

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOĞRUSAL OLMAYAN ZAMAN SERİLERİNİN
YAPAY SİNİR AĞLARI İLE TAHMİNİ

Ramazan CEVİZKIRAN

Yüksek Lisans Tezi
Elektronik ve Bilgisayar Eğitimi Anabilim Dalı
Danışman: Prof. Dr. Muammer GÖKBULUT

ŞUBAT-2012

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOĞRUSAL OLMAYAN ZAMAN SERİLERİNİN
YAPAY SİNİR AĞLARI İLE TAHMİNİ

YÜKSEK LİSANS TEZİ

Ramazan CEVİZKIRAN
(091131104)

Tezin Enstitüye Verildiği Tarih : 20 Ocak 2012

Tezin Savunulduğu Tarih : 15 Şubat 2012

Tez Danışmanı: Prof. Dr. Muammer GÖKBULUT (F.Ü)

Diğer Jüri Üyeleri: Yrd. Doç. Dr. Mehmet GEDİKPINAR (F.Ü)

Yrd. Doç. Dr. Cafer BAL (F.Ü)

OCAK-2012

ÖNSÖZ

Hazırladığım bu çalışmada bana çalışmamı öneren, çalışmalarımda beni her zaman özveriyle destekleyen ve çalışmamın bütün aşamalarında her türlü yardımı gösteren sayın hocam Prof. Dr. Muhammer GÖKBULUT' a, ayrıca çalışmalarımın gelişmesinde katkı sağlayan sayın hocam Yrd. Doç. Dr. Cafer BAL'a teşekkürü bir borç bilirim.

Ramazan CEVİZKIRAN

ELAZIĞ - 2012

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	II
İÇİNDEKİLER	III
ÖZET	VI
ŞEKİLLER LİSTESİ	VIII
TABLolar LİSTESİ	X
1. GİRİŞ	1
2. ZAMAN SERİLERİ	3
2.1. Zaman Serilerinin Grafikle Gösterilmesi	4
2.2. Zaman Serileri Bileşenleri	4
2.2.1. Eğilim.....	5
2.2.2. Mevsimsel Dalgalanma.....	6
2.2.3. Dönemsel Dalgalanma	6
2.2.4. Rassal Dalgalanma.....	7
2.3. Zaman Serilerinde Yanıltıcı Faktörler	7
3. ZAMAN SERİSİ TAHMİN YÖNTEMLERİ	8
3.1. Aritmetik Ortalama Yöntemi	9
3.2. Mekanik (Naïve) Tahmin Yöntemi.....	9
3.3. Ağırlıklı Hareketli Ortalama	10
3.4. Üssel Düzeltme Yöntemi	11
3.5. Box-Jenkins Yöntemi.....	12
3.5.1. Otoregresif Hareketli Ortalama Modeli: ARMA(p,q)	12
3.5.2. Otoregresif Hareketli Entegre Ortalama Modeli: ARIMA(p, d, q).....	13
4. YAPAY SİNİR AĞLARI	15
4.1. YSA'nın Kısa Tarihçesi	15
4.2. Biyolojik Sinir Hücreleri.....	16
4.3. Yapay Sinir Ağlarının Yapısı.....	17
4.4. Yapay Sinir Ağı Modelleri.....	23
4.4.1. Tek Katmanlı İleri Beslemeli Yapay Sinir Ağları (Feed Forward)	23
4.4.2. Çok Katmanlı Yapay Sinir Ağı	24
4.5. YSA'nın Genel Özellikleri.....	25
4.6. Yapay Sinir Ağlarının Öğrenme Stratejileri	26

4.6.1. Danışmanlı (Eğitici) Öğrenme.....	27
4.6.2. Danışmansız (Eğitici) Öğrenme	27
4.7. Öğrenme Kuralları	28
4.7.1. Delta Kuralı.....	28
4.7.2. Geri Yayılım Öğrenme Algoritması	29
5. YAPAY SİNİR AĞLARI İLE ZAMAN SERİLERİNİN TAHMİNİ.....	33
5.1. Yapay Sinir Ağı Giriş ve Çıkış Verileri.....	33
5.2. YSA Tasarımı	36
6. DENEYSEL SONUÇLAR.....	39
6.1. Altın Fiyatlarının Tahmini İçin Yapılan Uygulama.....	40
6.1.1. 6_6_1 YSA Modeli ile Bir Ay Sonraki Altın Fiyatları Tahmini	42
6.1.2. 6_3_1 YSA Modeli ile Bir Ay Sonraki Altın Fiyatları Tahmini	44
6.1.3. 3_6_1 YSA Modeli ile Bir Ay Sonraki Altın Fiyatları Tahmini	45
6.1.4. 3_3_1 YSA Modeli ile Bir Ay Sonraki Altın Fiyatları Tahmini	46
6.1.5. Atlamalı 6_6_1 YSA Modeli ile Üç Ay Sonraki Altın Fiyatları Tahmini.....	47
6.1.6. Atlamalı 6_3_1 YSA Modeli ile Üç Ay Sonraki Altın Fiyatları Tahmini.....	48
6.1.7. Atlamalı 3_6_1 YSA Modeli ile Üç Ay Sonraki Altın Fiyatları Tahmini.....	49
6.1.8. Atlamalı 3_3_1 YSA Modeli ile Üç Ay Sonraki Altın Fiyatları Tahmini.....	50
6.1.9. Ardışık 6_6_1 YSA Modeli ile Üç Ay Sonraki Altın Fiyatları Tahmini.....	51
6.1.10. Ardışık 6_3_1 YSA Modeli ile Üç Ay Sonraki Altın Fiyatları Tahmini	52
6.1.11. Ardışık 3_6_1 YSA Modeli ile Üç Ay Sonraki Altın Fiyatları Tahmini	53
6.1.12. Ardışık 3_3_1 YSA Modeli ile Üç Ay Sonraki Altın Fiyatları Tahmini	54
6.1.13. Altın Fiyatlarının Tahmini İçin Değerlendirme.....	55
6.2. Mackey-Glass (M-G) Kaotik Zaman Serisi Tahmini İçin Yapılan Uygulama...	56
6.2.1. 6_6_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Bir Adım İleri Tahmini..	57
6.2.2. 6_3_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Bir Adım İleri Tahmini..	58
6.2.3. 3_6_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Bir Adım İleri Tahmini..	59
6.2.4. 3_3_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Bir Adım İleri Tahmini..	60
6.2.5. Atlamalı 6_6_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Üç Adım İleri Tahmini	61
6.2.6. Atlamalı 6_3_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Üç Adım İleri Tahmini	62

6.2.7. Atlamalı 3_6_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Üç Adım İleri Tahmini	63
6.2.8. Atlamalı 3_3_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Üç Adım İleri Tahmini	64
6.2.9. Ardışık 6_6_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Üç Adım İleri Tahmini	65
6.2.10. Ardışık 6_3_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Üç Adım İleri Tahmini	66
6.2.11. Ardışık 3_6_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Üç Adım İleri Tahmini	67
6.2.12. Ardışık 3_3_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Üç Adım İleri Tahmini	68
6.2.13. Mackey-Glass Kaotik Zaman Serisi Tahmini İçin Değerlendirme	69
7. SONUÇLAR	71
KAYNAKLAR	72
ÖZGEÇMİŞ	74

ÖZET

Zaman serileri, zamana bağılı bir olaydan belirli zaman aralıklarında yapılan ölçümlerinden elde edilen verilerdir. Zaman serileri geçmiş döneme ait verileri ihtiva eder ve veriler gerçek dünyadaki çeşitli olaylardan elde edilebilir. Geçmiş dönemdeki verileri kullanarak, gelecekteki veri değerlerini belirleme işlemi, zaman serisi tahmini olarak adlandırılır. Zaman serilerinin tahmininde çeşitli istatistiksel yöntemler kullanılabilir ya da seriye uygun doğrusal ya da doğrusal olmayan bir matematiksel model geliştirilebilir. Fakat zaman serileri ekonomik, sosyal, mevsimsel ve spekülatif vb. çeşitli faktörlerin etkisiyle ani dalgalanmalar gösterebilir. Ayrıca, doğrusal olmayan ve kaotik bir dinamik davranışa sahip olabilir. Bu tür zaman serilerinin tahmininde istatistiksel yöntemlerin yerine zaman serisine uygun bir model yardımıyla zaman serisini tahmin etmek gerekir.

Bu tez çalışmasında, yapay sinir ağları ile zaman serilerinin tahmini incelenmiştir. Yapay sinir ağları, doğrusal olmayan matematiksel modeli nedeniyle birçok alanda olduğu gibi zaman serilerinin tahmininde de yaygın olarak kullanılmaktadır. Bu tezde, genel bir trende sahip olan altın fiyatlarını gösteren zaman serisi ile Mackey-Glass kaotik zaman serisi kullanılmıştır. İleri beslemeli yapay sinir ağları ile bu zaman serilerinin geleceğe yönelik kısa ve orta vadeli tahminleri gerçekleştirilmiştir. Farklı sayıda geçmiş veri değeri ve çeşitli YSA yapıları ile zaman serilerinin tahmin performansı araştırılmıştır.

Anahtar kelimeler: Yapay Sinir Ağları, Doğrusal olmayan Zaman Serileri, Zaman Serilerinin Tahmini, Altın Fiyatları,

ABSTRACT

NONLINEAR TIME SERIES PREDICTION USING ARTIFICIAL NEURAL NETWORK

Time series is a sequence of data which is obtained from measurements of time dependent phenomenon. Time series includes data points in the past and it can be measured from various phenomenons in real world. The procedure for determining the future values of the series, by using the past values, is called as time series prediction. Various statistical methods can be used for time series prediction or a linear or nonlinear mathematical model can be suited to time series. Time series may include some economic, social, seasonal and speculative fluctuations. Furthermore, time series can also be governed by nonlinear and/or chaotic dynamics. In this case, time series prediction using a suitable mathematical model may be necessary, instead of statistical methods.

In this thesis, time series prediction using artificial neural network is examined. Neural networks are also widely used in signal prediction as they can be used in various fields, due to their nonlinear mathematical model. In this study, gold prices having a regular trend and Mackey-Glass chaotic time series are used for testing of neural network predictor. Short and mid term prediction of these time series are implemented using feed-forward neural network. Various neural network structures using different data points as inputs are tested and prediction performances are determined.

Keywords: Artificial Neural Networks, Nonlinear Time Series, Time Series Prediction, Gold Prices

ŞEKİLLER LİSTESİ

	<u>Sayfa No</u>
Şekil 2.1. Trabzon ilinin aylık ortalama yağış miktarı.....	4
Şekil 2.2. Altın fiyatlarının ağırlıklı ortalaması	5
Şekil 4.1. Basit bir biyolojik sinir hücresi	17
Şekil 4.2. Yapay sinir hücresi.....	18
Şekil 4.3. Lineer fonksiyon	21
Şekil 4.4. Step fonksiyonu.....	21
Şekil 4.5. Eşik değer fonksiyonu.....	22
Şekil 4.6. Hiperbolik tanjant fonksiyonu	22
Şekil 4.7. Sigmoid aktivasyon fonksiyonu.....	23
Şekil 4.8. Tek katmanlı bir YSA	23
Şekil 4.9. Çok katmanlı yapay sinir ağı modeli	24
Şekil 4.10. Çok katmanlı ileri beslemeli değişkenleri.....	30
Şekil 5.1. Kayan pencere yaklaşımıyla zaman dizileri kestirimi	34
Şekil 5.2. İki adım ileri tahmin için YSA yapısı	35
Şekil 5.3. k adım ileri tahmin için YSA yapısı.....	35
Şekil 5.4. Atlamalı veri girişi ile k adım ileri tahmin YSA yapısı	36
Şekil 6.1. 6_6_1 YSA modeli ile bir ay sonraki altın fiyatları tahmin performansı ...	42
Şekil 6.2. 6_3_1 YSA modeli ile bir ay sonraki altın fiyatları tahmin performansı	44
Şekil 6.3. 3_6_1 YSA modeli ile bir ay sonraki altın fiyatları tahmin performansı	45
Şekil 6.4. 3_3_1 YSA modeli ile bir ay sonraki altın fiyatları tahmin performansı	46
Şekil 6.5. Atlamalı 6_6_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı.....	47
Şekil 6.6. Atlamalı 6_3_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı.....	48
Şekil 6.7. Atlamalı 3_6_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı.....	49
Şekil 6.8. Atlamalı 3_3_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı.....	50
Şekil 6.9. Ardışık 6_6_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı.....	51

Şekil 6.10. Ardışık 6_3_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı.....	52
Şekil 6.11. Ardışık 3_6_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı.....	53
Şekil 6.12. Ardışık 3_3_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı.....	54
Şekil 6.13. YSA veri girişi olarak kullanılacak kaotik zaman serisi.....	56
Şekil 6.14. 6_6_1 YSA modeli ile M-G kaotik zaman serisinin bir adım ileri tahmin performansı.....	57
Şekil 6.15. 6_3_1 YSA modeli ile M-G kaotik zaman serisinin bir adım ileri tahmin performansı.....	58
Şekil 6.16. 3_6_1 YSA modeli ile M-G kaotik zaman serisinin bir adım ileri tahmin performansı.....	59
Şekil 6.17. 3_3_1 YSA modeli ile M-G kaotik zaman serisinin bir adım ileri tahmin performansı.....	60
Şekil 6.18. Atlamalı 6_6_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı.....	61
Şekil 6.19. Atlamalı 6_3_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı.....	62
Şekil 6.20. Atlamalı 3_6_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı.....	63
Şekil 6.21. Atlamalı 3_3_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı.....	64
Şekil 6.22. Ardışık 6_6_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı.....	65
Şekil 6.23. Ardışık 6_3_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı.....	66
Şekil 6.24. Ardışık 3_6_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı.....	67
Şekil 6.25. Ardışık 3_3_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı.....	68

TABLolar LİSTESİ

Tablo 2.1. Trabzon ilinin aylık ortalama sıcaklık değerleri.....	3
Tablo 4.1. Toplayıcı fonksiyonları	20
Tablo 6.1. Altın fiyatlarının yıllara ve aylara göre değeri	40
Tablo 6.2. 6_6_1 YSA modeli ile bir ay sonraki altın fiyatları tahmin performansı... 43	
Tablo 6.3. 6_3_1 YSA modeli ile bir ay sonraki altın fiyatları tahmin performansı... 44	
Tablo 6.4. 3_6_1 YSA modeli ile bir ay sonraki altın fiyatları tahmin performansı.. 45	
Tablo 6.5. 3_3_1 YSA modeli ile bir ay sonraki altın fiyatları tahmin performansı... 46	
Tablo 6.6. Atlamalı 6_6_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı.....	47
Tablo 6.7. Atlamalı 6_3_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı.....	48
Tablo 6.8. Atlamalı 3_6_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı.....	49
Tablo 6.9. Atlamalı 3_3_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı.....	50
Tablo 6.10. Ardışık 6_6_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı.....	51
Tablo 6.11. Ardışık 6_3_1 ysa modeli ile üç ay sonraki altın fiyatları tahmin performansı.....	52
Tablo 6.12. Ardışık 3_6_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı.....	53
Tablo 6.13. Ardışık 3_3_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı.....	54
Tablo 6.14. YSA ile altın fiyatlarının tahmin sonuçları	55
Tablo 6.15. 6_6_1 YSA modeli ile M-G kaotik zaman serisinin bir adım ileri tahmin performansı.....	57
Tablo 6.16. 6_3_1 YSA modeli ile M-G kaotik zaman serisinin bir adım ileri tahmin performansı.....	58
Tablo 6.17. 3_6_1 YSA modeli ile M-G kaotik zaman serisinin bir adım ileri tahmin performansı.....	59

Tablo 6.18. 3_6_1 YSA modeli ile M-G kaotik zaman serisinin bir adım ileri tahmin performansı.....	60
Tablo 6.19. Atlamalı 6_6_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı.....	61
Tablo 6.20. Atlamalı 6_3_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı.....	62
Tablo 6.21. Atlamalı 3_6_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı.....	63
Tablo 6.22. Atlamalı 3_3_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı.....	64
Tablo 6.23. Ardışık 6_6_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı.....	65
Tablo 6.24. Ardışık 6_6_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı.....	66
Tablo 6.25. Ardışık 3_6_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı.....	67
Tablo 6.26. Ardışık 3_3_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı.....	68
Tablo 6.27. Mackey-Glass kaotik zaman serisinin tahmini için yapılan uygulama sonuçları	69

KISALTMALAR

- ANN** : Artificial Neural Networks (Yapay Sinir Ağları)
AR : Auto Regressive (Oto regresif)
ARIMA : Oto regresif Entegre Hareketli Ortalama Modeli
ARMA : Oto regresif Hareketli Ortalamalar
GA : Genetik Algoritma
MATLAB : Matrix Laboratory (Matris Laboratuvarı).
M-G : Mackey-Glass
MLP : Multiple Layer Perceptron
RMSE : Hata Kareleri Ortalamasının Karekökü
YSA :Yapay Sinir Ağları

1. GİRİŞ

Zaman serisi, zaman içinde gözlenen ölçümlerin bir dizisidir. Bir ülkeye gelen aylık turist sayısı, döviz-altın gibi yatırım araçlarının aylık ortalama fiyatları, bir şehirde meydana gelen yıllık kazalar, mevsimsel deniz seviyesi yüksekliği, bir mağazanın aylık satışları zaman serilerine örnek olarak verilebilir. Zaman serileri ekonomik, sosyal, psikolojik, mevsimsel, spekülasyon vb. çeşitli faktörlerin etkisi ile farklı şiddet ve yönlerde dalgalanmalar gösterebilir.

Geçmiş gözlem dönemlerine ait veriler yani zaman serileri kullanılarak gelecek dönemler hakkında tahminde bulunmak mümkündür. Buna da zaman serileri tahmini denmektedir. Bir başka deyişle zaman serilerinin tahmini; önceden kayıt altına alınmış zamansal verileri matematiksel bir model kullanarak ileriye yönelik tahminde bulunmadır. Geçmiş dönemlerde ki verilerin geleceğin tahmininde kullanılmasına dayanan bu teknik kısa, orta ve uzun dönem tahminlerine ihtiyaç duyulan her alanda kullanılmaktadır.

