



T. C.

BURSA ULUDAĞ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
EKONOMETRİ ANABİLİM DALI
İSTATİSTİK BİLİM DALI

**ELEKTRİK TALEBİNİN ZAMAN SERİSİ ANALİZİ,
YAPAY SİNİR AĞLARI VE HİBRİT YÖNTEM İLE
TAHMİNİ**

(DOKTORA TEZİ)

Savaş TARKUN

BURSA – 2023



T. C.

BURSA ULUDAĞ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
EKONOMETRİ ANABİLİM DALI
İSTATİSTİK BİLİM DALI

**ELEKTRİK TALEBİNİN ZAMAN SERİSİ ANALİZİ,
YAPAY SİNİR AĞLARI VE HİBRİT YÖNTEM İLE
TAHMİNİ**

(DOKTORA TEZİ)

Savaş TARKUN

Danışman

Prof. Dr. Erkan IŞIĞIÇOK

BURSA – 2023

Tez Onay Sayfası

**T. C.
BURSA ULUDAĞ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ MÜDÜRLÜĞÜNE**

Ekonometri Anabilim, İstatistik Bilim Dalı'nda **711817007** numaralı **Savaş TARKUN**'un hazırladığı **ELEKTRİK TALEBİNİN ZAMAN SERİSİ ANALİZİ, YAPAY SİNİR AĞLARI VE HİBRİT YÖNTEM İLE TAHMİNİ**" başlıklı **doktora** tezi ile ilgili savunma sınavı, **27/01/2023** günü **10:30 – 12:30** saatleri arasında yapılmıştır. Alınan cevaplar sonunda adayın **Başarılı** olduğuna **oy birliği** ile karar verilmiştir.

Üye (Tez Danışmanı ve Sınav Komisyonu
Başkanı)

Akademik Unvanı, Adı Soyadı
Üniversitesi

PROF. DR. ERKAN İŞİĞİÇOK

Üye

Akademik Unvanı, Adı Soyadı
Üniversitesi

PROF. DR. DİLEK ALTAŞ

Üye

Akademik Unvanı, Adı Soyadı
Üniversitesi

PROF. DR. AYŞE OĞUZLAR

Üye

Akademik Unvanı, Adı Soyadı
Üniversitesi

PROF. DR. MEHMET ÇINAR

Üye

Akademik Unvanı, Adı Soyadı
Üniversitesi

DR. ÖĞR. ÜY. EMRAH AKDAMAR

27/01/2023

Yemin Metni

Doktora tezi olarak sunduđum “**Elektrik Talebinin Zaman Serileri Analizi, Yapay Sinir Ağları ve Hibrit Yöntem ile Tahmini**” başlıklı çalışmanın bilimsel araştırma, yazma ve etik kurallarına uygun olarak tarafımdan yazıldığına ve tezde yapılan bütün alıntıların kaynaklarının usulüne uygun olarak gösterildiđine, tezimde intihal ürünü cümle veya paragraflar bulunmadığına şerefim üzerine yemin ederim.

Tarih ve İmza

27/01/2023

Adı Soyadı: Savaş TARKUN

Öğrenci No: 711817007

Anabilim Dalı: Ekonometri

Programı: İstatistik

Tezin Türü: ~~Yüksek Lisans~~ / Doktora / ~~Sanatta Yeterlilik~~

BURSA ULUDAĞ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
EKONOMETRİ ANABİLİM DALI BAŞKANLIĞI'NA

Tarih: 24/01/2023

Tez Başlığı / Konusu: ELEKTRİK TALEBİNİN ZAMAN SERİSİ ANALİZİ, YAPAY SİNİR AĞLARI VE HİBRİT YÖNTEM İLE TAHMİNİ

Yukarıda başlığı gösterilen tez çalışmamın a) Kapak sayfası, b) Giriş, c) Ana bölümler ve d) Sonuç kısımlarından oluşan toplam XII+148 sayfalık kısmına ilişkin, 27/12/2022 tarihinde şahsım tarafından Turnitin adlı intihal tespit programından (Turnitin)* aşağıda belirtilen filtrelemeler uygulanarak alınmış olan özgünlük raporuna göre, tezimin benzerlik oranı %10'dur.

Uygulanan filtrelemeler:

- 1- Kaynakça hariç
- 2- Alıntılar hariç/dahil
- 3- 5 kelimedenden daha az örtüşme içeren metin kısımları hariç

Bursa Uludağ Üniversitesi Sosyal Bilimler Enstitüsü Tez Çalışması Özgünlük Raporu Alınması ve Kullanılması Uygulama Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.

24/01/2023

Adı Soyadı: Savaş TARKUN
Öğrenci No: 711817007
Anabilim Dalı: Ekonometri
Programı: İstatistik
Statüsü: Y.Lisans Doktora

Danışman:

PROF. DR. ERKAN IŞIĞIÇOK

* Turnitin programına Bursa Uludağ Üniversitesi Kütüphane web sayfasından ulaşılabilir.

ÖZET

Yazar adı soyadı	Savaş Tarkun
Üniversite	Bursa Uludağ Üniversitesi
Enstitü	Sosyal Bilimler Enstitüsü
Anabilim dalı	Ekonometri
Bilim dalı	İstatistik
Tezin niteliği	<i>Doktora</i>
Mezuniyet tarihi	27/01/2023
Tez danışmanı	Prof. Dr. Erkan IŞIĞIÇOK

ELEKTRİK TALEBİNİN ZAMAN SERİSİ ANALİZİ, YAPAY SİNİR AĞLARI VE HİBRİT YÖNTEM İLE TAHMİNİ

Elektrik; sürdürülebilir yaşamda önemli bir rol oynayan ve çeşitli sektörlerle katma değeri çok yüksek olan enerji türüdür. Elektrik, sosyo-ekonomik kalkınmada stratejik önemde bulunduğu için ekonomik refahın ve büyümenin en önemli aktörlerindedir. Yapısı gereği depolanamayan ve üretildiği anda tüketilmesi gereken bu enerji türü, ekonomik kalkınmanın tüm yönleri ile entegre olması ve aynı zamanda tek bir modelin her zaman doğru tahminleri vermemesi sebebi ile elektrik talep tahmini çalışmaları her dönem güncelliğini korumuştur. Dolayısıyla bu tez çalışmasında elektrik talep tahmini farklı yöntem ve modeller ile tahmini gerçekleştirilmiştir.

Tez çalışmasında, uygulama dönemi, 2007:01 – 2020:12 belirlenmiştir. Bu dönemin belirlenmesindeki en önemli sebep ise ekonomi ve sosyal hayatta yaşanan birtakım olumsuzlukların bulunmasıdır. Çalışma, tek değişkenli ve çok değişkenli olmak üzere iki farklı uygulama ile gerçekleştirilmiştir. Tek değişkenli modellerde, brüt elektrik talep miktarı kullanılırken, çok değişkenli model çalışmalarında ise brüt elektrik talep miktarı, tüketici fiyat endeksi, sanayi üretim endeksi, ülkeye gelen turist sayısı ve işsizlik değişkenleri kullanılmıştır. Zaman serisi modellerine ilişkin uygulamalar Eviews 10 paket programı ile gerçekleştirilirken yapay sinir ağı ve hibrit yöntem uygulamaları MATLAB ile yapılmıştır.

Yapılan uygulama sonuçlarında, resmi makamlarca açıklanan 2021:01-2021:10 dönemi talep miktarı ile tek değişkenli ve çok değişkenli modeller ile tahmin edilen talep miktarları karşılaştırılmış ve istatistiksel performans kriterlerine göre en düşük hata değerlerine sahip olan model çok değişkenli yapay sinir ağı mimarisi olmuştur. Çalışma bu noktadan sonra 2022:07 dönemine kadar talep tahmini gerçekleştirilmiş ve çok değişkenli yapay sinir ağı mimarisi ile hibrit yöntem benzer dalgalanmalar sergilemiştir. Bu dönem için çok değişkenli yapay sinir ağına göre 28519.12993 GWh olarak tahmin edilirken tek değişkenli yapay sinir ağına göre ise 27009.25479 GWh tahmin edilmiştir.

Anahtar kelimeler: Elektrik Talep Tahmini, Hibrit Yöntem, Koşullu Değişen Varyans, Vektör Otoregresif Model, Yapay Sinir Ağı

ABSTRACT

Name & surname	Savaş Tarkun
University	Bursa Uludağ University
Institute	Institute of Social Sciences
Field	Econometrics
Subfield	Statistics
Degree awarded	<i>PhD.</i>
Date of degree awarded	27/01/2023
Supervisor	Prof. Dr. Erkan IŞIĞIÇOK

ESTIMATION OF ELECTRICITY DEMAND WITH TIME SERIES ANALYSIS, ARTIFICIAL NEURAL NETWORKS, AND A HYBRID METHOD

Electricity is a type of energy that plays an important role in sustainable life and has a very high added value in changing sectors. Electricity is one of the most important actors in economic prosperity and growth, as it has strategic importance in socio-economic development. This type of energy, which cannot be stored due to its nature and must be consumed as soon as it is produced, has always been up-to-date in electricity demand forecasting studies since it is integrated with all aspects of economic development, and at the same time, a single model does not always give accurate forecasts. Therefore, in this thesis, electricity demand forecasting was carried out with different methods and models. The application period for the thesis study is January 2007–December 2020. The most important reason for determining this period is the existence of some negativities in economic and social life. The study was carried out with two different applications as univariate and multivariate. In univariate models, gross electricity demand amount is used, while in multivariate model studies, gross electricity demand amount, consumer price index, industrial production index, number of tourists coming to the country, and unemployment variables are used. While applications related to time series models were carried out with Eviews 10 package program, artificial neural network and hybrid method applications were made with MATLAB.

In the results of the application, the demand amount for the period January 2021–November 2021 announced by the official authorities and the estimated demand amounts with univariate and multivariate models were compared, and the model with the lowest error values according to statistical performance criteria was the multivariate artificial neural network architecture. After this point, demand forecasting was carried out until July 2022, and the multivariate artificial neural network and hybrid method exhibited similar fluctuations. For this period, it was forecast as 28519.12993 GWh according to the multivariate artificial neural network, while it was forecast as 27009.25479 GWh according to the univariate artificial neural network.

Keywords: Electricity Demand Forecast, Hybrid Method, Autoregressive Conditional Heteroscedasticity, Vector Autoregressive Models, Artificial Neural Network

ÖNSÖZ

Yeryüzündeki birçok kaynak gibi, elektrik enerjisi de kıt kaynaktır. Dolayısıyla, kıt kaynakların en iyi şekilde kullanımı, ekonomik verimliliğe dayanmaktadır. Elektrik, yeniden üretim, modern hayatın sürdürülebilirliği, temel hizmetlerin sağlanabilmesi, yaşam standartlarının desteklenmesi, ülkelerin gelişebilmesi ve dolayısıyla sanayinin kalkınabilmesi için gerekli olan en önemli enerji kaynağıdır. Elektrik arzının verimli bir şekilde değerlendirilebilmesi için elektrik talebini etkileyen içsel değişkenlerin zamanla değişmesinden dolayı, her dönem elektrik talep tahmin çalışmalarına ihtiyaç duyulmaktadır. “**Elektrik Talebinin Zaman Serileri Analizi, Yapay Sinir Ağı ve Hibrit Yöntem ile Tahmini**” başlıklı doktora tezim, elektrik talep tahmin yöntemlerine farklı bir bakış açısı sunmuştur. Dolayısıyla; bu tezimin, ulusal enerji projeksiyonlarına, dağıtım-iletim şirketlerine ve konu ile ilgilenen çalışmacılara faydalı olmasını diliyorum. Ayrıca, doktora öğrenimim boyunca, akademik yetkinliklerimin temellerini bana kazandıran ve kendisinden çok şey öğrendiğim, çalışmayı sevdiren ve yönlendiren, her an fikir alışverişinde bulunabildiğim, özellikle de her konudaki desteğini hiçbir zaman esirgemeyen, çok kıymetli Danışman Hocam, **Prof. Dr. Erkan IŞIĞIÇOK**’a sonsuz teşekkürü bir borç bilirim. Ayrıca tez yazım sürecimde katkılarını esirgemeyen **Prof. Dr. Mehmet Çınar**’a ve **Dr. Öğr. Üyesi Emrah Akdamar**’a ve doktora jürimde bulunan ve katkılarını esirgemeyen Hocalarım **Prof. Dr. Ayşe OĞUZLAR**’a ve **Prof. Dr. Dilek ALTAŞ**’a teşekkürlerimi sunarım.

Varlıklarını hiçbir zaman esirgemeyen her zaman yanımda olan annem ve babama, desteği ile hep yanımda olan sevgili eşim ile biricik kızım Defne’ye ithaf ediyorum.

İÇİNDEKİLER

TEZ ONAY SAYFASI.....	Hata! Yer işareti tanımlanmamış.
YEMİN METNİ	v
ÖZET.....	iii
ABSTRACT	iv
ÖNSÖZ.....	v
İÇİNDEKİLER	vi
TABLolar LİSTESİ.....	x
ŞEKİLLER LİSTESİ	xi
KISALTMALAR	xiii
GİRİŞ	1

BİRİNCİ BÖLÜM

ZAMAN SERİSİ MODELLERİNİN TEORİK YAPISI

1.1. ZAMAN SERİLERİNE İLİŞKİN BAZI TEMEL KAVRAMLAR	4
1.1.1. Durağanlık	5
1.1.2. Trend	7
1.1.3. Mevsimsellik.....	8
1.2. BİRİM KÖK TESTLERİ.....	9
1.2.1. ADF (Augmented Dickey-Fuller) Birim Kök Testi	10
1.2.2. KPSS (Kwiatkowski, Philips, Schmidt, Shin) Birim Kök Testi.....	12
1.3. OTOREGRESİF HAREKETLİ ORTALAMA (ARIMA) MODELLERİ.....	13
1.3.1. Oto regresif Model (AR)	13
1.3.2. Hareketli Ortalama Modeli (MA).....	14

1.3.3. Otoregresif Hareketli Ortalama Modeli (ARMA).....	15
1.3.4. ARIMA Modeli	16
1.4. KOŞULLU DEĞİŞEN VARYANS MODELLERİ.....	17
1.4.1. Otoregresif Koşullu Değişen Varyans (ARCH) Modeli	18
1.4.2. ARCH (p) Modeli.....	19
1.4.3. Olabilirlik Fonksiyonu	21
1.4.4. ARCH Regresyon Modelinin Tahmini.....	23
1.5. GENELLEŞTİRİLMİŞ OTOREGRESİF KOŞULLU DEĞİŞEN VARYANS (GARCH) MODELİ.....	26
1.5.1. GARCH(p,q) Modeli.....	26
1.5.2. GARCH(1,1) Süreci	28
1.5.3. GARCH Regresyon Modelinin Tahmini.....	30
1.6. ARCH-GARCH BOZUKLUKLARININ TESTİ (ARCH-LM TESTİ)	32
1.7. ARCH-GARCH MODELLERİNE İLİŞKİN KISITLAMALAR.....	34
1.8. VEKTÖR OTOREGRESİF (VAR) MODELLERİ.....	35
1.8.1. Nedensellik Analizi (Testi).....	38
1.8.1.1. Granger Nedensellik Testi.....	39
1.8.1.2. Toda Yamamoto Nedensellik Testi	42
1.8.2. Varyans Ayırıştırması.....	43
1.8.3. Etki-Tepki Fonksiyonları	46

İKİNCİ BÖLÜM

YAPAY SİNİR AĞLARI TEORİK YAPISI VE HİBRİT YÖNTEM

2.1. YAPAY SİNİR AĞLARI.....	51
2.1.1. Yapay Sinir Ağlarının Tarihsel Gelişimi.....	52
2.2. YAPAY PROSESİN ELEMANLARI	54

2.3. YAPAY SİNİR AĞLARININ EĞİTİM SÜREÇLERİ VE ÖĞRENME ÖZELLİKLERİ	57
2.4. YAPAY SİNİR AĞLARININ TEMEL KATMANLARI.....	58
2.5. YAPAY SİNİR AĞI MİMARİLERİ.....	59
2.5.1. Tek Katmanlı - İleri Beslemeli Ağ	59
2.5.2. Çok Katmanlı - İleri Beslemeli Ağ.....	60
2.6. ÇOK KATMANLI ALGILAYICI	61
2.6.1. Çok Katmanlı Algılayıcıların Çalışma Prensipleri.....	62
2.6.2. Çok Katmanlı Algılayıcıların Eğitim Süreci	63
2.6.3. Geri Yayılım Algoritması.....	64
2.6.3.1. Geri Yayılım Algoritmasının Çalışma Prensipleri	65
2.6.3.2. Geri Yayılım Algoritmasının Türetilmesi	65
2.6.4. Geri Yayılım Algoritmasının Optimize Edilmiş Türleri	71
2.7. HİBRİT MODEL	75
2.7.1. Zhang ARIMA-YSA Hibrit Model Yaklaşımı.....	75
2.7.2. Khashei – Bijari Hibrit Model Yaklaşımı	76
2.7.3. Babu – Reddy Hibrit Model Yaklaşımı.....	77
2.7.4. Roh Hibrit Model Yaklaşımı	77

ÜÇÜNCÜ BÖLÜM

UYGULAMA

3.1. LİTERATÜR TARAMASI	80
3.2. KOŞULLU DEĞİŞEN VARYANS UYGULAMASI.....	89
3.2.1. Elektrik Talebine İlişkin Koşullu Değişen Varyans Modellerinin Tahmini	92
3.3. ELEKTRİK TALEBİNİ ETKİLEYEN FAKTÖRLERİN VEKTÖR OTOREGRESİF MODEL İLE BELİRLENMESİ.....	95

3.3.1. VAR Modelinde Kullanılan Değişkenlere İlişkin Birim Kök Testleri.....	96
3.3.2. VAR Modelinin Uygun Gecikme Genişliğinin Belirlenmesi	99
3.3.3. VAR Modeline İlişkin Nedensellik Analizi Bulguları	101
3.3.3.1. Granger Nedensellik Bulguları.....	102
3.3.3.2. Toda Yamamoto Nedensellik Bulguları.....	103
3.3.4. Varyans Ayrıştırması Bulguları.....	105
3.3.5. Etki Tepki Fonksiyonu	109
3.4. YAPAY SİNİR AĞI UYGULAMA BULGULARI.....	114
3.4.1. Tek Değişkenli Yapay Sinir Ağı Bulguları	114
3.4.2. Çok Değişkenli Yapay Sinir Ağı Uygulaması	120
3.5. HİBRİT YÖNTEM UYGULAMASI	124
3.6. TAHMİN EDİLEN MODELLERİN PERFORMANSLARININ DEĞERLEDİRİLMESİ.....	128
3.7. ELEKTRİK TALEBİNİN FARKLI MODELLER İLE TAHMİNİ.....	129
SONUÇ ve DEĞERLENDİRME.....	137
KAYNAKÇA	142

TABLolar LİSTESİ

Tablo 1: Toplama Fonksiyonları Örnekleri.....	56
Tablo 2: Uygun ARMA Modelinin Belirlenmesi	93
Tablo 3: ARCH-LM Test Sonucu	93
Tablo 4: Koşullu Değişen Varyans Analiz Sonuçları	94
Tablo 5: Düzey Birim Kök Testi Sonuçları	97
Tablo 6: Birinci Farkı Alınan Değişkenlerin Birim Kök Sonuçları.....	98
Tablo 7: Uygun Gecikme Uzunluğunun Belirlenmesi.....	100
Tablo 8: Granger Nedensellik Testi Sonuçları.....	102
Tablo 9: Toda Yamamoto Nedensellik Testi Sonuçları.....	104
Tablo 10: Elektrik Talebi Değişkenine İlişkin Sonuçlar.....	105
Tablo 11: Tüketici Fiyat Endeksi Değişkenine İlişkin Sonuçlar	106
Tablo 12: Sanayi Üretim Endeksine İlişkin Sonuçlar	107
Tablo 13: Ülkeye Gelen Turist Sayısı Değişkenine İlişkin Sonuçlar	108
Tablo 14: İşsizlik Değişkenine İlişkin Sonuçlar	109
Tablo 15: En İyi Performans Sergileyen Mimariler.....	115
Tablo 16: En Kötü Performans Sergileyen Mimariler	116
Tablo 17: Çok Değişkenli Ağ Mimarilerinin Performansları	121
Tablo 18: En İyi Performans Gösteren Mimariler	125
Tablo 19: Tahmin Modellerinin Karşılaştırma İstatistikleri	129
Tablo 20: Elektrik Talep Tahmini.....	131
Tablo 21: Tahmin Mimarilerinin Karşılaştırılması	134

ŞEKİLLER LİSTESİ

Şekil-1: Tek Katmanlı - İleri Beslemeli Ağ Örneği.....	60
Şekil-2: Çok Katmanlı - İleri Beslemeli Ağ Örneği.....	61
Şekil-3: Çok Katmanlı Bir Algılayıcı Ağı	62
Şekil-4: MLP Ağının Her İki Eğitim Aşamasının Görünümü	64
Şekil-5: Geri Besleme Algoritması Örneği	65
Şekil-6: Hata Sinyallerinin Geri Yayılımına İlişkin Bir Bölümünün Sinyal Akışı.....	69
Şekil-7: Elektrik Talebinin Zaman Yolu.....	90
Şekil-8: Sanayi Sektörü Elektrik Tüketim Oranı (%)	90
Şekil-9: AR Karakteristik Köklerin Birim Çember Konumları	101
Şekil-10: Elektrik Talebinin Elektrik Talebine Tepkisi	110
Şekil 11: TALEP ve TÜFE'nin Etki Tepki Şekilleri	111
Şekil 12: TALEP ve SUE Etki Tepki Şekilleri	112
Şekil-13: TALEP ve TUR Etki Tepki Şekilleri	112
Şekil-14: TALEP ve ISSIZ Etki Tepki Şekilleri.....	113
Şekil-15: En iyi Performans Sergileyen Mimari	116
Şekil-16: 12 nöron 4 gecikmeli Ağın Performansı	117
Şekil-17: Hataların Histogram Grafiği.....	118
Şekil-18: Veri Setlerinin Regresyon Performansları.....	119
Şekil-19: Zaman Serisine Çıktının Tepkisi.....	120
Şekil-20: 10 Nöron ile Elde Edilen YSA Mimarisi	121
Şekil-21: 10 Nöron ile Oluşturulan Ağın Performansı	122
Şekil-22: Hataların Histogram Grafiği.....	123
Şekil-23: Veri Setlerinin Regresyon Performansları.....	123
Şekil 24: 9 Nöron ve 4 Gecikmeli Ağın Performansı	126

Şekil 25: Veri Kümelerinin Regresyon Performansları	126
Şekil-26: Zaman Serisine Çıktının Tepkisi	127
Şekil-27: YSA-NAR mimarisine ilişkin kapalı döngü	130
Şekil-28: YSA-NAR Mimarisinin Öngörüsü.....	130
Şekil-29: Tahmin Sonuçlarının Karşılaştırılması.....	132
Şekil-30: Hibrit Modele Göre Elektrik Talebinin Oynaklık Tahmini.....	133
Şekil-31: Gerçekleşmiş Değerlerin Tahmin Değerleri ile Karşılaştırılması	134
Şekil-32: YSA-NAR ve YSA-Çoklu Tahmin Karşılaştırılması	135
Şekil-33: Hibrit Oynaklık Tahmini (Forecast).....	136

KISALTMALAR

ADF	Augmented Dickey-Fuller
AR	Otoregresif Model
ARCH	Otoregresif Koşullu Değişen Varyans
ARIMA	Otoregresif Entegre Edilmiş Hareketli Ortalama
ARMA	Otoregresif Hareketli Ortalama
BIST	Borsa İstanbul
EPDK	Enerji ve Tabii Kaynaklar Bakanlığı
GARCH	Genelleştirilmiş Otoregresif Koşullu Değişen Varyans
GSMH	Gayri Safi Milli Hasıla
GSYİH	Gayri Safi Yurtiçi Hasıla
ISSIZ	İşsizlik Oranı
KPSS	Kwiatkowski, Philips, Schmidt, Shin
MA	Hareketli Ortalama Modeli
MATLAB	Matrix Laboratory (Matris Laboratuvarı)
MLP	Çok Katmanlı Algılayıcı
OLS	Olağan En Küçük Kareler
PDP	Paralel Dağıtılmış İşleme
SUE	Sanayi Üretim Endeksi
TALEP	Brüt Elektrik Talebi
TCMB	Türkiye Cumhuriyeti Merkez Bankası
TEİAŞ	Türkiye Elektrik İletim Anonim Şirketi
TUFE	Tüketici Fiyat Endeksi
TÜİK	Türkiye İstatistik Kurumu
TUR	Ülkeye Gelen Turist Sayısı
TY	Toda Yamamoto
VAR	Vektör Otoregresif Model
VMA	Vektör Hareketli Ortalama
YSA	Yapay Sinir Ağı

GİRİŞ

Tarih boyunca hayatını kolaylaştırmak, rahat ve konforlu bir yaşam sürebilmek isteyen insanoğlu, birtakım yenilikleri keşfetmeye yönelmiştir. Yerleşik yaşam ile birlikte, üretilen ürünlerin miktarlarının artmaya başlaması (arz fazlası) ve meydana gelen bu fazla üretimin pazarlanması düşüncesi ile harekete geçme ihtiyacı, birinci sanayi devrimine kadar atlı, su gücü ve rüzgâr gücünden oluşmaktaydı. Ancak bu araçların yetersiz kalması ve uzaklara gidilmemesi nedeniyle; insanoğlunu, enerjinin keşfine yöneltmiştir. Birinci sanayi devrimi ile birlikte, buharın döndürme gücünün keşfi, dokumacılıktan ulaşıma kadar her alanda bu gücün kullanılmaya başlanması ile çok daha fazla üretme ve daha uzak ülkelere ulaşma olanağını sunmuştur. Farklı dönemlerde farklı deneyler ile varlığı ispat edilmeye çalışılan elektrik, bu keşiflerin en önemlilerinden biri olmuştur.

Elektrik; yaşamın devamı, teknolojinin ilerleyebilmesi ve sanayinin gelişebilmesi için stratejik öneme sahip ikincil bir enerji kaynağıdır. Ayrıca elektrik, yeniden üretim ve hayatın sürekliliği için gerekli bir kaynak olmakla birlikte, ekonomilerin gelişmesi ve dolayısıyla, yaşam kalitesinin iyileştirilmesi için de önemli bir kaynaktır. Özellikle, sanayi üretiminde stratejik bir yeri bulunan bu kaynağın (elektriğin), yaşam standartlarını desteklemesi ve temel hizmetlerin sağlanabilmesi için de önemlidir.

Elektrik enerjisi kıt kaynak olup, kıt kaynakların en iyi şekilde kullanımı ise ekonomik verimliliğe dayanmaktadır. Kuşkusuz, özellikle gelişmekte olan ülkelerin, enerji planlamasında, elektrik enerjisi önemli yer tutmaktadır. Dolayısıyla, bu enerji türünün talep tahmini de önem kazanmaktadır. Elektrik talebinin doğru ve en küçük hata ile öngörülmemesi, arz-talep dengesinin bozulmasına neden olmaktadır. O halde, bu dengenin bozulması, enerji açığı veya fazlalığının oluşmasına neden olurken; talebin, arzdan fazla olması durumunda; elektrik açığının oluşmasına, elektrik kesintilerine ve sistemsel darboğazlar gibi birtakım olumsuzluklara neden olacaktır. Elektrik arzının, talepten fazla olması durumunda ise mevcut elektriğin israfına yol açacaktır. Kuşkusuz, elektrik arzını verimli bir şekilde değerlendirebilmek için de elektrik talebinin doğru bir şekilde tahmin edilmesi gerekmektedir. Yukarıda sayılan bu gibi nedenlerden dolayı; elektrik talebinin tahmini, ekonomik ve sosyal hayatta her zaman önemini korumaktadır.

Elektrik talebi, bir ülkenin veya bölgenin; saatlik, günlük, aylık, vb. zaman dilimlerinde farklılıklar gösterebilmektedir. Talebin farklı periyotlarda, farklı miktarlarda oluşması, talebin kendine has yapısı ve elektriğin stoklanamaması nedeniyle, elektrik talebinin karşılanması hem üretim hem de tüketim boyutu ile yakından ilişkilidir. Elektrik tüketim verileri, genellikle karmaşık ya da kararsız serilerden oluştuğundan, tek bir yöntemin her zaman diliminde ve her tahmin modelinin, doğru tahminleri vermesi beklenemez. Bu yüzden, elektrik talep tahmin çalışmaları, her dönem araştırma konusu olarak güncelliğini korumaktadır.

Yukarıda anlatılanlar doğrultusunda, bu çalışmasının temel amacı, elektrik talep tahminini hem dönem içi gerçekleşmiş değerleri ile tahmin edip karşılaştırmak hem de çalışılan mimari veya modeller ile ileriye dönük elektrik talep miktarlarını tahmin etmektir. Bu doğrultuda hem tek değişkenli hem de çok değişkenli modeller ile çalışılmıştır. Etkili modelleme ve tahmin, verinin özelliklerinden çıkarılıp geleceğe yansıtılabilmesi için mevcut verilerde bulunan bilginin verimli kullanımını gerektirmektedir. Bu amaca paralel olarak, elektrik talebinde olası oynaklığı tahmin edebilmek ve sonuç ile bağlantılı olarak elektrik talep tahmininde hibrit yöntem uygulamasıyla oynaklığın tekrar tahmin edilmesi de amaçlanmaktadır. Bu doğrultuda hem zaman serisi modelleri hem de yapay sinir ağları mimarileri ile çalışılmıştır. Bu çalışmanın bir başka amacı ise, elektrik talebine etkisi bulunan içsel (endojen) değişkenleri ve bu değişkenlerin etki düzeylerini belirlemektir. Dolayısıyla, çalışmanın yanıt aradığı sorular genel olarak şu şekilde özetlenebilir: Elektrik talep tahmininde, zaman serileri analizi modelleri mi, yapay sinir ağları mimarilerinin mi yoksa her iki yapıyı da içeren hibrit yöntemin mi daha etkili sonuçlar verebileceğinin yanıtları karşılaştırmalı olarak irdelenmeye çalışılacaktır.

O halde, bu çalışmanın beş temel amacını gerçekleştirmek üzere, çalışmanın birinci bölümünde zaman serilerine ilişkin temel bazı kavramlar olan; durağanlık, trend, mevsimsellik, birim kök testleri ile çalışmada kullanılan bazı modeller olan; Box-Jenkins modelleri, koşullu varyans modelleri ile vektör otoregresif modellerine ilişkin teorik yapıdan bahsedilmiş ve bu özelliklere sahip zaman serileri için gerekli modeller ve analiz yöntemleri belirlenmiştir.

İkinci bölümde, çalışmanın uygulamasını oluşturan bir diğer yöntem olan yapay sinir ağlarının teorik çerçevesi anlatılmıştır. Bu doğrultuda, yapay sinir ağlarının ortaya çıkışı, tarihsel gelişimi, eğitim ve öğrenme süreçleri ile yapay sinir ağlarının temel bölümleri tanıtılmış ve uygulama yöntemine bağlı kalarak, yapay sinir ağlarının kendine özgü mimarilerinin tanıtılması hedeflenmiştir. Aynı zamanda, bu bölümde literatürde kabul görmüş bazı önemli hibrit yöntemlere değinilmiş ve uygulama yöntemi olarak belirlenen hibrit yöntemin teorik yapısından söz edilmiştir.

Çalışmanın uygulama kısmını oluşturan son bölümü olan üçüncü bölümde ise, öncelikle elektrik talep tahmini ile ilgili literatür incelenmiştir. Daha sonra, zaman serileri analizi uygulaması, yapay sinir ağı uygulaması ve hibrit yöntem uygulaması yapılmıştır. Ayrıca, elde edilen bulguların, çalışmada kullanılan yöntemler ile performanslarının teknik ve yorumsal karşılaştırılmaları gerçekleştirilmiştir. Daha sonra, elde edilen bu çıktılar ile ileriye yönelik elektrik talep tahmininin öngörüsünün yapılmış, kullanılan teknikler karşılaştırılmış ve tahmin sonuçlarının performansları karşılaştırılmıştır.

BİRİNCİ BÖLÜM

ZAMAN SERİLERİ MODELLERİNİN TEORİK YAPISI

1.1.ZAMAN SERİLERİNE İLİŞKİN BAZI TEMEL KAVRAMLAR

Veriler mekân vasfı olarak toplanabileceği gibi, zaman vasfının şıkları olarak da derlenebilir. Zaman vasfının şıklarından oluşan seriye zaman serisi adı verilir (Işığışok, 1994, s. 43). Diğer bir deyişle, zaman içerisinde veya zaman değişkeninin şıklarına göre ardışık olarak derlenen gözlemlerden oluşan seri zaman serisi adını alır (Box et al., 1967, s. 1). Sosyal bilimlerde zaman serileri yaygın olarak kullanılmakta ve dakikalık, saatlik, günlük, haftalık, aylık, yıllık, vb. gibi zaman dönemlerine göre elde edilebilmektedir. Zaman serilerine örnek olarak; borsada dakikalık işlem hacmi, saatlik elektrik tüketim miktarı, günlük elektrik üretim miktarı, haftalık para arzı miktarı, bir fabrikadan sevk edilen aylık ürün miktarı, yıllık enflasyon oranı, vb. verilebilir.

Zaman serileri sürekli ve kesikli zaman serileri olmak üzere, iki farklı şekilde elde edilmektedir (Işığışok, 1994, s. 46). Devamlı derleme sonuçlarından oluşan serilere sürekli zaman serileri adı verilir iken, anlık derleme sonuçlarından elde edilen serilere kesikli zaman serileri adı verilmektedir (Serper, 2014, s. 608). Sürekli zaman serileri, zaman döneminin çeşitli anlarında sürekli olarak elde edilen veriler olmasına karşın, kesikli zaman serileri sadece belirli zamanlarda derlenen verilerden oluşur. Örneğin, yıllık işsizlik oranları, aylık elektrik tüketim miktarı, haftalık elektrik üretim miktarı gibi seriler, sürekli zaman serilerine örnek olarak gösterilebilir. Buna karşılık 2022 yılında Türkiye’de meydana gelen grev sayısı, 2020 yılı elektrik kesinti sayısı, 2021 yılında meydana gelen orman yangını sayısı gibi seriler, kesikli zaman serilerine örnek olarak verilebilir.

Bir zaman serisinin önemli bir özelliği ardışık (bitişik) gözlemlerden oluşmasıdır. Bu nedenle, zaman serilerindeki gözlemlerin çoğu zaman birbirileri ile bağımlı oldukları söylenebilir. Bu bağımlılığın ortaya konmasında bu çalışmanın ilerideki bölümlerinde anlatılacak olan bazı tekniklerinden yararlanılır. Ayrıca, yine daha sonra irdeleneceği gibi, zaman serisi verilerine stokastik ve dinamik modellerin uygulanması mümkün

olmaktadır. Zaman serilerinin diğere önemli bir özelliđi ise, deđişken veya deđişkenlerin geđmiş dönemlere ilişkin gözlem deđerleri yardımıyla, gelecek dönemlere yönelik öngörüler yapabilmeye olanak sağlamasıdır. Bununla birlikte; zaman serileri, yapılan öngörülerin yanı sıra deđişkenlerin uzun ve kısa dönem ilişkileri hakkında bilgi sunmasına ve aynı zamanda deđişkenler arasındaki nedenselliđin yönünün belirlenmesine de olanak vermektedir.

Zaman serileri analizi, bir serinin özelliklerini özetler ve serinin göze çarpan yapısını ortaya koymaya çalışır. Zaman serileri analizinin ve modellenmesinin temelde aşığıdaki gibi iki amacı bulunmaktadır (Sevüktekin ve Çınar, 2014, p. 48):

- (i) Tek deđişkenli zaman serileri analizlerinde tek bir seriye ait gözlemlerin dinamik ya da zamana bađlı yapısının anlamaya çalışmak ve
- (ii) Çok deđişkenli zaman serileri analizlerinde ise birden fazla seri arasında önceleştirme, geciktirme ve geri-besleme ilişkilerini ortaya koymaktır.

Bundan sonraki başlıklarda ele alınacak konular, zaman serilerinin gösterdikleri farklılıkların uzunca tartışılmasından ziyade, söz konusu özelliklerin farklı model ve algoritmalar ile nasıl elde edileceđi üzerinde durulmaktadır. Bu doğrultuda doğru model ve deđişkenlerin seçimi ve buna bađlı olarak doğruya yakın öngörülerin elde edilmesi, bu tezin temel amaçlarından birisi olarak; elektrik talep tahmininde, i) Zaman serileri analizi modellerinin mi, ii) Yapay sinir ađları mimarilerinin mi veya iii) Her iki yapıyı içeren hibrit yöntemlerin mi daha etkili sonuçlar verebileceđinin yanıtlarını bulmaya çalışmaktır.

1.1.1. Durađanlık

Zaman serilerinin en önemli yönlerinden biri, ilgili seri veya serilerin durađan ya da durađan dışı (durađan olmayan) şeklinde olmak üzere, iki farklı yapıdan birisinde bulunmasıdır. Deđişkenler arasında anlamlı ilişkiler elde edilebilmesi için analizi yapılan deđişkenin durađan bir yapıya sahip olması gerekir. O halde, zaman serisi yaklaşımında ele alınan modellerde deđişkenlerin zamanla deđişmediđi veya aynı anlama gelmek üzere, ortalamanın, varyansın, kovaryansın ve birleşik dađılım fonksiyonunun zamana

göre sabit kaldığı varsayılır. Varsayımın bu kadar detayı içermesi durumu tam durağanlık olarak ifade edilir (Işığışok, 1994, s. 47).

Durağanlık varsayımı, etkin ve tutarlı tahmin ve/veya tahminciler elde etmek için gerekli bir varsayımdır. Ancak, dikkate alınan stokastik sürecin birleşik dağılım fonksiyonunu tanımlamak genellikle zor veya çok kısıtlayıcı olabilmekte ve test edilememektedir. Ayrıca, zaman serileri analizinde tam durağanlığa gerek duyulmamaktadır. Bu nedenle, $t=1,2,\dots,T$ olmak üzere, sürecin rassal değişkeni Y_t 'ye ilişkin olarak ortalamasının, varyansın ve kovaryansın durağan olması ile yetinilmektedir. Aşağıdaki koşulları sağlayan bir zaman serisi, zayıf durağan (kovaryans durağan) seri olarak adlandırılır:

- i) Ortalama : $E(Y_t) = \mu$ bütün t 'ler için sabit ise
- ii) Varyans : $Var(Y_t) = \sigma_Y^2 = \gamma_0$ bütün t 'ler için sabit ise
- iii) Kovaryans : $Cov(Y_t, Y_{t-k}) = \gamma_k$ bütün t 'ler için sabit ve $k \neq 0$ ise

Zayıf durağanlık, ikinci dereceden durağanlık veya kovaryans durağanlık olarak da ifade edilmektedir. Eğer bir seri (veya süreç), zayıf veya kovaryans durağan ise Y_t ile Y_{t-k} arasındaki kovaryans, gözlemlerin zamanını belirten t 'ye değil, zaman ayırım uzunluğunu gösteren k gecikme uzunluğuna bağlıdır (Sevüktekin ve Çınar, 2007, s. 65; Işığışok, 1994, s. 47).

Zaman serileri ile yapılan analizlerde durağan stokastik süreç istatistiksel bir dengeyi ifade etmektedir. Bunun nedeni, gözlem değerlerinin sabit bir ortalama etrafında değişim göstermesidir. Zaman serilerinin modellenmesinde ve uygulanmasında, AR (otoregresif), MA (hareketli ortalama) ve ARMA (otoregresif hareketli ortalama) durağan süreçleri kullanılmaktadır. İktisadi zaman serileri, çoğu zaman durağan bir yapı sergilememektedir. Bu nedenle; durağanlık, serinin uygun dereceden farkları alınarak elde edilmektedir. Farkları alınan bu tür seriler de ARIMA (otoregresif entegre edilmiş hareketli ortalama) süreci olarak tanımlanmaktadır.

Durağan süreçler; $I(0)$ ise sıfırıncı dereceden bütünleşik (entegre), $I(1)$ ise birinci dereceden farkı alınmış birinci dereceden bütünleşik, $I(2)$ ise ikinci dereceden farkı alınmış ve ikinci dereceden bütünleşik ve $I(d)$ ise d . dereceden farkı alınmış ve d . dereceden bütünleşik bir yapıyı ifade etmektedir (Sevüktekin ve Çınar, 2007, s.70).

1.1.2. Trend

Bilindiği gibi değişkenler, üzerinde etkileri birkaç dönemde yok olan geçici şokların yanında, etkileri uzun süre devam eden kalıcı şokları da barındırmaktadır. Geçici şoklar düzensiz olmaları nedeniyle, seriler üzerinde etkiler göstermez iken, kalıcı şoklar trendin oluşumuna yol açar. Kalıcı şokların oluşturduğu trend, serinin ortalamasında ve/veya varyansında artma veya azalma yönünde kendini gösterebilir. Bu yapı serinin durağan dışı olduğunu gösterir ve bu durum stokastik trend¹ olarak adlandırılır (Tarı, 2005, s. 381).

Zaman serilerinde stokastik trend ve deterministik trend olmak üzere, iki tür trend etkisine rastlanır. Trend içeren birinci dereceden otoregresin bir süreç (AR) (Sevüktekin ve Çınar, 2007, s. 68),

$$Y_t = \alpha + \beta t + \phi Y_{t-1} + \varepsilon_t \quad (\alpha=0) \quad (1.1)$$

şeklinde yazılır. Burada ε_t , sıfır ortalama ve sabit varyans özelliğini gösteren hata terimini ve β parametresinin yanındaki t değişkeni ise zamana bağlı olarak trendi temsil etmektedir. Burada, $\phi = 1$ ve $\beta = 0$ olduğunda,

$$Y_t = \alpha + Y_{t-1} + \varepsilon_t \quad (1.2)$$

olur ve Y_{t-1} eşitliğin soluna alındığında, $Y_t - Y_{t-1} = \alpha + \varepsilon_t$ elde edilir ve son olarak

$$\Delta Y_t = \alpha + \varepsilon \quad (1.3)$$

sonucuna ulaşılır. Burada Y_t , α 'nın işaretine bağlı olarak yukarı ya da aşağı yöne doğru bir eğilim göstermekte ve bu tür trende de stokastik trend adı verilmektedir. İkinci olarak, denklem (1.1)'de $\beta \neq 0$ ve $\phi = 0$ olduğunda ise; $Y_t = \alpha + \beta t + \varepsilon_t$ sonucuna ulaşılır. Burada, t bir zaman değişkenini ifade etmekte ve Y_t , β 'nin işaretine bağlı olarak farklı eğilimler sergilemekte ve bu da deterministik trend olarak adlandırılmaktadır.

Buna karşılık, denklem (1.1)'deki modelde $\beta \neq 0$ ve $\phi = 1$ olduğunda ise hem stokastik hem de deterministik trend söz konusu olmaktadır. Deterministik trend etrafındaki dalgalanmalar 'trend durağan süreç' ve stokastik trend etrafındaki dalgalanmalar ise 'fark durağan süreç' olarak ifade edilmektedir (Göktaş, 2005, s. 8).

¹ Bazı kaynaklarda kayan rassal yürüyüş olarak da isimlendirilmektedir. Bkz: Sevüktekin ve Çınar, 2007

Stokastik trend, çoğu zaman Y_t serisinin birinci dereceden farkı alınarak ortadan kaldırılabilmektedir. Bunun nedeni, ΔY_t 'nin ($Y_t - Y_{t-1} = \Delta Y_t$) eğilimsiz olmasıdır. Burada fark durağan süreç söz konusu olmakla birlikte, bu durum deterministik trend için t 'nin süreç dışında kalamaması nedeniyle söz konusu değildir. Eğer, Y_t böyle bir eğilim altındaysa trend durağan süreç ortaya çıkmaktadır (Thomas, 1997, ss. 410-411).

Diğer taraftan, trendden arındırma ve fark alma işlemleri birbirinden tamamıyla farklı çözümler olup, bir model için geçerli olan çözüm bir başka model için geçerli olmayabilir. İki süreç arasındaki seçim, birim kökün varlığını test etmeye yaramaktadır (Baltagi, 1998, s. 372).

1.1.3. Mevsimsellik

Mevsimsellik veya mevsimsel bileşen, gözlem değerlerinin zaman değişkeninin sıklıklarına göre aylık veya çeyrek yıllık olarak mevsimi içerecek şekilde derlenen verilerdir. Kuşkusuz, yıllık verilerde mevsimselliğin gözlemlenemeyeceği açıktır. Zaman serilerinin trend dışındaki bir diğer bileşeni olan mevsimsellik veya mevsimlik dalgalanmalar, döngüsel veya periyodik dönemler için geçerlidir. Bir zaman serisinin aynı hareketleri tekrarlaması döngüsel kavramı olarak ifade edilir iken, yine bir zaman serisinin eşit zaman aralıklarında tekrarlanması ise periyodik kavramı ile ifade edilir (Işığışık, 2019, s. 254).

Mevsimin etkisinde olan değişkenler yılın bazı dönemlerinde, diğer dönemlere oranla daha yüksek ya da daha düşük değerlere ulaşabilmektedir. Nitekim, zaman serilerinde mevsimsellik farklı şekillerde ortaya çıkabilmektedir. Örneğin; iklimler, insan alışkanlıkları, özel günler, vb. gibi birçok faktör sıralanabilir (Sevüktekin ve Çınar, 2014, s. 16). Dolayısıyla mevsimsellik, bir dönem (genellikle yıl) içerisinde oluşan düzenli hareketler olarak değerlendirilebilir (Işığışık, 2019, s. 254).

Tanımlardan yola çıkıldığında, trendde olduğu gibi zaman serilerinde mevsimsellik de deterministik mevsimsellik ve stokastik mevsimsellik olmak üzere, iki şekilde ortaya çıkmaktadır:

- Deterministik mevsimsellik, gözlem değerlerinin her yıl aynı dönemde tekrarlanması durumunda ortaya çıkmaktadır.
- Stokastik mevsimsellik, gözlem değerlerinin yaklaşık olarak aynı dönemde tekrarlanması durumunda meydana gelmektedir. Milli bayramlar her yıl aynı dönemlere denk gelmesi nedeniyle deterministik mevsimselliğe yol açar iken, dini bayramlar ise dönemlerin kaymaları nedeniyle stokastik mevsimselliğin ortaya çıkmasına neden olur.

1.2. BİRİM KÖK TESTLERİ

Durağan olmayan zaman serileri genellikle trend içeren değişkenlerdir. Bu trend, değişkende bazen deterministik (ortalamadan kaynaklanan) bazen de stokastik (kovaryansın zamana bağlı olması) olabilmektedir. Birim kök içeren seriler, genellikle stokastik trend içeren serilerdir. Diğer bir deyişle, ilgili zaman serisinin zaman içerisindeki şokların etkisinin geçici olması veya şoklara karşı dirençli olması serinin durağan olduğunu gösterirken, şokların etkisinin kalıcı olması durumunda ise serinin durağan olmadığı veya birim kök içerdiği sonucuna ulaşılmaktadır. Herhangi bir seriye bir şok geldiğinde, uzun dönemde serinin ortalamasında ve varyansında herhangi bir değişim meydana gelmiyor ise serinin birim kök içermediği veya aynı anlama gelmek üzere durağan olduğu anlaşılmaktadır.

Zaman serisi analizlerinde sözü edilen durağanlık kavramı, zayıf veya kovaryans durağanlık olarak bilinmektedir. Zayıf durağanlığın gerçekleşebilmesinin temelde üç koşulu bulunmaktadır. Bir Y_t serisi, aşağıdaki şartları sağlayabildiği takdirde, bu serinin durağanlığından bahsedilebilir:

$$i) E(Y_t) = \mu \quad (1.4)$$

$$ii) Var(Y_t) = \sigma^2 \quad (1.5)$$

$$iii) Cov(Y_t, Y_{t-k}) = \gamma_k \quad (1.6)$$

Eşitlik (1.4), ilgili zaman serisinin ortalamasının zaman boyunca sabit olduğunu, Eşitlik (1.5), serinin varyansının zaman boyunca değişmediğini ve Eşitlik (1.6) ise serinin kendi gecikmeleri ile olan kovaryansının zamandan bağımsız ve gecikme uzunluğuna bağlı

olarak deđiřtiđini ifade etmektedir. Bir zaman serisi için yukarıda belirtilen üç kořul sađlandıđı taktirde, söz konusu serinin durađan (zayıf durađan) olduđu söylenmektedir. Durađanlık analizinin temeli, Eřitlik (1.7)'deki rassal yürüyüş sürecine dayanmaktadır:

$$Y_t = \phi Y_{t-1} + \varepsilon_t \quad (1.7)$$

Burada, $\phi = 1$ olması, sürecin sabitsiz ve trendsiz bir rassal yürüyüş süreci olduđunu ve durađan olmadıđını ifade eder. Söz konusu eřitlikte $\varepsilon_t \sim iid(0, \sigma^2)$ özelliđine sahip olup temiz dizidir. Bu süreç her bir t zamanı için řu řekilde yazılabilir:

$$Y_1 = \varepsilon_1$$

$$Y_2 = Y_1 + \varepsilon_2 = \varepsilon_1 + \varepsilon_2$$

$$Y_3 = Y_2 + \varepsilon_3 = \varepsilon_1 + \varepsilon_2 + \varepsilon_3$$

⋮

$$Y_t = Y_{t-1} + \varepsilon_t = \varepsilon_1 + \varepsilon_2 + \dots + \varepsilon_t$$

Dolayısıyla, $E(Y_t) = E(\varepsilon_1 + \dots + \varepsilon_t) = E(\varepsilon_1) + \dots + E(\varepsilon_t) = 0$ elde edilir ki bu durum Eřitlik (1.4)'de bulunan kořulu sađlamıřtır. Eřitlik (1.5)'te verilen kořul ise $Var(Y_t) = Var(\varepsilon_1 + \dots + \varepsilon_t) = t\sigma^2$ řeklinde elde edilecektir. Bu durum, $t\sigma^2$ varyansının t zamanından bađımsız olmaması nedeniyle, sabit varyans kořulunun gerçekteřmediđini ve dolayısıyla rassal yürüyüş sürecinin durađan dıřı olduđunu gösterir. O halde, Eřitlik (1.7)'de $|\phi| < 1$ kořulunun geçerli olması durumunda durađanlık sađlanacaktır.

Herhangi bir zaman serisindeki birim kök varlıđını tanımlayabilmek için parametrelerin tahmin edilme yöntemlerine göre, farklı özelliklere sahip birim kök testleri bulunmaktadır. Literatürde önerilen ve bu çalışmada uygulanan testler ADF (Augmented Dickey Fuller) ve KPSS (Kwiatkowski-Phillips-Schmidt-Shin) testleridir. Bu nedenle, çalışmada bu iki test üzerinde durulacaktır.

