

T.C.
KARA HARP OKULU
SAVUNMA BİLİMLERİ ENSTİTÜSÜ
HAREKAT ARAŞTIRMASI ANA BİLİM DALI

İSTATİSTİKSEL YÖNTEMLERLE YAPAY SİNİR AĞLARI
UYGULAMALARININ KARŞILAŞTIRILMASI: MİLLİ SAVUNMA
BAKANLIĞI BÜTÇESİNİN ÖNGÖRÜLMESİ

YÜKSEK LİSANS TEZİ

Hazırlayan
P. Yzb. Yasin Sefa SAYGILI

Tez Danışmanı
Prof. Dr. Halil KAYIM

Eş Tez Danışmanı
Dr. Topçu Alb. Ercan KAYA

ANKARA - 2008

TEZ TANITIM FORMU

TEZİN TARİHİ : 07.03.2008

TEZİN TİPİ : Yüksek Lisans Tezi

TEZİN BAŞLIĞI : İstatistiksel Yöntemlerle Yapay Sinir Ağları Uygulamalarının Karşılaştırılması: Milli Savunma Bakanlığı Bütçesinin Öngörülmesi.

TEZİN YAPILDIĞI BİRİM : Kara Harp Okulu Savunma Bilimleri Enstitüsü Harekat Araştırması Ana Bilim Dalı

SPONSOR KURULUŞ : -

DAĞITIM LİSTESİ : Kara Harp Okulu Savunma Bilimleri Enstitüsü Tez Hazırlama, Onay, Dağıtım ve Muhafaza Esasları Kılavuzunda Belirtilen Yerlere.

TEZİN ÖZETİ : Türk Silahlı Kuvvetleri'nin geleceğini şekillendirmek için öncelikle kaynak-maliyet analizlerinin yapılması esastır. Bu analizler yapıldıktan sonra yapılabilecek tasarruf veya ilave kaynak ihtiyaçları ortaya çıkacak, bazı politikalar geliştirilecek ve planlı bir şekilde adımlar atılacaktır. Bu çalışmada; Türkiye'nin savunma harcamaları kapsamında önümüzdeki dönemde oluşacak olan Milli Savunma Bakanlığı bütçesi, Zaman Serileri, Regresyon ve Yapay Sinir Ağları analizleri kullanılarak modellenmiş, doğruluk analiz ölçütleri kapsamında en iyi performanslı model seçilerek ön tahminler yapılmaya çalışılmıştır.

ANAHTAR KELİMELER : Savunma Harcamaları, Milli Savunma Bakanlığı Bütçesi, Ön Tahmin, Zaman Serileri, Box-Jenkins, Ekonometri, Yapay Sinir Ağları.

SAYFA SAYISI : 100

GİZLİLİK DERECESESİ : Tasnif Dışı

T.C.
KARA HARP OKULU
SAVUNMA BİLİMLERİ ENSTİTÜSÜ
HAREKAT ARAŞTIRMASI ANA BİLİM DALI

İSTATİSTİKSEL YÖNTEMLERLE YAPAY SİNİR AĞLARI
UYGULAMALARININ KARŞILAŞTIRILMASI: MİLLİ SAVUNMA
BAKANLIĞI BÜTÇESİNİN ÖNGÖRÜLMESİ

YÜKSEK LİSANS TEZİ

Hazırlayan
P. Yzb. Yasin Sefa SAYGILI

Tez Danışmanı
Prof. Dr. Halil KAYIM

Eş Tez Danışmanı
Dr. Topçu Alb. Ercan KAYA


ANKARA - 2008

KARA HARP OKULU

SAVUNMA BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜNE

P. Yzb. Yasin Sefa SAYGILI'nın, **İstatistiksel Yöntemlerle Yapay Sinir Ağları Uygulamalarının Karşılaştırılması: Milli Savunma Bakanlığı Bütçesinin Öngörülmesi**, konulu tez çalışması, jürimiz tarafından HAREKAT ARAŞTIRMASI Ana Bilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

Başkan 
Prof.Dr. Halil KAYIM
(DANIŞMAN)

Üye 
Doç. Dr. Hasan ŞAHİN

Üye 
Yrd.Doç. Dr. Güvenç ARSLAN

Üye 
Dr. Topçu Alb. Köksal HAZIR



Üye -----
Dr.Topçu Alb. Ercan KAYA
(Danışman)

ONAY

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.

07/03/2008


Taner ALTUNOK
Prof.Dr.Y.Müh Alb.
Svn. Bil. Ens. Md.



TEŞEKKÜR

Öncelikli olarak; mensubu olmaktan büyük onur duyduğum Türk Silahlı Kuvvetleri'ne, Kara Harp Okulu Komutanı Tümgeneral Tefik ÖZKILIÇ başta olmak üzere, enstitü müdürümüz Prof. Dr. Y. Müh. Alb. Taner ALTUNOK'a ve bütün sıralı komutanlarıma, tezimin her safhasında büyük emeği geçen ve beni her zaman engin tecrübesiyle destekleyen kıymetli tez danışmanım Prof. Dr. Halil KAYIM'a, yardım ve önerilerini benden esirgemeyen diğer tez danışmanım Dr. Topçu Alb. Ercan KAYA'ya, çalışmamın tıkanıdığı anda bana yol gösteren saygıdeğer Anabilim Dalı Başkanım Dr. Topçu Alb. Köksal HAZIR'a teşekkürlerimi sunmayı bir borç bilirim.

Bütün Yüksek Lisans Programı süresince manevi destek ve sevgilerini bir an olsun benden eksik etmeyen eşim Semra SAYGILI'ya, tezimi tamamlarken onunla beraber paylaşacağımız zamandan çaldığım biricik kızım Çağla Duru'ya ve her zaman yanımda olan sevgili aileme sevgilerimi sunarım.

T.C.
KARA HARP OKULU
SAVUNMA BİLİMLERİ ENSTİTÜSÜ
HAREKAT ARAŞTIRMASI ANA BİLİM DALI
ANKARA 2008

İSTATİSTİKSEL YÖNTEMLERLE YAPAY SİNİR AĞLARI
UYGULAMALARININ KARŞILAŞTIRILMASI: MİLLİ SAVUNMA
BAKANLIĞI BÜTÇESİNİN ÖNGÖRÜLMESİ

YÜKSEK LİSANS TEZİ

P. Yzb. Yasin Sefa SAYGILI

ÖZET

Türk Silahlı Kuvvetleri'nin geleceğini şekillendirecek irili ufaklı pek çok proje yürütülmekte, Silahlı Kuvvetler'in ihtiyaçlarını azami şekilde karşılayacak ve teknolojik açıdan üstün bir konuma getirecek yeni silah sistemlerinin alınması için planlamalar yapılmaktadır. Bu aşamada kaynak-maliyet analizleri devreye girmektedir. Savunma harcamaları özellikle silah sistemlerinin maliyetlerinin yüksek olmasından dolayı sürekli artmaktadır. Bu nedenle savunma harcamalarının büyük bir kısmını oluşturan Milli Savunma Bakanlığı bütçe büyüklüklerinin gelecek dönemlerde alabileceği değerlerin ön tahmini önemlidir.

Bu çalışmada amaç; çeşitli istatistiksel analiz yöntemleri ile Yapay Sinir Ağları yapılarını karşılaştırıp en iyi yöntemi bularak, önümüzdeki dönemde oluşacak olan MSB bütçesini modellemek ve ön tahminler yapmaktır. Ön tahmin sonucu elde edilecek rakamlar sayesinde bütçenin genel gelişimi ile ilgili belirsizlikler ortadan kalkacak ve bu rakamlara göre bir takım çıkarımlar yapılarak genel durum incelenebilecektir.

Çalışma, beş bölümden oluşmaktadır. Birinci bölümde; savunma harcamalarının planlaması, kaynakları, dağılımı ve harcamaları etkileyen faktörler ile MSB bütçesinin aşamaları ve bütçe kalemleri incelenmiştir.

İkinci bölümde; zaman serileri analiz yöntemlerinden Box-Jenkins metodu açıklanmaktadır. Yine bu bölümde diğer analiz tekniklerinden. Regresyon Analizleri ve Yapay Sinir Ağları ile ilgili bilgiler verilmiştir. Yapay Sinir Ağları yapılarının genel tanımları verildikten sonra, ağ yapıları ve elemanları incelenmiş, ağ çeşitleri ile ilgili açıklamalar yapılmıştır.

Üçüncü bölümde incelenen her üç analiz yöntemine göre alternatif modeller kurulmuş ve bu modellerin istatistiksel analizleri yapılmıştır.

Dördüncü bölümde, kurulan modeller karşılaştırılmış ve doğruluk analiz ölçütlerine göre en iyi model belirlenmiştir..

Son bölümde yapılan analizler sonunda ulaşılan sonuçlar değerlendirilmiş ve Milli Savunma Bakanlığı bütçe verilerini tahmin etmek için bir metodoloji ortaya konulmaya çalışılmıştır.

Anahtar Kelimeler : Savunma Harcamaları, Milli Savunma Bakanlığı Bütçesi, Ön Tahmin, Zaman Serileri, Box-Jenkins, Ekonometri, Yapay Sinir Ağları.

Tez Yöneticisi : Prof. Dr. Halil KAYIM

Sayfa Sayısı : 100

T.C.
TURKISH MILITARY ACADEMY
DEFENSE SCIENCE INSTITUTE
DEPARTMENT OF OPERATIONAL RESEARCH
ANKARA 2008

**COMPARING THE STATISTICAL METHODS WITH THE
ARTIFICIAL NEURAL NETWORKS : FORECASTING THE
MINISTRY OF NATIONAL DEFENSE’S BUDGET**

MASTER THESIS

P.YZB. YASİN SEFA SAYGILI

ABSTRACT

In order to shape the future of Turkish Armed Forces, there are several projects that are being executed. Through these projects, procurement of new defense systems are planned, and these systems are expected to fully satisfy the needs of armed forces and carry them to a technologically superior position. At this point, resource-cost analyses are considered. It is known that an important part of defense expenditures which are realized in the budget of Ministry of National Defense, constitute a significant portion in annual government budgets as well. Consequently, it is crucial to generate forecasts for the budget of Ministry of National Defense and coordinate related studies accordingly.

The objective of this study is to forecast the future budget of MND by statistical modelling, and to investigate the overall position with the light of numerical data deducted from the results of the models.

The study consists of five chapters. In the first chapter; the factors that affect planning, resources, distribution and disbursements of defense expenditures; the phases of preparation and details of MND budget, are studied.

In the second chapter; time series analyses and Box-Jenkins method are explained. After the scrutiny of time series analyses, regression and artificial neural networks which are the other methods of analysis of this study are discussed. After ANNs are generally defined, the infrastructure and the elements of network are analysed and types of networks are explained.

In the third chapter; alternative models are built by using three methods that has been discussed previously, subsequently these models are statistically analysed.

In the fourth chapter; by using the statistical precision analysis models have been compared and the best model chosen.

At the last chapter; the results of the analyses are investigated, and forecasts that are obtained through the utilization of the best model which was constructed according to MND budget data, are discussed.

Keywords : Military Expenditures, The Ministry of National Defense's Budget, Forecasting, Time Series, Box-Jenkins, Econometrics, Artificial Neural Networks.

Advisor : Prof. Dr. Halil KAYIM

Number of Pages : 100

İÇİNDEKİLER

	<u>Sayfa</u>
TEŞEKKÜR.....	i
ÖZET	ii
ABSTRACT	iv
İÇİNDEKİLER	vi
TABLolar LİSTESİ.....	x
ŞEKİLLER LİSTESİ	xi
KISALTMALAR LİSTESİ.....	xiii
GİRİŞ	1

BİRİNCİ BÖLÜM

SAVUNMA HARCAMALARI

1. SAVUNMA HARCAMALARI	4
a. Savunma Harcamalarının Planlanması	6
b. Savunma Harcamalarının Finansmanı	7
c. Savunma Harcamalarını Etkileyen Faktörler	8
2. MİLLİ SAVUNMA BAKANLIĞI BÜTÇESİ.....	11
a. Bütçenin Aşamaları	11
(1) Bütçenin Hazırlanması	11
(2) Bütçenin Onaylanması	11
(3) Bütçenin Uygulanması	12
(4) Bütçenin Denetimi	12
b. Milli Savunma Bütçesinin Harcama Kalemleri	12
(1) Personel Giderleri	12
(2) Diğer Cariler	12
(3) Yatırımlar.....	13
(4) Transferler.....	13
c. Milli Savunma Bakanlığı Bütçesinin Dağılımı	13

İKİNCİ BÖLÜM

KULLANILAN YÖNTEMLER

1. ZAMAN SERİLERİ ANALİZİ	15
a. Giriş	15
b. Zaman Serisi Çeşitleri	16
c. Zaman Serisinin Bileşenleri	16
(1) Trend	17
(2) Mevsimlik Değişmeler	17
(3) Devresel Değişmeler	17
(4) Rastlantısal Değişmeler	17
d. Durağanlık	18
e. Box-Jenkins Yöntemi	19
(1) Giriş	19
(2) Box- Jenkins Yönteminin Aşamaları	20
(a) Belirleme (Identification)	20
(i) Otokorelasyon Fonksiyonu (ACF)	20
(ii) Kısmi Otokorelasyon Fonksiyonu (PACF)	22
(b) Parametre Tahminleri (Estimation)	23
(c) Uygunluk Testleri (Diagnostic Checking)	23
(d) Öngörü (Forecasting)	25
f. Süreçler	27
(1) Doğrusal Durağan Stokastik Süreç	27
(a) Otoregresif (AR) Modelleri	27
(b) Hareketli Ortalama (MA) Modelleri	28
(c) Karışık Otoregresif Hareketli Ortalama (ARMA) Modelleri	28
(2) Doğrusal Durağan Olmayan Stokastik Süreçler	29
(a) Birleştirilmiş Otoregresif Hareketli Ortalama (ARIMA) Modelleri	29
(b) Mevsimlik Öngörü Modelleri	30
2. REGRESYON ANALİZLERİ	32
a. Basit Doğrusal Regresyon	32
b. Çoklu regresyon modelleri	33
c. Kukla (Dummy) Değişkenler	34

3. YAPAY SİNİR AĞLARI ANALİZLERİ.....	37
a. Giriş.....	37
b. Genel Tanımlar.....	38
c. Yapay Sinir Ağlarının Yapısı ve Temel Elemanları	40
(1) Biyolojik Nöron	40
(2) Yapay Nöron	41
d. Yapay Sinir Ağlarının Sınıflandırılması	44
(1) İleri Beslemeli Yapay Sinir Ağları	44
(2) Geri Beslemeli Yapay Sinir Ağları	45
e. Temel Öğrenme Kuralları	46
(1) Hebb Kuralı	46
(2) Hopfield Kuralı.....	47
(3) Delta Kuralı	47
(4) Kohonen Kuralı	47
f. Yapay Sinir Ağlarının Öğrenme Yöntemlerine Göre Sınıflandırılması ..	48
(1) Danışmanlı Öğrenme	48
(a) Geri Yayılım Algoritması	49
(2) Danışmansız Öğrenme	53
g. Yapay Sinir Ağları Tasarımı.....	53
(1) Ağ Yapısı	53
(2) Girdi Nöron Seçimi	54
(3) Gizli Katman ve Nöron Sayısını Belirleme	54
(4) Çıktı Nöron Sayısını Belirleme	55
(5) Aktivasyon Fonksiyonu Seçimi.....	55
(6) Veri Normalizasyonu	56
(7) Eğitim ve Test Kümesi	56
(8) Öğrenme Algoritmasının Seçimi.....	57
h. Yapay Sinir Ağları Yapılarının Avantaj ve Dezavantajları	57

ÜÇÜNCÜ BÖLÜM

UYGULAMA

1. VERİLER	59
2. YÖNTEMLER	60

a. Zaman Serileri Analizi.....	60
(1) Belirleme	60
(2) Parametre Tahmini ve Uygunluk Testleri	63
(3) Öngörü	66
b. Regresyon Analizi.....	69
c. Yapay Sinir Ağları Analizi	75
(1) Ağ Yapısının Oluşturulması	75
(2) Eğitim ve Test	77

DÖRDÜNCÜ BÖLÜM

DEĞERLENDİRME

1. DOĞRULUK ANALİZ ÖLÇÜTLERİ.....	83
2. EKONOMETRİK MODEL VE SARIMA MODELİNİN KARŞILAŞTIRMASI.....	84
3. YAPAY SİNİR AĞLARI MODELİ VE SARIMA MODELİNİN KARŞILAŞTIRMASI.....	87

BEŞİNCİ BÖLÜM

SONUÇ VE ÖNERİLER

1. SONUÇ.....	90
2. ÖNERİLER	92
3. GELECEK ÇALIŞMALARA ÖNERİLER	93

KAYNAKÇA	94
EKLER	100

TABLÖLAR LİSTESİ

Sayfa

Tablo-1: Model Belirlemede Kullanılan Otokorelasyon ve Kısmi Otokorelasyon Örnekleri.	22
Tablo-2 : YSA Uygulama Alanlarına Göre Ağ Yapıları	54
Tablo-3 : MSB Bütçesi Üçer Aylık Zaman Serileri İçin Uygun Modeller.....	64
Tablo-4 : MSB Bütçesi Zaman Serisi Analizi Ön Dönem Tahminleri (Milyon YTL).....	67
Tablo-5 : GSMH Ait Yıllara Göre Değişim ve Ön Tahmin Tablosu (Milyon YTL).....	74
Tablo-6 : MSB Bütçesi Regresyon Analizi Ön Dönem Tahminleri.	75
Tablo-7 : YSA Modeli Performans Değerlendirmesi.	81
Tablo-8 : YSA Modeli 2008-2010 Ön Tahminleri (Milyon YTL).....	82
Tablo- 9: Ekonometrik Model ve SARIMA Modelinin Performans Tablosu...86	
Tablo- 10 : YSA ve SARIMA Modelinin Performans Tablosu	88

ŞEKİLLER LİSTESİ

Sayfa

Şekil-1 : Genel Bütçe ile MSB Bütçesinin Karşılaştırılması.	5
Şekil-2 : MSB Bütçesinin Genel Bütçeye Oranı.....	6
Şekil-3 : MSB Bütçesinin İlgili Kuruluşlara Göre Dağılımı.....	14
Şekil-4 : Sinir Sisteminin Blok Yapısı.....	40
Şekil-5 : Biyolojik Nöron Yapısı ve İşlevleri.	41
Şekil-6 : Yapay Nöron Yapısı	42
Şekil-7 : Aktivasyon Fonksiyonu Örnekleri.	43
Şekil-8 : Çok Katmanlı Bir YSA Modeli.....	44
Şekil-9 : İleri Beslemeli Yapay Sinir Ağları.	45
Şekil-10 : Geri Beslemeli Yapay Sinir Ağı.	46
Şekil-11 : Danışmanlı Öğrenme.	49
Şekil-12 : Geri Yayılım Algoritması.....	50
Şekil-13 : Geri Yayılım Algoritması Gelişimi.	52
Şekil-14 : Danışmansız Öğrenme.....	53
Şekil-15 : MSB Bütçesi Üçer Aylık Zaman Serisi Grafiği.....	60
Şekil-16 : MSB Bütçesi Otokorelasyon Fonksiyonu.....	61
Şekil-17 : MSB Bütçesi Birinci Fark Otokorelasyon Fonksiyonu.....	61
Şekil-18 : MSB Bütçesi Yıllık Birinci ve Mevsimlik Dördüncü Fark Otokorelasyon Fonksiyonu.	62

Şekil-19 : MSB Bütçesi Yıllık Birinci ve Mevsimlik Dördüncü Farkı Kısmi Otokorelasyon Fonksiyonu.	63
Şekil-20 : Zaman Serisi Modelinin Örneklem İçi Tahminleri.	66
Şekil-21 : MSB Bütçesinin, SARIMA Modeli Örneklem Dışı Tahminleri.	68
Şekil-22 : Zaman Serisi Modellerini Karşılaştırma Grafiği.	68
Şekil-23 : MSB Bütçesinin Gerçek, Tahmin ve Hata Terimleri Grafiği.	73
Şekil-24 : YSA Modeli Geçmiş Dönem Tahminleri.	78
Şekil-25 : YSA Modeli Hata Grafiği.....	79
Şekil-26 : YSA Modeli Test Değerleri.	80
Şekil-27 : YSA Modeli Test Hata Grafiği.....	80
Şekil-28 : Ekonometrik Model ve SARIMA Modeli Ön Tahmin Hataları Grafiği.	85
Şekil-29 : Ekonometrik Model ve SARIMA Modeli Geçmiş Dönem Tahminleri Grafiği.	85
Şekil-30 : SARIMA ve YSA Modeli Hata Grafiği.	87
Şekil-31 : SARIMA ve YSA Modeli Geçmiş Dönem Tahminleri.	88

KISALTMALAR LİSTESİ

ACF	:	Autocorrelation Function
AIC	:	Akaike Information Criteria
AR	:	Autoregressive Model
ARIMA	:	Autoregressive Integrated Moving Average
ARMA	:	Autoregressive Moving Average
ÇKA	:	Çok Katmanlı Ağlar
DPT	:	Devlet planlama Teşkilatı
EKKY	:	En Küçük kareler Yöntemi
GYA	:	Geri Yayılım Algoritması
GSMH	:	Gayri Safi Milli Hasıla
LMS	:	Least Mean Square
LVQ	:	Learning Vector Quantization
MA	:	Moving Average
MLP	:	Multilayered Perceptrons
MSB	:	Milli Savunma Bakanlığı
ORVÇÖZ	:	Ortak Varyans Çözümlemesi
OYTEP	:	On Yıllık Tedarik Planı
PACF	:	Partical Autocorrelation Function
PPBS	:	Plan Program Bütçe Sistemi
SARIMA	:	Seasonal Autoregressive Integrated Moving Average
SATEN	:	Savunma Teknolojileri Enstitüsü
SAVTEK	:	Savunma Teknolojileri Kongresi
SHP	:	Stratejik Hedef Planı
SSR	:	Sum of Square

TEFE	:	Toptan Eşya Fiyatları Endeksi
ÜFE	:	Üretici Fiyatları Endeksi
VARÇÖZ	:	Varyans Çözümlesi
YSA	:	Yapay Sinir Ağları

GİRİŞ

Günümüzde ülkeler güvenlik amacıyla iç ve dış tehditler karşısında tedbir alma gereksiniminden dolayı, bütçelerinden önemli bir kısmı savunma harcamalarına ayırmaktadır.

Önlenemeyen bazı olayların ve gelişmelerin yaşanmasıyla, Dünya genelinde soğuk harbe ve silahlanma yarışına son verilerek, bir yumuşama ortamına girilmiştir. Bu gelişmelere rağmen, Türkiye'nin bulunduğu bölgedeki tehdit, istikrarsızlık ve belirsizlikler halen önemini korumakta, hatta bunlara artan şekilde yenileri eklenmektedir. Bütün bu olumsuz durumların da katkısıyla, Türkiye'nin bölgesinde caydırıcı bir silahlı güce sahip olmasının önemi, belirgin bir şekilde ortaya çıkmaktadır. Krizlerin merkezinde yer alan Türkiye'nin jeopolitik konumu, barışta ve savaşta muhtelif görevler üstlenmesini, güçlü ve modern bir Silahlı Kuvvetlere sahip olmasını gerekli kılmaktadır. Ülkemizin bulunduğu bölgeden kaynaklanan klasik anlamdaki tehditlerden, asimetrik tehdide kadar her türlü tehdit ortamında, Silahlı Kuvvetlerin görevini eksiksiz olarak yapabilecek imkan ve kabiliyetlere kavuşturulması için, ihtiyaç duyulan kaynak miktarının bilinmesi gerekmektedir. Günümüzde etkin bir yapıya kavuşturulmak istenen Silahlı Kuvvetler için, ileriye dönük pek çok plan yapılmaktadır.

