T.C.
HARRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZİ

DURAĞAN OLMAYAN ZAMAN SERİLERİNDE ALTERNATİF TAHMİN YÖNTEMLERİNİN KARŞILAŞTIRMALI OLARAK İNCELENMESİ

Levent KAYA

TARIM EKONOMİSİ ANABİLİM DALI

ŞANLIURFA
2015

Prof. Dr. Turan BİNİCİ danışmanlığında, Levent KAYA'nın hazırladığı "Durağan Olmayan Zaman Serilerinde Alternatif Tahmin Yöntemlerinin Karşılaştırmalı Olarak İncelenmesi" konulu bu çalışma 16/06/2015 tarihinde aşağıdaki jüri tarafından oy birliği ile Harran Üniversitesi Fen Bilimleri Enstitüsü Tarım Ekonomisi Anabilim Dalı'nda DOKTORA TEZİ olarak kabul edilmiştir.

İmza

Danışman : Prof. Dr. Turan BİNİCİ ……...

Üye : Prof. Dr. Ömer YILMAZ ……...

Üye : Doç. Dr. Mehmet Suphi ÖZÇOMAK ……

Üye : Yrd. Doç. Dr. Tamer IŞGIN ……....

Üye : Yrd. Doç. Dr. Zeki DOĞAN ……

Bu Tezin Tarım Ekonomisi Anabilim Dalında Yapıldığını ve Enstitümüz Kurallarına Göre Düzenlendiğini Onaylarım.

Prof. Dr. Sinan UYANIK
Enstitü Müdürü

Bu Çalışma HÜBAK Tarafından Desteklenmiştir.
Proje No: 13096

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

İÇİNDEKİLER

Sayfa No

ÖZET i
ABSTRACT ii
TEŞEKKÜR iii
ŞEKİLLER DİZİNİ iv
ÇİZELGELER DİZİNİ v
SİMGELER DİZİNİ vi
1. GİRİŞ 1
2. ÖNCEKİ ÇALIŞMALAR 4
3. MATERYAL ve YÖNTEM 10
3.1. Materyal 10
3.1.1. Pamuk 10
3.1.1.1. Pamuğun Tarihçesi 11
3.1.1.2. Pamuğun Kullanım Alanları 12
3.1.1.3. Pamuğun Türkiye İçin Sosyo-Ekonomik Önemi 13
3.1.1.4. Pamuk Ekim Alanları 14
3.1.1.5. Dünya Pamuk Verimleri 15
3.1.1.6. Dünya Pamuk Üretimi 16
3.1.1.7. Dünya Pamuk Tüketimi 17
3.1.1.8. Türkiye Pamuk Üretimi ve Tüketimi 17
3.1.1.9. Dünya Pamuk İthalatı 20
3.1.1.10. Dünya Pamuk İhracatı 21
3.1.1.11. Türkiye'nin Pamuk İhracatı 22
3.1.1.12. Türkiye'nin Pamuk İthalatı 23
3.1.1.13. Dünya ve Türkiye Pamuk Fiyatları 24
3.2. Yöntem 26
3.2.1. Doğal Zekâ 26
3.2.2. Yapay Zekâ 29
3.2.3. Yapay Zekâ ile Doğal Zekânın Karşılaştırılması 29
3.2.4. Yapay Zekânın Amaçları 30
3.2.5. Turing Testi 31
3.2.6. Yapay Zekâ Teknolojileri 32
3.2.6.1. Uzman sistemler 32
3.2.6.2. Genetik Algoritmalar 32
3.2.6.3. Bulanık Mantık 33
3.2.6.4. Yapay Sinir Ağları 33
3.2.7. Beyin 34
3.2.7.1. Beyinin Temel Yapısı 35
3.2.7.2. Biyolojik Sinir Hücresi 36
3.2.8. Yapay Sinir Ağları 38
3.2.8.1. YSA'nın Temel Özellikleri 39
3.2.8.2. YSA'nın Geleneksel İstatistik Yöntemleriyle Ortak ve Farklı Yönleri 42
3.2.8.3. YSA'nın Avantaj ve Dezavantajları 43
3.2.8.4. YSA'nın Uygulama Alanları 46
3.2.8.5. YSA'nın Tarihçesi 49
3.2.8.6. Yapay Sinir Hücresi 52
3.2.8.7. YSA'nın Yapısı ve Temel Elemanları 53
3.2.8.8. YSA'da Öğrenme 58
3.2.8.9. YSA'da Öğrenme Stratejileri 59
3.2.8.10. YSA'da Çevrimiçi ve Çevrimdışı Öğrenme 60
3.2.8.11. YSA'da Öğrenme Kuralları 60
3.2.8.12. Tek Katmanlı YSA Modelleri 62
3.2.8.13 Çok Katmanlı YSA Modelleri 66
3.2.8.14. İleri Beslemeli YSA Modelleri 68

3.2.8.15. Geri Beslemeli YSA Modelleri 69
3.2.8.16. YSA'da Verilerin Normalizasyonu 81
3.2.8.17. YSA'nın Eğitimi ve Testi 83
3.2.8.18. YSA Mimarisinin Tasarımı 84
3.2.8.19. YSA'nın Performans Kriterleri 86
3.2.9. Çoklu Doğrusal Regresyon Modeli 88
3.2.9.1. Regresyon Katsayılarının EKK Yöntemi ile Tahmin Edilmesi 89
3.2.9.2. EKK Yönteminin Varsayımları 93
3.2.9.3. EKK Tahmin Edicilerinin Varyansları ve Standart Hataları 95
3.2.9.4. Belirlilik Katsayısı ve Düzeltilmiş Belirlilik Katsayısı 96
3.2.9.5. Parametrelerin Anlamlılık Testleri 99
3.2.9.6. Çoklu Doğrusal Bağlantı 102
3.2.9.7. Değişen Varyans 110
3.2.9.8. Otokorelasyon 124
3.2.10. Zaman Serileri Analizi 141
3.2.10.1. Otokovaryans Fonksiyonu 143
3.2.10.2. Otokorelasyon Fonksiyonu 144
3.2.10.3. Kısmi Otokorelasyon Fonksiyonu 144
3.2.10.4. Otoregresif Süreç: AR(p) 145
3.2.10.5. Hareketli Ortalama Süreci: MA(q) 147
3.2.10.6. Otoregresif Hareketli Ortalama Süreci: ARMA(p,q) 148
3.2.10.7. Durağan-dışı Süreçler: ARIMA(p,d,q) 150
3.2.10.8. ARIMA modellerinde Box-Jenkins Model Kurma Stratejisi 151
3.2.10.9. Portmanteau Testleri: Q istatistikleri 152
3.2.10.10. Model Seçme Kriteri 153
3.2.10.11. Önraporlama 155
3.2.10.12. Durağanlık 155
3.2.10.13. Birim Kök Testleri 156
3.2.10.14. Yapısal Kırılmalı Birim Kök Testleri 162
4. ARAŞTIRMA BULGULARI ve TARTIŞMA 173
4.1. Yapısal Kırılma Birim Kök Testi Sonuçları 173
4.2. Çoklu Regresyon ile Model Tahmini 174
4.3. Box – Jenkins ARIMA İle Model Tahmini 185
4.4. YSA ile Model Tahmini 192
4.5. Tahmin Sonuçlarının Karşılaştırmalı Olarak İncelenmesi 194
5. SONUÇLAR ve ÖNERİLER 197
5.1. Sonuçlar 197
5.2. Öneriler 200
KAYNAKLAR 201
ÖZGEÇMİŞ 208

ÖZET

Doktora Tezi

DURAĞAN OLMAYAN ZAMAN SERİLERİNDE ALTERNATİF TAHMİN YÖNTEMLERİNİN KARŞILAŞTIRMALI OLARAK İNCELENMESİ

Levent KAYA

Harran Üniversitesi
Fen Bilimleri Enstitüsü
Tarım Ekonomisi Anabilim Dalı

Danışman : Prof. Dr. Turan BİNİCİ
Yıl: 2015, Sayfa: 209

Bu çalışmada, durağan-dışı zaman serileri için kullanılan öngörü tekniklerinin karşılaştırmalı analizi yapılmıştır. Tek değişkenli analiz için Box-Jenkins metodu, Çok değişkenli analizler için Çoklu Regresyon Analizi ve Yapay Sinir Ağları yöntemleri kullanılmıştır. Zaman serisi verileri olarak 2000-2014 yıllarına ait 180 veriden oluşan aylık Türkiye pamuk fiyatları, Dünya pamuk fiyatları, Türkiye buğday fiyatları ve Türkiye mısır fiyatları kullanılmıştır. Analiz yöntemlerinin tahmin gücünü ölçmek için verilerin % 10'luk kısmı analize dâhil edilmemiş ve ilk 162 veri analize tabi tutulmuştur. Yapılan analizler sonucunda kullanılan yöntemlerin son 18 aylık dönemle ilgili elde edilen tahmin değerleri karşılıklı olarak incelenmiştir. Öncelikle birim kök testleri uygulanarak değişkenlerin durağanlığı incelenmiştir. Testler sonucunda serilerin durağan olmadığı, birinci farkı alındıktan sonra durağanlaştığı tespit edilmiştir. Türkiye pamuk fiyatlarına bir ve iki yapısal kırılmaya kadar izin veren sırasıyla Zivot-Andrews ve Lumsdaine-Papell yapısal kırılma birim kök testleri uygulanmış ve kırılma zamanları tespit edilmiştir. Ayrıca serinin durağan-dışı olmasına yapısal kırılmaların sebep olup olmadığı test edilmiştir. Box-Jenkins (ARIMA) yöntemi ile Türkiye pamuk fiyatlarının geçmiş değerleri dikkate alınarak uygulama yapılmıştır. Yapılan denemeler sonucunda en uygun ARIMA seviyesinin (3,1,2) olduğuna karar verilmiştir. Elde edilen tahmin sonuçlarının yapılan testlerle bazı varsayımları sağlamadığı görülmüştür. Bu nedenle elde edilen modelin kalıntıları incelenmiş ve aşırı sapma gösteren dönemler için modele kukla değişkenler eklenmiştir. Kukla değişkenli modelin tahmin sonuçları incelenmiş ve yapılan testler sonucunda varsayımları sağladığı görülmüştür. Çok değişkenli yöntemler için bağımlı değişken, Türkiye pamuk fiyatları, bağımsız değişkenler, Dünya pamuk fiyatları, Türkiye buğday fiyatlar, Türkiye mısır fiyatları ve bütün değişkenlerin bir gecikmeli değerleri kullanılmıştır. Çoklu Regresyon Analizi ile elde edilen tahmin sonuçları incelenmiş ve bazı varsayımları sağlamadığı görülmüştür. Box-Jenkins metodunda olduğu gibi tahmin edilen modelde aşırı sapma gösteren dönemler için kukla değişkenler oluşturulmuş ve modele dâhil edilmiştir. Elde edilen tahmin sonuçlarının, uygulanan testlerle varsayımları sağladığı görülmüştür. Yapay Sinir Ağları ile analiz yapabilmek için en uygun ağ mimarisini elde edilmeye çalışılmıştır. Yapılan denemeler sonucunda, (7,7,1) ağ yapısına karar verilmiş ve öğrenme algoritması olarak Levenberg-Marquardt Backpropagation algoritması kullanılmıştır. Tahmin değerlerini karşılaştırmak için MAPE, SSE, MSE ve RMSE performans kriterleri kullanılmıştır. Elde edilen sonuçlar incelendiğinde Yapay Sinir Ağlarının diğer tahmin yöntemlerine göre daha başarılı sonuçlar verdiği tespit edilmiştir.

ANAHTAR KELİMELER: Yapay Sinir Ağları, Çoklu Regresyon Analizi, Box-Jenkins Yöntemi, Yapısal Kırılma Birim Kök Testleri, Pamuk Fiyatları

ABSTRACT

PhD Thesis

A COMPARATIVE INVESTIGATION OF ALTERNATIVE ESTIMATION METHODS IN NON-STATIONARY TIME SERIES

Levent KAYA

Harran University
Graduate School of Natural and Applied Sciences
Department of Agricultural Economics

Supervisor : Prof. Turan BİNİCİ
Year: 2015, Page: 209

In this study, comparative analysis of the predictive techniques used for non-stationary time series had been made. The method of Box-Jenkins for univariate analysis, Multiple Regression Analysis and Artificial Neural Networks techniques for multivariate analysis had been used. The monthly prices of cotton in Turkey and World and also the monthly price of wheat and corn in Turkey consisting of 180 data between in 2000-2014 years used as time series data. % 10 of the data hadn't been included in the analysis to measure the predictivite power of analysis methods and first 162 data had been analysed. At the end of the analysis, predicted values obtained about the last 18 months period had been examined in mutual. Stationary of variables had been examined by applying the unit root tests, It had been determined that as a result of the tests, series were not stationary but it has been stationary after taking the first difference. Zivot-Andrews structural break unit root test which allows a single structural break and Lumsdaine-Papell structural break unit root test which allows two structural breaks has been applied to Turkey cotton prices. Being non-stationary of series is determined whether the cause of structural breaks. Past values of the Turkey cotton prices has been applied with Box-Jenkins ARIMA method. It has been concluded that as a result of attempts the most appropriate level of ARIMA is (3,1,2). estimation results have been examined and it didn't provide some assumptions. Therefore examining the residuals of model were obtained and dummy variables have been added for showing extreme deviation period in the model. The estimation of results of the model with dummy variable is examined and the tests have been found the assumptions. The dependent variable for multivariate methods, Turkey cotton prices, independent variables are World cotton prices, Turkey wheat prices, Turkey corn prices and lagged values of all variables were used. Multiple regression estimation results have been examined and it didn't provide some assumptions. Therefore examining the residuals of model were obtained and dummy variables have been added for showing extreme deviation period in the model as in Box-Jenkins method. The estimation of results of the model with dummy variable is examined and the tests have been found the assumptions. The analyze the Artificial Neueal Networks, it has attepted to obtain optimal network architecture. As a results of attempts, (7,7,1) network structure was decided and Levenberg-Marquard Backpropagation algorithm was used for learning algorithm. MAPE, SSE, MSE and RMSE performance criteria were used to compare the predicted values. It was determined that Artificial Neural Networks gave more reliable results than other estimation methods.

KEYWORDS: Artificial Neural Networks, Multiple Regression Analysis, Box-Jenkins Method, Structural Break Unit Root Tests, Cotton Price

TEŞEKKÜR

Tez çalışmamın her aşamasında yardımlarını ve desteklerini esirgemeyen danışmanım Sayın Prof. Dr. Turan BİNİCİ'ye, Tez konumun seçiminde, araştırmanın yürütülmesi ve değerlendirmesinde yardımlarını esirgemeyen Sayın Yrd. Doç. Dr. Zeki DOĞAN'a, araştırma ile ilgili görüş ve önerilerinden faydalandığım Sayın Yrd. Doç. Dr. Tamer IŞGIN'a, değerli desteklerinden dolayı Ekonometri bölüm başkanı Sayın Yrd. Doç. Dr. Hasan TÜRKAL'a, Sayın Doç. Dr. Murat DEMİR'e, Sayın Doç. Dr. Mehmet Suphi ÖZÇOMAK'a, Sayın Nihat KÜÇÜK'e, Sayın Arş. Gör. Merve OFLUOĞLU'na, Sayın Arş. Gör. Çiğdem Yuvarlakbaş ÇADIRCI'ya, Sayın Arş. Gör. Talha ELMALI'ya, Harran Üniversitesi Fen Bilimleri Enstitüsü çalışanlarına, Doktora çalışmam süresince gösterdiği sabır, anlayış ve fedakârlıktan dolayı eşim Sayın Öğr. Gör. Miyaser KAYA'ya, dünyaya gözlerini açarak hayatımıza renk katan ve ayrı bir motivasyon kaynağı olan oğlum Erdem Aslan KAYA'ya yürekten teşekkür ederim.

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 3.1. Pamuğun Kullanım Alanları 12
Şekil 3.2. Beyinin Temel Yapısı 35
Şekil 3.3. Biyolojik Sinir Hücresi 37
Şekil 3.4. YSA'nın Temel Elemanlar 53
Şekil 3.5. Aktivasyon Fonksiyonları 57
Şekil 3.6. Perception Modeli 64
Şekil 3.7. ADALINE Modeli 66
Şekil 3.8. MADALINE Modeli 67
Şekil 3.9. Çok Katmanlı YSA 68
Şekil 3.10. İleri Beslemeli YSA Modeli 70
Şekil 3.11. Geri Beslemeli YSA Modeli 71
Şekil 3.12. LVQ Ağı 72
Şekil 3.13. Kohonen Ağı 78
Şekil 3.14. Hopfield Ağı 80
Şekil 3.15. Jordan Ağı 81
Şekil 3.16. Elman Ağı 82
Şekil 4.1. TPF verilerinin zaman yolu grafiği 175
Şekil 4.2. DTPF verilerinin zaman yolu grafiği 175
Şekil 4.3. DPF verilerinin zaman yolu grafiği 177
Şekil 4.4. DDPF verilerinin zaman yolu grafiği 177
Şekil 4.5. TBF verilerinin zaman yolu grafiği 178
Şekil 4.6. DTBF verilerinin zaman yolu grafiği 178
Şekil 4.7. TMF verilerinin zaman yolu grafiği 179
Şekil 4.8. DTMF verilerinin zaman yolu grafiği 179
Şekil 4.9. Hata Terimlerinin Dağılımı 184
Şekil 4.10. TPF verilerinin zaman yolu grafiği 186
Şekil 4.11. DTPF verilerinin zaman yolu grafiği 186
Şekil 4.12. TPF Verilerinin Korelogramı 187
Şekil 4.13. ARIMA(3,1,2) modelinin hatalarının grafiği 189
Şekil 4.14. Hata Terimlerinin Dağılım Tablosu 192
Şekil 4.15. Hata terimlerinin karelerinin korelogramı 192
Şekil. 4.16. YSA Ağ Mimarisi 193
Şekil. 4.17. Hata Kareler Ortalaması 194
Şekil. 4.18. Eğitim, Validation ve Test Veri Setlerinin Regresyon Grafikleri 195
Şekil. 4.19. Gerçek ve Tahmini Değerlerin Grafiksel Gösterimi 197

ÇİZELGELER DİZİNİ

Sayfa No

Çizelge 3.1. Dünya Pamuk Ekim Alanları (Bin Ha) 14
Çizelge 3.2. Dünya Lif Pamuk Verimleri (Kg/Ha) 15
Çizelge 3.3. Dünya Lif Pamuk Üretimi (Bin Ton) 16
Çizelge 3.4. Dünya Lif Pamuk Tüketimi (Bin Ton) 17
Çizelge 3.5. Bölgeler İtibariyle Türkiye Pamuk Ekim Alanları (Bin Ha) 18
Çizelge 3.6. Bölgeler İtibariyle Türkiye Lif Pamuk Üretimi (Bin Ton) 19
Çizelge 3.7. Türkiye Lif Pamuk Üretim ve Tüketimi (Bin Ton) 19
Çizelge 3.8. Dünya Lif Pamuk İthalatı (Bin Ton) 20
Çizelge 3.9. Dünya Lif Pamuk İhracatı (Bin Ton) 21
Çizelge 3.10. Türkiye Pamuk İhracatı 22
Çizelge 3.11. Türkiye'nin İhracatının Ülkelere Göre Dağılımı 23
Çizelge 3.12 Türkiye Pamuk İthalatı 23
Çizelge 3.13. Türkiye İthalatının Ülkelere Göre Dağılımı 24
Çizelge 3.14. Türkiye'de Kütlü Pamuk Üretici Fiyatları (TL/Kg) 24
Çizelge 3.15. Türkiye ve Dünya Yıllık OrtalamaPamuk Fiyatları (TL/Kg) 25
Çizelge 3.16. Doğal Zeka ile Yapay Zekanın Karşılaştırılması 30
Çizelge 3.17. Yapay Sinir Ağları ve İstatistiksel Model Terminolojisinin Karşılaştırılması 43
Çizelge 3.18. Yapay Sinir Ağlarının Tarihçesi 49
Çizelge 3.19. Biyolojik Sinir Ağı ve Yapay Sinir Ağının Karşılaştırılması 53
Çizelge 3.20. Toplama Fonksiyonu Örnekleri 55
Çizelge 3.21. Diğer Aktivasyon Fonksiyonları 58
Çizelge 3.22. Veri Normalizasyon Türleri 82
Çizelge 3.23. YSA'da Kullanılan Öğrenme Algoritmaları 84
Çizelge 3.24. YSA'da Kullanılan Performans Fonksiyonları ve Matematiksel Açılımları 87
Çizelge 3.25 ACF ve PACF'nin teorik davranışları 145
Çizelge 3.26. AR, MA ve ARMA Sürecine İlişkin Otokorelasyon Yapısı 149
Çizelge 3.27. Model Seçim Kriterleri 154
Çizelge 4.1. Zivot – Andrews Birim Kök Testi 173
Çizelge 4.2. Lumsdaine – Papell Birim Kök Testi 173
Çizelge 4.3. TPF ve DTPF verileri için ADF birim kök testi 175
Çizelge 4.4. DPF ve DDPF verileri için ADF birim kök testi 176
Çizelge 4.5. TBF verileri için ADF birim kök testi 177
Çizelge 4.6. TMF verileri için ADF Birim kök testi 178
Çizelge 4.7. Çoklu Regresyon Modeli Tahmin Sonuçları 182
Çizelge 4.8. Değişen Varyans Testi 183
Çizelge 4.9. Otokorelasyon testi 184
Çizelge 4.10. Çoklu Doğrusal Bağlantı Testi 184
Çizelge 4.11. TPF ve DTPF verileri için ADF birim kök testi 186
Çizelge 4.12. TPF ve DTPF verileri için Phillips-Perron Birim Kök testi 187
Çizelge 4.13. TPF ve DTPF verileri için KPSS Birim Kök testi 188
Çizelge 4.14. ARIMA Modeli Tahmin Sonuçları 190
Çizelge 4.15. Gerçek ve Tahmini Değerler 195
Çizelge 4.16. Gerçek ve Tahmini Değerler 195

SİMGELER DİZİNİ

ACF	Autocorrelation Function (Otokorelasyon Fonksiyonu)
ADALINE	Adaptive Linear Element (Uyarlanabilir Doğrusal Eleman)
ADF	Augmented Dickey-Fuller (Genişletilmiş Dickey-Fuller)
AIC	Akaike Information Criterion (Akaike Bilgi Kriteri)
AR	Autoregressive (Otoregresif)
ARIMA	Autoregressive Integrated Moving Avarage (Bütünleşik Otoregresif Hareketli Ortalama)
ARMA	Autoregressive Moving Avarage (Otoregresif Hareketli Ortalama)
ART	Adaptive Resonance Theory (Uyarlanabilir Rezonans Teorisi)
DDPF	Birinci farkı alınmış Dünya Pamuk Fiyatları
DF	Dickey-Fuller
DPF	Dünya Pamuk Fiyatları
DTBF	Birinci farkı alınmış Türkiye Buğday Fiyatları
DTMF	Birinci farkı alınmış Türkiye Mısır Fiyatları
DTPF	Birinci farkı alınmış Türkiye Pamuk Fiyatları
EKK	En Küçük Kareler
LVQ	Learning Vector Quantization
MA	Moving Avarage (Hareketli Ortalama)
MADALINE	Many Adaptive Linear Element (Çoklu Uyarlanabilir Doğrusal Eleman)
MAPE	Mean Absolute Percentage Error (Ortalama Mutlak Hata Yüzdesi)
MSE	Mean Squared Error (Hata Kareler Ortalaması)
PACF	Partial Autocorrelation Function (Kısmi Otokorelasyon Fonksiyonu)
RBF	Radial Basis Function (Radyal Tabanlı Fonksiyon)
RMSE	Root Mean Squared Error (Hata Kareler Ortalamasının Kare Kökü)
SIC	Schwarz Information Criterion (Schwarz Bilgi Kriteri)
SOM	Self Organizing Maps (Özdüzenleyici Haritalar)
SSE	Sum Squared Error (Hata Kareler Toplamı)
TBF	Türkiye Buğday Fiyatları
TMF	Türkiye Mısır Fiyatları
TPF	Türkiye Pamuk Fiyatları
VIF	Variance Inflation Factor (Varyans Büyütme Faktörü)
YSA	Yapay Sinir Ağları

1. GİRİŞ

Son yıllarda bilgisayar teknolojilerinde meydana gelen gelişmeler birçok bilim dalında köklü değişikliklere yol açmıştır. Bu değişim ekonomik değişkenlerin analizinde de kendini göstermiştir. Özellikle ekonometri disiplinin hızla gelişmesi, istatistiksel ve matematiksel tekniklerin, ekonomik parametrelerin analizinde yoğun olarak kullanılmaya başlamasına neden olmuş ve buna paralel olarak da bilgisayar teknolojileri, ekonomik araştırma ve analizlere hızla entegre olmuştur.

Zaman serileri analizleri, istatistiksel ve ekonometrik araştırmalarda önemli bir yer teşkil etmektedir. Geçmiş dönemlerin çeşitli yöntemlerle incelenmesiyle elde edilen bilgilerin, öngörü tahmininde kullanılmasına dayanan bu teknikler, özellikle kısa, orta ve uzun dönem kestirimlerine ihtiyaç duyulan her alanda kullanılmaktadır. Bilinmeyen geleceğin bilimsel yöntemlerle kestirilmesi ve gelecek için önceden hazırlıkların yapılması her alanda olduğu gibi özellikle ekonomide ve finans sektöründe büyük önem taşımaktadır.

Finansal zaman serilerinin modellenmesi, tüm zaman serileri analizleri arasında en zor olanıdır. Bunun nedeni, ekonomik sistemin sonsuz sayıda içsel ve dışsal değişkenin etkisi altında olmasıdır. Sistemin etkilendiği tüm değişkenler modele dâhil edilemeyeceğinden tahmini zorlaşmaktadır. Finansal zaman serilerinin modellenmesi ve analizinin bu kadar zor oluşu ve herhangi bir ekonomik parametrenin bir sonraki adımdaki değerinin doğru bir şekilde öngörülmesinin insanlara sağladığı büyük avantaj, bu konuya olan ilgiyi sürekli canlı tutmuştur. Bu da konuyla ilgili sayısız çalışmanın yapılmasına ve birçok analiz yönteminin geliştirilmesine olanak sağlamıştır. Doğrusal zaman serilerinin analizinde oldukça başarılı sonuçlar veren Box-Jenkins modelleri bu tekniklerin en önemlilerindendir. Doğrusal ve durağan süreçlerde ya da durağan olmayan fakat bazı dönüşümlerle durağanlaştırılabilen serilerde Box-Jenkins yöntemi başarılı sonuçlar verebilir. Ancak, gerçek hayata ilişkin seriler genellikle doğrusal değildir. Bu nedenle doğrusal olmayan zaman serilerini modellemede bazı problemlerle karşılaşılabilmektedir.

Geleneksel istatistik yöntemleri, iyi bir performansa sahip olmalarına rağmen pek çok kısıtlamalara sahiptir. Enformasyon miktarındaki artışlar, veri sayılarının

artmasına yol açmıştır. Hızlı gelişmeler ışığında değişkenler arasındaki fonksiyonel ilişkiler de giderek karmaşıklaşmıştır. Bu durumun yansıması olarak farklı modelleri çözümlemek için geleneksel yöntemlerin yanında alternatif yöntemlere ihtiyaç duyulmaktadır. Finansal zaman serileri arasındaki ilişkilerin doğrusal olmayan yapıda olma eğiliminde olduklarını ortaya koyan birçok araştırma sonrasında, klasik modellere alternatif olabilecek uyarlanabilir sistemlerin bu alana uygulanması çalışmalarını hızlandırmıştır.

Yapay zekâ araştırmalarının bir alt kümesi olan yapay Sinir Ağları, zaman serisi analizlerinde kullanılan alternatif yöntemlerin en önemlilerinden biridir. 1950'lerden itibaren özellikle mühendislik alanında çok başarılı uygulamalara imza atmıştır. Son yıllarda iktisadi olaylara ilişkin analizlerde sıkça kullanılmaya başlanmış ve oldukça başarılı sonuçlar elde edilmiştir. Yapay Sinir Ağlarına olan ilginin artmasına en büyük sebeplerden biri Box-Jenkins, Regresyon,.. gibi geleneksel istatistiksel yöntemlerdeki kısıtlamaların hiçbirine sahip olmamasıdır. Herhangi bir varsayım, ön şart gerektirmeden her türlü veri tipine uygulanması, araştırmacıların bu yönteme olan ilgisini gün geçtikçe daha da arttırmaktadır. Ayrıca geleneksel yöntemlerden farklı olarak öğrenebilme, genelleme, doğrusal olmayan ilişkileri tanımlayabilme, eksik veriler söz konusu olduğunda dahi etkin öngörüde bulunabilme, teorik olarak sonsuz değişken ile çalışabilme gibi bazı avantajları bulunmaktadır.

Bu çalışmada, iktisadi zaman serisi analizlerinde sıkça kullanılan yöntemlerden Box-Jenkins ve Regresyon Analizi ile bu yöntemlere iyi bir alternatif teşkil eden Yapay Sinir Ağlarının karşılaştırmalı olarak incelenmesi amaçlanmıştır. Bu karşılaştırma için bölge için büyük önem arz eden pamuğun aylık fiyat verileri kullanılmıştır. Ayrıca yapılan karşılaştırmalar sonucunda hem yöntemlerin birbirlerine olan üstünlüklerini ortaya koymak hem de benzer iktisadi konularda da kullanılabilir olduğunu göstermeye gayret edilmiştir.

Çalışmanın ikinci bölümünde, önceden yapılmış karşılaştırmalı analiz çalışmalarına değinilmiş, ağırlıklı olarak iktisadi alandaki yaygın kullanımı, analizlerden elde edilen sonuçlarla gösterilmeye çalışılmıştır.

Üçüncü bölümde, ilk olarak karşılaştırmalı analizlere konu olan pamuk bitkisiyle ilgili bilgi verilmiştir. Türkiye'de ve özellikle de bölgemizdeki iktisadi önemi, sayısal verilerle desteklenerek açıklanmaya çalışılmıştır. Ayrıca dünya piyasalarıyla karşılaştırılması yapılarak ve uygulanan politikaların sonuçları gösterilmeye çalışılmıştır. Analizlerde bağımlı değişken olarak 2000-2014 yıllarına ait aylık Türkiye pamuk fiyatları, bağımsız değişkenler ise aynı dönemlere ait Dünya pamuk fiyatları, Türkiye buğday fiyatları ve Türkiye mısır fiyatları verileri kullanılmıştır. Daha sonra analizlerde kullanılacak yöntemlere değinilmiştir. Birim kök test yöntemleri, yapısal kırılma birim kök testleri, Box-Jenkins yöntemi, Çoklu Regresyon Analizi ve Yapay Sinir Ağları yöntemi, kısıtları ve varsayımlarıyla detaylı olarak incelenmiştir.

Dördüncü bölümde verilere, durağanlık koşulunu sağlayıp sağlamadığını göstermek için birim kök testleri uygulanmıştır. Ayrıca verilerde süreç içinde meydana gelen yapısal kırılma veya kırılmaları göstermek için yapısal kırılmalı birim kök testleri uygulanmıştır. Gerekli dönüşümler yapılarak verilerin analizler için kullanılır hale gelmesi sağlanmıştır. En son olarak tek değişkenli zaman serisi analiz yöntemi için Box-Jenkins metodu, Çok değişkenli analiz için Çoklu Regresyon metodu ve YSA metodu ile ayrı ayrı analizler yapılarak sonuçlar elde edilmiştir. Analiz sonuçlarını elde etmek için EVIEWS 8.0, MATLAB R2012B ve WINRATS 8.0 paket programlarından faydalanılmıştır. Son olarak analiz sonuçlarının güvenilirliği sınanmış, varsayımları sağlayıp sağlamadığı çeşitli tekniklerle test edilmiştir.

Son bölümde ise, elde edilen sonuçlar, çeşitli performans kriterleri göz önüne alınarak karşılaştırmalı olarak incelenmiş ve en iyi tahmin yöntemi hem tablo hem de grafik yardımıyla gösterilmiştir.

2. ÖNCEKİ ÇALIŞMALAR

Vaziri (1997), 1986 – 1993 yıllarına ait Hazar Denizi aylık ortalama yüzey su seviyesi verileri ile YSA ve ARIMA tahmin modellerini kullanarak karşılaştırmalı olarak incelemiştir. Analiz sonuçlarına göre, YSA, yüzey su seviyesini ortalama olarak üç santimetrenin altında, ARIMA modelleri ise ortalama olarak üç santimetrenin üstünde bir tahmin sonucu elde etmiştir. Elde edilen tahminlerin Hazar Denizindeki su seviyesinin yükselmesini tahmin etmede fayda sağladığını ifade etmiştir.

Contreras ve ark. (2003), elektrik enerjisi üretici ve tüketici piyasalarındaki rekabet nedeniyle fiyat tahminlerinin büyük bir önem teşkil ettiğini belirtmişlerdir. Bu amaçla ARIMA yöntemini kullanarak İspanya ve Kaliforniya piyasaları için tahmin amaçlı analizler yapmışlardır. İspanya ve Kaliforniya için iki farklı ARIMA modeli oluşturmuşlardır. Analiz sonucunda İspanya'da elektrik fiyatları öngörüsü için 5 saate, Kaliforniya için 2 saate ihtiyaç olduğu sonucuna varmışlardır.

Hamzaçebi ve Kutay (2004), Uzun dönemli elektrik enerjisi tüketimi tahmininde YSA, Box-Jenkins modelleri ve Regresyon tekniğini karşılaştırmalı olarak incelemişlerdir. Bulunan sonuçlar neticesinde, YSA'nın elektrik enerjisi tüketiminde iyi bir tahmin aracı olduğunu göstermişlerdir.

Pao (2007), Tayvan'da yüksek teknolojili ve geleneksel sanayilerin sermaye yapısını analiz edebilmek için YSA ile Çoklu Regresyon Analizini yöntemlerini karşılaştırmalı olarak kullanmıştır. Belirleyici etkenler olarak iş riski ve büyüme fırsatları kriterlerini kullanmıştır. Yapılan analizler sonucunda, hata kareleri ortalamasının kere kökü (RMSE) ölçütüne göre YSA'nın Çoklu Regresyon Analizine göre daha iyi bir tahmin sonucuna ulaştığını göstermiştir.

Tolon ve Tosunoğlu (2008), Ankamall müşterileriyle ilgili tüketici tatmin araştırması yapmışlardır. Elde edilen sonuçları YSA ve Regresyon Analiziyle karşılaştırmalı olarak analiz etmişlerdir. Yapılan analizler sonucunda, YSA'nın, Regresyon Analizinden daha az hataya sahip sonuçlar verdiğini göstermişlerdir. Regresyon Analizinin gerçekleştirilebilmesi için gerekli varsayımların sağlanmadığı durumlarda YSA yönteminin rahatlıkla tercih edilebileceğini belirtmişlerdir.

Ersöz ve ark. (2008), çalışmalarında matematiksel modeller ve optimizasyon teknikleri ile kontrol altına alınamayan müşteri pozisyonu bilgilerini YSA'yı kullanarak analiz etmişlerdir. Yapılan analizler sonucunda, test sonuçları ile YSA ile elde edilen sonuçların % 82 oranında örtüştüğünü göstermişlerdir.

Diaz-Robles ve ark. (2008), çalışmalarında Şili'nin Temuco şehrinde, kış aylarında yanan yakıttan dolayı oluşan partikül madde ölçüm tahmini için Box-Jenkins (ARIMA) ve YSA'nın melez modeli ile Çoklu Doğrusal Regresyon Analizini karşılaştırmalı olarak kullanmışlardır. Yaptıkları analizlerle hava kalitesinin tahminini amaçlamışlardır. Analiz sonuçlarına göre, ARIMA – YSA melez modelinin güçlü bir tahmin performansına sahip olduğunu belirtmişlerdir.

Önder ve Hasgül (2009), çalışmalarında uzun dönemli yabancı ziyaretçi sayısının tahmini için Box-Jenkins yöntemi, Winters yöntemi ve YSA yöntemi kullanmış ve elde edilen sonuçları karşılaştırmışlardır. Winters yöntemi modelinin ürettiği hata değerinin diğer yöntemlerden daha düşük olduğu sonucuna varmışlardır.

Kaynar ve Taştan (2009), aylık ve günlük döviz kuru verilerini kullanarak Box-Jenkins ve YSA yöntemlerini kullanarak modeller oluşturulmuştur. Her bir teknik için en iyi sonuçları veren modeller seçilerek karşılaştırma yapılmıştır. Elde edilen sonuçlarla YSA'nın finansal verilerin tahmininde kullanılabilecek başarılı bir yöntem olduğunu göstermişlerdir.

Çuhadar ve ark (2009), Antalya iline yönelik aylık dış turizm talebi tahminlemesi için Üstel Düzleştirme, Box-Jenkins ve YSA yöntemlerinin tahmin doğruluklarını karşılaştırmışlardır. Çalışmada Ocak 1992 – Aralık 2005 döneminde Antalya iline gelen yabancı turist sayısı verilerinden yararlanmışlardır. Yapılan analizler sonucunda YSA modelinin en yüksek doğruluğu sağladığını göstermişlerdir.

Asilkan ve Irmak (2009), YSA'yı kullanarak ikinci el otomobillerin gelecekteki fiyatlarını tahmin etmeye çalışmışlardır. Girdi olarak Avrupa kökenli çok sayıda ikinci el otomobil web sitesinden elde edilmiş olan ilan verilerini kullanmışlardır. Elde ettikleri sonuçlarla, YSA'nın ikinci el otomobillerin

gelecekteki fiyatlarını tahmin etmede başarıyla kullanılabileceğini ortaya koymuşlardır.

Ünlü ve ark. (2009), İMKB'de ilk defa halka arz edilen hisse senetlerinin uzun dönem getirilerini YSA kullanarak tahmin etmişlerdir. Literatürde uzun dönem halka arz getirilerinin tahmin edilmesinde yaygın olarak doğrusal regresyon yönteminden yararlanıldığı halde, elde edilen bulgular YSA'nın uzun dönem halka arz getirilerini tahmin etmede Doğrusal Regresyon yönteminden daha başarılı olduğunu ortaya koymuşlardır.

Fahimifard ve ark. (2009), İran Riyali/Amerikan Doları döviz kuru tahmininde bulunmak için adaptif sinir-bulanık çıkarım sistemi (ANFIS), YSA, GARCH ve ARIMA yöntemlerini karşılaştırmışlardır. Tahmin performans kriterleri olarak da R^2, MAD, RMSE ölçütlerini kullanmışlardır. Yapılan analiz sonuçlarına göre, ANFIS ve YSA gibi doğrusal olmayan modellerin ARIMA ve GARCH gibi doğrusal modellere göre daha iyi bir tahmin performansı gösterdiğini ortaya koymuşlardır.

Çelik (2010), Türkiye'de bankaların finansal başarısızlıklarının öngörülmesine yönelik erken uyarı modelleri oluşturmayı amaçlamıştır. 36 adet özel sermayeli ticaret bankasına ait finansal oranları kullanarak bankaların finansal başarısızlığa düşme olasılıklarını 1 ve 2 yıl önceden ayrı ayrı tahmin etmeye çalışmıştır. Çalışmada Diskriminant Analizi ve YSA modellerinin tahmin güçlerini karşılaştırmış ve iki ayrı tahminde de YSA'nın, Diskriminant Analizine göre daha başarılı olduğunu belirtmiştir.

Erilli ve ark. (2010), Tüketici Fiyat Endeksi (TUFE) için ileri ve geri beslemeli YSA yaklaşımını kullanarak öngörüler elde etmişlerdir. Hangi tahmin yöntemi kullanılırsa kullanılsın enflasyon öngörüsünde tam bir başarı sağlanmasının oldukça zor olduğunu belirtmelerinin yanında, hataları ve zorlukları en aza indirgemede YSA'nın kullanılabilir bir yöntem olduğunu ifade etmişlerdir.

Bayata ve Hattatoğlu (2010), çalışmalarında 1974-2007 yılları arasındaki ceza alan sürücü sayıları ile kaza sayılarını dikkate alarak, çok değişkenli istatistiksel analiz ve YSA yöntemleri ile modelleme yapmışlardır. İstatistiksel

değerlendirmelerde, Yapay Sinir Ağlarının çok değişkenli istatistiksel analize göre daha yüksek bir R^2 değerine ve minimum ortalama karesel hataya sahip olduğunu ortaya koymuşlardır. Bu sonuçlara göre YSA yöntemini istatistiksel olarak daha başarılı bir yöntem olarak kabul etmişlerdir.

Morova ve Terzi (2010), trafikten kaynaklanan gürültünün tahmin edilmesi amacıyla YSA yöntemi ile çeşitli modeller geliştirmişlerdir. Modellemede, girdi olarak ağır taşıt sayısı, hafif taşıt sayısı, toplam saatlik trafik ve hız parametrelerini, çıktı olarak da trafik kaynaklı gürültü parametresini kullanmışlardır. Elde ettikleri sonuçlarla YSA'nın kullanılabilir uygun bir yöntem olduğunu belirtmişlerdir.

Abudu ve ark. (2010), ARIMA, SARIMA ve Jordan-Elman YSA modellerini kullanarak 1998-2005 yıllarını kapsayan aylık Çin'in Sincan bölgesindeki Kızıl Nehir su akımını tahmin etmeyi amaçlamışlardır. Analiz sonucunda, ARIMA ve SARIMA zaman serisi modellerinin Jordan-Elman YSA modelleriyle benzer tahminlerde bulunduğu sonucuna ulaşmışlardır.

Elmas ve ark. (2011), çalışmalarında işletmelerde mali başarısızlığı tahmin edebilmek için başarılı ve başarısız işletmeleri belirleyerek istatistikî modeller kurup, örnek, kestirim seti ve kontrol seti oluşturmuşlardır. Veri seti olarak İMKB'de işlem gören 140 sanayi işletmesinin 2005-2008 yılları arasındaki mali başarısızlıkları kullanmışlardır. Yöntem olarak Lojistik Regresyon Modeli ve YSA'dan faydalanmışlardır.

Alizadeh (2011), Yüksek lisans tez çalışmasında, YSA ile ürünlerin fiyat geçmişi bilgilerini kullanarak ilerleyen zaman birimlerinde fiyat tahminleri yapmayı amaçlamıştır. Uygulamada Narx YSA modelini kullanmış ve Yapay Sinir Ağlarının özelliklerine ve öğrenme kabiliyetlerine dayanarak, tahmin yürütmede uygun bir araç olduğunu göstermiş ve belirtmiştir.

Chattopadhyay ve ark. (2011), çalışmalarında 1749-2007 yıllarına ait, 11 yıllık döngü içinde değişiklik gösteren güneş lekeleri ölçüm verilerini kullanarak, otoregresif ARMA, ARIMA ve YSA yöntemleriyle tahminlemede bulunmuşlardır. Analiz sonucunda, otoregresif sinir ağı tabanlı modelin ARMA ve ARIMA modellerinden çok daha iyi bir tahmin performansına sahip olduğunu belirtmişlerdir.

Azad ve Mahsin (2011), Bangladeş için döviz kuru tahmin modelleri oluşturmuşlardır. Tahmin analizleri için ileri besilemeli çok katmanlı YSA ve ARIMA modellerini kullanmışlardır. Performans ölçüm kriterleri olarak da ortalama mutlak hata (MAE), hata kareleri ortalamasının kere kökü (RMSE) ve ortalama mutlak yüzde hata (MAPE) performans ölçütlerini kullanmışlardır. Yapılan analizler sonucunda, YSA modelinin ARIMA modeline göre daha iyi bir tahmin gücüne sahip olduğunu göstermişlerdir.

Özkan (2012), Döviz kurunun kısa periyotlarla değişmesi ve oynak olması nedeniyle, yatırımcıların risklerini azaltmak için YSA ile yapısal döviz kuru tahmin metotlarından biri olan parasal modelin tahmin performanslarını karşılaştırmıştır. Modellerde yerli ve yabancı ülkeye ait enflasyon, para arzı, faiz oranı ve milli gelir ekonomik verilerini kullanmış ve Amerikan doları için 1986-2010, Avro için ise 1999-2010 dönemini ele almıştır. Analiz sonuçlarıyla YSA'nın yüksek tahmin gücüne sahip olduğunu göstermiştir.

Safi (2013), çalışmasında Gazze şeridindeki elektrik tüketiminin tahmini için uygulamada en çok kullanılan tahmin yöntemlerinden ARIMA ve YSA modellerini karşılaştırmalı olarak ele almıştır. Elektrik tüketim verileriyle yapılan tahmin analizleri sonucunda YSA yönteminin ARIMA yöntemine göre daha üstün tahmin sonuçları verdiğini ortaya koymuştur.

Mbarek ve Feki (2013), Türkiye'nin gayri safi milli hasıla ve işsizlik verilerini kullanarak YSA ile vektör otoregresif (VAR) modellerini karşılaştırmalı olarak analize tabi tutmuşlardır. Yapılan analiz sonuçlarına göre, YSA yönteminin VAR analizi yöntemine göre daha sağlam tahminlerde bulunduğu sonucuna varmışlardır.

Mirsoltani ve Niaki (2013), Mart-1996 ile Mart-2010 yılları arasında aylık İran sanayi sektöründe enerji fiyat ve tüketim verilerini kullanarak 2011 ve 2012 yılları için tahminlerde bulunmuşlardır. Tahmin yöntemleri olarak YSA ile adaptif sinir-bulanık çıkarım sistemi (ANFIS) yöntemlerini kullanmışlardır. Karşılaştırmalı olarak yapılan analizler sonucunda ANFIS yönteminin YSA yöntemine göre daha az hata kareleri toplamına sahip olduğunu göstermişlerdir.

Kuo ve ark, (2013). Çin Halk Cumhuriyetinin askeri harcamalarını tahmin etmek amacıyla YSA ve ARIMA modelleriyle analizler yapmışlardır. Veri seti olarak, Çin'in askeri harcamalarını, gayrisafi yurtiçi hâsılasını ve enflasyon oranlarını kullanmışlardır. Ayrıca analizleri kısa vadeli, orta vadeli, orta-uzun vadeli ve uzun vadeli olmak üzere dört zaman periyodunu incelemişlerdir. Tahmin doğruluğunu ölçmek için de ortalama mutlak yüzde hata (MAPE) yaklaşımını kullanmışlardır. Yapılan analizler sonucunda, Dört zaman periyodu için YSA'nın ARIMA modellerine göre daha tutarlı sonuçlar verdiğini göstermişlerdir.

AbdRahman ve ark. (2013), Malezya'da sanayi ve konut izleme istasyonlarından elde ettikleri on yılı kapsayan aylık hava kirliliği indeksi verilerini kullanarak tahminde bulunmayı ve erken uyarı sisteminin daha etkin çalışarak kaliteli bir hava imkânının sağlanmasını amaçlamışlardır. Tahmin yöntemleri olarak ARIMA, bulanık zaman serisi ve YSA yöntemlerini kullanmışlardır. Yapılan analizler sonucunda, YSA'nın, ARIMA ve bulanık zaman serisi yöntemine göre daha küçük tahmin hatası verdiği sonucuna ulaşmışlardır.

Mishra ve Singh (2013), Delhi'de Yerfıstığı yağı tahmini fiyatları üzerine analiz çalışması yapmışlardır. Tahmin yöntemleri olarak ARIMA ve YSA modellerinden faydalanmışlardır. Fiyat tahmini için sadece talep değil ayrıca ürün tedariki, hava şartları, kontrol, depolama, kapasite, ulaşım imkânları gibi faktörleri de dikkate almışlardır. Ayrıca performans kriteri olarak da RMSE ve MSE ölçütlerini kullanmışlardır. Yapılan analizler sonucunda, iki yöntem için de benzer tahmin sonuçları elde etmişlerdir.

Adebiyi ve ark. (2014), NewYork Menkul Kıymetler Borsası hisse senetlerinin tahmini için ARIMA modeli ile YSA modelini karşılaştırmalı olarak incelemişlerdir. Elde ettikleri ampirik sonuçlara göre hisse senetleri fiyatlarının tahmininde, YSA modelinin ARIMA modellerinden daha üstün olduğunu ortaya koymuşlardır

3. MATERYAL ve YÖNTEM

3.1. Materyal

Çalışmada, 2000 – 2014 yıllarına ait aylık pamuk fiyatları kullanılarak fiyat tahmin analizleri yapılacaktır. Bu amaçla ülkemiz ve bölgemiz için büyük önem arz eden pamuk ile ilgili olarak aşağıda kavramsal ve istatistiksel bilgiler verilmiştir.

3.1.1. Pamuk

Pamuk (Gossypium Hirsitum), ebegümecigiller (Malvaceae) familyasından anavatanı Hindistan olan kültürü yapılan bir bitki türüdür (Anonim, 2015c). Pamuk bitkisi kök, sap, yaprak, çiçek ve tohumdan oluşmaktadır. Tür ve varyetesine göre 60-120 cm., ağaç halinde olanlar ise 5-6 metre boylanabilir. Pamuk 30-100 cm. derine, 50-80 cm. yanlarına uzanan kazık köke sahiptir. Toprak yüzeyinin 8-10 cm. altında ilk yan kökler meydana gelir. Bunlar yatay olarak büyürler. Yan köklerin sayıları 3-4 tanedir. Her biri tekrar dallanarak etrafa yayılır. Epidermis hücrelerinin dışa doğru uzaması ile sayısız emici tüyler meydana gelir. Genel olarak kök toprakta dik olarak ya da bir süre sonra zigzag çizerek devam eder. Uygun koşullarda kök uzunluğu 1.5 metreye kadar ulaşabilir. Pamuk gövdeleri dik, dallanmış ve çok tüylüdür. Yaprakları uzun saplı, parçalı ve tabanı kalp şeklindedir. Çiçekler saplı ve yaprakların koltuğunda tek tek bulunur. Dış çanak yaprakları üç parçalı, taç yaprakları ise beş serbest parçalıdır. Meyve, olgunlukta açılan ya da kapalı kalan, 3-5 gözlü bir kapsüldür. Bu kapsüle *"koza"* da denir. Her gözde siyahımsı renkli, oval şekilli ve üzeri uzun, sık ve beyaz renkli tüylerle örtülü 5-10 tohum bulunur. Pamuk tohumu, etrafındaki bu tüy veya liflerle beraber *"kütlü"* adını alır.