1.2.1. ADF (Augmented Dickey-Fuller) Birim Kök Testi

Standart Dickey-Fuller (DF) testinde, $Y_t = \phi Y_{t-1} + \varepsilon_t$ řeklindeki rassal yürüyüş sürecinin birinci farkından yararlanılmaktadır. Fark alma iřlemi, eřitliđin her iki tarafından Y 'nin bir dönem gecikmeli deđerini çıkarılarak $Y_t - Y_{t-1} = \phi Y_{t-1} - Y_{t-1} + \varepsilon_t$

şeklinde yapılır. Bu ifade, $\Delta Y_t = (\phi - 1)Y_{t-1} + \varepsilon_t$ olarak da yazılabilir. Burada $(\phi - 1) = \delta$ olmak üzere, yukarıdaki fark eşitliği yeniden düzenlenirse, Eşitlik (1.8)'e ulaşılır:

$$\Delta Y_t = \delta Y_{t-1} + \varepsilon_t \quad (1.8)$$

Dikkat edileceği üzere, elde edilen eşitlikte sabit terim ve trend bulunmamaktadır (None). Bu eşitliğe sabit terim (Intercept) eklendiğinde Eşitlik (1.9)'a ve sabit terime ek olarak trend de eklendiğinde (Trend and intercept) Eşitlik (1.10)'a ulaşılır:

$$\Delta Y_t = \mu + \delta Y_{t-1} + \varepsilon_t \quad (1.9)$$

$$\Delta Y_t = \mu + \beta t + \delta Y_{t-1} + \varepsilon_t \quad (1.10)$$

Dolayısıyla, ilgili serideki birim kök içeren bir seri için $\delta = \phi - 1 = 0$ veya aynı anlama gelmek üzere, $\phi = 1$ olurken, birim kök içermeyen bir seri için ise $\delta = \phi - 1 < 0$ veya aynı anlama gelmek üzere, $\phi < 1$ olacaktır. Nitekim standart DF testi için oluşturulan hipotezler şu şekilde oluşacaktır:

$$H_0: \delta \geq 0 \quad (\phi \geq 1) \text{ (Seri durağan değildir) (Birim kök vardır)}$$

$$H_1: \delta < 0 \quad (\phi < 1) \text{ (Seri durağandır) (Birim kök yoktur)}$$

Bu hipotez grubunun sınanması için $t_\delta = \frac{\hat{\delta}}{S_\delta}$ test istatistiğinden yararlanılır.

Dickey ve Fuller (1979), bu test istatistiğinin standart t dağılımı için yeterli olmadığını göstermişler ve farklı örneklem genişlikleri için τ ile sembolize edilen kritik değerler üretmişlerdir (Dickey & Fuller, 1979, s. 430). MacKinnon (1991 ve 1996) ise çok daha kapsamlı simülasyon çalışmaları yaparak kritik değerler üretmiştir.

Standart DF testi, AR(1) sürecinden üretilmiştir. Seride yüksek derecede bir korelasyon varsa, ε_t temiz dizi (white noise) olma özelliğini kaybedecektir. Arttırılmış Dickey-Fuller (ADF) testi, bu problemin üstesinden gelebilmek amacıyla, AR(1) yerine AR(p) sürecinden yararlanarak, Eşitlik (1.8), (1.9) ve (1.10)'a p gecikmeli fark terimleri ekleyerek giderilmiştir. Böylece, trendsiz ve sabitsiz (1.11), sabitli (1.12), sabitli ve trendli (1.13) olmak üzere, üç farklı ADF denklemi elde edilmiştir:

$$\Delta Y_t = \delta Y_{t-1} + \sum_{i=1}^p \beta_i \Delta Y_{t-i} + \varepsilon_t \quad (1.11)$$

$$\Delta Y_t = \mu + \delta Y_{t-1} + \sum_{i=1}^p \beta_i \Delta Y_{t-i} + \varepsilon_t \quad (1.12)$$

$$\Delta Y_t = \mu + \beta t + \delta Y_{t-1} + \sum_{i=1}^p \beta_i \Delta Y_{t-i} + \varepsilon_t \quad (1.13)$$

Bu eşitlikler için kullanılan durağanlık hipotezleri DF testinde kullanılan hipotezler ile aynıdır ve t_δ istatistiğinin asimptotik dağılımı, eşitliğe eklenen gecikmeli fark terimlerinden bağımsız olmaktadır. Oluşturulan hipotez testlerinde elde edilen test istatistiği, ilgili kritik değerden küçük olduğunda ($t_h > t_k$), sıfır (yokluk) hipotezi reddedilecek ve alternatif hipotez kabul edilecektir.

Birim kök testi için kullanılan bir diğer test ise Phillips Perron (PP) testidir. Ancak, PP testinin ADF testine benzer sonuçlar vermesi nedeniyle, bu çalışmada PP testi uygulanmamıştır. Bu nedenle, PP testinin teorisine de burada yer verilmemiştir.

1.2.2. KPSS (Kwiatkowski, Phillips, Schmidt, Shin) Birim Kök Testi

KPSS (1992) birim kök testi, Y_t zaman serisinin durağanlığını (trend durağanlık) literatürde var olan diğer testlerden farklı kılan hipotezi:

H_0 : Seri durağandır (Birim kök yoktur)

H_1 : Seri durağan dışıdır (Birim kök vardır)

KPSS testi Eşitlik (1.14)'te verilen ve olağan en küçük kareler (OLS) tahmininden elde edilen hatalara dayanmaktadır:

$$Y_t = X_t' \alpha + \varepsilon_t \quad (1.14)$$

Eşitlik (1.14), sabit terimi veya sabit ile trendi içermektedir. Buradan hareketle LM istatistiği Eşitlik (1.15)'de gösterilmiştir:

$$LM = \sum_t S_t^2 / (T^2 f_0) \quad (1.15)$$

Bu eşitlikte verilen f_0 , sıfır frekansta kalıntı spektrumu (residual spectrum at frequency zero) tahmincisi ve S_t , Eşitlik (1.16)'daki eşitlikte tanımlanan birikimli kalıntı fonksiyonunu temsil etmektedir:

$$S_t = \sum_{r=1}^t \hat{\varepsilon}_r \quad (1.16)$$

Eşitlik (1.16)'da kalıntı tahminleri ise; $\hat{\varepsilon}_t = Y_t - X_t' \hat{\alpha}(0)$ olarak hesaplanmaktadır. Bu eşitlikte verilen α tahmincisi, orijinal regresyon kalıntılarına dayalı elde edilmektedir. Ayrıca α tahmincisi yarı-fark regresyonuna dayandığından,

$$d(Y_t|a) = d(X_t|a)' \alpha(a) + \eta_t \quad (1.17)$$

veya $Y_t^d = Y_t - X_t' \hat{\alpha}(\bar{a})$ elde edilir. Bu tahminciler birbirlerinden farklı olmaktadır. Eşitlik (1.15)'te verilen LM test istatistiği için kritik değerler KPSS (1992) tarafından üretilmiştir (Kwiatkowski et al., 1992, s. 171). LM test istatistiği ilgili kritik değerden büyük olduğunda, serinin durağanlığını belirten yokluk hipotezi reddedilecek ve serinin durağan olmadığına karar verilecektir.

1.3. OTOREGRESİF HAREKETLİ ORTALAMA (ARIMA) MODELLERİ

Otoregresif hareketli ortalama (ARIMA) modelleri, George E.P. Box ile Gwilym M. Jenkins (1970) tarafından geliştirilen ve kısa dönem öngörülerinde sıklıkla başvurulan tek değişkenli modellerdir. Geliştirilen bu modelin AR, MA, ARMA ve ARIMA olmak üzere, dört farklı alt modeli (süreci) bulunmaktadır. Bu tez çalışması kapsamında, koşullu değişen varyans modelinin uygulamasında model seçim sürecinde değerlendirilmesi nedeniyle, otoregresif hareketli ortalama modelleri hakkında kısa da olsa bilgi vermekte yarar vardır.

1.3.1. Otoregresif Model (AR)

Bir otoregresif model, Y_t gibi bir bağımlı değişkenin mevcut değerinin, yalnızca ilgili değişkenin önceki (geçmiş) dönemlerde aldığı değerlerle ve bir hata terimine bağlı olduğu bir model olarak tanımlanabilir. AR(p) olarak da ifade edilen p . dereceden bir otoregresif model Eşitlik (1.18)'deki gibidir.

$$Y_t = \mu + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + u_t \quad (1.18)$$

Bu eşitlikte μ , kesme terimini ve stokastik süreç olan Y_t 'nin ortalamasını gösterir iken, $\phi_1, \phi_2, \dots, \phi_p$ ise otoregresif sürecin p . dereceden bilinmeyen parametrelerini göstermektedir. Eşitlikte yer alan u_t ise beyaz gürültülü hata terimidir. Otoregresif bir modelin özelliklerini göstermek için söz konusu model şu şekilde de ifade edilebilir:

$$Y_t = \mu + \sum_{i=1}^p \phi_i Y_{t-i} + u_t \quad (1.19)$$

Bu model, aynı zamanda gecikme operatörü kullanılarak,

$$Y_t = \mu + \sum_{i=1}^p \phi_i L^i Y_t + u_t \quad (1.20)$$

şeklinde veya

$$\phi_p(L)Y_t = u_t \quad (1.21)$$

biçiminde de yazılabilir. Bu eşitlikte $\phi_p(L) = 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p$ şeklinde tanımlanmaktadır.

1.3.2. Hareketli Ortalama Modeli (MA)

($t = 1, 2, 3, \dots$) olmak üzere; u_t , $E(u_t)$ ve $Var(u_t) = \sigma^2$ olan bir beyaz gürültülü süreç olsun. Bir hareketli ortalama modeli, Y_t gibi bir bağımlı değişkenin mevcut değerinin, t dönemindeki hata teriminin (u_t) ve hata terimlerinin geçmiş dönemlerdeki değerlerine bağlı olduğu bir model olarak tanımlanabilir. MA(a) olarak da ifade edilen q . dereceden bir hareketli ortalama modeli Eşitlik (1.22)'deki gibidir.

$$Y_t = \mu + u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2} + \dots + \theta_q u_{t-q} \quad (1.22)$$

Bu eşitlik aşağıdaki gibi de gösterilebilir:

$$Y_t = \mu + \sum_{i=1}^q \theta_i u_{t-i} + u_t \quad (1.23)$$

Hareketli ortalama modeli, beyaz gürültü sürecinin doğrusal birleşimidir. Y_t , beyaz gürültülü hata teriminin mevcut ve geçmiş değerlerine bağlıdır. Eşitlik (1.23) aynı zamanda gecikme operatörü kullanılarak da tanımlanabilir. Gecikme operatörü² Y_t 'nin, bir kez gecikmeli olduğunu belirtmek için $LY_t = Y_{t-1}$ olarak da yazılabilir. Eşitlik (1.23), gecikme operatörü ile yazıldığında,

$$Y_t = \mu + \sum_{i=1}^q \theta_i L^i u_t + u_t \quad (1.24)$$

şeklinde olacaktır. Bu eşitlik benzer şekilde şu şekilde de yazılabilir:

² Bazı kaynaklarda, gecikme operatörü, B ile gösterilen “geri kaydırma (backshift)” operatörü olarak da isimlendirilmektedir. Bknz. (Shumway & Stoffer, 2011; Mills & Markellos, 2008, p. 14)).

$$Y_t = \mu + \theta_q(L)u_t \quad (1.25)$$

Bu eşitlikte $\theta_q(L) = 1 + \theta_1L + \theta_2L^2 + \dots + \theta_qL^q$ tanımlanmaktadır.

Yukarıda tanımlanan hareketli ortalama eşitliklerinde bulunan μ 'nün çıkarılması, ilgili denklemlerin karmaşıklığını önemli ölçüde kolaylaştırmaktadır ve bu parametrenin modelden çıkarılması, genelliği kaybetmesine herhangi bir neden oluşturmamaktadır (Brooks, 2008:212). Bunu görmek için ortalaması \bar{Z} olan bir Z_t serisine ilişkin bir gözlem değeri olduğu varsayalım. Sıfır ortalamalı bir Y_t seri, her bir Z_t gözleminde \bar{Z} çıkartılarak elde edilebilir.

Yukarıda tanımlanan hareketli ortalama süreçlerinde verilen q düzeyindeki hareketli ortalama sürecinin ayırt edici özellikleri ise şu şekildedir (Sevüktekin ve Çınar, 2014, s. 155):

- $E(Y_t) = \mu$
- $Var(Y_t) = \gamma_0 = (1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2)\sigma_u^2$
- $Kovaryans \gamma_k = \begin{cases} (\theta_k + \theta_{k+1}\theta_1 + \dots + \theta_q\theta_{q-k})\sigma_u^2 & k = 1, 2, \dots, q \text{ için} \\ 0 & k > q \end{cases}$

1.3.3. Otoregresif Hareketli Ortalama Modeli (ARMA)

AR(p) ile MA(q) süreçleri birleştirilerek, bir ARMA(p,q) eşitliği elde edilir (Sevüktekin ve Çınar, 2014, s. 167). Böyle bir model, bazı y serilerinin mevcut değerinin, kendi geçmiş değerlerine ve bir beyaz gürültü hata teriminin mevcut ve önceki değerlerinin bir kombinasyonuna doğrusal olarak bağlı olduğunu belirtmektedir. Model gecikme operatörü ile şu şekilde yazılabilir:

$$\phi_p(L)Y_t = \mu + \theta_q(L)u_t \quad (1.26)$$

bu eşitlikte,

$$\phi_p(L) = 1 - \phi_1L - \phi_2L^2 - \dots - \phi_pL^p$$

ve

$$\theta_q(L) = 1 + \theta_1L + \theta_2L^2 + \dots + \theta_qL^q$$

veya

$$Y_t = \mu + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2} + \dots + \theta_q u_{t-q}$$

şeklinde yazılabilir. Burada, $E(u_t) = 0$; $E(u_t^2) = \sigma_u^2$ ve $E(u_t u_s) = 0$, $t \neq s$ şeklindedir. Bir ARMA³ sürecinin özellikleri, otoregresif ve hareketli ortalama bölümlerinden gelenlerin bir kombinasyonu olmaktadır.

1.3.4. ARIMA Modeli

Durağan olmayan yapıdaki ARIMA modeli (süreci), ARMA modelinden farklı olarak kısaltmasında “entegre” anlamına gelen “I” harfine sahiptir. Entegre bir otoregresif süreç, karakteristik denkleminin birim çember üzerinde bir kökü olan bir süreç olarak nitelendirilebilir. Tipik olarak, farkı alınan bir değişkenin üzerinde ARMA modeli oluşturulur. Diğer bir deyişle, d kez farkı alınan bir değişkenin, ARMA(p, q) modelindeki entegre sürecinin derecesini tamamlaması ile orijinal verilerdeki bir ARIMA(p, d, q) modeline eşdeğer olmaktadır. ARIMA süreci veya modeli, ilgili değişkenin farkı alınarak elde edildiği için bu değişkenin artık durağan hale getirmek için uygun şekilde dönüştürüldüğü varsayılır.

Durağan bir seri, W_t 'yi ($W_t = \Delta Y_t$ olarak tanımlanmaktadır) elde edebilmek için Y_t değişkeninin farkı alındıktan sonra bir ARMA süreci gibi W_t ele alınabilir. Böyle bir durumda, $W_t = \Delta^d Y_t$ ise ve W_t bir ARMA(p, q) sürecindeyse bu durumda, Y_t zaman serisi, (p, d, q) olarak ifade edilmektedir ve bu süreç gecikme operatörü yardımıyla (Sevüktekin ve Çınar, 2014, s. 186):

$$(1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p) \Delta^d Y_t = \mu + u_t + \theta_1 u_{t-1} + \dots + \theta_q u_{t-q} \quad (1.27)$$

olarak ifade edilebilir.

³ Bir ARMA süreci, saf bir AR işleminde olduğu gibi geometrik olarak azalan bir ACF'ye sahip olacaktır. Dolayısıyla, PACF bir AR(p) süreci ile bir ARMA(p, q) süreci arasında ayırım yapmak için kullanışlıdır. Burada, ilk olarak, geometrik olarak azalan bir otokorelasyon fonksiyonuna sahip olacaktır. Ancak p gecikmesinden sonra sifıra kesen kısmi bir otokorelasyon fonksiyonuna sahip olacaktır. İkincisi ise geometrik olarak azalan hem otokorelasyon hem de kısmi otokorelasyon fonksiyonlarına sahip olacaktır (Brooks, 2008, p. 224).

1.4. KOŞULLU DEĞİŞEN VARYANS MODELLERİ

1950'lerde portföy teorisi üzerine yapılan ilk çalışmaların ardından oynaklık (volatility) konusu, finans alanında son derece önemli bir kavram haline gelmiştir (Mills, 2019, s. 161). Oynaklığın çeşitli tanımları bulunmasına rağmen, bir zaman serisi temelinde genellikle yüksek değişkenlik veya eşdeğer yüksek varyans ile ilişkilendirilen yapı, oynaklık olarak tanımlanabilir (Mills, 2019, s. 161). Bu sadece finansal getirilerin değil, aynı zamanda birçok zaman serisinin değişkenliğinin düşük olduğu ve göreceli oynaklığın önemli ölçüde daha yüksek olduğu değişkenlik gösteren bir yapı olarak ifade edilebilir.

Genellikle finansal piyasalarda, özelde hisse senetlerinin oynaklığının bir özelliği de doğrudan gözlemlenebilir olmasıdır. Oynaklığın gözlemlenemezliği, koşullu değişen varyans modellerinin tahmin performansının değerlendirilmesini zorlaştırmaktadır. Örneğin, BİST hisse senetlerinin günlük kazanç uzunlukları düşünülebilir. Günlük oynaklık, bir işlem gününde yalnızca bir gözlem olduğundan dolayı getiri verilerinden doğrudan gözlenemez. Bir hisse senedinin 15 dakikalık getirisi gibi gün içi veriler mevcut ise günlük oynaklık tahmin edilebilir. Ancak böyle bir tahminin doğruluğu için dikkatli bir çalışma gerektirmektedir. Örneğin, elektrik tüketimi oynaklığı gün içi-gece veya kış-yaz mevsimi ya da bölgesel gelişmişlik gibi faktörlere göre bölgelerarası farklılıklar gösterebilmektedir. Bir ülkedeki elektrik tüketiminin yüksek frekanslı olduğu sanayileşmiş bölgeler, daha az gelişmiş bölgelerin elektrik tüketimi oynaklığı hakkında çok sınırlı bilgiyi içerebilir.

1980'lerin başında, oynaklığın gözlemlenen zaman serileri için stokastik model içine yerleştirilmesi önerildi. Bu bazı serilerin, korelasyonsuz görünmesine rağmen, zaman içinde bağımsız olmadıklarından kaynaklandığı gözlemlenmiştir (Durllauf & Blume, 2010, s. 15). Bu nedenle, serilerdeki olağanüstü hareketlilik sonucunda zengin dinamikler sergileme potansiyeline sahip olduklarından dolayı, bunlar genellikle Gaussian olmayan dağılım özellikleri sergilemektedirler. Bu koşullar altında, sadece koşullu ortalamayı modellemekten ziyade, serinin daha yüksek momentlerinin özelliklerine odaklanılmaktadır (Mills, 2019, s. 161).

Bu durumu gerçekleştirmenin en basit hali, Y_t serisini oluşturan sürecin varyansının ya sürekli olarak ya da zaman içinde belirli aralıklarda değişmesine izin vermektir (Mills, 2019, s. 162). Durağan bir sürecin sabit bir varyansa sahip olması gerekse de belirli koşullu varyanslar değişebilir ve böylece koşulsuz varyanslar V_t tüm t için sabit olsa da koşullu varyans $V(Y_t|Y_{t-1}, Y_{t-2}, \dots)$, Y_t 'nin gerçekleşmesine bağlı olan t 'nin gözlemden gözleme değişir olmasıdır.

1.4.1. Otoregresif Koşullu Değişen Varyans (ARCH) Modeli

Bu bölümün amacı, bir zaman serisinin oynaklığını modellemek için literatürde mevcut olan bazı istatistiksel ve ekonometrik modelleri incelemektir. Bu modeller ise koşullu varyans modelleri olarak adlandırılır. Oynaklık, bir zaman serisi için önemli faktördür. Dolayısıyla; ARCH modelleri, başta finansal piyasalar olmak üzere, birçok zaman serisine uygulanmaktadır. Ayrıca ortalama ve varyansı sabit olmayan (değişkenlik gösteren) bir zaman serisinin oynaklığının modellenmesi, parametre tahminindeki verimliliği ve aralık tahminindeki başarısını artırabilmektedir.

Standart regresyon ve zaman serisi modellerindeki birçok tanınmış kontrol, hata terimine ilişkin varsayımlarla belirlenir: Bağımsızlık, sıfır ortalama ile özdeş dağılım ve sabit varyans varsayımları bunlardan bazılarıdır. Varyans başta olmak üzere, daha yüksek koşullu momentler arasında bağımlı olma olasılığı, zaman serisi verilerinde doğrusal olmayan stokastik süreçleri daha gerçekçi bir perspektiften incelemeyi ima eder. Bazı zaman serileri rasgele yürüyüş modelleri ile yaklaşık olarak hesaplanabilmektedir. Ancak rasgele yürüyüş varsayımlarının çok kısıtlayıcı olması nedeniyle, oynaklığın zamanla değişmesi sürecin durağanlığını ihlal edebilmektedir.

Ampirik bir bakış açısına göre, özelde finansal zaman serileri, çeşitli doğrusal olmayan dinamikler sunar. Bunların en önemlisi ise serilerin değişkenliğinin geçmiş dönem değerlerine güçlü şekilde bağımlı olmasıdır. Serilerin, doğrusal olmama durumları, sabit olmayan koşullu değişen varyanstır ve genellikle bağımlı değişkene yönelik büyük şokların kümelenmesi ile kendini gösterirler. Diğer bir deyişle, oynaklığın olduğu bir seride varyans zamanla değişir ve büyük (küçük) değişiklikleri takip etme eğilimindedir (Montgomery et al., 2015, s. 507). Koşullu değişen varyans modellerinin

ek bir avantajı ise tahmin aralıklarının tahminini iyileştirmek için stokastik hatadaki, koşullu varyansı modele dahil etmesidir. Bazı doğrusal olmayan modeller, hem koşullu ortalama hem de koşullu varyans ile modellenenmektedir (Poo, 2003, s. 256).

Ekonometrik modellerin çoğunda bir zaman serisinin gelişimi, koşullu ortalamayı/beklentiyi kullanmaktır. Öngörü hatalarının varyansının en aza indirilmesi anlamında en iyi (optimal) tahmin, temel alınan modelin koşullu ortalaması ile elde edilmektedir. Burada hataların sadece korelasyonsuz değil aynı zamanda sabit varyansa sahip (homoscedasticity) olduğu, yani açıklanamayan dalgalanmaların ikinci momentlerde hiçbir bağımlılığının olmadığını varsayar (Kirchgässner & Wolters, 2007, s. 241). Ancak; Benoit Mandelbort (1963), bazı finansal verilerin (genellikle varsayılan) normal dağılıma uygun olmasından ziyade, aykırı değere sahip olabildiğini ve oynaklık kümelerine⁴ sahip olduğunu göstermiştir. Bu durum normal dağılıma kıyasla, dağılımın merkezinde ve kuyruklarda daha fazla kütle sergileyen asimetric/çarpık (leptokurtik) dağılımlara yol açabilmektedir (Brooks, 2008, s. 380). Dolayısıyla bu durum, “aşırı sivrilik” ile neticelenir. Diğer bir deyişle, basıklık değerinin 3’ün üzerine çıkmasına yol açmaktadır (Kirchgässner & Wolters, 2007, s. 242).

Doğrusal regresyon analizindeki sabit varyans varsayımına göre, hataların karelerinin toplamı farklı zaman dönemlerinde aynı olmalıdır (Brooks, 2008, s. 387). Bununla birlikte, birçok zaman serisi verisi, hata terimlerinin varyanslarının eşit olmadığı bazı gözlemler ya da veri dönemleri için hata terimlerinin diğerlerinden daha büyük olması durumunda değişen varyans (heteroscedasticity) olduğu söylenir (Rachev et al., 2007, s. 279). Engle (1982) tarafından literatüre kazandırılmış olan otoregresif koşullu değişen varyans (ARCH) modeli, bu tez çalışmasının uygulama modellerinden birini oluşturmaktadır.

1.4.2. ARCH (p) Modeli

Engle (1982) çalışmasında, varyansın geçmişe bağlı olduğu bir model sınıfı önermiş ve ekonomideki yararlarını tartışmıştır. Tahmin yöntemleri, bu tür modellerin

⁴ Oynaklık kümesi veya oynaklık havuzu: Küçük (büyük) şokların tekrar büyük (küçük) şokları takip etmesidir.

varlığına yönelik testler ve ampirik bir örnek sunmuştur. Başlangıçta birinci dereceden otoregresyon modeli şu şekildedir:

$$Y_t = \gamma Y_{t-1} + \varepsilon_t \quad (1.28)$$

Burada ε , $V(\varepsilon) = \sigma^2$ ile beyaz gürültüdür. Y_t 'nin koşullu ortalaması γY_{t-1} iken koşulsuz ortalaması sıfırdır. Zaman serisi modellerinden kaynaklanan tahminler, koşullu ortalamanın kullanılmasından kaynaklanmaktadır. Y_t 'nin koşullu varyansı σ^2 iken koşulsuz varyansı $\sigma^2/(1 - \gamma^2)$ 'dir. Geçmişten gelen ek bilgilerin tahmin varyansını etkilemesine izin verilirse, gerçek süreçler için daha iyi tahmin aralıkları beklenebilir.

Değişen varyansın standart yaklaşımı, varyansı tahmin eden bir dışsal değişken X_t 'nin ortalaması sıfır olarak bilinen bir modeli aşağıdaki eşitlik ile verilmektedir:

$$Y_t = \varepsilon_t X_{t-1} \quad (1.29)$$

Burada yine $V(\varepsilon) = \sigma^2$ 'dir. y_t 'nin varyansı $\sigma^2 X_{t-1}^2$ dir ve bu nedenle tahmin aralığı dışsal bir değişkenin gelişimine bağlıdır. Soruna yönelik bu standart çözüm hem koşullu ortalamanın hem de varyansların zamanla birlikte gelişebileceği için yetersiz görünmektedir. Belki de bu zorluk nedeniyle, zaman serisi verilerinde değişen varyans düzeltmeleri nadiren dikkate alınır.

Koşullu varyansın serinin geçmiş gerçekleşmesine bağlı olmasına izin veren bir model Granger ve Andersen tarafından tanımlanan doğrusal modeldir:

$$Y_t = \varepsilon_t Y_{t-1} \quad (1.30)$$

Bu durumda koşullu varyans artık $\sigma^2 Y_{t-1}^2$ 'dir (Işığışık, 1999, s. 2). Bununla birlikte, koşulsuz varyans ya sıfırdır ya da sonsuzdur. Bu da bunu çekici olmayan bir formülasyon haline getirir ancak hafif genellemeler bu sorunu önler. Tercih edilen bir model:

$$Y_t = e_t \sqrt{h_t}$$

$$h_t = \alpha_0 + \alpha_1 Y_{t-1}^2 \quad (1.31)$$

Burada $V(\varepsilon_t) = 1$ 'dir. Bu otoregresif koşullu varyans ARCH modeli olarak isimlendirilecek olanın bir örneğidir. Tam olarak çift doğrusal bir model değil, ancak bire çok yakındır. Normallik varsayımı eklendiğinde t zamanda mevcut olan bilgi seti olan Ψ_t türünden ifade edilebilir:

$$Y_t|\psi_{t-1} \sim N(0, h_t) \quad (1.32)$$

$$h_t = \alpha_0 + \alpha_1 Y_{t-1}^2 \quad (1.33)$$

Varyans fonksiyonu daha genel şu şekilde ifade edilebilir:

$$Y_t = h(Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}, \alpha) \quad (1.34)$$

ARCH regresyon modeli Y_t 'nin ortalamasının $X_t\beta$ olarak verildiği varsayılarak elde edilir. ψ_{t-1} bilgi kümesine dahil edilen gecikmeli içsel ve dışsal değişkenlerin doğrusal bir kombinasyonu ve β ise bilinmeyen parametre vektörüdür. Model biçimsel olarak şöyle yazılabilir:

$$Y_t|\psi_{t-1} \sim N(X_t\beta, h_t)$$

$$h_t = h(e_{t-1}, e_{t-2}, \dots, e_{t-p}, \alpha) \quad (1.35)$$

$$\varepsilon_t = Y_t - X_t\beta$$

Burada p , ARCH sürecinin sırasındır ve α bilinmeyen parametrelerin bir vektörüdür. Varyans fonksiyonu mevcut gecikmeli X 'leri de içerecek şekilde daha da genişletilebilir. Çünkü bunlar da bilgi kümesine girmektedir (Engle, 1982, s. 989):

$$h_t = h(e_{t-1}, e_{t-2}, \dots, e_{t-p}, X_t, X_{t-1}, \dots, X_{t-p}, \alpha) \quad (1.36)$$

veya

$$h_t = h(\psi_{t-1}, \alpha)$$

ve özellikle h_t fonksiyonu aşağıdakileri hesaba katarsa, şöyle yazılabilir:

$$h_t = h_t(\varepsilon_{t-1}, \dots, \varepsilon_{t-p}, \alpha) h_x(X_t, \dots, X_{t-p}) \quad (1.37)$$

Bu genelleme bu çalışmada ele alınmadığı için sadece tanım olarak verilmiştir.

1.4.3. Olabilirlik Fonksiyonu

Y_t 'nin denklem (1.32) ve (1.33)'te açıklanan bir ARCH süreci tarafından üretildiği varsayalım. Bu sürecin özellikleri $E(x) = E(E(x)|\psi)$ ilişkisinin tekrar tekrar uygulanmasıyla belirlenebilir. Y_t 'nin ortalaması ve tüm otokovaryansları sıfırdır. Koşulsuz varyansı ise $\sigma_t^2 = EY_t^2 = Eh_t$ 'dir. Birçok h fonksiyonu ve α 'nın değeri için

varyans t 'den bağımsızdır. Bu koşullar altında Y_t 'nin kovaryansı durağanlığı için bir dizi yeterli koşul aşağıda türetilmiştir. (1.32) ve (1.33) ile tanımlanan süreç tüm gözlemlerin koşullu normal dağılıma sahip olmasına rağmen, Y vektörü ile birlikte normal dağılım sergilemez. Ortak yoğunluk, tüm koşullu yoğunlukların ürünüdür ve bu nedenle \log olabilirlik (1.32) ve (1.33)'e karşılık gelen normal koşullu \log olasılıklarının toplamıdır. l ortalama \log olabilirlik ve l_t , t 'inci gözlemin \log olabilirliği ile örneklem büyüklüğü T olsun. Bu durumda,

$$l = \frac{1}{T} \sum_{t=1}^T l_t \quad (1.38)$$

$$l_t = -\frac{1}{2} \log h_t - \frac{1}{2} y_t^2 / h_t$$

olabilirlikteki bazı sabitler dışında bilinmeyen parametreleri α tahmin etmek için bu olabilirlik fonksiyonu maksimize edebilir. Birinci-sıra koşullar;

$$\frac{\partial l_t}{\partial \alpha} = \frac{1}{2h_t} \frac{\partial h_t}{\partial \alpha} \left(\frac{y_t^2}{h_t} - 1 \right) \quad (1.39)$$

ve Hessian,

$$\frac{\partial^2 l_t}{\partial \alpha \partial \alpha'} = -\frac{1}{2h_t} \frac{\partial h_t}{\partial \alpha} \frac{\partial h_t}{\partial \alpha'} \left(\frac{y_t^2}{h_t} \right) + \left[\frac{y_t^2}{h_t} - 1 \right] \frac{\partial}{\partial \alpha'} \left[\frac{1}{2h_t} \frac{\partial h_t}{\partial \alpha} \right] \quad (1.40)$$

ψ_{t-m-1} verilen ikinci terimin koşullu beklentisi sıfırdır ve birincideki son faktör birdir. Dolayısıyla, tüm gözlemler üzerinden ortalaması alınan Hessian'nın olumsuz beklentisi olan bilgi matrisi tarafından

$$I_{\alpha\alpha} = \sum_t \frac{1}{2T} E \left[\frac{1}{h_t^2} \frac{\partial h_t}{\partial \alpha'} \frac{\partial h_t}{\partial \alpha} \right] \quad (1.41)$$

tutarlı bir şekilde tahmin edilen,

$$\hat{I}_{\alpha\alpha} = \frac{1}{T} \sum_t \left[\frac{1}{2h_t^2} \frac{\partial h_t}{\partial \alpha} \frac{\partial h_t}{\partial \alpha'} \right] \quad (1.42)$$

h fonksiyonu p 'inci dereceden lineer ise (karelerde) şöyle yazılabilir:

$$h_t = \alpha_0 + \alpha_1 Y_{t-1}^2 + \dots + \alpha_p Y_{t-p}^2 \quad (1.43)$$

O zaman bilgi matrisi ve gradient (gradyan-eğim-türev) özellikle basit bir forma sahiptir. $Z_t = (1, Y_{t-1}^2, \dots, Y_{t-p}^2)$ ve $\alpha' = (\alpha_0, \alpha_1, \dots, \alpha_p)$ olsun, böylece (1.43)'deki eşitlik yeniden yazılabilir:

$$h_t = z_t \alpha \quad (1.44)$$

Kısmi türev alınarak,

$$\frac{\partial l}{\partial \alpha} = \frac{1}{2h_t} z_t \left(\frac{y_t^2}{h_t} - 1 \right) \quad (1.45)$$

ve bilgi matrisinin tahmini:

$$\hat{I}_{\alpha\alpha} = \frac{1}{2T} \sum_t (Z_t' Z_t / h_t^2) \quad (1.46)$$

elde edilecektir.

1.4.4. ARCH Regresyon Modelinin Tahmini

ARCH rasgele değişkenleri, dışsal ve gecikmeli bağımlı değişkenlerin doğrusal bir kombinasyonu olarak ve regresyon çerçevesine uygun olarak ifade edilebilen ve Eşitlik (1.35) ve (1.36)'daki gibi yazılabilir. Model için alternatif bir yorum ise doğrusal bir regresyondaki bozulmanın bir ARCH sürecini takip etmesidir. p'inci dereceden olabilirlik spesifikasyonu şu şekilde verilir:

$$\begin{aligned} Y_t | \psi_{t-1} &\sim N(X_t \beta, h_t), \\ h_t &= \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_p \varepsilon_{t-p}^2, \\ \varepsilon_t &= Y_t - X_t \beta, \\ l &= \frac{1}{T} \sum_{t=1}^T l_t, \\ l_t &= \frac{1}{2} \log h_t - \frac{1}{2} \varepsilon_t^2 / h_t \end{aligned} \quad (1.47)$$

Bu olabilirlik fonksiyonu bilinmeyen α ve β parametrelerine göre maksimize edilebilir. (1.47)'deki varsayımlar altında, β parametresinin olağan en küçük kareler (OLS) tahmincisi tutarlıdır. Çünkü X ve ε , regresyonun koşullu bir beklenti olarak tanımlanması yoluyla korelasyonsuzdur. Eğer X 'ler sabit olarak ele alınıyorsa, OLS tahmininin standart hataları doğru olacaktır. Ancak X_t 'de gecikmeli bağımlı değişkenler varsa, hataların kareleri ile bağıntılı olacağından, geleneksel hesaplanan standart hatalar tutarlı olmayacaktır. Bu White'in değişen varyans ile ilgili argümanının bir uzantısı olup

kovaryans matrisi için alternatif formunu kullanmanın, OLS standart hatasının tutarlı bir tahminini vereceğini öne sürer.

Regresörler bağımlı değişken içermiyorsa ve süreç durağan ise Y ve X 'in sırasıyla $T \times 1$ ve $T \times K$ vektörü ile bağımlı ve bağımsız değişken olmasına izin veren süreç şu şekilde ifade edilir:

$$E(Y|X) = X\beta \quad (1.48)$$

$$\text{Var}(Y|X) = \sigma^2 I \quad (1.49)$$

Geçerli olan bu ifade, aynı zamanda Gauss-Markov varsayımlarını da sağlayacaktır. OLS, Eşitlik (1.47)'deki model için en iyi doğrusal yansız tahmin edicidir ve varyans tahminleri yansız ve tutarlıdır. Ancak maksimum olabilirlik farklıdır ve asimptotik olarak üstündür.

Birinci sıra koşul yerine getirilerek β 'ya göre kısmi türevi alınarak maksimum olabilirlik tahmincisi şöyle bulunur:

$$\frac{\partial l_t}{\partial \beta} = \frac{\varepsilon_t X_t'}{h_t} + \frac{1}{2h_t} \frac{\partial h_t}{\partial \beta} \left(\frac{\varepsilon_t^2}{h_t} - 1 \right) \quad (1.50)$$

Birinci terim dışsal değişken varyans düzeltmesi için bilinen birinci dereceden koşuldur. İkinci terim ortaya çıkar, çünkü h_t aynı zamanda Amemiya (1973)'de olduğu gibi β 'ların bir fonksiyonudur. Doğrusal varyans fonksiyonunun yerine konulması ile;

$$\frac{\partial l}{\partial \beta} = \frac{1}{T} \sum \left[\frac{\varepsilon_t X_t'}{h_t} - \frac{1}{h_t} \left(\frac{\varepsilon_t^2}{h_t} - 1 \right) \sum_j \alpha_j \varepsilon_{t-j} \varepsilon_{t-j}' \right] \quad (1.51)$$

X ve ε terimlerini aşağıdaki gibi toplayarak yaklaşık olarak yeniden yazılabilir:

$$\frac{\partial l}{\partial \beta} = \frac{1}{T} \sum_t X_t' \varepsilon_t \left[h_t^{-1} - \sum_{j=1}^p \alpha_j h_{t+j}^{-2} (\varepsilon_{t+j}^2 - h_{t+j}) \right] \quad (1.52)$$

Köşeli parantez içerisindeki ifade s_t olarak isimlendirilerek aşağıdaki gibi belirtilir:

$$\equiv \frac{1}{T} \sum_t X_t' \varepsilon_t s_t$$

Hessian şöyledir:

$$\frac{\partial^2 l_t}{\partial \beta \partial \beta'} = -\frac{X_t' X_t}{h_t} - \frac{1}{2h_t^2} \frac{\partial h_t}{\partial \beta} \frac{\partial h_t}{\partial \beta'} \left(\frac{\varepsilon_t^2}{h_t} \right) - \frac{2\varepsilon_t}{h_t^2} \frac{\partial h_t}{\partial \beta} + \left(\frac{\varepsilon_t^2}{h_t} - 1 \right) \frac{\partial}{\partial \beta'} \left[\frac{1}{2h_t} \frac{\partial h_t}{\partial \beta} \right]$$

Hessian'dan koşullu beklentiler alındığında, son iki terim tamamen geçmişin bir fonksiyonu olduğu için ortadan kalkar. Benzer şekilde ikinci terimdeki ε_t^2/h_t ifadesi geçerli olduğundan bir olmaktadır. X_t 'nin gecikmeli bağımlı değişkenleri içerip içermediğine bakılmaksızın geçerliliğini korumaktadır. Bilgi matrisi, koşullu beklentilerin beklenen değerinin tüm t'lerin ortalamasıdır ve bu nedenle aşağıdaki gibi verilir:

$$\begin{aligned} I_{\beta\beta} &= \frac{1}{T} \sum_t E \left[E \left(\frac{\partial^2 l_t}{\partial \beta \partial \beta'} \mid \psi_{t-1} \right) \right] \\ &= \frac{1}{T} \sum_t E \left[\frac{X_t' X_t}{h_t} + \frac{1}{2h_t^2} \frac{\partial h_t}{\partial \beta} \frac{\partial h_t}{\partial \beta'} \right] \end{aligned} \quad (1.53)$$

p'inci dereceden doğrusal ARCH regresyonu için tutarlı bir şekilde şu şekilde tahmin edilir:

$$\hat{I}_{\beta\beta} = \frac{1}{T} \sum \left[\frac{X_t' X_t}{h_t} + 2 \sum_j \alpha_j^2 \frac{\varepsilon_{t-j}^2}{h_t^2} X_{t-j}' X_{t-j} \right] \quad (1.54)$$

Eşitlik (1.54)'deki son etkiler dışında, terimleri $X_t' X_t$ 'de toplayarak ve köşeli parantezi r_t^2 ile ifade edilirse eşitlik yeniden şöyle yazılabilir:

$$\begin{aligned} \hat{I}_{\beta\beta} &= \frac{1}{T} \sum_t X_t' X_t \left[\frac{1}{h_t} + 2 \varepsilon_t^2 \sum_{j=1}^p \alpha_j^2 h_{t+j}^{-2} \right] \\ &\equiv \frac{1}{T} \sum_t X_t' X_t r_t^2 \end{aligned} \quad (1.55)$$

Bilgi matrisinin diogonal olmayan bloku ise şöyledir:

$$I_{\alpha\beta} = \frac{1}{T} E \left(\frac{1}{2h_t^2} \frac{\partial h_t}{\partial \alpha} \frac{\partial h_t}{\partial \beta'} \right) \quad (1.56)$$

Eşitlik (1.56)'daki $I_{\alpha\beta}$ Hessian matrisinin ters işaretlisi olması nedeniyle, bilgi sisteminin diogonal olmayan blokuna eşit olmaktadır. ARCH, simetrik ve düzenli olması nedeniyle $I_{\alpha\beta} = 0$ olacak ve bu diogonal olmayan bloku sıfıra eşit hale getirecektir. Dolayısıyla α ve β parametrelerinin tahmini asimptotik verim kaybı olmadan ayrı ayrı ele alınabildiği ve bunların varyanslarının da ayrı ayrı hesaplanabildiği için ulaşılan çıkarımlar geniş kapsamlıdır (Engle, 1982, s. 996).

1.5. GENELLEŞTİRİLMİŞ OTOREGRESİF KOŞULLU DEĞİŞEN VARYANS (GARCH) MODELİ

Geleneksel zaman serileri ve ekonometrik modeller, sabit varyans varsayımı altında oluşturulurken, Engle (1982) tarafından literatüre ARCH süreci olarak sunulan model, koşullu varyansın, koşulsuz varyansı sabit bırakarak, hataların geçmiş dönem değerlerinin bir fonksiyonu olarak zaman içerisinde değişmesine izin veren modeli öne sürmüştür.

GARCH modeli, varyansın cari dönem değerlerinin belirlenmesinde, geçmiş dönem değerleri rol almaktadır. Bu nedenle, ARCH modeli yerine zaman zaman tercih edilebilmektedir (Işığışık, 1999, s. 6). Aynı zamanda ARCH modelindeki gecikme değerleri çok uzun olduğunda, GARCH modelinin kullanılması gecikme yapısının kısalmada etkili olması nedeniyle, daha kullanışlı modellerdir. Bu başlıkta, çok daha esnek bir gecikme yapısına izin veren ve daha genel bir süreç sınıfı olan Genelleştirilmiş Otoregresif Koşullu Değişen Varyans modeli ele alınacaktır.

1.5.1. GARCH(p,q) Modeli

ARCH modelinin uygulamalarında, koşullu varyans denkleminde, gecikme yapısının uzunluğu ve negatif ARCH parametrelerinin (α), tahminiyle ilgili sorundan kaçınmak için tipik olarak sabit bir gecikme yapısı uygulanır. Bu doğrultuda hem daha uzun bir hafızaya (Nargeleçekenler, 2004, s. 158) hem de daha esnek bir gecikme yapısına izin verebilmek için Bollerslev (1986) tarafından ARCH modeli genelleştirilmiş ve GARCH süreci olarak literatüre kazandırılmıştır.

ε_t , gerçek değerli ayırık zamanlı bir stokastik süreci ve ψ_t , t zamanı boyunca tüm bilgileri içeren bilgi kümesini göstermek üzere, GARCH(p,q) modeli (süreci) aşağıdaki gibi verilmektedir (Bollerslev, 1986, s. 309):

$$\varepsilon_t | \psi_{t-1} \sim N(0, h_t) \quad (1.57)$$

$$h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j h_{t-j} \quad (1.58)$$

$$= \alpha_0 + A(L)\varepsilon_t^2 + B(L)h_t$$

Burada şu kısıtlamalar vardır:

$$\begin{aligned} \Rightarrow p &\geq 0, q > 0 \\ \Rightarrow \alpha_0 > 0 \text{ ve } \alpha_i &\geq 0 \quad i = 1, 2, \dots, q \\ \Rightarrow \beta_j &\geq 0 \quad j = 1, 2, \dots, p \end{aligned}$$

$p = 0$ için model ARCH(q) modeline indirgenir ve $p=q=0$ için, ε_t sadece beyaz gürültüdür. ARCH(q) işlemine koşullu varyans, yalnızca geçmiş örnek varyanslarının doğrusal bir fonksiyonu olarak belirtirken GARCH(p,q) modeli gecikmeli koşullu varyansların da modele girmesine izin verir. Bu bir tür uyarlanabilir öğrenme mekanizmasına (adaptive learning) karşılık gelir.

GARCH(p,q) regresyon modeli, ε_t 'lerin lineer bir regresyonda yenilikler olmasına izin verilerek elde edilir:

$$\varepsilon_t = Y_t - X_t' b, \quad (1.59)$$

Burada Y_t bağımlı değişken, X_t bağımsız değişkenlerin bir vektörü ve b ise bilinmeyen parametrelerin bir vektörüdür. $1 - B(z) = 0$ 'ın tüm kökleri birim çember dışında ise Eşitlik (1.58), ε_t 'lerin dağıtılmış gecikmesi olarak yeniden yazılabilir:

$$\begin{aligned} h_t &= \alpha_0(1 - B(1))^{-1} + A(L)(1 - B(L))^{-1} \varepsilon_t^2 \\ &= \alpha_0(1 - \sum_{j=1}^p \beta_j)^{-1} + \sum_{i=1}^{\infty} \delta_i \varepsilon_{t-i}^2 \end{aligned} \quad (1.60)$$

Eşitlik (1.57) ile birlikte sonsuz boyutlu bir ARCH(∞) süreci olarak görülebilir. δ_i 'ler $D(L) = A(L)(1 - B(L))^{-1}$ 'in güç serisi (power series) açılımında bulunur:

$$\begin{aligned} \delta_i &= \alpha_i + \sum_{j=i}^n \beta_j \delta_{i-j} \quad i = 1, 2, \dots, q \\ &= \sum_{j=i}^n \beta_j \delta_{i-j} \quad i = q + 1, \dots \end{aligned} \quad (1.61)$$

Burada, $n = \min\{p, i - 1\}$ 'dir. Eğer $B(1) < 1$ ise ve δ_i , $m = \max\{p, q\}$ 'den büyük i için azalıyor olacaktır. Bu nedenle $D(1) < 1$ ise GARCH(p,q) süreci yeterince büyük bir q değeri için durağan bir ARCH(q) ile herhangi bir doğruluk derecesine yaklaştırılabilir (Bollerslev, 1986, s. 310).

Sonlu boyutlu ARCH(q) süreçleri teorisinden, geniş anlamda durağanlık için $D(1) < 1$ veya eşdeğeri $A(1) + B(1) < 1$ olması beklenir (Milhøj, 1985). GARCH (p,q) sürecinin eşdeğer bir temsili şu şekilde verilmektedir:

$$\varepsilon_t^2 = \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \varepsilon_{t-j}^2 - \sum_{j=1}^p \beta_j v_{t-j} \quad (1.62)$$

ve

$$v_t = \varepsilon_t^2 - h_t = (\eta_t^2 - 1)h_t \quad (1.63)$$

Burada, $\eta_t \sim N(0,1)$ 'dir.

Tanım gereği v_t 'nin ortalaması sıfır ve korelasyonsuzdur. Bu nedenle, GARCH(p,q) süreci, sırasıyla $m = \max\{p, q\}$ ve p'inci mertebeden ε_t^2 'de bir otoregresif hareketli ortalama süreci olarak yorumlanabilir.

Ayrıca, Y_t değişkeninin artıklarının koşullu varyansının, bir ARMA sürecini oluşturmasını göstermesi beklenir. Dolayısıyla, ARMA modelinden elde edilen hatalar, bu yapıya benzerlik gösterirler (Işığışok, 1999, s. 7). ARMA süreci olarak öngörülen Y_t serisi ile oluşturulan model uygun ise otokorelasyon ve kısmi otokorelasyon fonksiyonları beyaz gürültü sürecini göstermelidir (Nargeleçekenler, 2004, s. 159). Aynı zamanda, ARCH sürecinin, GARCH sürecine genişletilmesi, standart zaman serisi modellerinden AR modeli sürecinin genel ARMA sürecine genişletilmesine benzemektedir.

1.5.2. GARCH (1,1) Süreci

En basit ama genellikle çok kullanışlı GARCH (1,1) süreci, Eşitlik (1.57)'de verilen genel GARCH(p,q) sürecinden hareketle aşağıdaki gibidir:

$$h_t = \alpha_0 \alpha_1 \varepsilon_{t-1}^2 + \beta_1 h_{t-1} \quad (1.64)$$

$$\alpha_0 > 0, \quad \alpha_1 \geq 0, \quad \beta_1 \geq 0$$

Geniş anlamda durağanlık için $\alpha_1 + \beta_1 < 1$ yeterlidir. Eşitlik (1.58) ve (1.62) de verilen GARCH (1,1) süreci, 2. momentin varlığı için yeterli ve gerekli koşul:

$$\mu(\alpha_1, \beta_1 m) = \sum_{j=0}^m \binom{m}{j} \alpha_j \alpha_1^j \beta_1^{m-j} < 1 \quad (1.65)$$

Burada:

$$\alpha_0 = 1, \alpha_j = \prod_{i=1}^j (2i - 1) \quad \text{ve} \quad j = 1, 2, \dots \quad (1.66)$$

2. moment özyinelemeli formülle ifade edilebilir:

$$E(\varepsilon_t^{2m}) = a_m \left[\sum_{n=0}^{m-1} a_n^{-1} E(\varepsilon_t^{2n}) \alpha_0^{m-n} \binom{m}{m-n} \mu(\alpha_1, \beta_1, n) \right] \times [1 - \mu(\alpha_1, \beta_1, m)]^{-1} \quad (1.67)$$

İkinci moment varsa, simetri $E(\varepsilon_t^{2m-1}) = 0$ olur (Bollerslev, 1986, s. 311).

$\beta_1 = 0$ için Eşitlik 9'a göre ARCH (1) süreci için en iyi koşul, $a_m \alpha_1^m < 1$; (Engle, 1982, ss. 1005–1006). Böylece ARCH (1) sürecinde $\alpha_1 > (a_m)^{-1/m}$ ise ikinci moment mevcut değildir. Oysa $\sum_{i=1}^{\infty} \delta_i = \alpha_1 (1 - \beta)^{-1} > (a_m)^{-1/m}$ GARCH (1,1) sürecinde bu işlemde daha uzun bellek nedeniyle ikinci moment çok iyi var olabilir.

GARCH(1,1) sürecinde koşullu varyansta ortalama gecikme denklem tarafından verilir (Bollerslev, 1986, s. 311):

$$\bar{\delta} = \sum_{i=1}^{\infty} i \delta_i / \sum_{i=1}^{\infty} \delta_i = (1 - \beta_i)^{-1}$$

ve medyan gecikme olduğu bulunabilir:

$$v = -\log 2 / \log \beta_1$$

Burada, $\frac{\sum_{i=1}^v \delta_i}{\sum_{i=1}^{\infty} \delta_i} = \frac{1}{2}$ ve δ_i değeri, Eşitlik (1.58)'de tanımlanmıştır (Bollerslev, 1986, s. 312). Eğer, $3\alpha_1^2 + 2\alpha_1\beta_1 + \beta_1^2 < 1$ ise Bollerslev (1986)'da öne sürmüştüğü Teorem 2⁵'ye göre dördüncü dereceden moment mevcuttur.

$$E(\varepsilon_t^2) = \alpha_0 (1 - \alpha_1 - \beta_1)^{-1}$$

ve

$$E(\varepsilon_t^4) = 3\alpha_0^2 = (1 + \alpha_1 + \beta_1)[(1 - \alpha_1 - \beta_1)(1 - \beta_1^2 - 2\alpha_1\beta_1 - 3\alpha_1^2)]^{-1}$$

Bu nedenle basıklık katsayısı:

$$K = (E(\varepsilon_t^4) - 3E(\varepsilon_t^2)^2)E(\varepsilon_t^2)^{-2}$$

⁵ Bkz. Bollerslev 1986, s. 325.

$$= 6\alpha_1^2(1 - \beta_1^2 - 2\alpha_1\beta_1 - 3\alpha_1^2)^{-1}$$

Bu değer, varsayıma göre sıfırdan büyüktür. Dolayısıyla; GARCH (1,1) süreci, sürecin ARCH (q) süreci ile paylaştığı bir özellik olan leptokurtic (ağır kuyruk / sivri seri) özelliğine sahiptir (Mihøj, 1985).