Türk Silahlı Kuvvetleri'nin nicelik bakımından daha küçük, nitelik bakımından daha çağdaş, etkin, hareket kabiliyeti ve ateş gücü yüksek, modern silah sistemleri ile teçhiz edilmiş ve kuvvet çarpanlarına sahip, her türlü ortam ve hava şartlarında gece gündüz kesintisiz olarak her türlü hareketi icra edebilecek, üstün hava savunma sistemleri olan, çağımızın her türlü yeniliklerini yakalayabilen, teknolojik konularda iyi eğitilmiş, çok iyi sevk ve idare edilen bir yapıya ulaştırılması hedeflenmektedir. Nitekim bu yapıya ulaşıldığını, Kuzey Irak'taki bölücü terör örgütü kamplarına yapılan kara ve hava hareketlerinde görmek mümkündür.

Türk Silahlı Kuvvetleri'nin geleceğini şekillendirecek irili ufaklı pek çok proje yürütölmekte, Silahlı Kuvvetler'in ihtiyaçlarını azami şekilde karşılayacak ve teknolojik açıdan üstün bir konuma getirecek yeni silah sistemlerinin alınması için planlamalar yapılmaktadır.

Bu aşamada, kaynak maliyet analizleri devreye girmektedir. Savunma harcamaları, özellikle silah sistemlerinin maliyetlerinin yüksek olmasından dolayı sürekli artmaktadır. Savunma harcamaları, her dönemde genel bütçe içinde önemli yer tutsa da, özellikle son yıllarda Milli Savunma Bakanlığı'nın milli bütçeden aldığı payın, düşme eğilimi gösterdiği görölmektedir. Bu azalışın, önümüzdeki dönemde de süreceğı değerlendirilmektedir. Harcamalar da dengeyi sağlama zorunluluğı vardır. Bu denge, zorunlu olan harcamaları yapmayarak sağlanamaz. Mutlak bir planlama yapılması gerekir. Bu kapsamda; MSB'nın genel bütçeden aldığı payın yıllara göre dağılımını incelemek ve geçmiş dönemdeki bütçe verilerinden yola çıkarak gelecekteki bütçe rakamlarının ne olacağı konusunda ön tahminler yapmak, gerekli planlamaları yapma ve gelecekteki yatırımlara kaynak ayırma açısından önem arz etmektedir.

Gelecekteki koşulların gelişimini görmek ve önceden tahmin etmek, geleceğı yönelik her türlü değerlendirmede alınacak kararların, her durumda daha gerçekçi olmasını sağlayacaktır. Böylece oluşacak farklı her türlü duruma uyum sağlamakta zaman kazanılacak ve zamanında gerekli tedbirler alınabilecektir.

Bu çalışmanın amacı; çeşitli istatistiksel analiz yöntemleri ile Yapay Sinir Ağları yapılarını karşılaştırıp en iyi yöntemi bularak, önümüzdeki dönemde oluşacak olan MSB bütçesini modellemek ve ön tahminler yapmaktır. Ön tahmin sonucu elde edilecek rakamlar sayesinde, bütçenin genel gelişimi ile ilgili belirsizlikler ortadan kalkacak ve bu rakamlara göre bir takım çıkarımlar yapılarak genel durum incelenebilecektir. Bu incelemeler yapıldıktan sonra yapılabilecek tasarruf veya ilave kaynak ihtiyaçları ortaya çıkacak bazı politikalar geliştirilecek ve planlı bir şekilde adımlar atılacaktır.

Çalışma, beş bölümden oluşmaktadır. Birinci bölümde; savunma harcamalarının planlaması, kaynakları, dağılımı ve harcamaları etkileyen faktörler ile MSB bütçesinin aşamaları ve bütçe kalemleri incelenmiştir.

İkinci bölümde; zaman serileri analizleri konusu incelenmiştir. Zaman serileri hakkında kısa bir bilgi verildikten sonra, durağanlık kavramı ele alınmış, zaman serileri analiz yöntemlerinden Box-Jenkins methodu incelenmiştir. Zaman serileri incelendikten sonra çalışmanın ikinci yöntemi olan regresyon analizleri açıklanmıştır. Son olarak da Yapay Sinir Ağlarının genel tanımları verildikten sonra ağ yapıları ve elemanları incelenmiş, ağ çeşitleri ile ilgili çıkarımlar yapılmıştır.

İncelen tekniklere göre modeller kurulması ve bu modellerin uygulanması üçüncü bölümün konusudur. Bu bölümde, her üç analiz yöntemine göre de alternatif modeller kurulmuş ve modellerin istatistiksel analizleri yapılmıştır.

Dördüncü bölümde; üç analiz yöntemine göre kurulan modeller karşılaştırılmış ve en iyi sonuçları veren model değerlendirildikten sonra ön tahminler yapılmıştır.

Son bölüm, sonuç ve önerilerin yapıldığı bölümdür. Bu bölümde kullanılan analiz teknikleri karşılaştırılmış, Milli Savunma Bakanlığı bütçe verilerini tahmin etmek için bir metodoloji ortaya konulmaya çalışılmıştır.

BİRİNCİ BÖLÜM

SAVUNMA HARCAMALARI

1. SAVUNMA HARCAMALARI

Dünya genelinde soğuk savaşın sona ermesiyle birlikte, savunma harcamaları önemli oranda azalmıştır. Bu azalma, özellikle kriz merkezlerinde meydana gelen gelişmelerin de etkisiyle son yıllarda, sona ermiş ve savunma harcamaları artmaya devam etmiştir (Giray, 2004: 182).


Dünya'daki toplam savunma harcamaları, 2001 yılında 819 milyar dolarken beş sene sonra 2006 yılında bu rakam 1.204 milyar dolara çıkmıştır (SIPRI [web], 2007). Bu durum pek çok ülkenin devlet harcamaları içinde savunma harcamalarının önemli bir paya sahip olduğunu göstermektedir.

Savunma harcamaları, ülkelerin gelişmişlik düzeyine göre farklı özellikler taşımaktadır. Gelişmiş ülkelerde savunma harcamaları; hem ekonomik hem de stratejik anlamda uzun vadeli bir bakışla değerlendirildiği halde, Türkiye gibi gelişmekte olan ülkelerde, ekonomik ve siyasi değerlendirmeler gerektiği gibi yapılamamakta, kısa vadeli değerlendirmelerde, daha ziyade güvenlik ihtiyacı ve tehdit altında olma duygusu, savunma politika ve bütçesinin belirleyicisi olmaktadır (Ziylan ve diğerleri, 1998: 25).

Türkiye'nin savunma harcamalarını etkileyen en büyük etken ise jeopolitik konumudur. Kriz merkezlerinin ortasında yer alan Türkiye'nin savunma harcamaları, tarihi gelişim içinde bütçede her zaman önemli bir bölümü oluşturmuştur. Bütçe açısından değerlendirildiğinde ise savunma harcamalarındaki azalma, günümüze kadar belirli oranda devam etmiştir.

Savunma harcamalarına genel bütçe dışından, belirli kanunlarla kurulan Savunma Sanayi Destekleme Fonu ile Türk Silahlı Kuvvetlerini Güçlendirme Fonu gibi kaynaklar da belirgin oranlarda destek sağlamaktadır (Sezgin, 2000).


Yıllara göre, genel bütçe ile MSB bütçesi arasındaki değişim, Şekil-1'de görülmektedir. Özellikle, 1995 yılından itibaren genel bütçe, belirgin bir şekilde artış sağlamıştır. Oldukça sert bir şekilde olan bu artış, 2003 ve 2005 yılları arasında yatay bir konuma geçmiş, 2005 yılından sonra yine yukarı yönlü hareketine devam etmiştir. Genel bütçedeki 1995 yılından itibaren oluşan dik artışa rağmen, MSB bütçesi çok az bir artış göstermiştir. MSB bütçesinin yıllar bazında, yatay bir görünüm sergilediği görülmektedir. Bu durum bize; MSB bütçesinin kısmen de olsa artmasına karşın, genel bütçede meydana gelen artış oranını yakalayamadığını göstermektedir.



Şekil-1 : Genel Bütçe ile MSB Bütçesinin Karşılaştırılması.

Farklı bir açıdan değerlendirme yapmak için, MSB bütçesinin, genel bütçe içindeki oranının da incelenmesi gerekmektedir. Şekil-2'deki grafikte bu oran, yıllar bazında değişimi görülmektedir. Grafikte, 1990 ile 2007 yıllarını kapsayan dönem içinde, bazen kısmi artışlarda görülse bu oran, belirgin

şekilde düştüğü gözlenmektedir. Bu oran, 2003 yılında en düşük seviyesine ulaştıktan sonra, 2005 yılına kadar artış göstermiş, bu artış 2005 yılında son bularak, 2007 yılında MSB bütçesinin, genel bütçeye oranı en düşük seviyeye ulaşmıştır.



Şekil-2 : MSB Bütçesinin Genel Bütçeye Oranı.

a. Savunma Harcamalarının Planlanması

Planlama aşamasında, kaynakların kullanımı önemlidir. Genel ekonomik göstergeler, büyüme hızı, dış ticaret dengesi, fiyat ve maliyet artışları, dış yardım ve kredi imkanları, kalkınma planları, hükümet programı, yürürlükte bulunan programlar ve yükümlülükler gibi etkenler dikkate alınarak plan döneminde savunma harcamalarına ayrılacak kaynak boyutları belirlenerek, Türk Silahlı Kuvvetleri'ne tahsisi mümkün olan kaynaklar değerlendirilir. (Milli Savunma Bakanlığı, 1998:117).

Değerlendirme yaparken bir takım kriterler öne çıkmaktadır. Savunma harcamalarına yönelik stratejik planlama yapılırken, bu kriterlere dikkat edilir ve planlama yapılır. Bu kriterler şunlardır (Maliye Bakanlığı, 1993:13-14):

- Ülke güvenlik menfaatleri ve taahhütleri.
- Tehdit kabulleri ve tehdidin değerlendirilmesi.
- Savunma politika ve stratejisinin belirlenmesi.
- Politik ve stratejik değerlendirmelere göre ihtiyaç duyulan silah sistemlerinin alınması ve askeri kuvvet yapısının geliştirilmesi.

Savunma harcamalarının ve kaynaklarının belirlenmesi amacıyla Türkiye’de, Planlama-Programlama ve Bütçeleme Sistemi (PPBS) olarak ifade edilen bir sistematik kullanılmaktadır. Bu sistem; Türk Silahlı Kuvvetleri’nin kuvvet yapısının teşkili, çağın gereklerine göre geliştirilmesi, harbe hazırlık düzeyinin yükseltilmesi, işletme bakım ve sefer stoklarıyla idamesi, inşaat ve altyapı faaliyetlerinin yönlendirilmesi gibi amaçlarla ayrılmış bir yönetim sistemidir. Bu sistemin oluşturulmasındaki diğer amaçlar arasında; dış kaynakların etkin, ekonomik ve zamanında kullanılmasının sağlanması da yer almaktadır (Altun, 1998:91).

Planlama; orta (3-10 yıl) ve uzun (11-20 yıl) vade için askeri strateji ile stratejik hedeflerin ve kuvvet yapısının belirlenmesi işlemidir. Programlama; planlama ile belirlenen hedeflerin kaynaklar bazında nasıl gerçekleştirileceğinin bir zaman boyutu üzerinde projelendirilmesi işlemidir. Bütçeleme ise; On Yıllık Tedarik Programlarında (OYTEP) belirtilen muhtemel kaynak tahsislerinin her yıl için o bütçe yılında nereye, ne maksatla ve ne kadar tahsis edileceğinin kararlaştırılması işlemidir.

b. Savunma Harcamalarının Finansmanı

Türkiye’de savunma harcamalarının ve aynı zamanda mali planın kaynakları şunlardır (Milli Savunma Bakanlığı, 2000:107):

- Milli Savunma Bakanlığı bütçesinden tahsisli kaynaklar.
- Savunma Sanayi Fonu kaynakları.

- Türk Silahlı Kuvvetleri Güçlendirme Vakfı kaynakları.
- Jandarma Genel Komutanlığı bütçesi.
- Sahil Güvenlik Komutanlığı bütçesi.
- Geri ödemeleri Hazine Müsteşarlığı bütçesinden garanti edilen yabancı devlet veya firma kredileri.
- Milli Savunma Bakanlığı'nın özel kanunlara dayanan gelirleridir.

Bu sıraladığımız kaynaklar içinde, savunma harcamalarının en büyük kısmını, Milli Savunma Bakanlığı bütçesi karşılamaktadır. 1985 yılında kurulan Savunma Sanayi Destekleme Fonu (SSDF) da söz konusu harcamaların karşılanmasında önemli rol üstlenmiştir. 1989 yılında kurulan Savunma Sanayi Müsteşarlığı (SSM) yürütülen projelerin finansmanını esas itibarıyla SSDF'dan karşılamaktadır. SSM'nin, modernizasyon programını yürütmek, Türkiye'de milli sanayi-yabancı teknoloji sermaye işbirliği ile Türk Silahlı Kuvvetlerinin büyük kapsamlı silah, araç ve gereç tedarik projelerinin gerçekleştirilmesini sağlamak, milli sanayi ile savunma sanayiinin ihtiyaçlarını yeniden organize ve entegre etmek, araştırma, geliştirme, prototip imali gibi çalışmalarla yatırım ve işletme faaliyetlerini finanse etmek, ihale açmak, projeyi değerlendirmek, uygulamaları takip etmek ve kamuoyunu bilgilendirmek gibi görevleri vardır. SSDF, işlemlerin gizlilik ve sürat gerektirdiği gerekçesi ile benzer kuruluşların tabi olduğu denetim süreçlerinden muaftır (Günlük-Şenesen, 2002: 38-39).

Diğer kaynakların da etkisi göz ardı edilmemekle birlikte bu çalışmada; harcamaların karşılanmasında nispeten daha büyük payı olan Milli Savunma Bakanlığı bütçesi kullanılacaktır.

c. Savunma Harcamalarını Etkileyen Faktörler

Türkiye'nin savunma harcamalarını incelediğimizde genel bir artış söz konusudur. Bunda da en büyük etken kuşkusuz Türkiye'nin

jeopolitik ve jeostratejik önemlidir. Harcamaların artmasını sağlayan diğer etmenler ise ekonomik ve siyasal istikrarsızlık, algılanan tehditler, komşu ülkelerin savunma harcamaları ile terör olaylarıdır.

Asya ile Avrupa kıtalarını birbirine bağlayan Türkiye, eskiden olduğu gibi günümüzde de, kıtalararası ticaret yollarının geçtiği bir transit merkezi durumunu, hemen hemen aynen muhafaza etmektedir. Ayrıca Türkiye'nin dünyanın en önemli petrol yataklarına sahip ülkelere komşu olması, coğrafi konumunun önemini ortaya açıkça koymaktadır (Şimşek, 1989: 144).

İki kıtanın bağlantı noktası olan Boğazlar'a sahip olan Türkiye, özellikle Dünya genelinde en önemli kriz bölgeleri olan Ortadoğu, Balkanlar ve Kafkaslar'ın merkezi durumundadır. Türkiye'nin bu coğrafi konumu stratejik açıdan önemini oldukça arttıran bir etkidir.

Siyasal istikrarsızlık dönemlerinde, iç ve dış tehditlere karşı ülkemizin korunması amacıyla silahlı kuvvetlere daha fazla ihtiyaç duyulmuştur. Dolayısıyla bu tür istikrarsızlık dönemlerinde savunma harcamaları sürekli artmıştır. 1970 ve 1980 askeri müdahaleleri ve koalisyon hükümetleri zamanında yaşanan karışıklıklar, siyasal istikrarsızlık göstergeleridir ve savunma harcamalarında artışlara neden olmuştur (Uçar, 2003: 30-31).

Tüm bu gelişmelerin yanında, özellikle komşu ülkelerde savunma harcamalarında yapılan artışlar, savunma politikalarının gözden geçirilmesine neden olmakta ve bölgedeki mevcut dengenin korunması açısından savunma harcamalarını arttırmaktadır (Kaya, 1997: 35).

Türkiye, Yüce Atatürk'ün işaret ettiği çizgide "Yurtta barış, Dünya'da barış" ilkesini dış politikasının ana unsuru olarak benimsemiştir. Ancak halihazırda, komşu ülkelerin bir takım emellerinden kaynaklanan pek çok sorun vardır. Türkiye'nin kendine yönelik tehdit olarak algıladığı

faaliyetler arasında; Yunanistan ile süregelen Kıbrıs ve Ege Sorunları (Adalar, Kıta Sahanlığı, Kara Suları), Batı Trakya Türklerine uygulanan baskılar, Kıbrıs Rum Kesimi'nin, Türkiye ile Avrupa Birliği'nin son zamanlarda hızlanan ilişkilerini engelleme hareketleri, Suriye'nin Türkiye'den toprak talebi ve Fırat sularının paylaşımı ile ilgili istekleri, Irak'ın toprak bütünlüğüne karşı özellikle de Kuzey Irak'ta yaşanan kaygı verici gelişmeler ve bölücü terör örgütüne verilen destek faaliyetleri, İran'ın benimsediği dini rejimi ihraç etmeye yönelik sergilediği davranışlar ve tüm karşı çıkmalara rağmen sürdürdüğü nükleer enerjiyi güçlendirme faaliyetleri yer almaktadır.

Ayrıca, Sovyetler Birliği'nin dağılmasından sonra etnik grupların ve azınlıkların artan bağımsızlık hareketleri, Türkiye'nin de üniter devlet yapısını ve ülke bütünlüğünü tehdit eder hale gelmiştir. Nitekim bu durumun ülkemize yansması, özellikle bölücü terör şeklinde olmuştur. Türkiye'de savunma harcamalarının özellikle 1984 yılından sonra önemli düzeyde artış göstermesinde, Doğu ve Güneydoğu Anadolu Bölgeleri'nde etkili olan bölücü terör örgütünün eylemlerine karşı yapılan silahlı operasyon maliyetlerinin büyük etkisi olmuştur (Türk, 2007: 23).

Tüm bu faktörlerin sonucunda; Türkiye'de savunma harcamalarının yüksekliği, iktisadi ve sosyal bazı problemleri beraberinde getirmektedir. Ancak ülkenin bulunduğu konum ve içinde bulunan şartlar, bu harcamaların yüksek tutulmasını zorunlu kılmaktadır. Bölgede barışın sağlandığı ve silahsızlanmaya gidildiği ölçüde savunma harcamaları azaltılarak kaynaklar ulusun refahını artırıcı giderlerde kullanılabilecektir (Kaya, 2006: 144).

2. MİLLİ SAVUNMA BAKANLIĞI BÜTÇESİ

a. Bütçenin Aşamaları

(1) Bütçenin Hazırlanması

Savunmaya ayrılan kaynağın en önemli bölümünü, Milli Savunma Bakanlığı bütçesi oluşturmaktadır. Bir sonraki yıla ait bütçe çalışmalarına cari yılın ilk yarısında başlanmaktadır. Bu çerçevede, “Fiyat Tespit ve Fiili Kadro Komiteleri” oluşturulmakta ve bütçenin hazırlanmasında esas alınacak ilkeleri açıklayan bir dizi direktif yayımlanmaktadır (Milli Savunma Bakanlığı, 1998:117-118) .

PPBS’ye uygun olarak ihtiyaçlar en küçük birlik seviyesinde belirlenmekte, tahmin edilen birim fiyatlar, fiili kadrolar, stok seviyeleri ve modernizasyon projelerinin maliyetleri esas alınarak hazırlanan birliklerin taslak bütçeleri, Milli Savunma Bakanlığı’ndaki inceleme ve düzenlemeleri müteakip, Milli Savunma Bakanlığı bütçe teklifi olarak her yıl temmuz ayının sonunda, önce Maliye Bakanlığı’nda daha sonra da Türkiye Büyük Millet Meclisi’nde yapılacak inceleme süreci için Maliye Bakanlığı’na gönderilmektedir.

(2) Bütçenin Onaylanması

Bütçenin onaylanması görevi yasama organına verilmiştir. Türkiye Büyük Millet Meclisi’ne sunulan bütçe tasarısı önce ilgili teknik komisyonlar tarafından incelenir ve düzeltmeler yapılır. Meclise sunulan bütçe tasarısı onaylanmayı müteakip Cumhurbaşkanı’na sunulur, onaylanan bütçe kanunu resmi gazetede yayımlandıktan sonra yürürlüğe girer.

(3) Bütçenin Uygulanması

Bütçe kanunu onaylanıp yayınlandıktan sonra, kanunda belirtilen esaslar çerçevesinde tahsisler ve harcamalar bakanlık tarafından yapılır.

(4) Bütçenin Denetimi

Denetim faaliyetleri uygulama esnasında ve uygulama safhasından sonra yapılır. Bütçe denetimi uygulama sırasında gelirlerin toplanması, ödeme emri, tahakkuk, ödeme emrine bağlama gibi aşamaların yapılması sırasında bizzat uygulamadan sorumlu kişiler tarafından yapılır. Bu nedenle bütçenin uygulanması sırasında yapılan denetim, üst kademenin alt kademeyi denetlediği bir idari denetimdir. Uygulama sonrasında yapılan denetim hem uygunluk denetimi, hem de harcamaların ve gelirlerin sonucunu değerlendirmek amacıyla duruma göre bakanlık teftiş kurulları, Maliye Bakanlığı Teftiş Kurulu ve Sayıştay tarafından icra edilir.

b. Milli Savunma Bütçesinin Harcama Kalemleri

Bütçe, ana hizmet gruplarına göre sıralanan dört bölümden oluşmaktadır:

(1) Personel Giderleri

Personel ile doğrudan ilgili olan özlük haklarından meydana gelmekte olup, ilgili mevzuata göre belirlenmektedir.

(2) Diğer Cariler

Bütçenin en önemli bölümünü oluşturmaktadır. Stratejik Hedef Planı (SHP)'nda yer alan modernizasyon projeleri, askeri personelin

yasalarla belirlenmiş beslenme ve giyim istihkakları, inşaatlar, bina onarımları, görev yollukları, akaryakıt, elektrik, su, doğal gaz, tedavi ve ilaç ihtiyaçları, demirbaş, kırtasiye ihtiyaçları, taşıma, ulaştırma hizmetleri, yedek parça tedariki bu ana hizmet grubunda bulunan ödenekler ile sağlanmaktadır. Bu grupta yer verilen modernizasyon harcamalarının önemli bir bölümü ekonomik alanda yatırım kategorisinde bulunmakla birlikte, bütçenin fonksiyonel ayrımına göre “Devlet Planlama Teskilatı (DPT)” denetimine tabi olmadığından, cari gider olarak kabul edilmektedir.

(3) Yatırımlar

DPT vizesine tabi bulunan ödeneklerden oluşmaktadır. Kapsamında taşıt alımları, bir kısım inşaat projeleri ve çeşitli yenileştirme projeleri yer almaktadır.


