

**T.C.
MİMAR SİNAN GÜZEL SANATLAR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**ZAMAN SERİSİ ANALİZİ İLE YAPAY SİNİR AĞLARI
KESTİRİMLERİNİN KARŞILAŞTIRILMASI**

YÜKSEK LİSANS TEZİ

Çiğdem Seda USLU

İstatistik Anabilim Dalı

İstatistik Programı

Tez Danışmanı: Prof. Dr. Gülay KIROĞLU

HAZİRAN 2011

Çiğdem Seda USLU tarafından hazırlanan ZAMAN SERİSİ ANALİZİ İLE YAPAY SİNİR AĞLARI KESTİRİMLERİNİN KARŞILAŞTIRILMASI adlı bu tezin ~~Yüksek Lisans~~ tezi olarak uygun olduğunu onaylarım.

Prof. Dr. Gülay Kiroğlu

Tez Yöneticisi

Bu çalışma, jürimiz tarafındanİSTATİSTİK..... Anabilim Dalında
.....Yüksek Lisans..... tezi olarak kabul edilmiştir.

Başkan: : Prof. Dr. Gülay KIROĞLU

Üye : Prof. Dr. Aydın ERAR

Üye : Yrd. Doç. Dr. Yalçın ÖZKAN

Üye : _____

Üye : _____

Bu tez, Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygundur.

ÖZET

Elektrik enerjisi çoğunlukla depolanamayan ve üretildiğinde hemen tüketilmesi gereken bir enerji çeşididir. Büyük miktarlardaki elektrik enerjisinin depolanması mevcut koşullar altında mümkün değildir. Bu nedenle elektrik talebinin, elektrik arzı ile paralel bir şekilde gitmesi gerekmektedir. Elektrik enerjisi tüketimi yıllara, aylara, günlere ve saatlere göre değişiklik göstermektedir. Bu değişkenlikten dolayı elektrik talebini kestirmek ve talebi karşılayabilecek seviyede kapasiteyi belirlemek çok önemlidir. Elektrik enerjisinin talep planlamalarının yapılması, tüketici memnuniyetsizliklerine sebep olabilecek sorunların yaşanmasını büyük ölçüde engelleyecektir. Bu nedenle elektrik enerjisi tüketimi kestirimleri ne kadar doğru olursa ileriye yönelik planlamalar o kadar doğru olacaktır.

Bu çalışmada, uzun dönemli Türkiye elektrik enerjisi tüketimi kestiriminde zaman serisi yöntemlerinden, “Box-Jenkins” ve “Yapay Sinir Ağları” yöntemlerinin kestirim başarılarını karşılaştırarak en yüksek başarıyı sağlayan yöntem belirlenmeye çalışılmıştır.

Bu amaçla ilk olarak yıllara göre verilmiş olan Türkiye elektrik enerjisi tüketiminin kestirimi için çeşitli zaman serisi analizleri EVIEWS 5 ve MINITAB 15 programları yardımı ile yapılmış ve uygun görülen Otoregresif Model (AR) seçilerek bu model yardımıyla kestirim yapılmıştır. İkinci olarak farklı yapay sinir ağları kullanılarak MATLAB R2008a programı yardımı ile denemeler yapılarak, uygun olan yapay sinir ağı modeli ile kestirimler yapılmıştır. Son olarak performans istatistikleri yardımı ile iki yöntem karşılaştırılmış ve uygun olan model seçilmiştir.

ANAHTAR KELİMELER: Zaman Serileri, Box-Jenkins, Yapay Sinir Ağları, Elektrik Tüketimi, Kestirim

ABSTRACT

Electrical energy cannot be stored and should be consumed after production type of energy. Storage of electrical energy is not possible under certain circumstances. Therefore, the demand for electricity should go in parallel with the supply of electricity. Consumption of electrical energy differs monthly, daily or yearly. Because of this difference, to estimate the level of demand and to meet the supply capacity for this demand is very important. Demand planning of electrical energy would prevent the occurrence of customer dissatisfaction problems. Consequently, if the estimations of electrical energy consumption is more accurate, then futuristic long term plans will be more correct.

In this study, the method that provides the highest success in the estimation of long-term electric energy consumption in Turkey is determined by comparing the “Box-Jenkins” and “Artificial Neural Networks” time series estimation methods.

To this end, first, time series analysis of the estimation of yearly electrical energy consumption of Turkey is done by the help of EVIEWS 5 and MINITAB 15 programs and selection of an appropriate Auto-Regressive (AR) model. Second, using different neural networks and making comparisons by the help of MATLAB R2008a program, estimations are done with a suitable neural network model. Lastly, a suitable model is chosen by the comparison of two models with performance statistics method.

KEYWORDS: Time Series, Box-Jenkins, Artificial Neural Networks, Electricity Consumption, Forecast

ÖNSÖZ

Bu çalışmada görüş ve önerileri ile katkıda bulunan, sabır ve anlayış gösteren, çalışma boyunca desteğini esirgemeyen değerli hocam Sayın Prof. Dr. Gülay Kiroğlu'na sonsuz şükranlarımı sunarım.

Ayrıca göstermiş olduğu desteği, önerileri ve cevapsız bırakmadığı sorularım için Sayın Dr. Barış Aşıkil'e, bilgi ve deneyimlerini paylaşan ve bütün sorularımı sabırla cevaplayan Sayın Yrd. Doç. Dr. Semra Erpolat'a, yaptığı yardımlardan dolayı Sayın Okutman Esin Yavuz ve Sayın Yrd. Doç. Dr. Övünç Polat'a, çalışmam boyunca sonsuz desteği için Sayın Göktürk Cirit'e, son olarak tüm hayatım boyunca sonsuz sevgi ve desteklerini esirgemeyen; Sayın Meral Uslu, Sayın Ayhan Uslu ve Sayın Volkan Uslu'ya teşekkürlerimi bir borç bilirim.

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
ÖNSÖZ.....	iii
İÇİNDEKİLER	iv
TABLO DİZİNİ	vi
ŞEKİL DİZİNİ	vii
1. GİRİŞ	1
2. ZAMAN SERİSİ ANALİZİ	4
2.1. GİRİŞ	4
2.2. ZAMAN SERİSİNİN BİLEŞENLERİ.....	4
2.2.1. Trend	4
2.2.2. Mevsimsel Dalgalanmalar.....	4
2.2.3. Konjonktürel Dalgalanmalar.....	5
2.2.4. Düzensiz (Rassal) Hareketler.....	5
2.3. ZAMAN SERİSİ MODELLERİ	5
2.4. DURAĞANLIK	6
2.5. BOX-JENKİNS YÖNTEMİ.....	7
2.5.1. Giriş.....	7
2.5.2. Box-Jenkins Yönteminin Adımları	9
2.5.3. Doğrusal Durağan Stokastik Modeller.....	13
2.5.4. Doğrusal Durağan Olmayan Stokastik Modeller (ARIMA) (Autoregressive Integrated Moving Average)	17
3. YAPAY SİNİR AĞLARI	20
3.1. GİRİŞ	20
3.2. YAPAY SİNİR AĞLARININ TARİHÇESİ	20
3.3. YAPAY SİNİR AĞI VE EN TEMEL GÖREVİ	22
3.4. YAPAY SİNİR AĞLARININ YAPISI VE TEMEL ELEMANLARI	23
3.4.1. Biyolojik Sinir Hücreleri.....	23
3.4.2. Yapay sinir hücresi	24
3.5. YAPAY SİNİR AĞININ YAPISI.....	27
3.5.1. İleri Beslemeli Ağlar	29

3.5.2. Geri Beslemeli Ağlar	29
3.6. YAPAY SİNİR AĞLARI EĞİTİMİ	30
3.6.1. Öğretmenli Öğrenme.....	30
3.6.2. Öğretmensiz Öğrenme	33
3.6.3. Öğrenme Kuralları	33
3.7. YAPAY SİNİR AĞLARININ ÜSTÜNLÜKLERİ VE SAKINCALARI.....	34
3.7.1.Üstünlükler.....	34
3.7.2. Sakıncalar.....	35
3.8. YAPAY SİNİR AĞLARI TASARIMI.....	36
3.8.1. Ağ Yapısı	36
3.8.2. Girdi Nöron Seçimi.....	36
3.8.3. Gizli Katman ve Nöron Sayısını Belirleme	36
3.8.4. Çıktı Nöron Sayısını Belirleme.....	37
3.8.5. Aktivasyon Fonksiyonu Belirleme.....	37
3.8.6. Veri Normalizasyonu	37
3.8.7. Yapay Sinir Ağlarının Eğitimi ve Test Edilmesi	38
3.8.8. Öğrenme Algoritmasının Seçimi	39
3.9. K-KATLI ÇAPRAZ DOĞRULAMA YÖNTEMİ VE BAŞARI ÖLÇÜMÜ	39
4. UYGULAMA.....	40
4.1. VERİLER.....	40
4.2. YÖNTEMLER.....	40
4.2.1. Zaman Serisi Analizi.....	40
4.2.2. Yapay Sinir Ağları Analizi	46
4.3. YÖNTEMLERİN KARSILAŞTIRILMASI	47
SONUÇ.....	50
KAYNAKLAR	52
EKLER.....	57

TABLO DİZİNİ

Tablo 2.1.: Durağan modeller için otokorelasyon ve kısmi otokorelasyon fonksiyonlarının teorik davranışı.....	10
Tablo 4.1.: Dickey-Fuller Test İstatistiği.....	41
Tablo 4.2.: Parametre Tahminleri.....	44
Tablo 4.3.: Test performans değerleri.....	48
Tablo 4.4.: Eğitim performans değerleri.....	49

ŞEKİL DİZİNİ

Şekil 2.1.: Alternatif modeller arasından seçim yapılabilmesi için izlenen süreç.....	8
Şekil 2.3: ARIMA Modellerini Belirlemede Kullanılan Yöntem.....	19
Şekil 3.1: Biyolojik nöron.....	23
Şekil 3.2: Yapay sinir hücresi.....	24
Şekil 3.3: Eşik fonksiyonu.....	26
Şekil 3.4: Sigmoid fonksiyonu.....	27
Şekil 3.5: Yapay sinir ağının yapısı.....	28
Şekil 3.6: İleri beslemeli ağ yapısı.....	29
Şekil 3.7: Geri beslemeli ağ yapısı.....	30
Şekil 3.8:Öğretmenli öğrenme.....	31
Şekil 4.1: Logaritması alınmış seri.....	41
Şekil 4.2.: Logaritması alınmış serinin korelogram grafiği.....	43
Şekil 4.3.: AR(1) Modelinin Kestirim Hatalarının Korelasyonları.....	45
Şekil 4.4.:YSA yapısı.....	47

1. GİRİŞ

Elektrik, maddenin elektron, pozitron, proton vb. parçacıklarının hareketleriyle ortaya çıkan enerji türüdür [3]. Elektrik, enerji dönüşümü sırasında ortaya çıkar. Kömür, petrol ve nükleer tepkilerden veya akarsuların gizli enerjisinin harekete dönüşmesi ile elektrik enerjisi elde edilir [8]. 2009 yılında Türkiye elektrik üretiminin, %48,6'sı doğal gazdan, %28,3'ü kömürden, %18,5'i hidrolikten, %3,4'ü sıvı yakıtlardan ve %1,1'i yenilenebilir kaynaklardan elde edilmiştir [4].

İnsan yaşamı ve ülkelerin kalkınmasındaki önemi doğrultusunda, ülkemiz elektrik enerjisi sektörünün de sağlıklı gelişimi için talep, arz, iletim, dağıtım, yakıt ve tarife konularında planlar yapılması ve elektrik enerjisi ile ilgili olarak tüketici memnuniyetsizliklerine sebep olabilecek sorunların yaşanmaması büyük önem taşımaktadır [1].

Elektrik piyasasında, arz ve talep arasındaki ilişkinin dengede tutulabilmesi için, elektrik üreticisi şirketlerin güvenilir, kaliteli ve ekonomik üretim yapabilmeleri gerekmektedir. Bu noktada, planlama yapmanın, planlama yapabilmek için de gelecekteki elektrik tüketim verilerinin doğru kestirilmesi gerekliliği öne çıkmaktadır. Elektrik tüketim kestirimi kısa, orta ve uzun dönem için yapılabilmektedir. Saatlik ve günlük kestirimler kısa dönem, aylık ve yıllık kestirimler ise uzun ve orta dönem kestirim olarak adlandırılmaktadır [4].

Elektrik tüketim kestirimlerinde gerek zaman serisi gerekse yapay sinir ağları oldukça sık kullanılmaktadır.

Kestirimin asıl anlamı gelecekte ne olacağını önceden belirlemektir. Meteorologlar, doktorlar, ekonomistler, pazar araştırmacıları, mühendisler, politikacılar ve anketçiler gibi birçok meslekte kestirim yapılmaktadır. Kestirim tehlikeli bir oyundur. Çünkü belirli bir kestirim sonunda gerçek ile mukayese edilebilir [5].

İstatistiksel kestirim, bağımlı değişken değerlerinin, bağlanım denkleminde kestirimidir. Eğer bir niceliğin zamanın gelecekteki bir noktasına ilişkin değerinin kestirimi yapılacaksa zaman serileri çözümlemesi söz konusu olur. İstatistiksel bir olayın zaman değişkeninin konumlarına göre aldığı değerlerin sıralanmasıyla zaman serisi elde edilir [6].

Zaman serisi gözlem değerlerinde bazı değişimler gözlenir. Bu değişimler zaman serisini etkileyen faktörler ya da bileşenler olarak ifade edilirler ve Trend Bileşeni, Mevsimsel Bileşen, Konjonktürel Bileşen ve Rassal Bileşen olarak isimlendirilirler. Zaman serileri bu bileşenler nedeniyle, çözümlenmeden bir anlam ifade etmezler. En

basit anlamda, zaman serisi çözümlemesi serinin özelliklerini açıklamaktır. Zaman serisinin en önemli amacı kestirim yapmaktır. Kestirimin amacıyla zaman serisi çözümlemesi; seriyi etkileyen bileşenlerin, belirlenmesi belirlenen bileşenlerinin etkilerinin kestirilmesi ve hesaplanan kestirimlerden yararlanılarak, serinin gelecek dönemlerine ilişkin kestirim çalışmalarını kapsar [8].

1980'li yılların sonlarından başlamak üzere zaman serilerine ilişkin kestirimler için kullanılmakta olan yöntemlerden biri de Yapay Sinir Ağları (YSA) yöntemidir. YSA, girdi ve çıktı değişkenleri arasındaki herhangi bir ön bilgiye gereksinim duymadan doğrusal ve doğrusal olmayan modellemeyi sağlayabilmektedir. Bu nedenle YSA, kestirim aracı olarak diğer yöntemlere göre daha genel ve esnektir [9].

Bu çalışmanın amacı; zaman serisi analizi ve yapay sinir ağları yöntemini karşılaştırarak en iyi sonucu verecek olan modelle Türkiye uzun dönemli elektrik enerjisi tüketimini kestirmektir. Bu kestirim sonucunda elde edilecek veriler sayesinde, elektrik talebini karşılayabilecek seviyede kapasite belirlenebilir ve planlama çalışmaları bu veriler yardımıyla yürütülebilir.