1.5.3. GARCH Regresyon Modelinin Tahmini

Bu bölümde Eşitlik (1.57), (1.58) ve (1.59)'da verilen GARCH regresyon modelinin maksimum olabilirlik tahmini ele alınacaktır. Ancak sonuçların ARCH regresyon modeline benzemesi nedeniyle, anlatım kısa tutulacaktır. GARCH regresyon modeli

$$Z_t' = (1, \varepsilon_{t-1}^2, \dots, \varepsilon_{t-q}^2, h_{t-1}, \dots, h_{t-p}), w' = (\alpha_0, \alpha_1, \dots, \alpha_q, \beta_1, \dots, \beta_p) \text{ ve } \theta = (b', w')$$

olarak tanımlandıktan sonra, model (1.68)'deki gibi yeniden yazılabilir. Bu eşitlikteki w' , $(1 + p + q) \times 1$ boyutlu varyans denkleminde ait parametreler vektörü, θ ise sistemin bütün parametrelerini barındıran $(k + 1 + q + p) \times 1$ boyutlu vektördür.

$$\varepsilon_t = Y_t - X_t' b$$

$$\varepsilon_t | \psi_{t-1} \sim N(0, h_t) \quad (1.68)$$

$$h_t = Z_t' w$$

T örnek büyüklüğü için log olabilirlik fonksiyonu:

$$L_T = T^{-1} \sum_{t=1}^T l_t(\theta)$$

$$l_t(\theta) = -\frac{1}{2} \log h_t - \frac{1}{2} \varepsilon_t^2 h_t^{-1} \quad (1.69)$$

Varyans denklemi parametresi olan w' 'ye göre kısmi türevi alındığında,

$$\frac{\partial l_t}{\partial w} = \frac{1}{2} \frac{1}{h_t} \frac{\partial h_t}{\partial w} \left(\frac{\varepsilon_t^2}{h_t} - 1 \right) \quad (1.70)$$

$$\frac{\partial^2 l_t}{\partial w \partial w'} = \left(\frac{\varepsilon_t^2}{h_t} - 1 \right) \frac{\partial}{\partial w'} \left[\frac{1}{2} h_t^{-1} \frac{\partial h_t}{\partial w} \right] - \frac{1}{2} h_t^{-2} \frac{\partial h_t}{\partial w} \frac{\partial h_t}{\partial w'} \frac{\varepsilon_t^2}{h_t} \quad (1.71)$$

Burada,

$$\frac{\partial h_t}{\partial w} = Z_t + \sum_{i=1}^p \beta_i \frac{\partial h_{t-i}}{\partial w} \quad (1.72)$$

Bu eşitlikteki tek fark Eşitlik (1.72)'deki özyinelemeli kısmın dahil edilmesidir. Burada, $B(1) < 1$, Eşitlik (1.72)'nin kararlı olduğu belirtilmektedir. Eşitlik (1.71)'deki ilk terimin koşullu beklentisi sıfır olduğundan bilgi matrisinin w 'ye karşılık gelen kısmı, yalnızca birinci türevleri içeren Eşitlik (1.71)'deki son terimin örnek benzerliği (analoğu) tarafından tutarlı bir şekilde tahmin edilir.

Ortalama parametre verimlerine göre farklılaştırma şöyledir:

$$\frac{\partial l_t}{\partial b} = \varepsilon_t X_t h_t^{-1} + \frac{1}{2} h_t \frac{\partial h_t}{\partial b} \left(\frac{\varepsilon_t^2}{h_t} - 1 \right) \quad (1.73)$$

$$\begin{aligned} \frac{\partial^2 l_t}{\partial b \partial b'} &= -\frac{1}{h_t} X_t X_t' - \frac{1}{2} h_t^{-2} \frac{\partial h_t}{\partial b} \frac{\partial h_t}{\partial b'} \left(\frac{\varepsilon_t^2}{h_t} \right) \\ &= -2h_t^2 \varepsilon_t \frac{\partial h_t}{\partial b} + \left(\frac{\varepsilon_t^2}{h_t} - 1 \right) \frac{\partial}{\partial b'} \left[\frac{1}{2} h_t^{-1} \frac{\partial h_t}{\partial b} \right] \end{aligned} \quad (1.74)$$

Burada,

$$\frac{\partial h_t}{\partial b} = -2 \sum_{j=1}^q \alpha_j X_{t-j} \varepsilon_{t-j} + \sum_{j=1}^p \beta_j \frac{\partial h_{t-j}}{\partial b} \quad (1.75)$$

şeklindedir.

Burada da ARCH regresyon denkleminde tek fark özyinelemeli kısmın Eşitlik (1.75)'e dahil edilmesidir. Bilgi matrisinin b 'ye karşılık gelen kısmının tutarlı bir tahmini, Eşitlik (1.74)'deki ilk iki terimin örnek benzerliği tarafından verilir. Ancak ikinci terimdeki $\varepsilon_t^2 h_t^{-1}$, beklenen değeri bir ile değiştirilmiştir. Bu tahmin yalnızca birinci türevleri de içerecektir.

Son olarak, bilgi matrisindeki köşegen dışı bloktaki elemanlar sıfır olarak gösterilebilir. Bu asimptotik bağımsızlık nedeniyle w , tutarlı bir b tahminine dayalı olarak asimptotik etkinlik kaybı olmadan tahmin edilebilir ve bunun tersi de geçerlidir.

Maksimum olabilirlik tahminlerini ve ikinci dereceden verimliliği (second-order efficiency) elde etmek için iteratif bir prosedür gereklidir (Bollerslev, 1986, s. 316). ARCH(q) regresyon modeli için puanlama yöntemi, basit bir yardımcı regresyon olarak ifade edilebilir. Ancak Eşitlik (1.72) ve (1.75)'deki özyinelemeli terimler bu prosedürü karmaşıktırır. Bunun yerine; Bernart, Hall, Hall ve Hausman (BHHH) (1974)

algoritmasının uygun olduğu belirlenmiştir. $\theta^{(i)}$ iterasyondan sonraki parametre tahminlerini gösterebilir. $\theta^{(i+1)}$ daha sonra şöyle hesaplanır:

$$\theta^{(i+1)} = \theta^{(i)} + \lambda_i \left(\sum_{t=1}^T \frac{\partial l_t}{\partial \theta} \frac{\partial l_t}{\partial \theta'} \right)^{-1} \sum_{t=1}^T \frac{\partial l_t}{\partial \theta}$$

Burada, $\frac{\partial l_t}{\partial \theta}$, $\theta^{(i)}$ 'de değerlendirilir ve λ_i verilen yönde olabilirlik fonksiyonunu maksimize etmek için seçilen değişken bir adım uzunluğudur. Yön vektörünün, $\frac{\partial l_t}{\partial \theta}$ üzerinde bir Tx1 vektörünün OLS regresyonundan hesaplanabilmektedir. Ayrıca bilgi matrisindeki blok köşegenliği nedeniyle, $w^{(i)}$ ve $b^{(i)}$ için iterasyonlar ayrı ayrı gerçekleştirilebilir. Maksimum olabilirlik tahmini, $\hat{\theta}_T$ 'nin θ_0 için güçlü bir şekilde tutarlı olduğu ve ortalama θ_0 ve kovaryans matrisi $\mathcal{F}^{-1} = -E(\partial^2 l_t / \partial \hat{\theta} \partial \theta')$ ile asimptotik olarak normal olduğudur. Bununla birlikte, $\mathcal{F} = F$ 'dir. Burada $F = E((\partial l_t / \partial \theta)(\partial l_t / \partial \theta'))$ ve asimptotik kovaryans matrisinin tutarlı bir tahmini ve bu nedenle BHHH iterasyonu $T^{-1}(\sum_{t=1}^T (\partial l_t / \partial \theta)(\partial l_t / \partial \theta'))^{-1}$ tarafından verilir.

Eşitlik (1.57)'nin daha zayıf varsayımlar kümesiyle değiştirilmesi ile:

$$E(\varepsilon_t | \psi_{t-1}) = 0$$

$$E(\varepsilon_t^2 h_t^{-1} | \psi_{t-1}) = 1 \quad (1.76)$$

$$E(\varepsilon_t^4 h_t^{-2} | \psi_{t-1}) \leq M < \infty$$

$\hat{\theta}_T$, θ_0 için güçlü bir şekilde tutarlıdır ve ortalama θ_0 ile ancak kovaryans matrisi $\mathcal{F}^{-1} F \mathcal{F}^{-1}$ ile asimptotik olarak normaldir (Weist, 1986) ve White(1982). Gerçek koşullu dağılım doğru ise $F = \mathcal{F}$ ve dolayısıyla $\mathcal{F}^{-1} F \mathcal{F}^{-1} = \mathcal{F}^{-1}$ normaldir.

1.6. ARCH-GARCH BOZUKLUKLARININ TESTİ (ARCH-LM TESTİ)

Gecikmeli bağımlı değişkenli veya gecikmesiz doğrusal regresyon modelinde, bozulmalar koşullu olarak değişen varyanslı değilse, OLS uygun bir prosedürdür (Nargeleçekenler, 2004, s. 157). ARCH modeli iteratif yöntemler gerektirdiğinden,

tahmin etmeye başlamadan önce uygun olup olmadığının test edilmesi gerekmektedir. Lagrange çarpan test yöntemi, birçok benzer durumda olduğu gibi ARCH-GARCH modelleri için de idealdir.

Sıfır hipotezi altında, $\alpha_1 = \alpha_2 = \dots = \alpha_p$ test edilir. Test, sıfırın altındaki puana ve sıfırın altındaki bilgi matrisine dayanmaktadır. $h_t = h(Z_t\alpha)$ ile ARCH modeli düşünüldüğünde burada h , hem doğrusal hem de üstel durumları ve diğer birçok durumu içeren türevlenebilir bir fonksiyon olup $Z_t = (1, \varepsilon_{t-1}^2, \dots, \varepsilon_{t-p}^2)$ 'dir. Sıfır hipotezi altında, h_t , h^0 ile ifade edilen bir sabittir. h' , h 'ın skaler türevi olduğu $\partial h_t / \partial \alpha = h'Z_t'$ yazıldığında puan ve bilgi şu şekilde yazılabilir:

$$\frac{\partial l}{\partial \alpha} \Big|_0 = \frac{h'}{2h^0} \sum_t Z_t' \left(\frac{\varepsilon_t^2}{h^0} - 1 \right) = \frac{h^{0'}}{2h^0} Z' f^0$$

$$I_{\alpha\alpha}^0 = \frac{1}{2} \left(\frac{h^{0'}}{h^0} \right)^2 E Z' Z$$

LM test istatistiği aşağıda belirtildiği gibi tutarlı bir şekilde tahmin edilebilir:

$$\xi^* = \frac{1}{2} f^{0'} Z (Z' Z)^{-1} Z' f^0 \quad (1.77)$$

Burada $Z' = (Z'_1, \dots, Z'_T)$ ve $\left(\frac{e_t^2}{h^0} - 1 \right)$ 'in sütun vektörü ise f^0 'dir.

Bu, Breusch ve Pagan (1979) ile Godfrey (1981) tarafından değişen varyans testi için kullanılan formdur. Belirttikleri gibi h fonksiyonuna yapılan tüm referanslar ortadan kalkar ve bu nedenle test yalnızca $Z_t\alpha$ 'nın bir fonksiyonu olan h için aynıdır.

Bu problemde bilgi matrisinde istenen beklenti, sıfır hipotezi altında değerlendirilebilir. Üstün sonlu örnek performansına sahiptir. Hem bu model hem de değişen varyans modeli için uygun olan ikinci bir sadeleştirme, normallik varsayıldığı için $f^{0'} f^0 / T = 2$ 'nin katı olduğunu belirtmektedir. Böylece asimptotik olarak eşdeğer bir istatistik olacaktır (Bollerslev, 1986, s. 318).

$$\xi = T f^{0'} Z (Z' Z)^{-1} Z' f^0 / f^{0'} f^0 = TR^2 \quad (1.78)$$

Burada R^2 , Z ve f^0 arasındaki çoklu belirlilik (determinasyon) katsayısıdır. Bir sabit eklemek ve bir skaler ile çarpmak bir regresyonun R^2 'sini değiştirmeyeceğinden, bu aynı zamanda e_t^2 'nin bir kesme ve p gecikmeli değerleri üzerindeki regresyonun

R^2 'sidir. Sıfır hipotezi reddedilemediğinde, p serbestlik dereceli ki kare (χ^2), asimptotik olarak dağılacaktır.

Test süreci OLS regresyonunu uygulamak ve hataları kaydetmektir. Söz konusu hataların kareleri, bir sabit ve p gecikme üzerinde regres edilir ve TR^2 yi χ_p^2 olarak test eder. Bu durumda, asimptotik olarak yerel en güçlü test, olabilirlik oranı olacaktır.

1.7. ARCH-GARCH MODELLERİNE İLİŞKİN KISITLAMALAR

ARCH modelinde otoregresyon parametrelerine ilişkin kısıtlamalar (α_0 ve α_i) bulunmaktadır. Koşullu varyansın ε_t 'nin gerçekleşmiş tüm değerleri için pozitif olma zorunluluğu bulunmaktadır. Bu durumun sağlanabilmesi için α_0 ve α_i parametrelerinin negatif olmaması gerekir. Bu durum

$$\alpha_0 > 0 \quad \text{ve} \quad \alpha_i \geq 0 \quad (i = 1, 2, \dots, q \text{ için})$$

şeklinde yazılabilir ((Engle, 1982). ε_t rassal değişken olup $\varepsilon_t^2, \varepsilon_{t-1}^2, \dots, \varepsilon_{t-q}^2$ değerleri pozitif olmaktadır. Bu nedenle rassal değişkenin tüm değerleri için aşağıda ARCH(1) süreci ile belirtildiğinde,

$$h_t = E(\varepsilon_t^2 | \varepsilon_{t-1}^2) = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 \quad (1.79)$$

Kuşkusuz α_0 negatif olduğunda ε_{t-1} yeteri küçüklükteki gerçekleşen değeri ile Eşitlik (1.79)'daki koşullu varyans negatif değer alabilir. Benzer durum α_1 parametresi için de geçerli olacaktır. Eşitlikteki otoregresif sürecin istikrarının sağlanabilmesi için α_1 parametresinin $0 < \alpha_1 < 1$ arasında bir değere sahip olması beklenir. ARCH (q) sürecini fark denkleminde göre tekrar düzenlenirse, sürecin karakteristik denklemi şöyle oluşturulabilir:

$$1 - \alpha_1 \lambda - \alpha_2 \lambda^2 - \dots - \alpha_q \lambda^q = 0 \quad (1.80)$$

Eşitlik (1.80)'de kovaryans durağanlığının gerçekleşebilmesi için karakteristik köklerin mutlak değerce 1'den büyük olması gerekmektedir (Higgins, Berra, 1992). Dinamik istikrarın sağlanabilmesi için α_i 'lerin toplamının

$$\sum_{i=1}^q \alpha_i < 1$$

şeklinde 1'den küçük olması gerekir. Bu durum ise ARCH modelinin bir diğer önemli kısıtıdır. Modele getirilen bu son kısıtın göz ardı edilmesi durumunda, süreç sonsuz varyansa sahip olacaktır (Engle, 1982).

Koşullu varyans, yapısı gereği kendi gecikmeli değerlerinin bir fonksiyonu olarak tasarlanmıştır. Ancak, koşullu varyansın gecikme uzunlukları sayısı arttıkça varyans parametreleri olan α 'ların sayısının artmasını da beraberinde getirecektir. Bu durum, parametrelerin pozitif olma kısıtları ve durağanlığın da güçleşmesine neden olabilecektir. α parametrelerine getirilen kısıtların gerçekleşebilmesi için gecikme sürecinin ağırlıklarının model içinde belirlenmesi gerekmektedir.

ARCH modeline ilişkin yukarıda açıklanan kısıtlamalara ek olarak, benzer kısıtlamalar GARCH modeli için de geçerliliğini korumaktadır. Eşitlik (1.58)'de verilen GARCH modelini temsil eden β_j parametresine ilişkin kısıtlama, ARCH parametresi olan α_i ile birlikte aşağıdaki gibidir:

$$\sum_{i=1}^p \alpha_i + \sum_{j=1}^q \beta_j < 1$$

Geçerli bir ARCH ve/veya GARCH modeli için bu kısıtların yanında $\alpha_0 > 0$, $\alpha_i \geq 0$ ve $\beta_j \geq 0$ olmak zorundadır (Işığışık, 1999, s. 4) ve (Nargeleçekenler, 2004, s. 159).

1.8. VEKTÖR OTOREGRESİF (VAR) MODELLERİ

İktisatçı Tinbergen ve Klein tarafından 1930 ve 1940'lı yıllarda geliştirilmeye başlayan ve 1950-1960 yıllarında geniş eşanlı denklemlerden oluşan makroekonometrik modellere dönüşen eşanlı denklem modelleri, birçok yönden Lucas⁶ (1976) ve Sims (1980) tarafından eleştirilmiştir. Yapısal eşanlı denklem modelleri olarak da tanımlanan bu modellere en yoğun eleştiri Lucas tarafından getirilmiştir. Ona göre, yapısal denklem

⁶ Lucas Kritiği: Eşanlı denklemlerin tahmin amacı dışsal değişkenlerdeki değişmelerin içsel değişkenler üzerindeki etkisini tahmin etmektir. Ancak dışsal değişkenler değişirse ve kar maksimizasyonu amacıyla hareket eden ekonomik birimler değişimin meydana geleceğini görürlerse, davranışlarını uygun biçimde değiştirebilirler. Bu durumda eşanlı denklem modellerindeki katsayılar dışsal değişkenlerdeki değişmelerden bağımsız olarak ele alınamazlar. Lucas kritiği süper dışsallık ile ilgilidir.

sistemindeki karar kuralları (decision rules), doğru olsa dahi ekonomi politikaları değıştikçe aynı kalmayacaktır. Bu eleştiri, eşanlı modellerin arkasında yatan paradigmanın çökmesine neden olmaktadır. Benzer şekilde, iktisadi değışkenler arasındaki ilişki iktisadi politikalara göre değışmektedir. Bu durumda bir regresyon modelinden elde edilen parametreler öngörü için çok fazla anlam ifade etmemektedir.

Sims 1980’de eşanlı denklem modellerinin⁷ ayırtedilme (identification) yöntemlerini eleştirmiş ve özellikle modeldeki bazı değışkenlerin dışsal olarak nitelendirilmesinin arařtırmacının tercihlerine ya da bazı öngörülere de dayandırıldığını belirtmiştir. Sims, eşanlı denklem modellerinin ayırtedilebilmesi için çok sayıda kısıtlamaya ihtiyaç olduğunu vurgulamıştır. Ayrıca modellerdeki denklemleri ayırtedebilmek için konulan kısıtlamaların çoğunun önsezilere ve tartışmalı teorilere dayandığını ifade etmiştir (Sims, 1980, s. 14).

Vektör otoregresif model (Vector Autoregression (VAR)), zamanın herhangi bir döneminde ekonomik serilerin tahminini sađlayan bir yöntem olarak ileri sürülebilir. VAR modeli, yapısal modellerdeki gibi bir değışkenin kendi geçmiş değerlerinden, gelecek değerleri tahmin edilebilecek serileri içeren çeşitli denklemleri kapsamaktadır (Kadılar, 2000, s. 2). Bu yönü ile tek değışkenli otoregresif (AR) modelinin çok değışkenli biçimi olarak nitelendirilebilir (Tarı & Bozkurt, 2006, s. 5). VAR modelleri, yapısal model üzerinde herhangi bir kısıtlamaya gerek duymadan dinamik ilişkileri ortaya koyabilmektedir (Keating, 1990, ss. 453–454). Ayrıca bu modellerde değışkenlerin gecikmeli yapıları modelde yer aldığı için, güçlü öngörü yapılmasına olanak sağlamaktadır (Kumar et al., 1995, s. 365).

VAR modellerinde dışsal değışken bulunmadığı için her bir zaman serisi içsel (endojen) olarak sisteme dahil edilmektedir. Ayrıca her bir değışken otoregresif yapı ile modelde yer almakta ve bu şekli ile tahminler yapılmaktadır. Dolayısıyla, iktisat teorisinden sadece değışken seçimi yapılırken yararlanılmaktadır. Bu sayede modelin parametreleri yapısal bir yorumla yapılmamakta ve teoride belirtilmeyen sonuçlar ortaya çıkabilmektedir (Kadılar, 2000, ss. 41-42).

⁷ Eşanlı denklem modelleri, modellerin öngörü performansları 1970’li yıllarda meydana gelen petrol şokları sonrası önemi zayıflamıştır.

VAR denklem sisteminde amaç, parametre tahmini yapmaktan ziyade zaman serilerinin birbirlerinden nasıl veya ne yönde etkilendiklerini ortaya koymaya çalışmaktır. Bir VAR(p) modelinde katsayıları yorumlamak oldukça güç olduğundan, VAR analizindeki temel amaç, serilerin etki-tepki fonksiyonları, varyans ayrıştırması veya nedensellik analizi sonuçlarını elde etmektir.

k=3 tane durağan değişkene ait p=2 gecikmeli bir VAR modeli aşağıdaki gibi ifade edilmiş olsun:

$$Y_t = a_{11}Y_{t-1} + a_{12}X_{t-1} + a_{13}Z_{t-1} + a_{14}Y_{t-2} + a_{15}X_{t-2} + a_{16}Z_{t-2} + u_{1t} \quad (1.81)$$

$$X_t = a_{21}Y_{t-1} + a_{22}X_{t-1} + a_{23}Z_{t-1} + a_{24}Y_{t-2} + a_{25}X_{t-2} + a_{26}Z_{t-2} + u_{2t} \quad (1.82)$$

$$Z_t = a_{31}Y_{t-1} + a_{32}X_{t-1} + a_{33}Z_{t-1} + a_{34}Y_{t-2} + a_{35}X_{t-2} + a_{36}Z_{t-2} + u_{3t} \quad (1.83)$$

Bu denklem sisteminde, $Y_t = [Y_t, X_t, Z_t]'$ olarak belirtilirse VAR modeli şu şekilde yazılabilir:

$$Y_t = \mu + \Gamma_1 Y_{t-1} + \Gamma_2 Y_{t-2} + u_t$$

Buradan,

$$\Gamma_1 = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix} \quad \Gamma_2 = \begin{bmatrix} a_{14} & a_{15} & a_{16} \\ a_{24} & a_{25} & a_{26} \\ a_{34} & a_{35} & a_{36} \end{bmatrix}$$

Burada, $E[u_t] = 0$ ve $E[u_t u_s'] = \Omega$ olup köşegen olması zorunlu değildir. Diğer bir deyişle, indirgenmiş VAR modelinde şoklar birbiriyle ilişkili olabilirler.

Yukarıda ikinci dereceden VAR modelini birinci dereceden VAR modeli olarak şu şekilde yazılabilir:

$$\begin{bmatrix} Y_t \\ Y_{t-1} \end{bmatrix} = \begin{bmatrix} \mu \\ 0 \end{bmatrix} + \begin{bmatrix} \Gamma_1 & \Gamma_2 \\ I & 0 \end{bmatrix} \begin{bmatrix} Y_{t-1} \\ Y_{t-2} \end{bmatrix} + \begin{bmatrix} u_t \\ 0 \end{bmatrix}$$

Buradan,

$$Y_t = \mu + \Gamma_1 Y_{t-1} + u_t$$

şeklinde yazılabilir. Burada, Γ yandaş (companion) matris adını alır. İndirgenmiş VAR modelinde değişkenlerin, cari dönem hata terimiyle ilişkisiz olduğu varsayıldığı için VAR modeli en küçük kareler yöntemi ile tahmin yapılmasına uygundur.

VAR analizinde kullanılacak değişkenlerin öncelikle durağan olması gerekmektedir. Bunun için değişkenlerin deterministik özelliklerinin incelenmesi gerekebilir. Daha sonra VAR modelini kurmak için uygun gecikme uzunluğu belirlenmeye çalışılır. Uygun gecikme uzunluğunun belirlenmesinde AIC, SC, HQ ve FPE kriterleri kullanılabilir. İlgili kriterler, yüksek gecikmeden düşük gecikmeye doğru araştırılır ve kriterler arasından düşük olan tespit edilerek VAR modeli en küçük bilgi kriteri değerine göre oluşturulur. (Lütkepohl, 2005, s. 4; Mert ve Çağlar, 2019, s. 222; Tarı & Bozkurt, 2006, s. 7).

1.8.1. Nedensellik Analizi (Testi)

Dünya, bağımsız stokastik süreçlerden oluşmamaktadır. Aksine genel denge teorisine göre, ekonomistlerin genellikle her şeyin diğer şey(ler)e bağlı (ilişkili) olduğunu varsayarlar. Nedensellik, çeşitli yorumlar ya da tartışmalı anlamlar içerdiği için ele alınması zor ve detaylı olarak incelenmesi gereken bir kavramdır. Nedensellik kavramı, sosyal bilimlerde kısaca; herhangi bir nedenin, bir sonuca yol açması olarak tanımlanmaktadır. Ekonomi literatüründe, bu kavramı ele alabilmek için iki büyük girişimde bulunulmuştur: Bunlardan birisi Cowles Komisyon⁸ yaklaşımı (eşanlı denklem modeli yaklaşımı) iken, diğeri zaman serisi yaklaşımıdır. Zaman serisi yaklaşımının savunucuları ise nedensellik kavramını şekillendirmek için istatistiksel kriterler kullanmaktadırlar. Bu düşünceyi benimseyen en önemli temsilcilerinden biri de Clive W.J. Granger'dir.

Diğer taraftan, koentegrasyon (eşbütünleşme) kavramının ortaya çıkmasında sahte regresyon kavramının varlığı etkili iken, rasgele birliktelik⁹(Işığışok, 1994) olgusunun varlığı ise nedensellik kavramının ortaya çıkmasında tetikleyici olmuştur. Granger (1969), yaptığı çalışmasında göstermiştir ki zaman serileri arasında elde edilen

⁸ Cowles Komisyonu, nedenselliği eşanlı denklem modelleri ile açıklamaya çalışır. Komisyon için nedensellik, eşanlı denklem modelleri ile ekonomik teori alanı altında nedensel ilişkileri belirli bir hiyerarşiye göre kümeler ve bu kümeleri, seviye I, II, III, ..., vb, içinde sınıflandırma olasılığı ile ele almaktadır. Bu sistemde, düşük sayılı kümelerdeki değişkenler, eğer birincisi tersi doğru olmadan ikincisini etkiliyorsa, daha yüksek sayılı kümelerdeki değişkenlere neden olduğu söylenir. Yani nedensellik, bazı değişkenler arasında veya aralarında "asimetrik bir ilişki" göstermektedir. (Bkz. Ando, A., F.M. Fisher, and H.A. Simon (1963), Essays on the Structure of Social Science Models, Cambridge: MIT Press, Aktaran: (Mamingi, 2005)).

⁹ Bazı kaynaklarda sahte korelasyon olarak tanımlanmaktadır.

korelasyonların anlamlı bir şekilde yorumlanamadığını ve bu durumun ise sahte ilişkilere neden olduğunu belirtmiş ve bu sorunu, nedensellik kavramı ile çözmeye çalışmıştır.

Granger (1969) nedensellik tanımının önemini anlamak için literatürdeki önceden var olan tartışmaların kısaca irdelenmesi yararlı olacaktır. Simon (1953), nedenselliği “bir bilim adamı modelinin özellikleri” olarak tanımlamaktadır. Değişkenler arasındaki asimetric fonksiyonel ilişkilere nedensel yorumlar verilirken, Simon bu tanım için zaman kavramına gerek olmadığını belirtmektedir. Lineer denklem sistemleri bağlamında Simon’un nedensel ilişkiler tanımı, denklemlerin blok özyinelemeli yapıyı tanımlamak için sistem hakkında önsel bilgiye duyulan ihtiyacı vurgulamıştır. Wold (1954), Strotz ve Wold (1960) bir modelin tamamen özyinelemeli olmasını gerektirecek şekilde nedensellik tanımını güçlendirirler. Onlara göre, modelin üç değişkeni X, Y ve Z varsa özyinelemelilik, X’in Y ve Z’yi bilmeden çözülebileceği anlamına gelir. Böyle bir sistem, daha sonra X’in Y’ye ve X ve Y’nin her ikisinin de Z’ye neden olduğu bir nedensel ilişkiye sahip olduğu şeklinde yorumlanmıştır.

Literatürde farklı nedensellik analizleri bulunmak ile birlikte, bu çalışmada sadece Granger nedensellik testi ve Toda Yamamoto nedensellik testi üzerinde durulacaktır.

1.8.1.1. Granger Nedensellik Testi

Granger’in (1969) yaptığı çalışmada, gerçekte tahmin (prediction) veya öngörü (forecast) ile bağlantılı olan nedensellik kavramını formüle etmek için geleceğin, şimdiye veya geçmişe neden olmayacağı öncülünden yola çıkar (Mamingi, 2005). Granger’in nedensellik tanımının en büyük avantajı, gözlemlenen verilerden doğrudan test edilebilir olmasıdır. Granger (1969), nedenselliğin operasyonel tanımını vermiş ve doğrusal zaman serisi spesifikasyonlarında test edilebilir parametre kısıtlamalarını tartışmıştır.

Birinci olayın ortaya çıkışını yüksek olasılıkla ikinci olayın ortaya çıkışı takip ediyorsa, birinci ve ikinci olay arasındaki olasılık ilişkisini dışlamamak için kullanılabilir üçüncü bir olay yoksa, bir olay diğerinin nedenidir (Suppes, 1970, s. 10). Diğer bir deyişle, X değişkeninin Y değişkenini tam açıklanması söz konusu ise, X’in Y için gerekli ve yeterli bir koşul olduğudur (Işığışık, 1994, s. 21). Suppes’in bu tanımı Granger’in tanımıyla özellikle zamansal ardışıklığın gerekliliği, neyin neden

olabileceğine dair herhangi bir kısıtlama olmadığı ve nedenlerin etki değişkeninin koşullu dağılımı üzerindeki etkileriyle tanımlandığı gerçeği ile bazı paralellikler göstermektedir. Holland (1986), nedensel etkileri deney yoluyla belirleme fikrini Mill'e atfeder. Deney, o zamandan beri nedenselliğin istatistiksel analizinde merkezi bir rol oynamaktadır. Ancak Granger (1980, s. 329), bundan sadece kısaca bahseder ve nedensellik tanımında onunla aynı düşüncede değildir. Holland'ın belirttiği gibi "nedenler yalnızca, prensipte deneylerde tedavi edilebilecek şeylerdir" (Holland 1986, s. 954).

Ampirik çalışmalarda ilgilenilen değişkenleri belirlemede iktisat teorisinin rolü, ekonometri ve ampirik iktisatta tartışmalı konulardan biri olmaya devam etmektedir. Nedenselliğin doğru tanımı üzerindeki tartışma, ister neden-sonuç ilişkisinin zamansal yönü üzerindeki kısıtlamalar, isterse ekonomik değişkenler arasındaki etkileşimi yöneten temel yapılar olsun, bireysel araştırmacıların a priori olarak neyi varsaymaya hazır olduklarına bağlıdır. Granger (1980), nedensel ilişkilerin belirlenmesinde a priori teorik kısıtlamaların potansiyel yararlılığını tartışmaz, ancak bu kısıtlamaların yanlış olduğu ortaya çıkarsa yanıtıcı çıkarım potansiyelini vurgular.

Bu analizin altındaki temel düşünce, bir değişkenin cari dönemdeki değerini açıklanırken, başka bir değişkenin gecikmeli değerlerinin bu değişkenin açıklanmasına katkısı varsa, değişkenler arasında nedensellik ilişkisinin varlığını gösterebilmektir. Diğer bir deyişle, bir zaman serisinin taşıdığı bilginin bir miktarı, başka bir zaman serisinin geçmiş değerlerinden etkileniyor veya geçmiş değerleri ile açıklanabiliyorsa, bu iki seri arasında nedensellik ilişkisi olduğu söylenebilir.

Bu bilgiler ışığında, iki değişkenin X_t ve Y_t olduğu varsayalım. Granger (1969)'in önermiş olduğu eşitlikler aşağıda verilmiştir:

$$X_t + b_0 Y_t = \sum_{j=1}^m a_j X_{t-j} + \sum_{j=1}^m b_j Y_{t-j} + \varepsilon'_t \quad (1.84)$$

$$Y_t + c_0 X_t = \sum_{j=1}^m c_j X_{t-j} + \sum_{j=1}^m d_j Y_{t-j} + \varepsilon''_t \quad (1.85)$$

Eğer Eşitlik (1.84) ve (1.85)'de verilen $b_0 = c_0 = 0$ olur ise, basit nedensellik modeli geçerli olacaktır. Aksi takdirde, Granger (1969, ss. 431-435) tanımına göre, anlık nedensellik¹⁰ durumu söz konusu olacaktır (Işığışık, 1994, s. 4).

¹⁰ *Anlık Nedensellik*: t dönemdeki bir değişkenin, benzer şekilde t dönemdeki diğer bir değişkene neden olduğu anlamına gelmektedir (Işığışık, 1994, p. 28).

Granger (1969), X ve Y arasındaki nedensellik durumları için aşağıdaki tanımları önermiştir:

- Granger Nedensellik: X (basitçe) Y için Granger nedenidir, ancak ve ancak optimal bir doğrusal tahmin fonksiyonunun uygulanması aşağıdaki duruma yol açar:

$$\sigma^2(Y_{t+1}|I_t) < \sigma^2(Y_{t+1}|I_t - \bar{X}_t)$$

Yani Y 'nin gelecekteki değerleri daha iyi tahmin edilebiliyorsa, daha küçük bir tahmin varyansı ile yani X 'in şimdiki ve geçmiş değerleri kullanılıyorsa, X 'in Y 'nin Granger nedeni olduğu söylenir.

- Anlık Granger Nedensellik: X ancak ve ancak optimal bir doğrusal tahmin fonksiyonunun uygulaması aşağıdaki sorunlara yol açarsa, X değişkeni Y değişkeni için anlık Granger nedenselidir:

$$\sigma^2(Y_{t+1}|\{I_t, X_{t+1}\}) < \sigma^2(Y_{t+1}|I_t)$$

Yani, Y 'nin gelecekteki değeri olan Y_{t+1} , daha iyi tahmin edilirse, diğer bir deyişle, daha küçük bir öngörü hatası varyansı ile eğer X 'in gelecekteki değeri X_{t+1} , X 'in mevcut ve geçmiş değerlerine ek olarak kullanılırsa, X 'in Y 'nin anlık Granger nedeni olduğu söylenir.

- Geri Bildirim (Geri Besleme): X , Y için nedensel ise ve Y , X için nedensel ise X ve Y arasında geri besleme vardır.

Geri bildirim yalnızca basit nedensel ilişkiler durumu için kullanılır. Bunun nedeni, ek bilgi veya varsayımlar olmadan anlık nedensel ilişkilerin yönünün belirlenememesidir. Bu tanımlardan sonra, iki zaman serisi arasında aşağıda gösterilen sekiz farklı özel nedensel ilişki olasılığı oluşmaktadır (Işığışçok, 1994, s. 84):

- X ve Y bağımsızdır: (X, Y)
- Yalnızca anlık nedensellik vardır: $(X - Y)$
- X anlık nedensellik olmaksızın Y için nedenseldir: $(X \rightarrow Y)$
- Y anlık nedensellik olmaksızın X için nedenseldir: $(X \leftarrow Y)$
- X anlık nedensellik ile Y için nedenseldir: $(X \Rightarrow Y)$
- Y anlık nedensellik ile X için nedenseldir: $(X \Leftarrow Y)$
- Anlık nedensellik olmadan geri bildirim vardır: $(X \leftrightarrow Y)$

viii. Anlık nedensellik ile geri bildirim vardır: $(X \Leftrightarrow Y)$

Yukarıda verilen tanımlamalar ışığında I_t , t zamandaki mevcut olan tüm bilgileri içerir. Ancak normalde X ve Y zaman serilerinin yalnızca mevcut ve gecikmeli değerlerini dikkate alır:

$$I_t := \{X_t, X_{t-1}, \dots, X_{t-k}, Y_t, Y_{t-1}, \dots, Y_{t-k}\} \quad (1.86)$$

Granger nedensellik testinde yokluk hipotezi $\sum_{j=1}^m a_j = 0$ 'dir. Diğer bir deyişle, X_t, Y_t 'nin nedeni değildir şeklinde oluşturulurken, alternatif hipotez ise $\sum_{j=1}^m a_j \neq 0$ yani X_t, Y_t 'nin nedenidir şeklinde ifade edilmektedir.

1.8.1.2. Toda Yamamoto Nedensellik Testi

Granger nedensellik sınaması, durağan olan serileri VAR analizi ile irdeledikten sonra, F istatistiğine dayanan bir testtir. Toda – Yamamoto (TY) (1995), değişkenler arasında bir eşbütünleşme ilişkisi söz konusu olduğunda, ilgili değişkenlerin F istatistiğinin standart dağılımına uymayarak geçerliliğini yitirebileceğini belirtirken, bir ekonometrik model kurulurken ilgili değişkenlerin birim kök içermesi durumunda, değişkenlerin düzey değerleri kullanılarak VAR analizi yapılabileceğini ve bunun için de Wald testi yardımıyla kullanılabilceğini ileri sürmüşlerdir (Toda & Yamamoto, 1995, s. 227).

Granger nedensellik testi için ilgili değişkenlere durağanlık testi yapıldıktan sonra eşbütünleşme ilişkisi araştırılmaktadır. Sonraki aşamada ise VAR analizi yardımı ile nedensellik ilişkileri incelenmektedir. Diğer bir deyişle, Granger nedensellik testi için ön testlere ihtiyaç vardır. Toda Yamamoto, bu ön testlerin yanıltıcı sonuçlar verebileceğini ve ayrıca bunun bir işlem yükü getirdiğini belirtmektedir. 1995 yılındaki çalışmasında $(k + d_{max})$. dereceden bir VAR modeli oluşturulmasını önermiştir. X ve Y gibi iki değişken için Toda Yamamoto nedensellik sınamaları için aşağıdaki eşitliklerden yararlanılmaktadır:

$$Y_t = \delta + \sum_{i=1}^{k+d_{max}} \alpha_i Y_{t-i} + \sum_{i=1}^{k+d_{max}} \vartheta_i X_{t-i} + \varepsilon_{1t} \quad (1.87)$$

$$X_t = \delta + \sum_{i=1}^{k+d_{max}} \gamma_i X_{t-i} + \sum_{i=1}^{k+d_{max}} \theta_i Y_{t-i} + \varepsilon_{2t} \quad (1.88)$$

Eşitliklerde bulunan k , en uygun gecikme uzunluğunu temsil ederken d_{max} ise şu şekilde belirlenmektedir:

$$x \sim I(0) \text{ ve } y \sim I(1) \text{ ise } d_{max} = 1,$$

$$x \sim I(1) \text{ ve } y \sim I(0) \text{ ise } d_{max} = 1,$$

$$x \sim I(1) \text{ ve } y \sim I(2) \text{ ise } d_{max} = 2,$$

$$x \sim I(2) \text{ ve } y \sim I(1) \text{ ise } d_{max} = 2,$$

$$x \sim I(0) \text{ ve } y \sim I(2) \text{ ise } d_{max} = 2,$$

$$x \sim I(2) \text{ ve } y \sim I(1) \text{ ise } d_{max} = 2$$

...

$$x \sim I(d) \text{ ve } y \sim I(d + 1) \text{ ise } d_{max} = d + 1$$

$$x \sim I(0) \text{ ve } y \sim I(d) \text{ ise } d_{max} = d,$$

Bu kombinasyonlarda ilgili değişkenlerden hangisinin bütünleşme derecesi en büyük ise bütünleşme değeri olarak o değer kabul edilmektedir. Dolayısıyla, bu testin önemli bir özelliği olarak değişkenlerden biri durağan diğeri durağan dışı bir yapı sergilemiş olsalar bile, değişkenler arası nedensellik testinin araştırılmasına olanak sağlamasıdır. Ayrıca, Toda Yamamoto nedensellik testi, k gecikme uzunluğu ile χ^2 asimptotik dağılım özelliği göstermektedir (Toda & Yamamoto, 1995, s. 230). Hemen ekleyelim ki, bu nedensellik analizinin verimli işleyebilmesi için k gecikme uzunluğunun ve d_{max} bütünleşme derecesinin doğru olarak belirlenmesi gerekmektedir.

1.8.2. Varyans Ayrıştırması

Varyans ayrıştırması (variance decomposition), öngörü ile ilişkili olan bir değişkenin s dönem öngörü hata varyansının ne kadarının diğer değişkenlere gelen şoklar ile açıklandığını göstermektedir (Özgen & Güloğlu, 2004, s. 98). Bu yöntemde, değişkenin öngörü hata varyansının hiçbir kısmı öngörü dönemi boyunca, diğer değişkenlere gelen şoklarla açıklanmıyorsa, o değişkene dışsal değişkendir denir. Diğer bir deyişle, değişkenin öngörü hata varyansı, diğer değişkenlerden gelen şoklar ile

açıklanabiliyorsa bu değişkenin içsel olduğu söylenebilir (Enders, 2014, ss. 302–303). Cholesky yöntemine dayalı olan bu analiz, etki tepki fonksiyonundan yararlanılarak hesaplanmaktadır.

Varyans ayrıştırması fonksiyonu için başlangıç noktası dönüştürülmüş Wold temsili şu şekildedir:

$$X_t = \mu + \sum_{j=0}^{\infty} (\Phi_j W_{t-j}), \quad \sum_{j=0}^{\infty} \Phi_j \Phi_j' = I \quad (1.89)$$

Bu eşitliğin koşullu beklenen değeri alındığında,

$$E_t[X_{t+\tau}] = \mu + \sum_{j=0}^{\tau-1} (\Phi_j E_t[W_{t+\tau-j}]) + \sum_{j=\tau}^{\infty} (\Phi_j W_{t+\tau-j}) \quad (1.90)$$

Burada, $E_t[W_{t+s}] = 0$, $s > 0$ ve $j \geq \tau$ terimleri için göz ardı edildiğinden, $j = 0, 1, \dots, \tau - 1$ değerleri için gerçekleşir ve bu nedenle gözlemlenebilir:

$$\hat{X}_t(\tau) = \mu + \sum_{j=\tau}^{\infty} (\Phi_j W_{t+\tau-j})$$

Bu sayede veri üretme süreci için aşağıdaki gibi yazılabilir:

$$X_{t+\tau} = \mu + \sum_{j=0}^{\infty} (\Phi_j W_{t+\tau-j}) \quad (1.91)$$

Öngörünün hatası ise aşağıdaki gibi elde edilir:

$$F_t(X_{t+\tau}) = X_{t+\tau} - \hat{X}_t(\tau) \quad (1.92)$$

$$F_t(X_{t+\tau}) = \sum_{j=0}^{\tau-1} \Phi_j W_{t+\tau-j} \quad (1.93)$$

Artan tahminle yataylaşan ve $\tau \rightarrow \infty$ için, öngörü hatası sürecin stokastik kısmına yakınsamaktadır.

$$\begin{aligned} X_{j,t+\tau} - \hat{X}_{j,t} &= \sum_{i=0}^{\tau-1} (\phi_{j1}^i w_{1,t+\tau-i}) + \dots + \sum_{i=0}^{\tau-1} (\phi_{jk}^i w_{k,t+\tau-i}) \\ &= \sum_{m=1}^k [\sum_{i=0}^{\tau-1} (\phi_{jm}^i w_{m,t+\tau-i})] \end{aligned} \quad (1.94)$$

$i = 0, 1, \dots, \tau - 1$ olmak üzere, sadece farklı zamanlarda değil aynı zamanda w_m , $m = 1, 2, \dots, k$ farklı yeniliklerin katkılarına sahiptir.

$\Sigma_{WW} = I$ olduğundan, yani W 'nin tek tek elemanları sadece beyaz gürültülü ve birbiriyle korelasyonsuz değil, aynı zamanda bir varyansa sahip olduğundan bu öngörü hatasının bileşenlerinin varyansı şu şekildedir:

$$\begin{aligned} E \left[\left(X_{j,t+\tau} - \hat{X}_{j,t}(\tau) \right)^2 \right] &= E \left[\left(\sum_{m=1}^k \sum_{i=0}^{\tau-1} \phi_{jm}^i w_{m,t+\tau-i} \right)^2 \right] \\ &= \sum_{m=1}^k \sum_{i=0}^{\tau-1} (\phi_{jm}^i)^2 \end{aligned} \quad (1.95)$$

Burada, $E[w_{m,t+\tau-i}, w_{r,t+\tau-s}] = 0$ olduğundan, $m = r$ ve $i = s$ dışında, tüm çapraz terimler atlanmıştır ve sadece katsayıların kareleri $E[(w_{m,t+\tau-i})^2] = 1$ alınmıştır.

Diğer taraftan, varyans $w_m, m = 1, 2, \dots, k$ gibi bireysel yeniliklerin j değişkeni üzerindeki etkisiyle, τ dönem boyunca bir tahmin yapıldığında parçalara ayrıştırılabilir:

$$\omega_{jm}^\tau = \frac{\sum_{i=0}^{\tau-1} (\phi_{jm}^i)^2}{\sum_{s=1}^k \sum_{i=0}^{\tau-1} (\phi_{js}^i)^2}, \quad m = 1, 2, \dots, k \quad \text{ve} \quad \tau = 1, 2, \dots \quad (1.96)$$

Yatay zamanda bir artış ile yani, $\tau \rightarrow \infty$ için, sadece öngörü hatasının varyansı değil, aynı zamanda farklı yenilikler w_m tarafından üretilen kesirlere ayrıştırabilen değişkenin kendisinin varyansıdır (Kirchgässner & Wolters, 2007, s. 147). Bu kesirler yapı gereği birbirlerine dik olduklarından, toplamı 1 olur. Bu sayede, öngörü hatalarının analizi, sistem değişkenlerinin varyanslarının ayrıştırılmasına yol açar.

Varyans ayrıştırması öngörü hatasından faydalanarak da elde edilebilir (Enders, 2014, s. 301):

$$Y_{t+s} - E_t(Y_{t+s}) = \sum_{i=0}^{s-1} \Psi_i u_{t+s-i} \quad (1.97)$$

$$Y_{t+s} - E_t(Y_{t+s}) = \Psi_0 u_{t+s} + \Psi_1 u_{t+s-1} + \dots + \Psi_{s-1} u_{t+1} \quad (1.98)$$

Burada, Ψ_i öngörü hatalarından elde edilen etki-tepki fonksiyonudur. Cholesky ayrıştırmasıyla elde edilen etki tepki fonksiyonları kullanılabilir. Eğer şoklar arasındaki ilişki zayıfsa, bu durumda ayırtehdilme sorunu çok önemli olmamaktadır.

Ψ_i 'nin 1. satır m. sütun elemanına $\Psi_{i,m}(i)$ ile belirtilirse, bu durumda k. değişkenin öngörü hata varyansı aşağıdaki gibi olacaktır:

$$Y_{k,t+s} - E_t(Y_{k,t+s}) = \sum_{i=0}^{s-1} \left(\Psi_{k,1}^{(i)} u_{1,t+s-i} + \dots + \Psi_{k,K}^{(i)} u_{K,t+s-i} \right)$$

$$\sigma_k^2(s) = \sum_{i=0}^{s-1} \left(\Psi_{k,1}^2(i) u_{1,t+s-i} + \dots + \Psi_{k,K}^2(i) u_{K,t+s-i} \right) = \sum_{j=1}^K \left(\Psi_{k,j}^2(0) + \dots + \Psi_{k,j}^2(s-1) \right)$$

Burada, $\left(\Psi_{k,j}^2(0) + \dots + \Psi_{k,j}^2(s-1) \right)$ terimi, j. değişkenin k. değişkenin öngörü hata varyansına katsayısı olarak düşünülebilir. VAR modelinde denklemlerdeki her bir şok, ilgili değişken ile eşleştirildiği için bu terim her bir değişkene gelen şokun k. değişkenin öngörü hata varyansına katkısını verecektir. Bu terimi, $\sum_{j=1}^K \left(\Psi_{k,j}^2(0) + \dots + \Psi_{k,j}^2(s-1) \right)$ terimine oranlandığında, her bir değişkene gelen şokun k. değişkenin öngörü hata varyansı içindeki yüzdesel payına aşağıdaki gibi ulaşılır:

$$\omega_{kj}(s) = \frac{\left(\Psi_{k,j}^2(0) + \dots + \Psi_{k,j}^2(s-1) \right)}{\sum_{j=1}^K \left(\Psi_{k,j}^2(0) + \dots + \Psi_{k,j}^2(s-1) \right)} * 100 \quad (1.99)$$

1.8.3. Etki-Tepki Fonksiyonları

Uygun VAR modeline karar verildikten sonra, değişkenlere bir şok verildiğinde diğer değişkenlerin bu şoktan ne yönde etkilendiklerini incelemek için etki tepki fonksiyonlarından yararlanılmaktadır (Lutkepohl, 1990, s. 117). Diğer bir deyişle, rassal hata terimlerinden birine uygulanan bir birimlik standart sapma şokunun, içsel değişkenlerin şimdiki ve gelecekteki etkileri hakkında bilgi vermektedir (Özgen & Güloğlu, 2004, s. 97). Bir VAR modeli, kararlı ise bu model durağandır. Diğer bir deyişle; kararlılık, durağanlığı göstermektedir. Durağan bir VAR modelinden yararlanılarak sonsuz gecikmeli Vektör Hareketli Ortalama (VMA) temsili elde edilebilir. Gecikme operatörü çok terimlisini kullanarak VMA temsili şu şekilde elde edilebilir:

$$\Gamma(L)Y_t = \mu + u_t \quad (1.100)$$

ise,

$$Y_t = \Gamma(L)^{-1}(\mu + u_t)$$

$$Y_t = (\Gamma(L)^{-1}\mu) + (\Gamma(L)^{-1}u_t) \quad (1.101)$$

Eğer VAR süreci kararlı ise bu durumda $\Gamma(L)$ 'nin tersi alınabilir:

$$\Gamma(L)^{-1} = I + \Psi_1L + \Psi_2L^2 + \dots = \Psi(L) \quad (1.102)$$

matrisinin katsayıları toplanabilir ve VMA süreci yakınsaktır.

$$(\Gamma(L)^{-1}\mu) = \bar{Y}$$

şeklinde belirtilirse, VMA süreci aşağıdaki gibi işleyecektir:

$$Y_t = \bar{Y} + u_t + \Psi_1u_{t-1} + \Psi_2u_{t-1} + \Psi_3u_{t-1} + \dots = \bar{Y} + \Psi(L)u_t \text{ ve } VMA(\infty)$$

Bu eşitliği şu şekilde gösterilebilir:

$$Y_t = \bar{Y} + \sum_{i=0}^{\infty} \Psi_i u_{t-i} \quad (1.103)$$

Bu eşitlikten etki tepki fonksiyonları şu şekilde elde edilir:

$$\Gamma(L)^{-1}\Psi(L) = I$$

olduğundan,

$$(I - \Gamma_1L - \Gamma_2L^2 - \dots - \Gamma_pL^p)(I + \Psi_1L + \Psi_2L^2 + \dots) = I \quad (1.104)$$

elde edilir. Buradan L'nin katsayıları sıfıra eşitlenir. Çünkü durağanlık için L¹'in, L²'nin katsayıları sıfıra eşit olmalıdır.

$$\Gamma_1L - \Psi_1L = 0;$$

$$\Psi_1 - \Gamma_1 = 0$$

dolaysıyla

$$\Psi_1 = \Gamma_1$$

olur. L²'nin katsayıları sıfıra eşitlenirse,

$$\Psi_2L^2 - \Gamma_1\Psi_1L^2 - \Gamma_2L^2 = 0$$

$$\Psi_2 = \Gamma_1\Psi_1 + \Gamma_2$$

bu şekilde hareket edildiğinde, s dönem etki tepki katsayıları matrisi,

$$\Psi_s = \Gamma_1\Psi_{s-1} + \Gamma_2\Psi_{s-2} + \dots + \Gamma_p\Psi_{s-p} \text{ ve } (s=1,2,\dots\text{ için}) \quad (1.105)$$

elde edilir. Ayrıca, $s > p$ için

$$\Psi_0 = I_k \text{ ve } \Psi_s = 0$$

yazılabilir. VMA temsilini ve etki tepki fonksiyonlarını yandaş (companion) formdan hareketle de elde edilebilir:

$$Y_t = \mu + \Gamma Y_{t-1} + u_t \quad (1.106)$$

Eşitliğinden geriye doğru iterasyon yapılırsa aşağıdaki sonuçlara ulaşılır:

$$t=1 \text{ için, } Y_1 = \mu + \Gamma Y_0 + u_1$$

$$t=2 \text{ için, } Y_2 = \mu + \Gamma Y_1 + u_2$$

$$Y_2 = \mu + \Gamma(\mu + u_1) + u_2$$

$$Y_2 = \mu + \Gamma\mu + \Gamma u_1 + u_2$$

$$t=3 \text{ için, } Y_3 = \mu + \Gamma Y_2 + u_3$$

$$Y_3 = \mu + \Gamma(\mu + \Gamma\mu + \Gamma u_1 + u_2) + u_3$$

$$Y_3 = \mu + \Gamma\mu + \Gamma^2\mu + \Gamma^2u_1 + \Gamma u_2 + u_3$$

.....

$$Y_t = \mu(I + \Gamma + \Gamma^2 + \dots) + (u_t + \Gamma u_{t-1} + \Gamma^2 u_{t-2} \dots)$$

$$Y_t = \bar{Y} + u_t + \Gamma u_t + \Gamma^2 u_{t-2} + \dots$$

Buradan etki tepki katsayıları ise,

$$\Psi_0 = I, \Psi_1 = \Gamma, \Psi_2 = \Gamma^2, \dots, \Psi_s = \Gamma^s \quad (1.107)$$

şeklinde elde edilebilir.