(4) Transferler

Uluslar arası kuruluşlara üyelik aidatlarını, kamulaştırmayı, geçen yıllardan kalan borçların ödenmesini ve çeşitli dernek, birlik, kurum ve kuruluşlara yapılacak sosyal yardımları kapsamaktadır.

c. Milli Savunma Bakanlığı Bütçesinin Dağılımı

Milli Savunma Bakanlığının bütçe verileri incelendiğinde genel olarak harcamaların % 30'u personel giderlerine, % 68,9'u diğer cari harcamalara, kalan kısım ise yatırım ve transfer harcamalarına ayrılmaktadır.

Milli Savunma Bakanlığı'na bağlı kurumlara gelince; bakanlığın bütçesi %49,3 oranında Kara Kuvvetleri Komutanlığı, %21,9 oranında Hava Kuvvetleri Komutanlığı, %14,4 oranında Deniz Kuvvetleri Komutanlığı, %7,2 oranında Milli Savunma Bakanlığı, %7,1 oranında ise Genelkurmay Başkanlığı tarafından kullanılmaktadır (Milli Savunma Bakanlığı, 2000:109):



Şekil-3 : MSB Bütçesinin İlgili Kuruluşlara Göre Dağılımı.

İKİNCİ BÖLÜM

KULLANILAN YÖNTEMLER

1. ZAMAN SERİLERİ ANALİZİ

a. Giriş

İstatistiksel çalışmalarda, zaman serileri veya zaman kesiti serileri kullanılır. Bu çalışmada zaman serisi verileri kullanılmaktadır.

Zaman serisi modellerinde değişkenlerin, geçmiş dönemlerdeki gözlem değerleri kullanılarak, değişkenin gelecek dönemlerde alabileceği değerlerin ön tahminleri yapılabilir. Zaman serileri, gözlemlerin belirli bir zaman aralığına göre sıralanmasıdır.

Zaman aralıkları aylık, üç aylık ve yıllık olabileceği gibi haftalık ve hatta günlük bile olabilir. Farklı aralıklara göre düzenlenmiş seriler, farklı istatistiksel özellikler gösterir.

Geçmişteki davranışlardan gelecekteki davranışları çıkarmada kullanılan basit modellerde rastlantısallık yoksa, bu modellere deterministik (basit trend denklemi) modeller denir. Zaman serilerinde kullanılan olasılık modellerine de stokastik zaman serileri denir. Zaman serisi modeli, olasılıklı bir terim içeriyorsa bu modele de olasılıklı model denir (Pindyck ve Rubinfeld, 1981: 473).

b. Zaman Serisi Çeşitleri

Zaman serileri toplanma şekillerine göre sürekli ve süreksiz olarak ikiye ayrılırlar. Gözlem değerleri belirli bir zaman aralığına göre toplanıyorsa böyle serilere süreksiz (ör; yıllık savunma harcamaları), eğer gözlem değerleri zaman içerisinde devamlı olarak toplanıyorsa böyle serilere de sürekli zaman serileri (ör; meteoroloji verileri) denir.

Zaman serileri geldikleri kaynaklara göre ekonomik, üretim, mali, demografik, sosyolojik vb. zaman serileri olarak çeşitlere ayrılırlar (Chatfield, 1978: 5).

Zaman serileri durağan ve durağan olmayan seriler olmak üzere iki şekilde incelenebilir. İncelenen zaman serisinin ortalaması ve varyansı simetrik bir değişme göstermiyorsa veya birim kök içermiyorsa, böyle serilere durağan zaman serileri denir. Seride belirgin bir trend varsa veya diğer bir ifadeyle birim kök varsa, bu serilere de durağan olmayan zaman serileri denir.

Zaman serileri göstermiş oldukları periyodik şekillere göre de mevsimlik ve mevsimlik olmayan zaman serileri diye ikiye ayrılabilir. Bu şekilde bir ayrımın yapılması için serinin gözlem değerleri bakımından yeterli uzunlukta olması gerekir. Genelde güvenilir sonuç için örneklem sayısı en az 100 olmalıdır (Kayım, 1985: 70).

c. Zaman Serisinin Bileşenleri

Zaman serilerinin gözlem değerlerinde, zaman içinde azalma ya da artma şeklinde, değişimler görülebilir. Ekonomik, sosyal, psikolojik vb. çeşitli nedenlerin zaman serisi gözlem değerleri üzerindeki, yön ve şiddetinin farklı olmasından ileri gelen bu değişmelerin dört elemandan oluştuğu görülür.

(1) Trend

Zaman serisinin uzun dönemdeki eğilimini gösterir. Trendin biçiminin bilinmesi, işletmelerin uzun döneme göre süresi sınırlanmış (uzun vadeli) plan ve programlarının en iyi biçimde düzenlenmesine olanak tanır. Trend, genel ve sürekli nedenlerin etkisinden dolayı ortaya çıkar (Bozkurt, 2007: 9).

(2) Mevsimlik Değişmeler

Seri içinde belirli ve eşit aralıklarla meydana gelen ve düzenli bir biçimde tekrarlanan dalgalanmalara, periyodik değişme adı verilir. Periyodik değişme, değişimin tamamlanması için geçen sürenin uzunluğuna göre adlandırılır. Günlük, haftalık, aylık, yıllık vb. periyodik değişmeler olabilir. En önemli periyodik değişme mevsimlik değişmedir. Mevsimlik değişmeler bir yıldan kısa süreli ay ve üç aylık zaman serilerinde görülebilir. Bir yıldan daha uzun süreli zaman serilerinde mevsimlik değişme yerine devresel (konjoktürel) değişmeler görülür (Bozkurt, 2007: 16).

(3) Devresel Değişmeler

Genellikle gelişmiş piyasa ekonomileri için toplanmış serilerde devresel etkilere rastlanır. Bir yıldan uzun, değişik sürelerle tekrarlanan dalgalanmalardır. Çevrimsel değişmelerin süreleri çoğunlukla 3-15 yıl arasında değişir. Uzun yılları kapsadığından devresel değişmeleri takip etmek zordur (Chatfield,1978:10).

(4) Rastlantısal Değişmeler

Belirli faktörler dışında kalan, varlığı daha önce tahmin edilemeyen ve etkisini devamlı olarak göstermeyen bazı olayların (grevler, devalüasyonlar vb.) sonucunda ortaya çıkar. Rastlantısal değişmelerin

tahmini diğer deęişmelerin aksine yapılamaz. Ne zaman ne biçimde meydana geleceęi bilinmeyen dalgalanmalardır (Kayım, 1985: 18)

Bileşenleri hesaplamada kullanılan iki teknik klasik parçalara ayırma ve Census II yöntemleridir. Bu tekniklerle seri üzerindeki etkiler hesaplanarak giderilmeye çalışılır. Bu etkilerin seri üzerinde çarpımsal bir etkisi olduęu varsayılır. Bu etki řu řekilde hesaplanır (Pindyck ve Rubinfeld, 1981: 488).

$$y_t = LSCI \quad \text{Çarpımsal} \quad [2.1]$$

$$y_t = L + S + C + I \quad \text{Toplamsal} \quad [2.2]$$

Burada;

y_t :zaman serisi deęişkenini,

L :trendi,

S : mevsimlik deęişmeleri,

C : devresel deęişmeleri,

I : rastlantısal deęişmeleri ifade etmektedir.

d. Duraęanlık

Stokastik bir süreç izleyen zaman serilerinde, serinin duraęan olup olmadıęı, incelemenin saęlıklı yapılabilmesi açısından önemlidir. Stokastik veya tesadüfi bir deęişkenin zaman içerisinde ortalaması, varyansı ve otokovaryansının sabit olması řeklinde ifade edilebilen duraęanlık kavramı, serinin deęerlerinin belli bir deęere yaklařmasını ya da belirli bir deęer etrafında dalgalandıęını ifade eder. Eęer stokastik bir süreç duraęan

değilse, serinin davranışı sadece ele alınan tahmin dönemini kapsar, diğer dönemlerle ilgili bir genelleme yapılamaz (Granger ve Newbold ,1986: 38-41). Bu durumda durağanlık koşulları şu şekilde ifade edilir:

$$E(y_t) = \mu \quad [2.3]$$

$$Var(y_t) = E(y_t - \mu)^2 = \sigma^2 \quad [2.4]$$

$$E[(y_t - \mu)(y_{t-k} - \mu)] = \gamma_k \quad [2.5]$$

Bu eşitliklerde, μ (ortalama), σ^2 (varyans), γ_k (kovaryans) sabittir. Bu şekilde ifade edilen durağanlığa zayıf ikinci mertebeden durağanlık denir.

Güçlü durağanlık ise değişkenin koşullu olasılık dağılımının zaman içerisinde değişmediği bir süreci gösterir (Enders, 1995: 69).

Durağanlığın tespit edilmesi için pek çok yöntem mevcuttur. Serinin grafiği incelendiğinde seyir konusunda önsel bir bilgi edinilebilir. Durağanlığın şartı, zaman içerisindeki artış ve azalışların tamamen düzensiz olmasıdır. Artış ve azalışlardaki sürekli artma eğilimi durağansızlığa işarettir. Ayrıca grafikte, mevsimsel etkiler görülüyorsa bu durumda durağansızlığı gösterir. Durağanlığın tespitinde otokorelasyon fonksiyonunun incelenmesi, Portmanteau testi ve birim kök testi gibi testler de kullanılmaktadır.

e. Box-Jenkins Yöntemi

(1) Giriş

Zaman serileri analizinde en yaygın olarak kullanılan yöntem Box-Jenkins yöntemidir.

Box-Jenkins yönteminde, ön tahmin modellerinin uygulanmasında zaman serisinin, belirli ve eşit aralıklı gözlem değerlerinden oluşan kesikli bir seri olduğu var sayılmaktadır. Bu yöntemin amacı, en az sayıda parametre içeren uygun modeller elde etmektir. Box-Jenkins uygulamalı çalışmalardan elde edilen bilgileri kullanarak amaca uygun genel modeller ortaya koyar. Ayrıca Box-Jenkins ön tahmin modelleri, çeşitli model seçenekleri arasında uygun olanını seçme ve seçilen modelin kurulmasındaki her aşamada modelin incelenen probleme uygunluğunu denetleme gibi olanaklara sahiptir.

(2) Box- Jenkins Yönteminin Aşamaları

Box-Jenkins bir birini tamamlayan dört aşamadan geçerek ön tahmin modellerinin kurulmasını önerir. Bunlar belirleme (identification), parametre tahminleri (estimation), uygunluk testleri (diagnostic checking) ve öngörü (forecasting) olarak sıralanabilir (Box-Jenkins, 1976).

(a) Belirleme (Identification)

Belirleme aşamasında öncelikli olarak zaman serisinin durağanlığı araştırılır. Serinin durağan olup olmadığı yukarıda açıklandığı şekilde belirlenir. Seri durağansa, mevcut durumuyla, durağan değilse uygun derecede farkı alınarak durağan hale getirilir. Bu aşamadan sonra serinin $AR(p)$, $MA(q)$ ya da $ARMA(p,q)$ modellerinden hangisi olduğuna karar verilerek p ve q değerleri bulunur. Zaman serisinin ACF ve PACF değerleri incelenerek seri mevsimlik fark barındırıyorsa, d kadar fark alınarak sürece devam edilir.

(i) Otokorelasyon Fonksiyonu (ACF)

Otokorelasyon fonksiyonu, olası uygun modelleri belirlemede ve hangi modelin seçilmesi konusunda önemli bilgiler veren analiz araçlarından biridir. Uygulamada karşılaşılan bir dağılım fonksiyonun

ifade edilmesine benzeyen otokorelasyon fonksiyonu, zaman serileri analizinde incelen verilerin hangi parametrik modellerle gösterilmesi gerektiği ile ilgili de bazı ipuçları verir.

Stokastik süreçten gelen bir modelin k gecikmesi için ρ_k otokorelasyonu aşağıdaki gibi tanımlanır.

$$\rho_k = \frac{E[(y_t - \mu)(y_{t-k} - \mu)]}{\sqrt{E[(y_t - \mu)^2]E[(y_{t-k} - \mu)^2]}} \quad [2.6]$$

$$\rho_k = \frac{E[(y_t - \mu)(y_{t-k} - \mu)]}{\sigma^2} \quad [2.7]$$

$$\rho_k = \frac{\gamma_k}{\gamma_0} \quad [2.8]$$

Eşitliklerde;

μ :aritmetik ortalama,

σ^2 : varyans,

γ_k : k gecikme için kovaryans,

γ_0 : varyanstır.

Elde edilen otokorelasyon fonksiyonuna korelogram denir. Durağan bir serinin korelogramı incelendiğinde, Q (Ljung-Box) istatistiklerin anlamlı olup olmadığı söylenebilir. ACF değerleri, durağan bir seri için sıfıra yaklaşırsa, bütün gecikmeler için otokorelasyon olmadığını söyleyen hipotez kabul edilir. Serinin gecikme değerleri artırıldığında ACF değerleri sıfıra yaklaşıyorsa seri durağan, aksi halde durağan değildir (Enders, 1995: 78).

(ii) Kısmi Otokorelasyon Fonksiyonu (PACF)

Otokorelasyon fonksiyonu ile birlikte kullanılan diğer bir fonksiyonda kısmi otokorelasyon fonksiyonudur. Geçici olarak belirlenen uygun öngörü modellerinin p ve q gibi mertebelerinin ne olması gerektiğini ortaya koyar.

Otokorelasyon ve kısmi otokorelasyon fonksiyonlarının mevsimlik olmayan seriler için uygun modelin otoregresif (AR), hareketli ortalama (MA) veya karışık otoregresif hareketli ortalama (ARMA) modellerinden hangisinin olacağının belirlenmesinde kullanılacak yardımcı bilgiler Tablo-1’de görülmektedir (Hanke ve Wichern, 2005: 389).

Tablo-1: Model Belirlemede Kullanılan Otokorelasyon ve Kısmi Otokorelasyon Örnekleri.

SÜREÇ	ACF	PACF
AR(p)	Azalan görünüm sergiler.	p gecikmeden sonra eksenini keser.
MA(q)	p gecikmeden sonra eksenini keser.	Azalan görünüm sergiler.
ARMA(p,q)	Azalan görünüm sergiler.	Azalan görünüm sergiler.
Durağan Olmayan Zaman Serisi	Sıfıra doğru azalma görülmez.	Sıfıra doğru azalma görülmez.
Mevsimlik Etki	Belirli aralıklarda sıfırdan farklıdır.(4.,8. dönem)	Belirli aralıklarda sıfırdan farklıdır.(4.,8. dönem)

(3) Parametre Tahminleri (Estimation)

Box-Jenkins yönteminin ikinci aşaması parametre tahminleridir. Bu aşamada belirlenmiş modelin parametreleri hata kareler toplamını minimum yapacak şekilde tahmin edilir. Bu tahminler, doğrusal olmayan en küçük kareler yöntemiyle yapılır. Doğrusal olmayan hata kareler yöntemi, adım adım hata kareler toplamını bulan bir algoritmadır. En küçük kareler tahminleri ve standart hataları bulunduğundan sonra t değerleri hesaplanır. Parametre değerlerinin anlamlı olarak sıfırdan farklı olup olmadığı kontrol edilir. Anlamlı olmayan parametreler modelden atılır.

Box-Jenkins tahmin modelinde iteratif bir yöntem kullanılır. Marquardt algoritması kullanılarak parametreler tahmin edilir. Bunlara ek olarak hata kareler toplamı yani $\mathcal{E}_t$ nin tahmin varyansı:

$$s^2 = \frac{\sum_{t=1}^n e_t^2}{n-r} = \frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n-r} \quad [2.10]$$

ile bulunur. Burada;

$\mathcal{E}_t$: t zamanındaki hatayı

n : hataların sayısını

r : tahmin edilen toplam parametre sayısını göstermektedir.

(a) Uygunluk Testleri (Diagnostic Checking)

Uygunluk testleri, örneklem için öngörü hatalarının otokorelasyonlarını kullanarak, belirleme ve etkin parametre tahmini aşamaları sonucunda seçilmiş bulunan modelin zaman serisi için uygun olup

olmadığını gösterir. Modelin uygunluğunun test edilmesi sırasında serinin otokorelasyonları incelenerek, Box- Pierce tarafından geliştirilen ve Ljung-Box tarafından düzeltilen Q istatistiği hesaplanır. Özellikle gözlem sayısının 100' den az olduğu durumlarda χ^2 dağılımının yetersiz olacağını savunan Ljung ve Box düzeltilmiş Q istatistiğinin kullanımını önermektedir (Ljung ve Box, 1978: 297-303). Box- Pierce tarafından geliştirilen Q istatistiği şu şekilde hesaplanır;

$$Q = n \sum r_k^2(a) \quad [2.11]$$

Burada $k=1, 2, 3, \dots, m$ 'dir. $r_k(a)$ örneklem içi öngörü hatalarının çeşitli gecikmelerdeki otokorelasyonlarıdır. n ise örneklem hataları büyüklüğüdür. (Box- Pierce, 1970). Ljung- Box tarafında düzeltilen Q istatistiğinde ise,

$$Q^m = n(n+2) \sum_{k=1}^m \frac{r_k^2(e)}{n-k} \quad [2.12]$$

olup Q^m yaklaşık olarak $m-r$ serbestlik derecesinde χ^2 dağılımına uygundur. Burada;

$r_k(e)$: k gecikmedeki hata otokorelasyonu,

n : hata sayısı,

k : gecikme,

m : test edilen gecikme sayısıdır.

Eğer Q istatistiğinden elde edilen p-değeri küçükse (p-değeri < 0.05) model uygun değildir. Yeni veya düzeltilmiş bir model kurulması ve testlere devam edilmesi gerekir.

Modeli doğru değerlendirmek çok önemlidir. Modelin doğru çalıştığı tespit edilirse alışılmadık durumlardan kaynaklanan birkaç hata değeri göz ardı edilebilir. Bu durumda model, kalan gözlem değerleri için uygun olur.

(b) Öngörü (Forecasting)

Uygun bulunan modeller bulunduğundan sonra gelecek için ön tahminler yapılabilir. Mevsimlik olmayan serilerde hata kareleri minimum olan ön tahminler, o modelin fark denklemi biçimi kullanılarak elde edilir.

Geriye doğru (recursive) hesaplamalarda öngörü değerleri ve bu değerlerin güven aralıkları bulunur.

Şimdiki dönemde Y_{t+l} gözlem değeri için, $\hat{Y}_t(l)$ gibi bir ön tahmin yapılır. Bu durumda ön tahminin, t başlangıcına göre l ön dönemi (lead time) için yapıldığı söylenir. t başlangıç döneminde l ön dönemi için yapılan ön tahminler, $Y_t, Y_{t-1}, Y_{t-2}, \dots$ gözlem değerlerinin doğrusal bir fonksiyonu olduğuna gibi aynı zamanda $\varepsilon_t, \varepsilon_{t-1}, \varepsilon_{t-2}, \dots$ hata terimlerinin de doğrusal bir fonksiyonudur. l ön dönem için hata terimi $e_t(l)$ aşağıda verilen denklemden hesaplanır.

$$e_t(l) = \varepsilon_{t+l} + \psi_1 \varepsilon_{t+l-1} + \dots + \psi_{l-1} \varepsilon_{t+1} \quad [2.13]$$

Eğer $E[e_t(l)] = 0$ ise ön tahmin sapmasızdır. Ön tahminin varyansıda şu şekilde hesaplanır.

$$Var[e_t(l)] = (1 - \psi_1^2 + \psi_1^2 + \dots + \psi_{l-1}^2) \sigma_a^2 = 1 + \sum \psi_i^2 \sigma_a^2 \quad [2.14]$$

Normal dağılım varsayıldığında Y_{t+L} 'nin güven aralıkları şu şekilde hesaplanır.

$$y_t = (L) \pm 1,96 \sqrt{VAR [\varepsilon_n (L)]} \quad [2.15]$$

Durağan ve y_t için $t = n + L$ olan ARIMA(p,0,q) süreci şu şekilde gösterilir,

$$y_{t+L} = \phi_1 y_{n+L-1} + \dots + \phi_n y_{n+L-p} + \varepsilon_{n+L} - \theta_1 \varepsilon_{n+L-1} - \dots - \theta_n \varepsilon_{n+L-p} \quad [2.16]$$

Burada, t gözlem dönemi L' de kestirilecek dönemdir. Verilen denklemden y_{t+L} şu şekilde bulunur:

- $y_{t-j}, (j = 0,1,2 \dots)$ Gerçekleşmiş gözlem değerleridir, herhangi bir değişiklik yapılmadan bırakılır.
- $y_{t+j}, (j = 0,1,2 \dots)$ Henüz gerçekleşmemiş gözlem değerleri olup, öngörü değerleri ile değiştirilir.
- $\varepsilon_{t-j}, (j = 0,1,2 \dots)$ Dönem farklarından hesaplanmakta ve değerleri bilinmemektedir.
- $y_{t+j}, (j = 0,1,2 \dots)$ Değerleri bilinmemektedir, sıfır alınır (Kayım,1985: 85-87).

Box-Jenkins yönteminde üç modelleme söz konusudur. Bunlardan ilki Otoregresif (AR) Süreci, ikincisi Hareketli Ortalamalar (MA) sürecini, sonuncusu ise diğer iki modelin birleşiminden oluşan Otoregresif Hareketli Ortalamalar (ARMA) sürecidir. Durağan olmayan bir seride fark

alınması durumunda ise ARMA süreci, Birleşik Otoregresif Hareketli Ortalamalar (ARIMA) sürecine dönüşür.

f. Süreçler

Box- Jenkins öngörü modelleri iki önemli stokastik sürece dayanır.

(1) Doğrusal Durağan Stokastik Süreç

Doğrusal durağan stokastik süreç istatistiksel dengeyi ifade etmektedir. Özellikle gözlem değerleri sabit bir ortalama etrafında değişim göstermektedir. Uygulamada zaman serilerinin modellenmesinde kullanılan doğrusal stokastik süreçler sınıfında yer alan önemli öngörü modelleri aşağıdadır.

(a) Otoregresif (AR) Modeller

Otoregresif süreç; değişkenin t döneminde ve p periyodunda, geçmiş dönemde incelenen belirli sayıdaki gözlemlerle, hata değişkeni ε_t 'nin doğrusal birleşimidir. Bu durum şu formda gösterilir:

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad [2.17]$$

Bu denkleme p mertebesinde otoregresif model denir ve AR(p) şeklinde gösterilir. Basit bir AR(1) süreci şu şekildedir.

$$y_t = \phi_1 y_{t-1} + \varepsilon_t \quad [2.18]$$

Bu model bağımlı değişken, bir dönem gecikmesi ve hata teriminden oluşmaktadır.

AR(1) sürecinde Otokorelasyon fonksiyonun (ACF) azalan görüntüsü ve Kısmi Otokorelasyon fonksiyonunda (PACF) anlamlı bir p değeri söz konusudur (Pindyck ve Rubinfeld, 1981: 520).

(b) Hareketli Ortalama (MA) Modelleri

Hareketli Ortalama modelinde değişkenin t dönemindeki değeri aynı dönemdeki hata terimi ve belirli sayıda geri dönem hata terimleri doğrusal bileşimidir.

$$y_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad [2.19]$$

Burada hata terimi, sıfır ortalamaya ve sabit varyansa sahiptir. MA süreci yavaş etkileri modellemede kullanılan ve serideki trend eğilimini ortadan kaldırmak için tercih edilen bir yöntemdir. MA(1) süreci:

$$y_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} \quad [2.20]$$

şeklinde ifade edilebilir.

MA sürecinde, ACF ve PACF değerlerine bakarak PACF’de geometrik azalma ve ACF’de anlamlı çıkışlar takip edilerek Gecikme sayısı (q) belirlenir (Gujarati, 1999: 736-737).

