

**ZAMAN SERİSİ ANALİZİNDE
ESNEK HESAPLAMA TEKNİKLERİ
(TÜRKİYE DIŞ TİCARET ÖRNEĞİ)**

Ferhan Demirkoparan

Cumhuriyet Üniversitesi
Sosyal Bilimler Enstitüsü

Lisansüstü Eğitim, Öğretim ve Sınav Yönetmeliğinin
İşletme Anabilim Dalı
Sayısal Yöntemler Bilim Dalı İçin Öngördüğü

YÜKSEK LİSANS TEZİ
Olarak Hazırlanmıştır.

Sivas
Haziran 2010

KABUL VE ONAY

Ferhan Demirkopran'ın hazırlamış olduđu "Zaman Serisi Analizinde Esnek Hesaplama Teknikleri (Türkiye Dış Ticaret Örneđi)" başlıklı bu çalışma, 14 Haziran 2010 tarihinde yapılan savunma sınavı sonucunda başarılı bulunarak jürimiz tarafından, "İşletme Anabilim Dalı, Sayısal Yöntemler Bilim Dalı"nda Yüksek Lisans Tezi olarak kabul edilmiştir.

İmza

Doç. Dr. Ziya Gökalg GÖKTOLGA

İmza

Yrd. Doç. Dr. Oğuz KAYNAR (Danışman)

İmza

Yrd. Doç. Dr. Mehmet Ali ALAN

Yukarıdaki imzaların adı geçen öğretim üyelerine ait olduğunu onaylarım./..../.....

İmza

Prof. Dr. Mehmet ARSLAN
Enstitü Müdürü

TEŐEKKÜR

Tez konusunun seçiminde ve çalışmalarımnda bana yol gösteren, destekleyen, her türlü yapıcı ve yönlendirici yardımlarını benden esirgemeyen tez danışmanım Yrd. Doç. Dr. Oğuz KAYNAR'a teşekkürlerimi sunmayı bir borç bilirim.

Ayrıca bütün Yüksek Lisans Programı süresince manevi destek ve sevgilerini bir an olsun benden eksik etmeyen sevgili ailem ve bölüm arkadaşlarıma sevgilerimi sunarım.

ÖZET

DEMİRKOPARAN, Ferhan,. Zaman Serisi Analizinde Esnek Hesaplama Teknikleri (Türkiye Dış Ticaret Örneği) Yüksek Lisans Tezi, Sivas, 2010.

Ülkelerin refah seviyelerinin artırılması ve sürekli kılınmasında dış ticaretin önemi ve gerekliliği önemini gittikçe arttırmaktadır. Türkiye'nin gelecek yüzyıla hazırlanması için, dünyanın bugün içinde bulunduğu ekonomik ve ticarî koşulların doğru bir resminin ortaya konulmasına ve gelecekle ilgili güvenilir tahminlere ihtiyaç vardır. Geleceğe ilişkin yapılacak doğru ve güvenilir tahminler, ekonominin sağlıklı bir şekilde gelişmesi ve istikrarı açısından gerekli planlamaların yapılmasına imkân verecektir.

Bu çalışmanın amacı Türkiye İstatistik Kurumu'ndan alınan 1969 ile 2009 yılları arası Türkiye'nin ithalat ve ihracat verileri üzerinde klasik zaman serisi analiz yöntemleri ile yapay sinir ağları ve uyarlamalı ağ tabanlı bulanık çıkarım sistemleri gibi esnek hesaplama tekniklerini karşılaştırmak ve doğru ve güvenilir dış ticaret tahminleri gerçekleştirmek üzere en iyi yöntemi belirlemektir. Tahmin sonucunda elde edilecek rakamlar sayesinde Türkiye ithalat ve ihracatının genel gelişimi ile ilgili belirsizlikler ortadan kalkacak ve bu rakamlara göre bir takım çıkarımlar yapılarak geleceğe ilişkin daha sağlıklı kararlar alınabilecektir.

Çalışmanın birinci bölümünde Türkiye dış ticaretinin dünü ve bugünü ve dış ticaretin Türkiye ekonomisindeki yeri ve öneminden bahsedilmiştir. İkinci bölümde istatistiksel zaman serisi analizi ve Box-Jenkins metodu, üçüncü bölümde yapay sinir ağları ve dördüncü bölümde bulanık mantık metodu ayrıntılı olarak incelenmiştir. Beşinci bölümde bu metotlar kullanılarak yapılan tahmin uygulaması ve sonuçlar, son bölümde de yapılan uygulamaya ilişkin değerlendirme ve öneriler yer almaktadır.

Anahtar Sözcükler

Zaman serisi analizi, dış ticaret, tahmin, MLP, RBF, ANFIS

ABSTRACT

DEMİRKOPARAN, Ferhan,. Soft Computing Techniques in Time Series Analysis (Turkey Foreign Trade) Master's Thesis, Sivas, 2010.

Foreign trade grows in importance and necessity in the way of increasing and making constant the prosperity level of countries. For Turkey, to get ready for the next century requires to be taken an accurate picture of economic and commercial conditions of the world and to make accurate predictions. Robust and reliable predictions allow making plans in the way of developing the economy and stabilization.

The objective of this study to compare classical time series analysis methods with soft computing techniques such as artificial neural networks and adaptive network based fuzzy inference systems on Turkey's import and export data between 1969 and 2009 obtained from Turkey Statistics Institution and to determine the best method to make correct and accurate foreign trade predictions. By the help of values obtained from the result of the prediction, uncertainty about general development of Turkey's foreign trade remove and by making deductions according to these numbers general situation can be examined.

In the first section of this study, it is mentioned about how the foreign trade of Turkey was in the past and how it is in this day and the importance and position of foreign trade in Turkish economy. Statistical time series analysis and Box-Jenkins method is examined in detail in the second section, artificial neural networks in the third section and fuzzy logic and neuro fuzzy system in the fourth section. Prediction application by using these methods and results are located in the fifth section and conclusion in the sixth section.

Keywords

Time series analysis, foreign trade, forecasting, MLP, RBF, ANFIS

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
İÇİNDEKİLER	iii
KISALTMALAR LİSTESİ	vi
SİMGELER LİSTESİ	viii
TABLolar LİSTESİ	ix
ŞEKİLLER LİSTESİ	x
GİRİŞ	1
1. TÜRKİYE'DE DIŞ TİCARET	5
1.1. 1980 ÖNCESİ DÖNEM	5
1.2. 1980 SONRASI DÖNEM	7
1.3. DIŞ TİCARETİN TÜRKİYE EKONOMİSİNDEKİ YERİ VE ÖNEMİ	8
2. ZAMAN SERİLERİ	10
2.1. GİRİŞ	10
2.2. ZAMAN SERİSİ ÇEŞİTLERİ	10
2.3. ZAMAN SERİSİ BİLEŞENLERİ	11
2.4. DURAĞANLIK	11
2.5. BOX-JENKINS YÖNTEMİ	12
2.5.1. Giriş	12
2.5.2. Box-Jenkins Yönteminin Aşamaları	13
2.5.2.1. Belirleme (Identification)	15
2.5.2.1.1. ACF (Otokorelasyon Fonksiyonu)	15
2.5.2.1.2. PACF (Kısmi Otokorelasyon Fonksiyonu)	16
2.5.2.2. Parametre Tahminleri (Parameter Estimations)	17
2.5.2.3. Uygunluk Testleri (Diagnostic Checking)	17
2.5.2.3.1. Model Seçim Kriterleri	18
2.5.2.3.1.1. Standart Belirlenim Katsayısı $-R^2$	19
2.5.2.3.1.2. F İstatistiği Yaklaşımı	19
2.5.2.3.1.3. Akaike Bilgi Kriteri (AIC)	20
2.5.2.3.1.4. Schwarz Bilgi Kriteri (SIC)	20
2.5.2.4. Öngörü (Forecasting)	21
2.6. ZAMAN SERİSİ SÜREÇLERİ	21
2.6.1. Stokastik Süreçler	21
2.6.1.1. Durağan Stokastik Süreçler	21

2.6.1.1.1.	Otoregresif Süreçler (AR(p)).....	21
2.6.1.1.2.	Hareketli Ortalama Süreci (MA(q)).....	25
2.6.1.1.3.	Karma Otoregresif - Hareketli Ortalama Süreci (ARMA(p,q)).....	27
2.6.1.2.	Durağan Olmayan Stokastik Süreçler.....	29
2.6.1.2.1.	Birleştirilmiş Otoregresif Hareketli Ortalama Modelleri (ARIMA(p,d,q)).....	30
2.6.1.2.2.	Mevsimsel ARIMA Modelleri (SARIMA(p,q)).....	31
3.	YAPAY SİNİR AĞLARI.....	33
3.1.	GİRİŞ.....	33
3.2.	TEMEL KAVRAMLAR.....	34
3.2.1.	Yapay Sinir Hücresi (İşlem Elemanı).....	35
3.2.2.	Basit Algılayıcı Modeli (Perseptron).....	38
3.3.	YAPAY SİNİR AĞLARININ ÖZELLİKLERİ.....	39
3.4.	YAPAY SİNİR AĞLARININ SINIFLANDIRILMASI.....	40
3.4.1.	Mimariye Göre	40
3.4.1.1.	İleri Beslemeli Yapay Sinir Ağları	40
3.4.1.1.1.	MLP (Multi Layer Perseptron- Çok Katmanlı Algılayıcı) ..	41
3.4.1.1.2.	RBFN (Radial Basis Function Networks - Radyal Tabanlı Fonksiyon Ağları).....	43
3.4.1.1.3.	MLP ve RBF Ağlarının Karşılaştırılması	46
3.4.1.2.	Geri Beslemeli Yapay Sinir Ağları.....	47
3.4.2.	Öğrenme Yöntemlerine Göre	48
3.4.2.1.	Yapay Sinir Ağlarında Öğrenme	48
3.4.2.2.	Danışmanlı Öğrenme	49
3.4.2.2.1.	Geriye Yayılım (Backpropagation) Algoritması	50
3.4.2.3.	Danışmansız Öğrenme.....	52
3.4.2.4.	Takviyeli Öğrenme	53
3.5.	YAPAY SİNİR AĞLARININ ZAMAN SERİSİNDE KULLANIMI... 53	
3.5.1.	Ağ Yapısını Belirleme	55
3.5.2.	Giriş Düğüm Sayısını Belirleme.....	55
3.5.3.	Gizli Katman ve Bu Katmandaki Dğümlerin Sayısını Belirleme....	56
3.5.4.	Çıkış Dğümlerinin Sayısını Belirleme.....	56
3.5.5.	Aktivasyon Fonksiyonunu Belirleme	57
3.5.6.	Veri Normalizasyonu.....	57
3.5.7.	Öğrenme ve Test Kümesi	59
3.5.8.	Öğrenme Algoritmasının Belirlenmesi.....	59
3.5.9.	Performans Kriterleri.....	59

4.	BULANIK MANTIK.....	61
4.1.	BULANIK KÜMELER VE ÜYELİK FONKSİYONLARI.....	62
4.2.	BULANIK KURAL TABANI.....	62
4.3.	BULANIK ÇIKARIM SİSTEMLERİ.....	63
4.4.	ANFIS (UYARLAMALI AĞ TABANLI BULANIK ÇIKARIM SİSTEMLERİ).....	64
4.5.	ANFIS AĞINDA KULLANILAN HİBRİD ÖĞRENME ALGORİTMASI.....	67
5.	UYGULAMA VE SONUÇLAR.....	70
5.1.	MEVSİMSEL ARIMA İLE YAPILAN TAHMİN UYGULAMASI....	70
5.2.	ESNEK HESAPLAMA TEKNİKLERİ İLE YAPILAN TAHMİN UYGULAMASI.....	77
5.3.	BULGULAR.....	81
6.	DEĞERLENDİRME VE SONUÇ.....	86
	KAYNAKÇA.....	88

KISALTMALAR LİSTESİ

- ACF : Autocorrelation Funciton (Otokorelasyon Fonksiyonu)
- AIC : Akaike Information Criteria (Akaike Bilgi Kriteri)
- ANFIS : Adaptive Network Based Fuzzy Inference System (Uyarlanabilir Ağ Tabanlı Bulanık Çıkarım Sistemi)
- AR : Autoregressive Model (Oto regresif Model)
- ARIMA : Autoregressive Integrated Moving Average (Birleştirilmiş Oto regresif Hareketli Ortalama)
- ARMA : Autoregressive Moving Average (Oto regresif Hareketli Ortalama)
- BIC : Bayesian Information Criteria (Bayes ya da Schwarz Bilgi Kriteri – SIC)
- FIS : Fuzzy Infernce System (Bulanık Çıkarım Sistemi)
- LMS : Least Mean Square (En Küçük Kareler)
- LVQ : Learning Vector Quantization
- MA : Moving Average Model (Hareketli Ortalama Modeli)
- MAD : Mean Absolute Deviation (Ortalama Mutlak Sapma)
- MAPE : Mean Absolue Percentage Error (Mutlak Ortalama Yüzde Hata)
- MLP : Multi Layer Perceptron (Çok Katmanlı Algılayıcı)
- MSE : Mean Square Error (Ortalama Kare Hata)
- PACF : Partial Autocorrelation Function (Kısmi Otokorelasyon Fonksiyonu)

RBFB : Radial Basis Function (Radyal Tabanlı Fonksiyon)

RMSE : Root Mean Square Error (Ortalama Kare Hata Kökü)

SARIMA : Seasonal ARIMA (Mevsimsel ARIMA)

SSE : Sum Square Error (Toplam Kare Hata)

YSA : Yapay Sinir Ağları

SİMGELER LİSTESİ

μ	: Ortalama
σ^2	: Varyans
γ	: Kovaryans
ρ	: Otokorelasyon
Φ	: Korelasyon katsayısı
n	: Örneklem Büyüklüğü
m	: Serbestlik Derecesi
p	: Önem Seviyesi
R^2	: Standart Belirlenim Katsayısı
δ	: AR Süreci Kesme Terimi
ϕ	: Bilinmeyen AR Parametresi
ε_t	: Hata Terimi
θ	: Bilinmeyen MA Parametresi
Θ	: Mevsimsel MA Parametresi
Φ	: Mevsimsel AR Parametresi

TABLOLAR LİSTESİ

Tablo 1. ACF ve PACF'nin teorik davranışları	17
Tablo 2. Biyolojik sinir ağı ile yapay sinir ağının karşılaştırılması	36
Tablo 3. Toplama fonksiyonu örnekleri.....	37
Tablo 4. Aktivasyon fonksiyonu örnekleri.....	38
Tablo 5. Aşırı değerler alan tasarım parametrelerinin ağıın yakınsama ve genelleme yeteneği üzerindeki etkileri.....	54
Tablo 6. Yapay sinir ağları uygulama alanları	55
Tablo 7. İhracat serisi için ADF test istatistikleri.....	73
Tablo 8. İthalat serisi için ADF test istatistikleri	73
Tablo 9. Birinci dereceden ve mevsimsel fark alınmış ihracat serisi için ADF test istatistikleri.....	74
Tablo 10. Birinci dereceden ve mevsimsel fark alınmış ithalat serisi için ADF test istatistikleri.....	74
Tablo 11. İhracat serisi için oluşturulan ARIMA modelleri	75
Tablo 12. İthalat serisi için oluşturulan ARIMA modelleri	75
Tablo 13. ARIMA(1,1,3)(1,1,1) ₁₂ modeli ve istatistikleri	75
Tablo 14. ARIMA(0,1,1)(1,1,1) ₁₂ modeli ve istatistikleri	75
Tablo 15. İhracat serisi için oluşturulan bazı MLP modelleri ve performans kriterleri	78
Tablo 16. İthalat serisi için oluşturulan bazı MLP modelleri ve performans kriterleri	79
Tablo 17. İhracat serisi için oluşturulan bazı RBF modelleri ve performans kriterleri	79
Tablo 18. İhracat serisi için oluşturulan bazı RBF modelleri ve performans kriterleri	80
Tablo 19. İhracat serisi için ANFIS modelleri ve performans kriterleri	81
Tablo 20. İhracat serisi için ANFIS modelleri ve performans kriterleri	81
Tablo 21. İhracat serisi için gözlenen ve tahmin edilen değerler	82
Tablo 22. İthalat serisi için gözlenen ve tahmin edilen değerler.....	83

ŞEKİLLER LİSTESİ

Şekil 1. Box-Jenkins Yaklaşımı.....	14
Şekil 2. Alternatif ϕ_1 değerleri için $Y_t = \phi_1 Y_{t-1} + \varepsilon_t$ AR(1) süreci	23
Şekil 3. AR(1) Süreci için ACF ve PACF Grafikleri	24
Şekil 4. MA(1) Süreci için ACF ve PACF Grafikleri	27
Şekil 9. ARMA(1,1) Süreci için ACF ve PACF Grafikleri.....	29
Şekil 6. Biyolojik Sinir Hücresi.....	34
Şekil 7. Bir sinir hücresinin başlıca elemanları	35
Şekil 8. Yapay bir sinir (düğüm)	36
Şekil 9. Basit Algılayıcı Modeli (Perseptron).....	38
Şekil 10. MLP Yapay Sinir Ağı.....	42
Şekil 11. RBF Yapay Sinir Ağı	43
Şekil 12. Geri Beslemeli Yapay Sinir Ağı.....	47
Şekil 13. Öğrenme Yöntemleri.....	49
Şekil 14. Danışmanlı Öğrenme.....	50
Şekil 15. Danışmansız Öğrenme	53
Şekil 16. Bulanık Alt kümeler	62
Şekil 17. Bulanık Sistemin Yapısı.....	64
Şekil 18. ANFIS Mimarisi.....	65
Şekil 19. Türkiye ihracat rakamları grafiği	70
Şekil 20. Türkiye ithalat rakamları grafiği	71
Şekil 21. İhracat serisi korelasyon tablosu	72
Şekil 22. İthalat serisi korelasyon tablosu	72
Şekil 23. İhracat serisi kalıntıları korelasyon tablosu (Q istatistikleri).....	76
Şekil 24. İthalat serisi kalıntıları korelasyon tablosu (Q istatistikleri)	77
Şekil 25. İhracat serisi gözlenen ve tahmin edilen değerler grafiği.....	85
Şekil 26. İthalat serisi gözlenen ve tahmin edilen değerler grafiği.....	85

GİRİŞ

Son yıllarda çeşitli tahmin metotlarının gelişmesi ile birlikte tahmin uygulamaları çok daha popüler hale gelmiştir. Tahmin etkili ve verimli planlamanın en önemli unsurudur. Dünyada gelişim ve değişim olduğu sürece tahminlere her zaman ihtiyaç duyulacaktır. Çünkü bilinmezliklerden oluşan gelecekte ortaya çıkabilecek durumlara karşı önceden hazırlıklı olabilmek için planlama yapmak şarttır. Çeşitli tahmin metotları kullanılarak yapılan tahminler her türlü planlama, strateji geliştirme, politika oluşturma, programlama, satın alma, yatırım ve pek çok karar verme faaliyeti için girdi olarak kullanılmaktadır.

Yapay sinir ağları (YSA) ve bulanık çıkarım sistemleri gibi son yıllarda gelişen ve son derece popülerlik kazanan tahmin metotları, klasik istatistiksel zaman serisi analizi metotlarına güçlü bir alternatif oluşturmaktadır. Bu metotlar işletme, ekonomi ve finans, ekonometri, hidroloji, meteoroloji, mühendislik ve tıp gibi pek çok farklı sahada uygulama alanı bulmakta ve sınıflandırma ve gizli örüntüleri yakalama gibi amaçlarla kullanılmaktadır. Bu konu ile ilgili literatür incelendiğinde çok çeşitli çalışmalara rastlanmaktadır.

Zhang ve Hu İngiliz Sterlini ve Amerikan Doları döviz kurunu tahmin ettikleri çalışmalarında giriş katmanı ve gizli katmanın tahmin performansına katkısını değerlendirerek giriş nodu sayısının performansta oldukça etkili olduğunu ve YSA yönteminin lineer metotlardan daha başarılı sonuçlar verdiğini belirtmişlerdir (Zhang ve Hu, 1998). Yine bir başka çalışmalarında Zhang, Patuwo ve Hu YSA ile zaman serisi tahminindeki en önemli üç faktör olan giriş nodları, gizli katman düğümleri ve örnek büyüklüğünü inceleyerek, giriş nodu sayısının gizli katman nodu sayısından çok daha önemli olduğunu ve yakınsama problemini çözmeye örnek büyüklüğünün fazla olmasının etkili olduğunu belirtmişlerdir (Zhang, Patuwo ve Hu, 2001). Kuo, Chen ve Huang hisse senedi alım satımı için zeki bir karar destek sistemi olarak kullanılacak bir genetik algoritma tabanlı bulanık sinir ağı yaklaşımı önermişler ve bu modeli Tayvan menkul kıymetler borsası verilerine uygulayarak başarılı sonuçlar elde etmişlerdir (Kuo, Chen ve Huang, 2001). Fish vd.

bir kahve dükkânındaki müşteri tercihlerini ve marka paylaşımını modellemek için genetik algoritma ile eğitilmiş bir YSA mimarisi önermiş ve önerdikleri modelin MNL (multinomial logit) ve standart backpropagation algoritması ile eğitilen ağa göre daha iyi olduğunu belirtmişlerdir (Fish vd., 2004). Efendigil, Önüt ve Kahraman İstanbul'daki bir işletmenin verilerinden yararlanarak talep tahmini yaptıkları çalışmalarında uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS) ve YSA modellerini içeren bir yapay zekâ yaklaşımı önermişlerdir (Efendigil, Önüt ve Kahraman, 2009). Zhang vd. 220 firmanın eşlenmiş verilerini kullanarak sinir ağlarının iflas tahmin performansını değerlendirerek sinir ağlarının hem sınıflandırma oranı hem de klasik tahminde lojistik regresyon modellerinden iyi olduğunu belirtmişlerdir (Zhang, 1999). Kuo satış tahmini yaptığı çalışmasında başlangıç ağırlıkları genetik algoritma ile belirlenen bulanık sinir ağı önermiştir (Kuo, 2001). Hamzaçebi YSA'nın yakınsama kabiliyeti, tahmin yaklaşımı ve mevsimsel ARIMA (SARIMA)'nın mevsimsellik parametresinden esinlenerek SANN (mevsimsel YSA) adını verdiği bir model önermiş ve bu modelin mevsimsel özellik gösteren serilerin tahmininde standart YSA ve SARIMA'dan daha başarılı olduğunu belirtmiştir (Hamzaçebi, 2008). Thirumalaiah ve Deo ise Jedgalpur bölgesindeki su seviyelerini tahmin ettikleri çalışmalarında üç farklı algoritma ile eğittikleri YSA modellerini karşılaştırmışlardır (Thirumalaiah ve Deo, 1998). Kaynar, Taştan ve Demirkoparan ise Türkiye ham petrol fiyatlarını tahminleyerek MLP ve RBF yapay sinir ağlarının ARIMA metoduna göre daha iyi tahmin performansına sahip olduğunu belirtmişlerdir (Kaynar, Taştan ve Demirkoparan, 2010).

Ekonomik tahminleme son yıllarda tahmin uygulamaları içinde önemli yer edinmektedir. Beklenen gelecek ekonomik gelişmeler hem özel hem de genel anlamda her gün tartışılmaktadır. Ekonomik açıdan risk taşıyan haberler her an finansal pazarları gerginliğe sürükleyebilmektedir. Ekonomik beklentilerin değerlendirilmesi artık ekonomi politikalarının oluşum mekanizmalarının vazgeçilmez bir bileşeni olarak görülmektedir.

Türkiye'nin de, gerek işadamları gerek bürokratları ile gelecek yüzyıla

hazırlanması, dünyanın bugün içinde bulunduğu ekonomik ve ticarî koşulların doğru bir resminin ortaya konulmasını gerektirmektedir.

Literatür incelendiğinde dış ticaret verileri kullanılarak yapılan tahmin çalışmalarının oldukça sınırlı sayıda olduğu görülmektedir. Eğrioğlu, Aladağ ve Günay Türkiye'nin dış ticaret rakamlarını kullandıkları çalışmalarında ileri beslemeli yapay sinir ağlarında ağ mimarisini belirlemede kullanılan model seçim kriterlerini inceleyerek yeni bir model seçim kriteri önermişler ve bu seçim kriterinin bilinenlere oranla daha güvenilir sonuçlar verdiğini belirtmişlerdir. (Eğrioğlu, Aladağ ve Günay, 2008). Hatırlı, Demircan ve Aktaş çalışmalarında ayçiçek ve soya yağı ithalatını “görünüşte ilişkisiz regresyonlar” yöntemi ile analiz etmişler (Hatırlı, Demircan ve Aktaş, 2002); Gusev ve Shirov ise Rus dış ticareti için Rus Bilim Akademisi Ekonomik Tahmin Enstitüsü tarafından geliştirilen bir tahmin modelini kullanarak dünya petrol fiyatları ile Rus dış ticaretinin karşılaştırmalı analizini yapmışlardır (Gusev ve Shirov, 2009). Co ve Boosarawongse Tayland'ın pirinç ihracatını tahmin ettikleri çalışmalarında yapay sinir ağları ile üstel düzleştirme ve ARIMA modellerinin tahmin performanslarını karşılaştırmış ve YSA'nın dinamik, doğrusal olmayan ve mevsimsel yapıyı ve aralarındaki ilişkiyi modellemede oldukça iyi performans gösterdiğini belirtmişlerdir (Co ve Boosarawongse, 2007). Mehrara vd. GMDH tabanlı yapay sinir ağları ve bazı etken değişkenleri kullanarak İran'ın petrol haricindeki ihracatının büyüme oranına etkilerini inceleyerek bir model oluşturmuşlardır (Mehrara vd., 2008). Xiao, Gang ve Zou tahmin hassasiyetini bulanık üyelik fonksiyonu kriteri olarak kullandıkları çalışmalarında bulanık küme tabanlı hibrit bir yaklaşım önermiş ve Çin Changqing Belediyesi'nin 1993-2006 arası uluslar arası ticaret verilerini kullanmışlardır. Yaptıkları uygulama sonucunda hibrit modelin tahmin performansını arttırdığını belirtmişlerdir (Xiao, Gang ve Zou, 2009). Edwards, Abraham ve Lazarevic ise Malezya'daki çok uluslu ticari şirket iştiraklerinin karmaşık ihracat davranışlarını Takagi-Sugeno bulanık çıkarım sistemini kullanarak modellemişlerdir. Sistemi sinir ağı öğrenmesi ve evrimsel hesaplama ile optimize etmişler ve önerdikleri modelin klasik sinir ağı yaklaşımından daha iyi olduğunu belirtmişlerdir (Edwards, Abraham ve Lazarevic, 2005). Yu, Wang ve Lai Çin'in dış ticaretini tahminledikleri çalışmalarında doğrusal

olmayan ekonometrik model ile YSA'yı birleştiren hibrit bir model önermişler; ekonomik değişkenlerin etkisini eş bütünleşme tabanlı hata düzeltme vektör otoregresyon modeli (EC-VAR) ile, ekonomik faktörler ve dış ticaret arasındaki doğrusal olmayan ilişkiyi YSA tabanlı EC-VAR modeli ile, dış ticaretteki beklenmedik etkileri ise bu modelle metin madenciliği (text mining) ve uzman eleştirel ayarlama (expert's judgemental adjustment) yaklaşımlarının birleşimi ile modellemişlerdir (Yu, Wang ve Lai, 2007). Bu konu ile ilgili iki adet yüksek lisans tez çalışması bulunmaktadır. Bunlardan ilki Sevim'in naive, üstel düzeltme ve ARIMA (Auto Regressive Integrated Moving Average) metotlarını kullanarak yaptığı kısa dönem dış ticaret tahmini uygulamasıdır (Sevim, 2006). Şentın ise tez çalışmasında regresyon, üstel düzeltme, eğilim analizi, hareketli ortalama ve ARIMA metotları ile Türkiye cam ve cam ürünleri dış ticaret rakamlarını enflasyon etkisinden arındırarak uzun dönemli tahmin uygulaması yapmıştır (Şentın, 2006).

Bu tez çalışmasında klasik zaman serisi analizi, yapay sinir ağları ve bulanık çıkarım sistemleri metotları yardımıyla Türkiye İstatistik Kurumu'ndan alınan Türkiye'nin 1969 – 2009 yılları arası dış ticaret verileri kullanılarak bir tahmin uygulaması yapılmıştır.

Çalışmanın birinci bölümünde Türkiye dış ticaretinin dünü ve bugünü ve dış ticaretin Türkiye ekonomisindeki yeri ve öneminden bahsedilmiştir. İkinci bölümde istatistiksel zaman serisi analizi ve Box-Jenkins metodu, üçüncü bölümde yapay sinir ağları ve dördüncü bölümde bulanık mantık ve sinirsel bulanık mantık metodu incelenmiştir. Beşinci bölümde bu metotlar kullanılarak yapılan tahmin uygulaması ve son bölümde de elde edilen sonuçlar ve değerlendirme yer almaktadır.