Geleceğin bilimsel yöntemlerle tahmin edilmesi ve gelecek için önceden hazırlıkların yapılması çok önemlidir. Özellikle ekonomide ve finans sektöründe büyük önem taşımaktadır.

Son yıllarda geleceği anlamak ve kestirmek için pek çok araştırma yapılmış, bu araştırmalar pek çok tahmin metodu ortaya çıkarmıştır. Bu metotlar genellikle istatistiksel tekniklere bağlıdır. Son zamanlarda geleneksel istatistiksel metotlara alternatif olarak ortaya konan yeni bir metot ise Yapay Sinir Ağları (YSA) metodudur[1].

Yapay Sinir Ağları (YSA) tahmin amacıyla birçok alanda yaygın olarak kullanılmaktadır. Özellikle doğrusal olmayan zaman serilerinde YSA'nın geleneksel yöntemlerden daha üstün başarı göstermesi bu yöntemin tercih edilmesinde önemli bir faktör olmuştur[2].

Doğrusal yapıya sahip olmayan (nonlinear) zaman serilerinin tahmininde YSA'nın üstünlüğü araştırmacıların daha da ilgisini çekmiştir. Problemlerin giriş verisinin uygun seçildiği takdirde her türlü sürecin tahmin edilebilmesi YSA'nın önemini arttırmıştır.

Bu çalışmanın amacı; zaman serisi yöntemlerinde yapay sinir ağlarının en doğru sonucu verebilmesi için üzerinde çalışılan zaman serisinin yapısına en uygun yapay sinir ağı mimarisinin belirlenmesi ve bir zaman serisi için tespit edilen uygun mimarinin başka bir zaman serisinde nasıl sonuçlar ürettiğini ortaya çıkarmaktır.

Çalışma altı ana bölümden oluşmaktadır. İkinci bölümde, genel olarak zaman serisi kavramı, zaman serilerinin çeşitleri anlatılmış ve zaman serilerini etkileyen trend (eğilim), mevsimsellik, konjonktürel (devirsel), rassal(düzensiz) gibi önemli bileşenlerden ayrıntılı bir şekilde bahsedilmiştir.

Üçüncü bölümde zaman serileri tahmin yöntemlerine ilişkin kavramlara yer verilirken sık kullanılan tahmin yöntemlerinden "Aritmetik Ortalama", "Mekanik Tahmin", "Ağırlıklı Hareketli Ortalama", "Üstsel Düzeltme", "Boz-Jenkins", "Oto regresif Hareketli Ortalama" ve "Oto regresif Hareketli Entegre Ortalama" modelleri alt başlıklar altında açıklanmıştır. Bu bölümde ayrıca zaman serileri tahminine hangi alanlarda neden ihtiyaç duyulur sorularına cevap verilerek zaman serileri tahmininin önemi vurgulanmıştır.

Dördüncü bölümde yapay sinir ağları kavramı açıklanırken yapay sinir ağlarının kullanım alanlarından, yapısından, aktivasyon fonksiyonlarından, öğrenme stratejilerinden bahsedilmiştir.

Beşinci bölümde zaman serileri tahmininde yapay sinir ağlarının yeri ve önemi; yapay sinir ağlarının klasik tahmin yöntemlerine göre avantaj ve dezavantajları ele alınmıştır. Ayrıca yapay sinir ağlarının ne tür zaman serilerinde ve hangi sektörlerde tahmin yöntemi olarak tercih edildiği açıklanmıştır.

Uygulamaya ayrılan son bölümde ise yapay sinir ağları ile tahmini yapılmak üzere 1996-2010 yılları arasındaki toplam 180 aylık altın fiyatlarının aylık ortalamalarından oluşan zaman serisi ve 1201 adet veriden oluşan Mackey-Glass kaotik zaman serisi ile çeşitli uygulamalar yapılmıştır. Bununla beraber yapay sinir ağlarının zaman serileri tahmininde yakın tahmin ve uzak tahmin başarıları kıyaslanmıştır. Uygulama sonuçlarıyla birbirinden farklı iki zaman serisine en uygun ağ mimarileri tespit edilmiştir.

2. ZAMAN SERİLERİ

Bir işletmenin aylık satış miktarı, giderleri, bir ülkeye gelen turist sayısı, bir ülkenin ithalat-ihracat miktarı ve benzeri zaman içinde değişen zamanla ilişkili veri dizisine “zaman serisi” denir. Gözlem ayırık zamanlarda gerçekleştirilirse zaman serisi ayırık zaman serisi adını alır. Gözlem, belirli zaman aralıklarında sürekli yapıldığında ise zaman serisi sürekli zaman serisi olur. Zaman serileri üzerine yapılan çalışmaların çoğunda sürekli zaman serileri kullanıldığı görülmektedir. Sürekli zaman serilerinin zaman noktaları günler (günlük üretim miktarı), aylar (aylık yağış miktarı) ve yıllar (yıllık ithalat tutarı) olabilir. Zaman noktalarının seçimine göre seri günlük zaman serisi, aylık zaman serisi, ya da yıllık zaman serisi olarak adlandırılır.

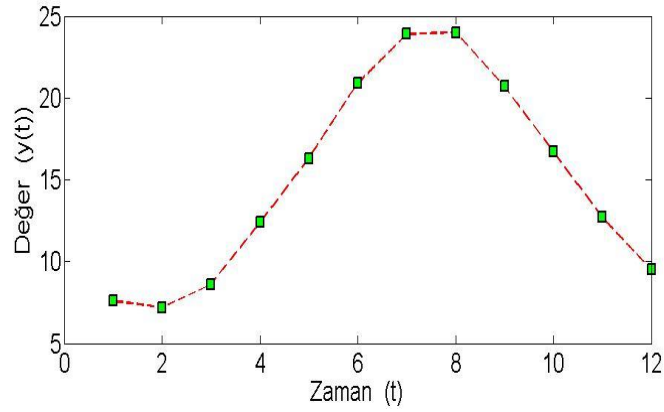
Zaman serilerinde zaman değişkeni genellikle $t=1, 2, 3, \dots, n$ şeklinde ifade edilirken zaman noktalarındaki gözlem değerleri genellikle y_1, y_2, \dots, y_n şeklinde ifade edilir. Aylık zaman serilerine örnek olarak, Trabzon iline ait aylık ortalama sıcaklık değerleri Tablo 2.1. de verilmiştir.

Tablo 2.1. Trabzon ilinin aylık ortalama sıcaklık değerleri

Aylar	t	(y_t) Ortalama Sıcaklık	Aylar	t	y_t Ortalama Sıcaklık
Ocak	1	7,6	Temmuz	7	23,9
Şubat	2	7,2	Ağustos	8	24,0
Mart	3	8,6	Eylül	9	20,7
Nisan	4	12,4	Ekim	10	16,7
Mayıs	5	16,3	Kasım	11	12,7
Haziran	6	20,9	Aralık	12	9,5

2.1. Zaman Serilerinin Grafikle Gösterilmesi

Zaman serilerinin gözlem değerlerinin zaman noktalarıyla nasıl bir ilişkiye sahip olduğunu daha kolay anlamak için zaman serileri grafiklerle; genelde de kartezyen koordinatlı bir grafikte gösterilir. Zaman değişkeni (t) grafiğin apsis(x) ekseninde, gözlem değeri grafiğin ordinat(y) ekseninde gösterilir. Tablo 2.1’de verilen zaman serisinin grafiği Şekil 2.1’de zaman serisi grafiğine örnek olarak verilmiştir.



Şekil 2.1. Trabzon ilinin aylık ortalama yağış miktarı

2.2. Zaman Serileri Bileşenleri

Zaman serileri ekonomik, sosyolojik, psikolojik, iklimsel, tesadüfi v.b. nedenlerden etkilenmesi sebebiyle gözlem değerlerinde bazı değişimler olur. Bu değişimlere neden olan etkenler zaman serileri bileşenleri olarak adlandırılırlar. Zaman serileri için üç önemli bileşen tanımlanmıştır. Eğilim (Trend) (T), zaman serisinin uzun vadeli iniş-çıkış eğilimini işaret eder. Mevsimsellik (Seasonality) (S), zaman serisinin belirli bir zaman aralığındaki periyodik davranışını belirtir. Eğilim ve mevsimsel bileşen kaldırıldığında, geriye kalan dalgalanma zaman serisinin düzensiz (Irregular) (I) bileşeni olarak adlandırılır[3]. Zaman serilerinin dördüncü bileşeni olarak kabul edebileceğimiz dönemsel (Conjectural) (C) bileşen, belirsiz zaman aralıklarındaki devirsel davranışı belirtir.

Zaman serilerinin en önemli özelliği, gözlem değerlerindeki değişmelerin genelde bu unsurların ortak etkisi neticesinde oluşmasıdır[4].

Yukarıdaki unsurlara sahip bir zaman serisi genel olarak Denklem 2.1 ile gösterilebilir:

$$Y = T + S + C + I \quad (2.1)$$

Zaman serilerini etkileyen bileşenlerin özelliklerinden ayrıntılı bir şekilde alt başlıklarda bahsedilmiştir.

2.2.1. Eğilim

Zaman serileri gözlem değerlerinin uzun dönemde (yıllık veriler için 7, 8 yıl) azalma ya da artma yönünde gösterdiği eğilime trend denir.



Şekil 2.2. Altın fiyatlarının ağırlıklı ortalaması

Şekil 2.2’de görüldüğü gibi 1996 yılından itibaren önceki yıllara göre hemen hemen her yıl altın fiyatlarında bir artış olmuştur. Bu verilerde 1996 yılının ilk ayındaki ortalama altın fiyatı ile 2010 yılının son ayındaki ortalama altın fiyatı bir doğru parçası ile birleştirilirse elde edilen doğrunun pozitif bir eğime sahip olduğu açıkça görülebilir. Yani altın fiyatlarının uzun vadede bir artış eğilimine sahip olduğu söylenebilir.

Zaman içinde genel bir artış ya da azalış göstermiyorsa bu serinin eğilimi yoktur denilebilir.

2.2.2. Mevsimsel Dalgalanma

Birbirini izleyen yılların, mevsimlerin, ayların haftaların, günlerin hatta saatlerin aynı zaman noktalarındaki gözlem değerlerinde sürekli bir artma ya da azalma gözlenirse bu değişimler mevsimsel değişimleri açıklar. Ülkemizde uzun tatil dönemlerinde seyahat eden yolcu sayısının artmasından dolayı trafik kazalarının artış göstermesi, sonbahar aylarında yağış miktarının artması ya da sıcaklıkların düşmesi, kış aylarında doğal gaz tüketiminin artması mevsimsel dalgalanmaya örnek verilebilir. Şekil 2.1'deki aylara göre sıcaklık değerlerini gösteren grafikte kış aylarında sıcaklığın düştüğünü yaz aylarında yükseldiğini gösteren grafik mevsimsel dalgalanmaya başka bir örnek olabilir. Ayrıca yine Şekil 2.1'de verilen grafiğe göre sıcaklığın en yüksek olduğu Ağustos ayındaki sıcaklığa yakın bir değere sonraki yılın Ağustos ayında ulaşılması beklenir.

Aradaki on iki aylık zaman farkına “dalga uzunluğu” denir. Yine aynı grafikteki en yüksek sıcaklıkla en düşük sıcaklık arasındaki farka da “dalga şiddeti” denir.

2.2.3. Dönemsel Dalgalanma

Gözlem değişkenleri her zaman sabit oranda artış ya da azalış göstermez. Eğilim değişimlerinin dışındaki daha uzun dönemlerdeki yükselişler ya da düşüşler dönemsel dalgalanma olarak açıklanabilir.

Örneğin beş, altı, ya da on yılda bir bazı bölgelerde normalin dışında aşırı yağış, kuraklık ya da don olayları yaşanır. O dönemlerde tarım ürünleri zarar görür ve üretilen ürün miktarında ve bölgede satılan ürün fiyatlarında değişimler gözlenebilir. Daha sonraki yıllar hava koşulları iyi gittiğinde üretilen ürün miktarı, satılan malların fiyatları eski değerlerine geri döner. Ama buna benzer bir olay yedi sekiz yıl sonra tekrar yaşanabilir. Bu türden değişimler belirsiz aralıklarda tekrarlanır gider. Periyodik olmayan ama döngüsel olan bu değişimlere dönemsel dalgalanma denir.

2.2.4. Rassal Dalgalanma

Zaman serilerindeki düzensiz deęişimlere rassal deęişim adı verilir. Rassal deęişikliler deprem, sel, siyasal karışıklık gibi beklenmeye olayların meydana gelmesi rassal dalgalanmaya neden olur. Rassal bileşen zaman serisindeki eğilim, mevsimsel, dönemsel etki kaldırıldıktan sonra geride kalan etki olarak ta açıklanabilir.

17.Ağustos.1999 da yaşanan Kocaeli depreminin etkisiyle 1998 yılında 206.559 milyar dolar olan milli gelir, 1999 yılında 185.266 milyar dolara gerilemiştir. Bölgenin turizm gelirleri ve bölge ile ilgili birçok sosyal, ekonomik, ekolojik gözlem deęişkenleri artma ya da azalma eğilimi göstermiştir. Bu tür beklenmedik olaylar rassal bileşene örnek verilebilir.

2.3. Zaman Serilerinde Yanıltıcı Faktörler

Özellikle aylı zaman serilerinde ilgili zaman serisinin o aya ait deęişkenini ay boyunca aldığı toplam deęerlerler belirler. Bazı aylarda 28 gün bazı aylarda 30 veya 31 gün olması, bazı aylarda çalışma gününün daha fazla olması, bazı ayların tatil dönemlerine denk gelmesi zaman serilerinde mevsimsel bir bileşen varmış gibi göstermesi önemli bir yanıltıcı faktördür. Bir mağazanın aylık satış miktarını gösteren zaman serisi bu yanıltıcı faktörden etkilenen zaman serisine örnek verilebilir.

3. ZAMAN SERİSİ TAHMİN YÖNTEMLERİ

Zaman serileri gözlem değerlerine etki eden bileşenlerin geçmişteki etkileri çözümlenerek zaman serilerinin gelecekteki değerlerinin tahmin edilmesine zaman serilerinin tahmini denir. Başka bir deyişle zaman serileri tahmini geçmiş gözlem dönemlerine ait veriler kullanılarak, gelecek dönemler hakkında tahminde bulunabilmedir.

Eğer bir zaman serisi geçmiş değerlerinden tam olarak kestirilebiliyorsa, bu zaman serisi tayin edilebilir (deterministik) olarak adlandırılır. Aksi halde, geçmiş değerlerin sadece gelecekteki davranışın olasılığını işaret ettiği durumda zaman serisi istatistikselidir. Belirli gözlem aralıkları için değeri değişmeyen zaman serileri ise durağandır[3].

Sanayi, turizm, eğitim, sağlık, üretim, pazarlama gibi birçok alanda geleceği öngörebilmek hayati önem taşıdığından bu konuda sayısız çalışma yapılmış ve zaman serilerini çözümlenerek geleceği tahmin edebilmek için onlarca değişik yöntem geliştirilmiştir.

Geleceği bilebilmek, gelecekte olacak olayları önceden görebilmek tarih boyunca insanların en büyük hayallerinden birisi olmuştur. Bu nedenle eski çağlarda geleceği tahmin edebilmek maksadıyla kimi zaman yıldızlardan kimi zaman da yere atılan taslardan yararlanılmaya çalışılmıştır. Elbette matematiksel yöntemlerin ve özellikle çok hızlı bir hesaplama aracı olan bilgisayarların geliştirilmesi ile hiçbir bilimsellik içermeyen eski yöntemlerin yerini üzerinde binlerce kişinin yıllarca emek sarf ederek ortaya koyduğu karmaşık hesaplama modelleri almıştır[5].

Zaman serilerinin gelecek değerlerinin tahmin edilmesinde kullanılan yöntemin seçimi; tahminin amacına, zaman serisinin tipine ve unsurlarına, geçmişe ait veri miktarına ve tahmin döneminin uzunluğuna bağlı olarak değişmektedir[4].

Zaman serilerinin tahmininde en çok kullanılan yöntemler ve özellikleri aşağıda anlatılmıştır.

3.1. Aritmetik Ortalama Yöntemi

Zaman serileri tahmininde kullanılan en basit yöntem aritmetik ortalama yöntemidir. Gözlemlenen değişkenin gelecekteki değeri geçmişteki değerlerinin ortalamasına yakınsayacağı varsayımına dayanmaktadır. Bu serinin ortalaması aşağıdaki Denklem 3.1 ile bulunmaktadır.

$$\text{---} \tag{3.1}$$

Burada;

y_{t+1} = (t+1) dönemindeki tahmin değeri,

y_t = t dönemindeki gözlem değeri,

n= gözlem sayısıdır.

Bu yöntem bütün gözlem değerlerini işleme aldığından devirsel ve mevsimsel bileşenleri çözümlenmeden arındıramaz. Ayrıca herhangi bir trendi olan zaman serisinde de kullanımı uygun değildir. Durağan bir seride basit bir tahmin yöntemi olarak kullanılabilir.

3.2. Mekanik (Naïve) Tahmin Yöntemi

Bir zaman serisi değişkeninin son dönemde aldığı değer bir sonraki dönemin tahmini olarak kullanılır ve tahmin aşağıdaki Denklem 3.2 ile hesaplanır;

(3.2)

y_{t+1} = (t+1) dönemindeki tahmin değeri,

y_t = t dönemindeki gözlem değeri,

Eğer tahmini yapılacak olan serinin kesin trendi gözleniyorsa, tahmin trendin yönüne göre Denklem 3.3 ile yapılır;

(3.3)

Burada;

y_{t+1} = (t+1) dönemindeki tahmin değeri,

y_t = t dönemindeki gözlem değeri,

$y_t - y_{t-1}$ = t dönemiyle, bir önceki dönemin değerleri arasındaki farktır.