(c) Karışık Oto regresif Hareketli Ortalama (ARMA) Modelleri

Bazı stokastik durağan seriler ne oto regresif ne de hareketli ortalama süreçleriyle modellenenebilir. Bu serilerde her iki süreç de aynı anda kullanılır. Bu durumda ortaya çıkarılan ARMA(p,q) modeli şu şekilde ifade edilir:

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad [2.21]$$

Bu seri durağandır. En basit ARMA(1,1) modeli şu şekildedir:

$$y_t = \phi_1 y_{t-1} + \varepsilon_t - \theta_1 \varepsilon_{t-1} \quad [2.22]$$

Bu süreçte ACF ve başlangıç değerinden sonra geometrik bir şekilde azalır. Bu bize MA sürecinin bir periyotluk olduğunu gösterir (Pindyck ve Rubinfeld, 1981: 526-527).

(2) Doğrusal Durağan Olmayan Stokastik Süreçler

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

(a) Birleştirilmiş Otoregresif Hareketli Ortalama (ARIMA) Modelleri

Durağan olmayan zaman serileri, ARMA modellerinin özel bir hali olan Birleştirilmiş Otoregresif Hareketli Ortalama (ARIMA) modelleriyle gösterilir. Bu modeli şu şekilde ifade edebiliriz:

$$w_t = \Delta^d y_t \quad [2.23]$$

durağan bir seriyi ifade eder. Buradaki Δ fark işlemidir.

$$\Delta y_t = y_t - y_{t-1} \quad [2.24]$$

$$\Delta^2 y_t = \Delta y_t - \Delta y_{t-1} \quad [2.25]$$

şeklinde gösterilir. Burada incelenen w_t serisinden, y_t serisini şu şekilde elde ederiz:

$$y_t = \sum^d w_t \quad [2.26]$$

Bu denklemde, $\sum$ toplama işlecini ifade etmektedir. Δ işlecini, Δ fark işleci şeklinde gösterirsek:

$$\Delta = 1 - B \quad [2.27]$$

$$\sum = \Delta^{-1} = (1 - B)^{-1} \quad [2.28]$$

olur. Durağan w_t serisini elde etmek için, y_t serisinin farkını aldıktan sonra, w_t serisi ARMA süreci şeklinde modellenir. Eğer $w_t = \Delta^d y_t$ ve w_t serisi, ARMA(p,q) süreci ise, y_t serisinin Birleştirilmiş Otoregresif Hareketli Ortalama süreci (p,d,q) yani ARIMA (p,d,q) olduğu ifade edilerek;

$$\phi(B) \Delta^d y_t = \theta(B) \varepsilon_t \quad [2.29]$$

şeklinde gösterilir (Pindyck ve Rubinfeld, 1981: 529-530).

(b) Mevsimlik Öngörü Modelleri

Pek çok ekonomik seride trend ve mevsimlik etkiler birlikte görülmektedir. Mevsimlik etkiler; hava, tatil günleri, ya da tekrarlanan

promosyonlar gibi ekonomik etkiler yüzünden, periyodik ve yinelenen davranışlar gösterirler (Hylleberg, 1992: 4). Özellikle tarım, inşaat ve turizm sektörlerinde belirgin bir şekilde bu etkiler görülmektedir. Mevsimlik etkilerden arındırılmamış seriler kullanmak, çoğu zaman hatalı sonuçlar vermektedir. Trend ve mevsimlik etkiler yok edilerek durağanlaştırılmış seriler pek çok ekonomik alanda etkili ve doğru kararlar vermek için kullanılmaktadır (Makridakis ve Wheelwright, 1987).

Böyle birbirini izleyen periyotlardaki gözlem değerleri arasındaki ilişkiler aşağıdaki modelle gösterilir:

$$\Phi(B^s)\Delta_s^D y_t = \Theta(B^s) \varepsilon_t \quad [2.30]$$

Burada s=4 veya 12 olup mevsimsel etkinin periyodunu göstermektedir. $\Delta_s = (1 - B^s)$ olup $\Phi(B^s)$ 'ler P ve Q mertebesindeki B^s polonomiyallarıdır, durağanlık ve çevrilebilirlik koşulunu karşılarlar (Box-Jenkins 1970: 304). Aynı şekilde;

$$\Phi(B^s)\Delta^d y_{t-1} = \Theta(B^s) \varepsilon_{t-1} \quad [2.31]$$

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.

Bu modellerde hata terimleri genellikle ilişkili değildir. Bu gibi ilişkiyi göz önüne alarak ikinci bir model ortaya konur. Bu model mevsimlik zaman serileri için çarpımsal öngörü modeli elde edilir.

$$\phi_p(B)\Phi_p(B^s)\Delta^d\Delta_s^D y_t = \theta(B)\Theta_Q(B^s)\varepsilon_t \quad [2.32]$$

Burada;

p :otoregresif mevsimlik olmayan model mertebesini,

P :otoregresif mevsimlik model mertebesini,

q :mevsimlik olmayan hareketli ortalama model mertebesini,

Q :mevsimlik hareketli ortalama model mertebesini,

ϕ :mevsimlik olmayan otoregresif parametreyi,

Φ :mevsimlik otoregresif parametreyi,

θ :mevsimlik olmayan hareketli ortalama parametresini,

Θ :mevsimlik hareketli ortalama parametresini,

d :zaman serisinin yıllara göre alınmış farklarını,

D ise serinin mevsimlere göre alınmış farklarını göstermektedir. Bu modele genel olarak $(p,d,q) \times (P,D,Q)$ s mertebesinde çarpımsal mevsimlik öngörü modeli denir (Kayım, 1985: 88-89).

2. REGRESYON ANALİZLERİ

Milli Savunma Bakanlığı bütçe verilerini kullanarak, ön tahmin yapmak amacıyla alternatif olarak kuracağımız modellerden biri de ekonometrik yöntemlerdir.

a. Basit Doğrusal Regresyon

Regresyon analizinde, bir değişkendeki değişmeler onu etkileyen başka bir değişken veya değişkenler tarafından açıklanır. Değişmelerin bir değişken tarafından açıklanması, basit regresyon olarak tanımlanır. Basit doğrusal regresyon modelinde, bir bağımlı ve bir bağımsız değişken vardır ve şöyle tanımlanır;

$$Y = a + bX \quad [2.33]$$

denkleminde Y bağımlı değişken, X ise bağımsız değişkendir.

Bu model deterministik bir ilişkiyi göstermektedir. Tamamıyla matematiksel bir karakterde gelişir. Ekonometrik araştırmalarda, deterministik denklemler yerine hata terimi içeren olasılıklı (stokastik) denklemler kullanılır. Şöyle ki:

$$y_i = \hat{\alpha} + \hat{\beta} x_i + u_i \quad [2.34]$$

Burada y_i bağımlı değişkeni, x_i bağımsız değişkeni, $\hat{\alpha}$ ve $\hat{\beta}$ modelin parametrelerini, u_i ise hata terimini göstermektedir.

Model parametreleri, en küçük kareler yöntemi (EKKY) kullanılarak tahmin edilir. Modellerde tahmin edilen değerler ile gerçek değerler arasında bir takım etkenlere bağlı olarak farklar meydana gelmektedir. EKKY öyle tahminler ortaya koyar ki, bu tahminler hata kareler toplamını minimize eder. EKKY diğer yöntemlere kıyasla minimum varyanslı tahmin ediciler, ortaya koyan en uygun yöntemdir. (Maddala, 2001: 68-71).

b. Çoklu regresyon modelleri

Regresyon modellerinde temel amaç; bağımlı ve bağımsız değişkenler arasındaki nedensellik ilişkilerini ortaya koymak ve tahmin edilen model kullanılarak ön döneme yönelik ön tahminler elde etmektir (Johnston ve Dinardo, 1997: 69).

Çoklu regresyon modelleri şu denklemlerle gösterilir;

$$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + \dots \beta_k X_k + u \quad [2.35]$$

yazabiliriz. Burada;

Y : bağımlı değişkeni,

X_i : bağımsız değişkenleri,

β_1 : regresyon sabit parametresini,

$\beta_2, \beta_3, \dots, \beta_k$: regresyon parametrelerini,

u : hata terimini göstermektedir.

Model parametreleri, EKKY ile tahmin edilir. EKKY tahmin edicileri, istatistiksel niteliklerin (doğrusal, sapmasız, minimum varyans) tümünü karşılamaktadır. Bu çalışmada, ön tahminler yapmak için kurulacak model çoklu regresyon modelidir.

Bağımlı ve bağımsız değişkenler arasındaki ilişkinin açıklanmasında kullanılan bağımsız değişkenlerden bazıları kantitatif, bazıları kalitatif olabilir. Kalitatif nitelikte olan değişkenler, kukla değişkenler olarak tanımlanır.

c. Kukla (Dummy) Değişkenler

Bağımlı değişkeni etkileyen kantitatif bağımsız değişkenlere ek olarak, kalitatif özellikte olan değişkenlerinde modele getirilmesi gerekebilir. Örneğin; zaman içerisinde oluşan ekonomik ve siyasi krizler, terör olayları, yakın komşu ülkelerde meydana gelen rahatsızlıklar ve rakip komşu ülkelerde savunma sanayine yapmış olduğu yatırımlar vb. gibi durumlarda kalitatif özellikte olan kukla (dummy) değişkenler içeren regresyon modelleri kullanılır.

Kukla değişkenleri, genellikle bir niteliğin ya da özelliğin varlığını ya da yokluğunu gösterdiği için 0 veya 1 değerlerini alan yapay değişkenler oluşturmaktadır. Bir regresyon modelinin bütün bağımsız değişkenleri kukla

değişkenlerden oluşuyorsa bu tür modellere varyans çözümlemesi (VARÇÖZ) modelleri denir (Gujarati, 1999: 500-506).Örneğin;

$$Y_i = \alpha + \beta D_i + u_i \quad [2.37]$$

modelinde, Y_i : Savunma harcamaları olsun,

$D_i=1$ ekonomik kriz varlığını,

$D_i=0$ ekonomik krizin olmadığını,

gösterir. Burada D kesişim kukla değişkenidir. Model bize savunma harcamalarındaki ekonomik krizlerin rolünü tanımlamaktadır.

Ekonomik kriz yoksa savunma harcamaları: $E(Y_i / D_i = 0) = \alpha$

Ekonomik kriz varsa savunma harcamaları: $E(Y_i / D_i = 1) = \alpha + \beta$

Sabit terim α , ekonomik krizin olmadığı durumdaki savunma harcamalarını, eğim katsayısı β , kriz durumunun yarattığı farkı, $\alpha + \beta$ ise kriz durumunda savunma harcamalarını göstermektedir.

Ekonometrik araştırmaların çoğunda, açıklayıcı değişkenlerin bazıları kalitatif bazıları ise kantitatifdir. Yani kalitatif ve kantitatif değişkenler beraber kullanılmaktadır. Bu tür modellere ortak varyans çözümlemesi (ORVÇÖZ) denir. Daha önce verilen örnekten yola çıkarak, modele döviz kurunu tanımlayan bir X bağımsız değişkeni, getirip yeni bir eğim kukla değişkeni tanımlarsak:

$$Y = \alpha_1 + \alpha_2 D_1 + \beta X + \gamma (ZX) + u \quad [2.38]$$

modelini elde ederiz.

Burada;

Y : savunma harcamaları,

D_1 kesişim kukla değişkeni;

$D_1 = 1$, ekonomik kriz var,

$= 0$, ekonomik kriz yok.

X : döviz kuru,

(ZX) eğim kukla değişkeni;

$(ZX) = X$, döviz kuru yüksek ($Kur > 1.5$ YTL.),

$= 0$, döviz kuru düşük ($Kur < 1.5$ YTL.) .

$\alpha_1, \alpha_2, \beta$ ve γ : model parametreleridir.

Modelde $E(u) = 0$ olduğunu varsayarsak şunu görürüz;

1. $E(Y / X, D_1 = 0, ZX = 0) = \alpha_1 + \beta X$; ekonomik kriz yok, döviz kuru düşük.

2. $E(Y / X, D_1 = 0, ZX = X) = \alpha_1 + (\beta + \gamma)X$;ekonomik kriz yok, döviz kuru yüksek.

3. $E(Y / X, D_1 = 1, ZX = 0) = (\alpha_1 + \alpha_2) + \beta X$;ekonomik kriz var, döviz kuru düşük.

4. $E(Y / X, D_1 = 1, ZX = X) = (\alpha_1 + \alpha_2) + (\beta + \gamma)X$;ekonomik kriz var, döviz kuru yüksek.

Yukarıda modelde, kukla değişkenlerin aldığı değerlere göre beklenen değerlerdeki değişimler görülmektedir. Örneğin; hem ekonomik

krizin olduđu, hem de döviz kurunun yüksek olduđu durumda model řu řekilde olacaktır:

$$Y = (\alpha + \alpha_2) + (\beta + \gamma) X + u \quad [2.39]$$

Modelde, kukla deđiřkenlerde m bađımsız deđiřken düzeyi varsa kukla deđiřken sayısı m-1 olmalıdır.

3. YAPAY SİNİR AĞLARI ANALİZLERİ

a. Giriř

Günümüz dünyasında, bilgisayarlar ve bilgisayar sistemleri yařantımızın ayrılmaz bir parçası olmuřtur. Bu teknolojilerde meydana gelen mükemmel geliřmeler, bilgisayarların yaptıđı iřlerin boyutunu da deđiřtirmiřtir. Bilgisayarlar, artık hem olaylar hakkında karar verebilmekte hem de olaylar arasındaki iliřkileri öđrenebilmektedir. Bilgisayarlara bu özellikleri kazandıran ve bu yeteneklerin geliřmesini sađlayan çalıřmalar “yapay zeka” olarak bilinmektedir.

Yapay zeka sistemlerinin en temel özelliklerinin, olaylara ve problemlere çözümler üretirken veya çalıřırken, bilgiye dayalı olarak karar verebilme özelliklerinin olması ve eldeki bilgiler ile olayları öđrenerek, sonraki olaylar hakkında kararlar verebilmeleri olduđu söylenebilir (Öztemel, 2003: 13).

Yapay zeka çalıřmalarındaki geliřmeler, yeni teknolojilerin dođmasına neden olmuřtur. Bunların bařlıcaları řunlardır; uzman sistemler, bulanık mantık, genetik algoritma, yapay sinir ađları vb. (Elmas, 2003: 21).

Özellikle Yapay Sinir Ađları, diđer kullanım alanlarının yanında, çeřitli ekonomik çalıřmalarda ön tahmin yapma amacıyla yaygın olarak

kullanılmaktadır. Hill, Tang ve Buhamra'nın yaptığı çalışmalarda ve yapılan diğer pek çok çalışmada; YSA yapıları tahmin aracı olarak iyi sonuçlar vermiştir.

Temelde yapay sinir ağları, insan beyninin mimarisinden yola çıkılarak düzenlenmektedir. Bu konudaki ilk teoriler Mc Culloch ve Pitts tarafından 1943 yılında ortaya atılmıştır. Daha sonra Hebb'in çalışması (Hebb,1949) öğrenme teorisinde, insan beyninin nöronlarının nasıl öğrendiklerini ortaya koymaya çalışmıştır. 1958 yılında Rosentblatt algılama üzerinde durmuştur. Yapay sinir ağları hakkında en başarılı uygulamalar 1960'lı yıllarda Widrow ve Hoff tarafından geliştirilmiştir. Paul Werbos 1974 yılında Widrow–Hoff prosedürü için karşıt hata görevleri yapısını teklif etmiş, böylece daha önceki tek-katman kısıtı elimine edilmiş ve pek çok kısıtlı süreç hesaplanabilmiştir. Diğer gelişmeler, büyük ölçüde Kolmogorov'un (1957) süper durum teoreminden esinlenmiştir. Bu bize, sürekli fonksiyonların doğrusal olmayan sonuçlarla, doğrusal sonuçların bütünleştirilmesiyle hesaplanabileceğini göstermiştir (Krycha ve Wagner, 1999: 186).

1982 yılında Hopfield, YSA yapılarının matematik temellerini üretmiş, 1986 yılında Rumelhart ve McClelland karmaşık ve çok katmanlı ağlar için geriye yayımlı öğrenme algoritmasını ortaya koymuşlardır (Elmas, 2003: 29).

b. Genel Tanımlar

Yapay sinir ağları, insan beyninin işleyişini taklit ederek yeni sistemler oluşturmaya çalışan yaklaşımlardır. Tüm YSA yapılarında esin kaynağı, biyolojik sinir ağlarının işleyişi olmuştur. Beynin işleyiş kuralları bir çok YSA modelinin geliştirilmesinde kullanılmıştır (Sağıroğlu ve diğerleri, 2003: 23).

Bir sinir ağı, bilgiyi depolamak için doğal eğilimi olan, basit birimlerden oluşan paralel dağıtılmış bir işlemcidir. YSA iki açıdan insan

beynine benzemektedir. Bilgi, ağ tarafından bir öğrenme süreci aracılığı ile elde edilmektedir ve sinir hücreleri arasında snaptik ağırlık olarak adlandırılan bağlar bilgiyi depolamakta kullanılmaktadır. (Haykin, 1999: 10).

YSA yapıları mühendislikte; sistem modelleme, ses, el yazısı ve parmak izi tanıma, otomatik araç kullanımı, meteorolojik tanımlama gibi pek çok alanda kullanılmaktadır. Ayrıca satışlar, üretim, pazar performansı, enerji ihtiyacının tahmini gibi konularda da yaygın olarak kullanılmakta ve başarılı sonuçlar vermektedir.

Yapay Sinir Ağları, insanlar tarafından gerçekleştirilmiş örnekleri kullanarak olayları öğrenebilen, çevreden gelen olaylara karşı tepkiler geliştirebilen bilgisayar sistemleridir. İnsan beyninin fonksiyonel özelliklerine benzer şekilde;

- Öğrenme
- İlişkilendirme
- Sınıflandırma
- Genelleme
- Özellik belirleme
- Optimizasyon
- Tahmin

gibi konularda başarılı bir şekilde uygulanmaktadır (Öztemel, 2003: 13).


Yapay sinir ağları, verileri analiz edebilmek ve veriyle ilgili farklı yapıları ortaya koyabilmek amacıyla geliştirilmiş bilgisayara dayalı bir araçtır. Yapay sinir ağları modelini geliştirebilmek için kullanılan veriye, çalışma verisi adı verilir. Yapay sinir ağları, çalışma verilerini kullanarak verinin içindeki modelleri öğrenmeye çalışır. Pek çok çıktıyı kullanarak yeni veriler üzerine uygulanabilir. Yapay sinir ağları:

- Tarihsel çalışma verilerinin gözlemlerine dayanarak gelecekteki olaylarla ilgili kestirimler yapmayı öğrenmek,
- Çalışma verilerinde gözlemlenmiş olan öncelikli tanımlanmış grupların karakteristiklerini gruplandırmayı öğrenmek,
- Çalışma verileriyle, doğal grup arasındaki benzerlikleri kümelemeyi öğrenmek amacıyla kullanılabilir (Smith ve Gupta, 2002: 1).

c. Yapay Sinir Ağlarının Yapısı ve Temel Elemanları

(1) Biyolojik Nöron


Biyolojik sinir sistemi, bilgiyi alan, yorumlayan ve uygun karar üreten bir merkez ve bu merkezin kontrolünde bulunan alıcı ve tepki sinirlerinden oluşur (Şekil-4).



Şekil-4 : Sinir Sisteminin Blok Yapısı.

Sinir hücreleri, nöron olarak da bilinir. Tüm doğal nöronlar dört temel bileşene sahiptir. Bu bileşenler, biyolojik isimleri ile bilinirler. Bunlar; dentrit, çekirdek (soma), akson ve sinapslardır (Şekil-5). Dentritler, çekirdeğin saça benzeyen uzantılarıdır ve girdi kanalları olarak işlev görürler. Bu girdi kanalları, diğer nöronların sinapsları aracılığıyla girdilerini alırlar. Daha sonra çekirdek, gelen bu sinyalleri zaman içinde işler. Çekirdek, bu


işlenmiş değeri bir çıktıya dönüştürdükten sonra bu çıktıyı akson ve sinapslar aracılığıyla diğer nöronlara gönderir.



Şekil-5 : Biyolojik Nöron Yapısı ve İşlevleri.

(2) Yapay Nöron

Yapay sinir ağlarının temel işlem elemanı olan yapay nöronlar, doğal nöronların dört temel fonksiyonunu simüle ederler. Bir yapay nöronun temel yapısı genel haliyle, Şekil-6'da sunulmaktadır. Şekil-6'da girdi değerler $x(i)$ matematiksel sembolü ile gösterilmiş ve bu gösterimde $i = 0, 1, 2, \dots, N$ değerlerini almaktadır. Bu girdi değerlerin her biri bir bağlantı ağırlığıyla çarpılmaktadır. Bu ağırlıklar ise $w(i)$ ile gösterilmektedir. En basit yapıda, bu çarpımlar toplanır ve bir aktivasyon fonksiyonuna gönderilerek sonuç üretilir. Bu sonuç daha sonra bir çıktıya dönüştürülür. Bu elektronik uygulama, değişik toplama fonksiyonları ve transfer fonksiyonları kullanabilir, farklı ağ yapılarında uygulanabilir (Yurtoğlu, 2005: 14).



Şekil-6 : Yapay Nöron Yapısı (Gurney, 1996).

Bir sinir ağı modeli için, t zamanında, ağ içerisindeki bir nörona gelen net girdi sinyallerinin toplamı,

$$net_j(t) = \sum_{i=1}^N w_{ij}(t)x_i(t) \quad [2.40]$$

ile tanımlanır ve formüldeki değerler;

$net_j(t)$: ağı j. nöronuna gelen net girdi sinyali,

$w_{ij}(t)$: i. nöron ile j. nöron arasındaki bağlantının ağırlığı,

$x_i(t)$: i nöronunun çıktısını ifade eder.

Hesaplama esnasında bir aktivasyon fonksiyonu kullanılmaktadır. Herhangi iki nöronun arasından geçen sinyal, hem aktivasyon fonksiyonuna hem de bağlantının ağırlığına bağlıdır. Modelde yer alan bir nöronun girdilerinin ağırlıklandırılmış toplamı, yani net girdi değeri bir aktivasyon fonksiyonundan geçer. Bu fonksiyondan elde edilen sonuç değer,

bu nöronun çıktı değeridir (Güneri ve Apaydın, 2004: 174–175). Sonuçta elde edilen çıktılar;


$$Y_j(t) = g_j(net_j(t)) \quad [2.41]$$

ile hesaplanır. Bu denklemdeki değerler:

$g_j(.)$: aktivasyon fonksiyonunu,

$Y_j(t)$: j. nöronun çıkışını göstermektedir.


Aktivasyon fonksiyonları, bir YSA yapısında nöronun çıkış genliğini, istenilen değerler arasında sınırlar. Bu değerler çoğunlukla $[0,1]$ ve $[-1,1]$ aralığındadır. YSA yapılarında kullanılacak olan fonksiyonların türevi alınabilir ve süreklilik arz etmesi gereklidir. Doğrusal ve doğrusal olmayan aktivasyon fonksiyonlarının, YSA yapılarında kullanılması, karmaşık ve çok farklı problemlere uygulanmasını sağlamıştır. Uygulamalarda, en çok tanjant hiperbolik veya sigmoid fonksiyonu kullanılmaktadır. Yapay sinir ağında hangi aktivasyon fonksiyonunun kullanılacağı probleme bağlı olarak değişmektedir. Şekil-7’de çeşitli aktivasyon fonksiyonu örnekleri görülmektedir.