Çalışma, beş bölümden oluşmaktadır. İlk bölüm giriş bölümüdür. İkinci bölümde, zaman serisi analizi konusu işlenmiştir. Bu bölümde zaman serisi ve analizi hakkında bilgiler verilmiş, sonrasında zaman serisinin bileşenleri, durağanlık incelenmiştir. Son olarak Box-Jenkins yöntemi ele alınmıştır.

Üçüncü bölümde, yapay sinir ağları hakkında bilgi verilmiştir. Burada yapay sinir ağları tanımlanmış ve yapay sinir ağlarının temel yapısı, görevi ve elemanları ifade edilmiştir. Sonrasında yapay sinir ağlarının tarihçesi verilmiş ve üstünlükleri ve sakıncaları incelenmiştir. Yapay sinir ağlarının yapısı ileri ve geri beslemeli ağlar olarak incelenmiştir. Yapay sinir ağları eğitimi konusunda öğrenme şekilleri ve öğrenme kuralları ele alınmıştır. Yapay sinir ağları tasarımı, k-katlı çapraz doğrulama yöntemi ve başarı ölçümü incelenmiştir.

Dördüncü bölüm uygulama bölümüdür. Uygulamada kullanılacak veriler TEDAŞ web sitesinden temin edilmiştir. Türkiye elektrik enerjisi tüketiminin analizi için ilk olarak zaman serisi analizi EVIEWS 5 ve MINITAB 15 paket programları kullanılarak yapılmış ve uygun görülen Otoresif Model (AR) seçilerek bu model yardımıyla kestirim yapılmıştır. Sonrasında MATLAB R2008a programı yardımı ile yapay sinir ağları kullanılarak en uygun model belirlenmiştir. Son olarak zaman serisi analizi yöntemlerinden Otoresif Model (AR) ve yapay sinir ağları yöntemlerinde ileri beslemeli geri yayılım ağlarının üretmiş olduğu değerler performans istatistikleri yardımı ile karşılaştırılmış.

Son bölümde ise uygulama kısmında elde edilen sonuçlar yorumlanmış ve daha sonraki çalışmalar için önerilerde bulunulmuştur.

2. ZAMAN SERİSİ ANALİZİ

2.1. Giriş

Bir zaman dizisi, özel zamanlarda, çoğunlukla eşit zaman aralıklarında alınan gözlemler kümesidir.

Matematiksel olarak bir zaman dizisi, bir Y değişkeninin $t_1, t_2, \dots$ anlarında $Y_1, Y_2, \dots$ değerleriyle tanımlanır [10].

Her bilim dalı kendi alanında belli bir zaman periyodundaki sayısal değişimleri görmek isteyebilir. Burada iki değişkenin varlığı söz konusudur. Bağımsız değişken daima zaman birimidir. Zaman birimi, gün, hafta, ay, yıl vs. olabilmektedir. Bağımlı değişken olarak satış miktarları, çalışma süreleri, faiz miktarları, milli gelir, milli hasıla gibi değişkenler olabileceği gibi bunların dışındaki olaylarda olabilir [16].

2.2. Zaman Serisinin Bileşenleri

Zaman serilerinin analizi, bu serilerin unsurlarının çeşitli yöntemlerle ayırt edilmesi demektir. Seri, zamanın ve zamana bağlı olarak değişen çeşitli sosyo ekonomik değişkenlerin etkilerini taşır. Bir zaman serisinde, aşağıdaki 4 unsurdan birkaçı veya hepsi aynı anda etkili olur [11].

1. Trend
2. Mevsimsel dalgalanmalar (Seasonal variation)
3. Konjonktürel dalgalanmalar (Cyclical variation)
4. Düzensiz (Rassal) hareketler (Irregular variation)

2.2.1. Trend

Zaman serisinin uzun bir dönemde belli bir yöne doğru gösterdiği ana eğilime uzun devre eğilimi veya trend adı verilir.

Trendin yön ve şiddet açısından aynı kaldığı söylenemez. Bağlı olduğu faktörlerin şiddet derecesindeki değişimlere göre trenddeki artış azalış bazen yavaşlayabilir. Yani trend doğrusal olabileceği gibi eğriselde olabilir. Ancak trendin önemli bir özelliği her iki durumda istikrarlı oluşudur [12].

2.2.2. Mevsimsel Dalgalanmalar

Zaman serileri yıllık değil de, haftalık, aylık, üç aylık gibi yıl içindeki zaman birimlerine göre düzenlenmişlerse, bu durumda mevsim hareketleri denen kısa dönem hareketlerinin olup olmadığı araştırılır. Bu hareketler varsa, bunlar incelenir

ve gerektiğinde mevsim katsayıları hesaplanarak hem bazı öngörüler için kullanılırlar, hem de bunlar yardımıyla seri mevsim etkisinde arındırılarak, öteki hareketler incelenir.

Mevsim hareketlerinin olup olmadığını anlamak için, grafiklere başvurmak uygun bir yol olabilir. her yıla ilişkin grafikler karşılaştırılarak, her yılın aynı anlarında ya da üç aylarında benzer hareketlerin olup olmadığı anlaşılabilir [13].

2.2.3. Konjonktürel Dalgalanmalar

Konjonktürel hareketler tekrarlanan hareketlerdir. Bu hareketlerin süresi birbirini izleyen en düşük ya da en yüksek iki nokta arasındaki süredir. Konjonktürel hareketler bir yıldan uzun, fakat değişik sürelerde olabilir. Konjonktürel hareketler bütün ekonomik faaliyetleri değişik şiddette fakat aynı yönde etkiler. Tarım ürünlerinde fiyatların artmasının ardından üretimin artması, üretim arttığında fiyatların düşmesi, fiyatlar düştüğünde çiftçinin ekonomik zorluklarla karşılaşması gibi olaylar Konjonktürel hareketlerin sık rastlanan örnekleridir [14].

2.2.4. Düzensiz (Rassal) Hareketler

Düzensiz hareketler doğal, ekonomik veya siyasi nedenlerle ortaya çıkabilirler. Deprem, kuraklık, savaş, siyasi istikrarsızlık, grev gibi sebepler düzensiz hareketlere neden olmaktadır. Bu tür olayların ne zaman olacakları belli olmadığından düzensiz hareketlerdir ve önceden tahmin edilemezler. Düzensiz hareketlerin ne zaman ortaya çıkacakları belli olmadığı gibi, şiddetleri de farklı olacak ve etkileri şiddetlerine bağlı olarak artacaktır [15].

2.3. Zaman Serisi Modelleri

Bir zaman serisinin terimleri trendin ve konjonktürün, mevsimsel ve rassal dalgalanmaların ortak sonucu gibidir. Bunlar bir zaman serisinin dört ögesidir. Bir zaman serisinin analizi, ister bir tek ögenin başlı başına incelenmesi için, ister bir veya daha fazla zaman serisinden çıkarılması için yapılsın, serinin ayrıştırılmasını gerektirir. Bir seriyi ayrıştırabilmek için dört ögesi arasında bir ilişki olduğu varsayılacaktır. Genellikle bir zaman serisinin bazı toplamsal veya çarpımsal ögelerden meydana geldiği varsayılır.

Toplamsal model asıl verilerin değerinin dört ögenin toplamı olduğunu varsayar.

Y = Zaman serisinin asıl değeri,

T = Trend,

K = Konjonktürün değeri,

M= Mevsimsel ögenin değeri,

D= Rassal ögenin değeri,

Toplamsal model (2.1) nolu eşitlikteki gibi gösterilir:

$$Y=T+K+M+D \quad (2.1)$$

Çarpımsal model asıl verilerin değerinin dört öge değerlerinin çarpımı olduğunu varsayar. Toplamsal model (2.2) nolu eşitlikteki gibi gösterilir:

$$Y=T \times K \times M \times D \quad (2.2)$$

Toplamsal model dört ögenin birbirinden bağımsız olduğunu varsayar. Her bir öge, dört bağımsız etki kaynağının sonucu olarak düşünülür. Bunun içinde trendin değeri ne olursa olsun, mevsimsel ve konjonktür hareketlerin etkilenmediği kabul edilir.

Çarpımsal model dört ögenin farklı nedenlerden kaynaklandığını, ancak birbiriyle ilişkili olduklarını varsayar. Bu varsayıma göre ögelere ayırma, bölme işlemleriyle sağlanır [6].

2.4. Durağanlık

Stokastik bir süreç izleyen zaman serilerinde, serinin durağan olup olmadığı çok önem kazanmaktadır. Stokastik veya rasgele bir değişkenin zaman içinde ortalaması, varyansı ve otokovaryansının sabit olması şeklinde ifade edebileceğimiz durağanlık kavramı, serinin değerlerinin belirli bir değere yaklaşmasını ya da beklenen değer etrafında dalgalandığını ifade eder.

Zaman serileri alanında yapılan çalışmaların büyük bir çoğunluğu belirsiz ve bilinmeyen gelecek hakkında doğru kestirimler yapmaya yöneliktir. Eğer bir stokastik süreç durağan değilse, serinin davranışı sadece ele alınan tahmin dönemi için geçerli olacaktır. Zaman serileri alanında yapılan çalışmalarda amaç, güvenilir parametre tahmini yerine, geleceğe yönelik öngörülerde bulunmak ve tahmin dönemi dışında da değişkenin genel tavrını ya da eğilimini yakalayabilmektir. O halde durağanlık koşulları (2.3), (2.4) ve (2.5) nolu eşitlikteki gibidir.

$$E(Y_t) = \mu \quad (2.3)$$

$$\text{Var}(Y_t) = E(Y_t - \mu)^2 = \sigma^2 \quad (2.4)$$

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

Tüm gecikmeler için ortalama, varyans ve kovaryans değerlerinin sabit olmasıdır. Literatürde bu yöndeki durağanlığa zayıf (weakly stationary), ikinci mertebeden durağanlık denmektedir. Bu yöndeki durağanlıkta, serinin ortalaması zamandan bağımsızdır, zaman içinde sabittir. Varyansı ise sonlu bir sayı ile ifade edilir ve zaman içinde sistematik olarak değişmediği kabul edilir. güçlü durağanlık (strongly stationary) ise değişkenin koşullu olasılık dağılımı zaman içinde değişmediği bir süreci gösterir [22].

2.5. BOX-JENKINS YÖNTEMİ

2.5.1. Giriş

Zaman serisi modeli kurmada Box-Jenkins (1976) yaklaşımı gerçekleşen verilere en uygun ARIMA (Doğrusal Durağan Olmayan Stokastik Model) (Autoregressive Integrated Moving Average) veri üretme süreci bulma yöntemidir. 1970’li yıllarda George Box ve Gwilym Jenkins tarafından popüler hale getirilen ve zaman serisi analizleri ile ön raporlamada uygulanan genel modelleri ile onların isimleri eş anlamlı kullanılır olmuştur. Box ve Jenkins tek değişkenli zaman serisi ARIMA modellerinin anlaşılması ve kullanılması için gerekli ilgili bilgileri anlaşılır bir biçimde bir araya getirerek ortaya koymuşlardır [20].


Box-Jenkins yöntemi durağan olmayıp fark alma işlemi sonucu durağanlaştırılan serilere uygulanan ARIMA modellerini kapsamaktadır. Bu modellemenin temelleri 1927 yılında Yule tarafından atılmıştır. İncelenen zaman serisi durağan olması sonucunda ARIMA modeli AR (Oto regresif Modeller) (Autoregressive Model), MA (Hareketli Ortalama) (Moving Average Model) modelleri ya da ARMA (Oto regresif Hareketli Ortalama) (Autoregressive Moving Average) modeli olacaktır. Box-Jenkins yönteminin temeli tutumluluk (parsimony) ilkesine dayanmaktadır. Burada amaçlanan en az sayıda parametre içeren uygun modelin elde edilmesidir. Bir zaman serisi incelendiğinde tamamı ile AR (p) süreci mi yoksa MA (q) sürecimi yahut ARMA (p,q) ya da ARIMA (p,d,q) süreci mi sorusunu yanıtlamada Box-Jenkins yöntemi kullanılmaktadır.

Bu yöntemde birden fazla deneysel model belirlenmekte olup içlerinden uygun olan model seçilmektedir. Uygun modelin denemelere bağlı olarak belirlenmesi bu yöntemin en büyük sakıncası olmaktadır.

Modelin öngörü amaçlı kullanımı için yeterli iyi bir model olması gerekmektedir. Modelin yeterliliği için ortaya koyulan koşullar aşağıda belirtilmektedir.

- Sürece ait daha küçük toplam hata kareye sahip parametre tahmini olmaması durumunda durdurulması gerekmektedir.
- Parametrelerin çevrilebilirlik ve/veya durağanlık koşulları sağlanması gerekmektedir.
- Hata terimleri rassal olmalı ve yaklaşık olarak normal dağılmaları gerekmektedir.
- Tüm parametre tahminleri, istatistiksel olarak sıfırdan farklı olmalıdır.
- Model cimrilik prensibine uygun olarak en basit biçimde oluşturulmalıdır.
- Model en küçük kök ortalama hata kareye sahip olmalıdır.

Alternatif modeller arasından seçim yapılabilmesi için izlenen süreç bu modellemenin aşamalarını oluşturmaktadır.(Şekil 2.1.)



Şekil 2.1.: Alternatif modeller arasından seçim yapılabilmesi için izlenen süreç

2.5.2. Box-Jenkins Yönteminin Adımları

Box-Jenkins yöntemi dört adımdan oluşmaktadır. Bunlar belirleme (identification), parametre kestirimi (estimation), uygunluk testleri (diagnostic checking) ve kestirim (forecasting) olarak sıralanabilir [17].

2.5.2.1. Belirleme

Bu aşamada genel modellerden uygun olanlar belirlenmektedir. Model belirleme aşaması aşağıda belirtilmektedir.

1. Verilerin matematiksel karakteristiğini görmek için zaman serisi grafiği çizilir. Bu grafik ile serinin trende, uç değerlere, sabit olmayan varyansa, mevsimselliğe ve diğer normal olmayan ve durağan olmayan olgulara sahip olup olmadığını tespit edebiliriz. Varyansın sabitliğini sağlamak için dönüştürme işlemi varyans sabit olana dek devam edilir [21].

2. ACF'ler (otokorelasyon fonksiyonu) ve PACF'ler (kısmi otokorelasyon fonksiyonu) hesaplanır. Otokorelasyon fonksiyonu (ACF) bize, herhangi bir serideki komşu veri noktalar arasında ne kadar korelasyon olduğunu gösterir. Otokorelasyon fonksiyonu, bir zaman serisinde iki nokta arasındaki ilişkiyi araştırmakta yararlı bir ölçüdür. Ancak bazen bu iki nokta arasında ilişki araştırılırken bu noktalar arasında kalan gözlemlerin etkisinin arındırılması zaman serisi hakkında daha fazla bilgi edinmemizi sağlar. Bu şekilde hesaplanan ilişki iki nokta arasındaki kısmi otokorelasyondur (PACF). Eğer otokorelasyonlar hızlı bir biçimde düşmüyorsa veya ortadan kaybolmuyorsa seri durağan dışıdır [52]. Bu durumda durağanlık sağlanana dek bir veya iki kere verilerin farkı alınır. Daha sonra farkı alınan seriler için ARMA modeli belirlenir.