Zaman serisi örneğin t-1 gözlem noktasında mevsimsel bileşenden etkilenmişse daha önceki mevsimsel bileşenden etkilenmemiş t-2 dönemindeki değer hesaba katılarak hesaplama yöntemi Denklem 3.4 deki gibi düzenlenir.

(3.4)

Hem trend, hem de mevsimsel bir yapı gösteren zaman serilerinde ise iki yaklaşım kombine edilerek, örneğin üçer aylık seriler için Denklem 3.5. ile hesaplama yapılır[6].

(3.5)

3.3. Ağırlıklı Hareketli Ortalama

Zaman serileri tahmininde hareketli ortalama yönteminin yaygın bir kullanım alanı vardır. Tahmin yapılacak zamanın yakın geçmişinde bir grup belirlenir gruptaki her bir değişkene en yakın geçmişteki değerlerin etkisi yüksek tutularak bir ağırlık verilir. Her bir değişkenin ağırlıklı toplamı alınarak toplam ağırlığa bölünür ve grubun ağırlıklı ortalaması bize tahmin değerini verir. Bu yöntem ile döngüsel dalgalanmalar (konjonktürel ve mevsimsel) yok edilmeye çalışılır.

Ağırlıklı hareketli ortalama yönteminde, her döneme farklı bir ağırlık verilerek w_i değerleri ağırlıkları, y_t t anındaki gözlem değerlerini, ağırlıklı ortalama ile hesaplanmış tahmin değerini göstermek üzere;

(3.6)

formülü ile hesaplanmaktadır.

3.4. Üssel Düzeltme Yöntemi

Üssel düzeltme yöntemleri, geçmiş dönem verilerine eşit ağırlık veren basit hareketli ortalamalar yöntemine benzeyen ancak geçmiş dönem verilerine eşit değil farklı ağırlıkların verildiği yöntemler topluluğudur. Üssel terimi verilen ağırlıkların veriler eskidikçe üstel bir şekilde azalması anlamını taşımaktadır. Diğer bir ifadeyle tahminde kullanılan geçmiş dönem verilerinden yakın geçmişte gerçekleşenlere yüksek, veriler eskidikçe ise üstel olarak azalan ağırlıklar verilmektedir[6].

Doğal olarak en yakın geçmiş verilerin geleceğe etkisi, eski dönem verilerinden daha fazla olacaktır. Üssel düzeltmenin de kendi içinde farklı yöntemleri vardır. Basit üstel düzeltme yönteminin formülü Denklem 3.7. de verilmiştir.

(3.7)

Burada;

- y_{t+1} = t+1 dönemindeki tahmin değeri,
- y_t = t dönemindeki gözlem değeri,
- \hat{y}_t = t dönemindeki tahmin değeri,
- α = 0..1 arası değer alabilen düzeltme sabitidir.

Üssel düzeltme yöntemi, bir bakıma, tüm verilerin hareketli ortalaması olmaktadır. Üssel düzeltme yönteminin kullanılmasındaki temel düşünce gözlemlenen değişkendeki tesadüfi dalgalanmaların etkilerini gidererek genel yönetime uygun bir tahminde bulunabilmektir[7].

3.5. Box-Jenkins Yöntemi

Temel olarak iki ayrı yöntemin (Oto regresyon ve Hareketli Ortalama) birleşiminden oluşturulmaya çalışılan Box- Jenkins yöntemi 1970 yılında George Box ve Gwilym Jenkins tarafından geliştirilmiştir. ARMA (Auto Regressive Moving Averages) modeli sadece durağan serilerde kullanılabilirdiği için seriye fark alma işlemi uygulanması gerekmektedir. Fark alma işleminin sayısını belirleyen entegrasyon indeksinin de (d ifadesi) ifadeye katılması ile ARIMA (Auto Regressive Integrated Moving Average) modelleri ortaya çıkmıştır[8].

3.5.1. Oto regresif Hareketli Ortalama Modeli: ARMA(p,q)

Zaman serisi modellerinde esneklik sağlamak için en az sayıda parametre kullanım ilkesini gerçekleştirmek amacıyla bazı hallerde modele hem oto regresif (AR(p): p. dereceden oto regresif ortalama model- Auto Regressive) hem de hareketli ortalama (MA(q): q. dereceden hareketli ortalama-Moving Averages) parametrelerinin alınması birçok faydalar sağlamaktadır[10]. Bu düşünce ARMA(p,q) modelini ortaya çıkarmıştır.

Bu modelin, bir zaman serisinin herhangi bir t dönemine ait y_t gözlem değeri, ondan önceki belirli sayıda $y_{t-1}, y_{t-2}, \dots, y_{t-p}$ gözlem değerlerinin ve $\varepsilon_t, \varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}$ hata terimlerinin doğrusal birleşiminden meydana gelmektedir. p ve q parametrelerine sahip ARMA (p, q) modelinin genel ifadesi[11];

(3.8)

şeklinde yazılır.

Burada;

$$\begin{aligned} y_t &= t \text{ dönemindeki tahmin değeri,} \\ y_{t-p} &= t-p \text{ dönemindeki gözlem değeri,} \\ &= t-p \text{ dönemindeki geçmiş değer katsayısı,} \end{aligned}$$

= t-q dönemindeki hata değeri,
= t-q dönemindeki hatanın katsayısıdır.

3.5.2. Otoregresif Hareketli Entegre Ortalama Modeli: ARIMA(p, d, q)

Durağan olmayıp farkı alınarak durağan hale getirilmiş serilere uygulanan modellere durağan olmayan doğrusal stokastik modeller veya kısaca entegre modeller denir[12].

Durağan olmayan bir zaman serisini durağan hale getirmek için ihtiyaç durumuna göre serinin genellikle 1 veya 2 defa farkı alınır. Kaç defa farkı alındığı d ile gösterilir. Entegre modeller belirli sayıda farkı alınmış serilere uygulanan AR ve MA modellerinin birleşimidir. Eğer AR modelinin derecesi p, MA modelin derecesi q ve serinin de d kez farkı alınmışsa bu modele (p, d, q) dereceden otoregresif entegre hareketli ortalama modeli denir ve ARIMA (p, d, q) şeklinde gösterilir.

Durağan olmayan y_t serisinin d. mertebeden farkı alınarak durağanlaştırıldığında yeni seri; w_t olarak tanımlanırsa, dönüşüm[6].

(3.9)

Şeklinde gösterilmektedir.

Burada;

Δ = Fark alma işlemcisi,

d = Fark derecesi,

$w_t, w_{t-1}, \dots, w_{t-p}$ = Farkı alınmış seriyi göstermektedir.

Bu durumda ARIMA (p,d,q) modelinin genel ifadesi aşağıdaki gibi olmaktadır[13];

(3.10)

ARIMA(p,d,q) modelinin orijinal veri cinsinden genel gösterimi $\delta \neq 0$ varsayımı ile;

(3.11)

şeklinde yapılmaktadır[6].

Burada;

Δ = Fark alma işlemcisi,

d = Fark derecesi,

$w_t, w_{t-1}, \dots, w_{t-p}$ = Farkı alınmış seriyi,

, = Ağırlıkları göstermektedir.

4. YAPAY SİNİR AĞLARI

Bu bölümde yapay sinir ağlarını kısaca tarihçesinden, yapay sinir ağı kavramları ve belli başlı yapılarından bahsedilmiştir. Daha sonra yapay sinir ağlarının eğitim yöntemlerine değinilmiştir.

4.1. YSA'nın Kısa Tarihçesi

Yapay sinir ağları ile ilgili ilk çalışmalar; 1943 yılında neurophysiologist, Warren Mc. Culloch ve matematikçi Walter Pitts tarafından başlatılmıştır. Yayınladıkları bir makalede elektrik devrelerinden basit bir sinir ağı modellemişlerdir. 1949'da Donald Hebb "The Organization of Behaviour" adlı kitabında hücrese seviyede beyinin öğrenme mekanizmasından bahsetmiştir. 1957 yılında Frank Rosentblatt'ın perceptron'u geliştirmesiyle YSA alanındaki gelişmeler hız kazanmıştır. Frank Rosentblatt algılayıcılar üzerine çalışmaya başlamıştır. 1959 yılında, Bernard Widrow ve Marcian Hoff ADALINE ve MADALINE olarak tanımlanan modelleri geliştirmiştir. MADALINE, gerçek dünya problemlerine uygulanan ilk yapay sinir ağıdır. MADALINE telefon hatlarındaki ekoları ortadan kaldıran bir filtre yapılmasında kullanılmıştır ve hala ticari olarak kullanımdadır[14].

Marvin Minsky ve Seymour Papert'ın 1969 yılında yayınladıkları Algılayıcılar isimli kitapta, algılayıcıların doğrusal olmayan problemlere çözüm üretemeyeceği sonucu ortaya atılmıştır. Ancak 1982 yılındaki gelişmeler, yeni ilgi alanları oluşturmuştur. John Hopfield, Ulusal Bilim Akademisine bir makale sunmuş ve bu makalede Hopfield'ın yaklaşımı basit bir şekilde beyni modellemek değil, faydalı cihazlar yapmak olmuştur. Matematiksel analizlerle böyle bir ağın nasıl çalışabileceğini ve neler yapabileceğini göstermiştir. Japonya'nın Kyoto şehrinde Amerika-Japonya ortak katılımlı Yardımcı/Rekabetçi Yapay Sinir Ağları üzerine bir konferans yapılmıştır.

1984'te Kohonen danışmansız öğrenme ağlarını geliştirmiş ve 1986'da Rumelhart ve McClelland karmaşık ve çok katmanlı ağlar için geri yayımlı öğrenme algoritmasını


ortaya koymuşlardır. Bugün tüm dünyada sinir ağları ile ilgili birçok araştırma yapılmaktadır. Yeni ve daha verimli öğrenme algoritmaları geliştirilmeye çalışılmaktadır.

4.2. Biyolojik Sinir Hücreleri

Biyolojik sinir ağları beynimizde bulunan çok sayıda sinir hücresinin bir topluluğudur. Bir sinir ağı milyonlarca sinir hücresinin bir araya gelmesi ile oluşmaktadır. Sinir hücreleri birbirleri ile bağlanarak fonksiyonlarını yerine getirirler. Bir grup insan resmi içinden tanıdık bir resmi 100-200 msn gibi kısa bir sürede fark edebilir. Ama geleneksel bilgisayarları böyle bir tanıma işlemi yapması çok uzun zaman alabilir. Bugün insan beyninin kapasitesinin çok küçük bir oranında kapasiteye sahip ve çalışabilen bir makine yapılırsa olağanüstü bilgi işleme ve kontrol edebilme mekanizmaları geliştirmek ve mükemmel sonuçlar elde etmek mümkün olabilir. Biyolojik sinir ağlarının performansları küçümsenmeyecek kadar yüksek ve karmaşık olayları işleyebilecek yetenektedir.

Biyolojik sinir hücreleri insan beyninin çalışmasını sağlayan temel taşlardan birisidir. İnsanın çevresini anlamasını ve ona göre davranışlar göstermesini sağlar. Biyolojik sinir ağları beş duyu organından gelen veriler ışığında algılama ve anlama mekanizmasını çalıştırarak insanın bütün davranışlarını ve çevresini anlamasını sağlarlar. Biyolojik sinir ağları beş duyu organından gelen bilgiler ışığında geliştirdiği algılama ve anlama mekanizmalarını çalıştırarak olaylar arasındaki ilişkileri öğrenir. Göstereceği bütün davranışlarını da öğrendikleri bu ilişkisel bilgilere göre gösterir.

Yapay sinir ağları ile biyolojik sinir ağlarının yeteneğini bilgisayarlara kazandırmak amaçlanmaktadır Şekil 4.1'de biyolojik sinir hücresinin yapısı görülmektedir[15].



Şekil 4.1. Basit bir biyolojik sinir hücresi

Yukarıdaki şekilde görülen biyolojik sinir hücresi sinapslar, soma, akson ve dentritlerden oluşmaktadır. Sinapslar sinir hücresi arasındaki bağlantılar olarak görülebilir. Bunlar fiziksel bağlantılar olmayıp bir hücreden diğerine elektrik sinyallerinin geçmesini sağlayan boşluklardır. Bu sinyaller somaya giderler. Soma bunları işleme tabi tutar, sinir hücresi kendi elektrik sinyallerini oluşturur ve akson aracılığı ile dentritlere gönderir. Dentritler ise bu sinyalleri sinapslara göndererek diğer hücrelere gönderilir[15].

4.3. Yapay Sinir Ağlarının Yapısı

Sinir hücreleri katmanlar halinde dizilerek yapay sinir ağını meydana getirirler. Yapay sinir ağı birden fazla katmandan ve birden fazla yapay sinir hücresinden meydana gelir. İlk katman genellikle giriş katmanıdır. Çıkış katmanı ise son katmandır. Aradaki diğer katmanlar ise gizli katman ya da ara katman olarak adlandırılırlar. Bir ağda birden fazla gizli katman olabilir[11].

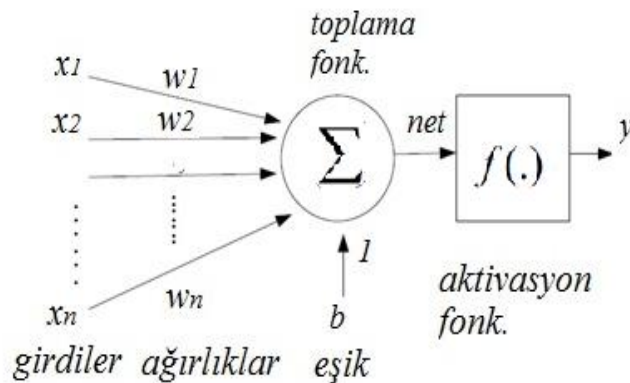
Yapay sinir ağları verilen girdilere göre çıktılar üreten akıllı bir kara kutu modeli olarak da nitelendirilebilir. Yapay sinir ağları sahip olduğu özelliklerden dolayı alışlagelmiş bilgi işleme yöntemlerinden farklılık göstermektedir. Bu özelliklerden bazıları paralellik, hata toleransı, öğrenilebilirlik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

başarılı sonuçlar üretebilir. Yapay sinir ağlarında bilgilerin işlenmesi paralel olarak gerçekleştirildiği için taşınan bilgiler birbirinden bağımsızdır. Ayrıca aynı tabakadaki bağlantılar arasında zaman bağımlılığı olmadığından tamamı ile eşzamanlı çalışabilmekte dolayısıyla da bilgi akış hızı artmaktadır. Paralel çalışma prensibinden dolayı herhangi bir birimde meydana gelen hata tüm sistemde belirgin bir hataya neden olmamaktadır. Sadece hücrenin ağırlıkları oranında bir etkilenme gerçekleşmektedir. Böylece genel sistem yerel hatalardan en az bir şekilde etkilenmektedir[16].

Öğrenme yeteneği sayesinde tam tanımlı olmayan problemlerin yapay sinir ağlarıyla çözülebilmesi de mümkün olabilir. Paralel çalışan bir yapay sinir ağı modeli karışık fonksiyonlarla yapılan işlemler yerine basit işlemler içerdiğinden ve karmaşık olmayan bir mimari yapıya sahip olduğundan birçok sorunun çözümlenmesinde tercih sebebidir[5].

Başka bir deyişle yapay sinir ağları insan beynindeki sinir hücrelerinin taklit edilmesi ile eski bilgileri kullanarak yeni bir bilgi üretebilen, keşfedebilen algoritmalarıdır. Yapay sinir ağlarındaki ağırlıklar eğitim ve test kümesindeki bilgiler ışığında optimum düzeye getirilerek eğitilmiş olurlar. Böylece eğitilmiş YSA yeni bir girişle yeni bir çıkış tahmin edebilecek konuma gelmiş olur[2].

Yapay sinir ağları zaman serilerini tahmin edebilmenin, öğrenebilmenin, genelleme yapabilmenin yanında eksik veriler ile çalışarak sınıflandırma, optimizasyon ve örüntü tanıma işlemlerinde de oldukça başarılı bir yöntemdir. Basit bir yapay sinir hücresi Şekil 4.2’de gösterilmiştir.



Şekil 4.2. Yapay sinir hücresi

$x_1 \dots x_n$ n adet dış ortamdan gelen girdileri gösterir.

$w_1 \dots w_n$ girdilerin ağırlıklarını gösterir. Toplam fonksiyonu Denklem 4.1’de verildiği gibidir.

(4.1)

Toplam fonksiyonunun çıktısı doğrusal ya da doğrusal olmayan bir fonksiyondan geçirilerek çıktı hesaplanır.

(4.2)

Bir yapay sinir hücresi, girdiler, ağırlıklar, toplam fonksiyonu, aktivasyon fonksiyonu ve çıktı olmak üzere beş ana kısımdan oluşur.

Girdiler: Bir yapay sinir hücresine dış dünyadan gelen bilgilerdir. Bunlar ağırlık öğrenmesi istenen örnekler tarafından belirlenir.

Ağırlıklar: Ağırlıklar bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini gösterir.

Toplama Fonksiyonu: Bu fonksiyon, bir hücreye gelen net girdiyi hesaplar. Bunun için değişik fonksiyonlar kullanılır. En yaygın olanı ağırlıklı toplamı bulmaktır. Burada her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır. Böylece ağa gelen net girdi bulunmuş olur. Denklem 4.1 ile hesaplanır.

Toplama fonksiyonu olarak en çok kullanılan formül Denklem 4.1. deki gibidir. Fakat yapay sinir ağlarında daima bu formülün kullanılması şart değildir. Kullanılan diğer fonksiyonlara ilişkin özellikler Tablo 4.1’de verilmiştir[5].


Tablo 4.1. Toplayıcı fonksiyonları

Net Giriş	Açıklama
Toplam	Girdiler kendilerine ait ağırlıklar ile çarpılıp daha sonra hepsi toplanır.
Çarpım	Girdiler kendilerine ait ağırlıklar ile çarpılıp daha sonra da birbirleri ile çarpılır.
Maksimum	Tüm girdiler kendilerine ait ağırlıklar ile çarpıldıktan sonra aralarından en büyük değer alınır.
Minimum	Tüm girdiler kendilerine ait ağırlıklar ile çarpıldıktan sonra aralarından en küçük değer alınır.
Çoğunluk	Tüm girdiler kendilerine ait ağırlıklar ile çarpıldıktan sonra pozitif ve negatif olanların sayısı bulunur. Hangisi daha çok ise hücrenin net girdisi o kabul edilir.
Kümülatif Toplam	Hücreye uygulanan tüm girdiler toplanır ve daha önceki toplama eklenir.