Pamuk, alüvyonlu ve kuvvetli toprakları sever. Derin sürülmüş ve iyi gübrelenmiş topraklara ekilir. Ekim; sıcak bölgelerde şubat, soğuk bölgelerde mart-nisan aylarında yapılır. Ağustos ve eylülde hasat edilir (Anonim, 2015c).

Pamuk bitkisi, yaygın ve zorunlu kullanım alanıyla insanlık açısından yarattığı katma değer ve istihdam olanaklarıyla da üretici ülkeler açısından büyük ekonomik öneme sahip bir üründür. Pamuk, işlenmesi açısından çırçır sanayisinin, lifi ile tekstil sanayisinin, çekirdeği ile yağ ve yem sanayisinin, linteri ile de kâğıt

sanayisinin hammaddesi durumundadır. Petrole alternatif olarak pamuğun çekirdeğinden elde edilen yağ, giderek artan miktarda biyodizel üretiminde de hammadde olarak kullanılmaktadır. Bu sebeplerin yanında nüfus artışı ve yaşam standardının yükselmesi, pamuk bitkisine olan talebi de artırmaktadır. Bu yönleriyle pamuğa olan ihtiyaç, tüm dünyada artış göstermekte ve geçtiğimiz dönemde hissedilen ekonomik kriz sebebiyle azalan üretim ve tüketim değerlerinin önümüzdeki dönemde artacağı beklenmektedir (Anonim, 2014b).

3.1.1.1. Pamuğun Tarihçesi

İnsanlar tarafından tarımının yapılma tarihi çok eski dönemlere rastlayan pamuk, lifi işlenen ilk bitkidir. Hindistan'da pamuk tarımının en az 5000 yıl önce yapıldığı, kumaş dokumasında kullanılmasının da M. Ö. 3000 yılına rastladığı arkeolojik kazılarda belirlenmiştir. Pamuk hakkındaki ilk literatür de M. Ö. 15. asıra aittir. M. Ö. 8. asırda yazılan Manu kanunlarında pamuktan söz edilmiş olup, en güvenilir kaynaktır.

Hintliler, pamuklu kumaş dokuma sanatını 2000 yıl kadar tekellerinde tutmuş Asurlular ancak günümüzden 3000-3500 yıl önce bu sanatı öğrenebilmişlerdir. Pamuğun Akdeniz sahillerinde yetiştirilmesi ancak günümüzden 2200 yıl önce Pelepones yarımadasının batısındaki küçük bir adada (Elis Adası) başlamış, büyük bir pamuk plantasyonu oluşturulmuş, Akdeniz'in liman şehirlerinde dokunan pamuklu kumaşlar değer olarak altınla aynı kabul edilmiştir.

Anadolu'nun Dünya pamuk üretimine katılması günümüzden, 1900 yıl öncesine kadar uzanır. Pamuk, Anadolu'ya 1. yy.'da Hindistan'dan getirilmiş olup Bizans, Selçuklu ve Osmanlı dönemlerinde tarımı yapılmıştır. Bu dönemlerde ekilen pamuk çeşitleri kapalı kozalı eski dünya pamuklarıdır. 19. yy.'dan itibaren ise dönemin uluslararası taleplere uygun yeni orijinli, açık kozalı Upland varyeteleri getirilip ekilmeye başlanmış ve Osmanlı Devleti 27.01.1862 tarihli genelgesiyle pamuk tarımını geliştirmek için geniş önlemler almıştır.

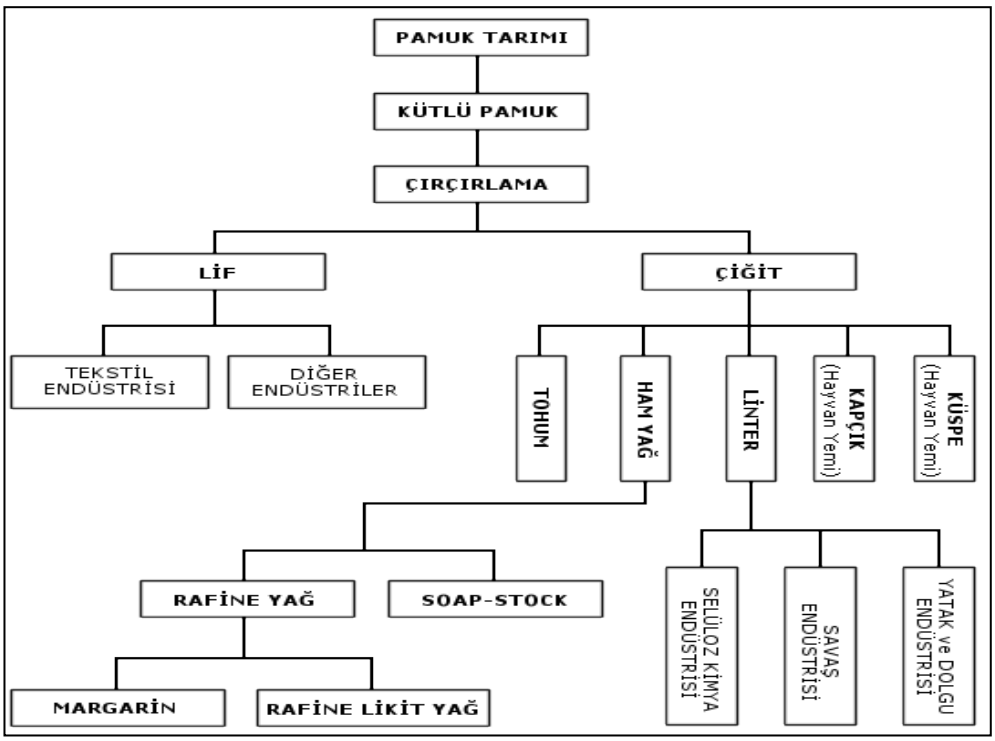
Pamuk tarımında asıl gelişme Türkiye Cumhuriyeti döneminde olmuştur. Pamuk ıslah istasyonları kurulmuş ve ABD'den getirtilen çeşitlerle pamuk araştırmaları başlatılmıştır. Günümüze kadar geliştirilerek sürdürülen bu araştırmalar

sonucunda, ülke ve uluslararası Pazar istekleri ile bölge ekolojilerine uygun birçok pamuk çeşidi elde edilmiştir (Anonim, 2014a).

3.1.1.2. Pamuğun Kullanım Alanları

Pamuk, bitkisel yağ ve yem sanayisinden, tekstil ve hazır giyim sanayisine değin kullanım alanlarının çeşitliliğiyle tarıma dayalı sanayinin önemli hammaddelerinden biridir. Gelişmiş ve gelişmekte olan birçok ülkenin istihdamından sanayisine kadar çeşitli katma değerler yaratan bir üründür. (Kılıç, 2013)

Endüstri bitkileri içinde lif ve yağ bitkilerinin her ikisine de giren pamuk, şekil 3.2.'de görüldüğü gibi birçok sanayinin temel hammaddesini karşılayan önemli bir bitkidir. Lifi ile tekstil sanayinin, çekirdeğinden elde edilen pamuk yağı ile bitkisel yağ sanayinin, kapçık ve küspesi ile yem sanayinin, lifleri de selüloz sanayinin hammaddesini teşkil etmektedir.



Şekil 3.1. Pamuğun Kullanım Alanları

3.1.1.3. Pamuğun Türkiye İçin Sosyo-Ekonomik Önemi

Türkiye, Dünya pamuk üretiminde sekizinci, tüketimde ise dördüncü sırada yer alan önemli bir pamuk ülkesidir. Ülkemizde her yıl yaklaşık 600 bin hektar alanda 2 milyon ton dolayında kütlü pamuk üretilmekte ve bunlar çırçır sanayimizde işlenerek yaklaşık 900 bin ton lif pamuk, 1.1 milyon ton çiğit elde edilmektedir. Pamuk üretiminde, diğer tarım ürünleriyle karşılaştırılmayacak kadar yoğun girdi kullanılmaktadır. Dolayısıyla, pamuk tarımı yüksek üretim değerinin yanı sıra, bu girdileri sağlayan tohum, gübre, ilaç, makine sanayi; ticaret ve ulaştırma sektörü ile işçilerden oluşan çok geniş bir kesimin gelir ve istihdam kaynağı olmaktadır. Mevcut pamuk üretimimizde her yıl 120 milyon yevmiyeden fazla insan işgücü tüketilmekte; 500 bin daimi, 1.5 milyon geçici istihdam yaratılmaktadır. Sadece tarım kesiminde 3.5 milyonu aşkın insan geçimini pamuktan sağlamaktadır. Yerli pamuk üretiminin değeri 2011 itibariyle 1.2 milyar doları aşmakta ve Gayri Safi Tarımsal Hâsılamızın % 2 'sini oluşturmaktadır.

Türkiye, Dünya tekstil ihracatında dokuzuncu, hazır giyim ihracatında ise altıncı sırada yer alan önemli bir tekstil ve hazır giyim ülkesidir. Tekstil sanayimizin temel hammaddesi pamuktur; üretimin yarısından fazlasını pamuklu ürünler oluşturmaktadır. Hazır giyimde de yine önemli oranda pamuklu mensucat kullanılmaktadır. Lif pamuk bu şekilde 5 ile 20 kat artan değerlerle ülke ekonomisine kazandırılmakta, ayrıca bu kazancın önemli bölümü ihracat geliri olarak sağlanmaktadır. Türkiye, tekstil ve hazır giyim sanayilerinde halen yılda yaklaşık 2 milyar dolar değerinde lif pamuk işlenerek toplam değeri 15 milyar dolar kadar dış gelir elde edildiği, ayrıca 2.5 milyon kişi istihdam edilerek 10 milyondan fazla insanımıza geçim kaynağı sağlandığı tahmin edilmektedir.

Pamuğun ülke ekonomisine katkısı tarım, tekstil ve konfeksiyon sanayi ile sınırlı kalmamakta, bitkisel yağ, yem, v.b., sanayi dallarındaki kazanımlarla sürmektedir. Örneğin, kütlü pamuk üretiminden elde edilen 1.3 milyon ton dolayındaki pamuk çekirdeği, yüksek yağ oranı nedeniyle, bitkisel yağ sanayinde kullanılmakta ve yurt içi tüketimi karşılamada 1.2 milyon ton açığı bulunan yağ sanayimizin, ayçiçeği ile birlikte en önemli ham maddesini oluşturmaktadır. Yağ

çıkarma sürecinde ortaya çıkan pamuk küspesi de, yüksek protein içeriği ile yem sanayinin vazgeçilmez girdisi olmaktadır (Anonim, 2014c).

3.1.1.4. Pamuk Ekim Alanları

Uluslararası Pamuk Danışma Kurulu (ICAC) verilerine göre; 2003/04 dönemi ile 2009/10 dönemi arasında dünyada ortalama 33 milyon hektar alanda pamuk üretimi yapıldığı, 2008/09 ile 2009/10 dönemlerinde yaklaşık 30 milyon hektar ekim alanı ile ortalamanın oldukça altında kalındığı tespit edilmektedir. 2012/13 sezonunda ekim alanlarındaki artışın 33.8 milyon hektarlara ulaşmıştır. 2013/14 sezonunda ise 32.9 milyon hektar olacağı öngörülmektedir.

Çizelge 3.1. incelendiğinde Dünya pamuk ekim alanlarının en geniş olduğu ülke yaklaşık 11 milyon hektar alan (% 34) ile Hindistan'dır. Onu sırasıyla Çin, ABD, Pakistan, Özbekistan, Brezilya, Burkina Faso ve Türkmenistan izlemektedir. Türkiye'nin ekim alanları tablodaki sekiz dönemin ortalamasına göre dokuzuncu sırada yer almaktadır. (Anonim, 2013)

Çizelge 3.1. Dünya Pamuk Ekim Alanları (Bin Ha)

Ülkeler	**2007/08**	**2008/09**	**2009/10**	**2010/11**	**2011/12**	**2012/13**	**2013/14**	**2014/15**
Hindistan	9.439	9.373	10.120	11.142	12.178	11.760	11.878	11.878
Çin	6.317	6.317	5.419	5.166	5.528	4.975	4.600	3.910
ABD	4.245	3.063	3.112	4.330	3.829	3.793	3.149	3.401
Pakistan	3.055	2.850	3.110	2.800	2.800	2.960	2.914	2.856
Özbekistan	1.450	1.391	1.317	1.330	1.316	1.285	1.246	1.284
Brezilya	1.077	840	836	1.400	1.393	870	1.063	1.063
Burkina Faso	407	466	420	374	429	586	557	562
Türkmenistan	642	674	607	550	550	525	550	550
Türkiye	**500**	**365**	**280**	**380**	**542**	**488**	**500**	**490**
Tanzanya	450	400	348	460	568	420	409	434
Myanmar	310	310	310	349	349	349	332	332
Zimbabve	308	375	340	390	450	397	357	339
Arjantin	304	285	430	550	528	362	554	554
Diğer	4.332	3.947	3.644	4.109	5.582	5.102	4.887	4.896
TOPLAM	**32.836**	**30.656**	**30.293**	**33.330**	**36.042**	**33.872**	**32.996**	**32.549**

3.1.1.5. Dünya Pamuk Verimleri

Son yıllar itibariyle pamuk ekim alanlarında ve verimlerde önemli artış kaydedilmemiştir. Dünya lif pamuk verim rakamları ülkeler itibariyle çizelge 3.2.'de gösterilmiştir.

Çizelge 3.2. Dünya Lif Pamuk Verimleri (Kg/Ha)

Ülkeler	2008/09	2009/10	2010/11	2011/12	2012/13	2013/14	2014/15
Avustralya	2.006	1.861	1.522	1.800	2.138	2.269	2.280
İsrail	1.667	1.762	1.860	1.930	1.786	1.746	1.894
Brezilya	1.439	1.429	1.475	1.352	1.450	1.437	1.444
Meksika	1.235	1.313	1.357	1.407	1.511	1.459	1.466
Çin	1.311	1.300	1.226	1.339	1.467	1.514	1.521
Türkiye	**1.333**	**1.357**	**1.184**	**1.384**	**1.759**	**1.380**	**1.473**
Suriye	1.263	1.206	1.071	1.140	1.100	976	981
Yunanistan	960	919	720	933	930	974	974
ABD	911	871	910	886	1.012	904	908
Mısır	795	785	869	821	895	828	832
Pakistan	683	666	636	819	740	744	423
Özbekistan	719	645	684	669	778	697	704
Türkmenistan	441	412	562	600	638	485	582
Hindistan	524	489	475	400	518	526	526
Arjantin	410	510	509	398	434	447	447
Burkina Faso	390	362	380	404	586	444	453
Dünya Ort.	**770**	**733**	**734**	**757**	**792**	**735**	**763**

Türkiye, dünya pamuk verimi sıralamasında altıncı, önemli pamuk üretici ülkeler arasında ise verim yönüyle Çin ve Brezilya'dan sonra üçüncü konumdadır. Ancak, Türkiye veriminin Genetiği Değiştirilmiş Organizma (GDO)'suz üretim yapan ülkeler sıralamasında önemli bir konumdadır.

Dünya pamuk ekim alanlarında önemli pay alan Hindistan, Pakistan, Özbekistan ve Türkmenistan ortalama verim düzeylerinin altında bir verimle üretim yapmaktadır. Bu ülkelerin verim düzeylerinde yaşanacak artış, dünya pamuk üretiminde de önemli artışların yaşanmasına neden olacaktır.

3.1.1.6. Dünya Pamuk Üretimi

Dünyada en büyük pamuk üretimi Çin'de gerçekleşmektedir. Çin'i pamuk üretiminde artış gösteren Hindistan izlemekte, bu ülkeleri ise ABD, Pakistan, Brezilya, Avustralya, Özbekistan ve Türkiye takip etmektedir.

Dünya lif pamuk üretimi 2004-2007 yılları arasında 26 milyon ton seviyelerinde gerçekleşirken, çizelge 3.3.'te görüldüğü üzere 2008/2009 döneminde 23.5; 2009/2010 döneminde ise 22.2 milyon ton seviyesine gerilemiştir. 2010/2011 döneminde üretim artış eğilimine girmiş ve 25 milyon tonu aşmıştır. 2011/2012 tahminleri üretimin 28 milyon tonu yakalamış, 2012/2013 döneminde lif pamuk üretimi 26.8 milyon tona, 2013/2014 döneminde 25 milyon ton ve 2014/2015 döneminde 24.84 milyon tonlara gerileyeceği öngörülmektedir.

Ülkemizin dünya üretimindeki payı, 2011/2012 sezonunda % 2.7 olmuştur. 2012/2013 sezonunda % 3.1, 2013/2014 sezonunda % 3.2 ve 2014/2015 sezonunda ise % 2.9 olacağı tahmin edilmektedir.

Çizelge 3.3. Dünya Lif Pamuk Üretimi (Bin Ton)

Ülkeler	**2008/09**	**2009/10**	**2010/11**	**2011/12**	**2012/13**	**2013/14**	**2014/15**
Çin	8.025	6.925	6.400	7.400	7.300	6.700	5.950
Hindistan	4.930	5.185	5.865	6.001	6.095	6.440	6.250
ABD	2.790	2.654	3.942	3.391	3.770	2.850	3.090
Pakistan	1.926	2.070	1.907	2.294	2.204	2.100	2.160
Brezilya	1.214	1.194	1.960	1.884	1.261	1.640	1.540
Avustralya	329	389	898	1.080	999	995	939
Özbekistan	1.000	850	910	880	1.000	920	950
Türkiye	**500**	**475**	**618**	**750**	**858**	**843**	**722**
Türkmenistan	297	250	360	330	335	329	320
Yunanistan	240	215	180	280	248	280	268
Diğer	2.252	2.040	2.325	2.994	2.768	2.695	2.650
TOPLAM	**23.503**	**22.247**	**25.365**	**27.284**	**26.838**	**25.792**	**24.839**

3.1.1.7. Dünya Pamuk Tüketimi

Dünyada en çok pamuk tüketen ülkeler, yine en çok üretim payına ve pamuğu işleme kapasitesine sahip olan Çin, Hindistan, Pakistan ve Türkiye gibi ülkelerdir. 2006/2007 döneminde dünya tüketimi en yüksek seviyesine çıkmışken, 2008 yılında tüm dünyada pamuk üretim düşüşlerine paralel olarak tüketimde de daralma yaşanmıştır. Çizelge 3.4.'te görüldüğü gibi 2011/2012 döneminde artan fiyatlara paralel olarak 22.7 milyon tonlara gerileyen tüketimin 2012/2013 döneminde 23.5 milyon tona, 2013/2014 döneminde ise 23.7 milyon ton ve 2014/2015 döneminde 24.54 milyon tona çıkacağı öngörülmektedir.

Çizelge 3.4. Dünya Lif Pamuk Tüketimi (Bin Ton)

Ülkeler	2008/09	2009/10	2010/11	2011/12	2012/13*	2013/14	2014/15
Çin	9.156	10.192	9.580	8.635	8.290	8.040	7.800
Hindistan	3.863	4.300	4.509	4.340	4.845	5.100	5.510
Pakistan	2.428	2.402	2.100	2.217	2.416	2.490	2.610
Türkiye	**1.175**	**1.350**	**1.300**	**1.495**	**1.350**	**1.404**	**1.544**
Brezilya	974	1.024	958	888	887	930	930
ABD	781	773	849	718	751	784	823
Bangladeş	810	851	770	700	800	800	880
Endonezya	435	452	438	448	493	600	690
Meksika	410	420	415	390	236	238	250
Vietnam	267	355	362	378	412	453	544
Diğer	3.096	3.080	3.119	2.832	2.860	2.923	2.963
TOPLAM	**23.395**	**24.485**	**24.528**	**22.797**	**23.340**	**23.762**	**24.544**

3.1.1.8. Türkiye Pamuk Üretimi ve Tüketimi

Türkiye'de pamuk tarımı genelde Ege Bölgesi, Güneydoğu Anadolu Bölgesi ile Çukurova ve Antalya yörelerinde yapılmaktadır. Son on yıllık süreçte pamuk ekim alanlarının yaklaşık % 25 oranında gerilediği aşağıdaki tablodan görülebilmektedir. Çizelge 3.5.'te görüldüğü gibi bölgeler bazında incelendiğinde ekim alanlarında en önemli düşüşlerin sırasıyla Ege, Antalya ve Çukurova bölgelerinde olduğu görülmektedir.

Türkiye'nin başlıca pamuk üretim bölgeleri;

1. Ege Bölgesi: Gediz, Büyük – Küçük Menderes ve Batı Akdeniz Havzaları

2. Çukurova Bölgesi: Seyhan, Ceyhan, Asi Havzaları

3. Antalya Bölgesi: Antalya, Finike, Kalkan, Serik, Manavgat, Alanya Ovaları

4. Güneydoğu Anadolu Bölgesi: Adıyaman, Şanlıurfa, Diyarbakır, Mardin, Fırat Havzaları

5. Diğer Bölgeler: Hatay, Meriç, Susurluk, Aras, Dicle

Çizelge 3.5. Bölgeler İtibariyle Türkiye Pamuk Ekim Alanları (Bin Ha)

Sezon	Ege	Çukurova	Güneydoğu Anadolu	Antalya	TOPLAM
2003/04	202.8	125.8	300.5	8.2	637.3
2004/05	176.0	130.1	325.4	8.5	640.0
2005/06	142.8	102.5	295.3	5.4	546.0
2006/07	150.5	125.7	309.7	4.2	590.2
2007/08	119.1	114.9	292.0	3.9	529.8
2008/09	82.6	95.2	313.1	3.9	494.9
2009/10	81.1	99.5	235.8	3.4	419.9
2010/11	83.3	105.3	287.7	4.2	480.5
2011/12	98.1	124.1	313.9	5.9	542.0
2012/13	83.5	96.9	302.2	5.7	488.4

Çizelge 3.6'da görüldüğü üzere lif pamuk üretimimizde en önemli bölge Güneydoğu Anadolu Bölgesidir. 2011/12 sezonunda üretimin yaklaşık % 58'i Güneydoğu Anadolu Bölgesinde, % 23'ü Çukurova'da, % 18'i Ege Bölgesinde ve % 1'i Antalya yöresinde gerçekleştirilmiştir.

Ülkemiz pamuk üretiminde son yıllarda yaşanan düşüşe paralel olarak, dünyanın en kaliteli pamuklarının yetiştirildiği Ege Bölgesinde de pamuk üretim alanları önemli ölçüde gerilemiştir. 2000'li yılların başlarında 200 bin hektar seviyelerinde olan Ege Bölgesi pamuk ekim alanları 98 bin hektar seviyelerine gerilemiştir. 2003/04 dönemine oranla Ege Bölgesindeki düşüş oranı % 58.9 olarak gerçekleşmiştir.

Çizelge 3.6. Bölgeler İtibariyle Türkiye Lif Pamuk Üretimi (Bin Ton)

Sezon	Ege	Çukurova	Güneydoğu Anadolu	Antalya	TOPLAM
2003/04	265.9	197.3	443.9	13.3	919.5
2004/05	254.4	191.7	476.2	12.4	939.9
2005/06	218.5	186.9	448.0	13.6	863.7
2006/07	225.2	241.0	502.7	10.3	976.5
2007/08	166.1	223.3	472.1	7.6	867.7
2008/09	95.0	150.1	423.1	6.1	673.4
2009/10	113.9	170.4	348.7	5.2	638.2
2010/11	143.9	201.3	464.2	7.3	816.7
2011/12	168.4	239.0	535.9	11.2	954.6
2012/13	152.4	181.8	512.6	11.5	858.4

TUİK verilerine göre son on yıllık süreçte en yüksek lif pamuk üretimi 976.5 bin ton ile 2006/07 sezonunda en düşük pamuk lif üretimi ise 638 bin ton ile 2009/10 sezonunda gerçekleşmiştir. 2012/13 sezonunda lif pamuk üretimi bir önceki sezona göre % 10 oranında azalarak 858.4 bin tona gerilemiştir.

2012/13 sezonunda hemen hemen bütün bölgelerde üretim miktarı azalmıştır. Ege Bölgesinde % 9, Güneydoğu Anadolu Bölgesinde % 4, Çukurova Bölgesinde % 24 oranında azalma; Antalya Bölgesinde ise % 2 oranında artış olmuştur.

Uluslararası Pamuk Danışma Kurulu'nun projeksiyonuna göre, 2013/14 sezonunda 843 bin ton olan lif pamuk üretimimizin 2014/15 sezonunda % 15'lik bir azalışla 722 bin ton olarak gerçekleşeceği tahmin edilmektedir.

Çizelge 3.7. Türkiye Lif Pamuk Üretim ve Tüketimi (Bin Ton)

YIL	ÜRETİM	TÜKETİM	FARK	ÜRETİMİN TÜKETİMİ KARŞILAMA ORANI(%)
2008/09	500	1.175	-675	42,5
2009/10	475	1.350	-875	35,2
2010/11	618	1.300	-682	47,5
2011/12	750	1.300	-550	57,7
2012/13	858	1.350	-492	63,5

Çizelge 3.7. **(devam)**

2013/14	843	1.404	-561	60
2014/15	722	1.544	-822	46,7
Ortalama	**680**	**1.346**	**-666**	**50,5**

2008 ve 2009 yıllarında yaşanan küresel ekonomik krizin olumsuz etkisiyle pamuğun özellikle üretimi olmak üzere, tüketim ve ticareti sadece Türkiye'de değil tüm dünyada azalmıştır. Çizelge 3.7'de görüldüğü üzere 2011/12 sezonunda fiyatlarda yaşanan tarihi seviye nedeniyle tüm dünyada olduğu gibi ülkemizde de üretim artmıştır. Ancak gevşeyen fiyatların da etkisi ile önümüzdeki dönemde dünyada ve ülkemizde üretimde düşüşün sürmesi beklenmektedir.

3.1.1.9. Dünya Pamuk İthalatı

Çin, Türkiye ve Bangladeş yıllara göre değişmekle birlikte dünyanın en büyük pamuk ithalatçıları konumundadır. Çin diğer iki ülkeden farklı olarak dünyanın başta gelen pamuk üreticisi olmasına karşın tekstil ve konfeksiyon sektörünün artan ihtiyaçları sebebiyle aynı zamanda küresel olarak büyük ithalatçılar arasında yer almaktadır.

Dünya pamuk ithalatının küresel krizle birlikte çizelge 3.8'de görüldüğü gibi 2008/09 sezonunda 6.6 milyon tona gerilemesine rağmen, gelişmekte olan ülkelerde yaşanan olumlu gelişmelere paralel olarak 2010/11 sezonunda 7.7 milyon tonun üzerine çıktığı görülmektedir. En büyük ithalatçı ülke konumundaki Çin'in yıllardır 2-2.5 milyon ton aralığında gerçekleşen ithalatı, 2011/12 sezonunda 9.7 milyon ton ve 2013/14 sezonlarında 8.5 milyon ton seviyelerinde olacağı ve 2014/15'de ise 7.7 milyon tona gerileyeceği öngörülmektedir.

Çizelge 3.8. Dünya Lif Pamuk İthalatı (Bin Ton)

Ülkeler	**2008/09**	**2009/10**	**2010/11**	**2011/12**	**2012/13**	**2013/14**	**2014/15**
Çin	1.523	2.374	2.609	5.342	4.426	3.127	1.960
Bangladeş	816	775	750	680	593	837	853
Türkiye	**630**	**961**	**729**	**519**	**804**	**599**	**849**
Endonezya	430	464	420	440	683	699	648

Çizelge 3.8. **(devam)**

Vietnam	264	363	363	379	429	480	544
G. Kore	215	220	230	255	286	311	285
Tayland	349	393	375	275	329	352	387
Meksika	285	305	292	221	245	114	142
Tayvan	171	221	195	188	205	214	193
Pakistan	417	342	314	195	430	463	495
Diğer	1.547	1.510	1.448	1.261	1.279	1.331	1.386
TOPLAM	**6.647**	**7.928**	**7.725**	**9.775**	**9.709**	**8.527**	**7.742**

3.1.1.10. Dünya Pamuk İhracatı

Dünyanın en büyük pamuk ihracatçısı ülkeler yıllara göre değişmekle birlikte, çizelge 3.9.'da görüldüğü üzere ortalama olarak % 35-35'lik payla ilk sırayı alan ABD'yi, % 19-20'lik payla Hindistan ve son yıllardaki üretim artışları ile dikkat çeken önemli ihracatçı ülkelerden Brezilya ve Avustralya takip etmektedir.

10 yıl öncesine kadar dünya pamuk üretim ve ticaretindeki yeri çok daha gerilerde olan Hindistan ve Avustralya, GDO'lu pamuk üretimine geçişle beraber 7 yılda pamuk ihracatını önemli oranda arttırmıştır.

Ortalama 7.7 milyon ton olan dünya ihracatı 2011/12 sezonunda Çin'in tarihi ithalat miktarına paralel olarak 9.8 milyon ton seviyelerine çıkmıştır. İhracatın 2012/13 sezonunda 10 milyon ton 2013/14 sezonunda 8.5 milyon ve 2014/2015 sezonunda 7.7 milyon ton olacağı tahmin edilmektedir.

Çizelge 3.9. Dünya Lif Pamuk İhracatı (Bin Ton)

Ülkeler	**2009/10**	**2010/11**	**2011/12**	**2012/13***	**2013/14****	**2014/15****
ABD	2.621	3.130	2.526	2.902	2.240	2.210
Hindistan	1.420	1.085	2.159	1.685	1.330	1.030
Avustralya	460	545	1.010	1.345	1.000	760
Brezilya	433	435	1.043	938	820	700
Özbekistan	820	600	550	653	680	530
Pakistan	156	110	250	92	80	81
Yunanistan	220	155	200	237	261	241

Çizelge 3.9. **(devam)**

Burkina Faso	182	138	152	215	253	243
Türkmenistan	235	230	118	171	195	168
Türkiye	**33**	**32**	**65**	**47**	**38**	**38**
Diğer	1.570	1.179	1.697	1.741	1.630	1.741
TOPLAM	**8.150**	**7.639**	**9.770**	**10.026**	**8.527**	**7.742**

3.1.1.11. Türkiye'nin Pamuk İhracatı

Ülkemizde yıllar itibariyle tekstil sektöründe yaşanan genişlemeye paralel olarak pamuk tüketimindeki artış iç üretim artışıyla karşılanamadığından, pamuk ithalat miktarı artmış ve 1990 yılına kadar pamuk ihracatçısı olan Türkiye, başlıca pamuk ithalatçısı ülkelerden biri konumuna gelmiştir.

Çizelge 3.10. Türkiye Pamuk İhracatı

Sezon	**Miktar (Bin Ton)**	**Miktar Endeksi**	**Değer (Milyon $)**	**Değer Endeksi**
2003/04	78.0	115	118.0	153
2004/05	33.0	48	49.0	64
2005/06	47.0	69	66.4	86
2006/07	66.0	97	92.0	119
2007/08	80.6	118	141.9	184
2008/09	29.7	44	53.9	70
2009/10	32.5	48	60.5	78
2010/11	31.8	47	102.7	133
2011/12	65.2	96	143.8	186
2012/13	47.2	69	96.7	125

Çizelge 3.10'da görüldüğü gibi bazı sezonlarda artış olsa da son on sezonluk dönemde pamuk ihracatı 30 bin ton seviyelerinde gerçekleşmiştir. Bu dönemde en fazla ihracat yaklaşık 81 bin ton ile 2007/08 sezonunda, en düşük ihracat ise 29.7 bin ton ile 2008/09 sezonunda gerçekleşmiştir. 2012/13 sezonunda ihracat miktarı bir önceki sezona göre % 27 oranında azalmıştır. Ayrıca çizelge 3.11'de Türkiye ihracatının ülkelere göre dağılımı gösterilmiştir.

Çizelge 3.11. Türkiye'nin İhracatının Ülkelere Göre Dağılımı

Ülkeler	Ton	Pay (%)	Bin $	Pay (%)
İtalya	8.201	17.4	17.076	17.7
Polonya	6.684	14.2	14.266	14.8
Mersin Serbest Böl.	4.754	10.1	7.403	7.7
Hollanda	3.990	8.5	9.126	9.4
Fransa	2.598	5.5	5.674	5.9
Yunanistan	2.379	5.0	4.920	5.1
Endonezya	2.315	4.9	3.745	3.9
Almanya	2.071	4.4	4.932	5.1
ABD	1.309	2.8	2.399	2.5
Diğer	11.616	24.6	24.779	25.6
TOPLAM	**47.197**	**100.0**	**96.698**	**100.0**

3.1.1.12. Türkiye'nin Pamuk İthalatı

Türkiye, iç üretimin tüketimi karşılayamaması sebebiyle dünyanın en fazla pamuk ithal eden ikinci ülkesi konumundadır. Çizelge 3.12'de verilen TUİK verilerine göre, ülkemizin pamuk ithalatına sezonlar itibariyle bakıldığında, son on yıllık dönemde en fazla ithalat, 961 bin ton ile 2009/10 sezonunda, en düşük ithalat ise 516.9 bin ton ile 2003/04 sezonunda yapılmıştır.

Çizelge 3.12. Türkiye Pamuk İthalatı

Sezon	Miktar (Bin Ton)	Miktar Endeksi	Değer (Milyon $)	Değer Endeksi
2003/04	516.9	105	761.5	139
2004/05	748.4	152	882.8	161
2005/06	762.3	154	960.8	175
2006/07	877.3	178	1137.9	207
2007/08	711.4	144	1099.8	200
2008/09	630.2	128	866.4	158
2009/10	960.9	195	1570.2	286
2010/11	729.4	148	2044.1	372
2011/12	518.6	105	1274.2	232
2012/13	803.7	163	1513.3	276

Çizelge 3.13'e göre Türkiye'nin pamuk ithalatının yaklaşık % 70'i ABD ve Yunanistan'dan yapılmaktadır. ABD'nin payı % 50-60 civarındadır. Bu ülkeleri Türkmenistan, Brezilya, Tacikistan, Hindistan ve Suriye gibi ülkeler takip etmektedir.

Çizelge 3.13. Türkiye İthalatının Ülkelere Göre Dağılımı

Ülkeler	Ton	Pay (%)	Bin $	Pay (%)
ABD	456.112	56.7	872.810	57.7
Yunanistan	94.480	11.8	170.790	11.3
Brezilya	56.054	7.0	117.887	7.8
Türkmenistan	104.442	13.0	186.905	12.4
Tacikistan	30.668	3.8	53.795	3.6
Arjantin	4.784	0.6	9.084	0.6
Suriye	21.451	2.7	33.205	2.2
Özbekistan	5.608	0.7	6.737	0.4
Mısır	3.972	0.5	12.187	0.8
Hindistan	7.477	0.9	15.010	1.0
Diğer	18.712	2.3	34.906	2.3
TOPLAM	**803.760**	**100.0**	**1513.32**	**100.0**

3.1.1.13. Dünya ve Türkiye Pamuk Fiyatları

Pamuk üretiminde yüksek girdi maliyeti, üreticinin rekabet gücünü olumsuz etkileyen temel faktörlerden biridir. Pamukta girdi/ürün fiyatı paritesi girdiler aleyhine artmasının yanı sıra sübvansiyonlu ithalatın da etkisi ile "ortalama iç piyasa fiyatı" maliyeti karşılama konusunda yetersizdir. Bu nedenle devlet destekleri ile aradaki fark dengelenmeye çalışılmaktadır. Çizelge 3.14'te Türkiye kütlü pamuk üretici fiyatları gösterilmiştir.

Çizelge 3.14. Türkiye'de Kütlü Pamuk Üretici Fiyatları (TL/Kg)

	2006	2007	2008	2009	2010	2011	2012	2013
Ocak	1,20	1,28	1,29	1,20	1,58	1,97	1,33	1,26
Şubat	1,29	1,27	1,29	1,25	1,58	2,13	1,36	1,27
Mart	1,25	1,28	1,34	1,26	1,69	2,11	1,30	1,28
Nisan	1,27	1,28	1,43	1,26	1,72	1,98	1,17	1,26

Çizelge 3.14. **(devam)**

Mayıs	1,30	1,32	1,43	1,30	1,82	1,96	1,16	1,23
Haziran	1,37	1,28	1,47	1,34	1,88	1,94	1,17	1,25
Temmuz	1,48	1,29	1,49	1,35	1,94	1,93	1,18	1,24
Ağustos	1,46	1,27	1,48	1,37	1,92	1,92	1,16	1,24
Eylül	1,37	1,28	1,42	1,42	1,93	1,89	1,16	1,30
Ekim	1,33	1,30	1,33	1,40	2,04	1,66	1,29	1,61
Kasım	1,27	1,28	1,33	1,42	2,43	1,56	1,29	1,63
Aralık	1,29	1,26	1,22	1,54	2,43	1,39	1,29	1,61

Pamuk dış piyasa fiyatlarının oluşmasında en önemli etken, Dünya pamuk üretimini elinde bulunduran ülkelerin (ABD, Çin Halk Cumhuriyeti gibi) üretim miktarları ve stoklarıdır. Pamuğun yanı sıra yün, tiftik, sentetik iplik gibi dokuma sanayine yönelik diğer liflerin üretim miktar ve fiyatları da pamuk fiyatlarında önemli rol oynamaktadır.

Çizelge 3.15. Türkiye ve Dünya Yıllık OrtalamaPamuk Fiyatları (TL/Kg)

Yıllar	Türkiye	Dünya
2000	0.91	0.82
2001	1.34	1.25
2002	1.72	1.55
2003	2.19	2.09
2004	2.16	1.95
2005	1.85	1.63
2006	1.98	1.85
2007	2.01	1.85
2008	2.15	2.05
2009	2.25	2.13
2010	3.76	3.39
2011	5.27	5.50
2012	3.49	3.54
2013	3.89	3.79
2014	4.28	4.00

Çizelge 3.15'te görüldüğü gibi 2010 yılından başlamak üzere özellikle 2011 yılında pamuk fiyatları, son 150 yılın en yüksek seviyesine çıkmıştır. Bu rekor yükselişin ana nedenleri;

-Dünyada pamuk üretim miktarının tüketimden daha yüksek oranda düşmesi,

-2008 ve 2009 yıllarında dünya pamuk stoklarında görülen gerileme,

-Avustralya, Pakistan, Hindistan ve Çin'deki kötü hava koşulları nedeniyle üretimin azalması,

-ABD'nin pamuk politikaları,

-Bir yıl öncesinde Çin'in pamuk ithalatının % 86 oranında artması,

-Hindistan'da devletin çiftçiyi desteklemek için pamuğu yüksek fiyattan alması ve Hindistan'ın pamuk ihracatına uygulamış olduğu kısıtlama,

-Dünyadaki pamuk üretim alanlarının azalması,

-Özellikle tekstil sanayinin hızla gelişmesi nedeniyle pamukta güçlü bir talep oluşması,

şeklinde ifade edilebilir (Anonim, 2011).

3.2. Yöntem

Çalışmada Yapay Sinir Ağları, Çoklu Regresyon Analizi ve Box – Jenkins yöntemleri ile pamuk fiyat analizi yapılacaktır. Analizlere geçmeden önce yöntemler, ayrıntılı olarak incelenecek ve çalışma prensipleri hakkında bilgiler verilecektir.

3.2.1. Doğal Zekâ

Birçok felsefeci ve psikolog tarafından yapay zekâ gibi doğal zekânın da farklı tanımları verilmektedir. Fransız felsefeci Taine'ye göre zekâ; zihinsel hayatı kurmayı amaçlayan bir araçtır.

Binet'e göre zekâ; insanın sahip olduğu dikkat, bellek, yargılama, akıl yürütme, soyutlama vs. gibi yetiler topluluğudur.

Wechsler' göre zekâ; bireyin amaçlı bir biçimde hareket edebilme, mantıklı düşünebilme ve çevresine uyum gösterme yetilerinin tamamıdır.

Genel bir ifadeyle zekâ; insanın düşünme, akıl yürütme, nesnel gerçekleri algılama, yargılama ve sonuç çıkarma yeteneklerinin tamamıdır.

Bazen zekâ; yeni duruma hızlı biçimde ayak uydurmak, uyum sağlamak biçiminde de tanımlanmaktadır.

Prof. Dr. Howard Gardner, çoklu zekâ kavramını ileri sürmüştür. Gardner teorisi açısından, farklı zeka türleri vardır ve çocukların sahip oldukları yeteneklere ve ilgi duydukları alanlara göre 8 grup oluşturulmaktadır:

1. Dilsel Zekâ: Konuşma ve yazma dilinde sözcükleri etkili kullanma yeteneğidir. (politikacılar, yazarlar)

2. Sosyal Zekâ: Diğerlerinin duygularını, ruh hallerini anlama yeteneğidir. (Politik liderler, danışmanlar)

3. Mantık-Matematik Zekâsı: Sebep- sonuç ilişkisi kurabilme, sayı ve numaraları akıllıca kullanma yeteneğidir. (Bilim adamları, matematikçiler, programcılar)

4. Mekânsal (görsel) Zekâ: Etraftaki nesneleri hayalinde canlandırma ve görme yeteneğidir.(Ressamlar, mimarlar)

5. Müzik Zekâsı: Seslere karşı duyarlılık gösterme kapasitesi ve kendini müzikte ifade etme yeteneğidir. (Müzisyenler)

6. Dışadönük (bedensel) Zekâ: Kişinin kendini ifade etmesinde bedenini kullanma kapasitesi ve kişinin ellerini bir şeyler oluşturmak için kullanma yeteneğidir. (Atletler, aktörler, dansçılar, heykeltıraşlar)

7. İçedönük (kişinin kendine dönük) Zekâsı: Kendini yönlendirme, idare etme ve tanıma kapasitesidir. (Psikologlar, psikoterapistler)

8. Doğal Zekâ: Bu gruba dâhil olanlar hayvanlara, temiz ve yeşil çevreye, doğa olaylarına ilgi duymaktadır. (Çevreciler)

Çoklu zekâ tanımından esinlenerek Daniel Goleman, "Duygusal Zeka" (EQ) kavramını ortaya açmıştır. R. Bandler ve J. Grinder ise, "İnsan Mükemmelliği Modeli" (NLP) kuramını geliştirmiştir. Son zamanlarda "Ruhsal Zekâ" (SQ) da konuşulmaktadır. Çoklu zekâ teorisine göre, herkesin zeki olabilme ihtimali yüksektir. Önemli olan ise, hangi zekâ türünün konuşulduğudur (Nabiyev, 2012).

Zekânın ne anlama geldiği ve ne kadarının ölçülebildiği konusunda henüz bir görüş birliği sağlanmış değildir. Latince "intellectus" kelimesinin karşılığı olan zekânın, kavramsal olarak birkaç tarifi şöyle sıralanabilir:

Cevap vermede, muhtemel çözümleri inceden inceye aramadaki çabukluk ve bir problemin evreleri arasındaki yeni ilişkileri anlayabilme kapasitesidir.

Yeni bir düzeneği veya kuralı keşfetme ya da bir tahmin yürütme ile ilgili faaliyettir.

Beynin bilgiyi alıp, hızlı ve doğru olarak analiz etmesidir.

Zekânın sözlük anlamı ise, insanın düşünme, akıl yürütme, nesnel gerçekleri algılama, kavrama, yargılama ve sonuç çıkarma yeteneklerinin tümü olarak verilmektedir.

Ağırlıklı olarak bilim adamları zekânın oluşumunda büyük payı kalıtıma vermektedirler. Sosyolog Charles Murray "Çan Eğrisi" adlı kitabında, kalıtımın rolünün % 60 dolaylarında olduğunu belirtmektedir. Günümüzde genellikle kabul edilen görüş, zekânın kısmen kalıtsal, kısmen de çevresel olduğu şeklindedir (Doğan, 2002).

Daha çağdaş psikoloji kuramcıları ise iki farklı türde zekâ tanımlamaktadırlar: akışkan zekâ ve kristalize zekâ. Çıkarsama, bellek, bilgi işleme yetenekleri ile ilgili durumlarda akışkan zekâ söz konusudur. Eğer bir problemin çözülmesinde deneyimlerle elde edilen strateji, yetenekler ve bilgiden bahsediliyorsa bu durumda kristalize zekâ söz konusudur (Yıldız, 2009).

3.2.2. Yapay Zekâ

Yapay zekânın bir bilim dalı olarak ortaya çıkış tarihi, ikinci dünya savaşı ve hemen sonrasıdır. Bu yıllarda ABD ve Avrupa'da insan davranışları ve zekâ üzerine yürütülen birbirinden bağımsız, fakat aslında birbirine bağımlı çalışmalar görmek mümkündür. Bu çalışmalarda Alan Turing'in zeki makineler, Norbert Wiener'in sibernetik ve Herbert Simon'un davranışlar üzerine yaptıkları araştırmalar öncü rol oynuyordu (Doğan, 2002).

Yapay zekâ, bir bilgisayarın ya da bilgisayar denetimli bir makinenin, genellikle insana özgü nitelikler olduğu varsayılan akıl yürütme, anlam çıkartma, genelleme ve geçmiş deneyimlerden öğrenme gibi yüksek zihinsel süreçlere ilişkin görevleri yerine getirme yeteneği olarak tanımlanmaktadır (Nabiyev, 2012). Başka bir deyişle, Yapay zekâ, insanların yaptıklarını bilgisayarlara yaptırabilme çalışmasıdır.

Yapay zekâ, aşağıdaki programları yapabilmelidir:

1. İnsanın düşünmesini taklit ederek karmaşık problemleri çözebilmek.

2. Yorumlarını açıklayabilmek, yani bir durum karşısında kişiye yanıt verebilmek.

3. Öğrenerek uzmanlığını geliştirmek ve eski bilgilerini yenilerle uyumlu biçimde kullanarak bilgi tabanını genişletmek (Nabiyev, 2012).

3.2.3. Yapay Zekâ ile Doğal Zekânın Karşılaştırılması

1. Yapay zekâ daha fazla kalıcıdır. Çünkü doğal zekâ zaman içinde çalışanlar yer değiştirdikçe değişebilir veya doğal zekâya sahip olan insanlar sahip oldukları bilgileri unutabilir.

2. Yapay zekâ kolaylıkla kopyalanabilir ve geniş kitlelere yayımlanabilir.

3. Yapay zekâ doğal zekâdan daha ucuza elde edilebilir.

4. Yapay zekâ bir bilgisayar teknolojisi olarak bütünüyle tutarlı sayılabilir.

5. Yapay zekâ belgelenebilir.

Bütün bunlara karşın doğal zekânın da yapay zekâdan üstün olduğu durumlar ve alanlar vardır.

1. Doğal zekâ, yaratıcı ve doğurgandır. Yapay zekâda ise yaratıcılık ve doğurganlık yok denecek kadar azdır.

2. Doğal zekâ, insanlara duyuları yoluyla öğrendiği deneyimleri kullanma ve bunlardan faydalanma yeteneği sağlar.

3. Doğal zekâ, insanın muhakeme gücünün, problemleri çözmek için geniş tecrübeleri, karşılaşılan konuya göre hemen kullanma yeteneğidir (Doğan, 2002).

Çizelge 3.16. Doğal Zeka ile Yapay Zekanın Karşılaştırılması

İnsan Uzmanlığı	**Yapay Uzmanlık**
Çabuk etkilenebilir	Kalıcı
Aktarılması güç	Kolay aktarılabilir
Dökümantasyonu güç	Kolay dökümante edilir
Tahmini zor	Tutarlı
Pahalı	Satın alınabilir
Yeni fikirler üretebilir	Esinlenemez
Uyumludur	Uyum dışarıdan sağlanmalıdır
Hassas gözlem yapabilir	Sembolik verilerle çalışır
Geniş görüş açısına sahiptir	Dar açıdan bakış
Sosyal duyuma sahiptir	Teknik duyuma sahiptir

3.2.4. Yapay Zekânın Amaçları

1. İnsan beyninin fonksiyonlarını modellerle anlamaya çalışmak.

2. İnsanın zihinsel yeteneklerini, bilgi kazanma, öğrenme ve buluş yapmada uyguladıkları strateji ve metotları araştırmak.

3. Bu metotları formel hale getirmek, bilgisayarlarda uygulamak.

4. Bilgisayar kullanımını kolaylaştıracak ara yüzler geliştirmek.

5. Uzman sistemler ve genel bilgi sistemleri geliştirmek.

6. Yapay zekâ iş yardımcıları ve zeki robot gelişimini yapabilmek.

7. Bilimsel araştırma ve buluşlar için araştırma yardımcıları geliştirmek.

şeklinde sıralamak mümkündür (Saraç, 2004).

