anlatılarak gösterilmiştir.Son bölümde ise, birincisinde ayrıntılı olarak bir yapay sinir ağı programının çalışmasını ve verilen girişler ile nasıl çıkış değerine ulaştığını göstermek ve ikincisinde ise bir yapay sinir ağı programının nasıl çalıştığını göstermek üzere 2 adet örnek uygulama gösterilmiştir.

SUMMARY

Neuoral networks are computer programming algoritms which makes development parallel to the advances in computer technologies and tries to act like human brain.Human brain can memorize the events he lived and can guess future situations from his experiences about the same patterns which he shaw in his past experiences. The method which neural networks use is same as this method and this feauture is the one which makes neural networks diffirent from other computer programming algoritms.Neural networks are trained by sample input values and than new input values are given to network for future predictions.

One of the applications of neural networks is financial prediction.It is very important to make predictions in economics and finance.It is very important to have trend values though exact values are not present.It is necessery for an application to have mathematical expressions of input and output values to be suitable for neural networks.In the same way,financial applications must have mathematical expressions of input and output values to be suitable for neural network predictions.If the financial application is suitable for neural networks and after making adjustments on the sample input data ,the learning process or neural network starts and after learning process ,predictive output values are given by neural network.

Purpose at the scope of this thesis is to show how efficient and feasible the neural networks for financial forecasting is.And also to show how success of neural networks in financial forecasting.In this thesis,at the beginning ,general information about human brain and neural networks and it's history is given.Later,it has been discussed about spesifications which financial applications must have to be suitable for neural networks and what must be done to make application more efficient.For the subject to be understood better ,a financial application have been chosen and the steps of neural network application has been shown on this application.At the last part,two example applications have been chosen.1st application has been chosen for showing the

steps of neural network program detailed and the 2nd application has been chosen for showing a sample neural network program.

TEŞEKKÜR

Bu tezi hazırlarken kıymetli destek ve yardımlarını gördüğüm tez danışmanım GYTE İşletme Fakültesi eski Dekanı sayın Hocam Prof. Dr. Erol EREN'e sonsuz şükranlarımı sunarım.Ayrıca bu tez çalışmam sırasında gerekli araştırma ve çalışmaları yapmam için bana yardımcı olan BİLPA A.Ş. Teknolojik Stratejiler Proje ve Dizayn Grubu Yönetmeni sayın Dr. Atilla GÜLTEKİN'e teşekkür ederim.

Bu tez çalışması sırasında sabır ve hoşgörü ile yardım ve desteğini esirgemeyen ailemin tüm fertlerine teşekkür ederim.

İÇİNDEKİLER

ÖZET	**IV**
SUMMARY	**VI**
TEŞEKKÜR	**VIII**
İÇİNDEKİLER DİZİNİ	**IX**
SİMGELER VE KISALTMALAR	**XIII**
ŞEKİLLER DİZİNİ	**XIV**
ÇİZELGELER DİZİNİ	**XVIII**
1. GİRİŞ	**1**
1.1 Konunun Ortaya Konulması	2
1.2 Konunun Önemi	2
1.2.1 Bugün için Önemi	2
1.2.2 Gelecekteki Önemi	3
2. BİYOLOJİK BEYİN VE YAPAY ZEKA	**4**
2.1 Mikro Beyin Yapısı	5
2.2 Yapay Sinir Ağlarının Gelişimi	9
2.3 Yapay Sinir Ağlarının Kullanım Alanları	11
2.4 YSA'lar İçin Uygun Problemler	11
3. YAPAY SİNİR AĞLARINA GENEL BİR BAKIŞ	**13**
3.1 Yapay Sinir Ağları İle İnsan Beyninin Karşılaştırması	13
3.2 Neyin Tahmin Edileceğinin Belirlenmesi	15
3.3 Data'nın Toplanması	16
3.4 Data'nın İşleme Uygun Hale Getirilmesi	16
3.5 Test Datasının Açılması	18
3.6 Network Yapısı	18
3.7 Algoritmanın Eğitilmesi	19
3.8 Eğitme ve Test Etme	19

4.NEYİN TAHMİN EDİLECEĞİNİN VE UYGUN GİRİŞLERİN SEÇİMİ 22

4.1 Zaman Serileri Tahmini – Kesin Değer 22

5. GİRİŞ DATALARININ SEÇİMİ 24

5.1 Uygun Girişlerin Seçimi 24
5.2 Korelasyon ve Katkı Ölçüm Programları 24
5.3 Bir YSA Problemi Olarak İpotek İmzalama 26
5.4 Zaman Serisi Tahminleri 27

6. DATANIN HAZIRLANMASI 34

6.1 Hücre Formatlı Giriş Dataları (Spreadsheets) 34
6.2 Spreadsheet'in Oluşturulması 34
6.3 Data'nın Önişlenmesi 36
6.3.1 Girişlerin Teleskoplanması – Lag'ler 37
6.3.2 Hareketli Ortalamalar 38
6.3.3 Katkı Grafikleri 39
6.3.4 Farklar 39

7. DATANIN İYİLEŞTİRİLMESİ 40

7.1 Mevsime Bağlı Değişim 40
7.1.1 Günlük ve Aylık Tanımlama 40
7.2 Minimumlar ve Maksimumlar 41
7.2.1 Extreme Değerler 41
7.3 Minimum / Maksimum Örnekleri 43
7.4 Test Datasının Genişletilmesi 46
7.5 Ne kadarlık data yeterlidir ? 46

8. NETWORK YAPISI VE NETWORK'ÜN EĞİTİLMESİ **48**

8.1 Eğitim 48
8.1.1 Eğitim Algoritmaları 48
8.2 Network Yapıları 49
8.2.1 3 Katmanlı Geri Yayılımlı Network Yapısı 49
8.2.2 4 Katmanlı Network Yapısı 50
8.2.3 Tekrar Eden Networkler 52
8.2.4 Zıplama Bağlantılı Networkler 54
8.2.4.1 katmanlı zıplama bağlantılı network 54
8.2.4.2 4 katmanlı zıplama bağlantılı network 54
8.2.4.3 5 katmanlı zıplama bağlantılı network 55
8.3 Aktivasyon Fonksiyonları 55
8.4 Ward Networkü 60
8.5 Kohonen Networkleri 62
8.6 Olasılıksal Nöral Networkler (ONN) 62
8.6.1 Uygunlaştırma Faktörleri 63
8.6.2 Genel Regresyonlu Nöral Networkler 64
8.7 Jenerik Uyumlu GRNN Networkleri 66

9. EĞİTİMİN BAŞLATILMASI VE DURDURULMASI **67**

9.1 Eğitimin Başlatılması 67
9.2 Eğitimin Durdurulması 69
9.3 En Doğru Değer Için Eğitim 71
9.4 Network'ün Kullanılması 71

10. S&P 500 ENDEKSİNİN 10 GÜN SONRAKİ DEĞERİNİN TAHMİN EDİLMESİ İÇİN BİR NETWORK'ÜN GELİŞTİRİLMESİ **73**

10.1 ilk Girişler 73
10.2 Data'nın Toplanması 74
10.3 Data'nın Önişlenmesi 74
10.4 Hangi Girişlerin Katkıda Bulunduğunun Tesbiti 78
10.5 Hacim Girişi Için Uygun Bir Hareketli Averajın Belirlenmesi 79
10.6 Hangi Girişlerin Geriye Alınacağının (LAG) ve Geri Alınacak Gün Sayısının Karar Verilmesi 82
10.7 Hangi Hareketli Ortalama Periyodunun En Fazla Katkı Yaptığının Tesbiti 89
10.8 Teknik Göstergeler 92
10.9 Kesin Girişlerin Seçimi 99
10.10 Sonuç Networkü 101
10.11 Jenerik Algoritmalı GRNN Networkü 102

11. ÖRNEK UYGULAMALAR 103

11.1 Ayrıntılı bir YSA Örneği 103
11.2 YSA Programı Kullanılarak Yapılan Bir YSA Örneği 108
11.3 Uygulama Sonuçları 115

12. SONUÇLAR VE ÖNERİLER 117

KAYNAKLAR 119

ÖZGEÇMİŞ 121

SİMGELER VE KISALTMALAR

YSA	Yapay Sinir Ağları
IMKB	İstanbul Menkul Kıymetler Borsası
RSI	Relative Strenght Index - Al/Sat Göstergesi
ADX	Average Directional Movement - Averaj Yönsel hareket
S&P	Standarts And Poors
GRNN	Genel Regresyonlu Nöral Networkler
ONN	Olasılıksal nöral networkler
MACD	Moving Average Convergence/Divergence Indicator

ŞEKİLLER DİZİNİ

Şekil **Sayfa**

Şekil 2-1 Biyolojik Nöronun Detayları (Joseph, S.Z.,S-4,1997) 5

Şekil 2-2 YSA Nöron Modeli. (Joseph, S.Z.,S-5,1997) 6

Şekil 2-3 Basit bir 3 katmanlı network. 8

Şekil 3-1 Tipik bir zaman serisi data grafiği.Uzun vade trendi görülmektedir. 17

Şekil 3-2 Uzun vadeli trend kaldırıldıktan sonraki data grafiği. 17

Şekil 3-3 Beyin için data nın organize edilmesi. 20

Şekil 3-4 6912 öğrenme olayından sonra bir networkün hata grafiği. 21

Şekil 3-5 12900 öğrenme olayından sonra hata eğrisi. 21

Şekil 5-1 Grafikten de anlaşılabileceği gibi iki değer arasında ilişki yoktur. 24

Şekil 5-2 Yukarıdaki şekil göstermekedir ki bu 2 değişken arasında korelasyon bulunmamaktadır. 25

Şekil 5-3 Bu grafik benchmark networke farklı teknik göstergeler eklemenin etkisini göstermektedir. 28

Şekil 5-4 5 periyotlu hareketli ortalamalı SPY değeri 10 periyotlu değerden çıkarılmış ve 7. Giriş olarak eklenmiştir. 29

Şekil 5-5 Momentum göstergeli bir benchmark. 29

Şekil 5-6 14 periyot stokastikli bir network 30

Şekil 5-7 SPY nin 10 günlük hareketli ortalamı network. 30

Şekil 5-8 7. Giriş olarak MACD kullanılan bir benchmark. 31

Şekil 5-9 SPY nin 10 günlük gecikmeli değeri 7. Giriş olarak kullanılmış bir benchmark. 31

Şekil 5-10 SPY nin 5 periyotlu hareketli ortalaması 7. Giriş olarak 32

kullanılmış bir benchmark.

Şekil 5-11 12 periyotlu relative güç indeksinin (RSI – Relative Strength Index) 12 periyotlu hareketli ortalaması 7. Giriş olarak uygulanmış bir benchmark. 32

Şekil 5-12 12 periyot RSI lı bir benchmark. 33

Şekil 6-1 Tipik bir nöral network Spreadsheet'i 35

Şekil 6-2 Benchmark sistemine geciktirilmiş girişlerin eklenmesi. 38

Şekil 7-1 Dataların daha çok 0-1 aralığında bulunduğu bir grafikte extreme değer örneği. 42

Şekil 7-2 Bir benchmark networkdeki extreme noktalar. 42

Şekil 7-3 Şekil 7-2 deki grafiğin 1-56 zaman aralığı için detaylı gösterimi. 43

Şekil 7-4 Bir benchmark sisteminin MIN/MAX değerlerinin gerçek minimum maksimumlar olarak alındığı hata-zaman eğrisi. 44

Şekil 7-5 MIN/MAX değerleri gerçek değerlerin %40 daha fazlasına ayarlanmış bir zaman-hata grafiği. 44

Şekil 7-6 MIN/MAX değerleri gerçek değerlerin %40 daha azına ayarlanmış bir zaman-hata grafiği. 45

Şekil 7-7 MIN/MAX değerleri 2.0 standart dağılım değerine ayarlanmış bir hata-zaman grafiği. 46

Şekil 8-1 3 katmanlı bir networkün şematik gösterimi. 49

Şekil 8-2 Gizli katman nöronları-hata grafiği. 51

Şekil 8-3 Giriş katmanından (katman 1) tekrar oluşturmalı katmanına (katman 4)geribesleme alan bir yeniden oluşturmalı network örneği. 52

Şekil 8-4 Gizli (katman2) katmanından tekrar oluşturmalı katmanına (katman 4)geribesleme alan bir yeniden oluşturmalı network örneği. 52

Şekil 8-5 Çıkış katmanından (katman3) tekrar oluşturmalı katmanına 53

(katman 4)geribesleme alan bir yeniden oluşturmalı network örneği.

Şekil 8-6 3 katmanlı zıplama bağlantılı network. 54

Şekil 8-7 4 katmanlı zıplama bağlantılı network. 55

Şekil 8-8 5 katmanlı zıplama bağlantılı network. 55

Şekil 8-9,8-16 Çeşitli transfer fonksiyonları 57-59

Şekil 8-17 Temel Ward networkü. 60

Şekil 8-18 Modife edilmiş Ward networkü. 61

Şekil 8-19 Herbiri farklı aktivasyon fonksiyonuna sahip 3 gizli katmanlı Ward Networkü. 61

Şekil 8-20 Kohonen networkünün şematik gösterimi 62

Şekil 8-21 ONN networkünün şekilsel gösterimi 63

Şekil 8-22 Uygunlaştırma faktörü 0.05 olduğunda giriş-çıkış grafiği. 63

Şekil 8-23 Uygunlaştırma faktörü 0.08 olduğunda giriş-çıkış grafiği. 64

Şekil 8-24 Uygunlaştırma faktörü 0.1 olduğunda giriş-çıkış grafiği. 64

Şekil 8-25 Genel Regresyonlu Nöral Networklerin şematik gösterimi 65

Şekil 8-26 Uygunlaştırma faktörü-Hata oran grafiği 66

Şekil 9-1 Eğitim süresine bağlı olarak hata oranının grafiği. 67

Şekil 9-2 Bir önceki grafikten farkı eğitim olayı sayısı 1772 den 2583'e yükseltilmiştir. 68

Şekil 9-3 Bir önceki grafikten farkı eğitim olayı sayısı 2583 den 4503'e yükseltilmiştir. 69

Şekil 9-4 Öğrenme olayının 104400 değerindeki hata oranını gösteren grafik. 69

Şekil 9-5 Şekil 8-4'teki grafiğin son noktasının büyütülmüş bir grafiği. 70

Şekil 10-1 Dow Jones 30 günlük değerinin Spreadsheet'i. 76

Şekil 10-2 Orjinal spreedsheet'in YSA için düzeltilmiş hali. 77

Şekil 10-3 Çizelge 10-2 de gösterilen değerlerin grafiksel gösterimi. 81
Şekil 10-4 Çizelge 10-3 de gösterilen değerlerin grafiksel gösterimi. 82
Şekil 10-5 Çizelge 10-4 deki dataların grafiksel gösterimi. 84
Şekil 10-6 Çizelge 10-5 deki dataların grafiksel gösterimi. 85
Şekil 10-7 Çizelge 10-6 daki dataların grafiksel gösterimi. 87
Şekil 10-8 Çizelge 10-7 deki dataların grafiksel gösterimi. 88
Şekil 10-9 Çizelge 10-8 deki dataların grafiksel gösterimi. 89
Şekil 10-10 Çizelge 10-9 deki dataların grafiksel gösterimi. 90
Şekil 10-11 Çizelge 10-10 daki dataların grafiksel gösterimi. 91
Şekil 10-12 Çizelge 10-12 daki dataların grafiksel gösterimi. 93
Şekil 10-13 Çizelge 10-13 deki dataların grafiksel gösterimi. 95
Şekil 10-14 Çizelge 10-14 deki dataların grafiksel gösterimi. 96
Şekil 10-15 S&P 500 fiyat datasının alt ve üst tarafından Bollinger Bantları çizilmiş bir grafiği. 97
Şekil 10-16 Çizelge 10-15 deki dataların grafiksel gösterimi. 98
Şekil 10-17 Çizelge 10-16 deki dataların grafiksel gösterimi. 99
Şekil 10-18 Çizelge 10 -17 deki dataların grafiksel gösterimi. 101
Şekil 11.1 Giriş ve çıkışlardan oluşmuş ilk network yapısı 103
Şekil 11.2 İlk durum ile ilgili giriş değerleri networke uygulandıktan sonra elde edilen çıkış değeri ve bunun istenilen çıkış değeri ile kıyaslanması. 104
Şekil 11.3 İlk çevrim sonucu elde edilen çıkış değerleri. 105
Şekil 11.4 Gizli nöron konularak uygulanan 2. çevrim sonucu network çıkışı. 106
Şekil 11.5 5. çevrim sonunda network çıkışı ve networkün görünümü. 106
Şekil 11.6 10. çevrim sonunda network çıkışı ve networkün görünümü. 107
Şekil 11.7 21. çevrim sonunda network çıkışının görünümü. 108
Şekil 11.8 Networkün eğitilmesi ve gizli nöron sayısı ile networkün eğitilmesi arasındaki ilişki. 111
Şekil 11.9 Gerçek çıkış değerleri ile tahmin edilen çıkış değerlerinin karşılaştırmalı tablosu. 112
Şekil 11.10 Çıkış değerleri ve gerçek değerlerin grafiği 115

ÇİZELGELER DİZİNİ

Çizelge	Sayfa
Çizelge 3-1 İnsan beyni ile nöral networkler arası farklılıklar	14
Çizelge 8-1 Kesinliğe gizli katmandaki nöron sayısının etkisi.	50
Çizelge 8-2 Kesinliğe 2. Bir gizli katman eklemenin etkisi.	51
Çizelge 10.1 Geri yayılımlı bir networkün eğitiminde her bir girişin eğitim için kullanıldığında ortaya çıkan relatif katkısının tablosu.	78
Çizelge 10-2 OEX TRIN ve Hacim girişleri silindikten sonraki katkı değerleri.	80
Çizelge 10-3 OEX TRIN ve Hacim girişleri silindikten sonraki katkı değerleri.	81
Çizelge 10-4 10 günlük lag değerine sahip girişlerin relative katkısı.	83
Çizelge 10-5 Benzin girişinin 10,15 ve 20 günlük lag'li değerlerinin eklenmiş halinde katkı grafiği.	85
Çizelge 10-6 Tablo 9-5 e benzer bir tablo,fark olarak benzin yerine altın gümüş endeksi kullanılmış.	86
Çizelge 10-7 Altın gümüş endeksinin 10,20,30 ve 40 günlük lag'li değerleri kullanılan tablo.	87
Çizelge 10-8 Herhangi bir anda lag'li girişler uygulanmış bir networkdeki hata oranlarını gösteren tablo.	88
Çizelge 10-9 Her girişin 10 günlük hareketli ortalamasının kullanılarak test edildiği tablo.	90
Çizelge 10-10 Her girişin 20 günlük hareketli ortalamasının kullanılarak test edildiği tablo.	91
Çizelge 10-11 Her girişin 30 günlük hareketli ortalamasının kullanılarak test edildiği tablo.	92
Çizelge 10-12 12 günlük RSI ve 12 günlük RSI in 12 günlük hareketli ortalamalı değerli giriş-katkı tablosu.	93
Çizelge 10-13 12 günlük RSI değeri giriş olarak kullanılmış bir tablo.	94

Çizelge 10-14 12 günlük RSI değerinin 12 günlük hareketli ortalaması giriş olarak alınmış bir tablo. 95

Çizelge 10-15 Bollinger bantları ek giriş olarak eklenmiş bir networkün katkı tablosu. 97

Çizelge 10-16 Değişim (12) Momentum göstergesi eklenmiş giriş-katkı tablosu. 98

Çizelge 10-17 Hemen hemen bitmiş bir networkte girişlerin katkısını göstermektedir. 101

1. GİRİŞ

Elektriğin icadından itibaren insanlık çok büyük gelişimler sarfetmiştir ve bu gelişimlerin belki de günümüzdeki en büyük sonuçlarından birtanesi de bilgisayarlardır.Bilgisayarların kullanılmaya başlamadığı hemen hemen hiçbir alan yoktur.Yapay sinir ağları ise son 5 yıl içinde bahsedilmeye başlayan ve bilgisisayar dünyasındaki gelişimlere paralel olarak gelişen bir alandır.Yapay sinir ağları ise insan beyninin işleyiş mekanizmasını taklit ederek birbakıma bilgisayarların insanlar gibi düşünüp karar verebilmesini sağlayan bir programlama alanıdır.Yapay sinir ağları ile amaçlanan bilgisayara verilen belli durumların ne gibi sonuçlar doğurabileceğinin anlaşılmasının sağlanabilmesidir.Finansal tahmin ise herzaman ekonomik açıdan önemli bir kavram olmuştur.Finans ile uğraşan insanlar için geleceğe yönelik doğru tahminlerde bulunabilmek çok önemli ve bir o kadarda zor bir olaydır.Finansal analiz ve tahminler için birçok teknik analiz yöntemi kullanılagelmektedir.Fakat bu analizlerin yapabildikleri o an varolan durumun daha iyi anlaşılabilmesine yardımcı olmak ve gelecek ile ilgili çok kısıtlı tahminlerde bulunmaktır.Klasik bir analiz yönteminin gelecek ile ilgili tahmini çok gerçekçi olamamaktadır çünkü her analiz yöntemi sadece belli kriterleri göz önüne alır ve birebir tekrar eden durumlar için geleceğe yönelik tahminlerde bulunabilir.

Yapay sinir ağları giriş ve çıkış değerleri matematiksel büyüklükler şeklinde ifade edilebilen durumlar için geleceğe yönelik tahminlerde bulunabilmektedir. Yapay sinir ağları kendisine verilen giriş değerlerini kendi çalışma mekanizması içinde defalarca değerlendirir,her bir girişin çıkış değerine katkısını hesaplar,giriş değerlerinin değişimlerine göre çıkış değerinin değişimini gözlemler,bu safhalara kısaca yapay sinir ağının "öğrenmesi" denilir.Yapay sinir ağlarını diğer analiz yöntemlerinden ayıran bu "öğrenme" safhasıdır.Bir durum için ne kadar çok giriş ve giriş değeri uygulanırsa yapay sinir ağının öğrenmesi ve doğru sonuçlar vermesi o kadar başarılı olabilmektedir.

1.1 Konunun Ortaya Konulması

Finansal tahminlerde bulunmak için pekçok teknik analiz yöntemi ve programı bulunmaktadır. Bu analiz yöntemleri sadece belli kriterleri göz önüne aldıkları için güvenilir ve başarılı değildirler.Finansal tahmin tüm değişkenleri makro anlamda göz önüne alarak başarılı olunabilen bir alan olduğu için klasik analiz yöntem ve programları başarıya ulaşmaktan uzaktırlar.Finansal tahmin için bilgisayar bu yüzden çok önemli bir uygulama aracı olamamıştır.Finansal analiz yaparken daha çok insan sezgisinden,yani farklı durumlarda doğru karar verebilme yeteneğinden yararlanmak klasik analiz yöntemlerine göre daha başarılı ve gerçekçi sonuçlar vermektedir.İnsan bu yeteneğini geçmiş bilgi birikimini kullanarak benzer aynı durumlar için doğru karar verebilme yeteneğine,diğer anlamda beynine borçludur. İnsanın bu özelliği araştırmacıları bilgisayarları da insan gibi düşünerek karar verebilme yeteneği kazandırma çabasına yöneltmiştir ve bunun sonucunda da insan beynini ve çalışma mekanizmasını model alan yapay sinir ağları ortaya çıkmıştır. Finansal tahmin ise yapay sinir ağları uygulaması olabilecek özellikler taşıdığı için yapay sinir ağlarının uygulama alanlarından birisi haline gelmiştir.

1.2 Konunun Önemi

Finansal tahminlerde doğru ve gerçeğe yakın tahminlerde bulunabilmek ne kadar önemliyse yapay sinir ağları ile finansal analizin başarısı o kadar önemlidir. Yapay sinir ağları sadece finansal analiz alanında değil tüm dünyada potansiyel olarak çok büyük beklentilerin olduğu bir konudur.

1.2.1 Bugün İçin Önemi

Günümüzde yapay sinir ağlarının çok yeni bir konu olması ve bilgisayar işlemci gücüne ihtiyacı olmasından dolayı çok etkili olduğu bir alan henüz bulunmamaktadır.Bunun birinci nedeni bilgisayarların işlemci güçlerinin henüz yapay sinir ağları hesaplamaları için yeterli seviyeye gelememiş olmasıdır.Yapay sinir ağları çok ağır matematiksel hesaplamalar gerektirdiği için henüz yeterli seviyeye gelememişlerdir.İkinci neden ise yapay sinir ağları programlama mantığının çok karmaşık ve zor olmasıdır.Bu nedenle etkili yapay sinir ağları programlarının

yapılabilmesi çok uzun çalışmalar gerektirmektedir.Buna rağmen yapay sinir ağları alanında çalışan araştırma kuruluşları ve üniversiteler başarılı uygulamalar ve programlar yapmaya başlamışlardır.Fakat yapay sinir ağları henüz emekleme devresinde olduğu için geniş kullanım alanı bulamamaktadır.

1.2.2 Gelecek İçin Önemi

Gelecekte bilgisayarların işlemci gücündeki ve programlama mantıklarındaki gelişmelere paralel olarak yapay sinir ağları çok büyük ve önemli bir konu haline gelmesi çok büyük bir olasılıktır.Bilgisayar alanındaki çalışmalar kendi kendisini besleyen ,yani feedback veren çalışmalardır.Örneğin yeni işlemcilerin tasarımında gene işlemciler kullanılmakta,daha iyi işlemciler yapıldıkça daha iyi tasarımlar yapılabilmekte,dolayısıyla yeni işlemcilerin tasarlanması kendi kendisini geliştiren ve besleyen bir çalışma konusudur.Yapay sinir ağları da benzer şekilde çok hızlı gelişim içinde olan bir alandır.İşlemcilerin güçleri ve yapay sinir ağları programlarının becerileri arttıkça çok daha kapsamlı ve büyük datalar işlenilebilecek ve daha doğru sonuçlar elde edilebilecektir.Bir yapay sinir ağının başarısı kendisine verilen değişkenlerin ve bu değişkenlere ait giriş datalarının sayısının çokluğuna, kullanılan bilgisayarın işlem gücüne ve yapay sinir ağı programının programlanmasındaki başarıya bağlıdır.Tüm bu gelişimler sonucunda başarıyı etkileyen bu etkenler iyileştikçe yapay sinir ağları ile çok daha iyi sonuçlar alınabilecek ve yapay sinir ağlarının yetenekleri artacaktır.Dolayısıyla yapay sinir ağları ile finansal tahmin de çok önemli olacaktır.Finansal tahmin çok yüksek sayıda değişkene bağlı olduğu için yapay sinir ağları için ağır uygulama alanlarından birisidir.Yapay sinir ağlarındaki gelişim ile yapay sinir ağları ile finansal tahminin öneminin artması kaçınılmaz bir sonuçtur.

2. BİYOLOJİK BEYİN VE YAPAY ZEKA

Tüm canlıların beyinleri nöron adı verilen hücrelerden oluşur.Bu hücrelerin diğer vücut hücrelerinden farkı yenilenememeliri,yani öldükten sonra yerine yenilerinin yapılamamasıdır.Bu sayede insan beyni olayları hatırlayabilir.İnsan beyninde ortalama 100 milyar nöron bulunmaktadır. Bu rakam bir salyangozda ise yaklaşık olarak 20.000 dir.

İnsan beyni dikey olarak yaklaşık eşit büyüklükte 2 parçaya ayrılmıştır.Her bir yarım parça farklı fonksiyonları yerine getirir.Çalışmalar sonunda anlaşılmıştır ki sol yarım küre logic ve matematik işlemleri,sağ yarım küre ise duygusal işlemleri, şekil tanıma ve duyu organları ile ilgili işlevleri yerine getirmektedir.İnsanlarda bu yarım dairelerden bir tanesi diğerine göre baskın olmaktadır.Bilim adamları ve matematikçilerin sol yarım küreleri daha gelişmiş olmaktayken yazar ve sanatçıların ise sağ yarım küreleri daha gelişmiştir.Finans alanı da matematiksel teknik analizlere dayandığı için sol yarım küresi daha gelişmiş insanların daha başarılı oldukları bir alandır.Diğer taraftan yapay sinir ağları sağ yarım küre ağırlıklıymış gibi davranır, çünkü tahmin yapmak için girdiler ve çıktılar arasındaki gizli ilişkileri ve örnekleri tanımaya dayanır.

İnsanoğlu matematiksel ve logic işlemleri daha az uğraş ve beyin görevi ile halledebilmek için mekranik ve elektronik hesaplama makineleri yapmaya çalışmıştır.İlk temel hesaplama makineleri 1700 li yılların sonlarında yapılmıştır.1930larda Bell laboratuvarlarındaki bilim adamları analog derverlere dayanan ve basit matematiksel 4 işlem ve integral türev gibi karmaşık işlemleri yapabilen elektronik hesaplayıcıyı yapmıştır.Bu makineler insan beyninin çalışma mantığının dışında çalışmaktadır.Normal bir insan beyni hesaplama yaparken mantık yürüterek sonuca gider,mekanik hesaplayıcılar ise 2 basamaklı (digit) işlemlerin değişik varyasyonlarını kullanarak hesaplama yapar.Fakat mekanik hesaplayıcılar insan beyni gibi farklı durumlarda mantık yürütemez,sadece kendisine daha önce öğretilen hesaplamalara birebir uyan hesaplamaları çözüme kavuşturabilir.(John,G.H.;Zhao,Y.,S-59,1996)

Biyolojik sinirler iletimini elektriksel sinyaller vasıtasıyla yapmaktadır.Bir sinir hücresinden diğer bir sinir hücresine sinyaller sinir hücreleri boyunca dizilmiş olan iyonlardaki elektriksel yük değişimleri ile iletilmektedir.Diğer bir ifade ile sinirsel sinyal iletimi elektro-kimyasal olaylar vasıtasıyla sağlanmaktadır.

2.1 Mikro Beyin Yapısı

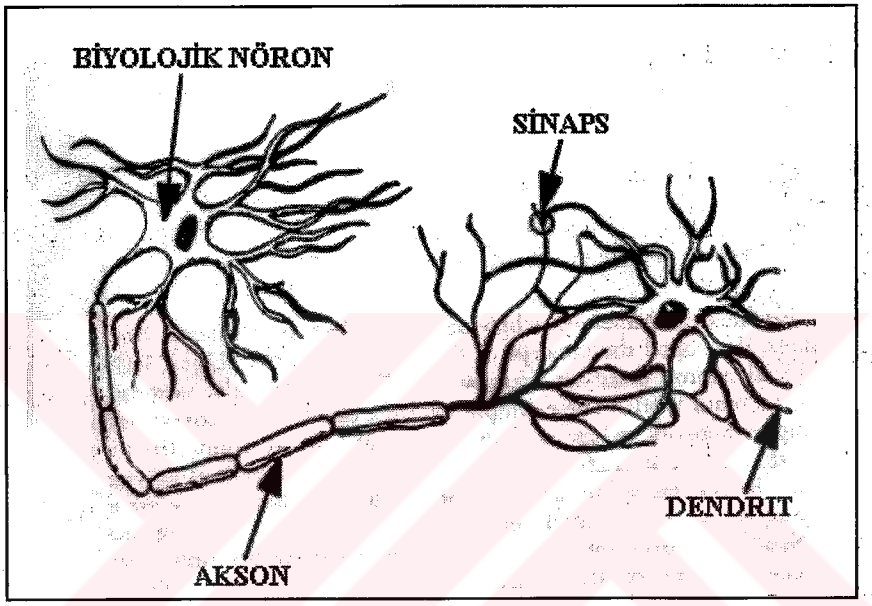

Şekil 2-1 Biyolojik Nöronun Detayları (Swingler,K, S 100,1994)

Biyolojik beyin sinir hücresi adı verilen özelleşmiş hücrelerden oluşmaktadır ve bu sinir hücrelerine nöron ismi verilmektedir.Beyindeki her nöron "soma" isimli bir gövdeden oluşmaktadır (Şekil 2-1). Bir beyin hücresi,yani nöron ,3 kısımdan oluşmaktadır.Baş,gövde ve kök kısımları.Gövde kısmı bir sap görünümünde olup "akson" ismi verilmektedir.Akson aracılığı ile elektriksel darbeler diğer hücrelere iletilirler.Hücreye gelen elektriksel darbeler (impulslar) "dendrid" adı verilen sensorlar tarafından algılanırlar. Darbelerin alındığı özelleşmiş iletişim noktasına ise "sinaps" adı verilir.Sinir impulsları bir hücreden diğer bir hücreye sinapslar üzerinden iletilir.Bu yapı elektrokimyasal olarak çalışır.Bu ,beyinin kimyasal aksiyonlar tarafından oluşturulan elektriksel darbeler sayesinde çalıştığı anlamına gelir.Sinapslara gelen birçok darbe belli bir eşik değerinin üstüne çıktığı an soma üzerindeki elektriksel yükü boşaltır ve bu elektriksel impuls diğer nöronlara

iletilir.Sinaptik boşluklar arasında sinir impulslarının iletimini aminoasitlerden oluşmuş biojenik-aminler diye adlandırılan kimyasal taşıyıcılar yapar.

Şematik olarak biyolojik nöronlar birçok girişi ve tek bir çıkışı olan ve diğer nöronlara bağlanana hücreler olarak şekillendirilebilir .

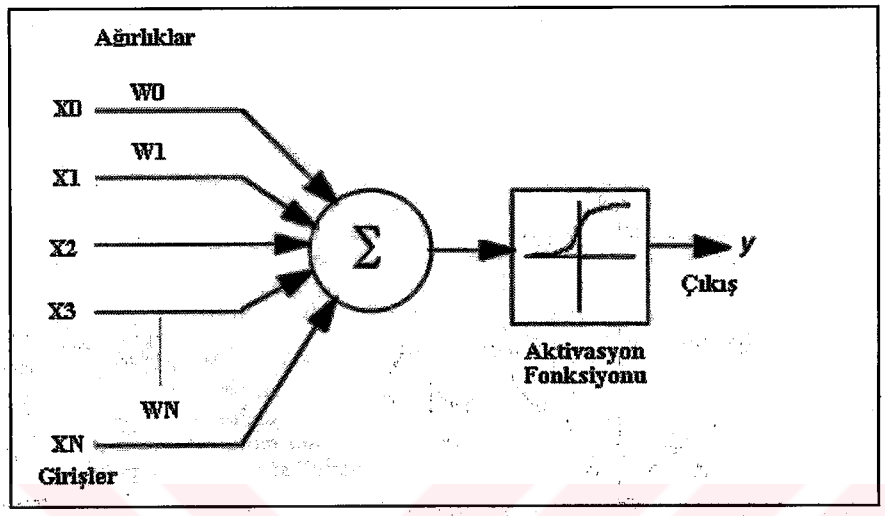

Şekil 2-2 YSA Nöron Modeli. (Swingler,K, S 101,1994)

YSA insan beynininin bu şematik yaklaşımına çok benzerdir.YSA lardaki nöron modeli insan beynindeki mekanizmadan yola çıkılarak oluşturulmuştur.İnsan beynindeki 3 temel eleman olan soma,akson ve dendrit YSA'daki nöron modelinde sırasıyla toplama elemanı,aktivasyon fonksiyonu ve girişlerin ağırlık değerleri ile hesaplanmış şekline karşılık gelmektedir. YSA'daki nöron modeli şekil 2-2'de gösterilmiştir.Biyolojik sinir hücrelerindeki sipanslar arasındaki boşluğun etkisi YSA da yapay sinir girdilerinin önemlilik derecesi ve ağırlığının ölçülmesi ile kıyaslanabilir.Beyindeki nöronların doğrusal olmayan yapısı YSA da nöronlar arasında doğrusal olmayan aktivasyon fonksiyonları kullanılarak modellenebilir.

Tüm bu kabuller ve modellemeler sonucunda YSA nöron modeli matematiksel bir eşitlik ile ifade edilebilmektedir.

$$y = f\left(\sum_{i=0}^{N} x_i w_i\right)$$

Bu eşiklikte X_i giriş,y çıkış,w_i ağırlıklar ve N giriş sayısını ifade etmektedir. Giriş değerleri 0 dan N'e kadar ağırlıkları ile çarpılarak toplanmaktadır.Buraya kadar ifade edilen yapay sinir ağlarının en basit modeline tahminci(perceptron) adını vereceğiz.Her bir tahminci basit örnekleri öğrenme ve anlama yeteneğine sahiptir.Örneğin bir tahminci girişlerin hangi sınıfa dahil olduğunu anlayabilir.2 sınıfı birbirinden ayıran basit bir çizgi tahminci tarafından öğrenilebilir. Öğrenme algoritmasının görevi istenilen çıkış değerinin elde edilmesi için ağırlıkları ayarlamaktır.Tahminci kendisine bir set giriş verilerek eğitilir ve gerekli çıkışı bulması istenir.İstenilen çıkış değeri (d) ve çıkış değeri (y) arasındaki hata değerine göre ağırlıklar öğrenme algoritması tarafından bu hatanın düşürülmesi amacı ile ayarlanır.Ağırlıkları adapte etmek için kullanılan ilk tekniklerden birisi "Tahminci Yakınsama Prosedürü (Perceptron Convergence Procedure)" idi. Tahminci Yakınsama Prosedürü'nün işleyişi aşağıdaki gibidir:

Adım 1: Ağırlıkların ve kesim noktalarının (treshold) ayarlanması ve başlatılması.w_i 'ye küçük rastgele değerler atanır ($0 <= i <= N$).w_i herbir i girişine ait ağırlığı ifade etmektedir.

Adım 2 : Yeni girişler ve istenilen çıkış değerleri işleme alınır. Giriş değerleri x_i şeklinde ifade edilmektedir ($0 <= i <= N$) ve bu giriş değerleri ile istenilen çıkış değerleri alınmaktadır,istenilen çıkış değeri "d" ile ifade edilmektedir.

Adım 3 : Anlık çıkış değerleri hesaplanır

$$y = f\left(\sum_{i=0}^{N} x_i w_i\right)$$

Adım 4 : Ağırlıklar adapte edilir.Burada n öğrenmenin uygulanacağı oranı ve d ise istenilen doğru çıkışı ifade etmektedir.

$$w_i = w_i x_i n(d-y)$$

Bu işlem hata değeri (d-y) minimum bir değere getirilene kadar devam ettirilir ve istenilen ideal hata değeri 0 dır.Tahminci ilk uygulanmaya başlandığında oldukça faydalı olduğu görüldü fakat daha sonra örneklerin karmışıklığı arttığında çözüm getirememeye başladı.Günümüzde bu yöntem sayısal integral problemlerinde

kullanılmaktadır ve matemetikte "iterasyon" tekniği olarak adlandırılmaktadır. Tahminci örnek olarak aşağıdaki gibi bir soruna çözüm getirememektedir. Bu problemde 2 çizgi arasında kalan 4 bölge için sınıflandırma yapılmak istenildiğinde tahminci yetersiz kalmaktadırFakat çok katmanlı tahmin sistemleri bu problemin üstesinden kolaylıkla gelebilmektedirler. (Swingler,K, S 105-107,1994)

Daha sonra birden çok tahmincinin giriş ve çıkışları birbirlerine bağlanarak bir network oluşturulursa birçok problemin çözülebileceği keşfedildi.Bu yeni yapıya çok katmanlı tahminci ve daha sonra ise genel ismi ile yapay sinir ağları ismi verildi. Bu tip bir yaklaşım başlangıçta pekçok problemin çözümü olarak görülse bile bu tip bir yapının hayata geçirilmesi ve işlevsel hale getirilmesinin çok karmaşık bir sistemin kurulup işlevsel hale getirilmesini gerektirdiği anlaşıldı.İleri beslemeli ve gizli katmanlı bir yapay sinir ağı networkü şekil 2-3 de gösterilmektedir.Gizli katman giriş ve çıkışları networkün giriş ve çıkış noktaları dışındaki noktalara bağlanan noktalar (node) grubudur.Gizli katman giriş katmanından veya başka bir gizli katmandan girişleri alıp çıkış katmanına veya başka bir gizli katmana çıkış olarak veren katmandır.Geri beslemeli eğitim algoritması çıkış değeri istenilen çıkış değerine çok yaklaşan networklerin ağırlıklarını iyileştirmek için kullanıldı.Bu istenilen çıkış değeri ile çıkış değeri arasındaki farkların alınıp tekrar ağırlıklara adapte edilmesi şeklinde uygulanmaktadır.