Etki tepki fonksiyonlarına bazen öngörü hataları (forecast errors) da denilmektedir. Bunu aşağıdaki şekilde ifade edebiliriz:

$$Y_t = \mu + \Gamma Y_{t-1} + u_t \quad (1.108)$$

$$Y_{t-1} = \mu + \Gamma Y_t + u_{t+1} \quad (1.109)$$

Bu ifadenin koşullu beklenen değeri alındığında,

$$E_t(Y_{t+1}) = \mu + \Gamma Y_t$$

olur. Y_t 'nin bir dönem ileri öngörüsü elde edilir. Buradan, bir dönem ileri öngörü hatası ise şu şekildedir:

$$Y_t - E_t(Y_{t+1}) = u_{t+1}$$

Benzer şekilde devam ettirilirse, iki dönem ileri öngörüsü şöyle olur:

$$Y_{t+2} = \mu + \Gamma Y_{t+1} + u_{t+2}$$

$$Y_{t+2} = \mu + \Gamma(\mu + \Gamma Y_t + u_{t+1}) + u_{t+2}$$

$$Y_{t+2} = \mu + \Gamma\mu + \Gamma^2 Y_t + \Gamma u_{t+1} + u_{t+2}$$

$$\begin{aligned} E_t(Y_{t+2}) &= \mu + \Gamma\mu + \Gamma^2 Y_t \\ &= (I + \Gamma)\mu + \Gamma^2 Y_t \end{aligned}$$

İki dönem sonrasının öngörü hatası ise şöyledir:

$$Y_{t+2} - E_t(Y_{t+2}) = \Gamma u_{t+1} + u_{t+2}$$

Benzer şekilde s dönem sonrasının öngörüsü şu şekildedir:

$$E_t(Y_{t+s}) = (I + \Gamma + \Gamma^2 + \dots + \Gamma^{s-1})\mu + \Gamma^s Y_t$$

Y_t 'nin s dönem sonraki gerçekleşen değeri:

$$\begin{aligned} Y_{t+s} &= (I + \Gamma + \Gamma^2 + \dots + \Gamma^{s-1})\mu + \Gamma^s Y_t + u_{t+s} + \Gamma u_{t+s-1} \\ &\quad + \Gamma^2 u_{t+s-2} + \dots + \Gamma^{s-1} u_{t+1} \end{aligned}$$

Dolayısıyla s dönem ileri öngörü hatası şöyle bulunur (Hamilton, 1994, s. 314):

$$Y_{t+s} - E_t(Y_{t+s}) = u_{t+s} + \Gamma u_{t+s-1} + \Gamma^2 u_{t+s-2} + \dots + \Gamma^{s-1} u_{t+1}$$

Burada, Y_{t+s} 'yi

$$Y_t = \bar{Y} + \sum_{i=0}^{\infty} \Psi_i u_{t-i}$$

olarak kullanarak aşağıdaki gibi yazılabilir:

$$Y_{t+s} = \bar{Y} + \sum_{i=0}^{\infty} \Psi_i u_{t+s-i}$$

Buradan

$$Y_{t+s} - E_t(Y_{t+s}) = \sum_{i=0}^{s-1} \Psi_i u_{t+s-i} \quad (1.110)$$

olarak hesaplanır. Bu biçimi ile hesaplanan etki-tepki fonksiyonları¹¹ sistemdeki değişkenlerden birinde cari dönemde meydana gelen 1 birimlik, şoka diğer değişkenlerin cari dönem ve sonraki s dönemdeki dinamik tepkisini yansıtır.

Etki-tepki fonksiyonlarında, eğer indirgenmiş form hata terimleri arasında eş dönem ilişki varsa, diğer bir deyişle, Ω matrisi köşegen değilse, bu durumda verilen bir şokun etkisi diğerlerinden ayırt edilemeyecektir (Lütkepohl & Kratzig, 2004, s. 166). Bu nedenle etki-tepki fonksiyonları hesaplanırken şoklar dikeyleştirilir (orthogonalized) yani, ilişkisiz hale getirilir (Kirchgässner & Wolters, 2007, s. 138). Bunu da varyans kovaryans matrisinin Cholesky ayrıştırmasının kullanılması ile gerçekleştirmek mümkündür.

¹¹ Etki tepki katsayıları toplanırsa, şokların birikimli etkileri elde edilebilir. Şokların toplam uzun dönem etkisi ise şu şekilde hesaplanmaktadır: $\Psi_{long} = \sum_{i=0}^{\infty} \Psi_i = (I - \Gamma_1 - \Gamma_2 - \dots - \Gamma_p)^{-1}$ veya $\Gamma(L)^{-1}$ de $L=1$ denilirse; $\Psi_{long} = (I - \Gamma_1 - \Gamma_2 - \dots - \Gamma_p)^{-1}$

İKİNCİ BÖLÜM

YAPAY SİNİR AĞLARININ TEORİK YAPISI

2.1. YAPAY SİNİR AĞLARI

Yapay sinir ağları (YSA), isminden de anlaşılacağı üzere, biyolojik merkezi sinir sisteminin, sinir hücresi (nöron) ağlarını yüzeysel şekilde simüle (benzetme) etmeye çalışan hesaplama yöntemi şeklinde tanımlanabilir. Örüntü tanımayı içeren birçok görevin, otomatikleştirilmesi son derece zordur. Bazı canlılar; örneğin hayvanlar, çok az çaba gerektiren çeşitli nesnelere tanır ve çevrelerindeki geniş miktardaki görsel bilgiden anlam çıkarabilmektedirler. Bir arı, bir engelden kaçarken veya bir kedi, bir köpekten kaçarken yörüngeler üzerinde hiçbir diferansiyel denklem çözmez ve karmaşık örüntü tanıma algoritmalarını kullanmazlar. Beyni çok basittir, ancak bazı gelişmiş hayvanlarda ve insanda, bu tür hücrelerin yapısına temel olarak uyan birkaç temel sinir hücresi vardır. Einstein, bir çözümün veya modelin eldeki probleme uyacak şekilde mümkün olduğunca basit olması gerektiğini belirtmiştir. Yapay sinir ağının çözümü de buna benzer bir basitlik hedeflemektedir. Öğrenme yeteneği ile yeni bilgiler keşfedebilen, türetebilen veya genelleştirebilen insan beyninin bu özellikleri ise diğer canlılara göre daha kapsamlıdır. Benzer görevlerin yüklenmeye çalışıldığı bilgisayar sistemlerinin ve canlıların bu işlevleri nasıl gerçekleştirdiğinin anlaşılması ve fiziksel sınırlamaların izin verdiği ölçüde simüle edilmesi düşüncesi ile yapay sinir ağları disiplini, bilim dünyasında kendine yer edinmiştir.

Bu bilgiler ışığında, biyolojik sinir ağının işleyişi ile ilgili kısaca bilgi vermek gerekirse; nöronun hücre gövdesi, bir pile benzer şekilde küçük elektrik yüklerini depolayabilmektedir. Bu depolama, diğer nöronlardan gelen elektriksel uyarılar tarafından yüklenir. Ne kadar çok elektrik darbesi meydana gelirse, ortaya çıkan voltaj da o kadar yüksek olmaktadır. Ortaya çıkan bu voltaj belirli bir eşiği aşarsa ilgili nöron ateşlenir. Bu, akson¹² ve sinaps¹³lar üzerinde bir artış göndererek deponun boşaltıldığı

¹² Sinir hücresinin gövdesindeki elektriksel uyarıları başka bölgelere ileten elemandır.

¹³ Sinir hücrelerinin kaslara veya salgı bezleri gibi sinir hücresi olmayan hücrelere mesaj ileten birimdir.

anlamını taşımaktadır. Elektrik akımı, aynı işlemin gerçekleştiği sinaps'lar üzerinden diğer birçok nörona bölünür ve başka nöronlara ulaştırılmaktadır.

Nöronlar arasındaki bağlantıyı oluşturan merkezi rol ise sinaps elemanıdır. İki nöron arasındaki bağlantı noktasında, iki kablo ucu buluşuyormuş gibi bir etki yaratmaktadır. Ancak bu iki uç iletken olarak mükemmel şekilde birbirine bağlanmazlar. Bunun yerine, elektronların doğrudan üzerinden atlayamayacağı küçük boşluklar bulunmaktadır. Bu boşluk, nörotransmitter¹⁴'in konsantrasyonu (yoğunlaşması) ve kimyasal bileşimi gibi birçok parametreye bağlıdır (Ertel, 2017, s. 245).

Yapay sinir ağı mimarileri, geleneksel hesaplamalardan farklı bir hesaplama yaklaşımı sunmaktadır. Bilgisayarlar sıralı olarak çalışır ve aritmetik hesaplamaları oldukça hızlı yapabilmektedirler. İnsan beynindeki biyolojik nöronlar, oldukça yavaşlardır ve günlük karmaşık görevleri, akıl yürütmeyi ve bulanık durumlarla baş edebilmek için gerekli olan çok sayıda hesaplama görevini yerine getirebilme yetisine sahiptir.

Bu durumun altında yatan temel neden, geleneksel bir bilgisayardan farklı olarak, beynin paralel olarak, hareket eden biyolojik sinir sisteminin bilgiyi işleyebilmesi için çok sayıda nörona sahiptir. Bu nöronlar bilginin işlenmesinde görev alır. YSA'lar bağlantı ağırlıkları ile tek yönlü sinyal kanalları aracılığıyla birbirine bağlanan işlem elemanlarından oluşan ve paralel dağıtılmış bir bilgi işleme yapısıdır (Kamruzzaman et al., 2006, s. 3). Yapay sinir ağları, canlı organizmalardaki biyolojik sinir yapısından esinlenerek tasarlanmıştır. Biyolojik nöronlardan çok daha sonra modellenmesine rağmen; YSA'lar, çok basitleştirilmiş ve biyolojik sinir ağına sadece yüzeysel benzerlik göstermektedir. Bu benzerlikte temel alınan payda ise öğrenmedir.

2.1.1. Yapay Sinir Ağlarının Tarihsel Gelişimi

İnsan zihninin çalışma prensipleri üzerine yapılan ilk çalışmalar, 1890'lı yıllarda Alman psikolog Hermann'a¹⁵ kadar uzanmaktadır. 1930'larda ise Kurt Gödel, Alonso

¹⁴ Sinir hücreleri arasında iletişimi sağlayan kimyasala verilen isimdir.

¹⁵ Hermann Ebbinghaus 1850- 1902 yıllarında yaşayan önemli bir psikologdur. Unutma eğrisi ve aralık etkisini literatüre kazandırmıştır.

Church ve Alan Turing, mantık ve teorik bilimi için önemli temeller atmışlardır (Ertel, 2017, s. 7). Beyin işlevleri hakkında bilgi sunan ilk çalışmalar ise Helmholtz, Poincare... gibi araştırmacılar, yapay sinir ağı üzerine yoğunlaştıkları çalışmalardır (Öztemel, 2006, s. 37). Yapay sinir ağlarının günümüze kadar uzanan temelleri ise McCulloch, Hebb... gibi bilim adamlarının 1940'lerde yaptıkları çalışmalar ile atılmıştır. Bu yıllarda yapılan çalışmalar, yapay sinir hücreleri ile mantıksal ifadeleri formüle edebilmenin olabirliğini göstermişlerdir. Hebbian öğrenme kuralı olarak bilinen ve günümüzde kullanılan birçok öğrenme kurallarının temelini oluşturan çalışma, Hebb tarafından 1949 yılında literatüre kazandırılmıştır (Hebb, 1949). 1950'li yıllara gelindiğinde ise Farley ve Clark tarafından rassal ağlar ile adaptif tepki üretme kavramı geliştirilmiştir (Farley & Clark, 1954). Yapay sinir ağı literatürüne en büyük katkı ise 1958 yılında Rosenblatt tarafından geliştirilen perceptron (algılayıcı model)'dur. Yapay sinir ağlarının mühendislik disiplinde uygulanmaya başlanmasının temeli kabul edilen çalışma, Widrow ve Hoff tarafından 1960 yılında ortaya atılmıştır (Widrow & Hoff, 1960).

1960'lı yılların sonunda, yapay sinir ağı çalışmalarının hızı yavaşlamaya hatta duraklamaya başlamıştır (Öztemel, 2006, s. 38). Dönemin önde gelen bilim insanları; yapay sinir ağlarının, doğrusal olmayan problemlerin çözümüne katkısının olmadığını XOR¹⁶ problemini öne sürerek belirtmişlerdir. Bu dönemden sonra YSA çalışmaları XOR probleminin çözümüne kadar duraklamıştır (Akpınar, 1994, s. 62).

1970 yılına gelindiğinde ise bazı önemli yapay sinir ağı araştırmacıları, çalışmalarına devam etmişler ve çalışmaları 1980'li yıllarda yayınlanmaya başlamasıyla, bu konu tekrar ilgi görmeye başlamıştır. Birçok bilim insanı, yapay sinir ağları konusunda katkı sunarken, özellikle elektrik mühendisi olan Kohonen ve nöropsikolojist Anderson'un çalışmaları ön plana çıkmıştır. Özellikle denetimsiz öğrenme kurallarını benimseyen çalışma, 1982 yılında Kohonen'e ait olan "kendi kendine öğrenme nitelik haritaları" (self organizing feature maps- SOM) konusundaki çalışmalardır (Dreyfus, 2005, p. 328). Özellikle Carpenter ile Adaptif Rezonans Teorisi (ART), bu dönemde geliştirilmiştir (Carpenter & Grossberg, 1987).

¹⁶ Bu problem, doğrusal olmayan bir ilişkiyi göstermektedir. Çıktılar arasında bir doğru ve/veya doğrular çizilerek iki sınıfa ayrılamamaktadır. (XOR probleminin çözümü için bkz. (Öztemel, 2006, pp. 85–86).

Hopfield tarafından 1982 ve 1984 yıllarında yapılan çalışmalar, yapay sinir ağlarının, çözümlenmesi zor olan çalışmaların bilgisayar programlama ile çözülebileceğini göstermiş olmasıdır (Hopfield, 1982, 1984). Bu duruma en iyi örnek ise Gezgin satıcı probleminin çözümlenmesi olmuştur. Benzer dönemlerde Boltzman makineleri, Hinton ve Senjnowski çalışmaları ile literatüre kazandırılmıştır (Hinton & Senjnowski, 1986).

Rumelhart vd. paralel programlama ile ilgili çalışmaları ile çok katmanlı algılayıcı mimarisinin temellerini literatüre kazandırarak, yapay sinir ağlarının tarihsel gelişiminde önemli katkı sunmuşlardır (Rumelhart vd., 1986). Tek katmanlı mimarilerin XOR probleminin çözümünde yetersiz kalması, çok katmanlı mimariler ile çözüme kavuşmuş ve 1970'li yıllardan önce yapay sinir ağlarına getirilen eleştiriler yanıtını bulmuştur. Çok katmanlı algılayıcılar ile ilgili çalışmalar, sadece Rumelhart'ın çalışmaları ile sınırlı kalmamıştır. Parker (1985) ve Werbos tarafından yapılan çalışmalar, aynı zamanda XOR probleminin çözümünün yanında, Hopfield ve Boltzman makinelerinin sınırlarını da çözmüşlerdir.

Özellikle Rumelhart, McClelland ve Paralel Dağıtılmış İşleme (PDP) grubunun (1986) önemli çalışmalarından günümüze kadar yapay sinir ağları; örüntü tanımda (Fukumi et al., 1997), görüntü işlemede (Duranton, 1996), doküman analizinde (Marinai et al., 2005), mühendislik görevlerinde (Jin et al., 2002; Wang et al., 2000), finansal modellemede (Abu-Mostafa, 2001), üretimde (Kong & Nahavandi, 2002), biyomedikalde (Nazeran & Behbehani, 2000), optimizasyonda (Cho et al., 2005), vb çalışmalar başarılı uygulamaları nedeniyle büyük ilgi görmüştür.

2.2. YAPAY PROSESİN ELEMANLARI

Yapay sinir ağlarının da tıpkı biyolojik sinir ağları gibi sinir hücreleri bulunmaktadır. Yapay sinir hücreleri, mühendislik biliminde proses elemanı olarak da adlandırılmaktadır (Öztemel, 2006, s. 48). Her yapay prosesin i) Girdiler, ii) Ağırlıkla, iii) Toplama Fonksiyonu, iv) Aktivasyon Fonksiyonu ve v) Çıktı olmak üzere, beş temel elemanı bulunmaktadır. Şimdi bu elemanlar hakkında bilgi verelim.

- i. **Girdiler:** Yapay sinir hücresine dış dünyadan (Akkaya, 2005, s. 197), başka hücreden veya kendi gecikmeli değerlerinden gelen bilgileri içermektedir.
- ii. **Ağırlıklar:** Yapay hücreye verilen bilginin önemini ve ilgili hücre üzerindeki etkisini göstermektedir. Ağırlıkların küçük, sıfır veya negatif olması o ağ için önemli olabilir ve anlamsız şekilde düşünülmemelidir. Ağırlığın işaretinin türü sadece pozitif veya negatif etkisini gösterirken, sıfır olması herhangi bir etkisinin olmadığını ifade etmektedir.
- iii. **Toplama Fonksiyonu:** Prosesin bu elemanı, hücreye gelen net bilgiyi hesaplamaktadır. Toplama fonksiyonu için farklı hesaplama yöntemleri bulunmaktadır. Ancak en yaygın kullanılanı toplama fonksiyonudur. Ağın bu bölümünde girdi değeri kendi ağırlığı ile çarpılarak toplanmaktadır. Bu şekilde, ağa gelen net girdi hesaplanmış olur. Net girdi şu şekilde formüle edilebilir (Öztemel, 2006, s. 49):

$$NET = \sum_{i=1}^n G_i W_i$$

Burada, G girdi değişkenini, W ağırlıkları, n ise hücreye gelen toplam proses eleman sayısını temsil etmektedir. Bir problemin çözümünde kullanılan standart bir toplama fonksiyonu bulunmamaktadır. Uygun bir toplama fonksiyonunu elde etmek için deneme-yanılma yolu kullanılmaktadır (Öztemel, 2006, p. 49). Literatürde farklı toplama fonksiyonları bulunmaktadır. Bu fonksiyonlardan bazıları Tablo-1’de yer almaktadır.

- iv. **Aktivasyon Fonksiyonu:** Hücreye gelen net girdiyi işleyerek, hücrenin bu girdiye karşılık üreteceği çıktıyı belirleme görevindedir. YSA’ya verilen bir örnek, toplama fonksiyonundan sonra eşik seviyesinin belirlendiği aktivasyon fonksiyonuna gönderilir ve girdi ile ağırlık değerleri toplama fonksiyonu ile belirli eşik değerleri ile karşılaştırılmak için aktivasyon fonksiyonuna gönderilir (Navibey, 2010, s. 555). Bu nedenle, eşik seviyesi ayrı bir nöron modeli olarak şöyle gösterilir:

$$y = f(GxW) = f(NET)$$

Burada f olarak ifade edilen fonksiyon, bir aktivasyon fonksiyonu olarak gösterilmektedir. Bu fonksiyon bölgesi, nöron modelinin bir dizi aktivasyon değeridir. Eşikleme fonksiyonlarının, doğrusal ve doğrusal olmayan biçimleri bulunmaktadır. Bu aktivasyon fonksiyonlarına örnek vermek gerekirse; step ve signum fonksiyonları genellikle örüntü tanıma ve sınıflandırma çalışmalarında, sigmoid fonksiyonu geri yayımlı ağlarında, doğrusal aktivasyon fonksiyonu ise genellikle doğrusal yakınlıştırmada kullanılmaktadır.

Tablo-1: Toplama Fonksiyonları Örnekleri

<u>Çarpım</u> $NET = \prod_i G_i W_i$	Girdi değerleri ağırlık değerleri ile çarpılır ve bulunan değerler birbirleri ile çarpılarak net girdi hesaplanır.
<u>Maksimum</u> $NET = \text{Max}(G_i W_i), i = 1, 2, \dots, N$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra, elde edilen en büyük olanı yapay sinir hücresine net girdi olarak gönderilir.
<u>Minimum</u> $NET = \text{Min}(G_i W_i), i = 1, 2, \dots, N$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra, elde edilen en küçük olanı yapay sinir hücresine net girdi olarak kabul edilir.
<u>Çoğunluk</u> $NET = \sum_i \text{sgn}(G_i W_i)$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra, negatif ve pozitif olanların sayısı bulunur. Büyük olan sayı hücrenin net girdisi olmaktadır.
<u>Kümülatif Toplam</u> $NET = \text{Net}(\text{eski}) + \sum (G_i W_i)$	Hücreye gelen bilgiler ağırlıklı olarak toplanır ve daha önceden gelen bilgilere eklenerek hücrenin net girdisi bulunur.

Kaynak: (Öztemel, 2006).

- v. **Çıktı:** Aktivasyon fonksiyonundan başarı ile geçebilen sonuç, çıktı değeri olarak elde edilir. Elde edilen bu çıktı, dış dünyaya veya başka bir hücreye tekrar gönderilebilir. Diğer bir deyişle, hücre kendi çıktısını yine kendisine girdi olarak geri gönderebilir (Vural, 2007, s. 15). Bir sinir hücresinin birden fazla elemanı olmasına rağmen, sadece bir çıktısı bulunmaktadır.

2.3. YAPAY SINIR AĞLARININ EĞİTİM SÜREÇLERİ VE ÖĞRENME ÖZELLİKLERİ

Yapay sinir ağlarının en değerli özelliklerinden biri, sistem davranışını ifade eden örneklerin sunumundan ortaya çıkan öğrenme yetenekleridir (da Silva et al., 2017, s. 25). Bu nedenle ağ, girdiler ve çıktılar arasındaki ilişkiyi öğrendikten sonra çözümlmeyi genişletebilir. Diğer bir deyişle, ağın herhangi bir verili girdi değerinin beklenen çıktısına yakın bir çıktı üretebileceği anlamına gelmektedir. Bir sinir ağının eğitim süreci, çıktıları tarafından üretilen çözümleri genelleştirmek için nöronların ağırlıklarını ve eşiklerini (thresholds) ayarlamak için gerekli koordineli adımları uygulamaktan ibarettir. Ağı eğitmek için kullanılan sıralı adımlar kümesine öğrenme algoritması denilmektedir. Diğer bir deyişle, verilen bilgilere göre ağırlıkları değiştirmeye yönelik sistematik yaklaşıma öğrenme kuralı denilmektedir (Kim, 2017, s. 29). Yürütülmesi sırasında ağ, sistemden alınan örneklerden haritalanan sistem ile ilgili ayırt edici özellikleri çıkarabilmektedir.

Sistem davranışını mevcut tüm örneklerini içeren tam veri kümesi, genellikle eğitim alt kümesi ve test alt kümesi olarak iki alt kümeye ayrılır. Tüm veri kümesinden rassal örneklemelerin %60-90'ından oluşan eğitim alt kümesi, öğrenme sürecinde esas olarak kullanılmaktadır. Diğer taraftan, tüm veri kümesinin %10-40'ından oluşan test alt kümesi, genelleştirme çözümlerinin ağ yeteneklerinin kabul edilebilir seviyelerde olup olmadığını doğrulamak için kullanılacak ve böylece belirli bir topolojinin doğrulanmasına izin verecektir. Yapay sinir ağlarının eğitim sürecinde ağırlıkları ve eşikleri ayarlamak için eğitim kümesine ait tüm örneklemelerin eksiksiz sunumuna ise eğitim dönem ismi verilmektedir. Öğrenme stratejileri olarak da denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli (takviyeli) öğrenme olmak üzere üç strateji vardır.

i) Denetimli Öğrenme

Bu öğrenme stratejisi, 1949 yılında nörofizyolojik gözlemlerden esinlenerek, Donald Hebb tarafından önerilmiştir (Mehrotra vd., 1996, s. 218). Denetimli öğrenme, belirli bir giriş sinyal kümesi için çıktıların mevcut olmasını içermektedir. Diğer bir deyişle; her eğitim örneği, giriş sinyallerinden ve buna karşılık gelen çıkışlardan oluşmaktadır. Süreci ve davranışını temsil eden öznitelik veya değer tablosu olarak da adlandırılan girdi/çıkı verilerini içeren bir tabloya ihtiyaç duymaktadır. Denetimli

öğrenmenin uygulanması yalnızca bu öznelik/değer tablosunun varlığına bağlıdır. Ağa sunulan her örnek için doğru yanıtın ne olduğunu öğretiyormuş gibi davranılır.

ii) Denetimsiz Öğrenme

Denetimsiz öğrenmeye dayalı bu stratejide, ilgili istenilen çıktılar hakkında herhangi bir bilgiye gerek yoktur. Bu nedenle, tüm örnek kümesini oluşturan öğeler arasında benzerlikler sunan alt kümeler tanımlayan mevcut özellikler olduğundan, ağ kendi kendini düzenlemektedir (Mehrotra vd., 1996, s. 24). Öğrenme algoritması, ağın kendi içindeki bu kümeleri yansıtmak için ağın ağırlıklarını ve eşiklerini ayarlamaktadır. Bu öğrenmede; ağ tasarımcısı, eldeki problem hakkındaki bilgisini kullanarak olası kümelerin maksimum miktarını önceden belirleyebilir.

iii) Pekiştirmeli - Takviyeli Öğrenme

Takviyeye dayalı yöntemler, ağ tarafından üretilen yanıt ile karşılık gelen veya istenilen çıktı arasındaki fark, sürekli olarak analiz edilir. Pekiştirmeli öğrenme, denetimli öğrenme tekniğinin bir varyasyonu olarak kabul edilmektedir (Sutton ve Barto, 1998). Bu öğrenme algoritmaları haritalanan sistem ile etkileşim yolu ile elde edilen herhangi bir nitel veya nicel bilgiye dayanarak, dahili sinirsel parametreleri ayarlar ve bu bilgiyi öğrenme performansını değerlendirmek için kullanmaktadır.

Pekiştirmeli öğrenmede, ağ öğrenme süreci genellikle deneme – yanılma yoluyla yapılmaktadır. Çünkü belirli bir girdi için mevcut tek yanıt, tatmin edici ya da yeterli olup olmadığıdır. Yanıtın tatmin edici olması durumunda, sistem ilgili bu davranışsal durumu güçlendirmek için ağırlıkları ve eşikleri kademeli olarak günceller.

2.4. YAPAY SİNİR AĞLARININ TEMEL KATMANLARI

Bir yapay sinir ağının mimarisi, birkaç nöronunun birbirlerine göre nasıl düzenlendiğini tanımlar. Bu düzenlemelerde temel olarak nöronların bağlantılarını yönlendirerek yapılandırılır. Belirli bir mimari içindeki belirli bir sinir ağının geometrik şekli (topolojisi), üstlenebileceği farklı yapılar olarak tanımlanabilir. Diğer bir deyişle, benzer mimariye ait iki topolojiye sahip olmak mümkündür. Örneğin, bir ağın geometrik şekli (topolojisi) 12 nörondan oluşurken, başka bir ağın geometrik şekli 18 nörondan

oluşabilir. Aynı mantıkla, birinci ağın geometrik şeklindeki aktivasyon fonksiyonu sigmoid iken, diğerinin şekli logsig olabilir. Genel olarak bir yapay sinir ağı; i) Girdi katmanı, ii) Gizli, ara veya görünmez katmanlar ve iii) Çıktı katmanı olmak üzere, üç katmana ayrılmaktadır.

i) Girdi Katmanı

Girdi katmanı, dış dünyadan veya ortamdan sinyal, bilgi, özellik veya ölçüm almaktan sorumludur. Bu girdiler genellikle aktivasyon fonksiyonu tarafından üretilen sınır değerler içinde normalleştirilir. Bu normalleştirme, ağ tarafından gerçekleştirilen matematiksel işlemler için daha iyi sonuçlar sağlamaktadır.

ii) Gizli, Ara veya Görünmez Katmanlar

Bu katman, analiz edilen süreç veya sistemle ilişkili kalıpları çıkarmaktan sorumlu nöronlardan oluşmaktadır. Bu katmanlar, dahili işlemlerin çoğunu bir ağdan gerçekleştirir.

iii) Çıktı Katmanı

Çıktı katmanı, aynı zamanda nöronlardan oluşabilir ve bu nedenle önceki katmanlardaki nöronlar tarafından gerçekleştirilen işlemlerden kaynaklanan nihai ağ çıktılarının üretilmesinden ve sunulmasından sorumludur.

2.5. YAPAY SİNİR AĞI MİMARİLERİ

Yapay sinir ağı mimarileri; i) Tek katmanlı – İleri beslemeli ağ ve ii) Çok katmanlı - İleri beslemeli ağ olmak üzere ikiye ayrılmaktadır.


2.5.1. Tek Katmanlı - İleri Beslemeli Ağ

Bu mimari (ağ), yalnızca bir giriş katmanına ve aynı zamanda çıkış katmanına sahip olan tek bir sinir ağıdır. Bilgi her zaman giriş katmanından çıkış katmanına tek bir yönde ilerlemektedir. Tek katmanlı mimarilerde, çıktı fonksiyonu doğrusal fonksiyondur. Diğer bir deyişle, ağa gösterilen örnekler iki sınıf arasından paylaştırılarak, bu iki sınıfı

ayırt etmeye ve bir doğru bulmaya çalışılmaktadır (Öztemel, 2006, s. 60). Bu nedenle, eşik değer fonksiyonu kullanılmaktadır. Elde edilen sonuca göre, ağın çıktısı 1 veya 0 değerini almaktadır. Buradaki 1 ve 0 değerleri farklı sınıfları temsil etmektedir. Ağın çıktısının 1 olması durumunda ilgili nesnenin (veri, görsel, ses, vb.) birinci sınıfta veya grupta, 0 olması durumunda ise ikinci sınıfta veya grupta olduğu kabul edilmektedir. Bu tür mimariler genellikle örüntü, sınıflandırma ve doğrusal filtreleme problemlerinin çözümünde tercih edilmektedir.

İleri beslemeli mimariye ait ana ağ türleri arasında, eğitim süreçlerinde kullanılan öğrenme algoritmaları Hebb kuralı, Delta kuralına dayanan algılayıcı bulunmaktadır. Şekil-1’de n adet girdi ve m adet çıktıdan oluşan tek katmanlı - ileri beslemeli bir ağ yer almaktadır. Söz konusu şekildeki mimariye ait ağlarda, ağ çıkışlarının sayısının her zaman nöron sayısıyla çakışacağı görülebilmektedir.

Şekil-1: Tek Katmanlı - İleri Beslemeli Ağ Örneği




2.5.2. Çok Katmanlı - İleri Beslemeli Ağ

Çok katmanlı ağlar, bir veya daha fazla gizli katmandan oluşmaktadır. Fonksiyon yaklaşımı sistem tanımlaması, süreç kontrolü, optimizasyon, robotik, vb. ile ilgili olan çeşitli problemlerin çözümlerinde kullanılırlar. Şekil-2’de, n örnek sinyalli bir giriş katmanı, sırasıyla n_1 ve n_2 nörondan oluşan iki gizli katman ve m çıktı katmanından oluşan bir ileri beslemeli ağı gösterilmektedir. Söz konusu şekildeki ilk gizli katmanı oluşturan nöronların miktarı, genellikle ağı giriş katmanını oluşturan sinyal sayısından

farklılık göstermektedir. Gizli katmanların sayısı ve ilgili nöron miktarı, ağ tarafından haritalanan problemin doğasına, karmaşıklığına ve ayrıca problemle ilgili mevcut verilerin miktarına ve kalitesine bağlıdır.

Şekil-2: Çok Katmanlı - İleri Beslemeli Ağ Örneği



2.6. ÇOK KATMANLI ALGILAYICI

Çok katmanlı algılayıcı (Multi Layer Perceptron,MLP) ağı, girdi katmanı ile çıktı katmanı arasına yerleştirilen ve en az bir gizli katmana sahip olan bir algılayıcıdır. MLP, ağları en az iki sinir katmanına sahip olup nöronları ara ve çıkış katmanları arasında dağıtılmaktadır (da Silva et al., 2017, s. 55).

MLP ağları farklı bilgi alanlarından çeşitli problemlerde geniş uygulama alanları ile bilinir ve uygulanabilirlik açısından geniş yelpazeye sahip ağlar olarak kabul edilirler. Bu potansiyel alanlar arasında en önemli olanları şunlardır:

- Evrensel Fonksiyon Yaklaşımı (Eğri Uydurma)
- Desen Tanıma
- Proses tanımlama ve kontrol
- Zaman serisi tahmini

- Sistem optimizasyonu
- ...


MLP ağları, eğitimi denetimli bir süreçle gerçekleştirilen çok katmanlı ileri beslemeli mimariye sahiptir. Ağ içindeki bilgi akışı; giriş katmanından başlar, daha sonra ara katmanlara geçer ve çıkış katmanı ile son bulur. Geleneksel MLP ağları, çıktı katmanı veya ara katman tarafından üretilen herhangi bir değer geri beslemeye ait değildir.

Bu ağlar, 1980’li yılların sonlarında, geri yayılım adı verilen öğrenme algoritmasının olduğu “Paralel Dağıtılmış İşleme (Parallel Distributed Processing, PDP)” kitabının yayınlanması ile literatüre kazandırılmıştır (Rumelhart vd. 1986).

2.6.1. Çok Katmanlı Algılayıcıların Çalışma Prensipleri

Belirli bir uygulamadan gelen sinyalleri temsil eden ağın her giriş değeri, çıkış katmanına doğru yayılmaktadır. Bu durumda, birinci katmandan gelen nöronların çıktıları, ikinci gizli katmandan gelen nöronların girdileri olmaktadır. Çok katmanlı bir algılayıcı ağının görünümü Şekil-3’te yer almaktadır.

Şekil-3: Çok Katmanlı Bir Algılayıcı Ağı



Algılayıcı gibi ağlardan farklı olarak Şekil-4’de MLP topolojisinde (sinir ağının geometrik şeklinde, haritalanmasında) gizli katmanların varlığının yanısıra, çıktı katmanının birkaç nörondan oluşabileceğini ve bu nöronların her birinin çıktılardan birini

temsil ettiği gösterilmektedir. Haritalandırılan süreç m çıktıdan meydana gelmişse, MLP ağının son katmanında da m nöron olacaktır.

Tüm sürecin haritalanmasında, tek katmanlı algılayıcıların aksine, sistemin giriş ve çıkışlarının davranışına ilişkin bilgi, sistemi oluşturan tüm nöronlar arasında dağıtılmaktadır. Bir MLP’de sinyaller veya dış dünyadan gelen bilgiler, ağa girdi katmanında sunulmaktadır. Ara katmanlar ise sistem davranışıyla ilgili bilgilerin çoğunu çıkarır ve nöronlarının ağırlıklarını ve eşiklerini kullanarak kodlar. Bu sayede, belirli sistemin bulunduğu ortamın bir temsili oluşturmuş olur. Son kısımda bulunan çıktı katmanı ise son ara katmanın nöronlarından uyarıları alır ve ağ tarafından üretilen çıktı olacak şekilde bir yanıt modeli üretir.

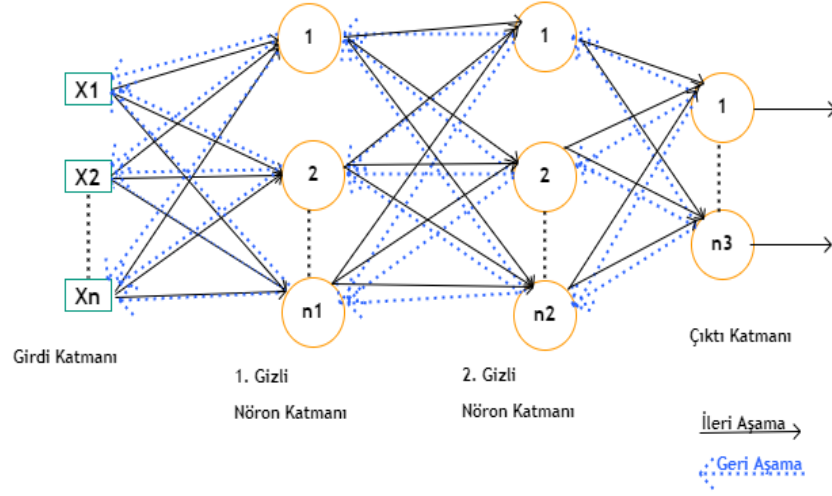
Bir MLP ağının topolojik konfigürasyonunun spesifikasyonu (geometrik şeklinin belirlenmesi), ara katmanların sayısı ve bunların ilgili nöron sayısı, bu bölümde ele alınacak birkaç faktöre bağlıdır. Daha spesifik olarak MLP tarafından haritalanan problemin sınıfı, eğitim örneklerin uzamsal dağılımı ve hem eğitim parametreleri hem de ağırlık matrisleri için başlangıç değerleri, ağın topolojisinin kurulmasına yardımcı olan unsurlardır.

2.6.2. Çok Katmanlı Algılayıcıların Eğitim Süreci

Geri yayılım algoritmasını kullanan MLP ağlarının eğitim süreci genellikle iki spesifik aşamanın peş peşe uygulanması ile yapılır. Bu aşamalar, iki gizli katmandan, giriş katmanından n sinyal, birinci gizli katmanında n_1 nöron, ikinci gizli katmanından n_2 nöron ve bunlarla ilişkili çıkış katmanı (üçüncü sinir katmanı) n_3 sinyalden oluşan bir MLP konfigürasyonunu ifade eden Şekil-4’de gösterilmektedir.

İlk aşama, eğitim kümesinden belirli bir örneğin $\{X_1, X_2, \dots, X_n\}$ sinyallerinin ağ girdilerine eklendiğini ve karşılık gelen çıktıların üretimine kadar katmanlar arası yayılımı, ileri yayılma olarak adlandırılmaktadır. Bu nedenle; bu aşama, yalnızca nöronlarının ağırlıklarının ve eşiklerinin, bu aşamanın yürütülmesi sırasında değiştirilmeden kalacak olan mevcut değerleri dikkate alınarak, ağdan gelen yanıtları elde etmeyi amaçlamaktadır.

Şekil-4: MLP Ağının Her İki Eğitim Aşamasının Görünümü



Daha sonra, ağ çıktıları tarafından üretilen yanıtlar, denetimli bir öğrenme sürecinde olduğundan, ilgili mevcut istenen yanıtlarla karşılaştırılır. Çıktı katmanında n_3 nöronlu bir MLP ağı göz önüne alındığında, istenilen yanıtlar ile çıktı tarafından üretilenler arasındaki ilgili n_3 , sapmaların (hesaplandığı) ve hataların kullanılacağını belirtmek mümkündür.

Bu nedenle, bu hatalardan dolayı geriye yayılım algoritmasının geri yayılımı olarak bilinen ikinci aşama uygulanır. İlk aşamadan farklı olarak, ağın tüm nöronlarının ağırlıklarının ve eşiklerinin modifikasyonları bu aşamada gerçekleştirilir.

İleri ve geri aşamalarının ardışık olarak uygulanması; nöronların, ağırlıklarının ve eşiklerinin her tekrarlama otomatik olarak ayarlanmasına izin vermektedir. Ayrıca ağ yanıtları tarafından üretilen hatalar toplamının (istenilen tepkilerin veya sonuçların) kademeli olarak azalmasıyla sonuçlanır.

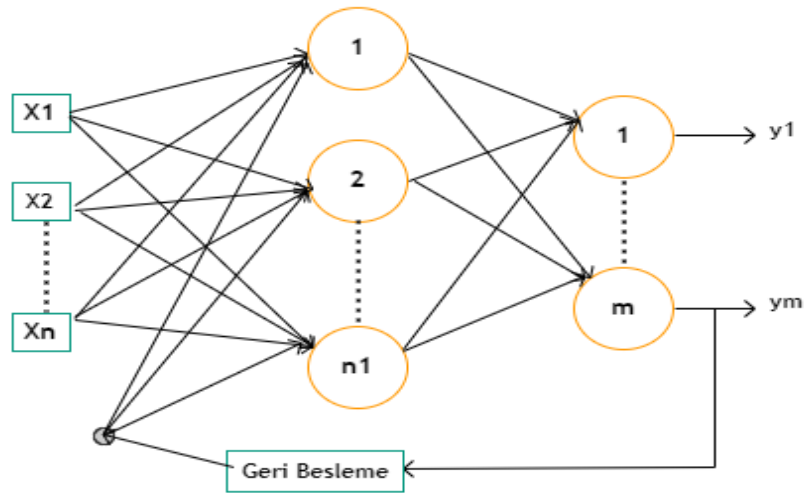
2.6.3. Geri Yayılım Algoritması

Geri yayılım algoritmasının (mimarisinin) çalışma prensibi ile geri yayılım algoritmasının türetilmesini irdelemekte yarar vardır.

2.6.3.1. Geri Yayılım Algoritmasının Çalışma Prensibi

Bu ağlarda; nöronların çıktıları, diğer nöronlar için geri besleme girdileri olarak kullanılırlar. Geri besleme özelliği, bu ağların dinamik bilgi işleme için kullanılabilmesini sağlar. Diğer bir deyişle; zaman serisi tahmini, sistem tanımlama ve optimizasyon, süreç kontrolü gibi zamanla değişen sistemlerde kullanılabilirler. Geri besleme algoritmasının bir örneği Şekil-5'teki gibidir.

Şekil-5: Geri Besleme Algoritması Örneği



Şekil-5, çıkış sinyallerinden birinin orta katmana geri beslendiği bir algılayıcı örneğini göstermektedir. Bu algoritmaya (mimariye) sahip ağlar, geri besleme sürecini kullanarak ve önceki çıkış değerini de dikkate alarak güncel çıktılar üretmektedir.

2.6.3.2. Geri Yayılım Algoritmasının Türetilmesi

Çok katmanlı algılayıcıların denetimli öğrenmedeki popülerliği, geri yayılım algoritmasının geliştirilmesi ile daha da artmıştır. Bu algoritma, hata kareleri ortalamasının dereceli olarak düşürülerek minimize edilmesi temeline dayanmaktadır. Bu minimize işlemi ise ağırlıkların ayarlanması şeklinde gerçekleştirilmektedir.

Nöron j ile bağlantılı aktivasyon fonksiyonunun girişinde üretilen uyarlanmış yerel alan $v_j(n)$ olsun:

$$v_j(n) = \sum_{j=0}^m w_{ji}(n)y_i(n) \quad (2.1)$$

Burada m, j nöronuna uygulanan toplam girdi sayısıdır. Ağırlık w_{j0} , sabit giriş $y_0 = +1$ 'e karşılık gelmektedir. j nöronuna uygulanan b_j biasına eşittir. Dolayısıyla, n iterasyonunda j nöronunun çıkışında görünen $y_j(n)$ fonksiyon sinyali şu şekildedir:

$$y_j(n) = \phi_j(v_j(n)) \quad (2.2)$$

Geri yayılım algoritması, ağırlığına bir $w_{ji}(n)$ düzeltmesi uygulanır ve bu $\partial \varepsilon(n)/\partial w_{ji}(n)$ kısmı türevi ile orantılıdır. Diğer bir deyişle, hata fonksiyonunu en küçükleyene kadar değiştirmektedir. Zincir kuralına göre, bu gradyanı şu şekilde ifade edilebilir:

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = \frac{\partial \varepsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (2.3)$$

Bu gradyandaki her bir terim için farklılaştırıldığında aşağıdaki eşitlikler elde edilmektedir:

$$\frac{\partial \varepsilon(n)}{\partial e_j(n)} = e_j(n), \quad \varepsilon_j(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \text{ olduğunda,} \quad (2.4)$$

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1, \quad e_j(n) = d_j(n) - y_j(n) \text{ olduğunda,} \quad (2.5)$$

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \phi_j'(v_j(n)), \quad y_j(n) = \phi_j(v_j(n)) \text{ olduğunda,} \quad (2.6)$$

$$\frac{\partial v_j(n)}{\partial w_{ji}(n)} = y_i(n), \quad v_j(n) = \sum_{j=0}^m w_{ji}(n)y_i(n) \text{ olduğunda,} \quad (2.7)$$

Denklemler (2.4)-(2.7) kullanımı ile (2.3)'in sonucu

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = -e_j(n) \phi_j'(v_j(n)) y_i(n) \quad (2.8)$$

olarak elde edilir. $\Delta w_{ji}(n)$ ögesine uygulanan düzeltme, $w_{ji}(n)$ delta kuralı ile tanımlanır (Ertel, 2017, p. 270) veya

$$\Delta w_{ji}(n) = -\eta \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} \quad (2.9)$$

şeklinde elde edilir. Burada η , geri yayılım algoritmasının öğrenme oranı parametresidir. Eşitlikte bulunan eksi (-) işaretinin kullanımı, ağırlık uzayında düşüşü açıklar. Diğer bir

deyişle, ağırlık deęişimi için deęerini azaltan $\varepsilon(n)$ 'in yön arayışıdır. Buna göre Eşitlik (2.8) ve (2.9) kullanılarak:

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (2.10)$$

sonucu elde edilir. Yerel gradyan $\delta_j(n)$ 'in tanımını ise aşağıdaki gibidir:

$$\begin{aligned} \delta_j(n) &= \frac{\partial \varepsilon(n)}{\partial v_j(n)} \\ &= \frac{\partial \varepsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \\ &= e_j(n) \phi'_j(v_j(n)) \end{aligned} \quad (2.11)$$

Yerel gradyan, ağırlıklarda gerekli deęişlikleri göstermektedir. Eşitlik (2.11)'de, j çıkış nöronu için yerel gradyan $\delta_j(n)$, o nöron için karşılık gelen hata sinyali $e_j(n)$ ve ilişkili aktivasyon fonksiyonunun $\phi'_j(v_j(n))$ türevinin çarpımına eşittir.

Eşitlik (2.10) ve (2.11)'de ağırlık ayarının Δw_{ji} hesaplanmasında bulunan önemli bir faktör, j nöronunun çıkışında bulunan $e_j(n)$ hata sinyalidir. Bu bağlamda, j nöronunun yer aldığı durum için düzenlenmiştir. Ağın geri kalan katmanlarındaki nöronlarda ağırlık deęerinin de öğrenme sürecinde güncellenmesi veya ayarlanması gerekmektedir (Haykin, 2010, p. 131).

Eşitlik (2.11) için gizli nöron j için yerel gradyan $\delta_j(n)$ aşağıdaki şekilde yeniden yazılabilir:

$$\begin{aligned} \delta_j(n) &= - \frac{\partial \varepsilon(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \\ &= - \frac{\partial \varepsilon(n)}{\partial y_j(n)} \phi'_j(v_j(n)), \quad \text{nöron } j \text{ gizlidir.} \end{aligned} \quad (2.12)$$

İkinci satırda, Eşitlik (2.6) kullanılmıştır. $\frac{\partial \varepsilon(n)}{\partial y_j(n)}$ kısmi türevi hesaplanması için aşağıdaki gibi devam edilebilir:

$$\varepsilon(n) = \frac{1}{2} \sum_{k \in C} e_k^2(n), \quad (2.13)$$

Burada, k değeri bir çıkış düğümüdür. Eşitlik (2.13) de j indeksi yerine k indeksi kullanılmıştır. Bu ikame durum karıştırılmaması için kullanılmıştır. Eşitlik 4.18'i, $y_j(n)$ fonksiyon sinyaline göre kısmi türevi alındığında,

$$\frac{\partial \varepsilon(n)}{\partial y_j(n)} = \sum_k e_k \frac{\partial e_k(n)}{\partial y_j(n)} \quad (2.14)$$

Daha sonra $\frac{\partial e_k(n)}{\partial y_j(n)}$ kısmi türevi için zincir kuralı kullanılır ve Eşitlik (2.14)'a eşdeğer hali:

$$\frac{\partial \varepsilon(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k}{\partial y_j(n)} \quad (2.15)$$

elde edilecektir. Ancak,

$$\begin{aligned} e_k(n) &= d_k(n) - y_k(n) \\ &= d_k(n) - \phi'_k(v_k(n)) \end{aligned} \quad (2.16)$$

olmaktadır. Burada nöron k bir çıktı düğümüdür. Buradan şu sonuca ulaşılır:

$$\frac{\partial e_k(n)}{\partial v_k(n)} = -\phi'_k(v_k(n)) \quad (2.17)$$

Ayrıca k nöronu için uyarlanmış yerel alan şöyledir:

$$v_k(n) = \sum_{j=0}^m w_{kj}(n) y_j(n) \quad (2.18)$$

Burada m , nöron k 'ya uygulanan toplam girdi sayısıdır. Burada yine $w_{k0}(n)$ ağırlığı, k nöronuna uygulanan $b_k(n)$ biasına eşittir ve karşılık gelen girdi +1 değerine sahiptir (Haykin, 2010, p. 133). Eşitlik (2.18), $y_j(n)$ ' e göre kısmi türevi alınırsa,

$$\frac{\partial v_k(n)}{\partial y_j(n)} = w_{kj}(n) \quad (2.19)$$

olacaktır. Bu durumda,


$$\begin{aligned} \frac{\partial \varepsilon(n)}{\partial y_j(n)} &= -\sum_k e_k(n) \phi'_k(v_k(n)) w_{kj}(n) \\ &= -\sum_k \delta_k(n) w_{kj}(n) \end{aligned} \quad (2.20)$$

Son olarak Eşitlik (2.12) ve (2.20) tarafından açıklanan yerel gradyan $\delta_k(n)$ için geri yayılım formülü şöyle elde edilir:

$$\delta_j(n) = \phi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (2.21)$$

Eşitlik (2.21), çıktı katmanının m_L nöronundan oluştuğu varsayılmıştır. Şekil-6'da, Eşitlik (2.21)'deki yerel gradyan $\delta_j(n)$ 'in hesaplanmasında yer alan dış faktör $\phi'_j(v_j(n))$ yalnızca gizli nöron j ile ilişkili aktivasyon fonksiyonuna bağlıdır. Bu hesaplamada yer alan geri kalan faktör, yani k üzerinden toplama iki terim kümesine bağlıdır. İlk terim kümesi $\delta_k(n)$, gizli nöron j 'nin hemen sağındaki katmanlarda bulunan ve doğrudan j nöronuna bağlı olan tüm nöronlar için $e_k(n)$ hata sinyallerinin bilgisini gerektirir. İkinci terim kümesi $w_{kj}(n)$, bu bağıntılarla ilişkili ağırlıklardan oluşmaktadır.