1. TÜRKİYE’DE DIŞ TİCARET

Ülkelerin refah seviyelerinin artırılması ve sürekli kılınmasında dış ticaretin önemi ve gerekliliği önemini gittikçe arttırmaktadır. Dünyada özellikle 1990’lı yılların ikinci yarısından sonra hız kazanan küreselleşme ve rekabet koşulları, bu koşullara uyum sağlayabilen ülkelere önemli fırsatlar oluşturabilmektedir. Türkiye’de de 1980 sonrası dönemde dışa açık ekonomi politikaları uygulanmaya başlanmış olup, bu yöndeki politikaların uygulanması 1990’lı ve 2000’li yıllarla birlikte daha da derinleştirilmiştir. Ülkede dışa açık ekonomik politikaların takip edilmesi, firmaların süregelen bu değişikliklere ve artan rekabete uyum sağlamaları, daha elverişli fırsatlardan yararlanmak için dışa açılmaları, teknolojik açıdan kendilerini geliştirmeleri vb. değişimlerin ortaya çıkmasında etkili olmaktadır (Bozoğlu).

Türkiye’nin mevcut doğal, beşeri ve sermaye kaynaklarının daha etkin kullanılması, daha hızlı ve sürdürülebilir kalkınmanın sağlanabilmesi bakımından ülkenin dış ticaretinin ve özellikle ihracatının daha da fazla artırılması büyük önemi arz etmektedir. Ülkeler arasındaki ticaretin gelişmesinde; doğal (coğrafi durum, iklim, toprak ve doğal kaynaklar gibi) faktörler ve sosyal (ırk özellikleri, yetenekler, kültür, iş başarı dereceleri gibi) faktörlere bağlı olarak ülkelerin uzmanlaşması, üretim, ulaştırma ve haberleşme teknolojilerinde yaşanan gelişmeler, uluslararası ticaretin serbestleşmesi konusunda yapılan anlaşmalar, nüfus artışı ve hareketleri gibi faktörlerin etkisi bulunmaktadır (Bozoğlu).

1.1. 1980 ÖNCESİ DÖNEM

Dış ticaretimiz 1925 yılına kadar hızlı bir artış göstermiş Cumhuriyetin ilk sekiz yılında ticaret dengesi devamlı açık vermiştir. Dış ticaretimizi, ekonomik gelişmemizi destekleyecek şekilde denetim altına almamızı sağlayacak önlemlerden biri olan gümrük tarifelerinin koruyucu bir nitelik kazandığı 1929 yılı aynı zamanda, dünya ekonomilerinin büyük sıkıntılar geçirmesine yol açan 1929 – 1930 Dünya Ekonomik Bunalımının başlangıç yılıdır. Ticaret dengesinin 1938 yılı hariç, 1930 – 1939 arasında fazla verdiği bu dönemde, toplam dış ticaret değerinin en düşük

olduğu yıl 1933 yılıdır. Dış ticaretimizin olumsuz yönde etkilenmesinin sebebi, bunalımın etkisinden Türkiye'nin uzak kalamaması, bu sıkıntılı dönemi daha az zararla atlattık için hükümetlerin aldığı önlemler ve bunların en önemlisi olan, 1930 yılında Türkiye'de kambiyo denetiminin kurulmasıdır (Serin, 2001, s.307).

İkinci dünya savaşının başladığı 1939 yılından, sona erdiği 1945 yılına kadar, diğer ülkelerde olduğu gibi Türkiye'de de dış ticaret büyük güçlüklerle yürütülmüştür. 1948 yılından itibaren Türkiye'de uygulanmaya başlanan ve 1950 yılında iktidar değişikliği ile birlikte liberalleşen ekonomi politikalarının sonucu olarak, 1950 yılından itibaren ithalat fazlası devamlı olarak büyümüş, 1950 – 1953 arasında dünya ekonomik ve siyasi konjonktürünün olumlu etkileri Türkiye'nin dış ticaret hadlerini düzeltmiştir. Bu dönemde izlenen aşırı liberal ekonomi politikasının sonucu olarak ithal mallara olan talebin hızla büyümesi, varolan altın ve döviz rezervinin hızla erimesi ve ihracatta başlayan daralma, dış kredilerin de gittikçe büyüyen ödemeler dengesi açığını kapayamaması, dış ticarete liberasyon sisteminin fiilen 22 Eylül 1952'de, resmen 20 Nisan 1953'te terkedilmesine ve ithalatı kısıtlayıcı önlemler alınmasına yol açmıştır (Serin, 2001, s.307).

1950 – 1960 döneminde izlenen politikalar Türkiye'nin gereklerine ters düşmüş, bu dönemde paramızın iç ve dış değerinde düşme başlamış buna rağmen sabit kur sistemi ihracatı azaltmış, ithalatı aşırı kazançlı hale getirmiş ve kaynak israfına yol açmıştır. Bu durum karşısında hükümet iç ve dış ekonomik istikrarı sağlamak amacıyla 4 Ağustos 1958 tarihinde önlem alma yoluna gitmiş ve dış ticaret politikası yeni baştan düzenlenmiştir.

1959 – 1961 döneminde kambiyo denetiminin hafifletilmesi cari işlemler dengesinde açığın büyümesine yol açmıştır. Planlı kalkınma döneminde (1963'ten sonra) sistematik ve tutarlı bir çözüm yolu bulunmaya çalışılmış on beş yıl sonunda dış ödeme dengesinin sağlanması hedeflenmiştir. Döviz kuru politikası açısından 10 Ağustos 1970 tarihinde yeni ve devalüasyon yapılmış, bazı ihraç malları ve bazı işlemlerle ilgili olarak farklı kurlar belirlenmiştir. OPEC'in ham petrol fiyatlarını 1974 yılında büyük oranda artırması ve Türkiye'nin ekonomik ilişkilerinde önemli yeri olan ülkelerde görülen durgunluk ekonomimizin bir bunalım dönemine

girmesine ve ikinci petrol şokundan (1978) sonra ihracatımızın ancak petrol faturasını karşılayabilir bir düzeyde kalması, dış kredi bulmaktaki güçlükler nedeniyle ithalatta karşılaşılan sıkıntılar, özellikle 1978 – 1979 döneminde, tam bir ekonomik bunalım yaşanmasına yol açmış, bu arada paramız 1978 ve 1979 yıllarında iki kere devalüe edilmiştir (Serin, 2001, s.308).

Bu gelişmelerin sonucunda yeni bir istikrar politikasının yürürlüğe konulması gündeme gelmiş ve 24 Ocak 1980 kararları alınmıştır.

1.2. 1980 SONRASI DÖNEM

24 Ocak 1980 kararları Türkiye'nin dış ticareti açısından bir dönüm noktası olmuştur. 24 Ocak kararlarının en önemli özelliği Türkiye ekonomisinin dışa açılmasını hızlandıran bütünleşmiş bir sistem haline dönüşmesi gereğini ve sanayinin ve hatta tarımın yaşamak ve gelişmek için ihracata yönelmesinin zorunlu olduğunu açık bir biçimde vurgulaması ve bunu da büyük ölçüde gerçekleştirmiş olmasıdır (Serin, 2001, s.308)

24 Ocak kararları kısa dönemde istikrar sağlama, uzun dönemde ise ekonomide yapısal bir değişim gerçekleştirmek üzere yürürlüğe konmuştur. İthalatın serbestleştirilmesi, ihracatın teşviki yönünde düzenlemeler yapılmış, kur politikasında önemli değişikliklere gidilerek TL'nin değeri düşürülmüştür (Ege, 1998).

Türkiye, uluslar arası ticareti düzenleyen ve dünya ticaretinin geliştirilmesinde önemli rolü olan Gümrük Tarifeleri ve Ticaret Genel Anlaşması'na 21.12.1953 tarihinde katılmıştır. Uruguay görüşmeleri sonucunda kabul edilen Nihai Senet çerçevesinde imzalanan ve Dış Ticaret Örgütü'nü kuran Marakeş Anlaşması, Türkiye Büyük Millet Meclisi'nde 31 Aralık 1994 tarihinden itibaren geçerli olmak üzere, 25 Şubat 1995 tarihinde onaylanmıştır. Böylece Türkiye; tekstil ve hazır giyim, hizmetler sektörü, tarım sektörü ve fikri ve sınaî mülkiyet haklarına ilişkin GATT Uruguay görüşmeleri sonucunda getirilen yeni düzenlemeleri de kabul

etmiştir. Tüm bu gelişmeler sonucunda Türkiye'nin ihracat ve ithalat büyüklükleri, dış ticaret hacminin GSMH'ya oranı büyük ölçüde artmıştır (Türker, 2007, s.176).

1 Ocak 1996 tarihinde Türkiye, AB (Avrupa Birliği) ile Gümrük Birliği sürecine girmiştir. Böylece Türkiye, AB ve EFTA (Avrupa Serbest Ticaret Topluluğu) ülkeleri menşeli mallardan alınan tüm vergiler ve TKF (Toplu Konut Fonu) ücretleriyle, miktar kısıtlamalarını iptal etmeyi ve üçüncü ülkelere ortak gümrük tarifelerini uygulamayı kabul etmiştir.

1997 yılının ikinci yarısında Asya'da ortaya çıkan mali kriz ihracatı olumsuz yönde etkilemiş, küresel krizin 1998 yılı Ağustos ayında Rusya'ya sıçraması ihracat artışını engellemiştir. 1999 yılında yaşanan depremin de etkisi ile 1989 yılından itibaren artış gösteren ihracat 26,6 milyar dolara gerilemiştir. 2001 yılında yaşanan ekonomik kriz ile ortaya çıkan olumsuz gelişmeler 2002 yılında hızlanarak devam etmiş, işsizlik artmış ve iç talep yetersizliği nedeniyle firmaların dış pazarlara yönelmeleri sonucu ihracatta artış yaşanmıştır (Türker, 2007, s.180).

1.3. DIŞ TİCARETİN TÜRKİYE EKONOMİSİNDEKİ YERİ VE ÖNEMİ

Dış ticaretin bir ülke ekonomisindeki yerini değerlendirmek için başvurulabilecek birkaç ölçüt bulunmaktadır. Bunlardan birincisi ihracat ve ithalatın veya bunların toplamı olan dış ticaret hacminin GSMH'ya oranlarıdır. Bu oranlarda zaman içinde meydana gelen değişmelerin incelenmesi ve bu oranların başka ülkelere ait oranlarla karşılaştırılması ülkede dış ticaretin yerini değerlendirmek imkânı verecektir. Bir ülkede dış ticaretin önemini tartmak için kişi başına ihracat ve ithalat değerlerine ve/veya sınaî ürünler ihracatının toplam ihracata oranına bakılabilir. Ayrıca ülkenin dünya dış ticaret hacmindeki payı başka ülkelerin payları ile karşılaştırılabilir. Tüm bu oran ve ortalamaların incelenmesi ülkede dış ticaret sektörünün önemini ve ülkenin ne derece dışa açık olduğunu ve küreselleşmeye katıldığını gösterecektir. Günümüzde ülkenin dışarı ile ekonomik ilişkilerinin yoğunluğunu değerlendirmek için sadece mal dış ticareti ile ilgili oran ve ilişkiler ile

yetinilmeyip, yabancı özel sermaye yatırımları, ülkenin dış alemdeki yatırımları, kurumsal yatırımlar bakımından kredilibite sıralaması, turizm gelir ve giderleri de değerlendirmeye alınabilir (Şahin, 2006, s.382).

Özellikle gelişme ve kalkınma süreci içinde olan bir ülkede dış ticaretin iki önemli rolü vardır. Bunlardan birincisi, özellikle kısa dönemde önemli olup, ekonomik gelişme çabalarının gerektirdiği, ithalatı gecikmelere yol açmaksızın karşılama, yani dış ödeme gücünü temin etmektir. İkincisi ise daha uzun dönemli bir sorun olup, dış ticaretin ekonomik yapıdaki köklü değişikliğe uygun olarak yeniden şekillenmesi veya başka bir deyişle, dış ticaretin uluslar arası iş bölümünü uyararak ekonomideki kaynak dağılımını olumlu yönde etkilemektir (Serin, 2001, s.306)

2. ZAMAN SERİLERİ

2.1. GİRİŞ

Son yıllarda hızla gelişen zaman serileri analizi genellikle geleceği öngörmeye yönelik olarak kullanılmaktadır. Bir zaman serisi bir değişkenin zaman içindeki hareketini gözlemleyen sıralı gözlemler dizisi olarak tanımlanabilir (Bozkurt, 2007, s.7; Wei, 2006, s.1). Zaman serisi verileri günlük, haftalık, aylık, üç aylık, yıllık veya daha uzun aralıklı dönemler şeklinde derlenebilir. Zaman serileri gerek bilimsel amaçlı gerekse farklı amaçlarla ekonomi, mühendislik, sağlık, eğitim gibi pekçok farklı alanda kullanılmaktadır. Özellikle istatistiksel ve ekonometrik çalışmalarda zaman serilerine oldukça fazla ihtiyaç duyulmaktadır (Sevüktekin ve Nargeleçekenler, 2007).

2.2. ZAMAN SERİSİ ÇEŞİTLERİ

Elektrik sinyali veya voltajı gibi zaman içerisinde sürekli şekilde gözlenebilen zaman serilerine sürekli zaman serileri adı verilir. Faiz oranları, kar ve satış hacimleri gibi sadece belirli zaman aralıklarında gözlenebilen serilere ise kesikli zaman serileri denir (Wei, 2006, s.1). Bir zaman serisinin gelecek değeri tam olarak öngürülebiliyorsa, zaman serisi deterministik (kesin), aksi takdirde stokastik (olasılıklı) seri olarak adlandırılır. Benzer şekilde zaman serileri durağan ve durağan olmayan zaman serileri şeklinde de gruplandırılabilir. Eğer bir zaman serisinin ortalamasında ve varyansında sistematik bir değişme yoksa ve düzenli periyodik değişmeler ortaya çıkmıyorsa seri durağandır denir (Sevüktekin ve Nargeleçekenler, 2007).

Zaman serisi analizinde iki tür yaklaşımdan söz edilebilir. Bunlar frekans domaini ve zaman domaini yaklaşımlarıdır. Zaman domaini yaklaşımında zaman serisinin gelecek değerleri, o anki ve geçmişteki değerlerin parametrik bir fonksiyonu şeklinde modellenir. Bu yaklaşım, sonuçların tahmin aracı olarak kullanılmasına imkân sağladığı için oldukça popülerdir (Shumway ve Stoffer, 2006, s.2)

2.3. ZAMAN SERİSİ BİLEŞENLERİ

Zaman serisi analizinin temel amacı, örnek veriler için mantıksal açıklamalar sağlayan matematiksel modeller geliştirmektir. Zaman içinde oynak ve rastgele olarak gözlenmiş olan verinin karakterini tanımlamak için, serilerin zaman içinde gözleendiği sıraya göre indekslenen rastgele değişkenlerin bir toplamı olduğu varsayılır (Shumway ve Stoffer, 2006, s.11).

Bir zaman serisi temel olarak dört bileşenden oluşur. Bunlar:

T=Trend (Uzun Dönem Eğilimi)

S= Mevsimsel (Seasonal) Dalgalanmalar

C= Konjonktürel (Cyclical) Dalgalanmalar

I= Düzensiz Hareketler

Y_t zaman serisi gözlem değerleri olmak üzere bu dört bileşenin seri üzerindeki etkisi çarpımsal ve toplamsal şekilde gösterilmektedir. Toplamsal yaklaşımda serinin bu dört bileşenin toplamından oluştuğu varsayılır:

$$Y_t = T + S + C + I \quad (1.1)$$

Çarpımsal yaklaşımda ise zaman serisinin bu dört bileşenin çarpımından oluştuğu varsayılır:

$$Y_t = TSCI \quad (1.2)$$

2.4. DURAĞANLIK

Zaman serilerinin davranışları ile ilgili herhangi özel varsayımda bulunulmamasına karşın bazı örnekler bize zaman serisi davranışlarının zamana göre bir tür düzenlilik gösterdiğinin ipuçlarını verir. Bu düzenlilik fikri durağanlık denilen bir kavram ile açıklanmaktadır (Shumway ve Stoffer,2006, s.23). Durağan seriler sabit bir ortalama seviye etrafında yayılım göstermekle birlikte bu ortalama seviye

etrafında bir tür istatistiksel denge ile karakterize edilirler (Yaffee ve McGee,2000, s.5).

Herhangi bir Y_t serisinin durağan olma şartları şu şekilde özetlenebilir (Hamilton,1994):

$$E(Y_t) = \mu \quad (\text{Bütün } t\text{'ler için}) \quad (1.3)$$

$$Var(Y_t) = E(Y_t - \mu)^2 = \sigma^2 \quad (1.4)$$

$$\gamma_j = E(Y_t - \mu)(Y_{t-j} - \mu) \quad (\text{Bütün } t\text{'ler ve herhangi } j \text{ için}) \quad (1.5)$$

Yukarıdaki eşitliklerde μ (ortalama), σ^2 (varyans) ve γ_j (kovaryans) sabittir. Bu tip durağanlığa zayıf ikinci mertebeden durağanlık denir.

Zaman serileri ile çalışılırken ilk aşamada serinin durağan olup olmadığının test edilmesi gerekir. Çünkü durağan olmayan bir seride değişkenler arasında anlamlı bir ilişki yoksa bile anlamlı bir ilişki varmış gibi görünebilir. Bu nedenle durağan olmayan seriler analiz yapılmadan önce durağanlaştırılmalıdır. Durağanlığı tespit edebilmek için seri grafiğinin incelenmesi, otokorelasyon fonksiyonunun incelenmesi, korelogram testi ve birim kök testi gibi yöntemler kullanılır.

Durağan olmayan seriler rassal yürüyüş, trend ya da değişen varyans ile karakterize edilir. Durağan olmayan serileri istatistiksel modellemeye hazırlamak için, seriler doğal logaritması ya da farkı alınarak veya zaman üzerine regresyon uygulayıp artıklarla çalışılarak (Sevüktekin ve Nargeleçekenler, 2007, s.236) durağanlaştırılır. Eğer seri fark alınarak durağanlaştırıldıysa fark durağan; bir regresyonda eğilim giderilip kalıntılar kullanılarak durağanlaştırıldıysa trend durağan olarak adlandırılır (Yaffee ve McGee, 2000, s7).

2.5. BOX-JENKINS YÖNTEMİ

2.5.1. Giriş

1972 yılında George E. P. Box ve Gwilym M. Jenkins tarafından geliştirilen

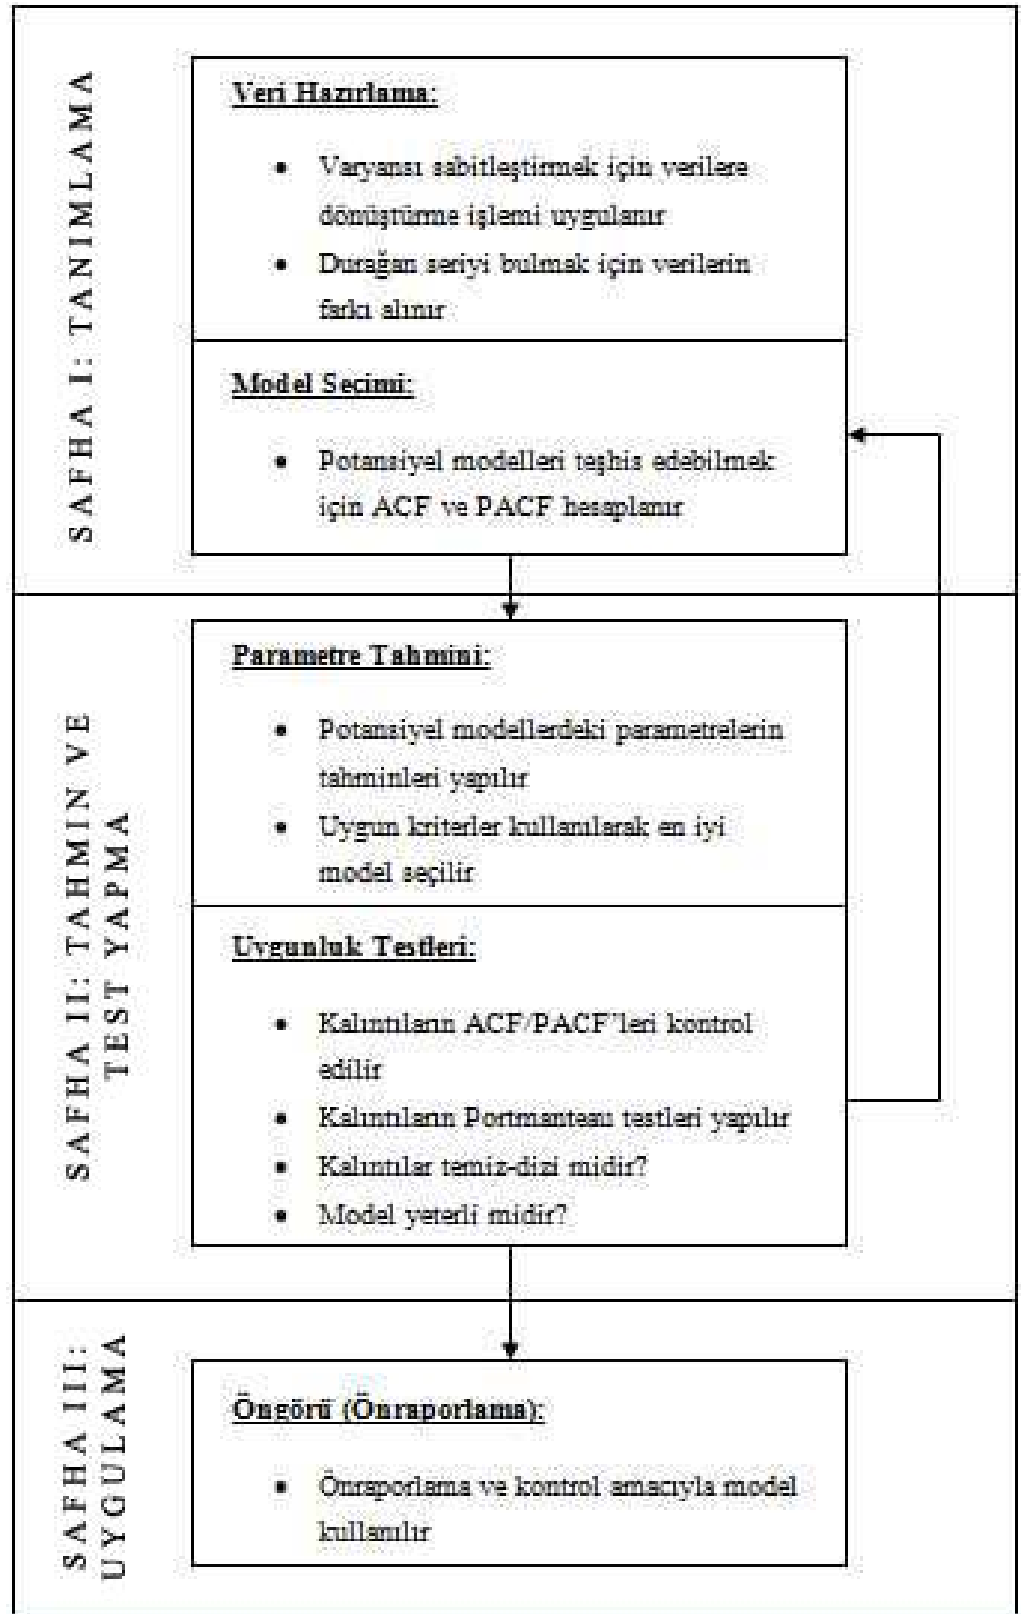
Box-Jenkins metodu zaman serisi analizinde en yaygın olarak kullanılan yöntemlerden biridir (Yaffee ve McGee, 2000, s.70). Yöntem birçok alternatif model arasından en iyi modeli seçerek geleceği tahmin etmeye yöneliktir. Bir değişkene ilişkin yapılacak tahmin, kendi gecikmeli değerleri, hata terimleri ya da her ikisinin kombinasyonu ile yapılmaktadır. Box-Jenkins yöntemi alternatif modeller arasından en iyisinin belirlenmesine yöneliktir (Bozkurt, 2007, s.47)

Box-Jenkins metodunda seriler durağanlaştırılır sonra hareketli ortalama ve otoregresif parametreler, tahmine uygun kapsamlı bir model ortaya çıkarmak üzere birleştirilir. Daha önceden bilinen yöntemlere kıyasla Box-Jenkins yöntemi, daha esnek ve güçlü modelleme yeteneğine sahiptir. Bu modelde ayırık zaman serisi verilerinin zaman içindeki sıklığının eşit olması ve eksik verinin olmaması gerekir. Seri anlamlılık parametreleri testinin güçlü olması dolayısıyla sağlıklı parametre tahmini için yeterince uzun olmalıdır (Yaffee ve McGee, 2000, s.71).

2.5.2. Box-Jenkins Yönteminin Aşamaları

Box-Jenkins yöntemi 4 temel aşamadan oluşur. Bunlar belirleme (identification), parametre tahminleri (estimation), modelin testi (diagnostic checking) ve önraporlama (forecasting) olarak sıralanabilir (Bozkurt, 2007, s.49-50).

Zaman serisi modeli kurmada Box-Jenkins yaklaşımı aşağıdaki şekilde şematize edilebilir (Sevüktekin ve Nargeleçkenler, 2007, s.180):



Şekil 1. Box-Jenkins Yaklaşımı

2.5.2.1. Belirleme (Identification)

Bu aşamada öncelikle serinin durağan olup olmadığına bakılır. Seri durağan ise orijinal haliyle bırakılır; trend durağan ise trendden arındırılarak, birim kökü varsa farkı alınarak durağan hale getirilir. Daha sonra serinin AR(p) (Auto Regressive), MA(q) (Moving Average) veya ARMA(p,q) (Auto Regressive Moving Average) süreçlerinden hangisini izlediğine karar verilerek p ve q değerleri saptanır. Eğer seri mevsimsel ise d kadar farkı alınır ve serinin ACF (otokorelasyon) ve PACF (kısmi otokorelasyon) değerleri incelenerek uygun modelleme yapılır.

2.5.2.1.1. ACF (Otokorelasyon Fonksiyonu)

Bir stokastik süreci tamamen tanımlamak mümkün olmadığından süreci kısmen tanımlayan otokorelasyon fonksiyonu hangi modelin seçileceği ile ilgili karar aşamasında önemli bir yere sahiptir. Otokorelasyon fonksiyonu, herhangi bir serideki komşu veri noktaları arasında ne kadar korelasyon olduğunu gösterir. Bir serinin k gecikmeli ρ_k otokorelasyonu şu şekilde tanımlanır (Wei, 2006, s.10):

$$\rho_k = \frac{E(Y_t - \mu)(Y_{t+k} - \mu)}{\sqrt{E[(Y_t - \mu)^2(Y_{t+k} - \mu)^2]}} \quad (1.6)$$

Durağan bir süreç için t dönemindeki varyans ile t+k dönemindeki varyans birbirine eşit olduğundan yukarıdaki eşitliğin paydası 1 kabul edilerek aşağıdaki şekilde ifade edilir:

$$\rho_k = \frac{E[(Y_t - \mu)(Y_{t+k} - \mu)]}{\sigma^2} \quad (1.7)$$

Aynı şekilde Y_t ile Y_{t+k} dönemindeki varyans değerleri aynı olduğundan yukarıdaki eşitlik şu şekilde yeniden yazılabilir:

$$\rho_k = \frac{\gamma_k}{\gamma_0} \quad (1.8)$$

Burada μ aritmetik ortalama, σ^2 varyans, γ_k k gecikme için kovaryans

ve γ_0 varyanstır.

Durağan bir seri için elde edilen otokorelasyon fonksiyonu incelendiğinde; eğer ACF değerleri sıfıra yaklaşıyorsa bütün gecikmeler için otokorelasyon olmadığını savunan hipotez kabul edilir. Bir serinin gecikme değeri arttırıldığında ACF değerleri sıfıra yaklaşıyorsa seri durağandır, aksi halde değildir (Bozkurt, 2007, s.33).

2.5.2.1.2. PACF (Kısmi Otokorelasyon Fonksiyonu)

Y_t ve Y_{t+k} arasındaki otokorelasyona ek olarak bu iki nokta arasında kalan gözlemlerin etkisini arındırdıktan sonra korelasyon hakkında da bilgi sahibi olmak isteyebiliriz. Bu şekilde hesaplanan ilişki iki nokta arasındaki kısmi otokorelasyondur ve uygun öngörü modellerinin p ve q gibi mertebelerinin ne olması gerektiğinin belirlenmesinde kullanılır (Wei, 2006, s.11):

$$\Phi_{kk} = \rho(Y_t, Y_{t+k} | Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}) \quad (1.9)$$

Burada Φ_{kk} , Y_t ile Y_{t+k} arasındaki korelasyon katsayısıdır. Kısmi otokorelasyonlar otokorelasyon fonksiyonunun değerlerinden yararlanarak elde edilir. Bunun için aşağıdaki eşitlikler kullanılır:

$$\Phi_{kk} = \frac{\rho_k - \sum_{j=1}^{k-1} \Phi_{k-1,j} \rho_j}{1 - \sum_{j=1}^{k-1} \Phi_{k-1,j} \rho_j} \quad (1.10)$$

$$\Phi_{kj} = \Phi_{k-1,j} - \Phi_{kk} \Phi_{k-1,k-j} \quad j=1,2,\dots,k-1 \text{ için} \quad (1.11)$$

Bir serinin otokorelasyonlarının, kısmi korelasyonların ve Q (Ljung-Box) istatistiklerinin serinin özelliğine göre yaklaşık olarak seçilen k sayıda gecikmeye göre işaretlenerek grafiğinin çizilmesine korelogram denir (Sevüktekin ve Nargeleçekenler, 2007, s.271).