3. Durağanlığa ulaşıldığında belirli bir kalıp görünüyorsa otokorelasyonlar incelenir. Bu durumda

a. Bir MA(q) sürecine ilişkin otokorelasyonlar $k > q$ için $\rho_k = 0$ 'dır veya gecikme q'dan sonra anlamlı otokorelasyonlar yoktur. Kısmi otokorelasyonlar bir süre daha anlamlı olmaya devam ederler. Otokorelasyon fonksiyonunun kesilme noktasını belirlemek için örneklem otokorelasyonları $\pm 2/\sqrt{T}$ ile karşılaştırılır.

b. Bir AR(p) sürecine ilişkin kısmi otokorelasyonlar $k > p$ için $\phi_{kk} = 0$ 'dır. Gecikme p'den sonra anlamlı kısmi otokorelasyonlar yoktur. Otokorelasyonlar bir

süre daha anlamlı olmaya devam eder. Kısmi otokorelasyon fonksiyonunun kesilme noktasını belirlemek için $\pm 2/\sqrt{T}$ ile karşılaştırılır.

c. ne otokorelasyonlar ne de kısmi otokorelasyonlar belirli bir noktada kesilmiyorsa bu durumda ARMA modeli uygun olacaktır. AR ve MA bileşenlerinin derecesi otokorelasyon ve kısmi otokorelasyon kalıplarından çıkarılabilir.

Durağan modeller için otokorelasyon ve kısmi otokorelasyon fonksiyonlarının teorik davranışı Tablo 2.1’de gösterilmektedir [20].

Tablo 2.1: Durağan modeller için otokorelasyon ve kısmi otokorelasyon fonksiyonlarının teorik davranışı

Model	Otokorelasyon Fonksiyonu	Kısmi Otokorelasyon Fonksiyonu
AR(p)	Azalarak kaybolur.*	q gecikme sonra kesilir.
MA(q)	p gecikme sonra kesilir.	Azalarak kaybolur.
ARMA(p,q)	Azalarak kaybolur ve p gecikme sonra kesilir.	Azalarak kaybolur ve q gecikme sonra kesilir.

*Azalma (yaklaşık olarak) üstel (geometrik) veya bir sinüs dalgası şeklinde olabilir.

2.5.2.2. Parametre Kestirimi

Uygun model belirlendikten sonra sıra modelin otoregresif ve hareketli ortalama terimlerinin tahmin edilmesine gelmektedir. Bu hesaplamalarda bazen en küçük kareler yöntemi bazen de doğrusal olmayan çözüm yöntemleri kullanılmaktadır.

Eğer süreç AR(p) ise parametreler en küçük kareler yöntemi ile tahmin edilmektedir. MA(q) da ise en çok benzerlik ve en küçük kareler yöntemine başvurulmaktadır. Bazı durumlarda ise her süreç aynı anda modelde ise doğrusal olmayan çözüm yöntemlerini kullanmak gerekebilmektedir.

Bu aşamada dikkat edilmesi gereken bazı önemli noktalar vardır. Bunlar:

- Tahmin edilen tüm AR ve MA parametrelerinin durağanlık sınırı içinde olması gerekmektedir. Bu durum sağlanamadığında ise incelenen model reddedilip yeni bir model belirlenmelidir.

- Tahmin edilen parametrelerin istatistiksel açıdan anlamlı olmaları gerekmektedir. Parametrelerin anlamlılığı t-testi kullanılarak test edilmekte olup anlamsız parametreler modelden çıkarılarak model yeniden tahmin edilmelidir.

Modelin tüm katsayılarının anlamlı olduğunu tespit ettiğimizde bu modelin uygunluğuna hemen karar verilemez. Model parametrelerinin nokta tahminleri de durağanlık koşulunu sağlamalıdır [19].

2.5.2.3. Uygunluk Testleri

Geçici uygun modelin seri için uygun olup olmadığı, uygunluk testi ile belirlenir. Uygunluk testi için önce geçici uygun modelde parametre değerleri yerine konularak tahmin yapılır. Daha sonra tahmin hatalarının otokorelasyon katsayıları incelenerek modelin uygun model olup olmadığına karar verilir. Özellikle bu amaçla Box-Pierce Q istatistiği kullanılır.

Box- Pierce tarafından geliştirilen Q istatistiği (2.6) nolu eşitlikteki gibi hesaplanır;

$$Q = n \sum r_k^2(a) \quad (2.6)$$

$k=1,2,3,\dots,m'$ dir.

$r_k(a)$: örneklem içi tahmin hatalarının çeşitli gecikmelerdeki otokorelasyonları

n : örneklem hata büyüklüğü

Hesaplanan Q istatistikleri $(m-p-q)$ serbestlik derecesi ile χ^2 dağılımına uygunluk göstermektedir.

Eğer Q istatistiğinden elde edilen p-değeri 0,05 değerinden küçükse model uygun değildir. Yeni veya düzeltilmiş bir model kurularak testlere devam edilmesi gerekir.

Uygunluk testi sonunda yeterli olduğuna karar verilen model tahmin amacıyla kullanılır.

2.5.2.4. Kestirim

Bir zaman serisi modeli belirlenip, tahmini yapıp, uygunluk testlerinden geçtikten sonra bu model öngörü amacıyla kullanılabilir. Burada başlıca amacımız gelecek

değere yakın öngörü değerleri elde etmektir. Bu amacı gerçekleştirmenin bir yolu gerçek ve öngörülen değerler arasında ortalama hata kareyi minimum yapmaktır.

Çeşitli tahmin modelleri arasında birini seçme sürecinde yaygın kabul gören kriterlerden biri de modelin verilere uyum göstermesi, modelin öngörü başarısının yüksek olmasıdır. Bu bağlamda modellerin öngörü başarılarının karşılaştırılması amacı ile çeşitli kriterler kullanılmaktadır. Bunlar arasında en fazla kullanılanlar aşağıda açıklanacaktır [19].

Ortalama Hata Kare (Mean Squared Error – MSE);

$$OHK = \frac{\sum(Y^T - Y^G)^2}{t-k} \quad (2.7)$$

Kök Ortalama Kare Hata (Root Mean Squared Error - RMSE);

$$KOKH = \sqrt{\frac{\sum(Y^T - Y^G)^2}{t-k}} \quad (2.8)$$

Ortalama Mutlak Hata (Mean AbsoluteError - MAE);

$$OMK = \frac{\sum|Y^T - Y^G|}{t-k} \quad (2.9)$$

Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error - MAPE);

$$OMYH = \sum \left| \frac{Y^T - Y^G}{Y^G} \right| \cdot \frac{100}{t} \quad (2.10)$$

Ortalama Yüzde Hata (Mean Percentage Error – MPE);

$$OYH = \frac{1}{t-k} \sum \left(\frac{Y^T - Y^G}{Y^G} \right) \quad (2.11)$$

Kök Ortalama Yüzde Hata Kare (mean Squared Percentage Error-MSPE);

$$KOYHK = \sqrt{\frac{1}{t-k} \cdot \sum \left(\frac{Y^T - Y^G}{Y^G} \right)^2} \quad (2.12)$$

t: Durağan hale getirilen serinin gözlem sayısı

k: Modelde tahmin edilen parametre sayısı

Y^T : Modelin tahmin değeri

Y^G : Serinin gerçek deęerleri

Deęerleri minimum ve en az parametreye sahip olan model başarılı olarak seçilmektedir.

2.5.3. Doğrusal Duraęan Stokastik Modeller

Uygulamada duraęan zaman serilerinin modellenmesinde kullanılan B.J. yönteminin önemli doğrusal duraęan stokastik tahmin modelleri, otoregresif (AR), hareketli ortalama (MA) ve otoregresif hareketli ortalama (ARMA) modelleridir.

2.5.3.1. Otoresif Modeller (AR)(Autoregressive Model)

AR modeller bir zaman serisinin herhangi bir dönemdeki gözlem deęerini, aynı serinin ondan önceki belirli sayıda dönemin gözlem deęerinin ve hata teriminin doğrusal bir bileşimi olarak ifade eden modellerdir. AR modelleri içerdikleri geçmiş dönem gözlem deęeri sayısına göre isimlendirilirler. Yani bir AR deęeri bir tane geçmiş dönem gözlem deęeri içeriyorsa “birinci dereceden”, iki tane geçmiş dönem gözlem deęeri içeriyorsa “ikinci dereceden” ve genel olarak p tane geçmiş dönem gözlem deęeri içeriyorsa p’inci dereceden AR modeli olarak isimlendirilir.

Bir zaman serisinin gözlem deęerleri kümesi Y_t verildiğinde ve hata terimleri kümesi $\{a_t\}$ ’nin ortalaması sıfır varyansı σ_a^2 olan rassal bir deęişken olduęu varsayımı altında, bu zaman serisinin herhangi bir t dönemine ait Y_t gözlem deęeri, $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$ gibi p sayıda geçmiş dönem gözlem deęeri ve a_t hata terimi tarafından açıklanıyorsa veya sözü edilen sayıdaki geçmiş dönem gözlem deęeri ile a_t ’nin doğrusal bileşimi olarak ifade ediliyorsa, bu model p’inci dereceden AR modelidir ve kısaltılarak AR (p) şeklinde gösterilir. AR (p) modelinin genel ifadesi şöyledir:

$$y_t = \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \dots + \varphi_p y_{t-p} + a_t \quad (2.13)$$

Burada $y_{t-1}, y_{t-2}, \dots, y_{t-p}$ küçültülmüş gözlem deęeridir. Bu deęerler her gözlem deęerinin μ ’den farkı alınarak elde edilir. $\varphi_1, \varphi_2, \dots, \varphi_p$ modelin parametreleridir. Bu parametrelere t dönemine ait gözlem deęeri y_t ile geçmiş dönem gözlem deęerleri

$y_{t-1}, y_{t-2}, \dots, y_{t-p}$ arasındaki ilişkiyi gösteren “ilişki katsayılarıdır”. p modelin derecesini ve a_t bağımsız bir süreç oluşturan, normal dağılmış hata değişkenidir [18].

2.5.3.2. Hareketli Ortalama (MA) Modelleri (Moving Average Model)

Bir değişkenin t dönemdeki değeri aynı dönemdeki hata terimi (ε_t) ve hata teriminin önceki dönemlere ait gecikmeli değerleri ile belirleniyor ise bu sürece hareketli ortalama süreci adı verilmektedir. 1. mertebeden hareketli ortalama süreci:

$$Y_t = \mu + \varepsilon_t + \beta_1 \varepsilon_{t-1} \quad (2.14)$$

şeklinde gösterilmektedir. ε_t hata terimi sıfır ortalama ve sabit varyansa sahip bulunmaktadır (ak gürültü). q . mertebeden hareketli ortalama süreci MA(q):

$$Y_t = \mu + \varepsilon_t + \beta_1 \varepsilon_{t-1} + \dots + \beta_q \varepsilon_{t-q} \quad (2.15)$$

olarak ifade edilmektedir. Bir hareketli ortalama süreci, sıfır ortalama ve sabit varyansa sahip hata terimlerinin doğrusal bir bileşenidir. MA(q) süreci $\mu = 0$ olması varsayımıyla gecikme işlemcisi (L) kullanılarak yeniden yazılırsa:

$$Y_t = (1 + \beta_1 L + \beta_2 L^2 + \dots + \beta_q L^q) \varepsilon_t \quad (2.16)$$

şeklinde bir polinomla gösterilmektedir.

$$\Theta(L) = 1 + \beta_1 L + \beta_2 L^2 + \dots + \beta_q L^q \quad (2.17)$$

$$Y_t = \Theta(L) \varepsilon_t \quad (2.18)$$

biçiminde MA(q) sürecini elde ederiz.

Bir hareketli ortalama süreci MA(q), q tane durağan, sıfır ortalama ve sabit varyansa sahip hatta terimlerinin bir ortalaması olduğu için her hareketli ortalama durağan olmaktadır. Bu süreçle ilgili en önemli özelliklerden biri tersine çevrilebilirliktir.

Gecikme işlemcisi L kullanılarak yazılan 1. mertebeden hareketli ortalama süreci MA(1);

$$Y_t = (1 + \beta L)\varepsilon_t \quad (2.19)$$

$$\varepsilon_t = Y_t/(1 + \beta L) \quad (2.20)$$

dir. MA(1) modelinin tersine çevrilebilmesi için $|\beta| < 1$ olması gerekmektedir. Genellikle q. mertebeden bir hareketli ortalama sürecini ifade eden polinomun kökleri mutlak değerdeki kökten büyükse MA(q) tersine çevirebilir.

Tersine çevrilebilirlik koşulu sayesinde MA(q) süreci, AR(∞) şeklinde ifade edilebilmektedir [19].

2.5.3.3. Otoregresif Hareketli Ortalama (ARMA) Modelleri (Autoregressive Moving Average)

Ampirik çalışmalarda bir araştırmacının karşı karşıya kaldığı durumlardan birisi veri üretme sürecinin görüntüsünü teşhis etmek ve daha sonra zaman serisi verilerinin bir gerçekleştirmelerinin kullanarak karşı gelen istatistiksel modeli tanımlamaktır.

AR ve MA süreçlerinin belirli bazı özelliklere sahip oldukları otokorelasyon ve kısmi otokorelasyon fonksiyonları ρ_k 'nın bulunmasıyla görülebilir. Örneğin, MA(q) sürecinin derecesi hesaplanan otokorelasyon katsayısının kesildiği gecikme dönemi ile belirlenebilir.

Bununla birlikte bir model için hesaplanan otokorelasyonlar, ρ_k 'lar daha ileri gecikmelerde sıfıra doğru bir azalma gösterir fakat kısmi otokorelasyonların hesaplanmasında çok kısa süreli gecikmelerde kesilme söz konusu oluyorsa otoregresif sürecin daha baskın olduğu söylenebilir. Zaman serisi verileri için hem otokorelasyon hem de kısmi otokorelasyon fonksiyonları belirli bir gecikmede kesilmediği gibi sıfıra doğru çok yavaş hareket edebilirler. Bu durumlarda zaman serisi hem otoregresif hem de hareketli ortalama bileşenlerini aynı anda içerebilir ve zaman serisi modelinde bu iki durum birlikte ortaya çıkabilir.

Birçok durağan rassal süreç pür otoregresif veya pür hareketli ortalama süreci ile modellenemez. Bazen zaman serisi her iki süreçte birlikte gösterebilir. Başka bir ifade ile zaman serisi modeli hem AR hem de MA bileşenleri p ve q'uncu dereceden olmak üzere ARMA(p,q) olarak tanımlanabilir. İstatistiksel modelin cebirsel gösterimi (2.21) nolu eşitlikteki gibidir.

$$Y_t = \delta + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \quad (2.21)$$

olarak sunulabilir. Burada kesme terimi δ , Y_t 'nin ortalaması ile ilgili iken hatalar ε_t , $E(\varepsilon_t)=0$ ve varyans $\text{Var}(\varepsilon_t)=\sigma_\varepsilon^2$ ile korelasyonsuz rassal değişkenler olduğu varsayılır. Eğer bu süreç durağan ise tüm dönemler için sabit bir ortalamaya μ sahiptir. Eşitlik (2.21)'in beklenen değeri alındığında

$$E(Y_t) = E(\delta + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}) \quad (2.22)$$

$$\mu = \delta + \phi_1 \mu + \dots + \phi_p \mu + 0 + \theta_1 0 + \dots + \theta_q 0$$

$$\mu = \delta + \phi_1 \mu + \dots + \phi_p \mu$$

yazılabilir. Burada $E(Y_t) = E(Y_{t-1}) = E(Y_{t-2}) = \dots = E(Y_{t-p}) = \mu$ ve $E(\varepsilon_t) = E(\varepsilon_{t-1}) = E(\varepsilon_{t-2}) = \dots = E(\varepsilon_{t-q}) = 0$ özellikleri kullanılmıştır. Gerekli düzenlemeler yapılırsa ortalama

$$\mu = \frac{\delta}{1 - \phi_1 - \dots - \phi_p} \quad (2.23)$$

Eşitlik (2.23) elde edilir. Bu sonuç aynı zamanda durağanlık için gerekli koşuluda belirtir. Yani,

$$\phi_1 + \phi_2 + \dots + \phi_p < 1 \quad (2.24)$$

olmalıdır.