Şekil-7 : Aktivasyon Fonksiyonu Örnekleri.

d. Yapay Sinir Ağlarının Sınıflandırılması

YSA yapıları, genel olarak birbirleri ile bağlantılı işlemci birimlerden veya diğer bir ifadeyle nöronlar veya işlemci elemanlardan oluşur. Nöronlar arasındaki bağlantılar ağın yapısını oluşturur. Yapay sinir ağı modeli, birbirleriyle bağlantılı olan sinirlerin bulunduğu katmanlardan oluşmaktadır. Temelde bu katmanlar; girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç tanedir. Girdi değişkenleri, girdi katmanından gelmektedir. Bu girdi unsurları, etkileşime tabi tutulduktan sonra ortaya çıktı değişkenleri çıkar. Bunlar da çıktı katmanını oluşturur. Arada bulunan gizli katman ise, dış ortamla bağlantısı olmayan sinirlerden oluşur ve bu sinirler girdi katmanındaki sinyalleri çıktı katmanına gönderirler. Yapay sinir ağı yapısını Şekil-8 'de görmek mümkündür.




Şekil-8 : Çok Katmanlı Bir YSA Modeli.

YSA, yapılarına göre, ileri beslemeli (feedforward) ve geri beslemeli (feedback) olmak üzere iki farklı yapıdadır.

(1) İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli ağlarda, işlemci elemanlar genellikle katmanlara ayrılmışlardır. İşaretler, girdi katmanından çıktı katmanına tek yönlü bağlantılarla iletilir. İşlemci elemanlar, bir katmandan diğerine bağlantı

kurarken, aynı katman içerisinde bağlantıları bulunmaz (Şekil-9). İleri beslemeli ağlara örnek olarak çok katmanlı perseptronlar (multiplayered perseptrons-MLP) ve LVQ (Learning Vector Quantization) ağları verilebilir (Sağıroğlu ve diğerleri, 2003: 43).



Şekil-9 : İleri Beslemeli Yapay Sinir Ağları.

Oldukça yaygın kullanım alanı bulan çok katmanlı perseptron sinir ağı (MLP) bir giriş, bir ya da birden çok gizli katman ve bir çıkış katmanından oluşur. Her katmanda, bir veya daha fazla işlemci eleman olabilir. MLP'deki herhangi bir nöron çıkışı aşağıdaki denklemle hesaplanır:


$$y_k = f\left(\sum_k w_k x\right) \quad [2.42]$$

Bu YSA yapısında, giriş katmanında herhangi bir bilgi işleme yapılmaz. İşlem elemanı sayısı tamamen uygulanan problemlerin giriş sayısına bağlıdır. Ara katman sayısı ve ara katmanlardaki işlem elemanı sayısı ise, deneme yanılma yoluyla bulunur (Rumelhart ve Mclelland, 1986).

(2) Geri Beslemeli Yapay Sinir Ağları

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 (Şekil-10). Geri besleme, bir katmandaki işlemci elemanlar arasında olduğu gibi katmanlar

arasındaki işlemci elemanlar arasında da olabilmektedir. Bu yapısı sayesinde geri beslemeli yapay sinir ağıları, doğrusal olmayan dinamik bir davranış gösterirler. Bu sayede, geri beslemenin yapılış şekline göre farklı yapı ve davranışta geri beslemeli yapay sinir ağıları elde edilebilir.



Şekil-10 : Geri Beslemeli Yapay Sinir Ağı.

Geri beslemeli yapay sinir ağıları, karmaşık bir çalışma düzeneğine sahip olmalarına rağmen, dinamik hafızaları nedeniyle ön tahmin uygulamalarında başarılı sonuçlar verirler. Bu ağlara örnek olarak Hopfield, Elman ve Jordan ağıları verilebilir.

e. Temel Öğrenme Kuralları

Öğrenme işlemi, çok parametrelili, karmaşık ve matematiksel olarak ifade edilmesi zor bir işlemdir. Bugün kullanılan öğrenme kuralları, bu işlemin basitleştirilmiş veya farklı formatta ifade edilmiş biçimleridir. Bu algoritmalarından dört tanesi temel olup diğerleri bunlardan türetilmiştir. Bunlar, Hebb, Delta, Kohonen ve Hopfield öğrenme kurallarıdır.

(1) Hebb Kuralı

Hebb (1949) tarafından ve biyolojik öğrenme temel alınarak geliştirilen bu kural bilinen en eski öğrenme kuralıdır. Diğer öğrenme kurallarına da temel olan Hebb Kuralı'na göre, bir yapay sinir hücresi diğer bir yapay sinir hücresinden girdi alırsa ve her iki hücre de yüksek derecede aktif

ise (matematiksel olarak aynı işareti taşıyorsa) her iki hücrenin arasındaki bağlantının ağırlığı artırılmalıdır.

(2) Hopfield Kuralı

Hopfield Kuralı, bir farklılık dışında Hebb Kuralına benzer. Bu farklılık, Hopfield Kuralı'nda, bağlantı ağırlığında yapılacak olan değişikliğin büyüklüğünün de belirlenmesidir. Buna göre, girdi ve istenilen çıktının ikisi de aktifse, bağlantı ağırlığı öğrenme katsayısı kadar artılmakta, aksi durumda ise öğrenme katsayısı kadar azaltılmaktadır. Öğrenme katsayısı genel olarak 0-1 arasında tasarımcı tarafından atanan sabit ve pozitif bir değerdir.

(3) Delta Kuralı

Widrow ve Hoff tarafından geliştirilen bu kural Hebb Kuralının gelişmiş şeklidir. En çok kullanılan kurallardan biri olan Delta Kuralı, yapay sinir hücresinin gerçek çıktısı ile beklenen çıktısı arasındaki farkı azaltmak için yapay sinir ağlarının işlemci elemanları arasındaki bağlantı ağırlık değerlerinin sürekli değiştirilmesi ilkesine dayanır. Bu kuralla, gerçek çıktı ile beklenen çıktı arasındaki hatanın karesi, en aza indirilmeye çalışılmaktadır. Bu nedenle En Küçük Kareler Kuralı (Least Mean Square Rule-LMS) olarak da adlandırılır. Ayrıca geri yayılım ve Widrow-Hoff Kuralı olarak da geçer.

(4) Kohonen Kuralı

Kohonen (1982) tarafından geliştirilen bu öğrenme kuralında biyolojik sistemlerdeki öğrenmeden esinlenilmiştir. Bu kuralda işlemci elemanlar, ağırlıklarının ayarlanması (öğrenme) için yarışmaktadırlar. Kazanan işlemci elemanın bağlantı ağırlıkları değiştirilmektedir. En uygun çıktıya sahip işlemci elemanın kazandığı kuralda, bu işlemci eleman kendisine komşu işlemci elemanların ağırlıklarının değiştirilmesine de izin vermektedir.


f. Yapay Sinir Ağlarının Öğrenme Yöntemlerine Göre Sınıflandırılması

Yapay sinir ağlarında bilgi, ağdaki bağlantıların ağırlıklarında depolanır. Bir ağda öğrenme, istenen bir işlevi yerine getirecek şekilde ağırlıkların ayarlanması sürecidir. Yapay sinir ağlarında öğrenme, sinirler arasındaki ağırlıkların değiştirilmesi ile gerçekleşmektedir. Buna göre sinirler arası bağlantılar üzerindeki ağırlıkları belirli bir yöntem uyarınca dinamik olarak değiştirilebilen ağlar eğitilebilir. Öğrenebilen ağlar, yeni şekilleri tanıyabilir ya da verilen bir girişin hangi sınıfa ait olduğuna karar verebilir. Yapay sinir ağlarında öğrenme düğümler arasındaki ağırlıkların, düğümlerdeki etkinlik ya da aktarım işlevlerinin değişkenlerinin ayarlanmasıyla yapılmaktadır (Elmas, 2003: 95).

Yapay sinir ağları kullanılarak yapılan araştırmalarda en sık kullanılan öğrenme yöntemleri, danışmalı ve danışmasız öğrenme yöntemleri olmasından dolayı bu yöntemler üzerinde durulacaktır.

(1) Danışmanlı Öğrenme

Yapay sinir ağlarında en fazla kullanılan öğrenme metodu olan danışmanlı öğrenmede, yapay sinir ağına örnek olarak bir çıktı (beklenen çıktı) verilir ve bu çıktıyla ağıın ürettiği çıktı karşılaştırılır (Şekil-11). İki çıktı arasındaki fark, hata olarak alınır. Başlangıçta; genellikle rassal olarak verilen ağırlıklar, ağ tarafından hata minimize edilene kadar döngüler halinde değiştirilir (Anderson ve McNeill, 1992).



Şekil-11 : Danışmanlı Öğrenme.


Danışmanlı öğrenme algoritmasının bir öğretmene veya bir danışmana ihtiyacı vardır. Öğrenme eğitici kontrolündedir. Öğretmen, eğitim kümesini ve hata değerini belirleyerek eğitimin ne kadar devam edeceğine karar verir. Bu yöntemin en önemli özelliği, eğitim esnasında gerçek giriş ve çıkış değerlerinin kullanılmasıdır. En yaygın olarak kullanılan danışmanlı öğrenme kurallarının bazıları; Perceptron kuralı, delta kuralı, genişletilmiş delta kuralı ve geri yayılım algoritmasıdır. (Şen, 2004: 98).

Bu bölümde sadece literatürde yaygın olarak tahminleme problemlerinde kullanılan geri yayılım ağı incelenecektir.

(a) Geri Yayılım Algoritması

Geri yayılım algoritması YSA'nın eğitilmesi amacıyla kullanılan yönlendirmeli bir eğitim metodudur (Arbib, 2002). Geri yayılım algoritması (GYA) matematiksel olarak kolay ispatlanabilir ve basit olmasından dolayı en çok tercih edilen öğrenme algoritmasıdır. Bu algoritma, hataları çıkıştan girişe, geriye doğru azaltmaya çalışmasından dolayı geri yayılım adını almıştır. GYA, sürekli ve türevi alınabilir aktivasyon fonksiyonuna sahip nöronlardan meydana gelen Çok Katmanlı Ağ yapılarında, uygulanabilmektedir (Şekil-12). GYA'nın kullanıldığı ÇKA yapıları, geri yayılım ağı olarak da adlandırılmaktadırlar. Geri yayılım ağına hatalar, ileri besleme aktarım işlevinin türevi tarafından, ileri beslemeli ağlar için kullanılan bağlantılar yardımıyla geriye doğru yayılırlar. Öğrenme

işlemi, basit çift yönlü hafıza birleştirmeye dayanır (Mehrota ve diğerleri, 1997: 70).



Şekil-12 : Geri Yayılım Algoritması.

Geri yayılım öğrenme sürecini, başlatmadan önce aşağıdakilerin belirlenmiş olması gerekir (Kartalopoulos,1996: 1-80):

- Eğitim kümesi,
- Öğrenme oranı,
- Algoritmayı sonlandırma kriteri,
- Ağırlıkları düzenleme metodolojisi,
- Aktivasyon fonksiyonu,
- Başlangıç ağırlıkları.

Eğitim kümesindeki girdiler, ağırlık girdi katmanındaki nöronların bir çıktı üretmesini sağlarlar. Bu çıktı, bir sonraki katman nöronlarının girdisini oluşturur. Böylece çıktı katmanındaki nöronların, ağırlık çıktısını üretmeleri sağlanır. Ağırlık ürettiği çıktı ile eğitim kümesindeki gerçek değerler karşılaştırılır. Aradaki fark hesaplanır. Hatayı minimize etmek için algoritma, geriye doğru çıktı katman ağırlıklarını (son gizli katman ile çıktı katmanı arasındaki ağırlıklar) yeniden hesaplamaya çalışır. Daha sonra son

gizli katmandaki ve girdi katmanına doğru bütün katmanlardaki ağırlıklar yeniden hesaplanır. Algoritmayı sonlandırma kriteri sağlanana kadar bu işlem sürer. Bu algoritma ile i ve j kat işlem elemanları arasındaki ağırlıklardaki $\Delta w_{ji}(t)$ değişikliği hesaplanır (Sağıroğlu ve diğerleri, 2003: 85-86). Bu ifade;

$$\Delta w_{ji}(t) = \eta \delta_j x_j + \alpha \Delta w_{ji}(t-1) \quad [2.43]$$

olarak verilir. Burada;

η : öğrenme katsayısı,

α : momentum katsayısı

δ_j : ara veya çıkış katındaki herhangi bir j nöronuna ait bir faktördür. Çıkış katmanı için bu faktör aşağıdaki gibi verilir.

$$\delta_j = \frac{\partial f}{\partial net_j} (y_j^{(t)} - y_j) \quad [2.44]$$

Burada;

$$net_j = \sum x_j w_{ji} \quad [2.45]$$

ve $y_j^{(t)}$ ise j işlemci elemanının hedef çıkışıdır. Ara katmanlardaki nöronlar için ise bu faktör,

$$\delta_j = \left[\frac{\partial f}{\partial net_j} \right] \sum w_{qi} \delta_q \quad [2.46]$$

olarak verilir.


GYA bir dereceli azaltma algoritması olup, Çok Katmanlı Ağ yapılarını eğitmede kullanılan bir algoritmadır. Temelde istenilen çıkış ile ağ çıkışı arasındaki hatanın ağırlıklara bağlı olarak düşürülmesi prensibine dayanır. Geri yayılım algoritmasının gelişimi Şekil-13'te görülmektedir.



Şekil-13 : Geri Yayılım Algoritması Gelişimi (Sağıroğlu ve diğerleri, 2003: 80).

(2) Danışmansız Öğrenme

Danışmansız öğrenmede, herhangi bir danışmana ihtiyaç yoktur. İstenen çıktı, değerlerinin elde edilmesinin mümkün olmadığı durumlarda kullanılır. Ağa sadece girdiler gösterilir. Deneme yanılma yoluyla bilgi genelleştirilmesi yapılır. Daha çok sınıflandırma problemleri için kullanılır. Adaptif rezonans ağları (ART), Hopfield ağı, Kohonen ağı en çok kullanılanlarıdır. Danışmansız öğrenme, Şeli-14’de gösterilmiştir.



Şekil-14 : Danışmansız Öğrenme.

g. Yapay Sinir Ağları Tasarımı

Yapay sinir ağlarının performansı da, modelleme kadar önemli bir yer tuttuğundan, dikkatli bir şekilde ele alınmalıdır. Önemli kritik kararlardan biri ağın yapısıdır. Ağ yapısından kasıt; katman sayısı, her katmandaki nöron sayısı ve nöronlar arasındaki bağlantıların sayısıdır. Diğer kritik kararlar ise gizli katman ve çıktı katmanındaki aktivasyon fonksiyonunun seçimi, eğitim algoritması, veri normalleştirme yöntemi, eğitim ve test kümelerinin belirlenmesidir.

(1) Ağ Yapısı

Uygun yapay sinir ağı yapısının seçimi uygulama problemine bağlıdır. Bunun içinde yapay sinir ağları yapılarının hangi tip uygulama problemlerinde başarılı olacağının önceden bilinmesi faydalıdır. Şu ana kadar yapılan çalışmalardan elde edilen sonuçlara göre kullanılan ağ yapıları Tablo-2’de görülmektedir.

(2) Girdi Nöron Seçimi

Zaman serileri problemleri söz konusu olduğunda, girdi nöron sayısını belirlemek kolay değildir. Yapılan çalışmalarda; belirli bir kural olmamakla birlikte aylık veriler için 12, üçer aylık veriler için 4, yıllık veriler için 3 ağ girişinin uygun olacağı değerlendirilmektedir (Tang, 1991: 303-310).

Tablo-2 : YSA Uygulama Alanlarına Göre Ağ Yapıları (Elmas, 2003: 176).

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

(3) Gizli Katman ve Nöron Sayısını Belirleme

Gizli nöron sayısının da, belirlenmesiyle ilgili bir teori yoktur. Deneme yanılma yoluyla nöron sayısını belirleme sık kullanılan bir yoldur. Bazı teorik çalışmalar neticesinde, genellikle tek gizli katmanın, yapay sinir

ağları ile başarılı sonuçlara ulaşmada yeterli olduğu ileri sürülmüştür. n gizli nöron sayısını belirtmek üzere $2n+1$, $2n$, n , $n/2$ gizli katman nöron sayısını belirlemek üzere ileri sürülen bazı yaklaşımlardır (Lipmann, 1987: 4-22).

(4) Çıktı Nöron Sayısını Belirleme

Diğer tabakalardaki nöron sayılarını belirlemeye göre çıktı nöron sayısını belirlemek, daha kolaydır. Bir zaman serisinin geleceği tahmin problemlerinde, çıktı nöronu sayısı tahmin döneminin uzunluğuna eşittir. Tek dönemlik tahminde çıktı nöron sayısı bire eşitken, çok dönemlik tahmin söz konusu olduğunda çıktı nöronunu belirleme, iki yolla yapılabilir. Birincisi iteratif tahmindir. Tahmin edilen dönem değeri, bir sonraki dönem için girdi olarak kullanılır. Bu durumda tek çıktı nöronu yeterlidir. İkincisi ise, birden fazla dönemin aynı anda tahmin edildiği, direkt yöntem olarak adlandırılan durumdur. Bu durumda çıktı nöron sayısı, tahmin edilmek istenen dönem sayısına eşittir (Zhang, 1998).

(5) Aktivasyon Fonksiyonu Seçimi

Genel olarak, bir ağın aynı ya da farklı katmanlarındaki nöronlar farklı aktivasyon fonksiyonu kullanabilirler. Uygulamaların çoğundaysa, aynı katmandaki nöronların aynı aktivasyon fonksiyonunu kullandıkları görülmektedir.

Lojistik aktivasyon fonksiyonu, ikili hedef değerlerin olduğu sınıflandırma problemleri için çıktı katmanında sıklıkla kullanılmıştır. Ancak, hedef değerlerinin süreklilik gösterdiği kestirim problemi gibi problemlerde, çıktı katmanında doğrusal bir aktivasyon fonksiyonunun kullanılması tercih edilmelidir.

Girdi katmanı, gizli katman ve çıktı katmanından oluşan doğrusal aktivasyon fonksiyonun kullanıldığı, tek çıktı nöronuna sahip bir ağ için çıktının matematiksel gösterimi şu şekildedir:

$$z_t = \alpha_o + \sum_{j=1}^n \alpha_j f \left(\sum_{i=1}^m w_{ij} z_{t-i} + \theta_{0j} \right) + \varepsilon_t \quad [2.47]$$

Burada, m girdi nöron sayısını, n gizli nöron sayısını, f kullanılan aktivasyon fonksiyonunu, α_j , $j = 1, 2, \dots, n$ gizli nörondan çıktı nöronuna olan ağırlık değerlerini, w_{ij} , $i = 1, 2, \dots, n$ girdi nörondan gizli nörona ağırlık değerlerini, α_o ve θ_{0j} ise eşik değer aralıklarını göstermektedir (Chu ve Zhang, 2003: 217-231).

(6) Veri Normalizasyonu

Bütün eğitim verilerinin belli bir aralık içerisinde normalleştirilmesi gerekir. Çoğunlukla kullanılan veri normalleştirme formülleri aşağıdaki eşitliklerde verilmiştir (Sağıroğlu ve diğerleri, 2003: 110):

- [0,1] aralığı doğrusal dönüşüm: $x_n = \frac{(x_0 - x_{\min})}{(x_{\max} - x_{\min})}$
- [-1,1] aralığı dönüşüm: $x_n = 2 \frac{(x_0 - x_{\min})}{(x_{\max} - x_{\min})} - 1$
- [a,b] aralığı dönüşüm: $x_n = (b - a) \frac{(x_0 - x_{\min})}{(x_{\max} - x_{\min})} + a$
- Basit normalizasyon: $x_n = \frac{x_0}{x_{\max}}$

(7) Eğitim ve Test Kümesi

YSA yapılarında veri, eğitim ve test kümesi olmak üzere ikiye bölünür. Ancak bunu yapmanın, genel bir yöntemi yoktur. Problem özelliği, veri tipi ve eldeki veri miktarı bu kararı vermede dikkate alınır. Hem eğitim

kümesinin, hem de test kümesinin, bütün veri setinin özelliklerine sahip kümeler olması kritik bir noktadır. Bu nokta, özellikle zaman serileri kestirim problemlerinde önemlidir. Eğitim ve test kümelerinin uygunsuz belirlenmesi, optimal YSA yapısının seçimini ve YSA'nın kestirim performansının değerlendirilmesini etkileyecektir.

(8) Öğrenme Algoritmasının Seçimi

Ağın başarılı olabilmesi için önemli bir etken de öğrenme algoritmasıdır. Seçilen ağ yapısına uygun olan öğrenme algoritmasını seçmek gerekmektedir. Yapay sinir ağlarının az veriyle öğrenmesi ve genelleme yapabilmesi istenir. Ağın genellemesi, yapılan testlerle kontrol edilmelidir. Aşırı öğrenme, söz konusu ise ağ kabul edilebilir çıkışlar üretmez. Öğrenme algoritmasının seçiminde genellikle ağ yapısı, belirleyici rol oynar. Bu nedenle; seçilen ağ yapısı üzerinde kullanılabilecek öğrenme algoritmasının seçimi, ağ yapısına bağlıdır (Refenes, 1998).

Hızlı bir eğitim sağlayan geri yayılım algoritmaları; sezgisel (heuristic) tekniklerin ve optimizasyon tekniklerinin kullanıldığı algoritmalar olmak üzere iki ana kategoride toplanabilir. Optimizasyon tekniklerinin kullanıldığı algoritmalar içinde yer alan Levenberg-Marquardt (Trainlm) algoritması, ileri beslemeli ağlardaki en hızlı öğrenme algoritmasıdır (Demuth ve Beale, 2000).

h. Yapay Sinir Ağları Yapılarının Avantaj ve Dezavantajları

YSA yapılarının en önemli avantajları şunlardır (Öztemel, 2006: 31-35):

- Modellenmesi zor, karmaşık ve doğrusal olmayan özellikteki problemleri kolaylıkla modelleyebilirler.
- Eksik bilgiyle çalışabilir. Modelin performansına göre, hata toleransını değerlendirirler.

- Her türlü probleme uygulanabilir esnek bir yapıya sahiptirler.
- Kendisine sunulan örneklerle genellemeler yaparak, daha önce görmediği örnekler için sonuçlar üretirler.

Bu avantajlarının yanında, bir takım sakıncalara da sahiptirler. Bu sakıncalar şunlardır;

- Ağın eğitiminin nerede bitirileceği önemlidir. Ağın örnekler üzerindeki hatasının belirli bir değerin altına indirilmesi eğitimin tamamlanması için yeterli görülmektedir. Bu durumda optimum öğrenmenin gerçekleştiği söylenemeyebilir.
- Probleme uygun ağ yapısının oluşturulması genellikle deneme yanılma yoluyla yapılır.
- Ağ davranışları açıklanamaz. Ağ kara kutu gibi çalışır.

Belirtilen sakıncalarına rağmen, YSA yapılarının doğrusal olan ve olmayan her türlü probleme uygulanabilir olması, kullanımını yaygınlaştırmaktadır.