Aktivasyon Fonksiyonu: Bu fonksiyon, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonu olarak da çıktıyı hesaplamak için de değişik formüller kullanılır. Yaygın olarak kullanılan çok katmanlı algılayıcı modelinde genel olarak sigmoid fonksiyonu kullanılır.

Aktivasyon fonksiyonunu yapay sinir hücresinin çıktısının büyüklüğünü sınırlandıran bir fonksiyon olarak tanımlayabiliriz. Sık kullanılan aktivasyon fonksiyonları aşağıda gösterilmiştir[15].


Lineer Fonksiyon: Girdiler α katsayısı ile çarpılarak sonuç üretilir. $\alpha=1$ kabul edilerek lineer fonksiyona ilişkin örnek Şekil 4.3’de verilmiştir.



Şekil 4.3. Lineer fonksiyon


Step Fonksiyonu: Gelen veri belirlenen bir esik değerin üstünde ya da altında olmasına göre 1 ya da 0 değerlerini alır[10]. Şekil 4.4’deki grafik örnek olarak verilmiştir.

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



Şekil 4.4. Step fonksiyonu


Esik Değer Fonksiyonu: Gelen verilerin belirlenen değerler arasında veya değerden büyük ya da küçük olmasına göre değer alırlar. Belirlenen değerler arasında ise gelen değer kendisi çıktı olur[10]. Şekil 4.5 eşik değer fonksiyonuna örnek olarak verilmiştir.



Şekil 4.5. Eşik değer fonksiyonu

Hiperbolik Tanjant Fonksiyonu: Çıktı değeri hücreye gelen verilerin tanjant fonksiyonuna tabi tutulmasıyla hesaplanır[10]. Şekil 4.6 örnek grafik olarak verilmiştir.


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



Şekil 4.6. Hiperbolik tanjant fonksiyonu

Sigmoid Fonksiyonu: Yapay sinir ağları oluşturulurken en çok kullanılan aktivasyon fonksiyonudur. Doğrusal ve doğrusal olmayan davranışlar arasında denge sağlayan sürekli artan bir fonksiyon olarak tanımlanır. Şekil 4.7 deki grafik sigmoid fonksiyonuna örnek olarak verilmiştir.

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



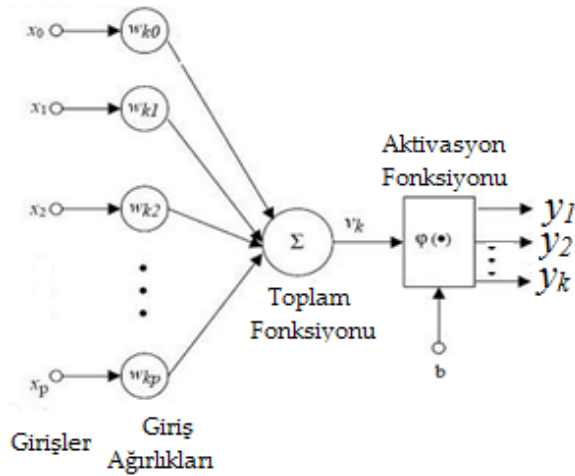
Şekil 4.7. Sigmoid aktivasyon fonksiyonu

4.4. Yapay Sinir Ağı Modelleri

Zaman serisinin yapısına daha doğru tahminler yapabilmek için yapay sinir ağlarında çeşitli modeller geliştirilmiştir. Günümüzde sık kullanılan yapay sinir ağı modelleri alt başlıklarda ayrıntılı olarak açıklanmıştır.

4.4.1. Tek Katmanlı İleri Beslemeli Yapay Sinir Ağları (Feed Forward)

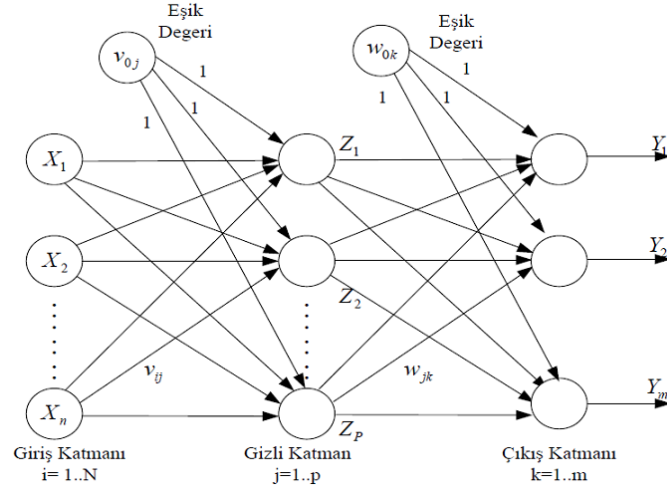
Giriş katmanı ve bir çıkış katmanından ibarettir. Bu ağ yapısında bilgi girişten çıkışa doğru ilerlediği için ağ ileri beslemelidir. Giriş katmanının veri üzerinde hiçbir işlem yapmadan veriyi çıkış katmanına ilettiği için tek katmanlı olarak isimlendirilir.



Şekil 4.8. Tek katmanlı bir YSA

4.4.2. Çok Katmanlı Yapay Sinir Ağı

Çok katmanlı yapay sinir ağlarında (MLP, Multiple Layer Perceptron) giriş katmanı, gizli katman ve çıkış katmanı bulunur. Giriş katmanında dışarıdan alınan çözümleri istenilen problemin bilgileri sisteme alır. Çıkış katmanı ise içeriden alınan bilgileri dışarıya aktaran katmandır. Arada ki katman ise gizli katman olarak adlandırılır. Gizli katman 1 veya daha fazla olabilir. Optimum katman sayısı ve katmanlardaki nöron sayısı ile ilgili belirli bir kural yoktur. Bu sayı genellikle deneme yolu ile bulunur. Şekil 4.9 çok katmanlı yapay sinir ağlarına örnek olarak verilebilir.



Şekil 4.9. Çok katmanlı yapay sinir ağı modeli

YSA'nın en fazla kullanılan modeli çok katmanlı perseptron (MLP) sinir ağıdır. MLP modelde bilgi akışı ileri yönde olduğu için ileri beslemeli YSA olarak da bilinir. Farklı öğrenme algoritmaları kullanılarak ağın eğitilmesi sağlanır[13].

MLP ağlarının eğitiminde geri yayılım (Backpropagation) algoritması kullanılmaktadır. Bu algoritma, hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geri yayılım ismini almıştır. Geri yayılım algoritması danışmanlı öğrenme yapısına sahip ve birçok uygulamada kullanılmış en yaygın öğrenme algoritmasıdır. Danışmanlı öğrenme algoritmalarında ağın eğitimi için, ağa örnek olarak girdi ve çıktı değerlerden oluşan bir örnek veri seti verilir[17].

Verilen hedef çıktı deęerleri, YSA literatüründe danışman ya da öęretmen olarak adlandırılır[18].

4.5. YSA'nın Genel Özellikleri

Yapay sinir ağlarının genel karakteristik özellikleri aşığıdaki gibi sıralanabilir;

YSA, bilgisayarların olayları öęrenerek, aynı durumlarla karşılaşıldığında karar vermesini sağlarlar.

Olaylarla ilgili bilgileri, örneklerden edinerek genelleme yapma yeteneğine sahip olurlar. Bu nedenle iyi genellemeler için ağı sunulan örneklerin önemi büyüktür.

YSA'da bilgi ağı bağlantılarındadır ve bağlantı deęerine göre önemli olup olmadığı belirlenir. Yorumlanması zordur.

Ağı kendisine sunulan örneklerle genellemeler yaparak, daha önce görmediğı örnekler içinde sonuçlar üretebilir.

Paralel yapıya sahiptirler. Birçok nöron eşzamanlı olarak çalışır. YSA'nın önce örneklerle eğitimi ve arkasından testi söz konusudur. İstenen iyi bir performansa ulaşmaya kadar ağı eğitime devam edilir. Ancak, bu durumda ağı örneklerden ezberleme özelliğinden de kaçınmak gerekir.

Geleneksel yöntemler eksik bilgi ile çalışmazken, YSA eksik bilgi ile çalışabilir. Olayları öğrendikten sonra eksik veri ile belirsizlik altında da karar verebilirler. Bilginin önemli olup olmadığı ağı performansına bakılarak anlaşılabilir. Buda hataya karşı toleranslı olma özelliğindedir.

Sinir ağları tabiatında doğrusal olmayandır. Bir gizli katman ile her türlü sürekli fonksiyona etkin bir şekilde yaklaşım gösterebilir. Ağı bu özelliğe doğrusal olmayan aktivasyon fonksiyonu ile sahiptir[19].

Bu özelliklerinin yanında YSA'nın bazı dezavantajları da vardır. Bunlar;

YSA kabul edilebilir sonuçlar üretir. Optimum çözümü garanti etmez. Performansı düşük çözümler elde edilmesi durumu ortaya çıkabilir.

Ağ için nöron sayıları, katmanların sayısı, aktivasyon fonksiyonu, öğrenme katsayısı vb. belirlenmesinde genel bir kural olmaması dezavantaj sayılabilir. Kullanıcının tecrübesine bağlıdır. Deneme yanılma neticesinde karar söz konusudur.

Daha önce belirtildiği gibi ağın eğitiminde örnekler çok önemlidir. Ağın performansının düşmesi çoğu zaman örneklerin doğru sunulmamasından kaynaklanmaktadır. Kullanıcı eksikliği, uygun bir ağ yapısının sağlanamaması gibi nedenler çözülebilecek bir problemde, çözümsüzlüğe yol açabilir.

Eğitimin ne zaman bitirileceği konusunda kesin bir sınır yoktur. Hata istenen belli bir değere ulaşıncaya, eğitimin tamamlanması yeterli görüldüğü için optimum öğrenmenin gerçekleştiği söylenmez. Ayrıca eğitimin geç sonlandırılması ağın ezberleme durumunu ortaya çıkardığı için örnekleri ezberleyen ağ, yeni örneklerle karşılaştığında uygun olmayan sonuçlar üretebilir.

Ağın davranışları açıklanamaz. Ağ bir kara kutu gibidir. Bu dezavantajlara rağmen YSA ile her probleme değişik şekillerde çözümler üretilebilmekte, başarılı sonuçlar elde edilebilmektedir.

4.6. Yapay Sinir Ağlarının Öğrenme Stratejileri

Sinir ağlarında, sinirlerin ağırlıklarının optimum seviyeye getirilmesi işlemine ağın eğitilmesi denir. Başlangıçta rastgele seçilen ağırlıklar gönderilen her örnekle kendini değiştirir böylece hatanın düşürülmesi sağlanır. Her seferinde verilen örneğe daha yakın değerler üretmesi sağlanır. Bu ağırlık yenileme işlemi kabul edilebilir bir hataya kadar veya belli bir iterasyona kadar sürdürülür. Değişik öğrenme stratejileri kullanılır. En çok kullanılan 2 öğrenme stratejisinden bahsedilecektir. Bunlar:

4.6.1. Danışmanlı (Eğitici) Öğrenme

Literatürde danışmanlı öğrenme olarak da geçen bu öğrenme yapay sinir ağlarının eğitilmesinde kullanılan en yaygın yöntemdir.

Girdi ve çıktı değerlerinin her ikisi de ağa gösterilir. Girdi değerleri ağ tarafından işlenerek elde edilen çıktı değeri elde edilmek istenen değerle karşılaştırılır. Ortaya çıkan farkın düşürülmesi için ağırlıklar güncellenir. Ağ, kendi çıktı değerini istenilen çıktı değerine yaklaştırmak için hücre bağlantılarının ağırlıkların güncellenir. Bir sonraki döngüde yine çıktı değeri ile elde edilmek istenen değer kıyaslanarak yine aradaki fark (hata) biraz daha düşürülmek üzere ağırlıklar yeniden güncellenir. Bu öğrenme süreci, hata değerleri istatistiksel olarak kabul edilebilir seviyeye ininceye kadar devam eder.

Danışmanlı öğrenme algoritmalarına örnek olarak; Widrow ve Hoff tarafından geliştirilen delta kuralı ve Rumelhart ve McClelland tarafından geliştirilen genelleştirilmiş delta kuralı algoritması verilebilir.

4.6.2. Danışmansız (Eğitici) Öğrenme

Danışmansız öğrenme metodunda, ağa sadece girdiler verilir, istenilen çıktı değerleri verilmez. Örneklerdeki parametreler arasındaki ilişkiyi kendi kendisine öğrenmesi beklenir. Ağ, girdi değerlerini gruplandırmak için yapacağı değişikliklere kendi karar verir. Daha çok sınıflandırma problemlerinin çözümünde kullanılır. Öğrenme bittikten sonra çıktılarının ne anlama geldiğini belirtmek için bir kullanıcıya ihtiyaç vardır. Bu yöntem kendi kendine öğrenme (Self-Organization) veya adaptasyon olarak bilinir[20].

Daha çok sınıflandırma problemleri için kullanılır. Adaptif rezonans ağları (ART), Hopfield ağı, Kohonen ağı en çok kullanılanlarıdır.

4.7. Öğrenme Kuralları

Eğitim sırasındaki amaç bulunması gereken doğru sonuçlara en yakın çıktıyı üretebilmektir. Ağ verilen girdilere göre kendi mimarisine de uygun olarak işlem yaptıktan sonra bir çıktı üretir. Çıktı ile hedef değerler arasındaki farkı kabul edilebilir seviyeye getirebilmek için işlemi tekrarlar. Eğitim setinin ağ içinde bir kez işlemden geçirilmesine devir (epoch) denir. Devir sayısının çok olması ağın öğrenme sürecinde performansı düşüren bir etkidir. Ağın mimarisi, aktivasyon fonksiyonu, öğrenme yöntemi ve devir sayısı ayarlanırken optimizasyonun iyi bir şekilde yapılması gerekir.

En bilinen ve en yaygın olarak kullanılan öğrenme kuralları şunlardır:

4.7.1. Delta Kuralı

Hebb kuralının biraz daha geliştirilmiş şeklidir. Bu kurala göre beklenen çıktı ile gerçekleşen çıktı arasındaki farkları azaltmak için bağlantıların ağırlık değerlerinin sürekli olarak değiştirilmesi gerekmektedir. Ağın ürettiği çıktı ile üretilmesi gereken çıktı arasındaki farkların karelerinin ortalamasının minimize edilmesidir. Bu kural, Widrow-Hoff Öğrenme Kuralı veya En Küçük Kareler Öğrenme Kuralı (Least Mean Square, LMS) diye de bilinir[20].

Başlangıçta giriş kümesi ağa verilir ve rastgele atanmış ağırlıklarla çıktı hesaplanır ve beklenen çıktı değeri ile arasındaki fark alınarak hata hesaplanır. Hata kabul edilebilir oradaysa ağırlıklar sabitlenir ve eğitim durdurulur. Aksi durumda hata oranı kabul edilebilir düzeye düşene kadar eğitime devam edilir. Delta öğrenme kuralı şu adımlardan oluşmaktadır[21]:

Adım 1: >0 olmak üzere değeri ve Emax değeri belirlenir.

Adım 2: Tüm ağırlıklara rastgele küçük değerler atanır. $K=1$ ve hata değeri $E=0$ olarak atanır.

Adım 3: Sistem çıkışı hesaplanır.

$$y_i(x) = (w_i, x) = \sum_{j=1}^m x_j w_{ij} \quad i=1, \dots, m$$

Adım 4: Ağırlıklar güncellenir.

$$w_{ij} = w_{ij}(\text{eski}) + (v_i - z_i) x_j$$

Adım 5: Toplam hata değeri, şuna kadarki hata değerleriyle toplanarak bulunur.

$$E = E + \frac{1}{2} (v_i - z_i)^2$$

Adım 6: Eğer $k < K$ ise $k = k + 1$ yapılır ve adım 3'e gidilir.

Adım 7: Buraya kadar 1 döngülük eğitim işlemi tamamlanmış oldu. $E < E_{\max}$ ise ağırlıklar sabitlenir ve eğitim bitirilir. $E > E_{\max}$ ise $E = 0$ yapılır ve yeniden eğitime başlamak için adım 3'e gidilir.

w_{ij} = i. çıkış nöronu ile j. gir nöronu arasındaki ağırlık,

= öğrenme sabiti,

v_i = i. çıkış nöronunun istenen değeri,

z_i = i. çıkış nöronunun eğitim çıkışı (tahmini),


E = hata değeri,

k = eğitim sayısıdır.

4.7.2. Geri Yayılım Öğrenme Algoritması

Bir katmandaki hiçbir düğüm kendi katmanındaki herhangi bir düğüme bağlı değildir. Her katmanın çıkış değeri bir sonraki katmanın giriş değeridir. Bu şekilde giriş değerlerinin ağırlık girişinden çıkışına doğru ilerlemesine ileri besleme denir. Geri yayılım çok katmanlı ağlarda kullanılan delta kuralı için geliştirilmiş bir algoritmadır[21].

Geriye yayılım öğrenme kullanıldığında, sonraki katmanların kullanılarak gizli katmanın ağırlıkları ayarlanır. Böylece çıkış katmanında hesaplanan hatalar ile son gizli katmanla çıkış katmanı arasındaki ağırlıklar ayarlanır. Aynı şekilde bu işlemler ilk gizli katmana kadar tekrarlanır. Bütün katmanlardaki ağırlıklar değiştirilerek toplam hata en aza indirilmeye çalışılır.



Şekil 4.10. Çok katmanlı ileri beslemeli değişkenleri

Geri yayılım işlemini anlatımını kolaylaştırmak için Şekil 4.10'daki bir gizli katmanı olan yapının mimarisi ve değişkenleri kullanıldı.