Durağan modeller için otokorelasyon ve kısmi otokorelasyon

fonksiyonlarının teorik davranışları aşağıdaki tabloda verilmiştir (Sevüktekin ve Nargeleçekenler, 2007, s.183):

Tablo 1. ACF ve PACF'nin teorik davranışları

Model	Otokorelasyon Fonksiyonu	Kısmi Otokorelasyon Fonksiyonu
AR(p)	Azalarak kaybolur	q gecikme sonra kesilir
MA(q)	p gecikme sonra kesilir	Azalarak kaybolur
ARMA(p,q)	Azalarak kaybolur ve p gecikme sonra	Azalarak kaybolur ve q gecikme sonra
Durağan	Sıfıra doğru azalma görülmez	Sıfıra doğru azalma görülmez
Mevsimsel Etki	Belirli aralıklarda sıfırdan farklıdır	Belirli aralıklarda sıfırdan farklıdır

Bir seride; eğer ACF azalan görünümde, PACF ise p gecikmeden sonra eksenini kesiyorsa bu seri için AR(p) süreci uygundur. Eğer ACF q gecikmeden sonra eksenini kesiyor ve PACF azalan görünümde ise MA(q) süreci, eğer hem ACF hem de PACF azalan görünüm sergiliyorsa ARMA(p,q) süreci uygundur. Benzer şekilde iki fonksiyonda da azalma gözlenmiyorsa bu seri durağan değildir. Eğer her iki fonksiyon da belirli aralıklarda sıfırdan farklı ise seride mevsimsel etkiler olduğu düşünülür.

2.5.2.2. Parametre Tahminleri (Parameter Estimations)

Serinin izlediği süreç belirlendikten sonra katsayılar tahmin edilir. Bunun için çeşitli yöntemler kullanılabilir. Eğer seride AR süreci varsa En Küçük Kareler yöntemi kullanılır. Bu yöntemde adım adım hata kareler toplamı bulunur. En küçük kareler tahminleri, standart hatalar ve t değerleri hesaplanarak parametre değerlerinin anlamlı olarak sıfırdan farklı olup olmadığı kontrol edilir. Anlamlı olmayan parametreler modelden atılır. MA modeli varsa hata teriminin kovaryans matrisini hesaplayabilmek için En Çok Benzerlik Yöntemi (Maximum Likelihood) kullanılır. Her iki süreç de modelde yer alıyorsa doğrusal olmayan optimizasyon yöntemine başvurulur.

2.5.2.3. Uygunluk Testleri (Diagnostic Checking)

Kurulan modelin seriyi iyi açıklayıp açıklamadığını ortaya koymak üzere uygunluk testleri yapılmalıdır. Bu süreç iki aşamadan oluşur. Birincisi benzetilen serinin otokorelasyon fonksiyonu orijinal serinin otokorelasyon fonksiyonu ile

karşılaştırılır. Eğer iki fonksiyon farklılık arz ediyorsa modelin uygun olmadığından şüphe edilir ve belirleme aşamasına geri dönülür. Eğer iki otokorelasyon fonksiyonu belirgin biçimde farklı değilse bu durumda modelin kalıntıları analiz edilir. Model doğru bir şekilde tanımlanmışsa kalıntılar $\hat{\varepsilon}_t$ bir temiz-dizi sürecine benzer. Dolayısıyla kalıntıların zaman yolu grafiğinde olağan dışı veya sapan değerlere rastlanmaz (Sevüktekin ve Nargeleçekenler, 2007, s.185). Bunun yanısıra serinin otokorelasyonları incelenerek Box-Pierce ve Ljung-Box istatistikleri hesaplanır. Otokorelasyon katsayıları, Q istatistiği ile m serbestlik dereceli χ^2 dağılımı kullanılarak değerlendirilir (Bozkurt, 2007, s.50):

$$Q = n \sum r_k^2(a) \quad (1.12)$$

Burada n örneklem hata büyüklüğü, $r_k(a)$ ise örneklem içi öngörü hatalarının çeşitli gecikmelerdeki otokorelasyonlarıdır. Ljung-Box Q istatistiği ise şu şekilde hesaplanır (Shumway ve Stoffer, 2006, s.149):

$$Q^m = n(n+2) \sum_{k=1}^m \frac{r_k^2(e)}{n-k} \quad (1.13)$$

Burada $r_k(e)$, k gecikmedeki hata korelasyonu, n hata sayısı, k gecikme ve m test edilen gecikme sayısı olup Q^m yaklaşık olarak $m-r$ serbestlik derecesinde χ^2 dağılımına uygundur.

Eğer Q istatistiğinden elde edilen olasılık değeri (p) önem seviyesinin altında ise ($p < 0.05$) belirlenen modelin uygun olmadığı anlaşılır. Bu durumda yeni bir model kurulup testlere devam edilir.

2.5.2.3.1. Model Seçim Kriterleri

Kurulan mevcut alternatif modeller arasından en uygun model seçilmek istendiğinde bir takım uygunluk kriterleri değerlendirilerek genellikle minimum değerlere sahip olan model en uygun model olarak seçilir. Bu seçim kriterleri şu şekilde sıralanabilir:

2.5.2.3.1.1. Standart Belirlenim Katsayısı – R^2 :

Standart belirlenim katsayısı regresyon modelleri arasında bu kritere dayanarak seçim yapma maksimizasyonuna dayanır. ARIMA modelleri için de benzer çözüm önerilir. Zaman serisi modelleri için belirlenim katsayısının hesabı teorik olarak en basit AR(1) modeli $Y_t = \phi_1 Y_{t-1} + \varepsilon_t$ için

$$R^2 = 1 - \frac{\sigma^2}{\gamma_0} = 1 - \frac{\sigma^2}{\left[\frac{\sigma^2}{1 - \phi_1^2} \right]} = \phi_1^2 \quad (1.14)$$

yazılabilir (Sevüktekin ve Nargeleçekenler, 2007, s.188). Dolayısıyla R^2 yalnızca AR parametrelerine bağlıdır.

2.5.2.3.1.2. F İstatistiği Yaklaşımı:

ARIMA model belirlemede kullanılan diğer bir seçim kriteri F istatistiği yaklaşımıdır. Zaman serisi verilerine AR(m)'in mi yoksa AR(p)'nin mi daha uygun olacağını belirlemeye çalışıldığı durumlarda bütüncül model olarak AR(p), kısıtlı model olarak da AR(m) düşünülürse sıfır ve alternatif hipotezler şu şekilde olacaktır:

$$H_0 : \phi_{m+1} = \phi_{m+2} = \dots = \phi_p = 0$$

$$H_1 : \phi_i \text{ 'lerden en az biri sıfırdan farklıdır } (i=m+1, \dots, p)$$

Hipotezleri test etmek için ilk önce bütüncül AR(p) modeli sonra p-m değişkeninin dışarıda bırakıldığı kısıtlı AR(m) modeli tahmin edilir. Daha sonra Wald F-istatistiği hesaplanır (Sevüktekin ve Nargeleçekenler, 2007, s.189):

$$F^* = \frac{(SSR_r - SSR_u)/(u - m)}{SSR_u/(T - u)} \quad (1.15)$$

Burada SSR_r kısıtlı AR(m) modelinin, SSR_u bütüncül AR(p) modelinin hata kareler toplamını gösterir. Eğer test istatistiği anlamlılık düzeyinin üstünde ise ($F^* > F_{u-m; T-u}$) sıfır hipotezi reddedilir. Diğer durumda serinin AR(m) olduğuna karar

verilir.

2.5.2.3.1.3. Akaike Bilgi Kriteri (AIC):

Bu kriter modeldeki terimlerin sayısını dikkate alarak modelin uyumunun iyiliğini ölçer. AIC kriteri

$$AIC = -2 \log L + 2m \quad (1.16)$$

şeklinde tanımlanır (Sevüktekin ve Nargeleçekenler, 2007, s.190). Burada L olabilirliği gösterir ve $m=p+q$ 'dur. Akaike tarafından öne sürülen bu ifadenin alternatifleri de vardır (Sevüktekin ve Nargeleçekenler, 2007, s.190). Bunlardan ilki

$$AIC = T \log \hat{\sigma}_{ML}^2 + 2m \quad (1.17)$$

şeklindedir. Burada $\hat{\sigma}_{ML}^2 = SSR/T$ ve SSR hata kareler toplamıdır. İkincisi ise aşağıdaki şekilde tanımlanır:

$$AIC = T \log(SSR) + 2m \quad (1.18)$$

Kurulan alternatif modeller arasında en küçük AIC değerine sahip olan model en uygun model olarak seçilir.

2.5.2.3.1.4. Schwarz Bilgi Kriteri (SIC)

Schwarz bilgi kriteri de aynen Akaike bilgi kriteri gibi kullanılır. Aynı zamanda Bayes Bilgi Kriteri (BIC) olarak da adlandırılır. SIC için de farklı iki tanımlama mevcuttur (Sevüktekin ve Nargeleçekenler, 2007, s.191):

$$SIC = T \log \hat{\sigma}_{ML}^2 + m \log T \quad (1.19)$$

veya

$$SIC = T \ln(SSR) + m \ln(T) \quad (1.20)$$

Uygun bir model için ideal olan AIC ve SIC kriterlerinin mümkün olan en

küçük değerini seçmektir.

2.5.2.4. Öngörü (Forecasting)

Öngörü geçmişteki ve güncel bilgilerden faydalanılarak gelecekteki olayların olabilirliği ile ilgili yapılan bir tahmin veya tahminler kümesidir. Oluşturulan zaman serisi modeli eğer uygun olduğuna karar verilirse öngörü amacıyla kullanılabilir. Dolayısıyla bu modelin tahminlerinden yararlanılarak rassal değişken Y_t için bir dönem Y_{T+1} veya h dönem Y_{T+h} ilerisi için öngörülme yapılabilir. Bir dönem ilerisi için yapılan tahmin \hat{Y}_{T+1} ile gösterilir. Amaç gelecek değere en yakın tahmin değerini elde etmektir. Bunun için tahmin edilen ve gerçek değer arasındaki ortalama kare hatanın minimize edilmesi gerekir (Sevüktekin ve Nargeleçekenler, 2007, s.191-192):

$$E_T[(\hat{Y}_{T+h} - Y_{T+h})] = \min \quad (1.21)$$

2.6. ZAMAN SERİSİ SÜREÇLERİ

2.6.1. Stokastik Süreçler

Reel olarak gözlenen bir zaman serisi $Y_t, t=1,2,\dots,T$; stokastik süreç olarak adlandırılan bir teorik sürecin gerçekleşmesi olarak düşünülür. Bir stokastik süreçte her gözlem yani serideki her değer Y_1, Y_2, \dots, Y_T bir olasılık dağılımından rassal olarak çekildiğinden rassal bir değişkendir ve gözlemlerin belirli bir olasılık dağılımına göre oluştuğu varsayılmaktadır. Dolayısıyla bir stokastik süreç matematiksel olarak zaman aralıklarına göre dizilmiş, rassal değişkenlerin bir birikimi olarak tanımlanabilir yani $\{Y_t, t \in T\}$, burada T , süreçte tanımlanan zaman noktalarının bir setidir (Sevüktekin ve Nargeleçekenler, 2007, s.53).

2.6.1.1. Durağan Stokastik Süreçler

2.6.1.1.1. Otoregresif Süreçler (AR(p))

Otoregresif süreç, değişkenin t döneminde ve p periyodunda geçmiş dönemde incelenen belirli sayıda gözlemlerle hata değişkeni ϵ_t 'nin doğrusal bir birleşimidir

ve şu şekilde ifade edilir (Sevüktekin ve Nargeleçekenler, 2007, s.63):

$$Y_t = \delta + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad (1.22)$$




Burada δ bir kesme (sabit) terimdir ve stokastik süreç olan Y_t 'nin ortalamasının gösterir, $\phi_1, \phi_2, \dots, \phi_p$ 'ler bilinmeyen otoregresif parametreler, hata terimi ε_t ise ortalaması sıfır ve sabit σ_ε^2 varyanslı korelasyonsuz rastgele değişkenlerdir.

Birinci derece otoregresif zaman serisi modeli (AR(1)) sadece kendisine, bir önceki dönem değerine (Y_{t-1}) ve bir rastgele kalıntıya bağlıdır. Bu ilişki şu şekilde ifade edilebilir (Yaffee ve McGee, 2000, s.76):

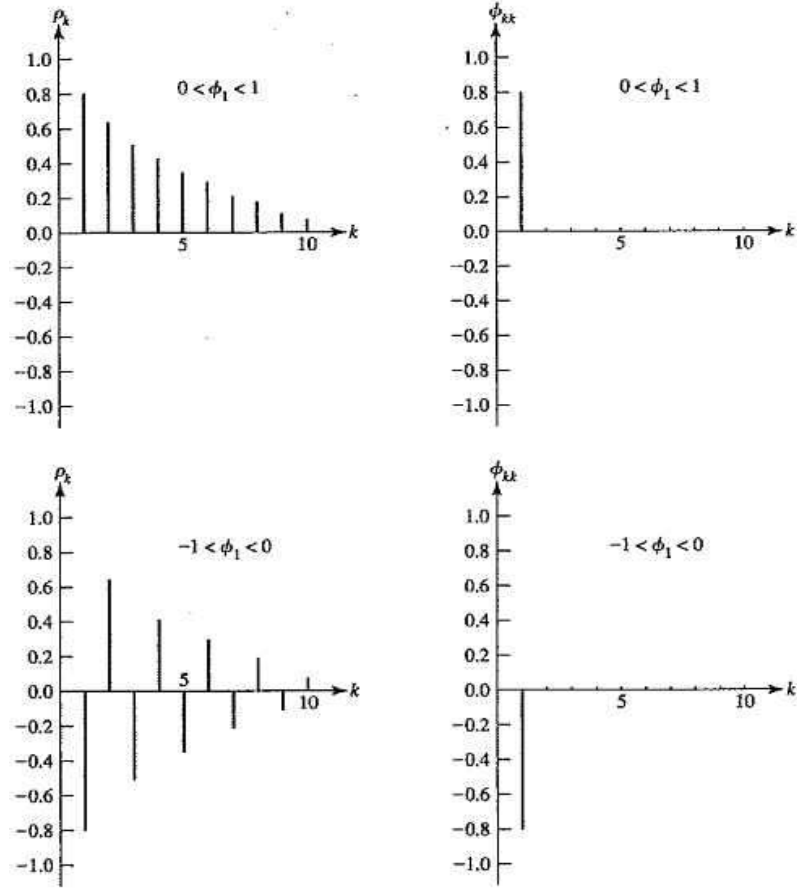
$$\begin{aligned} Y_t &= \phi_1 Y_{t-1} + \varepsilon_t \\ Y_t &= \phi_1 L Y_t + \varepsilon_t \end{aligned} \quad \text{veya} \quad (1.23)$$

$$(1 - \phi_1 L) Y_t = \varepsilon_t$$

Zaman serilerinde bütün rastgele değişkenlerin aynı ortalama ve varyansa sahip oldukları varsayılır. Ayrıca Y_t ve Y_{t+k} gibi herhangi iki gözlem değeri arasındaki kovaryansın zamana bağlı olmadığı, fakat iki değişken arasındaki sayıda öncüle veya gecikmeye bağlı olduğu varsayılır. Bu varsayımlardan hareketle seri ϕ değişkeninin aldığı değerlerden etkilenecektir. Eğer ϕ_1 sıfıra yakın değerler alırsa seri ortalamayı sıkça, 1'e yakın değerler alırsa az sayıda kesecektir. $\phi_1 > 1$ olması durumunda seri patlayan seri özelliği gösterir $\phi_1 = 0$ olduğunda ise süreç beyaz gürültü (white noise) sürecine eşit olacaktır. ϕ_1 değişkeninin aldığı değerlere göre AR(1) sürecinin davranışları aşağıdaki şekilde gösterilmiştir (Hamilton, 1994, s.55):

(a) $\phi_1=0$ (white noise)(b) $\phi_1=0.5$ (c) $\phi_1=0.9$ **Şekil 2.** Alternatif ϕ_1 değerleri için $Y_t = \phi_1 Y_{t-1} + \varepsilon_t$ AR(1) süreci

AR(1) süreci için ACF ve PACF grafikleri aşağıdaki şekilde verilmiştir (Wei, 2006, s.35):



Şekil 3. AR(1) Süreci için ACF ve PACF Grafikleri

İkinci dereceden bir otoregresif süreç AR(2) ise kendisine, bir rastgele değişkene ve kendisinden önceki iki dönem gözlem değerine bağlıdır (Yaffee ve McGee, 2000, s.76):

$$\begin{aligned}
 Y_t &= \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \varepsilon_t \\
 Y_t &= (\phi_1 L + \phi_2 L^2) Y_t + \varepsilon_t
 \end{aligned}
 \tag{1.24}$$

AR(2) sürecinin durağan olabilmesi için ϕ_1 ve ϕ_2 parametrelerinin şu şartları sağlaması gerekmektedir (Wei, 2006, s.41):

$$\begin{aligned}
\phi_1 + \phi_2 &< 1 \\
\phi_1 - \phi_2 &< 1 \\
-1 &< \phi_2 < 1
\end{aligned}
\tag{1.25}$$

ϕ_1 ve ϕ_2 değerleri sıfıra yaklaştıkça seri ortalamayı sıkça keser fakat seri durağanlık koşulunu sağlamasına karşın parametreler büyüdükçe daha az oranda ortalamayı keser.

Eşitlik 1.22’de verilen şekilde p. dereceden otoregresif davranış sergileyen herhangi Y_t serisinin gerçek hayatta derecesi çoğu zaman belirsizdir. Bu serinin derecesini belirlemek için kısmi otokorelasyon fonksiyonundan faydalanılır. Kısmi otokorelasyon katsayılarının p gecikmesine kadar anlamlı, sonraki gecikmeler için anlamsız (p gecikmesine kadar sıfırdan farklı, sonraki gecikmelerde sıfır) olduğu kabul ediliyorsa sürecin derecesinin p olduğu söylenecektir.

2.6.1.1.2. Hareketli Ortalama Süreci (MA(q))

Hareketli ortalama süreci, bir zaman serisinin t dönemdeki değerini (Y_t) rastgele kalıntıların geçmiş değerlerinin (ε_t) ağırlıklı bir ortalaması olarak ifade eden bir süreçtir. Genel MA(q) süreci için istatistiksel model şu şekildedir (Sevüktekin ve Nargeleçekenler, 2007, s.155):

$$Y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \tag{1.26}$$

Birinci dereceden bir hareketli ortalama süreci MA(1) şeklinde gösterilir ve şu şekilde ifade edilir (Yaffee ve McGee, 2000, s.75):

$$\begin{aligned}
Y_t &= \varepsilon_t - \theta_1 \varepsilon_{t-1} \\
Y_t &= \varepsilon_t (1 - \theta_1 L)
\end{aligned}
\tag{1.27}$$

Burada y_t orijinal seri olmak üzere, μ serinin ortalaması, Y_t ortalama merkezli seri ya da $Y_t = y_t - \mu$, ε_t t zamanındaki şok, ε_{t-1} bir önceki şok ve θ_1 de hareketli ortalama katsayısıdır.

MA(1) sürecinde k sayıda gecikme için $k > 1$ olduğu durumlarda kovaryans

aynı biçimde gösterilir yani bütün durumlarda kovaryans sıfırdır. Bu nedenle MA(1) sürecinin sadece bir dönemlik belleğe sahip olduğu söylenebilir. Yani herhangi bir Y_t değeri sadece Y_{t-1} ve Y_{t+1} ile korelasyonludur (Wei, 2006, s.48).

MA sürecinin otokorelasyon fonksiyonu için $|\theta_1| < 1$ olmalıdır. Buna tersine çevrilebilirlik koşulu da denir. Bu şart, AR(1) sürecinin durağanlık koşuluna benzer fakat MA(1) serisinin durağanlığı θ_1 katsayısına bağlı değildir.

İkinci dereceden hareketli ortalama süreci MA(2) ile gösterilir ve şu şekilde ifade edilir (Yaffee ve McGee, 2000, s.76):

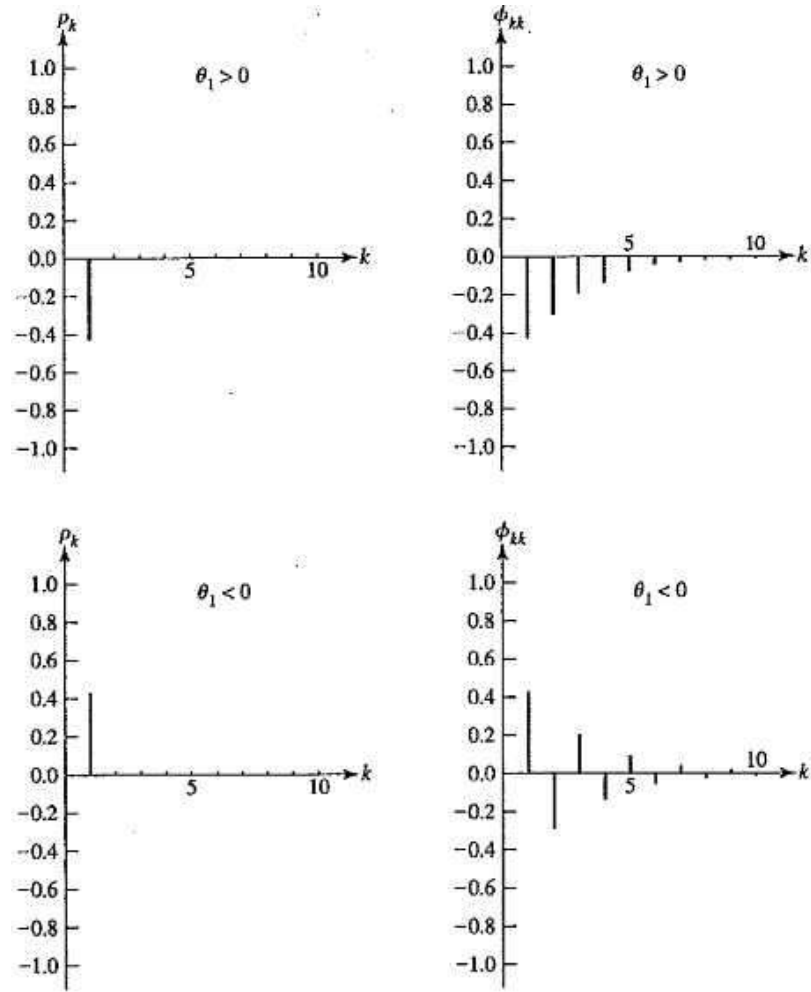
$$\begin{aligned} Y_t &= \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} \\ Y_t &= \varepsilon_t (1 - \theta_1 L - \theta_2 L^2) \end{aligned} \quad (1.28)$$

MA(2) süreci, MA(1) sürecine benzer şekilde 2 dönemlik bir belleğe sahiptir yani Y_t sadece ε_t ve ε_{t-2} 'ye bağlıdır. Aynı şekilde MA(q) sürecinin de q dönemlik belleği vardır.

MA(2) sürecinin tersine çevrilebilirlik koşulunu sağlaması için θ_1 ve θ_2 parametreleri şu şekilde olmalıdır (Wei, 2006, s.51):

$$\begin{aligned} \theta_2 + \theta_1 &< 1 \\ \theta_2 - \theta_1 &< 1 \\ -1 &< \theta_2 < 1 \end{aligned} \quad (1.29)$$

Bir MA sürecinin ACF'si sürecin derecesinden sonra kesilir, PACF'si ise sıfıra doğru söner. MA(1) sürecine ait ACF ve PACF grafikleri Şekil 4'te verilmiştir (Wei, 2006, s.49, s.53):



Şekil 4. MA(1) Süreci için ACF ve PACF Grafikleri

2.6.1.1.3. Karma Otoregresif - Hareketli Ortalama Süreci (ARMA(p,q))

Birçok durağan rastgele süreç pür otoregresif ya da pür hareketli ortalama süreci ile modellenemeyebilir, zaman serisi bu iki süreci birlikte barındırıyor olabilir. Diğer bir deyişle zaman serisi modeli hem p. dereceden AR, hem de q. Dereceden MA süreçleri olmak üzere ARMA(p,q) şeklinde tanımlanabilir. ARMA(p,q) sürecinin genel gösterimi aşağıdaki gibidir (Sevüktekin ve Nargeleşkenler, 2007, s.167):

$$Y_t = \delta + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \quad (1.30)$$

Burada kesme terimi δ , Y_t 'nin ortalaması ile ilgili iken, hataların (ε_t) $E(\varepsilon_t)=0$

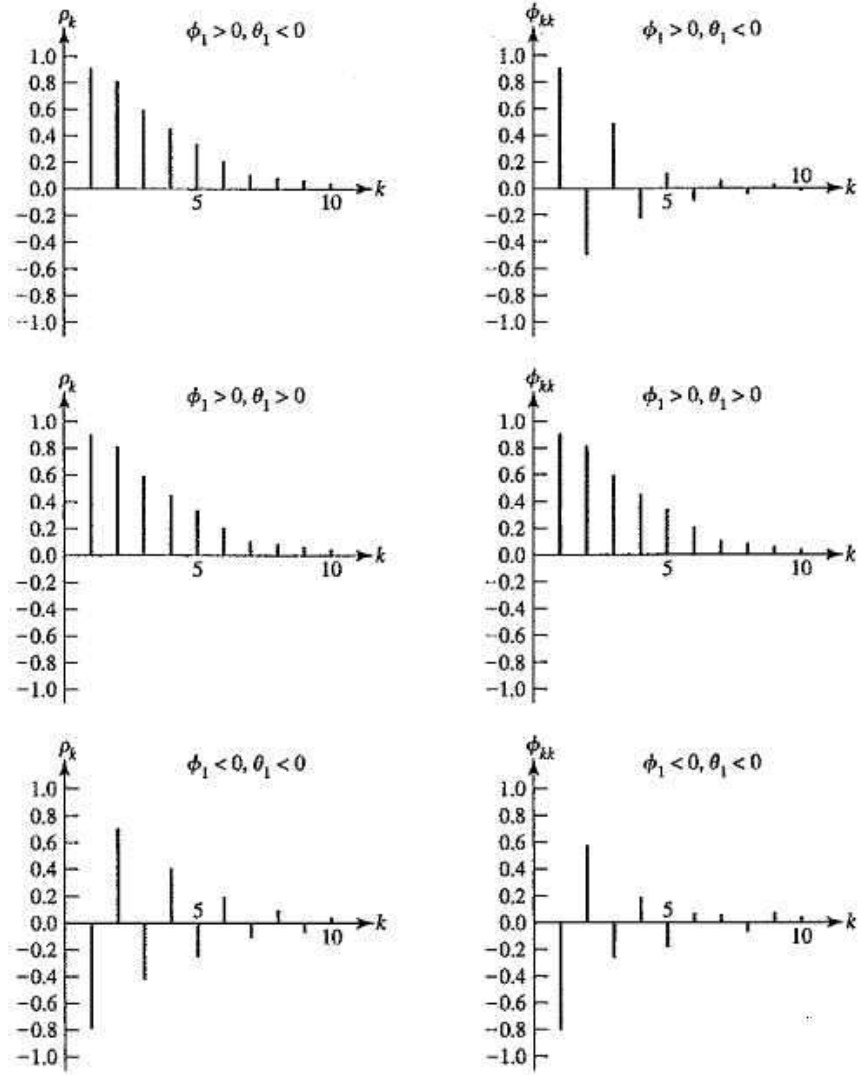
ve varyans $\text{Var}(\varepsilon_t) = \sigma^2$ ile korelasyonsuz rassal deęişkenler olduęu varsayılır. Eęer bu süreç duraęan ise tüm dönemler için sabit bir ortalamaya sahiptir. Buradan hareketle ARMA sürecinin duraęan olabilmesi için řu koşulu sağlaması gerekir (Sevüktekin ve Nargeleçekenler, 2007, s.167):

$$\phi_1 + \phi_2 + \dots + \phi_p < 1 \quad (1.31)$$

En basit karma otoregresif hareketli ortalama süreci ARMA(1,1) olarak gösterilir ve denklemini de řu şekildedir (Sevüktekin ve Nargeleçekenler, 2007, s.168):

$$Y_t = \delta + \phi_1 Y_{t-1} + \varepsilon_t + \theta_1 \varepsilon_{t-1} \quad (1.32)$$

ARMA(1,1) süreci AR ve MA bileşenlerinin bir kombinasyonu olduğundan otokorelasyon fonksiyonu hem AR hem de MA sürecinin özelliklerini birlikte gösterir. MA sürecinin yalnızca bir dönemlik belleęe sahip olmasından dolayı birinci gecikmeden sonra otokorelasyon fonksiyonunun kesilmesi beklenirken AR bileşeninin etkisiyle gecikme birden sonra otokorelasyon fonksiyonu azalan davranış sergiler. ARMA(1,1) süreci için otokorelasyon ve kısmi otokorelasyon fonksiyonları ařağıdaki şekilde verilmiştir (Wei, 2006, s.62):



Şekil 5. ARMA(1,1) Süreci için ACF ve PACF Grafikleri

2.6.1.2. Durağan Olmayan Stokastik Süreçler

Birçok zaman serisi durağan değildir. Böyle durağan olmayan stokastik süreçlerin, uygun modellerle gösterilebilmesi için seride durağanlığın sağlanması gerekir. Serilerde durağanlık, serinin uygun sayıda farkı alınarak sağlanır. Serilerin durağan olmamasının birçok nedeni vardır. Genelde ekonomik zaman serileri durağan değildir. Bu gibi serileri modellemek için doğrusal durağan olmayan stokastik süreçlerden faydalanılır.