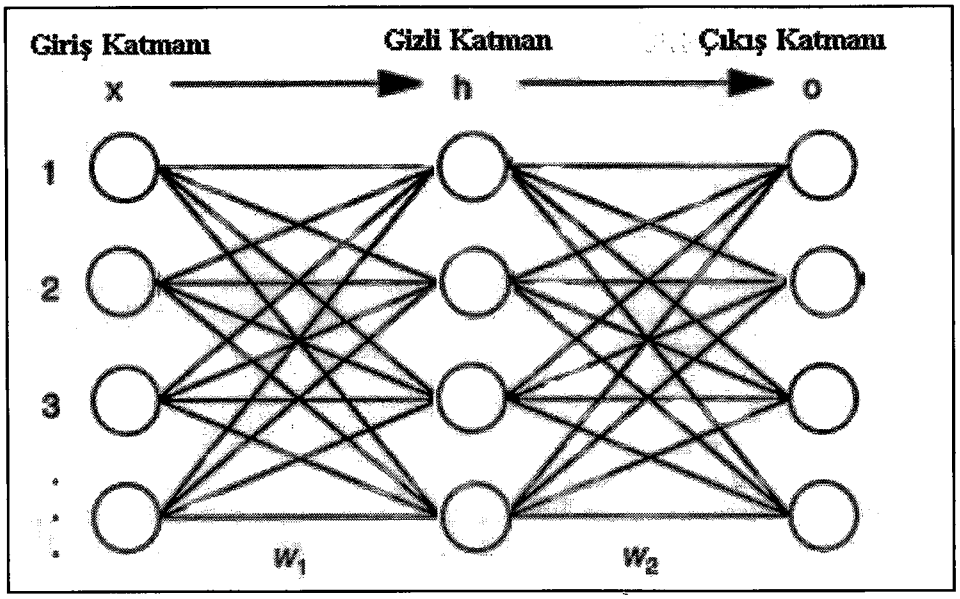

Şekil 2-3 Basit bir 3 katmanlı network. (Saad,E.W., S 13, 1998)

YSA'lar 3 veya daha fazla katmanda nörona sahiptir.İlk katman nöronlar giriş katmanı (girdilerin alındığı) olarak adlandırılır ve networke giren her bir giriş için bir nörona sahiptir.Giriş katmanındaki her nöron gizli katmandaki her nörona bağlıdır.Gizli alan genellikle birden çok katmandan oluşur ve birinci katmandaki her nöron 2. Katmandaki nöronlara bağlıdır.Eğer 2 den çok katman varsa 2. Katmandaki hücreler 3. Katmandaki her hücreye bağlanır.Gizli alandaki son katman dış katmana bağlanır.Şekil 2-3'de giriş katmanındaki her bir nöronun gizli katmandaki nöronlara bağlandığı ve gizli katmandaki nöronların benzer şekilde dış katmana bağlandığı basit 3 katmanlı bir network temsil edilmiştir.

Farklı nöronlar arasındaki bağlantının kuvveti networkün amacına göre değişir.Benzer networleri farklı kılan bu bağlantıların kuvvetleri arasındaki farklılıklardır.İki nöron arasındaki bağlantının kuvveti "ağırlık" olarak adlandırılır.Güçlü bir bağlantının zayıf bir bağlantıya göre daha fazla ağırlığı vardır.Önemli girişlere daha yüksek ağırlıklar verilir.Biyolojik beyin filtreleri önemsiz bilgileri gözardı etmektedir.Bu YSA da o ağırlığa 0 değerini vermekle eşdeğerdir.

YSAlardaki nöronlarla biyolojik beyin nöronları arasında belki de en önemli fark biyolojik beyin nöronlarına girdilerin sadece 5 duyu organından gelmesidir.YSA'larda ise girdiler matematiksel rakamlardır ve girdi olarak kullanılmak istenilen her bilgi rakamlara dökülebilir.Birçok uygulamada YSA'lar rakam olarak sadece 1 ve 0'I kullanır,0 girdi olmadığını 1 ise girdi olduğunu belirtir.Şaşırtıcı bir şekilde bu networkün başarılı bir sonuç bulmasını etkilemez

2.2 Yapay Sinir Ağlarının Gelişimi

1940'larda çarpabilen ,bölebilen,diğer basit matematiksel işlemleri yapabilen karmaşık makineler geliştirildi.İlk bildiğimiz anlamda hesap makinesi 1950'lerde bilim adamları tarafından geliştirildi.Bu makineler sadece basit 4 işlem yapmakla kalmıyor aynı zamanda kök ve üst alma gibi işlemleri de yerine getirebiliyorlardı. Bu

icatlardan sonra bu makineler tüm finansçılar ve bilim adamları için vazgeçilmez bir parça haline geldiler çünkü bir insan için çok fazla zaman alan matematiksel işlemleri çok kısa sürelerde ve %100 doğrulukla sonuca ulaştırıyorlardı.Aynı zaman dilimi içinde Pensylvania Üniversitesindeki bilim adamları ilk digital bilgisayarı geliştirmekteydiler.Bu bilgisayarın ismi "Eniac" idi.Eniac çok güçlü mainframe (günümüzde bankalarda ve askeri projelerde kullanılan çok büyük ölçekli bilgisayarlar) bilgisayarların atası sayılır.Eniac'ın tüm fonksiyonlari insan beyninin sol yarım küresinin yaptıklarıyla aynı mantığa dayanıyordu.Çünkü bu işlemler tamamıyla matematik kurallara bağlıydı.

1943 de Warren McCullock ve Walter Pits "A logical calculus of Ideas Immanent in nerous activity" (Sinir sistemi aktivitelerinin logical hesaplanması) isimli makalerlerini yayınladılar (Bulletin of mathematical biophysics,Sayı 5 sayfa 115-133).Bu makale şu anki yapay sinir ağlarının teorik temelini teşkil eder.1951 yılında MIT'de öğrenci olan Martin Minsky bir labirent çözme problemini öğrenme sonucu çözebilen nöral bir bilgisayar geliştirdi.Bu pratik anlamda yapay zekanın ilk adımı oldu ve hala MIT de çalışan Dr Minsky gelişmiş yapay zeka sistemlerinin babası olarak anılır.(Gately,E.,S-3,1996)

1970'lerin sonunda bilgisayarlar yapay sinir ağları alanında pratik çözümler getirebilecek güç ve yeterliliğe ulaşmaya başladılar.Bu 1986'da iş ,bilimsel ve endüstriyel alandaki sorunların çözümünü sağlayabilien yapay sinir ağlarının ateşleyicileri oldu.

Yapay sinir ağları (YSA) insan beyninin örnekleri sınıflandırıp geçmiş tecrübelerden de yararlanarak tahminler yapabilmesini model alıp bunu taklit eden bilgisayar programlarıdır.İnsan beyni 5 duyu organından aldıklarını girdi olarak kullanıyorken YSA ise data(bilgi) serilerinden gelen girdileri değerlendirir.

Pratik YSA uygulamaları 1970'lerde hazır olabilidiğinden ve gelişimleri bilgisayarların işlem gücüne bağlı olduğundan YSA'lar henüz bebeklik evrelerindedirler.YSA'ların sorun çözebilme hızı ağın büyüklüğü,problemin karmaşıklığı,verilen örnek bilgilerin çokluğu ve kullanılan bilgisayarın gücüne bağlıdır.Daha hızlı bilgisayarlar aynı problemi daha kısa sürede sonuça

ulaştırabilmektedir.8-12 Mhzlik 286 işlemci kullanan bir bilgisayar ile 489DX33 bir bilgisayar arasındaki çözüm getirme süresi yaklaşık olarak 8 kat daha yavaştır.Pentium 90 işlemcili bilgisayarlar ise 486DX33 işlemcili bir bilgisayara göre 4 kat daha hızlı çözüm getirebilmektedir.Ve bu süreler yeni CPU lar çıktıkça daha da azalmaktadır.

2.3 Yapay Sinir Ağlarının Kullanım Alanları

YSA'lar tıbbi tahlil,üretim hesaplama,petrol arama,ses tanıma,uçuş kontrolü,yeryüzü şekli sınıflandırma,nehir yatağı akış tahmini,makine kontrol ve finansal tahmin gibi gerçek dünya uygulama alanlarında pratik uygulamalara sahiptir.YSA'ların finans sektöründe kullanıldığı bazı uygulamalar şunlardır;

Market trenlerindeki değişim	Kredi kartı uygulamaları
İpotek uygulamaları	Vergi tahminleri
Borsa tahminleri	Banka hata payı hesaplamaları
Stok işlemleri	Döviz tahminleri
Nakit akış tahminleri	Ürün tahminleri
Şirket içi finansal sağlık değerlendirme	Ekonomik gösterge tahmini
Opsiyon fiyatlandırma	Kapital market analizi
Yönetim karar verme tahminleri	Alım vergisi analizi
Satış prospekti seçimi	Güvenlik riski profili

Bir uygulamanın YSA ile gerçeklenebilmesi için birinci şart bu uygulama ile ilgili girdilerin belirlenebilmesi ve bu girdilerin matematiksel büyüklükler haline getirilebilmesi ve sonuç olarak bu uygulama sonucunun gene matematiksel büyüklükler haline getirilebilmesidir.Matematiksel olarak ifade edilebilen uygulamalar YSA'ların uygulama alanına girebilmektedir.

2.4 YSA'lar İçin Uygun Problemler

İnsan beyni çözmek için ne kadar problem öğrenebilirse YSA larda o kadar problem öğrenebilir.Burada tek kıstas üzerinde çalışılan problemin matematiksel

büyüklükler olarak ifade edilebilme zorunluluğudur.Öğrenim prosesi çok benzerdir ,tekrar eden durumu materyale döndürür ve doğru çözümün tekrar gerçeklenmesi için uğraşır.

Beyin 2+2 nin 4 olduğu problemini çözümlerken hiç çaba sarfetmez ve ayrıca elma ile papatyanın farklı olduğunu görebilmek için de bir uğraş vermez.Fakat YSA'nın 2+2 sorununa çözümü bu kadar basit değildir.Bazen 3.933 bazen de 4.008 gibi çözümler gelebilir.4.000 değeri ise çok nadiren gelebilir.Bu tip matematiksel problemler klasik hesap makineleri ve hesaplama teknikleri ile daha sağlıklı olarak çözülebilir.

Bununla birlikte YSA'ların bir elma ile papatyanın farklılığını ayırdetmesi sorun olmayacaktır.Her ikiside yuvarlaktır fakat elmanın daha düzgün ve sert bir yüzeyi papatyanın ise yumuşak ve kırılgan bir yapısı vardır.

3. YAPAR SİNİR AĞLARINA GENEL BİR BAKIŞ

3.1 Yapay Sinir Ağları İle İnsan Beyninin Karşılaştırması

YSA insan beyninin yaptığı gibi daha önceki tecrübelere dayanarak örnekleri sınıflandıran ve tahminde bulunan bir bilgisayar programlama mantığıdır.İnsan nöral girdilere dayanırken YSA vektörlere veya matematiksel değer dizilerini kullanır.

YSA'lar insan beyninden birkaç noktada ayrıdır.Sıkılmaz,kahve molası vermez,fiyat ödenmek zoruda değildir,tatile ihtiyacı yoktur,sadece çalışır. Kapasiteleri birkaçyüz hücrenin birkaçyüz milyar hücrenin kapasitesine göre ne azsa insan beynine göre o kadar azdır.Bu kapasite şu anki teknolojik konum ve bilgisayar hızları ile ilgilidir.

Bu küçüklük eğer başarı isteniyorsa çok fazla özelleşmeye gerek olduğu anlamına gelir.Bu özelleşme istenilen bilginin üzerine yoğunlaşmayı gerektirir.Bu sınırlandırmanın başka bir avantajı daha vardır.Bu bir YSA sonucunun çok spesifik olmasını engeller.Bu yüzden sınırlandırma daha hızlı,daha anlamlı ve genel cevaplar ortaya çıkmasını sağlar.

Başka bir fark da YSA'nın sadece sayılarla,insan beyninin ise 5 duyu organından aldığı girdilerle işlem yapıyor olmasıdır.YSA içindeki nöronların ara bağlantıları insan beynindekilere göre çok daha kısıtlıdır.Biyolojik bir nöron 1000 veya daha fazla nörona bağlı iken simule edilmiş bir YSA nöronu networkdeki gizli nöronların sayısına bağlı olarak bağlantı kurabilir.Bu çok nadiren yüzü bulabilir ve genellikle ondur.Bu fark Çizelge 3-1 de gösterilmiştir.

Faktör	Beyin	Nöral Network
Boyut	100 milyar nöron	Birkaç 100 nöron
Girişler	5 duyu	Data serileri
Çalışma Etiği	Genelde sıkılan ve dikkati dapılan	Mekanik,sadece istenileni yapan
Özelleşme	Birçok ilgi ve yetenek fakat kolayca ilgi dağılabilir	Sadece tek görev
Yapı	Biyolojik	Matematiksel
Nöron başına bağlantı sayısı	Ortalama 1000	Çok nadiren 100 ve daha az
Beyin yönü	Sağ ve sol olmak üzere 2	Sadece sağ taraf

Çizelge 3-1 İnsan beyni ile nöral networkler arası farklılıklar(Saad,E.W., S 13, 1998)

Bir YSA'nın eğitilmesi ve kullanıma geçilmesi için bazı adımların atılması gerekir ve herbir adım başarıya ulaşılması için önemlidir.Bu adımların genel bir açıklaması şöyledir;

Adım 1- Neyin tahmin edileceğinin belirlenmesi

Adım 2 – Tahmin edilecek değişken ile ilgili bilgi serilerinin toplanması : Bu bilgiler tahmin yapılmasında kullanılacaktır.

Adım 3 – Bilgiyi elde etmek için dataların daha uygun hale getirilmek üzere düzenlenmesi.

Adım 4 – Maksimum ve minimumların belirlenmesi : Datanın sınırlarının belirlenmesi,minimum ve maksimumların bu değerlere çekilmesi bu datayı işlemeyi daha etkili kılar çünkü sadece mantıklı olan data aralığında çalışmayı sağlayarak daha etkili sonuçlar elde edilmesinde yardımcı olur.Eğer data serileri 100 ve 200

aralığında ise minimum ve maksimumları 100 ve 1000 de tutmak yerine 100 ve 200 de tutmak çok daha etkili ve mantıklıdır.

Adım 5 – Test data serilerinin açılması : Daha önce görülmeyen data serileri ile networkü test etmek ve networkü eğitmek için bir kısım detayı gelecekteki testler için kullanmak faydalıdır.Bu yüzden toplam data serisi ikiye bölünür;birinci kısım eğitim ve ikinci kısım test.

Adım 6 – Uygun network yapısını seçmek : Networkler 3,4 veya 5 katmanlı olabilir ve gizli katmandaki nöronların sayısı değişiklik gösterebilir.Networkün bu değişiklik ihtimali network yapısı olarak adlandırılır.Bilinen 12 den fazla network yapısı vardır ve bazıları belli spesifik durumlar için daha iyi sonuçlar vermektedir.

Adım 7 – Uygun bir eğitim algoritması seçmek : Belli network yapılarında kullanılabilecek birkaç algoritma (eğitim metodu) vardır.Bazı problemlerde bazı algoritmalar daha iyi sonuçlar verir.

Adım 8 – Network eğitimi : Belli bir eğitim algoritması ve yapısına bilgilerin uygulanması.Bu nöronların bağlandığı ağırlıkların ayarlanmasını sağlar ve bu sayede network benzer data serilerinde daha iyi tahmin sonuçları verir.

Adım 9 – Network ün kullanılması : Yeni data serilerinin veya o anki datayı tahmin sonuçlarının elde etmek üzere networke uygulanması.

YSA'ların gelişmiş özelliklerine rağmen her probleme çözüm olamazlar. YSA'lar örnek eşleştirme,kompleks ilişki veya bilginin seçime bağlı kullanımını gerektiren problemlerde faydalı olmaktadır.

3.2 Neyin Tahmin Edileceğinin Belirlenmesi

Başarılı bir işlem için neyin tahmin edileceğinin seçilmesi önemli bir aşamadır.Eğer IMKB'nin bir sonraki kapanış değerini tahmin etmek istiyorsak ne yapabiliriz ?Eğer endeks 15.000 ler cıvarındaysa ve günde ortalama 50 puan

değişiyorsa bu durumda endeksi tam olarak tahmin edebilmek % 0.33 oranında olasıdır. Eğer biz IMKB endeksini +-5 hata payı ile tahmin etmek istiyorsak % 0,033 hata payı ile tahmin etmek istiyoruz anlamına gelir.Eğer biz sadece artış oranını 10 puan gibi bir farkla tahmin etmek istiyorsa bu durumda gerçekleşme oranı %20 ye çıkar (50 puanda 10 puan).Bu biraz farklıdır ve basit anlamda problemin farklı bir gözle görülmesi olarak ifade edilebilir.

Eğer biz endeksin yükseleceğinimi yoksa düşeceğinimi tahmin etmek istiyorsak ve bu değişimin aralığı önemli değilse bu endeksin değerini tahmin etmeye göre çok daha basit bir problemdir.Burda seçimi 2 den 1 e indirerek başarı oranını % 50 ye çıkartmış oluruz.

Neyin tahmin edileceğini seçerken çok farklı sorunlarla karşı karşıya kalabiliriz.Eğer bir IMBK endeksinin bugünden bir haftaki değerini tahmin etmek istiyorsak haftalık bilgi kullarak 1 hafta sonraki haftanın tahminini mi yaparız yoksa günlük bilgi kullanarak 5 gün sonrasının tahminini mi yaparız ?Günlük bilgillerin daha doğru sonuçlar verebileceğini düşünebiliriz fakat uzun vadeli bir tahminde haftalık bilgiyi kullanmak daha doğru olacaktır.Bu gibi bir durum için yapılabililecek en iyi çözüm her iki networkü de kurup networkü optimize etmek,onu eğitmek ve günlük sonuçlarla haftalık sonuçları kıyaslamak olur. (Arman,T.T., S 92-93,1997)

3.3 Data'nın Toplanması

Neyin tahmin edildiğinin seçilmesinde olduğu gibi doğru dataların seçimi sonucu büyük oranda etkileyebilir.Şu da bir gerçektir ki seçilecek dataların hepsi zamana bağımlı ve zamanla değişiklik gösteren tarzdadır.

3.4 Data'nın İşleme Uygun Hale Getirilmesi

Datalar bazen 50 kolon ve 1000 satırlık data serilerinde olabilir ve bu 50.000 hücrelik bir data serisi anlamına gelir.Tüm datalar hücrelerde olduğu zaman data

uygunlaştırılmalıdır.Market tahminlerinde hücre serilerinin uygunlaştırılması için bir örnek artan değerlerin azalan değerlere bölümünün alınması olabilir.Bu eşitlik 2 girdinin değerini taşır. Testler sonucu anlaşılmıştır ki artan data/azalan data eşitliği çoğu zaman birçok diğer girdilere göre çok daha büyük önem taşımaktadır.



Şekil 3-1 Tipik bir zaman serisi data grafiği.Uzun vade trendi görülmektedir. (Lowe, D., Webb, A. , S 17,1995)

Data uygunlaştırmada diğer bir yöntem de datanın normalize edilmesi olabilir.Örneğin IMKB 100 endeksi 3 yıl önce 100.000 li değerlerdeyken şu an 15.000 li değerlerdedir ve ilk kurulduğunda bu değer 10.000 li değerlerdeydi.Bu farklılığın giderilmesine normalizasyon işlemi denilmektedir.Normalizasyon tarih bağımlı data bilgilerinin belli katsayılarla çarpılarak bugünkü değerlerine getirilme işlemidir.Şekil 3-1 ve 3-2 normalizasyon yapılmadan önce ve sonraki data eğrilerini göstermektedir.

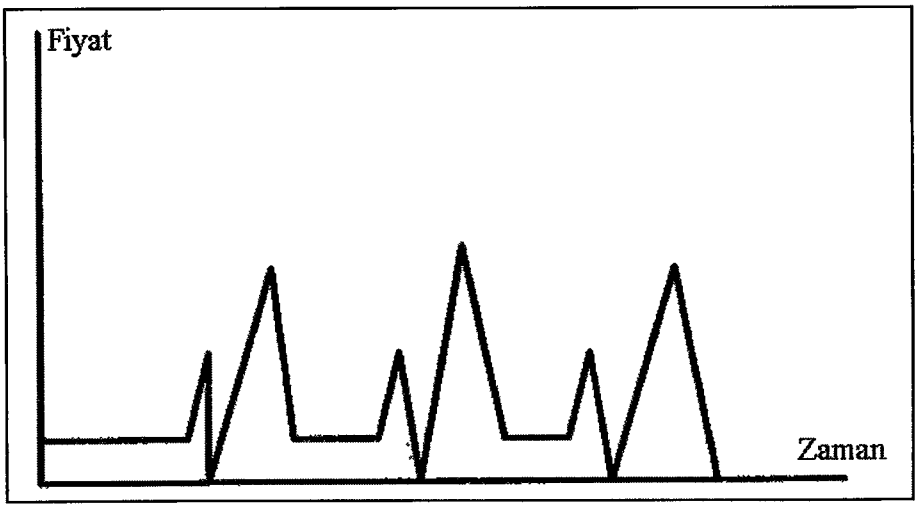

Şekil 3-2 Uzun vadeli trend kaldırıldıktan sonraki data grafiği. (Lowe, D., Webb, A. , S 17,1995)

Hücre şeklindeki data serileri uygunlaştırma yapıldıktan sonra tahmin yapan programlara girdi olarak verilmekte veya bazı programlar direk olarak hücre şeklindeki data serilerini işleyebilmektedir.Bu işlem esnasında YSA programı data serisi içindeki maksimum ve minimum değerleri çıkarmaktadır.Bu networkü bir sınır dahilinde inceleyebilmek için gereklidir.

3.5 Test Datasının Açılması

Bir sonraki işlemde ise datalar 2 veya 3 gruba ayrılmaktadir.İlk seri eğitim seti ikinci set ise test seti olarak adlandırılmaktadır.Normalde toplam datanın yüzde onluk bir kısmı test datası olarak ayrılır.Eğitim dataları ise networkün örnekleri ve ilişkileri ortaya çıkarmak için kullandığı data serileridir.Test dataları ise eğitim sonucu çıkan bilgilerin test edildiği ve eğitim datalarının içinde olmayan dolayısıyla networkün daha önce görmediği datalardır.Sadece test datası ile networkün doğru eğitilip eğitilmediği veya ne kadar doğru sonuçlar alınabileceği anlaşılabilir.Bazen datalar bir sonraki test aşaması için üçe bölünebilir. Test dataları bazen rastgele seçilebilir,örneğin her 10 datadan birisi veya 2 tarih aralığı arasındaki tüm datalar test datası olarak alınabilir.Her metod neyin yapılmak istendiğine göre farklı avantajlara sahiptir.

3.6 Network Yapısı

Bir sonraki adım uygun bir network yapısının seçilmesidir. Problemlerin yüzde seksenbeşi 3 katmanlı geri yayılımlı (back-propagation) bir networkde eğitilir.Geri yayılımlı network tahmin sonucunu güncel olan sonuçla karşılaştıran ve nöranlar arasındaki bağlantıları bu 2 sonuç arasındaki farka göre ayarlayan bir network çeşididir.Network yazılım paketlerinin 15 den farklı network yapısı olabilir.Bu yapılardan bazıları çok özelleşmiş olabilir.Genel olarak 2 katmanlı geri yayılımlı network yapıları kullanılmaktadır çünkü bu tip networkler en pratik ve en doğru sonuçları verebilen tiptir.

3.7 Algoritmanın Eğitilmesi

Bir sonraki adımda eğitim algoritması seçilmesi zorunludur, algoritma ilişkileri ve örnekleri bulmak üzere kullanılan formüldür. Momentum en sık kullanılan algoritma olmasına rağmen YSA programları yapan şirketler genellikle kendi algoritmalarını geliştirip kullanırlar.Networklerin çok büyük bir kısmı birkaç farklı momentum algotirması kullanılarak eğitilirler.Seçimler yapıldıktan sonra eğitim kısmına geçilebilir.

3.8 Eğitme ve Test Etne

Eğitim prosesi sırasında giriş datasının ilk kolonu alınır ve networke uygulanır.Daha sonra network bir tahmin yapar ve sonucu ,doğru bilgiyi içeren kolonla karşılaştırır.Hatayı kaydeder,nöronlar arası bağlantıları tekrar düzeltir ve bir sonraki kolona geçiş işlemi tekrarlar.Tüm data işlendikten sonra tekrar başa dönülür ve bu işlem defalarca tekrarlanır.Tüm dataların meydana çıkarılma işlemi "devir" (depoch) olarak adlandırılır (Şekil 3-3).Bir network için binlerce epoch'a , milyonlarca kolon detaya bakmak sonuçları değerlendirma işlemi sırasında sıradışı bir olay değildir.

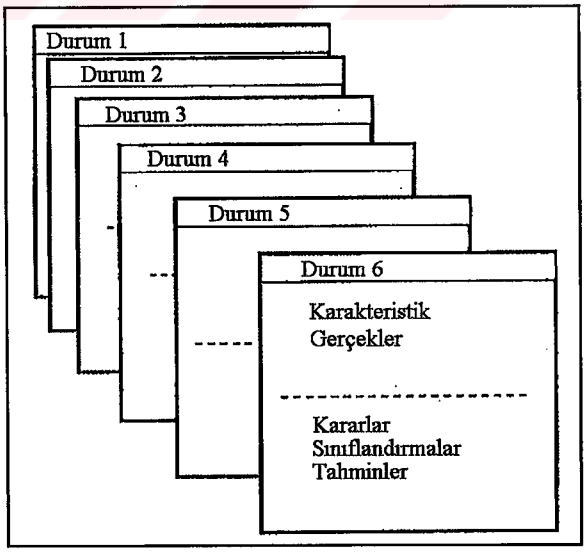

Şekil 3-3 Beyin için data nın organize edilmesi.

Nöronlar arası bağlantılara ağırlık adı verilmektedir.Networkü unik (kendine özel) yapan bu nöronlar arası bağlantılardır.Görünür olarak benzer 6 girişli,6 gizli nöronlu,3 katmanlı ve bir çıkışlı 2 networkün farkı nöronları arasındaki bağlantıların kuvvetidir.

Bazı yazılım programları eğitim işlemi sırasında networkü etkili bir şekilde eğilip eğitilmediğini anlamak üzere test eder.Periyodik olarak (örneğin data üzerine 200 işlem yapıldıktan sonra) eğitim işlemi durdurulur ve network test datası kullanılarak kontrol edilir.Bu periyodik durmalar ve tekrar başlamalar artık bu işlemler sonucu networkde bir iyileşme görünmemeye başlayıncaya kadar devam eder.Daha sonra ki eğitimler networkü geliştirmede başarısızlığa uğradığında datalar kaydedilir ve eğitim son bulur.Eğer yazılım programları bunları otomatik olarak yapamıyorsa network elle durdurulup testler yapılmalıdır.

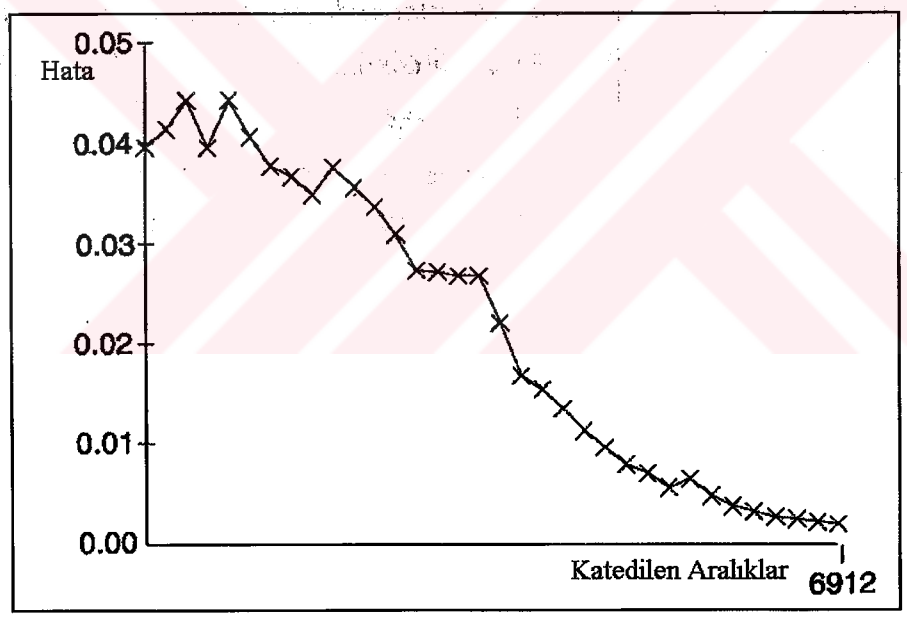

Şekil 3-4 6912 öğrenme olayından sonra bir networkün hata grafiği.

(Lowe, D., Webb, A. , S 29,1995)

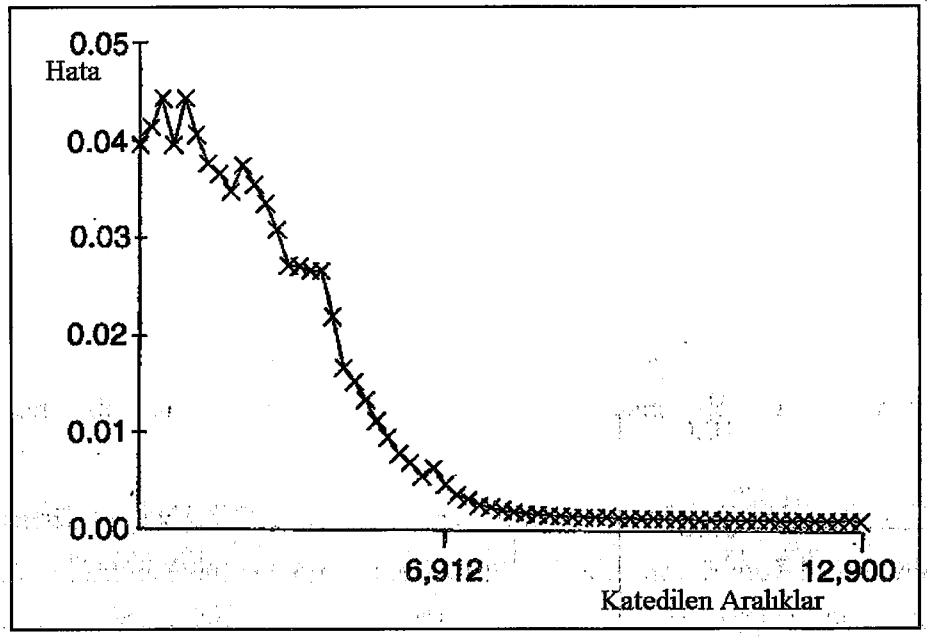

Şekil 3-5 12900 öğrenme olayından sonra hata eğrisi. (Lowe, D., Webb, A. , S 30,1995)

Şekil 3-4 ve 3-5 eğitim işlemi devam ederken networkün hata örneklerini göstermektedir.Dikkat edilecek olursa eğitimin ilk safhalarında hata oranlarının yüksek ilerleyen safhalarda ise daha düşük olduğu gözlenebilir ve belli bir seviyeden sonra artık hata oranı düşmemeye başlar.Bu noktada artık network öğrenmemeye başlar. (Gately,E.,S-23,1996)

Eğer öğrenmenin bittiği noktada eğitim devam ettirilirse artık network doğru cevapları ezberlemeye başlar ve hata oranı artmaya başlar.

4. NEYİN TAHMİN EDİLECEĞİNİN VE UYGUN GİRİŞLERİN SEÇİMİ

Tahmin edilecek optimistik bir hedef seçimi,giriş serilerinin temini ve seçimi,uygun bir öğrenim algoritması ile network yapısının eğitilmesi çok önemlidir.Aşağıdaki aşamalar yapıldığında başarı oranı daha da yükselmektedir:

1- Üzerinde çalışılmış bir hedef çıktısının seçilmesi .
2- Seçilen çıktıya uygun girdilerin seçilmesi.
3- Optimum Yapay sinir ağı yapısının ve eğitim algoritmasının seçilmesi.

4.1 Zaman Serileri Tahmini – Kesin Değer

IMKB'nin 5-10 periyodluk dilimlerinde tahminlerde bulunmak çok etkili değildir.Örneğin IMKB şu sıralarda 15.000 seviyelerinde seyretmekte ve ortalama günlük değişimi 50 puan veya % 3.3 civarlarındadır.Haftalık değişimin daha az veya daha fazla olduğu haftalar da görülebilir fakat ortalama olarak değişim bu değerdedir.Faydalı olabilmesi için IMKB endeksi ile ilgili tahminlerin 10 puan veya % 0.66 dan fazla hata payına sahip olmaması gerekir.IMKB'nin dinamik ve çok değişken yapısı göz önüne alındığında bu hedef çok gerçekçi görünmeyebilir.Bu yüzden daha yüksek toleranslı ve geniş aralıklı tahminler yapmak daha iyi sonuçlar verecektir.

Örneğin endeks tahmini yerine IMKB endeksindeki değişimi tahmin etmek istersek hata seviyesindeki tolerans daha büyük olabilir.Eğer IMKB deki ortalama değişim 50 puan olduğu düşünülürse ve hata payımız %20 lik dilimde ise,hala 4 ana hedefimiz vardır fakat hata payı tolerans değeri dramatik bir şekilde %0.1 den 20 ye yükselmiş olmaktadır.%20 hata paylı bir tahmin % 0.1 lik bir tahmine göre çok çok daha kolaydır.

Zaman serisi tahmininde gerçek değer yerine tahmini olarak kullanılan değişkenler aşağıdakileri içerir :

1-En son fiyat değişimleri

2-Son data'nın düşüşümü yoksa yükselişimi gösterdiği

3-Satmanınmı almanın mı yoksa elde tutmanın mı mantıklı olduğu

4-Tahmin edilen tarihdeki data'nın tavan veya tabanı gösterip göstermediği

5-Tahmin periyodu içindeki değer değişimi

6- Trendin aşağı mı yoksa yukarı mı olduğu

7-Değişim yüzdesi

8-Bulunulan zaman diliminin tahmin yapmaya uygun olup olmadığı

9-En son datanın trend değişimini gösterip göstermediği

5.GİRİŞ DATALARININ SEÇİMİ

5.1 Uygun Girişlerin Seçimi

Hedefle ilgili uygun girişlerin seçimi en uygun tahmin yapılabilecek hedefin seçimi kadar önemlidir.Örneğin S&P endeksinin 5 gün sonraki değerini tahmin ederken girişlerin seçimi hem de tahmin oldukça güçtür çünkü hem girişler hem de hedef çıkışlar zaman serileri tahmini için oldukça gürültülüdür.Datada çok fazla rastgele hareket vardır ve by da genel bir hareket şekli çıkarılmasını güçleştirir.

Zaman serili tahminlerde giriş değerleri bir gün artık diğer gün düşüp bir sonraki gün ise sabit kalabilmektedir.Burada zor olan örneğin o günkü yükselişin bir gürültümü yoksa önemli bir değermi olduğunu anlayabilmektir.Eğer giriş bir sonraki ay düşerse bu durumda o günkü yükselişin bir gürültü olduğu sonucuna varabiliriz.

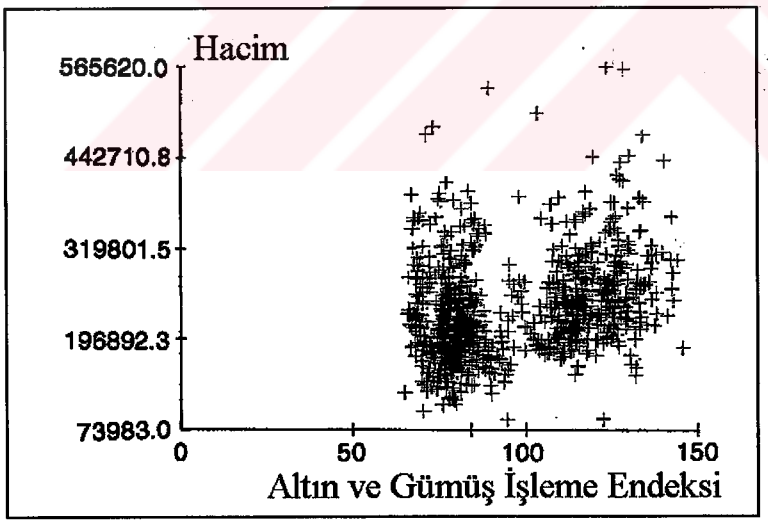

Şekil 5-1 Grafikten de anlaşılabileceği gibi iki değer arasında ilişki yoktur. (Felsen, J. , S 52 , 1990)

5.2 Korelasyon ve Katkı Ölçüm Programları

Birçok YSA programı uygun girişlerin seçiminde bir veya birden fazla alt programla birlikte çalışır.Bu alt program girişlerin tahmin edilecek hedefle ilgisinin olup olmadığını tespit etmede ana programa yardımcı olur.Bu tahmini yapılacak hedef ile giriş arasındaki korelasyonu verir.Bu alt program genellikle iki değişken arasındaki korelasyonu 2 boyutlu bir grafik olarak verir ve anlaşılması oldukça kolaydır.Şekil 5-1 New York borsasında altın ve gümüş çıkarma endeksini gösterir.Şekilden de anlaşılabileceği gibi tam anlamıyla bir korelasyon yoktur çünkü noktalar belli bir form oluşturmamışlardır.Klasik bir korelasyon sonucu çıkan noktalar bir daire oluştururlar.Şekil 5-2 OEX ile Dow taşımacılık endeksinin korelasyonunu gösterir.Bu şekilde diagonal olarak üst sağ köşeye doğru hareket eden güzel bir koralasyon eğrisi vardır.

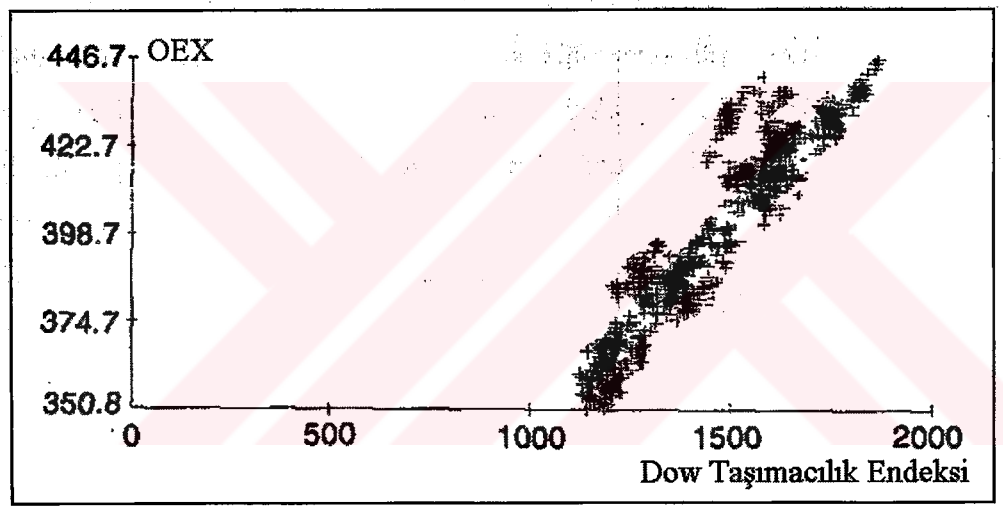

Şekil 5-2 Yukarıdaki şekil göstermekedir ki bu 2 değişken arasında korelasyon bulunmamaktadır. (Felsen, J. , S 52 , 1990)

YSA programlarında kullanılan 2. Alt program network eğitildikten sonra her girişin çıkışa katkısını ölçen alt programdır. Bu genellikle her girişe bağlanan her ağırlığın toplanması ile hesaplanır.Çok fazla ağırlığa sahip bir giriş az ağırlığa sahip bir girişe göre çok daha etkili ve önemlidir.