Daha yüksek dereceden süreçler için; yani genel ARMA(p,q) sürecinin varyans, kovaryans ve otokorelasyon fonksiyonu fark denklemlerine göre çözülür. Bununla birlikte ARMA(p,q) sürecinin kovaryansı (Eşitlik (2.25))

$$\gamma_k = \phi_1\gamma_{k-1} + \phi_2\gamma_{k-2} + \dots + \phi_p\gamma_{k-p} \quad k \geq q+1 \quad (2.25)$$

ve otokorelasyon fonksiyonu (Eşitlik (2.26))

$$\rho_k = \phi_1\rho_{k-1} + \phi_2\rho_{k-2} + \dots + \phi_p\rho_{k-p} \quad k \geq q+1 \quad (2.26)$$

ile verilebilir. Dikkat edilirse q süreci hareketli ortalama kısmının belleğidir. Şöyle ki $k \geq q+1$ için otokorelasyon fonksiyonu (ve kovaryansları) pür otoregresif sürecin özelliklerini sergiler [20].

2.5.4. Doğrusal Durağan Olmayan Stokastik Modeller (ARIMA) (Autoregressive Integrated Moving Average)

Uygulamada karşılaşılan serilerin çoğu, özellikle ekonomik zaman serileri durağan değildir. Bu serilerin durağanlığı trend, mevsimsel ve konjonktürel dalgalanmalar ve tesadüfi sebepler gibi etkenler tarafından bozulur. Bu etkenlere rağmen zaman serilerinin çoğunda yine homojenlik görülmektedir. Başka bir ifade ile serinin farklı kısımları benzer eğilim gösterebilir. Homojen durağan olmayan zaman serilerinin modellenmesi, serinin durağanlığın sağlanmasına bağlıdır. Durağanlığın sağlanması için söz konusu etkenlerin önce belirlenmesi sonra da yok edilmesi, kısaca durağan olmayan bir zaman serisinin durağan hale dönüştürülmesi gerekir.

Bir zaman serisinin gözlem değerleri bu serinin ortalama değeri etrafında durağan değilse, serinin uygun derecede farkları alınarak durağanlık sağlanır. Fark alma derecesi d ile simgelenir.

Durağan olmayan ancak fark alma işlemiyle durağan hale dönüştürülmüş serilere uygulanan modellere entegre modeller veya “durağan olmayan doğrusal stokastik modeller” adı verilir.

Durağan olmayan doğrusal stokastik modeller, belirli sayıda fark alınmış olan serilere uygulanan AR ve MA modellerinin bir kombinasyonu olan modellerdir. Eğer otokorelasyon parametresi olan $\varphi(B)$ ’nin derecesi p , hareketli ortalama parametresi $\theta(B)$ ’nin derece q ise ve d kez fark alma işlemi yapılmışsa, bu modele (p,d,q) dereceden otoregresif entegre hareketli ortalama modeli adı verilir ve ARIMA(p,d,q) şeklinde yazılır [18].

Genel ARIMA(p,d,q) modelinin ifadesi şöyledir:

$$w_t = \varphi_1 w_{t-1} + \varphi_2 w_{t-2} + \dots + \varphi_p w_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.27)$$


Bu (2.21) nolu eşitlikte y_t ’nin yerine bunların farkı olan $\Delta^d y_t = w_t$ ikame edilerek elde edilmiştir. Burada;

Δ = fark alma operatörü

d = fark alma derecesi

w_t = farkı alınmış seridir.

Zaman serisine en uygun ARIMA modelinin seçimi Şekil 2.3’te verildiği gibi sistematik olarak yapılmıştır. İlk olarak, zaman serisinin otokorelasyon ve kısmi otokorelasyon fonksiyonlarının değerleri hesaplanır ve bu fonksiyonların değerlerine göre ARIMA model parametreleri olan “ p ”, “ d ”, ve “ q ” Tablo 2.1 ile belirlenir. Fark faktörü “ d ” ise meyil analizi sonucu tespit edilip, zaman serisini sabit yapabilmek için uygulanacak eğrinin derecesine karşılık gelir. Tablo 2.1 sabit zaman serileri için AR(p) ve MA(q) modellerinin ve parametrelerin belirlenmesinde kullanılan kriterleri göstermektedir [24].



řekil 2.3: ARIMA Modellerini Belirlemede Kullanılan Yntem řeması [24].

3. YAPAY SİNİR AĞLARI

3.1. Giriş

Yapay sinir ağı kavramı beynin çalışma ilkelerinin sayısal bilgisayarlar üzerinde taklit edilmesi fikri ile ortaya çıkmış ve ilk çalışmalar beyni oluşturan biyolojik hücrelerin, ya da literatürdeki ismiyle nöronların matematiksel olarak modellenmesi üzerinde yoğunlaşmıştır. Bu çalışmaların ortaya çıkardığı bulgular, her bir nöronun komşu nöronlardan bazı bilgiler aldığı ve bu bilgilerin biyolojik nöron dinamiğinin öngördüğü biçimde bir çıktıya dönüştürüldüğü şeklinde idi. Bugün Yapay sinir ağı olarak isimlendirilen alan, birçok nöronun belirli biçimlerde bir araya getirilip bir işlevin gerçekleşmesi üzerindeki yapısal olduğu kadar matematiksel ve felsefi sorunlara yanıt arayan bir bilim dalı olmuştur. İnsan beyninin çalışma mekanizmasını taklit etmeye çalışan bu sistemler, her ne kadar günümüz teknolojisinin ürettiği, birim işlem zamanı nanosaniyeler mertebesinde olan silikon lojik kapılar ile gerçekleştirilebilirler de insan beyninin birim işlem zamanı milisaniyeler mertebesindeki nöronların toplu biçimde ele alındıklarındaki işlevselliklerinden çok uzakta kalırlar. Yapay sinir ağı, karar hızı açısından insan beyni ile yarışabilecek aşamayı henüz katedememiş almalarına rağmen, karmaşık eşleştirmelerin hassas bir biçimde gerçekleştirilmesi ve yapısal gürbüzlüğe sahip olmaları nedeniyle ki gün geçtikçe uygulama alanları genişlemektedir [25].

3.2. Yapay Sinir Ağlarının Tarihçesi

İnsan beyni hakkındaki çalışmalar binlerce yıl öncesine dayanır. Modern elektroniğin gelişmesi ile birlikte, bu düşünce işlemini kullanmaya çalışmak doğal bir hale gelmiştir. İlk yapay sinir ağı modeli 1943 yılında, bir sinir hekimi olan Warren McCulloch ile matematikçi Walter Pitts tarafından gerçekleştirilmiştir. McCulloch ve Pitts, insan beyninin hesaplama yeteneğinden esinlenerek, elektrik devreleriyle basit bir sinir ağını modellemiştir.

1948 yılında Wiener “Cybernetics” isimli kitabında, sinirlerin çalışması ve davranış özelliklerine değindi [27].

Donald Hebb (1949) ilk olarak, sinir hücrelerinin bağlantılarını güncellemek için “Hebb öğrenme kuralı” olarak adlandırılan bir öğrenme kuralını tasarlamıştır. Hebb bilgilerin bağlantılarda depolandığını varsaydı. Bu düşünce gelecekteki gelişmeler üzerinde çok büyük bir etki yaratmıştı ve Hebb öğrenme kuralı yapay sinir ağları teorisinde önemli katkıda bulunmuştur [34].

1950’li yıllardan sonra birçok araştırmacı Hebb kuralından esinlenerek yapay sinir ağlarının hesaplama gücünü artırıcı yönde çalışmalar yapmıştır. IBM araştırma laboratuvarında yapılan bir sinir benzetimi çalışmaları başarısızlıkla sonuçlanmasına karşın sonraki girişimlerde başarı sağlanmıştır. 1957 yılında Frank Rosentblatt’ın Perceptron’u gerçekleştirmesinden sonra yapay sinir ağı alanındaki gelişmeler hızlanmıştır. Perceptron, beyin işlevlerini modelleyebilmek amacıyla yapılan çalışmalar neticesinde ortaya çıkan tek katmanlı eğitilebilen ve tek çıkışa sahip olan yapay sinir ağıdır.

Frank Rosentblatt (1958), bir sineğin göz işlemleri ile ilgilenmiştir. Bir sineğe kaçmasını söyleyen işlemlerin çoğu sineğin beyni yerine gözünün içinde yapılması, kavrama düğümü diye adlandırılan ağ yapısının kurulmasını sağlamıştır. Tek katmanlı bir kavrama düğümünde, giriş değerleri ağırlıklı toplamı hesaplanarak, bir eşik değeri çıkarılmakta ve iki olası değerden biri sonuç olarak alınmaktadır. Kavrama düğümü bugün kullanımda olan en eski sinir ağıdır.

1959 yılında, Bernard Widrow ve Marcian Hoff (Stanford Üniversitesinde) ADALINE ve MADALINE diye adlandırdıkları ağ modellerini geliştirdiler. MADALINE, telefon hatlarında oluşan yanıkları yok eden uygulanabilir bir süzgeç olarak kullanılmış, gerçek dünya sorunlarına uygulanmış olan iki sinir ağıdır ve hala kullanımda bulunmaktadır [27].

Yapay sinir ağları konusunda ilginin artması ancak 1960’lı yıllarda bazı yeni çalışmalar yapılması ile oldu. İlk yöntemlerin karmaşık problemleri çözemeyecek kadar Zayıf olması bu konudaki çalışmaların ilerlemesini engelledi. Bu durgunluk, 1970’li yılların başından 1980’li yıllara kadar devam etti.

İlk kıpırdamalar Hopfield (1982) tarafından eğrisel ağların geliştirilmesiyle başladı. Bununla birlikte Khonen (1982) ve Anderson (1983) tarafından yapılan çalışmalar sonucunda eğiticiyiz öğrenen ağların geliştirilmesiyle çalışmalar yeniden ivme kazanmıştır [32].

1985 yılına kadar, Amerikan Ulusal Fizik Akademisi, yapay sinir ağı ile ilgili gelişmeleri izlemiş ve desteklemiştir.

1986 da Rumelhart ve McClelland karmaşık ve çok katmanlı ağı için geriye yayılmalı öğrenme algoritması ortaya koymuştur.

1987 yılında Elektrik Elektronik Mühendisliği Enstitüsü (IEEE) tarafından sinir ağlarını konu alan ilk uluslararası konferans 1800'ü aşkın katılımcıyla gerçekleşmiştir [27].

Bugün yapay sinir ağı üzerinde yapılan çalışmalar dünyada büyük bir hızla devam etmektedir. Her geçen gün değişik öğrenme algoritmaları ve ağı mimarileri hakkında yeni önermeler yapılmaktadır [32].

3.3. Yapay Sinir Ağı ve En Temel Görevi

Yapay sinir ağı, insanlar tarafından gerçekleştirilmiş örnekleri kullanarak olayları öğrenebilen, çevreden gelen olaylara karşı nasıl tepkiler üreteceğini belirleyebilen bilgisayar sistemleridir. İnsan beyninin fonksiyonel özelliklerine benzer şekilde,

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

gibi konularda başarılı bir şekilde uygulanmaktadır. Örneklerden elde ettikleri bilgiler ile kendi deneyimlerini oluşturur ve daha sonra, benzer konularda benzer kararlar verirler.


Yapay sinir ağı birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden oluşmuştur. Proses elemanları da denilen bu hücrelerin birbirlerine bağlandıkları ve her bağlantının bir değerinin olduğu kabul edilmektedir. Proses elemanlarının birbirleri ile bağlanmaları sonucu oluşan ağı yapay sinir ağı denmektedir.

Ağı oluşturan proses elemanları, bunların bilgileri işleme yetenekleri, birbirleri ile bağlantılarının şekilleri değişik modelleri oluşturmaktadır [26].

3.4. Yapay Sinir Ağlarının Yapısı ve Temel Elemanları

3.4.1. Biyolojik Sinir Hücreleri

Karakteristik bir biyolojik nöron; çekirdek, sinaps, akson ve çok sayıda kılcal dendritlerden oluşur. (Şekil 3.1)



Şekil 3.1: Biyolojik nöron

Dendritler iplik şeklinde hücre gövdesini sarar. Aksonlar ise uzun, ince, tüp şeklinde, dallara ayrılmış bir şekildedir ve neredeyse diğer hücrelerin aksonlarına temas edecek kadar uzanır. Akson ve dendritler arasındaki bilginin yayıldığı küçük boşluğa sinaps denir. Bir sinir hücresinin aksonu birçok nöronla sinaptik bağlantı oluşturur. Bir sinapsın bilgi gönderilen nöron kısmına presinaptik kısım, bilginin alındığı nöron kısmına ise postsinaptik kısım denir.

Sinir hücrelerinin çeşitli özelliklerinden bazıları;

1. Bir nöronun belirli bir aksonu bulunmayabilir ve bu nöron sadece bilgi alış verişinin işlenmesini sağlayabilir.
2. Aksonlar diğer aksonlarla sinaps oluşturabilirler.
3. Dendritler diğer dendritlerle sinaps oluşturabilirler.

Her nöronun oluşturduğu sinaps sayısı 100 ile 100.000 arasında değişir.

Biçimsel olarak iki çeşit sinaptik bağlantı çeşidi vardır:

1. Uyarıcı Sinaps: Asimetrik zar yapısına sahiptir. Postsinaptik kısımda zar kalınlaşması daha fazladır. Presinaptik kısımda nörotransmitter madde (glutamin ve


serotonin gibi kimyasallar) salgılayan yuvarlak kesecikler (sinaptik vesiküller) bulunur.

2. Yavaşlatıcı Sinaps: Simetrik zar yapısına sahiptir. Elips şeklinde ya da düz veziküller bulunur. Gama-amino bütirik asit gibi nörotransmitter maddeler salgılar.

Hücre zarı için negatif yüklenmesiyle zarda elektrostatik bir potansiyel fark oluşur. Bu potansiyel farkın korunması için zarda iyon yayılması olur. Diğer nöronlardan gelen uyarıcı ya da yavaşlatıcı sinyaller nörona dendritlerindeki sinapslarından iletilir. Bir nörona iletilen sinyalin büyüklüğü sinaptik iletimin verimine bağlıdır ve nöronlar arasındaki bağlantı gücü olarak düşünülebilir. Sinaps ile yeterli derecede uyarılan bir hücre elektriksel olarak aktifleşir. Bu hücre aksonu boyunca yaklaşık 100 mV'lık bir uyarı gönderir. Gelen uyarı yeterli derecede güçlü kalırsa nöron saniyede birkaç yüz uyarıdan oluşan bir frekansla uyarı iletmeye devam eder. Uyarılar akson boyunca dağılır ve sinaps ile diğer nöronların dendritlerine iletilir [28].