- v_{ij} = i giriş katman siniri ile j gizli katman siniri arasındaki ağırlık,
- w_{jk} = j gizli katman siniri ile k çıkış katmanı siniri arasındaki ağırlık,
- = x_p girdisini kullanan gizli katman sinirinin çıktısı,
- = çıkış katmanındaki i . hücreden beklenen çıktı,
- H_j = gizli katmandaki j . hücreye gelen net girdi,
- I_k = Çıkış katmanındaki k . hücreye gelen net girdi,
- E = hata değeri,

olmak üzere;

Hataların aritmetik ortalaması aşağıdaki gibi hesaplanır.

$$E_{ort} = (E_1 + E_2 + \dots + E_p) / p$$

Gizli katmandaki j . hücrenin net girdisi o hücreye gelen giriş değerlerinin ağırlıklı toplamına eşittir. Aşağıdaki denklemle hesaplanır.

Çıkış katmanındaki hücrenin net girdisi o hücreye gizli katmanlardan gelen değerlerin katsayılarıyla çarpılmış hallerinin toplamları alınarak hesaplanır. Aşağıdaki denklemle hesaplanır.

Çıkış katmanındaki hücrenin net girdisi (I_k) bir fonksiyondan geçirilerek çıkış değeri hesaplanır.

Aşağıdaki denklemle hata terimleri (δ) hesaplanır.

$$\delta_k = (v_k - z_k) f'(I_k)$$

Δ öğrenme katsayısı, δ_k hata terimi olmak üzere ağırlıkların değişim miktarları ($\Delta w, \Delta v$) aşağıdaki denklemlerle hesaplanır.

$$\Delta w_{jk} =$$

Ağırlıklarda yapacağımız değişim miktarları eski ağırlık miktarlarına eklenerek güncel ağırlık değerleri bulunur. Aşağıdaki denklemlerle hesaplanır.

$$\Delta w_{jk}$$

$$\Delta v_{ij}$$

Yenilenen ağırlıklarla ağıdan tekrar tahmin istenerek olması gereken deęerle kıyaslanıp hata bulunur. Kabul edilemeyecek bir hata ise eęitime tekrar devam edilir. Hata makul bir deęere düşene kadar ağırlıklar sürekli güncellenerek eęitime devam edilir.

5. YAPAY SINIR AĞLARI İLE ZAMAN SERİLERİNİN TAHMİNİ

Günümüzde yapay sinir ağlarının zaman serilerindeki potansiyeli istatistik bilimi için önemli bir yeri vardır. İstatistiksel yöntemlerde belli kurallar ve belli hesaplamalar vardır. Eğitim süreci söz konusu değildir. Daha çabuk sonuca ulaşılır. Bu yüzden aynı veriler girildiğinde her zaman aynı sonuç elde edilir. İstatistiksel yöntemin kullanıldığı pek çok alanda YSA kullanımı da mümkündür. Yalnız doğru ağ parametrelerinin seçimi için net bir bilgi yoktur. En doğru sitemi kurmak için genellikle deneme yanılma yöntemi kullanılmaktadır [22].

5.1. Yapay Sinir Ağı Giriş ve Çıkış Verileri

YSA başarıyla kullanıldığı alanlardan biri de tahmin problemleridir. Sıklıkla kullanılan bu ağlar, giriş dizisi üzerinde kayan pencere (sliding-window) yaklaşımını kullanan ileri beslemeli ağlardır [19].

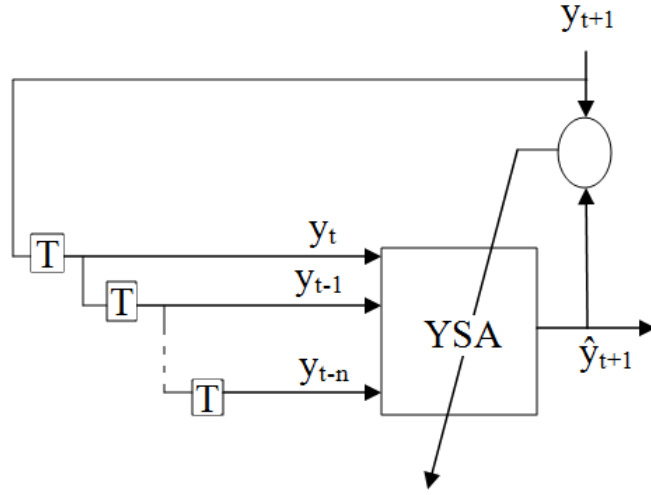
(5.1)

Burada p . girdi değişkenini, y_t de çıktıyı göstermektedir.

Zaman serilerinin tahmininde geçmiş değerler girdileri, gelecek zamanda çıktıyı verir. Bu durum aşağıdaki formülle ifade edilir.

(5.2)

Zaman serileri tahmini uygulamalarında, standart sinir ağı metodu giriş verisi olarak bir set ve ağın hedef değeri olarak tek bir çıktı kullanır. Kayan pencere tekniği olarak adlandırılan bu metot, eğitim setinin tamamı üzerinde giriş verisinin kaymasıyla gerçekleşir. Sekil 5.1’de temel bir yapı görülmektedir.



Şekil 5.1. Kayan pencere yaklaşımıyla zaman dizileri kestirimi

Üretilen gelecek zaman değeri giriş olarak kullanılarak bir sonraki gelecek değer, oda kullanılarak yeni ileri dönem tahminler yapılabilir.

Aşağıdaki ifadede k adım sonraki tahmini gösterilmektedir. , t+k anındaki tahmini ifade etmektedir.

$$(5.3)$$

$$(5.4)$$

·
·
·

$$(5.5)$$


Çıktı katmanında birden fazla nöron kullanımıyla çoklu dönem tahmini yapılabilir. Bir adım ileri tahmin yapmak için Denklem 5.6 kullanılır.

$$(5.6)$$

Denklem 5.6'ya ilişkin YSA yapısı Şekil 5.1'de verilmiştir.


Çıktı katmanının başka bir hücresine de iki adım ileri tahmin yaptırılır. İki adım ileri tahmin Denklem 5.7 ile Şekil 5.2'deki gibi yapılır.

(5.7)



Şekil 5.2. İki adım ileri tahmin için YSA yapısı

(5.8)

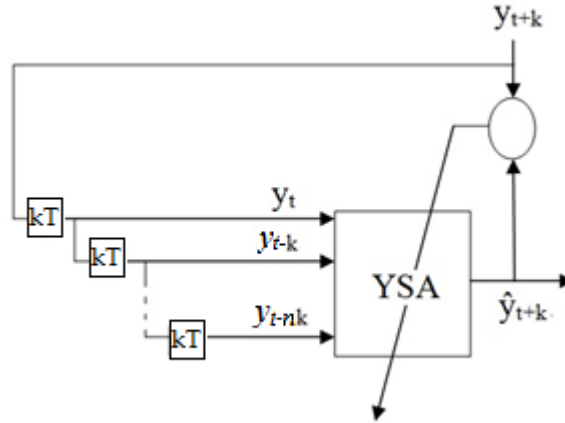


Şekil 5.3 . k adım ileri tahmin için YSA yapısı

Çoklu dönem tahmininde kullanılan diğer bir yönteme ilişkin eşitlik ise Denklem 5.9'da verilmiştir.

(5.9)

Denklem 5.9'a ilişkin YSA yapısı Şekil 5.4'deki gibidir.



Şekil 5.4 Atlamalı veri girişi ile k adım ileri tahmin YSA yapısı

5.2. YSA Tasarımı

Eğitim aşamasında girişler ve istenen çıkışlar girilir. Ağ girdileri kullanarak bir çıkış oluşturur ve bu çıktısını istenen çıktı ile kıyaslar ve hatayı bulur. Eğitim sonundaki amaç bu hatanın minimum seviyeye ulaşmasıdır. Eğer tasarlanan ağ tatmin edici bir sonuç vermiyorsa ağın tasarımında değişiklik yapılır.

YSA ile tahmin iki adım içerir. Eğitim ve kestirim(tahmin). Eğitim aşamasında girişler ve istenen çıktı ağa sunulur. Öğrenme algoritması yoluyla ağ kendi çıktısını üretir ve kendi çıktısı ile hedef çıktı arasındaki hata kareler toplamını minimum yapmaya çalışır. İyi eğitilmiş ağ, test setini kullanarak veri örneğinin geri kalanını kestirebilecektir. Bunun dışında, ağın mimarisi ve/veya parametreleri, test setinin performansını geliştirmek için değiştirilebilir. Tatmin edici bir şekilde test edilen ağ, tahmin için kullanılır.

Tahmin tek dönemlik ve çok dönemlik olmak üzere iki çeşittir. Tek dönemlik tahminde çıktı nöron sayısı 1'e eşittir. Çoklu dönem tahmini ise tek çıktı nöronu kullanılarak iteratif olarak ve birden fazla çıktı nöronu ile direkt olarak iki yolla yapılabilir.

Zhang vd., direkt metotta daha iyi sonuçlar elde etmişlerdir. İteratif metotta gözlem değerleri yerine, bulunan tahmin değerleri kullanılarak ileri dönemler kestirildiği için tahminlerin doğruluğunun azalacağı gerekçesiyle direkt metodun daha iyi olduğunu ileri sürmüşlerdir[2].

Gizli katman sayısının belirlenmesinde de bazı teorik çalışmalar neticesinde genellikle tek gizli katmanın, YSA ile başarılı sonuçlara ulaşmada yeterli olduğu ileri sürülmüştür. Bazı problemler için iki gizli katman kullanıldığı çalışmalarda mevcuttur. Ancak bu ifade bunun dışında bir tasarımın mümkün olmayacağı anlamına gelmez.

Giriş katmanında kullanılacak hücre sayısı için de belirlenmiş bir kural olmadığından bu sayı deneme yanılma yöntemi ile bulunabilir. Kohzadi vd. ise ürün fiyatlarının tahmini için kullandıkları, aylık veriler için oluşturdukları sinir ağı modelinde, fiyat tahmini için 6 ağ girişinin yeterli olacağı varsayımında bulunmuşlardır[23].

Aktivasyon fonksiyonları olarak, daha önce belirtildiği gibi sigmoid, hiperbolik tanjant, doğrusal, sinüs gibi aktivasyon fonksiyonları kullanılmaktadır. Bunlar arasında sıklıkla kullanılan aktivasyon fonksiyonu, sigmoid aktivasyon fonksiyonudur.

Hedef değerlerin normalleştirilmesi giriş verisi ile beraber uygulanır. Eğer sigmoid aktivasyon fonksiyonu kullanılmış ise veri $[0, 1]$, hiperbolik tanjant aktivasyon fonksiyonu kullanılmış ise $[-1, 1]$ aralığında normalleştirilir[24].

Çoğunlukla kullanılan veri normalleştirme formülleri aşağıdaki eşitliklerde verildiği gibidir:

$$[0,1] \text{ aralığında doğrusal dönüşüm:} \tag{5.10}$$

$$[a,b] \text{ aralığı doğrusal dönüşüm:} \tag{5.11}$$

$$\text{İstatistiksel normalizasyon:} \tag{5.12}$$

Basit normalizasyon:

(5.13)

Burada x_n ve x_0 normalleştirilmiş ve orijinal veriyi göstermektedir. x_{min} , x_{max} minimum ve maksimum değerleri, \bar{x} ortalamayı, s ise standart sapmayı göstermektedir.

YSA'nın eğitilmesi için ise arařtırmacılar genel olarak eğitim seti için %70, %80, %90 oranlarını tercih etmişlerdir. Geriye kalan %30, %20, %10 oranları ise test için ayrılırlar.

YSA'ya başlangıçta ağırlık değerleri rastgele atanır ve ağı eğitim sırasında kabul edilebilir bir hataya ulaşıncaya kadar ağırlıklarını deęiřtirir. İstenen ağırlık deęerinin ne olduęu bilinmedięi için YSA'nın davranıřlarını yorumlamak ve aıklamak mümkün olmaz. En az hatayı verecek ağırlık deęerleri bulunmaya alıřılır. Ağılar için belli bir hata deęeri kabul edilmektedir. Kabul gören hata deęerinin altındaki bir noktada ağın eğitimi yeterli kabul edilir.

6. DENEYSEL SONUÇLAR

Tez çalışmasının bu bölümünde, daha önceki bölümlerde anlatılanlar doğrultusunda; altının 1996-2010 yılları arasındaki aylık ortalama zaman serisinin ve Mackey-Glass kaotik zaman serisinin gelecekteki değerlerini tahmin edebilmek için YSA'dan yararlanılmıştır.

YSA tasarımında katman sayısı, katmanlardaki hücre (nöron) sayısı, aktivasyon fonksiyonu, öğrenme kuralı önemli parametrelerdir. Uygulamada altın ve Mackey-Glass zaman serisinin gelecekteki değerini tahmin edebilmek için bu serilere uygun yapay sinir ağı mimarisi tespit edilmiştir.

Çalışmanın önceki bölümlerinde de bahsedildiği gibi katman ve hücre sayılarının belli bir standardı yoktur. Yapılan deneysel çalışmalarda her iki zaman serisi için 1, 3 adım ileri tahmin, tek gizli katman, giriş katmanında ve gizli katmanda 3, 6 hücre denenmiş ve sonuçlar birbiri ile karşılaştırılarak; elde edilen sonuçlar verilmiştir. Elde edilen sonuçlar arasında değiştirilen parametrelerin performansa etkisi baskın olmadığından burada gizli katmandaki hücre sayıları 3 ve 6 alınarak elde edilen sonuçlar verilmiştir.

Ağın tasarımında ve çalıştırılmasında Mathworks firmasının MATLAB yazılımı kullanılmıştır. Uygulama için MATLAB yazılımında çalıştırılmak üzere programlar geliştirilmiştir. Uygulamada kullanılan iki farklı zaman serisinin açıklamaları ve sonuçları ayrı alt başlıklarda sunulmuştur.

Zaman serilerinin YSA ile eğitiminde ve tahmin performansı değerlendirme kriteri olan RMSE ve korelasyon katsayısı değerlerinin hesaplanmasında normalize değerler kullanılmıştır. Hata grafiklerinde, gerçek ve tahmin değerlerini gösterir grafiklerde gerçek veriler (denormalize değerler) kullanılmıştır.

6.1. Altın Fiyatlarının Tahmini İçin Yapılan Uygulama

Altın, döviz, hisse senedi ve diğer finansal ürünlerin değerleri çoğu zaman aynı zaman serisi bileşenlerinden etkilenir. Ekonomi alanında zaman serisi tahmininde yapay sinir ağlarına önemli ölçüde ihtiyaç duyulmaktadır. Altın fiyatları finansal bir veri olmasından dolayı uygulamada kullanacağımız zaman serisi olarak seçilmiştir. Altının aylık ağırlıklı ortalama fiyatları İstanbul Altın Borsası'nın web sitesinden (www.iab.gov.tr/Veriler/data/aaof.pdf) elde edilmiştir. Altın verilerin başlangıç tarihi Ocak 1996'dır. Son kullanılan veri ise Aralık 2010 tarihlidir. İki tarih arasında toplam 180 aylık veri kullanılmıştır. Verilerin 160 adeti eğitim, 20 adeti test için kullanılmıştır. Tablo 6.1. de 180 aylık veri sunulmuştur[25].


Tablo 6.1. Altın fiyatlarının yıllara ve aylara göre değeri

<i>YIL</i>	<i>AY</i>	<i>FİYAT(TL)</i>	<i>YIL</i>	<i>AY</i>	<i>FİYAT(TL)</i>	<i>YIL</i>	<i>AY</i>	<i>FİYAT(TL)</i>
1996	1	0,779221	2001	1	5,719621	2006	1	22,52
1996	2	0,842815	2001	2	5,79918	2006	2	23,28931
1996	3	0,872122	2001	3	8,291207	2006	3	23,77146
1996	4	0,922839	2001	4	9,949156	2006	4	26,87915
1996	5	0,972158	2001	5	9,693586	2006	5	31,36835
1996	6	0,992028	2001	6	10,36118	2006	6	30,5505
1996	7	1,027522	2001	7	11,224	2006	7	31,71364
1996	8	1,067795	2001	8	12,44377	2006	8	30,12323
1996	9	1,103055	2001	9	13,55202	2006	9	28,22125
1996	10	1,157743	2001	10	14,76192	2006	10	27,56869
1996	11	1,205272	2001	11	13,52225	2006	11	28,8423
1996	12	1,252048	2001	12	12,92636	2006	12	28,82355
1997	1	1,287708	2002	1	12,42969	2007	1	28,40391
1997	2	1,339033	2002	2	12,92562	2007	2	29,375
1997	3	1,425464	2002	3	12,88079	2007	3	29,42257
1997	4	1,466937	2002	4	12,73053	2007	4	29,582
1997	5	1,525689	2002	5	13,78017	2007	5	28,55593
1997	6	1,589751	2002	6	15,87033	2007	6	27,77805
1997	7	1,606624	2002	7	16,71557	2007	7	27,609
1997	8	1,714604	2002	8	16,19288	2007	8	27,76089
1997	9	1,774388	2002	9	16,78053	2007	9	28,78948
1997	10	1,877992	2002	10	16,79087	2007	10	29,38291
1997	11	1,854924	2002	11	16,45805	2007	11	30,46174
1997	12	1,861294	2002	12	17,43336	2007	12	30,53288
1998	1	1,969708	2003	1	18,76701	2008	1	32,84155

1998	2	2,149469	2003	2	18,6624	2008	2	35,20735
1998	3	2,244351	2003	3	18,42579	2008	3	38,97569
1998	4	2,446709	2003	4	17,19227	2008	4	37,72391
1998	5	2,434332	2003	5	17,08281	2008	5	35,65975
1998	6	2,462251	2003	6	16,36722	2008	6	35,29209
1998	7	2,541296	2003	7	16,02654	2008	7	36,52728
1998	8	2,517914	2003	8	16,07832	2008	8	33,47914
1998	9	2,590598	2003	9	16,70725	2008	9	31,93897
1998	10	2,674106	2003	10	17,04931	2008	10	38,84873
1998	11	2,814217	2003	11	18,50566	2008	11	40,24861
1998	12	2,896843	2003	12	18,78866	2008	12	41,30014
1999	1	3,005117	2004	1	17,81268	2009	1	43,33295
1999	2	3,174447	2004	2	17,30241	2009	2	50,35529
1999	3	3,367205	2004	3	17,04674	2009	3	50,84532
1999	4	3,471637	2004	4	17,68039	2009	4	45,72705
1999	5	3,549438	2004	5	18,56662	2009	5	46,65222
1999	6	3,497458	2004	6	18,6801	2009	6	47,04509
1999	7	3,533432	2004	7	18,53265	2009	7	45,58944
1999	8	3,614459	2004	8	18,66372	2009	8	45,51177
1999	9	3,84443	2004	9	19,45134	2009	9	47,85154
1999	10	4,677064	2004	10	20,00358	2009	10	49,5731
1999	11	4,697674	2004	11	20,38386	2009	11	54,67044
1999	12	6,827239	2004	12	19,9342	2009	12	55,77828
2000	1	5,025494	2005	1	18,53942	2010	1	52,9954
2000	2	5,504249	2005	2	17,94236	2010	2	53,46687
2000	3	5,373405	2005	3	18,18169	2010	3	54,84483
2000	4	5,378455	2005	4	18,47886	2010	4	54,6826
2000	5	5,469666	2005	5	18,72692	2010	5	60,35192
2000	6	5,646429	2005	6	18,366	2010	6	62,60988
2000	7	5,692582	2005	7	18,23677	2010	7	59,57888
2000	8	5,701743	2005	8	18,5043	2010	8	59,14711
2000	9	5,842708	2005	9	19,13304	2010	9	61,08812
2000	10	5,885739	2005	10	20,13304	2010	10	61,46455
2000	11	5,832173	2005	11	20,23422	2010	11	64,33803
2000	12	5,868383	2005	12	22,37234	2010	12	68,42354

6.1.1. 6_6_1 YSA Modeli ile Bir Ay Sonraki Altın Fiyatları Tahmini

Uygulamanın bu bölümünde altın fiyatları için altı aylık veri girişi, gizli katmanda altı hücre kullanarak bir ay sonraki fiyat tahmini yapılmıştır. Bu YSA yapısı 6 giriş, 6 gizli katmandaki hücre sayısı ve 1 çıkış katmanı hücre sayısı 6_6_1 olarak temsil edilmektedir. Eğitim sonucu ağın tahmin ettiği değerler ve gerçek değerler Şekil 6.1’de verilmiştir.