Korelasyon faktörünün 10'un altındaki değerleri için ADV (New York borsasındaki artış sayısı), DEC (New York Borsasındaki düşüş sayısı) , TRIN (Toplam yükseliş/toplam düşüş katsayısının yükseliş hacmi/düşüş hacmi katsayısına

bölünmesi ile hesaplanır) TICK (İşlem hacmi) değerleri normalde network için uygun girdiler olarak kabul edilmezler.Bununla birlikte tahminlere toplam katkısı düşünüldüğünde bu değerlerin gene de yarısı giriş değeri olarak alınmaya uygundur.Bu gösteriyorki giriş değerleri seçilirken her örnek yöntem göz önüne alınıp giriş değerleri bu yöntemlerin sonuçlarından sonra seçilmelidir.Şekil 4-3 her girişin networke olan bağımlı katkısını grafiksel olarak göstermektedir(Saad,E.W,S-1124,1998).

5.3 Bir YSA Problemi Olarak İpotek İmzalama

İpotek imzalama problemi görünüş olarak kolay olmasına rağmen girişlerin belirlenmesi ve imzalamanın iyi mi yoksa kötü mü olduğunun karar verilmesi göz önüne alındığında zor bir örnektir.İpotek imzalam probleminin muhtemel girdilerinin bazıları şunlarıdır :

- Yıllık kazanç
- Yıllık harcama
- Daha önceki ev sahipliği
- Daha önceki evde ikametgah süresi
- Daha önceki işte çalışma süresi
- Şu an ki işteki kariyer imkanları
- Kredi kartı bilgileri
- Toplam ipotek değeri
- Kazancın gidere oranı
- Ev alım gideririnin gelen kazanca oranı
- Toplam borç ödemelerinin kazanca oranı
- Maaş dışı gelirlerin toplam gelire oranı
- Maaş dışı gelirlerin devam etme olasılığı
- Harcamalarda hediye gibi sıradışı harcamaların oranı
- Daha önceki banka hesaplarının tarihçesi
- Borçların sayısı
- İş cinsi ? Maaşlı veya kendi işini mi yapıyor ?
- Faiz miktarı

- Faiz süresi
- Ortalam değer
- Evin yeri

İpotek problemlerinin uzun vadeli düşünülmesi gerektiğinden dolayı YSA lar açısından zor problemlerdir.Hedef çıktı seçiminde bazı yaklaşımlar aşağıdaki gibidir;

1. İpotekler konusunda bilgili uzmanlarla birlikte çalışmak
2. Faizler genellikle ilk 3 yıl için kötüye gitmez,3. Yıldan sonra 5. Yıla kadar ağırlaşmaya başlarlar.Bu yüzden 5-10 yıl aralıklı datalar kullanmak gerekir.Kötü bir faizi belirlemek için kullanılacak kriter ne olmalıdır ? Önemli sorulardan birisi de budur.Örneğin faiz ödemeleri geciktiğinde uygulanacak yaptırımlar ve cezalarda önem kazanır(Cheng,W; Wagner,L;Lin,C.H.,S-223,1996).
3. 5 yıldan daha eski uygulamalar kullanarak networkü eğitmeyi düşünüyorsak 5 yıl önceki duruma göre ekonomik durumdaki değişimleri gözönüne almamız gerekir.

İpotek problemi networkünü eğitmek için öncelikle uygun dataların seçimi çok önemli ve zordur.

5.4 Zaman Serisi Tahminleri

Zaman serisi tahminleri endeks tahminleri yapılırken kullanılır ve zaman serisi girişleri iki gruba ayrılabilir.İlk giriş türü temel faktörlere dayanır.Bunlar altın fiyatı,dolar/yen paritesi,dolar/pound paritesi, dolar/mark paritesi,benzin fiyatı, gayrisafi milli hasıla,enflasyon,devlet politikası ve başka benzer değişkenlerdir.

İkinci grup teknik göstergeleri içerir.Bunlar volativite,bağımlı güç enkeksi (Relative Strenght Index RSI),averaj yönsel hareket (Average Directional Movement ADX),günlük maksimum minimum ve kapanış değerleri,günlük işlem hacmi,hareketli ortalamalar,stokastik göstergeler gibi benzer göstergeleri içermektedir.

Teknik göstergeleri kullanarak başarılı tahminlerde bulunmak oldukça zor bir işlemdir.Temel dataları kullanarak tüm parametrelerin test edildiği ve maksimize edildiği bir nöral network daha yüksek başarı oranına sahiptir.Temel dataların kullanıldığı bir networke teknik göstergelerin eklenmesi başarı oranını arttırabilir.

Teknik göstergelerin etkilerini görmek amacıyla teknik göstergeler bir networke 7. Giriş datası olarak uygulanıp karşılaştırmalı sonuçların elde edildiği bir örnek şöyledir ;

Bu örnekte girişler 6 dan 7 ye yükseltildiği için gizli katmandaki nöronların sayısını da 6 dan 7 ye yükseltmek gerekmektedir.Şekil 5-3 den 5-12 e kadar olan şekiller orjinal 6 girişli bir network ile 7. Giriş eklenmiş bir network arasındaki karşılaştırmalı grafikleri göstermektedir.Şekil 5-3 6 girişin kullanıldığı temel bir benchmark sistemidir.Şekil 5-5 şekil 5-3 ile karşılaştırıldığında belirgin bir fark gözlemlenebilir.Networklerin 3 tanesi benchmark sisteme göre daha görü R-kare değerlerine sahiptir.Bu gösteriyor ki bazı girişlerin eklenmesi başarı oranını düşürmektedir.(John,G.H.;Zhao,Y,S 112,1997).

Bu sonuçlar gösteriyorki bir networkün girişlerinin seçimi çok önemlidir ve çok titizlikle çalışılması gereken bir konudur.Girişler seçildikten sonra optimum karışımın seçilip seçilmediğinin anlaşılması için testler yapılıp networkün iyiye gidip gitmediği kontrol edilmelidir.

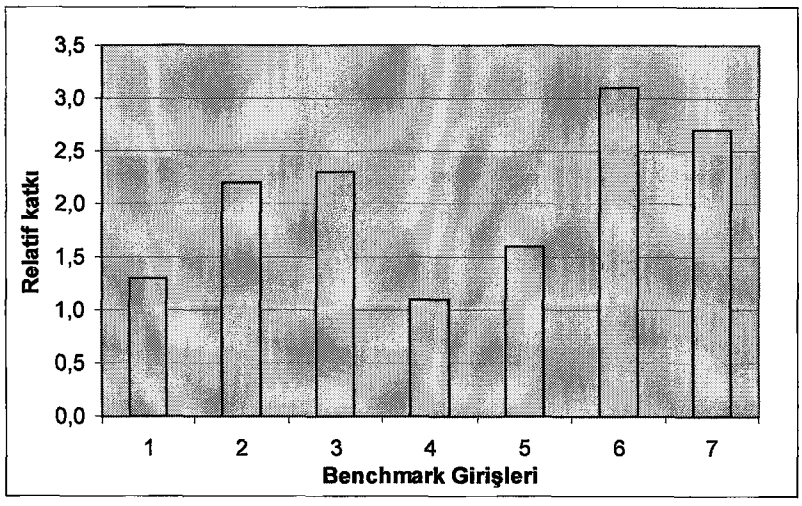

Şekil 5-3 Bu grafik benchmark networke farklı teknik göstergeler eklemenin etkisini göstermektedir.

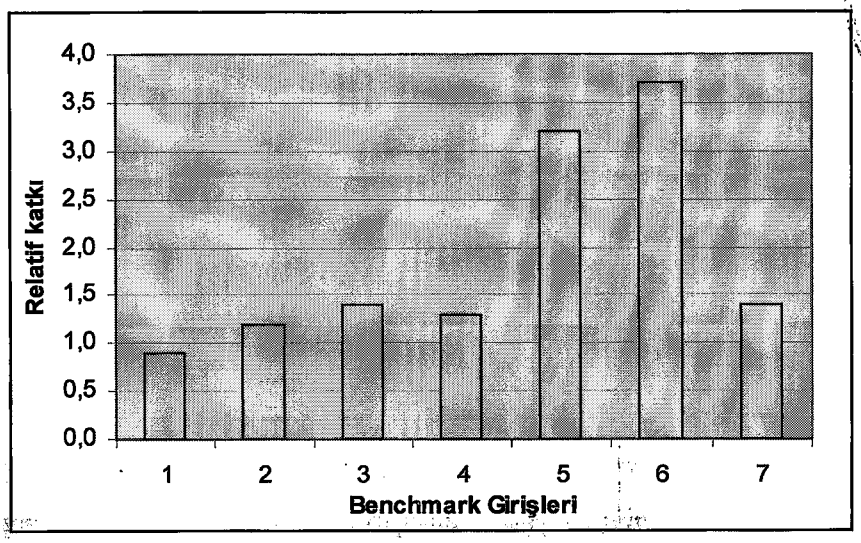

Şekil 5-4 5 periyotlu hareketli ortalamalı SPY değeri 10 periyotlu değerden çıkarılmış ve 7. Giriş olarak eklenmiştir.

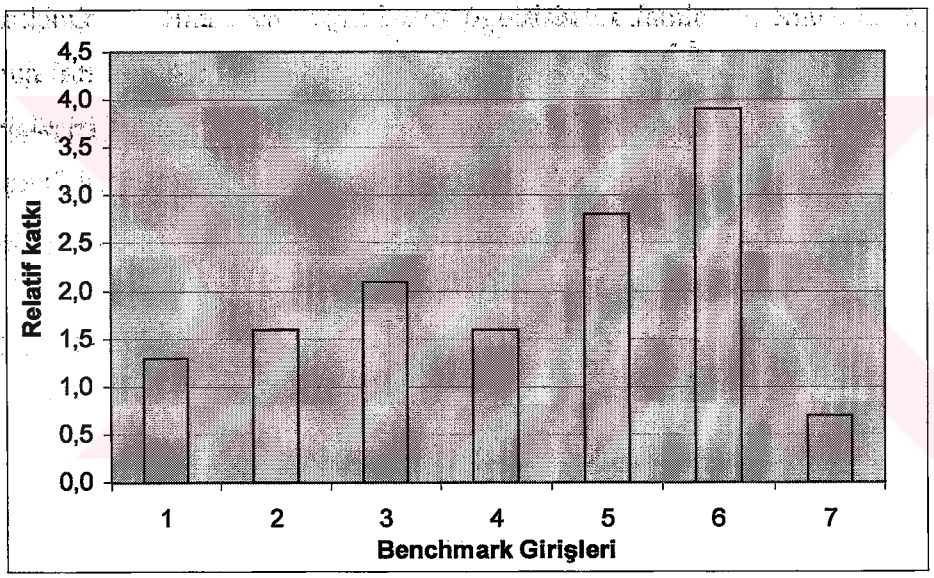

Şekil 5-5 Momentum göstergeli bir benchmark.

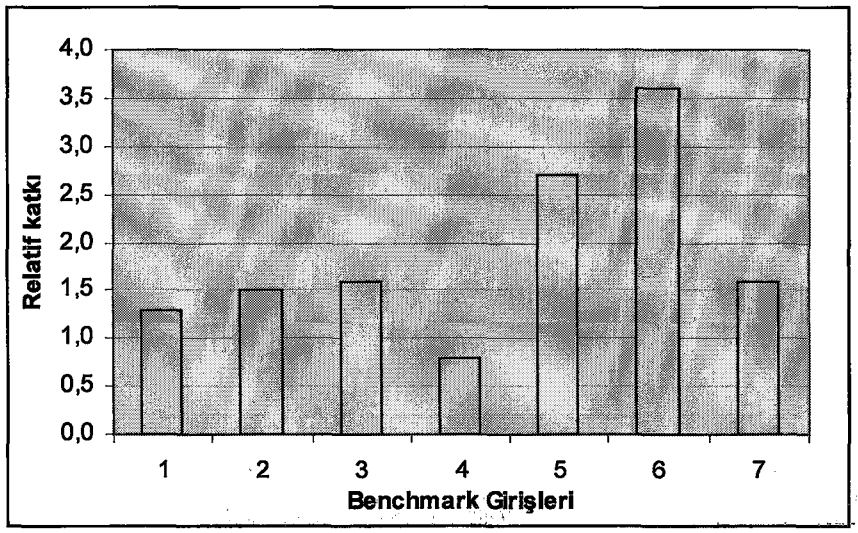

Şekil 5-6 14 periyot stokastikli bir network

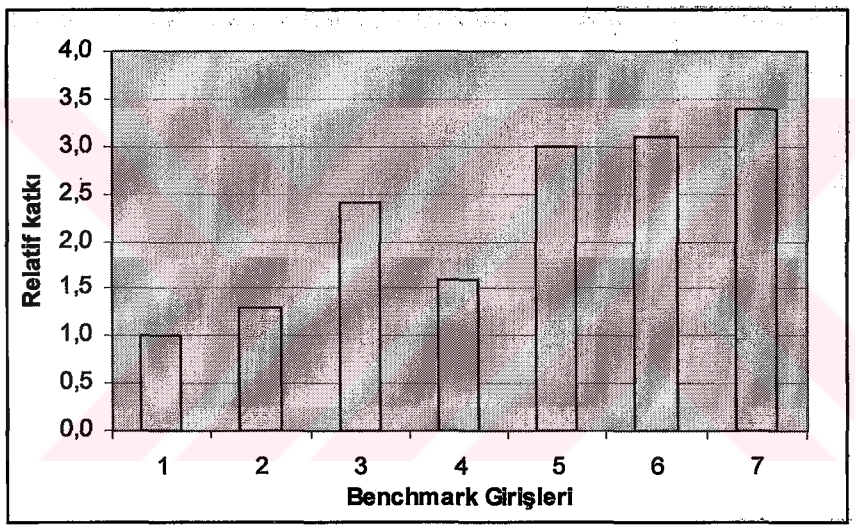

Şekil 5-7 SPY nin 10 günlük hareketli ortalamı network.

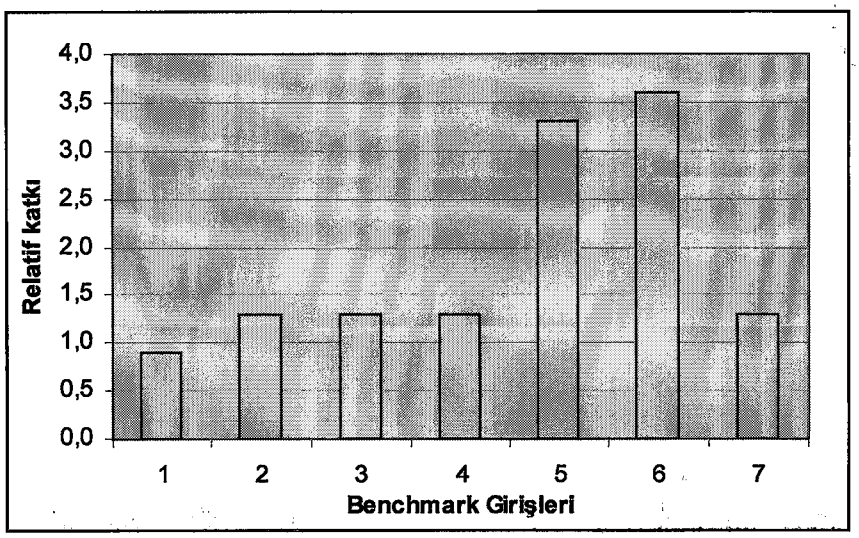

Şekil 5-8 7. Giriş olarak MACD (Moving Average Convergence/Divergence Indicator) kullanılan bir benchmark.

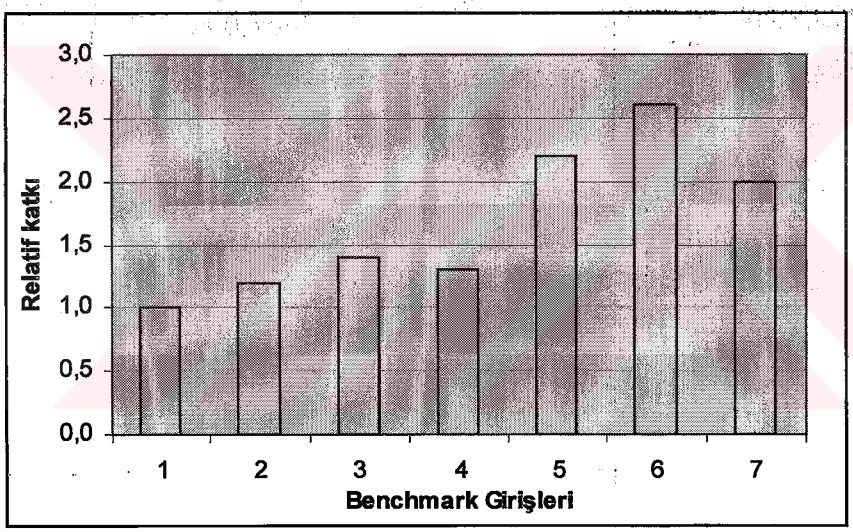

Şekil 5-9 SPY nin 10 günlük gecikmeli değeri 7. Giriş olarak kullanılmış bir benchmark.

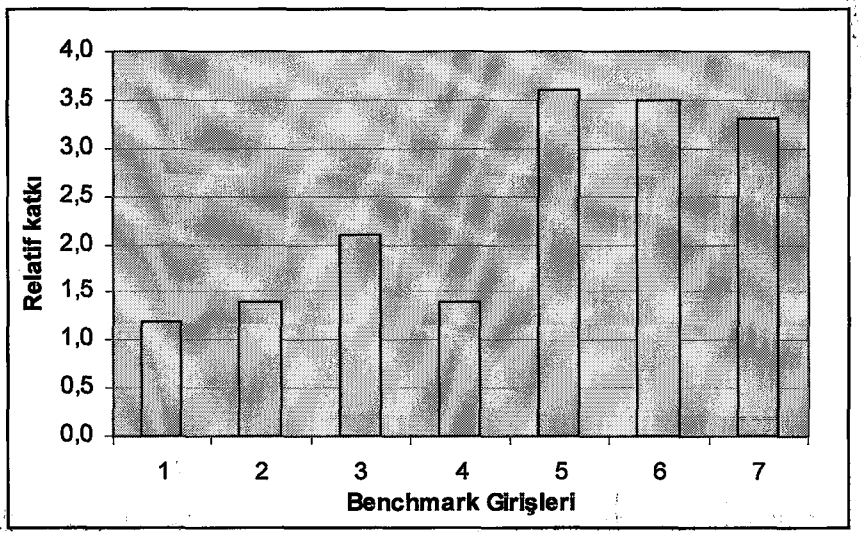

Şekil 5-10 SPY nin 5 periyotlu hareketli ortalaması 7. Giriş olarak kullanılmış bir benchmark.

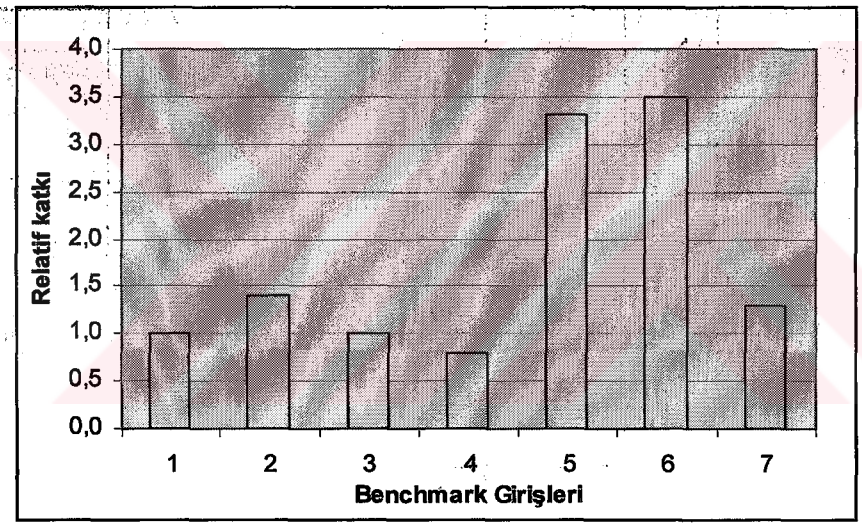

Şekil 5-11 12 periyotlu relative güç indeksinin (RSI – Relative Strength Index) 12 periyotlu hareketli ortalaması 7. Giriş olarak uygulanmış bir benchmark.

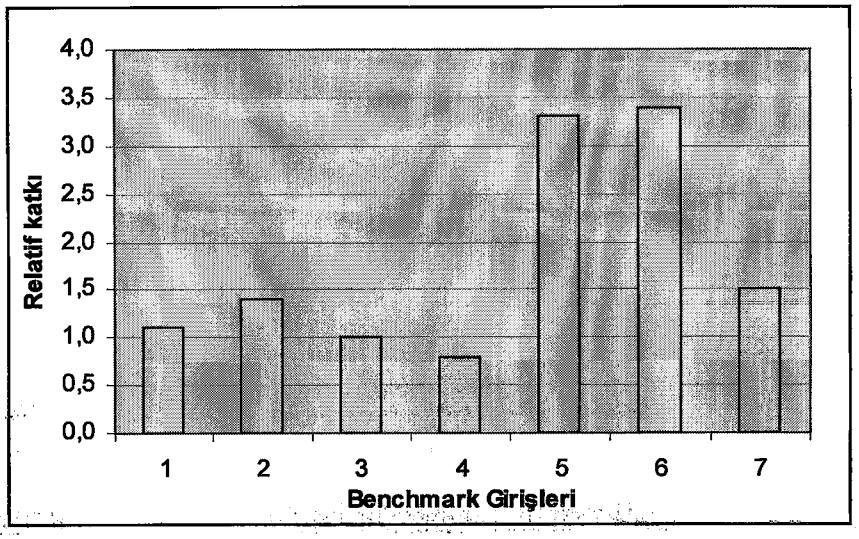

Şekil 5-12 12 periyot RSI lı bir benchmark.

T.C. 134

6. DATANIN HAZIRLANMASI

Bu bölüm uygun girişlerin seçilmesi ve networkün eğitilmesi safhaları arasındaki kalan bölümün açıklandığı kısımdır.Ayrıca bu bölümde network performansının arttırılması için data üzerine yapılabilecek işlemler de işlenecektir.

6.1 Hücre Formatlı Giriş Dataları (Spreadsheets)

Giriş ve çıkış datası networkte spreadsheet formlarında kullanılır. Giriş datalarındaki kolonlar networkün giriş datalarından herhangi birisinin seri değerleri olabilir.

Şekil 6-1 bir benchmark networkünün spreadsheet'in ilk 50 satırının değerlerini göstermektedir.Dikkat edilirse Lag (5) isimli kolonunda 2 ve 6 numaralı kolonlar arasında data bulunmamaktadır. Bunun nedeni Lag bilgilerinin referans datalarının hesaplanabilmesi için kaydırılarak kaydedilmesidir.YSA programı bu bu satırları ihmal etmektedir çünkü datanın eksik olduğunu düşünmektedir.Bazı YSA programlarında ise bu satırlar silinmektedir.Hareketli ortalama değerleri de bazı data serilerinde eksik satırlara neden olmaktadır.Eğer 10 günlük bir hareketli ortalama oluşturulacaksa ilk 9 satır eksik olmaktadır.

Tahmin edilecek örnekde de buna benzer bir sonuç oluşmaktadır. Örneğin 5 gün sonrasının tahmini yapılacaksa data 5 satır kaydırılmaktadır.Bu spreadsheet'in en alt 5 satırının boş kalmasına neden olur.Bu satırlar network tarafından kullanılmayacak şekilde adımlar atılmalıdır. (Saad,E.W., S 12-13, 1998)

6.2 Spreadsheet'in Oluşturulması

Spreadsheet'in oluşturulması için öncelikle datanın toplanması gerekmektedir.Bu daha çok data temin eden şirketlerden temin edilerek yapılmaktadır.Eğer endeks bilgileri isteniyorsa istenilen zaman dilimindeki endeks

bilgileri bir dosyada saklanır.Ve kullanılmak istenilen her bilgi ayrı ayrı dosyalarda muhafaza edilir.

Data genellikle metastock gibi bir programdan da elde edilebilir. Eğer alınan data text dosyasındaysa bu bilginin spreadsheet'e aktarılması gerekmektedir.Gerekli tüm bilgiler elde edildikten sonra bu bilgiler spreadsheet'in kolonlarına zaman bağımlı olarak yerleştirilir.

Giriş 1	Giriş 2	Giriş 3	Giriş 4	Giriş 5
0	1	4	2000	12360
0	2	6	2200	9300
0	1	3	1200	7500
0	4	8	2500	27200
1	6	11	3500	32000
1	9	20	6000	44350
1	8	23	6450	47800
1	10	25	7000	52000
1	10	18	5700	48290
0	7	12	4800	32000
0	2	6	2000	16000
0	3	6	3300	10000
0	1	5	2500	15000
0	2	8	3250	8400
0	1	2	1000	10300
0	6	8	2500	30000
1	9	15	4300	35000
1	11	25	7300	49050
1	9	23	6450	52460
1	10	27	7500	60000
1	9	16	5400	55800
0	7	15	5000	42500
0	5	5	1800	22000
0	3	6	3300	23000

Şekil 6-1 Tipik bir nöral network Spreadsheet'i

Zamanın bu data serisinde yerleştirilmesi oldukça önemlidir,yani her data alındığında yanında zaman bilgisi de olmalıdır.Tüm data tek bir spreadsheet de toplandıktan sonra satır satır tüm tarihlerin girilip girilmediği ve doğru olup olmadığı kontrol edilmelidir.Ayrıca farklı marketler farklı zaman şablonlarına sahip olabilir,örneğin İsrail'de cumartesi günü tatil yapılırken Avrupa ve Amerika'da pazar günü tatil yapılmaktadır.Bu gibi farklı çalışma tarihleri olan yerlerin dataları kullanılırken uygun eşleştirmeler yapılmalıdır.Eksik bilgilerin olduğu satırlarda ise

boş bırakmak programın işleyişi açısından sorun yaratacaksa boş kalan kısımlara tüm kolonların ortalama değerleri yazılabilir.Bazı YSA programları kolon ve satırların eksiksiz olmasını istemektedir,eksik olan satırları silmektense eksik yerleri ortalama değerlerle doldurmak daha doğru ve başarılı sonuçlar vermektedir.

6.3 Data'nın Önişlenmesi

Data elde edildikten,tarih bilgisinin doğruluğu kontrol edildikten ve eksik satırlar düzeltikten sonraki işlem önişleme safhasıdır.Bu işlem datanın bir spreadsheet'e aktarılması veya direk YSA programına giriş bilgisi olarak aktarılarak yapılabilir.Bazı YSA programları geleneksel spreadsheet'lerden de data girişine imkan vermektedir.Eğer YSA programı teknik analiz paketlerinden bilgi okuyamıyorsa bu durumda teknik analiz paketlerinden göstergeleri alamaz ve bu durumda teknik analiz formüllerinin direkt olarak spreadsheet'e girilmesi gerekmektedir.

Daha önce de gösterilmiştir ki networkler giriş datalarının birebir değerlerinin kullanılmasındansa giriş datalarındaki değişimler kullanıldığında daha başarılı sonuçlar elde edilebilmektedir.Girişlere yapılan bu tür bir değişiklik önişleme olarak adlandırılır.Önişleme bir networkün daha başarılı sonuçlar çıkarabilmesi açısıdan oldukça önemlidir.Önişlemenin birkaç faydası vardır,bunlar şu şekilde sıralanabilir ;

1.Networkün kullanımı için daha uygun data hazırlanmasına yardımcı olur: Birebir değerdense giriş değerindeki değişimin kullanılması tahmini daha başarılı yapmaktadır.Network değişim değerlerini kullanarak daha başarılı sonuçlar vermektedir.Birebir değerler kullanıldığında datanın sadece belirli bir kısmı network için anlamlıdır.

2.2 değişken network için daha anlamlı olan tek bir giriş değerine indirilebilir: Örneğin artış ve düşüş değerlerini ayrı ayrı girişler olarak vermektense bunların birbirine olan oranını tek bir giriş olarak networke uygulamak daha başarılı sonuçlar vermektedir.Bu işlem datayı genelleştirmeye yaramaktadır.Ayrıca iki değişken tek bir değişkene indirildiği için network'e daha az işlem yükü binmektedir.

Datanın önişlenmesinde diğer uygulanabilir metodlar teleskoplama, çıkartma,bölme,hareketli ortalamalar kullanma veya çoğullama olabilir.

6.3.1 Girişlerin Teleskoplanması – Lag'ler

Teleskoplama işlemi daha önceki tarihli dataların bir data serisinden seçilerek alınması işlemidir.Örneğin altın fiyatlarının 5 gün sonraki değerini tahmin etmek istiyorsak aşağıdaki teleskoplanmış dataları kullanabiliriz;

- Altın'ın bugünkü değeri
- 5 gün önceki değeri
- 10 gün önceki değeri
- 15 gün önceki değeri
- 20 gün önceki değeri

Şekil 6-2 her 6 giriş değerine 5 periyodlu bir lag eklemenin networke etkisini göstermektedir.Bu grafik ile ilgili 6 orjinal girişi ve bu girişlerin 5 periyod önceki değerlerini içeriyor denilebilir.Dikkat edilirse 7 ve 12 numaralı lag edilmiş girişler network'e orjinal girişler kadar katkıda bulunmaktadır.(Gately,E.,S-67,1996).

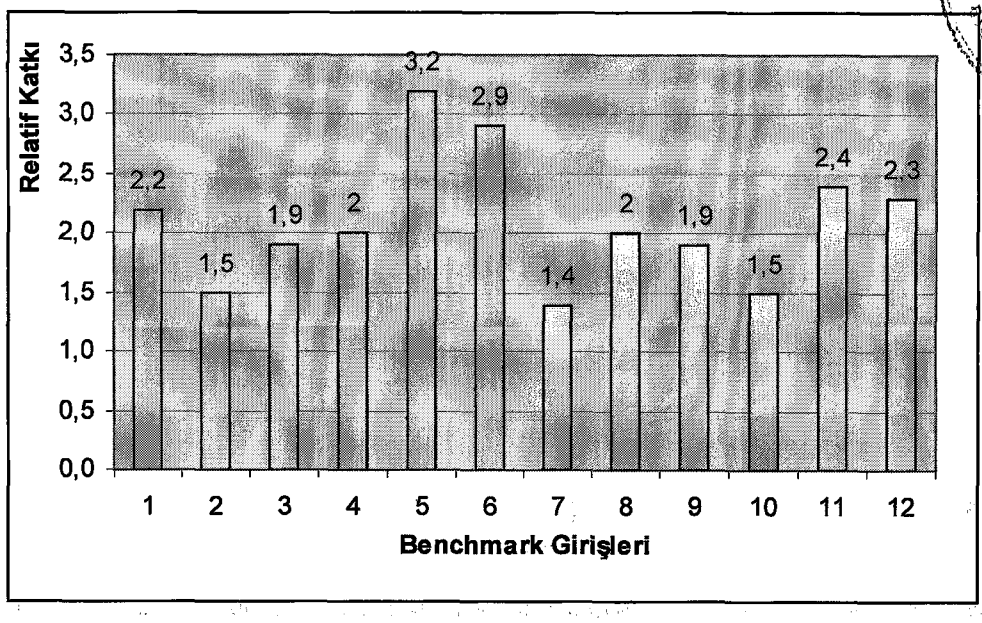

Şekil 6-2 Benchmark sistemine geciktirilmiş girişlerin eklenmesi.

6.3.2 Hareketli Ortalamalar

Hareketli ortalamalar kuvvetli bir önişleme yöntemidir.Kısa vadeli ,2-5 periyotlu hareketli ortalamalar genellikle rasgele dataları azaltmak ve gürültüyü yumuşatmak için kullanılmaktadır.Diğer uçta ise,uzun vadeli hareketli ortalamalar temel bir trendi simule edebilir.

6.3.3 Katkı Grafikleri

Katkı grafikleri her girişin networke ne kadar katkısının olduğunu gösterene grafiklerdir.Katkı grafikleri her girişe bağlanan ağırlıkların eklenmesi ile oluşturulmaktadır.5 değerinden yüksek değerler güçlü,0-2 aralığındaki değerler ise zayıf olarak nitelendirilmektedir.Bu grafikler girişlerin önizlenmesi ve önişlem sonuçlarının farklı yollardan değerlendirilmesi için kullanılmaktadır.Ayrıca bu yöntem lineer olmayan girişlerin de tespitinde yaralı olmaktadır.

6.3.4 Farklar

Diğer bir önişleme tekniği farkların kullanılmasıdır.Örneğin bugünün değerini 5,10,15 veya 20 gün öncesinin değerinden çıkarabilir. Farklar momentum adı verilen teknik göstergelerle aynı işlevi görmektedirler.

7. DATANIN İYİLEŞTİRİLMESİ

Tarihe bağımlı olarak dataların değişimi temel bir olaydır ve tahmin yaparken önemli bir etkendir.Tarihe bağımlı değişken dataya "sezonluk" data veya sezona bağlı değişim de denilebilir.Mevsimlik değişimler daha başarılı bir tahmin için yararlı olabilir.Tekrar eden takvim olayları veya sezona bağlı değişim,piyasaları etkileyip yeni örnekler ortaya çıkmasına neden olabilir.Bu bölümde bu faktörlerin nasıl kullanılacağından bahsedilecektir.

7.1 Mevsime Bağlı Değişim

Bazı marketler mevsime bağımlı büyük değişiklikler gösterirler.Bu değişim networke "mevsimsel değişim" adlı bir kolon eklenerek yansıtılabilir.Yılın düşün volativite değerini aldığı zamanlarda,örneğin mısır için kış aylarında bu kolonda 0 değeri kullanılabilir.Mahsülün toplanmaya başlandığı ve fiyatların değişmeye başladığı yaz aylarında ise bu kolon +1 değer konulabilir.Bu yolla networke ne seviyede bir volativite beklenilmesi gerektiği anlatılabilir.

7.1.1 Günlük ve Aylık Tanımlama

Örneğin eğer günlük olarak kaç adet banka teller'ına ihtiyaç olduğunu tahmin etmek istiyorsak,network bir şekilde haftanın farklı günlerini ayırtedebilmelidir.Salı günleri genellikle bankacılık işlemlerinin en az olduğu gündür ve cuma günü ise en yoğun gündür.Diğer günlerde ise bölgeler göre farklılık gösterir.

Bu farklılığı networke yansıtmanın bir yolu haftanın her günü için networke bir kolon eklemektir.En yoğun güne +1 ve en az yoğun güne 0 değeri atanabilir.Bu yöntemle network haftanın hangi gününe ait bilginin işlendiğini anlayabilir.

Networkün mevsimselliği anlayabilmesini sağlamanın başka bir yolu kolonları aylarla veya mevsimlerle isimlendirip datanın hangi mevsimden geldiğine

bakmaktır.Bazı YSA programları bu isimlendirme işlemlerini otomatik yapabilen modüllere sahiptir.

7.2 Minimumlar ve Maksimumlar

Bazı YSA programları giriş ve çıkış datalarının minimum ve maksimumlarını belirlemede farklı yöntemleri vardır.Eğer data 390 ve 460 aralığında seyrediyorsa YSA programları 0 460 veya 0 1000 aralığındansa 390 460 aralığında sınırlama getirmektedir.Eğer 0 460 aralığını kullansaydı gerçek data bu aralığın sadece % 18 'inde bulunacaktı.Birçok YSA programı minimum ve maksimumları otomatik olarak ayarlamaktadır.

7.2.1 Extreme Değerler

Extrene değerler ,şekil 7-1 de gösterildiği gibi datanın normal seyrinin fazlasıyla dışına çıkmış değerlerdir.Bu grafikteki dataların çok büyük kısmı 0-1 aralığında olmasına rağmen T anında ki fiyat değeri 3 tür.Bu nokta extreme nokta olarak adlandırılabilir çünkü normal değerlerden en az 3 kat daha yüksek bir değere sahip.Şekil 7-2 SPY networkünden belirli bir kısmın şeklini göstermektedir.Dikkat edilirse 27, 46 ve 265 periyorlarında muhtemel extreme noktalar vardır.Şekil 7-3 ise 0 dan 56 ya kadar ki kısmın daha ayrıntılı bir gösterimidir.Bu grafikte 27 ve 46. Periyorlardaki extreme noktalar daha net görülebilir.Extreme noktalar minimum ve maksimum değerlerin seçiminden etkilenmektedir, örneğin extreme nokta maksimum ve minimum değerlerin dışında kalıyorsa extreme noktalar otomatik olarak elimine edilmektedir ve bu sayede işlem hızında iyileşmeler olabilmektedir.

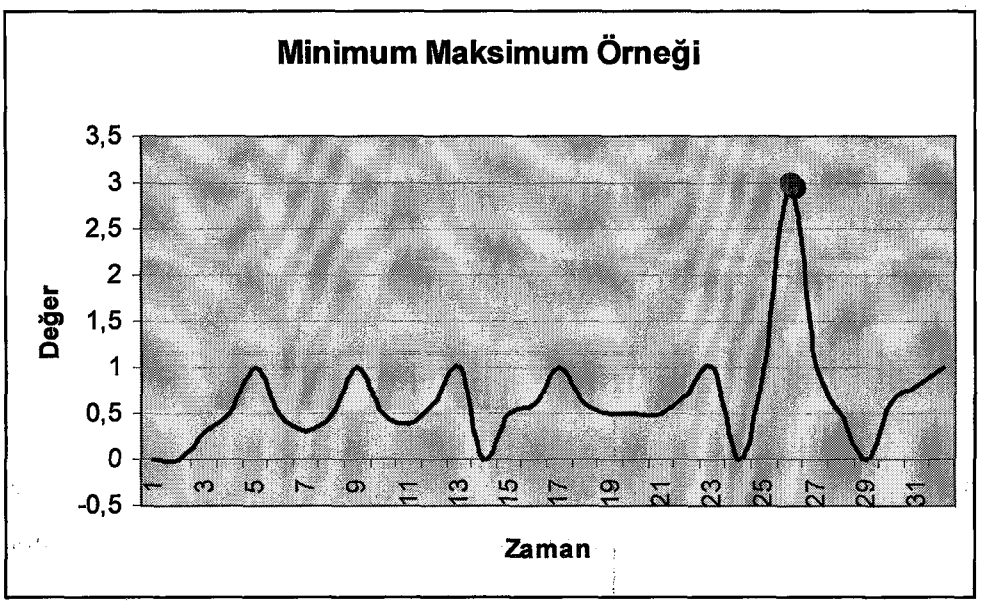

Şekil 7-1 Dataların daha çok 0-1 aralığında bulunduğu bir grafikte extreme değer örneği.