Şekil-6: Hata Sinyallerinin Geri Yayılımına İlişkin Bir Bölümünün Sinyal Akışı



Geri yayılım algoritması için elde edilenler özetlenirse, i nöronunu j nöronuna bağlayan ağırlığa uygulanan $\Delta w_{ji}(n)$ düzeltmesi delta kuralı ile şöyle tanımlanır:

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_j(n) \quad (2.22)$$

Bu eşitlikte, $\Delta w_{ji}(n)$ ağırlık düzeltmesini, η öğrenme oranı parametresini, $\delta_j(n)$ yerel gradyanı ve $y_j(n)$ ise j nöronunun giriş sinyalini göstermektedir. Geri yayılım algoritmasının uygulamasında iki farklı hesaplama geçişi ayırt edilir. İlkinde, ileri geçişte, ağırlıklar ağ boyunca değişmeden kalır ve ağın fonksiyon sinyalleri nöron bazında hesaplanır. Nöron k 'nin çıkışında görünen fonksiyon sinyali ise şu şekilde hesaplanır:

$$y_j(n) = \phi(v_j(n)), \quad (2.23)$$

Burada $v_j(n)$, j nöronunun uyarlanmış yerel alanıdır,

$$v_j(n) = \sum_{i=0}^m w_{ji}(n)y_i(n) \quad (2.24)$$

Burada m , j nöronuna uygulanan toplam girdi sayısıdır. $w_{ji}(n)$, nöron i 'yi nöron j 'ye bağlayan ağırlıktır ve $y_i(n)$, j nöronunun bir giriş sinyali ve buna eşdeğer olan nöron i 'nin çıkışında görünen fonksiyon sinyalidir. j nöronu ağırlık ilk gizli katmanı ise $m = m_0$ ve i dizini ağırlık i 'inci giriş terminalini ifade eder. Bunun için şöyle yazılır:

$$y_j(n) = x_i(n) \quad (2.25)$$

Burada, $x_i(n)$ girdi vektörünün i 'nci ögesi. Ayrıca nöron j , ağırlık çıkış katmanındaysa $m = m_L$ ve j indeks ağırlık j 'inci çıkış terminalini ifade eder. Bunun için şöyle yazılır:

$$y_j(n) = o_i(n) \quad (2.26)$$

Bu eşitlikteki $o_i(n)$, çok katmanlı algılayıcının çıkış vektörünün j 'inci elemanıdır. Bu çıktı j 'inci çıkış nöronu için $e_k(n)$ hata sinyalini elde ederek, istenilen $d_j(n)$ yanıtı ile karşılaştırılır. Bu sayede hesaplamaların ileri aşaması, ilk gizli katmanda onu girdi vektörü ile sunarak başlar ve bu katmanın her bir nöronu için hata sinyalini hesaplayarak çıktı katmanında sona erer (Haykin, 2010, p. 135).

İkincisi ise geriye geçiştir. Her nöron için hata sinyallerini ağırlıklardan sola, katman katman tekrarlı olarak δ (yerel gradyan) geçirmektedir. Bu öz yinelenmeli süreç, ağırlık ağırlıklarının delta kuralına göre değişikliklere uğramasına izin verir. Çıktı katmanında bulunan bir nöron için δ nöronun hata sinyalinin doğrusal olmaması durumunda birinci türevi ile çarpılmaktadır. Çıktı katmanında beslenen tüm bağlantıların ağırlıklarındaki değişikliklerin hesaplanabilmesi için Eşitlik (2.22) kullanılmaktadır. Çıkış katmanının nöronları için δ_s verildiğinde daha sonra Eşitlik (2.21) sondan bir önceki katmandaki tüm nöronlar için δ_s 'yi ve dolayısıyla da onu besleyen tüm bağlantıların ağırlığındaki değişiklikleri hesaplayabilmek için ağırlık tarafından kullanılmaktadır. Diğer bir deyişle, her eğitim örneğinin sunumu için giriş modelinin sabit olduğunu, yani ileri geçişi ve ardından geri geçişi kapsayan gidiş-dönüş süresi boyunca sıkı sıkıyadır.

2.6.4. Geri Yayılım Algoritmasının Optimize Edilmiş Türleri

Yakınsama etkinliğini artırabilmek için bazı geri yayılım yöntemleri kullanılmaktadır. Bu yöntemler arasında momentum parametresi, esnek yayılım ve Levenberg-Marquardt yöntemleri yer almaktadır. Bu çalışmada yapay sinir ağı uygulamasının Levenberg – Marquardt yöntemi ile gerçekleştirilmesi nedeniyle, bu optimizasyon yöntemini irdelemekte yarar vardır.

Geri yayılım algoritması, karesi alınmış hata fonksiyonunun gradyanının ters yönde ağırlık matrislerinin değerlerini ayarlamaktadır. Pratikte bu algoritma çok yavaş yakınsama eğilimlidir ve bu nedenle yüksek hesaplama çabası gerektirmektedir. Bu durumdan kaçınmak için yakınsama süresini azaltmak ve gereken çabayı artırabilmek için geri yayılım algoritmasına çeşitli optimizasyon yöntemleri dahil edilmiştir. Bu amaçla optimizasyon yöntemleri arasında Levenberg – Marquardt algoritması (Hagan & Menhaj, 1994) öne çıkmaktadır. Dolayısıyla, bu algoritma daha fazla bellek ancak daha az zaman gerektirmektedir (Hudson Beale et al., 2017, s. 118).

Levenberg – Marquardt algoritması, doğrusal olmayan modeller için en küçük kareler yöntemine dayanan ve eğitim sürecinin verimliliğini artırmak için geri yayılım algoritmasına dahil edilebilen ikinci dereceden bir gradyan yöntemidir (Hudson Beale et al., 2017, s. 108). Bu algoritma için verilen örneğe göre, çıkış nöronları tarafından üretilen sonuçlara ilişkin yerel performansı ölçmek amacıyla, aşağıdaki karesel hata fonksiyonu kullanılır:

$$E(k) = \frac{1}{2} \sum_{j=1}^{n_3} \left(d_j(k) - Y_j^{(3)}(k) \right)^2 \quad (2.27)$$

Burada, $Y_j^{(3)}(k)$ eğitim örneği için ağırlık j 'inci çıkış nöronu tarafından üretilen değerler iken, $d_j(k)$ ise istenilen değere karşılık gelen değeri temsil etmektedir. Sonuç olarak p örneklemeden oluşan bir eğitim kümesi varsayıldığında, geri yayılım algoritmasının global performansının ölçümü ortalama karesel hata ile hesaplanabilir:

$$E_M = \frac{1}{p} \sum_{k=1}^p E(k) \quad (2.28)$$

Burada, $E(k)$ elde edilen karesel hatadır. Eşitlik (2.27) ve (2.28) birlikte yazıldığında:

$$\begin{aligned}
V &= \frac{1}{2p} \sum_{k=1}^p \sum_{j=1}^{n_3} \left(d_j(k) - Y_j^{(3)}(k) \right)^2 \\
V &= \frac{1}{2p} \sum_{k=1}^p \left(d(k) - Y^{(3)}(k) \right)^T \left(d(k) - Y^{(3)}(k) \right) \quad (2.29) \\
V &= \frac{1}{2p} \sum_{k=1}^p E^T(k) E(k),
\end{aligned}$$

Burada, $\{E(k) = d(k) - Y^{(3)}(k)\}$, k 'inci eğitim örnekleme göre hata vektörünü belirtmektedir. k örnekleme için ise hata şu şekilde verilmektedir:

$$V = \frac{1}{2} E^T(k) \cdot E(k) \quad (2.30)$$

Geri yayılım algoritması, karesel hata fonksiyonunu en aza indirmek için gradyan azalan bir yöntem iken, Levenberg – Marquardt algoritması Newton yönteminin bir yaklaşımıdır (Battiti, 1992; Dan Foresee & Hagan, 1997). Bir $V(z)$ fonksiyonunun parametrik z vektörüne göre minimizasyonu aşağıdaki iterasyonu yöntem ile verilmektedir:

$$\Delta z = -(\nabla^2 V(z))^{-1} \nabla V(z) \quad (2.31)$$

Bu eşitlikte $\nabla^2 V(z)$ Hessian matrisini (ikinci dereceden türevlerin matrisini) göstermektedir ve $V(z)$ 'nin Jacobian matrisi, $\nabla V(z)$ ise birinci dereceden türevlerin matrisini göstermektedir. $V(z)$ 'nin q elemanlardan oluşan belirli bir parametrik z vektörü için Eşitlik (2.29)'de verilenler gibi m ikinci dereceden fonksiyonu yürüten bir fonksiyon olduğu varsayıldığında aşağıdaki eşitlik elde edilir:

$$V(z) = \sum_{i=1}^m e_i^2(z) \quad (2.32)$$

Böylece, önceki eşitlikten şu sonuçlara ulaşılır:

$$\nabla V(z) = J^T(z) \cdot e(z) \quad (2.33)$$

$$\nabla^2 V(z) = J^T(z) \cdot J(z) + \mu \cdot I \quad (2.34)$$

I birim matrisi, μ ise Levenberg – Marquardt algoritmasının yakınsama oranını ayarlayan bir parametreyi göstermektedir ve $J(z)$ ise Jacobian matrisi olup şu şekilde tanımlanmaktadır:

$$J(z) = \begin{bmatrix} \frac{\partial e_1(z)}{\partial z_1} & \frac{\partial e_1(z)}{\partial z_2} & \dots & \frac{\partial e_1(z)}{\partial z_q} \\ \frac{\partial e_2(z)}{\partial z_1} & \frac{\partial e_2(z)}{\partial z_2} & \dots & \frac{\partial e_2(z)}{\partial z_q} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(z)}{\partial z_1} & \frac{\partial e_N(z)}{\partial z_2} & \dots & \frac{\partial e_N(z)}{\partial z_q} \end{bmatrix} \quad (2.35)$$

Eşitlik (2.33) ve (2.34)'in sonuçları Eşitlik (2.31)'e eklenerek, Levenberg – Marquardt yönteminin iterasyonlu ifadesi şöyle elde edilir:

$$\Delta z = (J^T(z).J(z) + \mu.I)^{-1}.J^T(z).e(z) \quad (2.36)$$

Bu nedenle, bu algoritmanın birincil özelliği Jacobian matrisinin hesaplanmasıdır. MLP ağlarının eğitim süreci, Jacobian matrisi kullanılarak ağırlık matrislerine göre yeniden yazıldığında şöyle olur:

$$J(W) = [J(W^{(1)}) \quad J(W^{(2)}) \quad J(W^{(3)})] \quad (2.37)$$

Burada, $J(W) \in \mathfrak{R}^{(p) \times ((n+1).n_1 + (n_1+1).n_2 + (n_2+1).n_3)}$ olmaktadır. Bu durumda, W aşağıdaki bileşenlerden oluşur:

$$\begin{aligned} W &= [W^{(1)} \quad W^{(2)} \quad W^{(3)}] \\ &= \begin{bmatrix} W_{1,0}^1 \dots W_{1,n}^1 & W_{2,0}^1 \dots W_{2,n}^1 & \dots & W_{n_1,0}^1 \dots W_{n_1,n}^1 \\ W_{1,0}^2 \dots W_{1,n_1}^2 & W_{2,0}^2 \dots W_{2,n_1}^2 & \dots & W_{n_2,0}^2 \dots W_{n_2,n_1}^2 \\ W_{1,0}^3 \dots W_{1,n_2}^3 & W_{2,0}^3 \dots W_{2,n_2}^3 & \dots & W_{n_3,0}^3 \dots W_{n_3,n_2}^3 \end{bmatrix}^T \end{aligned} \quad (2.38)$$

Burada, $W \in \mathfrak{R}^{(p) \times ((n+1).n_1 + (n_1+1).n_2 + (n_2+1).n_3)}$ dir.

$J(W^{(1)})$, $J(W^{(2)})$ ve $J(W^{(3)})$ matrisleri ise şu şekilde tanımlanırlar:

$$J(W^{(1)}) = \begin{bmatrix} \frac{\partial E(1)}{\partial W_{1,1}^{(1)}} & \dots & \frac{\partial E(1)}{\partial W_{1,n}^{(1)}} & \frac{\partial E(1)}{\partial W_{2,1}^{(1)}} & \dots & \frac{\partial E(1)}{\partial W_{2,n}^{(1)}} & \frac{\partial E(1)}{\partial W_{n_1,1}^{(1)}} & \dots & \frac{\partial E(1)}{\partial W_{n_1,n}^{(1)}} \\ \frac{\partial E(2)}{\partial W_{1,1}^{(1)}} & \dots & \frac{\partial E(2)}{\partial W_{1,n}^{(1)}} & \frac{\partial E(2)}{\partial W_{2,1}^{(1)}} & \dots & \frac{\partial E(2)}{\partial W_{2,n}^{(1)}} & \frac{\partial E(2)}{\partial W_{n_1,1}^{(1)}} & \dots & \frac{\partial E(2)}{\partial W_{n_1,n}^{(1)}} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ \frac{\partial E(p)}{\partial W_{1,1}^{(1)}} & \dots & \frac{\partial E(p)}{\partial W_{1,n}^{(1)}} & \frac{\partial E(p)}{\partial W_{2,1}^{(1)}} & \dots & \frac{\partial E(p)}{\partial W_{2,n}^{(1)}} & \frac{\partial E(p)}{\partial W_{n_1,1}^{(1)}} & \dots & \frac{\partial E(p)}{\partial W_{n_1,n}^{(1)}} \end{bmatrix} \quad (2.39)$$

$$J(W^{(2)}) = \begin{bmatrix} \frac{\partial E(1)}{\partial W_{1,1}^{(2)}} & \dots & \frac{\partial E(1)}{\partial W_{1,n_1}^{(2)}} & \frac{\partial E(1)}{\partial W_{2,1}^{(2)}} & \dots & \frac{\partial E(1)}{\partial W_{2,n_1}^{(2)}} & \frac{\partial E(1)}{\partial W_{n_2,1}^{(2)}} & \dots & \frac{\partial E(1)}{\partial W_{n_2,n_1}^{(2)}} \\ \frac{\partial E(2)}{\partial W_{1,1}^{(2)}} & \dots & \frac{\partial E(2)}{\partial W_{1,n_1}^{(2)}} & \frac{\partial E(2)}{\partial W_{2,1}^{(2)}} & \dots & \frac{\partial E(2)}{\partial W_{2,n_1}^{(2)}} & \frac{\partial E(2)}{\partial W_{n_2,1}^{(2)}} & \dots & \frac{\partial E(2)}{\partial W_{n_2,n_1}^{(2)}} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ \frac{\partial E(p)}{\partial W_{1,1}^{(2)}} & \dots & \frac{\partial E(p)}{\partial W_{1,n_1}^{(2)}} & \frac{\partial E(p)}{\partial W_{2,1}^{(2)}} & \dots & \frac{\partial E(p)}{\partial W_{2,n_1}^{(2)}} & \frac{\partial E(p)}{\partial W_{n_2,1}^{(2)}} & \dots & \frac{\partial E(p)}{\partial W_{n_2,n_1}^{(2)}} \end{bmatrix} \quad (2.40)$$

$$J(W^{(3)}) = \begin{bmatrix} \frac{\partial E(1)}{\partial W_{1,1}^{(3)}} & \dots & \frac{\partial E(1)}{\partial W_{1,n_2}^{(3)}} & \frac{\partial E(1)}{\partial W_{2,1}^{(3)}} & \dots & \frac{\partial E(1)}{\partial W_{2,n_2}^{(3)}} & \frac{\partial E(1)}{\partial W_{n_2,1}^{(3)}} & \dots & \frac{\partial E(1)}{\partial W_{n_3,n_2}^{(3)}} \\ \frac{\partial E(2)}{\partial W_{1,1}^{(3)}} & \dots & \frac{\partial E(2)}{\partial W_{1,n_2}^{(3)}} & \frac{\partial E(2)}{\partial W_{2,1}^{(3)}} & \dots & \frac{\partial E(2)}{\partial W_{2,n_2}^{(3)}} & \frac{\partial E(2)}{\partial W_{n_2,1}^{(3)}} & \dots & \frac{\partial E(2)}{\partial W_{n_3,n_2}^{(3)}} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ \frac{\partial E(p)}{\partial W_{1,1}^{(3)}} & \dots & \frac{\partial E(p)}{\partial W_{1,n_2}^{(3)}} & \frac{\partial E(p)}{\partial W_{2,1}^{(3)}} & \dots & \frac{\partial E(p)}{\partial W_{2,n_2}^{(3)}} & \frac{\partial E(p)}{\partial W_{n_2,1}^{(3)}} & \dots & \frac{\partial E(p)}{\partial W_{n_3,n_2}^{(3)}} \end{bmatrix} \quad (2.41)$$

Burada, $J(W^{(1)}) \in \mathfrak{R}^{(p) \times (n \cdot n_1)}$, $J(W^{(2)}) \in \mathfrak{R}^{(p) \times (n_1 \cdot n_2)}$ ve $J(W^{(3)}) \in \mathfrak{R}^{(p) \times (n_2 \cdot n_3)}$ şeklindedir.

Eşitlik (2.36)'den, MLP ağırlıklar matrisleri ayarlayan Levenberg – Marquardt yönteminin iterasyonlu ifadesi aşağıdaki gibi yeniden yazılabilir:

$$\Delta W = [J^T(W) \cdot J(W) + \mu I]^{-1} \cdot J^T(W) \cdot E \quad (2.42)$$

Eşitlik (2.36)'de, $E = [E(1)E(2) \dots E(p)]^T$, p eğitim örneklerine göre hata vektörüdür.

$J(W^{(1)})$, $J(W^{(2)})$ ve $J(W^{(3)})$ matrislerinin elemanları, geleneksel geri yayılım algoritmasında kullanılan ileri ve geri aşamalarından sırası ile elde edilmektedir. Bu eşitlikler uygulanarak, Levenberg – Marquardt yönteminin MLP eğitim süreci geleneksel yöntemlere göre 10 ile 100 kat arasında daha hızlıdır (Hagan ve Menhaj, 1994). Ancak Eşitlik (2.36)'da kullanılan (z) matrisi uygun olmadığında, yakınsama sorununa neden olabilmektedir.

2.7. HİBRİT MODEL

Zaman serileri, bünyesinde doğrusal ilişkilerin yanında doğrusal olmayan ilişkileri de içerebilmektedir. Yapay sinir ağları (YSA) veri kümelerinde de benzer şekilde hem doğrusal hem de doğrusal olmayan ilişkiler bulunabilmektedir. YSA mimarileri her iki bileşene sahip veri kümelerini modelleyebilmektedir. Bununla birlikte, her veri kümesi için benzer şekilde etkili sonuçlar vereceği düşünülemez. Örneğin, YSA'ların oynaklığı tahmin etmedeki eksikliği, ekonometrik varsayımlar ile açıklanamamaktadır ve dolayısıyla kanıtlanamamaktadır (Hyup Roh, 2007, s. 917). Bu nedenle, literatürde farklı denemeler ile zaman serilerinin üstünlükleri ile YSA'nın üstünlüklerinin bir arada olduğu ve daha doğru sonuçlar öngörebilmek için çeşitli hibrit (karma, melez) çalışmalar önerilmiştir. Bu başlık altında literatürde kabul görmüş bazı hibrit yöntemlere değinilecektir.

2.7.1. Zhang ARIMA-YSA Hibrit Model Yaklaşımı

Hem ARIMA modeli hem de YSA mimarileri kendi uygulama alanları olan doğrusal veya doğrusal olmayan veri kümelerinde başarılı sonuçlar vermektedir. Ancak her ikisi de her koşula uygun evrensel model değildir. ARIMA modellerinin karmaşık doğrusal olmayan problemlere yaklaşımı yeterli değilken, YSA ise doğrusal problemlerin çözümünde kullanılmasının karışık sonuçlar¹⁷ verdiği gözlemlenmiştir (Zhang, 2003, s. 164). Dolayısıyla herhangi bir veriye YSA uygulanmamalıdır.

Zhang; ARIMA – YSA hibrit modelini, 2003 yılında yapmış olduğu çalışma ile literatüre kazandırmıştır. Öne sürmüştüğü bu modelin temelini oluşturan varsayım ise ilgili zaman serisinin doğrusal ya da doğrusal olmayan bileşenlerinin toplanmasından oluşmaktadır. Bunu aşağıdaki eşitlik ile şöyle ifade etmiştir:

$$Y_t = L_t + N_t \quad (2.43)$$

¹⁷ Doğrusal regresyon problemleri için YSA'nın performansının örneklem büyüklüğüne ve gürültü seviyesine bağlı olduğunu göstermiştir. Ayrıntılı bilgi için (Markham & Rakes, 1998) incelenebilir.

Bu eşitlikte, L_t doğrusal bileşeni, N_t ise doğrusal olmayan bileşeni temsil etmektedir. Bu iki bileşen verilerden tahmin edilmektedir. İlk olarak, ARIMA'nın doğrusal bileşeni modellenmesine izin verilmektedir. Daha sonra doğrusal modelden gelen hatalar sadece doğrusal olmayan ilişkiyi içerebilecektir (Zhang, 2003, s. 165).

$$e_t = Y_t - \hat{L}_t \quad (2.44)$$

Burada, e_t değişkeni, t zamandaki hataları göstermektedir. \hat{L}_t değeri ise t zamanda ARIMA modelinden elde edilen kestirim değerini temsil etmektedir. Y_t ise ilgili değişkenin gerçek değerlerini göstermektedir. Zhang (2003), hataların doğrusal modelin yeterliliğinin tanısı konusunda önemli olduğunu belirtirken, doğrusal modelin yeterli olabilmesi için hataların doğrusal korelasyon yapıları bulundurmamalı, ayrıca bir model bazı önemli varsayımları sağlamış olsa bile, doğrusal olmayan ilişkilerin uygun şekilde modellenememiş olduğundan, modelin yine de yeterli olamayacağını belirtmiştir. Doğrusal ilişkiye ilişkin bilgi ARIMA modeli ile elde edilirken, doğrusal olmayan ilişki ise YSA ile modellenerek elde edilmektedir:

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) + \varepsilon_t \quad (2.45)$$

Eşitlik (2.45)'de ε_t rassal hatayı temsil ederken, f ise YSA tarafından belirlenen doğrusal olmayan bir fonksiyonu temsil etmektedir. Bu sayede, ARIMA modeli ile elde edilen tahmin ile YSA dan elde edilen tahmin değerleri birleştirilerek toplanmaktadır:

$$\hat{Y}_t = \hat{L}_t + \hat{N}_t \quad (2.46)$$

Bu sayede doğrusal bileşen olan ARIMA ve doğrusal olmayan YSA bileşenleri toplanarak hibrit model elde edilmektedir.

2.7.2. Khashei – Bijari Hibrit Model Yaklaşımı

2010 yılında Khashei – Bijari'nin yapmış oldukları çalışma ile literatüre kazandırılmıştır. Bu modelde ARIMA modeli kullanılarak daha doğru sonuçlar elde edebilmek amacıyla, ileri beslemeli YSA temelli bir hibrit modeldir. Bu hibrit modelde, öncelikle ARIMA modeli tahmin edilerek, e_t hataları elde edilmektedir. İkinci aşamada

ise hatalar ve orijinal verilerde var olan doğrusal ve doğrusal olmayan ilişkileri modelleyebilmek için YSA kullanılmaktadır (Khashei & Bijari, 2010, p. 483).

2.7.3. Babu – Reddy Hibrit Model Yaklaşımı

Zhang ve Khashei – Bijari hibrit modellerinden farklı olarak verileri veya tahminleri doğrusal veya doğrusal olmayan bileşenlere ayırmamışlardır. Bunun yerine temel istatistik verilerini kullanarak hibrit modeli geliştirmişlerdir.

Babu – Reddy (2014) çalışmalarında, basıklık ve Jarque – Berra normallik testlerinden elde edilen katsayıları kullanmışlardır. Eğer, basıklık katsayısı 3'ten büyük ise normallik varsayımının sağlanmadığını ve dolayısıyla yüksek oynaklığa sahip olduğunu belirtmişlerdir. Diğer bir deyişle, basıklık katsayısı 3'ten küçük ise normallik varsayımının sağlandığını ve düşük oynaklığa sahip olduğunu belirtmişlerdir (Babu & Reddy, 2014, s. 29). Dolayısıyla, basıklık katsayısı 3'ten büyük olan zaman serisi doğrusal olmayan yapıyı temsil ettiği için YSA ile tahmin edilirken, basıklık katsayısı 3'ten küçük olması durumunda ise doğrusal yapıyı temsil ettiğini ve dolayısıyla ARIMA modeli ile tahmin edilmesi gerektiğini ileri sürmüşlerdir. Zaman serisine ait bu temel istatistik bilgisi doğrultusunda, veriler yüksek oynaklığa sahip olduğunda YSA ve düşük oynaklığa sahip ARIMA tahminlerinin toplanması ile elde edilen bir hibrit yöntemdir.

2.7.4. Roh Hibrit Model Yaklaşımı

Roh 2007 yılında yapmış olduğu çalışmasında, yukarıda açıklanan hibrit yöntemlerden farklı olarak ARIMA modeli yerine GARCH ve EGARCH modelleri ile çalışmıştır. Roh'un çıkış noktası ise YSA'ların zaman serilerindeki oynaklığını tahmin etmesindeki eksikliğinin ekonometrik olarak desteklenememesidir. Öne sürmüş olduğu temel yapı ise tekrarlayan denemeler ve hataların, öğrenme sürecinde tahmin edilen sonuçları etkileyen en önemli faktör girdi değişkeni(leri) belirlenmesidir. Aynı zamanda, YSA öğrenme sürecindeki bu zorlukları çözmek ve oynaklığın tahmin edebilirliğini, tahmin gücünün artırılabilmesi için NN-GARCH ve NN-EGARCH hibrit modellerini

önermiştir. Roh (2007), NN-GARCH ve NN-EGARCH hibrit modellerini şu şekilde tanımlamıştır (Hyup Roh, 2007):

NN-GARCH Modeli:

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2 \quad (2.47)$$

Eşitlik (2.47), GARCH(1,1) sürecini göstermektedir. Burada, GARCH(1,1) modeli az sayıda parametre ile kullanılsa bile, uzun zaman gecikmeli ARCH modelinin kullanılmasına benzer bir etki yaratmaktadır. Üç unsur ile ifade edilen Eşitlik (2.47)'deki unsurlar şunlardır (Hyup Roh, 2007, s. 918):

α_0 : koşulsuz oynaklık katsayısı

ε_{t-1}^2 : t-1 zamandaki hata

σ_{t-1}^2 : t-1 zamandaki varyans

Sonuç olarak, birbirleri ile koşullu ilişkilere sahip olan ε_{t-1}^2 ve σ_{t-1}^2 çıkarılabilir ve bu değişkenlerin katsayıları sırasıyla α_1 ve β_1 'e ayarlanır. Bunlar YSA öğrenme süreci için girdi değişkenlere dahil edilir. Yeni çıkarılan değişkenler ise şu şekildedir:

$$Y_1 = \hat{\beta}_1 \sigma_{t-1}^2 ,$$

$$Y_2 = \hat{\alpha}_1 \varepsilon_{t-1}^2$$

Bir sonraki aşamada ise bu yeni değişkenler YSA mimarileri ile yeniden oynaklık tahmin edilebilmektedir. Bu sayede, NN-GARCH(1,1) hibrit modeli tahmin edilmiş olmaktadır.

NN-EGARCH Modeli:

Nelson (1991) tarafından literatüre kazandırılan EGARCH modeli, koşullu varyansın negatif işaretli olmasını engelleyen ve asimetric etki göstererek kaldıraç etkisini tetikleyen ARCH ailesi modellerinden biridir. Birinci dereceden EGARCH modeli (Nelson, 1991):

$$\ln(h_t) = \alpha_0 + \beta_1 \ln h_{t-1} + \delta_1 \left| \frac{\varepsilon_{t-1}}{\sqrt{h_{t-1}}} \right| + \omega \frac{\varepsilon_{t-1}}{\sqrt{h_{t-1}}} \quad (2.48)$$

olarak tanımlanmaktadır. EGARCH modeli aşağıdaki dört unsur ile ifade edilebilir (Hyup Roh, 2007):

α : Koşulsuz varyans katsayısı

h_{t-1} : t-1 deki varyansın logaritmik değeri

$\left(\left| \frac{\varepsilon_{t-1}}{\sqrt{h_{t-1}}} \right| \right)$: Kaldıraç etkisi ile asimetrik şok

$\frac{\varepsilon_{t-1}}{\sqrt{h_{t-1}}}$: Kaldıraç etkisi

Yukarıdaki değişkenlere dayalı olarak yeni girdi değişkenleri çıkarılabilmektedir ve her değişken β, δ, ω ile NN- GARCH yapısına benzer şekilde ayarlanmaktadır¹⁸.

¹⁸ Bkz. Roh (2007).

ÜÇÜNCÜ BÖLÜM

ELEKTRİK TALEBİNİN (TÜKETİMİNİN) ZAMAN SERİSİ, YAPAY SINIR AĞI VE HİBRİT YÖNTEM İLE TAHMİNİ

3.1. LİTERATÜR TARAMASI

Elektrik talebi, saatlik zaman diliminden yıllık zaman dilimlerine kadar farklı periyotlarda, farklı istemlerin (taleplerin) oluşması ve elektriğin stoklanamaması gibi nedenlerle elektrik talebinin tahmini konularından dolayı, literatürde pek çok çalışmaya rastlamak mümkündür. Ülkeler ve/veya konunun tarafları, bu talebi tahmin etmek ve bu doğrultuda projeksiyonlar oluşturmaya çalışmaktadırlar.

Kısa, orta ve uzun vadeli elektrik talep tahminleri, ülkelerin büyümeleri ve kalkınmalarında önemli bir kaynak olduğu için tahminin yapılması ve bu tahminlerin ise doğruya en yakın olacak şekilde sonuçlar elde edilmesinin beklenmesi veya istenmesi nedeniyle, önemi daha da artmaktadır. Gelişmekte olan ülkelerin, gelişmiş ülke konumuna erişebilmesi için temel koşullardan biri de elektriğin arz – talep ve enerji – ekonomi etkileşimleri arasındaki dengeyi korumaktır (Ediger & Tatlıdil, 2002, s. 474). Yukarıda bahsedilen önemli özelliği nedeniyle, elektrik talep tahmini her dönem geçerliliğini korumaktadır. Bu yüzden, her dönem araştırmacıların ilgisini çekmiştir.

Literatürde var olan ve var olmaya devam edebilecek olan elektrik talebinin tahmininin kesin bir sonuca ulaştırılmasından ziyade, talebi etkileyen değişkenlerin parametrelerinde dönemden döneme farklılıklar oluşmasına neden olabilirken, elektrik talep tahminlerinin sürekli güncellenmesi ve çalışmalarda kullanılacak modellerin veya yöntemlerin yeniden değerlendirilmesine yol açarken, farklı veya yeni değişkenlerin çalışılan modellere veya yöntemlere eklenerek tekrarlanması, bu konuda yapılacak olan çalışmalarını teşvik etmektedir. Dolayısıyla elektrik talebinin tahmin edilmesi konusu, her zaman güncelliğini korumaya devam etmektedir. Literatürde elektrik talebini tahmin edebilmek için çok sayıda yöntem veya yaklaşım sunulmakla birlikte, bu bölümde

literatürde yapılmış olan çalışmalardan, tez çalışmasının uygulama bölümüne benzer yöntemler ile yapılmış çalışmalara kronolojik sıra ile değinilmiş ve özetlenmiştir.

Thompson (1976), hava koşullarına duyarlı elektrik yüklerini tahmin edebilmek amacıyla bir yöntem önermiştir. Bu yöntem ile coğrafi olarak farklı iklim alanlarını içeren güç sistemlerine uygulanabileceğini ve yıl içerisinde her mevsim çalışabilecek çevrimiçi (online) bir yöntem olarak sunmuştur. Çalışma sonucunda, hava koşullarına son derece duyarlı olan ve yaz dönemlerinde dahi yaklaşık %2'lik tahmin hatası ile öngörebilmiştir (Thompson, 1976).

Zivanovic (2002), çalışmasında, kısa vadeli elektrik talebini tahmin edebilmek amacıyla, parametrik olmayan bir algoritma önerisinde bulunmuştur. Nambiya'nın elektrik verileri kullanılan bu çalışmada, yerel doğrusal regresyon, yük zaman serisinin trend bileşenini tahmin etmek ve uygun yerel doğrusal fonksiyon ile ekstrapolasyon yaparak trend bileşenini tahmin etmeye çalışmıştır (Zivanovic, 2002).

Ghosh ve Das (2002) çalışmalarında, Hindistan'ın Maharashtra eyaletine ait 1980.04 – 1999.06 dönemine ilişkin mevsim etkisinden arındırılmış aylık veriler için çarpımsal mevsimsel otoregresif entegre edilmiş hareketli ortalama (MSARIMA) modeli ile öngörmeye çalışmışlardır. Elde edilen bulgu ise mevsimsel değişim ile birlikte, benzer trendi takip ettiği yönündedir (Ghosh & Das, 2002). Bu çalışmaya benzer yöntemleri kullanan bir başka çalışma ise Rallapalli ve Ghosh tarafından yapılmış ve bir önceki çalışma ile yakın bulgulara ulaşmışlardır (Rallapalli & Ghosh, 2012).

Taylor ve Buizza (2003)'nin çalışmalarında ise, elektrik talep tahmini için hava durumuna ait verileri kullanarak, 1 ile 10 gün arası için elektrik talebi tahmininde, hava durumu tahminlerinin kullanmasını araştırmışlardır. Bir hava durumu değişkenini 51 farklı senaryo ile oluşturmuşlardır. Sonuç olarak, farklı talep senaryoları üretilerek, elde edilen bu senaryoların dağılımları kullanılarak, geleneksel hava tahminleri kullanılarak elde edilen tahminlerden, daha iyi bir tahmin sonucuna ulaştığını göstermeyi hedeflemişlerdir. Ayrıca bu çalışma ile önermiş oldukları bu senaryolar ile tek değişkenli oynaklık tahmin yöntemleri kullanılarak elde edilen tahminlerin daha iyi sonuç verdiğini göstermişlerdir. (Taylor & Buizza, 2003).

Hamzaçebi ve Kutay (2004) yaptıkları çalışmada, elektrik talep tahminini YSA, Box – Jenkins modeli ile regresyon tekniklerini karşılaştırarak tahminde bulunmuş ve

elde edilen sonuçlara göre, YSA'nın diğer yöntemlere göre daha iyi sonuçlar verdiğine ulaşımlardır (Hamzaçebi & Kutay, 2004). Benzer çalışmayı Eraslan vd. (2017) yapmışlar ve YSA tekniğinin elektrik enerjisi tüketim tahmininde daha başarılı sonuçlara ulaşımlardır (Eraslan et al., 2017).

Taylor vd. (2006)'nın literatüre kazandırmış oldukları çalışmalarında, kısa vadeli elektrik talebini tahmin edebilmek için altı adet tek değişkenli yöntemin doğruluğunu karşılaştırmayı amaçlamışlardır. Önermiş oldukları yöntem ise üstel yumuşatma yöntemi ve temel bileşen analizine dayalı bir yöntemdir. Ele aldıkları bu talep tahmini ise Rio de Janerio, İngiltere ve Galler'in saatlik talep verileri kullanılarak gerçekleştirilmiştir (Taylor et al., 2006).

Halicioglu (2007), Türkiye'nin 1968 – 2005 dönemine ilişkin konut elektrik talebini; kentleşme, gelir ve fiyat açısından değerlendirmiştir. Çalışmasında eşbütünleşme, sınır testi ve Granger nedensellik testleri ile kısa ve uzun dönem ilişkileri ortaya koymaya çalışmıştır. Konut elektrik tüketiminin gelir, fiyat ve kentleşme üzerinde uzun dönemde Granger nedensellik ilişkisi bulgusuna ulaşırken, kısa dönemde ise ilişki bulamamıştır (Halicioglu, 2007).

Sözen ve Arcaklioglu (2007), çalışmalarında, Türkiye'nin 1968 – 2005 dönemine ilişkin, net elektrik tüketim miktarı, GSYİH, nüfus, GSMH, kurulu kapasite, brüt üretim, ithalat ve ihracat değişkenlerinden oluşan üç farklı YSA mimarisi oluşturmuşlardır. Model 1 olarak nitelendirdikleri YSA mimarisinin girdi değişkenleri: Nüfus, kurulu kapasite, brüt üretim, ithalat ve ihracat değişkenlerinden oluşurken; Model 2 olarak oluşturulan mimari GSMH ve nüfus; Model 3'ün girdi değişkenleri ise GSYİH ve nüfus değişkenlerinden meydana gelmektedir. Her üç modelin de çıktı değişkeni net elektrik tüketimi değişkenidir. Ekonomik göstergeler ile oluşturulan YSA mimarileri ile elde edilen tahmin sonuçlarının doğruluk derecesini artırdığı sonucuna ulaşımlardır (Sözen et al., 2007).

Hamzaçebi (2007) yapmış olduğu çalışmada, Türkiye'deki elektrik tüketim türlerine göre sanayi, konut, tarım ve taşımacılık sektörlerinin YSA ile 2020 yılına kadar tahminini gerçekleştirmiştir. YSA tahmin sonuçları ile gerçek gözlemlerin karşılaştırıldığı bu çalışmada, YSA'nın başarılı bir şekilde elektrik tüketim türlerini tahmin ettiği sonucuna ulaşmıştır (Hamzaçebi, 2007). Benzer şekilde, Ekonomou (2010),

Yunanistan'ın uzun vadeli elektrik talebini tahmin edebilmek için YSA'yı ele almıştır. YSA ile tahmin gerçekleştirebilmek için 2005-2008 dönemi verilerini kullanarak, 2010-12 ve 2015 dönemlerinin tahminini gerçekleştirmiştir (Economou, 2010). Çunkaş ve Altun (2010), çalışmalarında Türkiye'nin 2008 – 2014 dönemine ilişkin 8 adet ekonomik değişkeni girdi olarak kullanarak, elektrik talebini öngörebilmek için YSA mimarisi ile çalışmıştır (Çunkaş & Altun, 2010).

Pao (2009) çalışmasında, Tayvan'nın elektrik talep tahminini YSA ile gerçekleştirdiği çalışmasında, modelin girdi değişkeni olarak, değişen varyansı dahil ederek bir hibrit yöntem önermiştir. Ayrıca çalışmasında hem doğrusal hibrit yöntemi hem de doğrusal olmayan hibrit yöntemi karşılaştırmış ve her iki hibrit yönteminde elektrik talep tahmininde başarılı olduğunu göstermiştir (Pao, 2009).

Kavaklioglu vd. (2009), Türkiye'nin elektrik tüketimini tahmin edebilmek amacıyla, elektrik tüketimi, nüfus, GSMH, ithalat ve ihracat gibi ekonomik göstergelerin bir fonksiyonu olarak modellemişlerdir. 1975 – 2006 dönemlerini kapsayan çalışma YSA ile 2027 yılına kadar öngörüsü gerçekleştirilmiştir. YSA'nın elektrik tüketim tahmini için kullanılabilmesi sonucuna ulaşmışlardır (Kavaklioglu et al., 2009). Benzer bir çalışmayı Pençe vd. (2019), Türkiye'nin 2017-2023 dönemi elektrik talep tahminini gerçekleştirmişler ve Türkiye Elektrik İletim A.Ş (TEİAŞ)'ın tahmin sonuçları ile benzerlik gösterdiği sonucuna ulaşmışlardır (Pençe et al., 2019).

Sumer vd. (2009) çalışmalarında Kayseri ve Çevre Elektrik A.Ş. elektrik iletim bölgesine ait 1997.01 - 2005.12 dönemini kapsayan aylık veriler ile elektrik talep tahminini, ARIMA, SARIMA ve bu yöntemlere alternatif olarak mevsimsel gizil değişkenli (seasonal latent variable) regresyon modellerini kullanmışlardır. Sonuç olarak; önermiş oldukları model, mevsimsel dalgalanmaları ve yapısal kırılmaları da dikkate alması nedeniyle, diğer modellere göre daha iyi bulgulara ulaştıklarını belirtmişlerdir (Sumer et al., 2009).

Pappas vd (2010), elektrik talebini ve elektrik fiyatının tahminine yönelik yaptıkları çalışmada, çok modelli bölünme teorisini (the multi-model partitioning theory) kullanarak, elektrik talep yükü tahmini için yeni bir yöntem önermişlerdir. Çok modelli bölünme teorisini kullanarak, sorunu yeniden formüle etmeye çalışmışlardır. Bu yöntem, sistem modelinin ve istatistiklerin tam olarak bölünmesi durumunda, Kalman Filtresini

çeşitli formlarda kullanarak ve çeşitli bilgi kriterleri ile elde edilen sonuçları karşılaştırmışlardır. Çalışmanın uygulama kısmında ise Yunanistan'ın güç sistemine uygulamışlar ve elektrik tüketim ve fiyat tahmininde başarı ile kullanılabileceğini önermişlerdir (Pappas et al., 2010).

Kandananond (2011), Tayland'ın elektrik tüketim talebini öngörebilmek amacıyla; ARIMA, YSA ve çoklu doğrusal regresyon analizi (MLP) gerçekleştirmiş, Tayland elektrik talebine ilişkin kullanmış olduğu değişkenler ise: Nüfus, GSYİH, stok endeksi, ihracat (sanayi ürünlerinden elde edilen gelir) ve elektrik tüketim değişkenleridir. Yapılan uygulama sonuçlarında YSA mimarisi, ARIMA ve MLP ye göre, daha iyi sonuçlar vermiş ve YSA'nın elektrik tüketim talebinin tahmininde kullanılabilceğini önermiştir (Kandananond, 2011).

Hotunluoğlu ve Karakaya (2011), Türkiye'nin 2030 yılına kadar elektrik talebini tahmin etmişlerdir. Bu tahmini YSA ile gerçekleştirirken üç farklı senaryo oluşturmuşlardır. Bu senaryolar ise şu şekildedir: İlk senaryoya göre, ekonomik büyümenin istikrarlı olduğunu varsayan statik senaryodur. İkinci senaryo, enerji yoğunluklarının azaldığını varsayan sürdürülebilir senaryodur. Son senaryo ise ekonomik büyümenin beş yıllık değişimini dikkate alarak oluşturulan dönemsel senaryo şeklindedir. Bu çalışmanın sonuçlarını, Enerji ve Tabii Kaynaklar Bakanlığı (EPDK)'nın tahminleri ile karşılaştırmışlar ve EPDK tahminlerinden daha yüksek bir tahmin elde etmişlerdir (Hotunluoğlu & Karakaya, 2011).

Vilar vd. (2012) çalışmalarında, parametrik olmayan bir yöntem kullanarak, elektrik talebinin ve elektrik fiyatının bir gün sonrasını tahmin etmeyi amaçlamışlardır. İspanya'nın 2008-2009 yıllarına ait günlük verilerle yapılan bu çalışmada, yarı fonksiyonel kısmi doğrusal model ile parametrik olmayan regresyon tekniklerini kıyaslamışlardır. Önermiş oldukları yeni tahmin yönteminin, ARIMA modeline kıyasla daha iyi sonuç verdiği bulgusuna ulaşmışlardır (Vilar et al., 2012).

Makukule vd. (2012) yaptıkları çalışmada, Güney Afrika'nın elektrik tüketim verilerini kullanarak, SARIMA (mevsimsel otoregresif entegre edilmiş hareketli ortalama) modeli ile RegSARIMA (Regresyon ile SARIMA) modellerini kullanmışlardır. Bu çalışmada, 2001-2009 yılları arasında, haftanın günleri, tatiller ve diğer mevsimsel etkileri günlük elektrik talebi üzerinden incelemişlerdir. Sonuç olarak, elektrik talebi

üzerinde tatil günlerinin önemli bir etkisi olduğu sonucuna ulaşmışlardır (N. A. Makukule et al., 2012).

Wang vd. (2012), elektrik talebinin eğilimini belirleyebilmek ve değişkenliği modelleyebilmek için bir ayrıştırma yaklaşımı önermişlerdir. Avustralya'nın eyaletlerinden Queensland ve Victoria bölgelerinin 2002 – 2011 dönemlerini kapsayan yarım saatlik veriler ile mevsimsel birtakım ayrıştırmalar yapılarak, 2020 yılına kadar projeksiyon oluşturmuşlardır (Wang et al., 2012).

Abual-Foul (2012), Ürdün'ün elektrik talebini tahmin ettiği çalışmada, 1976 – 2008 dönemine ilişkin yıllık gözlemlerden oluşan GSYİH, nüfus, ihracat ve ithalat olmak üzere dört bağımsız değişkenden oluşan YSA mimarisi ile elektrik tüketim tahmininin başarılı olduğu sonucuna ulaşmış ve tahmin sonuçlarına göre, elektrik tüketiminin sırasıyla 2015, 2020 ve 2025 artacağı bulgusuna ulaşmıştır (Abual-Foul, 2012).

Saravanan vd. (2012), elektrik talep tahmini için, temel bileşenlere dayalı bir YSA ve regresyon analizi gerçekleştirmişlerdir. Çeşitli makroekonomik değişkenleri kullandıkları bu çalışmada, eğitim için kullanılan 29 yıllık veriler ve YSA'ları test etmek için 10 yıllık veriler kullanılmıştır. Ulaştıkları bulgular ise temel bileşenlerin, YSA'ya göre etkili olduğu yönündedir (S. et al., 2012).

Oğcu vd. (2012) elektrik talep tahminini gerçekleştirebilmek amacıyla, YSA ile SVR (support vector regression)'den oluşan en iyi modeli geliştirebilmek için SVR ve YSA modellerini kullanmışlar. Elde ettikleri bulgulara göre ise SVR'nin performansının daha iyi sonuç verdiği bulgularına ulaşmışlardır (Oğcu et al., 2012).

Bermúdez (2013), elektrik talep tahmin sonuçlarının iyileştirilebilmesi için üstel yumuşatma modelini çalışmada değerlendirmiştir. İspanya'ya ait günlük veriler ile yapılan bu çalışmada, mevsimsel kalıplar, ulusal, yerel tatil dönemleri gibi takvim etkileri ortak değişken olarak kullanılan yeni bir tahmin yöntemi önermiştir (Bermúdez, 2013).

Felice vd. (2013), İtalya'nın özellikle yaz mevsiminde hava koşulları sebebiyle elektrik tüketiminin etkilenmesi öncülü ile yapılan bu çalışmada, sıcaklığın etkisini incelemek amacıyla, ARIMAX modeli ile çalışılmıştır. İtalya'nın 2003-2009 dönemini kapsayan ve Haziran ile Temmuz aylarında bir ile beş gün arasındaki veriler dikkate alınarak, günlük elektrik yük tahminini gerçekleştirmişlerdir (De Felice et al., 2013).

An vd. (2013), elektrik talep tahminini gerçekleştirebilmek adına, ileri beslemeli sinir ağı ile ampirik mod ayrıştırma (empirical mode decomposition) yöntemlerinin birleşiminden oluşan taban sinyal filtrelemeyi ve mevsimsel ayarlamayı birleştiren yeni bir yaklaşım önermişlerdir. Avustralya'daki New South Wales'in yarım saatlik elektrik talep tahminlerini gerçekleştirdikleri bu yeni yaklaşım ile çalışmalarındaki diğer yöntemlerden daha iyi sonuçlar verdiği bulgusuna ulaşmışlardır (An et al., 2013).

Es vd. (2014) çalışmalarında, 1970 - 2010 dönemine ait, GSYİH, nüfus, ithalat, ihracat, bina yüz ölçümü ve taşıt sayısı değişkenleri ile Türkiye'nin net enerji talebini tahmin etmişlerdir. Tahmin çalışması için YSA ve çoklu doğrusal regresyon tekniklerini kullanmışlar ve YSA tekniğinin diğer tekniğe göre daha iyi performans sergilediği sonucuna ulaşmışlardır (ES et al., 2014) .

Hassan vd. (2015), sinir ağı tabanlı elektrik talep tahmin yöntemi önermişlerdir. Avustralya Enerji Piyasası (AEMO) ve New York Bağımsız Sistem (NYISO) elde edilen yarım saatlik gözlemler ile yapay sinir ağlarında toplama algoritmalarından oluşan toplam 100 sinir ağı topluluğu oluşturulmuş. Sinir ağları modellerinden elde edilen çıktılar, üç farklı toplama algoritma ile birleştirilmiş ve bu toplama algoritmalarından YSA ya girdi olarak verilen değerler; basit ortalama, kırpılmış ortalama ve Bayes ortalaması şeklinde yeni seriler oluşturularak elektrik talep tahmini gerçekleştirilmiştir (Hassan et al., 2015).

Shao vd. (2015), yarı parametrik model ve dalgalanma özelliği ayrıştırması ile birlikte, orta vadeli bir elektrik talep tahmini üretmeye çalışmışlardır. Çin'in Suzhou, Guangzho bölgelerine ait gözlemler ile yapılan bu çalışmada, önermiş oldukları yaklaşım, yaygın kullanılan ayrıştırma tahminlerine nazaran daha iyi performans sergilemiş. Ayrıca ortaya çıkarmış oldukları bileşenlerin, ham tüketim verilerinden gizli ancak potansiyel olarak önemli değişkenlerin (iklim, ekonomik kalkınma) yakalanmasına olanak sunduğunu belirtmişlerdir (Shao et al., 2015).

Guta vd. (2015) çalışmalarında, Etiyopya'nın 1970 – 2011 dönemine ilişkin verilerini analiz ederek, konut elektrik tüketimi ile GSYİH arasındaki ilişkiyi incelemişlerdir. GSYİH ile konut elektrik tüketimi arasında çift yönlü nedensellik ilişkisi bulgusuna ulaşmışlardır. Elektrik tüketimindeki düşüşlerin ekonomik büyümeyi etkileyeceğini, başka bir deyişle; elektrik tüketimini azaltmaya yönelik bir politika

önermenin ekonomik büyümeyi olumsuz etkileyeceği sonucuna ulaşmışlardır (Guta et al., 2015).

Hasanov vd. (2016), Azerbaycan'a ait elektrik tüketim talebinin tahmini için 1995 – 2013 dönemine ilişkin çalışmalarında, kişi başına toplam nihai elektrik tüketimi, reel elektrik fiyatları, kişi başına düşen petrol dışı GSYİH değişkenleri ile ısıtma derecesi - günleri (heating degree-days) ve soğutma derecesi günleri (cooling degree-days) değişkenleri kullanılarak, farklı eşbütünleşme ve hata düzeltme tekniklerini uygulamışlardır. Sonuç olarak, tahmin modelleri ile 2025 yılına kadar Azerbaycan'ın kişi başına elektrik talebini modellemeyi gerçekleştirmişlerdir (Hasanov et al., 2016).

Günay (2016) çalışmasında, Türkiye'nin yıllık brüt elektrik talebini, çoklu doğrusal regresyon ve YSA ile tahmin etmiştir. 1975 – 2013 dönemlerine ait; nüfus, kişi başına GSYİH, enflasyon, işsizlik, ortalama yaz sıcaklığı ve ortalama kış sıcaklığı değişkenlerinin bulunduğu bir fonksiyon ile çalışılmıştır. Elde ettiği bulgular ile Enerji ve Tabii Kaynaklar Bakanlığı tarafından açıklanan tahmin rakamlarından daha iyi sonuçlar vermiştir (Günay, 2016).