Şekil 6.1. 6_6_1 YSA modeli ile bir ay sonraki altın fiyatları tahmin performansı

Şekil 6.1’deki hata grafiğinde görüldüğü gibi hata sıfır dan çok fazla uzaklaşmamaktadır. Altın fiyatlarının bir ay içinde 10 TL gibi büyük değişimler gösterdiği dönemlerde bile yapay sinir ağının 3 TL gibi bir hata ile bir sonraki ayı tahmin ettiği gözlemlenmiştir. Makul görülebilecek bir hata ile bir sonraki ayı tahmin etmesi önemlidir ama bu her şeyin yolunda olduğunu göstermez. Bu yüzden yapay sinir ağı performansını değerlendirmek için tüm gruplar arasından hata kareleri ortalamasının karekökü (RMSE) ve korelasyon katsayısı (r) değerlerine bakılmıştır. Bu değerlerin hesaplanması için Denklem 6.1 ve Denklem 6.2 kullanılmıştır.

$$\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (6.1)$$

$$\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (6.2)$$

Burada:

et : t anındaki tahmin ve gerçek değer arasındaki farkı yani hatayı,

yt : t anındaki YSA tahminini,

: tahminleri ortalamasını,

dt : t anındaki gerçek değeri,

: gerçek değerlerin ortalamasını göstermektedir.

Tablo 6.2. 6_6_1 YSA modeli ile bir ay sonraki altın fiyatları tahmin performansı

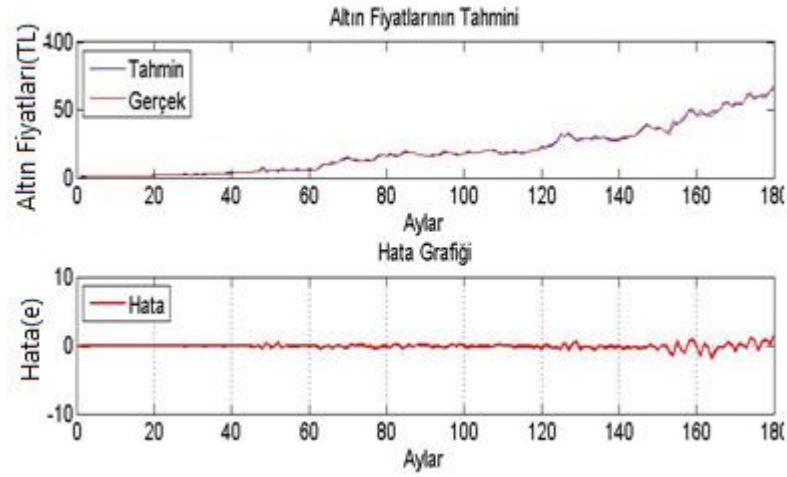
Grup	RMSE	r
Eğitim (1..160)	0.0062	0.9991
Test (161..180)	0.0146	0.9963

Yapay sinir ağlarının tahmin performansını yorumlamak için çeşitli ölçüm metotları vardır. Bu metotlardan hata kareleri ortalamasının karekökü 0'a ne kadar yakınsa performans o kadar yüksektir demektir. Tablo 6.2'de görüldüğü gibi 0'a yakın olan RMSE değeri gerçek değerler ile yapay sinir ağı modelinden elde edilen tahmin sonuçları arasındaki sapmaların çok küçük olduğunu göstermektedir.

Korelasyon katsayısı istatistik biliminde iki bağımsız değişken arasındaki doğrusal ilişkinin yönünü ve gücünü belirtmektedir. Eğer iki değişken arasından mükemmel ve ters yönde bir ilişki varsa korelasyon katsayısı -1 olacak, aynı yönde mükemmel bir ilişki olduğu takdirde ise +1 olacaktır[26]. +1'e çok yakın olan Tablo 6.2'deki korelasyon katsayısı (r) değerleri yapay sinir ağının tahmin ettiği altın fiyatları ile gerçek altın fiyatları arasında aynı yönde iyi bir ilişki olduğunu göstermiştir.

6.1.2. 6_3_1 YSA Modeli ile Bir Ay Sonraki Altın Fiyatları Tahmini

Uygulamanın bu bölümünde altın fiyatları için altı aylık veri girişi, gizli katmanda üç hücre kullanarak bir ay sonraki fiyat tahmini yapılmıştır. Bu YSA yapısı 6 giriş, 3 gizli katmandaki hücre sayısı ve 1 çıkış katmanlı hücre sayısı 6_3_1 olarak temsil edilmektedir. Eğitim sonucu elde edilen veriler Şekil 6.2. ve Tablo 6.3.'de verilmiştir.



Şekil 6.2. 6_3_1 YSA modeli ile bir ay sonraki altın fiyatları tahmin performansı


Tablo 6.3'de görüldüğü gibi 0'a yakın olan RMSE değeri gerçek değerler ile yapay sinir ağı modelinden elde edilen tahmin sonuçları arasındaki sapmaların çok küçük olduğunu göstermektedir. Ayrıca Tablo 6.2'deki RMSE değerlerinden çok az bir farkla büyük olduğu görülmektedir. Bu kadar küçük bir fark ile iki yapı arasındaki performansı kıyaslamak çok doğru değildir. Diğer değerlendirme ölçütü olan Tablo 6.3'deki korelasyon katsayısına bakalım olursak +1'e çok yakın bir değer olduğu gözükmektedir. Buda altın fiyatları ile gerçek altın fiyatları arasında aynı yönde iyi bir ilişki olduğunu ifade etmektedir.

Tablo 6.3. 6_3_1 YSA modeli ile bir ay sonraki altın fiyatları tahmin performansı

Grup	RMSE	R
Eğitim (1..160)	0.0062	0.9991
Test (161..180)	0.0159	0.9904

6.1.3. 3_6_1 YSA Modeli ile Bir Ay Sonraki Altın Fiyatları Tahmini

Uygulamanın bu bölümünde altın fiyatları için üç aylık veri girişi, gizli katmanda altı hücre kullanarak bir adım ileri tahmin yapılmıştır. Bu YSA yapısı 3 giriş, 6 gizli katmandaki hücre sayısı ve 1 çıkış katmanı hücre sayısı 3_6_1 olarak temsil edilmektedir. Eğitim sonucu elde edilen veriler Şekil 6.3. ve Tablo 6.4.'de verilmiştir.



Şekil 6.3. 3_6_1 YSA modeli ile bir ay sonraki altın fiyatları tahmin performansı

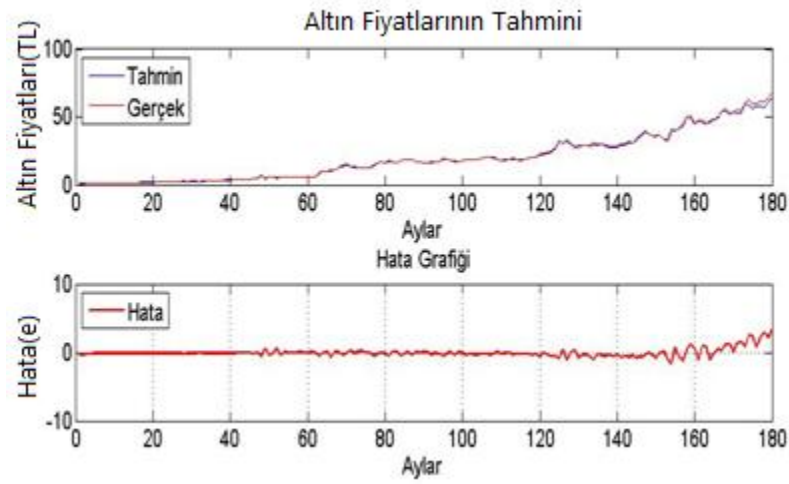
Şekil 6.3'deki hata grafiğinin sıfırdan çok fazla uzaklaşmadığı gözlenmiştir. Tablo 6.4'deki test kısmını gösteren RMSE ve r değerlerinin altı aylık veri girişi ile yapılan tahminlere göre istenmeyen yönde bir değişim gösterdiği saptanmıştır

Tablo 6.4. 3_6_1 YSA modeli ile bir ay sonraki altın fiyatları tahmin performansı

Grup	RMSE	r
Eğitim (1..160)	0.0048	0.9986
Test (161..180)	0.0210	0.9850

6.1.4. 3_3_1 YSA Modeli ile Bir Ay Sonraki Altın Fiyatları Tahmini

Uygulamanın bu bölümünde altın fiyatları için üç aylık veri girişi, gizli katmanda üç hücre kullanarak bir adım ileri tahmin yapılmıştır. Bu YSA yapısı 3 giriş, 3 gizli katmandaki hücre sayısı ve 1 çıkış katmanı hücre sayısı 3_3_1 olarak temsil edilmektedir. Sonuçlar Şekil 6.4. ve Tablo 6.5’de verilmiştir.



Şekil 6.4. 3_3_1 YSA modeli ile bir ay sonraki altın fiyatları tahmin performansı

Şekil 6.4’deki gerçek fiyatları ve tahmin fiyatlarını gösterir grafikte eğitim kısmında iyi bir başarı olduğu fakat test kısmında bu başarının azaldığı gözlenmiştir. Tablo 6.5’deki RMSE ve r değerleri bu tespiti doğrular niteliktedir.

Tablo 6.5. 3_3_1 YSA modeli ile bir ay sonraki altın fiyatları tahmin performansı


Grup	RMSE	r
Eğitim (1..160)	0.0049	0.9985
Test (161..180)	0.0233	0.9790

6.1.5. Atlamalı 6_6_1 YSA Modeli ile Üç Ay Sonraki Altın Fiyatları Tahmini

Uygulamanın bu bölümünde altın fiyatları için altı aylık giriş, gizli katmanda altı hücre kullanarak üç adım ileri tahmin yapılmıştır. Giriş verileri ile çıkış verileri arasında kurulan ilişki Denklem 6.3. de sunulmuştur.

(6.3)

YSA'nın tahmin sonuçları Şekil 6.5. ve Tablo 6.6.'de verilmiştir.



Şekil 6.5. Atlamalı 6_6_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı


Şekil 6.5'deki tahmin ve gerçek değerleri gösterir grafikte bir ay sonrası için yapılan tahminler kadar sağlıklı bir tahmin yapılamadığı tespit edilmiştir. Hata grafiğinde de hataların büyüdüğü anlaşılmaktadır. Yine Tablo 6.6'daki test kısmını gösterir RMSE ve r değerlerinin istenmeyen yönde bir değişim göstermiştir.

Tablo 6.6. Atlamalı 6_6_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı

Grup	RMSE	R
Eğitim (1..160)	0.0142	0.9965
Test (161..180)	0.0247	0.9721

6.1.6. Atlamalı 6_3_1 YSA Modeli ile Üç Ay Sonraki Altın Fiyatları Tahmini

Uygulamanın bu bölümünde altın fiyatları için altı aylık giriş, gizli katmanda üç hücre kullanarak üç adım ileri tahmin yapılmıştır. Giriş verileri ile çıkış verileri arasındaki ilişki denklem 6.3. de sunulmuştur. Eğitim sonucu elde edilen veriler Şekil 6.6. ve Tablo 6.7.'de verilmiştir.



Şekil 6.6. Atlamalı 6_3_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı

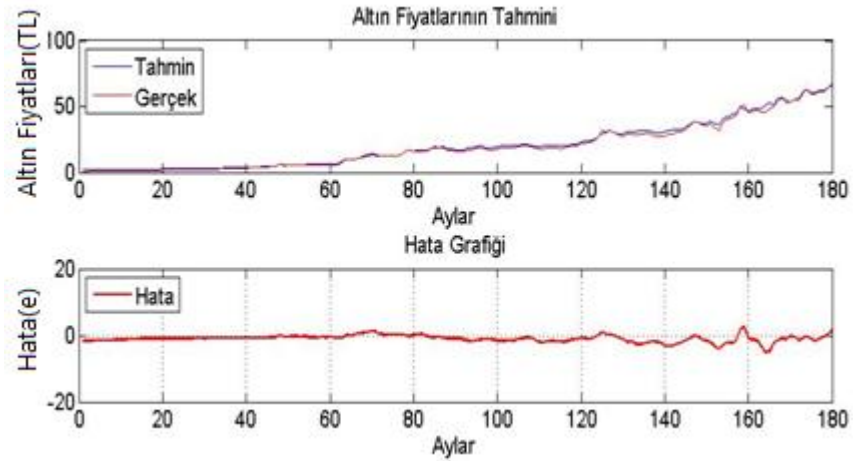
Şekil 6.6'daki tahmin ve gerçek değerleri gösterir grafikte bir ay sonrası için yapılan tahminler kadar sağlıklı bir tahmin yapılamadığı gözlenmiştir. Hata grafiğinde de hataların büyüdüğü anlaşılmaktadır. Yine Tablo 6.7'deki test kısmını gösterir RMSE ve r değerlerinin istenmeyen yönde bir değişim göstermiştir.

Tablo 6.7. Atlamalı 6_3_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı

Grup	RMSE	r
Eğitim (1..160)	0.0140	0.9968
Test (161..180)	0.0293	0.9721

6.1.7. Atlamalı 3_6_1 YSA Modeli ile Üç Ay Sonraki Altın Fiyatları Tahmini

Uygulamanın bu bölümünde altın fiyatları için üç aylık veri girişi, gizli katmanda altı hücre kullanarak üç ay sonrası tahmin edilmiştir. Giriş verileri ile çıkış verileri arasındaki ilişki denklem 6.3. de sunulmuştur. Eğitim sonucu elde edilen veriler Şekil 6.7. ve Tablo 6.8.'de verilmiştir.



Şekil 6.7. Atlamalı 3_6_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı

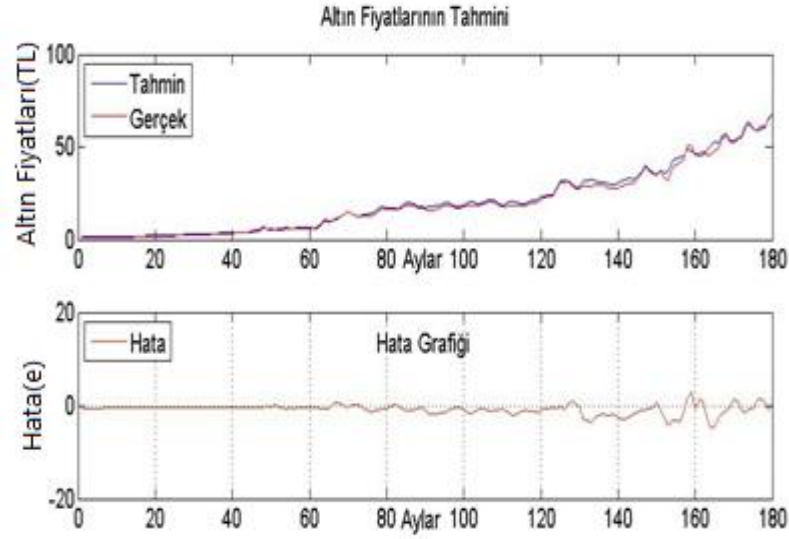
Şekil 6.7'de de görüldüğü gibi serinin test kısmında performans düşmüştür. Tablo 6.8'deki korelasyon katsayısı ve RMSE değeri bu performans düşüklüğünü doğrular niteliktedir. Birçok zaman serisi tahmininde bu ölçüm değerleri iyi bir sonuç olarak değerlendirilebilir ama aynı zaman serisi için yapılan daha önceki tahminlerde daha başarılı sonuçlar elde edilmiştir.