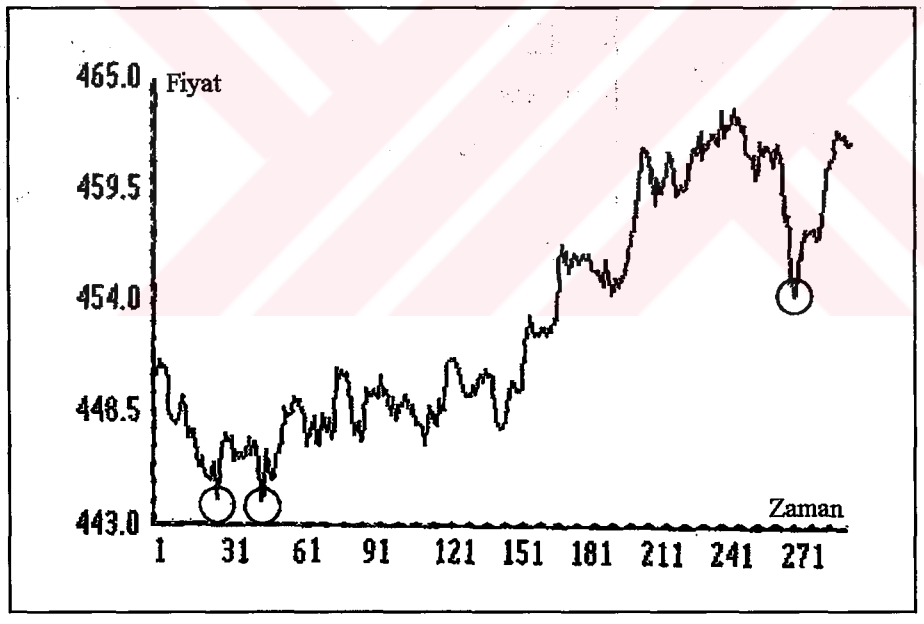

Şekil 7-2 Bir benchmark networkdeki extreme noktalar. (Glazier, S 40, 1990)

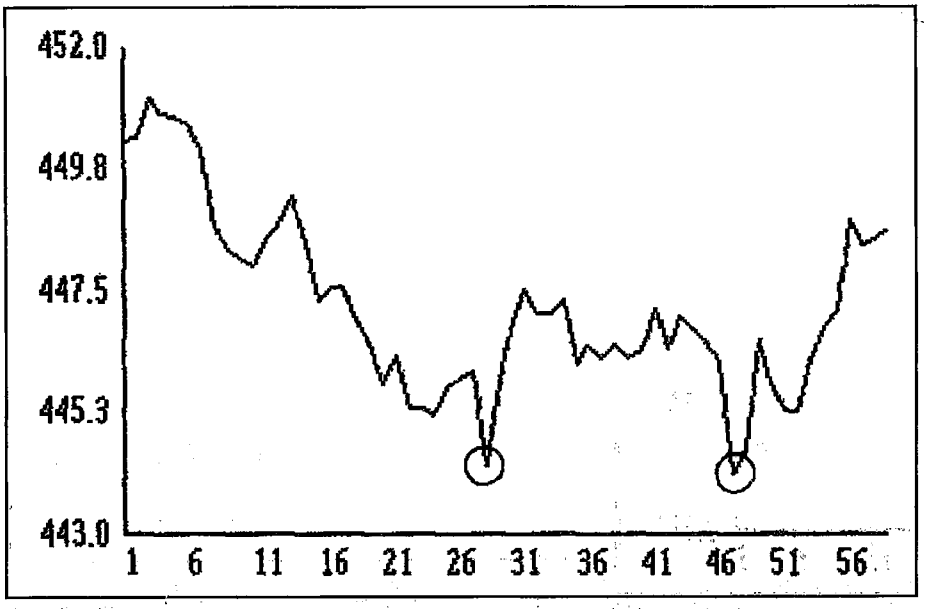

Şekil 7-3 Şekil 7-2 deki grafiğin 1-56 zaman aralığı için detaylı gösterimi. (Glazier, S 41, 1990)

7.3 Minimum / Maksimum Örnekleri

Minimum-Maksimum değerlerinin networkü nasıl etkilediklerini görmek için network farkı minimum-maksimum değerleri ile eğitilip daha sonra çıktısı grafik üzerinden izlenilebilir.Şekil 7-4 ,hata seviyelerinin gerçek minimum ve maksimumlar kullanılarak oluşturulmuş grafiğini göstermektedir.Dikkat edilirse hatanın + - 2.5 aralığında oluştuğu ve merkez eğrinin 0 değeri etrafında ortalandığı görülebilir.

Şekil 7-5 ,min-max değerlerinin %40 arttırılıp genişliğinde %40 oranında azaltıldığında bunun etkilerini göstermektedir.Minimum ve maksimumların arttırıldığı oranda genişliğin azaltıldığı örneklerde grafik yaklaşık olarak aynı kalmaktadır.

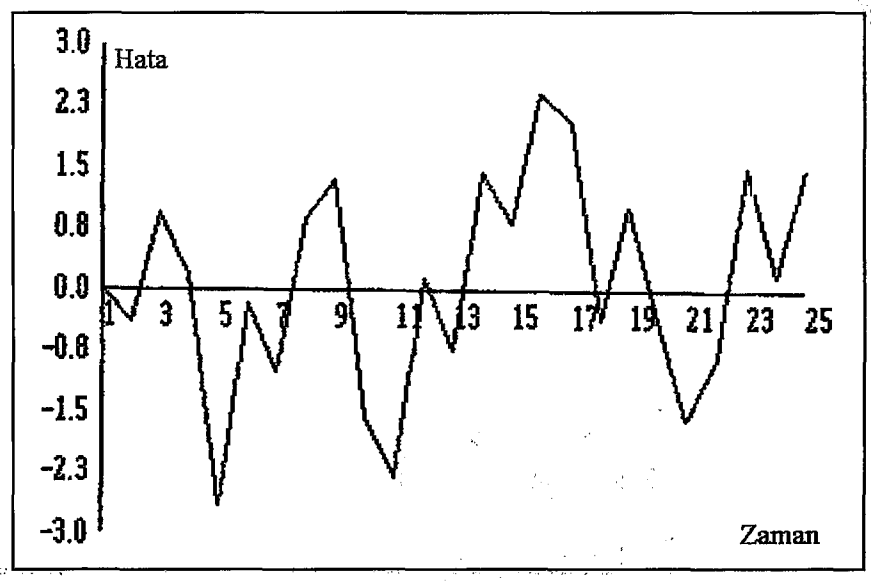

Şekil 7-4 Bir benchmark sisteminin MIN/MAX değerlerinin gerçek minimum maksimumlar olarak alındığı hata-zaman eğrisi. (Glazier, S 50, 1990)

Şekil 7-6 ,min-max değerlerinin %40 oranında azaltıldığı bir örneği göstermektedir.Bu uygulamadan sonra grafikte 0 çizgisi etrafında oluşmuş olan simetri bozulmuş ve + - 3 aralığında hatalar oluşmaya başlamıştır.

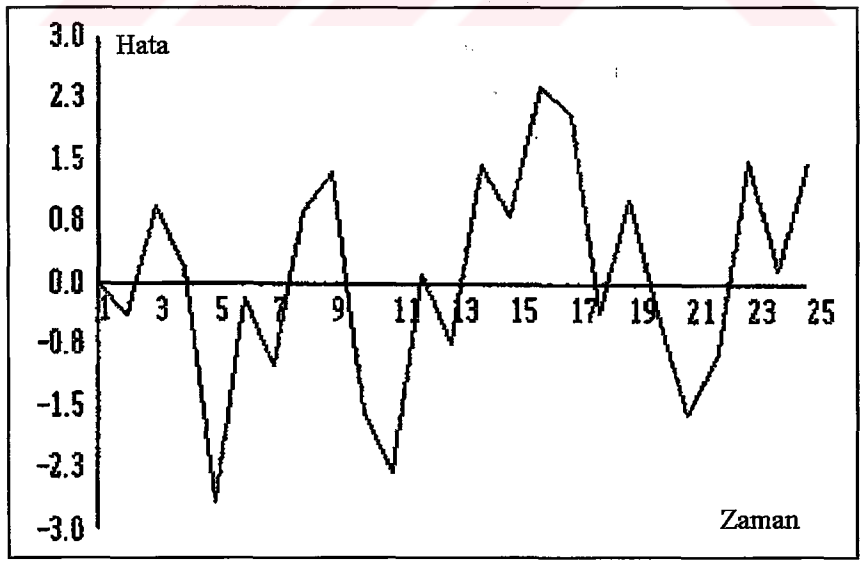

Şekil 7-5 MIN/MAX değerleri gerçek değerlerin %40 daha fazlasına ayarlanmış bir zaman-hata grafiği. (Glazier, S 50, 1990)

T.C. YÜKSEKÖĞRETİM KURULU
DOKÜMANTASYON MERKEZİ

Min-Max değerlerinin elle veya otomatik değiştirilmesi,veya değerlerin belli bir yüzdeye göre değiştirilmesindense bazı nöral network programları ana değer etrafında standart dağılım sınırlarında bir değer tanımlanması ile min-max değerlerinin tanımlanabilmesine imkan tanır. Standart dağılım ,datanın ana data etrafında ne kadar uzak sınırlarda dolaşabileceğini belirleyen istatistiksel bir terimdir.Örneğin + - 1 standart dağılım aralığında %68 oranında dolaşan bir data ana datayı %68 oranında içerebilirken,+ - 2 aralığında bulunan bir data ana datayı %95,+ - 3 aralığında bulunan bir data ise ana datayı %99 oranında içermektedir.Min ve Max değerlerinin bu yöntemle belirlendiği metodu denemek için standart dağılım 2.0 değerine ayarlanır,bu ana datanın %95 ini içermektedir ve test devam ettirilir.Şekil 7-7 bu tip bir testin sonuçlarını göstermektedir.En kötü sonuç + - 3.5 aralığında datalar kullanıldığı zaman elde edilmektedir.(Druey, K.,S-103, 1997).

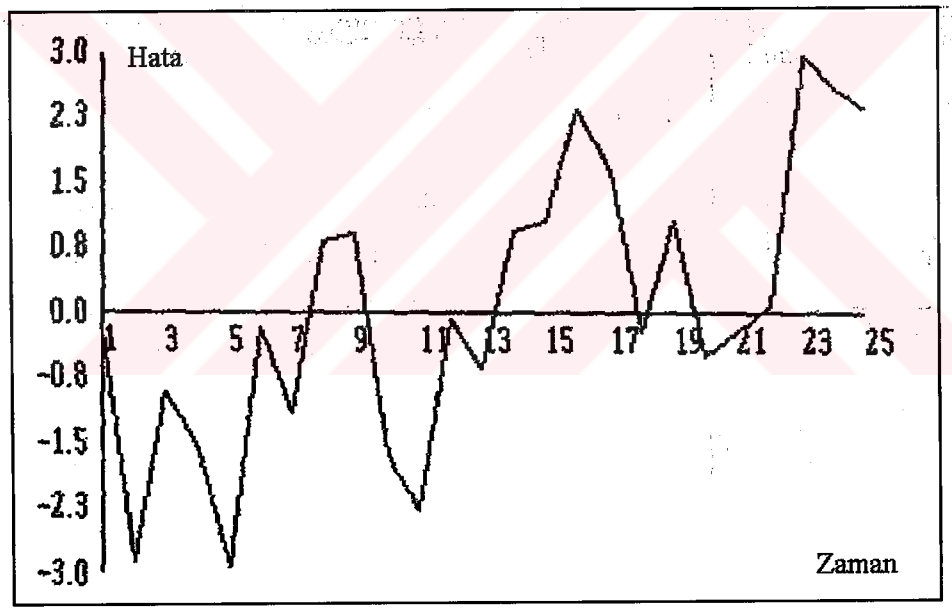

Şekil 7-6 MIN/MAX değerleri gerçek değerlerin %40 daha azına ayarlanmış bir zaman-hata grafiği. (Glazier, S 51, 1990)

Genellikle minimum ve maksimum değerlerini standart dağılım değerinin % 100 değişim aralığında tutmak iyi sonuçlar vermektedir. Minimum ve maksimum değerleri fazla geniş aralıklarda tutmak networkün hassasiyetini

bozmaktadır.Minimum ve maksimum değerleri fazla dar bir aralıkta tutmak ise network için yararlı olabilecek değerlerin gözardı edilmesine neden olabilmektedir.

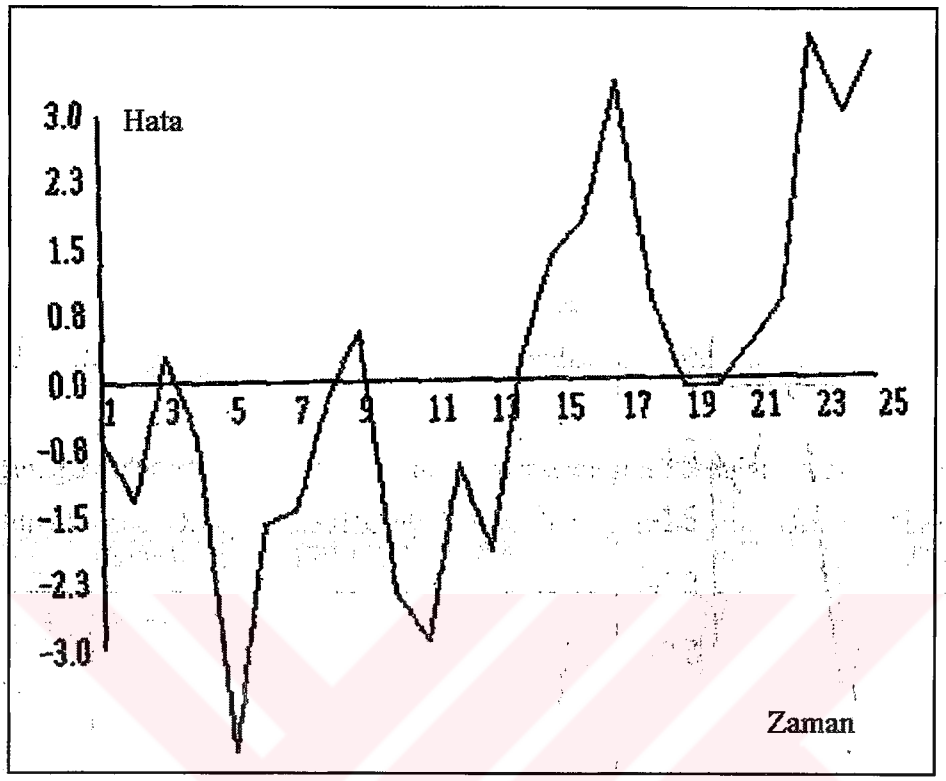

Şekil 7-7 MIN/MAX değerleri 2.0 standart dağılım değerine ayarlanmış bir hata-zaman grafiği. (Glazier, S 51, 1990)

7.4 Test Datasının Genişletilmesi

Test datası,daha önce networkte hiç kullanılmayan değerlerin network belli bir seviyeye geldikten sonra ne kadar başarılı tahminler yapabildiğini gözlemleyebilmek için kullanılan data setidir.Bunu yapmak için kullanılan en yaygın yöntem her 10 kolonda bir kolonu test datası için ayırıp daha sonra kullanmaktır.Diğer yöntemler ise toplam kolonların rastgele seçilen %10'unu almak veya son %10 unu almaktır.

7.5 Ne kadarlık data yeterlidir ?

Birçok yerde her giriş değeri için en az 10 kolonluk datanın gerekli olduğu vurgulanır.Örneğin network 6 girişli bir networkse en az 60 kolonluk bir data seti gerekmektedir.Varolon örneklerin maksimum değerinde (250) giriş sayısı başına örnek değeri 40 tı ve yeni örnekler eklendikçe network gelişmeye devam etmekteydi.Bu networkün performansı yeni örnekler eklendikçe artmaya devam etmektedir.Bu da istatistikteki genel kuralı doğrulamaktadır ;"çok data herzaman az data'dan daha iyidir".

8. NETWORK YAPISI VE NETWORK'ÜN EĞİTİLMESİ

8.1 Eğitim

Network'ün eğitilmesi network'e bilmesini istediğimiz şeyleri öğretme prosesidir.Eğer bir insana birşeyler öğretmek istiyorsak örneğin ilk öğretmek istediğimiz şeyi bir kağıda yazıp daha sonra kağıttakini öğrenmesini isteyip öğrendikten sonra da bir sonraki kağıdı verip yeni kağıttakileri öğrenmesini isteyebiliriz ve sonraki öğrenmesini istediğimiz bilgileri de bu şekilde öğrenmesini sağlayabiliriz.

Eğer biz yapay sinir ağlarının da insan beyninin yaptığı gibi bir öğrenme mekanizması ile öğrenmesini istersek gene aynı şeyi yapabiliriz ,tek fark datayı spreadsheetlerden kolon kolon alırız.Spreadsheet'teki kolonları rastgele de verebiliriz veya rotasyonlu adı verilen bir yöntem ile sıra sıra da verebiliriz.Bazı nöral network tipleri datanın rotasyonlu şekilde verilmesini gerektirir,bu özel tip dışındakiler ise rastgele seçimli veya rotasyonlu şekilde data girişine uygundur.

8.1.1 Eğitim Algoritmaları

Algoritma bir networkü eğitme yöntemine verilen isimdir.En yaygın eğitim algoritması "momentum" adı verilen eğitim algoritmasıdır.Bu algoritma networkün öğrenme hızına göre öğrenim oranını değiştirebilmektedir.Momentum şu anki moda eklenen daha önceki mod değeridir.Birçok YSA programı başka eğitim algoritmalarına da sahiptir. Bu algoritmaların diğerlerine göre kesinlilik,öğrenme hızı veya başka özellikler gibi avantajları vardır.

Seçilen network algoritmalarının networkü ne kadar etkilediğini gözlemleyebilmek için birden fazla eğitim algoritması networke uygulanıp sonuçları karşılaştırılabilir.

Benchmark dataları kullanılarak görülebilir ki öğrenme oranının networke + - % 6 gibi yüksek olmayan bir etkisi vardır.Kritik uygulamalarda ,0.00456 ve 0.00403 arasındaki fark başarı ve başarısızlık arasında fark olabilmektedir.Burdan tekrar görülebilir ki her network yapısı farklı eğitim algoritmaları ile test edilip uygun olanı seçilmelidir.

8.2 Network Yapıları

Network yapılarının %90 ı geri yayılımlı 3 tabakalı networkler olmalarına rağmen çok farklı network yapıları bulunmaktadır.

8.2.1 3 Katmanlı Geri Yayılımlı Network Yapısı

3 katmanlı geri yayılımlı network yapısı kullanılırken 2 adet değişken sabitleştirilmelidir.1. si öğrenme algoritması diğeri ise gizli katmandaki nöron sayısıdır (Şekil 8-1).Çizelge 8-1 1 ile 40 gizli nörona sahip networkler arasındaki ortalama hata oranlarının değişimini göstermektedir.Bu test yapılırken öğrenme oranı 0.05 ve momentum faktörü 0.5 olan bir momentum algoritması kullanılmıştır.(Joseph, S.Z.,S-77,1997).

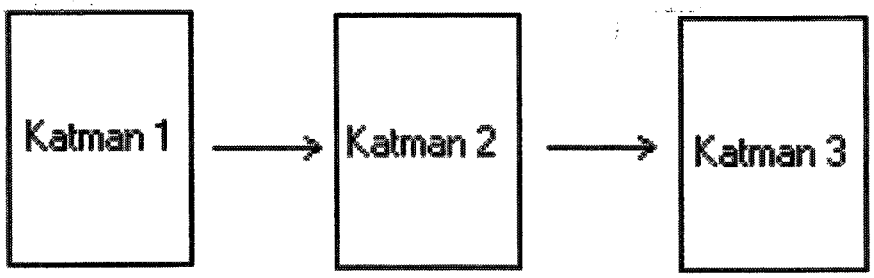

Şekil 8-1 3 katmanlı bir networkün şematik gösterimi. (Hiotis, A., S 40,1992)

Dikkat edilirse Çizelge 8-1'de hata sadece %5 oranında değişmekte ve 1 nöronlu network bile %5 hata aralığından küçük hataya sahiptir.Nöral networkler ile ilgili araştırmalar yapan bilim adamları gizli katmandaki nöron sayısının

hesaplanması için farklı förmüller öne sürmüşleridir.En yaygın olan yöntem giriş ve çıkışların toplamına eşit sayıda nöronla başlanılan yöntemdir.

Gizli katmandaki nöron sayısı	Minimum ortalama hata
1	0.00446
2	0.00441
3	0.00425
4	0.00433
5	0.00440
6	0.00435
7	0.00430
8	0.00431
9	0.00426
10	0.00425
11	0.00426

Çizelge 8-1 Kesinliğe gizli katmandaki nöron sayısının etkisi.

Gizli katmandaki nöronların sayısı kritik bir YSA değişkeni değildir ve bu tip testler optimum sayıda nöronun bulunmasında faydalı olabilir.

8.2.2 4 Katmanlı Network Yapısı

4 katmanlı networkler 3 katmanlı networklere çok benzerler,aradaki tek fark gizli katman ile çıkış katmanı arasına bir katman daha eklenmiştir.Bazı araştırmacılar gizli katman ve çıkış katmanındaki nöron sayısı toplam nöron sayısının % 10'undan fazla ise 4 katmanlı network kullanmanın daha iyi sonuçlar verdiğini keşfetmişlerdir.

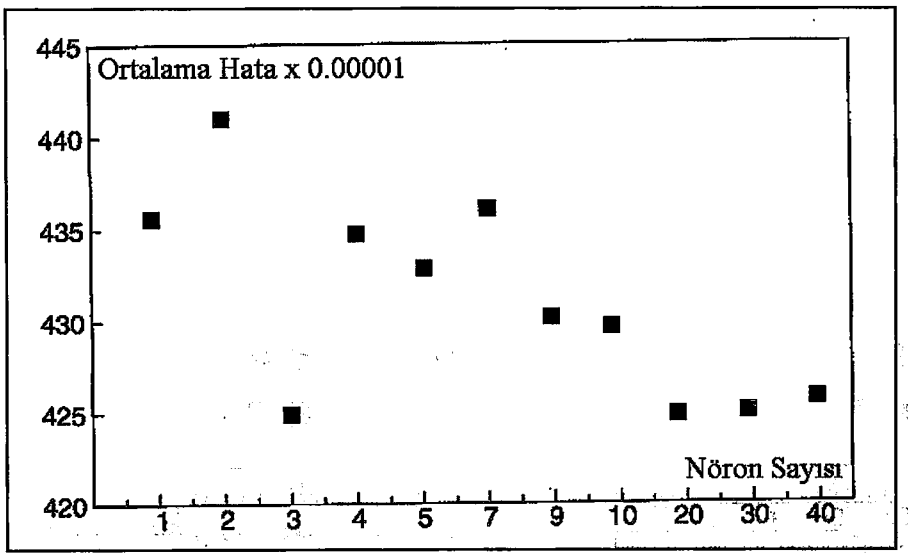

Şekil 8-2 Gizli katman nöronları-hata grafiği. (Hiotis, A., S60,1992)

Network Yapısı			Ortalama hata
Giriş Katmanı	Gizli Katman 1	Gizli Katman 2	
6	3	3	0.00449
6	3	3	0.00458
6	30	30	0.00432
6	30	15	0.00430
6	30	7	0.00438
6	30	3	0.00454

Çizelge 8-2 Kesinliğe 2. Bir gizli katman eklemenin etkisi.

8.2.3 Tekrar Eden Networkler

Tekrar eden networkler Jordan Elman networkleri olarak da bilinirler ve örnekleri hatırlayabilme özelliğine sahiptirler.Tipik örnekler "çift tabanlı" veya "baş ve omuz yukarıda" örnekleri olabilir.Daha çok finansal networklerde çok başarılı sonuçlar vermektedir.Tekrar eden networklerin eğitim süresinin çok uzun olması gibi bir dezavantajı vardır.Küçük networkler için bu sorun değildir fakat girişlerin sayısı 25'I ve kolonların sayısı 900'ü aştığı zaman bu sorun haline gelebilmektedir.

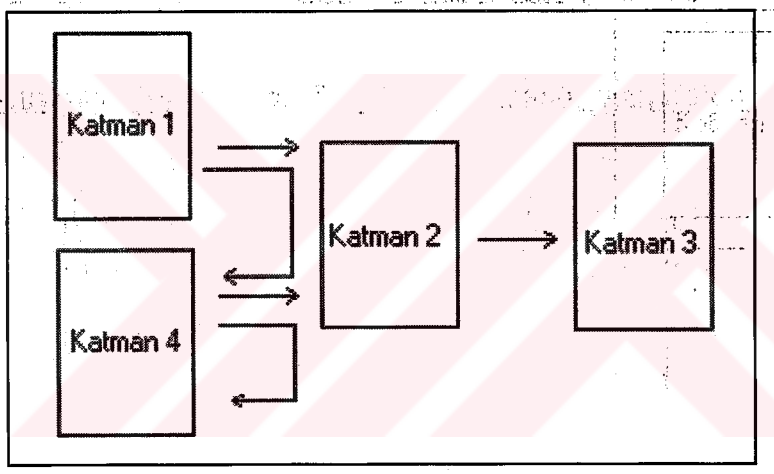

Şekil 8-3 Giriş katmanından (katman 1) tekrar oluşturmalı katmanına (katman 4)geribesleme alan bir yeniden oluşturmalı network örneği.

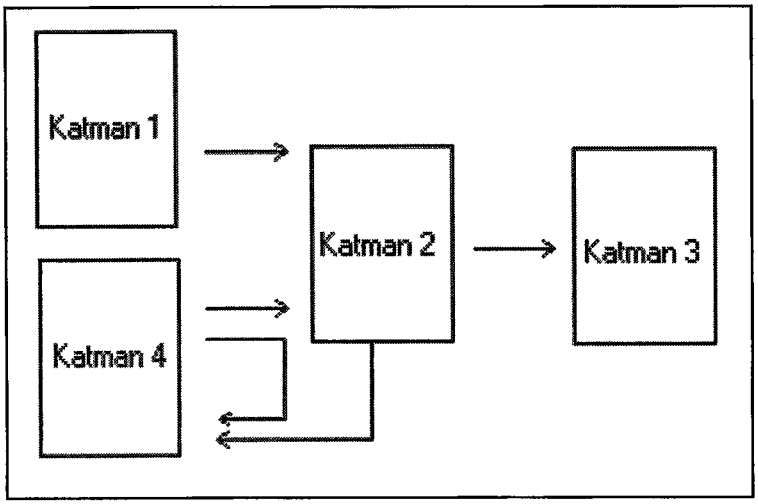

Şekil 8-4 Gizli (katman2) katmanından tekrar oluşturmalı katmanına (katman 4)geribesleme alan bir yeniden oluşturmalı network örneği.

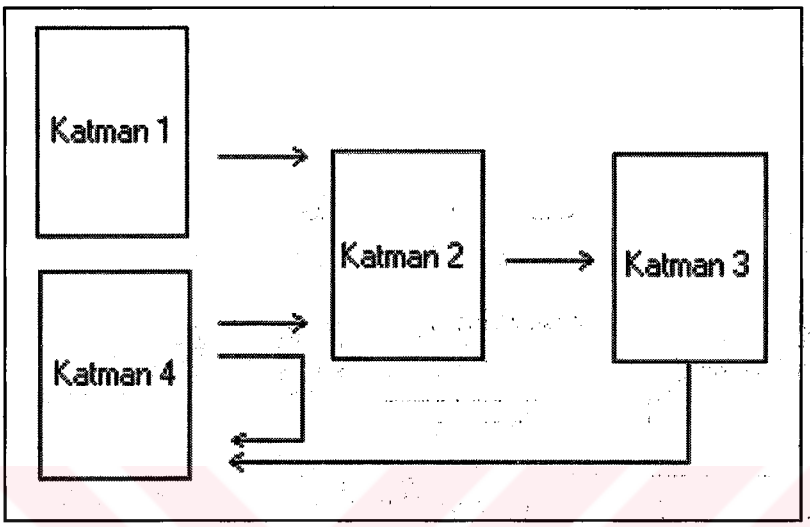

Şekil 8-5 Çıkış katmanından (katman3) tekrar oluşturmalı katmanına (katman 4)geribesleme alan bir yeniden oluşturmalı network örneği.

Tekrar eden networkler 3 katmanlı geri yayılımlı networklere benzerler fakat tekrar eden networklerde 4. Grup bir nöron grubu vardır ve bu gruba bağlantılar diğer 3 grup taradıfından yapılır.Bu tip nöron grubunu "levha" adı verilir (şekil 8-3).3 katmanlı geri yayılımlı networklerde 3 levha vardır ve 1. Levha giriş katmanı,2. Levha gizli katman ve 3. Levha ise çıkış katmanıdır. (Lippmann, R., S 49-52,1987)

4. levhanın nasıl geribesleme yaptığına göre değişen 3 tip tekrar eden network vardır.Ilk tip network şekil 8-4'de gösterildiği gibi geribeslemeyi giriş katmanından alır.2. tip network gizli katmandan (şekil 8-5),son tip ise çıkış katmanından almaktadır (Druey, K. ,S-34,1995).

Her katmandaki uygun nöron sayısı kullanılan YSA programına göre değişmektedir.Giriş katmanından geribesleme alan network modeli için sayılar şöyledir; giriş katmanı (katman 1) 6 nöron,gizli katman (katman 2) 20 nöron,çıkış katmanı (katman 3) 1 nöron ve tekrar eden katman (katman 4) 6 nöron.Gizli

katmandan geribeslemeli network için tekrar eden katmandaki nöron sayısı 20dir.Çıkış katmanından geribeslemeli network için ise bu sayı 6 dır.Çıkış veya gizli katmandan geribeslemeli tekrar eden katmanlı networklerde herhangi 3 veya 4 katmanı networklere göre daha başarılı sonuçlar alınabilmektedir. (Burke, G. ,S 85-87,1993)

8.2.4 Zıplama Bağlantılı Networkler

Zıplama bağlantılı networkler her katmanın bir önceki katmana bağlandığı geri yayılımlı networklerdir.

8.2.4.1 katmanlı zıplama bağlantılı network

3 katmanlı zıplama bağlantılı network benchmark datası ile şekil 8-6'de gösterildiği gibi testedilmiştir.Sonuç 0.000481 gibi minimum ortalamaya sahip bir değere sahiptir.

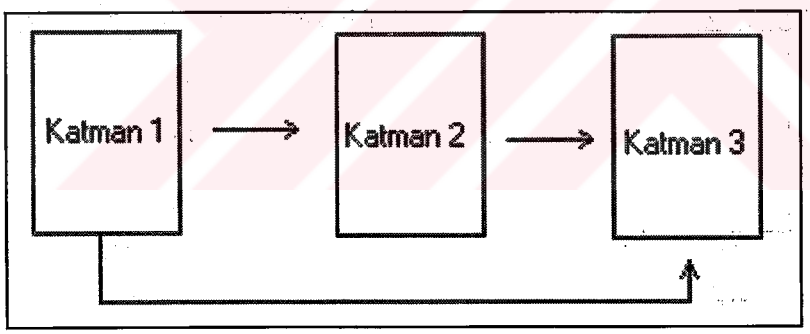

Şekil 8-6 3 katmanlı zıplama bağlantılı network.

8.2.4.2 4 katmanlı zıplama bağlantılı network

4 katmanlı zıplama bağlantılı network'ün şematik gösterimi şekil 7-9 da gösterilmiştir.Bu network 0.00544 gibi kötü bir çıkış değeri vermiştir.

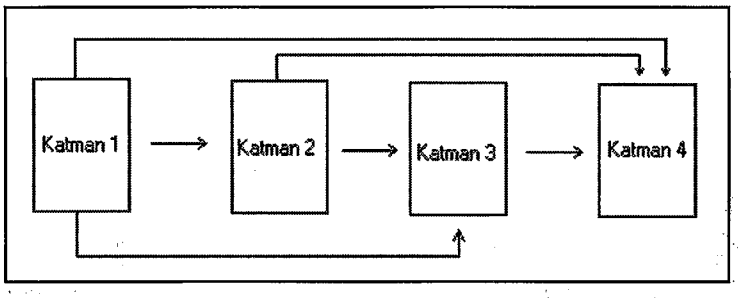

Şekil 8-7 4 katmanlı zıplama bağlantılı network.

8.2.4.3 5 katmanlı zıplama bağlantılı network

5 katmanlı zıplama bağlantılı network'ün şematik gösterimi şekil 7-10 da gösterilmiştir.Bu network 0.00633 gibi kötü bir çıkış değeri vermiştir. (Jurik, M. ,S 44,1992)

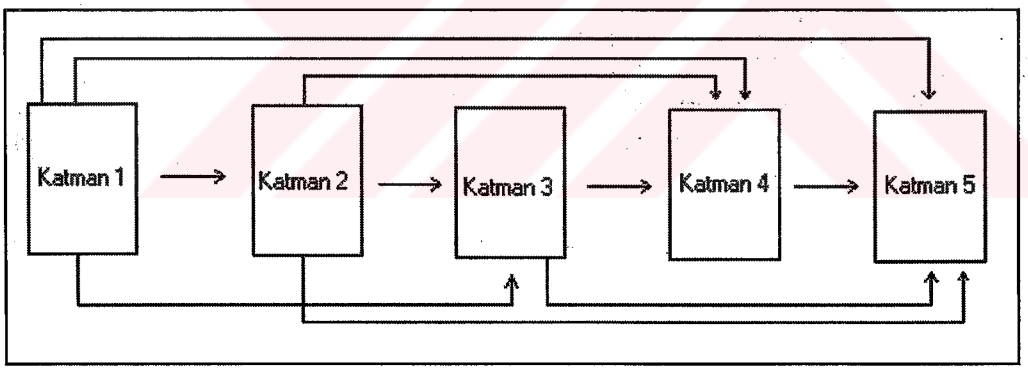

Şekil 8-8 5 katmanlı zıplama bağlantılı network.

8.3 Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları datanın hangi seviyesine daha çok önem verilmesi gerektiğini anlamaya yardımcı olan matematiksel fonksiyonlardır. Örneğin lineer bir fonksiyon kullanılırsa,tüm datalar eşit bir şekilde dağılmaktadır (Şekil 8-9).Bir Tanh

fonksiyonu 0 değerinin cıvarlarındaki bilgilere daha çok önem verirken +1 ve -1 data aralığındakilere çok daha az değer vermektedir (şekil 8-11).

Birçok YSA programı aksi belirtilmedikçe lojistik fonksiyonunu kullanır.Bazı YSA programları farklı fonksiyonların seçimine olanak verir. 3 katmanlı geri yayılımlı bir network farklı fonksiyonlar kullanıldığında aşağıdaki değerleri vermiştir: (Knight, K., S 73-74,1990)

Aktivasyon Fonksiyonu	Minimum Ortalama Hata
Lojistik	0.00403
Lineer	0.00416
Than	0.00394
Gaussian	0.00400
Sine	0.00396
Tanh15	0.00394
Simetrik Lojistik	0.00397
Gaussian Birleşimi	0.00387

Bazı aktivasyon fonksiyonları için matematiksel ifadeler aşağıdaki gibidir :

Lojistik	f(x)=1/(1+exp(-x))
Lineer	f(x)=x
Tanh	f(x)=tanh(x)
Tanh15	f(x)=tanh(1.5x)
Sine	f(x)=sine(x)
Simetrik lojistik	f(x)=2/(1+exp(-x))-1
Gauss	f(x)=exp(-xexp2)

Bu fonksiyonların grafikleri sırasıyla şekil 8-9 den şekil 8-16' ya kadar gösterilmiştir. (Bailey, D., Thompson, S 39-41,1990)

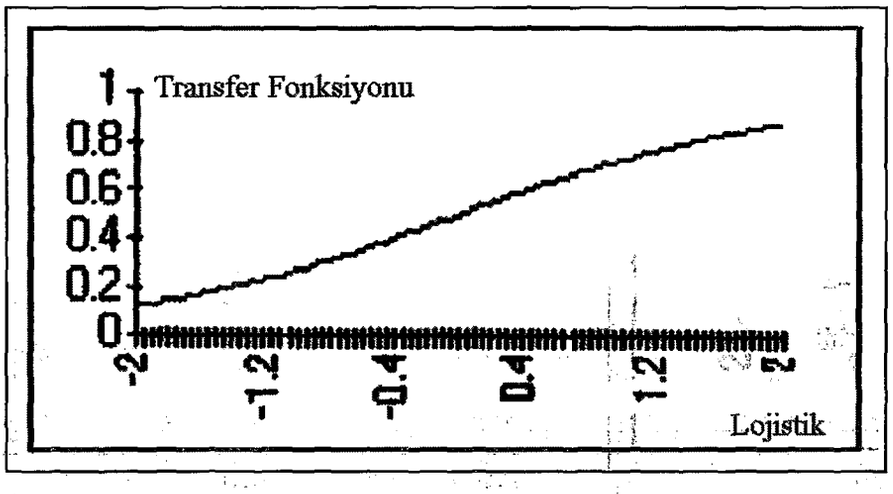
Transfer Fonksiyonu
1
0.8
0.6
0.4
0.2
0
-2
-1.2
-0.4
0.4
1.2
2
Lojistik

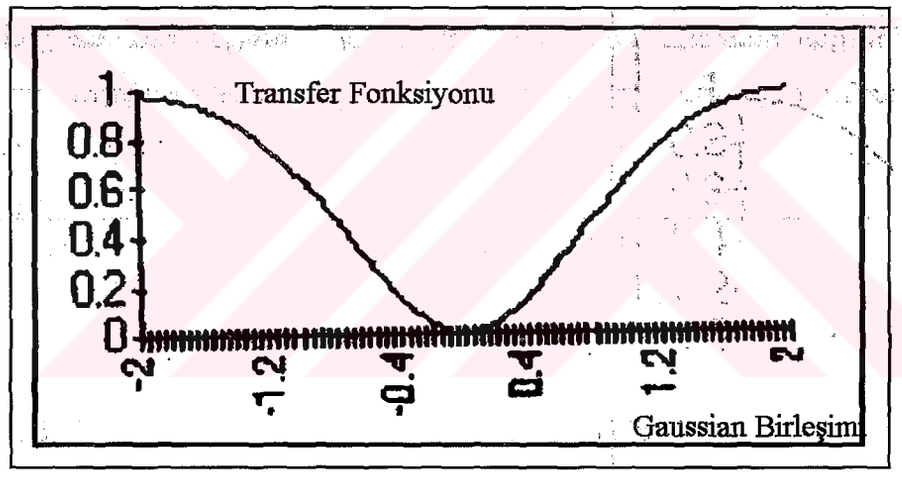
Transfer Fonksiyonu
1
0.8
0.6
0.4
0.2
0
-2
-1.2
-0.4
0.4
1.2
2
Gaussian Birleşim

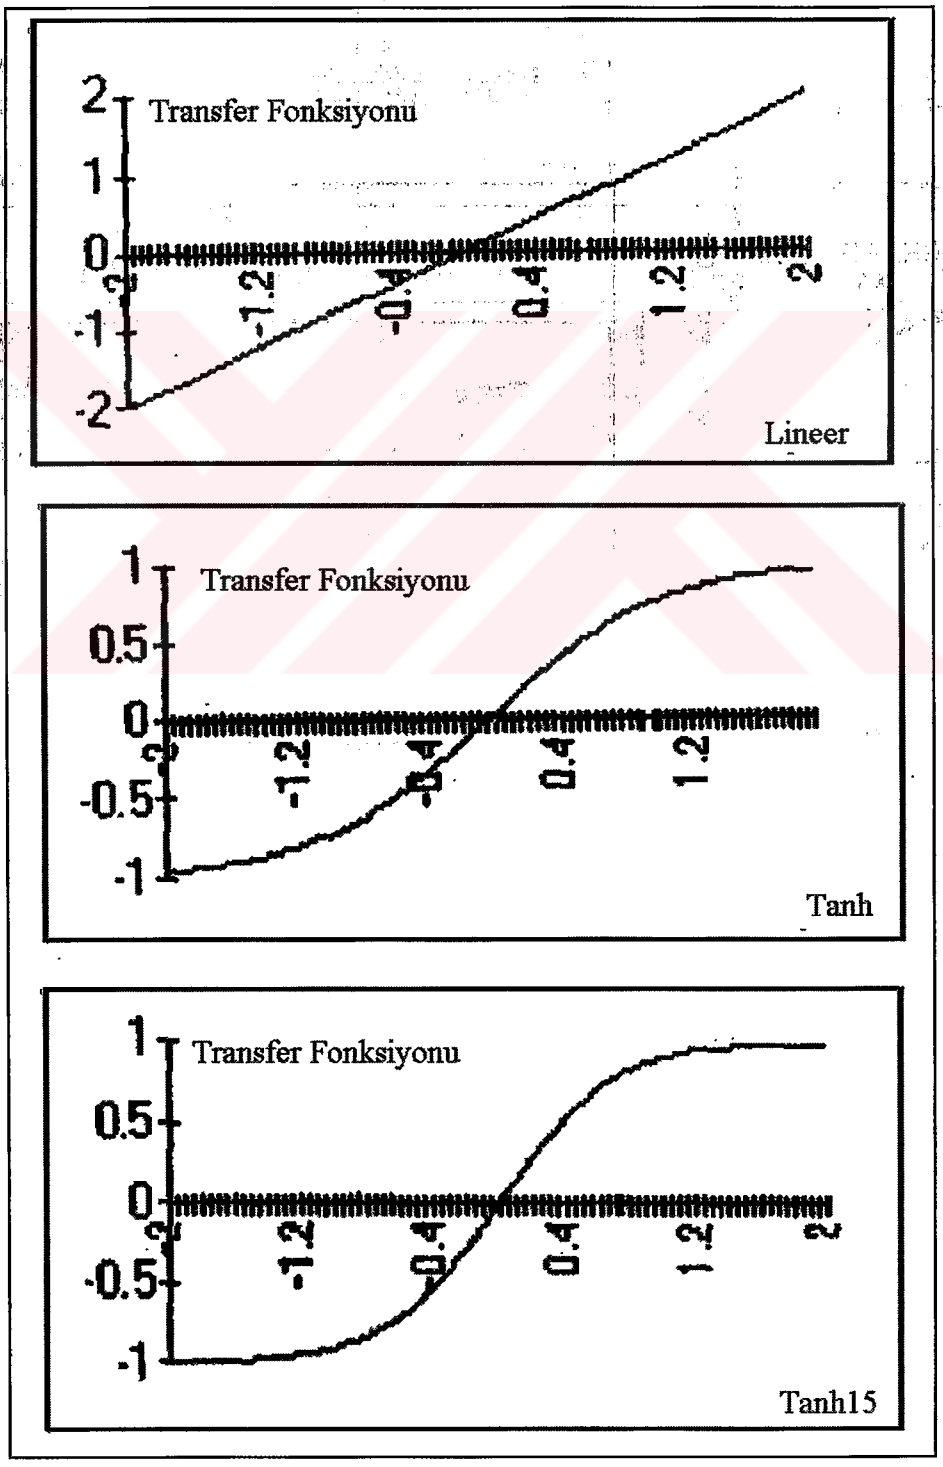
Transfer Fonksiyonu
2
1
0
-1
-2
-2
-1.2
-0.4
0.4
1.2
2
Lineer
Transfer Fonksiyonu
1
0.5
0
-0.5
-1
-2
-1.2
-0.4
0.4
1.2
Tanh
Transfer Fonksiyonu
1
0.5
0
-0.5
-1
-2
-1.2
-0.4
0.4
1.2
2
Tanh15