2.6.1.2.1. Birleştirilmiş Otoregresif Hareketli Ortalama Modelleri (ARIMA(p,d,q))

Durağan olmayan zaman serileri, ARMA modellerinin özel bir hali olan Birleştirilmiş Otoregresif Hareketli Ortalama (ARIMA) modelleriyle gösterilir. Örneğin birçok ekonomik ve finansal zaman serisi durağan değildir ve rassal yürüyüş sürecinin özelliklerini yansıtırlar. Birinci derece otoregresif bir süreç için ϕ parametresi 1 olarak alındığında süreç şu şekilde olur:

$$Y_t = Y_{t-1} + \varepsilon_t \quad (1.33)$$

Bu süreç rassal yürüyüş (random walk) süreci olarak bilinir ve ε_t bu sürecin korelasyonsuz rastgele kalıntılarını gösterir.

Durağan dışı olan zaman serileri bir veya birden fazla fark alınarak durağan hale getirilebilir. Böyle bir zaman serisi entegre süreç olarak adlandırılır. Entegre sürecin derecesini tanımlayan d , serinin durağanlaştırılması için alınması gereken fark sayısını belirtir. Durağan olmayan Y_t gibi bir serinin bir kere farkı alındığında aşağıdaki eşitlik 1.34 elde edilir (Sevüktekin ve Nargeleçekenler, 2007, s.176):

$$\Delta Y_t = Y_t - Y_{t-1} = Y_t' \quad (1.34)$$

Burada Y_t' serisi durağan hale gelmişse, entegre sürecin derecesi $d=1$ olarak tanımlanır ve $I(1)$ ile gösterilir. Eğer seri hala durağan hale gelmemişse eşitlik 1.35'teki gibi Y_t' 'nin bir kere veya eşitlik 1.36'da görüldüğü gibi Y_t 'nin iki kere farkı alınarak seri durağanlaştırılır:

$$\begin{aligned} \Delta^2 Y_t &= \Delta(Y_t') = Y_t' - Y_{t-1}' \\ &= (Y_t - Y_{t-1}) - (Y_{t-1} - Y_{t-2}) \\ &= Y_t - 2Y_{t-1} + Y_{t-2} \end{aligned} \quad (1.35)$$

$$\Delta^2 Y_t = Y_t'' \quad (1.36)$$

Rassal bir yürüyüş süreci durağanlaştırılıp aşağıdaki şekilde ifade edilebilir:

$$W_t = \Delta^d Y_t \quad (1.37)$$

Burada eğer W_t durağan bir seri ise Y_t , d. dereceden homojen durağan dışıdır denilebilir. W_t gibi bir seri de d kere toplamı alınarak tekrar Y_t serisine dönüştürülebilir. Bunun için fark işlemcisinin tersi olan toplam alma işlemcisi (Σ) kullanılır:

$$Y_t = \Sigma^d W_t \quad (1.38)$$

Y_t gibi durağan olmayan bir serinin farkı alınarak durağan hale getirildikten sonra elde edilen W_t serisi ARMA süreci gibi ele alınabilir. Eğer W_t ARMA(p,q) süreci ise bu durumda Y_t (p,d,q)'uncu dereceden bir entegre otoregresif hareketli ortalama süreci veya kısaca ARIMA(p,d,q) şeklinde ifade edilir. ARIMA(p,d,q) süreci en genel haliyle eşitlik 1.39'da verilmiştir (Sevüktekin ve Nargeleçekenler, 2007, s.177):

$$(1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p) \Delta^d Y_t = \delta + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \quad (1.39)$$

veya gecikme işlemcisi kullanılarak şu şekilde tanımlanır:

$$\Phi(L) \Delta^d Y_t = \delta + \Theta(L) \varepsilon_t \quad (1.40)$$

2.6.1.2.2. Mevsimsel ARIMA Modelleri (SARIMA(p,q))

Birçok ekonomik seride mevsimlik etkiler ortaya çıkmaktadır. Mevsimselliğin ortaya çıkışında iklim, tatil günleri, sosyal olaylar, insan alışkanlıkları gibi pek çok faktör etkili olmaktadır. bu gibi etkiler ile periyodik ve yinelenen davranış gösteren zaman serileri mevsimsel etkiler göz önünde bulundurularak şu şekilde modellenir (Wei, 2006, s.164):

$$\Phi(L^s) \Delta_s^d Y_t = \Theta(L^s) \varepsilon_t \quad (1.41)$$

Burada s=4 veya 12 olup mevsimsel etkinin periyodunu göstermektedir.

$\Delta_s = (1 - L^s)$ olup $\Phi(L^s)$ ler p ve q mertebesindeki L^s polonomiyallarıdır, durağanlık ve çevrilebilirlik koşulunu karşılarlar. Aynı şekilde;

$$\Phi(L^s)\Delta^d Y_{t-1} = \Theta(L^s)\varepsilon_{t-1} \quad (1.42)$$

denklemleri ile de birinci periyotla bir önceki periyot ilişkilendirilir. Aynı zamanda bu modelde otoregresif mevsimlik parametre Φ ile hareketli ortalama mevsimlik parametresi Θ 'nin her bir periyot içinde aynı olduğu varsayılır.

3. YAPAY SİNİR AĞLARI

3.1. GİRİŞ

Günümüz dünyasında bilgisayar ve bilgisayar sistemleri yaşantımızın ayrılmaz bir parçası olmuştur. Bilgisayarlar artık olaylar hakkında karar verebilme ve olaylar arasındaki ilişkileri öğrenebilme gibi özelliklere kavuşturulmak istenmekte ve bu yöndeki çalışmalar “yapay zekâ” olarak adlandırılmaktadır. Yapay zekâ kabaca bir bilgisayarın ya da bilgisayar denetimli bir makinenin, genellikle insana özgü nitelikler olduğu varsayılan akıl yürütme, anlam çıkarma, genelleme ve geçmiş deneyimlerden öğrenme gibi yüksek zihinsel süreçlere ilişkin görevleri yerine getirme yeteneği olarak tanımlanmaktadır. Bu kavramın pek çok farklı tanımı yapılmaktadır. Bunlardan bazıları şu şekilde sıralanabilir (Nabiyev, 2005, s.33):

Slage’e göre yapay zekâ; sezgisel programlama temelinde olan bir yaklaşımdır.

Genesereth ve Nilsson’a göre yapay zekâ, akıllı davranış üzerine bir çalışmadır. Ana hedefi, doğadaki varlıkların akıllı davranışlarını yapay olarak üretmeyi amaçlayan bir kuramın oluşturulmasıdır.

Tesler’e göre yapay zekâ; şu ana kadar yapılamayanlardır.

Axe’e göre ise; akıllı programları hedefleyen bir bilimdir. Bu programlar şunları yapabilmelidir:

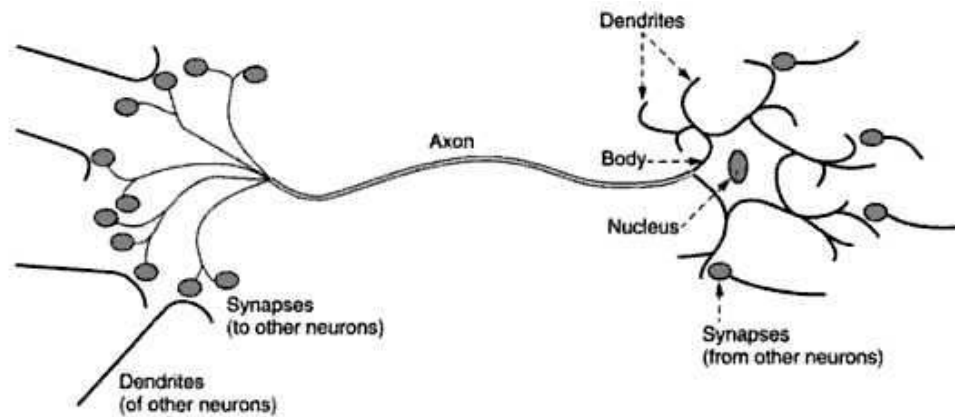
1. İnsanın düşünmesini taklit ederek karmaşık problemleri çözebilme.
2. Yorumlarını açıklayabilme, yani bir durum karşısında kişiye yanıt verebilme.
3. Öğrenerek uzmanlığını geliştirmek ve eski bilgilerini yenilerle uyumlu biçimde kullanarak bilgi tabanını genişletme.

Bu tanımlardan hareketle yapay sinir ağları da programlanması çok zor olan veya mümkün olmayan olaylar için geliştirilmiş adaptif bilgi işleme ile ilgilenen bir bilgisayar bilim dalı olarak tanımlanabilir (Öztemel, 2003, s.29). Temelde YSA insan

beyninin mimarisinden yola çıkılarak düzenlenmektedir. 1940'lı yıllardan sonra Hebb, McCulloch ve Pitts yapay sinir ağlarının temellerini atarak ilk yapay sinir hücresinin yapısını oluşturdular. 1949 yılında Donald Hebb günümüzde kullanılan birçok öğrenme kuralının temelini oluşturan bir öğrenme kuralı geliştirdi. Rosenblatt tarafından geliştirilen algılayıcı model (perceptron) daha sonra geliştirilecek ve yapay sinir ağlarında devrim niteliğinde olacak çok katmanlı algılayıcıların temelini oluşturmaktadır (Öztemel, 2003, s.37). Seksenli yıllar sinirsel hesaplama çalışmaları için bir atılım dönemi olmuştur. 1982 yılında Hopfield, ağların önemli sınıflarının matematik temellerini üretmiştir. 1984'te Kohonen sinirlerin düzenli sıralanışına eşleme özelliği için danışmansız öğrenme ağlarını geliştirmiştir (Elmas, 2007, s.28). YSA alanındaki gelişmeler günümüze kadar baş döndürücü bir hızla ilerlemiş, günümüzde de gelişimini arttırarak sürdürmektedir.

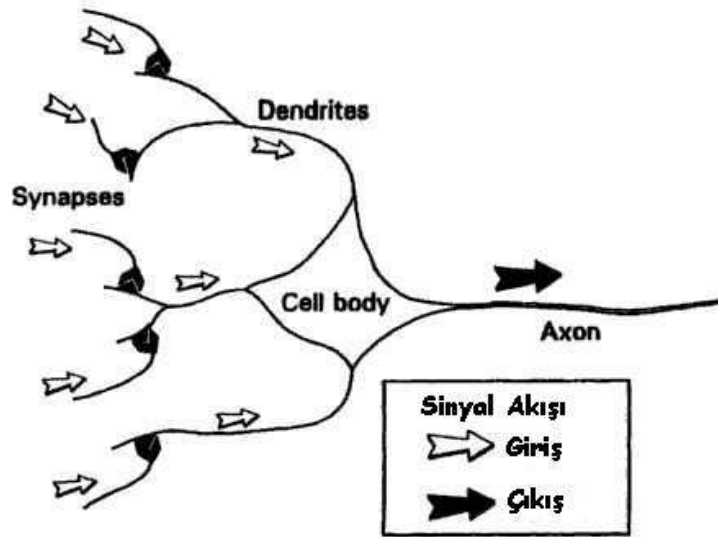
3.2. TEMEL KAVRAMLAR

Yapay sinir ağları biyolojik sinir sisteminden esinlenilerek ortaya çıkmıştır. Bu yüzden YSA'nın yapısını anlayabilmek için öncelikle orijinal sinir ağlarının yapısını anlamak gerekir. İnsanın sinir ağı birbiri ile iletişim içinde olan çok büyük sayıda sinirden oluşan sinir sisteminin bir parçasıdır (Mehrotra, Mohan ve Ranka, 2000, s.1). Bir biyolojik sinir hücresinin yapısı Şekil 6'da görüldüğü gibidir (Mehrotra, Mohan ve Ranka, 2000, s.8):



Şekil 6. Biyolojik Sinir Hücresi

Şekil 6’da görüldüğü gibi temel bir biyolojik sinir hücresi *sinapsler*, *axon* ve *dentrite*’lerden oluşmaktadır. Sinapsler sinir hücreleri arasındaki bağlantılar olarak düşünülebilir. Bunlar fiziksel bağlantılar olmayıp bir hücreden diğerine elektrik sinyallerinin geçmesini sağlayan boşluklardır. Bu sinyaller *soma* adı verilen hücre gövdesine giderler. Soma bunları işleme tabi tutar, sinir hücresi kendi elektrik sinyalini oluşturur ve axon aracılığıyla dentrite’lere gönderir. Dentrite’ler ise bu sinyalleri sinapslere ileterek diğer hücelere gönderilmesini sağlar. İki hücrenin birbirleri ile bilgi alışverişi sinaptik bağlantılardaki *neurotransmitter* madde yolu ile sağlanmaktadır (Öztemel, 2003, s.47). Bir sinir hücresinin başlıca elemanları Şekil 7’de görülmektedir (Gurney, 1997, s.2):



Şekil 7. Bir sinir hücresinin başlıca elemanları

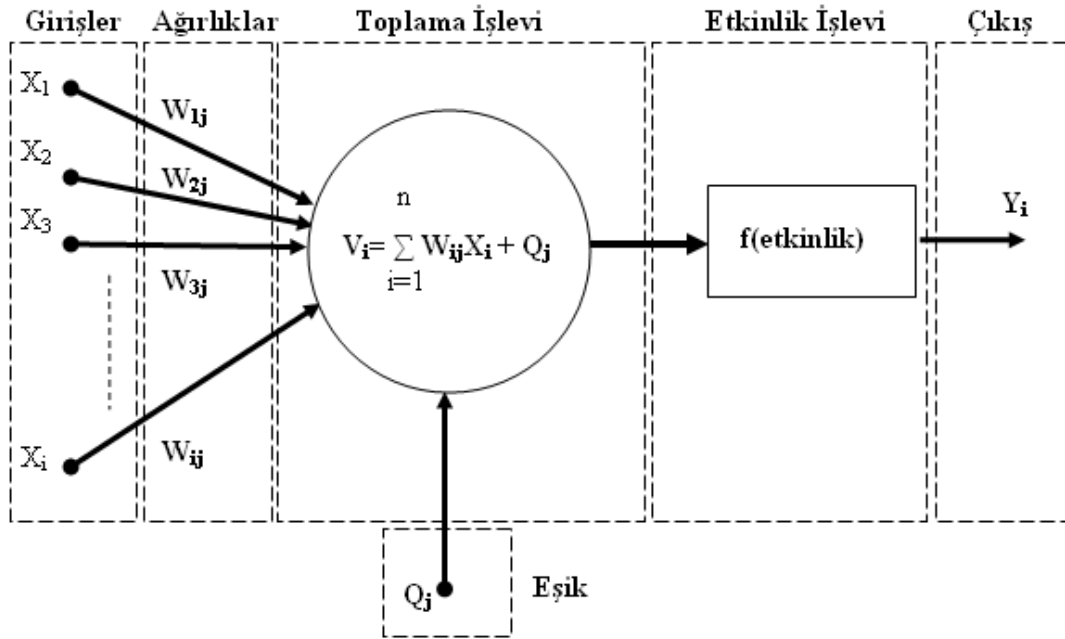
3.2.1. Yapay Sinir Hücresi (İşlem Elemanı)

İnsan beyninde öğrenme üç şekilde olmaktadır (Elmas, 2007, s.30);

- Yeni axonlar üreterek
- Axonların uyarılmasıyla
- Mevcut aksonların güçlerini değiştirerek

Yapay sinir hücreleri oluşturulurken de bu mantık gözetilmiştir. YSA'nın

temel birimi işlem elemanı ya da düğüm olarak adlandırılan yapay bir sinirdir. Aşağıda yapay bir sinir hücresi görülmektedir (Elmas, 2007, s.31):



Şekil 8. Yapay bir sinir (düğüm)

Burada girişler x_i sembolü ile gösterilmiştir. Bu girişlerin her biri w ağırlığı ile çarpılarak eşik değeri θ_j ile toplanır, sonucu oluşturmak için etkinlik işlevi ile işlem yapılır ve y_i çıkışı alınır. YSA'nın öğrenme yeteneği, seçilen öğrenme algoritmasının içinde ağırlıkların uygun bir şekilde ayarlanmasına bağlıdır.

Bir yapay sinir ağı ile biyolojik bir siniri karşılaştırsak aşağıdaki tabloyu elde ederiz.

Tablo 2. Biyolojik sinir ağı ile yapay sinir ağının karşılaştırılması

Biyolojik Sinir Ağı	Yapay Sinir Ağı
Sinir Sistemi	Sinirsel Hesaplama Sistemi
Sinir	Düğüm (Sinir, İşlem Elemanı)
Sinaps	Ağırlıklar
Dendrit	Toplama İşlevi
Hücre Gövdesi	Etkinlik İşlevi
Akson	Sinir Çıkışı

Girişler: Girişler (x_1, x_2, \dots, x_n) çevreden aldığı bilgiyi sinire getirir. Bunlar ağın öğrenmesi istenen örnekler tarafından belirlenir. Yapay sinir hücresine dış dünyadan olduğu gibi başka hücrelerden veya kendi kendisinden de bilgi gelebilir.

Ağırlıklar: Ağırlıklar (w_1, w_2, \dots, w_j) , girişlerin sinir üzerindeki etkisini belirleyen uygun katsayılardır. Her girişin kendine ait bir ağırlığı vardır. Ağırlıkların büyük ya da küçük olması veya negatif ya da pozitif olması önemli ya da önemsiz olduğu anlamına gelmez. Ağırlıklar değişken ya da sabit değerler alabilirler.

Toplama İşlevi: Toplama işlevi v_i , sinirde her bir ağırlığın ait olduğu girişlerle çarpımının toplamlarını eşik θ_j ile toplayarak etkinlik işlevine gönderir. Her durumda bu işlemin yapılması şart değildir. Literatürde pek çok farklı toplama fonksiyonu kullanılmaktadır. Aşağıdaki tabloda bazı toplama fonksiyonu örnekleri verilmiştir (Öztemel, 2003, s.50)

Tablo 3. Toplama fonksiyonu örnekleri

Net giriş	Açıklama
<i>Çarpım</i> $v_i = \prod_i G_i A_i$	Ağırlık değerleri girdiler ile çarpılır ve daha sonra bulunan değerler birbirleri ile çarpılarak net girdi hesaplanır.
<i>Maksimum</i> $v_i = \text{Max}(G_i A_i),$ $i=1 \dots N$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra en büyüğü yapay sinir hücresinin net girdisi olarak kabul edilir.
<i>Minimum</i> $v_i = \text{Min}(G_i A_i),$ $i=1 \dots N$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra en küçüğü yapay sinir hücresinin net girdisi olarak kabul edilir.
<i>Çoğunluk</i> $v_i = \sum_i \text{sgn}(G_i A_i)$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra pozitif veya negatif olanların sayısı bulunur. Büyük olan sayı hücrenin net girdisi olarak kabul edilir.
<i>Kümülatif toplam</i> $v_i = \text{Net}(\text{eski}) + \sum_i (G_i A_i)$	Hücreye gelen bilgiler ağırlıklı olarak toplanır ve daha önce gelen bilgilere eklenerek hücrenin net girdisi bulunur.

Etkinlik İşlevi (Aktivasyon Fonksiyonu): Toplama işlevinin sonucu etkinlik işlevinden $f(\text{etkinlik})$ geçirilip çıkışa iletilir. Etkinlik işlevinin kullanım amacı, zaman söz konusu olduğunda toplama işlevinin çıkışının değişmesine izin vermektir. Etkinlik işlevi olarak genellikle sigmoid fonksiyonu kullanılır. Sıklıkla kullanılan bazı etkinlik işlevleri aşağıdaki tabloda verilmiştir (Öztemel, 2003, s.51):

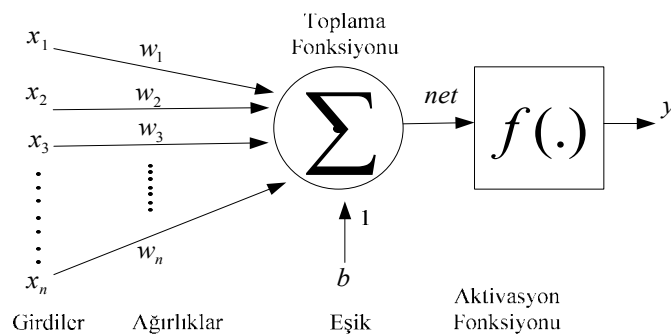
Tablo 4. Aktivasyon fonksiyonu örnekleri

Aktivasyon Fonksiyonu	Açıklama
Lineer fonksiyon $F(\text{NET})=\text{NET}$	Gelen girdiler olduğu gibi hücrenin çıktısı olarak kabul edilir.
Step Fonksiyonu $F(\text{NET})= \begin{cases} 1 & \text{eğer NET} > \text{eşik_değer} \\ 0 & \text{eğer NET} \leq \text{eşik_değer} \end{cases}$	Gelen NET girdi değerinin belirlenen bir eşik değerinin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerini alır.
Sinüs fonksiyonu $F(\text{NET})=\sin(\text{NET})$	Öğrenilmesi düşünülen olayların sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır.
Eşik değer fonksiyonu $F(\text{NET})= \begin{cases} 0 & \text{eğer NET} \leq 0 \\ \text{NET} & \text{eğer } 0 < \text{NET} < 1 \\ 1 & \text{eğer NET} \geq 1 \end{cases}$	Gelen bilgilerin 0 veya 1'den büyük veya küçük olmasına göre değer alır. 0 ve 1 arasında değerler alabilir, bunların dışında bir değer alamaz.
Hiperbolik tanjant fonksiyonu $F(\text{NET})=(e^{\text{NET}}+e^{-\text{NET}}) / (e^{\text{NET}}-e^{-\text{NET}})$	Gelen NET girdi değerinin tanjant fonksiyonundan geçirilmesi ile hesaplanır.
Sigmoid fonksiyonu $F(\text{NET})=1/(1+e^{-\text{NET}})$	En çok kullanılan aktivasyon fonksiyonudur.

Çıkış: Çıkış $y_i=f(s)$, etkinlik işlevi tarafından belirlenen çıktı değeridir. Üretilen çıktı dış dünyaya gönderilebilir veya herhangi bir sayıdaki diğer sınırlara giriş olabilir.

3.2.2. Basit Algılayıcı Modeli (Perseptron)

İlk defa 1958 yılında Rosentblatt tarafından örüntü sınıflandırma amacıyla geliştirilen perseptron bir sinir hücresinin birden fazla girdiyi alarak bir çıktı üretmesi prensibine dayanmaktadır. Ağın çıktısı bir veya sıfırdan oluşan mantıksal (boolean) bir değerdir. Perseptronun yapısı aşağıdaki şekilde görüldüğü gibidir (Öztemel, 2003, s.61):

**Şekil 9.** Basit Algılayıcı Modeli (Perseptron)

3.3. YAPAY SINİR AĞLARININ ÖZELLİKLERİ

YSA insan beyninin fonksiyonel özelliklerine benzer şekilde öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi konularda başarılı şekilde uygulanmaktadır. YSA'nın bazı karakteristik özellikleri vardır. Bunlardan bazıları şu şekilde sıralanabilir (Öztemel, 2003, s.31; Elmas, 2007, s.26; Haykin, 1999, s.24-26):

- Yapay sinir ağları makine öğrenmesi gerçekleştirirler.
- Programları, çalışma stili bilinen programlama yöntemlerine benzememektedir.
- Yapay sinir ağlarında bilgi ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır.
- Nanlineerlik özelliğine sahiptir. Bir yapay sinir lineer veya nanlineer olabilir.
- Sinir ağları sinaptik ağırlıklarını değişen çevre koşullarına adapte edebilme yani uyum sağlama yeteneğine sahiptirler.
- Paralel yapıları hızlı hesaplama yapmalarını sağlar. Aynı özellik VLSI (çok büyük ölçekli integre) teknolojisi kullanan uygulamalar için uygun olmalarını sağlar.
- Yapay sinir ağları örnekleri kullanarak öğrenirler.
- Yapay sinir ağlarının güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekmektedir.
- Görülmemiş örnekler hakkında bilgi üretebilirler.
- Algılamaya yönelik olaylarda kullanılabilirler.
- Şekil (örüntü) ilişkilendirme ve sınıflandırma yapabilirler.
- Örüntü tamamlama yapabilirler.
- Kendi kendini organize etme ve öğrenebilme yetenekleri vardır.
- Eksik bilgi ile çalışabilirler.
- Hata toleransına sahiptirler.
- Belirsiz, tam olmayan verileri işleyebilirler.
- Dağıtık belleğe sahiptirler.

- Sadece nümerik bilgilerle çalışabilirler.
- Matematiksel modele ihtiyaç duymazlar.
- Kural tabanı kullanımı gerektirmezler.

YSA'nın bu özelliklerini üstünlük veya avantaj olarak düşünürsek dezavantajlarını da belirtmek gerekir. Bunları da şu şekilde sıralayabiliriz (Öztemel, 2003, s.34; Elmas, 2007, s.26):

- Probleme uygun ağ yapısının belirlenmesi deneme yanılma yoluyla yapılmaktadır.
 - Bazı ağlarda ağın parametrelerinin (öğrenme katsayısı, her katmanda olması gereken işlem elemanı sayısı, katman sayısı vb.) belirlenmesinde genel bir kural yoktur.
 - Ağın eğitiminin ne zaman bitirileceğine karar vermek için geliştirilmiş bir yöntem yoktur.
 - Sistem içinde ne olduğu bilinemez.
 - Bazı ağlar hariç kararlılık analizleri yapılamaz.

3.4. YAPAY SİNİR AĞLARININ SINIFLANDIRILMASI

3.4.1. Mimariye Göre

3.4.1.1. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli yapay sinir ağları katmanlar şeklinde organize edilir. Katmanlı ağın en basit şeklinde, çıkış katmanına girişleri yansıtan bir giriş katmanı ve bunları işleyen bir çıkış katmanı yer alır ve bu ağlar ileri yönde işlenir. Bu tür ağlar tek-katmanlı ağlar olarak isimlendirilir. Buradaki tek katmandan kasıt çıkış katmanıdır. Giriş katmanında herhangi bir işlem yapılmadığından bu katman sayılmaz (Haykin, 1999, s.43).

1969 yılında Minski ve Popert bir algılayıcının (perseptron) kısıtlamaları ve yeteneklerinden bahsettikleri kitaplarında algılayıcının iki durumlu XOR problemini

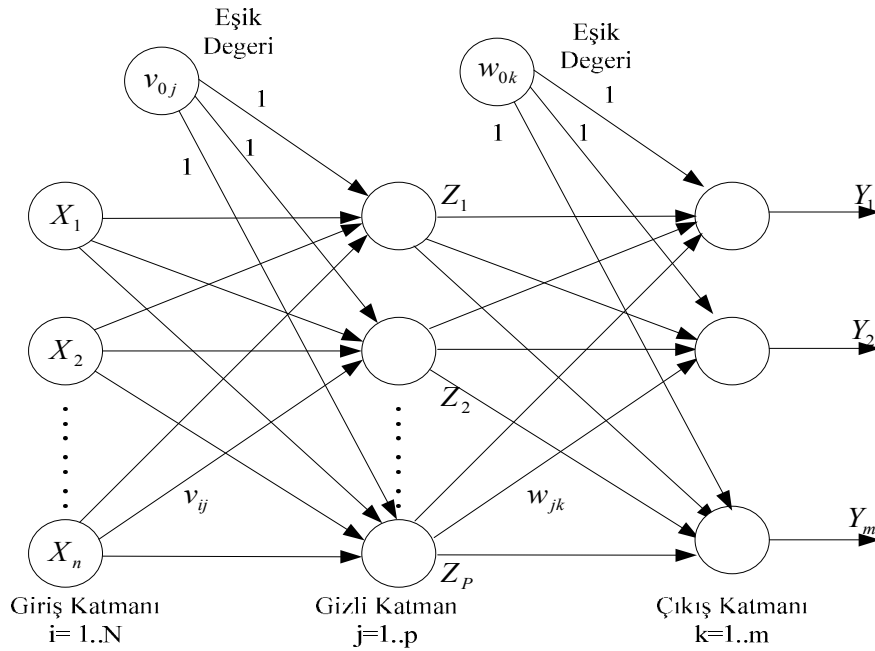
veya bunun tümleyeni olan iki durumlu XNOR problemini çözemediğini belirtmişlerdir (Graupe, 2007, s.23). Gerçekten de tek katmanlı sınıflandırıcıların çözemediği pek çok tip problem vardır. Bu nedenle çok katmanlı ileri beslemeli ağlar ortaya çıkmıştır. Bu ağlarda giriş ve çıkış katmanları arasında bir veya daha fazla gizli katman bulunur ki bu katmandaki düğümler gizli nöron olarak adlandırılır.

Reel değerli n boyutlu giriş vektöründe j gizli katman siniri, i girdisini w_{ij} ($i=1,2,\dots,n; j=1,2,\dots$) ağırlığına göre alır. j birimi x girdi işaretinin ve w_{ij} ağırlıklarının bir fonksiyonunu hesaplayıp sonucu sonraki tüm komşu sinirlere iletir. İlk gizli katman gibi ikinci gizli katman sinirleri de ağırlıklarla önceki katmana tam bağlıdır. Bu sinirler de girişlerin ve giriş ağırlıklarının bir fonksiyonunu hesaplayıp sonucu sonraki aşamaya aktarır ve bu işlem ağına geri kalanı için de bu şekilde devam eder. Ağına her katmanındaki nöronlar giriş olarak sadece önceki katmanın çıkışını kullanır (Haykin, 1999, s.43-44; Elmas, 2007, s.56).