Usha vd. (2017), çalışmalarında, Hindistan'ın Tamilnadu eyaletine ait 1964 – 2013 dönemine ilişkin veri kümesi ile bu bölgenin 15 yıllık elektrik talep tahminini gerçekleştirmişlerdir. Bu çalışmada, aynı zamanda sinir ağları algoritmalarına dayanan elektrik tüketim modellemesi ile çeşitli eğitim algoritmaları ile çalışmışlardır. Yapılan analizler sonucunda, Bayesian düzenleme (regularization) eğitim algoritmasının, diğer algoritmalara göre daha iyi performans gösterdiği sonucuna ulaşmışlardır (Usha & Appavu Alias Balamurugan, 2017).

Hamedmoghadam vd. (2018) çalışmalarında, Avustralya'nın uzun dönem elektrik talep tahminini hesaplayabilmek için derin sinir ağları ile çalışmışlardır. Elde ettikleri bulgulara göre; derin sinir ağlarının klasik yapay sinir ağlarına göre daha iyi performans sergilediği sonucuna ulaşmışlardır (Hamedmoghadam et al., 2018).

Guo vd. (2018), elektrik talebini tahmin edebilmek için Çin'in 2000-2014 dönemini kapsayan aylık veriler ile orta vadeli elektrik talebinin doğruluğunu ve uygulanabilirliğini geliştirebilmek için vektör hata düzeltme modeli (VECM) ve kendi kendine uyarlamalı taramaya (self-adaptive screening) (SAS) dayalı bir yöntem önermişlerdir. Çalışmada 15 adet makroekonomik değişkeni farklı boyutlara indirgeyerek

analizleri gerçekleştirmişlerdir. Elde ettikleri sonuçlar; önermiş oldukları yöntemin, geleneksel tahmin yöntemlerinden daha iyi sonuca ulaştığını vurgulamışlardır (Guo et al., 2018).

Kirikkaleli vd. (2018) çalışmalarında, elektrik tüketimi, ekonomik büyüme ve internet talebi arasındaki ilişkiyi panel eşbütünleşme, tam modifiye OLS, dinamik OLS ve Dumitrescu – Hurlin nedensellik sınaması uygulamışlardır. Elde edilen sonuçlara göre, uzun vadede elektrik, internet talebi ve ekonomik büyüme arasında pozitif bir bağlantı ve nedensellik sonuçlarına göre ise, elektrik tüketimi ile internet talebi arasında geri besleme nedenselliğini ve ekonomik büyümeden elektrik tüketimine tek yönlü bir nedensellik ilişkisi bulgusuna ulaşmışlardır (Kirikkaleli et al., 2018).

Hu vd. (2019) çalışmalarında, elektrik talebini tahmin edebilmek için dinamik uyarlanabilir entropi tabanlı ağırlıklandırma kullanarak, ayrıştırma tabanlı bir kombinasyon ile tahmin yöntemi geliştirmişlerdir. Geliştirdikleri bu modeli ARIMA ve YSA sonuçları ile kıyaslamışlar ve önerdikleri yöntemin elektrik talep tahmini için daha iyi sonuçlar verdiği bulgusuna ulaşmışlardır (Hu et al., 2019).

Yang ve Pang (2021) çalışmalarında, Çin'in elektrik talebini tahmin etmek ve hangi değişkenlerin elektrik tüketimindeki talep üzerinde etkilerinin olduğunu Johansen eşbütünleşme analizi, Granger nedensellik testi ve VAR modellerini kullanmışlardır. Çalışma, 1980-2017 dönemini kapsamaktadır ve tahmin dönemi için ise 2018-2020 dönemleri seçilmiştir. Modellerde kullanılan değişkenler ise Çin'in elektrik tüketim miktarı, GSYİH, sanayileşme oranı ve kentleşme oranına ait değişkenlerden oluşmaktadır. Çalışmada, kentleşme oranından elektrik tüketimine %95 güven düzeyinde, tek yönlü Granger nedeni tespit etmişlerdir (Yang & Pang, 2021).

Wahid vd. (2021), Pakistan'ın elektrik tüketiminin belirleyicilerini incelemişlerdir. Bu çalışmada, Johansen eşbütünleşme testi, hata düzeltme vektörü ile incelenmiş olup, GSYİH'nın ve nüfusun elektrik tüketimi üzerinde olumlu etkilerinin olduğunun bulgusuna ulaşmışlardır (Wahid vd., 2021).

Comert ve Yıldız (2022) çalışmalarında, Türkiye'nin elektrik talep tahminini gerçekleştirebilmek için nüfus yoğun şehirlerin ortalama sıcaklık değerleri ve tahmin çalışma dönemi içerisindeki aylık işsizlik oranlarını kullanarak YSA ile modellemişlerdir. Çalışmada eğitim veri kümesi olarak işsizlik değerlerini kullanarak brüt elektrik

tüketimini tahmin etmişlerdir. Çalışma sonucunda, elde ettikleri tahmin sonuçlarının performansının değerli olduğunu belirtirken, bu çalışmayı politika yapıcıların dikkate almaları gerektiğine değinmişlerdir (Comert & Yildiz, 2022).


3.2. KOŞULLU DEĞİŞEN VARYANS UYGULAMASI

Bu bölüme ilişkin uygulama modeli, TEİAŞ'tan elde edilen elektrik talebi (talep edilen miktar) verileri kullanılarak, koşullu değişen varyans modelleri ile gerçekleştirilmiştir. Türkiye'nin elektrik talebine ilişkin veriler 2007.01-2020.12 dönemini kapsayan aylık gözlemlerden oluşmaktadır. Elektrik talebine ilişkin zaman yolu grafiği Şekil-7'deki gibidir. Bu dönem aralığı ile çalışılmasının bazı nedenleri; ekonomik kriz, siyasi belirsizlik ve salgın dönemlerinin tamamını kapsıyor olmasıdır.

Oynaklık modelleri ile çalışılmasındaki amaç ise aşağıdaki gibidir:


- i. Koşullu değişen varyans modelleri genellikle, finansal zaman serisi niteliğindeki borsa, hisse senedi, kripto para, döviz, altın (Gün, 2020; Işildak, 2021; Nargeleçekenler, 2004; Uğurlu & Cihangir, 2017) vb. gibi finansal enstürmanın belirli bir zamandaki riskini ölçmek ve oynaklığın belirlenmesi konusunda daha yoğun kullanılıyor olmasıdır. Bazı çalışmalarda ise makroekonomik zaman serisi verileri ile de uygulama alanı bulmuştur (Bollerslev, 1986; Engle, 1982; Işığışok, 1999).
- ii. Türkiye'de bölgeler arası gelişmişlik düzeyleri, gelen turist sayısı, sanayi üretimi, vb. gibi değişkenlerin varlığı, elektrik tüketiminin ve talebinin miktarında değişmelere neden olmaktadır. Bu ve benzeri parametreler, elektrik talebine ilişkin hata teriminin zaman içerisinde sabit kalmamasına, başka bir deyişle, değişen bir yapıda olmasına neden olmaktadır. Dolayısıyla, yukarıda belirtilen etkilerin varlığı, elektrik talebi açısından önem taşımaktadır. Bu kapsamda, elektrik talebi için koşullu değişen varyans modeli (ARCH) ile tahmin edilmiştir.

Şekil-7: Elektrik Talebinin Zaman Yolu



Şekil-7’de elektrik talebine ilişkin zaman yolu grafiği incelendiğinde, istikrarlı ve artan eğilim sergilemektedir. Ancak istikrarlı artışlar bazı dönemlerde, sosyal ve ekonomik bazı nedenlerle düşüşler veya kırılmalar yaşamıştır. Şekil-7 incelendiğinde, 2008 yılının Şubat ayında ve 2010 yılının Ağustos ayını kapsayan dönemde sapma söz konusudur. Bu dönem, küresel piyasaları ve özellikle de dış ticaretteki partnerlerinin yaşamış olduğu ekonomik problemler nedeniyle, Türkiye ekonomisini de bu problemlerden etkilenmesi kaçınılmaz olmuştur. Benzer şekilde, 2019 yılı sonlarında benzer sapma yaşanmıştır. Şekil-8’de de görüleceği üzere, kriz döneminin sanayi sektörünün elektrik tüketimini etkilediği görülmektedir.

Şekil-8: Sanayi Sektörü Elektrik Tüketim Oranı (%)



Kaynak: TÜİK, TEDAŞ

Grafikten de görüleceği üzere, 2008 yılında yaşanan küresel ekonomik kriz, Türkiye ekonomisinin lokomotifini sayılan sanayi sektörünün elektrik tüketimini de etkilemiştir. 2007 yılında %47.6 oranında elektrik tüketimi bulunurken, 2008 yılında %1.4 oranında düşüşle %46.2 olarak gerçekleşmiştir. 2008 yılında yaşanan ekonomik

krizin etkileri, sadece 2008 yılı ile sınırlı kalmamış ve 2009 yılında daha şiddetli hissedilmiştir. 2009 yılında sanayi sektöründe gerçekleşen elektrik tüketim oranı %44.9 oranına gerilerken, 2007 yılı verilerine göre ekonomik kriz sürecinde yaklaşık %2.7 oranında azalma gerçekleşmiştir. Ayrıca, 2007 yılındaki sanayi sektöründeki elektrik tüketim oranı seviyesine, ancak 2015 yılında ulaşılabilmektedir.

Benzer şekilde 2012 yılı Şubat ayında, elektrik tüketiminde düşüş yaşanmıştır. Bu düşüşün nedeni ise Euro Bölgesi'nde yaşanan krizin, Türkiye elektrik tüketiminde kendini göstermesidir. Ancak bu krizin Türkiye ekonomisine etkileri, 2008 yılında yaşanan krizin etkisi gibi sert olmamış ve özellikle elektrik tüketiminde yaşanan bu kayıp, 2012 yılından 2013 yılına geçen süreçte ticarethanelerde ve sanayide yaklaşık %0.1 dolaylarında düşüş ile gerçekleşmiştir.

2016 yılında ise elektrik tüketiminde özellikle Haziran ayında başlayan düşüş, Ağustos ayında artmaya başlamışsa da, Eylül ayında tekrar düşüş yaşamıştır. 2016 yılı Türkiye ekonomisi açısından hem belirsizliklerin hem de ekonomik büyümenin yavaşladığı bir yıl olmuştur. TÜİK verilerine göre, 2016 yılı son çeyreğinde bir önceki yılın aynı dönemine göre %1.8 ve 2016 yılı üçüncü çeyreğine göre %2.7'lik bir daralma yaşanmıştır. Ekonomi, 2009 yılındaki aynı çeyrek dönemdeki ekonomik daralmayı (%2.8) yaşamıştır.

2019 yılının Aralık ayında Çin'in Vuhan şehrinde ortaya çıkan COVID-19 adlı bulaşıcı virüs, kısa sürede dünyayı etkisi altına almış ve Dünya Sağlık Örgütü (DSÖ-WHO), bu salgını 11.03.2020 günü pandemi olarak ilan etmiştir¹⁹. COVID-19 pandemisi ile başlayan süreç, öncelikle Çin ve çevresindeki ülkeleri, daha sonra da hemen hemen her ülkeyi etkisi altına almıştır. Türkiye'de salgının ilk tespiti ise dünyada pandeminin ilan edildiği gün olan 11.03.2020'de Sağlık Bakanlığı tarafından paylaşılmıştır.

Dünya Ekonomi Formu'nun 2020 yılında yayınlamış olduğu bir rapora göre, pandeminin başladığı Mart-Nisan ayı ortalarından Temmuz ayına kadarki süreçte, San Francisco'da %23'den fazla elektrik tüketiminde düşüş yaşanmıştır²⁰. Benzer durum, Türkiye'nin elektrik tüketiminde de yaşanmış ve bu durum ekonomik göstergelerin

¹⁹ [https://covid19.saglik.gov.tr/TR-66494/pandemi.html#:~:text=A%C3%A7%C4%B1klama%3A%20COVID%2D19%2C%20%C3%BClkemizde,DS%C3%96\)%20taraf%C4%B1ndan%20pandemi%20ilan%20edilmi%C5%9Ftir.](https://covid19.saglik.gov.tr/TR-66494/pandemi.html#:~:text=A%C3%A7%C4%B1klama%3A%20COVID%2D19%2C%20%C3%BClkemizde,DS%C3%96)%20taraf%C4%B1ndan%20pandemi%20ilan%20edilmi%C5%9Ftir.) (Erişim Tarihi: 22.07.2021).

²⁰ <https://www.weforum.org/agenda/2020/09/cities-north-africa-middle-east-covid-pandemic-coronavirus-economics/> (Erişim Tarihi: 22.07.2021).

negatife dönmesine ve özellikle de dış ticaret hacminin düşmesine neden olmuştur. Pandemi süreci, ekonomik daralmayı ve hatta küçülmeyi beraberinde getirirken, ülkede temel ihtiyaçlar dışındaki sektörlerin tamamında kısıtlamaların yaşanmasına neden olmuştur. Öyle ki; virüsün etkileri, finansal piyasaları da etkilemiş ve korku endeksi olarak bilinen VIX (volatility index), 16.03.2020 tarihinde 82.69²¹ seviyelerine kadar çıkmıştır. Bu değer, Kasım 2008 de ölçülen 80.86 değerinden dahi yüksektir.

Salgının etkisi, 2020 yılının ikinci çeyreğinde Türkiye ekonomisinin %-10.3 oranında küçülmesine neden olmuştur (Türkiye Cumhuriyeti Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı, TUİK). İkinci çeyrekte, özellikle sanayi ve hizmetler sektörü (inşaat sektörü dahil) sırasıyla %16.5 ve %10.6 düzeylerinde küçülme yaşanmasına neden olmuştur.

3.2.1. Elektrik Talebine İlişkin Koşullu Değişen Varyans Modellerinin Tahmini

Öncelikle, elektrik talebine ilişkin veriler (talep) Eviews'te Proc menüsünün altındaki Seasonal Adjustment komutunun altında yer alan Moving Average Methods komutu ile mevsimsellikten arındırılmıştır. Daha sonra, elektrik talebi değişkenine ilişkin mevsimsellikten arındırılan verilerin (talepsa) sırasıyla logaritmaları ve farkı alınarak Intf değişkenine ulaşılmıştır. Böylece, logaritmik fark alınmasıyla elektrik talebindeki şiddet (dalgalanma şiddeti/uzunluğu) ortaya konmaya çalışılmıştır.

Koşullu değişen varyans uygulamasına geçmeden önce, değişkene ilişkin uygun otoregresif hareketli ortalama modeli (ARMA) belirlenmeye çalışılmıştır.

Uygun ARMA modeli belirlenirken çeşitli denemeler gerçekleştirilmiştir. Yapılan çok sayıdaki tahmin sonucunda elde edilen modellerden istatistiksel olarak anlamlı olan modeller belirlenmiş ve en küçük bilgi kriterine sahip ARMA modeli ile koşullu değişen varyans modelinin ortalama denklemi oluşturulmuştur. ARMA(1,0), ARMA(1,1), ARMA(2,1), ARMA(0,1), ARMA(3,0) ve ARMA(0,3) modelleri anlamlı bulunmuştur. İlgili modellere ait bilgi kriterleri değerleri Tablo-2'de gösterilmiştir.

²¹ VIX korku endeksinde, endeks değeri 60'ın üzerinde olduğunda, piyasalarda büyük bir kargaşa yaşandığı anlamına gelmektedir (Yapı kredi yatırım, <https://www.yatirimkredi.com/vix-endeksi-volalite-endeksi-nedir.html>).

Tablo-2: Uygun ARMA Modelinin Belirlenmesi

	ARMA(1,0)	ARMA(1,1)	ARMA(2,1)	ARMA(0,1)	ARMA(3,0)	ARMA(0,3)
AIC	-3.988096	-4.031189	-4.048971	-4.020734	-3.991673	-4.040675
SC	-3.950602	-3.974949	-3.973676	-3.983393	-3.916067	-3.965992
HQ	-3.972877	-4.008361	-4.018406	-4.005578	-3.960980	-4.010363

AIC (Akaike Information Criterion), SIC (Schwarz Information Criterion) ve HQ (Hannan-Quinn Criter) bilgi kriterlerine göre, en küçük değer ARMA (2,1) modeli olarak belirlenmiştir. Bu doğrultuda koşullu değişen varyans modeli bu ortalama denklemi ile kurulmuştur.

Uygun ARMA modeli belirlendikten sonra, elde edilen modelin değişen varyansın varlığının test edilmesi gerekmektedir. ARCH-LM testi aşağıdaki regresyonun parametrelerinin tahmini ile elde edilmiştir:

$$\text{Intalep}_t = c + \theta_1 \text{Intalep}_{t-1} + \dots + \theta_p \text{Intalep}_{t-p} + u_t \quad (3.1)$$

$$\hat{u}_t^2 = c + \alpha_1 \hat{u}_{t-1}^2 + \dots + \alpha_q \hat{u}_{t-q}^2 + v_t \quad (3.2)$$

Talep değişkeninin geçmiş dönem değerleri ile oluşturulan Denklem (3.1) modelinin hatalarının kareleri ile elde edilen, Denklem (3.2) regresyonunun tahmini ile gerçekleştirilmektedir. Bu tahminde $LM = (T - q)R^2$ şeklinde hesaplanan test istatistiği χ^2 dağılımına sahip olup, sonuçlar Tablo-3'te yer almaktadır.

Tablo-3: ARCH-LM Test Sonucu

F-istatistiği	11.81627	Prob. F(1,162)	0.0007
Gözlem*R ²	11.14894	Ki-Kare prob.(1)	0.0008

Bu durumda, ilgili teste ilişkin kurulan hipotezler aşağıdaki gibidir:

$$H_0: \alpha_1 = \alpha_2 = \dots = \alpha_q = 0 \quad (\text{ARCH Etkisi Yoktur})$$

$$H_1: \alpha_i \neq 0 \text{ (en az bir tanesi)} \quad (\text{ARCH Etkisi Vardır})$$

Elde edilen ARCH-LM sonuçlarına ilişkin Tablo-3 değerleri incelendiğinde, Gözlem*R² olarak hesaplanan değere ve bunun p değerine göre, H₀ hipotezi reddedilir ve H₁ hipotezi kabul edilir. Diğer bir deyişle, elektrik talebi değişkeninin varyansının zaman

içerisinde sabit kalmadığı ARCH etkisinin var olduğu sonucuna ulaşılmıştır. Ayrıca, elektrik talebi değişkenine ilişkin seçilen ARMA(2,1) modelinin hatalarının serisel korelasyon içerip içermediği, Breush-Godfrey serisel korelasyon LM testi ile ortaya konmuştur. Buradaki Ki-kare test istatistiği Gözlem*R² değeri 0,297202 ve bunun p değeri 0,8619 bulunmuştur. Böylece, seçilen ARMA(2,1) modelinin serisel korelasyon içermediği ancak ARCH etkisinin olduğu sonucuna varılmıştır. Buradan hareketle, çeşitli ARCH ve GARCH modelleri denenmiş ve uygun olanlardan bazıları Tablo-4'e aktarılmıştır.

Tablo 4: Koşullu Değişen Varyans Analiz Sonuçları²²

ARMA(2,1)	ARCH	GARCH	ARCH	GARCH	GARCH
	p=1	p=1 q=1	p=2	p=2 q=1	p=1 q=2
Parametre	Ortalama Denklemi				
μ	0.002679 (0.00070)	0.0033 (0.00000)	0.003291 (0.00000)	0.003336 (0.00000)	0.003247 (0.00000)
ϕ_1	0.198257 (0.17960)	0.442513 (0.00000)	0.453545 (0.00000)	0.469450 (0.00000)	0.463965 (0.00000)
ϕ_2	0.171402 (0.19370)	0.322041 (0.00010)	0.319859 (0.00010)	0.368728 (0.00000)	0.330405 (0.00000)
θ_1	-0.774516 (0.00000)	-0.985103 (0.00000)	-0.984992 (0.00000)	-0.986811 (0.00000)	-0.985403 (0.00000)
	Varyans Denklemi				
	ARCH	GARCH	ARCH	GARCH	GARCH
	p=1	p=1 q=1	p=2	p=2 q=1	p=1 q=2
α_0	0.000541 (0.00000)	0.000376 (0.01350)	0.000468 (0.00000)	0.000556 (0.00030)	0.00041 (0.00770)
α_1	0.551863 (0.00000)	0.432951 (0.00020)	0.411838 (0.00020)	0.465523 (0.00000)	0.492181 (0.00010)
α_2			0.164465 <i>(0.19020)</i>	0.458895 (0.00000)	
β_1		0.223328 <i>(0.22140)</i>		-0.372924 <i>(0.04200)</i>	0.320666 <i>(0.23870)</i>
β_2					-0.164544 <i>(0.39590)</i>
AIC	-4.113447	-4.135384	-4.140647	-4.159155	-4.128941
SIC	-4.000504	-4.003616	-4.00888	-4.008563	-3.97835

²² Bu sonuçların yanında varyans denkleminde tüketici fiyat endeksi, sanayi üretim endeksi, ülkeye gelen turist sayısı ve işsizlik değişkenleri eklenerek yeniden modellenmiş ancak ARCH etkisi ortadan kalkmadığı için tez içerisinde yer verilmemiştir.

HQ	-4.0676	-4.081895	-4.087158	-4.098024	-4.067811
DW	1.768744	1.877175	1.89696	1.904126	1.911512
Gözlem*R ²	1.152516	0.010751	0.119034	0.174959	0.059719
Ki-Kare prob.(1)	0.283000	0.917400	0.730100	0.675700	0.806900

Not: Parantez içerisindeki değerler Prob değerleridir.

** Değerleri ise %10 anlamlılık düzeylerindeki sonuçları göstermektedir.

Farklı yapıda ARCH ve GARCH model denemeleri sonucunda, hem istatistiksel olarak anlamlı hem de katsayı kısıtlamalarını yerine getirebilen modellerin ARCH(1), ARCH(2) ve GARCH(1,1) modelleri olduğu görülmüştür. Ancak ARCH(2) modeli ile GARCH(1,1) modellerinin ilgili katsayıları istatistiksel olarak anlamsız bulunmuştur. Bu nedenle, Intf değişkeninin koşullu değişen varyans modeli ARCH(1) hem parametre kısıtlarına göre geçerli olması, hem de ilgili katsayılar istatistiksel olarak anlamlı olması nedeniyle, en uygun model olarak belirlenmiştir. Ayrıca, uygun olarak seçilen ARCH(1) modelinin ARCH etkisi içerip içermediği tekrar sınanmış ve ki-kare değerine ilişkin p değeri 0,283 olduğundan, seçilen bu modele ilişkin değişen varyans sorunun ortadan kalktığı sonucuna varılmıştır.

3.3. ELEKTRİK TALEBİNİ ETKİLEYEN FAKTÖRLERİN VEKTÖR OTOREGRESİF MODEL İLE BELİRLENMESİ

Vektör otoregresif (VAR) modeli uygulamasında, TCMB, TÜİK ve TEİAŞ'tan elde edilen veriler ışığında, 2007.01-2020.12 dönemine ilişkin elektrik talebini etkilediği düşünülen değişkenler olarak sırasıyla; sanayi üretim endeksi, tüketici fiyat endeksi, gelen turist sayısı, işsizlik değişkenleri kullanılmıştır. VAR modelinde kullanılan elektrik talebi ile diğer 4 değişken arasındaki kısa dönem ilişkinin tahmini gerçekleştirilmiştir.

Değişkenler arasındaki ilişkiler, bazı durumlarda ekonomi teorisi ile ortaya konulmamaktadır. Bir denklem sisteminde içsel ve dışsal değişkenlerin kesin olarak tanımlanamaması, eşanlı denklem sistemlerine ihtiyacı doğurmuştur. Ancak bu sistemde belirlenme (teşhis) sorunlarına rastlanılmaktadır. Bu nedenle; VAR modelleri, ekonomi teorisinin kesin açıklayamadığı durumlarda da kullanılmaktadır (Mert ve Çağlar, 2019, s. 342).

Elektrik talebinin doğru bir şekilde tahmin edilmesi, ekonomik sistemin temelinin ayrılmaz bir bütünüdür. Ekonomik sistemdeki olası değişimler, elektrik tüketiminin de değişmesine neden olmaktadır. Dolayısıyla, ekonomik sistem aracılığı ile bireyler, şirketler, vb. aktörler, bu olası ekonomik sistemdeki değişimlerin uygulanmasından sonra kendi faaliyetlerini, hedef ve çıkarlarına göre yeniden programlayacağından, elektrik talep miktarı da bu durumdan etkilenecektir. Ayrıca, elektrik talep tahmini ile ilgili çalışmalarda, özellikle planlamacıların sabit içsel değişkenler yerine, değişim eğiliminde olan değişkenlerin güncellenmesi anlayışının genişletilmesi, doğru tahminler için gereklidir. Bu gibi durumlar elektrik talep tahmininde, içsel değişkenlerin güncellenerek farklı değişkenlerin etkilerinin varlığının belirlenmesi amacıyla, Vektör Otoregresif Model (VAR) kullanılması gerekmektedir.

VAR modelinde, katsayıların yorumlanması oldukça güçtür. Çünkü modele dahil edilen değişkenler ve bu değişkenlerin gecikmeli değerlerinin modelde yer alması nedeniyle, elde edilen katsayı adedi fazlaşmaktadır. Bu nedenlerle, VAR analizinde katsayılar yorumlanmayıp, bunun yerine seriler arasındaki kısa dönem nedensellik ilişkisi, varyans ayrıştırması ve etki tepki fonksiyonunun grafikleri analiz edilip yorumlanmaktadır. Ancak bu analizlere geçmeden önce, uygun VAR modelinin belirlenmesi için bilgi kriterlerine göre gecikme uzunluğunun belirlenmesi gerekmektedir. Kuşkusuz, daha önce birim kök testlerinin yapılması gerekmektedir.

3.3.1. VAR Modelinde Kullanılan Değişkenlere İlişkin Birim Kök Testleri

Değişkenler birim kök testi ile incelenmeden önce, elektrik talebine ilişkin verilerde uygulandığı gibi diğer 4 değişken de mevsimsellikten arındırılmıştır. Böylece; mevsimsellikte arındırılan elektrik talebi (TALEP), Tüketici fiyat endeksi (TUFE), Turist sayısı (TUR), işsizlik (ISSIZ) ve sanayi üretim endeksi (SUE) değişkenlerine ilişkin verilere ADF ve KPSS birim kök testleri uygulanmıştır. Elde edilen sonuçlar Tablo-5'e aktarılmıştır.

Tablo-5'deki ADF birim kök testi sonuçlarına göre, test modeli sabit olarak belirlenen sonuçlara göre, tüm değişkenlerde hesaplanan test istatistiği, tüm kritik değerlerden büyük çıkmış ve yokluk hipotezi reddedilememiştir. Dolayısıyla sabit terimli

modelde (kesme terimli), tüm değişkenler durağan dışı bir yapı sergilemekte ve %1, %5 ve %10 hata düzeylerinde serilerde birim kök varlığı mevcuttur. Test modeli sabit terimli ve trend içeren sonuca göre ise elektrik talebi (TALEP) değişkeni %5 ve %10 yanılma düzeylerinde yokluk hipotezi reddedilmiştir. Benzer durum sanayi üretim endeksi (SUE) değişkenine ait test sonucunda %10 yanılma düzeyinde yokluk hipotezi reddedilmiştir. Dolayısıyla bu iki değişkende birim kök olmayıp bu iki değişkenin düzeyde durağan oldukları belirlenmiştir. Diğer taraftan, TUFİ, TUR ve İSSİZ değişkenlerinde yokluk hipotezi reddedilememiş, serilerde birim kök olduğu ve bu serilerin düzeyde durağan olmadıkları ortaya konmuştur.

Tablo-5: Düzey Birim Kök Testi Bulguları

Değişken	I(0) Test modeli	ADF				KPSS			
		t-Statistic	%1 Düzey	%5 Düzey	%10 Düzey	LM-Stat	%1 Düzey	%5 Düzey	%10 Düzey
TALEP	Sabit	-0.744019	-3.470427	-2.879045	-2.576182	3.382287	0.739	0.463	0.347
	Sabit ve Trendli	-3.477804	-4.014635	-3.437289	-3.142837	0.172808	0.216	0.146	0.119
TUFİ	Sabit	-1.178204	-3.472813	-2.880088	-2.576739	1.263996	0.739	0.463	0.347
	Sabit ve Trendli	-2.269757	-4.018748	-3.439267	-3.143999	0.301143	0.216	0.146	0.119
TUR	Sabit	-1.063762	-3.471987	-2.879727	-2.576546	0.295105	0.739	0.463	0.347
	Sabit ve Trendli	-0.556995	-4.017185	-3.438515	-3.143558	0.209013	0.216	0.146	0.119
İSSİZ	Sabit	-2.333276	-3.472259	-2.879846	-2.57661	0.998275	0.739	0.463	0.347
	Sabit ve Trendli	-2.554047	-4.017568	-3.4387	-3.143666	0.406312	0.216	0.146	0.119
SUE	Sabit	-0.261343	-3.473096	-2.880211	-2.576805	3.296758	0.739	0.463	0.347
	Sabit ve Trendli	-3.313525	-4.018349	-3.439075	-3.143887	0.163955	0.216	0.146	0.119

Not: ADF birim kök testi için gecikme uzunluğu AIC kullanılmıştır.

KPSS birim kök testi için Bartlett kernel fonksiyonu ile band genişliği ise 4 hesaplanmıştır.

Diğer taraftan, KPSS birim kök test sonucuna göre ise, sabit terimli modeli ile test edilen değişkenlerden ülkeye gelen turist sayısı (TUR) tüm hata düzeylerinde hesaplanan test istatistiği, kritik değerlerden küçük hesaplanmıştır. Dolayısıyla, KPSS birim kök testinde yokluk hipotezi, seri durağandır diğer bir deyişle seri birim kök içermemektedir şeklinde oluşturulduğundan bu test sonucuna göre, TUR değişkeni için yokluk hipotezi reddedilememiştir. Diğer bir deyişle, KPSS sabit terimli modelin birim kök testi sonucuna göre TUR değişkeni durağandır. Diğer değişkenlerde ise yokluk hipotezi

reddedilmektedir. Yani, değişkenlerde birim kök varlığı bulunmaktadır. KPSS birim kök testinin test modeli sabit terimli ve trend içeren model sonuçlarına göre ise %1 hata düzeyinde TALEP ve SUE değişkenleri için yokluk hipotezi reddedilememiş ve serileri durağan bir yapı sergilediği sonucuna ulaşılmıştır. Ancak, %5 ve %10 hata düzeylerinde TALEP ve SUE değişkenleri ile diğer değişkenler %1, %5 ve %10 hata düzeylerinde hesaplanan test istatistikleri, kritik değerlerden büyük olduğundan yokluk hipotezi reddedilmiştir. Dolayısıyla, KPSS'ye göre, ISSIZ ve TUFEE değişkeninin durağan dışı bir yapı sergilediği belirlenmiştir.

Son olarak, ADF ve KPSS bulgularına göre, tüm serilerin (değişkenlerin) durağan olmadıkları düşünülmüş ve hepsinin birinci dereceden farkları alınmıştır. Elde edilen bulgular, Tablo-6'ya aktarılmıştır.

Tablo-6: Birinci Farkı Alınan Değişkenlerin Birim Kök Bulguları

I(1)	ADF					KPSS			
Değişken	Test modeli	t-Statistic	%1 Düzey	%5 Düzey	%10 Düzey	LM-Stat	%1 Düzey	%5 Düzey	%10 Düzey
TALEP	Sabit	-9.613479	-3.470427	-2.879045	-2.576182	0.037628	0.739	0.463	0.347
	Sabit ve Trendli	-9.584591	-4.014986	-3.437458	-3.142936	0.025191	0.216	0.146	0.119
TUFEE	Sabit	-5.914162	-3.473382	-2.880336	-2.576871	0.050394	0.739	0.463	0.347
	Sabit ve Trendli	-5.920194	-4.019151	-3.439461	-3.144113	0.025614	0.216	0.146	0.119
TUR	Sabit	-6.395870	-3.471987	-2.879727	-2.576546	0.024742	0.739	0.463	0.347
	Sabit ve Trendli	-6.616457	-4.017185	-3.438515	-3.143558	0.015537	0.216	0.146	0.119
ISSIZ	Sabit	-4.269486	-3.471454	-2.879494	-2.576422	0.062123	0.739	0.463	0.347
	Sabit ve Trendli	-4.232143	-4.016433	-3.438154	-3.143345	0.062972	0.216	0.146	0.119
SUE	Sabit	-3.635956	-3.473096	-2.880211	-2.576805	0.043203	0.739	0.463	0.347
	Sabit ve Trendli	-3.628651	-4.018748	-3.439267	-3.143999	0.024485	0.216	0.146	0.119

Not: ADF birim kök testi için gecikme uzunluğu AIC kullanılmıştır.

KPSS birim kök testi için Bartlett kernel fonksiyonu ile band genişliği ise 4 hesaplanmıştır.

Çalışmada dikkate alınan 5 değişkenin birinci farkları alınarak elde edilen serilere uygulanan ADF ve KPSS sonuçlarını içeren Tablo-6'daki bulgulara göre, SUE değişkeni dışındaki tüm değişkenlerin %1, %5 ve %10 hata düzeylerinde sabit terimli model ile sabit terimli ve trendli modelde birim kök etkisi ortadan kalkmış ve dolayısıyla söz

konusu 4 deęişkenin birinci dereceden duraęan yapıda olduęu belirlenmiştir. Ancak, SUE deęişkeninin de %5 hata düzeyinde birinci dereceden duraęan yapı sergiledięi belirlenmiştir.

3.3.2. VAR Modelinin Uygun Gecikme Genişliğinin Belirlenmesi

VAR modeli oluşturulmadan önce, yukarıda da deęinildięi gibi, modelin hangi gecikme genişliğinde (gecikme sayısı, p) olduęunun belirlenmesi gerekmektedir. VAR modelinin tahmini yapılırken, uygun p gecikme sayısının doęru belirlenmesi gerekmektedir. Kuşkusuz gecikme sayısı olması gerekenden küçük alınırsa, parametre tahminleri tutarlı olmamakta; olması gerekenden büyük alınırsa, parametrelerin tahminin varyansı büyük çıkmaktadır (Mert ve Çaęlar, 2019, s. 222). VAR modeli belirlenirken ařaęıdaki bilgi kriterlerinden yararlanılmaktadır. Bu bilgi kriterleri²³ ise (Brooks, 2008, p. 233) řu řekildedir:

$$AIC = \ln(\hat{\sigma}^2) + \frac{2k}{T}$$

$$SC = \ln(\hat{\sigma}^2) + \frac{k}{T} \ln T$$

$$HQ = \ln(\hat{\sigma}^2) + \frac{2k}{T} \ln(\ln(T))$$

Eřitliklerdeki, $\hat{\sigma}^2$ hataların varyansını, T gözlem sayısını ve k ise $k = p + q + 1$ olmak üzere, tahmin edilen toplam parametre sayısını göstermektedir. Kuşkusuz, k 'nın içinde yer alan p deęeri otoregresif terim sayını, q deęeri ise hareketli ortalama terim sayısını ve 1 de kesme terimi göstermektedir. Ayrıca, \bar{p} deęeri otoregresif terim sayısının üst sınırını ve \bar{q} deęeri de hareketli ortalama terim sayısı üst sınırını göstermek üzere; bilgi kriterleri, $p \leq \bar{p}, q \leq \bar{q}$ 'e tabi olarak fiilen en aza indirilir.

Mevsimsellikten arındırılmış ($_sa$) 5 deęişkenin ikisinin deęerinin büyük olması nedeniyle logaritmaları alınmış ve VAR modeli olarak $\ln TALEP_{sa}$, $TUFESa$, SUE_{sa} , $\ln TUR_{sa}$ ve $ISSIZ_{sa}$ deęişkenleri grup olarak seçilmiştir. Daha sonra, bu

²³ SC'nin AIC'den çok daha katıdır. HQ ise arada bir yerde bulunmaktadır. Düzeltilmiş R^2 ölçüsü, tipik olarak en büyük modelleri seçecek olan çok yumuşak bir ölçü olmasına rağmen bir bilgi kriteri olarak da görülebilir.

değişkenlerin birinci dereceden farklarının durağan olmaları nedeniyle, endojen değişkenler olarak her bir değişkenin birinci farkları modele dahil edilmek üzere, $d(\ln TALEP_{sa})$, $d(TUFE_{sa})$, $d(SUE_{sa})$, $d(\ln TUR_{sa})$ ve $d(ISSIZ_{sa})$ seçilmiştir. Ayrıca, sanayi üretim endeksinin (SUE) %1 hata düzeyinde birim kök etkisinin olması nedeniyle, VAR modeline c sabitinin yanına ekzojen değişken olarak trend değişkeni (@TREND) de eklenmiş ve VAR modeli tahmin edilmiştir. View menüsünden, gecikme uzunluğu kriterine bakılarak uygun gecikme genişliğinin LR, FPE ve AIC kriterlerine göre 7 olduğu belirlenmiştir. Bu durumda, Estimate sekmesi tıklanır ve VAR modelinde 1 2 şeklinde olan gecikme aralıkları 1 7 şeklinde değiştirilip model tahmin edilmiş ve Tablo-7'deki sonuçlara ulaşılmıştır.

Tablo-7: Uygun Gecikme Uzunluğunun Belirlenmesi

Gecikme	LogL	LR	FPE	AIC	SC	HQ
0	-703.2546	NA	0.006076	9.086045	9.280711	9.165106
1	-584.3872	227.135	0.001838	7.890283	8.571612*	8.166995
2	-527.6246	104.8482	0.001228	7.485663	8.653655	7.960026*
3	-499.3069	50.50285	0.001181	7.443400	9.098055	8.115414
4	-472.6185	45.89723	0.001161	7.421892	9.563211	8.291556
5	-440.6898	52.87554	0.001072	7.333628	9.96161	8.400944
6	-410.6271	47.87056	0.001017	7.269135	10.38378	8.534102
7	-370.8979	60.73256*	0.000856*	7.081502*	10.68281	8.544120
8	-352.4893	26.96800	0.000952	7.165469	11.25344	8.825738
9	-327.6722	34.77561	0.000981	7.167798	11.74243	9.025718
10	-302.4803	33.69606	0.001014	7.165355	12.22665	9.220926


Not: LR: Olabilirlik Oranı, FPE: Son Öngörü Hatası, AIC: Akaike Bilgi Kriteri, SC: Schwarz Kriteri, HQ: Hannan-Quinn Kriteri;

* ile belirtilen değerler bu bilgi kriterlerine göre en küçük değere sahip olan değerlerdir.

Tablo-7'deki bulgular incelendiğinde, tahmin edilen VAR modeline göre gecikme genişliğinin 7 olduğu, LR, FPE ve AIC kriterlerine göre belirlenmiştir. Diğer bir deyişle, dikkate alınan 5 değişken ile oluşturulan VAR modeli için en küçük bilgi kriteri değerine sahip AIC(7) olarak hesaplanmıştır. Buna göre elde edilen en küçük AIC değeri 7.081502 olarak bulunmuş ve VAR modeli bu gecikme uzunluğuna göre oluşturulmuştur. Hemen ekleyelim ki, 0. gecikmede * işareti görülseydi veya en küçük değere sıfırıncı gecikmede ulaşılmış olsaydı, dikkate alınan değişkenler arasında ilişki olmadığı ve bu değişkenler VAR modelinin kurulamayacağı söylenirdi.

Diğer taraftan, iyi bir VAR modelinin bazı koşulları yerine getirmesi gerekmektedir. Bu nedenle, uygun gecikme değerine göre oluşturulan VAR modeli için AR karakteristik polinomun ters kökleri ile durağanlığı incelenmiş ve sonuçlar Şekil-9'a aktarılmıştır.

Şekil-9: AR Karakteristik Köklerin Birim Çember Konumları



Şekil-9'da görüldüğü üzere, karakteristik köklerin tamamı birim çember içerisinde yer almaktadır. Dolayısıyla, köklerin tamamı mutlak değerce 1'den küçük değerdendirler. Bu sonuç, modelin birim kök içermediğini, diğer bir deyişle, modelin istikrarlı olduğunu göstermektedir. Hemen ekleyelim ki, VAR model bulgularının çok fazla olması nedeniyle, model sonuçları çıktı olarak verilmemiştir. Ancak, modelden elde edilen bilgi olarak, VAR modelimizin gecikme uzunluğunun 7 olduğu bilgisi, bundan sonraki analizlerde kullanılacaktır.

3.3.3. VAR Modeline İlişkin Nedensellik Analizi Bulguları

Uygun gecikme yapısına göre oluşturulan VAR(7) modeli için öncelikle Granger Nedensellik (1969) sınaması, daha sonra da Toda Yamamoto Nedensellik (1995) sınaması yapılmıştır. Hemen ekleyelim ki, VAR(7) modelindeki veri yapıları burada kullanılmaya devam edilmiştir. Diğer bir deyişle, dikkate alınan 5 değişkenin mevsimsellikten arındırılmış değerlerinin logaritmalarının birinci farkları dikkate alınmış ve gecikme genişliği olarak 7 seçilmiştir.

3.3.3.1. Granger Nedensellik Bulguları

Çalışmanın konusunun elektrik talebi ile ilgili olması nedeniyle, Granger nedensellik sonuçları sadece elektrik talebi değişkeni ile diğer 4 değişken arasındaki ilişkiler araştırılmış ve elde edilen bulgular Tablo-8'e aktarılmıştır. Diğer bir deyişle, elektrik talebi değişkeni dışındaki diğer değişkenlerin birbirleri ile olan nedensel ilişkilerine tabloda yer verilmemiştir.

Tablo-8: Granger Nedensellik Testi Bulguları

<u>Sıfır Hipotezi:</u>	Gözlem	F-Stat	Prob.
D(TUFESA) Granger Nedeni Değil D(TALEPSA)	160	1.08793	0.3740
D(TALEPSA) Granger Nedeni Değil D(TUFESA)		0.98677	0.4433
D(SUESA) Granger Nedeni Değil D(TALEPSA)	160	1.07265	0.3840
D(TALPESA) Granger Nedeni Değil D(SUESA)		0.89841	0.5096
D(LNTURSA) Granger Nedeni Değil D(TALEPSA)	160	3.76700	0.0009
D(TALEPSA) Granger Nedeni Değil D(LNTURSA)		1.39758	0.2106
D(ISSIZSA) Granger Nedeni Değil D(TALEPSA)	160	5.54124	0.0000
D(TALEPSA) Granger Nedeni Değil D(ISSIZSA)		2.33798	0.0273

Granger nedensellik analizinin en önemli özelliklerinden biri de değişkenlerin nedensellik ilişkileri test edilmeden önce aynı derecede entegre olmaları gerekmektedir. Dolayısıyla, birim kök testi sonuçlarına göre, değişkenler düzey değerinde durağan olmadıkları için birinci farkları alınmıştır. Tablo-8'deki bulgulara göre, birinci farkları alınan değişkenlerin nedensellik testi sonuçlarına göre, TALEP ile ISSIZ değişkeni arasında %5 anlamlılık düzeyinde, çift yönlü nedensellik ilişkisine rastlanırken, TUR değişkeni TALEP değişkeninin nedeni değildir şeklinde oluşturulan sıfır hipotezi reddedilmiş ve dolayısıyla, TUR değişkeninden TALEP değişkenine %1, %5 ve %10 anlamlılık düzeylerinde tek yönlü nedensellik ilişkisi bulgusuna ulaşılmıştır. Diğer bir deyişle, TUR değişkeni Granger anlamında TALEP değişkeninin nedenidir. TALEP ile diğer değişkenler TUFESA (prob= 0.3740 ve 0.4433) ve SUE (prob=0.3840 ve 0.5096)

arasında verilen anlamlılık düzeylerinde istatistiksel olarak Granger anlamında nedensellik ilişkisinin olmadığı bulgusuna ulaşılmıştır.

3.3.3.2. Toda Yamamoto Nedensellik Bulguları

Toda Yamamoto (TY) nedensellik testinin, Granger nedensellik testine göre en önemli özelliği, değişkenlerin aynı derecede entegre olmaları gerekmemesidir. Diğer bir deyişle, TY testinde dikkate alınan değişkenlerin durağanlık dereceleri farklı olabilir. Dolayısıyla, TY'nin değişkenler arasında en büyük entegre (fark alma) değerine (d_{max}) sahip olan değer ile entegre değerinin belirlenebilmesine olanak sunmaktadır. Tablo-6'da yer alan birim kök testi sonuçları incelendiğinde, bazı değişkenlerin I(1) de entegre olmadıkları sonucuna ulaşılmıştır. Dolayısıyla, bu değişkenler arasında nedensellik ilişkisi test edilmek istendiğinde, fark alma derecelerinin farklı olmaları nedeniyle, Granger nedensellik testi yerine TY nedensellik testi tercih edilebilir.

Granger nedensellik bulgularının yorumlanmasında yapılan ayırım, TY testinde de yapılmıştır. Tez çalışmasının konusu elektrik talebine ilişkin olması nedeniyle, yine test sonuçlarının yorumlanması da sadece elektrik talebi ile diğer değişkenler arasındaki ilişki üzerinde olacaktır. TY testine ilişkin bulgular Tablo-9'daki gibi elde edilmiştir.

Tablo-9: Toda Yamamoto Nedensellik Testi Bulguları

A. Bağımlı Değişken: D(LNTALEPSA)				B. Bağımlı Değişken: D(TUFESA)			
Değişken	Chi-sq	df	Prob.	Değişken	Chi-sq	df	Prob.
D(TUFESA)	10.37349	7	0.1684	D(LNTALEPSA)	6.523758	7	0.4801
D(SUESA)	18.55034	7	0.0097	D(SUESA)	3.641739	7	0.8200
D(LNTURSA)	27.09852	7	0.0003	D(LNTURSA)	4.572870	7	0.7119
D(ISSIZSA)	36.09063	7	0.0000	D(ISSIZSA)	3.903533	7	0.7908
Hepsi	94.00962	28	0.0000	Hepsi	18.65450	28	0.9085

C. Bağımlı Değişken: D(SUESA)				D. Bağımlı Değişken: D(LNTURSA)			
Değişken	Chi-sq	df	Prob.	Değişken	Chi-sq	df	Prob.
D(LNTALEPSA)	12.46387	7	0.0863	D(LNTALEPSA)	8.051014	7	0.3281
D(TUFESA)	24.99363	7	0.0008	D(TUFESA)	35.33355	7	0.0000
D(LNTURSA)	53.43413	7	0.0000	D(SUESA)	14.68793	7	0.0402
D(ISSIZSA)	54.83097	7	0.0000	D(ISSIZSA)	5.193677	7	0.6363
Hepsi	167.7075	28	0.0000	Hepsi	68.83611	28	0.0000

E. Bağımlı Değişken: D(ISSIZSA)			
Değişken	Chi-sq	df	Prob.
D(LNTALEPSA)	19.16158	7	0.0077
D(TUFESA)	10.54400	7	0.1598
D(SUESA)	25.42266	7	0.0006
D(LNTURSA)	18.54124	7	0.0098
Hepsi	70.18057	28	0.0000

Elde edilen TY nedensellik test bulgularına göre, A panelinde SUESA (prop=0.0097), TURSA (prob=0.0003) ve ISSIZSA (prob=0.0000) olarak hesaplanmıştır. Dolayısıyla, bu değişkenlerden TALEPSA değişkenine doğru %5 anlamlılık düzeyinde TY nedensellik ilişkisi bulgusuna ulaşılmıştır. B ve D panellerinde TALPSA değişkeninden TUFESA'ya ve LNTURSA'ya doğru TY nedensellik ilişkisi istatistiksel olarak %1, %5 ve %10 anlamlılık düzeylerinde bulunamamıştır. Ancak C panelinde TALEPSA değişkeninden SUESA'ya %10 anlamlılık düzeyinde ve E panelinde TALESA değişkeninden ISSIZSA değişkenine %1 anlamlılık düzeyinde TY nedensellik ilişkisi olduğu sonucuna varılmıştır.

Granger nedensellik testi sonuçları ile TY nedensellik sonuçları birlikte incelendiğinde ise ISSIZ değişkeni ile TALEP değişkeni arasında çift yönlü Granger nedensellik ilişkisi tespit edilmiştir. Benzer sonuçlar TY nedensellik testinden de elde edilmiştir. Bir diğer benzerlik ise TUR değişkeninden TALEP değişkenine tek yönlü Granger nedensellik ilişkisi bulunmuştu, TY nedensellik testi sonuçlarında da benzer ilişki elde edilmiştir. Ancak Granger nedensellik testi neticesinde TALEP ile TUR ve

ISSIZ deęişkenleri arasında Granger nedensellięi tespit edilmiřken TY nedensellik testinde bu deęişkenlere ilave olarak SUE deęişkeni de dahil olmuřtur. Bařka bir deyiřle, SUE deęişkeninden TALEP deęişkenine TY nedensellik bulgusu elde edilmiřtir. Öte taraftan birim kök testi sonuçlarında I(1) düzeyde, SUE deęişkeni %1 yanılma düzeyinde birim kök bulunmaktaydı. Granger nedensellik sınaması sonucunda bu deęişken ile TALEP deęişkeni arasında istatistiksel olarak bir nedensellik iliřkisi bulgusuna rastlanılmamıřtır. Ne var ki, TY testi bu deęişkenin de TALEP deęişkeni arasında bir nedensellik iliřkisinin varlıęını ortaya koymuřtur.

3.3.4. Varyans Ayrıřtırması Bulguları

Varyans ayrıřtırmasında, VAR modeline dahil edilen deęişkenlerdeki toplam deęişimlerin, dönemler boyunca dięer deęişkenler tarafından nasıl paylařıldıęı görülebilmektedir. Dięer bir deyiřle, içsel deęişkenlerden birinde meydana gelen deęişimi, tüm içsel deęişkenleri etkileyen řokları tek tek olacak řekilde ayırmaktadır. Varyans ayrıřtırması, sistemin dinamik yapısı hakkında bilgi sunmaktadır. Bu analizin amacı, her bir rassal řokun, gelecek dönemler için öngörünün hata varyansına olan etkisini göstermektir (Özgen & Güloęlu, 2004, p. 98).

Daha önce elde edilen VAR(7) modeli üzerinde Varyans ayrıřtırması uygulaması yapılmıř ve elde edilen bulgular Tablo-10, 11, 12, 13, 14'e aktarılmıřtır.