3.2.5. Turing Testi

İngiliz matematikçi Alan Turing, 1950 senesinde "Mind" dergisinde basılmış "Computing Machinery and Intelligence" isimli makalesi, yapay zekâ alanında yazılmış en eski ve en ünlü makalelerden biridir. Yapay zekâ konusundaki hemen her çalışmada yerini bulan bu makalenin önemi, yapay zekâ konusunda felsefi bir tartışma yapmasından kaynaklanır. Turing bu makalesinde, "Makineler düşünebilir mi?" sorusuna cevap aramış ve makinelerin düşünemeyeceği konusundaki itirazları ret etmiştir (Turing, 1950). Turing testi olarak bilinen bu oyunda bilgisayar, insan ve sorgulayıcı (savcı) olmak üzere üç oyuncu iştirak etmektedir. İki haberleşme kanalı üzerinden savcı rolünü üstlenen kişi, insan ve bilgisayarla iletişim kurmaktadır. Bilgisayarın "düşünen programla" donatıldığı varsayılmaktadır. Soruların ve yanıtlarının tuşlar ve ekran aracılığıyla yapıldığı bir soru yanıt oyununda, savcının cevapları inceleyerek, bu yanıtların sahibinin makine veya insan olduğunu anlaması amaçlanmaktadır. Merak edilen makinenin bir insan kadar anlamlı yanıtlar vermesinin mümkünlüğü idi. Oyunda savcı, istenilen soruları verebilmektedir. Doğal olarak insan, kendisinin insan olduğunu ispatlamak için bir çaba sarf etmektedir. Oysa bilgisayar, insan düşüncesinin mümkün olduğu kadar iyi taklidini yapmaya çalışmaktadır. Birkaç soru cevaplaması sonunda savcı insanı bilgisayardan ayırabilirse, insan kazanmış oluyor. Turing testinde hangi ölçütlere dayanarak savcının karar vermesi açık değildir. Programcı, istatistikî verilere dayanarak sorular tekrarlandıkça nasıl cevaplanacağını programlayabilir. Fakat savcının farklı soru ve tavırlarının tümünü kestirebilmesi imkânsızdır. Turing testinde diğer açık nokta ise deneye tabi tutulan insanın kimliğidir. Bu, küçük bir çocuksa yanıtlar genellikle "evet/hayır" veya "bilmiyorum" biçimindedir. Yetişkin ve eğitimli birisinin cevapları ise daha dolgun biçimde olmaktadır ve bilgisayar programlarının bu derecede anlamlı ve geniş yanıtlarının olmasını beklemek zordur (Nabiyev, 2012).

3.2.6. Yapay Zekâ Teknolojileri

Zekâ araştırmaları derin, geniş, çok boyutlu, çok disiplinli bir alandır. Günümüzde insan zekâsının taklit edilmesinden henüz çok uzakta olduğumuzu söyleyebiliriz. Ancak zekânın değişik şekilleri ve boyutları, değişik yapay zekâ teknolojilerce taklit edilebilmektedir. Bu teknolojilerden en önemlileri, Uzman Sistemler, Genetik Algoritmalar, Bulanık Mantık ve Yapay Sinir Ağlarıdır. Bu teknolojilerin her biri, insan zekâsının değişik bir yanını taklit etmektedir. Ancak her birinin değişik eksiklikleri bulunmaktadır. Son yıllarda bu teknolojiler kullanılarak yeni melez teknolojiler elde edilmekte ve bir teknolojinin eksikliği bir diğer teknolojinin üstünlükleri ile kapatılmaktadır. Bu gelişmeler bize daha yetenekli ve üstün özellikli yapay zekâ teknolojileri sunmakta, insan zekâsına bir daha yaklaşılmaktadır. Yine de insan zekâsının henüz uzağında olduğumuz ve atılacak çok adım olduğu bilinen bir gerçektir (Yıldız,2009).

Başlıca Yapay zekâ teknolojileri 4 ana başlıkta incelenir:

3.2.6.1. Uzman sistemler

Belirli konuda uzman olan bir ve birçok insanın yapabildiği muhakeme ve karar verme işlemlerini modelleyen bir yazılım sistemidir. Bir sistemin uzman sistem olarak adlandırılması için bu sistemlerin kullanıcının hatalarını algılama ve yanlışlıkları bularak kullanıcıyı yönlendirme becerilerinin de olması gerekmektedir. Örneğin tıp konusunda yazılmış bir program doktorların önemli yardımcısı haline gelebilir. Parasal analiz, üretim planlaması, hukuki yasaların uygulaması veya mühendislerinkine benzer tasarım yapabilen sistem ya da yazılımların geliştirilmesi çalışmaları da uzman sistemlere ait çalışma alanlarıdır (Nabiyev, 2012).

3.2.6.2. Genetik Algoritmalar

Doğadaki canlıların geçirdiği süreci örnek alır ve iyi nesillerin kendi yaşamlarını korurken, kötü nesillerin yok olması ilkesine dayanır. Matematiksel modellemenin yapılamadığı veya kesin çözümün olmadığı problemlerde genetik algoritmadan yararlanılır. Bu algortima, anne ve baba bireyden (bir önceki nesil) doğan yeni bireylerin şartlara uyum sağlayıp yaşamlarını devam ettirmesine dayanır.

Yeni bireyler, anne ve babasından gelen iyi genleri bünyelerinde muhafaza edebileceği gibi kötü genleri de almış olabilir. Bu durumda kötü genlere sahip bireyler varlıklarını sürdüremeyecektir. Genetik algoritmalar, uygunluk (fitness) işlevi, yeni çözümler üretmek için çaprazlama ve değiştirme gibi operatörleri kullanır. Genetik algoritmanın önemli özelliklerinden birisi de bir grup üzerinde çözümü araması ve bu sayede çok sayıda çözümün içinden en iyiyi seçmesidir (Elmas, 2010). Genetik algoritmanın çeşitli uygulama alanları şöyle sayılabilir: otomatik programlama, veri madenciliği, montaj hattı dengeleme, atama problemleri, çizelgeleme, fabrika ve makine yerleşim problemleri, taşıma ve gezgin satıcı problemleri, rota problemleri, minimum maliyetli kablo döşeme, sermaye tesis problemleri, portföy optimizasyon problemleri, endeks tahminleri, ticari kurallar geliştirme, ürün taşarımı problemleridir (Yıldız, 2009).

3.2.6.3. Bulanık Mantık

1965 yılında Lotfi A. Zadeh tarafından yayınlanan bir makalede bulanık mantık veya bulanık küme kuramı adı altında ortaya konmuştur. Zadeh, bu çalışmasında insan düşüncesinin büyük çoğunluğunun bulanık olduğunu, kesin olmadığını belirtmiştir (Zadeh, 1965). İnsan mantığı, açık-kapalı, sıcak-soğuk, 0 ve 1 gibi değişkenlerden oluşan kesin ifadelerin yanı sıra, az açık, az kapalı, serin, ılık gibi ara değerleri de göz önüne almaktadır. Bulanık mantık klasik mantığın aksine iki seviyeli değil, çok seviyeli işlemleri kullanmaktadır. Bulanık kuramının uygulamalarının ürünleri Japonya'da 1990 yılında tüketicilere sunulmuştur. Arabalarda yakıt püskürtme ve ateşleme sisteminin denetimi, çamaşır makinesi, elektrik süpürgesi, televizyon ve müzik kümeleri gibi aygıtlarda bulanık mantık denetim kullanılmaktadır. Bugün elektronik pazarında pek çok üretim bulanık mantık temeline dayanmaktadır. Ayrıca ısı, elektrik akımı, sıvı gaz akımı denetimi, kimyasal ve fiziksel süreç denetimlerinde kullanılmaktadır (Elmas, 2010).

3.2.6.4. Yapay Sinir Ağları

İnsan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır. Yapay Sinir Ağları, bir başka deyişle,

biyolojik sinir ağlarını taklit eden bilgisayar programlarıdır. Yapay Sinir Ağları, bir programcının geleneksel yeteneklerini gerektirmeyen, kendi kendine öğrenme düzenekleridir. Bu ağlar öğrenmenin yanı sıra, ezberleme ve bilgiler arasında ilişkiler oluşturma yeteneğine de sahiptir. Yapay Sinir Ağları; denetim, sistem modelleme, ses tanıma, el yazısı tanıma, parmak izi tanıma, elektrik işareti tanıma, meteorolojik yorumlama, otomatik araç denetimi ve fizyolojik işaretler (kalp fonksiyonları gibi) izleme, tanıma ve yorumlama alanlarında kullanılmaktadır (Elmas, 2010).

3.2.7. Beyin

Beyin, yaklaşık olarak bir buçuk kilo ağırlığındadır ve bir cevizi andırır. Ortalama 60 yıllık ömür boyunca, saniyede 600 birimlik bilgiyi hafızamıza kaydedip işlemek ve programlamak kapasitesine sahiptir. Bu da dakikada 3.600, saatte 2.160.000 ve günde 51.840.000 bitlik bilgi demektir.

Beyin üzerine araştırmalar yapan Dr. V. Grey Walter'in incelemelerine göre, insan beynine benzeyebilen bir makinenin yapılabilmesi için 300 trilyon dolardan fazla para gerekiyor. Böyle bir makinenin çalışabilmesi için de 1 trilyon wattlık elektrik enerjisine ihtiyaç vardır. Yine de hiçbir makine insan beyninin potansiyel gücünü aşamaz.

Beyin gücünü kullanma ile ilgili olarak bir kitap yazan Scott Witt, duyu organlarıyla beyine bilgi gönderildiğini belirledikten sonra hayret verici bir bilgiyi açıklar: Yaşamımız boyunca beyin, gözlerinizle kulaklarınızla, burnunuzla, parmaklarınızla ve diğer duyu organlarınızla, devamlı olarak elektrik sinyalleri şeklinde, bilgi alır, depolar ve gönderir. Beyninizden geçen milyarlarca gerçek ve hayal, doksan milyon kalın kitabı doldururdu.

Hafıza uzmanı Madelyn Burley-Allen, bir kıyaslama yaparak ortalama bir yetişkin belleğinin Brittannica ansiklopedisinde içerilmiş olan bilginin 500 katı kadar bilgi saklayabildiğini belirtmiştir.

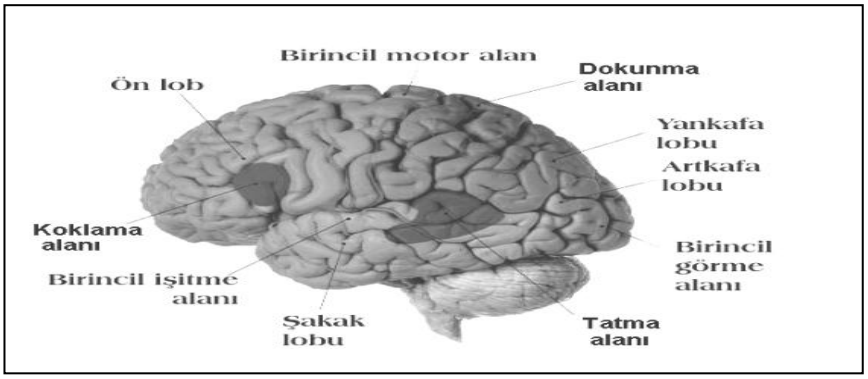
Ortalama bir beyinde 10 milyar kadar sinir hücresi vardır. Dolayısıyla sayıları arttıkça beyin işlevlerinin de artacağı açıktır. Nöron sayısı kadar önemli olan bir diğer özellik; nöronların uzantıları aracılığı ile diğer nöronlarla oluşturdukları

ilişkilerdir. Bilgi alışverişinin yapıldığı bu ilişki noktaları (sinaps'lar) nöron başına 1000 ile 10000 arasında değişir. Sinapslar etkiye, akım var/akım yok şeklinde tepki gösterir. Sinir sisteminde tepki sayısı ya da bilgisayar deyimiyle söylersek bit sayısı, 10 trilyon ile 100 trilyon arasında değişecektir. Bu bit sayısı 500 sayfalık bir milyon kitabı dolduracak kadar çoktur.

Aslında burada dikkat çekilmesi gereken, vücudun %2'sini kaplayan bir organ içinde bu kadar hücrenin yer alması ve birbirleriyle trilyonlarla ifade edilen bağlantı yapmış olmalarıdır (Doğan, 2002).

Beyine has en önemli işlevlerinden birisi de insanın çevresinde olanları öğrenmesi ve edindiği bilgileri daha sonra kullanmak üzere depolamasıdır. (Doğan, 2002)

3.2.7.1. Beyinin Temel Yapısı



Şekil 3.2. Beyinin Temel Yapısı

Şekil 3.2.'de görüldüğü gibi insan beyninin farklı bölgeleri farklı işlevlere sahiptir. İnsan beyni en temel şekliyle yedi bölgeye ayrılmıştır.

1. Alnın hemen arkasında bulunan alın lobu (frontal lob), hedefleri belirleme, davranışları planlama, geri bildirimi değerlendirme ve görevlere sistematik bir açıdan yaklaşma gibi yüksek seviyeli bilinci düzenler.

2. Beynin sağ ve sol taraflarında bulunan sağ ve sol şakak lobu çok kişiseldir. Görsel bilgi işleme süreçlerinin bazı yönleri, şakak lopları tarafından gerçekleştirilir.

3. Çeper lobu (Pariental Lob) dış çevrenin algılanması ve dış çevre ile daha önce kazanılmış olan algılar yardımıyla anlamlandırılması gibi önemli noktaları destekler. Bu faaliyetler aynı zamanda dış çevredeki objelerin birbirleri arasındaki veya kendi aralarındaki ilişkileri de kapsar.

4. Oksipital lob (Occipital lob) ise kafanın en arka kısmında yer alır. Ses kısmen beyindeki derin merkezde ve şakak loblarında işlenir. Duyusal gösterim ve hareketin kontrolü loblar arasındaki orta çizginin her iki yanındaki dar bantlarda (yarıkta) gerçekleşmektedir.

5. Beyin sapı (Brain Stem) omuriliğin tepesini çevreleyen kısımdır. Beynin bu kısmı temel yaşamsal faaliyetleri kontrol eder. Nefes alma, kalp atışları, tehlike durumundaki refleksler vb. gibi davranışlar beyin sapı tarafından kontrol edilir.

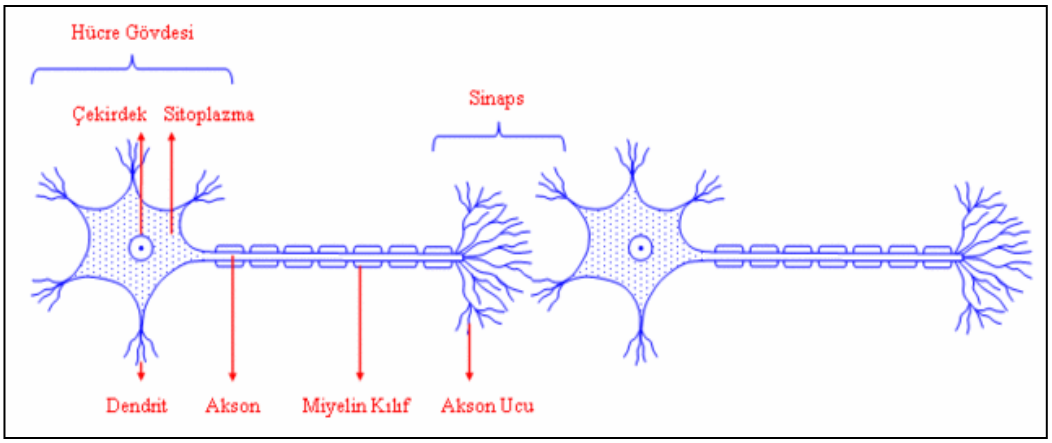
6. Limbik sistem, beyin sapını çevreleyen kısımdır. Limbik sistem duyularımızı kontrol eder. Açlığı, susuzluğu, cinsel arzuları ve diğer zevkleri düzenler. Ayrıca uzun süreli belleğin önemli bir kısmı limbik sistem tarafından düzenlenir.

7. Neokorteks, düşüncenin merkezidir. Görme, işitme, konuşma, oluşturma, düşünme gibi üst düzey zihinsel fonksiyonları yönetir. Duyular aracılığı ile algılananları bir araya getirip anlam üretilen merkezdir. Öte yandan neokorteks kararların alındığı, deneyimlerin saklandığı, konuşmanın üretildiği, anlamanın oluştuğu, sanat eserlerinin görüldüğü, müziğin dinlendiği merkezdir (Korkmaz, 2007).

3.2.7.2. Biyolojik Sinir Hücresi

İnsan beyni, nöron olarak adlandırılan yaklaşık 10^{11} hesap alanından oluşmaktadır. Nöronlar, büyüklük ve görünüş bakımından birbirlerinden önemli ölçüde farklı olsalar da bazı ortak özellikler taşırlar. Nöron, biyolojik sistemden gelen uyartıyı alan ve bu uyartıyı yorumlayarak uygun çıktıları ileten temel işlemcidir. Nöronlar çevreden aldıkları hücresel bilgiyi, işleme ve iletme yetenekleriyle donatılmış çok özel hücrelerdir (Çelik, 2008). Şekil 3.3.'te görüldüğü

gibi biyolojik sinir ağını oluşturan nöronlar temelde Soma, Dendrit ve Akson olarak üç bölgeye ayrılır. (Anonim, 2015b)



Şekil 3.3. Biyolojik Sinir Hücresi

Soma olarak adlandırılan hücre gövdesi, hücreyi denetler ve hücre etkinliklerinin tümünü yönetmekle sorumludur (Nabiyev, 2012). Vücudumuzda yer alan diğer hücrelerin çekirdeklerinden farklıdır. Soma diğer hücre çekirdeklerinin yaptığı görevlerin yanında, sinir hücresinin bilgi işleme yeteneğini oluşturan bir görev daha gerçekleştirir. Soma dendritlerden gelen elektriksel uyarının yeterli düzeyde olup olmadığını kontrol eder. Eğer bir sinir hücresine gelen elektriksel uyarılar belli bir eşiği aşarsa, soma, akson üzerinde bir elektrik akımı üreterek, kendisiyle sinaptik bağ oluşturan diğer sinir hücrelerini uyarır. Bir hücre akson üzerinde elektrik uyarısı ürettiğinde sinir hücresi tetiklenmiş kabul edilir. Eğer uyarı düzeyi yeterli değilse hiç akım üretmez ve kendisiyle bağlantılı diğer hücreleri de uyarmamış olur (Yıldız, 2009).

Dendritler, hücre gövdesinden dışarı uzanan ağaç dalları biçimindedir. Dentritler bilgiyi, iletim hatları olarak kullanılan uzun fiberlerden oluşmuş aksonlar boyunca diğer nöronlardan alır ve hücre gövdesine taşırlar. Bir hücrenin çok sayıda dendrit uzantısı bulunabilir (Yıldız, 2009). Bir nörondan yüzlerce, bazen de binlerce dendrit çıkabilir. Bunların uzunluğu genellikle bir milimetreden daha kısadır. bazıları ise birkaç milimetre uzunluğa ulaşabilir (Kapucugil, 2005).

Aksonlar ise, gövdedeki bilgiyi diğer nöronların dendritlerine taşımakla sorumludur. Bir sinir hücresinin aksonu, diğer sinir hücrelerinin dendritleri veya diğer sinir hücreleri ile sinaps adı verilen küçük kesecikler aracılığı ile bağlantı yapar. Bir sinir hücresinin ürettiği bir uyarı, diğer bir hücreye bu sinaptik bağlantılar aracılığıyla aktarılır (Yıldız, 2009).

Sinapslar, nöronlar arasındaki bağlantılardır. Bunlar fiziksel bağlantılar olmayıp bir hücreden diğerine elektrik sinyallerinin iletilmesini sağlayan boşluklardır. İki hücrenin birbirleri ile bilgi alışverişi bu sinaptik bağlantılarda kimyasal ileticiler (neurotransmitter) yolu ile sağlanır (Kapucugil, 2005). İnsan beyninde çok sayıda sinaps (düğüm noktası) bulunmaktadır. Küçük bir çocukta 10^{16} (10 kuadrilyon) adet sinaps bulunmaktadır. Bu sayı yaşlandıkça azalır ve ergenliğe eriştiğinde sabitlenir (Çelik, 2008).

3.2.8. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA)'nın literatürde birçok tanımı olmakla birlikte genel anlamda anlaşılır tanımları kısaca aşağıda belirtilmiştir.

YSA, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir (Öztemel, 2012).

YSA, insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır. Bir başka deyişle biyolojik sinir ağlarını taklit eden bilgisayar programlarıdır. YSA bir programcının geleneksel yeteneklerini gerektirmeyen, kendi kendine öğrenme düzenekleridir. Bu ağlar öğrenmenin yanı sıra, ezberleme ve bilgiler arasında ilişkiler oluşturma yeteneğine de sahiptir (Elmas, 2011).

YSA, insan beyninin çalışma prensiplerini kendisine baz alarak beyindeki sinirlerin işleyiş ve çalışma mekanizmasını taklit ederek, öğrenme, kavrama, analiz

ve sentez etme, genelleme yapma gibi yetenekleri kazandırmaya yönelik olan bilgi işleme sistemidir (Küçükönder, 2011).

3.2.8.1. YSA'nın Temel Özellikleri

1. YSA'nın temel işlevi bilgisayarların öğrenmesini sağlamaktır. Olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışırlar.

2. Geleneksel programlama ve yapay zekâ yöntemlerinin uygulandığı bilgi işleme yöntemlerinden tamamen farklı bir bilgi işleme yöntemi vardır.

3. YSA'da bilgi, ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır. Bilgiler, ağın üzerinde saklı olup ortaya çıkartılması ve yorumlanması zordur.

4. YSA'nın olayları öğrenebilmesi için o olayla ilgili örneklerin belirlenmesi gerekmektedir. Örnekleri kullanarak ilgili olay hakkında genelleme yapabilecek yeteneğe kavuşturulurlar. Örnek bulunamıyorsa ve yok ise YSA'nın eğitilmesi mümkün değildir. Örnekler ise gerçekleşmiş olan olaylardır.

5. YSA'nın güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekmektedir. YSA'nın eğitilmesi demek, mevcut örneklerin tek tek ağa gösterilmesi ve ağın kendi mekanizmalarını çalıştırarak örnekteki olaylar arasındaki ilişkileri belirlemesidir.

6. YSA, kendisine gösterilen örneklerden genellemeler yaparak görmediği örnekler hakkında bilgiler üretebilirler.

7. Genel olarak ağların çoğunun amacı kendisine örnekler halinde verilen örüntülerin kendisi veya diğerleri ile ilişkilendirilmesidir. Diğer bir amaç ise sınıflandırma yapmaktır. Verilen örneklerin kümelendirilmesi ve belirli sınıflara ayrıştırılarak daha sonra gelen bir örneğin hangi sınıfa gireceğine karar vermesi hedeflenmektedir.

8. Bazı durumlarda ağa eksik bilgileri içeren bir örüntü veya bir şekil verilir. Ağın bu eksik bilgileri bulması istenir. Bu tür olaylarda YSA'nın çok etkin çözümler ürettiği bilinmektedir.

9. YSA'nın örnekler ile kendisine gösterilen yeni durumlara adapte olması ve sürekli yeni olayları öğrenebilmesi mümkündür.

10. YSA, eğitildikten sonra eksik bilgiler ile çalışabilir ve gelen yeni örneklerde eksik bilgi olmasına rağmen sonuç üretebilirler. Eksik bilgiler ile de çalışmaya devam ederler. YSA'nın eksik bilgiler ile çalışması performanslarının düşeceği anlamına gelmez. Performansın düşmesi eksik olan bilginin önemine bağlıdır. Hangi bilginin önemli olduğunu ağın kendisi eğitim sırasında öğrenmektedir. Ağın performansı düşük olunca, kayıp olan bilginin önemli olduğu kararına varılır. Eğer ağın performansı düşmez ise eksik olan bilginin önemli olmadığı anlaşılır.

11. YSA'nın eksik bilgilerle çalışabilme yetenekleri hatalara karşı toleranslı olmalarını sağlamaktadır. Ağın bazı hücrelerinin bozulması ve çalışamaz duruma düşmesi halinde ağ çalışmaya devam eder.

12. YSA'nın belirsiz bilgileri işleyebilme yetenekleri vardır. Olayları öğrendikten sonra belirsizlikler altında ağlar öğrendikleri olaylar ile ilgili ilişkileri kurarak kararlar verebilirler.

13. YSA'nın hatalara karşı toleranslı olmaları bozulmalarının da dereceli (göreceli) olmasına neden olmaktadır. Ağlar, herhangi bir problem ortaya çıktığında hemen anında bozulmazlar. Zaman içerisinde yavaş yavaş ve zarif bir şekilde bozulurlar.

14. YSA'da bilgi ağa yayılmış durumdadır. Hücrelerin birbiri ile bağlantılarının değerleri ağın bilgisini gösterir. Tek bir bağlantının bir anlamı yoktur. Ağın bilgilerinin açıklanamamasının sebeplerinden birisi de budur. Bu ağlarda, ağın tamamı öğrendiği olayın bütününü karakterize etmektedir. O nedenle bilgiler ağa dağıtılmış durumdadır. Bu ise dağıtık bir belleğin doğmasına neden olmaktadır.

15. YSA sadece nümerik bilgiler ile çalışırlar. Sembolik ifadeler ile gösterilen bilgilerin nümerik gösterime çevrilmeleri gerekmektedir. Sembolik bilgilerin nümerik değerler ile ifade edilmesinde bilgilerin yorumlanmasını ve kararların (üretilen çözümlerin) açıklanmasını zorlaştırmaktadır (Öztemel, 2012).

16. YSA'nın en temel özelliklerinden birisi, gerçek hayattaki olası doğrusal olmayan yapıları da dikkate alabilmesidir. Yapıları gereği ekonomik verilerin de doğrusal olmayan bir yapıda olmaları normaldir fakat tahmin zorlukları nedeniyle analizler genellikle lineer yöntemlerle gerçekleştirilmektedir. Hâlbuki bu durum muhtemel bir doğrusal yapı içerilmesi durumunda yanlış sonuçlara yol açabilmektedir ya da en azından analizi yapılan sistemde açıklanamayan bileşenler kalabilmektedir. Sonuç olarak analiz konusunun içerdiği veri setinin doğrusal veya doğrusal olmayan yapı içeriyor olması, analiz sonuçlarını etkileyecek önemli bir faktördür. Bu yüzden doğrusal olmayan yapıları dikkate alabilmesi YSA'nın önemli bir özelliğidir (Usta, 2007).

17. YSA, paralel yapısı nedeniyle uygulama sürecinde hızlı çözümler üretebilirler. Paralel yapı, büyük ölçekli entegre devre teknolojisi ile gerçeklenebilmektedir. Bu özellik, YSA'nın hızlı bilgi işleme yeteneğini ve örnek tanıma işaret işleme, sistem kimliklendirme ve denetim gibi gerçek zaman uygulamalarında kullanımını arttırır.

18. İstatistiksel yöntemlerin maruz kaldığı kısıtlamalar konusunda güçlü istatistik bilgisi olmadan, çoğu araştırmacı, bunları göz ardı ederek analizler yapmaya kalkışmaktadır. Bunun sonucunda ise, sağlıksız sonuçlarla yorumlar yapılmaktadır. YSA ile bir problemi oluşturmak klasik istatistiksel yöntemlerle modelleme yapmaktan daha kolaydır. Çünkü araştırmacılar öğrenme algoritmalarını tam anlamadan bile YSA paket programlarını klasik istatistiksel programlardan daha kolay ve başarılı bir şekilde kullanabilmektedirler. Bu da çeşitli alanlardaki araştırmacıların YSA'ya kolaylıkla ulaşabilmesini sağlamaktadır. YSA araştırmacıları istatistiksel kurallara gerek kalmadan, tecrübe ile YSA'yı öğrenebilmektedirler (Kapucugil, 2005).

19. YSA'da işlemler doğrusal değildir ve bütün ağa yayılmış durumdadır. Bu sayede doğrusal olmayan karmaşık problemlerin de çözümlenmesi mümkündür (Adıyaman, 2007).

20. YSA, istatistikî yöntemlerin aksine sınırsız sayıda değişken ve parametre ile herhangi bir ekstra dönüşüme ihtiyaç duymadan çalışabilmektedir. (Bayır, 2006).

21. YSA paralel yapıya sahiptirler. Birçok nöron eş zamanlı olarak çalışır (Erdoğan, 2006).

22. YSA'da öğrenme, tüm nöronlar tarafından paylaşılan bir süreçtir ve devredeki her bir nöron sonuca katkıda bulunmaktadır (Batman, 2001).

23. YSA sadece sayısal giriş bilgileri ile çalışırlar. Bu yüzden ham bilgiler genellikle ölçeklendirilmelidir (Elmas, 2011).

3.2.8.2. YSA'nın Geleneksel İstatistik Yöntemleriyle Ortak ve Farklı Yönleri

YSA ve istatistik alanları arasında önemli sayılabilecek bir kesişim kümesi vardır. İstatistik, veri analizi ile uğraşan bir alandır. Benzer şekilde, sinir ağı terminolojisindeki hatalı veriden öğrenerek genelleştirme kavramı, istatistiksel çıkarım ile aynı anlamı taşımaktadır. Dolayısıyla, yapay Sinir Ağları da genelde veri analizi içermektedir. Fakat bazı sinir ağları veri analizi ile ilgilenmezler ve bu yüzden istatistik alanı ile ilişkileri kısıtlıdır. Örneğin, bazı ağlar öğrenme işlemi içermezler ki Hopfield ve Kohonen ağlar bunlardan bir kaçıdır. Bununla beraber, sinir ağlarının büyük çoğunluğu hatalı veriden genelleme yapabilmeyi öğrenebilmektedir ve bu sayede istatistiksel yöntemlerle benzer ya da aynı oldukları söylenebilir.

Bu benzerlik için birçok örnek gösterilebilir. Örneğin, gizli tabaka içermeyen ileri besleme sınıfı ağlar temel olarak genelleştirilmiş lineer modellere karşılık gelirler. Olasılıkçı ağlar, temel fark analizine karşılık gelirken, Hebbian öğrenme, temel bileşenler analizi ile oldukça ilişkilidir. İleri beslemeli ağlar, doğrusal olmayan regresyon ve ayrıştırma modellerinin oluşturduğu sınıfın bir alt kümesidir. Doğrusal olmayan modeller hakkındaki istatistiksel teorilerden elde edilen birçok sonuç ileri beslemeli ağlara uygulanmaktadır. Ayrıca doğrusal olmayan modeller için kullanılan yöntemler, örneğin Levenberg-Marquardt algoritma, ileri beslemeli ağları eğitmek için kullanılmaktadır.

YSA da istatistiksel modeller gibi dağılıma yönelik varsayımlara ihtiyaç duymaktadır. Fakat istatistik bilimi bu varsayımların sonuçları önem derecesi ile de ilgilenirken, YSA olayın bu yönünü göz ardı etmektedir. Örneğin en küçük kareler

yöntemi hem istatistiksel hem de sinir ağı modellerinde sıklıkla kullanılmaktadır (Özdemir, 2008).

Çizelge 3.17.'de YSA elemanlarının istatistiksel model karşılıkları gösterilmiştir.

Çizelge 3.17. Yapay Sinir Ağları ve İstatistiksel Model Terminolojisinin Karşılaştırılması

Yapay Sinir Ağları	**İstatistiksel Model**
Sinir Ağları	Parametrik (parametrik olmayan) model
Ağın Topolojisi	Model Spesifikasyonu
Girdiler	Bağımsız Değişkenler
Çıktılar	Bağımlı Değişkenler
Beklenen (Hedef) Değerler	Bağımlı Değişkenlerin Gözlenen Değerleri
Katman	Vektör
Eğitim	Öngörü
Ağırlıklar	Regresyon Parametreleri
Genelleme	İleriye Yönelik Tahmin
Örüntü Sayısı	Gözlem Sayısı
Eşik Nöron	Regresyon Sabiti
Danışmanlı Öğrenme	Regresyon
Danışmansız Öğrenme	Veri İndirgeme
Eğitim Seti	Örnek

3.2.8.3. YSA'nın Avantaj ve Dezavantajları

YSA'nın genel olarak avantajları aşağıda maddeler halinde belirtilmiştir.

1. Matematiksel olarak modellenmesi güç ve karmaşık olan problemleri rahatlıkla çözümleyebilme imkânına sahiptir.

2. Bir problem için bir ağ oluşturulurken herhangi bir bilgiye değil sadece örneğe ihtiyaç duyarlar. Örnekten yola çıkarak genelleme yapabilme yeteneğine sahiptirler. Bilgiyi bulmak zaman zaman zor olurken, örnek bulmak daha kolay mümkün olmaktadır (Akaytay, 2010).

3. Günlük hayatta olaylar ile olayların altında yatan değişik etkilerini ve ilişkilerini bilmek zordur fakat YSA ile bu durum kendiliğinden ortaya çıkarılması mümkün olmaktadır.

4. Olaylar ve olaylar arasındaki ilişkilerin doğrusal olmadığı, karmaşık ve zor problemlere çözüm üretmek zordur. Çözüme ulaşmak için bir takım varsayımlara gereksinim vardır. Bu da gerçekte var olan sistem ile oluşturulan sistem arasında farklılık olmasına neden olabilmektedir. Fakat YSA ile doğrusal olmayan ilişkiler içinde geleneksel bilindik yöntemlere nazaran daha iyi ve gerçekçi çözümler üretir.

5. YSA'nın uygulanması oldukça pratik ve ekonomiktir. Sadece probleme ilişkin örneklere ihtiyaç duyulduğundan basit bir programlama ile problemin çözümü mümkün olabilmektedir.

6. YSA diğer sistemlere oranla zaman bakımından da verimli olup, örnek bulunduğunda, probleme uygun ağ oluşturularak, ağın öğrenmesi ve diğer örnekler içinde kullanılabilmesi çok kısa zamanda yapılabilmektedir.

7. YSA, aynı olay için yeni ve farklı bilgiler oluşturduğunda da yeniden rahatlıkla eğitilebilir ve ortama uyum sağlaması sağlanabilmektedir.

8. YSA paralel olarak çalışma sistemine sahip olduğundan dolayı eş zamanlı uygulamalar içinde kullanımı kolay ve rahattır (Küçükönder, 2011).

9. Matematiksel modele ihtiyaç duymazlar.

10. Öğrenme kabiliyeti vardır ve farklı öğrenme algoritmalarıyla öğrenebilirler (Elmas, 2011).

YSA'nın genel olarak *dezavantajları* aşağıda maddeler halinde belirtilmiştir.

1. YSA ile uygulama yapılırken model seçim ve ağ topolojisinin belirlenmesi için herhangi bir sabit bir kural olmaması, tamamen kullanıcının tecrübesine dayanarak seçim yapmasına bağlıdır.

2. Ağın eğitiminin ne zaman bitirileceğine karar vermek için geliştirilmiş bir yöntem yoktur. Ağın örnekler üzerindeki hatasının belirli bir değerin altına

indirilmesi eğitimin tamamlanması için yeterli görülmektedir. Fakat neticede optimum öğrenmenin gerçekleştiği garanti değildir (Kapucugil, 2005).

3. Bazı ağ yapıları hariç kararlılık analizi yapılamaz.

4. Farklı sistemlere uygulanması zaman zaman zor ve güç olabilmektedir.

5. Herhangi bir problemin çözümünde kullanılmak üzere ağa sunulacak olan örnekler toplanırken de bir kural durumu yoktur, kullanıcı kendisi örnekleri belirler ve formülize eder.

6. Bazen eğitim aşamasının gerçekleşmesi uzun zaman alabilmektedir.

7. YSA'da öğrenme hızı önceden tahmin edilemez.

8. YSA, gürültü verileri için değişkenler arasındaki ilişkiler hakkında varsayımlar yapmadan modelleme yapmada oldukça yaygın kullanılan bir yöntemdir. Esneklik özelliğinin olması eğitim verilerine aşırı uyum ve gürültülü veriyi modelleme potansiyelinde zaman zaman ortaya kötü tahmin performansının çıkmasına neden olabilmektedir.

9. YSA'nın en büyük zayıflığı yarattıkları modelleri açıklayamamalarıdır. Bu konuda hala araştırmalar sürmektedir. YSA, tahmin edilen ağ ağırlıklarını yorumlayamamaktadır. Bir probleme çözüm üretildiği zaman bunun nasıl ve neden üretildiği konusunda bilgi bulmak mümkün değildir. (kara kutu problemi) Bu ise ağın sonucuna olan güveni azaltmaktadır (Kapucugil, 2005).

10. Ağın eğitiminde kullanılacak olan örneklerin bulunmasının zor olduğu durumlarda ya da doğru örnek olarak karar verilemediği durumlarda sonuçlar sağlıklı ve güvenilir bir şekilde elde edilemeyebilir (Küçükönder, 2011).

11. Probleme uygun ağ yapısının belirlenmesi genellikle deneme yanılma yolu ile yapılmaktadır. Bu ise önemli bir problemdir. Çünkü eğer problem için uygun bir ağ oluşturulmaz ise çözümü olan bir problemin çözülememesi veya performansı düşük çözümlerin elde edilmesi söz konusu olabilir (Öztemel, 2012).

12. Bazı ağlarda ağın parametre değerlerinin (mesela öğrenme katsayısı, her katmanda olması gereken proses elemanı (yapay hücrelerin) sayısı, katman sayısı vb. belirlenmesinde bir kural olmaması diğer bir problemdir. Bu, iyi çözümler bulmayı zor durumda bırakan bir etken olarak görülebilir. Bu parametrelerin belirlenmesi de kullanıcının tecrübesine bağlıdır. Her problem için ayrı faktörleri dikkate almayı gerektirmektedir. Bu parametre değerleri için belirli standartların oluşturulması çok zor olduğundan her problem için ayrı ayrı değerlendirmeler yapılması gerektirmektedir. Bu da önemli bir dezavantaj olarak görülebilir (Öztemel, 2012).

3.2.8.4. YSA'nın Uygulama Alanları

YSA'nın uygulamaları gözden geçirildiğinde binlerce uygulamanın yapıldığı ve başarılı sonuçların elde edildiği görülebilir. İlk Yapay Sinir Ağları çalışmaları yaklaşık elli yıl önce başlamış olmasına karşılık bunların etkin kullanımı ve sürekli gelişimine son 20 yıl içinde rastlanmaktadır. Bu kapsamda, YSA uygulamaları:

- Endüstriyel uygulamalar
- Finansal uygulamalar
- Askeri ve savunma uygulamaları
- Sağlık uygulamaları
- Diğer alanlardaki uygulamalar

şeklinde sınıflandırılarak incelenebilir. Bu alanlardaki uygulamalar incelendiğinde YSA'nın genel olarak aşağıdaki fonksiyonları gerçekleştirmek için uygulandıkları görülmektedir:

Tahmin: Bu amaçla kullanılan YSA, ağa sunulan bilgilerden yararlanılarak karşılık gelen çıktı değerini tahmin ederler. Hava tahmini, borsada hisselerin değerlerinin, ileriki satışların, üretim ihtiyacının, Pazar performansının, enerji ihtiyacının, at yarışlarının tahmini, kanser riskini belirleme, döviz kurlarının tahmini gibi örnekler vermek mümkündür.

Sınıflandırma: Bu amaçla kullanılan YSA kendilerine sunulan bilgileri kategorize etmek görevini üstlenirler. Bir makine üzerinde görülen hataların, müşteri/pazar profillerinin, imza tetkiklerinin, mal değerinin, hücre tiplerinin sınıflandırılması, borçlanma/risk değerlendirmeleri buna örnek olarak verilebilir.

Veri İlişkilendirme: Bu amaçla eğitilen ağlar ağa sunulan verilerin hatalı ve eksik olup olmadığını belirler. Öğrendikleri bilgiler ile eksik olan bilgileri tamamlarlar. Eksik bir resmin tamamlanması bu konuda örnek olarak verilebilir. Bu sınıflandırmaya benzer bir yaklaşım gibi görünse de buna ilave olarak hatalı olan verileri tanımlar. Örnek olarak taranan bir dokümandaki karakterleri algılamanın yanında tarayıcının düzgün olarak çalışmadığını da algılayabilir.

Veri Filtreleme: Bu amaçla eğitilen ağlar, birçok veri arasından uygun verileri belirleme görevini yerine getirirler. Telefon konuşmalarındaki gürültüleri asıl konuşmalardan ayıran ağlar, bir resim üzerindeki istenilmeyen parazitleri temizleme bu konudaki uygulamalara örnek olarak verilebilir. Giriş sinyalleri içerisindeki uygun olmayan verilerin ayıklanmasını sağlar.

Tanıma ve eşleştirme: Değişik şekil ve örüntülerin tanınması, eksik, karmaşık, belirsiz bilgilerin işlenerek eşleştirme ve tanıma fonksiyonları gerçekleştirilebilir. Daha önce örneği verilen kalite kontrol şemaları üzerindeki şekilleri tanıyan ağ, bu konuda örnek olarak verilebilir.

Teşhis: Bu amaçla geliştirilen ağlar, sistemlerin olumsuzluklarının ortaya konulması ve problemlerin teşhis edilmesi işlemini yerine getirirler. Makinelerin, süreçlerin arazi durumlarının ve hatalarının teşhis edilmesi buna örnek olarak verilebilir. Tıp alanında da bu tür sistemler yaygın olarak geliştirilmektedir.

Yorumlama: Bir olay hakkında toplanan örneklerden elde edilen ve eğitim sonucu oluşturulan bilgileri kullanarak yeni olayların yorumlanması işlemleri bu kapsamda düşünülmektedir. Bir olay hakkında toplanan verilerin yorumlanarak istatistiksel dağılımlarının belirlenmesi bu konuda örnek olarak verilebilir. Giriş verisindeki gruplar arasındaki ilişkileri analiz etme işlemidir (Ataseven, 2007).

YSA'nın gerçek hayattaki yaygın uygulama alanlarına şu örnekler de verilebilir:

- Kalite Kontrol
- Finansal Öngörü
- Ekonomik Öngörü
- Kredi Derecelendirme
- Konuşma ve Yapı Tanımlama
- İşlem Modelleme ve Yönetimi
- Laboratuar Araştırmaları
- İflas Tahmini
- Petrol ve Gaz Arama (Yurtoğlu, 2005).

YSA, bütün finansal piyasalarda, borsada, bono işlemlerinde, uluslararası nakit para akışında, ticaret mallarında, makro ekonomik tahminler, borsa benzetim çalışmaları endekslerinin tahmin edilmesi, kredi kartı hilelerinin tespiti, kredi kartı kurumlarında iflas tahminleri, banka kredilerinin değerlendirilmesi, emlak kredilerinin yönetilmesi, döviz kuru tahminleri, risk analizleri vb. finansal alanlarda da kullanılmaktadır (Vural, 2007).

YSA son dönemlerde regresyon analizi, sınıflandırma, örüntü tanıma ve zaman serilerinin analizi gibi istatistiksel alanlarda da kullanılmaktadır (Vural, 2007).

3.2.8.5. YSA'nın Tarihçesi

Çizelge 3.18.'de YSA'nın gelişimi kronolojik olarak gösterilmiştir.

Çizelge 3.18. Yapay Sinir Ağlarının Tarihçesi

Yıllar	Yapılan Çalışmalar
1890	William James, "Psychology (Briefer Course)" adlı yayınıyla insan beyninin yapısı ve fonksiyonlarıyla ilgili ilk çalışmayı yapmıştır. (Arabacı, 2007) Nöroloji ve psikoloji alanlarında yapılan çalışmaların sinir hücrelerinin yapısı ve sinir ağlarının çalışma biçimlerindeki bilinmeyenleri aydınlatmada kat edilen yol, YSA'nın gelişimine önemli katkılar yapmıştır (Baş, 2006).
1911	İnsan beyninin bileşenlerinin belirli bir düzenek ile sinir hücrelerinden oluştuğu fikri benimsenmiştir (Öztemel, 2012).
1943	İlk YSA modeli, bir sinir hekimi olan Warren McCulloch ile bir matematikçi olan Walter Pitts tarafından gerçekleştirilmiştir (Elmas, 2010). Bulletin of Mathematical Biophysics dergisinde yayınlanan "A Logical Calculus of the ideas Immanent in Nervous Activity" adlı makale bir sinir hücresinin ilk matematiksel modelinin anlatıldığı çalışma olmuştur. Bu makalede, insan beyninin hesaplama yeteneğinden esinlenerek, elektrik devreleriyle basit bir sinir ağı modellemişlerdir. Yapay sinir hücreleri ile her türlü mantıksal ifadeyi formülize etmenin mümkün olduğunu göstermişlerdir. Hücrelerin birbiri ile paralel çalışması gerektiği fikrini ortaya atarak öğrenme kurallarını belirlemeye başlamışlardır (McCulloch ve Pitts, 1943).
1948	Wiener, "Cybernetics" isimli kitabında sinirlerin çalışmasını ve davranış özelliklerini ele almıştır (Erdoğan, 2006).
1949	Donald Hebb, "The Organization of Behavior" adlı kitabı ile öğrenebilen ve uyum sağlayabilen sinir ağları modeli için temel olacak Hebb kuralını ortaya koymuştur. Hebb kuralı, sinir ağlarının bağlantı sayısının değiştirilmesi durumunda ağın öğrenebileceğini ileri sürer (Hebb, 1949). Donald Hebb ilk defa deneye dayalı, klasik-fizyolojik şartları kullanarak, sinir sinapslarını (bir hücrenin girişi ile diğer bir hücrenin çıkışını birleştiren noktaları) ayarlama yoluyla öğrenme kuralını açıklamıştır. Kısaca bu kural, sinir ağının bağlantı sayısı değiştirilebilirse, öğrenebileceğini öngörmektedir. Günümüzde sinir ağları alanında kullanılan öğrenme kurallarının hemen hemen hepsinin temeli "Hebbian Öğrenme" kuralı olarak adlandırılan bu kurala dayanmaktadır (Bayru, 2007). Öğrenme için geliştirdiği matematiksel modellerin sadece matematiksel analizlere bağımlı olmasından dolayı bazı işlemlerde çok büyük zorluklarla karşılaşmıştır (Ataseven, 2007).

Çizelge 3.18. **(devam)**

1950	Alan Turing, "Hesaplama Makinesi ve Zeka" isimli makalesi ile yapay zeka hakkındaki düşüncelerini ifade etmiştir. Turing, makalesinde Turing testini, makine öğrenmesini, genetik algoritmaları ve takviyeli öğrenmeyi tanıttı (Bayru, 2007).
1951	Minsky ve Edmonds, ilk yapay sinir ağı temelli bilgisayar olan SNARC'ı MIT'de yapmışlardır (Doğan, 2010).
1952	IBM, satranç oynayabilen ilk programı geliştirmiştir (Ataseven, 2007).
1954	Farley ve Clark tarafından rassal ağlar (random Networks) ile uyarlanabilir tepki üretme kavramı ortaya atılmıştır (Çelik, 2008).
1956	McCarthy, Dartmouth'da IBM araştırma laboratuarlarından Nathanial Rochester, Minsky ve Shannon ile beraber yapay zekâ üzerine yaptığı çalışmaları açıklamış ve ilk kez "Yapay Zekâ" kavramını kullanmıştır (Ataseven, 2007). Bronx Yüksek Bilim Okulu'ndan Frank Rosenblatt, gözün hesaplamaları ile ilgilenmiştir. Bilim adamları, öğrenmenin ve zekânın herhangi bir özelliğinin simülasyonunda bilgisayarların aktif olarak nasıl kullanılabileceğini, düzenlemiş oldukları ilk yapay zekâ konferansında tartışmışlardır.
1958	Frank Rosenblatt tarafından geliştirilen "Perceptron", YSA'daki çalışmaları hızlandırmıştır. Perceptron, örüntü (şekil) tanıma amacıyla geliştirilmiştir. Perceptron, beyin işlevlerini modelleyebilmek amacıyla yapılan çalışmalar neticesinde ortaya çıkan, tek katmanlı, eğitilebilen ve tek çıkışa sahip olan bir YSA'dır. Bu model daha sonraları geliştirilecek olan Çok Katmanlı Ağlar'ın (Multilayer Networks) temellerini oluşturmaktadır (Çelik, 2008).
1959	Bernard Widrow ve Marcian Hoff, ADALINE (**ADA**ptive **LI**near **NE**uron) diye adlandırdıkları ağ modelini geliştirmişlerdir. ADALINE, Rosenblatt'ın Perceptron'una yapı olarak çok benzer bir hücre olup, aralarındaki en büyük fark, aktivasyon fonksiyonlarının farklı olmasıdır. ADALINE tek bir yapay sinirden oluşan ve sinaptik ağırlıkların (hatayı minimize etmek için) En Küçük Kareler Toplamı (Least Sum of Squares, LSS) yöntemiyle ayarlandığı bir yapay sinirdir (Çelik, 2008). Yapay sinir ağlarının mühendislik uygulamalarında kullanılmaya başlanması için atılan ilk adımlardan biridir (Öztemel, 2012) Widrow, telefon hatları üzerindeki ekoları elimine etmeye yarayan adaptif filtreleri geliştirmede, adaptif lineer eleman algoritmasını kullanmıştır. Bununla ilk defa YSA, gerçek bir probleme uygulanmıştır (Kıraç, 2011).
1961	Karl Steinbruch, "Öğrenme Matrisi" isimli çalışmasında teknik olarak çağrışımlı belleğin işleyişini gösterdi. Çağrışımlı bellek, aynı zamanda Pavlov'un şartlı refleksinin açıklanmasında kullanıldı (Bayru, 2007).