3.4.2. Yapay sinir hücresi

Yapay sinir hücreleri bilgi işlem birimi olarak yapay sinir ağlarında önemli bir rol oynar. Her bir yapay sinir hücresinin 5 temel elemanı vardır (Şekil 3.2). Bunlar:



Şekil 3.2: Yapay sinir hücresi

3.4.2.1. Girdiler

Girdiler ($x_1, x_2, \dots, x_n$) çevreden aldığı bilgiyi sinire getirir. Girişler kendinden önceki sinirlerden veya dış dünyadan sinir ağına gelebilir. Bir sinir genellikle gelişmiş birçok girdileri alır.

3.4.2.2. Ağırlıklar

Ağırlıklar ($w_1, w_2, \dots, w_n$), yapay sinir tarafından alınan girişlerin sinir üzerindeki etkisini belirleyen uygun katsayılarıdır. Her bir giriş kendine ait bir ağırlığa sahiptir [27].

Ağırlıkların büyük ya da küçük olması önemli ya da önemsiz olduğu anlamına gelmez. İşaretlerin artı veya eksi olması etkinin pozitif veya negatif olduğunu gösterir. Sıfır olması ise herhangi bir etkinin olmadığını gösterir [26].

3.4.2.3. Toplama Fonksiyonu

Bu fonksiyon, bir hücreye gelen net girdiyi hesaplar. Bunun için değişik fonksiyonlar kullanılmaktadır. En yaygın olanı ağırlıklı toplamı bulmaktır. Burada her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır. Böylece ağa gelen net girdi bulunmuş olur. Bu fonksiyon Eşitlik (3.1) şeklinde formüle edilir.

$$NET = \sum_{i=1}^n G_i A_i \quad (3.1)$$

G: girdiler,

A: Ağırlıklar,

n: hücreye gelen toplam girdi sayısını göstermektedir.

Yalnız zaman sinir ağlarında bu fonksiyonun kullanılması şart değildir. Bir problem için en uygun toplama fonksiyonunu belirlemek için bulunmuş bir formül yoktur. Genellikle deneme yanılma yolu ile toplama fonksiyonu belirlenmektedir [26].

3.4.2.4. Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu ağırlıklı ortalama değerini genellikle 0–1 arasında bir çıktıya dönüştürür. Çıktının 0–1 arasındaki bir değere dönüştürülmesinin temel nedeni


toplam fonksiyonu aracılığı ile elde edilen değer çok büyük değerler alabilmesidir [29].

Aktivasyon fonksiyonu $\phi(v)$ şeklinde ifade edilir. v değeri ise ağırlıklandırılmış net girdiyi ifade eder. Bir yapay sinir ağı hücresinde kullanılan çok sayıda değişik geçiş fonksiyonları vardır. Burada üç temel aktivasyon çeşidini tanımlayacağız: [30].

3.4.2.4.1. Eşik Fonksiyonu

Eşik fonksiyonunun özelliği yapay sinir hücresine gelen girdilerin ağırlıklı toplamı 0 değerine ulaşınca kadar 0 değeri, girdilerin ağırlıklı değeri belli bir değeri aştıktan sonra 1 değerini üretmesidir [29].

$$\phi(v) = \begin{cases} 1 & \text{Eğer } v \geq 0 \\ 0 & \text{Eğer } v < 0 \end{cases} \quad (3.2)$$



Şekil 3.3: Eşik fonksiyonu

3.4.2.4.2. Doğrusal Fonksiyon

Bazı durumlar yapay sinir hücresinde geçiş fonksiyonu olarak doğrusal fonksiyon kullanılabilir. Doğrusal fonksiyon olduğunda yapay sinir hücresine gelen girdilerin ağırlıklı değerleri aynen çıktı olarak üretilir. Doğrusal geçiş fonksiyonu doğrusal bir problem için uygun bir geçiş fonksiyonudur. Doğrusal fonksiyon (Eşitlik 3.3):

$$\varphi(v) = v \quad (3.3)$$


şeklinde ifade edilir.

3.4.2.4.2. Sigmoid Fonksiyon

Belki de en çok kullanılan geçiş fonksiyonlarının başında Sigmoid fonksiyonu gelir. Bunun temel nedeni Sigmoid fonksiyonun doğrusal ve doğrusal olmayan fonksiyonların her ikisinin de modellenmesinde oldukça dengeli çıktılar üretmesidir [29].

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (3.4)$$

Eşitlik 3.4'te a parametresi fonksiyonun “eğim parametresi” dir. A parametresi deneme yanılma yöntemiyle seçilse de, uygulamada genellikle 1 olarak kullanıldığı gözlemlenmektedir [30].



Şekil 3.4: Sigmoid fonksiyonu


3.4.2.5. Hücrenin Çıktısı:

Aktivasyon fonksiyonu tarafından belirlenen çıktı değerlidir. Üretilen çıktı dış dünyaya veya başka bir hücreye gönderilir. Bir hücreden çıkan tek bir çıktı değeri vardır [26].

3.5. Yapay Sinir Ağının Yapısı

Bir yapay sinir ağı yapay sinir hücrelerinin oluşturduğu bir gruptur (Şekil 3.5). Bu ağdaki hücreler bir birleri ile bağlantılar aracılığıyla iletişim içindedirler. Bir yapay

sinir hücresinin çıktısı başka hücreler için girdi olur. Genellikle yapay sinir ağında hücreler katman adı verilen sıralar halinde bulunur. Bu katmanlar:



Şekil 3.5: Yapay sinir ağının yapısı


- Girdi katmanı: Yapay sinir ağında dışarıdan girdilerin ağına alınmasını sağlayan hücrelerin bulunduğu ilk katmandır.
- Ara Katmanlar: Girdi katmanı ve çıktı katmanı arasında kalan katman veya katmanlar ise gizli katman veya katmanlar olarak adlandırılır. Genellikle bir yapay sinir ağının kaç katmandan oluştuğu söylendiğinde, bu gizli katmanların sayısı kastedilmektedir. Bu durumda girdi ve çıkış katmanları sayıya ilave edilmez.
- Çıktı katmanı: İşlenen verilerin ağına dışına çıkartılmasını sağlayan hücrelerin bulunduğu son katman ise çıktı katmanı olarak adlandırılır.

Bir yapay sinir ağının katmanlarının ve/veya hücrelerin dizilişi, bir biriyle bağlantı şekilleri gibi özellikler yapay sinir ağının mimarisi olarak adlandırılır.

Başlıca mimari türleri:[29]

3.5.1. İleri Beslemeli Ağlar

İleri beslemeli sinir ağı modeli olarak adlandırılan yapıda bilgi akışı, ileri doğrudur ve geri besleme yoktur. Giriş katmanı, ara katmanı ve çıkış katmanındaki işlem elemanı sayıları, uygulanan problemin yapısına ve buna göre oluşturulacak eğitim ve test setine göre değişebilir [31]. İleri beslemeli ağ yapısı Şekil 3.6'da gösterilmiştir.




Şekil 3.6: İleri beslemeli ağ yapısı

3.5.2. Geri Beslemeli Ağlar

Geri beslemeli ağlar yapay sinir ağlarının özel bir formudur. Bu ağ bir veya daha fazla gizli katmandan oluşmaktadır. İleri beslemeli ağlardan temel farkı Şekil 3.7'de gösterildiği gibi bir veya daha fazla geri besleme döngüsü bulunmasıdır. Geri besleme döngüsü iki nöron arasında veya katmanlar arasında görülebilir. Geri

besleme döngüleri genellikle gecikme elemanı (z^{-1}) içermektedir. Çok sayıda ileri besleme ve geri besleme bağlantılarına sahip oldukları için geri beslemeli ağlar karmaşık yapılardır. Bu yapısı sayesinde zaman serisi işlemede ve dinamik problemlerin çözümünde avantaj sağlamaktadır.



Şekil 3.7: Geri beslemeli ağ yapısı [38]

Geniş uygulama alanına sahip olan geri beslemeli ağlar akıllı kontrol, sistem tanımlama ve dinamik sistem uygulamalarında kullanılmaktadır [38].

3.6. Yapay Sinir Ağları Eğitimi

Yapay sinir ağlarının en ayırt edici özelliği öğrenme yeteneğidir. Yapay sinir ağlarında öğrenme, istenen bir işlevi yerine getirecek bir şekilde ağırlıkların ayarlanmasıdır.

Yapay sinir ağları öğrenme esnasındaki elde ettiği bilgileri, sinir hücreleri arasındaki bağlantı ağırlıkları olarak saklar. Bu ağırlık değerleri yapay sinir ağı'nın verileri başarılı bir şekilde işleyebilmesi için gerekli olan bilgileri içerir.

Yapay sinir ağlarında öğrenmedeki önemli noktalardan birisi öğrenmeyi sağlayacak olan eğitim kümesinin seçilmesidir. Eğitim kümesi en az bilgi ile en iyi öğrenmeyi sağlayacak şekilde seçilmelidir [32].

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


3.6.1. Öğretmenli Öğrenme

Yapay sinir ağlarında gerçek çıkış istenen çıkışla kıyaslanır. Rasgele değişen ağırlıklar ağ tarafından öyle ayarlanır ki, bir sonraki döngüde gerçek çıkış ile istenen

ıkış arasında daha yakın karşılařtırma üretebilsin. Öğrenme yöntemi, bütün işleme elemanlarının anlık hatalarını en aza indirmeye çalışır. Bu hata azaltma işlemi, kabul edilebilir doğruluğa ulaşana kadar ağırlıklar devamlı olarak derlenir.

Öğretmenli öğrenmede, yapay sinir ağı kullanılmadan önce eğitilmelidir. Eğitme işlemi, sinir ağına giriş ve çıkış bilgileri sunmaktan oluşur. Bu bilgiler genellikle eğitme kümesi olarak tanımlanır.

Birçok uygulamada ağı gerçek veriler uygulanmak zorundadır. Bu eğitme safhası uzun zaman alabilir. Sinir ağı belirli bir sıralamadaki girişler için istenen istatistiksel doğrular elde ettiğı zaman eğitme işlemi tamamlanmış kabul edilir. Öğrenim aşaması tamamlandıktan sonra ağı kullanılmaya başlandığında, bulunan ağırlıkların değeri sabit olarak alınır ve bir daha değıştirilemez. Öğretmenli öğrenme Şekil 3.8. gösterilmiştir.



Şekil 3.8: Öğretmenli öğrenme

Eğer verilen girişe karşılık amaçlanan çıkış üretilmiyorsa, ağı çıkış değeriindeki hatayı enküçükleyecek şekilde bağlantı ağırlıklarının değıştirilmesi sağlanır [27].

3.6.1.2. Geriye Yayılım Algoritması

Geri yayılım algoritması 1974 yılında Paul Werbos tarafından geliştirildi ve bu gelişmeden bağımsız olarak Rumelhart ve Parker tarafından yeniden keşfedilmiştir. Geri yayılım algoritmasının yeniden keşfedilmesi, algoritmanın yaygın kullanılmasını sağlamıştır [35].

Geri yayılmalı ağlar girdi katmanı, bir veya daha fazla gizli katman ve çıktı katmanından oluşmaktadır [36]. Geri yayılma algoritması gizli katman içeren yapay sinir ağlarında kullanılan güçlü bir öğrenme algoritmasıdır. Bunun esası alt sistemlerden meydana gelen bir yapay sinir ağlarındaki değişimlerin tamamen ve etkili bir şekilde hesaplanabilmesine dayanmaktadır.

Geri yayılma algoritmasında iki temel akış vardır. Bunlardan birincisi ağlar üzerinden ileri doğru olan bilgi akışı, ikincisi ise geriye doğru olan hatanın yayılmasıdır [32]. Hataları çıkıştan girişe geriye doğru azaltmaya çalışmasından dolayı geri yayılım olarak isimlendirilir. Geri yayılma algoritmasında i ve j katman nöronları arasındaki ağırlıklardaki $\Delta w_{ij}(t)$ değişikliği hesaplanır. Bu değişiklik Eşitlik (3.5) kullanılarak bulunur [37].

$$\Delta w_{ij}(t) = \eta \delta_j x_j + \alpha \Delta w_{ij}(t - 1) \quad (3.5)$$

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.

$$\delta_j = \frac{\partial f}{\partial net_j} (y_j^{(t)} - y_j) \quad (3.6)$$

Eşitlik (3.6)'da;

$$net_j = \sum x_j w_{ji} \quad (3.7)$$

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

$$\delta_j = \frac{\partial f}{\partial net_j} \sum w_{qi} \delta_q \quad (3.8)$$

şeklinde hesaplanır. Ara katmanlardaki nöronlar için herhangi bir hedef çıkış olmadığından, (3.6) nolu eşitlik yerine (3.8) nolu eşitlik kullanılır. Bu duruma bağlı olarak çıkış katmanından başlayarak δ_j faktörü, bütün katmanlardaki nöronlar için hesaplanır. Daha sonra (3.5) nolu eşitliğe göre bütün bağlantılar için ağırlıklar güncellenir.

3.6.2. Öğretmensiz Öğrenme

Öğretmensiz öğrenmede yapay sinir ağları sadece girdi tabakasından bilgileri alır ve kendisine göre işledikten sonra tam hür olarak bunları sınıflara ayırır. Bu öğrenmede sadece giriş bilgileri verilir ve yapay sinir ağının çıkış üretmesi sağlanır. İstenilen çıkışlar ağı hiç verilmediğinden hata dikkate alınmaz [32].

3.6.3. Öğrenme Kuralları

3.6.3.1. Hebb Kuralı

Hebb (1949) tarafından tanımlanmış olan bu kural ilk ve en çok bilinen öğrenme kuralıdır. Kurala göre: bir nöron başka bir nörondan girdi alırsa ve iki nöron da yüksek derecede aktifse (yani matematiksel olarak aynı işarete sahipse) nöronlar arasındaki bağlantının ağırlığı arttırılmalıdır.

3.6.3.2. Hopfield Kuralı

Bir temel farklılık dışında Hebb kuralına benzemektedir. Temel farklılık ise bağlantı ağırlığında yapılacak değişikliğin büyüklüğünü de belirlemesidir. Buna göre, girdi ve istenilen çıktının ikisi de aktifse veya ikisi de aktif değil ise, bağlantı ağırlığı öğrenme oranı kadar arttırılır, aksi durumda ise öğrenme oranı kadar azaltılır [33].

3.6.3.3. Delta Kuralı

En yaygın kullanılan ve Hebb kuralını esas alan bir kuraldır. Burada bağlantı değerlerisin YSA çıktıları beklenen (önceden ölçülen) çıktı değerine yakın oluncaya kadar sürekli olarak önceki ağırlık değerinin biraz değiştirilmesi ile yapılan bir öğrenme şeklidir. YSA çıktılarının ortalama kare hatalarının en küçüklenmesi ile ağırlıkların yenilenmesi işlemine dayanır.