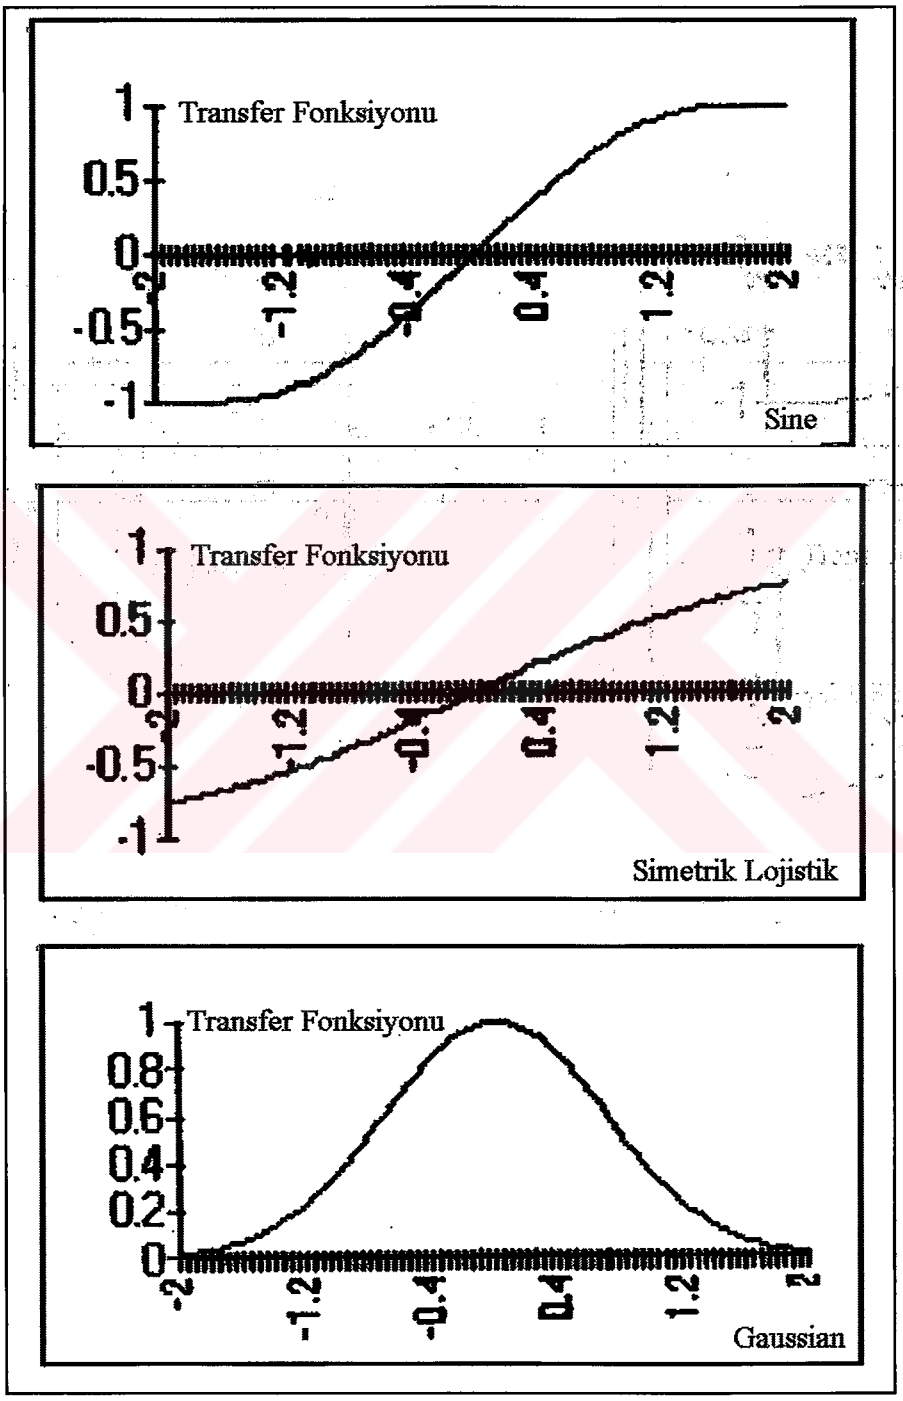

Şekil 8-9,8-16 Çeşitli transfer fonksiyonları (Druey, K. , S 73-75 , 1995)

8.4 Ward Networkü

Ward networkü herbiri farklı aktivasyon fonksiyonları alabilen extra levhalar kullanır.Örneğin şekil 8-17 da gösterilen ward networkü standart 3 katmanlı networke benzerdir,tek fark 2 numaralı normal gizli katmana paralel bir farklı aktivasyon fonksiyonun sahip levha daha kullanmasıdır. Test amaçlı olarak levhalardan teki gauss aktivasyon fonksiyonu diğeri ise gauss kopmlement fonksiyonu kullanılarak eğitilmiştir.Minimum 0.00431 hata ortalaması elde edilmiştir.

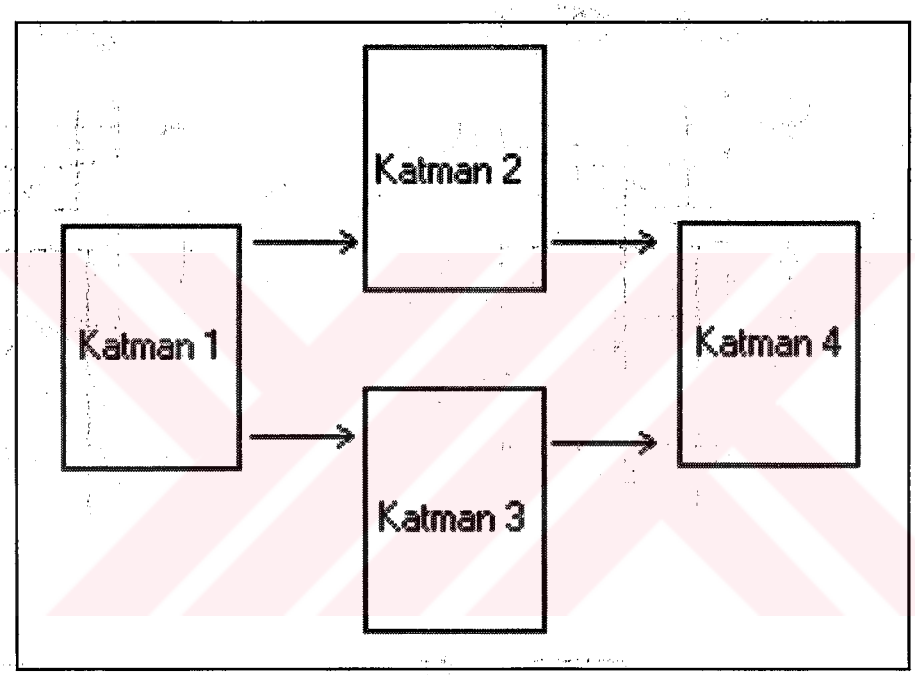

Şekil 8-17 Temel Ward networkü.

Şekil 8-18'deki networkte ise giriş levhasının direkt olarak çıkış levhasına bağlanmasını sağlayan ve gene bir önceki örnekte olduğu gibi gauss ve gauss komplement aktivasyon fonksiyonlarını kullananan bir network örneği gösterilmiştir ve bu network 0.00395 gibi minimum hata ortalamasına sahip olmuştur. (Azoff, E. M, S 20-22,1994)

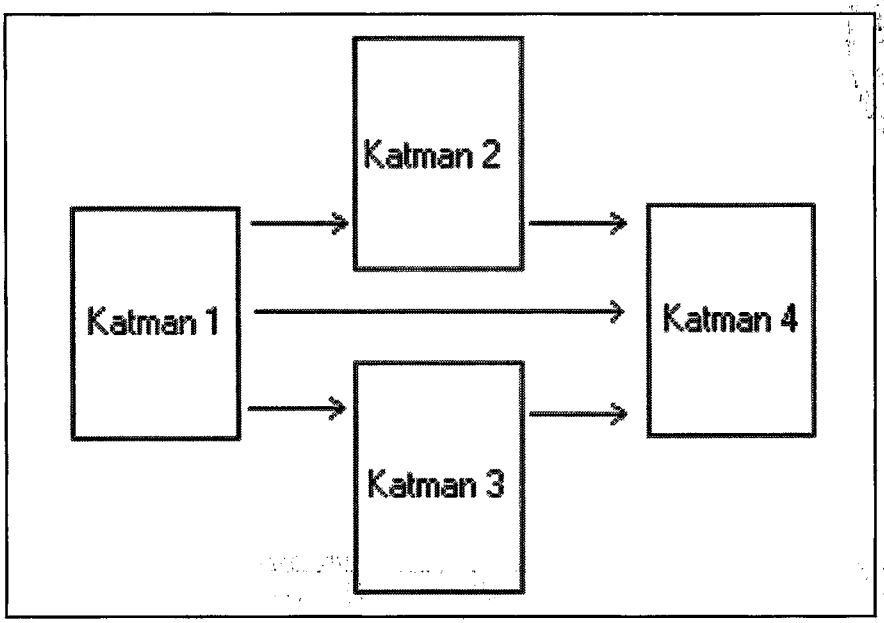

Şekil 8-18 Modife edilmiş Ward networkü.

Şekil 8-19'de ise 3 adet paralel gizli katmana levhasına sahip bir network örneği bulunmaktadır.Gauss ve gauss komplement aktivasyonu fonksiyonlarına ilaveten 3. Levhada tanh aktivasyon fonksiyonu kullanılmış ve 0.00403 gibi bir değer elde edilmiştir.(Gately, E.,S-78,1996)

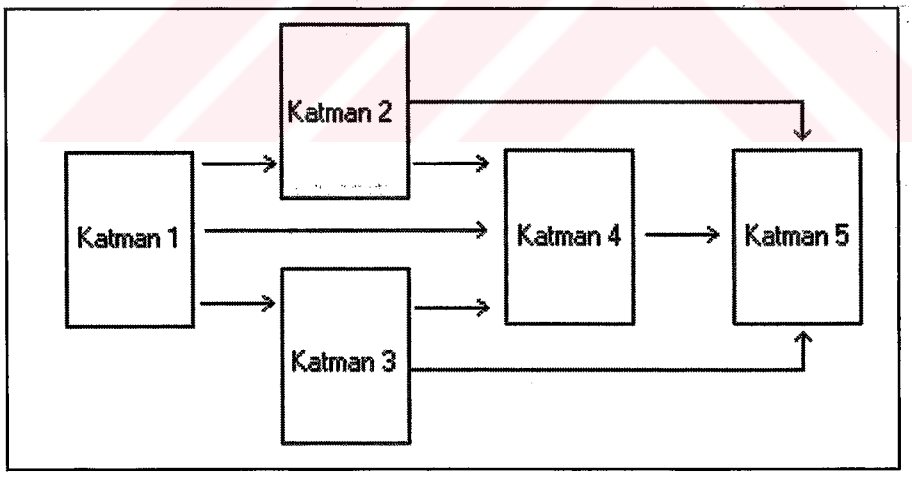

Şekil 8-19 Herbiri farklı aktivasyon fonksiyonuna sahip 3 gizli katmanlı Ward Networkü.

8.5 Kohonen Networkleri

Kohonen networklerinin amacı çıkışları farklı kategorilere ayırmaktır.Kohonen networklerinde eğitimin kıyaslanabileceği eğitim çıkış değerine sahip değildir.

Kohonen networkleri 2 katmana sahiptir (şekil 8-20),N değişkenli bir giriş katmanı ve çıkış katmanı.Eğitim sırasında örnekler rastgele veya rotasyonel olarak networke uygulanır ve daha sonra çıkış katmanına yayılım yapılır ve bu proses birkaç defa tekrar edilir.

Kohonen networkleri öğrenim safhasında çok hassastır.Network ağırlıkları çıkış nöronlarına ayarlamaya çalışır. (Gately, E.,S-85,1996)

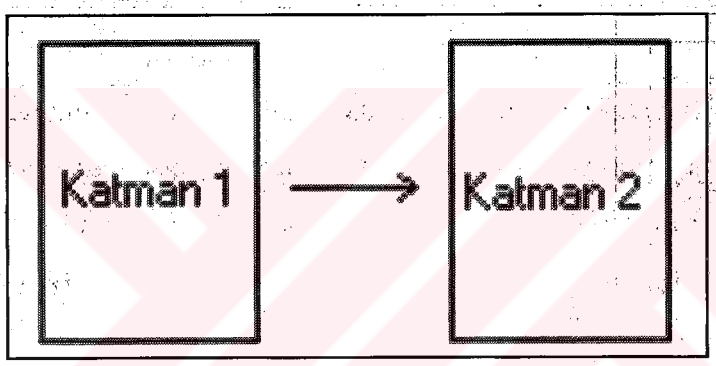

Şekil 8-20 Kohonen networkünün şematik gösterimi

8.6 Olasılıksal Nöral Networkler (ONN)

Olasılıksal nöral networkler (ONN) datayı farklı çıkışlara göre kategorize etmektedir.ONNler dağınık data setlerinde çok hızlı eğitilebilmektedirler.ONN networkleri şekil 8-21'de de görülebildiği gibi 3 katmanlı networklerdir.Çıkış nöronlarının sayısı kategori sayısı ile belirlenmektedir.Gizli katmandaki nöronların sayısı ise eğitim örneklerinin sayısına eşittir.ONN ve Genel Regresyonlu Nöral Networkler (GRNN) uygunlaştırma faktörü kullanımını gerektirirler.

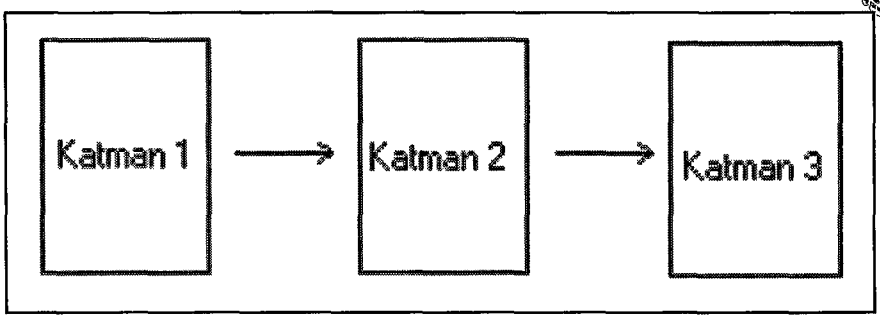

Şekil 8-21 ONN networkünün şekilsel gösterimi

8.6.1 Uygunlaştırma Faktörleri

ONN ve GRNN networkleri uygunlaştırma faktörüne ihtiyaç duyarlar.Şekil 8-22 den 8-24 ya kadar çıkış paternleri 25,50 ve 75'I +1 değerine sahiptir.Şekil 8-22'de 0.05 değerinde bir uygunlaştırma faktörü kullanılmıştır ve değerler +1 0 aralığındadır.Uygunlaştırma faktörü 0.08 e yükseltildiğinde (şekil 7-25 de gösterildiği gibi) değerler +0.5 1 aralığında olmaktadır.Uygunlaştırma faktörü 0.1'e yükseltildiğinde ise (şekil 7-26) tüm değerler +1'e yakındır ve değerler arasındaki farklılıklar uygunlaştırılmıştır. (Cheng,W; Wagner,L;Lin,C.H., S 50-52,1996)

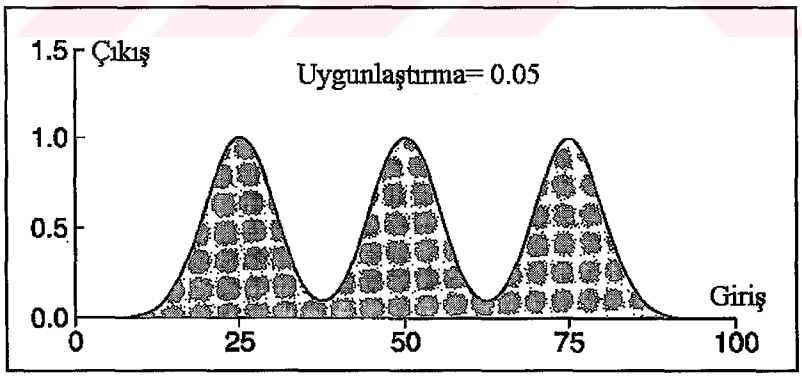

Şekil 8-22 Uygunlaştırma faktörü 0.05 olduğunda giriş-çıkış gra

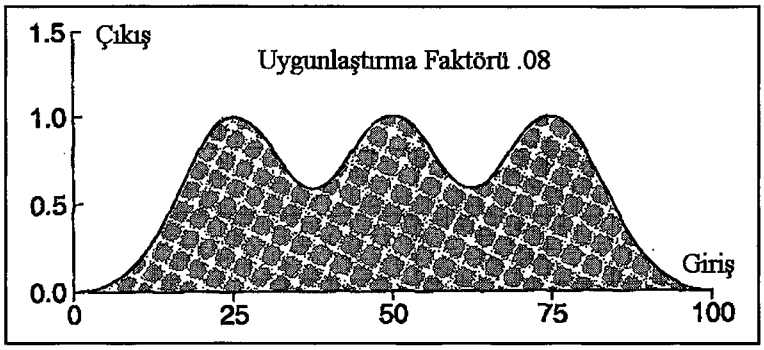

Şekil 8-23 Uygunlaştırma faktörü 0.08 olduğunda giriş-çıkış grafiği.

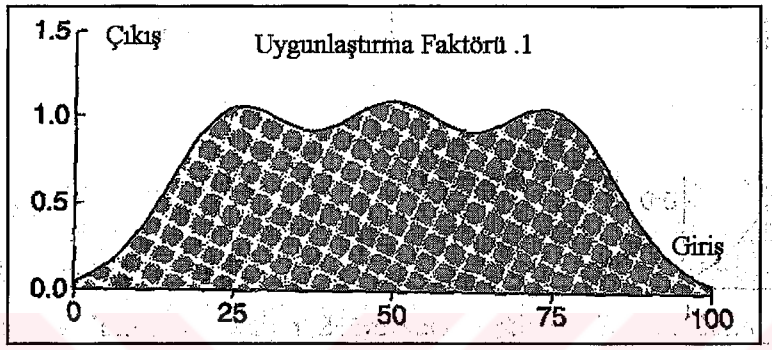

Şekil 8-24 Uygunlaştırma faktörü 0.1 olduğunda giriş-çıkış grafiği.

8.6.2 Genel Regresyonlu Nöral Networkler

Genel Regresyonlu Nöral Networkler ONN networklerinde olduğu gibi dağınık data setleri ile çalışabilme özelliğine sahiptirler.ONN networkleriyle kıyaslandıklarında GRNN networkleri sürekli değer çıktıları üretebilme yeteneğine sahiptirler.GRNN networkleri eğitim örnekleri sayısına eşit gizli katman nöronlarına sahip 3 katmanlı networklerdir (Şekil 8-25).Öğrenme oranı veya momentum gibi matematiksel ifadeleri yoktur fakat uygunlaştırma faktörleri vardır.

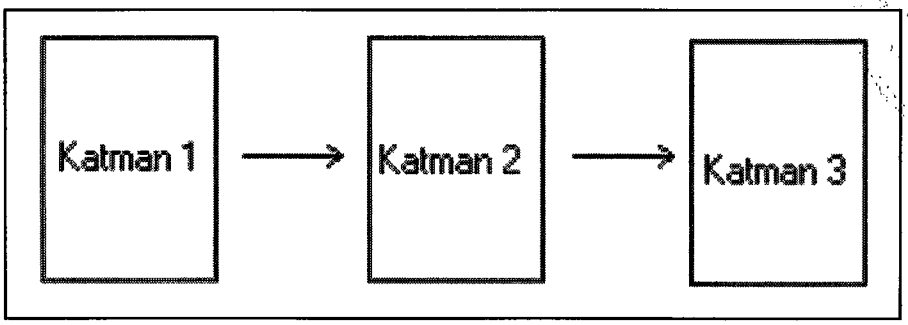

Şekil 8-25 Genel Regresyonlu Nöral Networklerin şematik gösterimi.

Eğitim süreleri geri yayılımlı networklerle kıyaslandığında daha hızlıdır,tekrar oluşturmalı networklere kıyasla ise çok daha hızlıdır.Bir GRNN networkünü eğitmek için kullanılan benchmark datalarında sonuç 0.00634 gibi çok da iyi olmayan bir değerdi.Bununla beraber ,12 periyotlu hareketli ortalama her bir girişe eklendiğinde ,minimum ortalama hata 0.00115 gibi bir önceki değerinde nerdeyse 4 katı daha iyi bir değere iner. Bu önişleme olayının GRNN networkü için ne kadar önemli olduğunu göstermektedir.

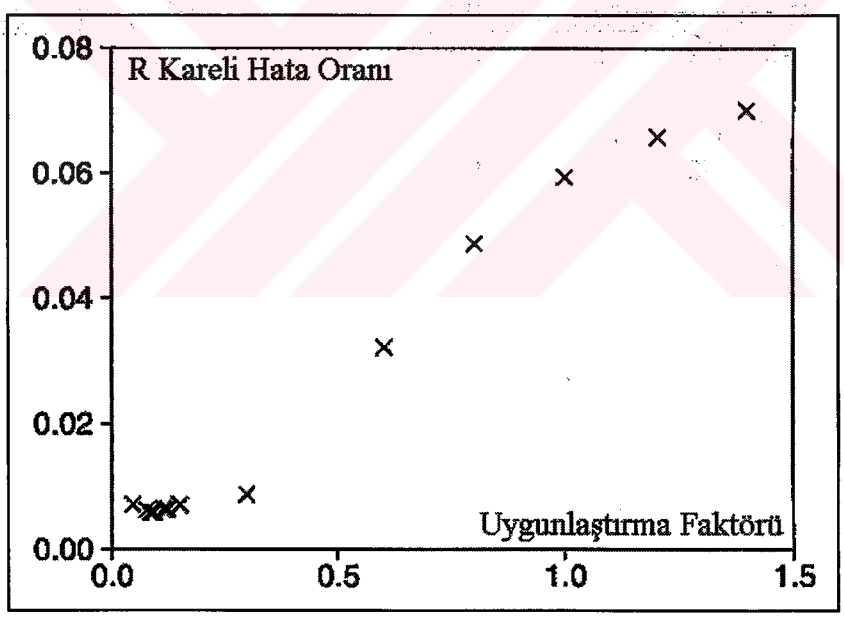

Şekil 8-26 Uygunlaştırma faktörü-Hata oran grafiği. (John,G.H.;Zhao,Y, S 75-77, 1996)

Şekil 8-26 GRNN networkünün eğitimle birlikte hata oranını göstermektedir.Dikkat edilirse minimum bir hata seviyesine inilene kadar network farklı uygunlaştırma değerleri kullanmaktadır. (Hiotis, A.,S-22,1992).

T.C.
66

8.7 Jenerik Uyumlu GRNN Networkleri

1994'ün ortalarında Ward sistemleri grubu jenerik uyumlu GRNN networkleri adında yeni bir GRNN network tipi duyurdu.Bu networkler geleneksel GRNN networklerinden birden çok uygunlaştırma faktörüne sahip olması ile farklılaşmaktadır;her bir giriş için 1 tane artı geleneksel genel uygunlaştırma faktörü.Test datası kullanılarak hem giriş için olan uygunlaştırma faktörü hem de genel uygunlaştırma faktörü minimum hata oranı elde edilecek şekilde uygunlaştırılmaktadır.Bu yeni tip GRNN networkü geleneksel GRNN networküne göre 2 kat daha az hata oranına sahiptir.Zaman serisi dataları ile çalışıldığında bu tip network en iyi sonuçları veren networktür. (Lippmann, R. , S 61-64,1989)

9. EĞİTİMİN BAŞLATILMASI VE DURDURULMASI

9.1 Eğitimin Başlatılması

Dataların elde edilmesi,elde edilen dataların spreadsheetlere aktarılması, önişleme,minimum ve maksimumların belirlenmesi, network testi için datanın bir kısmının ayrılması,bir network yapısı ve eğitim algoritması seçildikten sonra networkün eğitilmesine başlanması tüm bu işlemler içinde en kolay olanıdır.

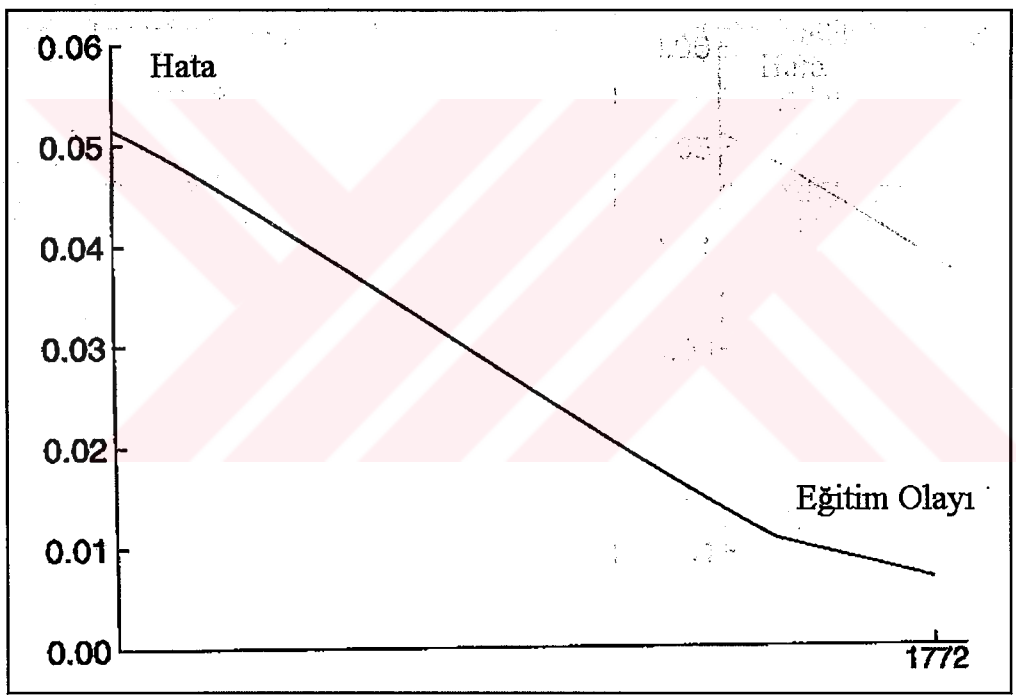

Şekil 9-1 Eğitim süresine bağlı olarak hata oranının grafiği. (Fishman, M., Barr, D, S 34 , 1991)

Eğitim,dataların farklı girişler arasında bir ilişki bulabilmek üzere networke uygulanma işlemidir.Şekil 9-1'den 9-4'e kadar olan grafikler 3 katmanlı bir networkün benchmark data'dan alınan bilgilerle eğitilmeye başlandıktan sonraki öğrenim grafikleridir.Momentum öğrenme algoritması 0.05 değerinde bir öğrenme oranı ve 0.5 momentum faktörü kullanmıştır. Dikey eksen networkün hata ekseni ,yatay eksen ise öğrenme olaylarının sayısını belirtmeltedir.Şekil 9-1 1,772 öğrenme

olayı olduktan sonraki durumu,şekil 9-2 2,583 öğrenme olayından sonraki durumu göstermektedir.Dikkat edilirse öğrenme oranının 1,772 ve 2,583 değerleri arasında azalma gösterdiği görülebilir.Şekil 9-3 ise hatanın 4,305 öğrenme olayı oldukan sonraki durumunu göstermektedir.Dikkat edilirse öğrenme daha da azalmıştır.Şekil 9-4 öğrenmenin 104,400 öğrenme olayından sonraki durduğu durumu göstermektedir.

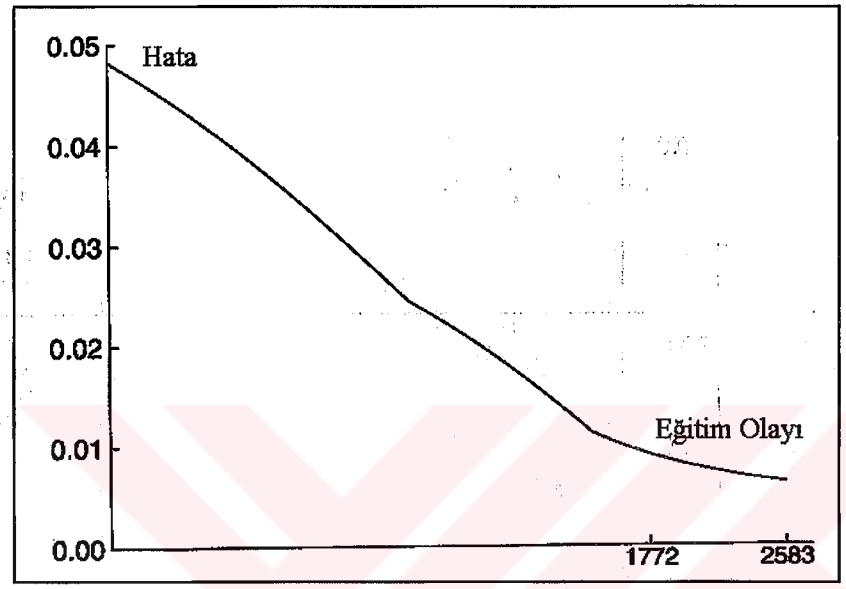

Şekil 9-2 Bir önceki grafikten farkı eğitim olayı sayısı 1772 den 2583'e yükseltilmiştir. (Fishman, M., Barr, D, S 34 , 1991)

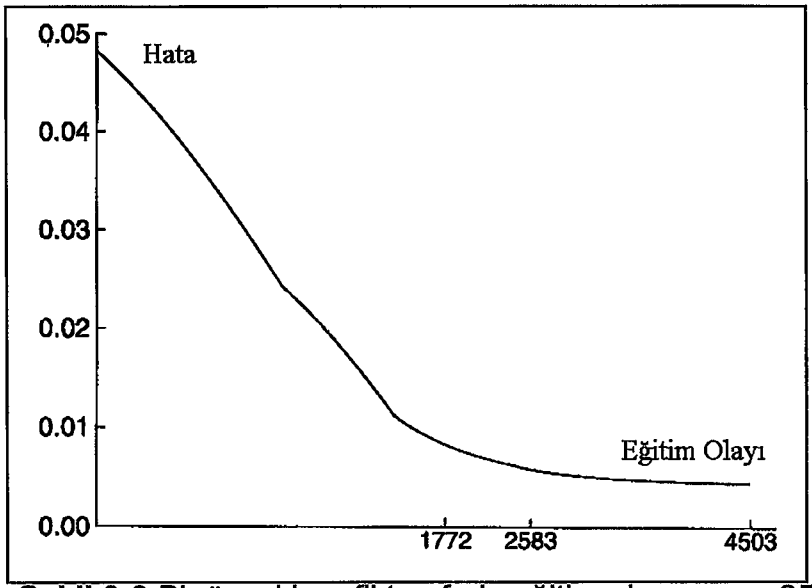

Şekil 9-3 Bir önceki grafikten farkı eğitim olayı sayısı 2583 den 4503'e yükseltilmiştir. (Fishman, M., Barr, D, S 35 , 1991)

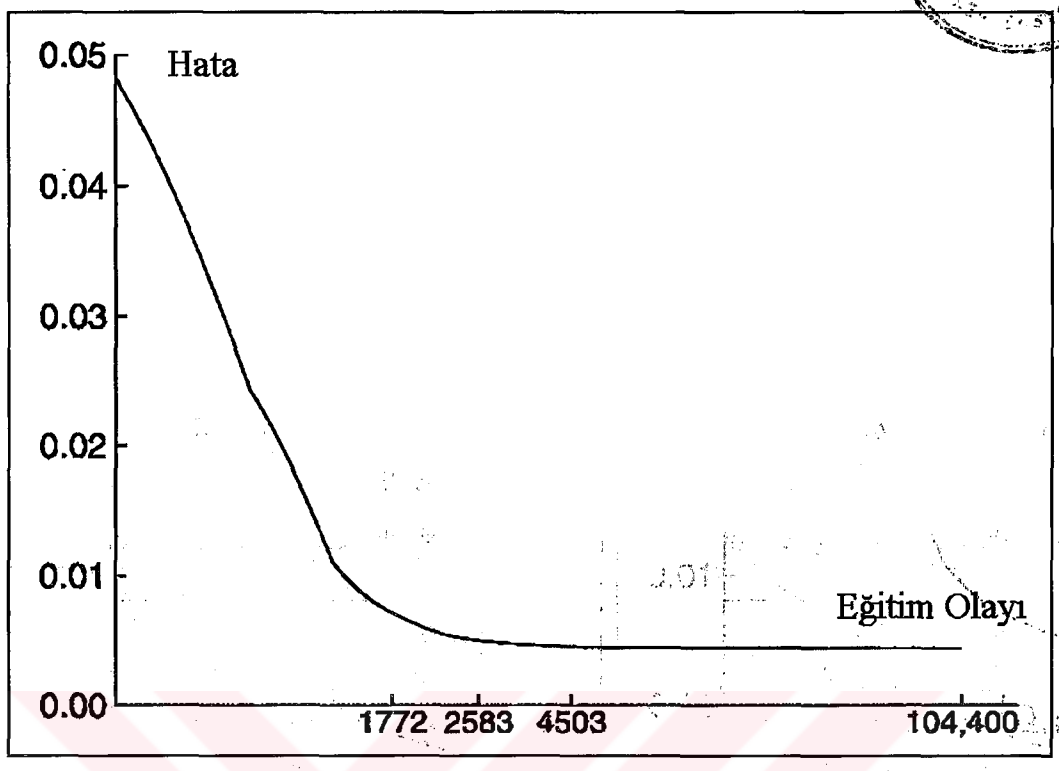

Şekil 9-4 Öğrenme olayının 104400 değerindeki hata oranını gösteren grafik. (Fishman, M., Barr, D, S 35 , 1991)

9.2 Eğitimin Durdurulması

Geri dağılımlı networkleri eğitirken eğitim çok önemlidir.Şekil 9-1 ve şekil 9-4 arasındaki grafikler göstermektedir ki eğitim sırasında öğrenme çok çabuk başlamaktadır.Eğitim devam ettikçe öğrenme oranı gittikçe düşmektedir.En son olarak öğrenme biter ve ezberleme olayı başlar. Ezberlemeye başladıktan sonraki hata networke yeni data girişi olsa bile artık networkden başarılı sonuçlar alabilme oranı düşmeye başlamaktadır.

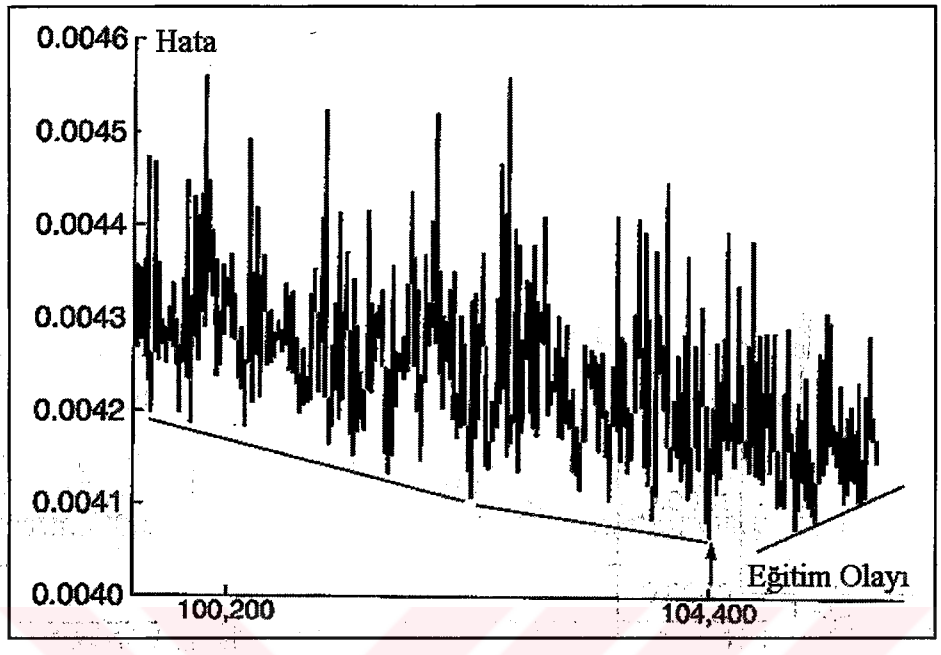

Şekil 9-5 Şekil 8-4'teki grafiğin son noktasının büyütülmüş bir grafiği. (Fishman, M., Barr, D, S 40 , 1991)

Şekil 9-4'ün sağ tarafının odaklanmış bir gösterimi olan şekil 9-5, öğrenmenin ileri safhalarındaki hata oranını göstermektedir ve bu etkiyi çok güzel bir şekilde göstermektedir.Öğrenme oranı grafiğin genel eğiminin değiştiği noktadan itibaren düşmektedir.Bunun nedeni networkün artık ezberlemeye başlamasıdır.

Burada amaç momentumun başladığı yerde öğrenme olayının bitirilmesidir. Bazı YSA programları eğitim işlemini durdurup networkü test datası ile test eder ve sadece test sonucu daha önceki sonuçlardan daha iyise öğrenme işemini durdurup sonuçları kaydeder.Eğer sonuçlar daha önceki testlerden daha iyi değilse yapılan işlemler kaydedilmez.Testten sonra genellikle network öğrenmeye devam eder.Genellikle öğrenme 50-200 öğrenme olayında bir test için durdurulur.Başarılı bir uygulama eğitimin erken safhalarında 200 olayda bir,ilerleyen safhalarda ise 50 olayda bir eğitime ara verilip test yapılmasıdır.Normalde eğitimin artık iyileştirme getirilmeyeceğine inanıldığı olay 10.000 ile 20.000 öğrenme olayı aralığındadır.

Eğer kullanılan program otomatik olarak nerede durması gerektiğine karar veremiyorsa elle eğitimin durdurulması gerekmektedir.

9.3 En Doğru Değer Için Eğitim

Sadece giriş dataları kullanılarak en doğru sonucu almak mümkün değildir,bir kısım işlemlerin de kullanıcı tarafından yapılması gerekmektedir ;

1.Hedef çıkışın tekrar düşünülmesi.
2.Gizli katmana nöronların eklenmesi veya çıkartılması
3.Girişlerin tekrar düşünülmesi.Ana hedefin tahmini için bunlar uygun girişlermi ?Önişleme programın doğru bir eğitim yapabilmesi için yeterlimi ?
4.Farklı bir network yapısı kullanmak daha iyi sonuçlar verebilirmi ?
5.Hedef çıkışın tekrar düşünülmesi.
6.Değişik bir öğrenme algoritmasının uygulanması.
7.Girişlerin tekrar düşünülmesi.
8.Gizli katmanların eklenmesi veya çıkartılması.
9.Problemin tekrar düşünülmesi.
10.Hangi girişlerin hedefe ulaşmada yardımcı hangi girişerin faydasız olduğunun bulunması.
11.Min/Max değerlerinin daraltılması veya açılması.
12.Tahmin hedefinin değiştirilmesi.
13.Çıkışın,girişlerin,problemin,yapının,öğrenme algoritmasının, minimum ve maksimumların,önişlemenin tekrar düşünülmesi.