Tablo 6.8. Atlamalı 3_6_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı

Grup	RMSE	r
Eğitim (1..160)	0.0130	0.9974
Test (161..180)	0.0302	0.9679

6.1.8. Atlamalı 3_3_1 YSA Modeli ile Üç Ay Sonraki Altın Fiyatları Tahmini

Uygulamanın bu bölümünde altın fiyatları için üç aylık girişi, gizli katmanda üç hücre kullanarak üç ay sonrası tahmin edilmiştir. Giriş verileri ile çıkış verileri arasındaki ilişki denklem 6.3. de sunulmuştur. Eğitim sonucu elde edilen veriler Şekil 6.8. ve Tablo 6.9.'de verilmiştir.



Şekil 6.8. Atlamalı 3_3_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı

Şekil 6.8'de de görüldüğü gibi serinin test kısmında, altı giriş kullanarak yapılan tahminlere göre performans düşmüştür. Tablo 6.9'deki korelasyon katsayısı ve RMSE değeri bu performans düşüklüğünü doğrular niteliktedir.


Tablo 6.9. Atlamalı 3_3_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı

Grup	RMSE	r
Eğitim (1..160)	0.0128	0.9975
Test (161..180)	0.0307	0.9717

6.1.9. Ardışık 6_6_1 YSA Modeli ile Üç Ay Sonraki Altın Fiyatları Tahmini

Altın fiyatları için altı aylık veri girişi, gizli katmanda altı hücre kullanarak üç adım ileri tahmin yapılmıştır. 3 adım sonrası tahmin edilirken giriş verileri sanki 1 adım sonrası tahmin ediliyor gibi hazırlanmıştır. Buna ilgili formül denklem 6.4’de verilmiştir. Ayrıca eğitim sonucu elde edilen veriler Şekil 6.9 ve Tablo 6.10’da sunulmuştur.

(6.4)



Şekil 6.9. Ardışık 6_6_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı


Şekil 6.9’da görüldüğü gibi serinin test kısmında, 6_6_1 YSA Modeli ile bir adım ileri tahmindeki performansa ulaşamamıştır. Fakat Atlamalı 6_6_1 model ile 3 adım ileri tahminden daha iyi bir başarı elde edilmiştir. Tablo 6.9’deki korelasyon katsayısı ve RMSE değeri bu performans düşüklüğünü doğrular niteliktedir.

Tablo 6.10. Ardışık 6_6_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı

Grup	RMSE	r
Eğitim (1..160)	0.0125	0.9977
Test (161..180)	0.0215	0.9854

6.1.10. Ardışık 6_3_1 YSA Modeli ile Üç Ay Sonraki Altın Fiyatları Tahmini

Uygulamanın bu bölümünde altın fiyatları için altı aylık girişi, gizli katmanda üç hücre kullanarak üç ay sonrası tahmin edilmiştir. 3 adım sonrası tahmin edilirken giriş verileri sanki 1 adım sonrası tahmin ediliyor gibi hazırlanmıştır. Bunla ilgili formül denklem 6.4’de verilmiştir. Ayrıca eğitim sonucu elde edilen veriler Şekil 6.10 ve Tablo 6.11’de sunulmuştur.



Şekil 6.10. Ardışık 6_3_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı


Tablo 6.11’deki veriler atlamalı 6_3_1 modele göre daha başarılı bir tahmin yapıldığı göstermektedir.

Tablo 6.11. Ardışık 6_3_1 ysa modeli ile üç ay sonraki altın fiyatları tahmin performansı

Grup	RMSE	r
Eğitim (1..160)	0.0128	0.9975
Test (161..180)	0.0204	0.9806

6.1.11. Ardışık 3_6_1 YSA Modeli ile Üç Ay Sonraki Altın Fiyatları Tahmini

Uygulamanın bu bölümünde altın fiyatları için üç aylık girişi, gizli katmanda altı hücre kullanarak üç ay sonrası tahmin edilmiştir. 3 adım sonrası tahmin edilirken giriş verileri sanki 1 adım sonrası tahmin ediliyor gibi hazırlanmıştır. Ayrıca eğitim sonucu elde edilen veriler Şekil 6.11. ve Tablo 6.12.'de sunulmuştur.



Şekil 6.11. Ardışık 3_6_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı


Tablo 6.12'deki değerlere bakıldığında RMSE değerinin 0'a çok yakın olduğu ve korelasyon katsayısının +1'e çok yakın olduğu gözükmektedir. Fakat serinin test kısmındaki korelasyon katsayısının eğitim kısmındaki kadar performans göstermediği tespit edilmiştir.

Tablo 6.12. Ardışık 3_6_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı

Grup	RMSE	r
Eğitim (1..160)	0.0109	0.9978
Test (161..180)	0.0222	0.9706

6.1.12. Ardışık 3_3_1 YSA Modeli ile Üç Ay Sonraki Altın Fiyatları Tahmini

Uygulamanın bu bölümünde altın fiyatları için üç aylık girişi, gizli katmanda üç hücre kullanarak üç ay sonrası tahmin edilmiştir. 3 adım sonrası tahmin edilirken giriş verileri sanki 1 adım sonrası tahmin ediliyor gibi hazırlanmıştır. Eğitim sonucu elde edilen veriler Şekil 6.12. ve Tablo 6.13.'de sunulmuştur.



Şekil 6.12. Ardışık 3_3_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı

Tablo 6.13'deki değerlere bakıldığında RMSE değerinin 0'a çok yakın olduğu ve korelasyon katsayısının +1'e çok yakın olduğu gözükmektedir. Fakat serinin test kısmındaki korelasyon katsayısının eğitim kısmındaki kadar performans göstermediği tespit edilmiştir.

Tablo 6.13. Ardışık 3_3_1 YSA modeli ile üç ay sonraki altın fiyatları tahmin performansı

Grup	RMSE	r
Eğitim (1..160)	0.0113	0.9988
Test (161..180)	0.0261	0.9683

6.1.13. Altın Fiyatlarının Tahmini İçin Değerlendirme

Altın fiyatlarının tahmini için yapılan testlerde elde edilen sonuçlar Tablo 6.14. de karşılaştırılmıştır. Tabloda 3 adım ileri tahminler “Atl.” Şeklinde belirtilmiştir. Tablodaki RMSE ve korelasyon katsayısına bakıldığında yapılan bütün testlerde de yapay sinir ağının altın verileri için iyi tahmin yaptığı tespit edilmiştir. Test veriler kendi içinde birbiri ile kıyaslandığında 1 adım ileri tahminde 3 adım ileri tahmine göre daha başarılı sonuçlar elde edildiği görülmektedir. Ayrıca hem 1 adım tahminde hem de 3 adım tahminde 6 giriş kullanılan yapay sinir ağının 3 giriş kullanılan yapay sinir ağına göre daha başarılı sonuç verdiği tespit edilmiştir.

3 adım tahmin için giriş verileri 2 farklı şekilde ağa girdi olarak verilmişti. Giriş verileri ağa $y_t, y_{t-1}, y_{t-2} \dots y_{t-n}$ şeklinde ardışık alınarak yapılan 3 adım ileri tahmin atlamalı 3 adım ileri tahmin modeline göre daha başarılı tahmin yapmıştır. Bu sonuçlara ulaşılırken yapılan birçok test ile en doğru sonuç elde edilmeye çalışılmıştır. Yapılan testlerde eğitimin çok fazla olması ya da yeteri kadar olmaması kötü sonuçlar doğurduğu gözlemlenmiştir. Bunu için zaman serisinin ve yapay sinir ağının yapısına uygun sayıda eğitim yaptırılmalıdır.

Tablo 6.14. YSA ile altın fiyatlarının tahmin sonuçları


Adım	YSA Yapısı	RMS eğitim (1..160)	Korelasyon Kat. eğitim(r) (1..160)	RMSE test (161..180)	Korelasyon Kat. test(r) (161..180)
1 adım	6_6_1	0.0062	0.9991	0.0146	0.9963
	6_3_1	0.0062	0.9991	0.0159	0.9904
	3_6_1	0.0048	0.9986	0.0210	0.9850
	3_3_1	0.0049	0.9985	0.0233	0.9790
3 adım	6_6_1Atl.	0.0142	0.9965	0.0247	0.9721
	6_3_1Atl.	0.0140	0.9968	0.0293	0.9721
	3_6_1Atl.	0.0130	0.9974	0.0302	0.9679
	3_3_1Atl.	0.0128	0.9975	0.0307	0.9717
	6_6_1	0.0125	0.9977	0.0215	0.9854
	6_3_1	0.0128	0.9975	0.0204	0.9806
	3_6_1	0.0109	0.9978	0.0222	0.9706
	3_3_1	0.0113	0.9988	0.0261	0.9683

6.2. Mackey-Glass (M-G) Kaotik Zaman Serisi Tahmini İçin Yapılan Uygulama

Bu bölümdeki uygulamalarda kullanılan zaman serisi Mackey-Glass kaotik zaman serisi olarak belirlenmiştir. Bu seride $t=1\dots 1201$ olmak üzere 0.2192 ile 1.3137 arasında 1201 adet kaotik yapıda değişken kullanılmıştır. 1201 adet verinin ilk 1000 adeti eğitim, son 201 adeti test için kullanılmıştır.

Giriş katmanında ve gizli katmanda farklı sayıda hücreler denenerek bir adım sonrası ve üç adım sonrası tahmin edilmeye çalışılmıştır. Üç adım ileri tahminde geçmiş değerler YSA'ya girdi olarak alınırken iki farklı yöntem kullanılmıştır.


Aşağıda Şekil 6.13.'de yapay sinir ağına tahmin ettirilen zaman serisinin grafiği sunulmuştur.



Şekil 6.13. YSA veri girişi olarak kullanılacak kaotik zaman serisi

6.2.1. 6_6_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Bir Adım İleri Tahmini

Uygulamanın bu bölümünde Mackey-Glass kaotik zaman serisi için altı veri girişi, gizli katmanda altı hücre kullanarak bir adım ileri tahmin yapılmıştır. Ayrıca eğitim sonucu elde edilen veriler Şekil 6.14. ve Tablo 6.15.'de sunulmuştur.



Şekil 6.14. 6_6_1 YSA modeli ile M-G kaotik zaman serisinin bir adım ileri tahmin performansı

Şekil 6.14'deki grafik hatanın çok küçük olduğunu ve başarılı bir tahmin yapıldığını göstermektedir. Grafik üzerinden her şeyin yolunda gittiğini söylemek her zaman mümkün olmayabilir. Bu yüzden Mackey-Glass kaotik zaman serisinin tahmininde yapay sinir ağı performansını değerlendirmek için tüm gruplar arasından hata kareleri ortalamasının karekökü (RMSE) ve korelasyon katsayısı (r) değerlerine bakılmıştır. Bu değerlerin hesaplanması için Denklem 6.1 ve Denklem 6.2 kullanılmıştır.


Tablo 6.15'e bakıldığında 0'a oldukça yakın RMSE değeri ve +1'e yakın korelasyon katsayısı iyi bir tahmin yapıldığını ifade etmektedir.

Tablo 6.15. 6_6_1 YSA modeli ile M-G kaotik zaman serisinin bir adım ileri tahmin performansı

Grup	RMSE	r
Eğitim (1..1000)	0.0095	0.9989
Test (1001..1201)	0.0134	0.9961

6.2.2. 6_3_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Bir Adım İleri Tahmini

Uygulamanın bu bölümünde Mackey-Glass kaotik zaman serisi için altı veri girişi, gizli katmanda üç hücre kullanarak bir adım ileri tahmin yapılmıştır. Ayrıca eğitim sonucu elde edilen veriler Şekil 6.15. ve Tablo 6.16.'da sunulmuştur.



Şekil 6.15. 6_3_1 YSA modeli ile M-G kaotik zaman serisinin bir adım ileri tahmin performansı


Şekil 6.15 ve Tablo 6.16 bir önceki bölümde 6_6_1 YSA Modeli ile yapılan tahmin den daha başarılı sonuç elde edildiğini göstermektedir.

Tablo 6.16. 6_3_1 YSA modeli ile M-G kaotik zaman serisinin bir adım ileri tahmin performansı

Grup	RMSE	r
Eğitim (1..1000)	0.0107	0.9990
Test (1001..1201)	0.0140	0.9962

6.2.3. 3_6_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Bir Adım İleri Tahmini

Mackey-Glass kaotik zaman serisi için üç veri girişi, gizli katmanda altı hücre kullanarak bir adım ileri tahmin yapılmıştır. Ayrıca eğitim sonucu elde edilen veriler Şekil 5.16. ve Tablo 5.17.'da sunulmuştur.



Şekil 6.16. 3_6_1 YSA modeli ile M-G kaotik zaman serisinin bir adım ileri tahmin performansı

Şekil 6.16'daki grafik hatanın çok düşük olduğunu göstermektedir.

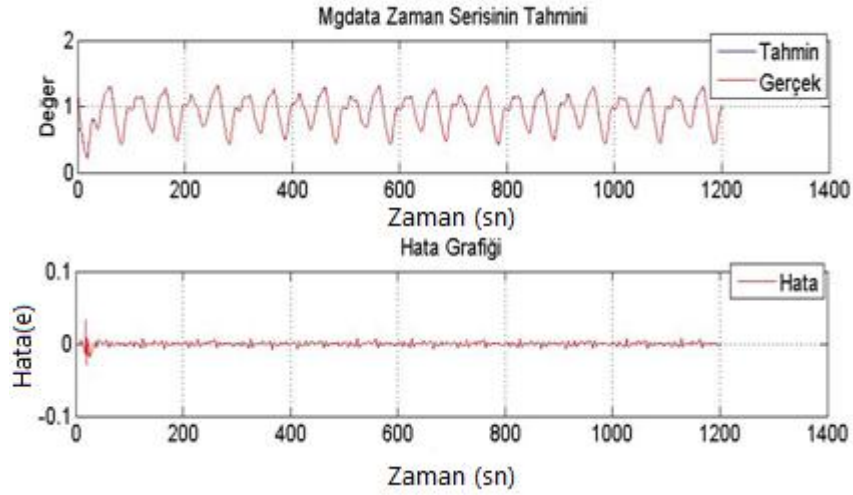
Tablo 6.17'deki 0'a oldukça yakın RMSE değeri ve +1'e yakın korelasyon katsayısı iyi bir tahmin yapıldığını ifade etmektedir.

Tablo 6.17. 3_6_1 YSA modeli ile M-G kaotik zaman serisinin bir adım ileri tahmin performansı

Grup	RMSE	r
Eğitim (1..1000)	0.0201	0.9986
Test (1001..1201)	0.0212	0.9803

6.2.4. 3_3_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Bir Adım İleri Tahmini

Uygulamanın bu bölümünde Mackey-Glass kaotik zaman serisi için üç veri girişi, gizli katmanda üç hücre kullanarak bir adım ileri tahmin yapılmıştır. Ayrıca eğitim sonucu elde edilen veriler Şekil 6.17. ve Tablo 6.18’de sunulmuştur.



Şekil 6.17. 3_3_1 YSA modeli ile M-G kaotik zaman serisinin bir adım ileri tahmin performansı

Şekil 6.17’deki grafik Mackey Glass kaotik zaman serisinin tahmini için yapılan daha önceki bölümlerde elde edilen tahmin başarısına yakın bir başarı elde edildiği tespit edilmiştir.


Tablo 6.18’e bakıldığında 0’a oldukça yakın RMSE değeri ve +1’e yakın korelasyon katsayısı iyi bir tahmin yapıldığını ifade etmektedir. Fakat giriş katmanında 6 hücre kullanılan yapılara göre tahmin performansında düşme olduğu gözlenmiştir.

Tablo 6.18. 3_6_1 YSA modeli ile M-G kaotik zaman serisinin bir adım ileri tahmin performansı

Grup	RMSE	r
Eğitim (1..1000)	0.0215	0.9896
Test (1001..1201)	0.0238	0.9836

6.2.5. Atlamalı 6_6_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Üç Adım İleri Tahmini

Mackey-Glass kaotik zaman serisi için altı veri girişi Denklem 5.3.'e göre düzenlenmiş ve gizli katmanda altı hücre kullanarak üç adım ileri tahmin yapılmıştır. Eğitim sonucu elde edilen veriler Şekil 6.18. ve Tablo 6.19.'de sunulmuştur.



Şekil 6.18. Atlamalı 6_6_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı


Şekil 6.18'deki grafik hatanın çok küçük olduğunu göstermektedir. Üç adım ileri tahminde de Mackey-Glass kaotik zaman serisi tahmininde yapay sinir ağı performansını değerlendirmek için hata kareleri ortalamasının karekökü (RMSE) ve korelasyon katsayısı (r) değerlerine bakılmıştır. Tablo 6.19'da verilen RMSE ve r değerleri iyi bir tahmin yapıldığını ifade etmektedir. Fakat bir adım ileri tahmine göre tahmin performansında düşme tespit edilmiştir.

Tablo 6.19. Atlamalı 6_6_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı

Grup	RMSE	r
Eğitim (1..1000)	0.0158	0.9966
Test (1001..1201)	0.0445	0.9932

6.2.6. Atlamalı 6_3_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Üç Adım İleri Tahmini

YSA'nın gizli katmanındaki hücre sayısı değiştirilerek YSA'nın performansını incelemek için altı veri girişi Denklem 5.3.'e göre düzenlenmiş ve gizli katmanda üç hücre kullanarak üç adım ileri tahmin yapılmıştır. Eğitim sonucu elde edilen veriler Şekil 5.19. ve Tablo 5.20.'de sunulmuştur.



Şekil 6.19. Atlamalı 6_3_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı


Şekil 6.19 ve Tablo 6.20 bir önceki bölümde atlamalı 6_6_1 YSA Modeli ile yakalanan tahmin başarısına yakın bir başarı elde edildiğini göstermektedir.

Tablo 6.20. Atlamalı 6_3_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı

Grup	RMSE	r
Eğitim (1..1000)	0.0092	0.9985
Test (1001..1201)	0.0404	0.9932

6.2.7. Atlamalı 3_6_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Üç Adım İleri Tahmini

Uygulamanın bu bölümünde Mackey-Glass kaotik zaman serisi için altı veri girişi Denklem 5.3.'e göre düzenlenmiş ve gizli katmanda altı hücre kullanarak üç adım ileri tahmin yapılmıştır. Eğitim sonucu elde edilen veriler Şekil 6.20. ve Tablo 6.21.'de sunulmuştur.