Çizelge 3.18. **(devam)**

1969	YSA'nın tarihinde bir duraklama devrine neden olan olay, yapay zekâ biliminin önde gelen isimlerinden Marvin Minsky ve Seymour Papert tarafından yazılan algılayıcılar (Perceptrons) başlıklı kitap oldu. Bu kitapta yazarlar özellikle YSA'ya dayalı algılayıcıların bilimsel bir değerinin olmadığını ve doğrusal (linear) olmayan problemlere çözüm üretemediğini iddia ettiler (Minsky ve Papert, 1987). Tezlerini kanıtlamak için ise meşhur XOR probleminin çözülmemesini örnek gösterdiler. Bu örnek birçok kişiyi tatmin etti ve çalışmalar bir bıçak gibi kesildi. YSA yapmak mümkün değildir inancı yükselmeye başladı. Birçok bilim adamı buna inandığından çalışmalar yok denecek kadar azaldı. Amerika Birleşik Devletlerinde araştırma geliştirme çalışmalarını yürüten ve eşgüdümünü sağlayan bir organizasyon olan DARPA, yapay sinir ağları ile ilgili çalışmaları desteklemeyi durdurdu. Sadece bir iki bilim adamı bu konuda çalışmaya devam etti. Çalışmalar öyle kesildi ki, XOR problemi çözülünceye kadar dikkatleri yapay sinir ağına çekmek mümkün olmadı (Öztemel, 2012).
1972	Kohonen, Korelasyon Matris Belleği'ni geliştirmiştir (Kohonen, 1972). Bu model özellikle örüntü tanıma ve sınıflandırma gibi verideki benzer davranışların analizi ve veri yapısının ortaya çıkarılması gibi problemlerde kullanılmaktadır. (Çelik, 2008) Klopf, yapay nöronlarda öğrenme işlemi için, "heterostasis" olarak adlandırılan ve nöronsal öğrenmenin biyolojik prensiplerine dayanan bir temel oluşturmuştur (Yurtoğlu, 2005).
1974	(Werbos, 1974), doktora tezinde geri yayılım (backpropagation) öğrenme algoritmasını geliştirdi. Birkaç yıl sonrasında bu metot oldukça popülarite kazanmıştır. Geri yayılım ağları, bugün en çok bilinen ve kullanılan YSA'dır. Yapay nöronunda farklı bir eşik fonksiyonuna sahip ve daha sağlam (robust) ve yetenekli öğrenme kuralı olan birçok tabakalı Perceptrondur.
1975	Fukushima, "Cognitron" olarak adlandırılan bir model ile el yazısı karakterleri yorumlamak için adım adım (stepwise) eğitilmiş çok tabakalı YSA oluşturmuştur (Özdemir, 2008).
1976	Grossberg tarafından geliştirilen ART (Adaptif Rezonans Teorisi) zamanın öğretmensiz öğrenmedeki en karmaşık YSA olarak görülmüştür.
1982	John Hopfield tarafından ortaya atılan Hopfield öğrenme modelinin geliştirilmesiyle matematiksel analizler yardımıyla YSA'nın nasıl çalıştığı ve neler yapabileceği ortaya çıkarıldı (Hopfield, 1982).

Çizelge 3.18. **(devam)**

1985	Hopfield, kendi adını verdiği ağlarla, "gezgin satıcı" problemini nasıl çözdüğünü göstermesiyle, YSA'ya günümüze değin sürecek olan ilgi yeniden canlanmaya başladı. Hopfield'in çalışmaları yapay sinir ağlarının genelleştirilebileceği ve özellikle bilgisayar programlama ile çözülmesi zor olan problemlere çözüm üretebileceğini gösterdi (Bayru, 2007).
1986	Rumelhart ve arkadaşları tarafından çok katmanlı algılayıcı tipi ağlar için geri yayılma olarak adlandırılan öğrenme algoritması geliştirilmiştir (Rumelhart ve ark., 1986). Bu algoritma güçlü olmakla birlikte oldukça karmaşık matematik esaslara dayanmaktaydı. Günümüzde dahi en çok kullanılan öğretim sistemlerinden biri olan bu algoritmanın ortaya çıkarılması yapay sinir ağları alanında çığır açmıştır. Tek katmanlı algılayıcının çözemediği XOR problemi çok katmanlı algılayıcıların bulunması ile çözülmüş ve YSA'nın çalışmadığını söyleyen bütün tezler çürütülmüştür (Öztemel, 2012).
1987	Elektrik ve Elektronik Mühendisleri Birliği (IEEE) tarafından 1800 kişinin katılımıyla ilk uluslararası YSA konferansı düzenlenmiştir (Ataseven, 2007).
1988	Broomhead ve Lowe, Radyal Tabanlı Fonksiyonlar (Radial Basis Functions) modelini geliştirmişlerdir. Makalelerinde radyal tabanlı fonksiyon temelli YSA'yı, çok katmanlı ağlara alternatif olarak geliştirdiklerini belirtmişlerdir (Broomhead ve ark., 1988). Radyal tabanlı ağlar özellikle filtreleme ve veri sıkıştırma problemlerinde kullanılmıştır. Ayrıca yapay sinir ağlarının zaman serisi analizinde ciddi bir şekilde kullanıldığı çalışmalardan ilki White tarafından yapılmıştır. White, makalesinde YSA'yı etkin piyasa hipotezini test etmek amacıyla kullanmıştır (Arabacı, 2007).

3.2.8.6. Yapay Sinir Hücresi

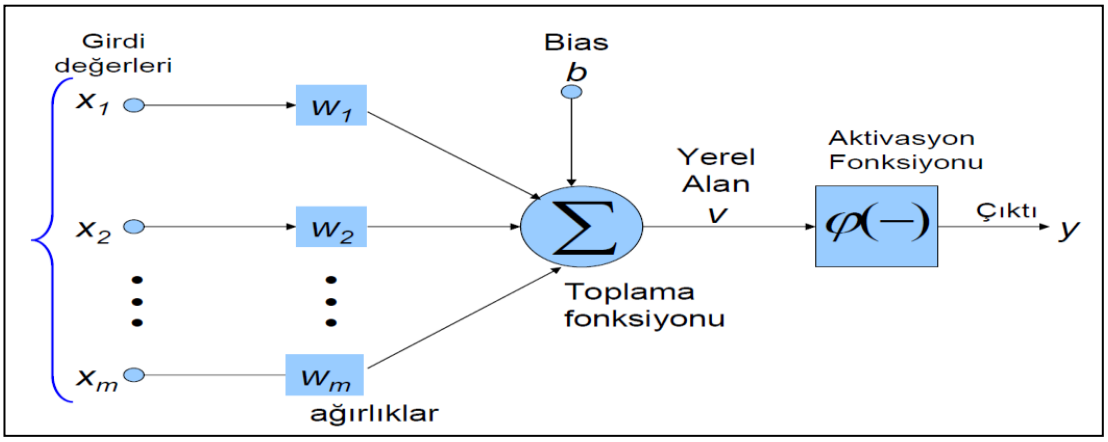
Çizelge 3.19.'da görüldüğü gibi Biyolojik sinir ağlarının sinir hücreleri olduğu gibi YSA'nın da yapay sinir hücreleri vardır. Yapay sinir hücreleri mühendislik biliminde proses elemanları olarak da adlandırılmaktadır. Bir Yapay Sinir Ağı, birbiriyle bağlantılı çok sayıda yapay sinir hücresinden meydana gelmektedir. Yapay sinir hücreleri, biyolojik sinir hücrelerinin basit bir modelidir (Baş, 2006).

Çizelge 3.19. Biyolojik Sinir Ağı ve Yapay Sinir Ağının Karşılaştırılması

Biyolojik Sinir Ağı	Yapay Sinir Ağı
Sinir Sistemi	Sinirsel hesaplama sistemi
Sinir Hücresi (Nöron)	İşlemci eleman (Yapay Sinir Hücresi)
Sinaps	İşlemci elemanlar arasındaki bağlantı ağırlıkları
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Aktivasyon Fonksiyonu
Akson	İşlemci eleman çıktısı

3.2.8.7. YSA'nın Yapısı ve Temel Elemanları

YSA, Şekil 3.4'de görüldüğü gibi temel olarak girdi elemanları rasgele ağırlıklarla çarpılarak toplama fonksiyonuna gönderilir. Toplama fonksiyonunda işlem görmüş değerler aktivasyon fonksiyonuna gönderilir. Aktivasyon fonksiyonunda son halini aldıktan sonra ortaya çıkan sonuç çıktı olarak üretilir (Anonim, 2014d)



Şekil 3.4. YSA'nın Temel Elemanlar

1. Girdiler: YSA'nın dış dünyadan verileri (X_1, X_2, $X_{3,\ldots,}X_i$) alan elemanlarıdır ve bu özellikleriyle biyolojik sinirdeki dentritlere benzemektedirler. Girişlerin, verileri bir sonraki aşamaya iletmekten başka bir işlevi bulunmamaktadır. Başka bir ifadeyle girişler veri üzerinde hiçbir matematiksel işlem yapmamakta ve sadece bir iletici olarak görev yapmaktadırlar. Girişler, YSA'nın dış dünya ile ilişki halinde olan iki elemanından biridir. Bir nöronun sınırsız sayıda girişi olabilir fakat her bir nöronun sadece tek bir çıkışı olmak zorundadır (Çelik, 2008). Yapay sinir

hücresine dış dünyadan olduğu gibi başka hücrelerden veya kendi kendisinden de bilgiler gelebilir (Öztemel, 2012).

2. Ağırlıklar: Ağırlıklar (w_1, w_2 ,w_3,…,w_i), hem tek başına matematiksel nöronun hem de genel olarak YSA'nın en önemli elemanıdır. Bunun nedeni ise; ağ tarafından öğrenilen bilginin ağırlıklar üzerinde saklanmasıdır (Çelik, 2008). Ağırlıklar, yapay sinir tarafından alınan girişlerin sinir üzerindeki etkisini belirleyen uygun katsayılardır. Bir ağırlığın değerinin büyük olması, o girişin yapay sinire güçlü bağlanması ya da önemli olması, küçük olması zayıf bağlanması ya da önemli olmaması anlamına gelmektedir (Elmas, 2010). Ağırlıkların başlangıç değerleri genellikle (-1,1) aralığında rassal değerler olarak seçilmektedir. Ağın, verilen değişkenler arasındaki ilişkiyi öğrenebilmesi için her bir ağırlığın nasıl ayarlanması gerektiğine öğrenme kuralı karar vermektedir (Çelik, 2008). Bir ağırlığın eksi değerler alması önemsiz olduğu anlamına gelmez. Ağırlığın artı veya eksi olması etkisinin pozitif veya negatif olduğunu gösterir. Sıfır olması ise herhangi bir etkinin olmadığını gösterir (Öztemel, 2012).

3. Toplama Fonksiyonu: Ağa dış dünyadan gelen veriler ile ilgili ağ ağırlığının çarpılarak toplanmasını ve ağırlıklandırılmış net girdinin hücre içine iletilmesinden sorumludur (Çelik, 2008).

$$G_i = x_1, x_2, x_3, ...x_n \qquad A_i = w_1, w_2, w_3, ..., w_n$$

$$NET = \sum_{i}^{n} G_i A_i + \theta \tag{3.1}$$

Denklem (3.1)'de G, girdileri, A ise ağırlıkları, n ise bir hücreye gelen toplam girdi (proses elemanı) sayısını göstermektedir. Eşik değer (θ_i), sinir hücrelerinde iletim için gerekli minimum uyartı şiddetidir. Bütün girdiler sıfır olsa dahi esik değer toplama fonksiyonuna eklendiğinden dolayı YSA çıkısında elde edilen değer sıfır olmayacaktır (Yıldız, 2009). Eşik değerinin toplama işlevinde kullanılması zorunlu değildir. Eşik değerinin kullanılması, ağ mimarisini dizayn eden uygulayıcının isteğine bağlıdır. Bir Yapay Sinir Ağında bulunan proses elemanlarının tamamının aynı toplama fonksiyonuna sahip olmaları gerekmez. Her proses elemanı bağımsız

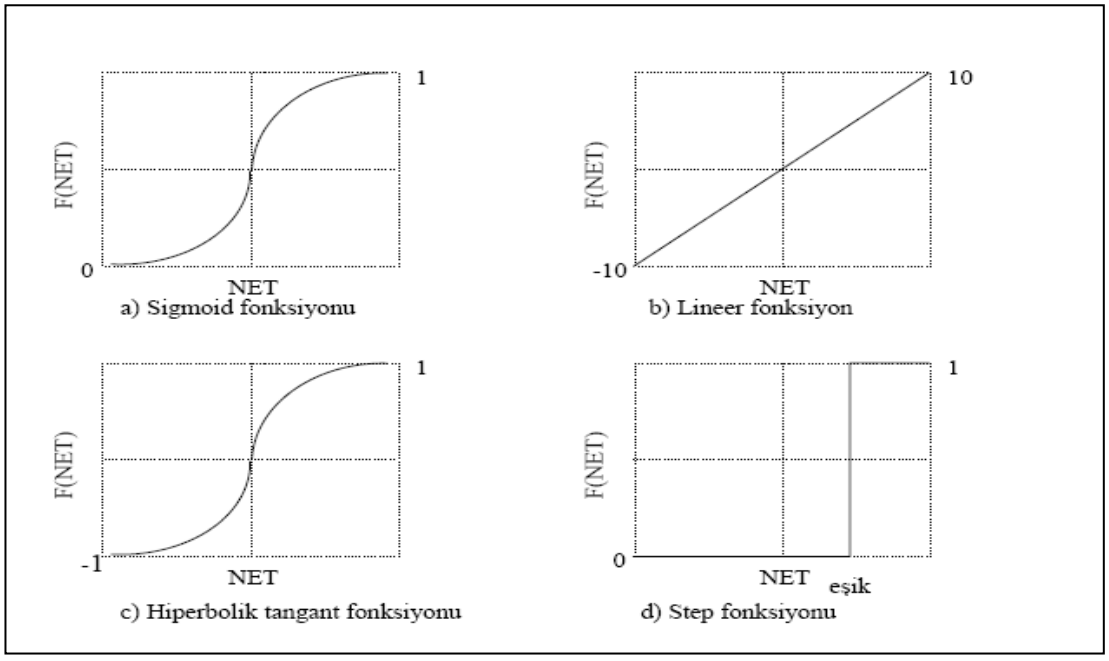
olarak farklı bir toplama fonksiyonuna sahip olabilecekleri gibi hepsi aynı proses elemanına sahip olabilir. Hatta ağın bazı proses elemanları grup halinde aynı toplama fonksiyonuna sahip olabilir. Diğerleri ise farklı fonksiyonlar kullanabilirler. Bu tamamen tasarımcının kendi öngörüsüne dayanarak verdiği karara bağlıdır. Literatürde toplama fonksiyonu olarak değişik formüllerin kullanıldığı görülmektedir. Bir problem için en uygun toplama fonksiyonunu belirlemek için bulunmuş bir formül yoktur. Genellikle deneme yanılma yolu ile toplama fonksiyonu belirlenmektedir (Öztemel, 2012). Çizelge 3.20.'de toplama fonksiyonunda kullanılabilecek yöntemler ve açıklamaları verilmiştir.

Çizelge 3.20. Toplama Fonksiyonu Örnekleri

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

4. Aktivasyon (Transfer) Fonksiyonu: Bu fonksiyon, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonu olarak da çıktıyı hesaplamak için değişik formüller kullanılmaktadır. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonunda da ağın proses elemanlarının hepsinin aynı fonksiyonu kullanması gerekmez. Bazı elemanlar aynı fonksiyonu diğerleri farklı fonksiyonları

kullanabilirler. Bir problem için en uygun aktivasyon fonksiyonu yine tasarımcının denemeleri sonucunda belirleyebileceği bir durumdur. Uygun fonksiyonu gösteren bir formül bulunmuş değildir (Öztemel, 2012). Burada değinilmesi gereken en önemli nokta, zaman serisi analizinde yoğunlukla kullanılan çoğu ağ mimarisinin öğrenme kuralları, kullanılacak olan aktivasyon fonksiyonunun türevlenebilir olmasını gerektirmektedir (Çelik, 2008). Literatürde, sıkıştırma veya eşik fonksiyonu olarak da adlandırılmaktadır. Bunun nedeni, çıktı sinyallerini [0,1] veya [-1,1] Aralığında sınırlandırmasıdır (Biçen, 2006). Transfer fonksiyonunun amacı çıktıların çok büyük değerlere ulaşmasını engellemektir. Eğer cıktılar çok büyük değerlere ulaşır ise ağ felç olur ve ağın eğitimi engellenmiş olur (Yıldız, 2009). Kullanımı en yaygın aktivasyon fonksiyonları, şekil 3.5'te grafiksel olarak gösterilmiştir.



Şekil 3.5. Aktivasyon Fonksiyonları

a. Sigmoid Fonksiyonu: Zaman serisi ile ilgili araştırmaların çoğunda sigmoid tipli aktivasyon fonksiyonu kullanılmaktadır (Çelik, 2008). Literatürde tek kutuplu aktivasyon fonksiyonu olarak da bilinir. YSA'da, özellikle sistemin yüksek seviyede karmaşık ve doğrusal olmadığı durumlarında tercih edilen bir fonksiyon olmasına rağmen, sigmoid fonksiyonu uzun dönemli tahminlerde oldukça zayıftır (Bayru, 2007). Bu fonksiyon, diferansiyel olması nedeni ile, çok katmanlı ve geri

besleme algoritması ile eğitilen ağlarda yaygın olarak kullanılır (Demir, 2007). Sürekli ve türevi alınabilir bir fonksiyondur. Doğrusal olmayışı dolayısıyla Yapay Sinir Ağı uygulamalarında en sık kullanılan fonksiyondur. Girdi değerlerinin her biri için 0 ile 1 arasında bir değer üretir. Sigmoid fonksiyonunun türevi her zaman pozitiftir. Eğer aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılacak ise verilerin [0 – 1] aralığında normalleştirilmesi gerekir. En çok kullanılan aktivasyon fonksiyonlarının başında sigmoid fonksiyonu gelir. Bunun temel nedeni, doğrusal ve doğrusal olmayan fonksiyonların her ikisinin de modellenmesinde oldukça dengeli çıktılar üretmesidir (Yıldız, 2009).

$$F(NET) = \frac{1}{1+e^{-NET}} = \frac{1}{1+e^{\left[\sum_{i=1}^{n} w_i x_i + \theta\right]}} \tag{3.2}$$

Denklem (3.2)'de verilen eşitliklerden de anlaşılacağı gibi sigmoid fonksiyonu yapısı gereği doğrusal olmayan bir fonksiyon olduğundan, doğrusal olmayan zaman serisi analizinde etkin olarak kullanılabilecek bir fonksiyondur. Bu fonksiyon doğası gereği negatif değerler içeren zaman serilerinin analizine uygun değildir. Bunun nedeni değer kümesinde negatif reel sayıların bulunmayışıdır (Çelik, 2008).

b. Hiperbolik Tanjant Fonksiyonu: YSA'da yoğun olarak kullanılan bir aktivasyon fonksiyonudur. Çift kutuplu fonksiyon olarak da bilinen hiperbolik tanjant fonksiyonu, [−1,+1] aralığını kullanır (Özdemir, 2008). Hiperbolik Tanjant Fonksiyonu, doğrusal olmayan, türevi alınabilir bir fonksiyondur. Sigmoid fonksiyonuna göre avantajı, denklem (3.3)'de negatif değişkenler içeren zaman serilerini de modelleyebilmesidir (Çelik, 2008).

$$F(NET) = \frac{e^{NET} - e^{-NET}}{e^{NET} + e^{-NET}} = \frac{e^{\left[\sum_{i=1}^{n} w_i x_i + \theta\right]} - e^{-\left[\sum_{i=1}^{n} w_i x_i + \theta\right]}}{e^{\left[\sum_{i=1}^{n} w_i x_i + \theta\right]} + e^{-\left[\sum_{i=1}^{n} w_i x_i + \theta\right]}} \tag{3.3}$$

c. Step Fonksiyonu: Gelen NET girdi değerinin belirlenen bir eşik değerinin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerlerini alır. Denklem (3.4) Zaman serisi analizine pek uygun olmayıp, özellikle doğrusal

olmayan serilerin analizinde yetersiz kalmaktadır. Genellikle tek katmanlı ağlarda kullanılan step fonksiyonu, daha çok resim tanıma, görüntü işleme ve sınıflandırma problemlerinin çözümünde kullanılmaya uygundur (Çelik, 2008).

$$F(NET)=\begin{cases}1 & NET > eşik_değeri \\ 0 & NET < eşik_değeri\end{cases} \tag{3.4}$$

Çizelge 3.21.'de YSA'da kullanılan diğer aktivasyon fonksiyonları gösterilmiştir.

Çizelge 3.21. Diğer Aktivasyon Fonksiyonları

İki Kutuplu Sigmoid Aktivasyon Fonksiyonu	$F(NET)=-1+\frac{2}{1+e^{-NET}}$
Cebirsel Sigmoid Aktivasyon Fonksiyonu	$F(NET)=\frac{NET}{\sqrt{1+NET^2}}$
Lineer Aktivasyon Fonksiyonu	$F(NET)=NET$
Sinüs Aktivasyon Fonksiyonu	$F(NET)=Sin(NET)$
Arctanjant Aktivasyon Fonksiyonu	$F(NET)=\arctan\left(\frac{NET}{\pi}\right)+0.5$
İki Kutuplu Arctanjant Aktivasyon Fonksiyonu	$F(NET)=\arctan\left(\frac{2NET}{\pi}\right)$
Gaussian Aktivasyon Fonksiyonu	$F(NET)=e^{-NET}$
Cauchy Aktivasyon Fonksiyonu	$F(NET)=\frac{1}{1+NET}$

5. Çıkış Fonksiyonu: Aktivasyon fonksiyonunun sonucunu dış dünyaya veya diğer sinirlere gönderildiği yerdir. Bir sinirin bir tek çıkışı vardır. Sinirin bu çıkışı, kendinden sonra gelen herhangi bir sayıdaki diğer sinirlere giriş olabilir (Elmas, 2010).

3.2.8.8. YSA'da Öğrenme

YSA'nın öğrenmesini sağlayan mekanizma öğrenme algoritmasıdır. Öğrenme algoritmaları YSA'nın istenen davranışı gösterebilmesini veya istenen çıktıları üretmesini sağlayan algoritmalardır. Sinir ağları insanlar gibi örnekler ile eğitilirler.

YSA'nın öğrenmesi, bir çocuğun öğrenmesine benzetilebilir. Sıcak bir nesneye dokunmaması gerektiğini deneyerek öğrenen çocuklar zamanla daha az sıcak olan bir cisme dokunabilme cesaretini gösterirler ve sıcak süt dolu bardağı elleriyle tutarlar. Yani çocuk sıcaklık bilgisini öğrenmiş olmaktadır (Çelik, 2008). YSA'nın belirli girdiler için istenen çıktıları üretebilmesi için, ağın içindeki bağlantıların ağırlıkları değiştirilir ve çıktıların üretilmesini sağlayacak ağırlık değerleri bulunur. Algoritmanın bu işlevi yerine getirebilmesi için örnek çıktılara ihtiyaç vardır. Öğrenme algoritması, istenen çıktılar elde edilinceye kadar iterasyon yapar. Öğrenme algoritmasının görevi, istenen çıktıların üretilmesi için Yapay Sinir Ağının ağırlıkları üzerinde düzeltmeler yapmaktır (Yıldız, 2009). Başlangıçta ağırlık değerleri rastgele atanır. YSA kendilerine örnekler gösterildikçe bu ağırlık değerlerini değiştirirler. Örnekler ağa defalarca gösterilerek en doğru ağırlık değerleri bulunmaya çalışılır. Bağlantı ağırlıklarının tamamının veya bir kısmının istenen çıktı ile ağ çıktısı arasındaki farkın (ε_i) belirli bir değere düşünceye kadar değiştirilir. Ağın doğru ağırlık değerlerine ulaşması örneklerin temsil ettiği olay hakkında genellemeler yapabilme yeteneğine kavuşması demektir. Bu genelleştirme özelliğine kavuşması işlemine ağın öğrenmesi denir (Elmas, 2010).

3.2.8.9. YSA'da Öğrenme Stratejileri

1. Öğretmenli Öğrenme: Ağın eğitiminde, çıktıların istenen değerleri ağa tanıtılabiliyorsa bu tip öğrenme, öğretmenli öğrenme adını alır. Girdi ve çıktı kümeleri ağa verilir. Ağ, girdiyi işleyerek kendi çıktısını üretir ve gerçek çıktı ile karşılaştırır. Öğrenme metodu sayesinde mevcut hatayı en aza indirmek için bağlantılardaki ağırlıklar yeniden düzenlenir. Bu işlem kabul edilebilir bir hata seviyesine ulaşıncaya kadar devam eder. Geri yayılım ağı ve Boltzmann makinesi en yaygın kullanılan öğretmenli ağlardır (Hamzaçebi, 2011).

2. Öğretmensiz Öğrenme: Çıktıların istenen değerleri ağa tanıtılamıyorsa bu tip öğrenme şekli öğretmensiz öğrenme olarak adlandırılır. Öğretmensiz öğrenmede girdiler aynı zamanda çıktı vazifesi görmektedir. Hem çıktı hem de girdi olan veriler arasındaki kural ve ilişkilerin araştırılması ve en uygununun bulunması ağın eğitilmesi anlamına gelmektedir. Adaptif Rezonans Teorisi (ART), Hopfield Ağı, Kohonen Ağı en çok kullanılanlarıdır (Hamzaçebi, 2011). Bu tip eğitimde ağdan; ne

yapması gerektiğini söylemeden, ne yapması gerektiğini öğrenmesi beklenir (Çelik, 2008).

3. Destekleyici Öğrenme: Öğretmenli öğrenme sisteminde olduğu gibi ağa bir öğretmen yardımcı olur. Ancak burada öğretmen, olması gereken çıktıları sisteme tanıtmaz. Bir girdi vektörüne karşılık ağın ürettiği çıktı için olumlu ya da olumsuz sinyal üretilerek ağ ağırlıklarının düzenlenmesi sağlanır (Hamzaçebi, 2011). LVQ ağı bu stratejiyi kullanan sistemlere örnek olarak verilebilir.

4. Karma Stratejiler: Yukarıda belirtilen üç stratejiden birkaçını birlikte kullanarak öğrenme gerçekleştiren ağlar da vardır. Burada kısmen öğretmenli, kısmen ise öğretmensiz olarak öğrenme yapan ağlar kastedilmektedir. Radial Tabanlı YSA (RBN) ve Olasılık tabanlı ağlar (PBNN) bunlara örnek olarak verilebilir (Öztemel, 2012).

3.2.8.10. YSA'da Çevrimiçi ve Çevrimdışı Öğrenme

Çevrimdışı (offline) öğrenmede; Yapay Sinir Ağı, problem için eğitilmeye başlandıktan sonra ağın bağlantı ağırlıkları sabitlenir. Yani öğrenme işlemi uygulamanın başlangıcında olmak üzere bir kez yapılır. Daha sonra bağların kuvvetleri değiştirilmez. Günümüzde kullanılan birçok model bu özelliktedir.

Çevrimiçi (online) öğrenmede ise YSA, bir yandan öngörü için kullanılırken bir yandan da yeni gelen verilerden öğrenmeye devam edebilir. Dolayısıyla, bağlantı ağırlıklarının değerleri yeni verilere göre de güncellenmiş olur. Bu tür ağlar, diğerlerine kıyasla daha karmaşık bir tasarıma sahiptirler (Çelik, 2008).

3.2.8.11. YSA'da Öğrenme Kuralları

1. Hebb Kuralı: Bilinen en eski öğrenme kuralıdır. Diğer öğrenme kurallarının temelini oluşturmaktadır. Hebb kuralına göre, Eğer sinyal alan ile gönderen nöronlar arasındaki sinaptik ağırlıkların ikisi de matematiksel olarak aynı işarete sahip ise, bu iki nöron arasındaki bağ kuvvetlendirilmelidir. Aksi halde bağın kuvveti azaltılmalıdır (Hebb, 1949). Diğer bir deyişle bir hücre kendisi aktif ise bağlı olduğu hücreyi aktif yapmaya, pasif ise pasif yapmaya çalışmaktadır. Diğer öğrenme

kurallarının çoğu bu felsefeyi baz alarak geliştirilmiştir (Öztemel, 2012). Günümüzde en çok bilinen YSA öğrenme algoritması olan geri yayılım algoritmasının temeli de bu kurala dayanmaktadır (Bayru, 2007).

2. Hopfield Kuralı: Hebb öğrenme kuralına benzemektedir. Hebb kuralına ek olarak, bağ kuvvetlerindeki değişimlerin ne kadar olacağını da belirtmektedir. Bu kurala göre; bağ kuvveti öğrenme hızı kadar arttırılır ya da azaltılır. Eğer beklenen çıktı ve girdiler ikisi de aktif/pasif ise öğrenme katsayısı kadar ağırlık değerleri kuvvetlendir/zayıflat denmektedir. Yani ağırlıkların kuvvetlendirilmesi veya zayıflatılması öğrenme katsayısı yardımıyla gerçekleştirilmektedir. Öğrenme katsayısı genel olarak 0-1 arasında kullanıcı tarafından atanan sabit ve pozitif bir değerdir (Öztemel, 2012).

3. Delta Kuralı: Günümüzde en yaygın kullanılan öğrenme kurallarından biridir. Hebb kuralının daha geliştirilmişidir. Bağların kuvvetleri, ağ çıktısı ile hedeflenen çıktı arasındaki fark minimum olana kadar sürekli olarak değiştirilir. Delta kuralında amaç, ağın hata karelerinin toplamının $\left(\sum_{i=1}^{n} \varepsilon_i^2\right)$ en aza indirilmesidir. Hata, bir önceki katmana geri çoğaltılır. Her bir zaman dilimi için bir hata şeklinde bu geri çoğaltma işlemi ilk katmana ulaşılıncaya kadar devam eder. Bu tip ağ, ileri beslemeli ağ olarak isimlendirilir. Geri yayılım adını bu hata terimlerini toplama yönteminden türetir. Bu kural ayrıca Windrow-Hoff öğrenme ve En küçük ortalamalar karesi (Least Mean Square) kuralı olarak da adlandırılır (Elmas, 2010). Delta kuralı kullanılırken dikkat edilmesi gereken en önemli unsur, girdi setindeki verilerin rasgele dağılmış olması gerekmektedir. Eğitim setinin düzgün sırada olması veya yapısal olarak düzgün olması, istenilen doğruluğa ulaşmaya engel teşkil etmekte ve ağın öğrenmesini zorlaştırmaktadır (Bayır, 2006).

4. Kohonen Kuralı: Kohonen tarafından geliştirilen bu yöntem, biyolojik sistemlerdeki öğrenmeden esinlenerek geliştirilmiştir. Bu kurala göre ağın hücreleri ağırlıklarını değiştirmek için birbirleriyle yarışırlar. En büyük çıktıyı üreten hücre kazanan hücre olmakta ve bağlantı ağırlıkları değiştirilmektedir. Bu, o hücrenin yakınındaki hücrelere karşı daha kuvvetli hale gelmesi demektir. Hem kazanan elemanların hem de komşuları sayılan hücrelerin ağırlıklarını değiştirmesine izin

verilmektedir (Öztemel, 2012). Başka bir deyişle; sadece kazanan elemanın çıktı üretmesine ve komşu hücreleri ile birlikte ağırlıklarının değiştirilmesine izin verilir (Bayır, 2006).

3.2.8.12. Tek Katmanlı YSA Modelleri

YSA modellerinin ilk hali olan tek katmanlı ağlarda sadece giriş ve çıkış tabakaları mevcuttur. Her ağın bir veya daha fazla girdisi ve tek bir çıktısı vardır. Çıktılar girdilerin tamamına bağlanmıştır. Her girdinin bir ağırlığı vardır. Bu kapsamda bir de eşik değeri vardır. Ağın çıktısı, girdilerin ağırlıkları ile çarpımından sonra tamamının ve eşik değerin toplanmasından sonra bir fonksiyondan geçirilmek sureti ile hesaplanır (Yıldız, 2009).

Tek katmanlı algılayıcılarda çıktı fonksiyonu doğrusal fonksiyondur. Ağa gösterilen örnekler iki sınıf arasında dağıtılarak, bu iki sınıfı birbirlerinden doğrusal olarak ayıran doğrunun bulunması hedeflenir. Ağın çıktısı +1 ile -1 değerlerini almaktadır. +1 ve -1 sınıfları temsil etmektedir. Eğer ağın çıktısı +1 ise birinci sınıfta, -1 ise ikinci sınıfta kabul edilmektedir. Bazı araştırıcılar sınıfları +1 veya 0 olarak göstermektedirler. Felsefede bir değişiklik yoktur.

$$f(g) = \begin{cases} 1 & Ç \rangle 0 \\ -1 & aksi \end{cases}$$

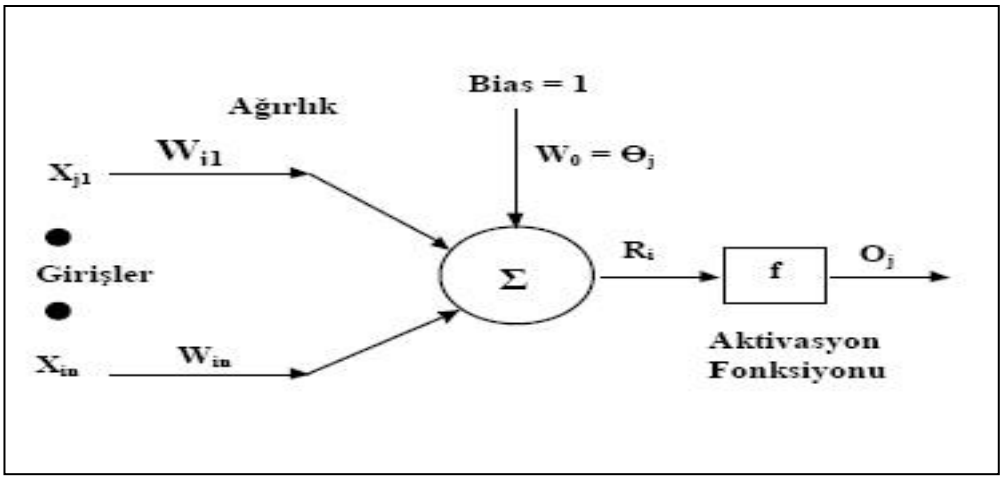
Formül incelendiğinde ağa gelen toplam girdinin pozitif olması durumunda ağa sunulan örnek 1 sınıfına, negatif olması durumunda ise -1 sınıfına ait demektir. Sıfır olması durumu ise tasarımcının kabulüne kalmıştır (Elmas, 2012).

Tek katmanlı Yapay Sinir Ağında Perceptron modeli ile ADALINE ve MADALINE modeli oldukça önemlidir.

1. Perceptron Modeli:

1958 yılında, Frank Rosenblatt, bir sineğin gözlerinin işleyişini temel alarak Perceptron'u (Algılayıcı) tasarlamıştır. Rosenblatt çalışmasında, iki katlı bir algılayıcının (perceptron) iki farklı sınıfı ayırt edebileceğini ispatlamıştır. İlk YSA modellerinden olan perceptron modeli, daha sonra geliştirilen modellere bir temel

oluşturması ve mevcut algoritmalarla bağlantılı olmasından dolayı önemli bir modeldir (Küçükönder, 2011).



Şekil 3.6. Perception Modeli

Şekil 3.6.'da görüldüğü üzere perceptron, bir sinir hücresinin birden fazla girdiyi alarak bir çıktı üretmesi prensibine dayanmaktadır. Ağın çıktısı 1 veya 0'dan oluşan mantıksal değerdir.

Perceptron, eğitilebilen tek bir yapay sinir hücresinden oluşur. Eğitilebilirden kasıt ağırlıkların değiştirilebilen olması demektir. Girdiler sinir hücresine gösterilirler. Her girdi setine karşılık gelen çıktı değerleri de ağa gösterilir. Daha sonra öğrenme kuralına göre ağın çıktı değerleri hesaplanır. Eğer ağın çıktısı olması gereken çıktıdan farklı ise ağırlıklar ve eşik değerleri değiştirilir. Değişikliğin nasıl yapılacağını ise öğrenme kuralı belirler. Girdilere karşılık çıktı değerleri 1 veya 0'dan oluşmaktadır (Öztemel, 2012).

Perceptron Modelinin Öğrenme Kuralı,

Adım 1: Ağa girdi setini ve ona karşılık olarak beklenen çıktı gösterilir. Burada birden fazla girdi değeri olabilir. Yani $X = (x_1, x_2, x_3, ..., x_n)$ demektir. Çıktı değeri ise 1 ve 0 değerlerinden birisini alır.

Adım 2: Perceptron ünitesine gelen net girdi şu şekilde hesaplanır:

$$NET = \sum_{i=1}^{n} w_i x_i$$

Adım 3: Perceptron ünitesinin çıktısı hesaplanır. Net girdinin eşik değerinden büyük veya küçük olmasına göre çıktı değeri 0 ve 1 değerlerinden birisini alır. Yani;

$$Ç = \begin{cases} 1 & NET \rangle \theta \\ 0 & NET \langle = \theta \end{cases}$$

Eğer gerçekleşen çıktı ile beklenen çıktı aynı olursa ağırlıklarda herhangi bir değişiklik olmaz. Ağ beklenmeyen bir çıktı oluşturmuş ise o zaman iki durum söz konusudur:

a) Ağın beklenen çıktısı 0 değeridir. Fakat NET girdi, eşik değerinin üstündedir. Yani ağın gerçekleşen çıktısı 1 değeridir. Bu durumda ağırlık değerleri azaltılmaktadır. Ağırlıkların değişim oranı girdi değerlerinin belirli bir oranı kadardır.

$$W_n = W_0 - \lambda X$$

Olur. Burada λ, öğrenme katsayısıdır. Ağırlıkların değişim miktarlarını belirlemekte ve sabit bir değer olarak alınmaktadır.

b) Beklenen çıktının 1 olması ve ağın gerçek çıktısının 0 olması durumudur. Yani net girdi eşik değerinin altındadır. Bu durumda ağırlıkların değerinin arttırılması gerekmektedir.

$$W_n = W_0 + \lambda X$$

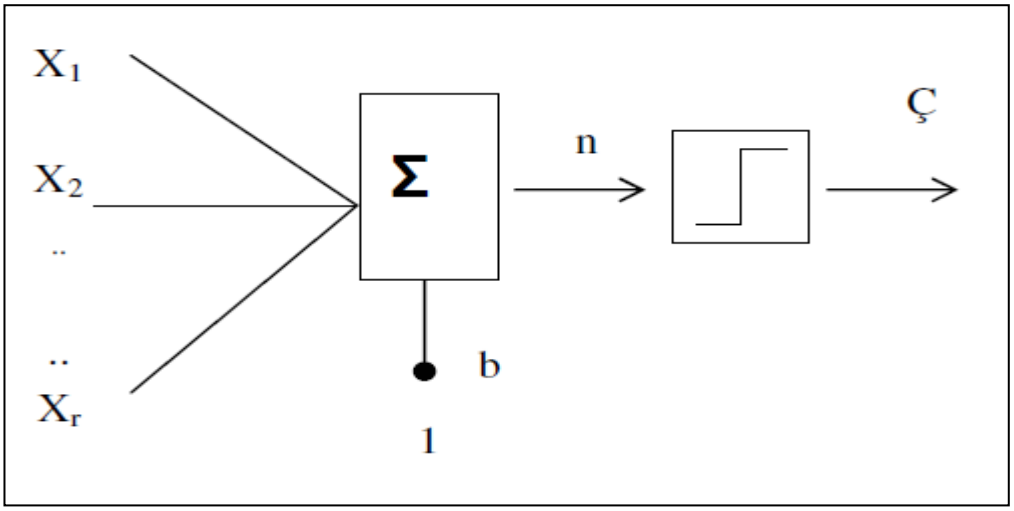
olacaktır.

Adım 4: Yukarıdaki adımları bütün girdi setindeki örnekler için doğru sınıflandırmalar yapılıncaya kadar ilk üç adımdaki işlemler tekrarlanır.

2. ADALINE Modeli

Şekil 3.7.'de çalışma prensibi basitçe ifade edilen ADALINE modeli, Widrof ve Hoff tarafından 1959 yılında gerçekleştirilmiş olup **ADA**ptif **LIN**ear **E**lement

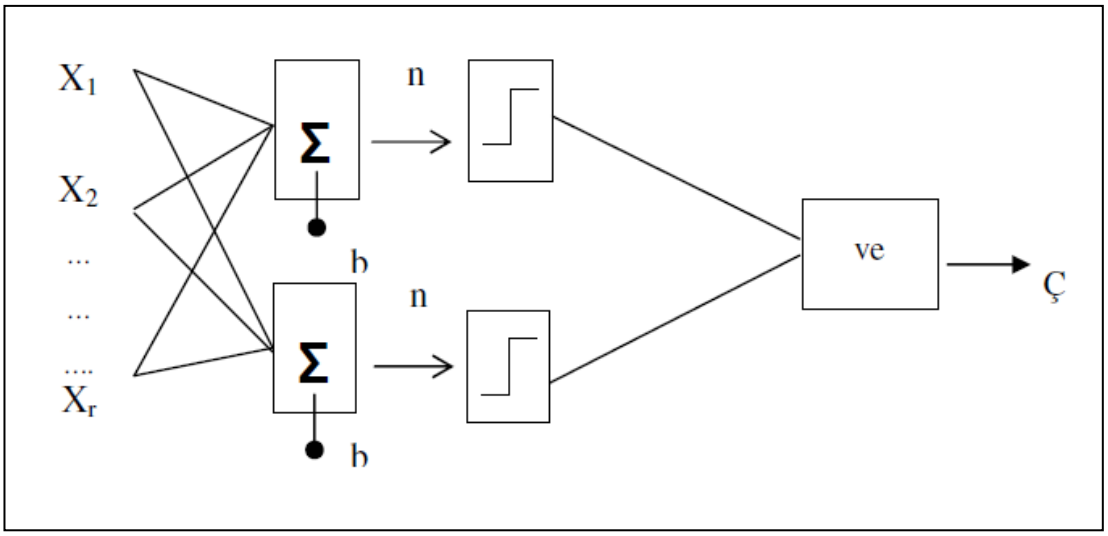
ağının kısaltılmış halidir (Adıyaman, 2007). ADALINE modeli, en küçük kareler yöntemini kullanarak öğrenme gerçekleştirir. Perceptron ile ADALINE arasındaki fark öğrenme kuralıdır. Öğrenme Delta Öğrenme Kuralına göre gerçekleşir.



Şekil 3.7. ADALINE Modeli

3. MADALINE Modeli

MADALINE ağları, birden fazla ADALINE ünitesinin bir araya gelerek oluşturdukları ağa verilen isimdir. MADALINE ağları genel olarak iki katmandan oluşmaktadır. Her katmanda değişik sayıda ADALINE ünitesi bulunmaktadır. Ağın çıktısı da yine 1 ve -1 değerleri ile gösterilmektedir. Her biri bir sınıfı temsil etmektedir. MADALINE'nin öğrenme kuralı ADALINE üniteleri için kullanılan öğrenme kuralı ile aynıdır. Burada en sonda bulunan AND veya OR sonlandırıcısı önemlidir. Klasik mantık teorisinde olduğu gibi AND sonlandırıcısı olması durumunda bütün ADALINE ünitelerinin 1 değerini üretmesi sonucu MADALINE ağının çıktısı 1 olur. Aksi halde -1 (veya 0) değerini alır. OR sonlandırıcısı olması durumunda ADALINE ünitelerinin birisinin 1 üretmesi MADALINE ağının çıktısının 1 olması yeterlidir. (Öztemel, 2012) MADALINE telefon hatlarında oluşan yankı ve parazitleri yok eden bir uyarlanabilir (adaptive) bir süzgeç olarak kullanılmıştır ve gerçek dünya sorunlarına uygulanmış ilk Yapay Sinir Ağı olma özelliğini taşımaktadır (Çelik, 2008) Şekil 3.7'nin çoklu halini ifade eden MADALINE modeli şekil 3.8.'de gösterilmiştir.

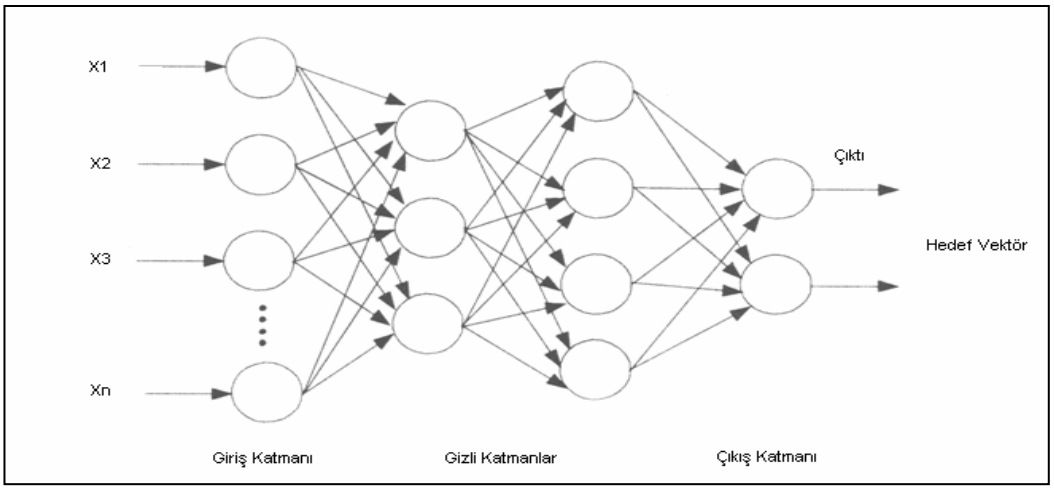


Şekil 3.8. MADALINE Modeli

3.2.8.13. Çok Katmanlı YSA Modelleri

Tek katmanlı YSA'nın en büyük sıkıntılarından bir tanesi de doğrusal olmayan olayları çözememesidir. Günlük olayların çoğu doğrusal olmayan nitelik taşımaktadır ve doğrusal olmayan problemi çözmek için yeni modellerin geliştirilmesine ihtiyaç duyulmuştur. Çok katmanlı ağları tek katmanlı ağlardan ayıran özellik, çok katmanlı ağlarda bulunan gizli katmandır. Giriş ve çıkış tabakalarının arasına gizli katman ya da ara katman denilen bir katman eklenmiştir. Gizli katmanda yapılan bir dizi işlem ile ağ doğrusal olmayan bir yapıya kavuşturulabilmektedir (Özdemir, 2008). Ara katman sayısı bir veya birden fazla olabilir. Ayrıca her ara katmanda birden fazla işlemci eleman bulunabilmektedir. Çok katmanlı ağlarda bilgiler girdi katmanından ağa sunulur ara katmanlardan geçerek çıktı katmanına ulaşır ve bu katman tarafından ağın cevabı olarak dış ortama iletilir. Bilgi akışı ileri doğru olduğu için çok katmanlı ağlar, ileri beslemeli YSA sınıfına girmektedir (Baş, 2006). İleri beslemeli ağ, genelde zaman serisi çalışmalarında çok katmanlı ağa verilen addır. Çok katmanlı ağ modeli, mühendislik problemlerinin hemen hemen hepsine çözüm üretebilecek bir güce sahiptir. Özellikle sınıflandırma, tanıma ve genelleme yapmayı gerektiren problemlerin çözümünde kullanılır. Kullanılan öğrenme algoritmasına göre ağın çıkışı ile arzu edilen çıkış arasındaki hata tekrar geriye doğru yayılarak hata minimuma düşünceye kadar ağın ağırlıkları değiştirilir. Bu nedenle çok katmanlı ağlar, geri yayılım ağı olarak da

anılmaktadır. Hata, ağa yayıldığı için Çok katmanlı ağların kullandığı öğrenme kuralına Genelleştirilmiş Delta Öğrenme Kuralı denir.



Şekil 3.9. Çok Katmanlı YSA

Şekil 3.9.'da görüldüğü gibi Çok katmanlı ağlar, 3 katmandan oluşur.

1. Girdi katmanı: Dış dünyadan gelen bilgileri alarak ara katmana gönderir. Bu katmanda bilgi işleme olmaz. Gelen her bilgi geldiği gibi bir sonraki katmana gider. Yani giriş katmanında herhangi bir bilgi işleme yapılmaz. Bu yüzden de bazı araştırmacılar tarafından ağların tabaka sayısına dahil edilmezler (Usta, 2007). Bu katmanda nöron sayısı, giriş değişkenlerinin sayısı kadardır ve her bir giriş nöronu bir veri alır ve bir sonraki katmanda bulunan bütün nöronların hepsine bağlıdır.

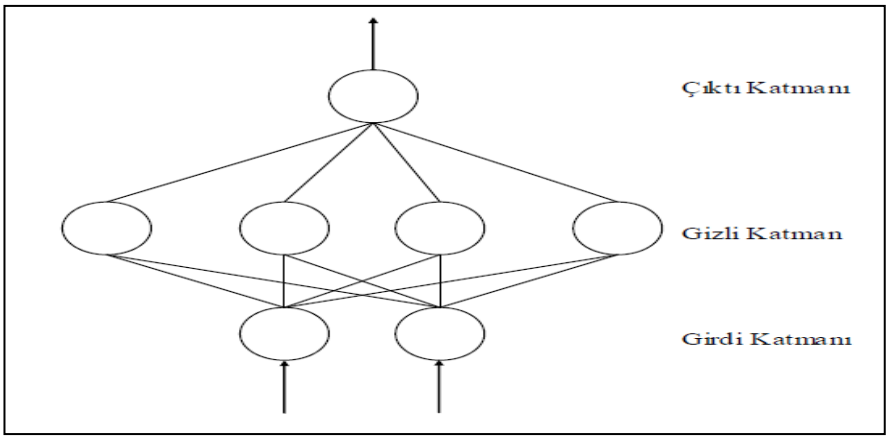
2. Ara Katmanlar: Girdi katmanı ile çıktı katmanı arasında yer alır. Ağın temel işlevini gören katmandır. Girdi katmanından gelen bilgileri işleyerek bir sonraki katmana gönderir. Bir Çok katmanlı ağda birden fazla ara katman ve her katmanda birden fazla proses elemanı olabilir. Ara katmandaki her proses elemanı bir sonraki katmandaki bütün proses elemanlarına bağlıdır. Gizli katman sayısı ve katmandaki nöron sayısı, ağ tasarımcısının kontrolünde olup probleme göre değişir. Gizli katmanda gereğinden az nöron kullanılması ağın mevcut çıktılarının tahmin verimini düşürürken gerektiğinden daha çok sayıda nöron kullanılması da yeni girdi değerleri için yapılacak çıkış tahminlerinin doğruluk oranını azaltır. Genel olarak gizli katman ve gizli katmandaki hücre sayısının sayıları deneyim ile belirlenir. Gizli

katman, sinir ağının hesaplama süresini yavaşlatabilir ancak çok önemli denge sağlayan avantajları vardır. Çok katmanlı sinir ağı, karar bölgesi doğrusal olmayan ve karışık sınıflama problemlerinin çözümü için gereklidir (Demir, 2007). Ara katman sayısı arttıkça YSA'nın girdi verilerinden yüksek mertebede istatistikler elde etme yeteneği artmaktadır. Bu, geniş girdi katmanlarının olduğu durumlarda önemli bir nitelik kazanmaktadır (Vural, 2007).