Rosentblatt'ın basit algılayıcı modelini ortaya atmasından sonraki yıllarda çok katmanlı ileri beslemeli ağların birçok çeşidi önerilmiştir. Bunlardan bazıları MLP (Multi Layer Perseptron) ve RBF (Radial Basis Function) ağlarıdır.

3.4.1.1.1. MLP (Multi Layer Perseptron- Çok Katmanlı Algılayıcı)

MLP ağlarında nöronlar katmanlar şeklinde organize edilmiştir. MLP'de ilk katman girdi katmanıdır. Girdi katmanı, çözülmesi istenilen probleme ilişkin bilgilerin YSA'ya alınmasını sağlar. Diğer katman ise ağ içerisinde işlenen bilginin dışarıya iletildiği çıktı katmanıdır. Girdi ve çıktı katmanlarının arasında yer alan katmana ise gizli katman adı verilir. MLP ağlarında birden fazla gizli katman da bulunabilir.



Şekil 10. MLP Yapay Sinir Ağı

MLP ağlarında çıkış değerleri şu şekilde hesaplanır:

$$y_t = w_o + \sum_{j=1}^p w_j f \left(v_{0j} + \sum_{i=1}^N v_{ij} y_{t-i} \right) + e_t \quad (3.1)$$

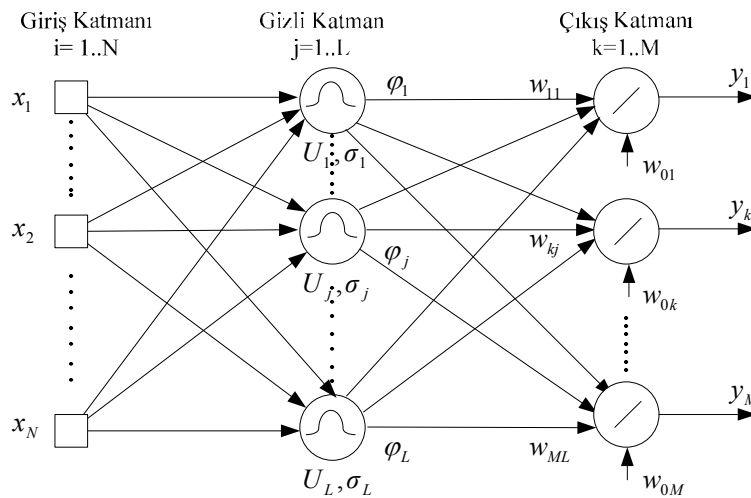
Bir MLP ağının mimarisi tasarlanırken belirlenmesi gereken en önemli üç şey; giriş düğümü sayısı, gizli katman sayısı ve bu katmanda kaç düğüm olacağı ve çıkış düğümü sayısıdır. Optimum YSA mimarisini belirlemek için pruning algoritması, polinomial zaman algoritması, kanonik ayrıştırma tekniği ve ağ bilgi kriteri gibi yaklaşımlar olmasına rağmen bu metotlar oldukça karmaşık ve uygulaması zordur. Üstelik hiçbirisi gerçek tahmin problemleri için optimum çözümü garanti edemez. Bu parametrelerin belirlenmesi için basit ve kesin bir metot bulunmamaktadır. Bu nedenle deneme yanılma yolu kullanılmaktadır (Zhang, Patuwo ve Hu, 1998).

YSA'nın öğrenmesi, işlem elemanlarının sahip olduğu ağırlıkların, seçilen eğitim algoritmalarıyla değiştirilmesi ile yapılmaktadır. Anlaşılması kolay ve matematiksel olarak ispatlanabilir olmasından dolayı MLP ağlarının eğitiminde geri yayılım (Backpropagation) algoritması kullanılmaktadır.

3.4.1.1.2. RBFN (Radial Basis Function Networks - Radyal Tabanlı Fonksiyon Ağları)

Sinir ağlarında gizli birimler, giriş vektörleri için gelişigüzel bir taban oluşturan fonksiyonlar kümesi sağlar ki bu fonksiyonlara radyal tabanlı fonksiyonlar denir (Haykin, 1999, s.278). Radyal tabanlı fonksiyon ağları 1980'lerin sonunda YSA'nın bir çeşidi olarak ortaya çıkmış ve eğri uydurma ve lineer olmayan problemleri sınıflandırma başarısından dolayı son yıllarda popülerlik kazanmıştır (Bors, 2001).

RBF'ler en basit haliyle her bir gizli birimin bir aktivasyon fonksiyonunu uyguladığı üç katman şeklinde organize edilir. Kaynak düğümlerden oluşan giriş katmanı ağın çevre ile olan bağlantısını sağlar. İkinci katman yani ağda bulunan tek gizli katman giriş alanından gizli alana nonlineer dönüştürme yapar. Giriş katmanından orta katmana dönüşüm, radyal tabanlı aktivasyon fonksiyonları ile doğrusal olmayan sabit bir dönüşümdür. Orta katmandan çıkış katmanına ise uyarlamalı ve doğrusal bir dönüşüm gerçekleştirilir. Ağın, girişe uygulanan aktivasyon sinyaline yanıtını sağlayan çıkış katmanı ise lineerdir. Gizli alanın boyutu, ağın iyi bir giriş-çıkış eşlemesine yakınsama kapasitesi ile doğrudan ilgilidir. Gizli alanın boyutu ne kadar yüksek olursa, yakınsamanın doğruluğu da o kadar iyi olacaktır (Haykin, 1999, s.279).



Şekil 11. RBF Yapay Sinir Ağı

RBFN tasarımı çok boyutlu uzayda eğri uydurma yaklaşımıdır ve bu nedenle RBFN'nin eğitimi, çok boyutlu uzayda eğitim verilerine en uygun yüzeyi bulma problemine dönüşür. RBFN'nin genellemesi test verilerini interpolate etmek amacıyla, eğitim sırasında bulunan çok boyutlu yüzeyin kullanılmasına eşdeğerdir. Radyal tabanlı fonksiyonlar, sayısal analizde çok değişkenli interpolasyon problemlerinin çözümünde kullanılmış ve YSA'nın gelişmesi ile birlikte bu fonksiyonlardan YSA tasarımında yararlanılmıştır.

Gizli katmandaki fonksiyon giriş bölgesel bir yanıt üretir ve genellikle gizli katman nöronlarını Gaussian fonksiyonu ile kullanır, bu durumda gizli birimlerin (j) aktivasyon seviyeleri φ_j şekilde hesaplanır (Kim, Byun ve Kwon, 2006):

$$\varphi_j = \exp\left[-\frac{\|x - c_j\|^2}{\sigma_j^2}\right] \quad (3.2)$$

Burada x giriş vektörü, c_j , j gizli biriminin merkezi, σ_j , verinin dağılımını gösteren genişlik katsayısı $\|\cdot\|$ uzaklık fonksiyonudur. Gizli birimin çıkışları 0 ile 1 arasındadır. Girişin merkeze uzaklığı azaldıkça, düğümün yanıtı artar. Elde edilen φ_j değerleri w_{kj} ağırlıkları ile çarpılıp toplanarak ağırlık çıkışı hesaplanır (Ranaweera, Hubele ve Papalexopoulos, 1995):

$$y_k = \sum_{j=1}^L \varphi_j w_{kj} + w_{k0} \quad (3.3)$$

Burada L , gizli katmandaki düğümlerin (fonksiyonların) sayısı, y_k , çıkış katmanındaki j . düğümün k . giriş için çıkışı, w_{kj} , k . RBF birimi ile j . çıkış düğümü arasındaki ağırlık, w_{k0} ise k . düğümdeki bias terimidir.

RBFN'de uyarlanabilecek serbest parametreler; merkez vektörleri, radyal fonksiyonların genişliği ve çıkış katman ağırlıklarıdır. RBF ağırlığının performansını kritik olarak gizli birimlerin sayısı ve merkezlerinin seçimine bağlıdır. Geleneksel eğitim yöntemlerinin birçoğu önce tasarımcının ağırlık yapısını belirlemesini daha

sonra model parametrelerinin hesaplanması ile devam edilmesini gerektirir. Merkezleri belirlemenin bir yolu eğitim kümesindeki her verinin bir merkez olarak belirlenmesidir. Eğer veri gürültü içeriyorsa bu durumda ağırlık genelleme yeteneğini oldukça körelten ezberleme problemi ortaya çıkar. Genelleme performansını arttırabilmek için bazı yaklaşımlarda eğitim iki aşamada gerçekleştirilir: ilk önce gizli katman merkezleri belirlenir daha sonra gizli katman ile çıkış katmanı arasındaki ağırlıklar hesaplanır (Ding, Xiao ve Yue, 2005, s.119).

MBF parametrelerinin belirlenmesi için pek çok yöntem kullanılmaktadır. Bunlardan bazıları şu şekildedir (Haykin, 1999, s.320):

-Merkez vektörlerinin rastgele belirlenmesi: En basit yaklaşım merkezlerin veri seti içerisinde rastgele seçilmesidir. Bunun için merkezlerin yayılımına göre standart sapması sabit olan *isotropic* Gaussian fonksiyonu kullanılabilir. Merkezi t_i olan radyal tabanlı bir fonksiyon şu şekilde tanımlanır:

$$G(\|x - t_i\|^2) = \exp\left(-\frac{m}{d_{\max}^2} \|x - t_i\|^2\right) \quad i=1, 2, \dots, m \quad (3.4)$$

Burada m merkezlerin sayısı, d_{\max} ise seçilen merkezler arasındaki maksimum uzaklıktır.

Tüm radyal tabanlı fonksiyonlar için σ standart sapması aşağıdaki formül ile sabitlenir. Böylece fonksiyonun çok fazla sıçrama yapması ya da düz ilerlemesi önlenmiş olur.

$$\sigma = \frac{d_{\max}}{\sqrt{2m}} \quad (3.5)$$

Bu yaklaşımda öğrenilmesi gereken tek parametre çıkış katmanındaki lineer ağırlıklardır. Bunu yapmanın en iyi yolu da pseudoinverse metodunu kullanmaktır (Broomhead ve Lowe, 1988).

-Merkez vektörlerinin kendinden uyarlamalı seçilmesi: Rastgele seçim metodunun temel problemi tatmin edici düzeyde bir performans için büyük bir eğitim

kümesi gerektirmesidir. Bunun üstesinden gelmenin bir yolu iki aşamadan oluşan hibrit bir öğrenme süreci kullanmaktır.

İlk aşama olan kendinden uyarlamalı öğrenme aşamasında gizli katmandaki radyal tabanlı fonksiyonların merkezleri için uygun tahmini merkezler belirlenir. Bunun için veri setini mümkün olduğu kadar homojen alt gruplara ayıran k-ortalamalar ve kendinden uyarlamalı ağlar (SOM) gibi kümeleme algoritmaları kullanılır.

-Merkez vektörlerinin danışmansız öğrenme ile seçilmesi: Bu yaklaşımda fonksiyon merkezleri ve diğer tüm serbest parametreler danışmanlı öğrenme sürecine sokulur. Bunun için gradient-descent prosedürünü uygulayan ve LMS (en küçük karelerin ortalaması) algoritmasının geliştirilmiş hali olan hata düzeltme (error-correction) kullanılır.

3.4.1.1.3. MLP ve RBF Ağlarının Karşılaştırılması

Bir MLP ağının yaptığı işin birebir aynısını yapan bir RBF ağının daima bulunmasına karşın bu iki ağın bir takım farklılıkları da mevcuttur. Bunları şu şekilde sıralayabiliriz (Haykin, 1999, s.315):


1. En basit haliyle bir RBF ağının bir gizli katmanı varken MLP ağında bir ya da birden fazla gizli katman bulunabilir.
2. Bir MLP ağının gizli ya da çıkış katmanlarında bulunan hesaplama düğümleri aynı sinirsel modeli paylaşırken, RBF ağının gizli katmanında bulunan hesaplama düğümleri çıkış katmanındakilerden tamamen farklıdır ve farklı bir amaca hizmet eder.
3. RBF ağında gizli katman nanlineerken çıkış katmanı lineerdir. Örüntü sınıflandırmada kullanılan MLP ağlarında ise genellikle her ikisi de nanlineerdir. MLP ağı nanlineer regresyon problemlerini çözmeye kullanıldığında ise çıkış katmanının lineer olması tercih edilir.
4. Bir RBF ağının her gizli birimindeki aktivasyon fonksiyonu giriş vektör ve o birimin merkezi arasındaki Öklit uzaklığını hesaplar. Bir MLP ağının her bir gizli birimindeki aktivasyon fonksiyonu ise giriş vektörünün iç çarpımını ve o

birimin ağırlık vektörünü hesaplar.

5. MLP ağları nanlineer giriş çıkış eşleşmesi için global yakınsama yaparken RBF ağları üssel azalan bölgesel nanlineerlikleri kullanarak lokal yakınsama yapar. Yani aynı derecede doğruluk için MLP, RBF'ye göre daha az sayıda parametre gerektirir.

3.4.1.2. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli ağ mimarileri, genellikle danışmansız öğrenme kurallarının uygulandığı ağlarda kullanılmaktadır. Geri beslemeli yapay sinir ağlarında, en az bir işlemci elemanın çıktısı, kendisine ya da diğer işlemci elemanlara girdi olarak verilmekte ve genellikle geri besleme, bir geciktirme elemanı (ara katman veya çıktı katmanındaki aktivasyon değerlerini, bir sonraki iterasyona girdi olarak taşımakla görevli eleman) üzerinden yapılmaktadır. Geri besleme, bir katmandaki işlemci elemanlar arasında olduğu gibi katmanlar arasındaki işlemci elemanlar arasında da olabilmektedir. Bu yapısı sayesinde geri beslemeli yapay sinir ağları, doğrusal olmayan dinamik bir davranış gösterirler. Bu sayede, geri beslemenin yapılış şekline göre farklı yapı ve davranışta geri beslemeli yapay sinir ağları elde edilebilir.



Şekil 12. Geri Beslemeli Yapay Sinir Ağı

Geri beslemeli ağlara örnek olarak Hopfield, Elman ve Jordan ağları verilebilir.

3.4.2. Öğrenme Yöntemlerine Göre

3.4.2.1. Yapay Sinir Ağlarında Öğrenme

İnsan beyni doğumdan sonraki gelişme sürecinde çevresinden duyu organlarıyla algıladığı davranışları yorumlar ve bu bilgileri diğer davranışlarında kullanır. Yaşadıkça beyin gelişir ve tecrübelenir. Artık olaylar karşısında nasıl tepki göstereceğini çoğu zaman bilmektedir. Fakat hiç karşılaşmadığı bir olay karşısında yine de tecrübesiz kalabilir.

Yapay sinir ağlarının öğrenme sürecinde de, tıpkı dış ortamdan gözle veya vücudun diğer organlarıyla uyarıların alınması gibi dış ortamdan girişler alınır, bu girişlerin beyin merkezine iletilerek burada değerlendirilip tepki verilmesi gibi yapay sinir ağında da aktivasyon fonksiyonundan geçirilerek bir tepki çıkışı üretilir. Bu çıkış yine tecrübeyle verilen çıkışla karşılaştırılarak hata bulunur. Çeşitli öğrenme algoritmalarıyla hata azaltılıp gerçek çıkışa yaklaşılmaya çalışılır. Bu çalışma süresince yenilenen yapay sinir ağının ağırlıklarıdır. Ağırlıklar her bir çevrimde yenilenerek amaca ulaşılmaya çalışılır. Eğitim algoritması hata kareleri toplamı (SSE) ya da ortalama hata kareleri (MSE) gibi hata ölçüm kriterlerini minimize eden ağırlıkları bulmak için kullanılır. Yani ağ eğitimi aslında kısıtsız nanlineer minimizasyon problemidir (Zhang, Patuwo ve Hu, 1998). Eğer yapay sinir ağı verilen giriş-çıkış çiftleriyle amaca ulaşmış ise ağırlık değerleri saklanır. Ağırlıkların sürekli yenilenip istenilen sonuca ulaşılan kadar geçen zamana öğrenme adı verilir (Güngör ve Tortum, 2007, s.45).

Açıklayıcı ya da nedensel bir tahmin problemi için YSA girişleri genellikle bağımsız değişken ya da tahmin değişkenidir. YSA tarafından tahmin edilen fonksiyonel ilişki şu şekilde yazılabilir (Zhang, Patuwo ve Hu, 1998):

$$y = (x_1, x_2, \dots, x_p) \quad (3.6)$$

Burada x_1, x_2, \dots, x_p , p sayıda bağımsız değişken; y ise bağımlı değişkendir. Diğer taraftan zaman serisi tahmin problemleri için girişler serinin geçmiş gözlemleri, çıkışlar ise gelecek değerler olmaktadır. Bu fonksiyon şu şekilde

yazılabilir:

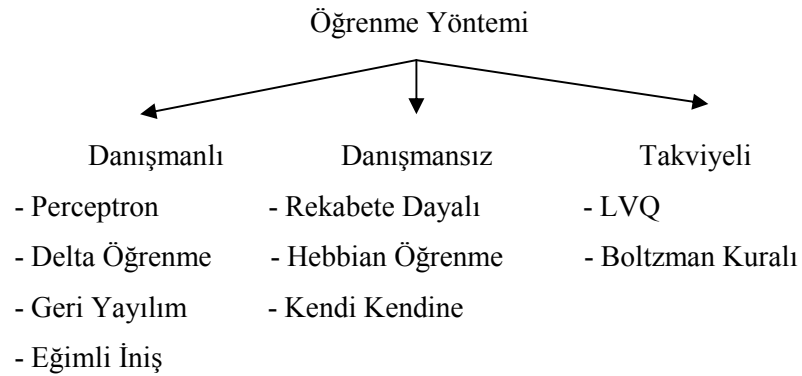
$$y(t+1) = f(y_t, y_{t-1}, \dots, y_{t-p}) \quad (3.7)$$

y_t , t zamanındaki gözlemdir.

Ağın eğitimi tamamlandıktan sonra öğrenip öğrenmediğini (performansını) ölçmek için yapılan denemelere ise, ağın “test edilmesi” denmektedir. Test etmek için ağın öğrenme sırasında görmediği örneklerden yararlanır. Ağ, eğitim sırasında belirlenen bağlantı ağırlıklarını kullanarak görmediği bu örnekler için çıktılar üretir. Elde edilen çıktılar doğruluk değerleri ağın öğrenmesi hakkında bilgiler verir. Sonuçlar ne kadar iyiye, eğitim performansının da o kadar iyi olduğunu gösterir. Eğitimde kullanılan örnek setine “eğitim seti”, test için kullanılan sete ise “test seti” adı verilmektedir (Öztemel, 2003, s.55-56).

Temelde öğrenme yöntemleri danışmanlı (supervised), danışmansız (unsupervised) and takviyeli (reinforcement) olmak üzere üç gruba ayrılmıştır (Öztemel, 2003, s.25).

Öğrenme stratejileri aşağıdaki şekilde gösterilebilir (Elmas, 2007, s.87):

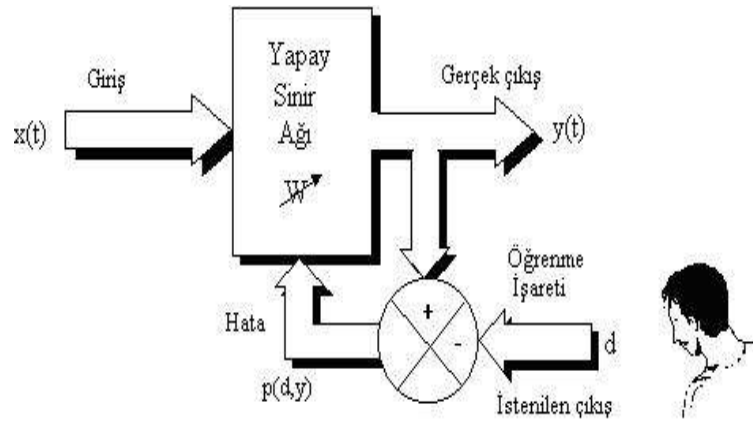


Şekil 13. Öğrenme Yöntemleri

3.4.2.2. *Danışmanlı Öğrenme*

Yapay sinir ağlarında en fazla kullanılan öğrenme metodu olan danışmanlı öğrenmede sistemin olayı öğrenebilmesine bir öğretmen yardımcı olmaktadır.

Öğretmen sisteme öğrenilmesi istenen olay ile ilgili örnekleri girdi/çıkı seti olarak verir. Her örnek için hem girdiler hem de o girdiler karşılığında oluşturulması gereken çıktılar sisteme gösterilir. Sistemin görevi girdileri öğretmenin belirlediği çıktılara haritalamaktır. Öğretmen eğitim kümesini ve hata değerini belirleyerek eğitimin ne kadar devam edeceğine karar verir. Hata değeri istenilen değerin altına düştüğünde tüm ağırlıklar sabitlenerek eğitim işlemi sonlandırılır.



Şekil 14. Danışmanlı Öğrenme

Danışmanlı öğrenmeye çok katmanlı algılayıcı (MLP), geriye yayılım (backpropagation), delta kuralı, en küçük karelerin ortalaması (LMS) ve ADALINE örnek verilebilir.

3.4.2.2.1. Geriye Yayılım (Backpropagation) Algoritması

Geri yayılım ağı Geoffrey Hinton ve James McClelland tarafından geliştirilmiştir (Elmas, 2007, s.114) ve hataları çıkıştan girişe geriye doğru azaltmaya çalışmasından dolayı geri yayılım adını almıştır. Tahmin için kullanılan yapay sinir ağları içinde de en yaygın olarak kullanılan öğrenme algoritmasıdır. Geri yayılım algoritması verilen bir x giriş vektörü için beklenen çıkışın bilindiği danışmanlı öğrenme yönteminin kullanıldığı ağlar için uygundur ve ileri beslemeli ve çok katmanlı bir ağ mimarisi gerektirmektedir. Çok katmanlı ağlar giriş, çıkış ve en az bir gizli katman olmak üzere üç katmandan oluşurlar. Gizli katman sayısı veya bu katmandaki düğüm sayısı değiştirilebilir. Düğüm sayısının artması ağın hatırlama yeteneğini arttırmakla beraber öğrenme işleminin süresini uzatır (Elmas, 2007,

s.114). Eğer az sayıda gizli katman kullanılırsa ağ öğrenmeyi başaramaz. Gereğinden fazla gizli katman bulunması halinde ise ağ ezberler, bu da ağın genelleme yeteneğini azaltır. Geri yayılım algoritmasında hata ağdaki ağırlıkların bir fonksiyonu olarak görülür. Ağın ürettiği çıkış değeri y_k ve beklenen çıkış değeri t_k olmak üzere hata fonksiyonu şu şekilde tanımlanır (Rojas, 1996, s.156):

$$E = \frac{1}{2} \sum_{k=1}^m (y_k - t_k)^2 \quad (3.8)$$

Öğrenme sürecine genellikle ağırlık değerlerine rastgele küçük değerler atanarak başlanır. Örnekler ağa öğretilir ve ağa hedef değeri verilir. Her örnek için ağın çıktığı değeri ile beklenen değer karşılaştırılır. Hata değeri, ağa tekrar geri besleme şeklinde verilir. Örnek setindeki hata kareleri toplamını azaltmak için nöronlar arasındaki bağlantı ağırlıkları değiştirilir. x giriş vektörü olan bir yapay sinir ağı için geri yayılım algoritması iki aşamada gerçekleştirilir (Rojas, 1996, s.161):

İleri Besleme: x girişi ağa verilir. Düğümlerdeki temel fonksiyonlar ve türevleri her düğümde hesaplanır ve türevler depolanır.

Geriyayılım: Çıkış birimine 1 sabit değeri verilir ve ağ geriye doğru işler. Düğüme gelen bilgi toplanır ve sonuç, birimin solunda depolanan değerle çarpılır. Elde edilen sonuç sola doğru aktarılır. Giriş katmanında toplanan sonuç ağ fonksiyonunun x 'e göre türevidir.

Öğrenme algoritması olarak geriyayılım algoritması seçildiğinde iki parametre önem kazanmaktadır. Bunlar öğrenme katsayısı η , (learning rate) ve momentum terimi α 'dır. Bu algoritma ile i ve j . kat düğümleri arasındaki ağırlıklardaki $\Delta w_{ij}(t)$ değişikliği şu şekilde hesaplanır (Basheer ve Hajmeer, 2000):

$$\Delta w_{ij}(t) = \eta \cdot \delta_j \cdot x_i + \mu \Delta w_{ij}(t-1) \quad (3.9)$$

η : Öğrenme katsayısıdır. Öğrenme katsayısı, ağırlıkların bir sonraki düzeltmede hangi oranda değiştirileceğini göstermektedir. Küçük öğrenme katsayıları, ağın sonuca ulaşmasını yavaşlatır. Büyük öğrenme katsayıları, ağın

sonuca daha kısa sürede ulaşmasını sağlar. Bununla birlikte çok yüksek oranlar ağıın hesaplamalarında büyük salınımlara neden olur ve ağıın dip noktayı bulmasını engelleyebilir. Öğrenme katsayısı için tipik değerler 0,01 ile 0,9 arasında değişir. Karmaşık ve zor çalışmalar için küçük öğrenme katsayıları seçilmesi önerilir.

μ : Momentum katsayısıdır. Momentum terimi, ağıdaki salınımları engellemeye ve ağıın hata yüzeyindeki bölgesel minimum noktalardan kaçarak, daha dip noktalara ulaşmasına yardımcı olur. Optimal öğrenme oranı ve momentum teriminin belirlenmesi büyük ölçüde deneysel ve sezgisel bir özellik taşır. Ayrıca bu parametreler büyük ölçüde ilgilenilen sorun alanına bağlı olarak değişiklik gösterir.

δ_j : Ara veya çıkış katındaki herhangi bir j nöronuna ait bir faktördür. Çıkış katı için bu faktör aşağıdaki şekilde verilir:

$$\delta_j = \frac{\partial f}{\partial net_j} (y_j^{(t)} - y_j) \quad (3.10)$$

Burada,

$net_j = \sum x_j w_{ji}$ ve y_j' ise j düğümünün hedef çıkışıdır. Ara katlardaki nöronlar için ise bu faktör:


$$\delta_j = \frac{\partial f}{\partial net_j} \sum w_{qi} \delta_q \quad (3.11)$$

olarak hesaplanır. Ara katlardaki düğümler için herhangi bir hedef çıkış olmadığından, eşitlik 3.8 yerine eşitlik 3.9 kullanılır. Bu duruma bağlı olarak çıkış katından başlayarak δ_j faktörü, bütün katlardaki düğümler için hesaplanır. Daha sonra eşitlik 3.7'deki formüle bağlı olarak, bütün bağlantılar için ağırlıkların güncelleştirilmesi gerçekleştirilir.

3.4.2.3. *Danışmansız Öğrenme*

Danışmansız öğrenmede sistemin doğru çıkış hakkında bilgisi yoktur ve girişlere göre kendi kendisini örnekler. Danışmansız olarak eğitilebilen ağlar isenen

ya da hedef çıkış olmadan giriş bilgilerinin özelliklerine göre ağırlık değerlerini ayarlar. Ağ istenen dış verilerle değil girilen bilgilerle çalışır. Bu tür öğrenmede gizli sinirler dışarıdan yardım almaksızın kendilerini örgütlemek için bir yol bulmalıdır. Yalnız sistemin öğrenmesi bittikten sonra çıktılarının ne anlama geldiğini gösteren etiketlendirmenin kullanıcı tarafından yapılması gerekir.



Şekil 15. Danışmansız Öğrenme

Danışmansız öğrenmeye yarışmacı öğrenme (competitive learning), Kohonen'in özörgütlemeli harita ağları (SOM), Hebbian öğrenme ve Grossberg öğrenme kuralları örnek verilebilir.

3.4.2.4. Takviyeli Öğrenme

Takviyeli öğrenme de danışmanlı öğrenmeye yakın bir metottur. Bu stratejide de öğrenen sisteme bir öğretmen yardımcı olur. Fakat öğretmen her girdi seti için üretilmesi gereken çıktı setini sisteme göstermek yerine sistemin kendisine gösterilen girdilere karşılık çıktısını üretmesini bekler ve üretilen çıktının doğru veya yanlış olduğunu gösteren bir sinyal üretir. Sistem öğretmenden gelen bu sinyali dikkate alarak öğrenme sürecini devam ettirir ya da durdurur. LVQ ağları ve Hilton ve Sejnowski tarafından geliştirilen Boltzman kuralı takviyeli öğrenmeye örnek verilebilir.

3.5. YAPAY SİNİR AĞLARININ ZAMAN SERİSİNDE KULLANIMI

YSA'nın performansını etkileyen modelleme konular dikkatlice gözden

geçirilmelidir. En kritik kararlardan biri katman sayısı, her katmanda kaç düğümün olacağı ve düğümlerle iletişimde olan arkların sayısı gibi konuları kapsayan uygun mimariyi belirlemedir. Ağ tasarımı yapılırken belirlenmesi gereken diğer konular ise gizli katman ve çıkış katmanındaki aktivasyon fonksiyonunun seçimi, öğrenme algoritması, veri dönüştürme ve normalizasyon metodu, eğitim ve test kümeleri ve performans ölçütleridir.