3.6.3.4. Kohonen Öğrenme Kuralı

Bu kural biyolojik sistemlerdeki öğrenme kurallarından esinlenerek ortaya atılmıştır. Burada sinir hücreleri öğrenmeyi ve ağırlıkları yenilemeyi kendi bünyelerinde halleder. En büyük çıktısı olan bir hücre, kazanan hücre olarak ilan edilir. Bu hücre komşularını etkilerken diğer hücreleri etkilememektedir. Sadece kazanan hücre çıktı verir ama bağlantıların yenilenmesinde komşu hücrelerde ağırlıklarını yenileyerek işin içine girerler. Kohonen kuralı bir çıkış veri dizisi olmasını gerektirmez. Bu sebeple öğretmensiz olan bir eğitimle öğrenimini tamamlar [32].

3.7. Yapay Sinir Ağlarının Üstünlükleri ve Sakıncaları

Yapay sinir ağlarının en büyük üstünlükleri, öğrenme kabiliyeti olması ve farklı öğrenme algoritmaları kullanabilmesidir. Bunun yanı sıra en sık belirtilen sakıncaları ise sistemin analiz edilememesi ve öğrenme işleminde başarılı olunamama riskidir [27]. Yapay sinir ağlarının üstünlükleri ve sakıncaları şunlardır:

3.7.1.Üstünlükler

- **Doğrusal Olmayan Yapı**

Analiz konusunun içerdiği veri setinin doğrusal veya doğrusal olmayan yapı içeriyor olması, analiz sonuçlarını etkileyecek önemli bir faktördür. Bu yüzden, doğrusal olmayan yapıları dikkate alabilmesi yapay sinir ağlarının önemli bir özelliğidir.

- **Öğrenme**

Yapay sinir ağları öğrenme yeteneği sayesinde geleneksel teknikler için çok karmaşık olan problemlere çözüm sağlayabilmektedirler.

- **Yerel İşlem ve Esneklik**

Geleneksel işlemcilerde, tek bir merkezi işlem elemanı her hareketi sırasıyla gerçekleştirir. Yapay sinir ağ modelleri, her biri büyük bir problemin bir parçası ile ilgilenen çok sayıda basit işlem elemanlarından oluşma ve bağlantı ağırlıklarının ayarlanabilmesi gibi özelliklerinden dolayı önemli derecede esnek bir yapıya sahiptirler. Ayrıca, toplam işlem yükünü paylaşan işlem elemanlarının birbirleri arasındaki yoğun bağlantı yapısı sinirsel hesaplamanın temel güç kaynağıdır. Bu yerel işlem yapısı sayesinde, yapay sinir ağları yöntemi en karmaşık problemlere bile uygulanabilmektedir.

- **Gerçek Zamanlı İşlem**

Yapay sinir ağları hesaplamaları paralel olarak yürütebildiğinden gerçek zamanlı işlem yapılabilir.

- **Genelleme**

Öğrenme yeteneği sayesinde bilinen örnekleri kullanarak daha önce karşılaşılmamış durumlarda genelleme yapabilmektedirler.

- **Hafıza**

İşlem elemanları arasındaki ağırlıklı bağlantılar sayesinde dağıtılmış hafızada bilgi saklayabildikleri söylenebilir.

- **Kendi İlişkisini Oluşturabilme**

Verilere göre kendi ilişkilerini oluştururlar, denklem içermezler.

- **Sınırsız Sayıda Değişken ve Parametre**

Sınırsız sayıda değişken ve parametre ile çalışabilmeleri sayesinde mükemmel bir öngörü doğruluğu ile genel çözümler sağlanabilmektedir.

3.7.2. Sakıncalar

Yapay sinir ağlarının kullanımında göz önünde bulundurulması gereken bazı sakıncalar vardır. Bunlar arasında en önemlisi geniş veri seti gereksinimidir. Sinir ağlarının eğitilebilmesine ve test edilebilmesine yetecek genişlikte veri setine ihtiyaç duyulmaktadır. Sakına olarak sayılabilecek bir diğer nokta ise basit olarak

görülebilecek modelleme yapılarına rağmen uygulamanın zor ve karmaşık olabilmektedir [33]. Diğer sakıncalar ise; sistem içerisinde ne olduğu bilinemez, bazı ağlar hariç kararlılık analizi yapılamaz ve farklı sistemlere uygulanması zor olabilir.

3.8. Yapay Sinir Ağları Tasarımı

3.8.1. Ağ Yapısı

Nöronların bağlantı şekilleri, oluşturdukları katman sayısı ve katmanlar arasındaki veri iletim şekli ağın yapısını belirler. Bir ağın yapısı, ağın fonksiyonelliği ve performansı üzerinde önemli bir rol oynar. Ağ seçimi, çözülmek istenen problemle ilgilidir. Hangi ağ modelinin hangi problemin çözümü için daha uygun olduğunun bilinmesi oldukça önemlidir. Yapay sinir ağları ağda kullanılan yapıya göre isimlendirilirler. Yapılar, ağda kullanılan katman sayısı (tek katmanlı, çok katmanlı), öğrenme algoritması (danışmanlı, danışmansız, takviyeli), öğrenme kuralı, iletişim yönü (ileri beslemeli, geri beslemeli, yarışmacı) gibi belirleyici özellikleri ile isimlenirler [46].

3.8.2. Girdi Nöron Seçimi

Girdi veri gruplarının ağa sunulduğu terminallerdir. Bu tabakadaki nöron sayısı, giriş veri sayısı kadardır ve her bir giriş nöronu bir veri alır. Burada veri işlemeden bir sonraki tabakaya yani gizli katmana geçer [39].

3.8.3. Gizli Katman ve Nöron Sayısını Belirleme

Kullanılacak gizli katman sayısına karar vermenin iki yolu vardır: Küçük bir ağ ile başlamak ve boyutu gittikçe artırmak (Gelişim (Üreme) Yöntemi) veya karmaşık bir ağ ile başlamak ve daha sonra çok önemli olmayan bileşenlerin atılmasıyla ağın boyutunu küçültmek (Budama Yöntemi). Nöron sayısının belirlenmesinde ise kesim noktaları kullanılmaktadır. Kesim noktalarından en çok kullanılanlar hata değeri veya iterasyon sayısıdır [45].

Bu tabakada gereğinden az sayıda nöron kullanılması giriş verilerine göre daha az hassas çıkış elde edilmesine sebep olur. Aynı şekilde, gerektiğinden daha çok sayıda nöron kullanılması durumunda da aynı ağda yeni tip veri gruplarının işlenmesinde zorluklar ortaya çıkar [39].

3.8.4. Çıktı Nöron Sayısını Belirleme

Ağın en uç tabakasıdır. Gizli katmandan aldığı veriyi ağın kullandığı fonksiyonla işleyerek çıktısını verir. Çıkış katmanındaki nöron sayısı, ağa sunulan her verinin çıkış sayısı kadardır. Bu tabakadan elde edilen değerler yapay sinir ağının söz konusu problem için çıkış değerleridir. İleri besleme safhasında, giriş tabakasındaki nöronlar, veri değerlerini doğrudan gizli katmana iletir. Gizli katmandaki her bir nöron kendi giriş değerlerini ağırlıklandırarak toplam değer hesap ederler ve bunları bir taşıma fonksiyonu ile işleyerek bir ileri tabakaya veya doğrudan çıkış tabakasına iletirler. Tabakalar arasındaki ağırlıklar rasgele küçük rakamlardan seçilir [39].

3.8.5. Aktivasyon Fonksiyonu Belirleme

Aktivasyon fonksiyonu, transfer fonksiyonu olarak da adlandırılmaktadır. Bir nöronun veya ağın girdisi ve çıktısı arasındaki ilişkiyi belirlemektedir. Uygulamada, sınırlı, tekdüze artan ve türevi alınabilen aktivasyon fonksiyonları kullanılmaktadır. Genel olarak, bir ağın, aynı ya da farklı katmanlarındaki nöronlar farklı aktivasyon fonksiyonunu kullanabilirler. Örneğin; her nöronun aktivasyon fonksiyonu ayrı ayrı belirlenebileceği gibi, kullanılacak aktivasyon fonksiyonu katman katman da belirlenebilir. 1. gizli katmanda sigmoid, 2. gizli katmanda doğrusal çıkış katmanında hiperbolik tanjant tipli aktivasyon fonksiyonları kullanılabilir [42].

Uygulamaların çoğunda ise, aynı katmandaki nöronların aynı aktivasyon fonksiyonunu kullandıkları görülmektedir.

Lojistik aktivasyon fonksiyonu, ikili hedef değerlerin olduğu sınıflandırma problemleri için çıktı katmanında sıklıkla kullanılmıştır. Ancak, hedef değerleri süreklilik gösterdiği kestirim problemi gibi problemlerde, çıktı katmanında doğrusal bir aktivasyon fonksiyonunun kullanılması tercih edilmelidir. Burada şu noktanın unutulmaması gerekir: ağın ürettiği çıktığı değerleri, kullanılan fonksiyona göre $[0,1]$ veya $[-1,1]$ aralığında olacağı için, hedef değerler de kullanılan fonksiyonla uyumlu bir şekilde yukarıdaki aralıkları dikkate alarak normalleştirilmelidir [41].

3.8.6. Veri Normalizasyonu

Bütün eğitim verilerinin belli bir aralık içerisinde normalleştirilmesi gerekir. Çoğunlukla kullanılan veri normalleştirme formülleri aşağıdaki eşitliklerde verilmiştir [40].

$$[0,1] \text{ aralığı doğrusal dönüşüm: } x_n = \frac{x_o - x_{\min}}{x_{\max} - x_{\min}} \quad (3.9)$$

$$[-1,1] \text{ aralığı dönüşüm : } x_n = 2 \frac{x_o - x_{\min}}{x_{\max} - x_{\min}} - 1 \quad (3.10)$$

$$[a,b] \text{ aralığı dönüşüm: } x_n = (b - a) \frac{x_o - x_{\min}}{x_{\max} - x_{\min}} + a \quad (3.11)$$

$$\text{Basit normalizasyon: } x_n = \frac{x_o}{x_{\max}} \quad (3.12)$$

3.8.7. Yapay Sinir Ağlarının Eğitimi ve Test Edilmesi

Yapay sinir ağlarının eğitimi, sistem için en uygun olan bağlantı ağırlıklarının elde edilmesi şeklinde tanımlanır. Eğitim ise,

- Yeni bağlantı ağırlıkları oluşturmakla,
- Bağlantı ağırlıklarının yenilenmesiyle,
- Bazı bağlantı ağırlıklarının yok edilmesi ile gerçekleşir.

Yapay sinir ağları eğitimi esnasında elde ettiği bilgileri, sinir hücreleri arasındaki bağlantı ağırlıkları olarak sağlar. Eğitim süresi boyunca bilgiye ihtiyaç duyulması ve sinir hücreleri arasındaki bağlantı ağırlıkları vasıtasıyla bilgilerin saklanması yönüyle sinir hücreleri insan beynini andırırlar. Yapay sinir ağların eğitimindeki önemli noktalardan biri de eğitimi sağlayacak olan eğitim kümesinin seçilmesidir. Yanlış kanılardan birisi, eğitim kümesinin ne kadar büyük seçilirse eğitmenin o kadar iyi olacağıdır. Halbuki eğitim kümesi oluşturulurken birbirine yakın bilgilerden ziyade, az miktarda da olsa birbirinden farklı ve bağımsız bilgilerin seçilmesi daha verimli bir eğitime sağlar. Ağın eğitimi tamamlandıktan sonra öğrenip öğrenmediğini (performansını) ölçmek için yapılan denemelere ise ağın test edilmesi denilmektedir. Test etmek için ağın öğrenme sırasında görmediği örnekler kullanılır. Test etme sırasında ağın ağırlık değerleri değiştirilmez. Test örnekleri ağa gösterilir. Ağ eğitim sırasında belirlenen bağlantı ağırlıklarını kullanarak görmediği bu örnekleri için çıktılar üretir. Elde edilen çıktıların doğruluk değerleri ağın öğrenmesi hakkında bilgiler verir. Sonuçlar ne kadar iyi olursa eğitimin performansı da o kadar iyi demektir [43].

3.8.8. 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 [40].

3.9. k -Katlı Çapraz Doğrulama Yöntemi ve Başarı Ölçümü

Herhangi bir amaç için oluşturulan sistemlerin yürütülmesi sonucunda elde edilen sonuçların doğruluklarının ölçülmesi suretiyle sistemlerin başarı değerlendirilmesi yapılabilmektedir. Bu amaçla kullanılan en yaygın yöntemlerden biri de k -katlı çapraz doğrulama yöntemidir. Bu yöntemde A olarak temsil edilen veri kümesi her birinde yaklaşık aynı sayıda veri olacak şekilde $A_1, A_2, \dots, A_k$ biçiminde gösterilen rastgele k sayıda alt kümeye ayrılır. Deneysel çalışmalar k -katlı çapraz doğrulama yönteminde k için optimum değer 10 olduğunu göstermiştir

k tane farklı eğitim ve test kümeleriyle eğitilen ve sınanan sistemin yine k tane başarı ölçüsü elde edilmiş olur. Bu nedenle sistemin genel başarısını belirlemek üzere, elde edilen bu ölçümlerin ortalaması alınır [44].

4. UYGULAMA

Çalışmamızın bu bölümünde, daha önceki bölümde anlatılan teorilere göre veriler incelenerek, Türkiye'nin yıllık elektrik tüketim miktarları (electric power consumption) (GWh) sırasıyla Box-Jenkins ve Yapay Sinir Ağları kullanılarak analiz edilmiş ve kestirimler yapılmıştır.

4.1. Veriler


1923–2009 yıllarını kapsayan 87 gözlemlili veri seti kullanılmıştır. Bu veriler TEİAŞ'ın (Türkiye Elektrik İletim Anonim Şirketi) web sitesinden temin edilmiştir. Veriler Ek A'da verilmiş olup tüketim miktarları GWh (Gigawatt Hour) değerindedir.

4.2. Yöntemler

4.2.1. Zaman Serisi Analizi

4.2.1.1. Belirleme

Türkiye'nin elektrik tüketimi miktarlarına (GWh) ilişkin serinin ilk önce trend içerip içermediğinin test edilmesi gerekir. Bu amaçla serinin grafiği incelenmelidir. Serileri olası değişen varyans ve kısmen de otokorelasyona karşı koruyabilmek için logaritmik dönüşümleri alınmaktadır. Logaritması alınan elektrik tüketimi miktarlarının (LGWh) korelogramı MINITAB 15 paket programı kullanılarak çizilmiştir. (Şekil 4.1.)



Şekil 4.1: Logaritması alınmış seri

Şekil 4.1, incelendiğinde seride deterministik trendin olduğu söylenebilir. Serinin durağan olup olmadığını incelemek için E-VIEWS paket programı yardımıyla Dickey-Fuller testi ile test edilmiştir ve elde edilen bulgular Tablo 4.1’de verilmiştir.

Tablo 4.1.: Dickey-Fuller Test İstatistiği

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.043981	0.0348
Test critical values: 1% level	-3.508326	
5% level	-2.895512	
10% level	-2.584952	


*MacKinnon (1996) one-sided p-values.

Tablo4.1.’de verilen sonuçlara göre $p < 0,05$ olduğu için serinin durağan olduğuna karar verilir.