9.4 Network'ün Kullanılması

Networkün tekrar kullanılması için pekçok YSA programı yeni giriş datalarının yeni bir spreadsheet'te toplanmasını gerektirir.Bazen de yeni datalar spreadsheet'in en son kolonundan sonra eklenirler.Bazen de ayrı bir dosya kullanılır.

Yeni dataların eklenilmesinde dikkat edilmesi gereken kısım yeni dataların doğru kolonlara yazılmasıdır.

Yeniden oluşturmalı networkler örnekleri hatırlayabildikleri için yeni data ile birlikte 10-20 periyot önceki datalara da ihtiyaç duyarlar.

10. S&P 500 ENDEKSİNİN 10 GÜN SONRAKİ DEĞERİNİN TAHMİN EDİLMESİ İÇİN BİR NETWORK'ÜN GELİŞTİRİLMESİ

10 günlük bir tahmin aralığı piyasaların ne yönde hareket edeceğinin anlaşılması için oldukça faydalı bir süredir.Bu bölümde ilk olarak 10 günlük bir tahmin oluşturulmaya çalışılacaktır.

Ikinci hedef ise mümkün olduğu kadar az girdi ile mümkün olduğu kadar doğru tahminlerde bulunabilen bir network oluşturmaktır.Çok fazla giriş networkün kontrol edilmesini ve oluşturulmasını zorlaştırır.Çok fazla data ile uğraşmak ayrıca hata yapma oranını da arttırmaktadır. Minimum girişli bir network çok daha kullanışlı bir networktür.

Bir network'ün son safhasına gelinceye kadarki yol milyonlarca farklı yaklaşımı içerebilir.Önemli olan genel yaklaşım,farklı kararlar arasındaki mantık,problemlerin çözümünde kullanılan method,karar verirken kullanılan yollar ve vazgeçilen yollar ve bu kararlar için gerekli nedenlerdir.Her network dizayncısı networkü genel anlamda etkileyen varsayımlara ve önizlenimlere sahiptir.Her dizaync aynı datayı kullanarak iyi veya kötü sonuçlara gidebilir.Sarfedilen emeğin ne kadar başarılı olduğununun göstergesi tahmindeki doğruluktur.

10.1 Ilk Girişler

Bu örnekte aşağıdaki 13 giriş değeri kullanılacaktır:

- Benzin Endeksi (XOI)
- Dow Jones Endüstri Ortalaması (DOW-30)
- Dow Jones Taşımacılık Ortalaması

- Dow Jones Ürün Ortalaması
- S&P 500 Endeksi
- CRB Endeksi
- US Dolar Endeksi
- 3 Aylık yatırım faiz oranı
- 1 Yıllık yatırım faiz oranı
- Altın ve Gümüş Endeksi
- S&P 100 Endeksi (OEX)
- Ilerleme-Gerileme Endeksi
- TRIN

(Gately,E., S 87-88,1996)

10.2 Data'nın Toplanması

Normalde datalar elle girilmesine rağmen en kısa ve az efor gerektiren yöntem bu giriş datalarını toplayarak saklayan kuruluşlardan istenilen periyotlar dahilinde dataların istenilmesidir.

10.3 Data'nın Önişlenmesi

Şekil 10-1 Dow Jones 30 Endeksinin tarih,en yüksek,en düşük, kapanış ve ortalama değerlerini gösteren bir spreadsheet tablosudur. Dikkat edilirse tarih bilgisi gün bazında yazılmıştır.

Diğer 13 giriş için bilgiler düzenlendikten sonra Dow Jones 30 endeksi için en düşük ve en yüksek değerleri silinmiştir.Bu işlem S&P 500 endeksi için yapılmamıştır.

Tüm bu 13 giriş düzeltildikten ve datalar girildikten sonra hepsi büyük ve tek bir spreadsheet tablosunda birleştirilmiştir.Tahmin hedefleri , geri almalar ve hareketli ortalamalar da eklendikten sonra eğitim için kullanılacak satır sayısı 40 olmuştur.Şekil 10-2 tarih bilgisi silinmemiş kombine edilmiş dosyayı göstermektedir.

Tarih entegrasyonu sağlandıktan sonra bir kolon hariç tarih bilgisi silinmektedir.Tek kolonluk tarih bilgisi daha sonra networke yeni data eklenirken tarih kıyaslaması yapılmak üzere silinmemektedir.Bu noktada var olan girişler ;

- S&P 500 (en yüksek,en düşük ve kapanış değerleri)
- Benzin Endeksi
- Dow Jones Endüstri Endeksi Ortalaması
- Dow Jones Endüstri Endeksi Işlem Hacmi
- Dow Jones Ürünler Endeksi
- Dow Jones Taşımacılık Endeksi
- CRB Endeksi
- Altın ve Gümüş Endeksi
- OEX
- TRIN

(Gately,E., S 89-91,1996)

MetaStock

Price and Indicator Data
03/01/91 to 07/22/94

Security: DOW JONES IND 30 Indicator: NONE

Date	High	Low	Close	Volume Indicator Last M.A.
03/01/91	2923.51	2846.78	2909.90	272470
03/04/91	2950.74	2897.03	2914.11	214530
03/05/91	2995.54	2913.86	2972.52	283650
03/06/91	3017.82	2957.67	2973.27	312750
03/07/91	2998.51	2948.51	2963.37	212890
03/08/91	3003.47	2934.90	2955.20	243280
03/11/91	2975.50	2923.27	2939.36	165280
03/12/91	2962.13	2906.68	2922.52	182990
03/13/91	2967.82	2910.89	2955.20	190200
03/14/91	3000.00	2925.74	2952.23	250040
03/15/91	2966.58	2918.81	2948.27	383820
03/18/91	2960.64	2899.75	2929.95	170370
03/19/91	2908.17	2840.84	2867.82	252890
03/20/91	2897.03	2840.84	2872.03	257190
03/21/91	2907.92	2841.58	2855.45	237240
03/22/91	2879.95	2829.21	2858.91	174330
03/25/91	2897.52	2837.87	2865.84	167890
03/26/91	2924.01	2848.02	2914.85	256330
03/27/91	2956.93	2886.14	2917.57	252850
03/28/91	2942.08	2893.32	2913.86	178990
04/01/91	2919.31	2868.32	2881.19	162160
04/02/91	2951.98	2878.22	2945.05	210660
04/03/91	2970.54	2915.84	2926.73	206520
04/04/91	2959.41	2899.75	2924.50	221630
04/05/91	2949.26	2876.98	2896.78	201700
04/08/91	2929.21	2877.72	2918.56	139630
04/09/91	2932.43	2863.37	2873.02	173840
04/10/91	2902.48	2848.51	2874.50	170130
04/11/91	2937.62	2877.72	2905.45	239430
04/12/91	2946.53	2884.16	2920.79	229420
04/15/91	2957.18	2896.29	2933.17	218910
04/16/91	2995.79	2912.13	2986.88	257900
04/17/91	3030.45	2963.12	3004.46	327500
04/18/91	3027.72	2976.24	2999.26	252520
04/19/91	3000.25	2943.56	2965.59	237760
04/22/91	2962.13	2911.63	2927.72	211280
04/23/91	2957.92	2905.94	2930.45	185520
04/24/91	2965.10	2913.37	2949.51	202080

Şekil 10-1 Dow Jones 30 günlük değerinin Spreadsheet'i. (Geva,A.B., S 1772,1998)

DATE	HIGH	LOW	CLOSE	VOLUME
33298	2923.51	2846.78	2909.9	272470
33301	2950.74	2897.03	2914.11	214530
33302	2995.54	2913.86	2972.52	283650
33303	3017.82	2957.67	2973.27	312750
33304	2998.51	2948.51	2963.37	212890
33305	3003.47	2934.9	2955.2	243280
33308	2975.5	2923.27	2939.36	165280
33309	2962.13	2906.68	2922.52	182990
33310	2967.82	2910.89	2955.2	190200
33311	3000	2925.74	2952.23	250040
33312	2966.58	2918.81	2948.27	383820
33315	2960.64	2899.75	2929.95	170370
33316	2908.17	2840.84	2867.82	252890
33317	2897.03	2840.84	2872.03	257190
33318	2907.92	2841.58	2855.45	237240
33319	2879.95	2829.21	2858.91	174330
33322	2897.52	2837.87	2865.84	167890
33323	2924.01	2848.02	2914.85	256330
33324	2956.93	2886.14	2917.57	252850
33325	2942.08	2893.32	2913.86	178990
33329	2919.31	2868.32	2881.19	162160
33330	2951.98	2878.22	2945.05	210660
33331	2970.54	2915.84	2926.73	206520
33332	2959.41	2899.75	2924.5	221630
33333	2949.26	2876.98	2896.78	201700
33336	2929.21	2877.72	2918.56	139630
33337	2932.43	2863.37	2873.02	173840
33338	2902.48	2848.51	2874.5	170130
33339	2937.62	2877.72	2905.45	239430
33340	2946.53	2884.16	2920.79	229420
33343	2957.18	2896.29	2933.17	218910
33344	2995.79	2912.13	2986.88	257900
33345	3030.45	2963.12	3004.46	327500
33346	3027.72	2976.24	2999.26	252520
33347	3000.25	2943.56	2965.59	237760
33350	2962.13	2911.63	2927.72	211280
33351	2957.92	2905.94	2930.45	185520
33352	2965.1	2913.37	2949.51	202080
33353	2958.42	2905.2	2921.04	174770
33354	2934.9	2888.61	2912.38	173310
33357	2941.09	2869.55	2876.98	163820
33358	2929.21	2859.41	2887.87	266030
33359	2945.3	2882.43	2930.2	215330
33360	2966.34	2917.33	2938.61	182340
33361	2959.9	2906.93	2938.86	171260
33364	2956.84	2911.45	2941.64	151990

Şekil 10-2 Orjinal spreedsheet'in YSA için düzeltilmiş hali. (Geva,A.B., S 1773,1998)

10.4 Hangi Girişlerin Katkıda Bulunduğunun Tesbiti

Hangi girişlerin katkıda bulunduğunun tesbiti için 3 katmanlı geri yayılımlı,0.05 eğitim oranlı ve 0.5 momentuma sahip momentum algoritması ile eğitilen bir networke girişler uygulanmıştır.Tablo 9-1 10 girişin değerlendirilmiş performansını göstermektedir.Minimum ve maksimum değerler gerçek minimum ve maksimum değerlerine ayarlanmışlardır.Her onuncu örnek ayrı bir dosyaya kaydedilmiş ve similasyon için 68 örnek kullanılmıştır.Toplamda ise 688 eğitim örneği bulunmaktadır.

Katkı	Giriş
1.22976	Hacim
1.31203	OEX
1.76214	TRIN
1.97092	S&P 500 Düşük
2.21308	DOW 30
2.41897	Ürün End
2.41966	Yaş. End.
3.02431	Altın gümüş
3.20924	S&P 500 Kap.
3.57766	S&P 500 Yüksek
3.69604	CRB
3.87979	Benzin

Çizelge 10.1 Geri yayılımlı bir networkün eğitiminde her bir girişin eğitim için kullanıldığında ortaya çıkan relatif katkısının tablosu. (Fishman, M., Barr, D., Loick, W. , S 22,1991)

300,200 olay sonrasında network'ün eğitimi tamamlanmıştır. Similasyon dışı data ile test edildiğinde networkün 0.9549 değerinde R-Kareköklü değeri vardı.Çizelge 10-1 farklı girişlerin katkılarını göstermektedir.En fazla katkıda bulunan girişler en altta en az katkıda bulunanlar ise en üsste bulunmaktadır.

Dow,OEX ve işlem hacminin zayıf performansları şaşırtıcı değildir. Dow ve OEX değerleri birbilerine ve S&P500 değerlerine non-lineerdir.Bu yüzden network'ü şaşırtmaktadır.

Normalde ham hacim datası nöral networklerde kullanılmaz çünkü çok gürültülü ve volatilitelidir.Hacmin bir veya daha fazla hareketli averajı giriş datası olarak kullanılır.

S&P 500 endeksi sonuca az katkısı olan başka bir giriştir.

10.5 Hacim Girişi Için Uygun Bir Hareketli Averajın Belirlenmesi

Bir sonraki adım OEX,TRIN ve Dow30 satırlarını sildikten sonra networkün eğitilmesi olacaktır.Hacmin 3,5 ve 10 günlük hareketli ortalamaları eklenecektir ve network hangi girişlerin sonuca katksının daha fazla olduğunun bulunması için eğitilecektir.

Çizelge 10-2 ve Şekil 10-3 hangi girişlerin networke katkısının hangi derecede olduğunu göstermektedir.Dikkat edilirse hacmin hareketli ortalaması S&P 500 endeksinin minimum değerinden daha fazla katkısı olmaktadır.Bununla beraber, hacim için doğru periyodu kullanıp kullanmadığımızı bilmiyoruz çünkü en geniş periyotlu hacim networke en çok katkısı bulunan hacim görünmektedir.Bir pik performansına ulaşılamadığı için 10 günlük periyodun en iyi periyot olup olmadığı bilinememektedir.

Katkı	Giriş
1,74687	S & P 500 Yüksek
1,80293	Hacim Hareketli (5) Ort.
1,8156	Hacim Hareketli (3) Ort.
2,31732	Hacim Hareketli (10) Ort.
2,79877	S&P 500 Yüksek
3,35121	S&P 500 Kapanış
3,46610	Taşımacılık
3,59537	Altın Gümüş
3,95347	CRB
4,33959	Ürün End.
5,46879	Benzin

Çizelge 10-2 OEX TRIN ve Hacim girişleri silindikten sonraki katkı değerleri.

Bu nedenle network en iyi hacim hareketli ortalaması ile eğitebilmek amacıyla 10,20,30 ve 40 günlük hareketli ortalamalı hacim değeri ile eğitilecektir. Çizelge 10-3 ve Şekil 10-4 bu testlerin sonuçlarını göstermektedir. Dikkat edilirse 30 günlük hareketli ortalamalı hacim en önemli 4. Giriş halini almıştır.20 ve 40 günlük hareketli ortalamalar bu kadar çok katkı göstermemektedir.Bu yeni işlem 693,200 öğrenme olayı sonunda 0.00178 gibi bir hata değeri almıştır. (Caudill, M. ,S-22,1993)

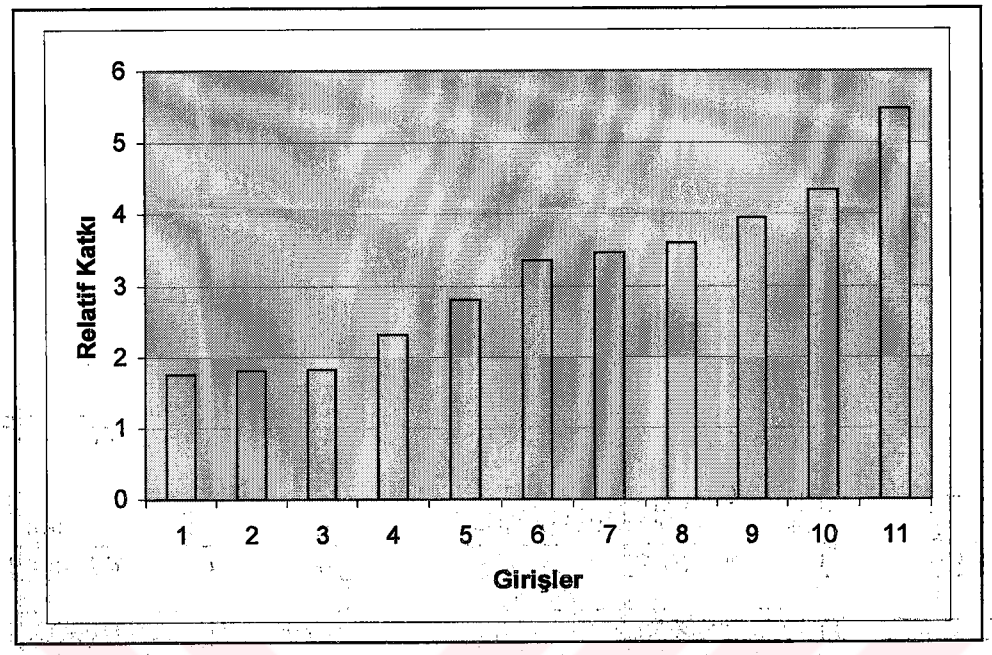

Şekil 10-3 Çizelge 10-2 de gösterilen değerlerin grafiksel gösterimi.

Katkı	Giriş
1,86366	S & P 500 Düşük
2,18126	Hacim Hareketli (10) Ort.
2,74433	Hacim Hareketli (20) Ort.
2,83724	Taşımacılık
2,96086	Hacim Hareketli (40) Ort.
3,11930	S&P 500
3,15833	S&P 500 Kapanış
3,31325	Ürün End.
3,58407	CRB
4,01614	Altın Gümüş
5,45404	Benzin

Çizelge 10-3 OEX TRIN ve Hacim girişleri silindikten sonraki katkı değerleri.

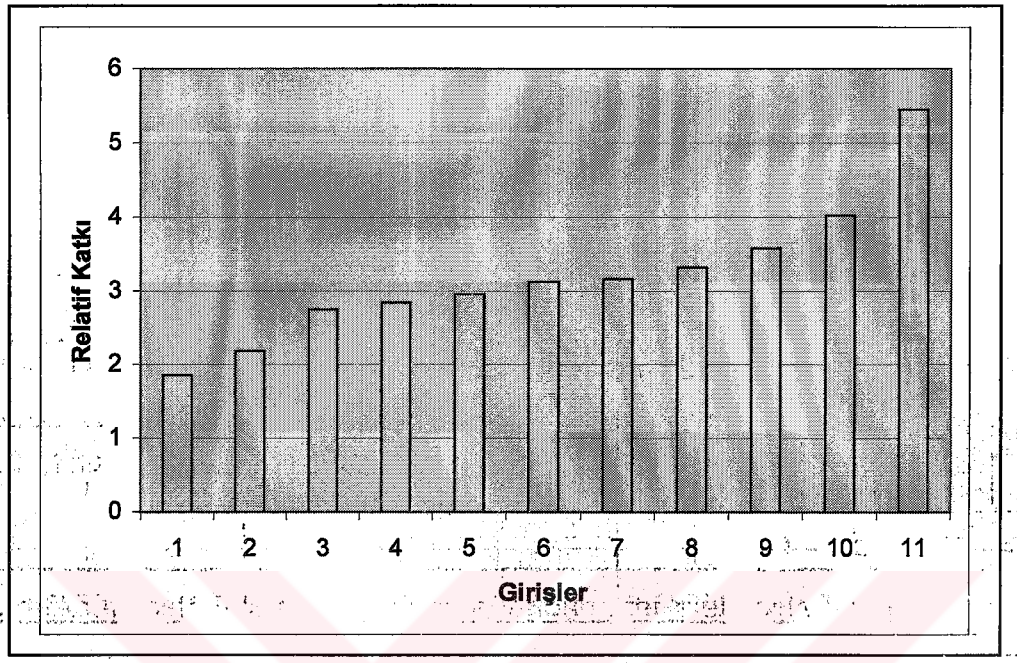

Şekil 10-4 Çizelge 10-3 de gösterilen değerlerin grafiksel gösterimi.

10.6 Hangi Girişlerin Geriye Alınacağının (LAG) ve Geri Alınacak Gün Sayısının Karar Verilmesi

Girişlerin geri alınması (Lagging) ki bu genellikler 5,10 veya 50 gün önceki girişler olarak düşünülmelidir;büyük tahminsel yeteneği vardır.Bu yüzden, hangi girişlerin geri alınabilme yeteneğinin olduğunu anlamak için aşağıdaki girişlerin geri alınmış değerleri kullanılacaktır ;

- S&P 500 En Yüksek Değer Endeksinin 10 Günlük Geri Alınmış Değeri
- S&P 500 En Düşük Değer Endeksinin 10 Günlük Geri Alınmış Değeri
- S&P 500 Kapanış Değerinin 10 Günlük Geri Alınmış Değeri
- Benzin Endeksinin 10 Günlük Geri Alınmış Değeri
- Dow Üretim Endeksinin 10 Günlük Geri Alınmış Değeri
- Dow Taşımacılık Endeksinin 10 Günlük Geri Alınmış Değeri

- Dow CRB Endeksinin 10 Günlük Geri Alınmış Değeri
- Altın ve Gümüş Endeksinin 10 Günlük Geri Alınmış Değeri
- Hacmin 30 Günlük Hareketli Ortalamasının 10 Günlük Geri Alınmış Değeri

Katkı	Giriş
3,95614	Lag (10) Üretim
4,11610	Lag (10) S&P500 Kapanış
4,33969	Lag (10) S&P500 Düşük
4,34565	Lag (10) S&P 500 Yüksek
4,58643	Lag (10) CRB
4,79716	Lag (10) Har Ort(30)Hacim
5,14433	Lag (10) Altın gümüş
5,36414	Lag (10) Taşımacılık
7,45319	Lag (10) Benzin

Çizelge 10-4 10 günlük lag değerine sahip girişlerin relative katkısı.

Eğitim örneğinin çıktıları çizelge 10-4 ve şekil 10-5 de gösterilmiştir. Dikkat edilirse 4 numaralı giriş benzin fiyatının en çok katkıyı yapığı görülebilir ve bu değer kendisine en yakın değerin % 60 %70 daha iyisidir. Geri alınmış girişlerin ağırlıklarının gösterilmesi için bu network 880,600 olay eğitilmiş ve sonuç olarak 0.00174 lik hata oranına sahip olmuştur. Bu daha önceki 0.00178 den bir derece daha iyidir. (Joseph, S.Z., S 18-22 ,1997)

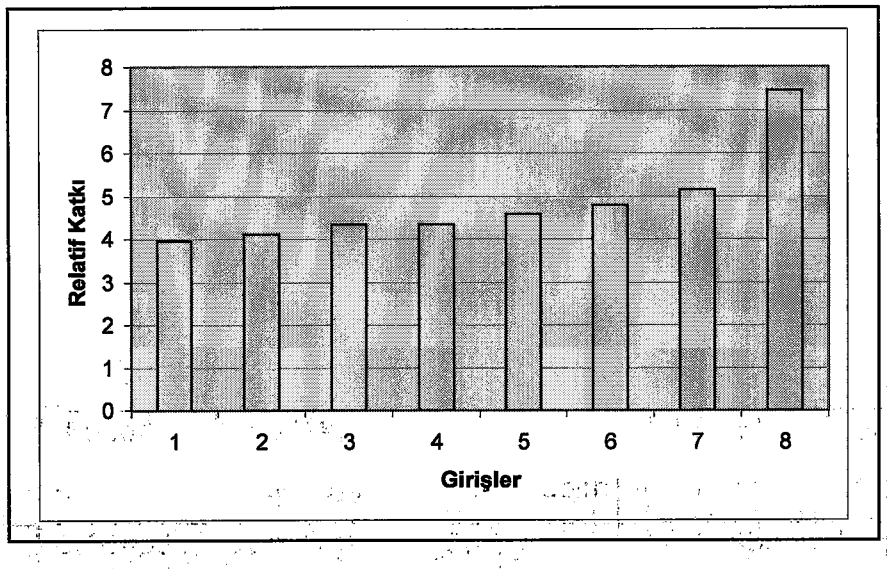

Şekil 10-5 Çizelge 10-4 deki dataların grafiksel gösterimi.

En iyi gerialmanın hangisi olduğuna karar verilebilmesi için network 5,10,15 ve 20 günlük geri almalarla denenmiştir.Bu testler sonucunda 10 günlük geri almanın daha başarılı olduğu gözlenmiştir.Çizelge 10-5 de çizelge 10-4 e göre girişlerin nasıl bir değişim gösterdiği gözlemlenebilir.Şekil 10-6 ise bu bilgileri grafiksel bir formda göstermektedir.Şekil 9-7 ile bu sonuç kıyaslanabilir.

En son network eğitimi için 543,000 eğitim olayı kullanılmış ve 0.00154 lük bir hata oranına sahip olunmuştur.Bu oran şimdiye kadarki işlemler sonucunda erişilen en iyi hata oranıdır.

Katkı	Giriş
2,22390	S&P500 Düşük
2,75324	Lag (5) Benzin
3,00056	CRB
3,17198	Hacim Hareketli (40) Ort.
3,42611	Benzin
3,45828	Lag (20) Benzin
3,56932	S&P500 Yüksek

3,61248	Taşımacılık
3,61321	Lag (15) Benzin
3,61448	S&P500 Kapanış
3,78064	Lag (10) Benzin
4,06948	Ürün
4,42846	Altın Gümüş

Çizelge 10-5 Benzin girişinin 10,15 ve 20 günlük lag'li değerlerinin eklenmiş halinde katkı grafiği.

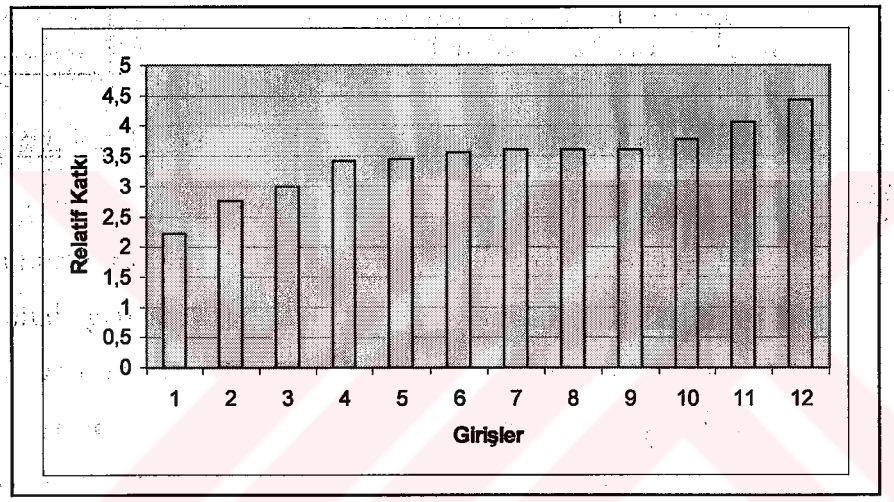

Şekil 10-6 Çizelge 10-5 deki dataların grafiksel gösterimi.

Şimdiye kadar yapılan işlemler averaj hacmin belirlenmesinde en uygun gün sayısının ne olduğu,daha sonra benzin endeksi için 15 günlük gerialmanın en optimum gerialma işlermi olduğunun anlaşılması idi.Bundan sonra yapılacak işlermler ise en fazla katkıyı sağlayan girişler için en uygun hareketli ortalamaların ne olduğu ve Altın,gümüş ve taşımacılık endeksi için en uygun gerialma periyodunun ne olduğunun anlaşılması olacaktır. Daha sonra ise ekstra iyileştirme için birçak teknik gösterge denenecektir.

Şimdiki denenecek işlem altın ve gümüş endeksinin 5,10,15 ve 20 günlük periyotlar için gerialma işlemi olacaktır.Çizelge 10-6 ve şekil 10-7 dan da anlaşılacağı gibi 5,10,15 ve 20 günlük gerialmalarar denk gelen 10,11,12 ve 13

numaralı girişler için bariz şekilde belli olabilen bir zirve değeri yoktur.Bu yüzden bundan sonra 10,20,30 ve 40 günlük gerialmalar için test tekrar yapılmalıdır. Çizelge 10-6 ve şekil 10-7 bu testlerin sonuçlarını göstermektedir.Şekil 10-8 şekil 10-9 ile kıyaslandığında 10,11,12 ve 13 numaralı girişlerin aşağı doğru çekildikleri gözlemlenebilir.Çizelge 10-8 ve şekil 10-9 altın ve gümüş endeksi için en optimum gerialım süresinin 40 gün olduğunu göstermektedir. (Joseph, S.Z., S 25-30 ,1997)

Katkı	Giriş
1,62168	Lag (5) Altın Gümüş
1,86548	Lag (15) Altın Gümüş
2,15252	Lag (10) Altın Gümüş
3,44518	Hacim Hareketli (40) Ort.
3,63554	S&P500 Düşük
3,74607	Lag (20) Altın Gümüş
3,83964	Taşımacılık
3,85705	S&P500 Kapanış
3,93033	Altın Gümüş
4,46468	S&P500 Yüksek
4,53664	Ürün
5,38466	Benzin
5,40981	CRB

Çizelge 10-6 Tablo 9-5 e benzer bir tablo,fark olarak benzin yerine altın gümüş endeksi kullanılmış.

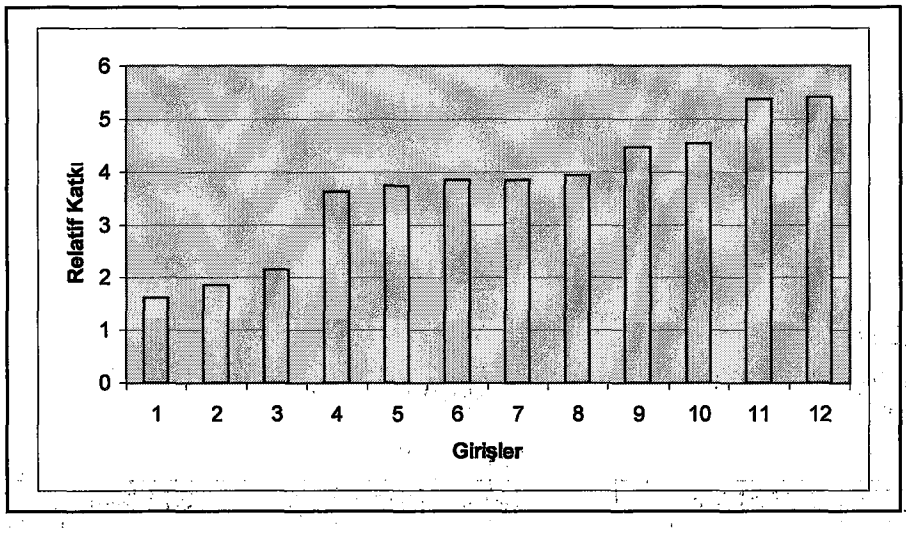

Şekil 10-7 Çizelge 10-6 daki dataların grafiksel gösterimi.

Katkı	Giriş
1,51651	Lag (10) Altın Gümüş
2,38571	Lag (30) Altın Gümüş
2,51152	Lag (40) Altın Gümüş
2,54426	Lag (20) Altın Gümüş
2,73408	S&P500 Düşük
2,77273	Taşımacılık
3,46385	S&P500 Yüksek
3,55830	Altın Gümüş
3,60025	S&P500 Kapanış
3,73590	Hacim Hareketli (30) Ort.
4,07699	Ürün
4,16612	CRB
5,09664	Benzin

Çizelge 10-7 Altın gümüş endeksinin 10,20,30 ve 40 günlük lag'li değerleri kullanılan tablo.

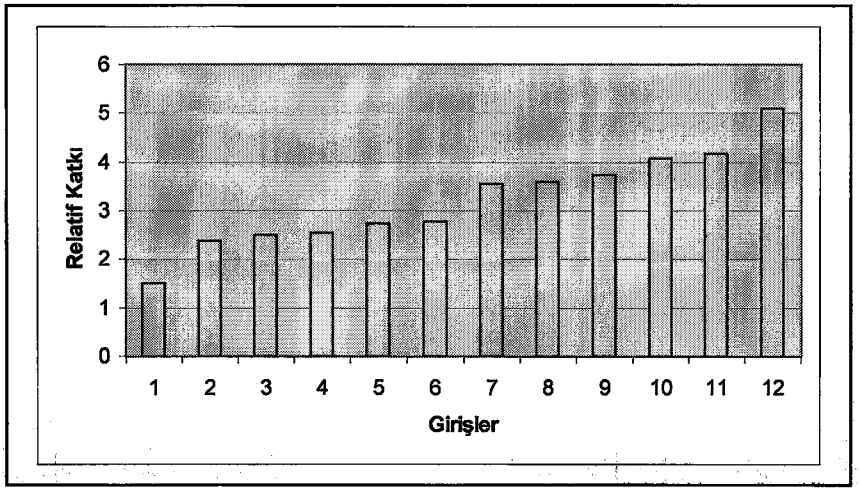

Şekil 10-8 Çizelge 10-7 deki dataların grafiksel gösterimi.

Altın ve Gümüş Endeksi	
Lag li gün sayısı	R – Kareli ortalama hata
0	0,000553
10	0,000522
20	0,000504
30	0,000507
40	0,000455
50	0,000494

Çizelge 10-8 Herhangi bir anda lag'li girişler uygulanmış bir networkdeki hata oranlarını gösteren tablo.

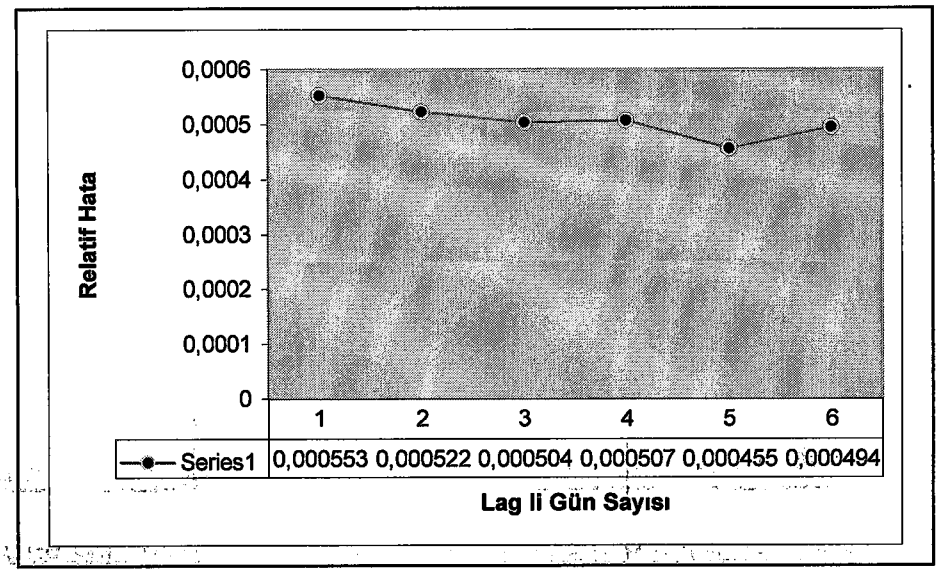

Şekil 10-9 Çizelge 10-8 deki dataların grafiksel gösterimi.

10.7 Hangi Hareketli Ortalama Periyodunun En Fazla Katkı Yaptığının Tesbiti

Girişlere uygulanabilecek hareketli ortalamaların hangi periyodunun daha fazla katkıda bulunduğunun tesbiti için hacim girişi hariç tüm girişler 10 günlük hareketli ortalamalara tabi tutulacak,daha sonra 20 günlük hareketli ortalamalar kullanılacak ve bu şekilde testlere devam edilecek. Dikkat edilmelidir ki networke sadece bu girişlerin hareketli ortalamaları etki edecektir,hareketli ortalamalar kullanılmaya başlandıktan sonra bu girişerin kendileri networke katılmayacaktır.

Katkı	Giriş
2,09745	Harek. Ort.(10) S&P500 Düşük
2,48538	Harek. Ort.(10) Altın Gümüş
2,77351	Harek. Ort.(10) S&P500 Kapanış
3,14686	Harek. Ort.(10) S&P500 Yüksek
334438	Harek. Ort.(10) S&P500 Düşük
3,37550	Harek. Ort.(10) Taşımacılık
3,95879	Harek. Ort.(10) CRB
4,15924	Harek. Ort.(10) Ürün

Çizelge 10-9 Her girişin 10 günlük hareketli ortalamasının kullanılarak test edildiği tablo.

Çizelge 10-9 ve şekil 10-10 tüm girişlere 10 günlük hareketli ortalamalar uygulandıktan sonra eğitimin sonuçlarını göstermektedir.Ürünler,benzin, CRB ve taşımacılık endekslerinin hareketli ortalamalarının networke büyük katkısı olduğu gözlemlenmektedir.Bir sonraki adımda 20 günlük hareketli ortalamalar kullanılacaktır.

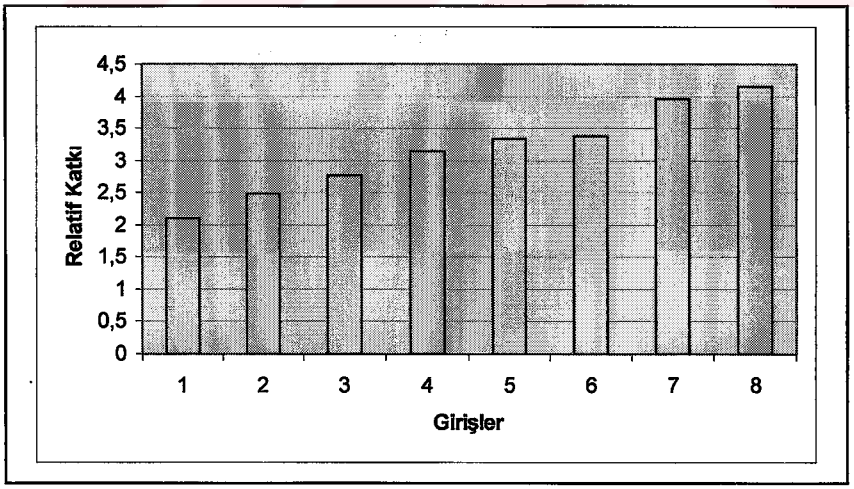

Şekil 10-10 Çizelge 10-9 deki dataların grafiksel gösterimi.

Tablo 9-10 ve şekil 9-10 20 günlük hareketli ortalamalar uygulandıktan sonra eğitimin sonuçlarını vermektedir.Bu sonuçlar bir önceki sonuçların nerdeyse birebir

kopyalarıdır.Tek ciddi değişiklik taşımacılık endeksinin katkısı 20 günlük hareketli ortalama ile birlikte daha fazla olmasıdır.

Katkı	Giriş
2,05892	Harek. Ort.(20) S&P500 Düşük
2,13794	Harek. Ort.(20) Altın Gümüş
2,86380	Harek. Ort.(20) S&P500 Kapanış
3,03801	Harek. Ort.(20) S&P500 Yüksek
3,37122	Harek. Ort.(20) S&P500 Düşük
3,89471	Harek. Ort.(20) Taşımacılık
3,93819	Harek. Ort.(20) CRB
4,36914	Harek. Ort.(20) Ürün

Çizelge 10-10 Her girişin 20 günlük hareketli ortalamasının kullanılarak test edildiği tablo.

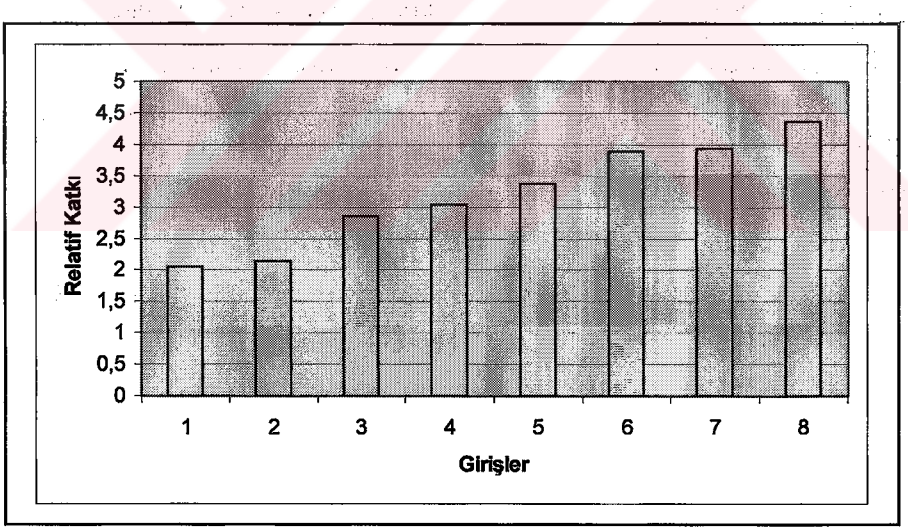

Şekil 10-11 Çizelge 10-10 daki dataların grafiksel gösterimi.