3. Çıktı Katmanı: Bu katmanda yer alan her hücre birden fazla girdi alır ve bir çıktı üretir. Ara katmandan gelen bilgileri alarak işler ve çıktıları elde eder.

3.2.8.14. İleri Beslemeli YSA Modelleri

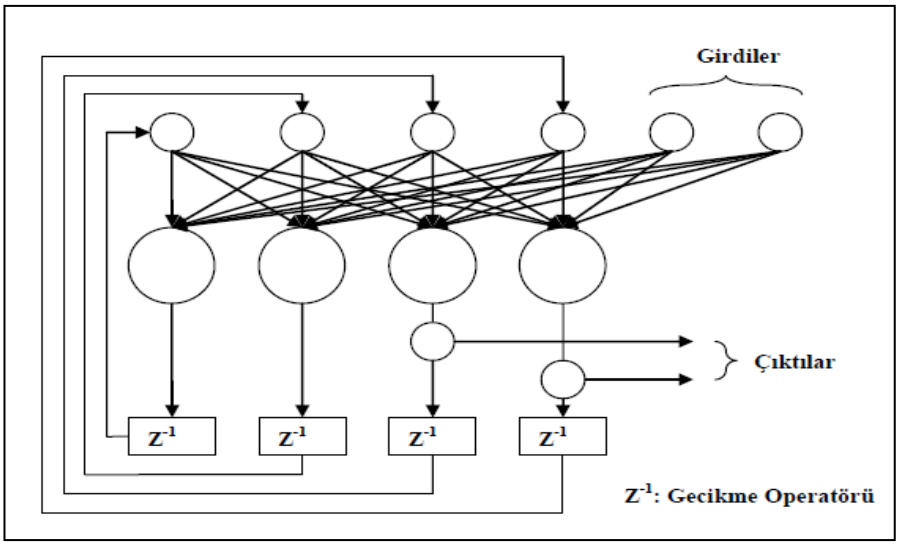
İleri beslemeli YSA'da hücreler katmanlar şeklinde düzenlenir ve bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir. Giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan gizli katmandaki hücrelere iletir. Bilgi, orta ve çıkış katmanında işlenerek ağ çıkışı belirlenir (Çuhadar, 2006). Şekil 3.10.'da görüldüğü üzere bir katmandaki her işlemci eleman bir sonraki katmandaki tüm elemanlarla bağlantılıdır ancak aynı katmandaki elemanlar arasında herhangi bir bağlantı bulunmamaktadır. Bu nedenle ileri beslemeli YSA'da işlemci elemanlar arasındaki bağlantılar bir döngü oluşturmamakta ve bu ağlar, girilen verilere hızlı bir şekilde çıktı üretebilmektedir (Baş, 2006). İleri besleme YSA, öğrenme algoritması olarak genellikle geri yayılım öğrenme algoritmasını kullanmakta ve bu nedenle bazen geri yayılım ağları olarak da adlandırılmaktadır. İleri beslemeli 3 katmanlı YSA'nın, orta katmanında yeterli sayıda hücre olmak kaydıyla herhangi bir sürekli fonksiyonu istenilen doğrulukta yaklaştırabileceği gösterilmiştir (Özgen, 2007). Gizli katmanlarda yer alan nöronların doğrusal olmayan davranışları, ileri beslemeli ağların doğrusal olmamasının nedenidir (Polat, 2009). İleri beslemeli ağlara örnek olarak Çok katmanlı Perceptronlar ve LVQ (Learning Vector Quantization) ağları verilebilir (Saygılı, 2008). İleri beslemeli YSA, bilgi akışı, giriş katmanından bir sonraki katmana tek yönlü bir bağlantı ile iletilerek sonraki katmanda ise çıkışların geriye giriş olarak tekrarlandığı bir döngü yapısına sahip olduğundan "statik ağlar" olarak da bilinmektedirler (Küçükönder, 2011). Genellikle şekil tanıma, sinyal işleme ve sınıflandırma gibi problemlerde kullanılmaktadır.



Şekil 3.10. İleri Beslemeli YSA Modeli

3.2.8.15. Geri Beslemeli YSA Modelleri

Geri beslemeli YSA, şekil 3.11.'de görüldüğü üzere ileri beslemeli ağların aksine dinamik bir yapıya sahip olup en az bir hücrenin çıkışı, kendisine veya diğer hücrelere giriş verisi olarak verilir. Genellikle geri besleme bir gecikme elemanı (ara katman veya çıktı katmanındaki aktivasyon değerlerini bir sonraki iterasyona girdi olarak taşımakla görevli eleman) üzerinden yapılmaktadır. Geri besleme, bir katmandaki hücreler arasında olduğu gibi katmanlar arasındaki hücreler arasında da olabilir. Bu yapısı ile geri beslemeli YSA, doğrusal olmayan dinamik bir davranış gösterirler (Karahan, 2011). Geri beslemeli ağ mimarileri genellikle danışmansız öğrenme kurallarının uygulandığı ağlarda kullanılmaktadır (Çuhadar, 2006). Geri beslemeli Yapay Sinir Ağları karmaşık bir çalışma düzeneğine sahip olmalarına rağmen dinamik hafızaları nedeniyle önceden tahmin uygulamalarında başarılı sonuçlar verirler. Geri dönüşümlü ağlar, yüksek performans vermelerine karşın yapılarının belirlenmesi oldukça zor olabilir ve çok dinamik oldukları için durumları denge noktasına ulaşıncaya kadar sürekli olarak yeni girdiler vermek gerekebilir. Denge noktasında girdi değişinceye kadar kalırlar ve daha sonra yeni bir denge bulunur. Dinamik sistemlerin modellenmesinde zaman gecikmesinin göz önüne alınması gereklidir. Geri beslemeli YSA, özellikle bozucu ve ölçülemeyen girişleri olan dinamik sistemleri modellemek amacıyla kullanılmış ve başarılı sonuçlar alınmıştır (Vural, 2007). Geri beslemeli ağlara örnek olarak Hopfield, Elman ve Jordan ağları verilebilir.

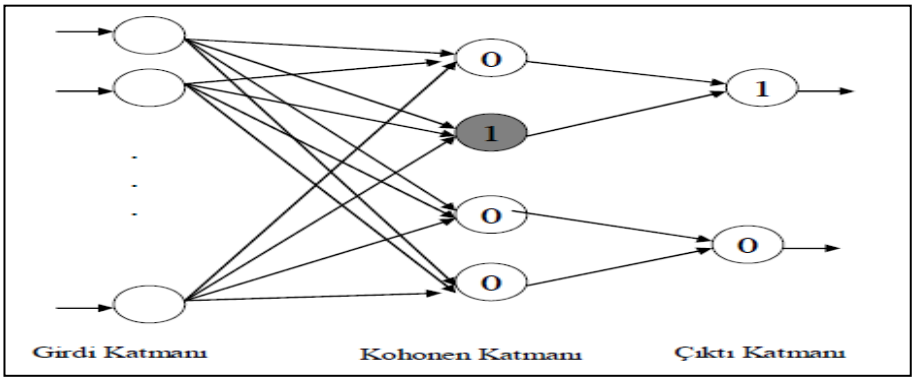


Şekil 3.11. Geri Beslemeli YSA Modeli

1. LVQ Ağı

Kohonen tarafından 1984 yılında geliştirilmiştir. Bu modeli Kohonen'in daha önce geliştirdiği SOM (Self Organizing Maps) modeli Kohonen katmanı denilen bir yapı üzerine temellendirilmiştir. Temel felsefesi, ***n*** boyutlu bir vektörü bir vektörler setine haritalamaktır (uydurmaktır). Aslında bir vektörün belirli sayıda vektörler ile gösterimi amaçlanmaktadır. Öğrenme ile de girdi vektörünün hangi vektör seti tarafından temsil edilmesi gerektiği bulunmak kastedilmektedir. LVQ ağları genel olarak sınıflandırma problemlerinin çözümünde kullanılmaktadır. Çıktılardan sadece birisi 1 diğerleri 0 değerlerini almaktadır. Çıktı değerinin 1 olması girdinin ilgili çıktının temsil ettiği sınıfa ait olduğunu göstermektedir. Eğitim sırasında girdilerin sınıflara ayrılması en yakın komşu kuralına göre gerçekleştirilmektedir. Girdi vektörü ile referans vektörleri arasındaki en kısa mesafe aranmakta ve girdi vektörünün en kısa mesafede bulunan vektör grubuna ait olduğu varsayılmaktadır. Ağın ağırlıklarını değiştirmek yolu ile girdileri doğru sınıflara ayıracak referans vektörleri belirlenmektedir. Kullanılan öğrenme stratejisi, destekleyici öğrenmedir. Çıktı değerlerinin belirlenmesinde ise ***kazanan her şeyi alır*** stratejisi uygulanmaktadır. Ağ eğitilirken her iterasyonda ağın ürettiği çıktının değeri yerine sadece doğru olup olmadığı söylenir. Sadece girdi vektörüne en yakın olan vektörün (kazanan vektör) değerleri (ağın bu vektöre ait ağırlıkları) değiştirilir. Diğer ağlarda

olduğu gibi LVQ ağında da ağın ağırlıkları öğrenme katsayısına göre değiştirilmektedir. Kullanılan öğrenme katsayısının zaman içerisinde sıfır olacak şekilde monoton olarak azaltılması istenmektedir. LVQ ağının öğrenme hızı da çok katmanlı algılayıcılara göre daha yüksektir. Yani LVQ ağları bir olayı Çok katmanlı algılayıcılara göre daha kısa zamanda öğrenebilmektedir (Öztemel, 2012).



Şekil 3.12. LVQ Ağı

Şekil 3.12.'de görüldüğü gibi LVQ ağında bir girdi, bir çıktı ve kohonen katmanı denilen bir ara katman mevcut olup giriş katmanındaki tüm nöronlar ara katmanlardaki tüm nöronlarla bağlantılı bir yapı sergilemektedir. Girdi katmanında bilgi işleme olmaz. Dış dünyadan alınan örneklerin ağa gösterilmesi girdi katmanında sağlanmaktadır. Gelen bilgiler girdi vektörünü oluşturur. Kohonen katmanında girdi setine en yakın olan ağırlık vektörü belirlenmektedir. Bu katmandaki her eleman bir referans vektörünü göstermektedir. Girdi vektörü, girdi katmanı ile Kohonen katmanı arasındaki ağırlıkların oluşturduğu referans vektörlerine haritalanmaktadır. Çıktı katmanı olan son katmanda ise girdilerin ait olduğu sınıfların belirlenmesi işlemi gerçekleştirilir.

LVQ ağları, girdi ve Kohonen katmanları arasında tam bağlantı, Kohonen ve çıktı katmanları arasında ise kısmi bağlantılı olmaktadır. Yani girdi katmanındaki her işlemci eleman Kohonen katmanındaki tüm işlemci elemanlarla bağlantılıdır. Kohonen katmanındaki işlemci elemanlar ise çıktı katmanındaki bir tek işlemci elemanla bağlantılıdır. Kohonen katmanı ile çıktı katmanı arasındaki ağırlıklar sabit olup 1'e eşittir ve bu ağırlıklar değişmez. Sadece girdi katmanı ile Kohonen katmanı arasındaki ağırlıklar değiştirilir. Öğrenme bu ağırlıklar üzerinden gerçekleştirilir.

Kohonen katmanında kaç tane proses elemanı var ise o kadar referans vektörü oluşacaktır. Referans vektörü girdi değerlerini Kohonen katmanındaki proses elemanlarına bağlayan bağlantıların ağırlık değerlerinden oluşur. Dolayısıyla referans vektörünün eleman sayısı girdi katmanındaki eleman sayısı kadardır.

Kohonen ve çıktı katmanlarındaki proses elemanlarının çıktıları ikili (binary) değerler olup sadece bir proses elemanının çıktısı 1 diğerlerininki ise 0'dır. Kohonen katmanında proses elemanları birbirleriyle yarışırlar. Yarışı kazanan proses elemanının çıktısı 1 değerini alır. Diğerlerinin çıktısı ise 0 olur. Hangi proses elemanının yarışı kazandığına öğrenme kuralına göre karar verilir. Kohonen katmanında hangi proses elemanının çıktısı 1 olursa onun bağlı olduğu çıktı katmanındaki proses elemanının çıktısı 1 değerini alır. Diğerlerinin çıktısı da 0 olur. Böylece ağa sunulan bir girdi için çıktı katmanında sadece bir proses elemanının 1 olmakta ve girdi vektörü o çıktının gösterdiği sınıfın üyesi kabul edilmektedir. Öğrenme ile girdi için doğru sınıfın belirlenmesi sağlanmaktadır.

LVQ ağında kazanan işlemci eleman için iki durum söz konusudur. İlk durumda, kazanan işlemci eleman doğru sınıfın üyesidir. Bu durumda ilgili ağırlıklar girdi vektörüne biraz daha yaklaştırılmaktadır. Bu, aynı örnek ağa tekrar gösterildiğinde yine aynı işlemci elemanın kazanması için yapılır. Bu durumda ağırlıkların değiştirilmesi gerçekleştirilir. Öğrenme katsayısı zaman içinde 0 değerini alacak şekilde monoton olarak azaltılır. Bunun nedeni, girdi vektörünün referans vektörüne çok yaklaştığında durması ve aksi yönde tekrar uzaklaşmamasıdır. Aksi takdirde ters yönde tekrar uzaklaşma meydana gelecektir. İkinci durumda ise, kazanan işlemci eleman yanlış sınıftandır. Bu durumda ağırlık vektörü girdi vektöründen uzaklaştırılmalıdır. Bunun amacı, bir daha aynı örnek geldiğinde aynı işlemci elemanın kazanmamasıdır. Bu durumda ağırlıklar değiştirilir. Öğrenme katsayısının zaman içinde azalması burada da geçerli olmaktadır (Bayır, 2006).

LVQ modelinin bazı dezavantajları bulunmaktadır. Bunlardan ilki öğrenme katsayısının zamanında 0 değerini almaması durumunda ağın doğru ağırlık değerlerinden uzaklaşmasıdır. Ayrıca bazı problemlerde sürekli aynı referans vektörü yarışmayı kazanmakta olduğundan ağın esnekliği ortadan kalkmaktadır. Diğer dezavantaj ise sınıflandırmayı yaparken iki sınıfın tam ortasında veya sınırlara çok

yakın bulunan vektörlerin hangi sınıfa gireceklerinin belirlenememesidir. Bu sorunları ortadan kaldırmak için LVQ2, ceza mekanizmalı LVQ ve LVQ-X modelleri geliştirilmiştir.

LVQ2 ağı yine Kohonen tarafından geliştirilmiştir. LVQ2, standart LVQ modelinin uygulanması sonucunda elde edilen çözümün iyileştirilmesi amacı ile geliştirilmiştir. Özellikle sınıfların sınır değerlerindeki yanlış sınıflandırmaları önlemeye çalışır. Standart LVQ'nun aksine LVQ2 ağı eğitim sırasında aynı anda iki referans vektörünün ağırlıklarını değiştirmeyi önermektedir. Bu iki vektörün ağırlıklarının değiştirilmesi için iki koşulun sağlanması gerekmektedir:

1. Girdi vektörüne en yakın iki vektörden birincisi (en yakın olan) yanlış, ikincisi doğru sınıftadır.

2. Girdi vektörü, bu iki vektörün arasında merkezi olarak belirlenmiş bir aralık içerisinde kalmaktadır.

Bir problemi LVQ ağı kullanarak bilgisayara öğretmek için o problemin öncelikle standart LVQ ağı kullanarak eğitmekte, ondan sonra LVQ2 ağını kullanarak eğitime devam etmekte fayda vardır. Standart LVQ, sınıfları belirlemekte, LVQ2 ise sınırlarda buluna vektörleri doğru sınıflara ayırmak için sınıfların sınırlarını güncellemektedir. LVQ2 ağının LVQ ağı ile birlikte kullanılması öğrenmenin hızını ve performansını arttırabilmektedir (Öztemel, 2012).

Cezalandırma Mekanizmalı LVQ Ağı, Standart LVQ modelinde bazı ağırlık vektörleri çok sık üst üste kazanmakta ve bu da ağın esnekliğini bozmaktadır. Diğer ağırlık vektörleri referans olma niteliklerini kaybetmektedirler. Belirlenen her ağırlık vektörü girdinin bir yönünü göstermesi gerekirken sadece bir tanesi bütün sorumluluğu üstlenmektedir. Bu problemden kurtulmak için 1988 yılında DeSieno tarafından ceza mekanizmalı LVQ modeli geliştirilmiştir. Bu modelde ağın eğitimi sırasında sürekli kazanan ağırlık vektörü cezalandırılmakta ve sürekli peş peşe kazanması önlenmektedir. Sürekli kazanan vektöre kaç defa kazandığı ile ilgili olarak uzaklığına bir değer eklenir, yani uzaklaştırılır. Bu sayede diğer vektörlere de kazanma şansı tanınmaktadır. Bu cezalandırma mekanizmasının özellikle ağın ezberlemesini önlediği söylenebilir (Öztemel, 2012).

LVQ-X ağının öğrenme kuralına göre eğitim sırasında her iterasyonda çoğunlukla iki ağırlık vektörünün ağırlıkları değiştirilmektedir. Bu, hem öğrenme hızını arttırmakta ve öğrenme zamanını kısaltmakta hem de ağın genelleme yeteneğini arttırmaktadır. LVQ-X ağının öğrenme kuralı Öztemel tarafından geliştirilmiş olup her iterasyonda yarışmayı kazanan iki tane proses elemanı belirlemektedir. *Global kazanan*, girdi vektörüne en yakın ağırlık vektörüne sahip olan proses elemanıdır. *Yerel kazanan* ise doğru sınıf içerisinden girdi vektörüne en yakın olan ağırlık vektörüne sahip proses elemanıdır. Eğer global kazanan proses elemanı doğru sınıf içerisinde değil ise onun ağırlık vektörü o girdi vektöründen uzaklaştırılır. Aynı zamanda doğru sınıf içindeki en yakın olan proses elemanının (yerel kazanan) ağırlık vektörü de girdi vektörüne yaklaştırılır. Bu doğru proses elemanın daha sonraki iterasyonlarda kazanmasına şans vermektedir. Eğer global kazanan ve yerel kazanan aynı proses elemanı ise o zaman sadece tek bir ağırlık vektörü değiştirilmekte ve kazanan proses elemanının ağırlık vektörü girdi vektörüne yaklaştırılmaktadır (Öztemel, 2012).

LVQ ağları genel olarak sınıflandırma yapmak amacı ile geliştirilmişlerdir. Örüntü tanıma ve birbirinden farklı şekilleri sınıflandırmak, birbirinden farklı nesneleri tanımak gibi konularda mühendislik bilimleri başta olmak üzere hayatın her alanında uygulamalarını görmek mümkündür. Çok hızlı sonuç üretiyor olmaları ve performanslarının çok yüksek olması diğer ağlara göre bu ağları tercih sebebi olmaktadır (Öztemel, 2012).

2. ART Ağları

ART ağları Grossberg'in 1976 yılında biyolojik beynin fonksiyonlarına yönelik olarak yaptığı çalışmalar neticesinde ortaya çıkmıştır. Bu modelin 3 temel özelliği vardır. Bunlar:

1. Normalizasyon: Bu, özellikle biyolojik sistemlerin çevredeki büyük değişikliklere karşı adaptif olduklarını göstermektedir. Örneğin insanın çok fazla gürültülü bir ortamda bir süre sonra gürültüden rahatsız olmaması sisteme adapte olunduğunu ve çevredeki olayların normalize edildiğini göstermektedir. Tren yoluna yakın yaşayan insanların gürültü anlayışlarında tren sesi gürültü sayılmamaktadır.

Günde defalarca geçen tren kimseyi rahatsız etmez iken başka küçük bir gürültü herkesin dikkatini çekebilmektedir. Bazı insanlar tren yoluna yakın yaşayanların sese karşı duyarsızlıklarını anlamakta güçlük çekmektedirler. Hâlbuki bu insanların da bazıları minibüs yoluna yakın yerde oturmakta ve korna sesinden etkilenmemektedirler.

2. Ayrıştırabilme: İnsanın karar verebilmesinde ve olayları yorumlayabilmesinde çevredeki olaylar arasında var olan fakat görülmesi zor farklılıkları ayrıştırmak çok önemlidir. Bazen küçük ayrıntılar hayati öneme sahip olabilir. Uyuyan bir aslan ile saldırıya hazır bir aslanın fark edilmesinin önemi açık olarak ortadadır. Yatan bir aslanın vücudunun hareketlerinin fark edilmesi çok önemli bir tehlikeyi önleyebilir. Biyolojik sistemlerin böyle ayrıntıları fark etmeleri çok önemli bir özellikleridir.

3. Ayrıntıların Saklandığı kısa dönemli hafıza: Belirlenen farklılıklar ve çevresel olaylar davranışlara neden olmadan önce hafızada saklanmakta ve daha sonra eyleme dönüşmektedir. Bu uzun dönemli hafızada değişikliklere neden olmaktadır. Hafızadaki her olay uzun süre etkili olmamakla beraber sürekli aynı şeyleri tekrar etmek sonucu olaylar unutulmaz hale gelebilmektedir. Fakat uzun karar vermede uzun dönemli hafızadaki bilgiler daha etkili olmaktadır. Anlık kararlar bazen olumsuz sonuçlar doğurmaktadır.

Grossberg, bu özelliklerden yola çıkarak arkadaşları ile Adaptif Rezonans Teorisi Ağı (ART) adını verdiği Yapay Sinir Ağları setini oluşturmuştur. ART ağları daha sonra geliştirilen öğretmensiz öğrenme ağlarının geliştirilmesine de temel olmuştur. ART ağları da LVQ ağları gibi sınıflandırma problemleri için geliştirilmiştir. LVQ ağlarından farkı ise yapılacak olan sınıflandırma ile ilgili olarak ağa herhangi bir bilginin verilmeyişidir. ART ağları sınıflandırmayı kendi başlarına yapmaktadırlar (Öztemel, 2012). ART, adını öğrenme ve hatırlama arasındaki karşılıklı etkileşimi gerçekleştiren yöntemden yani rezonanstan almıştır. ART Yapay Sinir Ağlarında işlemci elemanların çıktıları katmanlar arasında sürekli olarak ileri geri hareket etmektedir. Bu esnada eğer örnek girdi belirlenmiş bir sınıfa uyuyorsa ağ kararlı hale gelmekte ve ART ağı rezonanstadır denilmektedir.

ART ağları gerçek zamanlı olarak oldukça hızlı ve kararlı bir şekilde öğrenme yeteneklerine sahiptirler. ART ağları bu özellikleri gerçek zamanlı kullanılabilen donanımla da desteklenerek gerçek zamanlı öğrenebilen bilgisayarların oluşmasına yardımcı olmaktadır. Gerçek zamanda ortam, genel olarak durağan değildir. Olayların oluşumu her an beklenmedik olaylar ile değişebilmektedir. Bununda ötesinde gerçek zamanlı olaylar sürekli devam etmektedir. ART ağları, bu durağan olmayan dünyada sınırsız karmaşıklık altında çalışabilme yeteneğine sahiptirler. Diğer ağların çoğu ise durağan olarak çevrimdışı *(off-line*) öğrenip çalışırlar. Esneklikleri yoktur. Ortama anında uyum sağlamaları çok sınırlıdır. ART ağları beklenen çıktıları bir öğretmenden almak yerine kendi kendine öğrenmeye çalışır. ART ağları çevredeki olayları sürekli öğrenmeye devam eder. Uzun dönemli hafızada bulunan ağırlıklar sürekli olarak gelen girdi değerlerine göre değişmeye devam ederler. ART ağları girdi değerlerini otomatik olarak normalize ederler. Çok fazla ve oldukça düşük orandaki gürültülerin girdi işaretindeki etkileri ortadan kaldırılmış olur.

1976 yılından bugüne kadar değişik ART ağları tanımlanmıştır. Bunlar arasında ART1, ART2, ART3, ARTMAP, Fuzzy ART gibi ağları saymak mümkündür. Bu ağların hepsi aslında aynı temel felsefeye dayanmaktadır. Bir takım farklılıklar bulunmakla beraber bunlar içerisinde en yaygın olarak kullanılan ağlar, ART1 Ve ART2 ağlarıdır.

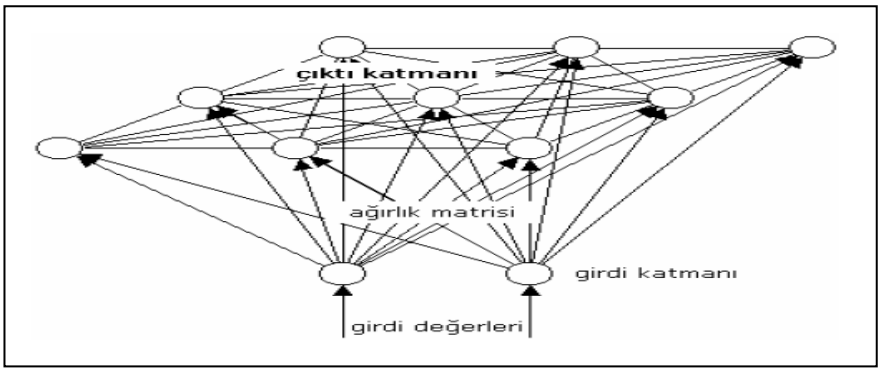
ART1 ağı sadece ikili (binary) girdiler ile çalışan ve en basit ART ağının örneğidir. Geliştirilen ilk ART ağı da denilebilir. ART2 modeli, 1986 ve 1987 yıllarında Carpenter ve Grossberg tarafından geliştirilmiştir. ART1 algoritmasının geliştirilmiş halidir. ART2 ağı hem ikili hem de sürekli girdi değerleri ile çalışabilme yeteneğine sahiptir (Öztemel, 2012).

ART ağlarının bilim dünyasında bu derece önemli olmasının nedenlerinden birisi de, yapısal olarak insan beyninin davranışları ve sinir sistemi hakkında bilinen (veya varsayılan) bulgular üzerine kurulmuş olmalarıdır. Bu ağlar, memeli hayvanların beyinlerinin çalışma prensipleri dikkate alınarak geliştirilmiştir. Beynin kullandığı sezgisel yaklaşımları matematik bir modele dönüştürmelerinden dolayı da bu ağlar oldukça yoğun ilgi görmüştür (Bayır, 2006).

3. Kohonen Ağı

SOM (Self Organization FeatureMap Network – Özörgütlemeli Özellik Haritası) olarak da adlandırılan Kohonen ağı, beynin Neocortex katmanında yaygın olan duyusal haritalardan esinlenilerek 1972 yılında Kohonen tarafından geliştirilmiştir. Genel olarak sınıflandırma yapmak için kullanılmaktadır. Bu ağların girdi vektörlerini sınıflandırmak ve girdi vektörlerinin dağılımını öğrenebilme yetenekleri çok yüksektir. Bu ağların en temel özelliği olayları öğrenmek için bir öğretmen veya ağın üretmesi gereken çıktıların ağa söylenme zorunluluğunun olmamasıdır. Özellikle beklenen çıktıların belirlenemediği problemler için kullanılmaktadır. Yapısal olarak da bu ağlar diğerlerinden farklıdır. Şekil 3.13.'te görüldüğü gibi ağ, girdi ve çıktı katmanından oluşmaktadır. Çıktı katmanı 2 boyutlu bir düzlemi göstermektedir. Proses elemanları bu düzlem üzerine dağılmış vektörleri gösterirler. SOM ağları yarışmayı kazanma ve kazanan elemanın 1 diğerlerinin 0 değerini alması ilkesine dayanmaktadır. Bir girdi verildiğinde çıktı uzayında yarışmayı kazanan ve onun etrafındaki komşuları eğitim sırasında ağırlıklarını değiştirmektedir.

Kohonen ağları, ses ve yazı tanıma, eş zamanlı çeviri gibi işlemlerde oldukça başarılıdır. Renk, desen ayırımını yapabilir ve görünen, hareket eden nesneleri ayrıştırabilirler. Bu özellikleri sayesinde robotik sistemlerde ve sensör uygulamalarında da kullanılmaktadır (Bayır, 2006).



Şekil 3.13. Kohonen Ağı

4. Hopfield Ağı

Hopfield ağı modeli 1982 yılında bi fizikçi olan John Hopfield tarafından geliştirilmiştir. Hopfield ağı, beyine benzer bir şekilde belirli hafızaları veya örüntüleri depolayan basit bir sinir ağıdır. Basit yapısı ve matematiksel tutarlılığı nedeniyle Yapay Sinir Ağları çalışmalarında önemli yeri olan ve tercih edilen bir modeldir. Her probleme uygulanamamasına rağmen daha karmaşık modelleri anlamak için giriş bilgisi sağlamaktadır (Bayır, 2006).

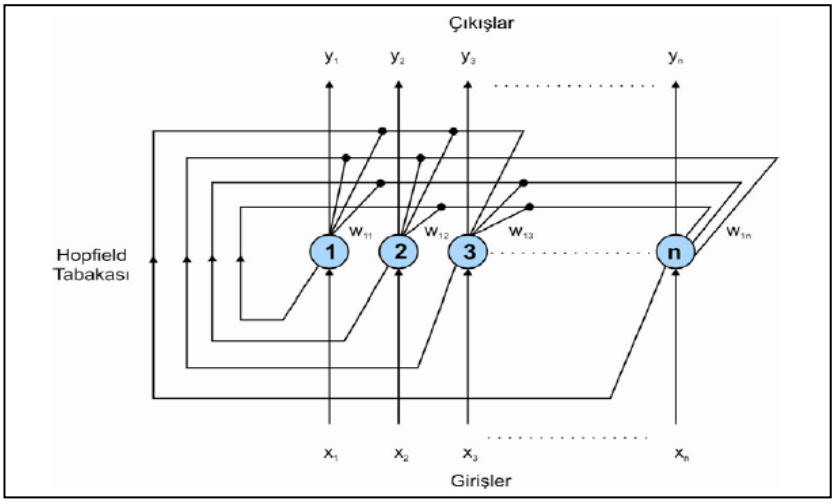
Hopfield ağı tek katmanlı ve geri beslemeli bir YSA'dır ve genellikle ikili (0 ve 1) ve çift kutuplu (-1 veya +) girişleri kabul etmektedir. Şekil 3.14.'te görüldüğü üzere Hopfield ağında işlemci elemanlar, birbirleriyle tam bağlantı halindedir ve hem girdi hem de çıktı elemanlarıdır. Bağlantılar çift yönlüdür (bilgi her iki yönde de akmaktadır) ve simetriktir. Ağın bağlantı değerleri bir enerji fonksiyonu olarak saklanır. Her iki yönde akan bilgiye uygulanan ve her bağlantı için hesaplanan bir ağırlık değeri vardır (Baş, 2006).

Her işlemci eleman diğer işlemci elemanlardan gelen girdilerin toplamını bir eşik değeri ile karşılaştırmakta ve diğer işlemci elemanlara çıktı olarak iletmektedir. Hopfield ağında örnek örüntü seçilmekte ve ağın ağırlıklarının başlangıç değerlerini saptamak için kullanılmaktadır. Bu bir kere yapıldıktan sonra herhangi bir örüntü ağa sunulmakta ve bu da giriş örüntüsüne en çok benzeyen örüntülerden biriyle sonuçlandırılmaktadır. Çıktı örüntüsü, birimlerin durumlarına bakılarak ağdan okunabilmektedir. Hopfield ağında ağırlık değerleri değişmemektedir.

Hopfield ağı, çıktı değerlerinin kesikli ve sürekli oluşlarına göre ikiye ayrılır. Bu nedenle kesikli ve sürekli olmak üzere iki tür Hopfield ağından söz edilebilir. Kesikli ve sürekli Hopfield ağlarının çalışma biçimleri aynıdır ancak kullanılan aktivasyon fonksiyonları farklıdır. Kesikli Hopfield ağları aktivasyon fonksiyonu olarak signum fonksiyonunu kullanırken Sürekli Hopfield ağları sigmoid fonksiyonunu kullanmaktadır (Baş, 2006).

Hopfield ağlarının ana kullanım amacı ilişkili hafızadır. Bunun yanında Hopfield ağları optimizasyon problemlerinde ve veri ilişkilendirmede yaygın olarak kullanılmaktadır. Hopfield ağlarının en önemli uygulamalarından biri, çözümü çok

zor olan gezgin satıcı problemidir. Bu problemde bir satıcı N adet şehre gitmek zorundadır. Bir şehre bir defa uğramak koşulu ile en kısa zamanda bütün şehirleri gezebilmesi için izlemesi gereken rotanın bulunması istenmektedir.

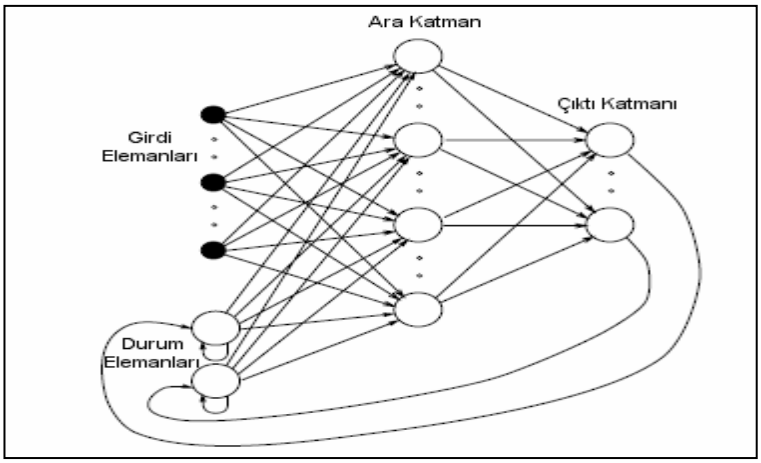


Şekil 3.14. Hopfield Ağı

5. Jordan Ağı

Jordan ağı, çok katmanlı geri beslemeli (yinelemeli) bir Yapay Sinir Ağıdır. İlk yinelemeli ağlardan biridir. Şekil 3.15.'te görüldüğü gibi çok katmanlı algılayıcılara benzer bir yapıda olan Jordan ağlarında, girdi, çıktı ve gizli elemanlara ek olarak durum elemanları (State Units) adı verilen özel işlemci elemanlar bulunmaktadır. Durum elemanları, çıktı katmanından aldıkları aktivasyon değerlerini bir sonraki iterasyona girdi olarak taşımakla görevli elemanlardır. İstenildiği kadar durum elemanı olabilir. Durum katmanındaki her işlemci elemanın kendisine bağlantısı bulunmaktadır. Durum elemanları ile çıktı elemanları arasındaki bağlantıların ağırlık değerleri sabittir ve +1 değerindedir. Dolayısı ile öğrenme, girdi katmanı ile gizli katman arasındaki ve gizli katman ile çıktı katmanı arasındaki bağlantılardan oluşmaktadır (Bayır, 2006).

Ara katman elemanlarının en önemli özelliği bu ağda hem doğrusal hem de doğrusal olmayan aktivasyon fonksiyonuna sahip olabilmeleridir. Öğrenme kuralı olarak çok katmanlı perceptron ağlarının kullandığı öğrenme kuralları bu ağda da kullanılabilir (Küçükönder, 2011).



Şekil 3.15. Jordan Ağı

6. Elman Ağı

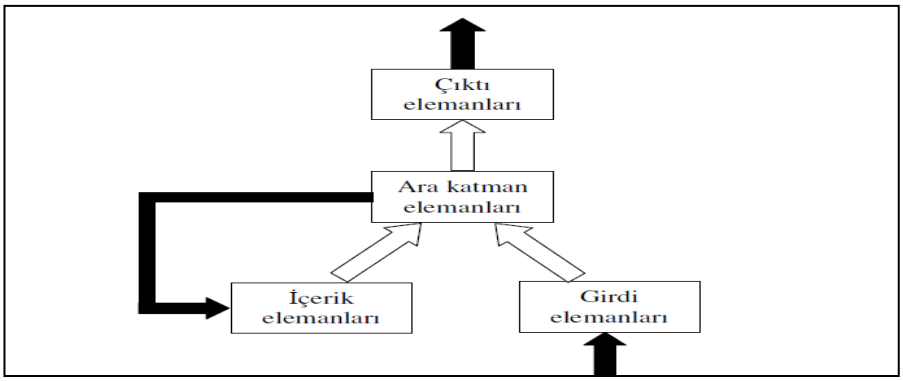
Elman ağı da, Jordan ağı gibi girdi katmanı, çıktı katmanı ve ara katmanlara ilaveten içerik katmanına sahip olan bir sinir ağı olup, bu ağ 1990 yılında Elman tarafından geliştirilmiştir. Bunlardan girdi ve çıktı elemanları dış dünya ile etkileşim halindedir. Girdi elemanları dış dünyadan bilgileri alır ara katmanlara iletirler. Çok katmanlı algılayıcılarda olduğu gibi Elman ağında da girdi elemanlarının bilgi işleme özellikleri yoktur. Şekil 3.16.'da görüldüğü gibi girdileri olduğu gibi ara katman elemanlarına gönderirler. Çıktı elemanları ise ağın çıktısını dış dünyaya iletirler. Çıktı ünitelerinin bilgi işleme fonksiyonları doğrusaldır. Sadece kendilerine gelen bilgileri toplarlar. Ara katman elemanları ise hem doğrusal hem de doğrusal olmayan aktivasyon fonksiyonlarına sahip olabilirler. İçerik elemanları, ara katman elemanlarının önceki aktivite değerlerini hatırlamak için kullanılmaktadır. Bu elemanlar bir adım gecikmeyi içermektedirler. Bir önceki iterasyondaki aktivasyon değerlerini bir sonraki iterasyona girdi olarak taşırlar. Geri dönüşümlerin ağırlıkları sabit olduklarından Elman ağına kısmi geri dönüşümlü ağ denilebilir.

Başlangıçta ara katmanların aktivasyon değerleri bilinmediğinden içerik elemanlarının başlangıç değerlerinin belirlenmesi gerekir. Bunun için genel olarak bir ara katmanın alabileceği maksimum değerin yarısı içerik elemanlarının başlangıç girdi değerleri olarak atanır. Eğer sigmoid fonksiyonu kullanılacak ise genellikle bu

elemanlar başlangıçta girdi olarak 0.5 değerini alırlar. Hiperbolik tanjant fonksiyonu için ise 0 değeri başlangıç girdi değerleri olarak atanmaktadır (Öztemel, 2012).

Elman ağı, Jordan ağına oldukça benzer olmakla beraber aralarında iki önemli farklılık bulunmaktadır. Bu farklılıklardan ilki, geri besleme yaptıkları aktivasyon değerlerini çıktı katmanından almak yerine ara katmandan almaları, ikincisi ise içerik elemanlarının kendilerine bağlantı durumlarının olmamasıdır (Küçükönder, 2011).

Ağın ağırlıklarını değiştirirken geri besleme bağlantı ağırlıklarının dikkate alınmaması ve içerik elemanlarının girdi elemanları olarak düşünülmesi durumunda Elman ağı çok katmanlı algılayıcı ile aynı olur.



Şekil 3.16. Elman Ağı

3.2.8.16. YSA'da Verilerin Normalizasyonu

YSA'da girdi ve hedef veriler nadiren ham olarak kullanılır. Hataların azaltılması, önemli ilişkilerin ve eğilimlerin belirlenmesi ile Yapay Sinir Ağının kalıpları öğrenebilmesi amacıyla değişkenlere ait dağılımların düzleştirilmesi için ağa sunulmadan önce verilerin normalleştirme işlemi yapılır (Polat, 2009). YSA'nın doğrusal olmama özelliğinden dolayı verilerin normalize edilmesi ağın başarılı sonuçlar üretmesi açısından oldukça önemlidir. Normalizasyon işlemi sırasında, ağın başarı performansını etkileyen verilerin birikimli (kümülatif) toplamlarının oluşturacağı etkinin ortadan kaldırılması gerekmektedir. Bu nedenle, normalizasyon işleminde kullanılan işlemci elemanlar, verileri birikimli toplamlarla koruma özelliğine sahiptir. Bu özellikleriyle aşırı değerlenmiş toplamların yaratacağı olumsuz etkileri de elimine etmiş olurlar (Küçükönder, 2011).

Veri normalleştirmenin genel olarak faydalı olduğu yapılan çalışmalarda görülmekle beraber, ağ ve örneklem büyüklüğü arttıkça faydanın azaldığı ve genellikle öğrenme sürecini yavaşlattığı ifade edilmektedir. Hedef veriler genellikle girdi verilerinden bağımsız olarak normalleştirilir. Ancak, zaman serilerinin öngörü hesaplamalarında hedef veriler, girdi verileri ile beraber ve çoğunlukla çıktı nöronlarının aktivasyon fonksiyonuna göre normalleştirilir. Çıktı nöronlarında yer alan aktivasyon fonksiyonu, lojistik fonksiyon ise [0,1] hiperbolik tanjant fonksiyonu ise [-1,1] aralığında normalleştirme yapılır. Ağdan elde edilen sonuçları yorumlamak ve performans ölçümlerinin yapılması için çıktıların orijinal aralığa yeniden dönüştürülmesi gerekir (Polat, 2009).

Kullanılacak verinin türüne göre birçok farklı normalizasyon tekniği geliştirilebilir veya sıklıkla kullanılan birçok hazır normalizasyon tekniğinden biri seçilebilir. Konuya zaman serisi analizi yönünden bakıldığında; kullanılacak normalizasyon tekniğinin, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi deformasyona uğratmaması, analizin doğruluğu, etkinliği ve geri yayılma ağının performansı açısından çok önemlidir (Çelik, 2008).

Zaman serisi analizi için geliştirilen iki adet normalizasyon tekniği bulunmaktadır. Birincisi *basit normalizasyon* tekniğidir. Bu normalizasyon tekniği, zaman serisi analizinde kullanılacak olan tüm değişkenleri veri setinde negatif değerler olması durumunda (-1,1), tersi durumda ise (0,1) aralığına sıkıştırmaktadır. İkincisi ise *sıfır toplamlı normalizasyon* tekniğidir. Bu teknik, veri setindeki tüm verileri (negatif değer içerip içermemesinden bağımsız olarak) (-1,1) aralığına sıkıştırmaktadır (Çelik, 2008). Çizelge 3.22.'de bazı normalizasyon yöntemleri, sayı aralıkları ve formülleri ile birlikte gösterilmiştir.

Çizelge 3.22. Veri Normalizasyon Türleri

Veri Normalizasyonu	Normalleştirme Formülleri
[0,1] aralığına doğrusal dönüşüm	$X_n = \frac{X_0 - X_{\min}}{X_{maks} - X_{\min}}$

Çizelge 3.22. **(devam)**

[a,b] aralığına doğrusal dönüşüm	$X_n = (b-a)\frac{X_0 - X_{\min}}{X_{maks} - X_{\min}} + a$
Basit Normalizasyon	$X_n = \frac{X_0}{X_{maks}}$
İstatistiksel Normalizasyon	$X_n = \frac{X_0 - \bar{X}}{s}$

3.2.8.17. YSA'nın Eğitimi ve Testi

İşlem elemanlarının bağlantı ağırlık değerlerinin belirlenmesi için yapılan işlemlere ağın eğitimi denir. Yapay Sinir Ağlarının tahmin edicisi tasarlanırken eğitim ve test verisi olmak üzere veri seti iki parçaya ayrıştırılır. Bu veri setlerinin ayırımı için de daha önceden belirlenmiş belli bir kriter mevcut olmamakla beraber çözüme ulaştırılmak istenen problemin karakteristik yapısı, veri tipi ve elde mevcut olan veri sayısı, bu ayırımı yaparken araştırıcıların göz önünde bulundurması gereken önemli noktalardır. Veri sayısının % 90'ının eğitim veri seti, % 10'unun da test veri seti olarak kullanılması tavsiye edilirken bu oranlar % 80 eğitim verisi, % 20'si test verisi ve % 70'i eğitim verisi, % 30'unun da test verisi olarak da ayrışımın yapılabileceği yönünde tavsiyeler de mevcuttur.

Eğitim veri seti, YSA modellerini geliştirmek amaçlı kullanılırken, test veri seti de geliştirilen modelin tahmin yeteneğinin belirlenmesine yönelik olarak kullanılmaktadır. Öğrenme sırasında, öğrenmeyi ifade etmekte olan ağırlıkların değişimi söz konusu olup bu değişiklikler öğrenme yaklaşımına göre yapılmaktadır. Başlangıçta bu ağırlık değerleri rastgele olarak atanırken, ağırlık değişimi bir noktadan sonra sabitlenip değişmiyor ise o zaman öğrenme işleminin durması olayı gerçekleşmiş olmaktadır (Küçükönder, 2011).

YSA'da kullanılan belli başlı öğrenme algoritmaları Çizelge 3.23.'te belirtilmiştir. (Anonim, 2015a)

Çizelge 3.23. YSA'da Kullanılan Öğrenme Algoritmaları

ÖĞRENME ALGORİTMALARI	MATLAB Kodu
Gradient Descent (GD)	Traingd
Gradient Descent with Momentum (GDM)	Traingdm
Gradient Descent with Adaptive (GDA)	Traingda
Gradient Descent with Adaptive and Momentum (GDX)	Traingdx
Resilient Backpropagation	Trainrp
Conjugate gradient backpropagation with Fletcher-Reeves updates (CGF)	Traincgf
Conjugate gradient backpropagation with Powell-Beale restarts (CGB)	Traincgb
Conjugate gradient backpropagation with Polak-Ribiére updates (CGP)	Traincgp
Scaled conjugate gradient backpropagation (SCG)	Trainscg
BFGS quasi-Newton backpropagation (BFGS)	Trainbfg
One-step secant backpropagation (OSS)	Trainoss
Levenberg-Marquardt backpropagation (LM)	Trainlm
Bayesian regulation backpropagation (BR)	Trainbr

3.2.8.18. YSA Mimarisinin Tasarımı

Girdi nöron sayısı, gizli nöron sayısı, çıktı nöron sayısı, gizli katman sayısı aktivasyon fonksiyonu gibi faktörler, YSA mimarisinin belirlenmesinde önemli bir yer tutmaktadır. Bunun yanında öğrenme ve momentum katsayısının seçimi de problemin çözümünde ve en iyi sonucun alınmasına yardımcı olmaktadır.

1. Girdi Nöron Sayısı

Girdi nöron sayısı, girdi vektöründeki değişkenlerin sayısına tekabül etmektedir. YSA'da kullanılacak girdi sayısının belirlenmesi için izlenen belirli bir kural yoktur. Öngörüsü yapılacak zaman serisinin içerisinde saklı bilgi ve kalıbı ortaya çıkarabilecek yeterli sayıda girdi değişkeni kullanılmalıdır. Bazı durumlarda kullanılan girdi sayısının arttırılması ağın öngörü performansını arttırmadığı gibi, girdi sayısının yeterli olmaması ağın öğrenmesini ve dolayısıyla öngörü performansını kötü etkileyebilir (Polat, 2009).

Sebep-sonuç ilişkisine dayanan bir tahmin probleminde girdi nöron sayısının belirlenmesi çok kolaydır. Probleme ilişkin bağımsız değişken sayısı girdi nöronu

sayısını verecektir. Ancak bir zaman serisi tahmin probleminde uygun girdi nöronu sayısını belirlemek kolay değildir. Girdi nöron sayısı, seri değerinin geçmiş gözlem değerleri ile olan ilişkisini gösterir. Bu ilişkinin kaç dönem geçmiş değeri kapsayacağının belirlenmesi oldukça önemlidir (Hamzaçebi, 2011). Başka bir deyişle, zaman serisi kestirim problemlerinde, girdi nöron sayısı, gecikme sayısı ile ilişkilidir. Ancak bu sayıyı belirlemede önerilen herhangi bir kesin yol yoktur (Biçen, 2006).

2. Gizli Nöron Sayısı

Gizli katmanlardaki nöron sayısının tespitinde sabit bir kural yoktur. Az sayıda gizli nöronun kullanılması, genelleştirme kabiliyetinin artmasını ve ezberleme probleminin azalmasını sağladığı için daha çok tercih edilir. Ancak çok az sayıda gizli nöron kullanmak da ağın öğrenmesi için yeterli olmayabilir. Çok sayıda gizli nöron kullanımı ise ağın genelleştirmeden çok ezberleme kabiliyeti kazanmasına yol açar (Polat, 2009). En uygun gizli nöron sayısını belirlemek için deney tasarımı yapılabilir ya da az sayıda gizli nöron ile başlayıp doğrulama kümesi için ağın performansı bozuluncaya kadar gizli nöron sayısı arttırılır (Hamzaçebi, 2011).

3. Gizli Katman Sayısı

Çok katmanlı ağ optimizasyonunda bir diğer önemli faktör gizli katman sayısıdır. Tek gizli katmanlı çok katmanlı ağ problemleri çözmede başarılıdır. Ancak bazen çok karmaşık bir yapıyı barındıran verilerle çalışırken iki gizli katmana ihtiyaç duyulabilir. Gizli katman sayısının arttırılması, hesaplama zamanını artırmakta ayrıca ağın öğrenme yerine ezberlemesine sebep olabilmektedir (Hamzaçebi, 2011).

4. Çıktı Nöron Sayısı

Çıktı nöron sayısını hesaplamak kolaydır ve çalışılan probleme direkt bağlıdır. Sebep-sonuç ilişkisine dayalı tahmin problemlerinde çıktı nöronu sayısı bağımlı değişken sayısına eşit alınabilir. Zaman serisi analizine dayalı tahmin probleminde çıktı nöronu sayısı, tahmin döneminin uzunluğuna eşittir. Çok dönemli tahmin ise iki yolla yapılabilir. Birincisi, Box-Jenkins modelindeki gibi ötelemeli (iteratif) tahmindir. Tahmin edilen dönem değeri, bir sonraki dönem için girdi olarak

kullanılır. Bu durumda yine sadece tek çıktı nöronu yeterlidir. İkincisi ise, birden fazla dönemin aynı anda tahmin edildiği direkt metot olarak adlandırılan durumdur. Bu durumda çıktı nöron sayısı, tahmin edilmek istenen dönem sayısına eşit alınır (Hamzaçebi, 2011).