4.2.1.2. Model Seçimi

Modelin seçiminde logaritması alınmış serisinin otokorelasyon (ACF) ve kısmi otokorelasyon (PACF) grafiklerine bakılarak AR ve MA'nın derecesini belirlenmelidir. Serinin ACF grafiğine bakıldığında (Şekil 4.2.) otokorelasyon değerlerinin giderek azalan bir yapıda olduğu görülmüştür. Bu bize modelde MA'nın derecesinin sıfır olduğunu göstermiştir. Serinin PACF grafiğine bakıldığında ise (Şekil 4.2.) ilk gecikme değerinin yüksek olduğu diğer gecikmelerin ise giderek azaldığı görülmüştür. Bu da bize AR'ın derecesinin 1 olduğu yani seride otoregresif etkinin olduğu sonucunu vermiştir. Logaritması alınmış elektrik tüketim serisinin durağan olduğuna karar verildiği için fark alma işlemi yapılmamıştır. Bu analizler sonucunda modelin AR(1) olduğuna karar verilmiştir.

Şekil 4.2' deki dikey çizgiler %95 kabul bölgesini göstermektedir. Örneklem otokorelasyon fonksiyonu bu bölgenin içinde olursa, istatistiksel bakımdan önemli bir anakütle otokorelasyon fonksiyonu yok, dışına taşıyor ise var demektir [53].



Şekil 4.2.: Logaritması alınmış serinin korelogram grafiği

4.2.1.3. Tahmin ve Test

Bu aşamada veriyi en iyi açıkladığı düşünülen AR(1) modeli kullanılarak parametre tahminlerinin yapılması gerekmektedir. EVIEWS paket programı yardımıyla hesaplanan parametre tahminleri Tablo 4.2.'de verilmektedir.

Tablo 4.2.: Parametre Tahminleri

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	9.340315	1.925451	4.850975	0.0000
AR(1)	0.992775	0.002374	418.2706	0.0000
R-squared	0.999520	Mean dependent var		3.620807
Adjusted R-squared	0.999514	S.D. dependent var		1.076298
S.E. of regression	0.023718	Akaike info criterion		-4.622173
Sum squared resid	0.047254	Schwarz criterion		-4.565095
Log likelihood	200.7534	F-statistic		174950.3
Durbin-Watson stat	2.039859	Prob(F-statistic)		0.000000
Inverted AR Roots	.99			

Modelde AR(1) katsayısı 0,992775 ve sabit terim 9,340315 olmaktadır. Modelin tümünün anlamlılığı için F testi = 174950,3, p değeri = 0,000000 < 0,05 olduğu için istatistiksel olarak % 5 anlamlılık düzeyinde model anlamlıdır.

Hesaplanan parametre değerlerine göre 1923–2009 yıllarına ilişkin tahmin değerleri Ek B’de verilmiştir.

4.2.1.4. Modelin Uygunluğunun Sınanması

Bu bölümde seçilen AR(1) modelinin uygunluğunun sınanması amaçlanmaktadır. Modelin hatalarının otokorelasyon fonksiyonu Şekil 4.3.’de gösterilmiştir.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1	-0.073	-0.073	0.4745
		2	0.159	0.155	2.7647
		3	-0.001	0.021	2.7647
		4	-0.070	-0.096	3.2155
		5	-0.005	-0.019	3.2174
		6	0.002	0.029	3.2177
		7	0.052	0.062	3.4799
		8	-0.075	-0.083	4.0197
		9	0.138	0.112	5.8886
		10	-0.196	-0.164	9.7247
		11	0.065	0.019	10.150
		12	-0.059	-0.013	10.501
		13	-0.076	-0.075	11.100
		14	-0.037	-0.067	11.248
		15	-0.055	-0.031	11.566
		16	-0.105	-0.117	12.763
		17	0.035	0.062	12.895
		18	0.092	0.090	13.827
		19	0.089	0.143	14.719
		20	0.004	-0.081	14.721
		21	0.060	0.055	15.136
		22	-0.004	0.032	15.138
		23	-0.030	-0.036	15.247
		24	-0.070	-0.121	15.843
		25	-0.014	0.004	15.866
		26	-0.083	-0.137	16.736
		27	-0.056	-0.066	17.145
		28	0.006	-0.013	17.150
		29	-0.055	-0.002	17.558
		30	-0.026	-0.095	17.653
		31	-0.003	0.055	17.654
		32	-0.051	-0.024	18.014
		33	-0.110	-0.091	19.753
		34	-0.013	-0.017	19.776
		35	-0.026	0.075	19.873
		36	0.100	0.043	21.381

Şekil 4.3.: AR(1) Modelinin Kestirim Hatalarının Korelasyonları

Otokorelasyon fonksiyonuna bakıldığında otokorelasyon katsayılarının %95 olasılıkla güven sınırları içinde olduğu ve prob. Değerlerinin tümü 0.05'den büyük olduğu saptanmıştır. Bu nedenle artıklarda otokorelasyon bulunmadığı anlaşılmaktadır. Yani AR(1) modeli uygun ve yeterli bir model olduğuna karar verilmiştir.

4.2.2. Yapay Sinir Ağları Analizi

4.2.2.3. Ağ Yapısının Oluşturulması

Çalışmada 1923–2009 dönemlerindeki Türkiye elektrik tüketim serisinin modellenmesi için denemeler yapılarak en iyi sonucu veren YSA yapısı seçilmiştir. YSA’da veriler test ve eğitim olarak iki gruba ayrılmıştır. YSA’nın giriş değerlerine göre çıkış değerleri arasındaki bağıntının bulunması sürecine YSA’nın eğitimi denir [47]. Test kümesinin amacı ise ağın öğrenmesinin yeterli ya da doğru olup olmadığının sınanmasıdır. Böylece ağın, tahmin sürecinde kullanılma yeterliliği değerlendirilmiş olur [50].


Yapay sinir ağları ile ilgili program kodları MATLAB R2008a kullanılarak yazılmıştır. MATLAB R2008a bilgisayar programı kullanılarak oluşturulan yapay sinir ağında, tahmin problemlerinde İleri Beslemeli Geri Yayılım Ağları (Feed Forward Back Propagation) sıklıkla kullanılmasından dolayı çalışmada bu ağ yapısı seçilmiştir.

Ağ yapısı seçildikten sonra giriş, çıkış ve gizli nöron ve katman sayılarını belirlemek için çeşitli denemler yapılarak en iyi sonucu veren değerler seçilmiştir. Buna göre, ilk olarak YSA yapılarında önemli konulardan biri olan giriş nöron sayısı belirlenmiştir. Literatürdeki çalışmalarda bu sayının belirlenmesinde kesin bir kural yoktur. Çalışmada deneme-yanılma yöntemi ile girdi nöron sayısı 1 olarak alınmıştır. Gizli nöron ve katmanların sayısının belirlenmesi için de herhangi bir kural bulunmamasından dolayı yapılan ön çalışmalarda farklı sayılar (1–20 arasında) ile modeller kurulmuş ve ağın ürettiği sonuçlar kaydedilmiştir.

Öğrenme yöntemini belirlemek için çeşitli öğrenme yöntemleri denenmiş (Levenberg-Marquardt (trainlm), Conjugate Gradient (traincgf)) ve bu çalışmada, yüksek modelleme yeteneğinden ve etkin yakınsama tekniğinden dolayı, Lavenberg-Marquardt öğrenme yöntemi tercih edilmiştir [51]. Öğrenme, her ikisi de 0 ile 1 değeri arasında değer alan öğrenme oranı ve momentum katsayısı ile kontrol edilir. Öğrenme işleminde son derece önemli olan bu katsayılar deneme-yanılma yolu ile belirlenmiştir [50]. Öğrenme oranının küçüklüğü daha yavaş öğrenmeye yol açar. Ancak büyük öğrenme oranları da algoritmanın dengeden uzaklaşmasına, büyük sıçramalar yapmasına sebep olmaktadır [49]. Dolayısı ile yapılan çalışmada öğrenme

oranı 0,1 olarak alınmıştır ve momentum sabiti (momentum constant) 0,1 olarak belirlenmiştir. İterasyon sayısı ise (epoch) 1000 olarak belirlenmiş ancak algoritmanın sonlanması 40–50 devir arasında değiştiği gözlemlenmiştir.

Bütün bu işlemlerden sonra yapay sinir ağı modeli; 1 girdi nöronu, 1 gizli katman ve 1 çıktı nöronundan oluşmaktadır. Gizli katmanda 1 nöron bulunmaktadır ve gizli katmanın aktivasyon fonksiyonu hiperbolik tanjant sigmoid (hyperbolic tangent sigmoid) olarak belirlenmiştir. Çıktı katmanında ise doğrusal (purelin) aktivasyon fonksiyonu kullanılmıştır. Öğrenme algoritması Levenberg-Marquardt (trainlm) ile oluşturulmuştur. Şekil1 de kullanılan ağın YSA yapısı gösterilmektedir.



Şekil 4.4.:YSA yapısı

YSA’da veri sayısının az olması, test başarımını olumsuz yönde etkileyebilmektedir. Bundan dolayı seçilen ağ yapısının güvenilirliğini ve geçerliliğini sağlamlaştırmak için *k*-katlı çapraz doğrulama (*k*-fold cross-validation) yöntemi uygulanmıştır. Çalışmada 10-katlı çapraz doğrulama yöntemi seçilmiştir. 87 adet veri 10 guruba ayrılmıştır. İlk 9 grupta 9 adet, son grupta ise 6 adet veri bulunmaktadır. Bu gruplardan biri dışarıda bırakılarak geriye kalan kısım ile eğitim kümesi, seçilen grup ise test kümesi olarak belirlenmiştir. Sırasıyla bu işlem dönüşümlü olarak diğer gruplar için de tekrarlanmış ve her bir grup için ağ 10 kez çalıştırılarak elde edilen sonuçların ortalaması alınmıştır.

4.3. Yöntemlerin Karşılaştırılması

Çalışmamızın bu bölümünde Türkiye elektrik tüketim kestirimini yapmak için uygun model seçilecektir. Kestirim modellerinin seçiminde kestirim başarısı yüksek olan model seçilmektedir. Kestirim başarısını karşılaştırmak için çeşitli istatistikler kullanılmaktadır.

Türkiye elektrik tüketim verilerinin kestiriminde YSA modeli ile AR(1) modelinin karşılaştırılmasında (2.8), (2.9), (2.10), (2.11) ve (2.12) nolu eşitlikler kullanılmıştır.

YSA’da kullanılan 10-katlı çapraz doğrulama yöntemindeki sistem ile AR(1) modelindeki çıkan kestirim sonuçlarda aynı şekilde gruplara ayrılmıştır. AR(1) modelinde 1923 yılına ait kestirim değeri hesaplanamadığı için ilk grupta 8 adet veri yer almaktadır.

AR(1) modelinde verilere logaritmik dönüşüm, YSA’da ise normalizasyon uygulanarak veriler [-1 1] aralığında değerler almıştır. Bu dönüşüm farklılığından dolayı performans istatistiklerindeki sonuçlarda herhangi bir sorun yaşamamak için veriler gerçek değerlere dönüştürülmüştür. YSA ve AR(1) modellerinin performans değerleri Tablo 4.3. ve Tablo 4.4.’te verilmiştir.

Tablo 4.3.: Test performans değerleri

GRUP	TEST							
	AR(1)	YSA	AR(1)	YSA	AR(1)	YSA	AR(1)	YSA
	MSE		MAE		RMSE		MAPE	
Grup1	31.97	56.29	4.54	6.24	5.65	7.50	7.99	9.82
Grup2	402.99	94.63	16.80	9.43	20.07	9.73	6.92	4.77
Grup3	19234.27	35188.34	117.52	168.17	138.69	187.59	22.73	33.40
Grup4	87145.11	169476.04	294.17	411.40	295.20	411.67	27.44	37.69
Grup5	61871.23	263734.55	227.15	511.52	248.74	513.55	7.81	15.69
Grup6	3045826.19	1190071.80	1260.70	695.34	1745.23	1090.90	10.44	5.77
Grup7	14634451.88	3724307.77	3770.69	1513.72	3825.50	1929.85	17.30	7.64
Grup8	57936534.42	969602.62	7439.53	842.91	7611.61	984.68	15.84	1.81
Grup9	146604658.54	31966717.07	11604.42	4185.31	12108.04	5653.91	13.34	4.36
Grup10	152676063.37	199161781.61	11288.57	12245.44	12356.22	14112.47	7.85	8.07
ORT.	37506622.00	23748103.07	3602.41	2058.95	3835.50	2490.19	13.77	12.90

Tablo 4.4. : Eğitim performans değerleri

GRUP	EĞİTİM							
	AR(1)	YSA	AR(1)	YSA	AR(1)	YSA	AR(1)	YSA
	MSE		MAE		RMSE		MAPE	
Grup1	37404711.52	6388229.28	3721.93	1256.12	6115.94	2527.49	14.66	11.83
Grup2	37890443.21	5752686.77	3768.77	1237.60	6155.52	2398.48	14.87	13.12
Grup3	37888242.20	9003235.07	3757.00	1330.34	6155.34	3000.54	13.02	12.55
Grup4	37880304.52	6847903.71	3736.35	1261.84	6154.70	2616.85	12.47	12.00
Grup5	37883258.61	7978187.16	3744.18	1522.31	6154.94	2824.57	14.77	16.83
Grup6	37534484.65	9754047.29	3623.38	1380.48	6126.54	3123.15	14.46	11.17
Grup7	36179969.96	5483942.09	3330.00	1075.02	6014.98	2341.78	13.66	17.14
Grup8	31118687.59	5376059.08	2901.18	1140.71	5578.41	2318.63	13.83	18.26
Grup9	20754880.87	3083852.49	2414.37	882.20	4555.75	1756.09	14.12	14.70
Grup10	10236722.07	1941121.93	822.27	768.56	3199.49	1393.24	11.60	8.57
ORT.	32477170.52	6160926.49	3181.94	1185.52	5621.16	2430.08	13.75	13.62

Literatürde MAPE değeri %10'un altında olan modeller "çok iyi", %10 ile %20 arasında olan modeller "iyi", %20 ile %50 arasında olan modeller "kabul edilebilir" ve %50'nin üzerinde olan modeller ise "yanlış ve hatalı" olarak sınıflandırılmaktadır [48]. Tablo 4.3. ve Tablo 4.4. incelendiğinde eğitim ve test kümelerinde en düşük MAPE değerlerini YSA analizinin verdiği görülmektedir. Diğer performans istatistikleri incelendiğinde de YSA modeli AR(1) modeline göre hem eğitim hem de test kümesinde, daha iyi bir performans sergilemiştir.

SONUÇ

Elektrik, çağımızda ısı, ışık ve kimyasal enerjiye çevrilerek günlük yaşamın ve sanayinin vazgeçilmez bir unsuru haline gelmiştir. Ülkelerin elektrik talebi ile onların gelişmişlik düzeyi arasında doğru bir orantı vardır.

Büyük miktarlardaki elektrik enerjisi depolanamayan bir enerji türüdür. Bu nedenle elektrik enerjisi tüketim kestirimini bilimsel yollarla yapmak oldukça önemlidir.

Bu çalışmada, 1923–2009 yılları arasındaki Türkiye elektrik enerjisi tüketim verileri Box-Jenkins ve yapay sinir ağları yöntemleri ile analiz edilmiştir. Zaman serisi için uygun model otoregresif model AR(1), yapay sinir ağları için, 1 girdi nöronu, 1 gizli katman ve 1 çıktı nöronundan oluşan, gizli katmanda 1 nöron bulunan ileri beslemeli geri yayılım algoritması seçilmiştir.