Şekil 6.20. Atlamalı 3_6_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı


Bu bölümde de atlamalı 3_6_1 modelinde elde edilen başarıya yakın bir başarı elde edilmiştir. Tablo 6.20'ye bakıldığında 0'a oldukça yakın RMSE değeri ve +1'e yakın korelasyon katsayısı iyi bir tahmin yapıldığını ifade etmektedir.

Tablo 6.21. Atlamalı 3_6_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı

Grup	RMSE	r
Eğitim (1..1000)	0.0210	0.9921
Test (1001..1201)	0.0652	0.9841

6.2.8. Atlamalı 3_3_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Üç Adım İleri Tahmini

Uygulamanın bu bölümünde YSA'nın gizli katmanındaki hücre sayısı değiştirilerek YSA'nın performansını incelemek için üç veri girişi Denklem 5.3.'e göre düzenlenmiş ve gizli katmanda üç hücre kullanarak üç adım ileri tahmin yapılmıştır. Eğitim sonucu elde edilen veriler Şekil 6.21. ve Tablo 6.22.'de sunulmuştur.



Şekil 6.21. Atlamalı 3_3_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı

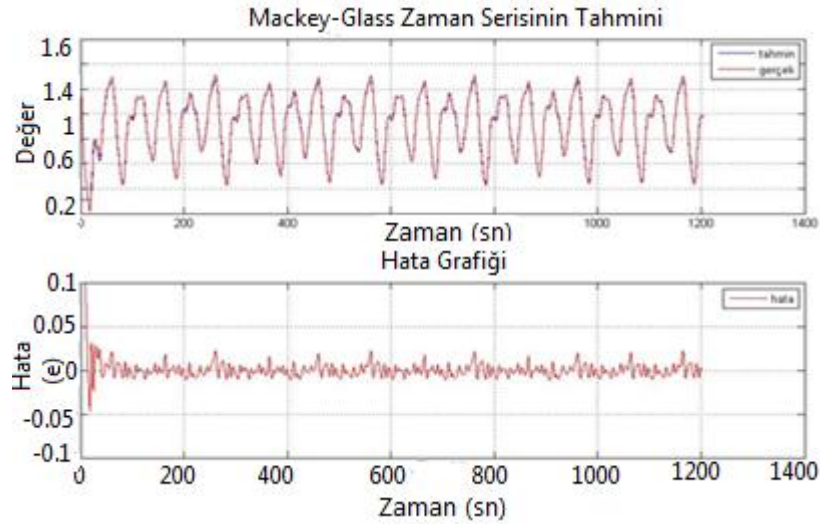
Şekil 6.21'deki grafik hatanın çok küçük olduğunu ve iyi bir tahmin yapıldığını göstermektedir. Tablo 6.22'deki RMSE ve r değerinde atlamalı altı girişli üç adım ileri tahmine göre kötüleşme olmuştur. Fakat 0'a oldukça yakın RMSE değeri, +1'e yakın korelasyon katsayısı yapılan tahminin kötü bir tahmin olmadığını ifade etmektedir.

Tablo 6.22. Atlamalı 3_3_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı

Grup	RMSE	r
Eğitim (1..1000)	0.0221	0.9900
Test (1001..1201)	0.0675	0.9894

6.2.9. Ardışık 6_6_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Üç Adım İleri Tahmini

Uygulamanın bu bölümünde Mackey-Glass kaotik zaman serisi için altı veri girişi Denklem 5.4.'e göre düzenlenmiş ve gizli katmanda altı hücre kullanarak üç adım ileri tahmin yapılmıştır. Eğitim sonucu elde edilen veriler Şekil 5.22. ve Tablo 5.23.'de sunulmuştur.



Şekil 6.22. Ardışık 6_6_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı


Altı giriş, gizli katmanda altı hücre kullanılarak üç adım ileri tahmin edilen bu testte de daha önceki tahminlerdeki gibi benzer başarı elde edilmiştir.

Tablo 6.23. Ardışık 6_6_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı

Grup	RMSE	r
Eğitim (1..1000)	0.0184	0.9931
Test (1001..1201)	0.0392	0.9926

6.2.10. Ardışık 6_3_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Üç Adım İleri Tahmini

Uygulamanın bu bölümünde YSA'nın gizli katmanındaki hücre sayısı değiştirilerek YSA'nın performansını incelemek için altı veri girişi Denklem 5.4.'e göre ardışık olarak düzenlenmiş ve gizli katmanda üç hücre kullanarak üç adım ileri tahmin yapılmıştır. Eğitim sonucu elde edilen veriler Şekil 6.23. ve Tablo 6.24.'de sunulmuştur.



Şekil 6.23. Ardışık 6_3_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı


Bir önceki testten farklı olarak gizli katmandaki hücre sayısı azaltılan bu testte de RMSE değerinde hafif kötüleşme görülürken korelasyon katsayısında iyileşme görülmüştür. Bu değişimlerin çok küçük olmasından dolayı iki test için tahmin başarıları benzerdir demek çok yanlış bir ifade olmayacaktır.

Tablo 6.24. Ardışık 6_6_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı

Grup	RMSE	r
Eğitim (1..1000)	0.0399	0.9969
Test (1001..1201)	0.0568	0.9956

6.2.11. Ardışık 3_6_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Üç Adım İleri Tahmini

Uygulamanın bu bölümünde Mackey-Glass kaotik zaman serisi için üç veri girişi Denklem 5.4.'e göre düzenlenmiş ve gizli katmanda altı hücre kullanarak üç adım ileri tahmin yapılmıştır. Eğitim sonucu elde edilen veriler Şekil 5.24. ve Tablo 5.25.'de sunulmuştur.



Şekil 6.24. Ardışık 3_6_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı


Tablo 6.25'deki RMSE ve korelasyon katsayısına bakıldığında başarılı bir tahmin yapıldığı anlaşılmaktadır.

Tablo 6.25. Ardışık 3_6_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı

Grup	RMSE	r
Eğitim (1..1000)	0.0137	0.9962
Test (1001..1201)	0.0374	0.9919

6.2.12. Ardışık 3_3_1 YSA Modeli ile M-G Kaotik Zaman Serisinin Üç Adım İleri Tahmini

Uygulamanın bu bölümünde Mackey-Glass kaotik zaman serisi için üç veri girişi Denklem 5.4.'e göre ardışık olarak düzenlenmiş ve gizli katmanda üç hücre kullanarak üç adım ileri tahmin yapılmıştır. Eğitim sonucu elde edilen veriler Şekil 5.25. ve Tablo 5.26.'de sunulmuştur.



Şekil 6.25. Ardışık 3_3_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı

Tablo 6.26'daki RMSE ve korelasyon katsayısına bakıldığında başarılı bir tahmin yapıldığı anlaşılmaktadır.

Tablo 6.26. Ardışık 3_3_1 YSA modeli ile M-G kaotik zaman serisinin üç adım ileri tahmin performansı

Grup	RMSE	r
Eğitim (1..1000)	0.0175	0.9941
Test (1001..1201)	0.0391	0.9937

6.2.13. Mackey-Glass Kaotik Zaman Serisi Tahmini İçin Değerlendirme

Mackey-Glass kaotik zaman serisinin tahmini için yapılan uygulamalarda elde edilen sonuçlar Tablo 6.27. de karşılaştırılmıştır. Veriler birbiri ile kıyaslandığında bir adım ileri tahminin ilk dört uygulamada birbirine yakın başarılar elde edildiği görülmektedir. Mackey-Glass kaotik zaman serisinin tahmini için yapılan bütün uygulamalarda RMSE değeri 0'a yakın, korelasyon katsayısı +1'e yakın çıkmıştır. Bu da bize gerçek değerler ile yapay sinir ağı modelinden elde edilen tahmin sonuçları arasındaki sapmaların çok küçük olduğunu ve aralarında iyi bir doğrusal ilişkinin olduğunu anlatır.

Tablo 6.27. Mackey-Glass kaotik zaman serisinin tahmini için yapılan uygulama sonuçları

Adım	YSA Yapısı	RMS Eğitim (1..1000)	RMSE test (1001..1201)	Korelasyon Kat. eğitim(r) (1..1000)	Korelasyon Kat. test(r) (1001..1201)
1 adım	6_6_1	0.0095	0.0134	0.9989	0.9961
	6_3_1	0.0107	0.0140	0.9990	0.9962
	3_6_1	0.0201	0.0212	0.9986	0.9803
	3_3_1	0.0215	0.0238	0.9896	0.9836
3 adım	6_6_1Atl.	0.0158	0.0445	0.9966	0.9932
	6_3_1Atl.	0.0092	0.0404	0.9985	0.9932
	3_6_1Atl.	0.0210	0.0652	0.9921	0.9841
	_3_1Atl.	0.0221	0.0675	0.9900	0.9894
	6_6_1	0.0184	0.0392	0.9931	0.9926
	6_3_1	0.0399	0.0568	0.9969	0.9956
	3_6_1	0.0137	0.0374	0.9962	0.9919
	3_3_1	0.0175	0.0391	0.9941	0.9937

Üç adım tahmin için giriş verileri iki farklı şekilde ağa girdi olarak verilmişti. Giriş verileri ağa $y_t, y_{t-1}, y_{t-2} \dots y_{t-n}$ şeklinde alınarak yapılan üç adım ileri tahmin diğer üç adım ileri tahmin modeline göre daha başarılı tahmin yapmıştır.

Bu sonuçlara ulařılırken yapılan birok test ile en doęru sonu elde edilmeye alıřılmıřtır. Yapılan uygulamalarda eęitimin ok fazla olması ya da yeteri kadar olmaması kt sonular doęurduęu gzlemlenmiřtir. Bunu iin zaman serisinin ve yapay sinir aęının yapısına uygun sayıda eęitim yaptırılmalıdır.

7. SONUÇLAR

Zaman serilerinin tahmininde, istatistiksel yöntemlere alternatif olarak yapay sinir ağlarının kullanılabileceği, hatta doğrusal olmayan zaman serilerinde yapay sinir ağlarının istatistiksel yöntemlere göre bazı avantajlar sağladığı bilinmektedir. Bu çalışmada, YSA ile zaman serilerini tahmin etmek için, genel bir trende sahip finansal bir veri olan altın fiyatları zaman serisi ve kaotik bir yapıya sahip Mackey-Glass kaotik zaman serisi kullanılmıştır.

Uygulamalarda, kısa ve uzun vadeye ilişkin tahmin gerçekleştirilmiştir. Kısa vadeli tahminlerde bir sonraki adımın tahmini gerçekleştirilirken, geçmiş üç ve altı veri YSA'ya giriş olarak verilmiştir. Uzun vadeli tahminlerde ise, geçmiş üç ve altı veri iki farklı şekilde YSA girişine uygulanmıştır. Bunlardan biri, geçmiş verilerin ardışık olarak seçilmesidir. Diğerinde ise geçmiş veriler tahmin edilecek adım sonrası kadar atlanarak seçilmiştir. Her iki seçim için uzun vadeli tahmin performansı ayrı ayrı incelenmiştir. Bununla birlikte, YSA'nın gizli katman hücre sayısındaki değişimin tahmin performansına etkisini görmek için, gizli katman hücre sayıları da kısa ve uzun vadeli tahminlerde değiştirilerek uygulamalar gerçekleştirilmiştir. Bu çalışmada, gizli katmandaki hücre sayıları, üç ve altı hücre şeklinde seçilerek elde edilen sonuçlar verilmiştir. Gerçekleştirilen farklı sayılardaki gizli katman hücreleriyle oluşturulan YSA yapıları ile benzer sonuçlar elde edilmiştir.

Altın fiyatları zaman serisinde, kısa dönem tahminlerin uzun dönem tahminlere göre daha başarılı olduğu gözlenirken, Mackey-Glass kaotik zaman serisinin tahmininde kısa dönem ile uzun dönem tahmin arasında belirgin bir fark gözlenmemiştir.

Bu çalışma göstermiştir ki, yapay sinir ağları mimarisi zaman serisinin türüne göre çeşitlilik göstermektedir. Katmanlarda kullanılan hücre sayısı ve eğitim süresi tahmini yapılacak zaman serisine uygun seçmek tahmin başarısını arttırdığı gösterilmiştir.

KAYNAKLAR

- [1] **Erdoğan, G.**, 2006. Yapay Sinir Ağları ile iktisadi ve finansal zaman dizilerinin kestirimi, Yüksek lisans tezi, Ankara.
- [2] **Zhang, G., Patuwo, B.E. ve Hu, Y.M.**, 1998. Forecasting with Artificial Neural Networks: *The State of the Art*, International Journal of Forecasting.
- [3] **Fırat, U.**, 2005. Yapay Sinir Ağı Kullanarak Deprem Eğiliminin Kestirimi, *Deprem Sempozyumu*, Kocaeli.
- [4] **Asilkan, Ö. ve Irmak, S.**, 2009. İkinci el otomobillerin gelecekteki fiyatlarının yapay sinir ağları ile tahmin edilmesi, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi 14, 375-391.
- [5] **Yıldız, Ö.**, 2006. Döviz Kuru Tahmininde Yapay Sinir Ağlarının Kullanımı, Yüksek lisans tezi, Eskişehir.
- [6] **Çuhadar, M.**, 2006. Turizm sektöründe talep tahmini için yapay sinir ağları kullanımı ve diğer yöntemlerle Karşılaştırmalı analizi (Antalya ilinin dış turizm talebinde uygulama), Doktora Tezi, S.D.Ü. Sosyal Bilimler Enstitüsü, Isparta.
- [7] **Kaym, H.**, 1985. İstatistiksel Ön Tahmin Yöntemleri, Hacettepe Ün. İİBF Yayınları, Ankara.
- [8] **Fretchling, D. C.**, 1996. Practical Tourism Forecasting, Oxford:Butterworth Heinemann.
- [9] **Sağiroğlu, S., Besdok, E., Erler, M.**, 2003. Mühendislikte yapay zeka uygulamaları 1:Yapay sinir ağları, Ufuk Yayıncılık, Kayseri.
- [10] **Şen, Z.**, 2004. Yapay Sinir Ağları İlkeleri, Su Vakfı, İstanbul.
- [11] **Yıldız, B.**, 2009. Finansal Analizde Yapay Zeka, Detay Yayıncılık, Ankara.
- [12] **Box, G.E.P. ve Jenkins. G.**, 1976. Time Series Analysis: *Forecasting and Control*, HoldenDay, Lancaster.
- [13] **Bircan,H. ve Karagöz, Y.**, 2003. Box-Jenkins Modelleri ile Aylık Döviz Kuru Tahmini Üzerine Bir Uygulama, Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi 2, 49-62.
- [14] **Saplıoğlu, K., ve Çimen, M.**, 2010. Yapay Sinir Ağlarını Kullanarak Günlük Yağış Miktarının Tahmini, Mühendislik Bilimleri ve Tasarım Dergisi Cilt:1 Sayı:1 14-21.
- [15] **Öztemel, E.**, 2003. Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul.

- [16] **Terzi, Ö. ve Keskin M.E.**, 2005. Yapay Sinir Ağı Yaklaşımı Kullanarak Günlük Tava Buharlaşması Tahmini, İMO Teknik Dergi, 3683 – 3693, Yazı 243
- [17] **Bolat, S. ve Kalenderli, Ö.** 2003. Yapay Sinir Ağı ile İzolatör Konum Açısı Optimizasyonu, Elektrik, Elektronik, Bilgisayar Mühendisliği 10. Ulusal **Kongresi**, s. 190, İstanbul.
- [18] **Kaynar, O.**, 2010. Ham Petrol Fiyatlarının Yapay Sinir Ağları İle Tahmini, Ege Akademik Bakış.
- [19] **Frank, R. J., Davey, N., Hunt, S. P.**, 1997., Time series prediction and Neural network, Neural Network World , 4(96):447-468.
- [20] **Bayır, F.**, 2006. Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama, Yüksek lisans tezi, İstanbul
- [21] **Elmas, Ç.**, 2003. Yapay Sinir Ağları, Seçkin Yayıncılık, Ankara, 21-39.
- [22] **Elmas, Ç.**, 2011. Yapay Zeka Uygulamaları Yapay Sinir Ağları – Bulanık Mantık– Genetik Algoritma, Seçkin Yayıncılık, Ankara.
- [23] **Kohzadi, N., Boyd, S. M., Kersmanhahi, B., Kaastra, L.**, 1996., A comparison of artificial neural network and time series models for forecasting commodity prices, Neurocomputing, 10:169-181.
- [24] **Hamzaçebi, C.**, 2005., Geleceği tahminde yapay sinir ağları için sezgisel öğrenme algoritması, Doktora Tezi, Gazi Üniversitesi, Ankara.
- [25] www.iab.gov.tr/Veriler/data/aaof.pdf, Altının Ağırlıklı Ortalama Fiyatları. 14.08.2011.
- [26] **Menase, M.**, 2009. Altın Piyasası ve Türkiye’de Altın Fiyatlarını Etkileyen Faktörlerin Analizi, Yüksek lisans tezi, İstanbul.

ÖZGEÇMİŞ

1984 yılında Karabük ilinde doğdu. İlköğretimini Eskipazar 100. Yıl Yatı ilköğretim Bölge Okulu'nda, liseyi Zonguldak Teknik ve E.M.Lisesi'nde tamamladı. 2001 yılında Kocaeli Üniversitesi T.E.F. Elektronik ve Bilgisayar Öğretmenliği Bölümü'nü kazandı. 2006 yılında Elektronik ve Bilgisayar Öğretmenliği Bölümü'nden mezun oldu. Aynı yıl endüstriyel otomasyon alanında eğitim almak için Almanya'ya gitti. 2009 yılında Fırat Üniversitesi T.E.F. Kontrol Sistemleri Ana Bilim Dalı'nda yüksek lisans eğitimine başladı. 2007 yılında bu yana Diyarbakır'da bilgisayar öğretmeni olarak çalışmaktadır.