Optimum YSA mimarisini belirlemek için pruning algoritması, polinomial zaman algoritması, kanonik ayrıştırma tekniği ve ağ bilgi kriteri gibi yaklaşımlar olmasına rağmen bu metotlar oldukça karmaşık ve uygulaması zordur. Üstelik hiç birisi gerçek tahmin problemleri için optimum çözümü garanti edemez. Bu parametrelerin belirlenmesi için basit ve kesin bir metot bulunmamaktadır. Bu nedenle deneme yanılma yolu ve zamanla kazanılan tecrübeler kullanılmaktadır (Zhang, Patuwo ve Hu, 1998).

Aşağıdaki tabloda aşırı değerler alan yapay sinir ağı parametrelerinin ağın yakınsama ve genelleme yeteneği üzerindeki etkileri gösterilmiştir (Basheer ve Hajmeer, 2000):

Tablo 5. Aşırı değerler alan tasarım parametrelerinin ağın yakınsama ve genelleme yeteneği üzerindeki etkileri

Tasarım Parametresi	Çok Yüksek	Çok Düşük
Gizli düğümlerin sayısı	Ezberleme (Genelleme yok)	YSA verideki kuralları elde edemez yani öğrenemez.
Öğrene oranı (η)	YSA kararsızdır optimum çözüm etrafında salınım yapar.	Yavaş öğrenme
Momentum katsayısı (μ)	Lokal minimumlara takılma riski azalır, eğitim süresi kısalır ancak çözümü kaçırma riski artar (kararsızlık).	Lokal minimumlara takılma riski artar, eğitim süresi uzar.
Öğrenme döngüsü sayısı	Ağın hatırlama yeteneği artar ancak öğrenilmemiş veriye genelleme yapamaz.	Veriyi temsil edemeyen bir YSA
Öğrenme kümesi büyüklüğü	Ağın hatırlama ve genelleme yeteneği artar	YSA problemi çözemez genelleme yeteneği azalır
Test kümesi büyüklüğü	YSA'nın genelleme yeteneğini doğrulama imkânı	YSA'nın genelleme yeteneğini yetersiz doğrulama

3.5.1. Ağ Yapısını Belirleme

Uygun yapay sinir ağı yapısının seçimi uygulama problemine bağlıdır. Bunun içinde yapay sinir ağları yapılarının hangi tip uygulama problemlerinde başarılı olacağını önceden bilinmesi faydalıdır. Şu ana kadar yapılan çalışmalardan elde edilen sonuçlara göre kullanılan ağ yapıları aşağıdaki tabloda verilmiştir (Elmas, 2007, s.162):

Tablo 6. Yapay sinir ağları uygulama alanları

Uygulama	Ağ Türü
Tahmin	-Geri Yayılım Ağı -Delta Bar Delta -Genişletilmiş Delta Bar Delta -Yüksek Seviyeli Ağlar -Özörgütlemeli Harita Ağı -Perceptron
Sınıflandırma	-Geri Yayılım Ağı -Öğrenme Vektörü Nicelemesi -Perceptron -Olasılıksal Sinir Ağları -Kohonen Ağı -Boltzman Makinesi
Veri Birleştirilmesi	-Hopfield -Boltzman Makinesi -Hamming Ağı -İki Yönlü Çağırışım Belleği -Yığın Ağları -Vektör Nicelemesi Ağı
Veri Kavramlaştırılması	-Uyarlanırlı Rezonans Ağı -Özörgütlemeli Harita Ağı
Veri Süzülmesi	-Yeniden Dolaşım
Resim veya Görüntü İşleme	-Geri Yayılım Ağı -Perceptron

3.5.2. Giriş Düğüm Sayısını Belirleme

Giriş düğümü sayısı gelecek değerleri tahmin etmede kullanılan giriş vektöründeki değişken sayısına tekabül eder. Bir zaman serisi tahmin probleminde giriş düğümü sayısı, zaman serisindeki örüntüyü keşfetmek ve gelecek değerler için tahmin yapmakta kullanılan gecikmeli gözlemlerin sayısını karşılık gelir. Bu sayıyı belirlemek için önerilen sistematik bir yol yoktur. Bu parametrenin seçimi model

yapılandırma sürecinde yapılmalıdır. Çok az ya da çok fazla giriş düğümü ağı öğrenme veya tahmin yeteneğini etkileyebilir. Zhang vd. göre zaman serisi tahmin problemleri için giriş düğümü sayısı verideki karmaşık otokorelasyon yapısı hakkında önemli bilgi içerdiğinden belki de en kritik karar değişkenidir ve bu parametre teorik araştırma ile belirlenebilir (Zhang, Patuwo ve Hu, 1998).

3.5.3. Gizli Katman ve Bu Katmandaki Düğümlerin Sayısını Belirleme

Gizli katman ve düğümleri pek çok başarılı sinir ağı uygulamasında önemli rol oynar. Ağa, verideki örüntüyü yakalama ve giriş-çıkış değişkenleri arasındaki karmaşık nanlineer ilişkiyi modelleme özelliğini kazandıran gizli katmandaki düğümlerdir. Gizli düğümler olmadan lineer çıkış düğümlü basit bir perceptron, lineer bir istatistiksel tahmin modeli ile eşit olacaktır. Literatürdeki tek gizli katman kullanılarak, beklenen güvenilirlikte sonuçlar alan uygulamalar göz önünde bulundurularak, çoğu yazar tahmin problemleri için tek gizli katman tercih etmektedir. Fakat tek gizli katman bazen çok sayıda gizli düğüm gerektirmektedir ki bu öğrenme zamanı ve genelleme yeteneğini kötü yönde etkilediğinden dolayı istenilen bir durum değildir. Çoğu tahmin problemi için tek gizli katman yeterli olmakla birlikte, bazı durumlarda özellikle tek gizli katman kullanıldığında tatmin edici sonuçlara ulaşmak için gizli düğüm sayısı çok fazla arttığında iki gizli katman daha iyi sonuçlar vermektedir. Gizli katman sayısını belirlemede en yaygın yol deneme yanılma yoludur.

Tang ve Fishwick gizli düğümlerin etkisini inceledikleri çalışmalarında gizli düğüm sayısının tahmin performansını etkilediğini fakat bu etkinin çok belirgin olmadığını belirtmişlerdir (Tang ve Fishwick, 1993). Pek çok çalışmada giriş düğümüne eşit sayıda gizli düğüm kullanmanın daha iyi tahmin sonucu verdiği belirtilmiştir (Zhang, Patuwo ve Hu, 1998).

3.5.4. Çıkış Düğümlerinin Sayısını Belirleme

Çıkış düğümü sayısını belirlemek, bu sayı direkt olarak çalışılan problemle ilgili olduğundan nispeten kolaydır. Zaman serisi tahmin problemi için çıkış düğümü sayısı genellikle tahmin horizonuna tekabül eder. İki tip tahmin vardır: bir adım

sonrası için tahmin veya birden çok adım sonrası için tahmin. Çok adımlı tahmin yapmanın iki yolu vardır. Birincisi iteratif tahmin olarak adlandırılır ve tahmin değerleri iteratif olarak bir sonraki tahmin için giriş olarak kullanılır. Bu durumda sadece bir çıkış gereklidir. Direkt metot olarak adlandırılan ikincisi ise sinir ağının çok sayıda çıkış düğümü ile her adımı doğrudan tahmin etmesine olanak sağlar. Zhang'a göre direkt tahmin yöntemi iteratif yöntemle göre çok daha iyi sonuç vermektedir (Zhang, Patuwo ve Hu, 1998).

3.5.5. Aktivasyon Fonksiyonunu Belirleme

Aktivasyon fonksiyonu başka bir deyişle transfer fonksiyonu bir düğümün ve bir ağın giriş ve çıkışları arasındaki ilişkiyi belirler. Teoride herhangi türevlenebilir fonksiyon aktivasyon fonksiyonu olarak kullanılabilir ancak pratikte bu fonksiyonların sayısı azdır çünkü fonksiyonun sınırlı, monoton artan ve türevlenebilir olması gerekmektedir. Genellikle bir ağ aynı veya farklı katmandaki farklı düğümler için farklı aktivasyon fonksiyonlarına sahip olabilir. Fakat hemen hemen bütün ağlarda aynı katmandaki düğümler için aynı aktivasyon fonksiyonu kullanılır. Araştırmacıların büyük çoğunluğu gizli katman için sigmoid fonksiyonunu kullanırken çıkış düğümleri için hangi fonksiyonun kullanılacağına dair bir fikir birliği yoktur.

3.5.6. Veri Normalizasyonu

Sigmoid fonksiyonu gibi nanlineer aktivasyon fonksiyonları bir düğümün muhtemel çıkışını (0,1) ya da (-1,1) şeklinde sıkıştırma etkisine sahiptir. Veri normalizasyonu genellikle öğrenme süreci başlamadan yapılır. Çıkış düğümlerinde nanlineer transfer fonksiyonları kullanıldıysa beklenen çıkış değerlerinin ağın gerçek çıkışlarının aralığına dönüştürülmesi gerekir. Lineer transfer fonksiyonu kullanılmış olsa bile çıkışları girişler gibi standardize etmek hesaplama problemlerinden kaçınmak için yararlı olabilir.

Giriş normalizasyonu için 4 metot Azoff tarafından özetlenmiştir (Zhang, Patuwo ve Hu, 1998):

1. Kanal boyunca normalizasyon: Bir kanal, öğrenme ya da test

kümesindeki tüm giriş vektörlerinden aynı pozisyona sahip olan elemanların kümesi şeklinde tanımlanır. Her kanal bağımsız bir giriş değişkeni gibi düşünülebilir. Kanal boyunca normalizasyon eğer giriş vektörleri bir matrise konulduysa kolon kolon yapılır. Başka bir deyişle her giriş değişkeni tek tek normalize edilir.

2. Kanal üstünden normalizasyon: Bu tip normalizasyonda her giriş vektörü bağımsız olarak normalize edilir yani bir veri örüntüsündeki bütün elemanlar bir taraftan diğer tarafa doğru normalize edilir.

3. Karışık kanal normalizasyonu: Adından da anlaşılacağı gibi bu metot kanal boyunca ve kanal üstünden normalizasyonlarının kombinasyonlarını kullanır.

4. Harici normalizasyon: Bütün öğrenme verisi özel bir aralığa normalize edilir.

Bu metotlardan birinin seçimi genellikle giriş vektörünün düzenine bağlıdır. Zaman serisi tahmin problemleri için tek uygun metot harici normalizasyondur. Yukarıda verilen normalizasyon yaklaşımları için genellikle şu formüller kullanılır:

- $[0,1]$ aralığına lineer dönüşüm: $x_n = \frac{(x_0 - x_{\min})}{x_{\max} - x_{\min}}$
- $[a,b]$ aralığına lineer dönüşüm: $x_n = (b - a) \frac{(x_0 - x_{\min})}{(x_{\max} - x_{\min})} + a$
- İstatistiksel normalizasyon: $x_n = \frac{(x_0 - \bar{x})}{s}$
- Basit normalizasyon: $x_n = \frac{x_0}{x_{\max}}$

Burada x_n ve x_0 normalize edilmiş ve orijinal veri; x_{\min} , x_{\max} , \bar{x} ve s ise minimum, maksimum, ortalama ve satır ve sütunlar arasındaki standart sapmadır.

Hedef değerleri normalize etmenin sonucu olarak ağın gözlenen çıkışı normalize aralıkta olacaktır. Bu nedenle ağdan elde edilen sonuçları anlamlandırabilmek için çıkışların orijinal aralığına göre tekrar ölçeklendirilmesi gerekmektedir. Performans ölçümleri de tekrar ölçeklendirilmiş çıkışlara göre yapılmalıdır.

3.5.7. Öğrenme ve Test Kümesi

Öğrenme kümesi YSA modeli geliştirmek için, test kümesi ise modelin tahmin kabiliyetini değerlendirmek için kullanılır. Bazen doğrulama kümesi denilen bir üçüncüsü ezberleme probleminde kaçınmak ya da öğrenme sürecinin durdurma noktasını belirlemek için kullanılır. Genellikle test ve doğrulama için tek bir test kümesi kullanılır, özellikle de küçük veri setleri için. Öğrenme ve test kümesinin seçimi YSA'nın performansını etkileyebilmektedir. Veri setinin ne şekilde bölüneceğine dair genel bir çözüm olmamakla birlikte problem karakteristiği, veri tipi ve kullanılabilir verinin miktarı gibi faktörler bu kararı verirken göz önünde bulundurulmalıdır. Hem öğrenme hem de test kümesinin verinin tümünü temsil etmesi oldukça önemlidir. Literatürde çoğu yazar eğitim ve test kümesini %90'a %10, %80'e %20 ya da %70'e %30 kuralına göre ayırmaktadır. Bir başka ilgili faktör de örnek büyüklüğüdür. Örnek büyüklüğü problemin doğruluk derecesi ile yakından ilgilidir. Örnek büyüklüğü ne kadar büyük olursa sonuçlar da o kadar güvenilir olacaktır.

3.5.8. Öğrenme Algoritmasının Belirlenmesi

Sinir ağı öğrenmesi, beklenen ve gerçek çıkış değerleri arasındaki tüm ortalama ve toplam hata karelerini minimize etmek için ağırlıklarının iteratif olarak modifiye edildiği kısıtsız nanlineer bir minimizasyon problemidir. Çok farklı optimizasyon metodlarının olması sinir ağı eğitimi için çeşitli seçenekler sağlamaktadır. Şu anda genel nanlineer optimizasyon problemi için kabul edilebilir bir sürede global optimum çözümü garanti eden bir algoritma bulunmamaktadır. Pratikte bütün optimizasyon algoritmaları lokal en iyi çözüm (local optima) sorunu ile karşı karşıyadır ve bizim yapabileceğimiz en iyi şey eğer global çözüm yoksa “en iyi” lokal çözümü veren optimizasyon metodunu kullanmaktır (Zhang, Patuwo ve Hu, 1998).

3.5.9. Performans Kriterleri

YSA tahmincisi için modelleme zamanı, eğitim zamanı gibi pek çok performans ölçütü olabilmesine rağmen en önemli kriter tahmin doğruluğudur.

Verilen bir problem için akademisyenler tarafından evrensel olarak kabul edilmiş uygun bir doğruluk ölçütü yoktur. Doğruluk ölçütü genellikle gerçek ve tahmin edilen değer arasındaki fark şeklinde tanımlanır. Tahmin literatüründe birkaç doğruluk ölçütü vardır ve her birinin avantaj ve sınırlamaları vardır. Bunların en çok kullanılanları şöyledir (Zhang, Patuwo ve Hu, 1998):

- Ortalama mutlak sapma (MAD): $\sum |e_i| / N$
- Toplam kare hata (SSE): $\sum (e_i)^2$
- Ortalama kare hata (MSE): $\sum (e_i)^2 / N$
- Ortalama kare hata kökü (RMSE): \sqrt{MSE}
- Ortalama mutlak yüzde hata (MAPE): $\frac{1}{N} \sum \left| \frac{e_i}{y_i} \right| (100)$

Burada e_i tek bir tahmin hatası, y_i gerçek değer ve N de hata terimleri sayısıdır. Her ölçüt için sınırlamalar olduğundan bu kriterlerin birkaçını birden kullanmak gerekebilir. MSE literatürde en çok kullanılan kriterdir.

4. BULANIK MANTIK

Bulanık mantık ayırt edilemeyen, kesin olmayan, belirsizlik gösteren koşullarda ve incelenen herhangi bir konunun kesin olarak bilinmemesi, sistemin sahip olduğu verilerin eksik ve belirsiz olması gibi durumlarda insana özgü akıl yürütme süreçlerinin matematiksel modellere uygulanmasıdır. Geleneksel matematiksel araçlarla yapılan sistem modellemeleri belirsiz ya da iyi tanımlanmamış sistemler için çok uygun değildir. Bulanık çıkarım sistemleri insan bilgisi ve akıl yürütme süreçlerinin nitel yönlerini kesin nicel analizlere ihtiyaç duymaksızın modelleyebilir. Bulanıklık, dereceli üyelik kavramı yardımıyla teknik bilim dünyasına taşınmıştır. Bulanık kümelerde dereceli üyelik kavramını ilk kez 1965 yılında Kaliforniya Üniversitesinden Lotfi Zadeh yapmıştır (Nabiyev, 2005).

Bulanık Mantığın Avantajları:

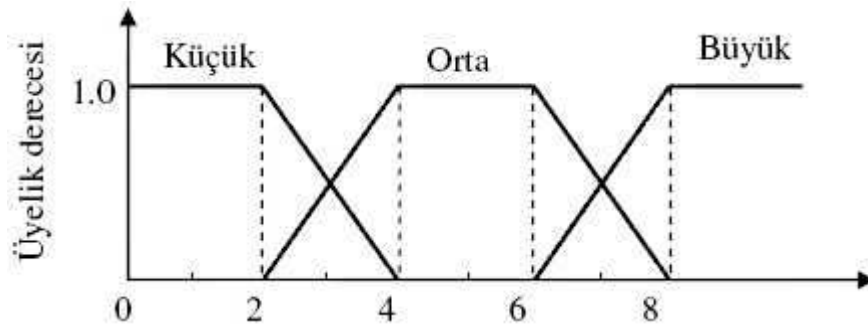
- İnsan düşünce tarzına yakın olması
- Uygulanışının matematiksel modele ihtiyaç duymaması
- Yazılımının basit olması dolayısıyla ucuza mal olması
- Eksik tanımlı problemlerin çözümüne uygun olması
- Uygulama kolaylığı

Bulanık Mantığın Dezavantajları:

- Uygulamada kullanılan kuralların oluşturulmasının uzmana bağlılığı
- Üyelik fonksiyonlarının deneme-yanılma yolu ile bulunmasından dolayı uzun zaman alabilmesi
- Kararlılık analizinin yapılışının zorluğu
- Bulanık mantık sistemlerinin öğrenilemez ve öğretilemez oluşu

4.1. BULANIK KÜMELER VE ÜYELİK FONKSİYONLARI

Aristo mantığına göre çalışan ve şimdiye kadar alışlagelen klasik küme kavramında, bir kümeye giren öğelerin oraya ait oluşları durumunda üyelik dereceleri 1 olarak, ait olmamaları durumunda ise 0 olarak kabul edilmiştir. Bu mantığa göre 0 ile 1 arasında hiçbir üyelik derecesi kabul edilmemektedir. Ancak bulanık küme kavramında 0 ile 1 arasında değişen, değişik üyelik derecelerinden söz edilebilmektedir. Bu durumda bulanık kümelerdeki öğelerin üyelik derecelerini, 0 ve 1 de dâhil olmak üzere kesintisiz olarak 0 ile 1 arasındaki tüm değerleri içermektedir. Bunun bir alt küme içerisindeki değeri ise üyelik fonksiyonu olarak bilinmektedir. Üyelik fonksiyonu kümesi altında toplanan öğeler önem derecelerine göre herbiri birer üyelik derecesine sahip olmaktadır. Bulanık küme mantığının en önemli özelliği günlük hayatta kullanılan dilsel ifadelerin matematiksel modellemede kullanılmasıdır. Örneğin küçük, orta ve büyük şeklinde ifade edilen kümeler aşağıdaki şekilde derecelendirilebilir.



Şekil 16. Bulanık Alt kümeler

4.2. BULANIK KURAL TABANI

Genel olarak çıkarım eldeki bilgileri kullanarak yeni bilgi elde etme olarak tanımlanabilir. Çıkarımda bilginin sunum ve gösterim şekli önemlidir. Sunum yöntemleri içinde “eğer – ise” kural tipi en sık kullanılan sunum tipidir. Kural tipi sunum, içerme olarak yorumlanır ve öncül (eğer) ve soncul (ise) kısımları içerir.

Önce girdi ve çıktı verileri bulanık üyelik fonksiyonlar yardımıyla alt kümelere ayrılarak bölünmektedir. Genel olarak, m alt küme sayısını ve n girdi

değişkenlerini gösterirse m^n adet bulanık kural sayısı oluşmaktadır. Böyle bir durumda, diyebiliriz ki, X_1 ve X_2 girdileri ile m alt kümesinin herbiri kural tabanında bir Y_k çıktı formuna götürmektedir ($k=1,2,\dots,m^2$). Eğer burada X_1 “çok küçük” ve “küçük” alt kümeler olarak ve X_2 “orta” ve “büyük” alt kümeler olarak iki değişkenli girdi ise, o zaman sonuç olarak burada aşağıdaki gibi dört kural olacaktır:

Kural1: Eğer X_1 “çok küçük” ve X_2 “orta” ise Y_1 ,

Kural2: Eğer X_1 “çok küçük” ve X_2 “büyük” ise Y_2 ,

Kural3: Eğer X_1 “küçük” ve X_2 “orta” ise Y_3 ,

Kural4: Eğer X_1 “küçük” ve X_2 “büyük” ise Y_4 .

4.3 BULANIK ÇIKARIM SİSTEMLERİ

Bulanık mantığa dayanan sistemlerde genel olarak bulandırma arayüzü, çıkarım motoru, durulama arayüzü ve bilgi tabanı olmak üzere dört bölümden söz edilir.

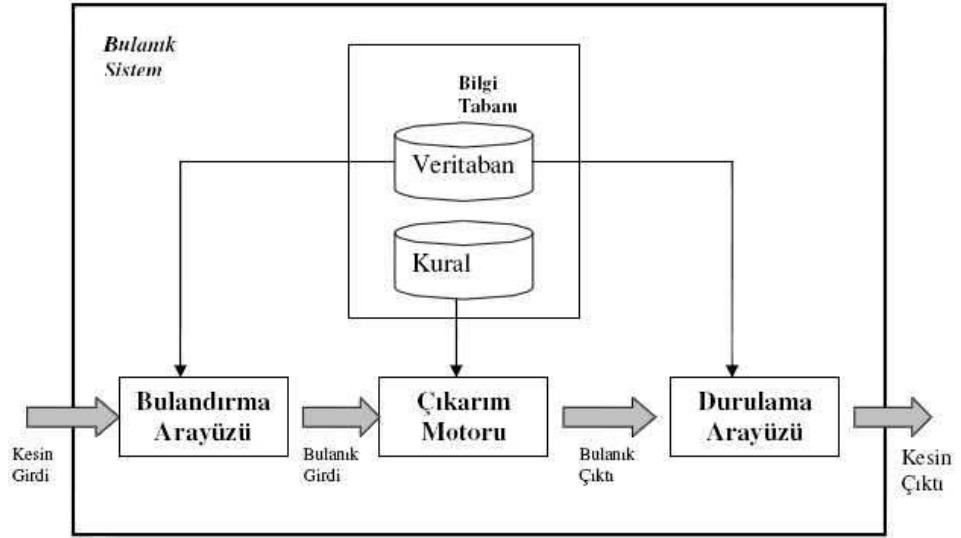
Bulandırma arayüzü; kesin girdi değerlerini bulanık değerlere çevirir. Bunun için girdi değerlerini alır, girdi değişken aralığının uygun evrensel kümeye dönüştürülmesini sağlar ve girdi verilerini sözel değerlere (bulanık kümelere) dönüştürür.

Çıkarım motoru; bulanık kavramlara dayalı olarak insan karar verme işlevini taklit eder. Ayrıca bulanık içerme ve sözel kuralları kullanan bulanık denetim etkinliklerini uygular. Çıkarım motoru akıl yürütme işlemini elde etmek üzere uygulanır.

Bilgi tabanı; uygulama alanı hedeflerinin bilgisini içerir, kural ve üyelik fonksiyonlarını tanımlar. Bilgi tabanı veritabanı ve sözel kural tabanı bölümlerinden oluşur. Veritabanı denetim kuralları ve veri işlemede kullanılan gerekli tanımları içerir. Sözel kural tabanı stratejiyi ve kuralları sözel ifadeler aracılığı ile tanımlamaktadır. Kural tabanı sözel olarak ilgili sistemin modellenmiş hali olarak görülebilir.

Durulama arayüzü ise bulanık çıktı değerlerini kesin değerlere çevirir.

Bulanık sistemin yapısı Şekil 17’de verilmiştir:



Şekil 17. Bulanık Sistemin Yapısı

4.4 ANFIS (UYARLAMALI AĞ TABANLI BULANIK ÇIKARIM SİSTEMLERİ)

Açık olarak uyarlamalı ağlara dayanan bulanık çıkarım sistemi veya uyarlamalı sinirsel bulanık çıkarım sistemi anlamına gelen ANFIS ismi, Adaptive Network-based Fuzzy Inference System veya Adaptive Neuro Fuzzy Inference System olan özgün adının baş harflerinden oluşmuştur. Esasen ANFIS yapısı, Sugeno tipi bulanık sistemlerin, sinirsel öğrenme kabiliyetine sahip bir ağ yapısı olarak temsilinden ibarettir. Bu ağ, her biri belli bir fonksiyonu gerçekleştirmek üzere, katmanlar halinde yerleştirilmiş düğümlerin birleşiminden oluşmuştur. Aslında bulanık çıkarım sistemi çok katmanlı perceptrona göre daha kuvvetlidir. Örnek olarak ANFIS denetleyicilerin özellikleri tanımlanabilir:

- Öğrenme yeteneği
- Paralel işlem
- Yapılandırılmış bilgi temsili
- Diğer denetim tasarım yöntemleriyle daha iyi bütünleşme

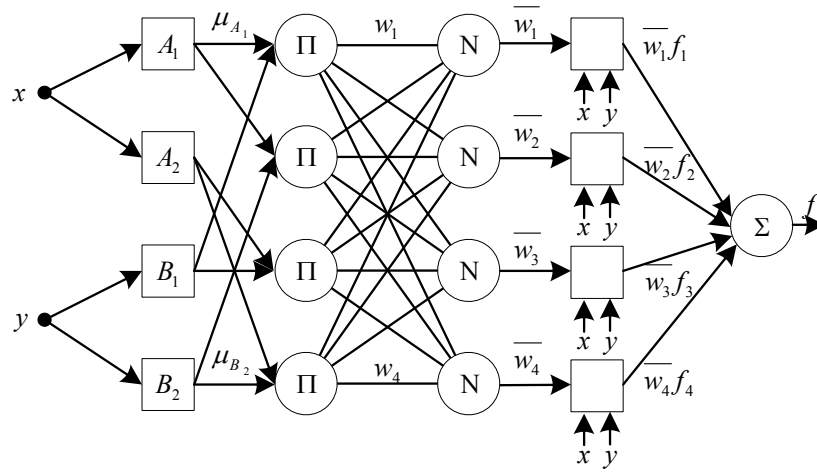
Basit olması açısından, bulanık çıkarım sistemini, x ve y gibi iki girişi ve z

gibi bir çıkışı olduğunu farz ederek ele alalım. İki tane bulanık eğer-ise kuralı bulunan birinci dereceden Sugeno bulanık modeli için tipik kural kümesi;

Kural-1: Eğer x A_1 ise ve y B_1 ise $f_1 = p_1 x + q_1 y + r_1$

Kural-2: Eğer x A_2 ise ve y B_2 ise $f_2 = p_2 x + q_2 y + r_2$

Bir ANFIS ağının mimarisi aşağıdaki Şekil 18’de görüldüğü gibidir (Kaynar vd., 2011):



Şekil 18. ANFIS Mimarisi

Yukarıda verilen şekilden de görüleceği üzere ANFIS yapısı 5 katmanlı bir mimariye sahiptir.

Katmanlarda farklı şekillere sahip düğümler değişik işlevlere sahip fonksiyonları içerir. Kare şeklinde gösterilen düğümler adaptif düğümler olarak adlandırılır ve düğümlere ait parametreler ağın eğitimi sırasında ayarlanır. Daire şeklinde gösterilen düğümler ise sabit düğümlerdir. Her bir katmandaki fonksiyonların işlevi aşağıda açıklanmıştır (Kaynar vd., 2011):

Katman1(Giriş katmanı): Bu katmanda yer alan düğümler ayarlanabilen düğümlerdir ve bu düğümlerde giriş değişkenlerine ait bulanık kümelerle ilişkin üyelik fonksiyonları yer almaktadır. Bu düğümlerin çıkışı, ilgili üyelik fonksiyonunun derecesini göstermektedir ve eşitlikteki şekilde verilir.

$$O_{1,i} = \mu_{A_i}(x) \quad i = 1, 2 \quad (4.1)$$

x, y değerleri i . düğüme ilişkin giriş değerlerini A_i ve B_i sözel olarak ifade edilen bulanık kümeleri, μ_{A_i} ve μ_{B_i} değerleri ise bu kümelere ait üyelik fonksiyonlarının derecelerini göstermektedir. Üyelik fonksiyonu olarak literatürde trapez, üçgen, genelleştirilmiş-bell, ve gauss fonksiyonları önerilmiştir. Bunlar arasında en yaygın olanı ve çalışmamızda da kullanılan genelleştirilmiş-bell fonksiyonu eşitlik verilmiştir.

$$\mu(x) = \frac{1}{1 + \left(\frac{x - c_i}{a_i} \right)^{2b_i}} \quad (4.2)$$

$\{a_i, b_i, c_i\}$ bu üyelik fonksiyonun şeklini belirleyen parametrelerdir ve öncül parametreler olarak adlandırılırlar. c_i parametresi bell fonksiyonunun merkezini, a_i değeri fonksiyonun genişlik değerini, b_i ise fonksiyona ilişkin düzeltme faktörünü belirler.