Seçilen modelleri karşılaştırmak için Ortalama Kare Hata (Mean Squared Error - MSE), Ortalama Mutlak Hata (Mean Absolute Error - MAE), Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error - MAPE) ve Ortalama Hata Karenin Karekökü (Root Mean Square Error- RMSE) performans istatistikleri kullanılmış ve en küçük Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error - MAPE) değerini veren model seçilmiştir.

Sonuç olarak Türkiye elektrik enerjisi tüketim kestirimi yapay sinir ağları kullanılarak elde edilen model yardımıyla yapılan kestirimin Box-Jenkins AR(1) modeli yardımıyla yapılan kestirimden daha iyi performans gösterdiği MAPE performans ölçütü yardımıyla söylenebilir.

Çalışmada kullanılan Box Jenkins yöntemi doğrusal zaman serilerinin kestiriminde başarılı olmasına karşın doğrusal olmayan zaman serilerinde başarı oranı azalmaktadır. Yapay sinir ağları ise doğrusal olmayan zaman serilerinde öğrenme ve genelleme yapabilme özelliği sayesinde başarı göstermektedir. Ancak yapay sinir ağları B.J.yönteminde olduğu gibi analizler yapılarak uygun model seçilememektedir. Yani ağın çıkarmış olduğu sonuçları nasıl ve neden çıkardığını açıklayamadıklarından (kapalı kutu) (black box) dolayı bazı olumsuz sonuçlar doğurabilir.

Her iki modelinde avantajlı ve dezavantajlı yönleri bulunmaktadır. İncelenen probleme göre seçilen YSA modeli B.J yöntemi ile desteklenmesi hem kurulan modelin doğruluğunu denetlenmesini hem de daha güvenilir sonuçlar elde edilmesini sağlayacaktır.

KAYNAKLAR

- [1] <http://ekutup.dpt.gov.tr/enerji/oik585.pdf> , 28 Aralık 2010.
- [2] <http://www.sempozyum1.dmi.gov.tr/FILES/PDF/187.pdf> , 28 Aralık 2010.
- [3] <http://tdkterim.gov.tr> , 28 Aralık 2010.
- [4] <http://www.enerji.gov.tr> , 28 Aralık 2010.
- [5] **Aitchison J. & Dunsmore I.R.**, 1980, Statistical Prediction Analıysis, Cambridge University Press, New York.
- [6] **Prof. Dr. Çömlekçi N.**, 1998, Temel İstatistik İlke ve Teknikleri, Bilim Teknik Yayınevi, Eskişehir.
- [7] **T.C. Milli Eğitim Bakanlığı**, 2006, Kişisel Gelişim İş Güvenliği ve İşçi Sağlığı, Mesleki Eğitim ve Öğretim Sisteminin Güçlendirilmesi Projesi, Ankara.
- [8] **Prof. Dr. Yüzer, A., & Diğerleri**, 2009, İstatistik, Anadolu Üniversitesi Yayını, Eskişehir.
- [9] **Özdemir, Ö.**, 2008, Zaman Serisi Modellemesinde Yapay Sinir Ağlarının Kullanımı ve Bir Uygulama, Yüksek Lisans Tezi, Anadolu Üniversitesi İstatistik Anabilim Dalı, Eskişehir.
- [10] **Spiegel Murray R., Ph. D. Stephens Larry J.**, 1999, Teori ve Problemlerle İstatistik, Nobel Yayın Dağıtım, İstanbul.
- [11] **Prof. Dr. Korum U.**,1986, İstatistiğe Giriş, Savaş Kitap ve Yayımlar Evi, Ankara.
- [12] **Prof. Dr. Serper Ö.**, 1996, Uygulamalı İstatistik 2, Filiz Kitapevi, İstanbul.

- [13] **İpek M.**, 1988, Betimsel İstatistik, Beta Basım, İstanbul.
- [14] **Prof. Dr. Kutsal, A., Prof. Dr. Alpan O., & Prof. Dr. Arpacık R.**, 1990, İstatistik Uygulamalar, Hacettepe Üniversitesi Veteriner Fakültesi, Ankara.
- [15] **Prof. Dr. Turanlı, M., Prof. Dr. Güriş, S., & Prof. Dr. Ayaydın A.**, 1995, İstatistik Temel Kavramlar Ve Uygulamalar, Der Yayınları, İstanbul.
- [16] **Prof. Dr. Çakıcı M., Yrd. Doç. Dr. Oğuzhan A., & Yrd. Doç. Dr. Özdil T.**, 2003 Temel İstatistik 2, İstanbul.
- [17] **Legendre P., & Legendre L.**, 1998, Numerical Ecology, Elsevier Science B.V., Amsterdam.
- [18] **Dr. Özmen A.**, 1986, Zaman Serisi Analizinde Box- Jenkins Yöntemi ve Banka Mevduat Tahmininde Uygulama Denemesi, Anadolu Üniversitesi Yayınları, Eskişehir .
- [19] **Göktaş Ö.**, 2005, Teorik ve Uygulamalı Zaman Serileri Analizi, Beşir Kitapevi, İstanbul.
- [20] **Nargeleçekenler M., Sevüktekin M., & Ekonometrik Zaman Serileri Analizi**, 2010, Nobel Yayın Dağıtım, Ankara.
- [21] **Schwartz Maurice L.**, 2005, Ecyclopedia of Coastal Science, Springer, Netherlands.
- [22] **Dr. Bozkurt H.**, 2007, Zaman Serileri Analizi, Ekin Kitapevi, Ankara.
- [23] **Öğr. Gör. Özmen A.**, 1986, Zaman Serisi Analizinde Box-Jenkins Yöntemi ve Banka Mevduat Tahmininde Uygulama Denemesi, Doktora Tezi, Anadolu Üniversitesi, Eskişehir.
- [24] **Kahraman, F. & Bilirgen, F.**, 2004, Oto Korelasyonlu Verilerde Proses Kontrol Tekniklerinin Uygulanması, Ç.Ü.Müh. Mim. Fak.Dergisi, **19**, 205-216.
- [25] **Dr. M. Efe Ö., & Prof. Dr. Kaynak O.**, 2000, Yapay Sinir Ağları ve Uygulamaları, Boğaziçi Üniversitesi, İstanbul.

- [26] **Prof. Dr. Öztemel E.**, 2006, Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul.
- [27] **Prof. Dr. Elmas Ç.**, 2003, Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama), Seçkin Yayıncılık, Ankara .
- [28] **Mehrotra K., K. Mohan C., & Ranka S.**, 1996, Elements of Artificial Neural Networks, The MIT Press.
- [29] **Yıldız B.**, 2009, Finansal Analizde Yapay Zeka, Beta Basım, İstanbul.
- [30] **Haykin S.**, 1999, Neural Networks, Prentice Hall, New Jersey.
- [31] **Taner A., Gültekin, S., & Çarman, K.**, 2010, Yapay Sinir Ağları İle Radyal Santrifüj Pompa Parametrelerinin Tahmini, Selçuk Tarım ve Gıda Bilimleri Dergisi, 24 ,28-38
- [32] **Şen, Z.**,2004, Yapay Sinir Ağları İlkeleri, Su Vakfı, İstanbul.
- [33] **Yurtoğlu, H.**, 2005, Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği, Uzmanlık Tezi, Ekonomik Araştırmalar Ve Stratejik Araştırmalar Genel Müdürlüğü.
- [34] **Zurada, J. M.**, 1995, Introduction to Artificial Neural Systems, PWS Publishing Company, Boston.
- [35] **Kartalopoulos S. V.**, 1996, Understanding Neural Network and Fuzzy Logic, IEEE Press., New York.
- [36] **Fu L.**, 1994, Neural Networks In Computer Intelligence, Mc Grow-Hill, Singopore.
- [37] **Babalık A.**, 2007, Yapay Sinir Ağları İle Buğday Tanelerinin Kalite Tespiti, Doktora Tezi Selçuk Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı,Konya.
- [38] **Chow, Tommy W. S., & Chow, Siu-Yeung**, 2007, Neural Networks and Computing Learning Algorithms and Applications, Imperial College Press, London.

[39] <http://e-imo.imo.org.tr/DosyaDizin/WPX/Portal/Yayin/td/Cilt15/15-3-3MahmutFirat.pdf> 20 Aralık 2010

[40] **P. Yzb. Saygılı, Y. S.**, 2008, İstatistiksel Yöntemlerle Yapay Sinir Ağları Uygulamalarının Karşılaştırılması: Milli Savunma Bakanlığı Bütçesinin Öngörülmesi, Yüksek Lisans Tezi, Kara Harp Okulu Savunma Bilimleri Enstitüsü Harekat Araştırması Ana Bilim Dalı, Ankara.

[41] **Bıçen, Ç.**, 2006, Box-Jenkins Zaman Serisi Analiz Yöntemi İle İleri Beslemeli Yapay Sinir Ağları Tahminlerinin Karşılaştırması, Hacettepe Üniversitesi, Sağlık Bilimleri Enstitüsü , Biyoistatistik Programı, Ankara.

[42] **Çelik, B.**, 2008, Yapay Sinir Ağları Metodolojisi İle Zaman Serisi Analizi: Teori ve Uygulama, Yüksek Lisans Tezi, Marmara Üniversitesi, Sosyal Bilimler Enstitüsü Ekonometri Anabilim Dalı, Ekonometri Bilim Dalı, İstanbul.

[43] <http://tez.sdu.edu.tr/Tezler/TF01364.pdf> 18 Aralık 2010.

[44] **Erpolat S.**, 2010, Verileri Sınıflandırmada Farklı Bir Tasarım: Hibrit Sınıflandırma Sistemi, 19. İstatistik Araştırma Sempozyumu Bildiriler Kitabı.

[45] **Erpolat S.**,2009, Akademik Başarımın Sınıflandırılmasında Farklı Yöntemlerinin Karşılaştırılması, 18. İstatistik Araştırma Sempozyumu Bildiriler Kitabı.

[46] **Bayır, F.**, 2006, Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama, Yüksek Lisans Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı Sayısal Yöntemler Bilim Dalı, İstanbul.

[47] <http://mbdergi.pau.edu.tr/index.php/mbdergi/article/viewFile/190/193> 19 Aralık 2010.

[48] **Çuhadar M.**, 2006, Turizm Sektöründe Talep Tahmini İçin Yapay Sinir Ağları Kullanımı ve Diğer Yöntemlerle Karşılaştırmalı Analizi (Antalya İlinin Dış Turizminde Uygulama), Doktora Tezi, Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Isparta.

[49] http://www.itudergi.itu.edu.tr/tammetin/itu-d_2008_7_6_R_Demir.pdf 20 Aralık 2010.

[50] http://www.arastirmax.com/bilimsel_yayin/845/4/121-130_yapay-sinir-a%C4%9Flari-ile-at%C3%B6lgeleme-tasarimi 20 Aralık 2010.

[51] **Yerdelen, C.**,2006, Mevsimlik Kar Erimesinin Yapay Sinir Ağları Yöntemi İle Tahmin Edilmesi, S.Ü. Müh. Mim. Fak. Dergisi, **21**, 3-4.

[52] **Erdoğan, E.**, 2006, Zaman Serilerinde Arima Modelleri, Yüksek Lisans Tezi, Muğla Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik ve Bilgisayar Bilimleri Anabilim Dalı, Muğla

[53] **Akıncı, M.**, 2008, Zaman Serilerinde Durağanlık Analizi ve İhracatın GSMH İçindeki Payı Üzerine Bir Uygulama, Yüksek Lisans Tezi, Kafkas Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Kars

EKLER

EK-A : TÜRKİYE ELEKTRİK ENERJİSİ TÜKETİMİ (1923-2009)

EK-B : AR(1) MODELİ KESTİRİM DEĞERLERİ (1924-2009)

EK-A

YIL	GWh
1923	41.3
1924	41.3
1925	41.9
1926	60.6
1927	63.4
1928	81.4
1929	88.9
1930	96.7
1931	106
1932	117.5
1933	136.2
1934	157.7
1935	199.6
1936	206.8
1937	257.7
1938	279.9
1939	316.8
1940	359.3
1941	377.6
1942	372.5
1943	395.7
1944	429.9
1945	459
1946	487
1947	541.2
1948	585.7
1949	633.9
1950	678.8
1951	764
1952	878.5
1953	1012.5
1954	1191.5
1955	1347.3
1956	1544.8
1957	1757
1958	1961.5
1959	2170.5
1960	2395.7
1961	2585.4
1962	3059.3

YIL	GWh
1963	3406.3
1964	3780.7
1965	4236.8
1966	4728.9
1967	5269.2
1968	5870.1
1969	6679
1970	7307.8
1971	8289.3
1972	9527.3
1973	10530.1
1974	11358.7
1975	13491.7
1976	16078.9
1977	17968.8
1978	18933.8
1979	19663.1
1980	20398.2
1981	22030
1982	23586.8
1983	24465.1
1984	27635.2
1985	29708.6
1986	32209.7
1987	36697.3
1988	39721.5
1989	43120
1990	46820
1991	49282.9
1992	53984.7
1993	59237
1994	61400.9
1995	67393.9
1996	74156.6
1997	81885
1998	87704.6
1999	91201.9
2000	98295.7
2001	97070
2002	102948

YIL	GWh
2003	111766
2004	121141.9
2005	130262.9
2006	143070.5
2007	155135.2
2008	161947.6
2009	156894.1

EK-B

YIL	FGWh
1923	
1924	46.96326
1925	53.35354
1926	60.5575
1927	68.6713
1928	77.80152
1929	88.06618
1930	99.59588
1931	112.535
1932	127.0429
1933	143.2956
1934	161.487
1935	181.8308
1936	204.5619
1937	229.939
1938	258.2459
1939	289.7944
1940	324.9263
1941	364.0162
1942	407.4742
1943	455.7489
1944	509.3307
1945	568.7551
1946	634.6065
1947	707.522
1948	788.1957
1949	877.3834
1950	975.9069
1951	1084.66
1952	1204.611
1953	1336.815
1954	1482.412
1955	1642.64
1956	1818.836
1957	2012.45
1958	2225.047
1959	2458.319
1960	2714.091
1961	2994.332
1962	3301.165
1963	3636.876

YIL	FGWh
1964	4003.923
1965	4404.954
1966	4842.81
1967	5320.545
1968	5841.436
1969	6408.998
1970	7026.994
1971	7699.46
1972	8430.71
1973	9225.36
1974	10088.34
1975	11024.93
1976	12040.74
1977	13141.78
1978	14334.43
1979	15625.51
1980	17022.26
1981	18532.4
1982	20164.13
1983	21926.15
1984	23827.73
1985	25878.66
1986	28089.36
1987	30470.86
1988	33034.84
1989	35793.67
1990	38760.43
1991	41948.94
1992	45373.83
1993	49050.52
1994	52995.3
1995	57225.33
1996	61758.73
1997	66614.56
1998	71812.9
1999	77374.88
2000	83322.72
2001	89679.78
2002	96470.58
2003	103720.9
2004	111457.7

YIL	FGWh
2005	119709.5
2006	128505.8
2007	137877.8
2008	147858.1
2009	158480.7