5. Öğrenme ve Momentum Katsayısının Seçilmesi

Öğrenme ve momentum katsayılarının belirlenmesi de ağın öğrenme performansı ile yakından ilgilidir. Öğrenme katsayısı, ağırlıkların değişim miktarını belirlemektedir. Eğer büyük değerler seçilirse o zaman yerel çözümler arasında ağın dolaşması ve osilasyon yaşaması söz konusu olmaktadır. Küçük değerler seçilmesi ise öğrenme zamanını artırmaktadır. Tecrübeler genellikle 0.2-0.4 arasındaki değerlerin kullanıldığını göstermektedir. Fakat bu tamamen ilgili probleme bağlıdır. Bazı uygulamalarda öğrenme katsayısının 0.6 değerini aldığı zaman en başarılı sonuçları verdiği görülmektedir (Öztemel, 2012).

Momentum katsayısı, bir önceki iterasyondaki değişimin belirli bir oranının yeni değişim miktarına eklenmesi olarak görülmektedir. Büyük öğrenme oranlarında salınıma imkân vermemenin bir yolu momentum teriminin eklenmesidir (Bayır, 2006).

Momentum değerinin küçük olması yerel çözümlerden kurtulmayı zorlaştırabilir. Çok büyük değerler ise tek bir çözüme ulaşmada sorunlar yaşanabilir. Tecrübeler bu değerin 0.6 - 0.8 arasında seçilmesinin uygun olacağını göstermektedir (Öztemel, 2012).

3.2.8.19. YSA'nın Performans Kriterleri

Bir Yapay Sinir Ağı tahmin edicisi için araştırıcıların dikkat etmesi gereken hususlardan biri de performans ölçütüdür. Bu ölçüt tahminin doğru bir şekilde yapılıp yapılmadığını gösteren bir ölçüttür. Aynı zamanda ağın performansını ve öğrenme yeteneğinin başarısını gösterir. İleri beslemeli ağlar için yaygın olarak kullanılan performans fonksiyonlarının matematiksel açılımlarını çizelge 3.24.'teki gibi sıralamak mümkündür.

Çizelge 3.24. YSA'da Kullanılan Performans Fonksiyonları ve Matematiksel Açılımları

Performans Fonksiyonları	Matematiksel Açılımı
Hata Kareler Ortalaması (Mean Squared Error-MSE)	$HKO = \frac{1}{n}\sum_{i=1}^{n}(t_i - g_i)^2 = \frac{1}{n}\sum_{i=1}^{n} e_j^2$ t_i : i-inci birimin tahmin değeri, g_i : i-inci birimin gerçek değeri, e_j : Tahmin hatası
Hata Kareler Ortalamasının Kare Kökü (Root Mean Squared Error-RMSE)	$HKOK = \sqrt{\frac{1}{n}}\sqrt{\sum_{i=1}^{n}(t_i - g_i)^2} = \sqrt{\frac{1}{n}}\sqrt{\sum_{i=1}^{n} e_j^2}$ t_i : i-inci birimin tahmin değeri, g_i : i-inci birimin gerçek değeri, e_j : Tahmin hatası
Hata Kareler Toplamı (Sum Squared Error-SSE)	$HKT = \sum_{i=1}^{n}(t_i - g_i)^2 = \sum_{i=1}^{n} e_j^2$ t_i : i-inci birimin tahmin değeri, g_i : i-inci birimin gerçek değeri, e_j : Tahmin hatası
Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percentage Error-MAPE)	$OMHY = \frac{1}{N}\sum_{k=1}^{N}\frac{\lvert g_i - t_i \rvert}{g_i} x100$ t_i : i-inci birimin tahmin değeri, g_i : i-inci birimin gerçek değeri,

Ele alınan bütün istatistiklerde arzu edilen sonuç, en küçük değere sahip MSE, RMSE, SSE ve MAPE istatistiklerine sahip tahmin modelini oluşturmaktır. Ancak hangi istatistiğin kullanılması gerektiği konusunda belirli bazı kriterler takip edilmektedir (Çuhadar, 2006).

Hata değerlerinin büyüklükleri benzer ise, MSE ve RMSE değerleri kullanılabilir. MSE istatistiği, hataların karelerini aldığı için büyük sapmaların olması durumunda abartılı sonuçlar vermektedir. Önraporlama performansları karşılaştırılan modeller, farklı frekanstan ya da farklı büyüklüklere sahip veri

setlerinden elde edilmiş iseler bu durumda MAPE kullanılmalıdır (Özer Arabacı, 2007). MAPE istatistiği, farklı birim değerlere sahip modellerin karşılaştırılmasında ortaya çıkabilecek avantajları elimine etmektedir.

3.2.9. Çoklu Doğrusal Regresyon Modeli

Olabilecek en basit Çoklu Regresyon modeli, bir bağımlı, iki açıklayıcı değişkeni olan üç değişkenli regresyondur (Gujarati,2000). Çoklu Regresyon modeli de basit regresyon modeli gibi, doğrusal veya doğrusal olmayan fonksiyonlarla ifade edilebilir. Değişkenler arasında doğrusal ilişki olduğu varsayımı ile doğrusal fonksiyonla ifade edilen modellere Çoklu Doğrusal Regresyon modelleri adı verilmektedir (Güriş, 2010).

Üç değişkenli anakütle regresyon fonksiyonu aşağıdaki gibi yazılabilir:

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + u_i \tag{3.5}$$

Denklem (3.5)'te Y_i, bağımlı değişken X_2 ile X_3, açıklayıcı (ya da bağımsız) değişkenler; u_i, olasılıklı bozucu terim, i, i'inci gözlemdir.

Yine denklem (3.5)'teki eşitlikte β_1 sabit terimdir. Matematiksel olarak regresyon doğrusunun Y ekseninin kesim noktasını verecektir. Her ne kadar bu, mekanik yorumla X_2 ile X_3 sıfıra eşitlendiğinde Y'nin ortalama değeri anlamına gelse de, modelde bulunmayan bütün değişkenlerin Y üzerindeki ortalama etkisini gösterir. β_2 ile β_2 ise kısmi regresyon katsayıları diye adlandırılır.

Kısmi regresyon katsayısının anlamı şudur: β_2, X_3 sabit tutulurken, X_2'deki bir birimlik değişmeye karşılık Y'nin beklenen değeri olan $E(Y \mid X_2, X_3)$'teki değişmeyi ölçer. Bir başka deyişle, X_3 sabitken $E(Y \mid X_2, X_3)$'ün X_2'ye göre eğimini verir. Değişik biçimde söylersek, X_2'deki bir birimlik değişmenin, Y üzerindeki X_3'ten ayrı "doğrudan" ya da "net" etkisini gösterir. Benzer biçimde β_3 de, X_2 sabit tutulurken, X_3'teki bir birimlik değişmeye karşılık Y'nin ortalama

değerindeki değişmeyi ölçer. Yani, X_3'teki bir birimlik değişmenin, Y üzerindeki, X_2'den ayrı "doğrudan" ya da "net" etkisini verir (Gujarati,2000).

3.2.9.1. Regresyon Katsayılarının EKK Yöntemi ile Tahmin Edilmesi

Üç değişkenli örneklem regresyon fonksiyonu denklem (3.6)'daki gibi yazılır;

$$Y_i = \hat{\beta}_1 + \hat{\beta}_2 X_{2i} + \hat{\beta}_3 X_{3i} + \hat{u}_i \tag{3.6}$$

$$\sum \hat{u}_i^2 = \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \hat{\beta}_3 X_{3i})^2 \tag{3.7}$$

Denklem (3.7) eşitliğinin üç bilinmeyene göre kısmi türevlerini alıp bu türevleri sıfıra eşitlersek Denklem (3.8), (3.9) ve (3.10)'yi elde ederiz;

$$\frac{\partial \sum \hat{u}_i^2}{\partial \hat{\beta}_1} = 2\sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \hat{\beta}_3 X_{3i})(-1) = 0 \tag{3.8}$$

$$\frac{\partial \sum \hat{u}_i^2}{\partial \hat{\beta}_2} = 2\sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \hat{\beta}_3 X_{3i})(-X_{2i}) = 0 \tag{3.9}$$

$$\frac{\partial \sum \hat{u}_i^2}{\partial \hat{\beta}_3} = 2\sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \hat{\beta}_3 X_{3i})(-X_{3i}) = 0 \tag{3.10}$$

Yukarıdaki ifadeleri basitleştirirsek denklem (3.11), (3.12) ve (3.13)'te belirtilen eşitlikleri elde ederiz:

$$\bar{Y} = \hat{\beta}_1 + \hat{\beta}_2 \bar{X}_2 + \hat{\beta}_3 \bar{X}_3 \tag{3.11}$$

$$\sum X_{2i} Y_i = \hat{\beta}_1 \sum X_{2i} + \hat{\beta}_2 \sum X_{2i}^2 + \hat{\beta}_3 \sum X_{2i} X_{3i} \tag{3.12}$$

$$\sum X_{3i} Y_i = \hat{\beta}_1 \sum X_{3i} + \hat{\beta}_2 \sum X_{2i} X_{3i} + \hat{\beta}_3 \sum X_{3i}^2 \tag{3.13}$$

Anakütle sabit terimi β_1'in EKK tahmin edicisi;

$$\hat{\beta}_1 = \bar{Y} - \hat{\beta}_2 \bar{X}_2 - \hat{\beta}_3 \bar{X}_3 \tag{3.14}$$

Denklem (3.14) olduğu gibi bulunur.

Örneklem ortalamasından sapmalar küçük harflerle gösterilirse anakütle kısmi regresyon katsayıları β_2 ile β_3'ün EKK tahmin edicileri denklem (3.15) ve (3.16)'da belirtildiği gibi;

$$\hat{\beta}_2 = \frac{\left(\sum y_i x_{2i}\right)\left(\sum x_{3i}^2\right) - \left(\sum y_i x_{3i}\right)\left(\sum x_{2i} x_{3i}\right)}{\left(\sum x_{2i}^2\right)\left(\sum x_{3i}^2\right) - \left(\sum x_{2i} x_{3i}\right)^2} \tag{3.15}$$

$$\hat{\beta}_3 = \frac{\left(\sum y_i x_{3i}\right)\left(\sum x_{2i}^2\right) - \left(\sum y_i x_{2i}\right)\left(\sum x_{2i} x_{3i}\right)}{\left(\sum x_{2i}^2\right)\left(\sum x_{3i}^2\right) - \left(\sum x_{2i} x_{3i}\right)^2} \tag{3.16}$$

şeklinde bulunur.

İki bağımsız ve bir bağımlı olmak üzere toplam üç değişken olması durumu için açıkladığımız Çoklu Doğrusal Regresyon modeli genelleştirilerek denklem (3.17)'deki gibi yazılabilir.

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + ... + \beta_k X_{ki} + u_i \tag{3.17}$$

Bağımsız değişkenler X_2'den başlayarak tanımlandığından modelde toplam k değişken ve $(k-1)$ bağımsız değişken yer almaktadır. Sabit katsayı β_1 ve eğim parametreleri $\beta_2, \beta_3, ..., \beta_k$ olduğundan tahmin edilecek parametre sayısı k'dır.

Yukarıda genel olarak ifade edilen model anakütle Çoklu Regresyon modeli olduğundan, örnek Çoklu Doğrusal Regresyon modeli,

$$Y_i = \hat{\beta}_1 + \hat{\beta}_2 X_{2i} + \hat{\beta}_3 X_{3i} + ... + \hat{\beta}_k X_{ki} + \hat{u}_i \tag{3.18}$$

olarak ifade edilecektir. Denklem (3.18)'de, $\hat{\beta}_2, \hat{\beta}_3, ..., \hat{\beta}_k$ parametreleri $\beta_2, \beta_3, ..., \beta_k$ 'nin tahmincileridir. Tahmincilerin basit regresyonda olduğu gibi belirlenmesi gerekmektedir. (3.18) no'lu denklemde Y_i 'nin beklenen değeri,

$$E(Y_i) = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + ... + \beta_k X_{ki} \tag{3.19}$$

Denklem (3.19)'daki gibi olacaktır. EKK yönteminde Y_i ile $E(Y_i)$ arasındaki farkların kareleri toplamı minimize edileceğinden, farkların kareler toplamı,

$$\sum u_i^2 = \sum \left[Y_i - E(Y_i) \right]^2 \tag{3.20}$$

$$\sum u_i^2 = \sum \left[Y_i - (\beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + ... + \beta_k X_{ki}) \right]^2 \tag{3.21}$$

$$\sum u_i^2 = \sum (Y_i - \beta_1 - \beta_2 X_{2i} - \beta_3 X_{3i} - ... - \beta_k X_{ki})^2 \tag{3.22}$$

sırasıyla denklem (3.20), (3.21) ve (3.22)'deki gibi olacaktır. Minimizasyon için (3.22) no'lu denklemin parametrelerinin $\beta_1, \beta_2, ..., \beta_k$ 'ya göre kısmi türevleri alınırsa,

$$\frac{\partial u_i^2}{\partial \beta_1} = 2\sum (Y_i - \beta_1 - \beta_2 X_{2i} - \beta_3 X_{3i} - ... - \beta_k X_{ki})(-1) \tag{3.23}$$

$$\frac{\partial u_i^2}{\partial \beta_2} = 2\sum (Y_i - \beta_1 - \beta_2 X_{2i} - \beta_3 X_{3i} - ... - \beta_k X_{ki})(-X_{2i}) \tag{3.24}$$

$$\frac{\partial u_i^2}{\partial \beta_3} = 2\sum (Y_i - \beta_1 - \beta_2 X_{2i} - \beta_3 X_{3i} - ... - \beta_k X_{ki})(-X_{3i}) \tag{3.25}$$

$$\vdots$$

$$\vdots$$

$$\frac{\partial u_i^2}{\partial \beta_k} = 2\sum (Y_i - \beta_1 - \beta_2 X_{2i} - \beta_3 X_{3i} - ... - \beta_k X_{ki})(-X_{ki}) \tag{3.26}$$

(3.23), (3.24), (3.25) ve (3.26) nolu denklemler elde edilir. Kısmi türevler sıfıra eşitlenir ve çarpım şeklinde yer alan ifadeler ile çarpılırsa,

$$\sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \hat{\beta}_3 X_{3i} - ... - \hat{\beta}_k X_{ki}) = 0 \tag{3.27}$$

$$\sum (Y_i X_{2i} - \hat{\beta}_1 X_{2i} - \hat{\beta}_2 X_{2i}^2 - \hat{\beta}_3 X_{2i} X_{3i} - ... - \hat{\beta}_k X_{2i} X_{ki}) = 0 \tag{3.28}$$

$$\sum (Y_i X_{3i} - \hat{\beta}_1 X_{3i} - \hat{\beta}_2 X_{3i} X_{2i} - \hat{\beta}_3 X_{3i}^2 - ... - \hat{\beta}_k X_{3i} X_{ki}) = 0 \quad (3.29)$$

$$\vdots$$

$$\vdots$$

$$\sum (Y_i X_{ki} - \hat{\beta}_1 X_{ki} - \hat{\beta}_2 X_{ki} X_{2i} - \hat{\beta}_3 X_{ki} X_{3i}^2 - ... - \hat{\beta}_k X_{ki}^2) = 0 \quad (3.30)$$

Denklem (3.27), (3.28), (3.29) ve (3.30)'daki gibi elde edilir. $\sum$ 'ya göre açılım yapılır. Y_i 'li ifadeler eşitliğin solunda, diğerleri sağında toplanırsa,

$$\sum Y_i = n\hat{\beta}_1 + \hat{\beta}_2 \sum X_{2i} + \hat{\beta}_3 \sum X_{3i} + ... + \hat{\beta}_k \sum X_{ki} \quad (3.31)$$

$$\sum X_{2i} Y_i = \hat{\beta}_1 \sum X_{2i} + \hat{\beta}_2 \sum X_{2i}^2 + \hat{\beta}_3 \sum X_{2i} X_{3i} + ... + \hat{\beta}_k \sum X_{2i} X_{ki} \quad (3.32)$$

$$\sum X_{3i} Y_i = \hat{\beta}_1 \sum X_{3i} + \hat{\beta}_2 \sum X_{3i} X_{2i} + \hat{\beta}_3 \sum X_{3i}^2 + ... + \hat{\beta}_k \sum X_{3i} X_{ki} \quad (3.33)$$

$$\vdots$$

$$\vdots$$

$$\sum X_{ki} Y_i = \hat{\beta}_1 \sum X_{ki} + \hat{\beta}_2 \sum X_{ki} X_{2i} + \hat{\beta}_k \sum X_{ki} X_{3i} + ... + \hat{\beta}_k \sum X_{ki}^2 \quad (3.34)$$

(3.31), (3.32), (3.33) ve (3.34) nolu denklemler elde edilir. Bu denklemler Çoklu Doğrusal Regresyonun normal denklemleridir. Elde ettiğimiz normal denklemler gerçek değerlerle ifade edilmiştir. Gerçek X_{ki} ve Y_i değerleri yerine ortalamadan farklar serileri oluşturularak yerine konursa,

$$\sum (Y_i - \bar{Y})(X_{2i} - \bar{X}_2) = \hat{\beta}_2 \sum (X_{2i} - \bar{X}_2)^2 + \hat{\beta}_3 \sum (X_{2i} - \bar{X}_2)(X_{3i} - \bar{X}_3)$$

$$= + ... + \hat{\beta}_k \sum (X_{2i} - \bar{X}_2)(X_{ki} - \bar{X}_k) \quad (3.35)$$

$$\sum(Y_i-\bar{Y})(X_{3i}-\bar{X}_3)=\hat{\beta}_2\sum(X_{2i}-\bar{X}_2)(X_{3i}-\bar{X}_3)+\hat{\beta}_3\sum(X_{3i}-\bar{X}_3)^2$$

$$=+...+\hat{\beta}_k\sum(X_{3i}-\bar{X}_3)(X_{ki}-\bar{X}_k) \quad (3.36)$$

$$\sum(Y_i-\bar{Y})(X_{ki}-\bar{X}_k)=\hat{\beta}_2\sum(X_{ki}-\bar{X}_k)(X_{2i}-\bar{X}_2)$$

$$=+\hat{\beta}_3\sum(X_{ki}-\bar{X}_k)(X_{3i}-\bar{X}_3)+...+\hat{\beta}_k\sum(X_{ki}-\bar{X}_k)^2 \quad (3.37)$$

sırasıyla (3.35), (3.36) ve (3.37) nolu denklemler elde edilir. Bu durumda k yerine $k-1$ denklemin ortak çözümü gerekmektedir. Sabit katsayı $\hat{\beta}_1$ ise,

$$\hat{\beta}_1=\bar{Y}-\hat{\beta}_2\bar{X}_2-\hat{\beta}_3\bar{X}_3-...-\hat{\beta}_k\bar{X}_k \quad (3.38)$$

(3.38) nolu denklem tahmin edilecektir.

3.2.9.2. EKK Yönteminin Varsayımları

Regresyon modelinin parametre tahminleri için herhangi bir yönteme başvurmadan önce bazı temel varsayımlara ihtiyaç vardır. Zira tahmin tekniklerinin tahmincilerinin iyi tahminciler olmasını her zaman garanti etmez ve bu durum göz ardı edilemeyecek kadar önemlidir. Bir regresyon ilişkisinde farklı örneklemler farklı tahminler üretir; dolayısıyla tahmincilerin her biri bir örnekleme dağılımına sahiptir. Bu örnekleme dağılımlarının arzu edilen özellikleri, bazı temel varsayımlar yapılmaz ise geçerlilik kazanmayabilir (Sevüktekin, 2013).

1. Anakütle gerçek ilişki regresyon denkleminde, X 'in her bir değeri için Y 'nin ortalama değeri doğrusal bir regresyon ile tanımlanır. Burada doğrusallıktan kastedilen anlam parametrelerine (katsayılarına) göre doğrusallıktır.

2. X açıklayıcı değişkeninin yinelenen örneklemlerde aldığı değerlerin aynı kaldığı düşünülür. Daha teknik bir deyişle, X 'in olasılıklı olmadığı varsayılır.

3. Bozucu u_i teriminin ortalaması sıfırdır. X değerleri veriyken rassal bozucu u_i teriminin ortalaması ya da beklenen değeri sıfırdır. Teknik olarak, denklem (3.38)'de görüldüğü gibi u_i 'nin koşullu ortalaması sıfırdır.

$$E(u_i / X_i) = 0 \tag{3.39}$$

4. u_i 'nin eşvaryansı, X değeri veriyken, u_i 'nin varyansı bütün gözlemler için aynıdır. Denklem (3.40)'da görüldüğü gibi u_i 'nin koşullu varyansları değişmez.

$$\begin{aligned} \text{Var}(u_i / X_i) &= E[u_i / X_i]^2 \\ &= E(u_i^2 / X_i) \\ &= \sigma^2 \end{aligned} \tag{3.40}$$

5. Bozucu terimler arasında ardışık bağımlılık yoktur. Denklem (3.41)'de görüldüğü üzere X_i ve X_j $(i \neq j)$ gibi iki X verilmişken, u_i ile u_j $(i \neq j)$ arasındaki korelasyon sıfırdır.

$$\begin{aligned} \text{Cov}(u_i, u_j / X_i, X_j) &= E[u_i - E(u_i) / X_i][u_i - E(u_j) / X_i] \\ &= E(u_i / X_i)(u_j / X_i) = 0 \end{aligned} \tag{3.41}$$

6. u_i ile X_i 'nin ortak varyansı denklem (3.42)'deki gibi sıfırdır.

$$\begin{aligned} \text{Cov}(u_i, X_i) &= E[u_i - E(u_i)][X_i - E(X_i)] && E(u_i) = 0 \text{ olduğundan:} \\ &= E[u_i(X_i - E(X_i))] && E(X_i) \text{ olasılıklı olmadığından:} \\ &= \text{E}(u_i X_i) - E(X_i)E(u_i) && E(u_i) = 0 \text{ olduğundan:} \\ &= \text{E}(u_i X_i) = 0 \end{aligned} \tag{3.42}$$

7. Gözlem sayısı n , tahmin edilecek anakütle katsayılarından fazla olmalıdır. Bu varsayımın başka bir söylenişi şöyledir: Gözlem sayısı n, açıklayıcı değişken sayısından büyük olmalıdır.

8. Belli bir örneklemdeki X değerlerinin hepsi aynı olmamalıdır. Eğer bütün X değerleri aynıysa $X_i = \bar{X}$ olur ve eşitliğin paydası sıfır çıkar. Bu da β_1'in dolayısıyla da β_2'nin tahmin edilmesini olanaksız kılar. Basit doğrusal regresyon durumunda bu koşul en azından $n > 2$ olmalıdır.

9. Regresyon modeli doğru kurulmalıdır. Başka bir deyişle, görgül çözümlemede kullanılan modelde kuruluş sapması ya da hatası bulunmamalıdır.

10. Hata terimi u_i rassal bir değişkendir. Hata terimi u_i'nin herhangi bir dönemde veya herhangi bir kesitte alacağı değerler olasılıklı veya şansa dayalı değerlerdir. Bağımlı değişken Y, stokastik bir modelde rassal hata terimi u_i'yi içerdiğinden aynı zamanda rassal bir değişken olarak adlandırılır.

11. Çoklu doğrusal bağlantı, yani açıklayıcı değişkenler arasında tam doğrusal ilişkiler yoktur.

3.2.9.3. EKK Tahmin Edicilerinin Varyansları ve Standart Hataları

Kısmi regresyon katsayılarının EKK tahmin edicileri elde edildikten sonra, bu tahmin edicilerin varyansları ile standart hataları aşağıda gösterildiği gibi bulunabilir. Sabit terimin varyansı ve standart hatası, denklem (3.43) ve (3.44), $\hat{\beta}_2$ parametresinin varyans ve standart hatası, denklem (3.45) ve (3.46), $\hat{\beta}_2$ parametresinin varyans ve standart hatası, denklem (3.47) ve (3.48) ile ifade edilmektedir.

$$\text{var}(\hat{\beta}_1) = \left[\frac{1}{n} + \frac{\bar{X}_2^2 \sum x_{3i}^2 + \bar{X}_3^2 \sum x_{2i}^2 - 2\bar{X}_2 \bar{X}_3 \sum x_{2i} x_{3i}}{\sum x_{2i}^2 \sum x_{3i}^2 - \left(\sum x_{2i} x_{3i} \right)^2} \right] . \sigma^2 \tag{3.43}$$

$$sh(\hat{\beta}_1) = \sqrt{\text{var}(\hat{\beta}_1)} \tag{3.44}$$

$$\text{var}(\hat{\beta}_2) = \frac{\sum x_{3i}^2}{\sum x_{2i}^2 \sum x_{3i}^2 - \left(\sum x_{2i} x_{3i} \right)^2} \sigma^2 \tag{3.45}$$

$$sh(\hat{\beta}_2) = \sqrt{\text{var}(\hat{\beta}_2)} \tag{3.46}$$

$$\text{var}(\hat{\beta}_3) = \frac{\sum x_{2i}^2}{\sum x_{2i}^2 \sum x_{3i}^2 - \left(\sum x_{2i} x_{3i}\right)^2} \sigma^2 \tag{3.47}$$

$$sh(\hat{\beta}_3) = \sqrt{\text{var}(\hat{\beta}_3)} \tag{3.48}$$

Yukarıdaki denklemlerde σ^2, anakütle bozucu terimi $\hat{u}_i$ 'nin sabit varyansıdır ve aşağıdaki şekilde bulunur:

$$\hat{\sigma}^2 = \frac{\sum \hat{u}_i^2}{n-k} \tag{3.49}$$

(3.49) nolu denklemde, k, parametre veya değişken sayısına eşittir. Modele ait kalıntı kareleri ($\sum \hat{u}_i^2$) için (3.50) nolu denklem kullanılarak daha çabuk hesaplanabilir:

$$\sum \hat{u}_i^2 = \sum y_i^2 - \hat{\beta}_2 \sum y_i x_{2i} - \hat{\beta}_3 \sum y_i x_{3i} \tag{3.50}$$

3.2.9.4. Belirlilik Katsayısı ve Düzeltilmiş Belirlilik Katsayısı

Bağımlı değişkendeki değişmelerin bağımsız değişken veya değişkenler tarafından açıklanma oranını belirten katsayıya *belirlilik katsayısı* denir. Belirlilik katsayısı, örneklem regresyonu doğrusunun verilere ne kadar iyi uyduğunu gösteren özet bir ölçüdür.

$Y_i = \hat{Y}_i + u_i$ eşitliğinde Y_i ve $\hat{Y}_i$'den $\overline{Y}$ çıkarılırsa,

$$(Y_i - \overline{Y}) = (\hat{Y}_i - \overline{Y}) + u_i \tag{3.51}$$

(3.49) nolu denklem söz konusu olacaktır. Bu ifade herhangi bir gözlem için geçerlidir. n gözlem söz konusu olacağından tarafların toplamı alınmalıdır. Fakat ortalamadan farkların toplamı sıfır olacağından, farklar mutlak değer olarak alınabilir. Bu durum bazı işlemlerin yapılmasını güçleştirmektedir. Bu nedenle mutlak değer yerine farkların işaretlerinin etkisini ortadan kaldırmak için sapmaların kareleri alınmaktadır.

Yukarıda elde ettiğimiz eşitlik için kareler toplamı,

$$\sum (Y_i - \bar{Y})^2 = \sum \left[(\hat{Y}_i - \bar{Y}) + u_i \right]^2$$

$$\sum (Y_i - \bar{Y})^2 = \sum (\hat{Y}_i - \bar{Y})^2 + \sum u_i^2 + 2\sum (\hat{Y}_i - \bar{Y}) u_i \qquad (3.52)$$

(3.52) nolu denklemde,

$\sum u_i = 0$ ve $\sum X_i u_i = 0$ olduğundan, $2\sum (\hat{Y}_i - \bar{Y}) u_i = 0$ olacaktır. Bu nedenle,

$$\sum (Y_i - \bar{Y})^2 = \sum (\hat{Y}_i - \bar{Y})^2 + \sum u_i^2 \qquad (3.53)$$

(3.53) nolu denklem elde edilecektir. Burada,

$\sum (Y_i - \bar{Y})^2$=Toplam değişme

$\sum (\hat{Y}_i - \bar{Y})^2$=Açıklanan değişme

$\sum u_i^2 = \sum (Y_i - \hat{Y})^2$=Açıklanmayan değişmedir.

Tarafları toplam değişmeye bölersek,

$$\frac{\sum (Y_i - \bar{Y})^2}{\sum (Y_i - \bar{Y})^2} = \frac{\sum (\hat{Y}_i - \bar{Y})^2}{\sum (Y_i - \bar{Y})^2} + \frac{\sum u_i^2}{\sum (Y_i - \bar{Y})^2} \qquad (3.54)$$

$$1 = \frac{\sum (\hat{Y}_i - \bar{Y})^2}{\sum (Y_i - \bar{Y})^2} + \frac{\sum u_i^2}{\sum (Y_i - \bar{Y})^2} \qquad (3.55)$$

(3.54) ve (3.55) nolu denklemler elde edilir. Eşitliğin sağ tarafındaki ifade tanımı gereği belirlilik katsayısıdır ve R^2 ile ifade edilir. Belirlilik katsayısı,

$$R^2 = \frac{\sum (\hat{Y}_i - \bar{Y})^2}{\sum (Y_i - \bar{Y})^2} \qquad (3.56)$$

(3.56) nolu denklemdeki gibi hesaplanır. Ayrıca eşitlikten belirlilik katsayısı,

$$1 = R^2 + \frac{\sum u_i^2}{\sum (Y_i - \bar{Y})^2} \tag{3.57}$$

$$R^2 = 1 - \frac{\sum u_i^2}{\sum (Y_i - \bar{Y})^2} \tag{3.58}$$

(3.57) ve (3.58) nolu denklemler elde edilir. R^2 açıklanmayan değişme oranının birden farkına eşittir. Yani, $(1 - R^2)$ açıklanmayan değişmelerin toplam değişmeye oranıdır.

Yukarıdaki açıklamalardan da anlaşılacağı gibi, regresyon modeli bağımlı değişkendeki toplam değişmelerin tümünü açıklıyorsa,

$$\sum (\hat{Y}_i - \bar{Y})^2 = \sum (Y_i - \bar{Y})^2$$

olacağından $R^2 = 1$ ve regresyon modeli bağımlı değişkendeki değişmeleri hiç açıklamıyorsa,

$$\sum (\hat{Y}_i - \bar{Y})^2 = 0$$

olacağından $R^2 = 0$ olacaktır. Yani,

$$0 \le \sum (\hat{Y}_i - \bar{Y})^2 \le \sum (Y_i - \bar{Y})^2$$

olacaktır. Taraflar toplam değişmeye bölünürse,

$$\frac{0}{\sum (Y_i - \bar{Y})^2} \le \frac{\sum (\hat{Y}_i - \bar{Y})^2}{\sum (Y_i - \bar{Y})^2} \le \frac{\sum (Y_i - \bar{Y})^2}{\sum (Y_i - \bar{Y})^2} \qquad 0 \le R^2 \le 1$$

olur. R^2'nin 1'e yaklaşması bağımlı değişkendeki değişmelerin bağımsız değişkenler tarafından iyi açıklandığını ortaya koyacaktır. Bu nedenle arzu edilen, büyük R^2 değerlerinin elde edilmesi olacaktır.

R^2'nin önemli bir özelliği, modelde bulunan açıklayıcı ya da bağımsız değişkenlerin azalmayan bir fonksiyon olmasıdır. Açıklayıcı değişken sayısı arttıkça,

R^2 hemen her zaman artar, asla azalmaz. Başka türlü söylersek, eklenen bir X , R^2 'yi azaltmaz.

Bağımlı değişkeni aynı, ama açıklayıcı değişkenleri farklı sayıda olan iki regresyon modelini karşılaştırıp, R^2'si yüksek olan modeli seçmek yanıltıcı sonuçlara yol açabilir. İki R^2 karşılaştırılırken, modeldeki X değişkenlerinin sayısı hesaba katılmalıdır.

$$\bar{R}^2 = 1 - \frac{\sum u_i^2 / (n-k)}{\sum (Y_i - \bar{Y})^2 / (n-1)} \tag{3.59}$$

(3.59) nolu denklemde $k =$ sabit terimle birlikte modeldeki katsayıların sayısıdır. Böyle tanımlanan R^2'ye *düzeltilmiş* R^2 denir.

3.2.9.5. Parametrelerin Anlamlılık Testleri

1. t − Testi

Basit doğrusal regresyonda olduğu gibi Çoklu Doğrusal Regresyonda da t testi parametrelerin anlamlılığının, yani sıfırdan farklı olup olmadığının ve belirli bir değerden farklı olup olmadığının testi için kullanılmaktadır. Çoklu Doğrusal Regresyonda yapılacak işlemler de aynıdır. Her bir parametre için test ayrı ayrı yapılır.

Parametrelerin sıfırdan farklı olup olmadığının testinde herhangi bir β_k parametresi için temel hipotez,

$$H_0 : \beta_k = 0$$

alternatif hipotez ise çift taraflı test için,

$$H_1 : \beta_k \neq 0$$

tek taraflı test için,

$$H_1 : \beta_k > 0 \quad \text{veya} \quad H_1 : \beta_k < 0$$

şeklinde oluşturulacaktır.

Hata payı α veya güven olasılığı $(1-\alpha)$ belirlenerek, $n \geq 30$ için normal dağılım tablolarından çift taraflı test için $Z_{\alpha/2}$ veya tek taraflı test için Z_{α} değeri alınacaktır. Örnekleme dağılımı t dağılımı, yani $n < 30$ ise, t dağılımı tablosundan uygun α ve $(n-k)$ serbestlik derecesi ile çift taraflı test için $t_{\alpha/2,n-k}$ veya tek taraflı test için $t_{\alpha,n-k}$ değerleri alınacaktır.

Parametrelerin anlamlılığının testinde test istatistiği,

$$t = \frac{\hat{\beta}_k - \beta_k}{S_{\hat{\beta}_k}}$$

ve $\hat{\beta}_k = 0$ test edildiğinden,

$$t = \frac{\hat{\beta}_k}{S_{\hat{\beta}_k}} \tag{3.60}$$

(3.60) nolu denklem elde edilecektir. Son olarak karar verilirken test istatistiği ile tablo değeri karşılaştırılacaktır.

Çift taraflı test için,

$|t| > |t_{\alpha/2,n-k}|$ veya $|t| > |Z_{\alpha/2}|$ ise H_0 Hipotezi

$|t| < |t_{\alpha/2,n-k}|$ veya $|t| < |Z_{\alpha/2}|$ ise H_1 Hipotezi

reddedilecektir.

Tek taraflı test için,

$|t| > |t_{\alpha,n-k}|$ veya $|t| > |Z_{\alpha}|$ ise H_0 Hipotezi

$|t| < |t_{\alpha/2,n-k}|$ veya $|t| < |Z_{\alpha}|$ ise H_1 Hipotezi

reddedilecektir.

2. F Testi

F testi ile Çoklu Doğrusal Regresyonda sabit parametre dışındaki parametrelerin tümünün birden anlamlılığı test edilmektedir. F testinde de biri temel, diğeri alternatif olarak iki hipotez kurulur. Temel hipotez sabit parametre hariç, tüm bağımsız değişken parametrelerinin anlamsız olduğunu, yani sıfıra eşit olduğunu ifade etmektedir.

$$H_0 : \hat{\beta}_2 = \hat{\beta}_3 = ... = \hat{\beta}_k = 0$$

Alternatif hipotez ise temel hipotezin doğru olmadığını ifade eder. Alternatif hipotez,

$$H_1 : \hat{\beta}_2 \neq \hat{\beta}_3 \neq ... \neq \hat{\beta}_k \neq 0$$

şeklinde gösterilebilir. Bu hipotez parametrelerden en az birinin sıfırdan farklı olduğunu ifade etmektedir.

F testinde test istatistiği,

$$F = \frac{\sum (\hat{Y}_i - \bar{Y})^2 / (k-1)}{\sum (Y_i - \hat{Y})^2 / (n-k)} \wedge \qquad (3.61)$$

denklem (3.61) şeklinde hesaplanır ve temel hipotezin doğru olması durumunda örnekleme dağılımı,

$$F_{\alpha,k-1,n-k}$$

$(k-1)$ ve $(n-k)$ serbestlik dereceli F dağılımıdır. Bu nedenle hesaplanan test istatistiği belirlenen α hata payı ile F tablosundan bulunacak tablo değeri ile karşılaştırılarak hipotezlerden biri kabul diğeri reddedilir.

$$F > F_{\alpha,k-1,n-k}$$

ise H_1 hipotezi kabul edilerek, H_0 hipotezi reddedilecektir. Tersi olduğunda,

$$F < F_{\alpha,k-1,n-k}$$

ise H_0 hipotezi kabul edilerek, H_1 hipotezi reddedilecektir.

3.2.9.6. Çoklu Doğrusal Bağlantı:

Çoklu doğrusal bağlantı, doğrusal regresyon modelinin önemli bir varsayımı olan, bağımsız değişkenlerin kendi aralarında ilişki bulunmaması varsayımından sapmadır. Yani Çoklu Regresyon modelinde açıklayıcı değişkenlerden bazılarının veya tümünün kendi aralarında ilişki içinde olmalarına çoklu doğrusal bağlantı denmektedir (Tarı, 2002).

Çoklu doğrusal bağlılık olmaması varsayımı yalnız Çoklu Regresyon için geçerlidir. Çoklu doğrusal bağlılık anakütleden kaynaklanmayıp örnekten kaynaklanır. Değişkenler arasındaki doğrusal ilişkinin derecesi doğrusal korelasyon katsayısı ile belirlenmektedir. Bu nedenle çoklu doğrusal bağlılık doğrusal korelasyon katsayısı ile ilişkilidir (Güriş, 2010).

Değişkenler arasında tam ilişki olması $(r_{23} = \pm 1)$ tam çoklu doğrusal bağlılık olarak adlandırılır. İki bağımsız değişkenli regresyon modeli ve değişkenler arasındaki tanımlanan ilişki için korelasyon katsayısı;

$$r_{23} = \frac{\sum (X_{2i} - \bar{X}_2)(X_{3i} - \bar{X}_3)}{\sqrt{\sum (X_{2i} - \bar{X}_2)^2 \sum (X_{3i} - \bar{X}_3)^2}} \tag{3.62}$$

denklem (3.62)'de $X_{3i} = aX_{2i}$ olduğundan

$$\bar{X}_3 = a\bar{X}_2$$

olacak ve

$$r_{23} = \frac{\sum (X_{2i} - \bar{X}_2)(aX_{2i} - a\bar{X}_2)}{\sqrt{\sum (X_{2i} - \bar{X}_2)^2 \sum (aX_{2i} - a\bar{X}_2)^2}}$$

$$= \frac{a\sum (X_{2i} - \bar{X}_2)^2}{\sqrt{a^2 \left[\sum (X_{2i} - \bar{X}_2)^2\right]^2}}$$

$$= \frac{a\sum (X_{2i} - \bar{X}_2)^2}{a\sum (X_{2i} - \bar{X}_2)^2} = 1 \tag{3.63}$$

(3.63) nolu denklem elde edilecektir.

Bağımsız değişkenler arasında tam ilişki olması ve ilişki olmaması durumlarında, birinde parametreler tahmin edilemediğinden, diğerinde sonuçlar etkilenmediğinden fazla problem olmamaktadır. Korelasyon katsayısının diğer değerleri alması durumu için aynı şeyler söylenemez. İki bağımsız değişkenli örnek için korelasyon katsayısı,

$$r_{23} = \frac{\sum (X_{2i} - \bar{X}_2)(X_{3i} - \bar{X}_3)}{\sqrt{\sum (X_{2i} - \bar{X}_2)^2 \sum (X_{3i} - \bar{X}_3)^2}} \tag{3.64}$$

denklem (3.64) ile ifade edildiğinden,

$$\sum (X_{2i} - \bar{X}_2)(X_{3i} - \bar{X}_3) = r_{23}\sqrt{\sum (X_{2i} - \bar{X}_2)^2 \sum (X_{3i} - \bar{X}_3)^2} \tag{3.65}$$

(3.65) nolu denklem elde edilir. Görüldüğü gibi korelasyon katsayısı ile ortalamadan farklar arasında korelasyon katsayısı ile ilgili bir ilişki söz konusudur.

Değişkenler arasında tam ilişki olması durumunda $X_{3i} = aX_{2i}$ olarak tanımlanmıştı. Değişkenler arasında tam ilişki yoksa X_{3i} ile aX_{2i} birlikte değişiminde u_i ile ifade edebileceğimiz farklar olacaktır. Yani X_3 'teki değişmelerin tamamı X_2 tarafından açıklanamayacaktır. Bu durumda,

$$X_{3i} = aX_{2i} + u_i \tag{3.66}$$

(3.66) nolu denklemdeki gibi tanımlanırsa,

$$\sum (X_{3i} - \bar{X}_3)^2 = \sum (aX_{2i} + u_i - a\bar{X}_2 - \bar{u})^2$$

$$= \sum \left[a(X_{2i} - \bar{X}_2) + (u_i - \bar{u}) \right]^2$$

ve

$$\bar{u} = 0$$

ise,

$$= a^2 \sum (X_{2i} - \bar{X}_2)^2 + \sum u_i^2 + 2a \sum (X_{2i} - \bar{X}_2)^2 u_i \tag{3.67}$$

(3.67) nolu denklem elde edilir. Daha önce açıklandığı gibi,

$$\sum (X_{2i} - \bar{X}_2) u_i = 0$$

olacağından,

$$\sum (X_{3i} - \bar{X}_3)^2 = a^2 \sum (X_{2i} - \bar{X}_2) + \sum u_i^2 \tag{3.68}$$

(3.68) nolu denklemde elde edilir. Aynı şekilde,

$$\sum (X_{2i} - \bar{X}_2)(X_{3i} - \bar{X}_3) = \sum (X_{2i} - \bar{X}_2)(aX_{2i} + u_i - a\bar{X}_2 - \bar{u})$$

$$= \sum (X_{2i} - \bar{X}_2)\left[a(X_{2i} - \bar{X}_2) + (u_i - \bar{u}) \right]$$

$$= \sum (X_{2i} - \bar{X}_2)\left[a(X_{2i} - \bar{X}_2) + u_i \right]$$

$$= a \sum (X_{2i} - \bar{X}_2)^2 + \sum (X_{2i} - \bar{X}_2) u_i$$

$$= a \sum (X_{2i} - \bar{X}_2)^2 \tag{3.69}$$

(3.69) nolu denklemde belirtildiği gibi olur. Buna göre korelasyon katsayısı,

$$r_{23} = \frac{a \sum (X_{2i} - \bar{X}_2)^2}{\sqrt{\sum (X_{2i} - \bar{X}_2)^2 \left[a^2 \sum (X_{2i} - \bar{X}_2)^2 + \sum u_i^2 \right]}} \tag{3.70}$$

denklem (3.70)'deki gibi olacaktır.

$$\sum u_i^2 = 0$$

ise $r_{23} = 1$ olacak, fakat $\sum u_i^2$ büyüdükçe r_{23} 1'den 0'a doğru küçülecektir.

1. Çoklu Doğrusal Bağlantının Nedenleri

1. Bağımsız değişkenlerin aynı trendin etkisinde bulunmaları: İktisadi değişkenler, aynı faktörlerin etkisi altında kalarak, zaman içinde birlikte değişme eğilimi gösterirler. Gerçekten de hızlı bir büyüme döneminde iktisadi değişkenler hep birlikte büyümekte ve daralma döneminde de yine hep birlikte küçülmektedirler. İşte, zaman serilerindeki büyüme ve trend faktörleri, çoklu doğrusal bağlantının en önemli nedenleridir.

2. Örnek büyüklüğünün küçük tutulması: Az sayıda veri ile çalışıldığında da çoklu doğrusal bağlantı ortaya çıkabilmektedir. Özellikle zaman serilerinde, kısa dönemde değişkenler birlikte değişme içinde olduklarında çoklu doğrusal bağlantı ortaya çıkmaktadır.

3. Bazı bağımsız değişkenlerin gecikmeli değerlerinin modele başka bir değişken olarak alınması: Bazı hallerde, bağımsız değişkenlerin bir veya birkaç dönem gecikmeli değerleri de modele ayrı bağımsız değişkenler olarak alınmaktadır. Bir değişkenin birbirini izleyen değerlerinin bağlantılı olmaları çok doğaldır.

2. Çoklu Doğrusal Bağlantının Sonuçları

1. EKK tahmin edicilerinin varyansları, kovaryansları ve standart hataları büyük çıkmaktadır.

$$Var(\hat{\beta}_2) = \frac{\sigma^2}{\sum (X_{2i} - \bar{X})^2 (1 - r_{23}^2)} \tag{3.71}$$

$$Var(\hat{\beta}_3) = \frac{\sigma^2}{\sum (X_{3i} - \bar{X})^2 (1 - r_{23}^2)} \tag{3.72}$$

$$Cov_{(\hat{\beta}_2, \hat{\beta}_3)} = \frac{-r_{23}^2 \sigma^2}{(1 - r_{23}^2) \sqrt{\sum (X_{2i} - \bar{X})^2 \sum (X_{3i} - \bar{X})^2}} \tag{3.73}$$

(3.71) ve (3.72) nolu denklemlerde r_{23}, X_2 ile X_3 arasındaki korelasyon katsayıdır. r_{23} 1'e yaklaşırken, yani ortak doğrusallık artarken iki tahmin edicinin varyanslarının büyüyeceği, limitte $r_{23} = 1$ olduğunda varyansların sonsuz olacağı açıktır. r_{23} 1'e

yaklaşırken, (3.73) nolu denklemde iki tahmin edicinin kovaryansının da mutlak değer olarak büyüyeceği aynı derecede açıktır.

2. Çoklu doğrusal bağlantıdan dolayı, herhangi bir katsayının standart hatası büyük çıktığında, o katsayının anlamlılığını araştırmak için kullanılan t testinde, t oranı küçük olacak ve bu da sonuçta ilgili katsayının sıfırdan farklı olmadığı anlamına gelecektir. Anlamsız çıkan katsayıya ilişkin açıklayıcı değişkenin, bağımlı değişkeni etkilemediği sonucuna varılarak bu değişken modelden çıkarılacaktır. Modelden çıkarılan açıklayıcı değişken, bağımlı değişkeni gerçekte etkiliyorsa, bu durumda, model kurma yanlışlığı yapılmış olacaktır.

3. Standart hatalar büyük çıktığı için güven aralıkları çok geniş olma eğilimindedir. Bu da sıfır hipotezlerinin kolayca kabul edilmesine yol açar.

4. Yine standart hatalar büyük çıktığı için bir ya da daha çok katsayının t oranları istatistik bakımından anlamsız olur.

5. Bir ya da daha çok katsayının t oranları istatistik bakımından anlamsız olmasına karşın, belirlilik katsayısı (R^2) çok yüksek olabilir.

6. EKK tahmin edicileriyle onların standart hataları, verilerdeki küçük değişmelere karşı duyarlı olabilirler.

3. Çoklu Doğrusal Bağlantının Belirlenmesi

1. Tahmin edilen modelin R^2 değeri yüksek çıktığı halde t oranları küçük çıkarsa, bu durum çoklu doğrusal bağlantının varlığına bir işaret olarak görülmektedir. Eğer bütün katsayıların birlikte anlamlılığını araştıran F testi olumlu sonuç verirken; katsayıların tek tek anlamlılığını araştıran t testi bazı katsayılar için olumsuz sonuç verirse, bu durumda çoklu doğrusal bağlantının olabileceği düşünülür. Ancak, burada kesinlik yoktur. Büyük standart hatalar ve dolayısıyla küçük t oranları, sadece açıklayıcı değişkenler arasındaki çoklu doğrusal bağlantı nedeniyle değil, başka nedenlerle de ortaya çıkabilir.

2. Açıklayıcı değişkenler arasındaki ikişerli korelasyon katsayılarının yüksek olması da çoklu doğrusallığın başka bir işaretidir. Fakat bu kriter, iki bağımsız

değişkenli modellerde yeterli olurken; ikiden fazla bağımsız değişkenli modellerde yeterli olmamaktadır.

3. Varyans büyütme faktörü (variance inflation factor) kısaca VIF de çoklu doğrusal bağlantının bir ölçüsü olarak kullanılmaktadır. VIF, tahmin edilen bir parametrenin, çoklu doğrusal bağlantı nedeniyle, gerçek değerden uzaklaşmasının bir ölçüsüdür. İki bağımsız değişkenli modelde,

$$VIF = \frac{1}{1 - r_{x_1 x_2}^2} \tag{3.74}$$

VIF, (3.74) nolu denklemdeki gibi olur. Doğrusal bağlantının bulunmaması durumunda $r_{x_1 x_2}^2 = 0$ olacağından, $VIF = 1$ olur.

İkiden fazla bağımsız değişkenli regresyon modelinde,

$$VIF = \frac{1}{1 - R_j^2} \tag{3.75}$$

VIF, (3.75) nolu denklemle ifade edilir. Burada R_j, j'inci bağımsız değişkenin diğer bağımsız değişkenlerle olan belirlilik katsayısıdır. Güçlü bir çoklu doğrusal bağlantı durumunda, bazı *VIF* 'ler de yüksek çıkmaktadır. $VIF > 5$ olması, çoklu doğrusal bağlantının varlığını göstermektedir.