ÜÇÜNCÜ BÖLÜM

UYGULAMA

Bu bölüm, çalışmanın amacına yönelik olarak kullanılacak verilerin daha önceki bölümde anlatılan teknik ve metodlara göre incelenerek, gerekli analizlerin yapılması konularını kapsamaktadır. Sırasıyla; Box-Jenkins, Regresyon ve Yapay Sinir Ağları yapıları kullanılarak veriler analiz edilmiş ve öngörüler yapılmıştır.

1. VERİLER

Öncelikli olarak çalışmada, Box-Jenkins yönteminden ve Yapay Sinir Ağları yapılarından elde edilecek tahmin modellerinin kurulması için, Milli Savunma Bakanlığı'nın 1990 ile 2005 yıllarını kapsayan 64 gözlemlili veri seti kullanılmıştır. Bu zaman serisi üçer aylık MSB bütçe rakamlarından oluşmaktadır. Box-Jenkins yönteminden ve Yapay Sinir Ağları analizinden elde edilen modelleri karşılaştırmak için ise 2006 ve 2007 yıllarına ait 8 veri, örneklem dışı veri seti olarak alınmıştır. Yapılan analizlerde, bütçe zaman serisinin logaritmik değerleri kullanılmıştır. Savunma harcamaları kapsamında değerlendirilen Milli savunma Bakanlığı bütçesinin, genel bütçe içerisinde önemli bir paya sahip olmasından dolayı, diğer kurumların bütçe verilerine bu çalışmada yer verilmemiştir. Öncelikli olarak verilerin mevcut haliyle değerlendirilmesi yapılmış, daha sonra yöntemlerin gerektirdiği uygulamalara geçilmiştir.

Regresyon analizinde; Milli Savunma Bakanlığı'nın bütçesini tahmin etmek için; bir takım makro değişkenler ile açıklayıcılığının yüksek olduğu düşünülen değişkenlere yer verilmiş, özel durumları açıklamak için de kukla değişkenler kullanılmıştır. Regresyon analizinde, değişkenlere ait yıllık veri setleri kullanılmıştır.


2. YÖNTEMLER

a. Zaman Serileri Analizi

Bu yönleme göre, MSB'nın verilerini değerlendirmek için ikinci bölümde, Box-Jenkins yönteminde açıklanan aşamalar uygulanmıştır.


(1) Belirleme

MSB bütçesi, üçer aylık zaman serisinden tahmin yapmak için kuracağımız modelleri belirlemeden önce serinin trend ya da mevsimsellik içerip içermediğinin test edilmesi gerekir. Bu amaçla serinin grafiği incelenmelidir.




Şekil-15 : MSB Bütçesi Üçer Aylık Zaman Serisi Grafiği.

Şekil-15'te görüldüğü gibi MSB bütçesinin üçer aylık verilerine göre oluşturulan zaman serisi durağan değildir. Grafik, incelendiğinde seride kuvvetli bir trendin olduğu görülmektedir. Seride kuvvetli trende ek olarak mevsimlik etkilerde açıkça gözlenebilmektedir. Her yılın son üçer aylık periyotları serinin grafiğinde, zirveler oluşturmaktadır. Bu bilgileri, serinin otokorelasyon fonksiyonunu inceleyerek de onaylayabiliriz.




Şekil-16 : MSB Bütçesi Otokorelasyon Fonksiyonu.

Şekil-16'da görüldüğü gibi 20 gecikme sonunda oluşan otokorelasyonların hepsi pozitif işaretlidir. İlk 5 gecikme anlamlı olarak sıfırdan farklı olup, sonraki otokorelasyon değerleri belirgin bir şekilde sıfıra yaklaşmaktadır. Bu durum serinin orijinal değerler yönünden durağan olmadığını gösterir. Seride rastlantısallığın ve durağanlığın elde edilmesi için serinin birinci ve gerekirse ikinci dereceden farklarının alınması gerekmektedir. Serinin 1. dereceden fark grafiği Şekil-17'de görülmektedir.



Şekil-17 : MSB Bütçesi Birinci Fark Otokorelasyon Fonksiyonu.


Şekil-17'deki grafikte üçer aylık bütçe zaman serisinin, birinci dereceden farkları alınmış otokorelasyon fonksiyonu görülmektedir. Otokorelasyonların sıfır etrafında daha düzenli dağılması serideki trendin yok olduğunu göstermektedir. Serideki trend etkisi giderilmesine rağmen özellikle r_4, r_8 ve r_{12} otokorelasyon değerleri anlamlı olarak sıfırdan farklıdır. Bu değerler, serideki mevsimlik aralığı gösteren otokorelasyonlardır. Üçer aylık zaman serisi değerlerindeki durağansızlık giderilmiş fakat özellikle son periyotlarda görülen mevsimlik etkiler giderilip durağansızlığa erişilememiştir. Diğer bir deyişle r_4, r_8 ve r_{12} otokorelasyonlarının yüksek olması birbirini izleyen dönemlerde durağansızlığın olduğunu ortaya koymaktadır. Bu mevsimlik etkiler, mevsimlik etkinin uzunluğuna yani 4'e göre farklarının alınması ile yok edilir. Bunun içinde serinin hem mevsimlik olarak 4. farkın hem de yıllık olarak 1. farkın birlikte kullanılarak, mevsimlik-yıllık farkın alınması gerekir.



Şekil-18 : MSB Bütçesi Yıllık Birinci ve Mevsimlik Dördüncü Fark Otokorelasyon Fonksiyonu.

Farkı alınmış serinin otokorelasyon fonksiyonunu Şekil-18'de görebiliriz. Serinin mevsimlik-yıllık fark serisi otokorelasyon değerlerinden sadece r_1 otokorelasyon katsayısı anlamlı olarak sıfırdan farklıdır. Mevsimlik-yıllık otokorelasyonların sıfır etrafında düzenli dağıldığı ve giderek azaldığı

görülmektedir. Mevsimlik yıllık fark serisinin bu durumu seride durağanlığa erişildiğini göstermektedir.



Şekil-19: MSB Bütçesi Yıllık Birinci ve Mevsimlik Dördüncü Farkı Kısmi Otokorelasyon Fonksiyonu.

Bu durumda kısmi otokorelasyon değerleri bulunur (Şekil-19). Kısmi otokorelasyon fonksiyonu azalan sinüs dalgaları biçiminde olup sadece r_1 kısmi otokorelasyon katsayısı anlamlıdır. Serinin mevsimlik etkilerinin seri ortalama düzeyi ile birlikte artış göstermesi seride çarpımsal etkinin olduğunu göstermektedir. Bu durumda MSB'liğin üçer aylık bütçe zaman serisine çarpımsal hareketli ortalama modelinin uygun olacağı söylenebilir. Bu mevsimlik öngörü modeli $(p, d, q) \times (P, D, Q)$ s şeklinde gösterilir. Burada p ve P otoregresif parametreleri; d ve D mevsimlik ve yıllık farkları; q ve Q da hareketli ortalamaları göstermektedir.

(2) Parametre Tahmini ve Uygunluk Testleri

Çalışmanın buraya kadarki bölümü bize kurulacak modellerin mevsimlik çarpımsal modellerin uygun olacağını göstermiştir. Bu aşamada parametrelerin hesaplanması gerekmektedir. Parametreler, Marquardt algoritması kullanılarak, doğrusal olmayan en küçük kareler yöntemiyle bulunmuştur. Modeller ve parametreleri, Tablo-3'te görülmektedir.

Tablo-3 : MSB Bütçesi Üçer Aylık Zaman Serileri İçin Uygun Modeller.

MODEL	1	2	3	4	5	6	7	8	9
	(0,1,1) x(0,1,1)	(0,1,2) x(0,1,1)	(0,1,1) x(1,1,0)	(0,1,1) x(1,1,1)	(1,1,1) x(0,1,1)	(1,1,0) x(0,1,1)	(1,1,0) x(1,1,0)	(1,1,0) x(1,1,1)	(1,1,1) x(1,1,1)
AR(1)					0,2681	-0,4924	-0,5211	-0,4960	-0,2662
					(-1,86)	(-4,47)	(-4,70)	(-4,45)	(-1,13)
MA(1)	0,4939	0,5823	0,5212	0,4975	0,3073				0,3125
	(4,38)	(4,65)	(4,79)	(4,39)	(1,35)				(1,35)
MA(2)		-0,1574							
		(-1,23)							
SAR(4)			-0,4405	-0,1346			-0,4100	-0,0912	-0,1224
			(-3,77)	(-0,45)			(-3,53)	(-0,33)	(-0,41)
SMA(4)	0,4345	0,4648		0,3303	0,4526	0,4832		0,4168	0,3611
	(3,61)	(3,90)		(1,12)	(3,83)	(4,18)		(1,59)	(1,25)
SSR	1,1641	1,1370	1,1683	1,1552	1,1355	1,1771	1,2284	1,1726	1,1292
AIC	1382,47	1383,06	1383,18	1384,38	1383,28	1382,95	1384,54	1384,87	1385,18
Q(12)	4,4 (0,926)	3,6 (0,936)	6,3 (0,792)	5,2 (0,817)	3,7 (0,928)	5,6 (0,847)	8,0 (0,630)	5,9 (0,747)	4,2 (0,836)
Q(24)	10,2 (0,984)	9,0 (0,989)	13,1 (0,932)	11,4 (0,955)	9,2 (0,988)	10,9 (0,977)	13,7 (0,913)	11,1 (0,962)	9,8 (0,972)
Q(36)	31,8 (0,574)	30,4 (0,599)	34,3 (0,452)	33,1 (0,461)	30,7 (0,584)	32,1 (0,560)	34,2 (0,46)	32,4 (0,499)	31,2 (0,506)
Q(48)	35,7 (0,864)	34,4 (0,875)	39,3 (0,746)	37,4 (0,781)	34,2 (0,88)	36,3 (0,847)	39,0 (0,760)	36,8 (0,802)	35,1 (0,830)

- ❖ Parametrelerin altında parantez içindeki değerler t istatistiğini göstermektedir.
- ❖ “Ho:”Tahmin edilen değişkenin değeri sıfıra eşittir.” hipotezinin reddilmesi için her bir değişkenin t istatistiğine göre anlamlı olması beklenir.
- ❖ SSR: Hata Kareler Toplamı. Değer olarak, düşük olanı kabul edilir.
- ❖ AIC: Akaike Bilgi Kriteri. Değer olarak, düşük olanı kabul edilir.
- ❖ Q(n):Tahmin edilen model hata otokorelasyonlarının, Ljung-Box istatistiğini gösterir. Parantez içinde gösterilen değerlerin anlamlı olması beklenir.

Açıklanan kriterlere göre modeller, Tablo-3'te incelendiğinde en uygun modelin 1. model yani $(0,1,1) \times (0,1,1)_4$ mertebeli çarpımsal SARIMA öngörü modeli olduğu görülür. Modelin matematiksel ifadesi;

$$y_t = (1 - \theta B)(1 - \Theta B^4) \quad [2.48]$$

şeklindedir. Bu modeli daha açık;

$$\Delta \Delta_4 y_t - y_{t-1} - y_{t-4} + y_{t-5} = \varepsilon_t - \theta \varepsilon_{t-1} - \Theta \varepsilon_{t-4} + \theta \Theta \varepsilon_{t-5} \quad [2.49]$$


olarak yazabiliriz. Tahmin edilen model;

$$y_t = (1 - 0,49 B)(1 - 0,43 B^4) \quad [2.50]$$

şeklindedir. Aynı modeli fark denklemi biçiminde;

$$y_t - y_{t-1} - y_{t-4} + y_{t-5} = \varepsilon_t - 0,49 \varepsilon_{t-1} - 0,43 \varepsilon_{t-4} + 0,21 \varepsilon_{t-5} \quad [2.51]$$

olarak yazabiliriz. Elde edilen çarpımsal SARIMA modeline göre elde edilen geçmiş dönem tahminleri Şekil-20'de görülmektedir.



Şekil-20 : Zaman Serisi Modelinin Örneklem İçerik Tahminleri.

Modelin grafiğinde, herhangi bir dönüm hatası olmayıp, modelden elde edilen değerler, gerçekleşen değerlerle paralellik göstermektedir. Ayrıca grafikteki değerler birbirine çok yakın seyretmektedir. Bu durum, çarpımsal SARIMA modelinin, başarılı bir model olduğunu göstermektedir.

(3) Öngörü

Parametreler belirlenip uygun model kurulduktan sonra yapılacak işlem ön tahminler yapmaktır. Milli Savunma Bakanlığı bütçesinin 2006-2010 yıllarının 20 ön dönemine ait için tahminlerin yapılması amacıyla;

$$y_t = (1 - 0,49B)(1 - 0,43B^4)$$


modeli kullanılacaktır. Tablo-4'te bu dönemler için yapılan ön tahmin değerleri görülmektedir.

Tablo-4 : MSB Bütçesi Zaman Serisi Analizi Ön Dönem Tahminleri (Milyon YTL).

ÖN DÖNEMLER	GERÇEK GÖZLEM DEĞERİ	ORT. NOKTA TAHMİNİ	*GÜVEN ARALIKLARI	
			ALT SINIR	ÜST SINIR
2006-1	1.620.925	1.501.988	1.134.951	1.987.524
2006-2	2.282.287	2.202.272	1.608.801	3.014.366
2006-3	2.790.255	2.763.200	1.957.933	3.899.660
2006-4	4.881.835	5.066.192	3.490.655	7.353.596
2007-1	1.929.220	1.684.029	1.043.614	2.717.438
2007-2	2.682.286	2.469.188	1.457.160	4.184.091
2007-3	2.887.919	3.098.101	1.748.205	5.490.885
2007-4	4.332.814	5.680.785	3.074.952	10.493.851
2008-1	-	1.888.135	917.217	3.887.201
2008-2	-	2.768.455	1.265.655	6.056.242
2008-3	-	3.473.940	1.501.237	8.038.877
2008-4	-	6.369.299	2.610.885	15.538.012
2009-1	-	2.117.189	775.994	5.776.451
2009-2	-	3.104.304	1.060.444	9.086.497
2009-3	-	3.894.984	1.245.689	12.179.929
2009-4	-	7.141.262	2.145.750	23.769.172
2010-1	-	2.373.794	635.139	8.871.904
2010-2	-	3.480.547	860.699	14.074.849
2010-3	-	4.367.494	1.002.392	19.027.579
2010-4	-	8.007.587	1.712.046	37.453.098


❖ Güven aralıkları % 5 anlamlılık düzeyindedir.

MSB bütçe zaman serisinin, Tablo-4 değerlerine göre oluşturulmuş grafiği, Şekil-21’de verilmiştir.



Şekil-21 : MSB Bütçesinin, SARIMA Modeli Örneklem Dışı Tahminleri.

Tahmin edilen fonksiyonun, ön tahmin gücünü ortaya koyabilmek amacıyla; veri seti için belirlemiş olduğumuz $(0,1,1) \times (0,1,1)_4$ mertebeli çarpımsal öngörü modeli esas alınıp, 1990-2002 dönemi verilerinden 2003, 2004 ve 2005 ön dönemleri için tahminler yapılmıştır.



Şekil-22 : Zaman Serisi Modellerini Karşılaştırma Grafiği.

Şekil-22’de modellerin karşılaştırma grafiği görülmektedir. Belirtilen ön dönemler, fonksiyonun tahmininde kullanılmadığından bizim için gerçekleşmiş gözlem değerleri olarak da düşünülebilir. Yine elimizde mevcut olan 1990-2005 yıllarından elde edilen modelin, geçmiş 2003, 2004 ve 2005 yıllarına ait değerlerini, 1990-2002 verilerinden elde edilen ön dönem tahminleriyle karşılaştırdığımızda; ilk modelimizin daha güçlü olduğunu görebiliriz. Çünkü ilk modelimizin standart sapması ve hata kareler toplamı, 1990-2002 yıllarından elde edilenlerden belirgin bir şekilde düşüktür. Bu durum bize; 1990-2005 verilerine göre kurulan modelin, iyi bir tahmin edici olduğunu açık bir şekilde göstermektedir.

b. Regresyon Analizi

Regresyon analizlerindeki temel amacımız, değişkenler arasındaki nedensellik ilişkilerini açıklamak olmayıp, ön tahminler yapmaktır. Bu sonuca ulaşmak için çeşitli regresyon modelleri tahmin edilmiş, bunlar arasında uygun olanlar değerlendirilerek en uygun tahmin modeli elde edilmiştir.

Savunma harcamalarını bir bütün olarak değerlendirdiğimizde aşağıdaki tip bir model öngörülmektedir (Dunne ve diğerleri, 2003):

$$M=M(E,Z) \quad [2.52]$$

Bu modelde M savunma harcamalarını, E ekonomik değişkenleri, Z ise sosyal refah fonksiyonunda gösterilen politik, stratejik ve demografik değişkenleri temsil etmektedir. Sonuç olarak; Milli Savunma Bakanlığı bütçesini öngörmek amacıyla kullanacağımız modeli şu şekilde tanımlayabiliriz:

$$Y = f (G, GB, B, E, N, DK) \quad [2.53]$$

Bu regresyon modelinde, bağımlı değişken olarak (Y) Milli Savunma Bakanlığı bütçesi (Milyon TL.-Bin YTL.) kullanılmıştır. MSB bütçe verileri, Maliye Bakanlığı kütüphanesinde bulunan Kamu Hesapları Bültenleri'nden derlenmiş ve veri seti olarak 1990-2005 yıllarına ait yıllık bütçe rakamları kullanılmıştır. Ekonomik değişkenlere ait veriler, Maliye Bakanlığı web sitesinden alınmış, yine aynı dönemi kapsayan yıllık rakamlar kullanılmıştır. Modellerde kullanılan bağımsız değişkenler ise şunlardır:

Y : MSB bütçesi

G :Gayri Safi Milli Hasıla (Milyar TL-Bin YTL)

GB :Genel bütçe (Milyar TL-Bin YTL).

B :Türkiye'nin ekonomik büyüme oranının yıllık yüzde değişimi.

E :Yıllık Toptan Eşya Fiyatları Endeksi (TEFE) ile Üretici Fiyatları Endeksinin (ÜFE) ortalamasının yıllık yüzde değişimi.

N :Nüfus (Yıl ortası,Bin kişi).

DK :Yıllık ortalama döviz kuru oranının yüzde değişimi (TL-YTL/\$).

Tahmin edilen modellerde, yukarıda tanımlanan bağımlı ve bağımsız değişkenlere ek olarak, Türkiye'de meydana gelen ekonomik krizleri açıklamak amacıyla iki adet de kukla değişken tanımlanmıştır. Bunlar:

D₁₉₉₄ :1994 yılında meydana gelen ekonomik kriz,

D₂₀₀₁ :2001 yılında meydana gelen ekonomik krizdir.

Bağımsız değişkenler ile Milli Savunma Bakanlığı bütçesi arasındaki ilişkilerin analizinde ilk olarak çoklu klasik regresyon modeli kullanılmış, son bölümde ise basit doğrusal regresyon modeli tercih edilmiştir. EKKY ile tahmin edilen ilk regresyon modelimiz şudur:

$$Y = 6611,5 - 54508,2D_{1994} - 350835,7D_{2001} + 2,73DK + 0,013G$$

(52278.5)	(155195)	(190083)	(0,2)	(0,0007)
0,13	-0,35	-1,85	13,19	18,1

[2.54]

$$R = 0,998 \quad R^2 = 0,998 \quad F = 2595,5 \quad D.W. = 1,55$$

Tahmin edilen modelde GSMH ve döviz kuru katsayıları % 5 anlamlılık düzeyinde, istatistiksel olarak anlamlıdır. Logaritmik model kullanıldığından 0,013 olan GSMH katsayısı, MSB bütçesinin GSMH'ya esnekliğini göstermektedir. Buna göre; GSMH'daki % 10'luk bir artış, % 0,13'lük bir değişim meydana getirir. Döviz kurlarındaki % 10'luk bir değişim ise MSB bütçesinde, % 27 oranında bir artışa neden olmaktadır.

İncelenen dönem göz önünde bulundurulduğunda 1994 ve 2001 yıllarında ekonomide yaşanan krizlerin harcamalar üzerinde önemli bir etkisinin olmadığı görülmektedir. 1994 ve 2001 krizlerini açıklamak üzere kullanılan katsayılar t testleri ve işaret kriterlerine göre beklentilerimizi karşılamamaktadır.

Tahmin edilen ilk regresyon modelimizden farklı olarak, ekonomik krizleri gösteren kukla değişkenlere ve GSMH değişkenine ilaveten genel bütçe ve nüfus değişkenlerini kullandığımızda oluşan diğer bir regresyon modeli;

$$Y = -4397512 - 149722D_{1994} + 58984D_{2001} + 0,006G + 0,044GB + 75,46N$$

(1747816)	(226278)	(255456)	(0,002)	(0,06)	(28,9)
-2,05	-0,66	0,23	2,9	7,07	2,6

[2.55]

$$R = 0,998 \quad R^2 = 0,996 \quad F = 971,7 \quad D.W. = 1,38$$

Bu modelde GSMH, genel bütçe ve nüfus katsayıları istatistiksel olarak anlamlı gözükmesine rağmen, yukarıda verilen diğer modele benzer şekilde kukla değişkenleri anlamsız sonuçlar ortaya koymuştur.

Bu iki modele ek olarak farklı açıklayıcı değişkenler (enflasyon, büyüme, döviz kuru vb.) kullanılarak bir çok alternatif model oluşturulmaya çalışılmıştır. Bu modellerde de ekonomik problemler (çoklu bağlantı ve otokorelasyon) ile karşılaşmıştır. Dolayısıyla, ekonomik ve istatistiksel kriterleri karşılayan başarılı modeller elde edilememiştir.

Bu durumda, benzer bir çalışmada kullanılan basit bir regresyon modeli ön tahmin modeli olarak kullanılmıştır (Karakuş, 2006: 124). Bu model;

$$MSB = 249143,5 + 0,023G \quad [2.56]$$

(195371)	(0,001)
1,28	24,05

$$R = 0,976 \quad R^2 = 0,974 \quad F = 578,7 \quad D.W. = 0,45$$


Bu modelde GSMH katsayısı istatistiksel olarak anlamlıdır. Modelin açıklama gücü 0,97 olup F istatistiği de regresyonun bir bütün olarak geçerli olduğunu ortaya koymaktadır. Durbin-Watson istatistiği ise otokorelasyon problemi olduğunu göstermektedir. Bu durumdan kaynaklı olarak hata terimlerinin 1. derecede otoregresif bir model olduğu varsayımı altında veri seti üzerinde gerekli düzeltmeler yapılarak otokorelasyon probleminin ortadan kaldırılması uygun görülmüştür. Bu duruma göre tahmin edilen model şudur;

$$MSB = 96295,69 + 0,024G \quad [2.57]$$

(94539)
(0,001)
1,02
24,08

$$R = 0,979 \quad R^2 = 0,978 \quad F = 615,5 \quad D.W. = 1,69$$

Görüldüğü gibi modelimiz işaret kısıtlarını karşılamakta ve tahmin edilen parametreler istatistiksel olarak anlamlıdır. Durbin-Watson istatistiği de 0,45'ten 1,69'a yükselmiş olup, otokorelasyon probleminin de görece olarak çözümlendiği görülmektedir. Sonuç olarak; ön tahmin amacıyla kullanacağımız ön tahmin fonksiyonumuz (regresyon modelimiz) bu formda olacaktır. Şekil-23'te tahmin modelinin hata terimlerini içeren grafik görülmektedir.



Şekil-23 : MSB Bütçesinin Gerçek, Tahmin ve Hata Terimleri Grafiği.