Katman2(Kural katmanı): Π ile etiketlenen bu katmandaki düğümlerin tamamı sabit düğümlerdir. İlgili kuralın öncül kısmına ait üyelik fonksiyonlarına T-norm (AND ya da çarpım operatörü) operatörünün uygulanması sonucunda ilgili düğümün çıkışı hesaplanır. Böylelikle her bir kuralın çıkış fonksiyonunun şeklini belirlemedeki etkisi elde edilir ve bu değer ilgili kuralın tetikleme ya da ateşleme ağırlığı (Firing strength) olarak adlandırılır. Bu katmanın çıkışları bir önceki katmandan elde edilen üyelik derecelerinin çarpımı şeklinde hesaplanır.

$$O_{2,i} = w_i = \mu_{A_j}(x) \times \mu_{B_j}(y) \quad (4.3)$$

$$i = 1, \dots, 4; j = 1, 2$$

Katman3(Normalizasyon katmanı): Bu katmanda yer alan her bir düğüm N ile etiketlenilmiş sabit bir düğümdür. i . düğümün çıkışı; i . kuralın tetikleme ağırlığının tüm kuralların tetikleme ağırlıklarının toplamına oranı şeklinde

hesaplanır. Bu katmanın çıkışları, normalize edilmiş tetikleme ağırlıkları olarak adlandırılırlar.

$$O_{3,i} = \overline{w}_i = \frac{w_i}{\sum_{k=1}^4 w_k} \quad i = 1, \dots, 4$$

(4.4)

Katman4(Sonuç katmanı): Bu katmandaki her bir düğüm, her bir kuralın toplam çıkış fonksiyonu üzerindeki etkisini belirler ve aşağıda verildiği şekilde hesaplanır.

$$O_{4,i} = \overline{w}_i f_i = \overline{w}_i (p_i + q_i + r_i) \quad i = 1, \dots, 4 \quad (4.5)$$

\overline{w}_i bir önceki katmanın çıkışını ifade ederken $\{p_i, q_i, r_i\}$ ise i . kurala ilişkin ayarlanabilen soncul parametreleri göstermektedir. Aynı zamanda bu parametreler Sugeno bulanık çıkarım sistemindeki lineer fonksiyonun katsayıları olarak da bilinir.

Katman5(Çıkış katmanı): Σ ile simgelenen bu katman tek düğüme sahiptir ve bu düğüm kendisine gelen tüm sinyallerin toplamını alarak sistemin toplam çıkışını hesaplar.

$$O_{5,i} = \sum_{i=1}^4 \overline{w}_i f_i = \frac{\sum_{i=1}^4 w_i f_i}{\sum_{i=1}^4 w_i} \quad (4.6)$$

4.5 ANFIS AĞINDA KULLANILAN HİBRİD ÖĞRENME ALGORİTMASI

ANFIS ağının eğitimi, tek başına gradyent eğitim azalım algoritması ya da en küçük hata kareler yöntemi ile gradyent eğitim azalım algoritmasının birleşiminden oluşan tümleşik eğitim algoritması yardımıyla gerçekleştirilir. Gradyent eğitim azalım algoritması tek başına tüm parametreleri belirlemek için kullanılabilir fakat eğitim

süresinin uzun olması ve bölgesel mimimumlara takılma riski nedeniyle ağın eğitiminde genellikle Jang tarafından önerilen iki aşamalı hibrid eğitim algoritması kullanılır (Jang, 1993). Hibrid eğitim algoritması ileri ve geri yönde olmak üzere iki aşamadan oluşur. Eğitimin başında üyelik fonksiyonları tanımlanarak öncül parametrelerin ilk değerleri belirlenir. Eğitim algoritmasının ileri doğru olan geçişinde bu öncül parametreler (a_i, b_i, c_i) sabit tutularak dördüncü katmana kadar her bir katmanın çıkışı hesaplanır. Ardından (p_i, q_i, r_i) soncul parametreleri en küçük hata kareler yöntemiyle elde edilir. Öncül parametreler belirli bir sabit değerde iken sistemin genel çıkışı soncul parametrelerin doğrusal birleşimi şeklinde yazılabilir.

$$\begin{aligned}
 f_{out} &= \sum_{i=1}^n \overline{w}_i f_i = \overline{w}_1 f_1 + \overline{w}_2 f_2 + \overline{w}_3 f_3 + \overline{w}_4 f_4 \\
 &= (\overline{w}_1 x) p_1 + (\overline{w}_1 y) q_1 + w_1 r_1 + (\overline{w}_2 x) p_2 + (\overline{w}_2 y) q_2 + w_2 r_2 \\
 &\quad + (\overline{w}_3 x) p_3 + (\overline{w}_3 y) q_3 + w_3 r_3 + (\overline{w}_4 x) p_4 + (\overline{w}_4 y) q_4 + w_4
 \end{aligned} \tag{4.7}$$

n adet örnek içeren eğitim veri seti için, bilinen (x_i, y_i) değerleri giriş örneklerini, d_i ise bu giriş değerlerine karşılık ilgili çıkış değerini gösterebilir. Öncül parametreler bilindiğinden sistemin çıkışı f , soncul parametreler yardımıyla matris formunda lineer denklem sistemi olarak ifade edilir

$$f = B\theta \tag{4.8}$$

Eşitlikte θ soncul parametreleri içeren bilinmeyenler matrisini, B ise bilinen katsayılar matrisini göstermektedir. Eğer B matrisinin tersi alınabiliyorsa en küçük kareler hata tahmincisi θ^* aşağıda verilen şekilde hesaplanır.

$$\theta^* = B^{-1} f \tag{4.9}$$

B matrisinin tersinin alınmadığı durumda ise θ^* değerini bulmak için yalancı tersleme (pseudo-inverse) yönteminden faydalanılır.

$$\theta^* = (B^T B)^{-1} B^T f \tag{4.10}$$

Soncul parametreler belirlendikten sonra eldeki eğitim verisi için sistemin toplam hatası aşağıdaki eşitlik yardımıyla hesaplanır.

$$E = \sum_{i=1}^n E_i = \sum_{i=1}^n (d_i - f_{out_i})^2 \quad (4.11)$$

E_i , ağa sunulan i . giriş için sistemin hatasını, d_i , i . giriş değeri için arzu edilen çıkış değerini, f_{out_i} i . giriş için sistemin hesapladığı çıkış değerini, E ise tüm girdiler için sistemin toplam hatasını göstermektedir.

Hybrid öğrenme algoritmasının geriye doğru geçişinde ise sonuç parametreleri sabitlenerek her bir düğüm için hata değişim oranı $\partial E_i / \partial O_i$ hesaplanır. Zincir kuralı uygulanarak, sistemde herhangi bir öncül parametreyi simgeleyen α değişkenine göre toplam hata değişimi aşağıda verilen şekilde hesaplanır.

$$\frac{\partial E}{\partial \alpha} = \sum_{i=1}^n \frac{\partial E}{\partial \alpha} = \sum_{i=1}^n \sum_{O \in S} \frac{\partial E}{\partial \tilde{O}} \frac{\partial \tilde{O}}{\partial \alpha} \quad (4.12)$$

Eşitlikte α , herhangi bir öncül parametreyi, S , çıkışı α 'ya bağlı olarak değişen düğümlerin kümesini, \tilde{O} ise bu küme içerisinde yer alan herhangi bir düğümün çıkışını göstermektedir. Daha sonra öncül parametreler aşağıdaki eşitlikler yardımıyla güncellenir.

$$\Delta \alpha = -\eta \frac{\partial E}{\partial \alpha} \quad (4.13)$$

$$\alpha_{yeni} = \alpha_{eski} + \Delta \alpha \quad (4.14)$$

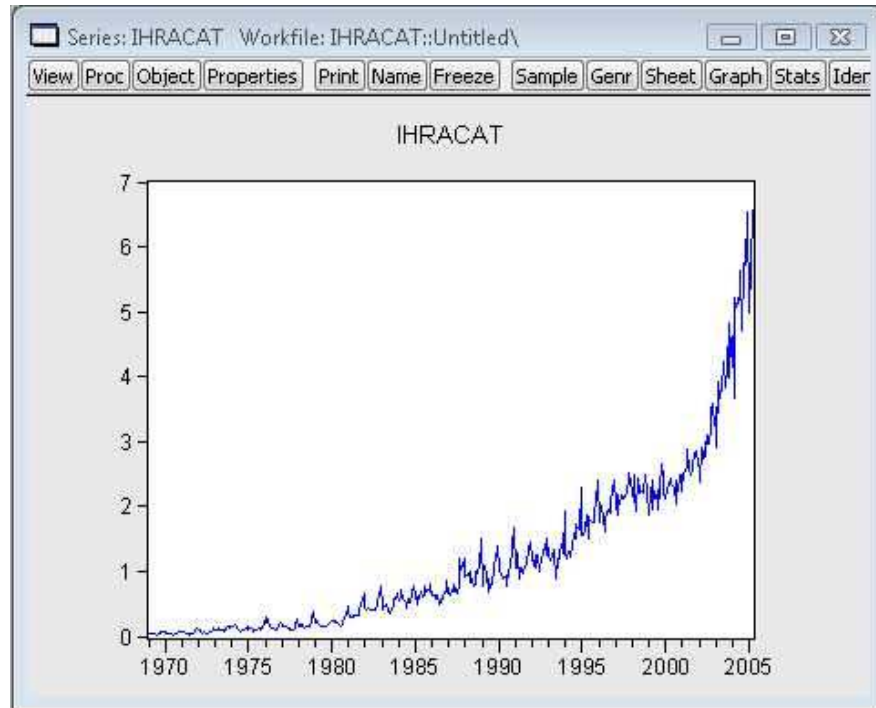
η öğrenme oranını, $\Delta \alpha$ ise α değişkenine ait değişim miktarını göstermektedir. parametrelerin optimum şekilde ayarlanmasını sağlayan eğitim işlemi, sistemin toplam hatası belirli bir değer altında kalıncaya kadar ya da verilen iterasyon sayısına ulaşıncaya kadar devam eder (Jang, 1993).

5. UYGULAMA VE SONUÇLAR

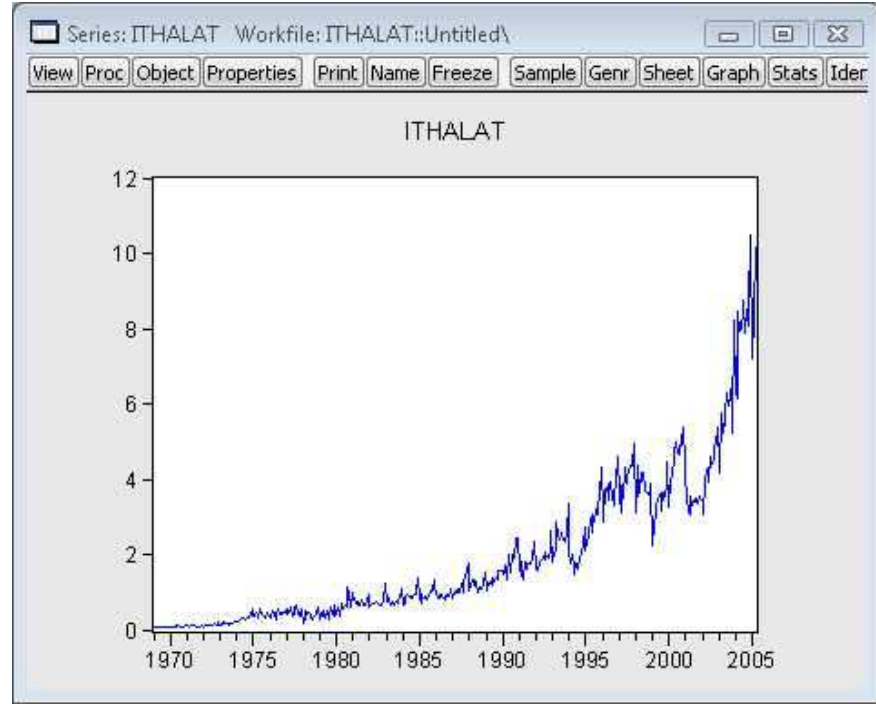
Bu çalışmada Türkiye İstatistik Kurumu'ndan elde edilen Türkiye'nin 1969 yılı Ocak ayı ve 2009 yılı Mayıs ayı arası aylık ithalat ve ihracat serileri kullanılmıştır. Klasik zaman serisi analiz yöntemlerinden mevsimsel ARIMA, yapay sinir ağları metotlarından MLP ve RBF ve bulanık çıkarım sistemi yöntemi ANFIS ile tahminler gerçekleştirilerek kullanılan modellerin tahmin performansları karşılaştırılmıştır.

5.1. MEVSİMSEL ARIMA İLE YAPILAN TAHMİN UYGULAMASI

Serilerin analizi için Eviews ve SPSS programlarından yararlanılmıştır. Öncelikle ihracat ve ithalat zaman serileri değerlendirilerek grafikleri incelenmiş ve Şekil 19 ve Şekil 20'de de görüldüğü gibi serilerin artan trende sahip oldukları ve durağan olmadıkları gözlenmiştir.

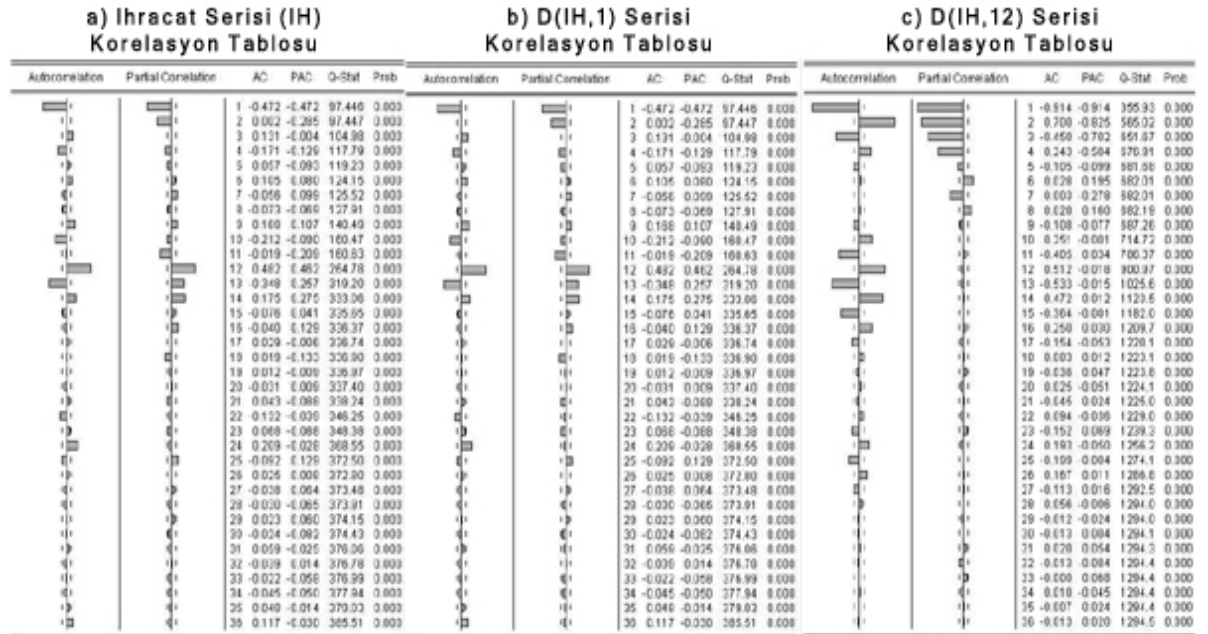


Şekil 19. Türkiye ihracat rakamları grafiği



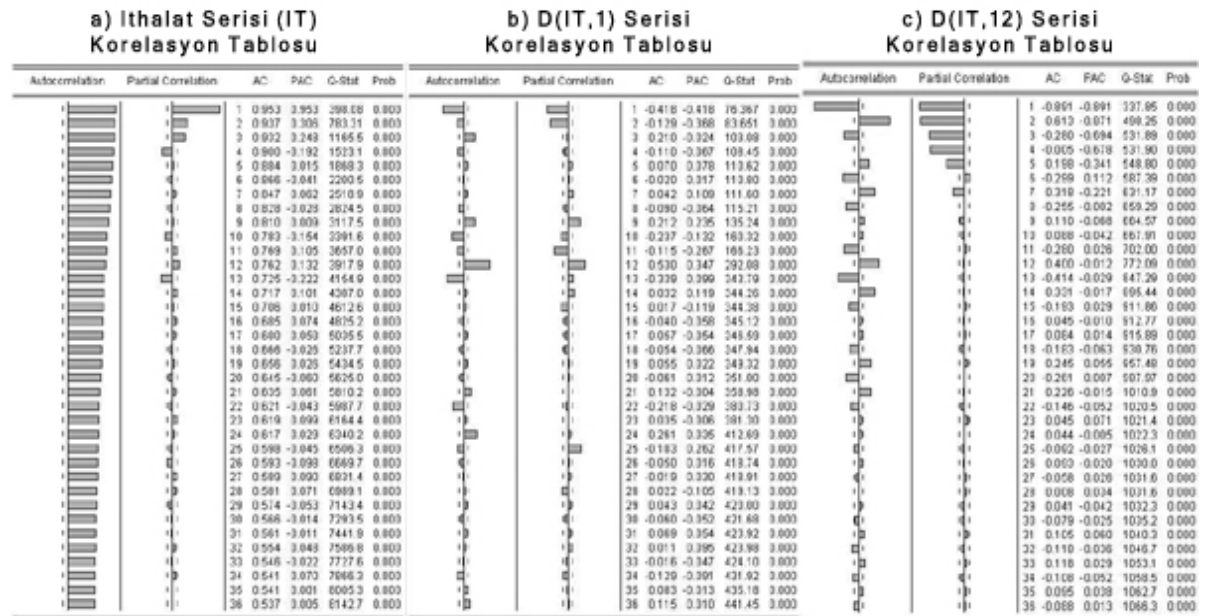
Şekil 20. Türkiye ithalat rakamları grafiği

Box-Jenkins metodolojisi doğrultusunda uygun bir ARIMA tahmin modeli oluşturabilmek için ilk olarak serilerin durağanlığı incelenmiştir. Bunun için örnek gözlem kümesinin otokorelasyon (ACF) ve kısmi otokorelasyon (PACF) fonksiyonları çizdirilmiştir. Aşağıdaki şekillerdeki orijinal, birinci dereceden farkı alınmış ve mevsimsel farkı alınmış serilerin otokorelasyon ve kısmi otokorelasyon fonksiyonları incelendiğinde orijinal serilerin özellikle otokorelasyon fonksiyonu itibariyle mevsimsel eğilim gösterdiği görülmektedir.



Şekil 21. İhracat serisi korelasyon tablosu

- a)Orijinal ihracat serisi b) Birinci dereceden farkı alınmış ihracat serisi
c)Mevsimsel farkı alınmış ihracat serisi



Şekil 22. İthalat serisi korelasyon tablosu

- a)Orijinal ithalat serisi b) Birinci dereceden farkı alınmış ithalat serisi
c)Mevsimsel farkı alınmış ithalat serisi

Serilerin durağanlaştırılmasının gerekip gerekmediğine karar vermek için Augmented Dickey Fuller (ADF) testi uygulanmıştır. ADF testi için sıfır hipotezi ve alternatif hipotez şu şekildedir:

- $H_0: \theta = 0$ ise seri birim kök içermektedir ve seriyi durağan hale getirebilmek için farkının alınması gerekmektedir.

- $H_1: \theta < 0$ ise seri birim kök içermez, durağandır ve fark alınmasına gerek yoktur.

ADF t test istatistiği %1, %5 ve %10 önem seviyesi kritik değerleri ile karşılaştırılmıştır. Test trendli, trendli ve kesmeli ve trendsiz ve kesmesiz olarak yapılmış ve t istatistik değerleri sırasıyla ihracat serisi için 2.818, 2.575 ve 2.853; ithalat serisi içinse 2.478, 0.779 ve 3.215 bulunmuştur. P olasılık değerleri ise her iki seri için de 1.00, 1.00 ve 0.99'dur. Farklı modeller için %1, %5 ve %10 önem seviyesi kritik değerleri Tablo 7 ve 8'de verilmiştir. Verilen değerlere göre bulunan α değeri kritik değerlerden yüksek olduğundan sıfır hipotezi kabul edilerek serinin durağanlaştırılması gerektiğine karar verilmiştir.

Tablo 7. İhracat serisi için ADF test istatistikleri

Augmented Dickey-Fuller Testi				
		Kesmeli	Trendli ve Kesmeli	Trendsiz ve Kesmesiz
Olasılık		1.0000	1.0000	0.9990
Test İstatistiği		2.818105	2.575080	2.853857
MacKinnon Kritik Değerleri	1% seviyesi	-3.445701	-3.980059	-2.570480
	5% seviyesi	-2.868202	-3.420558	-1.941579
	10% seviyesi	-2.570384	-3.132974	-1.616193

Tablo 8. İthalat serisi için ADF test istatistikleri

Augmented Dickey-Fuller Testi				
		Kesmeli	Trendli ve Kesmeli	Trendsiz ve Kesmesiz
Olasılık		1.0000	0.9998	0.9997
Test İstatistiği		2.478595	0.779275	3.215840
MacKinnon Kritik Değerleri	1% seviye	-3.445776	-3.980165	-2.570506
	5% seviye	-2.868235	-3.420610	-1.941583
	10% seviye	-2.570401	-3.133004	-1.616191

Serileri durağanlaştırmak için klasik ve mevsimsel fark alma işlemleri uygulanmış ve yeniden ADF testi uygulanmıştır. Yapılan test sonucunda üç farklı

model için de olasılık değerlerinin Tablo 9 ve 10'da gösterildiği gibi 0.000 olduğu görülmüştür. Bu nedenle sıfır hipotezi reddedilerek serinin durağan hale geldiğine karar verilmiştir.

Tablo 9. Birinci dereceden ve mevsimsel fark alınmış ihracat serisi için ADF test istatistikleri

Augmented Dickey-Fuller Testi			
	Kesmeli	Trendli ve kesmeli	Trendsiz ve kesmesiz
Olasılık	0.0000	0.0000	0.0000
Test İstatistiği	-27.90374	-27.81904	-27.94203
MacKinnon Kritik Değerleri	1% seviye	-3.446321	-3.980936
	5% seviye	-2.868475	-3.420985
	10% seviye	-2.570530	-3.133226

Tablo 10. Birinci dereceden ve mevsimsel fark alınmış ithalat serisi için ADF test istatistikleri

Augmented Dickey-Fuller Test,			
	Kesmeli	Trendli ve kesmeli	Trendsiz ve kesmesiz
Olasılık	0.0000	0.0000	0.0000
Test İstatistiği	-28.60354	-28.56417	-28.64184
MacKinnon Kritik Değerleri	1% seviye	-3.446321	-3.980936
	5% seviye	-2.868475	-3.420985
	10% seviye	-2.570530	-3.133226

En uygun modeli belirleyebilmek için farklı ARIMA modelleri oluşturulmuştur. Oluşturulan modeller Tablo 11 ve 12'de verilmiştir. Oluşturulan modeller arasından en iyi modeli seçmek için BIC, AIC, R^2 , MAPE ve RMSE kriterleri kullanılmıştır. İhracat serisi için en yüksek R^2 ve en düşük MAPE, RMSE and BIC değerlerine sahip olan ARIMA(1,1,3)(1,1,1)₁₂ modeli; ithalat serisi içinse ARIMA(0,1,2)(1,1,1)₁₂ modeli en iyi model olarak seçilmiştir. Seçilen modellerin parametre ve istatistikleri Tablo 13 ve 14'te verilmiştir. Serilerin son 50 verisi tahmin kümesi olarak kullanılmıştır.

Tablo 11. İhracat serisi için oluşturulan ARIMA modelleri

	R-squared	RMSE	MAPE	MAE	Normalized BIC
ARIMA(0,1,3)(1,1,1)	0.446905	.171	10.083	.102	-3.532
ARIMA(0,1,1)(1,1,1)	0.427408	.166	10.146	.100	-3.594
ARIMA(0,1,2)(1,1,1)	0.427701	.166	10.156	.100	-3.563
ARIMA(1,1,3)(1,1,1)	0.457246	.174	9.873	.101	-3.479
ARIMA(1,1,2)(1,1,1)	0.426929	.166	10.125	.100	-1.908
ARIMA(1,1,0)(1,1,1)	0.421550	.170	10.168	.102	-1.943

Tablo 12. İthalat serisi için oluşturulan ARIMA modelleri

	R-squared	RMSE	MAPE	MAE	Normalized BIC
ARIMA(0,1,1)(0,1,1)	0.551199	.291	12.323	.174	-2.394
ARIMA(0,1,1)(1,1,1)	0.587313	.288	11.697	.175	-2.417
ARIMA(1,1,1)(0,1,1)	0.553677	.288	12.262	.172	-2.385
ARIMA(1,1,1)(1,1,1)	0.593503	.285	11.683	.173	-2.420
ARIMA(0,1,2)(0,1,1)	0.552684	.288	12.273	.172	-2.388

Tablo 13. ARIMA(1,1,3)(1,1,1)12 modeli ve istatistikleri

		Tahmin	Std. hata	t	Olasılık
Fark		1			
AR	Lag 1	.597	.137	4.362	.000
MA	Lag 1	1.030	.144	7.164	.000
	LLag 2	-.245	.088	-2.793	0.005
	Lag 3	.127	0.063	2.010	0.045
AR. Mevsimsel	Lag 1	.235	.067	3.530	0.000
Mevsimsel Fark		1			
MA. Mevsimsel	Lag 1	.862	.041	21.136	0.000

Tablo 14. ARIMA(0,1,1)(1,1,1)12 modeli ve istatistikleri

		Tahmin	Std. hata	t	Olasılık
Fark		1			
MA	Lag 1	.594	.040	14.916	.000
AR. Mevsimsel	Lag 1	.161	.056	2.858	0.004
Mevsimsel Fark		1			
MA. Mevsimsel	Lag 1	.916	.035	26.083	0.000

Her iki seri için de en uygun model belirlendikten sonra modellerin doğruluğunu test etmek amacıyla kalıntıların korelasyon tablosu çizilerek ve Ljung Box Q istatistikleri incelenmiş ve hata terimleri arasında önemli bir korelasyon olmadığı görülmüştür. Kalıntıların rastgele değerlerden oluştuğuna ve seçilen

modellerin uygun olduğuna karar verilmiştir. Kalıntılara ait korelasyon tabloları Şekil 23 ve 24’te verilmiştir.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.002	-0.002	0.0016	
		2	0.010	0.010	0.0410	
		3	-0.023	-0.023	0.2589	
		4	0.035	0.035	0.7807	
		5	-0.017	-0.016	0.8965	
		6	0.080	0.079	3.5446	
		7	-0.033	-0.031	3.9976	0.046
		8	-0.064	-0.068	5.7298	0.057
		9	-0.008	-0.003	5.7596	0.124
		10	0.048	0.042	6.7186	0.152
		11	0.108	0.112	11.636	0.040
		12	0.012	0.009	11.702	0.069
		13	-0.107	-0.108	16.583	0.020
		14	-0.019	-0.011	16.735	0.033
		15	-0.008	-0.014	16.765	0.053
		16	0.051	0.043	17.888	0.057
		17	-0.005	-0.011	17.898	0.084
		18	-0.104	-0.105	22.569	0.032
		19	-0.084	-0.055	25.606	0.019
		20	-0.102	-0.111	30.060	0.007
		21	0.014	-0.006	30.139	0.011
		22	-0.002	-0.016	30.141	0.017
		23	0.163	0.179	41.657	0.001
		24	-0.037	0.018	42.266	0.001
		25	-0.010	-0.016	42.312	0.002
		26	0.010	-0.005	42.358	0.002
		27	0.067	0.028	44.344	0.002
		28	0.013	0.027	44.417	0.003
		29	0.026	0.045	44.708	0.004
		30	-0.108	-0.082	49.872	0.001
		31	-0.057	-0.050	51.316	0.001
		32	0.000	-0.025	51.316	0.002
		33	0.126	0.091	58.383	0.000
		34	0.010	-0.001	58.426	0.001
		35	0.114	0.130	64.228	0.000
		36	-0.079	-0.033	67.036	0.000

Şekil 23. İhracat serisi kalıntıları korelasyon tablosu (Q istatistikleri)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.077	-0.077	2.4726	
		2	0.058	0.052	3.8647	
		3	0.089	0.098	7.1736	
		4	0.038	0.050	7.7632	0.005
		5	-0.021	-0.025	7.9390	0.019
		6	-0.054	-0.074	9.1767	0.027
		7	-0.003	-0.020	9.1808	0.057
		8	0.041	0.051	9.8742	0.079
		9	-0.045	-0.022	10.731	0.097
		10	0.049	0.046	11.735	0.110
		11	-0.090	-0.093	15.201	0.055
		12	-0.015	-0.039	15.299	0.083
		13	-0.028	-0.027	15.635	0.111
		14	-0.057	-0.040	17.011	0.108
		15	-0.092	-0.087	20.654	0.056
		16	-0.022	-0.026	20.855	0.076
		17	-0.063	-0.057	22.583	0.067
		18	-0.099	-0.101	26.796	0.030
		19	0.048	0.057	27.807	0.033
		20	-0.057	-0.044	29.229	0.032
		21	0.045	0.052	30.110	0.036
		22	0.024	0.026	30.370	0.047
		23	0.052	0.048	31.541	0.048
		24	-0.006	-0.022	31.559	0.065
		25	-0.023	-0.037	31.799	0.081
		26	0.036	0.008	32.373	0.093
		27	0.105	0.110	37.244	0.041
		28	-0.056	-0.029	38.650	0.040
		29	0.092	0.039	42.367	0.022
		30	-0.061	-0.082	44.025	0.021
		31	-0.063	-0.125	45.777	0.018
		32	0.091	0.082	49.464	0.010
		33	-0.066	-0.038	51.399	0.009
		34	0.005	0.019	51.412	0.012
		35	0.083	0.072	54.479	0.008
		36	-0.048	-0.048	55.512	0.008

Şekil 24. İthalat serisi kalıntıları korelasyon tablosu (Q istatistikleri)

5.2. ESNEK HESAPLAMA TEKNİKLERİ İLE YAPILAN TAHMİN UYGULAMASI

Serilerin analizi için Matlab programından yararlanılmıştır. İhracat ve ithalat serilerinin son 50 gözlemi test verisi olarak, MLP ve ANFIS modelleri için geri kalan verinin %80'i eğitim, %20'si de doğrulama verisi olarak kullanılmıştır. RBF modeli içinse test kümesi haricindeki tüm veriler eğitim verisi olarak kullanılmıştır. Tüm veri setleri sinir ağları ve ANFIS modellerine verilmeden önce $[-1,1]$ aralığına normalize edilmiştir. Normalize etme işlemi için Matlab 'premnmx' fonksiyonu kullanılmıştır.