4. Çoklu korelasyon ile kısmi korelasyonların karşılaştırılması:

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \beta_4 X_{4i} + u_i \tag{3.76}$$

(3.76) nolu denklem modelinde, bağımlı değişken ile bağımsız değişkenler arasındaki çoklu korelasyon katsayısı,

$$R_{Y.X_{2i}X_{3i}X_{4i}}$$

çok yüksek iken, kısmi korelasyon katsayıları,

$$r_{YX_{2i}.X_{3i}X_{4i}}$$

$r_{YX_{3i}.X_{2i}X_{4i}}$

$r_{YX_{4i}.X_{2i}X_{3i}}$

düşük iseler, X_{2i}, X_{3i}, X_{4i} değişkenleri arasında güçlü bir doğrusal bağlantı olduğuna karar verilir. Bu durumda, bağımsız değişkenlerden en az biri gereksizdir.

4. Çoklu Doğrusal Bağlantının Düzeltilmesi

1. Örnek hacmi genişletilerek, çoklu doğrusal bağlantıdan kurtulmak ya da etkisini azaltmak mümkündür. Örnek hacminin arttırılması da, ya yeni veriler eklenerek ya da örnek dönemi küçültülerek, örneğin yıllık veriler yerine üçer aylık veriler kullanarak olmaktadır (Tarı, 2002).

2. Çoklu doğrusal bağlılığa neden olan bağımsız değişkenlere ait bilgiler elde edilebiliyorsa, bu bilgiler kullanılarak çoklu doğrusal bağlantı düzeltilmeye çalışılabilir. Bu bilgiler iktisat teorisinden elde edilebileceği gibi, daha önce yapılmış ekonometrik çalışmalardan da elde edilmiş olabilir.

Bu bilgiler parametrelerin tam değerleri, toplamları veya oranları ile ilgili olabilir. Tüketimin gelir ve yatırımla açıklandığı,

$$C_t = \beta_0 + \beta_1 Y_t + \beta_2 I_t + \varepsilon_t \tag{3.77}$$

(3.77) nolu denklemde modelinde $\beta_1 = 0,3\beta_2$ olduğuna ait ön bilgi varsa, bu modelde çoklu doğrusal bağlılık olacaktır. Bu ilişki ile model,

$$C_t = \beta_0 + 0,3\beta_2 Y_t + \beta_2 I_t + \varepsilon_t$$

$$C_t = \beta_0 + \beta_2 (0,3Y_t + I_t) + \varepsilon_t \tag{3.78}$$

(3.78) nolu denklemde belirtildiği gibi olacaktır ve

$$X_t^* = 0,3Y_t + I_t$$

olarak tanımlanırsa,

$$C_t = \beta_0 + \beta_1 X_t^* + \varepsilon_t \tag{3.79}$$

(3.79) nolu denklemde belirtildiği gibi tahmin edildikten sonra, $X_t^* = 0,3Y_t + I_t$ eşitliğinden yararlanarak β_2 tahmin edilecektir. Bu durumda çoklu doğrusal bağlılık düzeltilmiş olabilir.

3. İktisadi değişkenler zaman içinde aynı değişme eğilimi gösterdiklerinden bu değişkenler ile oluşturulan modellerde çoklu doğrusal bağlılık olabilir. Modeller yatay kesit verisi ile tahmin edildiğinde ise zaman boyutu değişmediğinden değişkenler arasında zamana bağlı birlikte hareket söz konusu olmayacaktır. Bu nedenle yatay kesit verisi ile elde edilecek bilgiler zaman serisi modellerinde kullanılarak çoklu doğrusal bağlılık ortadan kaldırılabilir (Güriş, 2010).

4. Çoklu doğrusal bağlantı içinde bulunan değişkenlerden, tek bir değişkenin unsurları durumunda olanları birleştirmek ve bazı değişkenleri de modelden çıkarmak suretiyle, model daraltılarak, doğrusal bağlantı düzeltilmeye çalışılmaktadır. Ancak bu durumda, bazı değişkenler birleştirildiğinde, her bir değişkenin ayrı ayrı etkisi bilinmemekte ve yine bazı değişkenler modelden çıkarıldığında da spesifikasyon hatası yapılmaktadır. Önemli bir değişken çıkarıldığında, modelde onunla ilişkisi bulunan değişkenlerin katsayıları olduğundan büyük ya da küçük çıkmaktadır (Tarı, 2002).

5. Çoklu doğrusal bağlılık söz konusu olduğunda değişkenlerde çeşitli dönüşümler yapılarak çoklu doğrusal bağlılık ortadan kaldırılabilir. Örneğin, ilk farkların alınması veya değişkenlerin logaritmik değerlerine modelde yer verilmesi gibi dönüşümler çoklu doğrusal bağlılığı ortadan kaldırabilir. Fakat bu durumda da farklı sorunlar ortaya çıkabilir. Dönüşümlerin modelin matematiksel yapısını veya bağımlı değişken ile ilişkilerini değiştirmesi modele farklı şekilde etki edileceğinden bunlara dikkat edilmesi gerekir. Bağımsız değişkenlerden birinin logaritmasının alınması bağımlı değişken ile söz konusu bağımsız değişken arasındaki ilişkinin şeklini değiştirecektir. İlk farkların alınması ise, modelde sabit katsayı yer almamasına ve bir devrenin kaybına neden olur (Güriş, 2010).

6. Çoklu doğrusal bağlılık örnekten kaynaklandığından yeni bir örnek alınması veya incelenen dönemin değiştirilmesi ile çoklu doğrusal bağlılık ortadan kalkabilir. Fakat yeni veri toplanması her zaman mümkün değildir veya incelenen

dönemin değiştirilmesi çalışmanın amacına uygun olmayabilir. Bu gibi durumlarda çoklu doğrusal bağlılık bu yolla düzeltilemeyecek veya düzeltilmesi doğru olmayacaktır.

7. Çoklu doğrusal bağlılığa neden olan değişkenler arasında çift yönlü neden sonuç ilişkisi olabilir. Bu durumda incelenen modele yeni bir denklem eklenerek eşanlı denklem sisteminin oluşturulması ile çoklu doğrusal bağlılık ortadan kalkabilir.

8. Çoklu doğrusal bağlılık olduğunda, EKK tahmincilerinin varyansları büyük olmaktadır. Bu sorundan kurtulmak için bazı değişkenlerin modelden çıkarılması veya dönüşüm gibi yollara başvurulmaktadır. Bu durumda başvurulabilecek yöntemlerden biri sapmalı tahmin yöntemlerinin kullanılmasıdır. Sapmalı tahmin yöntemleri, katsayılarda gerçekleşmesi beklenen sonuçlara ulaşmayı ve bu sonuçlara ulaşırken varyansların küçülmesini sağlayan yöntemlerdir. Bu yöntemlerden elde edilen sonuçlar her ne kadar sapmalı olsa da hem teorik beklentilere cevap vermesi hem de varyansın daha küçük olması nedenleri ile sapmasız tahmin yöntemlerine tercih edilmektedir.

Sapmalı tahmin yöntemlerinden biri olan *Ridge regresyon yöntemi* gerekli olan tüm değişkenlerin modele alınmasını sağlar. Bu yöntem çoklu doğrusal bağlılık söz konusu olduğunda EKK yöntemi tahminlerinden daha küçük varyanslı parametre tahminlerinin elde edilmesini ve modelden gereksiz değişkenlerin çıkarılmasını amaçlamaktadır (Güriş, 2010).

3.2.9.7. Değişen Varyans

Klasik doğrusal regresyon modelinin önemli varsayımlarından biri, açıklayıcı değişkenlerin seçilmiş değerlerinin koşullu sonucu olan her bir u_i bozucu teriminin varyansının (3.80) nolu denklemde görüldüğü gibi σ^2'ye eşit sabit bir sayı olduğunu ileri sürer. Bu da sabit varyans (homoscedasticity), ya da eşit (homo) yayıklık (scedasticity), eşit varyans varsayımıdır (Gujarati, 2000).

$$E(u_i) = \sigma^2 \qquad i = 1, 2, ..., n \quad \text{(şekil)} \tag{3.80}$$

1. Değişen Varyansın Nedenleri

1. Değişen varyans, zaman serilerinden daha çok yatay kesit verilerinde görülmektedir. Değişen varyans, modelin yapısından veya modeli tahmin için kullanılan veriden kaynaklanmaktadır.

2. Önemli değişkenlerin modelden dışlanması, gözlemlerin regresyon doğrusundan farklılığını arttırarak değişen varyansa yol açar.

3. Değişen varyans, örneklemdeki öteki gözlemlerden çok farklı (çok küçük ya da çok büyük) gözlemlerin varlığının bir sonucu olarak da ortaya çıkabilir. Böyle bir gözlemin alınması ya da atılması, özellikle örneklem küçükken, regresyon çözümlemesinin bulgularını önemli ölçüde değiştirilebilir.

4. Gelir yükseldikçe, insanların istedikleri gibi harcayabilecekleri gelir daha çok olur, gelirlerini harcayabilecekleri seçenekler genişler. Böylelikle σ^2'nin gelirle birlikte büyümesi beklenir. Bu nedenle, tasarrufların gelire göre regresyonunda σ^2 'nin gelirle birlikte büyüdüğünü görmek olasıdır, çünkü insanlar tasarruf davranışlarına ilişkin daha çok seçenek sahibidirler.

2. Değişen Varyansın Sonuçları

1. EKK tahmincileri, sapmasız ve tutarlı olma özelliklerini korumakta, ancak minimum varyanslı olma özelliğini kaybetmektedirler. Değişen varyans halinde EKK yöntemi ile bulunan tahminciler sapmasız ve tutarlı olmakta, fakat minimum varyanslı etkin tahminciler olamamaktadırlar. Başka tahmin yöntemleriyle, daha güvenilir tahminler elde etmek mümkündür.

2. EKK tahmincilerinin t ve F testleri anlamlarını kaybetmektedirler.

3. Belli bir X değerine karşılık olan Y'nin öngörüsü, öngörünün varyansı, tahmincilerin ve hata terimlerinin varyanslarını içerdiğinden, yüksek varyanslı olacak ve dolayısıyla etkin olmayacaktır.

3. Değişen Varyansın Belirlenmesi

Ekonometrik modellerde değişen varyans olup olmadığını araştırmada kullanılan çeşitli testler bulunmaktadır. Bu testleri sistematik olmayan testler ve sistematik testler olmak üzere ikiye ayırmak mümkündür.

a. Sistematik Olmayan Testler

1. Değişen varyans, hata terimi varyanslarının, bağımsız değişkenin değerlerine bağlı olarak değişmesidir. Bu nedenle Y ve X değişkenlerine ait gözlem değerlerinin dağılma diyagramlarına bakılarak değişen varyans olup olmadığı anlaşılabilir.

2. Standartlaştırılmış hata terimi (u_i / s) değerleri ile X değerleri karşılaştırılarak değişen varyans olup olmadığı anlaşılmaktadır. X değerlerine göre standartlaştırılmış hata terimi değerleri değişmeyip aynı kalıyorsa, sabit varyans, aynı kalmayıp değişiyorsa değişen varyans olmaktadır.

3. Bu yöntemin esası, hata kareleri (u_i^2)'nin, açıklayıcı değişkene göre olan dağılımını bir diyagram üzerinde izlemekten ibarettir. Eğer, açıklayıcı değişkendeki değişmelere göre hata kareleri dağılımı da bir değişme gösteriyorsa, yani aralarında sistematik bir ilişki varsa, modelde değişen varyans olduğuna karar verilir. Aksi durumda sabit varyans söz konusudur.

b. Sistematik Testler

1. Spearman Sıra Korelasyon Testi

Sıra korelasyonu katsayısı sabit varyans varsayımının geçerli olup olmadığının belirlenmesi için kullanılabilir. Bu durumda temel hipotez sıra korelasyon katsayısının sıfır olduğu, yani sabit varyans varsayımının geçerli olduğunu, alternatif hipotez ise sıra korelasyonu katsayısının anlamlı olduğunu, yani sabit varyans varsayımının geçerli olmadığını ifade edecektir. Anakütle sıra korelasyon katsayısı (ρ_s) ile ifade edilirse hipotezler,

$$H_0 : \rho_s = 0$$

$$H_1 : \rho_s \neq 0$$

olarak kurulur. Bunun için önce model tahmin edilerek artıklar belirlenir. Artıklar mutlak değer olarak alınarak; artıklar ve bağımsız değişkenin değerlerine göre her ikisine de sıra numaraları verilir. Sıra numarası verilirken değişkenlerin aldıkları değer birden fazla tekrarlanıyorsa bu değerler ile ilgili sıra numarasının ortalaması alınarak sıra numaraları olarak alınır. Sıra korelasyon katsayısı,

$$r_s = 1 - \frac{6\sum D^2}{n(n^2-1)} \tag{3.81}$$

(3.81) nolu denklemdeki gibi hesaplanır. Burada da,

$$-1 \leq r_s \leq 1$$

olacaktır. D, sıra numaraları arasındaki farktır. Hesaplanan sıra korelasyonu katsayısının anlamlılığı, belirlenen α hata payı ile test edilir. Bu durumda test istatistiği,

$$t = \frac{r_s\sqrt{n-2}}{\sqrt{1-r_s^2}} \tag{3.82}$$

(3.82) nolu denklem kullanılarak hesaplanacaktır. Hesaplanan t istatistiği, $n > 30$ ise normal dağılım tablosundan $Z_{\alpha/2}$, $n < 30$ ise $(n-2)$ serbestlik derecesi ile t dağılımı tablosundan bulunacak $t_{\alpha/2,n-2}$ değeri ile karşılaştırılacaktır. Hesaplanan test istatistiği tablo değerinden büyükse H_0 hipotezi reddedilir, küçükse H_0 hipotezi reddedilemez.

Çoklu Regresyon modellerinde birden fazla bağımsız değişken olduğundan, her bağımsız değişken için ayrı ayrı aynı işlemler yapılır. Sabit varyans varsayımının geçerli olması için her değişken için yapılan test sonucunda H_0 hipotezinin reddedilmesi gerekir. Burada doğrusal korelasyon yerine sıra korelasyon katsayısının kullanılmasının nedeni, regresyonun temel varsayımlarından biri olan artıklar ile bağımsız değişkenler arasında ilişki olmamasıdır.

2. White Testi

Sabit varyans varsayımının geçerli olup olmamasının belirlenmesinde yaygın olarak kullanılan testlerden biridir. White testi, normallik varsayımına dayanmayan ve yardımcı regresyon modelinin tahminini gerektiren bir testtir.

Testin uygulanması için kurulan model tahmin edilerek artıklar belirlenir. Belirlenen artıkların karelerinin bağımlı değişken olduğu, bağımsız değişkenlerin ise modelin bağımsız değişkenleri, bağımsız değişkenlerin kareleri ve bağımsız değişkenlerin birbirleri ile çarpımlarından oluşan yardımcı regresyon modeli tahmin edilir. İncelenecek model,

$$Y_t = \beta_1 + \beta_2 X_{2t} + ... + \beta_k X_{kt} + \varepsilon_t \qquad (3.83)$$

(3.83) nolu denklemde belirtildiği gibidir. Yardımcı regresyon modeli,

$$\varepsilon_t^2 = \alpha_1 + \alpha_2 X_{2t} + ... + \alpha_k X_{kt} + \gamma_1 X_{2t}^2 + \gamma_1 X_{3t}^2 + ... +$$

$$= \gamma_k X_{kt}^2 + \delta_1 X_{2t} X_{3t} + ... + \delta_k X_{2t} X_{kt} + \theta_1 X_{3t} X_{4t} + ... + v_t \qquad (3.84)$$

(3.84) nolu denklemde görüldüğü gibi olacaktır. Bu durumda hipotezler,

$H_0 : \beta_2 = \beta_3 = ... = \beta_k = 0$ Sabit varyans varsayımı geçerlidir.

$H_1 : \beta_2 \neq \beta_3 \neq ... \neq \beta_k \neq 0$ Sabit varyans varsayımı geçerli değildir.

şeklinde oluşturulur.

White testi için test istatistiği yardımcı regresyon modelinin belirlilik katsayısı ile nR^2 olarak hesaplanır. nR^2 dağılımı, serbestlik derecesi yardımcı regresyon modelinin bağımsız değişken sayısına eşit olan ki-kare dağılımıdır. α hata payı ile $ki-kare$ tablosundan bulunan tablo değeri ile nR^2 karşılaştırılarak hipotezlerden biri reddedilir. nR^2, tablo değerinden büyükse H_0 hipotezi reddedilir, küçükse H_0 hipotezi reddedilemez. Bu yöntem değişken sayısı az olduğunda kolay uygulanmaktadır. Fakat değişken sayısının artması, serbestlik derecesinin düşmesine neden olabilir.

3. Ramsey Reset Testi

Tanımlama hatalarında kullanılan Reset testi, sabit varyans varsayımının geçerli olup olmamasının belirlenmesinde de kullanılmaktadır.

Testin uygulanması için kurulan model tahmin edilerek artıklar belirlenir. Belirlenen artıklar bağımlı değişkenin tahmini değeri $\hat{Y}$'nın karesi, küpü ve dördüncü kuvveti ile yardımcı regresyon modeli oluşturulur. Uygulamalarda daha çok karesi ve küpü modele ilave edilmektedir. (3.4.80) no'lu denklemin, yardımcı regresyon modeli,

$$\varepsilon_t = \alpha_1 + \alpha_2 \hat{Y}^2 + \alpha_3 \hat{Y}^3 + \alpha_4 \hat{Y}^4 + v_t \qquad (3.85)$$

(3.85) nolu denklemdeki gibi olacaktır. Bu durumda hipotezler,

$H_0 : \alpha_i = 0$ Sabit varyans varsayımı geçerlidir.

$H_1 : \alpha_i \neq 0$ Sabit varyans varsayımı geçerli değildir.

şeklinde kurulur.

Yardımcı regresyon modeli tahmin edilerek katsayıların anlamlı olup olmadığı α hata payı ile t tablosundan bulunacak değer ile karşılaştırılacaktır. Katsayılar anlamlı ise H_0 hipotezi reddedilir, anlamsız ise H_0 hipotezi reddedilemez.

4. Park Testi

Bu testte değişen varyansın, hata terimi varyansı ile bağımsız değişken arasında,

$$\sigma_i^2 = \sigma^2 X_i^{\delta} e^{v_i} \qquad (3.86)$$

(3.86) nolu denklemde belirtildiği şekilde ilişki olduğu varsayılmaktadır. σ_i^2 bilinmediğinden bunun yerine artıkların kareleri kullanılmaktadır. Modelden elde edilen artıklar e_i ise,

$$e_i^2 = \sigma^2 X_i^{\delta} e^{vi} \tag{3.87}$$

(3.87) nolu denklemde belirtildiği şekilde olacaktır. Tarafların doğal logaritması alınırsa,

$$\ln(e_i^2) = \ln\sigma^2 + \delta \ln X_i + v_i$$

ve

$$\ln\sigma^2 = \beta$$

olarak tanımlanırsa,

$$\ln(e_i^2) = \beta + \delta \ln X_i + v_i \tag{3.88}$$

(3.88) nolu denklem elde edilir. Burada $\delta = 0$ ise $\ln X_i$ ile $\ln(e_i^2)$ arasında ilişki olmayacağından sabit varyans varsayımı geçerli olacaktır. Bu nedenle δ 'nın anlamlı olup olmadığına bakılarak sabit varyansın geçerli olup olmadığına karar verilir.

Park testinde hipotezler,

$H_0 : \delta = 0$ Sabit varyans varsayımı geçerlidir.

$H_1 : \delta \neq 0$ Sabit varyans varsayımı geçerli değildir.

şeklinde oluşturulur. Test için,

$$\ln(e_i^2) = \beta + \delta \ln X_i + v_i \tag{3.89}$$

(3.89) nolu denklem modeli tahmin edilerek δ 'nın anlamlı olup olmadığı t testi ile test edilir. Test sonucunda sabit varyans varsayımının geçerli olup olmadığına karar verilir.

5. Glejser Testi

Bu testte değişen varyans, hata terimi varyansı ile bağımsız değişken arasındaki farklı kalıptaki ilişkilerle açıklamaktadır. Park testi gibi değişen varyansı fonksiyonel şekillerle açıklamaya çalışan bu testte Park testinden farklı olarak σ_i^2

yerine artıkların mutlak değerleri kullanılmaktadır. Artıklar tahmin edilerek σ_i^2 ile ilişki olduğu düşünülen bağımsız değişkenler için,

$$|e_i| = \beta_0 + \beta_1 X_i + v_i \tag{3.90}$$

$$|e_i| = \beta_0 + \beta_1 \sqrt{X_i} + v_i \tag{3.91}$$

$$|e_i| = \beta_0 + \beta_1 \frac{1}{X_i} + v_i \tag{3.92}$$

$$|e_i| = \beta_0 + \beta_1 \frac{1}{\sqrt{X_i}} + v_i \tag{3.93}$$

$$|e_i| = \sqrt{\beta_0 + \beta_1 X_i} + v_i \tag{3.94}$$

$$|e_i| = \sqrt{\beta_0 + \beta_1 X_i^2} + v_i \tag{3.95}$$

(3.90), (3.91), (3.92), (3.93), (3.94), (3.95) nolu denklemlerdeki regresyon modelleri denenmektedir. Burada yukarıda verilen kalıpların hepsinin denenmesi şart olmayıp bir veya birkaç tanesi denenebilmektedir.

Basit regresyon modelleri için verilen bu kalıplar Çoklu Regresyon modelleri için de genelleştirilebilir. Denenen modellerin katsayılarının anlamlılığı *t* ve *F* testleri ile incelenebilir.

β_0 ve β_1'in anlamlı olup olmadığı testi ile incelendiğinde

$\beta_0 = 0 , \beta_1 = 0$ ise sabit varyans

$\beta_0 = 0 , \beta_1 = 0$ ise değişen varyans

$\beta_0 \neq 0 , \beta_1 \neq 0$ ise değişen varyans

olduğuna karar verilecektir. Görüldüğü gibi sabit katsayının anlamlı olup olmaması o kadar önemli değildir. Bu nedenle Çoklu Regresyon modellerinde tüm bağımsız değişkenlerin katsayılarının anlamlı olup olmadığı *F* testi ile de test edilebilir.

6. Breusch-Pagan Testi

Bu test Glejser ve Park testi gibi fonksiyonel şekle bağlı değildir. Değişen varyansın sadece bazı bağımsız değişkenlere bağlı olduğundan şüpheleniliyorsa Breusch-Pagan testini kolayca uyarlayabiliriz (Wooldridge, 2013). Breusch-Pagan testinde (3.96) no'lu denklem,

$$\sigma_i^2 = f(\alpha_1 + \alpha_2 Z_2 + ... + \alpha_p Z_p) \tag{3.96}$$

olarak tanımlanır. Burada modelde yer alan bağımsız değişkenlerden değişen varyansa neden olduğu düşünülenler Z ile ifade edilmiştir. Z değişkenleri, bağımsız değişkenlerin kendileri olabileceği gibi, kareleri veya e^x de olabilir. σ_i^2'nin bağımlı değişken ve modelin değişen varyansa neden olduğu düşünülen bağımsız değişkenlerin bağımsız değişken olduğu bir yardımcı regresyon modeli söz konusudur. Breusch-Pagan testinde hipotezler,

$H_0 : \alpha_2 = \alpha_3 = ... = \alpha_p = 0$ Sabit varyans varsayımı geçerlidir.

$H_1 : \alpha_2 \neq \alpha_3 \neq ... \neq \alpha_p \neq 0$ Sabit varyans varsayımı geçerli değildir.

şeklinde olacaktır.

Yardımcı regresyon modelinin tahmini için σ_i^2'nin belirlenmesi gerekir. σ_i^2 bilinmediğinden bunun yerine en çok benzerlik tahmincisi,

$$\sigma_i^2 = \frac{\sum e_i^2}{n} \tag{3.97}$$

(3.97) nolu denklemde belirtilen modelden tahmin edilir. Modelin regresyon tarafından açıklanan kareler toplamı SSR_0 değeri bulunur. Breusch-Pagan test istatistiği,

$$\lambda = \frac{SSR_0}{2\hat{\sigma}^4} \tag{3.98}$$

(3.98) nolu denklemde gösterildiği şekilde hesaplanır. λ'nın dağılımı $(p-1)$ serbestlik dereceli *ki-kare* dağılımıdır. Hesaplanan test istatistiği α hata payı ve

$(p-1)$ serbestlik derecesi ile *ki-kare* tablosundan bulunacak tablo değeri ile karşılaştırılır. Test istatistiği tablo değerinden büyükse H_0 hipotezi reddedilir, küçükse H_0 hipotezi reddedilemez.

7. Benzerlik Oranı Testi

Benzerlik oranı testi, örnek birim sayısının çok olması durumunda sabit varyansın geçerli olup olmamasında kullanılabilir. Temel hipotez sabit varyans varsayımı geçerlidir, alternatif hipotez sabit varyans varsayımı geçerli değildir şeklinde kurulur. Test için önce incelenecek model basit regresyon modeli ise tahmin edilen artıklar bağımsız değişkenin mutlak değerlerinin büyüklüğüne göre sıralanır. İncelenecek model Çoklu Regresyon modeli ise $\hat{Y}_i$ teorik değerleri belirlenerek, artıklar bunların büyüklük sırasına göre sıralanır. Sıralanan artıklar her biri n_i gözlemden oluşan k sayıda gruba bölünür. Bu durumda,

$$\sum n_i = n \tag{3.99}$$

(3.99) nolu denklemde gösterildiği gibi olacaktır. Gruplar oluşturularak her grup için hata terimi varyansının en çok benzerlik yöntemi ile tahminleri yapılır. Yani,

$$\hat{\sigma}_i^2 = \frac{\sum e_{1i}^2}{n_i} \tag{3.100}$$

(3.100) nolu denklemden bulunur. Test istatistiği (3.101) nolu denklemde belirtilen şekilde,

$$LR = \prod \frac{(\hat{\sigma}_i)^{n_i}}{\hat{\sigma}^n} \tag{3.101}$$

olarak hesaplanır. LR test istatistiğinin dağılımı $(k-1)$ serbestlik dereceli ki-kare dağılımıdır. *Ki-kare* tablosundan α hata payı ve $(k-1)$ serbestlik derecesi ile bulunan tablo değeri test istatistiği ile karşılaştırılır ve test istatistiği tablo değerinden büyükse H_0 hipotezi reddedilir, küçükse H_0 hipotezi reddedilemez.

8. Goldfeld-Quandt Testi

Bu testte σ_i^2'nin modelde yer alan bağımsız değişkenlerden biri ile ilişkili olduğu varsayılmaktadır. Bu değişken, X^* ile ifade edelim. Burada X^* ile σ_i^2 arasında doğru yönlü ilişki olduğu varsayımı ile yapılan test açıklanacaktır. Ters yönlü ilişki olması durumunda farklı test istatistiği kullanılır.

Goldfeld-Quandt Testi için temel hipotez, sabit varyans varsayımı geçerlidir, alternatif hipotez sabit varyans varsayımı geçerli değildir şeklinde kurulacaktır. Testteki temel düşünce, büyük X^* değerlerinin büyük artıklara neden olacağıdır.

Test istatistiğinin hesaplanması için gözlemler X^* değişkeninin büyüklüğüne göre sıralanır ve ortadaki p gözlem seçilerek atılır. Burada seçilerek atılan p gözlem sayısı önemlidir. Testten elde edilecek sonuç bir anlamda buna da bağlı olacaktır.

Atılacak gözlem sayısının (p) belirlenmesinde öncelikle serbestlik derecesinin sağlanması gereklidir. Serbestlik derecesinin sağlanması için $(n-p)/2 > k$ olmalıdır.

Testin iyi sonuç vermesi için p, ne çok küçük ne de çok büyük olmalıdır. Bu nedenle yaklaşık $p < n/3$ olmasının uygun olacağı söylenmektedir. Yapılan araştırmalar $n = 30$ için $p = 8$, $n = 60$ için $p = 16$ alınmasının uygun olacağını ortaya koymuştur. Atılacak p sayısı $(n/5)$ olarak da bulunabilir.

p belirlendikten sonra ilk $(n-p)/2$ gözlem ve son $(n-p)/2$ gözlem için regresyon modelleri ayrı ayrı tahmin edilerek artıkların kareleri toplamları hesaplanır. İlk grup için hesaplanan artıkların kareleri toplamını SSE_1 ve son grup için hesaplanan artıkların kareleri toplamını SSE_2 ile ifade edersek test istatistiği,

$$F = \frac{SSE_2}{SSE_1} \tag{3.102}$$

(3.102) nolu denklem olacaktır. Gözlemler X^*'in büyüklüğüne göre sıralandığından SSE_1, X^*'in küçük değerleri; SSE_2 ise X^*'in büyük değerleri için hesaplanan artıkların kareleri toplamı olacaktır ve büyük X^*'lerin büyük artıklara neden olduğu varsayımı geçerli ise $SSE_2 > SSE_1$ olacaktır.

Temel hipotezin geçerliliği ve hata teriminin normal dağıldığı varsayımı altında hesaplanan test istatistiğinin dağılımı,

$$SD = \frac{1}{2}(n - p - 2k)$$

veya

$$SD = \frac{(n-p)}{2} - k \qquad (3.103)$$

(3.103) nolu denklem, serbestlik dereceli F dağılımıdır. α hata payı ve ilgili serbestlik dereceleri ile F dağılımı tablosundan bulunacak tablo değeri ile hesaplanan test istatistiği karşılaştırılır. Hesaplanan değer tablo değerinden büyükse H_0, küçükse H_1 hipotezi reddedilir.

4. Değişen Varyansın Düzeltilmesi

Değişen varyansın düzeltilmesinde iki yaklaşım söz konusudur; birincisi σ_i^2 'nin bilindiği zaman, ikincisi ise σ_i^2 'nin bilinmediği zamandır.

1. σ_i^2 ***biliniyorsa,***

Değişkenlerin σ_i 'ye bölünmesi ile uygulanacak tartılı EKK yöntemi tahmincileri en iyi sapmasız tahminciler (3.104) nolu denklemde belirtildiği şekilde olacaktır.

$$Y/\sigma_i = \hat{\beta}_1(1/\sigma_i) + \hat{\beta}_2(X_i/\sigma_i) + (\hat{u}/\sigma_i) \qquad (3.104)$$

2. σ_i^2 ***bilinmiyorsa,***

I. Varsayım: Hata varyansının, açıklayıcı değişkenin karesi ile orantılı olduğu varsayımı;

$$E(u_i^2) = \sigma^2 X_i^2 \tag{3.105}$$

(3.105) nolu denklemde belirtildiği şekildedir. Burada,

$$\sigma^2 = E\left(\frac{u_i^2}{X_i^2}\right) = E\left(\frac{u_i}{X_i}\right)^2 \tag{3.106}$$

(3.106) nolu denklem, sabit varyansı ifade ettiğinden, modeldeki bütün terimler X_i 'ye bölünerek, model sabit varyanslı biçime dönüştürülür.

Sabit varyanslı yeni model,

$$\frac{Y_i}{X_i} = \frac{\beta_1}{X_i} + \beta_2 + \frac{u_i}{X_i}$$

$$= \beta_1 \frac{1}{X_i} + \beta_2 + v_i \tag{3.107}$$

(3.107) nolu denklemde v_i dönüştürülmüş hata terimidir, u_i / X_i 'ye eşittir.

$$E(v_i^2) = E\left(\frac{u_i}{X_i}\right)^2 = \frac{1}{X_i^2} E(u_i^2) \tag{3.108}$$

(3.108) nolu denklemde v_i 'nin varyansı artık sabit olur, Modele, EKK yöntemi uygulanarak Y_i / X_i 'nin $1/ X_i$ 'ye göre regresyonu bulunur.

II. Varsayım: Hata varyansının açıklayıcı değişkenin kendisiyle orantılı olduğu varsayım (3.109) nolu denklemde belirtildiği gibi ve;

$$E(u_i^2) = \sigma^2 X_i \tag{3.109}$$

şeklindedir. Orijinal model,

$$\frac{Y_i}{\sqrt{X_i}} = \frac{\beta_1}{\sqrt{X_i}} + \beta_2 \sqrt{X_i} + \frac{u_i}{\sqrt{X_i}}$$

$$= \beta_1 \frac{1}{\sqrt{X_i}} + \beta_2 \sqrt{X_i} + v_i \tag{3.110}$$

(3.110) nolu denklemde $v_i = u_i / \sqrt{X_i}, X_i > 0$'dır. Elde edilen modele EKK yöntemi uygulanarak $Y_i / \sqrt{X_i}$'nin $1/ X_i$ ile $\sqrt{X_i}$'ye göre regresyonu bulunur.

2.3. *III. Varsayım:* Hata varyansının, bağımlı değişkenin beklenen değerinin karesiyle orantılı olduğu varsayım;

$$E(u_i^2) = \sigma^2 \left[E(X_i)\right]^2 \tag{3.111}$$

(3.111) nolu denklemdeki gibi ifade edilir. Buna göre, orijinal modeldeki bütün terimler bağımlı değişkenin beklenen değerine bölünerek sabit varyanslı dönüştürülmüş biçim elde edilir.

Dönüştürülmüş yeni model,

$$\frac{Y_i}{E(Y_i)} = \frac{\beta_1}{E(Y_i)} + \beta_2 \frac{X_i}{E(Y_i)} + \frac{u_i}{E(Y_i)}$$

$$= \beta_1 \left(\frac{1}{E(Y_i)} \right) + \beta_2 \frac{X_i}{E(Y_i)} + v_i \tag{3.112}$$

(3.112) nolu denklemde $v_i = u_i / E(Y_i)$'dir. v_i bozucu terimleri sabit varyanslıdır. Ancak bu denklem uygulanabilir değildir, çünkü $E(Y_i)$, bilinmeyen β_1 ile β_2'ye bağlıdır. $E(Y_i)$'nin bir tahmin edicisi olan $\hat{Y}_i = \hat{\beta}_1 + \hat{\beta}_2 X_i$ olduğundan dolayı, işlemleri iki adımla sürdürebiliriz: Önce değişen varyans sorununu bir yana bırakıp klasik EKK yöntemini uygulayarak $\hat{Y}_i$'yi elde ederiz. Sonra, tahmin edilen $\hat{Y}_i$ 'yi kullanıp modeli şöyle dönüştürebiliriz:

$$\frac{Y_i}{\hat{Y}_i} = \beta_1 \left(\frac{1}{\hat{Y}} \right) + \beta_2 \left(\frac{X_i}{\hat{Y}_i} \right) + v_i \tag{3.113}$$

(3.113) nolu denklemde, $v_i = (u_i / \hat{Y}_i)$ 'dir ve denklemin regresyonu hesaplanır.

IV. Varsayım: Logaritmik Dönüşüm; Sabit varyans varsayımının geçerli olmaması durumunda yapılabileceklerden biri değişkenlerin logaritmalarını almaktır. (3.114) nolu denklem modeli,

$$Y_i = \hat{\beta}_1 + \hat{\beta}_2 X_i + \varepsilon_i \qquad (3.114)$$

şeklindedir. Y ve X değişkenlerinin logaritması alınarak model,

$$\ln Y_i = \alpha_0 + \alpha_1 \ln X_i + \varepsilon_i \qquad (3.115)$$

(3.115) nolu model tahmin edilirse, logaritmik ölçeklendirme nedeni ile değişen varyans durumu geçerliliğini kaybedebilir.

3.2.9.8. Otokorelasyon

Otokorelasyon, korelasyonun özel bir halidir. Korelasyonda X ve Y gibi iki farklı değişken arasındaki ilişki araştırıldığı halde otokorelasyonda aynı değişkenin birbirini takip eden değerleri arasındaki ilişkinin derecesi araştırılmaktadır (Akkaya, 1998). Başka bir deyişle, otokorelasyon, hata teriminin birbirini izleyen değerleri arasında ilişki bulunması halidir. Bu durum doğrusal regresyon modelinin önemli bir varsayımından sapmadır. Varsayım gereği olarak, hata terimleri arasında bir ilişki yoktur (Tarı, 1999).

Otokorelasyon genellikle zaman serilerinde karşılaşılan bir sorundur. Zamana göre düzenlenen veriler zaman sırasını izlemektedir ve bu sıranın değiştirilmesi doğru değildir. Oysa yatay kesit verilerinde böyle bir sıralama söz konusu değildir, sıralamanın değiştirilmesi sonucu etkilemeyecektir. Bu nedenle otokorelasyon bulunsa bile bunun tesadüfi dizilişin bir sonucu olduğu söylenebilir.

Regresyon modelinin hata terimi u ile ifade edilirse, otokorelasyon olmaması durumunda, (3.116) nolu denklem

$$Cov(u_i, u_j) = 0 \qquad i \neq j \qquad (3.116)$$

şeklinde olacaktır. Burada i ve j farklı devreleri ifade etmektedir. $i = j$ olması durumunda ise,

$$Cov(u_i, u_i) = \frac{\sum(u_i - \bar{u})(u_i - \bar{u})}{N} = \frac{\sum(u_i - \bar{u})^2}{N} = \sigma_u^2 \qquad (3.117)$$

(3.117) nolu modeldeki gibi olur.

1. Otokorelasyonun Nedenleri

1. Modele alınmayan açıklayıcı değişkenler, aynı yönde belli bir etki meydana getirecek şekilde hareket ediyorlarsa, bu durum hata terimlerine yansımakta ve birbirini izleyen hata terimleri arasında da bir ilişki ortaya çıkmaktadır. Eğer modelden dışlanan birden çok açıklayıcı değişkenin birbirini izleyen değerleri, farklı yönlerde hareket ediyorlarsa, bunlar birbirlerinin etkilerini götürürler ve dolayısıyla hata terimi otokorelasyonlu olmayabilir.

2. Değişkenler arasındaki ilişkiyi ortaya koyan matematiksel biçimin yanlış seçilmesi de otokorelasyona neden olmaktadır. Örneğin, Y ve X değişkenleri arasındaki gerçek ilişki parabolik olduğu halde, bu değişkenler arasındaki ilişkiyi belirlemek için doğrusal kalıp kullanılırsa, bu durumda hata terimleri düzenli bir dağılım göstermekte ve otokorelasyon ortaya çıkmaktadır.

3. Ölçme hataları belli bir yönde gelişiyorsa, hata terimleri de düzenli bir dağılım göstermekte ve birbirini izleyen hata terimleri arasında bir ilişki bulunmaktadır. Ölçme hataları bütün gözlemler için aynı kalırsa, hata terimleri bundan etkilenmeyecektir.

4. Verilere uygulanan işleme ve düzeltme teknikleri de otokorelasyona neden olmaktadır. Üçer aylık verilerin ortalamasının alınarak bu verilerin düzleştirilmesi ve eksik bulunan ara verilerin interpolasyon tekniği ile tahmini, hata terimlerinin düzenli bir dağılım göstermesine ve dolayısıyla otokorelasyona yol açabilir.

5. Hata terimine etki eden ve tamamıyla tesadüfi faktörler olan, savaş, yangın, kuraklık ve grev gibi olayların etkisi birden çok döneme yayılabilir. Örneğin, önemli bir grevin üretim üzerindeki etkisi birkaç dönem daha sürebilir. Böylece birbirini izleyen hata terimleri arasında bir ilişki ortaya çıkabilir.

2. Otokorelasyonun Sonuçları

1. Otokorelasyon halinde, EKK yöntemiyle tahmin edilen parametreler sapmasız olmakta ancak parametre tahminlerinin varyansları, öteki tahmin yöntemleriyle bulunanlardan daha yüksek olmaktadır. Bu da tahminlerin etkin olmadığını göstermektedir.

2. Hata terimi varyansı $\hat{\sigma}^2 = \sum \hat{u}_i^2 / (n-2)$, gerçek σ^2 'yi olduğundan küçük tahmin edebilir.

3. $\hat{\sigma}^2$, olduğundan küçük çıkınca, R^2 değeri de olduğundan daha büyük değerli olmaktadır.

4. Hata terimi varyansının küçük olması sonucu, parametre tahminlerinin varyansları ve dolayısıyla standart hataları olduğundan büyük değerli çıkmaktadır. Bu durumda EKK yöntemiyle bulunan, güven aralıkları ile t ve F testleri geçerliliğini kaybetmektedir.

5. EKK yöntemiyle bulunan tahminlere göre yapılan öngörüler etkin değildir.

3. Otokorelasyonun Belirlenmesi

Otokorelasyonun var olup olmadığı, geliştirilen ve otokorelasyon testleri olarak adlandırılan testlerle yapılmaktadır.

a. Grafik yöntemi:

Otokorelasyonun varlığı, örnek hata terimlerinin ya zamanla ya da kendi gecikmeli değerleriyle karşılaştırmalı olarak dağılma diyagramlarının çizilmesi ile anlaşılabilmektedir. Otokorelasyon varlığının grafiklerle belirlenmesi en kolay yöntem olmakla birlikte en az güvenilen yöntemdir. Grafiklerin farklı ölçeklendirilmesi sonucu elde edilen çizim şekilleri gözü yanıltarak hatalı kararlara neden olabilecektir.

b. Sıra Testi:

Tesadüfîliğin araştırılması için kullanılan parametrik olmayan bir testtir. Tesadüfîlik verilerin dizilişi ile ilgili bir kavramdır. Birbirini izleyecek şekilde ardı

ardına dizilen veriler tesadüfî iseler birbirini etkilemeyecekler, herhangi bir nedenle tesadüfî değiller ise birbirini etkileyeceklerdir. Bu durum örneğin seçim şeklinden kaynaklanmamakta, verilen verilerin dizilişi ile ortaya çıkmaktadır.

Sıra testinde sayısal büyüklükler dikkate alınmaz. Testin uygulanabilmesi için örneği oluşturan birimlerin başarılı, başarısız; yazı, tura; kusurlu, kusursuz gibi binom ve poisson dağılımlarında olduğu gibi ikili değerler alması veya bu şekilde düzenlenmesi gerekmektedir. Düzenleme, sayısal büyüklüklerin ortalama, medyan gibi bir parametreden büyük veya küçük-eşit olmalarına göre 0 ve 1, + ve – veya herhangi iki harf gibi karakterle ifadesi ile yapılabilir.

Regresyon modellerinden tahmin edilen ve ortalamaları sıfır olan artıkların bir kısmının işareti (+), bir kısmının işareti (-) olacak ve bunlar ard arda bir işaretler dizisi oluşturacaklardır. Bu diziliş için işaretlere göre sıra testi uygulanabilir.

(- - - - - - - -) (+ + + + + + + + + + + + + +) (-) (+) (- - - - - - - - -)

örnek olarak verilebilir. Burada 8 adet eksi kalıntıdan sonra 13 adet artı, daha sonra 1 adet eksi, 1 adet artı, en sonda da 9 adet eksi kalıntı gelmektedir.

n = toplam gözlem sayısı = $n_1 + n_2$

n_1 = (+) işaretlerin sayısı (artı kalıntılar)

n_2 =(-) işaretlerin sayısı (eksi kalıntılar)

k = dizilim sayısı

olmak üzere sıra testi, ortalaması,

$$E(k) = \frac{2n_1 n_2}{n_1 + n_2} + 1 \tag{3.118}$$

ve varyansı;

$$\sigma_k^2 = \frac{2n_1 n_2 (2n_1 n_2 - n_1 - n_2)}{(n_1 + n_2)^2 (n_1 + n_2 - 1)} \tag{3.119}$$

(3.118) ve (3.119) nolu denklem ile ifade edilir ve normal dağılım gösterir.

sıra testinde de diğer testlerde olduğu gibi biri temel, diğeri alternatif hipotez olmak üzere iki hipotez vardır. H_0 temel hipotezi tesadüfiliği, H_1 alternatif hipotezi ise tesadüfi olmamayı ifade etmektedir. H_0 hipotezi ile tesadüfilik kabul edileceğinden önceki değerlerin sonrakilere etkisi olmayacak, yani otokorelasyon olmayacaktır. Aksi halde artıkların birbirini etkilediği, yani otokorelasyon olduğu kararına varılacaktır.

c. Durbin – Watson d Testi

Otokorelasyon olup olmadığını bulmak için en yaygın kullanılan test, Durbin ile Watson tarafından geliştirilen testtir.

$$d = \frac{\sum_{t=2}^{n}(\hat{u}_t - \hat{u}_{t-1})^2}{\sum_{t=1}^{n}(\hat{u}_t)^2} \tag{3.120}$$

(3.120) nolu denklem ile tanımlanmaktadır. Testin mantığı payında yer alan ifade ile açıklanabilir. Payın karesi alınırsa test istatistiği ,

$$d = \frac{\sum_{t=2}^{n}\hat{u}_t^2 + \sum_{t=2}^{n}\hat{u}_{t-1}^2 - 2\sum_{t=2}^{n}\hat{u}_t\hat{u}_{t-1}}{\sum_{t=1}^{n}\hat{u}_t^2} \tag{3.121}$$

(3.121) nolu denklemde belirtildiği gibi olacaktır. Otokorelasyon olmaması durumunda $-2\sum\hat{u}_t\hat{u}_{t-1}$ sıfır olacaktır. Buna karşılık pozitif otokorelasyon olması durumunda $\sum\hat{u}_t\hat{u}_{t-1}$ pozitif olacağından $-2\sum\hat{u}_t\hat{u}_{t-1}$ nedeni ile d test istatistiği küçülecektir. Gözlem sayısı n 'in yeterince büyük olması durumunda,

$$\sum_{t=2}^{n}\hat{u}_t^2 \cong \sum_{t=1}^{n}\hat{u}_t^2 \tag{3.122}$$

olacağından

$$d = 2 - \frac{-2\sum_{t=2}^{n} \hat{u}_t \hat{u}_{t-1}}{\sum_{t=1}^{n} \hat{u}_t^2} \tag{3.123}$$

sırasıyla (3.122) ve (3.123) nolu denklemler elde edilir ve son ifade örnek otokorelasyon katsayısı olduğundan,

$$d = 2 - 2\hat{\rho} = 2(1 - \hat{\rho}) \tag{3.124}$$

(3.124) nolu denklem elde edilmiş olacaktır. Buna göre otokorelasyon olmaması durumunda $\hat{\rho} = 0$ olacağından $d = 2$ olur.

Otokorelasyon katsayısı $-1 \le \rho \le 1$ arasında değer alacağından,

$\rho = 1$ $\quad d = 2(1 - \hat{\rho}) = 0$

$\rho = 0$ $\quad d = 2(1 - \hat{\rho}) = 2$

$\rho = -1$ $\quad d = 2(1 - \hat{\rho}) = 4$

olur.

Hesaplanan d istatistiğinin t ve F testlerinde olduğu gibi bir tablo değeri ile karşılaştırılacağı düşünülebilir. Fakat d test istatistiği, yer alan bağımsız değişken sayısı ve gözlem sayısı yanında, bağımsız değişkenlerin değerlerine de bağlıdır. Bu nedenle d test istatistiğinin dağılımı örnekten örneğe değişmekte ve tam bir dağılım belirlenememekte, ancak farklı yaklaştırmalarla kritik değerler belirlenebilmektedir. Kısaca her bir örnek için belirlenen anlam seviyesine göre farklı kritik değerlerin belirlenmesi gerekmektedir.

Durbin ve Watson pozitif otokorelasyonu,

$H_0 : \rho = 0$

$H_1 : \rho > 0$

hipotezlerini test etmek için kritik alt ve üst sınır değerleri belirlemişlerdir. Hesaplanan bu değerler ile modelin bağımsız değişkenlerinin etkisi kaldırılmıştır. α

hata payı ile oluşturulan alt sınır (d_L) ve üst sınır (d_u) değerleri, hesaplanan d istatistiği ile karşılaştırılarak hipotezlerden biri kabul, diğeri reddedilir.

$d > d_u$ H_0 red, pozitif otokorelasyon yoktur.

$d < d_L$ H_0 reddedilemez, pozitif otokorelasyon vardır.

$d_L < d < d_u$ karar verilemez.

d_L ve d_u değerleri arası kararsız bölge olarak adlandırılır. Bu durumda bazı yardımcı testlerden yararlanılabilir. Fakat bu çözüm kesin değildir.

Pozitif otokorelasyon için belirlenen d_L ve d_u değerleri ile negatif otokorelasyon da test edilebilir.

$H_0 : \rho = 0$

$H_1 : \rho < 0$

hipotezleri için şöyle karar verilir.

$d < 4 - d_u$ H_0 reddedilemez, otokorelasyon yoktur.

$d > 4 - d_L$ H_0 red, otokorelasyon vardır.

$4 - d_u < d < 4 - d_L$ karar verilemez.

Görüldüğü gibi bu durumda da kararsızlık bölgesi vardır. Pozitif ve negatif otokorelasyonun testi için ayrı ayrı verilen karar kuralları alternatif hipotezin çift taraflı olması, yani,

$H_1 : \rho \neq 0$

şeklinde kurularak da otokorelasyon olup olmadığının testi için kullanılabilir.

Durbin-Watson d testi şu durumlarda kullanılamamaktadır:

1. Modelin sabit teriminin olmaması,

2. Bağımsız değişkenler stokastik ise,

3. Hata terimleri birinci dereceden otokorelasyonlu değilse,

4. Bağımsız değişkenler arasında bağımlı değişkenin gecikmeli değeri bulunuyorsa.

d. Durbin-h Testi

Durbin-Watson d testi, daha öncede belirttiğimiz gibi bağımsız değişkenler arasında bağımlı değişkenin gecikmeli değeri yer alıyorsa, geçerli olmamaktadır. Durbin-Watson d testinin tüm koşulları geçerli olup sadece bağımsız değişkenler arasında bağımlı değişkenin gecikmeli değerinin yer alması durumunda Durbin-h testi kullanılmaktadır. Bu test büyük örnekler için geçerlidir.

Durbin-h testinde H_0 temel hipotezi birinci mertebeden otokorelasyon yoktur, H_1 alternatif hipotezi birinci mertebeden otokorelasyon vardır şeklinde kurulur.

$$H_0 : \rho = 0$$

$$H_1 : \rho \neq 0$$

Durbin-h test istatistiğinin dağılımı asimtotik olarak normal dağılım olduğundan, belirlenecek hata payı ile normal dağılım tablosundan tablo değeri bulunur. Normal dağılım tablo değeri $\alpha / 2$ hata payı ile belirlenecektir.