Çizelge 10-11 30 günlük hareketli ortalamalar uygulandıktan sonra eğitimin sonuçlarını vermektedir.Bu sonuçlar da 20 günlük hareketli ortalamaların sonuçları ile hemen hemen aynıdır. (John,G.H.;Zhao,Y, S 90-99,1997)

Katkı	Giriş
1,89894	Harek. Ort.(30) S&P500 Düşük
2,12143	Harek. Ort.(30) Altın Gümüş
2,80172	Harek. Ort.(30) S&P500 Kapanış
2,98514	Harek. Ort.(30) S&P500 Yüksek
3,51706	Harek. Ort.(30) S&P500 Düşük
3,81150	Harek. Ort.(30) Taşımacılık
3,99805	Harek. Ort.(30) CRB
4,43341	Harek. Ort.(30) Ürün

Çizelge 10-11 Her girişin 30 günlük hareketli ortalamasının kullanılarak test edildiği tablo.

10.8 Teknik Göstergeler

Bir networke uygulanabilecek teknik göstergelerin sayısı nerdeyse limitsizdir.Tüm göstergeler uygulandığı zaman periyodu gibi kategorize edilebilirler.Buna ek olarak örneğin al veya sat sinyalleri kullanıcının belirlediği eşik değerlerine göre değişmektedir.

Teknik göstergelerin networke giriş olarak uygulanması için birkaç genel göstergenin networke katkıları incelenebilir.Ilk incelenecek gösterge Wilder diye de anılan 12 günlük RSI göstergesidir.Buna ek olarak, genellikle yönsel değişiklikleri gösteren 12 günlük RSI 'ın 12 günlük hareketli ortalaması incelenecektir.

Katkı	Giriş
1,40279	CRB
1,73755	Taşımacılık
1,81674	Wilder RSI (12) S&P500 Kapanış
1,97205	Harek. Ort.(12) Wilder RSI (12) S&P500 Kapanış
2,21270	Ürün
2,50631	Altın Gümüş End
2,91393	S&P500 Yüksek
3,38531	S&P500 Kapanış
3,98386	S&P500 Düşük

Çizelge 10-12 12 günlük RSI ve 12 günlük RSI in 12 günlük hareketli ortalamalı değerli giriş-katkı tablosu.

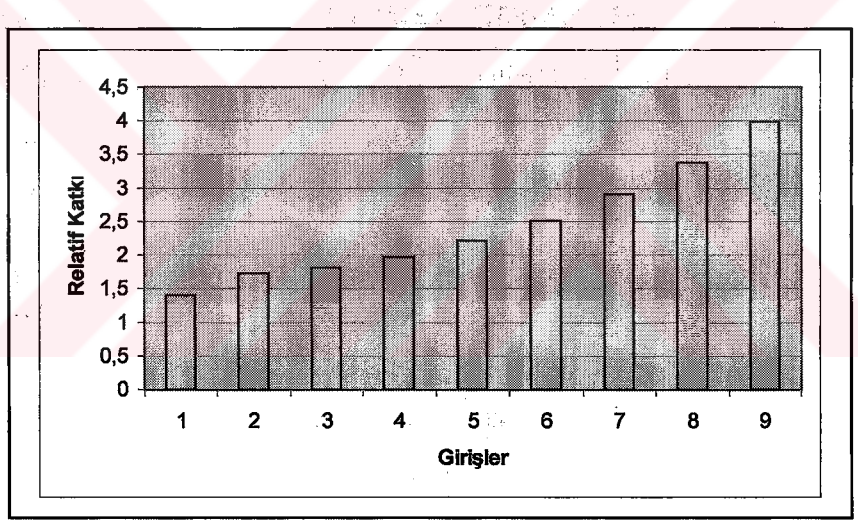

Şekil 10-12 Çizelge 10-12 daki dataların grafiksel gösterimi.

Çizelge 10-12 ve şekil 10-12 bu iki göstergenin katkılarını göstermektedir.Beklenmedik şekilde etkileri zayıftır.Büyük ihtimalle bu iki gösterge arasındaki non-lineerlik networkü kötü yönden etkilemektedir.Bu nedenle göstergelerin ayrı ayrı test edilmesi gerekmektedir.Ilk olarak test edilen 12 günlük RSI göstergesinin test sonuçları çizelge 10-13 ve şekil 10-13 de görülmektedir.

RSI endeksi daha iyi etki yapmaktadır.Bu şekil 10-13 ve 10-12 izlenilerek görülebilir.Ayrıca her iki gösterge kullanılarak oluşturulan network 0.00218 hata değerine sahipken sadece RSI kullanılarak oluşturulan networkün 0.00190 hata değeri vardır.

12 günlük hareketli ortalamalı 12 günlük RSI kullanılarak test edilen networkün sonuçları çizelge 10-14 ve şekil 10-14 de gözlemlenebilir.Sonuç sadece RSI kullanılarak test edilen networkün ki kadar iyi olmasa da gene de her iki değer kullanılarak test edilene göre daha iyidir.12 günlük RSI kullanılarak test edilen network en iyi seçim kabul edilebilir.Bu arayış farklı günlerin RSI değerlerin denenmesi ile genişletilebilir. (Joseph, S.Z.,S 75-77,1997).

Katkı	Giriş
2,35697	S&P500 Yüksek
2,55498	Taşımacılık
2,84366	Ürün Wilder RSI (12) S&P500 Kapanış
2,92278	CRB
2,94794	Altın Gümüş End
2,95302	Wilder RSI (12) S&P500 Kapanış
3,14279	Benzin
3,56224	S&P500 Kapanış
3,60003	S&P500 Düşük

Çizelge 10-13 12 günlük RSI değeri giriş olarak kullanılmış bir tablo.

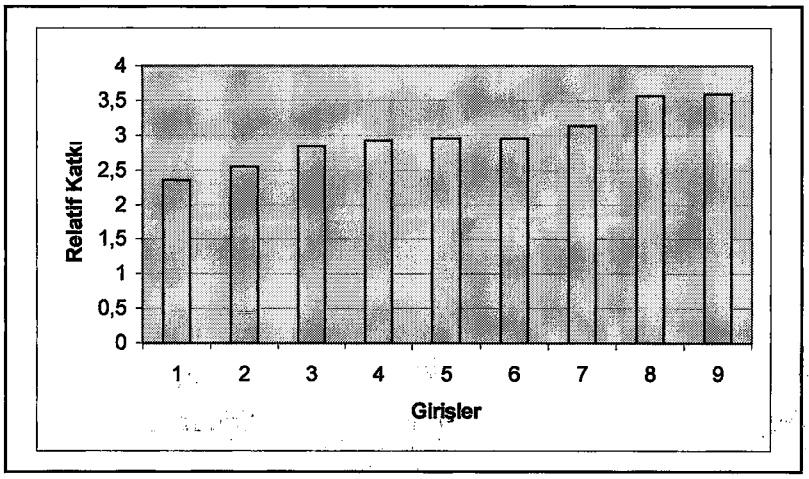

Şekil 10-13 Çizelge 10-13 deki dataların grafiksel gösterimi.

Bundan sonra Bollinger çizgilerinin ne kadar faydalı girişleri oldukları incelenecektir.Bollinger çizgileri fiyat bilgisinin altına ve üstüne çizilen çizgilerdir.

Katkı	Giriş
2,09485	S&P500 Düşük
2,12979	Harek. Ort.(12) Wilder RSI (12) S&P500 Kapanış
2,37479	Taşımacılık
2,92374	S&P500 Kapanış
3,14522	Altın Gümüş End
3,18821	CRB
3,25310	Benzin
3,52732	Ürün
3,76387	S&P500 Yüksek

Çizelge 10-14 12 günlük RSI değerinin 12 günlük hareketli ortalaması giriş olarak alınmış bir tablo.

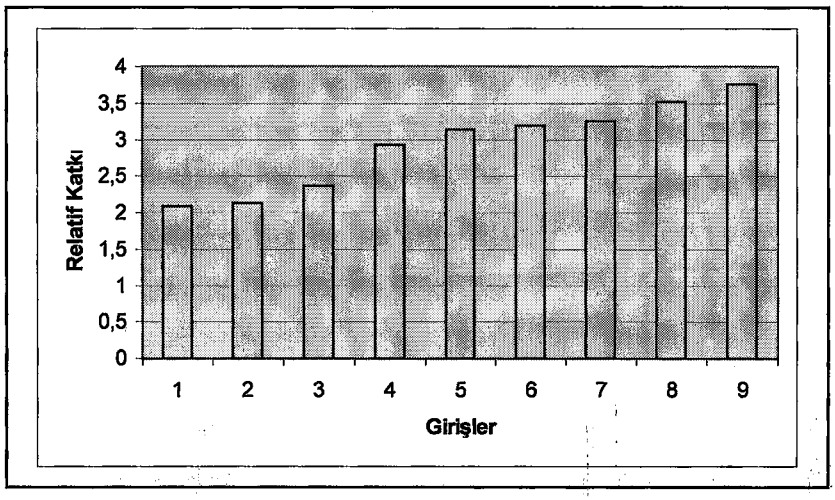

Şekil 10-14 Çizelge 10-14 deki dataların grafiksel gösterimi.

Çizgiler genellikle 20 günlük hareketli ortalamanın altına ve üstüne çizilirler.Şekil 10-15 S&P 500 endeksinin günlük fiyat data'sının her iki tarafına da çizilmiş Bollinger çizgilerini göstermektedir.

Çizelge 10-11 ve şekil 10-16 Bollinger çizgileri kullanılarak eğitilmiş networkün sonuçlarını göstermektedir.Bu çizgiler S&P 500 endeksinin 20 günlük hareketli ortalamasının iki tarafına çizilmiştir.Bollinger çizgilerinin katkısı olumlu yönde olduğu gözlemlenebilir.

Bir sonraki adımda 12 günlük momentüm göstergesi uygulanacaktır. Bu değer "S&P500-C 'nin 12 günlük değişimi" şeklinde de adlandırılabilir ve bilgisayarda "S&P500-C Değişim(12)" şeklinde görülmektedir.Bu gösterge fiyattaki son 12 günlük değişimi göstermektedir.Bu göstergenin de 4. Büyük katkısı olan giriş olduğu gözlemlenebilir. (Joseph, S.Z.,S 79-81,1997).

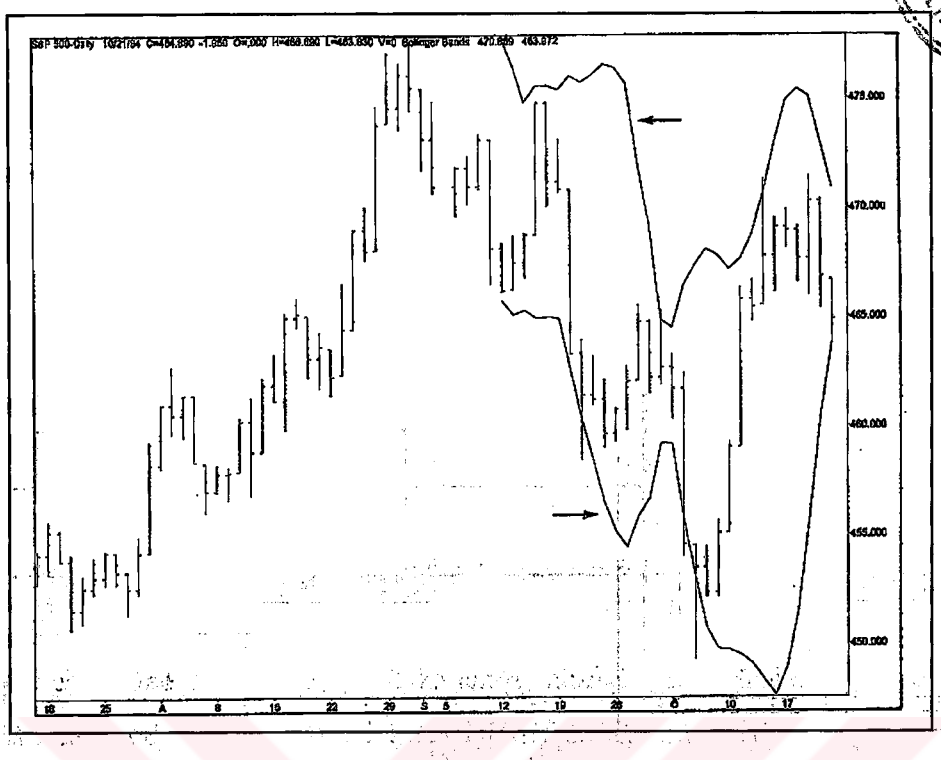

Şekil 10-15 S&P 500 fiyat datasının alt ve üst tarafından Bollinger Bantları çizilmiş bir grafiği.

Katkı	Giriş
1,84469	S&P500 Düşük
2,41241	Taşımacılık
2,51149	BbandDüşük (20,2) S&P500 Kapanış
2,56552	BbandYüksek (20,2) S&P500 Kapanış
2,57661	S&P500 Kapanış
2,76961	S&P500 Yüksek
3,33409	Ürün
3,74759	Benzin
3,87163	Altın Gümüş End
4,08155	CRB

Çizelge 10-15 Bollinger bantları ek giriş olarak eklenmiş bir networkün katkı tablosu.

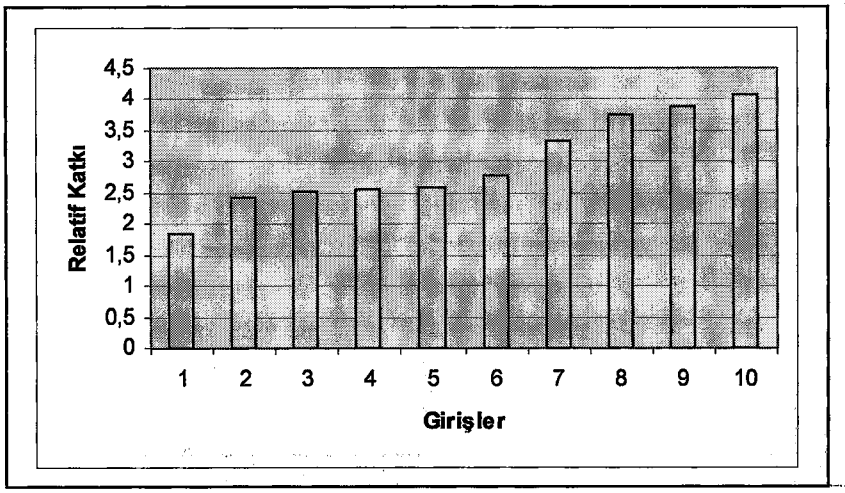

Şekil 10-16 Çizelge 10-15 deki dataların grafiksel gösterimi.

Katkı	Giriş
2,22728	S&P500 Düşük
2,82420	Taşımacılık
3,11503	CRB
3,20623	S&P500 Kapanış
3,32080	Altın Gümüş End
3,50186	Değişim (12) S&P500 Kapanış
3,53974	Ürün
3,55968	Benzin
3,59859	S&P500 Yüksek

Çizelge 10-16 Değişim (12) Momentum göstergesi eklenmiş giriş-katkı tablosu.

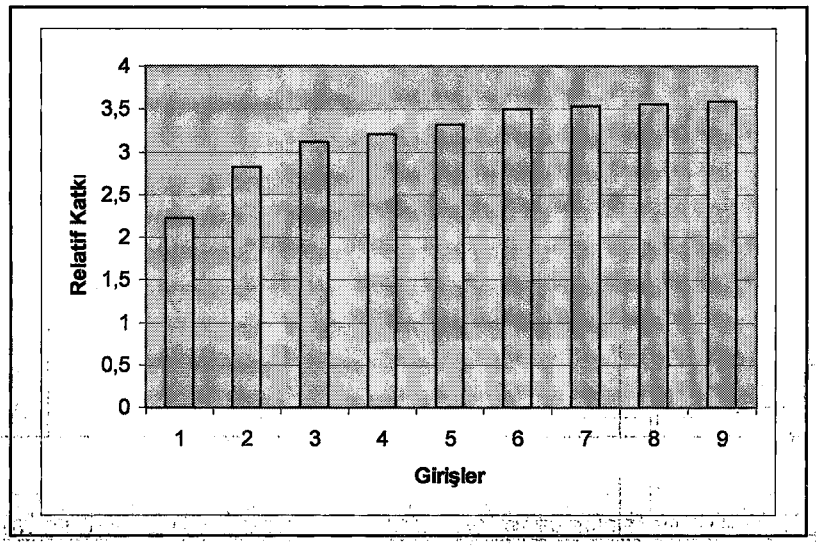

Şekil 10-17 Çizelge 10-16 deki dataların grafiksel gösterimi.

10.9 Kesin Girişlerin Seçimi

Testler çok sayıda olası teknik gösterge oluşturmuştur.Şimdiki problem bu göstergeler arasından katkıları iyi olan az sayıda göstergeyi seçmektedir.Ana girişler aşağıdaki gibidir :

- S&P 500 Enyüksek
- S&P 500 Endüşük
- S&P 500 Kapanış
- Benzin Endeksi
- Dow Üretim Endeksi
- CRB Endeksi
- Altın ve Gümüş Endeksi

Bu girişlere testler sonucu en yüksek değerleri alan 4 giriş daha eklenecektir.Bunlar ;

- CRB'nin 10 Günlük Gecikmeli Değeri
- Altın ve Gümüş Endeksi'nin 10 Günlük Gecikmeli Değeri
- Dow Taşımacılık Endeksi'nin 10 Günlük Gecikmeli Değeri
- Benzin Endeksinin 10 Günlük Gecikmeli Değeri

Daha sonra hacmin 30 günlük hareketli ortalamasını eklemek gerekmektedir.Dikkat edilirse hacim dışında hiçbir girişin hareketli ortalaması eklenmemektedir.Teknik göstergelerin networke katkısı 2.5-3.5 aralığında,hareketli ortalamaların katkısı ise 3-4 aralığında olmaktadır. Bunlar dışındaki tüm girişlerin katkıları 5'den büyüktür ve 5'den büyük katkıya sahip girişler networke katılmaktadır. (Carpenter, W., Hoffman, M. , S 30-33, 1990)

Bu girişler geri yayılımlı bir networkte grup olarak test edilmişlerdir. Bu testlerin sonuçları Çizelge 10-17 ve şekil 10-18 de gösterilmektedir.

Katkı	Giriş
1,96568	Lag (10) Altın Gümüş End
2,65485	S&P500 Kapanış
2,68148	S&P500 Yüksek
2,84308	S&P500 Düşüş
3,07333	Taşımacılık
3,33825	Hareketli Ort. (30) Hacim
3,34365	CRB
3,65791	Lag (10) CRB
3,73944	Altın Gümüş End
3,82980	Ürün End
4,70225	Benzin
4,72849	Lag (10) Benzin

4,75725	Lag (10) Taşımacılık

Çizelge 10-17 Hemen hemen bitmiş bir networkte girişlerin katkısını göstermektedir.

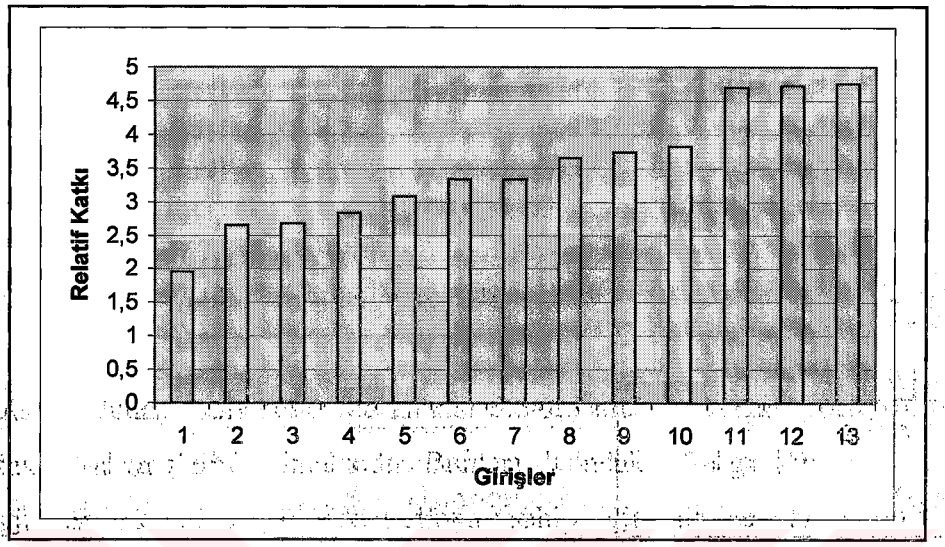

Şekil 10-18 Çizelge 10 -17 deki dataların grafiksel gösterimi.

10.10 Sonuç Networkü

Daha önceki bilgilerden de hatırlanabileceği gibi GRNN networkleri en başarılı sonucu veren networklerdir.Bu nedenle sonuç networkü de GRNN networkü olmalıdır.Eğitim sırasında network bir uygunlaştırma faktörü ortaya atar,daha sonra bunu test eder,daha sonra farklı bir uygunlaştırma faktörünü test eder.Bu olay network en az hata oranına sahip uygunlaştırma faktörünü bulana kadar devam eder.

GRNN networkü 0.04551 değerinde bir uygunlaştırma faktörüne sahipti ve bu network için hata değeri 0.000505 dir.Bu 1.965 ortalama hata değeri anlamına gelmektedir.Aynı network 3 katmanlı 12 gizli katmanlı geri yayılımlı bir modele uygulandığında ortalama hata değerinin 4.038 olduğu görüldü.GRNN networkü aynı girişlerin uygulandığı bir geri yayılımlı networke göre 2 kat daha doğru sonuçlar vermektedir. (Carpenter, W., Hoffman, M. , S 36-37, 1990)

10.11 Jenerik Algoritmalı GRNN Networkü

Jenerik algoritmalı GRNN networkleri zaman serili networklerde uygulandığında 2 kat daha doğru sonuçlar vermektedir.Ayrıca Jenerik algoritmalı GRNN networklerine her girişin networke katkısını hesaplayabilen hassasiyet faktörü eklenmiştir.

Sonuç GRNN networkü için kullanılan girişler JA-GRNN networkü için kullanılmıştır.Bu network için hata oranı 0.0004181,ortalama hata ise 1.843 ölçülmüştür.Bu GRNN networküne göre % 20 lik bir iyileştirme anlamına gelmektedir.Bununla beraber hassasiyet fonksiyonu göstermiştir ki S&P 500 kapanış,Dow 30 ve TRIN girişleri silinebilmektedir.Bu işlem yapıldığında hata oranı 0.000235'e düşmektedir.Daha sonra hassasiyet fonksiyonu OEX fonksiyonunun networkten çıkarılabileceğini göstermiştir. OEX fonksiyonu çıkartılmış ve network tekrar eğitilmiştir. Bu işlem sonunda hassasiyet fonksiyonu Dow taşımacılık endeksinin networkten çıkarılmasının networkün başarısını arttıracağını göstermiştir. Bu işlem yapıldıktan sonra network tekrar eğitilmiştir.Eğitim sonrasında hassasiyet fonksiyonu Altın ve gümüş endeksinin gecikmeli değerinin kaldırılmasının network başarısını arttıracağını göstermiştir.

Tüm bu işlemler yapıldıktan sonra network hatasının 0.0002992 değerine ortalama hatanın ise 1.53 değerine düştüğü gözlenmiştir. (Gately,E.,S 78-85,1996)

11. ÖRNEK UYGULAMALAR

11.1 Ayrıntılı bir YSA Örneği

Bu örnekte basit bir yapay sinir ağı örneği ayrıntılı olarak gösterilecektir. Network oluşturma ve eğitim safhaları ayrıntılı olarak incelenecektir. YSA ile tahminde bulunulacak örnek için girişler ve istenilen gerçek çıkış değerleri aşağıdaki gibidir :

Durum	Giriş 1	Giriş 2	Giriş 3	İstenilen Çıkış
1	5	32	2	2
2	2	45	5	5
3	11	66	3	3
4	7	89	6	6
5	4	56	7	7
6	12	98	6	6

Daha sonra her giriş için bir input nöronu hazırlanacaktır.Ayrıca çıkıç için de bir çıkış nöronu hazırlanacaktır.Giriş ve çıkışlar için hazırlanan ilk temel network Şekil 11.1 de gösterilmiştir.

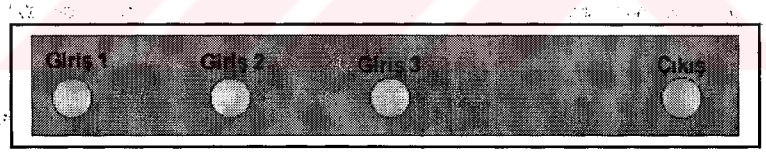

Şekil 11.1 Giriş ve çıkışlardan oluşmuş ilk network yapısı

Daha sonra teker teker her durum için giriş değerleri yerlerine yazılmaktadır. Bu işlemden sonra her bir giriş çıkış değerine bağlanmaktadır.Giriş nöronlarından çıkış nöronuna bağlantıya "ağırlık" adı verilmektedir.Çıkış değeri giriş değerlerinin ağırlıkla birlikte fonksiyonunun sonuçlarının toplamıdır.Çıkış değerinin istenilen gerçek çıkış değerine mümkün olduğu kadar yakın olması ana amaçtır.Başlangıçta ağırlık değerleri rastgele değerler olarak seçilmektedir.Bu nedenle ilk sonuçlar istenilen çıkış değeri ile büyük farklılıklar içerebilirler.Zamanla networkün eğitimi sürdükçe ağırlık değerleri doğru çıkış değerinin elde edilebilmesi için network tarafından eğitilecektir.

Çıkış değeri ile istenilen çıkış değeri arasındaki fark "hata" olarak adlandırılmaktadır.Bu hata ne kadar küçükse tahmin de o kadar iyi yapılmış sayılmaktadır.Networke ilk giriş değerleri uygulandığında network'ün verdiği çıkış değeri ve bu çıkış değerine karşılık gelen istenilen çıkış değeri şekil 11.2 de gösterilmiştir.İlk set giriş değerleri networke verilirken ağırlık değerleri rastgele verilmektedir.Dikkat edilirse istenilen çıkış değeri 13 iken network çıkış değeri 1.79 olmuştur.Tüm durum giriş değerleri networke girildiğinde bir "çevrim" tamamlanmaktadır ve ilk çevrim tamamlandıktan sonra bir sonraki çevrimlerle networkün eğitilmesi devam etmektedir.Herbir çevrim sonucunda istenilen çıkış değeri ve network çıkış değeri arasındaki "hata" oranı gittikçe düşecektir.

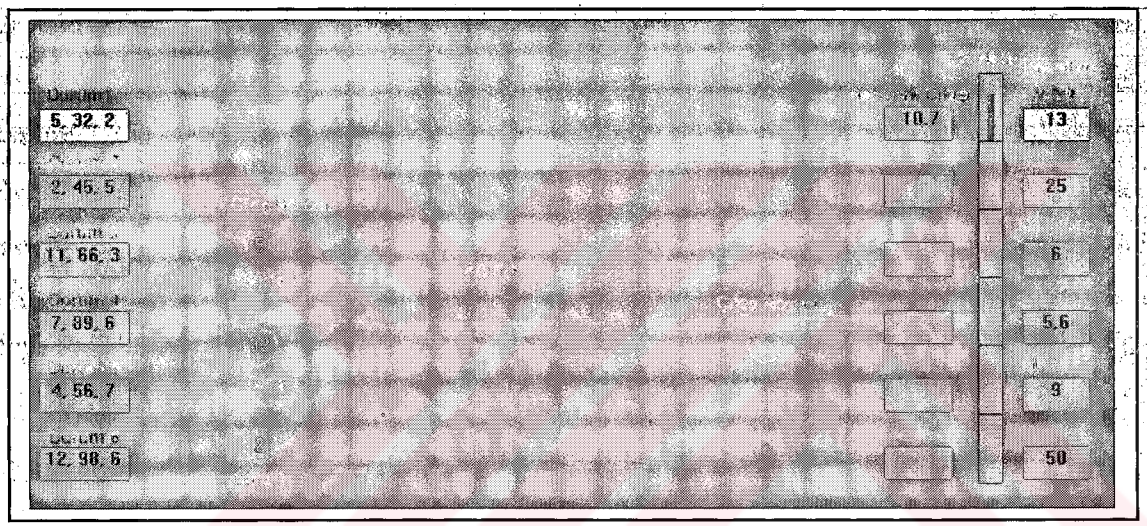

Şekil 11.2 İlk durum ile ilgili giriş değerleri networke uygulandıktan sonra elde edilen çıkış değeri ve bunun istenilen çıkış değeri ile kıyaslanması.

Birinci durumdan sonraki durumlar teker teker networke uygulanıp her bir durum için bir çıkış değeri alındıktan sonra 1. çevrim tamamlanır.1. çevrim sonucu elde edilen network çıkışları ağırlıkların rastgele seçilen değerleri ile hesaplandığı için büyük hata değerleri ile karşılaşmak çok büyük bir olasılıktır.Birinci çevrim sonucunda toplam hata değeri 33,54 olarak hesaplanmıştır.İlk çevrim sonunda elde edilen çıkış değerleri şekil 11.3 de gösterilmiştir:

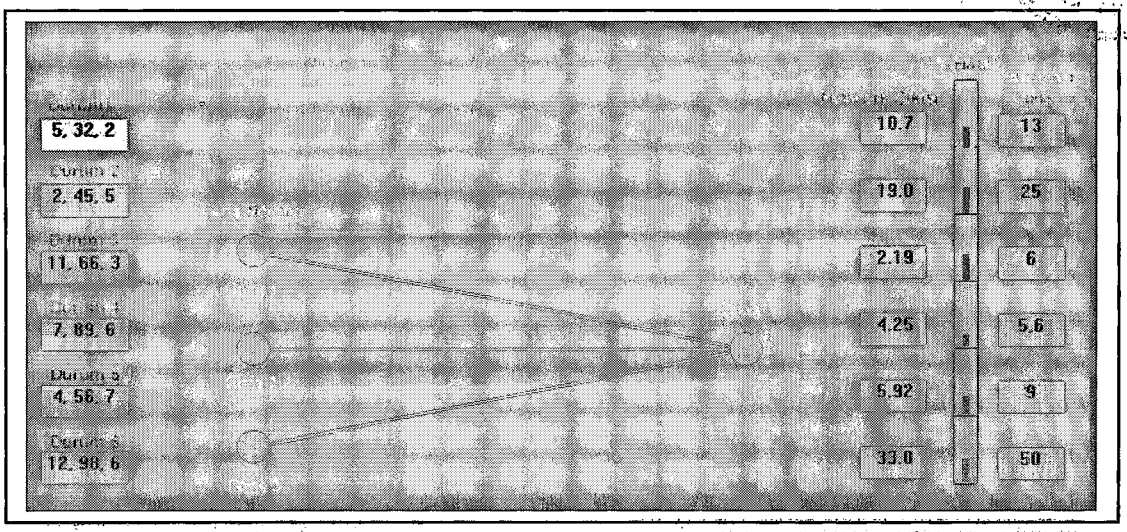

Şekil 11.3 İlk çevrim sonucu elde edilen çıkış değerleri.

Dikkat edilirse network çıkışı ile istenilen çıkış değerleri arasında genellikle büyük farklar vardır.Bu farklar,diğer bir değişle hatalar bundan sonraki çevrimlerde networkün eğitilmesi ile azalacaktır.

Eğer toplam hata değeri çok büyük çıkarsa bu durumda istenilen çıkış değerine yakın çıkış değerleri alınabilmesi için networke "gizli nöron"lar eklenmelidir.Gizli nöronlar giriş nöronları ve çıkış nöronu arasına yerleştirilmektedir.Gizli nöronlar istenilen çıkış değerlerinin alınabilmesi ve networkün daha iyi eğitilebilmesi için ağırlık değerlerinin ayarlanabilmesini sağlamaktadır.

Öğrenme işlemi ortalama hata değeri kabuledilebilir bir seviyeye gelene kadar veya öğrenme devam ettiği halde ortalama hata değerinde iyileşme olmadığı noktaya kadar devam ettirilir.2. çevrim ile birlikte networke bir adet gizli nöron eklenmiştir ve 2. çevrim sonucundan istenilen değer ve çıkış değeri şekil 11.4 deki gibi görünmektedir.Bu çevrim sonucu hata değeri 34,5 olarak ölçülmüştür.Görüldüğü gibi her çevrim sonucu hata değeri azalmayabilmektedir.Bu durumda network gizli nöronlar kullanarak bu hata değerini azaltmaya çalışmaktadır.

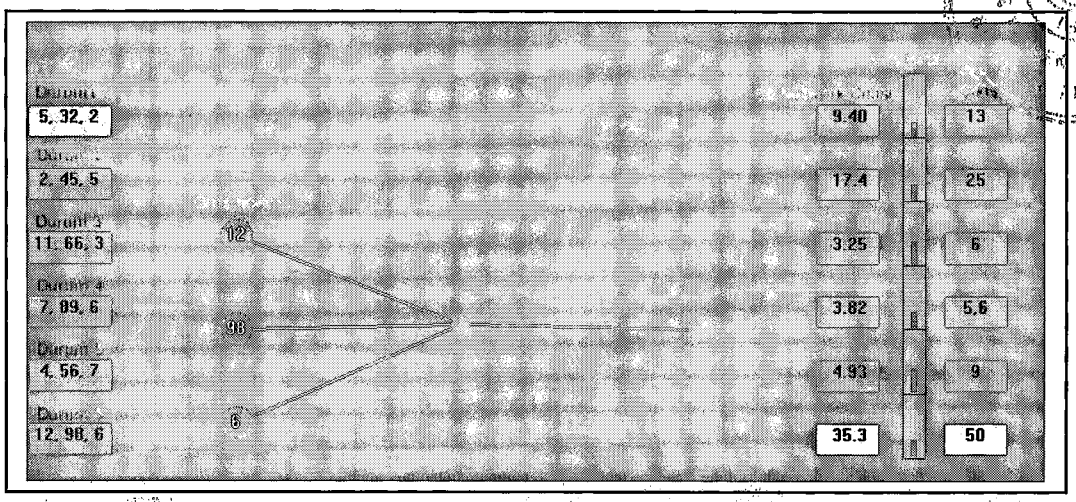

Şekil 11.4 Gizli nöron konularak uygulanan 2. çevrim sonucu network çıkışı.

5. çevrim sonucunda network çıkışı ve network'ün görünümü şekil 11.5'deki gibidir.Ayrıca 5. çevrim sonucunda toplam hata değeri 16,79 olmuştur.Dikkat edilirse 2. çevrim sonunda 34,5 olan toplam hata değeri 16,79 a düşmüştür.

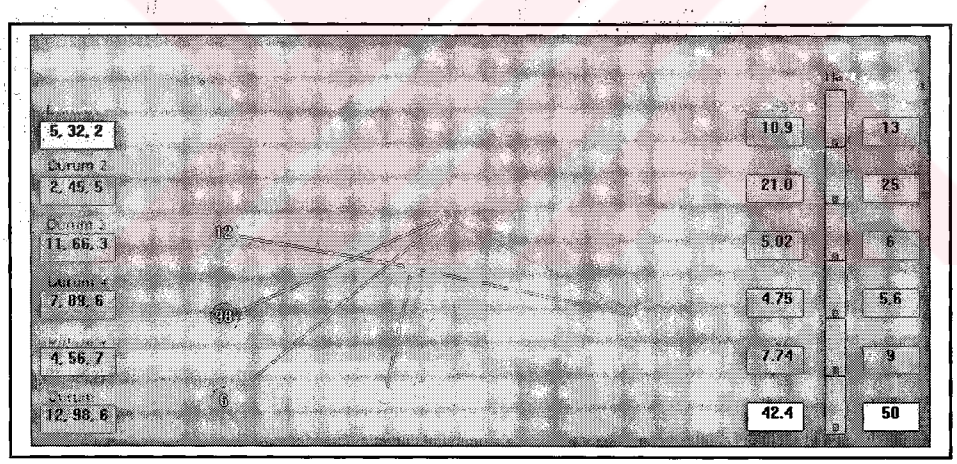

Şekil 11.5 5. çevrim sonunda network çıkışı ve networkün görünümü.

10. çevrim sonucunda network çıkışı ve network'ün görünümü şekil 10.6'deki gibidir.Ayrıca 10. çevrim sonucunda toplam hata değeri 9,6 olmuştur.Dikkat edilirse 2. çevrim sonunda 16,79 olan toplam hata değeri 9,6 ya düşmüştür.

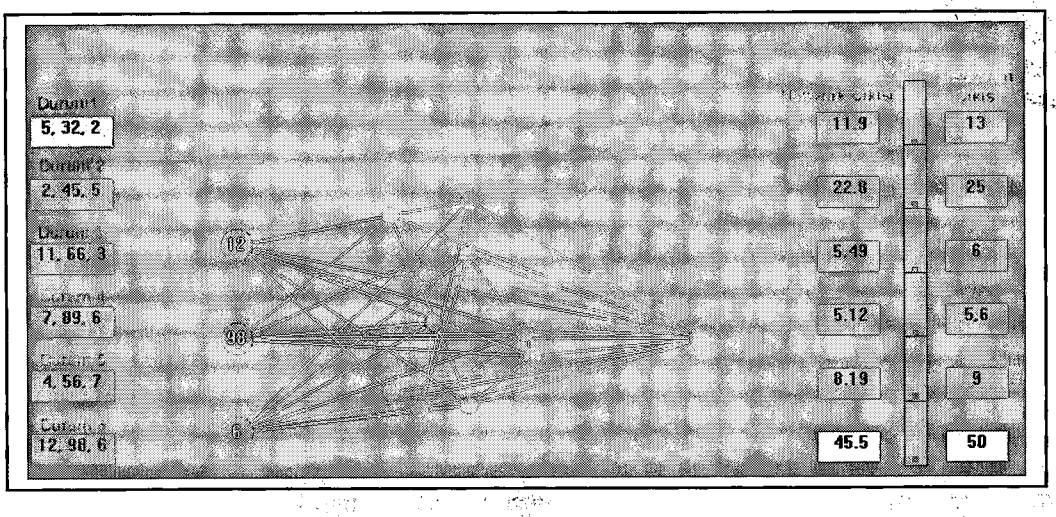

Şekil 11.6 10. çevrim sonunda network çıkışı ve networkün görünümü.

21. çevrim sonucunda artık networkün öğrenmesi tamamlanmıştır.Şekil 11.7 de 21 çevrim sonucunda networkün çıkış değerleri ve istenilen çıkış değeri ile karşılaştırılması gösterilmiştir.21. çevrim sonucunda toplam hata 5,27 olmuştur. Ortalama hata ise 0.87 olmuştur.21. çevrim sonucunda networkün eğitimi tamamlanmıştır.Artık network yeni girişlerin uygulanabilmesi için hazır durumdadır.

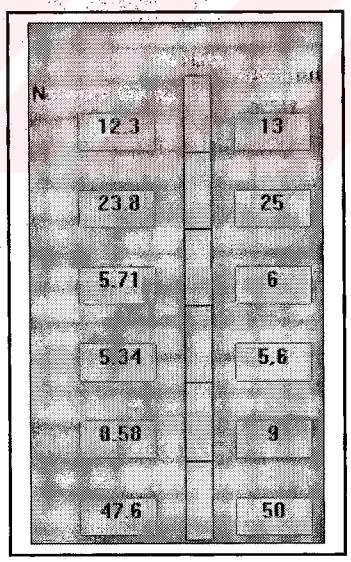

Şekil 11.7 21. çevrim sonunda network çıkışının görünümü.