Tablo-10: Elektrik Talebi Deęişkenine İliřkin Bulgular

Dönem	D(LNTALEPSA)	D(TUFESA)	D(SUESA)	D(LNTURSA)	D(ISSIZSA)
1	100.0000	0.000000	0.000000	0.000000	0.000000
2	77.15723	0.052865	1.352538	6.247240	15.19013
3	65.40612	0.369114	2.500572	10.25311	21.47108
4	62.41704	0.354281	4.174059	9.724233	23.33039
5	59.94908	0.562019	4.027246	9.635584	25.82607
6	58.16090	0.890493	3.907525	11.20252	25.83856
7	57.71660	1.144823	3.895832	11.50307	25.73967
8	55.92987	3.609878	3.749839	11.32958	25.38084
9	56.15464	3.575860	3.864397	11.26575	25.13935
10	55.18292	3.507120	3.989211	12.58297	24.73778

Tablo-10’da elektrik talebi deęişkeninin varyansındaki deęişime ilişkin ayrıştırma bulgular yüzde cinsinden yer almaktadır. Elektrik talebi deęişkenine ilişkin birinci dönem deęerlerinin tamamı (%100) kendisi tarafından açıklandığı gözlemlenirken, dięer deęişkenler bu dönemde elektrik talebini açıklamada herhangi bir etkisi olmamıştır. Ne var ki, ikinci dönem itibari ile elektrik talebinin varyansındaki deęişimin %15.19’u işsizlik deęişkeni tarafından açıklanmaktadır. Benzer dönemde elektrik talebini etkileyen bir dięer deęişken ise ülkeye gelen turist sayısı (%6.25) olarak gözlemlenmiştir. Dięer deęişkenler bu dönemde etkileri çok az olmaktadır. Ele alınan 10 dönem boyunca elektrik talebi deęişkeninin kendisi tarafından açıklanma ortalaması %64.81 olarak Excel’de hesaplanmıştır. Aynı mantıkla, dięer 4 deęişkenin 10 dönem ortalamaları da hesaplanmıştır. Böylece, modeli oluşturan dięer deęişkenler ise sırasıyla, işsizlik deęişkeni ortalama %21.27, ülkeye gelen turist sayısı ortalama %9.37, sanayi üretim endeksi ortalama %3.15 ve tüketici fiyat endeksi ise ortalama %1.41 düzeyinde elektrik talebinin varyansındaki deęişmeleri açıklamaktadırlar. Elde edilen bu bulgular, hem Granger hem de Toda Yamamoto nedensellik sonuçlarıyla da benzerlik göstermektedir.

Tablo-11: Tüketici Fiyat Endeksi Deęişkenine İlişkin Bulgular

Dönem	D(LNTALEPSA)	D(TUFESA)	D(SUESA)	D(LNTURSA)	D(ISSIZSA)
1	1.482479	98.51752	0.000000	0.000000	0.000000
2	3.141389	94.54940	2.159804	0.013709	0.135694
3	4.563199	90.60685	2.953804	1.006168	0.869983
4	5.070562	87.92075	3.630589	1.020241	2.357855
5	5.071525	87.67257	3.705589	1.143360	2.406959
6	5.416290	87.02556	3.638755	1.430267	2.489128
7	5.545193	86.90369	3.634237	1.430216	2.486662
8	5.553970	85.18634	3.717316	2.222475	3.319896
9	5.677394	84.27565	3.993104	2.738521	3.315327
10	6.267429	83.60373	4.139909	2.713785	3.275148

Tüketici fiyat endeksinin varyansının ilk dönemde %98.52’i kendisi tarafından açıklanmaktadır. Aynı dönemde çok az bir miktar %1.48’lik kısmı elektrik talebi deęişkeni tarafından açıklanmaktadır ve bu dönemde dięer deęişkenlerin tüketici fiyat endeksinin varyansında herhangi bir oranda deęişime neden olmamışlardır. Ancak ele alınan dönemler gözlemlendiğinde elektrik talebi deęişkeni ortalama %4.78’i tüketici fiyat endeksinin varyansındaki deęişime neden olurken özellikle son dönemlerde bu oran ortalama (son iki dönem) %6.26 düzeyine kadar çıkabilmektedir. Bu doğrultuda benzer

sonular incelendiĐinde lkeye gelen turist sayısı ilk dnemlerde fazla bir etkisi olmamasına raĐmen son dnemlerde bu dzey %2.71 ile %2.74 aralıĐında, aıklayabilmektedir. Ancak dnemler ortalamalar boyutu ile incelendiĐinde sırasıyla oranlar, %1.97’si lkeye gelen turist sayısı ile %3.15’i sanayi retim endeksi ile %2.06’sı ise iŐsizlik ile aıklanmaktadır. Elde edilen bu bulgular, hem Granger hem de Toda Yamamoto nedensellik sonularıyla da benzerlik gstermektedir.

Tablo-12: Sanayi retim Endeksine İliŐkin Bulgular

Dnem	D(LNTALEPSA)	D(TUFESA)	D(SUESA)	D(LNTURSA)	D(ISSIZSA)
1	42.73744	0.314321	56.94824	0.000000	0.000000
2	25.77266	0.520019	46.39592	10.45460	16.85680
3	19.53272	1.187296	38.05717	21.22580	19.99701
4	18.74158	1.392137	38.96959	20.70030	20.19639
5	18.59986	1.599273	37.84296	20.66854	21.28936
6	18.62425	1.668392	37.70857	20.92597	21.07282
7	18.73307	1.671164	37.55473	20.98805	21.05299
8	17.98474	6.413263	35.18291	20.61733	19.80175
9	17.93551	6.382036	35.14961	20.80937	19.72347
10	17.59139	6.493906	34.54601	22.30796	19.06073

Sanayi retim endeksine iliŐkin varyans ayrıŐtırmasına gre, birinci dnemde sanayi retim endeksi deĐiŐkenin %56.94’ kendi gemiŐ deĐerinden etkilenirken bu durum elektrik talebi deĐiŐkeninin, sanayi retim endeksinin varyansındaki deĐiŐimin %42.73’lk kısmını aıklamaktadır. Bu dnemde modelde kullanılan diĐer deĐiŐkenlerden sadece tketicici fiyat endeksinde ok kk bir miktar (yaklaŐık %0.10) sanayi retim endeksinin varyansındaki deĐiŐimi aıklayabilmektedir. Ele alınan 10 aylık dnemler incelendiĐinde, sanayi retim endeksi deĐiŐkeni kendi deĐerlerinden ortalama %39.84’lk kısmı tarafından aıklanabilmektedir. Buna karŐın, elektrik talebi deĐiŐkeni, sanayi retim endeksinin varyansındaki deĐiŐimlerin %21.63’n aıklayabilmektedir. Bu oran aynı zamanda modelde kullanılan diĐer deĐiŐkenlere kıyasla en yksek aıklama dzeyine sahiptir. Modelde kullanılan diĐer deĐiŐkenlerden; lkeye gelen turist sayısı, sanayi retim endeksi deĐiŐkenin %17.57’sini aıklamaktadır. Modeldeki bir diĐer yksek aıklama dzeyine sahip deĐiŐken iŐsizlik deĐiŐkenidir. Bu deĐiŐkenin, sanayi retimi endeksinin varyansındaki deĐiŐimlerin %17.87’sini aıklayabilmektedir. Tketicici fiyat endeksi deĐiŐkenlerinin, sanayi retim endeksinin aıklama dzeyleri ele alınan 10 aylık dnem boyunca ortalama %2.76 dzeyindedir. Elde edilen bu bulgular, Granger

nedensellik bulgularıyla uyumsuz iken, Toda Yamamoto nedensellik sonuçlarıyla paralellik göstermektedir. Bu da Toda Yamamoto nedensellik testinin elektrik talebi tahmini için Granger nedensellik sonucundan daha iyi performans gösterdiği şeklinde yorumlanabilir.

Tablo 13: Ülkeye Gelen Turist Sayısı Değişkenine İlişkin Bulgular

Dönem	D(LNTALEPSA)	D(TUFESA)	D(SUESA)	D(LNTURSA)	D(ISSIZSA)
1	17.05754	0.000000	12.58506	70.35740	0.000000
2	17.53125	0.217679	12.46946	67.86109	1.920516
3	16.46285	0.226726	12.92287	68.56287	1.824684
4	17.10992	0.151016	12.19062	68.33234	2.216111
5	16.69336	1.833818	11.95835	66.82586	2.688615
6	17.24795	2.387755	11.65732	66.05691	2.650054
7	16.88144	2.378053	13.00704	64.71105	3.022423
8	14.86866	15.11847	11.27496	55.33646	3.401448
9	14.88261	16.87682	10.93796	53.45155	3.851068
10	15.25166	16.26412	11.09260	53.60013	3.791496

Ülkeye gelen turist sayısına ilişkin varyans ayrıştırması sonucuna göre, birinci dönem %70.35'lik kısmı kendi gecikmeli değeri tarafından açıklanırken aynı dönemde elektrik talebi değişkeni ise %17.06'lik kısmını açıklamaktadır, başka bir deyişle TALEP değişkeni, ülkeye gelen turist sayısına ilişkin değişkenin varyansındaki değişime neden olmaktadır. Benzer dönemde dikkate değer bir oran ise %10.58'lik oran ile sanayi üretim endeksi değişkeni tarafından açıklanmasıdır. Ele alınan diğer değişkenler, gelen turist sayısı değişkenin varyansındaki değişmeye etkisi çok yüksek değildir. Elektrik talebi değişkeni, ele alınan dönemlerde ise ortalama %16.40'lık kısmını açıklayabilmektedir. Modelde bulunan diğer değişkenler, ele alınan 10 aylık dönemde ortalama sırasıyla %12.00 ile sanayi üretim endeksi, %2.54 ile işsizlik, %5.55 ile tüketici fiyat endeksi değişkenleri olmuştur. Elde edilen bu bulgular, hem Granger hem de Toda Yamamoto nedensellik sonuçlarıyla da benzerlik göstermektedir.

Tablo 14: İşsizlik Değişkenine İlişkin Bulgular

Dönem	D(LNTALEPSA)	D(TUFESA)	D(SUESA)	D(LNTURSA)	D(İSSİZSA)
1	0.513303	0.392408	4.627153	0.240305	94.22683
2	3.411008	0.297189	13.74657	0.713939	81.83129
3	8.079250	1.720913	12.74794	0.610979	76.84092
4	10.57218	3.065846	11.42644	5.509041	69.42649
5	12.75152	6.876812	10.29724	7.637677	62.43675
6	12.94391	8.794183	9.690704	9.186048	59.38515
7	14.41260	10.03440	9.668000	8.862674	57.02232
8	14.61127	10.49724	9.782656	9.049140	56.05970
9	14.75193	10.40810	10.29769	9.019270	55.52302
10	16.04722	10.86966	10.00249	9.246204	53.83442

İşsizlik değişkenine ilişkin varyans ayrıştırması sonuçlarına göre, ilgili değişkenin ilk dönemde %94.22'si kendisi tarafından açıklanmaktadır. Aynı dönemde sanayi üretim endeksi değişkeni, işsizlik değişkeninin varyansındaki değişimin %0.51'ini açıklayabilmektedir. Modeldeki diğer değişkenler ise toplam %1.75'ini açıklayabilmektedir. İşsizlik değişkenin varyansının kendi geçmiş değerleri tarafından açıklanma düzeyi dördüncü dönemden itibaren %69 düzeylerine inerken dönem sonunda %53.83 seviyelerine ulaşmış ve dönem boyunca ortalama %66.66 olmuştur. TALEP değişkeni, dördüncü dönemden (%10.57) itibaren, işsizlik değişkenin varyansındaki değişimlerin açıklama düzeyi artarak son dönemde %16.04'e kadar çıkmıştır. Buna karşın, elektrik talebi değişkeni, ülkeye gelen turist sayısına ilişkin değişkeni ve tüketici fiyat endeksi değişkenleri toplam değişimin ele alınan dönemler ortalamasına göre %8.33 seviyesinde, işsizlik değişkenin varyansındaki değişimi açıklayabilmektedir. Elde edilen bu bulgular, hem Granger hem de Toda Yamamoto nedensellik sonuçlarıyla da benzerlik göstermektedir.

3.3.5. Etki Tepki Fonksiyonu


Etki tepki fonksiyonu, değişkenlere herhangi bir şok verildiğinde, diğer değişkenlerin bu şoktan ne yönde etkilendiklerini belirlemek için etki tepki fonksiyonlarının grafikleri incelenerek kullanılır. Diğer bir deyişle, rassal hata terimlerinin bir tanesindeki bir standart sapmalı şokun, içsel değişkenlerin şimdiki ve

gelecek dönem değerlerine olan etkisini yansıtabilmektedir (Barışık & Kesikoğlu, 2003, p. 69). Etki tepki fonksiyonu ile bir değişkenin üzerinde en etkili bulunan değişkenin, politika aracı olarak kullanılabilir olup olmadığının belirlenmesinde kullanılabilmektedir (Özgen & Güloğlu, 2004).

Bir etki tepki fonksiyonu grafiğinde; düz yatay çizgi, sıfır çizgisi olarak adlandırılmaktadır. Bu yatay çizgi, tepkinin söndüğü veya yok olduğu çizgidir. Sıfır noktasındaki çizginin üst kısmı pozitif tepkiyi, alt kısmı ise negatif tepkiyi belirtmektedir. Etki tepki grafiğinde bulunan kesikli çizgiler ise tepkinin 0.95 güven aralığının alt ve üst sınırlarını göstermekle birlikte, bu çizgilerin arasındaki tüm çizgi, tepki eğrisi olarak tanımlanır. Grafiğin X eksenini dönemleri, Y eksenini ise tepkinin şiddetini yüzdesel göstermektedir.

Bu çalışmada, etki tepki fonksiyonlarının standart hataların hesaplanması için Monte Carlo tekniği kullanılmıştır. Bu tekniğe göre, VAR katsayıların asimptotik dağılımından rassal bir örneklem seçilmektedir. Simülasyonda elde edilmiş bu süreç, katsayılardan yararlanarak etki tepki katsayıları elde edilmektedir. Bu süreç, çalışma için 1000 olarak belirlenmiştir. Ayrıca, etki tepki katsayılarının elde edilmesinde en sık kullanılan yöntemlerden biri de Cholesky ayrıştırmasıdır. Bu yöntem ile katsayıların dikeyleştirilmesi ile elde edilen varyans kovaryans matrisinin diyagonal hale getirilmesidir (Özgen & Güloğlu, 2004).

Şekil-10: Elektrik Talebinin Elektrik Talebine Tepkisi




Şekil-10'da elektrik talebinin kendisine vermiş olduğu tepki dönemler itibarıyla gösterilmektedir. Elektrik talebine başlangıçta yaklaşık %3'lük bir şok gerçekleşmiş ve bu etki ikinci dönemin başına kadar pozitif olarak sürmüştür. Ancak bu dönemden beşinci

dönem sonuna kadar negatif etki şeklinde gerçekleşmiştir. Beşinci dönemden sonra sıfır civarında inişli çıkışlı hareket etmiştir. Birinci dönemde alt kesikli olan alt güven sınırı ile üst güven sınırı aynı yerden başlamadığından, birinci dönemde %95 düzeyinde bu etkinin istatistiksel olarak anlamlı olduğu söylenebilir. Ancak sıfır noktasındaki çizgi ile tepki eğrisi bu dönemden sonraki dönemler boyunca, %95 güven aralığı içerisinde olması nedeniyle istatistiksel olarak anlamsız olduğu bölgedir.

Şekil-11: TALEP ve TÜFE'nin Etki Tepki Şekilleri

Şekil-11.A TALEP'in TÜFE'ye Tepkisi

Şekil-11.B TÜFE'nin TALEP'e Tepkisi




Şekil-11.A'da TÜFE değişkenine verilen bir standart hatalık şokun elektrik talebine vermiş olduğu tepki gösterilmektedir. Birinci dönem hem tepkinin kaybolduğu hem de istatistiksel olarak anlamsız olduğu dönemdir.

Şekil-11.B'de ise elektrik talebine verilen 0 ile 0.5 aralığındaki yaklaşık %0.25'lik şok pozitif ancak beşinci aya kadar hafifçe azalan tepkiye sahiptir. Beşinci aydan sekizinci aya kadar negatif ve yatay etki gözlemlenirken dokuzuncu aydan on ikinci aya kadar pozitif etki gözlemlenmektedir. TÜFE'nin elektrik talebine tepkisi sıfır çizgisi içerisinde kalması nedeniyle, %95 güven aralığında istatistiksel olarak anlamsızdır.

Şekil-12: TALEP ve SUE Etki Tepki Şekilleri

Şekil- 12.A: TALEP'in SUE'ye Tepkisi

Şekil-12.B SUE'nin TALEP'e Tepkisi




Şekil-12.A'da sanayi üretim endeksine verilen bir standart hatalık şokun etkisine ait tepki grafiksel olarak gösterilmektedir. Birinci dönemde etkisiz olan bu etki, beşinci döneme kadar azalan ve artan düzeylerde değişiklik gösterirken, beşinci aydan itibaren etki kaybolmuştur. Tüm dönemler itibari ile tepki eğrisi %95 güven düzeyi (teпки sınırları) arasında kalmış ve bu nedenle anlamsız olduğu sonucuna ulaşılmıştır.

Şekil-12.B'de ise elektrik talebine verilen bir standart hatalık şokun sanayi üretim endeksinin tepkisi incelenmiştir. Birinci dönemde bu etki pozitif ancak ikinci döneme kadar azalan etki sergilemiştir. Daha sonraki dönemlerde artan azalan şeklinde devam eden bu etki, birinci dönemde istatistiksel olarak anlamlı iken, ikinci dönemden itibaren %95 güven düzeyi dışında kalmıştır. Bu nedenle istatistiksel olarak anlamsız oluşunun bulgusuna ulaşılmıştır.

Şekil-13: TALEP ve TUR Etki Tepki Şekilleri

Şekil-13.A: TALEP'in TUR'a Tepkisi

Şekil-13.B: TUR'un TALEP'e Tepkisi




Şekil-13.A' da elektrik talebine verilen bir standart hatalık şokun ülkeye gelen turist sayısı değişkeninin vermiş olduğu tepki gösterilmektedir. Birinci dönemde etkisi olmayan bu şekilde, ikinci dönem itibari ile artan ve daha sonraki dönemler itibari ile

azalan ve artan şekilde devam etmektedir. Ancak Şekil incelendiğinde, elektrik talebine verilen tepki anlamsızdır.


Şekil-13.B incelendiğinde, gelen turist sayısı değişkenine verilen bir standart hatalık şokun elektrik talebine olan tepkisi gösterilmektedir. Birinci dönem bu etki pozitif ancak azalan bir seyir izlemektedir. İkinci dönemde tepki eğrisi, sıfır çizgisi ile kesiştiği görülmektedir. Bu sebeple ikinci dönemden itibaren tepki güven sınırları içerisinde bulunduğundan dolayı bu dönemden itibaren tepkisiz olduğu sonucuna ulaşılmıştır.

Şekil-14: TALEP ve ISSIZ Etki Tepki Şekilleri

Şekil-14.A: TALEP'in ISSIZ'e Tepkisi



Şekil-14.B: ISSIZ'in TALEP'e Tepkisi



Şekil-14.A'da işsizlik değişkenine, elektrik talebine verilen bir şokun işsizliğe tepkisi gösterilmektedir. Birinci dönemde tepki gözlemlenmezken, ikinci dönemde ise tepki azalan ve negatif yönlü gerçekleşirken ikinci dönem sonrasında bu tepki istatistiksel olarak anlamsızdır. İkinci dönemden üçüncü döneme kadar artan ancak negatif tepkinin varlığı tespit edilmiştir. Ancak üçüncü dönemden itibaren tepki eğrisi, sıfır çizgisi ile kesiştiği ve dolayısıyla güven aralığı içinde olduğunu göstermektedir. Bu durum işsizlik değişkenine verilen şokun elektrik talep değişkeninin vermiş olduğu tepkinin ikinci dönemden sonra anlamsız olduğu tespit edilmiştir.

Şekil-14.B incelendiğinde, elektrik talep değişkenine verilen şoka işsizlik değişkeninin tepkisi birinci dönemde azalan ve negatif tepki verdiği gözlemlenmektedir. Ele alınan süre boyunca negatif etki devam ederken dokuzuncu aydan itibaren tepki pozitif etkiye yönelmiştir. Ayrıca Şekil incelendiğinde ikinci dönemde güven sınırları içerisinde seyretmiştir. Bu durum ikinci dönemden itibaren işsizlik değişkeninin tepkisinin anlamsız olduğunu göstermektedir.

3.4. YAPAY SİNİR AĞI UYGULAMA BULGULARI

Bu bölümde yapay sinir ağı algoritmaları ile elektrik talebi tahmininin hem tek değişkenli olarak hem de çok değişkenli olarak uygulaması gerçekleştirilmiştir.

3.4.1. Tek Değişkenli Yapay Sinir Ağı Bulguları

Bu bölümde YSA mimarisinin oluşturulması, eğitimi ve bu eğitim sonucunda elde edilen çıktılar bulunmaktadır. Çalışmaya ait veriler TEİAŞ ve EPIAŞ web sitelerinden temin edilmiş olup, ilgili YSA mimarileri, MATLAB 2018a sürümü ile gerçekleştirilmiştir. Ağ mimarisi oluşturulurken nöron sayısının belirlenmesinde herhangi bir kural olmaması nedeniyle, farklı denemeler yapılmıştır (Öztemel, 2006). Ancak, bu farklı denemeler gerçekleştirilmeden önce, çalışmada bulunan gözlem sayısının karekökünün yaklaşık olarak tam sayı değerlerinin, alt ve üst değerleri kadar nöron sayısı belirlenmiş ve ağ denemeleri yapılmıştır. Bu doğrultuda, N gözlem sayısını belirtmek üzere, aşağıdaki eşitlik şeklinde değerlendirilmiştir.

$$\text{Nöron Sayısı} \cong \sqrt{N}$$

Çalışmada, 168 adet gözlem bulunmaktadır ve bu sayıya en yakın tam karekök değeri verebilen 169 sayısı olduğundan, 13 nöron alt ve üst tam sayı değerleri ile denenmiştir. YSA nöron sayısının belirlemeleri subjektif olarak 9 nöron ile 15 nöron aralığında denemeler ile gerçekleştirilmiştir.

Tek değişkenli YSA mimarilerini oluştururken, MATLAB'ın kullanıcıya sunmuş olduğu NAR (Nonlinear Autoregressive) yöntemi ile çalışılmıştır. Bu yöntem Y_t değişkeninin d (Number of delays) gecikmeli değerlerinin de ağa sunulması ile gerçekleştirilmektedir. Dolayısıyla, ilgili NAR mimarisi ile aşağıdaki fonksiyon doğrultusunda tahminler gerçekleştirilmiştir.

$$Y(t) = f(Y(t-1), \dots, Y(t-d))$$

NAR ağı, geri yayımlı bir ağıdır. Bu ağda geri besleme ya da yayılma giriş ayarları, geri besleme çıkışına göre otomatik belirlenmektedir. NAR için gecikmeli

değerler de deneme yanılma yöntemi ile belirlenmektedir. Ancak, bu tez çalışmasında VAR modelleri ile de çalışılması nedeniyle, gecikme sayısının belirlenmesinde VAR modelindeki gecikme sayısı dikkate alınmıştır. VAR modelinde LR, FPE ve AIC bilgi kriterlerine göre optimal gecikme genişliği 7 olarak bulunmuştu. Bu doğrultuda farklı nöron kombinasyonları, 2 ile 7 gecikme değerleri arasında farklı gecikme yapıları ile değerlendirilmiştir. Örneğin, 9 nöron 2 gecikme, 9 nöron 3 gecikme, 9 nöron 4 gecikme, 9 nöron 5 gecikme, 9 nöron 6 gecikme ve 9 nöron 7 gecikme şeklinde toplam 42 ağ eğitilmiştir.

Elektrik talebi değişkeninin veri bölümleri; %70 (118 adedi) eğitim (training) için, %15 (25 adedi) doğrulama (validation) için ve %15 (25)'i ise test verisi şeklinde rassal olarak yapılmıştır. Burada, eğitim için ayrılan bölümün amacı; eğitim sırasında ayrılan gözlemler, ağa sunulmaktadır ve ağın hatasına göre ayarlama yapılmaktadır. Doğrulama için ayrılan bölüm ise; ağ genellemesini ölçmek ve bu genelleme gelişmesi durumunda eğitimi durdurmak için kullanılmaktadır. Test bölümü ise, eğitim üzerinde herhangi bir etkisi bulunmamasına rağmen, performansın bağımsız ölçüsü için değerlendirilmektedir.

Ağ, Levenberg - Marquardt (trainlm) eğitim fonksiyonu İleri beslemeli geri yayımlı ağ ile eğitilmiştir. Bu yöntemin, diğer yöntemlere göre daha hızlı olması nedeniyle, yapılan zaman serisi çalışması da bu yöntem ile gerçekleştirilmiştir. Ağın performans ölçütü olarak MSE (Mean Squared Error) ve R^2 değerleri ağ seçiminde karşılaştırmaya tabi tutulmuştur.


Yukarıda bahsedilen denemeler ile elde edilen bilgilere göre, MSE değeri en küçük olan ağ mimarilerine Tablo-15'te verilmiştir:

Tablo-15: En İyi Performans Sergileyen Mimariler

Gizli Katman	Gecikme Sayısı	İterasyon (Epoch)	Gradyan	MSE	R^2	Eğitim-Performans (MSE)	Test-Performans (MSE)	Doğrulama-Performans (MSE)	R değeri
9	7	14	0.394	0.0708	0.97028	0.00059	0.00065	0.00183	0.98503
10	4	9	0.287	0.0490	0.96309	0.00081	0.00190	0.00120	0.98137
11	6	8	0.175	0.0427	0.95907	0.00127	0.00076	0.00116	0.97932
12	4	10	0.165	0.0200	0.96586	0.00083	0.00150	0.00077	0.98278
13	6	10	0.702	0.2400	0.96639	0.00067	0.00223	0.00082	0.98305
14	6	9	0.293	0.0500	0.96191	0.00070	0.00215	0.00135	0.98077
15	7	7	0.268	0.0390	0.94344	0.00157	0.00188	0.00108	0.97131

Yapılan farklı nöron ve gecikme yapılarına göre oluşturulan ağlardan MSE değeri en küçük (0.02) olan 12 nöron ve 4 gecikmeye sahip ağ olmuştur. Bu ağda optimum sonuca ve en küçük hata değerine ise 10 iterasyon ile ulaşmıştır. Ayrıca, MSE değerinin yanında gradyan değeri, diğer MSE değeri küçük ağlar içerisinde en küçük değere sahiptir. İlgili ağın açıklanma düzeyi yaklaşık %96.586 iken, bu ağın eğitim için ayrılan veri kümesinin MSE değeri 0.00083 olurken, bu değer diğer (15 nöron 7 gecikme (MSE= 0.00157) 11 nöron 6 gecikme (MSE= 0.00127) ile oluşturulan ağlar dışında) ve ağların eğitim değerlerine göre yüksektir. Benzer şekilde, ağın test performans değeri de diğer ağların test değerlerinden (11 nöron 6 gecikmeli ağ ve 9 nöron ve 7 gecikmeli ağları dahil) sonra üçüncü en küçük değere sahiptir. Dolayısıyla, ana belirleyici ağın genel performans göstergesi olan MSE değerine göre, en küçük değerde 12 nöron ve 4 gecikmeli ağ olarak belirlenmiştir. En iyi performansı gerçekleştiren ağ ise Şekil-15'deki gibidir.

Şekil-15: En iyi Performans Sergileyen Mimari



12 adet nörona ve 4 gecikmeye sahip ileri beslemeli geri yayımlı bu ağda, aktivasyon fonksiyonu olarak logsig (Logaritmik – Sigmoid) fonksiyonu kullanılmıştır. Bu fonksiyonun seçilme nedeni ise, çalışmada kullanılan değişkenlerde negatif gözlem değeri bulunmamasıdır. Bu fonksiyon, aynı zamanda doğrusal olmayan problemlerin çözümünde oldukça başarılıdır. Ayrıca, Tablo-16'da gerçekleştirilen denemeler sonucunda performansı en kötü çıkan ağlar verilmiştir.


Tablo-16: En Kötü Performans Sergileyen Mimariler

Gizli Katman	Gecikme Sayısı	İterasyon (Epoch)	Gradyan	MSE	R^2	Eğitim-Performans (MSE)	Test-Performans (MSE)	Doğrulama-Performans (MSE)	R değeri
9	5	11	1.040	0.466	0.96820	0.00077	0.00068	0.00141	0.98397
10	7	13	0.979	0.509	0.96918	0.00085	0.00071	0.00083	0.98447
11	4	12	1.110	0.571	0.96548	0.00065	0.00100	0.00241	0.98259
12	3	10	0.583	0.269	0.95897	0.00099	0.00070	0.00219	0.97927
13	4	9	1.340	0.673	0.96266	0.00096	0.00081	0.00155	0.98115
14	7	9	1.240	0.527	0.96877	0.00089	0.00087	0.00081	0.98426
15	2	9	1.590	0.860	0.96126	0.00103	0.00059	0.00175	0.98044

En uygun ağı belirleyebilmek için denemeler yapılmıştır. Bu denemeler sonucunda ilgili nöron ve gecikme değerleri ile oluşturulan ağların performansı oluşturulan 42 farklı ağ içerisinde en kötü performansa sahip ağlar olarak belirlenmiştir. Tablo-16'dan da anlaşılacağı üzere, MSE değerleri 0.269 ile 0.860 arasında farklı sonuçlar elde edilmiştir. Benzer şekilde, gradyan değerleri bir değerine çok yakın sonuçlara ulaşılmıştır.

En iyi olarak belirlenen 12 nöron ve 4 gecikmeli ağın performansı Şekil-16'daki gibi elde edilmiştir.


Şekil-16: 12 nöron 4 gecikmeli Ağın Performansı



Şekil-16'dan da görüleceği üzere, gerçekleştirilen eğitim sonucu en iyiye ulaşabilmek için toplam 10 iterasyon gerçekleştirilmiştir. Ancak en iyi, diğer bir deyişle, MSE değerini en küçükleyen değer ise 4. iterasyonda elde edilmiştir. Elde edilen bu değer ise 0.0015 olarak hesaplanmıştır. Ayrıca, Doğrulama eğrisinin en iyi iterasyon sayısına ulaştıktan sonra, eğitim ve test eğrisine paralel hareket ettiği gözlemlenmektedir.

Eğitilen ağın çıktı ve hedefleri arasındaki farkı gösteren hataların histogramı ise Şekil-17'deki gibidir.

Şekil-17: Hataların Histogram Grafiği




İlgili ağı, hata terimine ilişkin histogram grafiğinde; eğitim, test ve doğrulama hatalarına ilişkin gözlemlerin sıfır hata çizgisi etrafında kümelendiği gözlemlenmektedir. Ancak, doğrulamaya ilişkin bir gözlemin sıfır hata çizgisinden çok uzakta (solda) olduğu görülmektedir. Bu durum, Şekil-18'deki doğrulama regresyon grafiğinde de görülebilmektedir.

Şekil-18'da; elde edilen regresyon sonuçları incelendiğinde, nerdeyse bütün gözlemler en uygun doğru olarak belirlenen regresyon doğrusu üzerinde yaklaşık olarak bulunmaktadır. 12 nöron ve 4 gecikmeli bu ağda sadece eğitim gözlemlerinin doğruya daha yakın oldukları gözlenirken, diğer doğrulama, test ve hepsini içeren regresyon analizi sonucunda bazı gözlemler doğrudan uzak konumda bulunmaktadır. Söz konusu şekilde eğitim verisi için ayrılan veriler ile oluşturulan regresyon modelinde bulunan hedef değişkeninin, çıktı değişkenini açıklama düzeyi²⁴ %97 olarak hesaplanırken, benzer şekilde doğrulama için ayrılan veriler ile oluşturulan regresyonun çıktı değişkenini açıklama düzeyi yaklaşık olarak %94, test için ayrılan verilerin çıktı değişkenini açıklama düzeyi yaklaşık olarak %96 olarak hesaplanmıştır. Hepsi olarak belirtilen regresyon sonucuna göre ise, hedef değişkeninin çıktı değişkenini %98 oranında açıklama düzeyine sahip olduğu hesaplanmıştır.

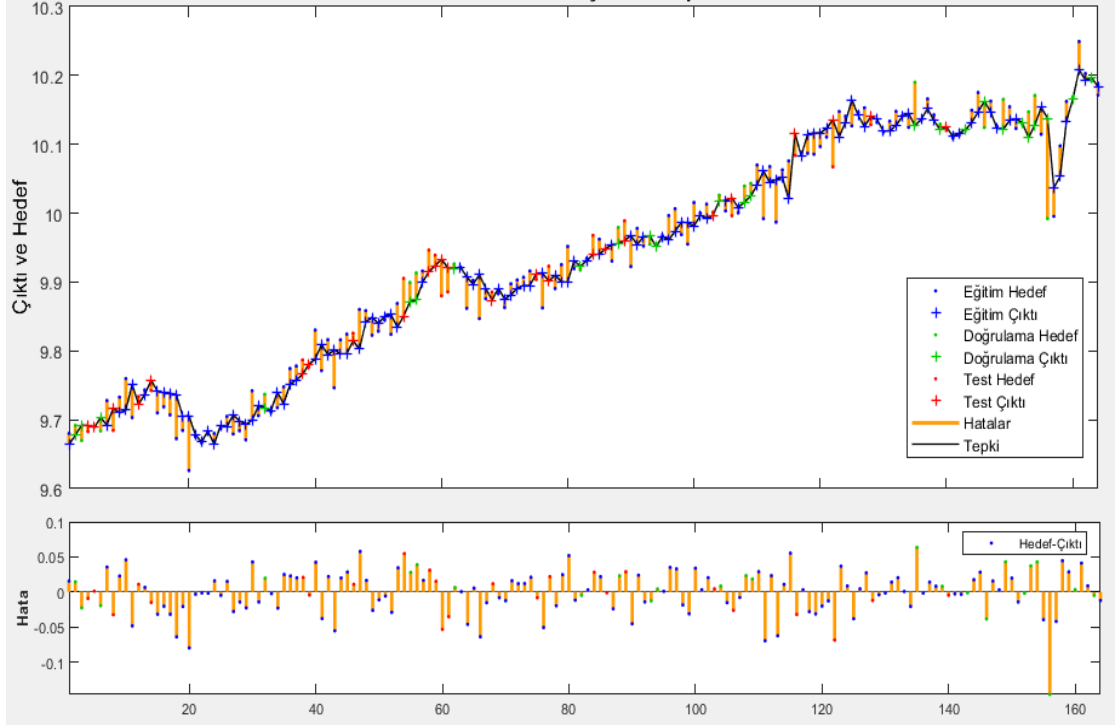
²⁴ R^2 değerleri R değerlerinin kareleri alınarak el ile hesaplanmıştır.

Şekil-18: Veri Setlerinin Regresyon Performansları



Eğitim, test ve doğrulama veri kümelerinin hata terimine tepkisine ilişkin grafik Şekil-19'daki gibi elde edilmiştir. Şekil-19'da ağın eğitimi sonucunda, elektrik talebi değişkeninin %70-%15-%15 olarak ayrılan veri kümesi sonuçlarına göre, elde edilen çıktıların tepkileri gösterilmektedir. Şekilde eğitim, test ve doğrulama, hedefleri artı (+) ile gösterilirken çıktıları ise nokta (.) ile göstermektedir. Ağın özellikle eğitim hedef için elde edilen çıktıların değerleri arasında küçük sapmaların olduğu görülmektedir. Eğitim çıktıları 2008 yılında gerçekleşen ekonomik krizin olduğu dönemde sapma sergilemiş ve bu dönemi tam anlamıyla yakalayamamıştır. Benzer şekilde, 2019 yılında yaşanan COVID-19 etkilerinin elektrik talebine de yansıdığı gözlemlenirken, bu dönemde doğrulama hedef ve çıktı değerleri birbirilerinden uzak kalmışlardır. Ancak, eğitim kümesinde bu dönemde bulunan gözlemler doğruya daha yakın bir sonuç ile tahmin edilebilmiştir.

Şekil-19: Zaman Serisine Çıktının Tepkisi



3.4.2. Çok Değişkenli Yapay Sinir Ağı Uygulaması


Çok değişkenli ağ ile oluşturulan bu uygulama bölümünde, girdi değişkeni olarak, zaman serisi uygulama bölümünde kullanılan değişkenler olan TÜFE, ülkeye gelen turist sayısı (TUR), işsizlik (ISSIZ) ve sanayi üretim endeksi (SUE) değişkenleri oluştururken, çıktı değişkeni olarak elektrik talep miktarı (TALEP) değişkeni yer almıştır. Oluşturulan ağ mimarileri, tek değişkenli ağ mimarilerinde uygulanan yöntem doğrultusunda, 9 ile 15 nöron denemeleri gerçekleştirilmiştir. Tablo-17'de, çalışmada uygulanan çok değişkenli ağ mimarilerinin performansları yer almaktadır.

Tablo-17: Çok Değişkenli Ağ Mimarilerinin Performansları

Gizli Katman	İterasyon (Epoch)	Gradyan	MSE	R^2	Eğitim-Performans (MSE)	Test-Performans (MSE)	Doğrulama-Performans (MSE)	R değeri
9	10	0.761	0.2790	0.9485	0.00121	0.00196	0.00216	0.9739
10	14	0.302	0.0635*	0.9500	0.00109	0.00239	0.00204	0.9747
11	9	0.666	0.2590	0.9122	0.00284	0.00532	0.00194	0.9551
12	23	0.430	0.1700	0.9526	0.00084	0.00337	0.00186	0.9760
13	14	0.255	0.0927	0.9551	0.00112	0.00199	0.00132	0.9773
14	20	1.130	0.3980	0.9604	0.00102	0.00123	0.00152	0.9800
15	8	1.320	0.3990	0.9397	0.00155	0.00242	0.00191	0.9694

9 ile 15 nöron denemeleri ile oluşturulan tek katmanlı farklı ağ denemelerinde en küçük MSE değerine sahip olan 10 nöron ile oluşturulan çok değişkenli mimaridir. Bu nörona ait MSE değeri ise 0.0635 olarak hesaplanmıştır. Benzer şekilde, eğitim için %70 (118 gözlem), doğrulama ve test için ise %15 (25'er gözlem) olarak ayrılan veri kümesine ait MSE değerlerine göre ise; eğitim kümesi için ayrılan gözlemlerde performansı en iyi olan 12 nörona sahip olan mimari iken, test performansı en iyi olan 14 nörona sahip mimari ve doğrulama performansı en iyi olan mimari ise 15 nörona sahip mimari olarak belirlenmiştir. Elde edilen R^2 değerlerine göre, en iyi performansı 14 nörona sahip olan mimari %96 olduğu sonucunda ulaşılmıştır. 10 nörona sahip mimarinin R^2 değeri %95 olup MSE'si en küçük olması nedeniyle, çalışılan ağ mimarisi olmuştur. Oluşturulan bu mimari ise Şekil-20'deki gibidir:

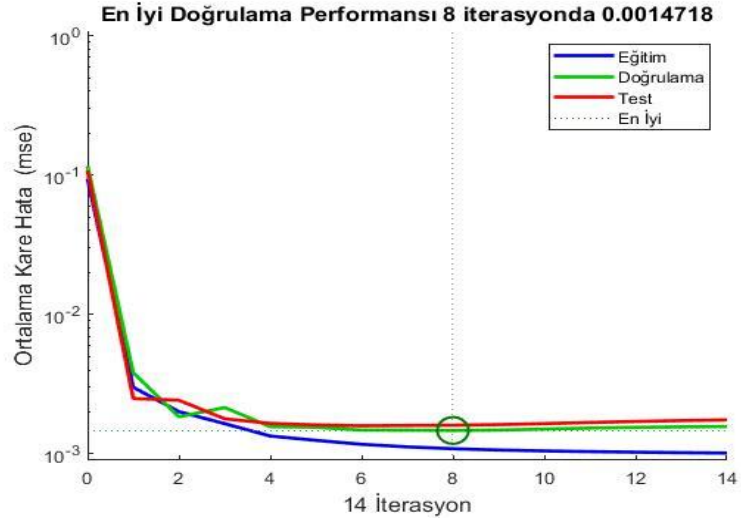
Şekil-20: 10 Nöron ile Elde Edilen YSA Mimarisi



TUFE, SUE, TUR ve ISSIZ değişkenleri, bu ağ mimarisinde girdi değişkenleri olarak kullanılarak, TALEP değişkeni tahmin edilmeye çalışılmıştır. 10 adet nörona sahip

ileri beslemeli geri yayımlı bu ağda, aktivasyon fonksiyonu olarak logsig (Logaritmik – Sigmoid) fonksiyonu kullanılmıştır. Bu fonksiyonun seçilme nedeni ise, çalışmada kullanılan değişkenlerin hiçbirinde negatif gözlem değeri olmamasıdır. Bu fonksiyon aynı zamanda doğrusal olmayan problemlerin çözümünde de oldukça başarılıdır. Elde edilen bu mimarinin performansı Şekil-21’deki gibidir.

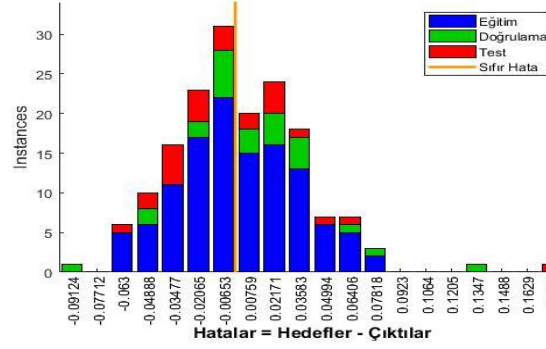
Şekil-21: 10 Nöron ile Oluşturulan Ağın Performansı



10 nörona sahip çok değişkenli ağ mimarisinin eğitimi ile en iyi sonuca ulaşabilmek için toplam 14 iterasyon gerçekleştirilmiştir. MSE değeri en küçükleyen ve dolayısıyla, en iyi performans değerine ise 8 iterasyon sonunda ulaşılmıştır. 8’inci iterasyonda, MSE değeri 0.0014718 olarak hesaplanmıştır. Doğrulama eğrisi en iyi performansı gerçekleştirdikten sonra, test ve eğitim serisi ile paralel olarak hareket etmiş ve aşırı uyumun olmadığını ve ağın başarı ile öğrenmeyi gerçekleştirdiği bulunmuştur.


Eğitilen ağın çıktı ve hedefleri arasındaki farkı gösteren hataların histogramı ise Şekil-22’deki gibidir. 10 nöron ile eğitilen ağın; eğitim, doğrulama ve test veri kümelerinin hatalarına ilişkin histogram grafiğinde, gözlemlerin büyük çoğunluğunun sıfır hata çizgisi etrafında toplandığı gözlemlenmektedir. Ancak doğrulama ve test verilerine ilişkin bazı hata gözlemleri sıfır hata çizgisinden uzakta kalmışlardır.

Şekil-22: Hataların Histogram Grafiği



Eğitim, doğrulama ve test için ayrılan veri kümelerinin öğrenme sürecinde oluşturulan regresyon doğrusuna göre dağılımları Şekil-23’de gösterilmektedir.

Şekil-23: Veri Setlerinin Regresyon Performansları



Şekil-23’deki bulgulara göre, eğitim için ayrılan 118 gözlemin regresyon çıktısında R değeri (korelasyon değeri) %98 olarak hesaplanmış ve başarılı bir eğitimin gerçekleştiğini göstermektedir. Benzer şekilde, Hepsini içeren regresyon doğrusuna göre çıktıda ise %97 olarak hesaplanan bu değerler uyumun çok iyi olduğunu göstermektedir. Ancak, test ve doğrulama için ayrılan veri kümelerinin (25 er gözlemin) bazı gözlemlerinin regresyon doğrusundan uzaklaştığı gözlemlenmiştir.

3.5. HİBRİT YÖNTEM UYGULAMASI

Literatürde farklı zaman serisi modelleri ile YSA mimarilerinin birleşiminden oluşan hibrit yöntem önerilerine sıkça rastlanılmaktadır. Yapılan çalışmaların çoğunda, hibrit yöntemler veya modeller ile farklı analiz yöntemlerinin birleşiminden elde edildiğine değinilmiştir. Bu çalışmada, elektrik talep miktarına ait değişkenin Roh (2007)'un önermiş olduğu Koşullu varyans modelleri ile yapılan hibrit yöntem üzerinde durulmuştur. Zaman serisi uygulama kısmında yapılan analiz sonuçlarında, elektrik talep değişkeninde ARCH etkisinin varlığına ulaşılmış ve ilgili modeldeki ARCH etkisi, çeşitli denemeler sonucunda ARCH(1) modeli ile ARCH etkisinin ortadan kalktığı gözlemlenmiştir.

Engle'in (1982) önermiş olduğu ARCH(1) modeli aşağıdaki gibidir:

$$h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 \quad (3.3)$$

Bu eşitlikte h_t koşullu varyansı, α_0 koşulsuz varyansın katsayısını ve ε_{t-1}^2 ise $t - 1$ zamandaki hatayı göstermektedir. Aynı zamanda α_0 ve α_1 ise ARCH modelinin parametreleridir. Bollerslev (1986), Engle'in önermiş olduğu ARCH modelini genişleterek, GARCH modelini öne sürmüştür. Bollerslev'in (1986) önermiş olduğu GARCH(1,1) modeli, aşağıdaki gibi tanımlanmıştır:

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2 \quad (3.4)$$

ARCH modelindeki tanımlamalara ek olarak β_1 parametresi, GARCH modelinin parametresidir. Roh(2007), GARCH(1,1) modelini hibrit yöntem için ise şu şekilde önermiştir:

$$Y_1 = \beta_1 \sigma_{t-1}^2 \quad (3.5)$$

$$Y_2 = \alpha_1 \varepsilon_{t-1}^2 \quad (3.6)$$

Daha sonra, yeni tanımlanan değişkenler YSA mimarisine girdi olarak kullanılarak, oynaklık tekrar tahmin edilmiş olur. Dolayısıyla, GARCH(1,1)-YSA modeli ile nihai tahmine ulaşılmış olacaktır.

Tez çalışmasında, Roh'un (2007) önermiş olduğu GARCH-YSA hibrit yöntemi, ARCH-YSA hibrit yöntemi olarak uygulanmıştır. Roh'un tanımlamalarından yola çıkarak, $Y_2 = \alpha_1 \varepsilon_{t-1}^2$ değişkeni YSA mimarisine girdi değişkeni olarak sunulmuş hibrit yöntem elde edilmiştir.

Zaman serisi analizi bölümünde uygulanan ve elde edilen ARCH(1) eşitliği şu şekilde tahmin edilmiştir:

$$h_t = 0.000541 + 0.551863\varepsilon_{t-1}^2$$

Bu doğrultuda, oynaklık tahminini YSA mimarisi ile tahmin edebilmek için Eşitlik (3.5)'ten yararlanılmıştır. Yapılan hesaplama ile ilgili oluşan yeni değişken, YSA'ya girdi değişkeni olarak sunulmuş ve en iyi performans gösteren mimariler Tablo-18'deki gibi elde edilmiştir.

Tablo-18: En İyi Performans Gösteren Mimariler


Gizli Nöron	Gecikme Sayısı	İterasyon (Epoch)	Gradyan	MSE	R^2	Eğitim Performans (MSE)	Test Performans (MSE)	Doğrulama Performans (MSE)	R değeri
9	4	15	0.000097	0.000002	0.1232	0.0000015	0.0000011	0.0000002	0.3510
12	7	12	0.000367	0.000069	0.1571	0.0000017	0.0000032	0.0000003	0.3964
14	4	10	0.000551	0.000125	0.0202	0.0000019	0.0000035	0.0000023	0.1422
14	5	11	0.000858	0.000283	0.1206	0.0000018	0.0000008	0.0000003	0.3473
14	6	19	0.000923	0.000282	0.1796	0.0000016	0.0000004	0.0000005	0.4237
14	7	12	0.000367	0.000055	0.1344	0.0000017	0.0000004	0.0000004	0.3666
15	4	11	0.000361	0.000054	0.0071	0.0000018	0.0000021	0.0000009	0.0843

En iyi ağ mimarisini elde edebilmek amacıyla, hibrit değişken ile oluşturulan ağlar deneme yanılma yapılarak elde edilmeye çalışılmıştır. 9 nöron ile 15 nöron arasında ve 2 gecikmeden 7 gecikmeye kadar farklı denemeler yapılmış ve toplamda 42 ağ mimarisi oluşturulmuştur. Kendi aralarında (örneğin, 9 nöron 2 gecikme, 9 nöron 3 gecikme, ...) ve diğer ağlar ile (örneğin, 9 nöron 4 gecikme, 12 nöron 5 gecikme,...) şeklinde değerlendirilmiştir. Karşılaştırma kriteri olarak MSE değeri dikkate alınmıştır.

Tablo-18'e göre, en küçük MSE değeri 0.00000168 olarak hesaplanan 9 nöron ve 4 gecikmeye sahip ağ olmuştur. Ağ, en küçük MSE değerine ulaşıncaya kadar 15 iterasyon gerçekleştirmiştir. Bu ağ mimarilerinde dikkat çeken bir unsur ise R ve R^2 değerlerinin


küçük çıkmasıdır. Bu durumun en önemli nedeni ise ARCH-YSA hibrit modeli ile oynaklığı daha iyi tahmin edebilmesi amaçlandığı için oynaklığa neden olan bölgelerin belirli alanlarda kümelenmesidir. Elde edilen bu mimarinin performansı Şekil-24'deki gibidir.

Şekil-24: 9 Nöron ve 4 Gecikmeli Ağın Performansı



Çeşitli denemeler ile elde edilen ARCH-YSA mimarisi, toplamda 15 iterasyon ile işlemi gerçekleştirmiş ve MSE değerini en küçükleyen değer olan 0.000001107 değeri ile 9. iterasyonda ulaşmıştır. Eğitim, test ve doğrulama eğrileri, 9 nöron ve 4 gecikme ile elde edilen bu ağın genelleme yeteneğinin iyi olduğunu göstermektedir. Veri kümelerinin regresyon performansları Şekil-25'deki gibidir:


Şekil-25: Veri Kümelerinin Regresyon Performansları



Elde edilen sonuçlar incelendiğinde hepsi olarak belirtilen veri kümesine ait regresyon sonucuna göre, hedef değişkenin, çıktı değişkenini açıklama düzeyi çok düşük olduğu gözlemlenmektedir (~%12). Benzer şekilde, eğitim veri kümesinin açıklama performansı da düşük çıkmıştır. Test kümesi için ayrılan veri kümesinin açıklama düzeyi, diğer sonuçlara göre oldukça yüksek çıkmıştır (~ %74). Ayrıca, doğrulama veri kümeleri ile hedef değişkeni arasındaki ilişkinin negatif olduğu sonucu grafiklerde gösterilmiştir. Ancak, daha önce de belirtildiği üzere oynaklığın YSA ile tahmin edilmesi ve gözlem değerlerinin bölgesel kümelenmelerin varlığı ARCH-YSA'nin doğrusal olmaması, hibrit ağın oynaklığı belirlemede başarılı olduğunu göstermektedir.

Eğitim, test ve doğrulama veri kümelerinin hata terimine tepkisine ilişkin grafik Şekil-26'deki gibi elde edilmiştir.

Şekil-26: Zaman Serisine Çıktının Tepkisi



Elektrik talebi değişkenine ilişkin zaman serisi analizi yöntemlerinden biri olan koşullu değişen varyans modeli uygulanmış ve elde edilen sonuçlar ile hibrit yöntem oluşturulmuştur. Şekil-26'deki tepki grafiğinde, hibrit yöntem, YSA ile tahmini sonucunda elde edilen bulgular, ilgili değişkenine olan tepkiyi göstermektedir. Şekil incelendiğinde, 2008 dönemi ile özellikle de 2019 döneminde gerçekleşen oynaklık, hibrit değişken ve hibrit yöntem ile başarılı bir şekilde tahmin edildiği, tepki grafiğine de

yansımıştır. Özellikle eğitim ve test veri kümeleri COVID döneminde gerçekleşen elektrik talebindeki oynaklığı doğruya yakın tahmin ettiği ve ağın genelleme yeteneğinin güçlü olduğu bulgusuna ulaşılmıştır.