Görüldüğü gibi modelimiz, işaret kriterlerini karşılamakta olup istatistiksel yönden de anlamlıdır. Bu ön tahmin fonksiyonunu kullanarak ön tahminler yapabiliriz. Bu tahminleri gerçekleştirmek için GSMH'nın ön dönemlerdeki değerlerinin, tahmin edilmesi gerekmektedir.

$$G = f(t) \quad [2.58]$$

Bu durumda veri setine göre kurulan model şudur:

$$G = -117609869 + 37682779 t \text{ ...Trend denklemi.} \quad [2.59]$$

Belirtilen modele göre, GSMH için ön dönem tahminleri yapılmıştır. Bu değerler Tablo-5'de görülmektedir.

Tablo-5 : GSMH Ait Yıllara Göre Değişim ve Ön Tahmin Tablosu (Milyon YTL).

YILLAR	GSMH	t	YILLAR	GSMH	t
1990	397.200	1	2001	176.484.000	12
1991	634.400	2	2002	273.463.000	13
1992	1.103.600	3	2003	356.680.000	14
1993	1.997.000	4	2004	428.932.000	15
1994	3.887.000	5	2005	486.401.000	16
1995	7.854.000	6	*2006	462.997.374	17
1996	14.978.000	7	*2007	500.680.153	18
1997	29.393.000	8	*2008	538.362.932	19
1998	53.518.300	9	*2009	576.045.711	20
1999	78.283.000	10	*2010	613.728.490	21
2000	125.596.000	11			

❖ İşaretli yıllar ön tahmin yapılan dönemlerdir.

GSMH'ya ait ön dönem tahminleri yapıldıktan sonra, MSB bütçesini tahmin etmek üzere kurulan, $MSB = 96295,69 + 0,024G$ modeli kullanılarak 2006-2010 yıllarına ait ön dönem tahminleri, % 5 anlamlılık düzeyinde yapılmıştır. Yapılan ön tahminler Tablo-6'da görülmektedir.

Tablo-6 : MSB Bütçesi Regresyon Analizi Ön Dönem Tahminleri.

MSB BÜTÇESİ ÖN DÖNEM TAHMİNLERİ				
ÖN DÖNEM	GERÇEK GÖZLEM DEĞERİ	ORTALAMA NOKTA TAHMİNİ	*GÜVEN ARALIKLARI	
			ALT SINIR	ÜST SINIR
2006	11.575.302	11.208.233	10.581.388	11.835.077
2007	11.832.239	12.112.619	11.489.866	12.735.372
2008	-	13.017.006	12.397.468	13.636.544
2009	-	13.921.393	13.304.777	14.538.008
2010	-	14.825.779	14.212.086	15.439.473

❖ Güven aralıkları % 5 anlamlılık düzeyinde yapılmıştır.

c. Yapay Sinir Ağları Analizi

Yapay Sinir Ağları, birçok veri grubuna uygulanabilen, esnek ve doğrusal olmayan bir yapıdadır. Teorik olarak, uygun sayıdaki doğrusal olmayan süreç içeren YSA yapıları, eğitilerek tecrübe kazanır ve pek çok karmaşık problemde doğru sonuçlar üretebilir. Doğrusal olmayan problemlerde olduğu kadar, doğrusal tahmin problemlerinde de çok iyi sonuçlar veren YSA yapılarının gösterdiği bu başarı, tahmin problemlerinde sıklıkla uygulanmalarını sağlamıştır.

(1) Ağ Yapısının Oluşturulması

Pek çok alanda çeşitli YSA modelleri kullanılmasına karşın özellikle tahmin problemlerinde, bir danışmanlı öğrenme yöntemi olan ileri

beslemeli geri yayılım ağıları (back-propagation) sıklıkla kullanılmaktadır. Bu nedenle çalışmamızda bu ağ yapısı kullanılmıştır.

YSA yapılarında en önemli konulardan birisi de girdi nöronu seçimidir. Literatürdeki yapılan çalışmalarda, bu konuda kesin bir kural olmamakla birlikte çalışmalarda kullanılan veri seti, girdi nöron sayısının belirlenmesinde belirleyici faktör konumundadır. Çalışmamızda, MSB bütçe zaman serisinin üçer aylık verileri kullanıldığından, girdi nöron sayısı 4 olarak belirlenmiştir.


Gizli nöron ve katman sayısını belirlemeyle ilgili de genel bir kural yoktur. En sık kullanılan yol, deneme yanılma yöntemidir. Bu nedenle çalışmada tek gizli katman kullanılmış olup yapılan denemeler neticesinde en iyi sonuçların, 2 gizli katman nöronuyla alındığı görülmüştür.

Çıktı nöron sayısının belirlenmesindeki kural, yapılacak olan tahmin dönem uzunluğuyla ilgilidir. Çıktı nöronun sayısı, tahmin döneminin uzunluğuna eşittir. Çalışmada, çıktı nöronu tahmin edilecek dönem sayısı kadar alınmıştır.

Genel olarak, bir ağın aynı ya da farklı katmanlarındaki nöronlar farklı aktivasyon fonksiyonlarını kullanabilirler. Yapılan denemeler sonucunda çalışmada, gizli katmanda hiperbolik tanjant sigmoid (tansig) aktivasyon fonksiyonu, çıktı katmanında ise doğrusal (purelin) aktivasyon fonksiyonu kullanılmıştır.

YSA yapılarının başarısında en büyük etkenlerden biride normalleştirmedir. Çalışmamızda kurulan YSA yapısında, hiperbolik tanjant sigmoid (tansig) aktivasyon fonksiyonu kullanıldığından dolayı veri setinde $[-1 \ 1]$ aralığında normalleştirme yapılmıştır.

Öğrenme algoritmalarının seçiminde, ağ yapısının belirleyici olduğu bilinmektedir. Bu nedenle özellikle geri yayılım ağlarında kullanılan ve çalışmamızda diğer algoritmalara göre daha başarılı sonuçlar veren Levenberg-Marquardt (trainlm) algoritması seçilmiş olup modellerin kurulup ön tahminler yapılmasında, Matlab 7.0 Neural Networks Toolbox programı kullanılmıştır. Oluşturulan ağ yapısı Şekil-24'tedir.



Şekil-24 : YSA Modeli

Çalışmamızda oluşturulan YSA modelinin genel yapısı Şekil-24'te görülmektedir. Model tek gizli katmandan oluşmakta olup gizli katmandaki nöron sayısı 2'dir. Gizli katmanda hiperbolik tanjant sigmoid (tansig) aktivasyon fonksiyonu, çıktı katmanında ise doğrusal (purelin) aktivasyon fonksiyonu kullanılmıştır.


(2) Eğitim ve Test

Yapay sinir ağları kullanılarak mevsimsel zaman serilerinin tahmini üzerine sınırlı sayıda çalışma yapılmıştır. Bu çalışmalarda, bir kısım araştırmacılar, YSA yapısında girdi veri setini oluştururken mevsimsel ve trend etkilerinin giderilmesini savunmuştur. Bir kısmı ise, YSA yapılarının öğrenme gücüne güvenerek veri setini olduğu gibi kullanmayı tercih etmiştir (Zhang ve Qi, 2005). Çalışmamızda, veriler mevcut durumlarıyla kullanılmış olup logaritmik değerlerin alınması dışında veriler üzerinde herhangi bir işlem yapılmamıştır.

Mevsimlik etkiler ve trend içeren zaman serilerinin yer aldığı bir kısım çalışmalarda; YSA yapısını oluştururken giriş katmanında farklı zaman gecikmelerindeki seri değerleri (y_{t-1} , y_{t-4} , y_{t-12} ... y_{t-k}), çıkış katmanında ise gecikmesiz seri değerleri (y_t) kullanılmıştır (Kajitani ve diğerleri, 2005).


Benzer şekilde çalışmamızda, MSB bütçe zaman serisinin gecikmeli değerleri girdi katmanı değerlerini oluşturmuştur. MSB bütçesinin 1990-2005 yıllarını kapsayan veri seti eğitim ve onay şeklinde ikiye bölünmüştür. Son dört dönem onay veri seti olarak kullanılmıştır. 2006 ve 2007 yıllarına ait veri seti ise Box-Jenkins yöntemiyle karşılaştırma yapılması amacıyla test veri seti olarak alınmıştır. Bu şekilde bölünme, YSA yapıları için önemlidir. Çünkü eğitim aşamasında, model eğitilerek parametreler tahmin edilir. Onay bölümü ise oluşturulan modellerden, en iyi olanını seçmek için kullanılır (Zhang ve Qi, 2005).

Şekil 25’de YSA modeli geçmiş dönem tahminlerinin, gerçek değerler karşısında gelişimi görülmektedir.



Şekil-25 : YSA Modeli Geçmiş Dönem Tahminleri.


Şekil-25 incelendiğinde, YSA modelinin, genel olarak oldukça başarılı bir performans çizdiği görülmektedir. YSA modelinden elde edilen değerlerle gerçek değerler arasında, dönüm noktası hatasına yol açan herhangi bir sapma yoktur. Modelin tahmin değerlerinin gerçek değerler ile uyum içinde hareket etmekte olduğu gözlemlenmektedir.



Şekil-26 : YSA Modeli Hata Grafiği.


Modelin eğitim hata grafiği Şekil-26'de görülmektedir. Hata grafiği incelendiğinde, öğrenme işleminin gerçekleştiği görülmektedir.

Eğitim işlemi sonucunda kurulan modelin, test veri seti üzerinde uygulanması gerekmektedir. Test kümesinin amacı, ağın öğrenmesinin yeterli ya da doğru olup olmadığının sınanmasıdır. Böylece ağın, tahmin sürecinde kullanılma yeterliliği değerlendirilmiş olur. YSA modelinden test işlemi sonucu elde edilen değerler ile gerçek değerlerden oluşan grafik Şekil-27'da görülmektedir.



Şekil-27 : YSA Modeli Test Değerleri.

YSA modelinin test işleminden elde edilen değerlerle, gerçek değerlerin karşılaştırıldığı grafikte, modelin başarılı ön tahminler yaptığı görülmektedir. Test çıktılarıyla gerçek değerler, uyum içinde hareket etmektedir. Grafikten de görüldüğü gibi, ön dönem tahminleri yapmak amacıyla kurulan YSA modeli, oldukça başarılı tahminler yapmıştır. Bu tahminler sonucunda ortaya çıkan hata grafiği, Şekil 28'de görülmektedir.



Şekil-28 : YSA Modeli Test Hata Grafiği.

YSA modelinin kurulması için yapılan eğitim ve test aşamalarından sonra modelin doğruluk analiz ölçütlerine göre hata değerleri bulunmuştur. Ortalama mutlak hata yüzdesi (MAPE), ortalama mutlak hata (MAE) ve karakök hata kareler toplamı (RMSE) ölçütlerine göre YSA modeli Tablo-7’de değerlendirilmiştir.

Tablo-7 : YSA Modeli Performans Değerlendirmesi.

	YSA MODELİ		
	EĞİTİM	ONAY	TEST
MAPE	9,84	6,88	7,23
MAE	72.315	168.590	215.872
RMSE	149.719	218.998	268.748

Tablo 7’den de görüldüğü gibi onay işlemine ait MAPE değeri, eğitim işlemine ve test işlemine göre daha düşük çıkmıştır. En düşük MAE değeri eğitim işlemine aittir. Yine en düşük RMSE değeri, eğitim işleminindir. YSA modeli; başarıyla eğitilmiş, onay işleminde kurulmuş, test işleminde de başarılı tahminler yapmıştır.

Yapılan değerlendirmeler neticesinde oluşturulan YSA modeli kullanılarak yapılan 2008-2010 yıllarına ait ön dönem tahminleri Tablo-8’de görülmektedir.

Tablo-8 : YSA Modeli 2008-2010 Ön Tahminleri (Milyon YTL).

ÖN DÖNEM	YSA MODELİ TAHMİN
2008-1	2.100.599
2008-2	2.706.171
2008-3	2.864.616
2008-4	4.218.719
2009-1	2.263.066
2009-2	2.732.818
2009-3	2.841.363
2009-4	4.100.654
2010-1	2.413.251
2010-2	2.762.321
2010-3	2.820.400
2010-4	3.983.754

DÖRDÜNCÜ BÖLÜM

DEĞERLENDİRME

1. DOĞRULUK ANALİZ ÖLÇÜTLERİ

Çalışmanın bu aşamasında, analizlerden elde edilen tüm modeller karşılaştırılmıştır. Genel olarak, kullanılan öngörü modelleri doğruluk derecelerine göre farklılık gösterir. Bundan dolayı da çeşitli modellerden elde edilen öngörü değerleri aynı olmayacaktır. Doğal olarak modellerden elde edilen öngörü değerleri gerçekleşmiş değerlerden farklılık gösterir. Çünkü gelecek dönemlerde ortaya çıkacak olaylar, belirsizlikler içerir. Bunun için yapılan öngörüler, bu olayları tam tanımlayamazlar. Bu durumda öngörülerin ekonomik politika ve karar yapımında bir araç olarak kullanılması ve uygun modellerin seçimi ön tahminlerin doğruluk derecesinin bilinmesini zorunlu kılar. Doğruluk analizleri temel olarak ön tahmin hatalarını alır. Bu nedenle modeller karşılaştırılırken ön tahmin hatalarının olduğu grafikler verilmiştir. Doğruluk analizlerinde ön tahmin hataları karşılaştırmaları için sıklıkla kullanılan bu ölçütler aşağıdaki eşitliklerde verildiği gibidir.

- Ortalama Hata Kare (MSE) = $\sum \frac{(e_t)^2}{N}$
- Ortalama Mutlak Hata (MAE) = $\sum \frac{|e_t|}{N}$
- Ortalama Mutlak Yüzde Hata ($MAPE$) = $\frac{1}{N} \sum \left| \frac{e_t}{y_t} \right| (100)$
- Hata Kareler Toplamı (SSE) = $\sum (e_t)^2$

- Ortalama Hata Karenin Karekökü ($RMSE$) = $\sqrt{MSE}$

Burada;

e_t : kestirim hatasını,

y_t : t'inci gözlem değerini,


N : hata terimleri sayısını göstermektedir.

Çalışmanın devamında, doğruluk analizleri çerçevesinde yukarıdaki ölçütlere göre öngörü modellerinin karşılaştırmaları yapılacak ve incelenen modeller içinde minimum hata kareli model seçilecektir. Burada ulaşılan sonuçlar kesin olmaktan çok öneri niteliğindedir. Çünkü değerlendirmede kullanılan karşılaştırma yöntemleri, öngörülerin sürekli bir şekilde yapılmasını ve ön dönemlerin aynı olması koşulunu aramaktadır.

2. EKONOMETRİK MODEL VE SARIMA MODELİNİN KARŞILAŞTIRMASI


Modellerdeki kullanılan verilerin zaman aralığı özellikle regresyon analizinde farklı dönemleri kapsadığı için değerlendirme yapmak güçleşmektedir. Regresyon analizinde üçer aylık veri bulunamamasından dolayı GSMH'nın yıllık verileri kullanılmıştır. Modeller arasında karşılaştırma yapılabilmesi amacıyla regresyon analizi verilerine uygun olarak, çarpımsal SARIMA modelinin örneklem içi tahminleri yıllık olarak düzenlenmiştir. YSA modeli bu karşılaştırmaların dışında tutulmuştur.

Analiz sonuçlarını değerlendirirken 1990-2005 yıllarına ait tahminler örneklem içi tahmin değerlerini oluştururken 2006 ve 2007 yıllarına ait tahminlerde örneklem dışı tahmin değerleri olarak kullanılmıştır. Ekonometrik model ve çarpımsal SARIMA modeline ait ön tahmin hataları Şekil-29'ta görülmektedir.



Şekil-29 : Ekonometrik Model ve SARIMA Modeli Ön Tahmin Hataları Grafiği.

Modellerin ön tahmin hata grafiği incelendiğinde SARIMA modelinin ekonometrik modele göre kısmen de olsa daha iyi bir gelişim sergilediği görülmektedir. Her iki model de 2002 ve 2003 yıllarında yüksek hata oranları göstermiştir. Modellerin hataları genelde ters yönlüdür. Modellerin geçmiş dönem tahminlerinin zaman içinde gelişimini görmek önemlidir.



Şekil-30 : Ekonometrik Model ve SARIMA Modeli Geçmiş Dönem Tahminleri Grafiği.

Şekil-30'da ekonometrik modelle, SARIMA modelinin gerçek değerler karşısında yıllara göre geçmiş dönem tahminleri görülmektedir. Grafikte, her iki modelinde gerçek değerlere paralel bir seyir izlediği görülmektedir. Ekonometrik model ve çarpımsal SARIMA modelinin açıklanan doğruluk analiz ölçütlerine göre yapılan karşılaştırması, Tablo-9'dadır.

Tablo- 9: Ekonometrik Model ve SARIMA Modelinin Performans Tablosu.


	ÖRNEKLEM İÇİ	
	REG.	SARIMA
MAPE	9,61	2,93
MAE	389.159	199.527
RMSE	606.864	384.618

Tablo-9'da iki model, örneklem içi verilerine göre değerlendirilmiştir. Örneklem içi olarak kullanılan 1990-2005 yıllarını kapsayan dönemde, çarpımsal SARIMA modelinin, ekonometrik modele göre tüm doğruluk analiz ölçütlerinde başarılı olduğu, net bir şekilde görülmektedir. Çarpımsal SARIMA modeli yaklaşık % 3 oranında hata içermektedir.

Örneklem dışı yani 2006 ve 2007 yıllarına göre uygulanan doğruluk analiz ölçütlerinde ise ekonometrik modelin RMSE değeri 326.614, SARIMA modelinin değeri ise 778.280'dir. Ekonometrik model % 2,77, SARIMA modeli ise % 4,82 oranında hata içermektedir. Örneklem dışı verilerde ekonometrik model, SARIMA modeline göre daha iyi bir performans göstermiştir. Ancak özellikle kısa dönem ön tahminlerinde, veri düzeyi öngörüsüne göre hesaplanmış olan ön tahmin hataları, birbirlerini etkileyerek hataların daha büyük olmasına neden olabilmektedir. Bu durum örneklem dışı değerlendirmede açıkça görülmektedir. Örneklem içi değerlendirmede daha iyi bir performans çizen çarpımsal SARIMA modeli, örneklem dışı verilerinin sadece iki dönemi kapsamından dolayı daha büyük hata değerleri vermektedir.


3. YAPAY SİNİR AĞLARI MODELİ VE SARIMA MODELİNİN KARŞILAŞTIRMASI

Çalışmanın bu aşamasında SARIMA çarpımsal modeliyle, YSA modeli karşılaştırılarak değerlendirilmiştir. Bu iki modele ait hata grafiği Şekil-31’de görülmektedir.



Şekil-31 : SARIMA ve YSA Modeli Hata Grafiği.

Şekil-31 incelendiğinde YSA modelinin, SARIMA modeline göre eksene daha yakın bir seyir izlediği görülmektedir. Özellikle 2002 yılını kapsayan dönemde ters yönlü hatalar meydana gelmiştir. İki modelin geçmiş dönem tahminlerine göre oluşturulan grafik, Şekil-32’de görülmektedir.



Şekil-32 : SARIMA ve YSA Modeli Geçmiş Dönem Tahminleri.

Modellerin geçmiş dönem tahminlerinin gösterildiği tahmin grafiğinden de görüldüğü gibi her iki model benzer bir performans sergilemiştir. Grafikte gerçek değerler baz alındığında dönüm noktası hatası görülmemektedir. Hem SARIMA modeli, hem de YSA modeli gerçek değerlere paralel bir seyir izlemiştir. Hangi modelin daha iyi olduğunun belirlenmesi açısından, modellerin doğruluk analiz ölçütlerine göre değerlendirilmesi Tablo-10'da yapılmıştır.

Tablo- 10 : YSA ve SARIMA Modelinin Performans Tablosu

	ÖRNEKLEM İÇİ		ÖRNEKLEM DIŞI	
	YSA	SARIMA	YSA	SARIMA
MAPE	9,65	11,2	7,23	8,1
MAE	78.734	92.160	215.872	234.877
RMSE	155.302	207.739	268.748	320.223

Modellerin doğruluk analizlerine göre değerlendirmesi yapılırken 1990-2005 yılları arası örneklem içi, 2006 ve 2007 yılları örneklem dışı veri seti olarak alınmıştır. Tablo-10'da görüldüğü gibi YSA modeli, çarpımsal SARIMA modeline göre hem örneklem içinde hem de örneklem dışında, daha iyi bir performans sergilemiştir. YSA modeli % 7,23 oranında mutlak hata içerirken, bu oran SARIMA modelinde % 8,1'dir. Yine benzer şekilde RMSE değeri örneklem dışı tahminlerin yapılması aşamasında YSA modelinde 268.748 olup SARIMA modelinde 320.223'tür.

BEŞİNCİ BÖLÜM

SONUÇ VE ÖNERİLER

1. SONUÇLAR

Savunma harcamaları, her dönemde genel bütçe içinde önemli bir paya sahip olmuştur. Son yıllara kadar savunma harcamalarının büyük kısmını oluşturan Milli Savunma Bakanlığı bütçesinin, genel bütçeden aldığı pay düşme eğilimi göstermiştir. Bu pay, 2007 yılında en düşük seviyesine ulaşmıştır. Milli Savunma Bakanlığının azalan bütçesinin yarattığı durum zaten sınırlı olan kaynakların daha iyi yönetilmesi zorunluluğunu ortaya koymuştur.

Gelecekle ilgili planlamaları yaparken, en büyük sorun belirsizliktir. Geleceğe yönelik değerlendirmelerde, gelecekteki koşulların neler olabileceğini bilmek ya da tahmin etmek, alınacak kararların daha gerçekçi olmasını sağlayacaktır. Karar vericiler oluşacak her türlü olumsuz değişikliklere karşı önceden tedbir alma fırsatı bulacaktır. Bu fırsatları yaratmak ve belirsizlik ortamında karar vermek için, gelecekte uygulanması düşünülen proje ve planlamaların maliyetleriyle ilgili iyi yapılmış ön tahminlere ihtiyaç vardır.

Bu çalışmada; regresyon analizi, Box-Jenkins yöntemi ve Yapay Sinir Ağları karşılaştırılarak, en iyi yöntemle Milli Savunma Bakanlığı bütçe büyüklüklerinin, gelecekte alabileceği değerlerin ön tahminleri yapılmıştır.

Öncelikli olarak regresyon analizinden elde edilen ekonometrik modelle, Box-Jenkins yönteminden elde edilen çarpımsal SARIMA modeli karşılaştırılmıştır. Bu karşılaştırmada, yıllık veri seti kullanılarak kurulan

modellerin performanslarında, SARIMA modeli özellikle nedensellik ilişkilerini yansıtmaya gibi bir eksiği olsa da, ön tahminlerde ekonometrik modele göre daha üstün bir performans göstermiştir. Çeşitli açıklayıcı değişkenlerle kurulan ekonometrik modeller arasında en anlamlı sonuçları, Gayri Safi Milli Hasıla'nın bağımsız değişken olduğu model vermiştir. Bu model, GSMH ile MSB bütçesi arasında sıkı bir ilişki olduğunu ortaya koymuştur. GSMH artarken MSB bütçesi de artmaktadır. Burada dikkati çeken nokta, 1994 ve 2001 yıllarında meydana gelen ekonomik krizleri ifade etmek için kullanılan kukla değişkenlerin, kurulan alternatif modellerde anlamlı olmamasıdır. Bu durum bize; ülkemizde meydana gelen ekonomik krizlerin, Milli Savunma Bakanlığı bütçe büyüklüğünü etkilemediğini ve bütçenin genel seyrini koruduğunu göstermiştir.