11.2 YSA Programı Kullanılarak Yapılan Bir YSA Örneği

Bu örnek Brainmaker 2.0 Professional isimli bir yapay sinir ağı similasyon programı kullanılarak gerçekleştirilmiştir.Bu örnek uygulamada IMKB de işlem görmekte olan Türk Hava Yolları A.Ş isimli şirketin 5 günlük fiyat değişimi tahmin edilmeye çalışılmıştır.Giriş değerleri olarak bu hisseyi etkilediği düşünülen etkenler seçilmiştir.Giriş değeri olarak kullanılan değişkenler şunlardır :

- Döviz Piyasası
- Dünya Ekonomi (Dünya bankası genel ekonomik göstergesi)
- New York Stock Exchange 7 Günlük Hareketli Ortalaması
- Interbank Gecelik Faiz 7 Günlük Hareketli Ortalaması
- Altın Piyasası 7 Günlük Hareketli Ortalaması
- Hissenin Al/Sat Göstergesi
- IMKB deki Dolaşan Paranın 7 Günlük Hareketli Ortalaması
- IMKB Sanayi Endeksi 7 Günlük Hareketli Ortalaması
- IMKB İşlem Hacmi 7 Günlük Hareketli Ortalaması
- Hisseye Ait Özvarlıklar Değeri
- Hisseye Ait Aktif Kar Değeri
- Hisseye Ait Toplam Borç Oranları
- Hisseye Ait Cari Oranlar
- Hisseye Ait Kar Marjı Değeri

Çıkış değeri olarak hissenin kapanış fiyatı alınmıştır.Bu değerlerden oluşan 133 günlük data tablosu YSA programının eğitilmesi için kullanılmıştır.Bu tablonun %10 luk kısmı eğitim için kullanılmayıp eğitim sonuçlarının test edilmesi için test datası olarak kullanılmıştır.Bu sayede network'ün eğitim başarısı gözlenmiştir.Bu test sonuçlarından en iyi sonuç elde edilene kadar eğitim sürdürülmüştür.3000 eğitim olayından sonra eğitim başarısında değişim gözlemlenemediği için network'ün eğitimi 3000 eğitim olayından sonra durdurulmuştur.Aşağıda eğitim için kullanılan data tablosu görülmektedir.

Giriş 1 Döviz	Giriş 2 D. Ekonomi	Giriş 3 NSE Har 7	Giriş 4 Inter Har. 7	Giriş 5 Altın Har. 7	Giriş 6 Al/Sat	Giriş 7 Dolas Har. 7
483.5775366	79859	394.5757143	0.834285714	5174.285714	0.719	179739.7143
485.6913981	79110.5	396.2328571	0.82	5167.142857	0.719	178920.2857
483.5451334	78141	397.2642857	0.805714286	5167.142857	0.719	178100.8571
485.4351592	78432.5	397.4785714	0.877142857	5174.285714	0.719	179451.5714
482.1103116	78388	397.7214286	0.942857143	5185.714286	0.719	180802.2857
478.6485209	78489	398.0357143	1.014285714	5197.142857	0.719	182972.4286
478.0320653	78892.5	398.4071429	1.007142857	5211.428571	0.719	185142.5714
479.4222694	78622	398.4342857	1	5222.857143	0.719	187312.7143
473.6046955	78907.5	398.7285714	0.985714286	5240.714286	0.719	188856.5714
481.887517	78733.5	399.3357143	0.971428571	5269.285714	0.719	190400.4286
483.1672477	79405.5	400.3857143	0.885714286	5297.857143	0.719	189774.1429
479.2640482	79252	401.2714286	0.857142857	5322.142857	0.719	189147.8571
477.7869187	79325.5	402.2642857	0.828571429	5353.571429	0.719	188521.5714
482.2126112	79798	403.2928571	0.878571429	5382.142857	0.719	190760.2857
481.335235	79674	404.68	0.928214286	5417.857143	0.719	192999
482.7217068	80207	405.1285714	0.963928571	5438.571429	0.715	195864
481.5993386	80730.5	405.5928571	1.021071429	5457.142857	0.715	198729
478.2328299	80407.5	407.3714286	1.0525	5492.857143	0.715	201594
479.5083978	80959	408.8571429	1.0525	5535.714286	0.715	204589.1429
482.253192	80325	409.7428571	1.045357143	5571.428571	0.715	207584.2857
484.5885908	80490.5	410.7714286	1.038214286	5614.285714	0.715	207714.4286
486.2757769	80768	410.9142857	0.974285714	5642.857143	0.715	207844.5714
485.2589989	80988	411.4571429	0.924285714	5668.571429	0.715	207974.7143
486.330861	81110.5	411.1071429	0.852857143	5685.714286	0.715	217556.7143
486.052849	82237	409.4071429	0.807142857	5692.857143	0.715	227138.7143
481.8099717	81442.5	408.0214286	0.735714286	5685.714286	0.715	236590.5714
478.2821857	81180.5	406.8357143	0.671428571	5685.714286	0.715	246042.4286
482.2675828	80957.5	405.8785714	0.671428571	5678.571429	0.715	255494.2857
482.9254383	80957.5	404.6071429	0.657142857	5692.857143	0.715	257313.4286
476.116332	80873.5	403.5642857	0.65	5721.428571	0.715	259132.5714
478.4314739	80749	402.8628571	0.707142857	5750	0.715	251499.8571
480.0449798	80751.5	402.5914286	0.764285714	5771.428571	0.7025	243867.1429
478.9668989	80811	401.9842857	0.814285714	5807.142857	0.7025	236234.4286
477.6391628	80669	400.5414286	0.864285714	5821.428571	0.7025	228065.7143
479.3837576	81310.5	398.87	0.85	5835.714286	0.7025	219897
478.6998699	81513	398.1271429	0.9	5835.714286	0.7025	219361
480.5298368	81754	396.8485714	0.95	5828.571429	0.7025	218825
481.7539876	80547.5	396.1428571	0.935714286	5828.571429	0.7025	218289
479.1494426	81404.5	395.4285714	0.921428571	5842.857143	0.7025	220712.7143
479.2775659	81717.5	394.9785714	0.914285714	5850	0.7025	223136.4286
479.3731456	81886	395.4214286	0.907142857	5864.285714	0.7025	226096.1429
480.596047	81370.5	395.7485714	0.9	5878.571429	0.7025	229055.8571
482.2592253	81553.5	396.0514286	0.897142857	5892.857143	0.7025	232015.5714
483.2184355	82695.5	396.5314286	0.894285714	5921.428571	0.7025	232415.7143
485.008557	82408.5	396.5457143	0.891428571	5942.857143	0.7025	232815.8571
486.6752962	82721.5	396.36	0.888571429	5950	0.7025	230256.2857
487.0947913	82752	396.1957143	0.885714286	5957.142857	0.7025	227696.7143
482.7484274	83886.5	396.21	0.882857143	5978.571429	0.7025	225137.1429
482.4610324	84768.5	396.5542857	0.88	6007.142857	0.7025	220655
482.2283308	84946	397.1514286	0.88	6042.857143	0.7025	216172.8571
483.6483329	84946	397.8214286	0.887142857	6064.285714	0.7025	214250.2857
484.5746573	83942.5	398.3357143	0.891428571	6085.714286	0.7025	212327.7143
488.141735	84132	398.4928571	0.895714286	6100	0.723	210405.1429
487.5320765	84486	398.4285714	0.9	6114.285714	0.723	210809.2857
487.1260142	84985	398.1142857	0.901428571	6121.428571	0.723	211213.4286
486.9861129	85052.5	397.4857143	0.902857143	6121.428571	0.723	213540.1429
488.014503	85400	396.6714286	0.904285714	6114.285714	0.723	215866.8571
489.2560189	85134	395.8714286	0.895714286	6107.142857	0.723	218193.5714
490.7072311	85272	395.3928571	0.89	6107.142857	0.723	220074.4286
489.8406949	85470	395.5928571	0.831428571	6121.428571	0.723	221955.2857
490.087744	86505	395.5071429	0.772857143	6135.714286	0.723	221509.4286
489.9431433	87533	395.5642857	0.71	6157.142857	0.723	221063.5714
487.5052783	84659	395.6571429	0.704285714	6178.571429	0.723	220617.7143
487.2866751	85395	395.4642857	0.698571429	6200	0.723	223130.8571
487.5417429	85395	395.3642857	0.695714286	6221.428571	0.723	225644
484.8319535	83634	394.7857143	0.692857143	6235.714286	0.723	228603
482.0783475	82928	393.9285714	0.742857143	6242.857143	0.723	231562
479.8239101	83102	393.2428571	0.792857143	6285.714286	0.723	234521
480.9171319	85471.5	392.6785714	0.85	6285.714286	0.723	246203.5714
480.4185512	84839.5	392.1428571	0.792857143	6290	0.723	257886.1429
476.8187143	85015.5	392.1642857	0.785714286	6294.285714	0.723	266609.7143
468.3725029	83920	392.05	0.778571429	6298.571429	0.7535	275333.2857

467.9845131	83320	392.2642857	0.767142857	6312.857143	0.7535	277443.4286
470.9834486	83369	392.5928571	0.71	6341.428571	0.7535	279553.5714
471.1384368	83191	393	0.652857143	6334.285714	0.7535	278928.5714
472.9891948	83238.5	393.2214286	0.595714286	6362.857143	0.7535	269580
472.2061878	83243.5	393.5071429	0.595714286	6394.285714	0.7535	260231.4286
472.9525268	82752.5	393.5785714	0.545714286	6425.714286	0.7535	250882.8571
471.731634	83110	393.5471429	0.495714286	6457.142857	0.7535	241534.2857
472.3486878	83490	393.2757143	0.491428571	6478.571429	0.7535	241475.2857
478.4936386	83660	392.8471429	0.491428571	6485.714286	0.7535	241416.2857
478.352433	83734.5	392.7614286	0.534285714	6492.857143	0.7535	244092.4286
478.1443087	82953.5	392.59	0.534285714	6500	0.7535	246768.5714
480.6683143	82953.5	392.4471429	0.577142857	6500	0.7535	249444.7143
478.6517987	84205	392.1042857	0.577142857	6500	0.7535	250412
479.0896369	84328.5	391.8642857	0.577142857	6507.142857	0.7535	251379.2857
477.5370854	84423.5	391.8357143	0.578571429	6514.285714	0.7535	249670.4286
482.0302201	84220	391.8357143	0.621428571	6521.428571	0.7535	247961.5714
482.1888544	84516	391.7071429	0.621071429	6528.571429	0.7535	246252.7143
484.9108463	84749.5	391.5785714	0.663928571	6542.857143	0.7535	243699.2857
486.5186575	84322	391.5071429	0.663928571	6557.142857	0.7535	241145.8571
483.0307728	83705.5	391.55	0.710714286	6571.428571	0.7535	240301.2857
488.8647981	83118.5	391.5714286	0.757857143	6578.571429	0.7535	239456.7143
489.5636186	82363	391.5	0.762142857	6585.714286	0.783	238612.1429
493.1722577	82400	391.4928571	0.766428571	6600	0.783	239950
492.1690244	82400	391.3714286	0.771071429	6607.142857	0.783	241287.8571
493.7756082	82400	390.9714286	0.775357143	6592.857143	0.783	243470.2857
492.7102952	82652.5	389.9714286	0.779642857	6585.714286	0.783	245652.7143
492.1825952	83098.5	388.9857143	0.78	6578.571429	0.783	247835.1429
493.5746022	83041	388.1928571	0.732857143	6571.428571	0.783	249768.4286
493.1859557	83194	387.4714286	0.685714286	6564.285714	0.783	251701.7143
491.7817544	83262	386.5928571	0.638571429	6550	0.783	251452.5714
488.7990883	83146.5	385.75	0.591428571	6550	0.783	251203.4286
493.4343654	83018	385.1785714	0.577142857	6564.285714	0.783	250954.2857
490.0630779	83783	385.2	0.572857143	6571.428571	0.783	252191
490.4686101	83325.5	385.1857143	0.568571429	6585.714286	0.783	253427.7143
488.8048292	83074.5	385.1071429	0.57	6604.285714	0.783	254913.5714
492.8772761	83309	384.9571429	0.57	6622.857143	0.783	256399.4286
492.1803488	83621.5	384.8285714	0.57	6644.285714	0.783	257885.2857
492.9740771	83681	384.7142857	0.612857143	6665.714286	0.783	258145.2857
494.6331797	83707.5	384.8714286	0.622857143	6687.142857	0.783	258405.2857
494.1589557	83707.5	384.7357143	0.622857143	6708.571429	0.783	257179.4286
498.6186593	84119.5	384.5071429	0.622857143	6715.714286	0.783	255953.5714
498.0749123	83991	384.0571429	0.664285714	6718.571429	0.7955	254727.7143
499.6730041	84839	383.7071429	0.707142857	6721.428571	0.7955	255890.8571
502.1617846	84651	383.4428571	0.75	6728.571429	0.7955	257054
502.6853691	84544.5	383.2714286	0.75	6732.857143	0.7955	259443
502.6107745	84636.5	382.7428571	0.75	6732.857143	0.7955	261832
503.0523173	84636.5	382.3657143	0.75	6732.857143	0.7955	264221
501.4887363	83441	382.1171429	0.75	6740	0.7955	266728.8571
499.7099829	83441	382.2428571	0.75	6754.285714	0.7955	269236.7143
501.2021433	83928.5	382.5928571	0.75	6768.571429	0.7955	269355.5714
500.6392816	83980.5	382.7428571	0.75	6775.714286	0.7955	269474.4286
502.2515655	84058	382.9428571	0.75	6785.714286	0.7955	269593.2857
500.7029841	83438	383.3357143	0.75	6807.142857	0.7955	273545.1429
500.9860499	83438	383.9057143	0.75	6828.571429	0.7955	277497
496.375177	82552.5	384.4757143	0.75	6850	0.7955	281330
494.9820089	83058.5	384.7928571	0.757142857	6864.285714	0.7955	285163
492.9935321	82056.5	384.8928571	0.764285714	6878.571429	0.7955	288996
493.5794122	81922	385.1785714	0.744285714	6892.857143	0.7955	291464.1429
494.4955178	81863.5	385.4428571	0.751428571	6900	0.7955	293932.2857
496.8037077	81608	385.6142857	0.75	6900	0.7955	292567.4286
498.1104353	82281.5	385.6714286	0.757142857	6900	0.7955	291202.5714

Giriş 8	Giriş 9	Giriş 10	Giriş11	Giriş 12	Giriş 13	Giriş 14	Çıkış
ISE100 Har.7	ISE Hacim Har.7	OzvarlikKar	AktifKar	BorcTopOr	CariOr	KarMarj	Kapanış
40040.57143	889569.8571	0.019	0.01	0.98	0.947	0.007	12500
40858	1129515.429	0.019	0.01	0.98	0.947	0.007	14750
41909.14286	1677240.143	0.019	0.01	0.98	0.947	0.007	16250
42680.28571	1827296.714	0.019	0.01	0.98	0.947	0.007	16250
43628.14286	1905116.429	0.019	0.01	0.98	0.947	0.007	15250
44573	2048970.857	0.019	0.01	0.98	0.947	0.007	15750
45571.71429	2121170.857	0.019	0.01	0.98	0.947	0.007	18000
46488.85714	2212060	0.019	0.01	0.98	0.947	0.007	17500
47230.71429	2192817.429	0.019	0.01	0.98	0.947	0.007	17500
47637.71429	1776083.143	0.019	0.01	0.98	0.947	0.007	17250
48009.28571	1694703.857	0.019	0.01	0.98	0.947	0.007	16750
48092.14286	1594895.857	0.019	0.01	0.98	0.947	0.007	15500
48125.28571	1529854.714	0.019	0.01	0.98	0.947	0.007	13750
47957.28571	1464111.429	0.019	0.01	0.98	0.947	0.007	14750
47580.42857	1259130.143	0.019	0.01	0.98	0.947	0.007	17250

47551.14286	1205847	0.019	0.01	0.98	0.947	0.007	18250
47875.42857	1312791.571	0.019	0.01	0.98	0.947	0.007	17500
48314.42857	1418127.429	0.019	0.01	0.98	0.947	0.007	17500
48988.28571	1566277.429	0.019	0.01	0.98	0.947	0.007	17250
49702.71429	1645980.143	0.019	0.01	0.98	0.947	0.007	18000
50593.28571	1748676.714	0.019	0.01	0.98	0.947	0.007	18000
51256.28571	1795404.571	0.019	0.01	0.98	0.947	0.007	18250
51461.57143	1696727.571	0.019	0.01	0.98	0.947	0.007	17750
51417.57143	1497944.429	0.019	0.01	0.98	0.947	0.007	17250
51520.57143	1354979.571	0.019	0.01	0.98	0.947	0.007	17000
51410.85714	1197638.429	0.019	0.01	0.98	0.947	0.007	17500
51747	1231923	0.019	0.01	0.98	0.947	0.007	17000
52005.85714	1188236.571	0.019	0.01	0.98	0.947	0.007	19000
53193.28571	1332414.857	0.019	0.01	0.98	0.947	0.007	19000
54728.57143	1611716.429	0.019	0.01	0.98	0.947	0.007	19750
56188.57143	1766620.286	0.019	0.01	0.98	0.947	0.007	19250
57462	1930975.429	0.019	0.01	0.98	0.947	0.007	19250
58977.14286	2078104.429	0.019	0.01	0.98	0.947	0.007	20000
60729	2242693.857	0.019	0.01	0.98	0.947	0.007	18750
62295.71429	2435867.429	0.019	0.01	0.98	0.947	0.007	19000
63309.42857	2401542.714	0.019	0.01	0.98	0.947	0.007	19000
63853.42857	2284424.286	0.019	0.01	0.98	0.947	0.007	18250
64202.14286	2211242.857	0.019	0.01	0.98	0.947	0.007	17500
64502.85714	2070070.429	0.019	0.01	0.98	0.947	0.007	17250
64395.28571	1978063.714	0.019	0.01	0.98	0.947	0.007	16750
63803.42857	1728075.714	0.019	0.01	0.98	0.947	0.007	17000
63664	1639228.143	0.019	0.01	0.98	0.947	0.007	16750
63357.28571	1796874	0.019	0.01	0.98	0.947	0.007	16250
63350.85714	1855777.571	0.019	0.01	0.98	0.947	0.007	17500
63665.85714	2027653.714	0.019	0.01	0.98	0.947	0.007	16750
64142.85714	2095565.143	0.019	0.01	0.98	0.947	0.007	17250
65055.57143	2266822	0.019	0.01	0.98	0.947	0.007	16750
65902.85714	2428175.286	0.019	0.01	0.98	0.947	0.007	17750
66692.71429	2400071.286	0.019	0.01	0.98	0.947	0.007	17500
67327.57143	2188026.143	0.019	0.01	0.98	0.947	0.007	17250
67759.42857	1987874.286	0.019	0.01	0.98	0.947	0.007	17500
67890	1812432.429	0.019	0.01	0.98	0.947	0.007	17000
68040.71429	1741219.714	0.019	0.01	0.98	0.947	0.007	17750
67920.85714	1528969.429	0.019	0.01	0.98	0.947	0.007	18250
67976.14286	1403368.714	0.019	0.01	0.98	0.947	0.007	18250
67885.28571	1381092	0.019	0.01	0.98	0.947	0.007	18500
68058	1422137.571	0.019	0.01	0.98	0.947	0.007	19000
68412.42857	1517272.714	0.019	0.01	0.98	0.947	0.007	18750
69152	1570718.429	0.019	0.01	0.98	0.947	0.007	18000
69633.57143	1600985.571	0.019	0.01	0.98	0.947	0.007	18250
70217.28571	1605540.286	0.019	0.01	0.98	0.947	0.007	17750
70526.85714	1560328.714	0.019	0.01	0.98	0.947	0.007	17500
70716.42857	1437251.429	0.019	0.01	0.98	0.947	0.007	17250
70460.42857	1298572.143	0.019	0.01	0.98	0.947	0.007	16750
69771.71429	1189485.286	0.019	0.01	0.98	0.947	0.007	17000
69009.85714	1103397.429	0.019	0.01	0.98	0.947	0.007	17000
68466.42857	1036226.714	0.019	0.01	0.98	0.947	0.007	16750
67800.85714	999869.1429	0.019	0.01	0.98	0.947	0.007	16000
66872.42857	921740.5714	0.019	0.01	0.98	0.947	0.007	17750
66292.85714	903886.5714	0.019	0.01	0.98	0.947	0.007	16750
65805.57143	867534.2857	0.019	0.01	0.98	0.947	0.007	16250
65606	802790.4286	0.019	0.01	0.98	0.947	0.007	17250
65638.14286	760038.1429	0.019	0.01	0.98	0.947	0.007	18250
65614.28571	756387.1429	0.019	0.01	0.98	0.947	0.007	16250
65494.71429	770615.5714	0.019	0.01	0.98	0.947	0.007	16250
65709.57143	827203.4286	0.019	0.01	0.98	0.947	0.007	16000
65596.85714	832601.2857	0.019	0.01	0.98	0.947	0.007	15750
65617.57143	830494	0.019	0.01	0.98	0.947	0.007	16250
65977.42857	944997	0.019	0.01	0.98	0.947	0.007	16250
66081.14286	1063596.143	0.019	0.01	0.98	0.947	0.007	16500
66270.14286	1120594.857	0.019	0.01	0.98	0.947	0.007	14500
66132.85714	1229517.286	0.019	0.01	0.98	0.947	0.007	14500
66251.28571	1340786.143	0.019	0.01	0.98	0.947	0.007	14000
66325.71429	1417291.571	0.019	0.01	0.98	0.947	0.007	14500
66593	1505579	0.019	0.01	0.98	0.947	0.007	14000
66447.71429	1490965	0.019	0.01	0.98	0.947	0.007	12750
65815.85714	1422981	0.019	0.01	0.98	0.947	0.007	12750
65222.28571	1357688.857	0.019	0.01	0.98	0.947	0.007	11500
64731	1308303.571	0.019	0.01	0.98	0.947	0.007	10500
63626.42857	1129176.571	0.019	0.01	0.98	0.947	0.007	10500
62530.85714	1060004.714	0.019	0.01	0.98	0.947	0.007	12250
61640.42857	1037505.429	0.019	0.01	0.98	0.947	0.007	13750
61028.57143	1059698.714	0.019	0.01	0.98	0.947	0.007	15000

60724.14286	1078182.286	0.019	0.01	0.98	0.947	0.007	16500
60536	1130682.143	0.019	0.01	0.98	0.947	0.007	17250
60830	1082932.571	0.019	0.01	0.98	0.947	0.007	17500
61338.28571	1210680.571	0.019	0.01	0.98	0.947	0.007	17750
62162.85714	1258463.143	0.019	0.01	0.98	0.947	0.007	18000
62898.85714	1319655.857	0.019	0.01	0.98	0.947	0.007	17750
63542.28571	1336978.286	0.019	0.01	0.98	0.947	0.007	18750
64440.42857	1333851	0.019	0.01	0.98	0.947	0.007	19250
65402	1393665.143	0.019	0.01	0.98	0.947	0.007	18750
66170.71429	1474346.286	0.019	0.01	0.98	0.947	0.007	19250
66896.71429	1456753.714	0.019	0.01	0.98	0.947	0.007	19250
67438.85714	1387971.714	0.019	0.01	0.98	0.947	0.007	19250
67747	1317028.143	0.019	0.01	0.98	0.947	0.007	20000
67952.57143	1242188.286	0.019	0.01	0.98	0.947	0.007	19250
67974.57143	1231966	0.019	0.01	0.98	0.947	0.007	19500
67935.14286	1145988.571	0.019	0.01	0.98	0.947	0.007	19250
67940.28571	1075911.143	0.019	0.01	0.98	0.947	0.007	19000
68006.57143	993709.5714	0.019	0.01	0.98	0.947	0.007	19500
68069.42857	1039326.429	0.019	0.01	0.98	0.947	0.007	19250
68140.28571	1036622.143	0.019	0.01	0.98	0.947	0.007	22500
68512.42857	1091516.571	0.14	0.075	0.872	1.475	0.095	25750
68903.42857	1105710.429	0.14	0.075	0.872	1.475	0.095	30500
69222	1119944.857	0.14	0.075	0.872	1.475	0.095	36500
69778.57143	1188982	0.14	0.075	0.872	1.475	0.095	34000
70430.14286	1282002	0.14	0.075	0.872	1.475	0.095	32500
71066.28571	1315460	0.14	0.075	0.872	1.475	0.095	33000
71825.14286	1344399.857	0.14	0.075	0.872	1.475	0.095	29000
72118.57143	1279541.143	0.14	0.075	0.872	1.475	0.095	27500
72357.85714	1218168.286	0.14	0.075	0.872	1.475	0.095	32000
72611.71429	1236392.429	0.14	0.075	0.872	1.475	0.095	30500
72426.14286	1190712.429	0.14	0.075	0.872	1.475	0.095	29500
71888.57143	1097798.857	0.14	0.075	0.872	1.475	0.095	34000
71298.28571	1027734.429	0.14	0.075	0.872	1.475	0.095	36500
70320	953692.4286	0.14	0.075	0.872	1.475	0.095	34500
69441.14286	892277.2857	0.14	0.075	0.872	1.475	0.095	32500
68469.85714	859838.5714	0.14	0.075	0.872	1.475	0.095	34000
67553.28571	769682.4286	0.14	0.075	0.872	1.475	0.095	33000
66670.71429	693955.1429	0.14	0.075	0.872	1.475	0.095	33500
65963.85714	683920.1429	0.14	0.075	0.872	1.475	0.095	33000
65201.42857	655162.4286	0.14	0.075	0.872	1.475	0.095	34500
64878.85714	640778.2857	0.14	0.075	0.872	1.475	0.095	33500
64511.71429	627223.5714	0.14	0.075	0.872	1.475	0.095	36000

Network'ün eğitimi bu datalar ile tamamlandıktan sonra ve network oluşturulduktan sonra aşağıdaki tabloda görülen 5 günlük giriş değerleri network'ün tahmin yapabilmesi için girilmiştir.

Giriş 1 Döviz	Giriş 2 D. Ekonomi	Giriş 3 IABMov7	Giriş 4 Inter Har. 7	Giriş 5 Altın Har. 7	Giriş 6 Al/Sat	Giriş 7 Dolas Har. 7
497.5010587	81932.5	385.6785714	0.758571429	6900	0.7955	289837.7143
495.3920831	81668.5	385.6928571	0.737142857	6900	0.7955	291069.2857
493.1503629	81615	385.7928571	0.737142857	6914.285714	0.7955	292300.8571
492.3549567	82275.5	385.9214286	0.721428571	6914.285714	0.7875	294897.2857
489.7490568	83004.5	385.9285714	0.678571429	6914.285714	0.7875	297493.7143
Giriş 8 ISE100 Har. 7	**Giriş 9 ISE Hacim Har. 7**	**Giriş 10 OzvarlikKar**	**Giriş 11 AktifKar**	**Giriş 12 BorcTopOr**	**Giriş13 CariOr**	**Giriş 14 KarMarj**
64289.57143	607991.4286	0.14	0.075	0.872	1.475	0.095
63864.28571	606627.8571	0.14	0.075	0.872	1.475	0.095
64076.57143	669636.1429	0.14	0.075	0.872	1.475	0.095
64469	757892.2857	0.14	0.075	0.872	1.475	0.095
65031.57143	809324.4286	0.14	0.075	0.872	1.475	0.095

Bu değerler sonucunda network'ün verdiği 5 günlük çıkış değerleri aşağıdaki gibidir.

Günler	Tahmin Edilen Değer	Gerçek Değer	Tahmindeki Sapma	Hata Yüzdesi
Gün1	38458	39500	1042	% 2.5
Gün2	39131	40000	869	% 2.1
Gün3	39250	39000	250	% 0.6
Gün4	37033	38500	1467	% 3.8
Gün5	38450	39000	550	% 1.4
Ortalama Sapma			**835.6**	
Ortalama Hata Yüzdesi				*% 2.08*

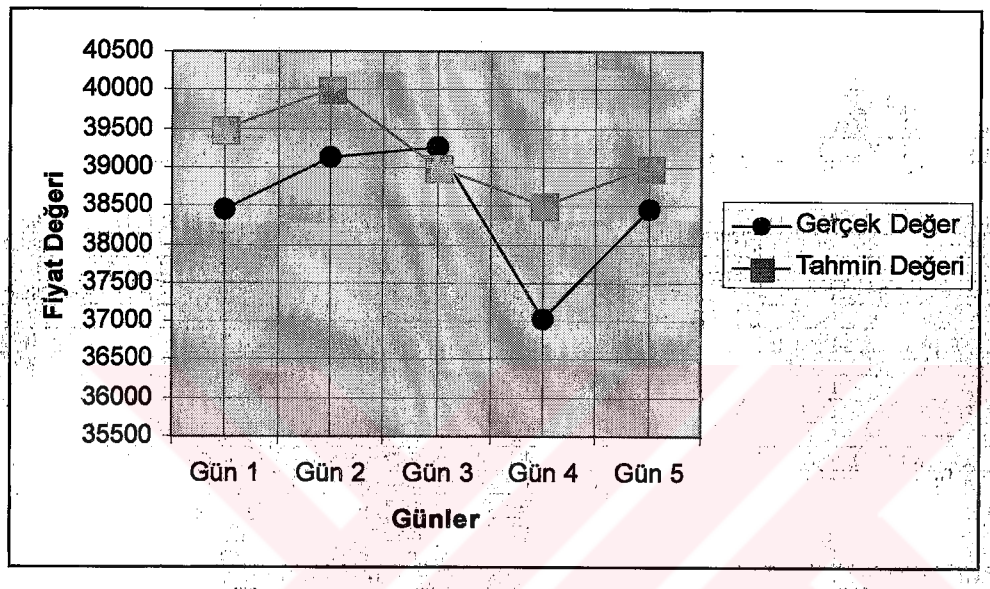

Şekil 11.10 Çıkış değerleri ve gerçek değerlerin grafiği.

11.3 Uygulama Sonuçları

Nöral ağlar kullanılarak finansal tahmin etkin olarak borsa tahminlerinde kullanılabilir.Bu tip bir uygulama hisse senetlerine ait giriş değerlerinin elektronik ortamlardan alınarak nöral network programları yardımıyla gerçekleştirilebilir.

Nöral ağları kullanarak gercekleştirecek örnek bir finansal analiz tahmin probleminde istenilen sonuçları elde edebilmemiz için bir dizi giriş değerinin (parametrenin) elimizde hazır bulunması gerekmektedir.Bu giriş değerlerinin bir kısmı kullanıcı tarafından ortama hazır olarak sunulacak verilerden elde edilebilir, diğer bir kısmı (günlük hisse senedi fiyatları) ise telefon hattı aracılığıyla hizmet veren firmalardan elde edilebilir.

Bu tip bir örnek uygulamada şu tip datalar kullanılabilir; borsada hisse senedi bulunan sirketlere ait mali tabloların (bilanço, gelir tablosu) yer aldığı bilgiler, ikincisi dünya çapında sektör bilgileri (personel/ciro,kapital/ciro,vb.) ve üçüncüsü ise Türkiye'de faaliyet gösteren sektörlere ilişkin bilgiler olabilir(sektör başına öz varlık karlılık oranları,fiyat kazanç oranları,aktif kar oranı,vb). Bu uygulamada tasarlanan sistemi kullanarak tahmini sonuçlara erişebilmek için üç ayrı ortam verilerini altı ayda bir sisteme sunması gerekmektedir.Sisteme sunulan bu verilerin nöral ağlarda giriş değerleri olabilmeleri için modüller içerisinde analiz edilmeleri gerekmektedir.

Kullanıcının ortama günlük olarak sunacağı veriler döviz fiyatları (dolar,mark,yen ve equya ait döviz alış ve satış fiyatları), üç aylık vadeye sahip hazine bonolarına uygulanan bileşik faiz oranı, dünyadaki ve Türkiye'deki dönemlik dalgalanmaları ve fiyat seviyelerindeki değişiklikleri belirten genel ekonomik duruma ait iki parametre ve yöneticilere duyulan güveni ifade eden bir başka parametre olabilir.

Bu uygulama çerçevesinde borsada hisse senedi bulunan her şirket için ayrı bir nöral network kurulması gerekmektedir.Denetimli öğrenme aşamasında beş ayrı temel sektörden farklı profillere sahip iki şirket seçilip toplam on şirket için girilen uygun parametreler yardımıyla nöral network öğrenme aşamasına getirilmelidir.Her örneklem başlangıç tarihi itibarıyla girilen beş hisse senedi değerini kullanarak başlangıç tarihinden 11 gün sonra hisse senedinin alacağı değeri bulacaktır.Başlangıç tarihlerine ait gün pazartesi olacak ve bir sonraki haftanın cuma gününe ait değerler tahmin edilecektir.Hisse senedi fiyatları bir hafta kaydırılarak girilecek ve bu arada değişmesi gereken parametrelerde günlenecektir.

Denetimli öğrenme aşamasında yüksek başarı sağlayan parametreler belli olduktan sonra kullanılacak parametreler kesinleşmiş ve nöral networkler için öğrenme aşamasına gelinmiş olacaktır.Öğrenmek işlemleri tamamlandıktan sonra artık yeni gelen her veri ile ileriye yönelik tahminler yapılabilecektir.

T.C. YÜKSEKÖĞRETİM KURULU
DOKÜMANTASYON MERKEZİ

12. SONUÇLAR VE ÖNERİLER

Yapay sinir ağları şu an çok büyük bir uygulama alanına sahip olmasa bile ileride çok önemli ve etkili uygulama alanına sahip olması kuvvetle muhtemeldir. Yapay sinir ağları ile finansal tahmin yapay sinir ağlarındaki gelişmelere paralel olarak artan bir öneme sahip olması kaçınılmazdır.

Yapay sinir ağları ile finansal tahmin tüm diğer finansal analiz tahmin yöntemlerinden oldukça farklıdır.Klasik finansal analiz tahmin yöntemleri matematiksel eşitliklere bağlı değişmez fonksiyonlar kullanmaktadırlar ve olaya geniş açıdan bakarak değerlendirme yapamamaktadırlar.Diğer bir ifade ile klasik finansal analiz tahmin yöntemleri olayı etkileyen tüm değişkenleri kullanamamaktadır. Yapay sinir ağları ile tahminin en önemli avantajı, bir olayı etkileyen tüm değişkenleri kullanarak tahmin yapabilmesi ve diğer analiz yöntemleri ile farkedilemeyen ,giriş değişkenleri ile çıkış değeri arasındaki ilişkileri farkedebilmesidir.

Yapay sinir ağları uygun olaylar seçildiğinde oldukça yetenekli ve güçlü bir finansal tahmin yöntemidir.Uygun olayların seçilebilmesi için yapay sinir ağlarının çalışma mekanizmasının ve mantığının çok iyi anlaşılması gerekmektedir. Yapay sinir ağları ile finansal tahmin yapmak isteyen bir finansçı için en fazla dikkat etmesi gereken konu ,uygun girişleri ve giriş değerlerini sağlayabilmesi ve yapay sinir ağları için uygun vakaları kullanmasıdır.Doğru bir olay ve doğru giriş değerleri sağlandıktan sonra önemli olan ve başarıyı etkileyen etken yapay sinir ağı programının becerisidir.

Yapay sinir ağları ile finansal tahmin, bilgisayarların hesaplama kabiliyetleri, diğer bir değişle işlemci güçleri arttıkça ve yapay sinir ağı programları geliştikçe çok

daha önemli bir yer edinecektir.Bu nedenle şimdiden yapay sinir ağları ile finansal tahmin konusuna eğinilmeli ve gerekli bilgiler edinilmelidir.

Yapay sinir ağları kullanılarak finansal tahmin yapılırken önemli noktalar şunlardır :

- Tahmin yapılması istenilen olayın matematiksel olarak ifade edilebilien giriş ve çıkış değerleri olması gerekmektedir.
- Tahmin yapılması istenilen olay ile ilgili ne kadar fazla giriş fonksiyonu varsa çıkış değeri de o kadar gerçeğe yakın olmaktadır. Bir olayı etkileyen değişkenlerin ne kadar fazlası bilinirse tahmin de o derecede başarılı olmaktadır.
- Yapay sinir ağları ile tahmin yapılırken eldeki giriş değerlerinin belli bir kısmı network'ün eğitilmesi için eğitim datası olarak kullanılmalıdır. Yapay sinir ağları ile tahminin en önemli kısmını network'ün eğitilmesi kısmı oluşturmaktadır.Networkün eğitimi istenilen seviyeye geldikten veya networkün eğitimi iyileşmemeye başladıktan sonra geri kalan giriş datası networkün ne kadar başarılı tahminlerde bulunabildiğinin kontrolü için test datası olarak kullanılmalıdır.
- Tahmin yapılması istenilen olayı etkilemediği görülen veya etkisinin fazla olmadığı düşünülen giriş değerleri kullanılmamalıdır.Gereksiz giriş datasının kullanımı networkün sonuca gitmesini geciktirmekte ve tahmin başarısını düşürmektedir.
- Her farklı olay için network başta eğitilmelidir.Benzer olmayan olaylar için aynı network kullanılmamalıdır.Unutulmamalıdır ki , network sadece eğitilmiş olduğu olay ile ilgili sağlıklı tahminlerde bulunabilmektedir.

KAYNAKLAR

1. Arman,T.T., Risk Analizine Giriş,1997 Alfa/Aktüel
2. Azoff, E. M, Neural Networks Time Series Forecasting Of Financial Markets, 1994 John Wiley & Sons
3. Bailey, D., Thompson, D. Developing neural-nenvork appiications. Al Expert, Sep, 34-41 , 1990
4. Burke, G. ,Good trading a matter of breeding? Futures, May, 26-29,1993.
5. Carpenter, W., Hoffman, M. , Training backprop neural networks. Al Expert, Mar, 30-33, 1990.
6. Caudill, M. ,A littie knowledge is a dangerous thing. Al Expert, Jun, 16—22 ,1993.
7. Cheng,W; Wagner,L;Lin,C.H., Forecasting Of The 30- Year US Treasury Bond With a System of Neural Networks.,1996 Finance&Technology Publishing
8. Druey, K. , Neural net input optimization. Technical Anaiysis of Stocks and Commodities, Dec, 69—75 , 1995.
9. Felsen, J. , Beating the market with an expert trading system. Technical Analysis of Stocks and Commodities, Dec, 47-52 , 1990.
10. Fishman, M., Barr, D, A hybrid system for market timing. Technical Analysis of Stocks and Commodities, Aug, 26—34 , 1991.
11. Fishman, M., Barr, D., Loick, W. , Using neural nets in market anaiysis. Technical Anafysis of Stocks and Commodities, Apr, 18—22,1991.
12. Gately,E., Neural Networks For Financial Forecasting, 1996 John Wiley & Sons
13. Geva,A.B., Multiscale Neural-Network Architecture For Time Serises Prediction, IEEE Transactions on Neural Networks V9 N5 Sep 98
14. Glazier, J. Archiving the experts. Technical Anafysis of Stocks and

Commodities, Jul, 38-42, 1990.

15. Hiotis, A., Inside a self-organizing map. Al Expert, Apr, 38-43,1992.
16. John,G.H.;Zhao,Y, Mortrage Data Mining,
    Computational Intelligence in Financial Engineering March 1997
17. John,G.H.;Zhao,Y, Stock Selection Using Recon,
    Neural networks in Financial Engineering 1996.
18. Joseph, S.Z., Financial Predictions Using Neural Networks ,
    1997 International Thompson Computer Press.
19. Jurik, M. ,The care and feeding of a neural netvrork. Futures, Oct, 40-44,1992.
20. Knight, K., Connectionist ideas and algorithms. Communications of the
    ACM, 33(11), 59-74,1990.
21. Lippmann, R., An introduction to computing with neural nets. IEEE ASSP
    Magazine, Apr, 4—22,1987.
22. Lippmann, R. , Pattern classification using neural networks.
    IEEE Communications Magazine, Nov, 47—64,1989.
23. Lowe, D., Webb, A. , Time series prediction by adaptive networks: a dynamical
    systems perspective. IEEE Proceedings-F, 138, 17-25,1995.
24. Saad,E.W., Comparative Study of Stock Trend Prediction Using Time Delay,
    recurrent and Probabilistic Neural Networks.,IEEE Transactions on Neural
    Networks V9 N6 Nov 98
25. Swingler,K, Financial Predictin Some Pointers Pitfalls and Common Errors,
    1994 Center For Cognitive And Computational Neuroscience.

119

ÖZGEÇMİŞ

1975 Ordu doğumlu olan Fatih Kılıç 1993 yılında Malatya Anadolu Lisesinden, 1997 yılında da İstanbul Teknik Üniversitesi Elektronik ve Haberleşme Mühendisliği bölümünden mezun olmuştur. Profesyonel hayata ise 1997 yılında Yapı Kredi Bankası Bilgi Teknoloji örgütü olan BİLPA A.Ş.'nin Teknolojik Stratejiler Direktörlüğünde başlamıştır ve halen Sistem Destek Uzmanı olarak görevini sürdürmektedir.1997-98 öğretim yılında Gebze Yüksek Teknoloji Enstitüsü İşletme Fakültesi'nde yüksek lisans yapmaya başlamıştır.