Matlab programı kullanılarak geliştirilen bir yazılım ile farklı MLP, RBF ve

ANFIS modelleri oluşturulmuştur. Oluşturulan tüm MLP ve RBF modelleri biri gizli katman olmak üzere üç katmanlı mimariye sahiptir.

MLP modeli için yazılan program yardımıyla giriş düğümü sayısı 1'den 12'ye; gizli katman düğüm sayısı da 1'den 10'a kadar değiştirilerek toplam 120 farklı model oluşturulmuştur. Gizli katmanda tanjant-sigmoid, çıkış katmanında ise lineer transfer fonksiyonu kullanılmıştır. Bütün MLP modellerinin eğitimi için Levenberg-Marquardt geri yayılım algoritması uygulanmıştır. Eğitimi durdurmak için kullanılan tekrarlama sayısı ve hedef hata oranı parametreleri 400 ve 0.01 olarak belirlenmiştir. Eğitim verileri ağa gösterilerek eğitim süreci tamamlanmış ve 120 model içinden en düşük MSE ve MAPE değerlerine sahip olan model en iyi model olarak seçilmiştir. İhracat serisi için 4 giriş düğümü ve 1 gizli düğümü olan, ithalat serisi için ise 10 giriş düğümü ve 1 gizli düğümü olan model en iyi model olarak belirlenmiştir. İhracat ve ithalat serileri için oluşturulan bazı MLP modelleri Tablo 15 ve 16'da verilmiştir.

Tablo 15. İhracat serisi için oluşturulan bazı MLP modelleri ve performans kriterleri

	Giriş düğümü	Gizli düğüm	MAPE(%)	MSE
MLP_Model1	1	1	12.78	189.2801
MLP_Model2	2	1	10.14	95.8976
MLP_Model3	3	1	10.32	116.9151
MLP_Model4	4	1	9.68	98.5552
MLP_Model5	5	2	12.73	221.8504
MLP_Model6	6	2	12.01	188.7935
MLP_Model7	7	1	11.51	167.8096
MLP_Model8	8	1	10.44	126.8148
MLP_Model9	9	2	11.42	160.6913
MLP_Model10	10	2	14.96	327.9157

Tablo 16. İthalat serisi için oluşturulan bazı MLP modelleri ve performans kriterleri

	Input neuron	Hidden neuron	MAPE(%)	MSE
MLP_Model1	1	1	10.61	289.4159
MLP_Model2	2	1	9.84	289.26
MLP_Model3	3	1	10.40	303.0325
MLP_Model4	4	1	9.22	271.4309
MLP_Model5	5	1	10.75	378.459
MLP_Model6	6	1	8.82	239.4299
MLP_Model7	7	1	12.18	493.9317
MLP_Model8	8	1	11.11	354.3848
MLP_Model9	9	1	11.62	430.1743
MLP_Model10	10	1	8.78	229.507

RBF modeli için yine Matlab programı ile yazılan kod yardımıyla gizli düğüm sayıları 1'den 30'a, giriş düğümü sayıları da 1'den 12'ye kadar artırılarak toplam 12x30 adet model üretilmiştir. Gizli katmandaki radyal fonksiyonların merkezleri eğitim kümesi içinden rastgele olarak seçilmiştir. Oluşturulan modeller içinden en küçük MAPE ve MSE değerlerine sahip olan modeller en iyi modeller olarak seçilmiştir. İhracat serisi için 1 giriş düğümü ve 2 gizli katman düğümü olan, ithalat serisi için de 1 giriş düğümü ve 10 gizli katman düğümü olan modeller en iyi model olarak belirlenmiştir. Tablo 17 ve 18'de oluşturulan bazı RBF modelleri verilmiştir.

Tablo 17. İhracat serisi için oluşturulan bazı RBF modelleri ve performans kriterleri

	Giriş Düğümü	Gizli Düğüm	MAPE(%)	MSE
RBF_Model1	1	2	11.19	118.0026
RBF_Model2	2	2	11.43	138.7215
RBF_Model3	3	2	12.60	188.7309
RBF_Model4	4	2	12.83	196.8483
RBF_Model5	5	3	13.62	220.6523

Tablo 18. İhracat serisi için oluşturulan bazı RBF modelleri ve performans kriterleri

	Giriş Dügümü	Gizli Dügüm	MAPE(%)	MSE
RBF_Model1	1	10	8.78	185.1799
RBF_Model2	2	3	9.47	267.9801
RBF_Model3	3	3	11.37	443.429
RBF_Model4	4	3	11.21	441.4417
RBF_Model5	5	5	11.63	495.6745
RBF_Model6	10	10	10.14	394.0576

ANFIS modeli yapılandırılırken ağ eğitilmeden önce FIS (Bulanık Çıkarım Sistemi) mimarisinin belirlenmesi gerekmektedir. Bu süreçte her giriş değişkeninin üyelik fonksiyonlarının sayısı, kuralları ve bu fonksiyonlara bağlı parametre değerleri belirlenmelidir. Matlab programında başlangıç FIS mimarisini belirlemek için genfis1 ve genfis2 gibi iki fonksiyon mevcuttur. Bu fonksiyonlar arasındaki temel fark kuralların giriş uzayını nasıl bölümlendiği ile ilgilidir.

Genfis1 fonksiyonu her değişken için bütün olası üyelik fonksiyonu kombinasyonlarını kullanarak grid bölümlenme yapar. Bu yöntemin en büyük dezavantajı çok fazla kural üretmesi dolayısıyla eğitilmesi gereken çok fazla parametrenin olmasıdır. N adet değişken, her değişken için P adet üyelik fonksiyonu ve her üyelik fonksiyonuna bağlı L adet parametre olduğu varsayılırsa, P^N adet kural üretilir böylece $P^N(N+1)$ adet lineer parametrenin ve $NxPxL$ adet de nonlineer parametrenin eğitilmesi gerekir. Giriş değişkeni sayısının büyük ve veri setinin küçük olduğu durumda boyut problemi ortaya çıkar. Bu da parametrelerin hesaplanamamasına neden olur. Bu problemi aşmak için kural sayısının düşürülmesi gerekir.

Genfis2 kural sayısını azaltmak için çıkarmalı kümeleme algoritmasını kullanır ve her küme için bir kural üretir. Ayrıca, belirlenen kümelerin merkezleri giriş değişkenlerinin üyelik fonksiyonu parametrelerinin başlangıç değerleridir.

Bu çalışmada başlangıç FIS mimarisini belirlemek için genfis1 ve genfis2 fonksiyonları uygulanmış ve bütün modeller hibrit öğrenme algoritması ile eğitilmiştir.

Genfis1 fonksiyonu uygulanan FIS modellerinde gecikme ve üyelik

fonksiyonu sayıları 2’den başlayarak boyut problemi oluşturmayacak sayıya kadar arttırılarak farklı ağ yapıları oluşturulmuştur. Oluşturulan modeller içinden en iyi tahmin performansına sahip modeller seçilmiştir. Hem ihracat hem de ithalat serisi için 2 girişli ve her giriş için 5 üyelik fonksiyonu yani 25 kuralı olan model en iyi model olarak belirlenmiştir.

Genfis2 fonksiyonu uygulanan FIS modellerinde de aynı şekilde giriş değişkeni sayısı 1’den başlayarak boyut problemi oluşturmayacak en büyük değere kadar arttırılarak farklı ağ yapıları oluşturulmuştur. Çıkarımlı kümele algoritması yardımıyla kuralları belirleyen genfis2 fonksiyonunda kullanılan küme genişlik değeri, 0.1 değerinden 1 değerine 0.05 adımlarla artırılarak farklı sayıda geçerli kurala sahip alt modeller oluşturulmuştur. Genfis2 fonksiyonu uygulanan modeller genfis2 uygulananlara göre daha iyi sonuçlar üretmiştir.

Tablo 19. İhracat serisi için ANFIS modelleri ve performans kriterleri

	ANFIS model1 (grid partition)	ANFIS model2 (Sub-
Giriş sayısı	2	2
Lineer parametre sayısı	75	35
Nanlineer parametre sayısı	30	56
Toplam parametre sayısı	105	91
Bulanık kural sayısı	25	7
MAPE(%)	15.51	9.20

Tablo 20. İhracat serisi için ANFIS modelleri ve performans kriterleri

	ANFIS model1 (grid partition)	ANFIS model2 (Sub-
Giriş sayısı	2	2
Lineer parametre sayısı	75	35
Nanlineer parametre sayısı	30	56
Toplam parametre sayısı	105	91
Bulanık kural sayısı	25	6
MAPE(%)	15.51	7.95

5.3. BULGULAR

Bu çalışmada klasik zaman serisi analiz yöntemlerinden mevsimsel ARIMA ve esnek hesaplama tekniklerinden MLP, RBF ve ANFIS metotları kullanılarak Türkiye’nin dış ticaret tahmini yapılmıştır. Bütün modeller için serilerin son 50

gözlemi tahmin için kullanılmış ve karşılaştırma için yorumlaması kolay, ölçekten bağımsız, güvenilir ve geçerli olmasından dolayı (Law ve Au, 1999) ortalama mutlak yüzde hata (MAPE) ile ortalama kare hate (MSE) performans kriterleri kullanılmıştır. Tablo 19 ve 20’de ihracat ve ithalat verileri için bütün modeller ile yapılan tahmin sonuçları, gerçek değerler ve MAPE kriteri değerleri verilmiştir. MAPE değeri ne kadar küçükse tahmin edilen değerler gerçek değerlere o kadar yakın demektir. Tablodan da görüldüğü gibi hem ihracat hem de ithalat serisi için esnek hesaplama teknikleri ile oluşturulan modeller klasik modelden daha iyi sonuç vermiştir.

Tablo 21. İhracat serisi için gözlenen ve tahmin edilen değerler


GÖZLENEN	ARIMA	MLP	RBF	ANFIS
4.997	4.997	6.433	6.578	6.320332
5.652	5.652	6.037	5.0321	6.412225
6.592	6.592	6.046	5.688	6.133886
6.128	6.130	6.191	6.630	6.111439
5.977	6.090	6.450	6.165	5.967062
6.039	5.816	6.561	6.014	5.727822
5.763	6.032	6.431	6.076	6.416791
5.553	5.550	6.272	5.799	6.895905
6.814	6.198	6.109	5.589	6.370878
6.772	7.059	6.468	6.852	6.837768
5.943	6.935	6.784	6.810	6.064088
7.246	7.016	6.821	5.980	5.785178
5.133	5.806	7.116	7.284	6.984962
6.058	5.584	6.428	5.168	6.941202
7.411	6.742	6.486	6.095	6.918095
6.456	6.774	6.728	7.449	7.626591
7.042	6.612	6.981	6.493	7.477519
7.815	6.659	7.364	7.080	7.021106
7.067	7.273	7.620	7.852	7.406593
6.811	6.997	7.710	7.105	7.285121
7.607	7.625	7.632	6.849	8.071707
6.889	7.940	7.668	7.644	8.750466
8.641	7.033	7.529	6.927	7.48566
8.604	9.035	8.215	8.677	7.338756
6.565	7.150	8.559	8.640	8.573522
7.657	6.894	8.260	6.603	8.698987
8.958	8.483	8.108	7.694	8.952641
8.313	8.051	8.337	8.993	9.183955
9.148	8.409	8.728	8.350	9.090946

8.98	8.869	9.260	9.182	8.950909
8.938	8.605	9.312	9.015	9.055574
8.737	8.457	9.456	8.973	9.701248
9.039	9.467	9.357	8.773	10.91693
9.895	9.285	9.389	9.074	10.50925
11.319	10.215	9.724	9.926	10.42731
9.724	11.710	10.522	11.342	11.06426
10.632	8.406	10.604	9.756	11.45677
11.078	9.748	10.870	10.660	11.55788
11.427	12.367	10.899	11.103	12.21497
11.364	10.667	11.291	11.449	12.22777
12.477	11.092	11.492	11.387	12.45026
11.771	11.597	11.899	12.490	11.83117
12.595	11.542	11.950	11.791	12.28178
11.047	11.632	12.262	12.607	11.09817
12.793	12.066	11.892	11.072	9.668791
9.722	13.076	12.193	12.803	8.51204
9.396	11.603	11.384	9.754	7.94114
7.722	10.274	10.878	9.430	8.345011
MAPE	%9.87	%9.68	%11.19	%9.20


Tablo 22. İthalat serisi için gözlenen ve tahmin edilen değerler

GÖZLENEN	ARIMA	MLP	RBF	ANFIS
7.220	7.220	9.527	9.550	9.625325
8.324	8.324	8.765	8.737	9.88005
10.196	10.196	9.317	9.262	9.813686
9.596	9.440	9.124	9.227	9.978277
9.812	9.656	9.752	9.693	9.794009
9.947	10.089	10.370	10.241	10.1173
9.596	10.026	10.263	10.354	10.41392
10.272	9.308	10.218	10.189	10.26459
10.366	10.440	10.862	10.689	9.894176
10.090	10.239	9.901	10.156	11.07316
9.673	10.766	11.162	11.120	9.441184
11.683	12.456	10.911	10.875	9.299828
8.146	8.704	11.098	11.261	11.06484
9.796	9.037	9.791	9.884	11.6814
11.605	10.690	10.770	10.849	12.40448
11.587	10.795	10.292	10.594	12.63858
12.694	11.313	11.914	11.911	12.06096
12.466	12.211	12.253	12.348	12.17153
11.709	12.174	12.627	12.845	12.2873
12.276	11.652	12.365	12.514	11.61646

12.153	12.683	13.088	13.128	12.40317
11.200	12.297	11.946	12.387	13.09232
12.897	12.311	12.974	13.142	11.527
13.048	15.120	13.370	13.694	11.1951
10.592	10.228	12.888	13.349	12.68937
11.383	11.167	12.563	12.833	13.12495
13.234	12.838	12.061	12.512	14.34352
12.919	12.817	12.282	12.821	14.60299
14.935	13.258	13.091	13.401	14.99507
14.266	14.246	14.225	14.732	14.97373
15.214	14.018	13.996	14.637	14.64216
14.682	14.071	15.398	15.983	15.3339
14.459	15.181	14.664	15.278	16.40175
15.627	14.537	14.797	15.603	16.41371
16.632	16.023	15.578	16.461	16.37992
16.120	19.008	16.463	17.583	16.25027
16.339	13.102	16.086	17.300	16.65938
16.026	15.159	16.768	18.119	17.64197
16.812	17.646	15.953	17.342	18.94948
17.889	17.008	16.663	18.117	19.55396
19.306	18.099	16.804	18.475	20.32515
19.477	18.911	17.803	19.905	19.84027
20.557	19.217	18.335	20.691	18.4862
19.251	18.943	18.928	21.730	16.07326
17.885	20.163	18.438	21.112	13.16122
14.942	19.264	18.425	21.063	11.72413
12.073	18.415	16.914	19.080	10.09361
11.405	17.960	15.549	17.372	9.22018
MAPE	%11.69	%8.78	%8.78	%7.95



Şekil 25. İhracat serisi gözlenen ve tahmin edilen değerler grafiği



Şekil 26. İthalat serisi gözlenen ve tahmin edilen değerler grafiği

6. DEĞERLENDİRME VE SONUÇ

Bu çalışmada Türkiye dış ticaret verileri istatistiksel zaman serisi analizi, YSA ve ANFIS metotları ile incelenmiştir. Veri seti Türkiye İstatistik Kurumu'ndan elde edilen aylık ihracat ve ithalat zaman serileridir. Tahmin için farklı modeller oluşturulmuş ve kullanılan her teknik için en düşük MAPE ve MSE değerine sahip model belirlenmiştir. Daha sonra bu modeller kullanılarak son 50 gözlem için tahmin yapılmış ve modellerin tahmin performansları karşılaştırılmıştır.

Elde edilen sonuçlara göre seçilen modellerin oldukça düşük ve birbirine yakın MAPE değerlerine sahip olduğu gözlenmiştir. Bu nedenle kullanılan bütün modellerin geçerli tahminler yaptıkları ve dış ticaret tahmin uygulaması için uygun oldukları söylenebilir. YSA modelleri içinde MLP modellerinin RBF modellerine göre daha iyi performans gösterdiği, ANFIS modelleri içinde ise başlangıç FIS yapısını belirlemek için kümeleme algoritması kullanan modelin grid bölümlere yapan modele göre daha iyi olduğu gözlenmiştir. Dolayısıyla bulanık kuralların ve hesaplanacak parametrelerin sayısını azaltmak, hesaplama karmaşasını ve boyut problemini aşmak için ANFIS modellerinde kümeleme algoritması kullanılabilir. Ayrıca ANFIS modellerinin MLP ve RBF modellerine kıyasla iyi performans gösterdiği görülmüştür. Daha az zaman alması ve YSA'ya göre daha esnek olması gibi özelliklerinden dolayı tahmin uygulamalarında yapay sinir ağlarına alternatif bir metot olarak kullanılabilir.

Sonuç olarak hem YSA hem de ANFIS modellerinin ARIMA modellerine göre daha iyi tahmin performansına sahip olduğu söylenebilir. Tahmin sonuçları göz önüne alınarak uygun ağ yapısı ve yeterli sayıda veri kullanıldığında YSA ve ANFIS metotları ekonomik ve finansal zaman serilerinin tahmininde istatistiksel metotlara alternatif bir yöntem olarak kullanılabilir.

Türkiye ithalat ve ihracatının tahmini özellikle makroekonomik amaçlar açısından oldukça önemlidir. Dış ticaret açığı; tüm ekonomideki dış ticaret paylaşımının yüksek olması için özellikle devlet ve politika ve strateji belirleyen hükümet mercileri tarafından analiz edilmelidir.

Bu çalışmada dış ticaret tahmin uygulaması için serilerin sadece geçmiş

değerlerinden faydalanıldı. İleride yapılacak olan çalışmalarda sanayi üretim endeksi, döviz kuru oranları gibi farklı değişkenler kullanılarak daha kapsamlı tahmin uygulamaları yapılabilir.

KAYNAKÇA

- Basheer, I.A. ve Hajmeer, M. (2000) “Artificial Neural Networks: Fundamentals, Computing, Design and Application”, *Journal of Microbiological Methods*, 43, ss.3 – 31.
- Bors, A. G. (2001) "Introduction of the Radial Basis Function (RBF) Networks," Online Symposium for Electronics Engineers, DSP Algorithms: Multimedia, <http://www.osee.net/>, Feb. 13 2001, issue 1, vol. 1, ss. 1-7.
- Bozkurt, Hilal (2007) **Zaman Serileri Analizi**, Ekin Kitabevi, Bursa.
- Co, Henry C. ve Boosarawongse, Rujirek (2007) “Forecasting Thailand’s Rice Export: Statistical Techniques vs. Artificial Neural Networks”, *Computers & Industrial Engineering*, 53, ss.610 – 627.
- Ding, Hongkai, Xiao, Yunshi ve Yue, Jiguang (2005) “Adaptive Training of Radial Basis Function Networks Using Partical Swarm Optimization Algorithm”, *Advances in Natural Computation, First International Conference, ICNC 2005 Changsha, China, August 2005, Proceedings, Part 1* (Ed.: Lipo Wang, Ke Chen ve Yew Soon Ong), Springer Verlag, Berlin Heidelberg.
- Edwards, Ron, Abraham, Ajlth ve Petrovic-Lazarevic, Sonja (2005) “Computational Intelligence to Model the Export Behavior of Multinational Corporation Subsidiaries in Malaysia”, *Journal of the American Society for Information Science and Technology*, 56(11), ss.1177 – 1186.
- Efendigil, Tuğba, Önüt, Semih, Kahraman, Cengiz (2009) “A Decision Support System for Demand Forecasting with Artificial Neural Networks and Neuro-Fuzzy Models: A Comparative Analysis”, *Expert Systems with Applications*, 36, ss.6697 – 6707.

- Ege, Yavuz (1998) “Türkiye’nin Dış Ticaretinin Bugünü ve 21. Yüzyıla Doğru Muhtemel Gelişmeler”, Alıntı Tarihi: 30 Mart 2010 <http://www.dtm.gov.tr/dtmadmin/upload/EAD/TanitimKoordinasyonDb/ozelsayi98.doc>
- Eğrioğlu, Erol, Aladağ, Çağdaş Hakan ve Günay, Süleyman (2008) “A New Model Selection Strategy in Artificial Neural Networks”, *Applied Mathematics and Computation*, 195, ss.591 – 597.
- Elmas, Çetin (2007) **Yapay Zekâ Uygulamaları**, Seçkin Yayıncılık, Ankara.
- Fish, Kelly E., Johnson, John D., Dorsey, Robert E. ve Blodgett, Jeffery G. (2004) “Using on Artificial Neural Network Trained with a Genetic Algorithm to Model Brand Share”, *Journal of Business Research*, 57, ss.79 – 85.
- Graupe, Daniel (2007) **Principles of Artificial Neural Networks**, 2nd Edition. World Scientific Publishing Co. Pte. Ltd.:Singapore.
- Gurney, Kevin (1997) **An Introduction to Neural Networks**, CRC Press, London.
- Gusev, M. S. ve Shirov, A. A. (2009) “Foreign Trade Forecast in the System of Midterm Forecasting of the Russian Economy”, *Studies of Russian Economic Development*, 20(1), ss.1 – 12.
- Güngör, Bener ve Tortum, Ahmet (2007) **Esnek Hesaplama Teknikleri ile Hisse Senedi Fiyat Tahminleri**, İmaj Yayıncılık, Ankara.
- Hamilton, James D. (1994) **Time Series Analysis**, Princeton University Press, Princeton, New Jersey.
- Hamzaçebi, Coşkun (2008) “Improving Artificial Neural Networks’ Performance in Seasonal Time Series Forecasting”, *Information Sciences*, 178, ss.4550 – 4559.

- Hatırlı, Selim Adem, Demircan, Verdi, Aktaş, Ali Rıza (2002) “Ayçiçek ve Soya Yağı İthalat Talebi Analizi”, Akdeniz Üniversitesi Ziraat Fakültesi Dergisi, 15(2), ss.71 – 79.
- Haykin, Simon (1999) **Neural Networks - A Comprehensive Foundation**, NY, USA: Prentice Hall.
- Jang, Jyh-Shing Roger (1993) “ANFIS: Adaptive Network-Based Fuzzy Inference System”, IEEE Transactions on Systems, Man and Cybernetics, 23(3), ss.665 – 685.
- Kaynar, O., Taştan, S. ve Demirkoparan, F. (2010) “Ham Petrol Fiyatlarının Yapay Sinir Ağları ile Tahmini”, Ege Akademik Bakış Dergisi, 10(2), 575 – 596.
- Kaynar, O., Yılmaz, I., Demirkoparan, F. (2011) “Forecasting of natural gas consumption with neural network and neuro fuzzy system”, Energy Education Science and Technology, PartA, Energy science and Research, 26(2), 221 – 238.
- Kim, Namyong, Byun, Hyung-Gi ve Kwon Ki Hyeon (2006) “Learning Behaviors of Stochastic Gradient Radial Basis Function Network Algorithms for Odor Sensing Systems” ETRI Journal, 28(1), ss.59 – 66.
- Kuo, R. J. (2001) “A Sales Forecasting System Based on Fuzzy Neural Network with Initial Weights Generated by Genetic Algorithm”, European Journal of Operational Research, 129, ss.496 – 517.
- Kuo, R. J., Chen, C. H. ve Huang, Y. C. (2001) “An Intelligent Stock Trading Decision Support System Through Integration of Genetic Algorithm Based Fuzzy Neural Network and Artificial Neural Network”, Fuzzy Sets and Systems, 118, ss.21 – 45.
- Mehrara, Mahsen, Ahrari, Mehdi, Farahani, Atafeh Shahabadi ve Sadr, Seyed

Mohammed Hosein (2008) “The Effects of Globalization on Non-Oil Export of Iran”, The 37th Australian Conference of Economists, 30th September – 4th October 2008, Gold Coast, Queensland, Australia.

Mehrotra, Kishan, Mohan, Chilukuri K. ve Ranka, Sanjay (2000) **Elements of Artificial Neural Networks**, Massachusetts Institute of Technology.

Nabiyev, Vasif V. (2005) **Yapay Zekâ**, Seçkin Yayınevi, Ankara.

Öztemel, E. (2003) **Yapay Sinir Ağları**, Papatya Yayıncılık, İstanbul.

Ranaweera, D. K., Hubele, N. F. ve Papalexopoulos, A. D. (1995) “Application of Radial Basis Function Neural Network Model for Short-Term Load Forecasting”, IEE Proc.-Gener. Transm. Distrib., I42(1), ss.45 – 50.

Rojas, R. (1996) **Neural Networks**, Springer Verlag, Berlin.

Serin, Necdet (2001) **Dış Ticaret ve Dış Ticaret Politikası, Türkiye Ekonomisi Sektörel Analiz** (Ed.: Ahmet Şahinöz), İmaj Yayıncılık, Ankara.

Sevim, Ayhan (2006) “Applications of Forecasting Techniques on Turkish Foreign Trade Data”, Marmara Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı Sayısal Yöntemler Bilim Dalı Yüksek Lisans Tezi, İstanbul.

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

Shumway, Robert H. ve Stoffer, David S. (2006) **Time Series Analysis and Its Applications with R Examples**, Second Ed., Springer, New York, USA.

- Şahin, Hüseyin (2006) “Türkiye Ekonomisi”, Ezgi Kitabevi, Yenilenmiş 8. Baskı, Bursa.
- Şentin, Cem Özgür (2006) “Developing a Forecasting Model for External Trade of Turkey in Glass and Glassware”, Marmara Üniversitesi Temel ve Uygulamalı Bilimler Enstitüsü Yüksek Lisans Tezi, İstanbul.
- Tang, Z. ve Fishwick, P. A. (1993) “Feedforward Neural Nets as Models for Time Series Forecasting”, *ORSA Journal on Computing*, 5 (4), ss.374–385.
- Thirumalaiah, Konda ve Deo, M. C. (1998) ”River Stage Forecasting Using Artificial Neural Networks”, *Journal of Hydrologic Engineering*, 3(1), ss.26 – 32.
- Türker, Munise Tuğba (2007) “Dışa Açık Büyüme: Türkiye Örneği”, T.C. Anadolu Üniversitesi Yayınları, No:1782, Eskişehir.
- Wei, William W. S. (2006) **Time Series Analysis: Univariate and Multivariate Methods**, Second Ed., Addison Wesley, London.
- Xiao, Zhi, Gang, Ke ve Zou, Yan (2009) “A Combined Forecasting Approach Based on Fuzzy Soft Sets”, *Journal of Computational and Applied Mathematics*, 228, ss.326 – 333.
- Yaffee, Robert ve McGee, Monnie (2000) **Introduction to Time Series Analysis and Forecasting: with Applications of SAS and SPSS**, Academic Press, San Diego.
- Yu, Lean, Wang, Shauyang ve Lai, Kin Keung (2007) “A Hybrid Econometric – AI Ensemble Learning Model for Chinese Foreign Trade Prediction”, *ICCS 2007, Part IV, LNCS 4490*, ss.106 – 113.
- Zhang, Gioqinang, Patuwo, B. Eddy ve Hu, Michael Y., (1998) “Forecasting

with artificial neural networks: the state of the art”, *International Journal of Forecasting*, Vol.14, ss.35-62.

Zhang, Gioqiang ve Hu, Michael Y. (1998) “Neural Network Forecasting of the British Pound/US Dollar Exchange Rate”, *Omega Int. J. Mgmt. Sci.*, 26(4), ss.495 – 506.

Zhang, Guoqiang, Hu, Michael Y., Patuwo, Eddy B. Indro, Daniel C. (1999) “Artificial Neural Networks in Bankruptcy Prediction: General Framework and Cross-Validation Analysis”, *European Journal of Operational Research*, 116, ss.16 – 32.

Zhang, G. Peter, Patuwo, B. Eddy, Hu, Michael Y. (2001) “A Simulation Study of Artificial Neural Networks for Nonlinear Time Series Forecasting”, *Computers & Operations Research*, 28, ss.381 – 396.