Box-Jenkins yöntemiyle kurulan modelle, YSA analizinden elde edilen model karşılaştırıldığında ise, YSA modelinin SARIMA modeline göre daha iyi bir performans gösterdiği görülmüştür. Milli Savunma Bakanlığı bütçe büyüklüğünü tahminde her iki modelde başarılı olmuştur. Fakat doğruluk analiz ölçütlerine göre, YSA modelinin performansı bir adım öne çıkmıştır.

Bu çalışma, Milli Savunma Bakanlığı bütçesinde olduğu gibi trend ve mevsimsellik içeren zaman serilerinin ön tahminlerinde başarılı bir yöntem olduğu bilinen Box-Jenkins modellerine, YSA modellerinin iyi bir alternatif olabileceğini göstermiştir. Özellikle YSA analizinde veri setine, logaritmik değerlerin alınması dışında, fark alma gibi başka bir işlem uygulanmaması artı bir faktör olarak değerlendirilmiştir.

Yapay Sinir Ağları son dönemde yıldızı parlayan ve özellikle ön tahmin problemlerinde de sıklıkla uygulanan bir yöntemdir. Doğrusal olmayan yapıdaki pek çok problemde başarılı sonuçlar veren YSA yapılarının, doğrusal özellikteki bir problemde de başarılı olabileceği görülmüştür. Milli Savunma Bakanlığı bütçe büyüklüklerinin ön tahminlerinin yapılması aşamasında; sıklıkla ön tahmin problemlerinde tercih edilmesi ve kullanım

kolaylığı gibi özellikleri nedeniyle, Geri Yayılım Yapay Sinir Ağları kullanılmıştır. Aşırı öğrenme ve hatalı ağ yapısının oluşturulması gibi problemleri olan YSA yapılarının bu problemleri aştıkları takdirde ön tahmin problemlerinde iyi bir alternatif olarak değerlendirilmesi gerektiği sonucuna varılmıştır.

2. ÖNERİLER

Ülkemizin etrafında şekillenen yeni durumlar ve oluşan farklı boyutlardaki tehdit algılamaları sonucunda, Türk Silahlı Kuvvetleri'nin mevcut yapılanmasını gözden geçirmeye ve yeniden yapılanmaya ihtiyacı olduğu açıktır. Bunun içindir ki; Türk Silahlı Kuvvetleri'nin vurucu ve caydırıcı gücünü arttıracak ve teknolojik yönden üstün konuma getirecek pek çok planlama ve çalışma yapılmaktadır. Savunma harcamalarının büyük kısmını oluşturan Milli Savunma Bakanlığı bütçesinin, genel bütçe içindeki payının giderek düştüğü görülmektedir. İhtiyaç duyulan yüksek teknolojik silah, araç ve gereçlerin maliyetleri ise savunma harcamalarını artırmaktadır. Bu problemlerin çözümüyse iyi planlanmış personel politikasında gizlidir. Her türlü teknolojik silahı kullanabilen, profesyonel ve iyi eğitilmiş personel, Türk Silahlı Kuvvetleri'ni başarıya taşıyabilir. Bu anlamda, ordudaki küçülme artan teknolojik harcamaları dengeleyecek ve her türlü ihtiyaç için kaynak sağlanabilecektir.

Türkiye'nin kısıtlı kaynaklarının yönetilmesi için sürekli planlama yapılmak zorundadır. Ayrılan en küçük kaynak bile büyük bir dikkatle ve özenle incelenip kullanılmalıdır. Bu çalışmada olduğu gibi; farklı yöntemler kullanılarak gelecekteki bütçe büyüklüklerini ön tahminle ilgili yapılan çalışmalar, kaynak ayırma ve kullanımı ile ilgili oluşacak her türlü kısıtı belirlemeye yardımcı olacaktır.

3. GELECEK ÇALIŞMALARA ÖNERİLER

Bu çalışma, elde edilen ön tahminlerin çeşitlendirilerek farklı yöntemler arasında karşılaştırma yapılmasının, daha doğru sonuçları elde etme adına önemli olacağını göstermiştir. Uzun zamandır kullanılan geleneksel tahmin yöntemleriyle beraber kullanıldığında YSA yapıları, daha verimli sonuçlar üretebilir.

İleriye yönelik olarak yapılacak çalışmalarda; farklı mimarilere sahip yapay sinir ağları modelleri kullanılarak, savunma harcamalarının farklı boyutları incelenip ön tahminler yapılabilir ve savunma harcamalarını oluşturan çeşitli faktörler modellenenebilir. Ayrıca yapay sinir ağları ile zaman serisi tahmin yöntemlerinin birleştirildiği melez modellerin tahmin performansları araştırılabilir.

KAYNAKÇA

ALTUN, Nurullah. **“Savunma Harcamaları ve Türkiye’deki Gelişme Seyri (1973-1998 Dönemi)”**, (Yayımlanmamış Doktora Tezi), İstanbul, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, 1998.

ANDERSON, D. and MCNEILL, G. **Artificial Neural Networks Technology**, Kaman Sciences Corporation, New York, 1992.

ARBIB, Michael. **The Handbook of Barin Theory and Neural Networks**, The MIT Press, 2002.

BOX, G.E.P. and JENKINS, G.M. **Time Series Analysis: Forecasting and Control**, Holdan-Day, San Francisco, 1976.

BOX, G.P. and PIERCE, D.A.” Distribution of Residual Autocorrelations in Autoregressive-Integrated Moving Average Time Series Models”, **Journal of American Statistical Association**, 65332:, 1970,1509-1526.

BOZKURT, H. **Zaman Serileri Analizi**, Ekin Kitabevi, Ankara, 2007.

BUHAMRA, S., SMAOUI, N., GABR, M. “The Box-Jenkins Analysis and Neural Networks: Prediction and Time Series Modelling” **Applied Mathematical Modelling**, 27, 2003, 805-815.

CHATFIELD, C. **The Analysis Of Time Series: Theory and Practice**, Chapman and Hall, London, 1978.

CHU, C. W. and ZHANG, G. P. “A comparative study of linear and nonlinear models for aggregate retail sales forecasting”, **International Journal of Production Economics**, 86, 2003, 217-231.

DEMUTH, H., BEALE, M. **Neural Network Toolbox For Use with MATLAB User’s Guide**, Version 4, The MathWorks, MA, 2000, 1-60.

DUNNE, Paul. ve diğerleri. “The Demand For Military Spending in the Peripheral Economies of Europe”, **Defence and Peace Economics**, 14, 2003, 447-460.

ELMAS, Ç. **Yapay Sinir Ağları**, Seçkin Yayıncılık, Ankara, 2003.

ENDERS, W. **Applied Econometric Time Series**, John Wiley & Sons, USA, 1995.

GİRAY, Filiz. Savunma Harcamaları ve Ekonomik Büyüme, **Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi**, 5, 1, 15 Aralık 2007, 181-199. <<http://www.cumhuriyet.edu.tr/edergi/makale/865.pdf> >

GUJARATI, D. N. **Temel Ekonometri**, (Çev. Ümit ŞENESEN, Gülay Günlük-ŞENESEN) Literatür Yayıncılık, 1999.

GURNEY, K. "Computers and Symbols versus Nets and Neurons", **UCL Draft Papers**, No:1, U.K, 1996.

GÜNERİ, N., APAYDIN, A. "Öğrenci Başarılarının Sınıflandırılmasında Lojistik Regresyon Analizi ve Sinir Ağları Yaklaşımı", **Ticaret ve Turizm Eğitim Fakültesi Dergisi**, 1, 2004, 170 – 188.

GÜNLÜK-Şenesen, Gülay. **Türkiye’de Savunma Harcamaları ve Ekonomik Etkileri 1980-2001**, İstanbul, Türkiye Ekonomik ve Sosyal Etüdler Vakfı, 2002.

GRANGER, C.W.J. ve NEWBOLD, P. **Forecasting Economic Time Series**, Academic Press, USA, 1986.

HAMZAÇEBİ, C., KUTAY, F. "Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini", **Gazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi**, 19, 3, 2004, 227-233.

HANKE, J. E. ve WICHERIN, D. W. **Business Forecasting**, Pearson Prentice Hall, New Jersey, 2005.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**, International Edition, Prentice-Hall, New Jersey, 1999, 1-22.

HEBB, D.O. **The Organization of Behaviour**, Wiley, New York, 1949.

HİLL, T., O’CONNOR, M., REMUS, W. "Neural Networks Models for Time Series Forecasts", **Management Sciences**, 42, 7, 1996, 1082-1092.

HOPFIELD, F.F. "Neural Networks and Physical Systems with Emmergent Collective Computational ağabeylities", **Proceedings of the National Academy of Sciences of the USA**, 79, 1982, 2554-2558.

HYLLEBERG, S. **Modelling Seasonality**, General Introduction.In: Hylleberg, S.(Ed.), Oxford University Press. Oxford, 1992, 3-14.

JONHSTON, J., DINARDO, J. **Econometric Methods**. The McGraw-Hill Companies, Inc., International Edition,1997.

KAJITANI, Y., HIPEL, K. W. ve MCLEOD, I. "A Forecasting Nonlinear Time Series with Feed-Forward Neural Networks: A Case Study of Canadian Lynx Data", **Journal of Forecasting**, Volume: 24, 2005, 108.

KARAKUŞ, Adnan. "Türk Savunma Sanayinin Gelişimi, Türkiye'nin Savunma Harcamalarının Boyutları ve Bazı Nato Ülkeleri ile Karşılaştırmalı Ekonometrik Analizi", (Yayımlanmamış Yüksek Lisans Tezi), Kara Harp Okulu Savunma Bilimleri Enstitüsü, Ankara, 2006.

KARTALOPOULAS, S. V. **Understanding Neural Networks and Fuzzy Logic**, The Institute of Electrical and Electronics Engineers Press, New York, 1996.

KAYA, E. "Türkiye'ye yapılan Güvenlik Yardımları ve Etkileri", (Yayımlanmamış Yüksek Lisans Tezi), Hacettepe Üniversitesi, Sosyal Bilimler Enstitüsü, Ankara, 1997.

KAYA, E. "Dışa Açılma Döneminde Savunma harcamalarının Ekonomik Etkileri (1980-2004 Türkiye Örneği)", (Yayımlanmamış Doktora Tezi), Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, Konya, 2006.

KAYIM, H. **İstatistiksel ön kestirim yöntemleri**, Hacettepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi, Yayın No:11, Ankara, 1985.

KRYCHA, Karl A., WAGNER, Udo 2001 Applications of Artificial Neural Networks in Management Science: A Survey, **Journal of Retailing and Consumer Services**, Vol. 6, 2001, 185 – 203.

KURUP, Pradeep U., DUDANI, Nitin K. Neural Networks for Profiling Stress History of Clays from PCPT Data., **Journal of Geotechnical & Geoenvironmental Engineering**, July 2002, Vol. 128, Issue 7, 571.

LİPMANN, R. P. An introduction to computing with neural nets, **IEEE ASSP Magazine**, April, (1987), 4-22.

LJUNG, G.M.and BOX, G.P. "On a Measure of Lack of Fit in Time Series Model" **Biometrika**, 65, 1978, 297-303.

MADDALA, G. S. **Introduction to Econometrics**, John Wiley & Sons, Third Edition, England, 2001.

MAKRIDAKIS, S., WHEELWRIGHT, S.C. **The Handbook of the Forecasting: A Manager's Guide**, Second Edition, Wiley, New York, 1987.

Maliye Bakanlığı İnternet Sitesi, 12 Haziran 2007.<<http://www.maliye.gov.tr>>

Maliye Bakanlığı Muhasebat Genel Müdürlüğü İnternet Sitesi, 13 Haziran 2007.<<http://www.muhasebat.gov.tr/ekogosterge/2007WEB/teg/teg.htm>>

Maliye Bakanlığı , **Savunma ve Güvenlik Hizmetleri (1924-1993)**, Ankara, Bütçe ve Mali Kontrol Genel Müdürlüğü, 1993.

MASTERS, T. **Neural, Novel & Hybrid Algorithms for Time Series Prediction**, John Wiley & Sons, Canada, 1995.

McCULLOUGH, W and PITTS, W. "A Logical Calculus of Ideas Immanent in Nervous Activity", **Bul. Math. Biophys.** 5, 1943, 115-133.

MEHROTA, K., MOHAN, C. K., RANKA S. **Elements of Artificial Neural Networks**, London d: Massachusetts Institute of Tecnology, 1997, 70.

Milli Savunma Bakanlığı, **Beyaz Kitap Savunma 1998**, Ankara, MSB, 1998, 117-118.

Milli Savunma Bakanlığı , **Beyaz Kitap Savunma 2000**, Ankara, MSB, 2000, 107.

ÖZDAMAR, Kazım. **Paket Programlar İle İstatistiksel Veri Analizi – 1**, Eskişehir, Kaan Kitabevi, 2004.

ÖZTEMEL, E. **Yapay Sinir Ağları**, Papatya Yayıncılık, İstanbul, 2003.

PINDYCK, R.S., RUBINFELD, D.L. **Econometric Models & Economic Forecasts**, McGraw-Hill, Second Edition, USA, 1981.

REFENES, A. P. and WHITE, H. **Neural Networks and Financial Economics**, International Journal of Forecasting, 1998.

RUMELHART, D. E., MCCLELLAND, J. L. "Paralel Distributed Processing, Explorations in the Microstructure of Cognition", Vol.1. **MIT Press**, Cambridge, Massachusetts, 1986.

SAĞIROĞLU, Ş., BEŞDOK, E., ERLER, M. **Mühendislikte Yapay Zeka Uygulamaları-1; Yapay sinir Ağları**, Ufuk Yayıncılık, Kayseri, 2003.

SEZGİN, Selami. "Türkiye’de Savunma Harcamaları; Bir Giriş", **Savunma Sanayisi Sempozyumu-2000: Türk Savunma Sanayisinin Dünyü, Bugünü, Yarını**, Ankara 7-8 Kasım 2000, 476-484.

SIPRI Yearbook 2005. SIPRI Home Page. 15 Aralık 2007.
<<http://www.yearbook2007.sipri.org/chap8>>.

SMITH, K. A., GUPTA, J.N.D. **Neural Networks in Business: Techniques and Applications**, IRM Pres: United Kingdom, 2002.

ŞEN, Zekai. **Yapay Sinir Ağları ve İlkeleri**, İstanbul, Su Vakfı Yayınları, 2004.

ŞİMŞEK, Muammer. **Üçüncü Dünya Ülkelerinde ve Türkiye’de Savunma Sanayi**, Ankara, SAGEB, 1989.

UÇAR, İbrahim. **“Savunma Harcamalarının Ekonomiye Etkileri ve Savunma Harcamaları-Büyüme İlişkisinin Ekonometrik Modellenmesi”**, (Yayımlanmamış Yüksek Lisans Tezi), Kara Harp Okulu Savunma Bilimleri Enstitüsü, Ankara, 2003.

TANG, Z., ALMAİDA, C., FISHWICK, P. “Time Series Forecasting Using Neural Networks vs. Box-Jenkins Methodology” , **Simulation**, 57, 5, 1991, 303-310.

TSAI, C-F., WU, J-W. “Using Neural Network Ensembles for Bankruptcy Prediction and Credit Scoring”, **Expert Systems with Applications**, 11 Mayıs 2007. <<http://www.sciencedirect.com/doi:10.1016/j.eswa.2007.05.019>>

TSENG, F. M., YU, H. C., TZENG, G. H. Combining neural network model with seasonal time series ARIMA model, **Technological forecasting & Social Change**, 69, 2002, 71-87.

TÜRK, Hünkar Karahan. **“Savunma Sanayiinin Ekonomik Etkileri ve Savunma harcamaları-Büyüme İlişkisinin Ekonometrik modellenmesi”**, (Yayımlanmamış Yüksek Lisans Tezi), Çukurova Üniversitesi Sosyal Bilimler Enstitüsü, Adana, 2007.

YAZICIOĞLU, Y. ve ERDOĞAN S. **SPSS Uygulamalı Bilimsel Araştırma Yöntemleri**, Ankara, Detay Yayıncılık, 2004.

YURTOĞLU, Hasan. **“Yapay Sinir Ağları ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği ”**, Uzmanlık Tezi, DPT, Ankara, 2005.

ZHANG, G.P., PATUWO, B. E., HU, Y. M. “Forecasting with artificial neural networks”, **International Journal of Forecasting**, 14,1998, 35-62.

ZHANG, G. P. and MİN Q. “Neural Network Forecasting For Seasonal and Trend Time Series”, **European Journal of Operational Research**, 160, 2005, 501-514.

ZİYLAN, A. ve diğ erleri. **Savunma Sanayisi ve Tedarik:  lkemizin Bilim ve Teknoloji Yeteneğinin Y kseltilmesini Esas Alan Bir Yaklaşım**, Ankara, T bitak Yayınları, 1998.

EKLER

EK-A : MİLLİ SAVUNMA BAKANLIĞI BÜTÇESİ (1990-2007)

EK-B : TEMEL EKONOMİK GÖSTERGELER (1990-2005)

MİLLÎ SAVUNMA BAKANLIĞI BÜTÇESİ (1990-1999)

(Milyar TL./Milyon YTL.)	1990	1991	1992	1993	1994	1995	1996	1997	1998	1999
Ocak	80	287	1.057	1.836	2.995	5.094	10.035	21.364	44.060	82.286
Şubat	511	850	1.020	1.919	3.501	6.986	9.887	21.790	50.304	79.491
Mart	447	1.900	1.300	1.968	3.595	7.514	13.680	25.769	61.271	105.410
Nisan	571	765	1.340	2.502	4.623	13.041	17.133	36.441	62.684	124.790
Mayıs	501	849	1.924	2.987	5.836	11.065	19.655	37.976	118.684	136.683
Haziran	552	816	1.451	2.905	6.886	9.800	20.467	45.399	96.068	184.669
Temmuz	606	889	1.980	2.628	6.044	13.542	26.661	73.063	107.565	178.924
Ağustos	585	1.158	2.288	3.039	6.175	15.041	33.167	54.482	99.019	174.989
Eylül	635	1.650	2.391	4.232	7.648	11.442	28.914	69.597	105.018	194.293
Ekim	655	1.430	2.371	4.576	7.674	16.884	35.142	59.998	106.160	187.432
Kasım	718	1.486	2.717	4.087	8.470	14.976	29.223	76.381	134.330	231.254
Aralık	2.105	2.681	5.625	10.627	21.806	42.053	89.433	223.486	371.924	694.493
Q1 OCAK-MART	1.038	3.037	3.377	5.723	10.091	19.594	33.602	68.923	155.635	267.187
Q2 NİSAN-HAZİRAN	1.624	2.430	4.715	8.394	17.345	33.906	57.255	119.816	277.436	446.142
Q3 TEMMUZ-EYLÜL	1.826	3.697	6.659	9.899	19.867	40.025	88.742	197.142	311.602	548.206
Q4 EKİM-ARALIK	3.478	5.597	10.713	19.290	37.950	73.913	153.798	359.865	612.414	1.113.179
Harcamalar toplamı	7.966	14.761	25.464	43.306	85.253	167.438	333.397	745.746	1.357.087	2.374.714
Ödenek toplamı	8.633	14.878	25.214	50.853	104.671	195.512	383.246	853.190	1.596.458	2.843.772
Başlangıç ödenegi	7.646	11.989	23.771	41.371	77.643	152.788	322.630	647.084	1.390.263	2.506.825

MİLLİ SAVUNMA BAKANLIĞI BÜTÇESİ (2000-2007)

(Milyar TL/Milyon YTL.)	2000	2001	2002	2003	2004	2005	2006	2007
Ocak	112.285	155.680	258.258	373.251	433.162	466.803	516.022	604.840
Şubat	123.996	190.454	253.334	330.333	366.916	438.519	486.794	589.117
Mart	144.248	205.029	381.692	401.264	417.205	477.458	618.109	735.263
Nisan	267.875	375.661	598.659	450.893	544.577	567.278	720.568	860.014
Mayıs	243.082	379.161	590.695	696.610	568.781	675.979	696.349	1.004.204
Haziran	317.098	372.313	435.201	787.930	608.560	674.833	865.370	818.068
Temmuz	333.738	469.174	751.749	1.170.835	641.341	743.064	971.159	1.183.286
Ağustos	299.771	339.044	593.748	553.558	682.485	631.851	841.250	797.618
Eylül	261.280	420.066	551.376	616.057	683.673	1.160.804	977.846	907.015
Ekim	406.058	662.217	760.197	951.929	1.008.467	811.785	984.158	891.498
Kasım	356.145	452.494	694.591	574.421	1.085.167	1.092.462	882.313	1.088.096
Aralık	874.701	1.336.181	1.809.837	1.934.215	2.400.052	2.541.514	3.015.364	2.353.220
Q1 OCAK-ARALIK	380.529	551.163	893.284	1.104.848	1.217.283	1.382.780	1.620.925	1.929.220
Q2 NİSAN-HAZİRAN	828.055	1.127.135	1.624.555	1.935.433	1.721.918	1.918.090	2.282.287	2.682.286
Q3 TEMMUZ-EYLÜL	894.789	1.228.284	1.896.873	2.340.450	2.007.499	2.535.719	2.790.255	2.887.919
Q4 EKİM-ARALIK	1.636.904	2.450.892	3.264.625	3.460.565	4.493.686	4.445.761	4.881.835	4.332.814
Harcamalar toplamı	3.740.277	5.357.474	7.679.337	8.841.296	9.440.386	10.282.350	11.575.302	11.832.239
Ödenek toplamı	4.855.100	7.287.140	9.930.296	12.179.340	13.492.907	14.935.062	16.651.403	17.747.945
Başlangıç ödenegi	4.136.352	5.126.252	8.234.969	10.209.250	10.011.848	10.976.455	11.877.533	13.052.398

TEMEL EKONOMİK BÜYÜKLÜKLER (1990-2005)

	1990	1991	1992	1993	1994	1995	1996	1997	1998	1999	2000	2001	2002	2003	2004	2005
GSMH (Trilyon TL-Milyon YTL)	397	634	1.104	1.997	3.887	7.854	14.978	29.393	53.518	78.283	125.596	176.484	273.463	356.680	428.932	486.401
GSMH (Milyar \$)	150,8	150,2	158,2	178,7	132,3	170,1	182,8	192,4	206,5	185,2	201,439	148,2	180,8	239,2	299,4	360,8
Büyüme (%)	9,4	0,3	6,4	8,1	-6,1	8,1	7,9	8,0	3,8	-6,4	6,1	-9,4	7,9	5,9	9,9	7,6
Nüfus (Yıl Ortası, Bin kişi)	56.473	57.305	58.401	59.491	60.576	61.644	62.697	62.510	63.451	64.385	67.420	68.529	69.626	70.712	71.789	72.065
Fert Başına GSMH (\$)	2.712	2.657	2.752	3.056	2.159	2.759	2.916	3.080	3.255	2.879	2.965	2.123	2.598	3,383	4.172	5.008
Ort. TEFE-ÜFE (%)	52,3	55,3	62,1	58,4	120,7	86,0	75,9	81,8	71,8	53,1	51,4	61,6	50,1	25,6	11,1	5,89
Ort. Döviz Kuru (TL- YTL/\$)	2.608	4.170	6.888	10.986	29.704	45.674	81.084	151.429	260.040	417.581	623.749	1.222.921	1.504.598	1,487,119	1,422,341	1,34