3.6. TAHMİN EDİLEN MODELLERİN PERFORMANSLARININ DEĞERLEDİRİLMESİ

Elektrik talebinin tahminini gerçekleştirebilmek için üç farklı yapıda model ve bir de hibrit yöntem olmak üzere, toplamda dört tahmin modeli ile çalışılmıştır. Karşılaştırma ve değerlendirme kriteri olarak aşağıdaki eşitlikler kullanılmıştır:

$$\text{Ortalama Hata Kare: MSE} = \frac{1}{n} \sum (Y_t - \hat{Y}_t)^2$$

$$\text{Ortalama Hata Kareleri Kökü: RMSE} = \sqrt{\frac{1}{n} \sum (Y_t - \hat{Y}_t)^2} \text{ veya } \sqrt{MSE}$$

$$\text{Ortalama Mutlak Yüzde Hata: MAPE} = \frac{100}{n} \sum \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|$$

$$\text{Ortalama Mutlak Sapma veya Ortalama Mutlak Hata: MAD} = \text{MAE} = \frac{1}{n} \sum |Y_t - \hat{Y}_t|$$

$$\text{Theil U Eşitsizlik Katsayısı: } U_1 = \frac{\sqrt{\frac{\sum (\hat{Y}_t - Y_t)^2}{n}}}{\sqrt{\frac{\hat{Y}_t^2}{n} + \frac{Y_t^2}{n}}}$$

Yukarıdaki eşitliklerde; Y_t gerçek değeri; \hat{Y}_t tahmin edilen değeri ve n ise gözlem sayısını göstermektedir. RMSE ve MAE veya MAD tahmin hatası, bağımlı değişkenin ölçeğine bağlıdır. Bunlar farklı modeller arasında aynı seriyi karşılaştırmak için göreceli ölçüler olarak kullanılmaktadır (Eviews, 2017, s. 159). Hata değeri ne kadar küçükse; çalışılan modelin, yukarıdaki kriterlere göre öngörü yeteneği o kadar iyi olmaktadır. MAPE ve Theil U istatistikleri ise ölçekte değişmezdir. Theil U eşitsizlik katsayısı, 0 ile 1 arasında bir değer almaktadır. Elde edilen çıktı, sıfır değerine ne kadar yakınsa çalışılan model, mükemmel yakın uyumu göstermektedir.

Buraya kadar tahmin edilen 4 modelin ve bu modellerinin hatalarının performans kriterlerine ilişkin bulgular, karşılaştırma yapmak amacıyla toplu olarak Tablo-19’da özetlenmiştir.

Tablo-19: Tahmin Edilen Modellerin Hatalarının Performans Kriterleri


	MSE	RMSE	MAPE	MAE	Theil U
ARCH	0.0010075	0.0317410	174.84447	0.0241810	0.591866
YSA-NAR	0.0092300	0.0960729	23.529913	0.0233779	0.001533
YSA-Çoklu	0.0014795	0.0384639	0.29142621	0.0233779	0.001942
ARCH-YSA	0.0000017	0.0012948	832.015873	0.0005762	0.511837

Tahmin edilen modellere/mimarilere ait karşılaştırma kriterleri incelendiğinde, dört farklı model için beş farklı değerlendirme yapılmıştır. Bu sonuçlara göre, üç kriterde en iyi performansı sergileyen ARCH-YSA ile oluşturulan mimari olurken, bu mimari için optimum sonucu veren istatistikler ise sırasıyla MSE, RMSE ve MAE’dir. ARCH-YSA için MAPE ve Theil U eşitsizlik katsayısı, diğer modellere göre daha büyük hesaplanmıştır. Bunun yanında, MAPE değeri en küçük hesaplanan model ise YSA-Çoklu modeli/mimarisi olurken, Theil U eşitsizlik katsayısının sıfıra en yakın sonucunu veren model ise YSA-NAR olmuştur. Bu sonuçlara göre, elektrik talep tahmini (öngörü) için YSA-NAR ve YSA-Çoklu mimarilerinin yanında oynaklık tahmini için ise ARCH-YSA ile çalışılacaktır.

3.7. ELEKTRİK TALEBİNİN FARKLI MODELLER İLE TAHMİNİ

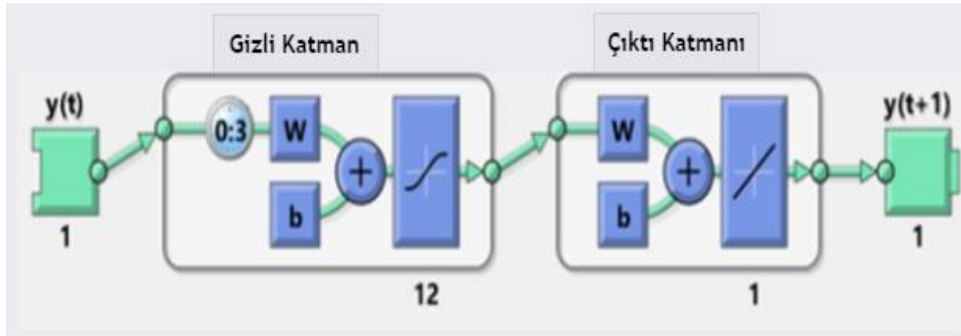
Tez çalışmasına başlarken çalışma dönemi olarak 2007.01–2020.12 dönemi olduğu belirtilmiştir. Ayrıca, çalışma devam ederken gerçekleşmiş olan yeni elektrik talep miktarları resmi makamlarca yayımlanmıştır. Bu nedenle, uygulama döneminin dışında gerçekleşmiş gözlemlerin tahminini ve bu sonuçları karşılaştırma imkanı sunması ile birlikte, henüz resmi olarak açıklanmamış dönemleri tahmin edebilme imkânı sunmaktadır. YSA–NAR ve YSA–Çoklu mimarileri ile gerçekleştirilen tahmin ağlarının görselleri sırası ile Şekil-27 ve Şekil-28’de verilmiştir.

Şekil-27: YSA-NAR Mimarisine İlişkin Kapalı Döngü



Kapalı döngü ile ağ eğitimini tamamlayıp aktivasyon fonksiyonundan başarı ile geçebilen gözlemler, çıktı sonucunu vermeden tekrar ağa girdi olarak verilmektedir. Kapalı döngü ağı, genellikle çok adımlı tahminler gerçekleştirebilmek amacıyla kullanılmaktadır. Kapalı döngü işlevi, geri besleme girişini, çıktı katmanından doğrudan bir bağlantı ile güncellemektedir. Bu işlemden sonra YSA-NAR mimarisinin (ağının) bir adım sonrasının tahmini (öngörüsü) Şekil-28'deki gibidir.

Şekil-28: YSA-NAR Mimarisinin Öngörüsü



Bu kısımda kapalı döngüden elde edilen sonuçlar, ağın bir adım sonrasını tahmin edebilmesi için kullanılmıştır. Elektrik talebi değişkenine ilişkin ağ, 12 nöron ve 4 gecikmeli ile mimari oluşturulmuş olup, bu son aşamada bir gecikmeyi kaydırarak çıkışın bir zaman adımını erken döndürmesi sağlanmaktadır. Bu sayede, minimum gecikme sayısı görselden de görülebileceği üzere, 4 gecikme yerine 3 gecikmeye inmiştir ve bu da çıktıların bir zaman adımını kaymasını sağlamaktadır.

Benzer yöntem, YSA – Çoklu ağ mimarisi için de kullanılmıştır. Bu doğrultuda oluşturulan ve tahmin edilen sonuçlar Tablo-20'de verilmiştir. TEİAŞ'ın 2021 yılı elektrik üretim ve tüketim raporlarından derlenen elektrik talep miktarları sonuçlarına göre, 2021 yılının ilk 10 ayında toplam talep miktarı 273.882,8266 GWh olarak gerçekleşirken, ilk 10 ay ortalaması ise 27.388,28266 GWh'dir.

Tablo-20: Elektrik Talep Tahmini

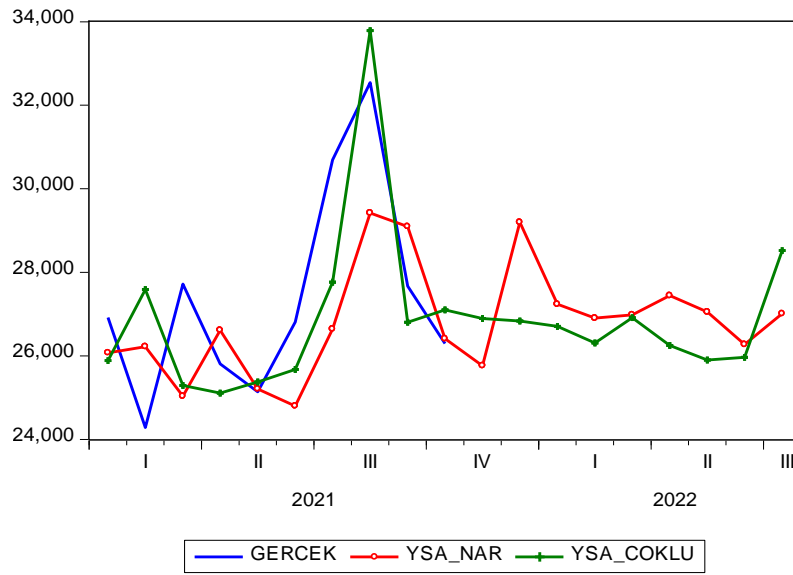
Dönem	Gerçekleşmiş Değerler (GWh)	YSA NAR	YSA Çoklu	Hibrit Volatilité	YSA NAR FARK (%)	YSA ÇOKLU FARK (%)
2021M01	26919.39275	26070.17	25887.78	0.001316488	-3.25744	-3.984938
2021M02	24284.75123	26221.51	27586.02	0.000790376	-.386140	11.96720
2021M03	27721.30125	25033.38	25292.35	0.000927891	-10.7374	-9.60351
2021M04	25806.44206	26614.21	25107.48	0.001117434	3.035120	-2.78388
2021M05	25140.43044	25206.55	25375.66	0.001003466	0.262320	0.926990
2021M06	26811.18769	24798.79	25675.56	0.001129519	-8.114914	-4.42297
2021M07	30694.27276	26640.5	27765.86	0.001048008	-15.21657	-10.5468
2021M08	32541.55348	29419.24	33786.82	0.001415906	10.61315	3.685650
2021M09	27670.17201	29094.91	26804.75	0.001168128	4.896850	-3.228613
2021M10	26293.32291	26409.42	27098.06	0.001117449	0.439590	2.969720
2021M11		25763.45	26895.33	0.000983125		
2021M12		29200.37	26836.01	0.000936953		
2022M01		27236.92	26707.75	0.000959882		
2022M02		26902.97	26308.59	0.001058603		
2022M03		26982.05	26913.71	0.001050075		
2022M04		27443.89	26248.41	0.001034174		
2022M05		27052.62	25901.13	0.001039617		
2022M06		26273.33	25962.50	0.000981589		
2022M07		27009.25	28519.13	0.001036705		

YSA – NAR mimarisi ile 2021 yılının ilk 10 ayına ait toplam elektrik talep miktarı 265.508,6788 GWh olarak tahmin edilirken, tahmin edilen bu dönemin ortalama talep miktarı ise 26.550,866788 GWh'dir. Bu dönemde gerçekleşen toplam elektrik talep miktarından 8.374,148 GWh fazla olurken ortalama fark ise 837,4159 GWh olarak hesaplanmıştır.

VAR modelinde kullanılan; TÜFE, SUE, TUR, ISSIZ değişkenleri bu mimaride girdi değişkeni olarak kullanılmış ve elektrik talep miktarı ise çıktı değişkeni olarak kullanılmış ve tahmin edilmiştir. YSA – Çoklu mimari ile 2021 yılının ilk 10 ayı için toplam elektrik talep miktarı 270.380,3419 GWh olarak tahmin edilmiştir. Benzer şekilde ilk 10 ayın ortalaması ise 27.038,03419 GWh hesaplanmıştır. Gerçekleşen değerler ile karşılaştırıldığında, toplam ilk 10 aylık fark 3.502,485 GWh olarak tahmin edilmiş ve bu döneme ait toplam ortalama fark ise 350,2485 GWh hesaplanmıştır.

Gerçekleşen elektrik talep miktarları ay bazında tahmin edilen değerler ile birlikte değerlendirildiğinde ise YSA – NAR mimarisi, 2021.03 (~%-10.74), 2021.07 (~%-15.22) ve 2021.08 (~%-10.61) aylarında farklar oluşmuştur. Diğer dönemlerde, bu oranlar %10'un altındadır. Benzer şekilde YSA – Çoklu mimarisi ile gerçekleştirilen tahmin sonucunda, 2021.02 (~%11.97) ve 2021.07 (~%-10.55) oranında fark oluşmuştur. Bu iki mimari ile gerçekleştirilen talep tahminleri sonuçlarına göre, doğruya en yakın tahmini YSA – Çoklu mimari ile oluşturulan ağ olmuştur. Bu sonuçlar, Şekil-29'de gösterilmiştir.

Şekil-29: Tahmin Sonuçlarının Karşılaştırılması




YSA ile farklı mimarilerle oluşturulan öngörüler, dönem içerisinde gerçekleşen talep miktarlarına göre, bazı dönemlerde çok iyi uyum sağlarken, bazı dönemlerde bu uyum bozulmuştur. Özellikle, 2020 döneminde dünya genelinde yaşanan COVID-19 etkisini bünyesinde barındıran YSA mimarileri, normalleşme süreçlerine geçilmeye başlanan bu dönemde gerçekleşen değerlere yakın sonuçlar tahmin edilmiştir. 2021 Ocak ayında gerçekleşen talep miktarı, yaklaşık 26.919,39 olarak gerçekleşirken, Şubat ayında talep miktarında düşüş yaşanarak 24.284,75 GWh olmuştur. YSA–NAR mimarisi Ocak ve Şubat dönemlerini oldukça yakın tahmin ederken, YSA-Çoklu mimari ise Şubat dönemini %-11.97 oranında bir fark ile (3.301,27 GWh) tahmin etmiştir. Her iki mimari de yaz aylarındaki elektrik talebindeki artışları doğruya yakın tahmin etmiştir. Ancak YSA-Çoklu mimarisi, YSA – NAR mimarisine göre daha yakın sonuçlar elde etmiştir.

Özellikle, Temmuz 2021 (~%-15.21) ve Ağustos 2021 (~%-10.61) dönemlerinde, YSA – NAR mimarilerinde meydana gelen fark, sırasıyla 4.053,77 ve 3.122,31 GWh olarak hesaplanmıştır. YSA –NAR ve YSA- Çoklu mimarileri 2022 yılı sonuçlara göre, özellikle Haziran 2022 ve Temmuz 2022 aylarında elektrik talebinin artacağı yönündedir.

Elektrik talebine ilişkin koşullu varyans çalışmasında, hibrit modele göre elektrik talebine ilişkin oynaklık tahmininden elde edilen bulguların grafiği Şekil-30'daki gibi gerçekleşmiştir.

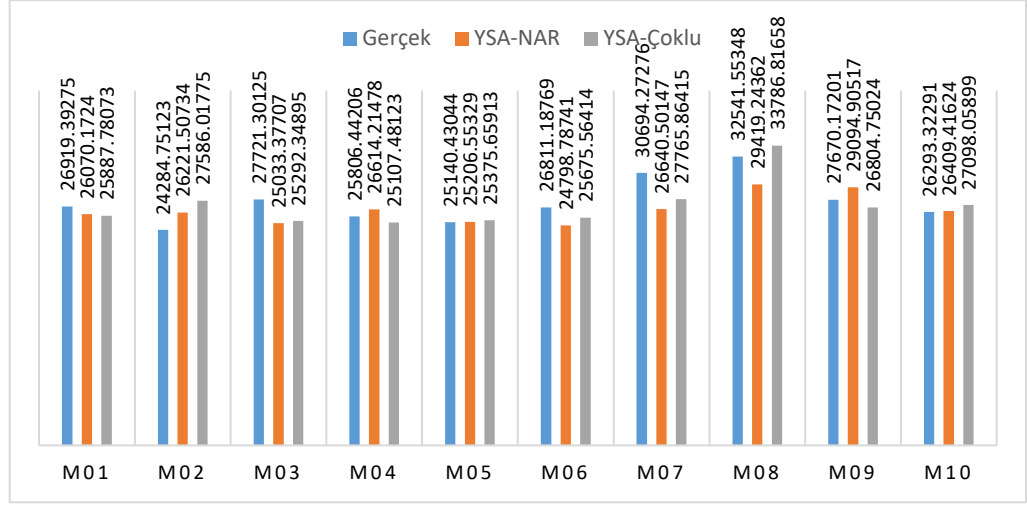
Şekil-30: Hibrit Modele Göre Elektrik Talebinin Oynaklık Tahmini



Diğer taraftan, Tablo-19'dan da görülebileceği üzere, model performanslarının karşılaştırması yapılırken, hibrit yöntem, ARCH modeline göre daha iyi performans sergilemiş ve oynaklığın tahmininde, kriterlere göre daha başarılı sonuçlar vermiştir. Şekil-30'daki oynaklığa ait öngörü dönemleri incelendiğinde, 2021 yılının ilk dönemi ve Mayıs ayı ile birlikte elektrik talebinde dalgalanmaların yaşanacağı tahmin edilmiştir. Özellikle, yaz mevsimine denk gelen bu dönemde, mevsimsel farklılık ve Türkiye'de turizm sektörünün canlanması ile ülkeye gelen turist sayılarının artması (geçici nüfus artışı), elektrik talebinin bu dönemlerinde oynaklığa neden olurken, bu durum öngörü sonuçlarında da kendini göstermiştir.

Nitekim aşağıdaki Şekil-31'de, YSA-NAR ve YSA-Çoklu mimarilerinin tahmini ve TEİAŞ tarafından açıklanmış olan gerçekleşmiş talep miktarlarına ilişkin sonuçlar ve bu sonuçların karşılaştırması verilmiştir:

Şekil-31: Gerçekleşmiş Değerlerin Tahmin Değerleri ile Karşılaştırılması



Şekil-31 incelendiğinde, resmi makamlarca açıklanmış olan reel talep miktarları ile her iki mimari tarafından tahmin edilmiş olan sonuçlar gösterilmektedir. Bu sonuçlara göre, tahmin edilen elektrik talep miktarları birkaç ay dışında genelde yakın sonuçlar vermiştir. Örneğin, 2021M05 ayında gerçek değer ile tahmin edilen değerler arasında fark her iki tahmin sonucunda da %1'in altında iken; YSA-NAR mimarisi, 2021M07 ayında, fark %-15.22 olarak hesaplanmıştır. Benzer şekilde, YSA-Çoklu mimarisi ile yapılan tahmin sonucunda en yüksek fark %-11.97 ile 2021m02 dönemi olarak hesaplanmıştır. Tablo-21'de ise bu iki mimariye ait tahmin karşılaştırma performansları sunulmuştur.


Tablo-21: Tahmin Mimarilerinin Karşılaştırılması

	MSE	RMSE	MAPE	MAE
YSA-NAR	4462898	2112.557	639.5946	1707.710
YSA-Çoklu	3121873	1766.882	541.2023	1467.547

Tablo-21'deki sonuçlara göre, tahmin performansı en iyi olan mimari YSA-Çoklu mimari ile oluşturulan ağdır. Bu mimarinin ise en doğru tahmin ettiği dönem %0.92 fark ile Mayıs 2021 olurken en kötü tahmin ettiği dönem ise %11.97'lik fark ile Şubat 2021 olmuştur.

Bir başka karşılaştırma ise YSA-NAR mimarisi ile YSA-Çoklu mimarinin tahmin (forecast) dönemlerinin karşılaştırılmasıdır. Bu tahmin dönemi ise 2021M11 ile 2022M07 dönemlerini kapsamaktadır. Elde edilen tahminler Şekil-32'de gösterilmiştir:


Şekil-32: YSA-NAR ve YSA-Çoklu Tahmin Karşılaştırılması



Her iki mimarinin tahmin sonuçları karşılaştırıldığında ise, 2022M03 dönemini birbirlerine yakın değerlerde tahmin ettikleri gözlemlenirken, en fazla fark ise YSA-NAR ayında 2021M12 dönemi; YSA-Çoklu ayında ise 2022M07 dönemi olarak hesaplanmıştır. YSA- NAR mimarisinde, bir önceki aya göre elektrik talebinde artış yaşanacağı dönem 2022M04 ve 2022M07 ayları olarak gözlemlenirken, YSA-Çoklu mimaride ise, 2022M03 dönemi ve 2022M07 aylarında, bir önceki aya göre elektrik talebinde artış olacağı yönünde sonuca ulaşılmıştır.

Elektrik talebindeki oynaklığın tahmininden daha iyi sonuçlar elde edebilmek amacıyla, hibrit yöntem uygulaması gerçekleştirilmiştir. Hibrit yöntem ile elde edilen oynaklık tahmin sonuçları Şekil-30'de gösterilmiştir. Bu sonuçlara göre ise 2022m01 döneminden 2022M02 dönemine geçerken elektrik talebinde artış olacağı ve bu artışın 2022M05 dönemine kadar azalarak devam edeceği tahmin edilirken, 2022M06 döneminden 2022M07 dönemine geçişte ise talebin tekrar artacağı yönünde olacağı sonucuna ulaşılmıştır.

Şekil-33: Hibrit Oynaklık Tahmini (Forecast)



Hibrit yöntem ile elde edilen oynaklık tahmini ile YSA-Çoklu mimari ile elde edilen tahmin sonuçlarındaki talep hareketliliği benzerlik göstermektedir. Dolayısıyla, elektrik talebi tahmininde oynaklık tahmini ile YSA-Çoklu tahmin sonuçları birbirlerine paralellik göstermektedir.

SONUÇ ve DEĞERLENDİRME

Elektrik; nüfus artışı, sanayileşme ve teknolojik gelişmeler ile birlikte, doğada varlığının keşfi ve gündelik yaşamda elverişli kullanımının icadına ek olarak, sürdürülebilir hayatın vazgeçilmez unsurudur. Elektrik, aynı zamanda ekonomik ve sosyal hayatın önemli bir parçası olurken, yaşam kalitesinin artırılmasında önemli bir bileşen ve ülkelerin gelişmişlik düzeylerinin büyük bir paydaşı olan ikincil enerji kaynağı olarak stratejik öneme sahiptir.

Elektrik enerjisinin, doğada var olan diğer enerji türlerinden pek çok yönden farklılıkları bulunmaktadır. Elektrik enerjisinin diğer enerji türlerinden en belirgin özelliği ve farklılığı ise günümüz teknolojik gelişmelerine rağmen, depolanamaması veya stoklanamamasıdır. Bu yüzden, üretim ve tüketiminin planlı ve belirli periyotlarda, gerek ülkelerin enerji planlamalarında, gerekse dağıtım ve iletim şirketlerinin enerji sürekliliğini sağlayabilmesi için kaçınılmaz olarak tahmin çalışmaları yapmalarını ve bu çalışmaların ise her dönem güncellemelerini gerekli kılmıştır.

Kısa, orta ve uzun dönemli elektrik tahmin çalışmaları, ekonomik büyüme ve ülkelerin kalkınması için önem arz etmektedir. Nitekim, günlük hayatın önemli bir parçası olan elektrik, kıt bir kaynaktır. Ekonomi teorisi ise kıt kaynakların en iyi kullanımına, diğer bir deyişle, ekonomik verimliliğe dayanmaktadır. Tahmin çalışmalarının ve sonuçlarının, sapmasız ve tutarlı olabilmesi için hem kurum ve kuruluşlar hem de akademik çevreler, bu konuda sürekli katkı sunmaya çalışmaktadır. Dolayısıyla, ülkelerin gelişmişlik düzeyine ulaşabilmeleri için özellikle geliştirmekte olan ülkelerin, elektrik arz-talep dengelerini korumaları ve kuşkusuz bu dengeleri doğruya yakın tahmin edebilmeleri gerekliliği, elektrik tahmini çalışmalarının her dönem önemli olmasını sağlamıştır.

Elektrik talep tahmini konusunda yapılan çalışmalar gerek çok komplike yapılar gerekse çok daha kolay yöntemler olsun, kısa dönemde (saat, gün ve hafta) benzer çıktıları üretecektir. Uzun dönemli (yıllık) tahminler ise gerçeğe yakın sonuçlar üretmeyebilir. Bunun nedeni, uzun dönemli tahminlerde kullanılan değişkenlerin parametrelerinde yıldan yıla farklılıklar olabilir. Bu duruma en güncel örnek ise 2020 yılında meydana gelen COVID-19 pandemisi gösterilebilir. Orta dönemli (aylık, çeyrek

yıllık) çalışmalar ise, yukarıda sayılan durumlara nazaran daha sağlıklı sonuçlar vermektedir. Ancak orta dönemli tahminlerin ise arz yetersizliği ve olası elektrik ithalatında yaşanabilecek aksaklık durumunda, yatırımların yapılması için yeterli zamanı sağlamayabilir.

Elektrik talep tahmini çalışmalarında, belirsizliğin tahmini için farklı senaryolar ya da farklı model ve değişkenler ile en iyi sonuca ulaşılmaya çalışılmaktadır. Dolayısıyla, elektrik talebi veya talep edilen miktarı, birçok faktörden etkilenebilmektedir. Elektrik talep tahminlerinin sürekli güncellenmesi ve modellerde kullanılacak değişkenlerin çeşitliliği; özellikle, talep miktarı planlamaları gerçekleştirilirken sabit içsel değişkenler yerine, değişim eğiliminde olan içsel değişkenlerin güncellenmesi ile hata payının en küçük değerine ulaşmasına ve dolayısıyla, daha doğru tahminler elde edilebilmesine olanak sağlar.

Elektrik talep tahmini gerçekleştirilen bu çalışmada, mevsim etkisinden arındırılmış aylık elektrik talep miktarına ilişkin kullanılan model ve mimariler şu şekildedir: Koşullu değişen varyans (ARCH) modeli, vektör otoregresif (VAR) model; tek değişkenli doğrusal olmayan YSA (YSA-NAR), benzer yapıda çok değişkenli YSA (YSA-Çoklu) ve son olarak hibrit yöntem ile çalışılmıştır. Çalışılan bu modeller ile elektriktik talebindeki oynaklığı tahmin etmek için ARCH modelleri ile çalışılırken, vektör otoregresif model ile elektrik talebine etki eden ekonomik ve sosyal içsel değişkenler etkileri belirlenmeye çalışılmıştır. Bunun yanında, doğrusallık ve durağanlık varsayımlarının geçerli olmasına gerek olmadan, tahmin etme ve genelleme yeteneği yüksek olan, tek ve çok değişkenli YSA ile tahmin mimarileri oluşturulmuş; nihayetinde koşullu değişen varyans modelinin öngördüğü oynaklığı daha iyi tahmin edebilmek amacıyla, hibrit yöntem olmak üzere beş farklı yöntem ile çalışılmıştır.

Çalışmada, ilk olarak koşullu değişen varyans uygulaması gerçekleştirilmiştir. Ele alınan çalışma döneminde, elektrik talebi değişkeninde ARCH etkisi belirlenmiştir. Bu sonuç, elektrik talebine ait seride, önemli artma veya azalma olması nedeniyle, hata teriminin de bu hareketlerden etkilenecek sabit varyans özelliğini yitirmesine yol açmıştır. Dolayısıyla, bu sonuç elektrik talebinde simetrik bir etkiyi göstermektedir. Diğer bir deyişle, ARCH(1) modeli, pozitif ve negatif şokların, önceki dönem şoklarının kareleri ile ilişkili olduğunu ve oynaklık ise bu ilişkiden aynı şekilde etkilendiğini göstermektedir.

Çalışma modelinde ARCH katsayısı, ($\alpha_1 = 0.55$) olarak hesaplanmıştır. Dönemsel etkiler nedeniyle, oynaklığın etki süresinin çok uzun olmayacağını, ancak bir oynaklığa neden olduğu sonucuna varılmıştır.

Çalışmada, diğer uygulama modeli olarak, VAR modeli kullanılmıştır. Bu model ile çalışılmasının temel amaçlarından biri de elektrik talebini etkileyen içsel değişkenleri belirlemektir. Literatür doğrultusunda belirlenen değişkenlerin yanında, Türkiye'ye gelen turist sayısı değişkeni de analize dahil edilmiştir. Bu değişkenin modele dahil edilmesinin temel nedeni, mevsimsel göçü temsil etmesidir. Dolayısıyla, ele alınan değişkenler ile yapılan varyans ayrıştırması sonucunda, elektrik talep değişkeninin varyansındaki değişimlerin, ortalama %9.37'sinin ülkeye gelen turist sayısı tarafından açıklandığı bulunmuştur. Benzer sonuçlar, hem Granger nedensellik testi sonuçlarında hem de Toda Yamamoto nedensellik testi sonuçlarında elde edilmiş olup bu bulguları destekler nitelikte olmuştur. Her iki nedensellik testi sonucunda da ülkeye gelen turist sayısından elektrik talebine tek yönlü nedensellik ilişkisi belirlenmiştir.

VAR modelinde çalışılan bir diğer önemli değişken ise işsizlik değişkenidir. Varyans ayrıştırması analizi sonucunda, elektrik talebinin varyansındaki değişimlerin ortalama %21.27'sini açıkladığı bulunmuştur. Benzer şekilde, işsizlik değişkeninin varyansındaki değişimlerin ortalama %10.80'inin elektrik talep değişkeni tarafından açıklandığı belirlenmiştir. Ayrıca, elektrik talep değişkeni ile işsizlik değişkeni arasında çift yönlü nedensellik hem Granger nedensellik testi ile hem de Toda Yamamoto nedensellik testi sonuçları ile elde edilmiş olup, işsizlik değişkeninin talep değişkeni için önemli bir değişken olduğu sonucuna ulaşılmıştır.

Çalışmada kullanılan değişkenler, düzey değerlerinde durağan olmadıkları için birinci farkları alınarak durağan hale getirilmiştir. Ancak sanayi üretim endeksi değişkeni birinci farkı alınmasına rağmen %1 anlamlılık düzeyinde durağan dışı bir yapı sergilemiştir. Bu nedenle, VAR modeli için uygun gecikme düzeyi belirlendikten sonra, aynı dereceden bütünleşik yapı gerektiren Granger nedensellik testi ile en yüksek (d_{max}) bütünleşme (fark alma) derecesi ile nedensellik testine imkan sunan Toda Yamamoto nedensellik testi olmak üzere, iki nedensellik testi gerçekleştirilmiştir. Nitekim, bu belirgin farklı özellik, sanayi üretim endeksi değişkeninin Granger nedensellik testinde, anlamlılık düzeylerinin hiçbir düzeyinde herhangi bir nedensel ilişkinin olmadığı ortaya

konmuştur. Bunun yanında, Toda Yamamoto nedensellik testinde, sanayi üretim endeksinden elektrik talebine tek yönlü nedensellik ilişkisinin olduğu bulgusuna ulaşılmıştır. Diğer taraftan, bu sonuca paralel bir başka analiz ise varyans ayrıştırması ile elde edilmiştir. Varyans ayrıştırması sonucuna göre, sanayi üretim endeksinin varyansındaki değişimlerin ortalama %39.84'ünün kendisi tarafından açıklandığı, elektrik talep değişkeninin ise, sanayi üretim endeksinin varyansındaki değişimlerin ortalama %21.63'ünü açıkladığı bulunmuştur. Bu sonuca paralel olarak elde edilen sonuç, etki tepki grafiklerinde de gözlemlenmiştir. İlk dönem elektrik talep değişkenine verilen yaklaşık %4'lük bir şok, sanayi üretim endeksi değişkenine %95 güven düzeyinde anlamlı tepkide bulunmuş ve bu tepki pozitif olarak gerçekleşmiştir. VAR modelinde kullanılan bir diğer değişken ise tüketici fiyat endeksi değişkenidir. Bu değişken, VAR modeli ile yapılan diğer birçok test ve analizler sonucunda, elektrik talebi ile ilişkisi çok sınırlı kalmıştır. Ayrıca her iki nedensellik testi sonucunda da tüm anlamlılık düzeylerinde ilişki bulunamamıştır. Bu da elektrik fiyatlarındaki artışın elektrik talebi üzerinde herhangi bir etkiye neden olmadığı şeklinde yorumlanabilir.

Yapay sinir ağları, zaman serisi analizinde olduğu gibi, birtakım varsayımların yerine getirilmesine gerek kalmadan, analiz yapabilme imkanı sunmaktadır. Bu sayede, YSA ile yapılan çalışmalarda herhangi bir bilgi kaybı yaşanmamaktadır. Dolayısıyla, analiz edilecek değişkende tüm bilgiler mevcuttur. YSA'nın en belirgin özelliği ise dış dünyadan gelen bilgileri öğrenebilmesi ve bu öğrendiği bilgileri genelleyebilmesidir. Bu özellik ise YSA ile farklı mimari yapıları deneyerek, doğrusal olmayan problemlerin çözümüne olanak sağlamaktadır.

Çalışmada farklı teknikler ile elektrik talebi tahmin edilmeye çalışılmıştır. Bu doğrultuda, ARCH, VAR, YSA-NAR, YSA-Çoklu model ve mimarileri ile elde edilen bulgulara göre, en küçük değerlere sahip hibrit yöntem olurken, YSA-NAR ve YSA-Çoklu mimarileri de diğer farklı karşılaştırma kriterlerine göre daha küçük değerler hesaplanarak elektrik talep tahmininde en iyi modeller olduğunun sonucuna ulaşılmıştır.

Çalışmanın temel amacı olan elektrik talep tahminini, hem dönem içi gerçekleşmiş değerleri olan 2021.01-2021.10 dönemlerini tahmin edip karşılaştırmak hem de kullanılan model ve/veya mimariler ile geleceğe yönelik 2021.11-2022.07 dönemlerinin tahmin değerlerini belirlemektir. Bu amaca yönelik elde edilen sonuçlara

göre, YSA-Çoklu mimarisi hem dönem içi hem de geleceğe yönelik tahminde en iyi sonuçları vermiştir. Dolayısıyla, tek değişkenli ve çok değişkenli olmak üzere, model ile çalışılarak hangisinin daha iyi performansa sahip olduğunun belirlenmesidir. Elde edilen sonuçlar, çalışma dönemi ve frekansına göre, elektrik talep tahmininde YSA-Çoklu ağ mimarisi diğer yöntemlere göre, en iyi performansa sahip olduğunun sonucuna ulaşılmıştır.

Bu çalışmanın araştırma sorularından bir diğeri de elektrik talebine etki eden içsel değişkenler, literatürde çalışılan değişkenlere ilave olarak farklı değişkenleri VAR modeli ile belirlemeye çalışmak olmuştur. Dolayısıyla bu amaca yönelik olarak, Tüketici Fiyat Endeksi (TUFE), Sanayi Üretim Endeksi (SUE), ülkeye gelen turist (TUR) ve İşsizlik (ISSIZ) değişkenleri ile VAR modeli oluşturulmuş ve ISSIZ değişkeni ile TUR değişkeninin, elektrik talebine etki eden önemli değişkenler olduğu bulgusuna ulaşılmıştır. Ayrıca, TALEP değişkeninden SUE değişkenine etki eden bir diğer önemli değişken olduğu Toda-Yamamoto nedensellik sınaması ile belirlenmiştir.

ARCH modeli ile elektrik talep miktarında oynaklık tespit edilmiş ve bu etki ARCH(1) modeli ile giderildiği gözlemlenmiştir. Benzer şekilde oynaklığın daha iyi tahmin edilebilmesi amacıyla hibrit yöntem geliştirilmiş ve bu yöntemin, oynaklığı daha iyi tahmin ettiği sonucuna ulaşılmıştır. Aynı zamanda hibrit yöntem ile oluşturulan uygulama diğer yöntemlere göre diğer en iyi performans sergileyen model olmuştur.

KAYNAKÇA

- Abu-Mostafa, Y. S. (2001). Financial model calibration using consistency hints. *IEEE Transactions on Neural Networks*, 12(4), 791–808. <https://doi.org/10.1109/72.935092>
- Akkaya, G. (2005). *Yapay Sinir Ağları ve Tarım Alanındaki Uygulamaları*. 38(2), 195–202.
- Akpınar, H. (1994). Yapay Sinir Ağları Gelişimi ve Yapılanların İncelenmesi. *İstanbul Üniversitesi İşletme Fakültesi Dergisi*, 23(1), 41–78.
- Babu, C. N., & Reddy, B. E. (2014). A moving-average filter based hybrid ARIMA-ANN model for forecasting time series data. *Applied Soft Computing Journal*, 23, 27–38. <https://doi.org/10.1016/j.asoc.2014.05.028>
- Barışık, S., & Kesikoğlu, F. (2003). Türkiye’de Bütçe Açıklarının Temel Makroekonomik Değişkenler Üzerine Etkisi [1981-2003 VAR, Etki-Tepki Analizi, Varyans Ayrıştırması]. *Ankara Üniversitesi SBF Dergisi*, 61(4), 59–82.
- Battiti, R. (1992). 1St-Order and 2Nd-Order Methods for Learning - Between Steepest Descent and Newton Method. *Neural Computation*, 4(2), 141–166. https://www-mitpressjournals-org.ezlibrary.technion.ac.il/doi/pdf/10.1162/neco.1992.4.2.141%0A/full_record.do?product=UA&search_mode=GeneralSearch&qid=1&SID=3D@iPO@38LHkOOj7dE7&page=1&doc=2&colname=WOS
- Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*, 31, 307–327. <https://doi.org/10.1109/TNN.2007.902962>
- Box, G. E. P., Jenkins, G. M., & Reinsel, G. C. (1967). Time series analysis. In *Water Resources Research* (4th ed., Vol. 3, Issue 3). Wiley. <https://doi.org/10.1029/WR003i003p00817>
- Brooks, C. (2008). Introductory Econometrics for Finance. In *Cambridge University Press*.
- Carpenter, G. A., & Grossberg, S. (1987). ART2: self-organization of stable category recognition codes for analog. *Applied Optics*, 26(23), 4919–4930.

- Cho, J. R., Shin, S. W., & Yoo, W. S. (2005). Crown shape optimization for enhancing tire wear performance by ANN. *Computers and Structures*, 83(12–13), 920–933. <https://doi.org/10.1016/j.compstruc.2004.11.011>
- da Silva, I. N., Hernane Spatti, D., Andrade Flauzino, R., Liboni, L. H. B., & dos Reis Alves, S. F. (2017). Artificial Neural Networks Apractical Course. In *Folia Pharmacologica Japonica*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-43162-8>
- Dan Foresee, F., & Hagan, M. T. (1997). Gauss-Newton approximation to Bayesian learning. *Proceedings of International Conference on Neural Networks (ICNN'97)*, 3, 1930–1935. <https://doi.org/10.1109/ICNN.1997.614194>
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the Estimators for Autoregressive Time Series With a Unit Root. *Journal of the American Statistical Association*, 74(366), 427. <https://doi.org/10.2307/2286348>
- Dreyfus, G. (2005). Neural networks: Methodology and applications. In *Neural Networks: Methodology and Applications*. <https://doi.org/10.1007/3-540-28847-3>
- Duranton, M. (1996). Image processing by neural networks. *IEEE Micro*, 16(5), 12–19. <https://doi.org/10.1109/40.540076>
- Durllauf, S. N., & Blume, L. E. (2010). Macroeconometrics and Time Series Analysis. In S. N. Durlauf & L. E. Blume (Eds.), *Macroeconometrics and Time Series Analysis*. Palgrave Macmillan UK. <https://doi.org/10.1057/9780230280830>
- Enders, W. (2014). Applied Econometric Time Series. In *Angewandte Chemie International Edition*, 6(11), 951–952. (4th ed.). Wiley.
- Engle, R. F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, 50(4), 987–1007. <https://doi.org/10.2307/1912773>
- Ertel, W. (2017). Introduction to Artificial Intelligence (Undergraduate Topics in Computer Science). In *Springer (Second Edi)*. Springer.
- Eviews. (2017). *Eviews 10 User's Guide II*. HS Global Inc.
- Farley, B. G., & Clark, W. A. (1954). Simulation of self-organizing systems by digital

- computer. *Transactions of the IRE Professional Group on Information Theory*, 4(4), 76–84. <https://doi.org/10.1109/TIT.1954.1057468>
- Fukumi, M., Omatu, S., & Nishikawa, Y. (1997). Rotation-invariant neural pattern recognition system estimating a rotation angle. *IEEE Transactions on Neural Networks*, 8(3), 568–581. <https://doi.org/10.1109/72.572096>
- Gün, M. (2020). Döviz Kuru Volatilitesinin Doğrusal ve Doğrusal Olmayan Yöntemler ile İncelenmesi. *İstanbul Ticaret Üniversitesi Sosyal Bilimler Dergisi*, 39(2020/3), 952–974. <https://doi.org/10.46928/iticusbe.763980>
- Hagan, M. T., & Menhaj, M. B. (1994). Training Feedforward Networks with the Marquardt Algorithm. *IEEE Transactions on Neural Networks*, 5(6), 989–993. <https://doi.org/10.1109/72.329697>
- Hamilton, J. D. (1994). *Time Series Analysis*. Princeton University Press Princeton.
- Haykin, S. (2010). Neural Networks and Learning Machines. In *Prentice Hall* (Third Edit). Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-02535-8>
- Hebb, D. . (1949). The Organization of Behavior; A Neuropsychological Theory. In *The American Journal of Psychology*. <https://doi.org/10.2307/1418888>
- Hinton, G. E., & Sejnowski, T. J. (1986). Learning and Relearning in Boltzmann Machines. In *International Journal of Engineering Science* (Vol. 20, Issue 1, pp. 282–317). The MIT Press. [https://doi.org/10.1016/0020-7225\(82\)90080-5](https://doi.org/10.1016/0020-7225(82)90080-5)
- Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences of the United States of America*, 79(8), 2554–2558. <https://doi.org/10.1073/pnas.79.8.2554>
- Hopfield, J. J. (1984). Neurons with Graded Response Have Collective. *Biophysics*, 81(May), 3088–3092.
- Hudson Beale, M., B.Hagan, M. T., & and Demuth, H. B. (2017). Neural Network Toolbox™ User’s Guide R2017a. In *MathWorks*. The MathWorks, Inc.
- Hyup Roh, T. (2007). Forecasting the volatility of stock price index. *Expert Systems with Applications*, 33(4), 916–922. <https://doi.org/10.1016/j.eswa.2006.08.001>
- Işildak, S. (2021). Garch Modellerle Oynaklık Tahmini: Bitcoin Örneği. *Journal of*

Business and Trade (JOINBAT), 2(2), 49–61.

Işığışok, E. (1994). *Zaman Serilerinde Nedensellik Çözümlemesi*. Uludağ Üniversitesi Basımevi.

Işığışok, E. (1999). Türkiye’de Enflasyonun Varyansının ARCH ve GARCH Modelleri ile Tahmini. *Uludağ Üniversitesi İİBF Dergisi*, 17(2), 1–17.

Jin, X., Cheu, R. L., & Srinivasan, D. (2002). Development and adaptation of constructive probabilistic neural network in freeway incident detection. *Transportation Research Part C: Emerging Technologies*, 10(2), 121–147. [https://doi.org/10.1016/S0968-090X\(01\)00007-9](https://doi.org/10.1016/S0968-090X(01)00007-9)

Kamruzzaman, J., Begg, R. K., & Sarker, R. A. (2006). Artificial neural networks in finance and manufacturing. In *Artificial Neural Networks in Finance and Manufacturing*. <https://doi.org/10.4018/978-1-59140-670-9>

Keating, J. W. (1990). Identifying VAR models under rational expectations. *Journal of Monetary Economics*, 25(3), 453–476. [https://doi.org/10.1016/0304-3932\(90\)90063-A](https://doi.org/10.1016/0304-3932(90)90063-A)

Khashei, M., & Bijari, M. (2010). An artificial neural network (p, d, q) model for timeseries forecasting. *Expert Systems with Applications*, 37(1), 479–489. <https://doi.org/10.1016/j.eswa.2009.05.044>

Kim, P. (2017). Matlab deep learning: With machine learning, neural networks and artificial intelligence. In *Apress, New York*. Springer.

Kirchgässner, G., & Wolters, J. (2007). Introduction to modern time series analysis. In *Introduction to Modern Time Series Analysis*. Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-540-73291-4>

Kong, L. X., & Nahavandi, S. (2002). On-line tool condition monitoring and control system in forging processes. *Journal of Materials Processing Technology*, 125–126, 464–470. [https://doi.org/10.1016/S0924-0136\(02\)00367-9](https://doi.org/10.1016/S0924-0136(02)00367-9)

Kumar, V., Leone, R. P., & Gaskins, J. N. (1995). Aggregate and disaggregate sector forecasting using consumer confidence measures. *International Journal of Forecasting*, 11(3), 361–377. [https://doi.org/10.1016/0169-2070\(95\)00594-2](https://doi.org/10.1016/0169-2070(95)00594-2)

- Kwiatkowski, D., Phillips, P. C. B., Schmidt, P., & Shin, Y. (1992). Testing the null hypothesis of stationarity against the alternative of a unit root. How sure are we that economic time series have a unit root? *Journal of Econometrics*, 54(1–3), 159–178. [https://doi.org/10.1016/0304-4076\(92\)90104-Y](https://doi.org/10.1016/0304-4076(92)90104-Y)
- Lutkepohl, H. (1990). Asymptotic Distributions of Impulse Response Functions and Forecast Error Variance Decompositions of Vector Autoregressive Models. *The Review of Economics and Statistics*, 72(1), 116. <https://doi.org/10.2307/2109746>
- Lütkepohl, H. (2005). *New Introduction to Multiple Time Series Analysis*. Springer-Verlag Berlin Heidelberg.
- Lütkepohl, H., & Kratzig, M. (2004). *Applied Times Series* (1st ed.).
- Mamingi, N. (2005). *Theoretical And Empirical Exercises in Econometrics*.
- Marinai, S., Gori, M., & Soda, G. (2005). Artificial neural networks for document analysis and recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(1), 23–35. <https://doi.org/10.1109/TPAMI.2005.4>
- Markham, I. S., & Rakes, T. R. (1998). The effect of sample size and variability of data on the comparative performance of artificial neural networks and regression. *Computers & Operations Research*, 25(4), 251–263. [https://doi.org/10.1016/S0305-0548\(97\)00074-9](https://doi.org/10.1016/S0305-0548(97)00074-9)
- Mehrotra, K., Chilukuri, K. M., & Ranka, S. (1996). *Elements of Artificial Neural Networks*. https://books.google.co.uk/books?id=6d68Y4Wq_R4C&hl=zh-CN&source=gbs_navlinks_s
- Miljøhøj, A. (1985). *The Moment Structure of ARCH Processes*. 12(4), 281–292.
- Mills, T. C. (2019). *Applied Time Series Analysis* (J. S. Bentley (ed.)). Academic Press publications.
- Mills, T. C., & Markellos, R. N. (2008). *The Econometric Modelling of Financial Time Series* (3rd ed.). Cambridge University Press.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2015). *Introduction Time Series Analysis and Forecasting*. Wiley.
- Nargeleçekenler, M. (2004). Euro Kuru Satış Değerindeki Volatilitenin ARCH ve

- GARCH Modelleri ile Tahmini. *İstanbul Üniversitesi İktisat Fakültesi Mecmuası*, 54(2), 153–179.
- Nazeran, H., & Behbehani, K. (2000). Neural Networks in Processing and Analysis of Biomedical Signals. In M. Akay (Ed.), *Nonlinear Biomedical Signal Processing, Fuzzy Logic, Neural Networks, and New Algorithms: Vol. I* (pp. 69–97). <https://doi.org/10.1002/9780470545362.ch4>
- Nelson, D. B. (1991). Conditional Heteroskedasticity in Asset Returns: A New Approach. *Journal Econometrica Society*, 59(2), 347–370.
- Özgen, F. B., & Güloğlu, B. (2004). Türkiye’de İç Borçların İktisadî Etkilerinin VAR Tekniğiyle Analizi. *ODTÜ Gelişme Dergisi*, 31, 93–114.
- Öztemel, E. (2006). Yapay Sinir Ağları. In *Papatya Yayıncılık*. Papatya Yayıncılık.
- Poo, J. R. (2003). Computer-Aided Introduction to Econometrics. In *Computer-Aided Introduction to Econometrics*. Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-55686-9>
- Rachev, S. T., Mittnik, S., Fabozzi, F. J., Focardi, S. M., & Jasic, T. E. O. (2007). *Financial Econometrics*. John Wiley & Sons, Inc.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536. <https://doi.org/10.1038/323533a0>
- Shumway, R. H., & Stoffer, D. S. (2011). *Time Series Analysis and Its Applications - With R Examples* (I. O. G. Casella, S. Fienberg (ed.); Third). Springer. <https://www.springer.com/series/417>
- Sims, C. A. (1980). Macroeconomics and Reality. *Econometrica*, 48(1), 1. <https://doi.org/10.2307/1912017>
- Suppes, P. (1970). *A Probabilistic Theory of Causality*. North-Holland Pub. Co.
- Tarı, P. D. R., & Bozkurt, Y. D. D. H. (2006). Türkiye’de İstikrarsız Büyümenin VAR Modelleri ile Analizi (1991.1-2004.3). *Ekonometri ve İstatistik E-Dergisi*, 4, 12–28. <https://dergipark.org.tr/iuekois/issue/8986/112061>
- Toda, H. Y., & Yamamoto, T. (1995). Statistical inference in vector autoregressions with

- possibly integrated processes. *Journal of Econometrics*, 66(1–2), 225–250. [https://doi.org/10.1016/0304-4076\(94\)01616-8](https://doi.org/10.1016/0304-4076(94)01616-8)
- Uğurlu, E., & Cihangir, Ç. K. (2017). Altın Piyasasında Asimetrik Oynaklık: Türkiye İçin Model Önerisi. *Journal of Business Research - Turk*, 3(9), 284–299. <https://doi.org/10.20491/isarder.2017.300>
- Vural, B. B. (2007). *Yapay Sinir Ağları İle Finansal Tahmin*. Ankara Üniversitesi.
- Wang, Z., Liu, Y., & Griffin, P. J. (2000). A combined ANN and expert system tool for transformer fault diagnosis. *2000 IEEE Power Engineering Society, Conference Proceedings*, 2(c), 1261–1269. <https://doi.org/10.1109/PESW.2000.850127>
- Weist, A. A. (1986). Asymptotic Theory for ARCH Models: Estimation and Testing. *Econometric Theory*, 2, 107–131.
- Widrow, B., & Hoff, M. E. (1960). Adaptive switching circuits. *Wescon Conference Record, Record Par*, 96–104.
- Zhang, P. G. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0)

ÖZGEÇMİŞ

ÖZGEÇMİŞ			
Adı-Soyadı	Savaş TARKUN		
Doğum Yeri ve Yılı			
Bildiği Yabancı Diller	İngilizce		
Eğitim Durumu	Başlama- Bitirme Yılı	Kurum Adı	
Lise	1999	2001	Mamak Tuzluca Yır Lisesi
Lisans	2006	2010	Malatya İnönü Üniversitesi
Yüksek Lisans	2011	2015	Muğla Sıtkı Koçman Üniversitesi
Doktora	2019	2023	Bursa Uludağ Üniversitesi
Katıldığı Proje ve Toplantılar	<ul style="list-style-type: none">• Ekonomi Yaz Seminerleri-IX• Fen Bilimleri Araştırma Sempozyumu• 1st International Data Science & Engineering Symposium• 20. Uluslararası Ekonometri, Yöneylem Araştırması ve İstatistik Sempozyumu		
Yayımlar:	<ul style="list-style-type: none">• (2012) Türkiye Ekonomisinde 1990 Sonrası Finansal Krizler ve Probit Model ile Finansal Kriz Öngörüsü• (2014) İşlem Bazlı Manipülasyon Şirketlerinin Vektör Otoregresif Analizi ile İncelenmesi• (2020) Forecasting and technical comparison of inflation Turkey with box-jenkins (ARIMA) models and the artificial neural network• (2023) Prediction of Economic Crisis Period with Logistic Regression Analysis Based on The Trading Volume of Companies in The Stock Exchange Istanbul• (2023) Türkiye’de Covid 19 Döneminde CDS Oynaklığı Üzerinde BIST100 ve VIX Endekslerinin Etkilerinin Simetrik ve Asimetrik Koşullu Değişen Varyans Modelleri ile Belirlenmesi		
İletişim (e-posta):			
	Tarih: İmza: Adı-Soyadı:	Savaş TARKUN	