Durbin-h test istatistiği,

$$h = \hat{\rho}\sqrt{\frac{n}{1 - nVar(\hat{\beta})}} \tag{3.125}$$

olarak hesaplanabilir. Burada $Var(\hat{\beta})$ gecikmeli bağımlı değişkenin varyansıdır. Burada $\hat{\rho}$ otokorelasyon katsayısı Durbin-Watson d istatistiği ile,

$$\hat{\rho} = 1 - \frac{d}{2} \tag{3.126}$$

(3.126) nolu denklemden hesaplanır. Test istatistiği,

$$h = \left(1 - \frac{d}{2}\right)\sqrt{\frac{n}{1 - nVar(\hat{\beta})}} \tag{3.127}$$

(3.127) nolu formül ile hesaplanır.

Hesaplanan test istatistiği normal dağılım tablosundan bulunacak $Z_{\alpha/2}$ değeri ile karşılaştırılarak hipotezlerden biri kabul diğeri reddedilecektir.

h, $\pm Z_{\alpha/2}$ aralığında yer alıyorsa H_0 hipotezi reddedilmeyecektir. $h > Z_{\alpha/2}$ ise pozitif, $h < -Z_{\alpha/2}$ ise negatif otokorelasyon olduğu kararına varılacaktır.

e. Berenblut-Webb Testi

Otokorelasyonun düzeltilmesi için başvurulan yöntemlerden biri olan, değişkenlerin ilk farklarının alınmasıyla oluşacak denklemlerde sabit katsayı yer almamaktadır. Bu nedenle ilk farklar yöntemi uygulandıktan sonra oluşacak modellerde otokorelasyon olup olmadığının araştırılması için Durbin-Watson testini uygulamak doğru değildir. Çünkü Durbin-Watson testinin ön koşulu modelin sabit teriminin olmasıdır. Berenblut-Webb testi, ilk farkları alınmış modellerde otokorelasyonun varlığını belirlemek amacıyla kullanılan bir testtir.

Bu testte hipotezler,

$$H_0 : \rho = 0$$

$$H_1 : \rho \neq 0$$

şeklinde oluşturulur. Berenblut-Webb test istatistiği,

$$g = \frac{\sum_{t=2}^{n} \hat{e}_t^2}{\sum_{t=1}^{n} \hat{u}_t^2} \tag{3.128}$$

(3.128) nolu formülden hesaplanmaktadır. Burada $\hat{e}_t^2$, ilk farklar denkleminin artıklarının kareleridir. $\hat{u}_t^2$ ise orijinal denklemin artıklarının kareleridir. Orijinal denklemlerde sabit parametre yer alıyorsa ilk farklar alındıktan sonra hesaplanan g test istatistiği, Durbin-Watson tablosundan bulunacak değerlerle karşılaştırılarak otokorelasyon olup olmadığına karar verilecektir.

f. Breusch-Godfrey Testi:

Bu teste Lagrange Çarpanı (LM) testi adı da verilmektedir. k bağımsız değişkenli regresyon modelinin hata teriminin,

$$u_t = \rho_1 u_{t-1} + \rho_2 u_{t-2} + ... + \rho_p u_{t-p} + e_t \qquad e_t \sim N(0, \sigma^2) \qquad (3.129)$$

(3.129) nolu denklem olduğunu varsayalım. Burada ρ_1 , 1'inci mertebeden; ρ_2 , 2'inci mertebeden; …; ρ_p , p 'inci mertebeden otokorelasyonu ifade etmektedir. Bu durumda hipotezler,

$$H_0 : \rho_1 = \rho_2 = ... = \rho_p = 0$$

$$H_1 : \rho_1 \neq \rho_2 \neq ... \neq \rho_p \neq 0$$

olarak kurulur. Orijinal denklemde gecikmeli bağımlı değişmenin bağımsız değişkenler arasında yer alması durumunda da bu test uygulanabilir.

Test istatistiğinin hesaplanması için orijinal modelden artıklar $(\hat{u}_t)$ tahmin edilir. Bu artıkların bağımlı değişken olduğu orijinal modeldeki bağımsız değişken ile gecikmeli hata teriminin bağımsız değişken olduğu yeni bir model oluşturulur. Hata teriminin gecikme sayısı test edilmek istenen otokorelasyonun sayısal değerine eşittir. Yani kaçıncı dereceden otokorelasyon test edilecek ise o sayıda gecikmeli hata terimine modelde yer verilmektedir. Hipotez,

$$H_0 : \rho_p = 0$$

$$H_1 : \rho_p \neq 0$$

şeklinde kurulmaktadır. Örneğin altıncı mertebeden otokorelasyon inceleniyorsa, birinci devreden altıncı devreye kadar gecikmeli hata terimine modelde yer verilerek,

$$H_0 : \rho_1 = \rho_2 = ... = \rho_6 = 0$$

$$H_1 : \rho_1 \neq \rho_2 \neq ... \neq \rho_6 \neq 0$$

olup olmadığı test edilirken, modelde sadece 6. devre gecikmeli hata terimine yer verilerek,

$$H_0 : \rho_6 = 0$$

olup olmadığı test edilecektir. Yardımcı model,

$$\hat{u}_t = \beta_1 + \beta_2 X_{2i} + ... + \beta_k X_{ki} + \rho_1 u_{t-1} + \rho_1 u_{t-2} + ... + \rho_1 u_{t-p} + v_t \qquad (3.130)$$

(3.130) şeklinde olacaktır. Yardımcı model tahmin edildikten sonra modelde bağımsız değişken olarak yer alan gecikmeli hata terimlerinin katsayılarının tümünün birlikte anlamlılığı F testi ile test edilir. Bu durumda F test istatistiği yerine (3.131) nolu denklem ile büyük örnekler için kullanılan LM test istatistiği,

$$LM = nR^2 \qquad (3.131)$$

olarak da hesaplanabilir. Burada R^2, yardımcı modelin belirlilik katsayısıdır. Test istatistiğinin dağılımı p serbestlik dereceli $ki-kare$ dağılımıdır.

g. King Testi

Aylık veriler için otokorelasyonun varlığının testi söz konusu olduğunda King testi kullanılmaktadır. Bu durumda temel hipotez otokorelasyon yoktur, alternatif hipotez otokorelasyon vardır şeklinde kurulur. Test istatistiği Durbin-Watson testi ile aynıdır. Yalnız aylık veri söz konusu olduğunda 12 gecikme için (3.132) nolu formül ile hesaplanır ve;

$$d_{12} = \frac{\sum_{t=13}^{n} (u_t - u_{t-12})^2}{\sum_{t=1}^{n} u_t^2} \qquad (3.132)$$

şeklinde olur.

Otokorelasyon olup olmadığına karar verilirken Durbin-Watson tablosu yerine King tablolarına bakılır. Modelde sabit katsayı olması, sabit ve doğrusal trendin olması, aylık mevsimsel kukla değişken kullanılması, doğrusal trend olması ve aylık kukla değişkenlerin kullanılması durumları için farklı tablolar düzenlenmiştir. Uygun tablolar seçilerek d_U ve d_L değerleri belirlenir ve otokorelasyon olup olmadığına karar verilir. Aylık veriler için uygulanan bu test büyük örnekler içindir.

h. Von-Neumann Oran Testi

Diğer otokorelasyonun varlığının araştırılması için kullanılan testler, EKK artıkları ile hesaplanmaktadır. Von-Neumann oran testi ise, ardışık artıklar ile hesaplanmaktadır. Test istatistiği,

$$VN = \frac{\delta^2}{S^2} = \frac{\sum_{t=2}^{n}(w_t - w_{t-1})^2 / (n-1)}{\sum_{t=1}^{n}(w_t - \bar{w}_t)^2 / n} \tag{3.133}$$

(3.133) nolu formül ile ifade edilir. Burada w_t ardışık artıkları göstermektedir.

Regresyon modelleri için ardışık artıklar hesaplandığında modelin tahmin edilen parametresi k kadar gözlem kaybolacaktır. Bu nedenle pay kısmında $(n-k-1)$ gözlem, payda kısmında ise $(n-k)$ gözlem yer alacaktır. Bu nedenle test istatistiği,

$$VN = \frac{\sum_{t=k+2}^{n}(w_t - w_{t-1})^2 / (n-k-1)}{\sum_{t=k+1}^{n}(w_t - \bar{w}_t)^2 / n-k} \tag{3.134}$$

(3.134) nolu denklem şeklinde olur. Bu ifadede yer alan ardışık artıkların ortalaması $(\bar{w}_t)$ sıfır olacağından test istatistiği,

$$VN = \frac{\sum_{t=k+2}^{n} (w_t - w_{t-1})^2 / (n-k-1)}{\sum_{t=k+1}^{n} w_t^2 / n-k} \qquad (3.135)$$

(3.135) nolu formül ile hesaplanır. Buradan hesaplanan test istatistiği, Von-Neumann oran tablosundan bulunan değerler ile karşılaştırılır. $(n < 60)$ olduğunda Von-Neumann oran tablosu kullanılırken, $(n > 60)$ olduğunda dağılım, normal dağılıma yaklaşacağından normal dağılım tablosu kullanılacaktır.

Von-Neumann oran tablosundan alt sınır (VN_L) ve üst sınır (VN_U) değerleri bulunur. Hesaplanan VN test istatistiği VN_L ve VN_U değerleri arasında yer alıyorsa, H_0 hipotezi reddedilemez ve otokorelasyon olmadığına karar verilir. Hesaplanan test istatistiği VN_U 'dan büyükse negatif, VN_L 'den küçükse pozitif otokorelasyon söz konusudur. Bu durumda H_0 hipotezi reddedilir.

Von-Neumann oran testinde kararsızlık bölgesi yoktur. Durbin-Watson testi kullanılıp, d test istatistiği kararsız bölgede kaldığında Von-Neumann oran testi alternatif bir test olarak kullanılabilir.

4. Otokorelasyonun Düzeltilmesi

Otokorelasyon testleri ile otokorelasyonun varlığına karar verilirse, otokorelasyonun olumsuz etkilerinin ortadan kaldırılması için çeşitli yöntemler kullanılmaktadır.

a. Birinci Dereceden Farklar Yöntemi

Bu yöntemle, orijinal verilerin birinci farkları alınarak dönüştürülmüş model elde edilmekte ve bu dönüştürülmüş modele EKK yöntemi uygulanmaktadır. Regresyon modeli,

$$Y_t = \beta_0 + \beta_1 X_t + \varepsilon_t$$

ise, Birinci dereceden gecikmesi alınan regresyon modeli,

$$Y_{t-1} = \beta_0 + \beta_1 X_{t-1} + \varepsilon_{t-1} \tag{3.136}$$

(3.136) nolu denklemle ifade edilir. Orijinal regresyon denklemi ve birinci dereceden gecikmesi alınan regresyon modeli birbirinden çıkarılırsa,

$$Y_t = \beta_0 + \beta_1 X_t + \varepsilon_t$$

$$Y_{t-1} = \beta_0 + \beta_1 X_{t-1} + \varepsilon_{t-1}$$

$$Y_t - Y_{t-1} = (\beta_0 - \beta_0) + \beta_1 X_t - \beta_1 X_{t-1} + (\varepsilon_t - \varepsilon_{t-1})$$

ve

$$Y_t - Y_{t-1} = \beta_1 (X_t - X_{t-1}) + (\varepsilon_t - \varepsilon_{t-1}) \tag{3.137}$$

(3.137) nolu denklem olacaktır.

$$Y_t^* = Y_t - Y_{t-1}$$

$$X_t^* = X_t - X_{t-1}$$

$$\varepsilon_t^* = \varepsilon_t - \varepsilon_{t-1}$$

şeklinde tanımlanırsa,

$$Y_t^* = \beta_1 X_t^* + \varepsilon_t^* \tag{3.138}$$

(3.138) nolu denklem modeli elde edilir. Elde edilen bu dönüştürülmüş modele EKK yöntemi uygulanır.

b. Genelleştirilmiş Farklar Yöntemi:

Bu yöntemin kullanılabilmesi için otokorelasyon katsayısı (ρ)'nun bilinmesi gerekmektedir. Birinci dereceden farklar yönteminde değişkenlerden bir önceki dönemlerin değerlerini çıkartarak yapılan dönüşüm bu yöntemde değişkenlerin

değerlerinden bir önceki devre değerinin ρ ile çarpımının çıkartılması ile yapılmaktadır. Model,

$$Y_t = \beta_0 + \beta_1 X_t + \varepsilon_t$$

ise bir önceki devre için model,

$$Y_{t-1} = \beta_0 + \beta_1 X_{t-1} + \varepsilon_{t-1}$$

olacak ve bunun ρ ile çarpımı sonucunda,

$$\rho Y_{t-1} = \rho\beta_0 + \rho\beta_1 X_{t-1} + \rho\varepsilon_{t-1} \qquad (3.139)$$

(3.139) nolu denklem elde edilecektir. Bu modeli orijinal modelden çıkarırsak,

$$Y_t = \beta_0 + \beta_1 X_t + \varepsilon_t$$

$$\rho Y_{t-1} = \rho\beta_0 + \rho\beta_1 X_{t-1} + \rho\varepsilon_{t-1}$$

$$Y_t - \rho Y_{t-1} = \beta_0 - \rho\beta_0 + \beta_1 X_t - \rho\beta_1 X_{t-1} + \varepsilon_t - \rho\varepsilon_{t-1}$$

elde edilir. Modeli düzenlersek,

$$Y_t - \rho Y_{t-1} = \beta_0(1-\rho) + \beta_1(X_t - \rho X_{t-1}) + (\varepsilon_t - \rho\varepsilon_{t-1}) \qquad (3.140)$$

(3.100) nolu model elde edilir.

$$Y_t^{**} = Y_t - \rho Y_{t-1}$$

$$\beta_0^{**} = \beta_0(1-\rho)$$

$$\mathrm{X}_t^{**} = X_t - \rho X_{t-1}$$

$$\varepsilon_t^{**} = \varepsilon_t - \rho\varepsilon_{t-1}$$

olarak tanımlanırsa,

$$Y_t^{**} = \beta_0^{**} + \beta_1^{**} \mathrm{X}_t^{**} + \varepsilon_t^{**} \tag{3.141}$$

(3.141) nolu denklem modeli elde edilir.

Genelleştirilmiş farklar yönteminin uygulanması ile orijinal modelde var olan otokorelasyonun düzelmesi ve bu modelde otokorelasyon olmaması beklenmektedir.

c. Durbin'in İki Aşamalı Yöntemi

Bu yöntemde otokorelasyon katsayısı ρ, genelleştirilmiş fark denklemlerinden yararlanılarak tahmin edilir. (3.4.13) nolu modelin genelleştirilmiş fark denklemi,

$$Y_t - \rho Y_{t-1} = \beta_1(1-\rho) + \beta_2(X_{2t} - \rho X_{2t-1}) + \beta_3(X_{3t} - \rho X_{3t-1})$$

$$= + \ldots + \beta_k(X_{kt} - \rho X_{kt-1}) + (\varepsilon_t - \rho\varepsilon_{t-1}) \tag{3.142}$$

(3.142) nolu denklem şeklinde olacaktır. Burada,

$$Y_t^{**} = Y_t - \rho Y_{t-1}$$

$$\beta_1^{**} = \beta_1(1-\rho)$$

$$\mathrm{X}_{2t}^{**} = X_{2t} - \rho X_{2t-1}$$

$$\mathrm{X}_{3t}^{**} = X_{3t} - \rho X_{3t-1}$$

.

.

$$\mathrm{X}_{kt}^{**} = X_{kt} - \rho X_{kt-1}$$

$$\varepsilon_t^{**} = \varepsilon_t - \rho\varepsilon_{t-1}$$

olarak tanımlanırsa model,

$$Y_t^{**} = \beta_1^{**} + \beta_2^{**} X_{2t}^{**} + \beta_3^{**} X_{3t}^{**} + ... + \beta_k^{**} X_{kt}^{**} + \varepsilon_t^{**} \quad (3.143)$$

(3.100) nolu model oluşturulabilir. Oluşturulan bu modelden ρ, EKK yöntemi ile Y_{t-1}'in katsayısı olarak tahmin edilir. Tahmin edilen bu $\hat{\rho}$ ile genelleştirilmiş farklar yöntemi uygulanır.

d. Cochrane-Orcutt Yöntemi:

Bu yöntemde otokorelasyon katsayısı ρ iterasyonla tahmin edilmektedir. (3.4.80) no'lu regresyon modelinin, artıkları $\hat{u}_t$ elde edilerek,

$$\hat{u}_t = \rho \hat{u}_{t-1} + e_t$$

ilişkisinden,

$$\hat{\rho} = \frac{u_t u_{t-1}}{\sum u_t^2} \quad (3.144)$$

(3.144) formülü ile $\hat{\rho}$ tahmin edilir. Tahmin edilen bu $\hat{\rho}$ değeri, genelleştirilmiş farklar denkleminde yerine konularak genelleştirilmiş farklar denklemi tahmin edilerek otokorelasyonun varlığı araştırılır. Buraya kadar yapılan işlemlerin yeterli olduğu düşünülürse yapılan bu işlemlere *İki Aşamalı Cochrane-Orcutt Yöntemi* adı verilmektedir.

Yapılan işlemlerin yeterli görülmemesi veya otokorelasyonu önlememesi durumunda işlemlere aynı şekilde devam edilebilir. Ardı ardına gelen ρ'lar arasında küçük bir fark kalana kadar işleme devam edilebilir. Bu durumda uygulanan yönteme *Çok Aşamalı Cochrane-Orcutt Yöntemi* denir.

İşleme devam edilecekse,

$$Y_t^{**} = \beta_1^{**} + \beta_2^{**} X_{2t}^{**} + \beta_3^{**} X_{3t}^{**} + ... + \beta_k^{**} X_{kt}^{**} + u_t^{**}$$

tahmin edilerek modelin artıkları u_t^{**} belirlenir. Bu artıklarla,

$$\hat{u}_t^{**} = \rho \hat{u}_{t-1}^{**} + w_t$$

ilişkisinden,

$$\hat{\rho} = \frac{u_t^{**} u_{t-1}^{**}}{\sum u_t^{**2}} \tag{3.145}$$

(3.145) formülü ile $\hat{\rho}$ tahmin edilir ve genelleştirilmiş farklar denkleminde yerine konularak ardı ardına gelen ρ'lar arasındaki fark çok küçülünceye kadar devam edilebilir.

3.2.10. Zaman Serileri Analizi

Zaman serileri, bir dönemden diğerine değişkenlerin değerlerinin ardışık bir şekilde gözlendiği sayısal büyüklüklerdir. Gözlenen verilerin zaman içinde ardışık bir biçimde gerçekleşmesi bir koşul değil fakat düzenli aralıklarla dizinin gelişimini görme açısından gereklidir. Geleneksel istatistiksel analizlerin kullanıldığı tekniklerde zaman serisi gözlemlerinin bir sırasının önemi yoktur. Oysa zaman serileri analizlerinde verilerin sırasının önemi büyüktür (Sevüktekin, 2010).

Zaman serileri analizinin ve modellemesinin iki temel amacı vardır. Birincisi, tek değişkenli zaman serileri analizlerinde tek bir seriye ait gözlemlerin dinamik ve zamana bağlı yapısını anlamaya çalışmak, ikincisi ise, çok değişkenli zaman serileri analizlerinde iki veya daha fazla seri arasında öncelleştirme, geciktirme ve geri besleme ilişkilerini ortaya koymaktır.

Zaman serisi modelleri, ekonometrik modellerden farklıdır, Ekonometrik modeller, değişkenler arasındaki davranışsal ilişkileri ifade ederken, zaman serileri değişkendeki hareketleri, kendi geçmiş değerlerindeki gelişmelerle açıklamaya çalışır. Bir diğer fark, zaman serisi gözlemlerinin birbiri ile korelasyonlu olmasıdır. Zaman serilerinde bir gözlem değerinin gerçekleşmesi diğer gözlem değerinin gerçekleşmesinden bağımsız değildir. Bundan dolayı gözlemlerin birbirleriyle bağımsız olduğu varsayımı altında gerçekleştirilen istatistiksel teknikler zaman serileri için geçerli olmayacaktır (Gürsakal, 2005).

Zaman serileri için olasılık modellerinin diğer bir tanımı stokastik süreçlerdir. Zaman serisi analizlerinin temel amacı bu stokastik (olasılıklı) sürecin özelliklerini ortaya çıkarmak ve bir model kurmaktır (Yıldız, 2009). Genel istatistiksel

yöntemlerde anakütle-örneklem ayırımının zaman serilerindeki karşılıkları gerçekleşme ve süreç kavramlarıdır (Sevüktekin, 2010).

Zaman serileri analizi, dört temel bileşenden meydana gelir. Trend (T), konjonktürel hareketler (C), mevsimsel hareketler (S) ve düzensiz (rassal) (I) hareketlerdir.

Zaman Serisi = f(Trend, konjonktürel hareketler, mevsimsel hareketler, düzensiz hareketler)

$$Y_t = f(T_t, C_t, S_t, I_t) \tag{3.146}$$

denklem (3.146) ile ifade edilebilir. Trend, zaman serisinin uzun dönemdeki eğilimini gösterir. Nüfus artışı, teknolojik değişme, sermaye stokunun büyümesi, zevk ve tercihler, tüketim kalıplarındaki değişmeler gibi etkisi ile seri, uzun dönemde artma veya azalma eğilimi gösterebilir (Özdemir, 2008). Zaman serisinin trend doğrusu veya eğrisi etrafındaki uzun dönem dalgalanmalarına konjonktürel dalgalanmalar denir. Konjonktürel hareketler daha çok ekonominin veya sektörlerin refah ya da durgunluk (ekonomik kriz) dönemlerini içeren değişmelerdir (Sevüktekin, 2010). Zaman serisi eğer kısa zaman aralıklı ise, örneğin aylık veya üç aylık olarak toplanmışsa bu halde mevsimlik değişmeler gözükebilir. Yıllık seriler için bu söz konusu değildir. Belirli faktörler dışında kalan ve varlığı daha önceden tahmin edilemeyen ve etkisini devamlı olarak göstermeyen bazı olayların sonucunda ortaya çıkan değişmelere rassal (düzensiz) değişmeler denir (Ataseven, 2007). Savaş, grev, ekonomik kriz, devalüasyonlar rassal hareketlere örnek olarak verilebilir.

Zaman serilerini durağan ve durağan-dışı olarak ayırabiliriz. Bir zaman serisinin eğer ortalamasında ve varyansında sistematik bir değişme yoksa serinin durağan olduğu kabul edilir. Aksi durumda serinin durağan-dışı olduğu kabul edilir. Genelde zaman serileri durağan-dışı bir eğilim göstermektedir. Durağan-dışı serilere regresyon analizi uygulandığında "sahte regresyon" ilişkisi nedeniyle yanıltıcı sonuçlar vereceği için uygulanmamalıdır. Bu nedenle durağan-dışı zaman serilerine analizler uygulamadan önce serinin durağanlaştırılması gerekir.

Zaman serilerini kesikli ve sürekli zaman serileri olarak sınıflandırmak da mümkündür. Eğer seri, zaman içerisinde sürekli bir biçimde gözlenebiliyorsa sürekli zaman serisi, Yalnızca belirli özel durumlarda gözlenebiliyorsa kesikli zaman serisi olarak adlandırılır. Eğer bir zaman serisi tam olarak öngörülebiliyorsa, deterministik (kesin) zaman serisi, öngörülemiyorsa stokastik (olasılıklı) zaman serisi olarak adlandırılır. Stokastik serilerin tam öngörülerini yapmak mümkün değildir ve ancak gelecekteki değerler, geçmiş değerlerin bir bilgisiyle koşullandırılan bir olasılık dağılımına sahiptirler (Sevüktekin, 2010).

Zaman serileri yöntemi, Box ve Jenkins'in 1976 yılında yayınladıkları "Zaman Serisi Analizi Tahmin ve Kontrol" adlı eserlerinin bu tekniği gün ışığına çıkarmasından bu yana inanılmaz bir hızla gelişti. Bugün sadece iktisat ve finans gibi alanlarda çalışan araştırmacılara yönelik zaman serisi ders kitabı sayısı oldukça fazladır. 1980'lerin sonundan bu yana batı dünyasında özellikle makro iktisat ve finans alanında zaman serisi tekniği kullanımı gittikçe yaygınlaşmıştır ve bu trend devam etmektedir. Bunun en önemli nedenlerinden bir tanesi zaman serisi yöntemi analizi ile daha önce teorik alanda ortaya atılmış birçok modelin sınanması imkânı olmasıdır (Gürsakal, 2005).

3.2.10.1. Otokovaryans Fonksiyonu

Bir zaman serisinin X_t ile X_{t+k} gibi belirli bir k zaman aralığıyla (gecikmesi) birbirinden ayrı iki değer arasındaki ilişkiye otokovaryans, bu ilişkinin derecesini ölçen ve genel olarak $\gamma(k)$ ile gösterilen katsayıya da otokovaryans katsayısı denir. Otokovaryans katsayılarını k gecikmesine bağlayan fonksiyona ise otokovaryans fonksiyonu adı verilir (Özdemir, 2008).

Otokovaryans katsayısı k gecikmesi için,

$$\gamma(k) = Kov(X_t, X_{t+k}) = E\left[(X_t - E(X_t))(X_{t+k} - E(X_{t+k}))\right]$$

veya

$$\gamma(k) = E\left[(X_t - \mu)(X_{t+k} - \mu)\right] \tag{3.147}$$

(3.147) fonksiyonu ile ifade edilir.

3.2.10.2. Otokorelasyon Fonksiyonu

Otokorelasyon fonksiyonu (ACF), Tek değişkenli zaman serisi çözümlemesinde kullanılan en önemli araçlardan biridir. Serinin durağan olup olmadığını ve seri durağan değilse, durağanlığı bozan etkenlerin belirlenmesinde, ARIMA modellerin tanımlama ve uygunluğunun sınanmasında kullanılır.

Bir zaman serisinin X_t ve X_{t+k} k gecikmeli değerleri arasındaki ilişkinin standartlaştırılmış ölçümüne otokorelasyon katsayısı ve bu katsayıların k gecikmesine bağlı olarak ifadesine de otokorelasyon fonksiyonu denir.

$$\rho_x(k) = \frac{E\left[(X_t - \mu_x)(X_{t+k} - \mu_x)\right]}{E\left[(X_t - \mu_x)^2\right]} \qquad k = 0, \pm 1, \pm 2, \ldots$$

veya

$$\rho_x(k) = \frac{\gamma_x(k)}{\sigma_x^2} = \frac{\gamma_x(k)}{\gamma_x(0)} \qquad k = 0, \pm 1, \pm 2, \ldots \tag{3.148}$$

(3.144) fonksiyonu ile ifade edilir.

3.2.10.3. Kısmi Otokorelasyon Fonksiyonu

Kısmi Otokorelasyon Fonksiyonu (PACF), Zamana bağlı bir değişkenin şimdiki değeri X_t'nin, diğer zaman gecikmelerinde etkisi sabit kalmak üzere, önceki X_{t-k} değerleriyle ilişkisini tanımlamada kullanılan ölçüme k gecikmesi için kısmi otokorelasyon katsayısı denir ve ϕ_{kk} ile gösterilir.

Genel olarak, k'ıncı dereceden AR sürecinde j'inci katsayı ϕ_{kj} ve son katsayı da ϕ_{kk} ile gösterilir. ϕ_{kk}'ların denklemler kümesi, Yule-Walker denklemler sistemi (3.149) nolu denklem şeklinde yazılıp çözümlenebilir ve;

$$\rho_j = \phi_{k1} + \phi_{k2}\rho_{j-1} + \ldots + \phi_{k(k-1)}\rho_{j-k+1} + \phi_{kk}\rho_{j-k} \qquad j = 1, 2, \ldots, k \tag{3.149}$$

şeklinde gösterilir. Daha açık olarak (3.150) denklemi şeklinde de yazılır.

$$\begin{aligned}
&\rho_1 = \phi_{k1} + \phi_{k2}\rho_1 + ... + \phi_{kk}\rho_{k-1} \\
&\rho_1 = \phi_{k1}\rho_1 + \phi_{k2} + ... + \phi_{kk}\rho_{k-2} \\
&.... \\
&\rho_k = \phi_{k1}\rho_{k-1} + \phi_{k2}\rho_{k-1} + ... + \phi_{kk}
\end{aligned} \tag{3.150}$$

Çizelge 3.25.'te ACF ve PACF'nin davranış biçimleri belirtilmiştir.

Çizelge 3.25 ACF ve PACF'nin teorik davranışları

Model	ACF	PACF
AR(p)	Azalarak kaybolur	q-gecikme sonra kesilir
MA(q)	p-gecikme sonra kesilir	Azalarak kaybolur
ARMA(p,q)	Azalarak kaybolur ve p-gecikme sonra kesilir	Azalarak kaybolur ve q-gecikme sonra kesilir

3.2.10.4. Otoregresif Süreç: AR(p)

Bir serinin cari değerlerinin geçmiş dönemlerdeki değerleri ile arasındaki doğrusal bağlantı doğru belirlendiğinde, sistemin kalıntıları rassal değişken özelliği taşıyacaktır. Bunu sağlayacak süreç ise "otoregresif" süreç olarak adlandırılmaktadır. Bu bağlamda p'inci mertebeden otoregresif modelde: AR(p) zaman serisi değişkeninin cari değeri, serinin p-dönem geçmiş değerlerin ağırlıklı toplamına artı rassal hata terimine bağlı olarak açıklanmaktadır. p, otoregresif sürecin mertebesidir ve modelde kullanılan serinin geçmiş değerlerinin sayısını göstermektedir.(Akgül, 2003)

p'inci dereceden bir otoregresif sürecin AR(p) istatistiksel modeli;

$$Y_t = \delta + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + ... + \phi_p Y_{t-p} + \varepsilon_t \tag{3.151}$$

(3.151) şeklinde yazılır. Burada δ bir kesme (veya sabit) terimdir ve stokastik süreç olan Y_t'in ortalamasını gösterir iken, $\phi_1, \phi_2, ..., \phi_p$'ler bilinmeyen otoregresif parametrelerdir. Hata terimi ε_t ortalaması sıfır ve sabit σ_ε^2 varyanslı korelasyonsuz rassal değişkenler olarak varsayılır. Diğer bir ifadeyle $\{\varepsilon_t\}$ bir temiz-dizidir (Sevüktekin, 2010).

L, gecikme işlemcisi olmak üzere, AR(p) modeli daha etkin bir şekilde gösterilebilir ve;

$$LY_t = Y_{t-1}$$

$$L^2Y_t = L(LY_t) = LY_{t-1} = Y_{t-2}$$

$$L^kY_t = Y_{t-k} \qquad k = 1, 2, \ldots$$

$$Y_t = \delta + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \ldots + \phi_p Y_{t-p} + \varepsilon_t$$

$$Y_t = \delta + \phi_1 LY_t + \phi_2 L^2 Y_t + \ldots + \phi_p L^p Y_t + \varepsilon_t$$

$$(1 - \phi_1 L + \phi_2 L^2 + \ldots + \phi_p L^p) Y_t = \delta + \varepsilon_t$$

$$\phi(L) Y_t = \delta + \varepsilon_t$$

$$\phi(L) = 1 - \phi_1 L + \phi_2 L^2 + \ldots + \phi_p L^p \qquad (3.152)$$

(3.152) nolu denklem ile ifade edilir. Denklemin sağ tarafındaki $\phi(L)$ polinomu gecikme işlemcisi olarak tanımlanır.

Eğer otoregresif süreç durağan ise ortalaması,

$E(Y_t) = E(Y_{t-1}) = E(Y_{t-2}) = \ldots = \mu$ 'dir.

$$E(Y_t) = E(\delta + \phi_1 Y_{t-1} + \ldots + \phi_p Y_{t-p} + \varepsilon_t)$$

$$\mu = \delta + \phi_1 \mu + \phi_2 \mu + \ldots + \phi_p \mu$$

$$\mu = \frac{\delta}{1 - \phi_1 - \phi_2 - \ldots - \phi_p} \qquad (3.153)$$

(3.153) nolu formül ile ifade edilir. Eğer μ sonlu ise aşağıdaki koşulun gerçekleşmesi gerekir;

$$\phi_1 + \phi_2 + \ldots + \phi_p < 1$$

varyansı,

$$Var(Y_t) = Var(Y_{t-1}) = Var(Y_{t-2}) = ... = \sigma_Y^2 = \gamma_0 \tag{3.154}$$

kovaryansı,

$$\gamma_k = Cov(Y_t, Y_{t-k}) = \phi_1^k \sigma_Y^2 = \phi_1^k \gamma_0 \qquad k = 0,1,2,... \tag{3.155}$$

(3.154) ve (3.155) denklemleri ile ifade edilir. Dönem farkı sabit (k) olacağı için bütün zaman gecikmelerinde k-derece otokovaryanslar da aynı olacaktır (Sevüktekin, 2010).

3.2.10.5. Hareketli Ortalama Süreci: MA(q)

Hareketli ortalama MA(q) süreci, bir zaman serisinin t dönemdeki değerini, rastgele bir değişken olan kalıntı (hata) payının cari ve geçmiş dönem değerlerinin ağırlıklı ortalaması ile ifade edilen bir süreçtir (Ataseven, 2007).

Genel MA(q) süreci için istatistiksel model,

$$Y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + ... + \theta_q \varepsilon_{t-q} \tag{3.156}$$

(3.156) ile ifade edilir. Burada korelasyonsuz rassal kalıntılar ε_t, ortalaması sıfır ve sabit bir varyansa sahiptir. θ_i (i=1,2,…,q) ise bilinmeyen parametrelerdir.

L, gecikme işlemcisi olmak üzere model;

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

$$Y_t = \mu + \varepsilon_t + \theta_1 L\varepsilon_t + \theta_2 L^2 \varepsilon_t + ... + \theta_q L^q \varepsilon_t$$

$$Y_t = \mu + (1 + \theta_1 L + \theta_2 L^2 + ... + \theta_q L^q)\varepsilon_t$$

$$Y_t = \mu + \theta(L)\varepsilon_t$$

$$\theta(L) = 1 + \theta_1 L + \theta_2 L^2 + ... + \theta_q L^q \tag{3.157}$$

(3.157) ile ifade edilir. MA(q) sürecinin ortalaması, zamandan bağımsızdır ve

$$E(Y_t) = \mu$$

olarak ifade edilmektedir. Varyansı,

$$Var(Y_t) = \gamma_0 = E\left[(Y_t - \mu)^2\right] = \sigma_\varepsilon^2(1 + \theta_1^2 + ... + \theta_q^2) \tag{3.158}$$

olarak ifade edilir. Genel olarak k sayıda gecikme için kovaryans,

$$\begin{aligned} &\mathrm{Cov}(Y_t - Y_{t-k}) = \mathrm{E}\left[(Y_t - \mu)(Y_{t-k} - \mu)\right] \\ &= E\left[(\varepsilon_t + \theta_1\varepsilon_{t-1})(\varepsilon_{t-k} + \theta_1\varepsilon_{t-k})\right] = \gamma_k = 0 \end{aligned} \tag{3.159}$$

(3.158) ve (3.159) ile ifade edilir. k>1 olduğu bütün durumlarda kovaryanslar sıfırdır. Bu durumda MA(1) süreci yalnızca bir dönemlik bir belleğe sahiptir. Yani herhangi bir Y_t değeri yalnızca Y_{t-1} ve Y_{t+1} ile korelasyonludur. Fakat diğer zaman serisi gecikmeleriyle herhangi bir korelasyonu söz konusu değildir (Sevüktekin, 2010).

3.2.10.6. Otoregresif Hareketli Ortalama Süreci: ARMA(p,q)

Birçok durağan rassal süreç pür otoregresif veya pür hareketli ortalama süreci ile modellenemez. Bazen zaman serisi her iki süreci birlikte gösterebilir. Başka bir ifadeyle zaman serisi modeli hem AR, hem de MA bileşenleri p ve q'uncu dereceden olmak üzere ARMA(p,q) olarak tanımlanabilir. ARMA modelleri, p mertebeden otoregresif süreç ile q mertebeden hareketli ortalama sürecin bir kompozisyonu olduğundan (p+q) adet parametre içereceğinden, ARMA modellerinde bir zaman serisinin herhangi bir dönemine ait gözlem değeri kendinden önceki belirli sayıdaki gözlem değerleriyle ve hata terimlerinin doğrusal bileşimi olarak açıklanır (Doğan, 2000). İstatistiksel modelin cebirsel gösterimi,

$$Y_t = \delta + \phi_1 Y_{t-1} + ... + \phi_p Y_{t-p} + \varepsilon_t + \theta_1\varepsilon_{t-1} + ... + \theta_q\varepsilon_{t-q} \tag{3.160}$$

şeklinde ifade edilir. (3.160) nolu denklemde kesme terimi δ, Y_t'nin ortalaması ile ilgili iken hatalar ε_t, $E(\varepsilon_t) = 0$ ve varyans $\mathrm{Var}(\varepsilon_t) = \sigma_\varepsilon^2$ ile korelasyonsuz rassal değişkenler olduğu varsayılır. L, gecikme işlemcisi kullanılarak (3.160) nolu denklemin ortalaması, (3.161) ile gösterilir.

$$\phi(L)Y_t = \delta + \theta(L)\varepsilon_t$$

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

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

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

$$\mu = \frac{\delta}{1 - \phi_1 - ... - \phi_p} \qquad (3.161)$$

Sürecin durağan olması için aşağıdaki koşulun sağlanması gerekir:

$$\phi_1 + \phi_2 + ... + \phi_p < 1$$

ARMA(p,q) sürecinin kovaryansı ve otokorelasyon fonksiyonu;

$$\gamma_k = \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2} + ... + \phi_p \gamma_{k-p} \qquad k \geq q+1 \qquad (3.162)$$

$$\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + ... + \phi_p \rho_{k-p} \qquad k \geq q+1 \qquad (3.163)$$

(3.162) ve (3.163) nolu denklemde belirtildiği şekilde yazılabilir.

Çizelge 3.26.'da AR, MA ve ARMA modellerinin otokorelasyon yapısı ve izledikleri süreçler ifade edilmiştir.

Çizelge 3.26. AR, MA ve ARMA Sürecine İlişkin Otokorelasyon Yapısı

Otokorelasyon Yapısı	Süreç
Otokorelasyon fonksiyonunda üssel azalma	AR(p) modeli. p değerini kısmi otokorelasyonun gecikmesi belirler.
Kısmi otokorelasyon fonksiyonunda üssel azalma	MA(q) modeli. Otokorelasyon fonksiyonunun gecikmesi q değerini belirler.
Otokorelasyon ve kısmi otokorelasyon fonksiyonunda üssel azalma	ARMA(p,q) modeli. Otokorelasyon fonksiyonu ve kısmi otokorelasyon fonksiyonunun gecikmeleri p ve q değerlerini verir.
Otokorelasyon ve kısmi otokorelasyon fonksiyonunda tüm değerler sıfır	Seri tesadüfi değişkendir.

Çizelge 3.26. **(devam)**

Belirli aralıklarla otokorelasyon ve kısmi otokorelasyon değerlerinin sıfırdan farklı olması (12., 24. değer gibi)	Mevsimsel otoregresif terim içerir.
Otokorelasyon ve kısmi otokorelasyon değerlerinin sıfıra doğru azalmaması	Durağan değildir.

3.2.10.7. Durağan-dışı Süreçler: ARIMA(p,d,q)

Süreçlerin ortalamasının, varyansının ve kovaryansının zamana bağlı olarak değişmemesi durumunda, başka bir deyişle seriler durağan olduklarında AR(p), MA(q) ve ARMA(p,q) modellerinden biri kullanılabilir (Akgül, 2003). Gerçek hayatta zaman serilerinin birçoğu zaman boyunca değişen belirli bir stokastik sürecin özelliklerini taşıdığından durağan-dışıdır (Sevüktekin, 2010). Bu tür zaman serilerini durağanlaştırmak için serinin bir veya daha fazla farkını alarak bir dönüştürme işlemi uygulanabilir. Farkı alınarak durağanlaştırılmış zaman serileri, "Entegre Süreç" olarak bilinirler.

Herhangi bir Y_t durağan-dışı zaman serisinin bir kere farkı alınırsa,

$$\Delta Y_t = Y_t - Y_{t-1} \tag{3.164}$$

şeklinde ifade edilir. Burada ΔY_t serisi durağan hale gelmiş ise entegre sürecin derecesi (d=1) olarak tanımlanır ve Y_t serisi I(1) dereceden entegre olarak gösterilir. Y_t serisinin farkı alındıktan sonra ΔY_t serisi hala durağan-dışı olmaya devam ediyorsa tekrar farkı alınırsa,

$$\Delta^2 Y_t = \Delta(\Delta Y_t) = (Y_t - Y_{t-1}) - (Y_{t-1} - Y_{t-2}) = Y_t - 2Y_{t-1} + Y_{t-2} \tag{3.165}$$

olur. Burada $\Delta^2 Y_t$ durağan ise entegre sürecin derecesi (d=2) olarak tanımlanır. Başka bir gösterimde ise, L ,bir gecikme işlemcisi olmak üzere

$$\Delta Y_t = Y_t - Y_{t-1} = (1-L)Y_t \tag{3.166}$$

(3.166) şeklinde ifade edilebilir. Burada $\Delta = 1 - L$ 'dir.

(p,d,q)'uncu dereceden bir otoregresif entegre hareketli ortalama süreci veya basitçe ARIMA(p,d,q) süreci, (3.167) nolu modeldeki gibi gösterilebilir.

$$(1-\phi_1 L-\phi_2 L^2-\ldots-\phi_p L^p)\Delta^d Y_t=\delta+\varepsilon_t+\theta_1\varepsilon_{t-1}+\ldots+\theta_q\varepsilon_{t-q} \quad (3.167)$$

3.2.10.8. ARIMA modellerinde Box-Jenkins Model Kurma Stratejisi

Zaman serisi modeli kurmada Box-Jenkins yaklaşımı gerçekleşen verilere en uygun ARIMA veri üretme süreci bulma yöntemidir (Sevüktekin, 2010). Box ve Jenkins yönteminin merkezinde cimrilik (parsimony) prensibi rol oynar. Minimum sayıda parametre ile etkin bir önraporlamayı amaçlamaktadır (Box and Jenkins, 1976).

Box-Jenkins model kurma süreci; modelin belirlenmesi, tahmin edilmesi, ayırt edici kontrol ve önraporlama olmak üzere dört aşamada ele alınabilir.

1. Belirleme: Herhangi bir zaman serisini modellemede ilk yapılması gereken durağan bir seri elde etmek için alınacak fark sayısını bulmaktır. (d)'yi belirlemek için ilk önce orijinal serinin ACF'leri ve PACF'leri hesaplanıp serinin durağan olup olmadığına bakılır. Eğer seri durağan değilse farkı alınır. Bu süreç seri durağan olana değin (d) kere tekrarlanır. Daha sonra farkı alınan seriler için bir AR(p), MA(q) veya ARMA (p,q) modeli belirlenir. ACF ve PACF'ler belli bir noktada kesilmiyorsa bu durumda ARMA modeli uygun olacaktır. AR ve MA bileşenlerinin derecesi, ACF ve PACF kalıplarından çıkarılabilir.

2. Modelin Tahmini: Modelin belirlenmesinden sonra sürecin parametreleri tahmin edilir. Tahminlerin EKK yöntemi ile yapılması durumunda hata terimlerinde görülen otokorelasyon etkisi nedeni ile etkin olmayan ve çok büyük varyansa sahip olan parametre tahminleri elde edileceğinden parametrelerin doğrusal olmayan EKK yöntemi ile tahmin edilmesi uygun olmaktadır. Hata terimleri normal dağılıma sahip olduğunda tahmin yöntemi olarak "Maksimum Olabilirlik" yöntemi de kullanılmaktadır (Akgül, 2003).

3. Ayırt Edici Kontrol: Bir zaman serisi modeli belirlenip parametreleri tahmin edildikten sonra ayırt edici testler yardımıyla yapılan tanımlamanın ne kadar doğru olduğu ortaya konulabilir. İlk aşamada, model tarafından oluşturulan zaman

serisinin ACF'si ile orijinal serinin örneklem ACF'si ile karşılaştırılır. Eğer iki ACF oldukça farklı görünüyorsa modelin geçerliliği üzerinde şüpheyle durulur ve yeniden belirleme aşamasına geri dönülür. Eğer iki otokorelasyon fonksiyonu belirgin bir biçimde farklı değilse, bu durumda modelin kalıntıları analiz edilebilir (Sevüktekin, 2010).

Kalıntılara otokorelasyon fonksiyonu ile kısmi otokorelasyon fonksiyonu uydurulur ve ayrıca otokorelasyonların alt setlerinin birlikte anlamlılığını test eden Box-Pierce veya Ljung-Box istatistiklerinin diğer ismiyle Portmanteau test istatistik değerleri hesaplanır.

3.2.10.9. Portmanteau Testleri: Q istatistikleri

Q-istatistikleri bir grup otokorelasyon katsayısının sıfırdan anlamlı bir şekilde farklı olup olmadığının test edilmesinde kullanılır. Uygulamada en yaygın kullanılan testler, Box-Pierce veya Ljung-Box Q-istatistikleridir.

1. Box-Pierce Q istatistiği

Örneklem otokorelasyonlarını kullanan ve Box ile Pierce tarafından geliştirilen Q-istatistiği,

$$Q_k = T\sum_{j=1}^{k}\left[ACF(j)\right]^2 \tag{3.168}$$

(3.168) ile formüle edilmektedir (Box and Pierce, 1970). Burada T örneklem büyüklüğü ve k gecikme uzunluğudur. Örneklem ilişkisini yansıtan hipotezler aşağıdaki gibi kurulmaktadır.

$$\begin{aligned} &H_0 : ACF(1) = ACF(2) = ... = ACF(3) = 0 \\ &H_1 : ACF(1) \neq ACF(2) \neq ... \neq ACF(3) \neq 0 \end{aligned} \tag{3.169}$$

Sıfır hipotezi, denklem (3.169)'da görüldüğü gibi tüm otokorelasyonların istatistiksel olarak anlamsız olduğunu ileri sürerken, alternatif hipotez en az bir otokorelasyonun anlamlı olduğunu göstermektedir.

Box-Pierce Q-istatistiği kullanıldığında orta büyüklükteki örneklemlerde yapılan çalışmalarda zayıf kalması problemi nedeniyle alternatif bir Portmanteau testi Ljung-Box tarafından önerilmiştir (Sevüktekin, 2010).

2. Ljung-Box Q-istatistiği

$$Q_k = T(T+2)\sum_{j=1}^{k}\frac{\left[ACF(j)\right]^2}{T-j} \tag{3.170}$$

(3.169)'daki formül ile hesaplanır (Ljung ve Box, 1978). Ljung-Box Q istatistiğinin Box-Pierce Q-istatistiğine göre küçük örneklemlerde daha iyi performans sergilemekte ve daha uygun bir χ^2 dağılımı sergilemektedir (Sevüktekin, 2010).

Hipotezler (2.) 'deki gibi ifade edilir ve Box-Pierce Q-istatistiğinde ifade edildiği gibi yorumlanır.

3.2.10.10. Model Seçme Kriteri

1. Akaike Bilgi Kriteri (AIC)

Modeldeki terimlerin sayısını dikkate alarak modelin uyumunun iyiliğini ölçen bir kriterdir (Sevüktekin, 2010). Modele eklenen değişkenlerin yarattığı yükselmeye sınırlama getirerek düzenlenmiştir.

$$AIC = -2\log L + 2m \tag{3.180}$$

denklem (3.180) ile tanımlanır (Akaike, 1973). Burada L olabilirliliği gösterir. $m = p + q$'dur. Bir başka alternatif tanımlama,

$$AIC = T\log\hat{\sigma}_{ML}^2 + 2m \tag{3.181}$$

denklem (3.181) ile yapılır. SSR,hata kareler toplamı olmak üzere, $\hat{\sigma}_{ML}^2 = SSR/T$ 'dir. Benzer bir tanımlama,

$$AIC = T\log(SSR) + 2m \tag{3.182}$$

denklem (3.182) ile de yazılabilir. Alternatif modeller arasında en küçük değeri veren AIC, en uygun model ya da p ve q değerleri olarak seçilir.

AIC, sadece seçili örnek büyüklüğü içinde değil aynı zamanda seçili örnek büyüklüğü dışındaki gelecek tahmini için de geçerlidir. Ayrıca gecikmeli modellerde rahatlıkla kullanılabilir (Ucal, 2006).

2. Schwarz Bilgi Kriteri (SIC)

AIC' ye benzer bir istatistiktir.

$$SIC = T\log\hat{\sigma}_{ML}^2 + m\log T \tag{3.183}$$

$$SIC = T\ln(SSR) + m\ln(T) \tag{3.184}$$

SIC, denklem (3.183) veya (3.184) biçiminde verilir (Schwarz, 1978).

SIC, AIC'ye göre yeni değişkenlerin modele eklendiğinde ortaya çıkacak durumu değerlendirme hususunda daha dikkatli düzenlenmiştir. Ayrıca SIC, her zaman AIC'den daha küçük çıkar (Ucal, 2006). Birçok uygun model arasında seçim yapmada SIC kriteri büyük örneklem özelliğine sahiptir. AIC ve SIC negatif bir değer verebilir (Sevüktekin, 2010).

Alternatif model tahmin sonuçlarını değerlendirmek ve en uygun tahmin modelini seçmek için çizelge 3.27.'de belirtilen kriterlere başvurulmalıdır.

Çizelge 3.27. Model Seçim Kriterleri

Kontrol	Kriter
Parametrelerin t-istatistiği	Anlamlı
Belirleme Katsayısı (R^2)	Yüksek
Modelin F-istatistiği	Anlamlı
Bilgi Kriterleri(AIC, SIC,…)	Düşük
Kalıntı Kareler Toplamı (SSR)	Düşük
Olabilirlik Oranı (LR)	Yüksek
Portmanteau Q-istatistikleri	Anlamsız

3.2.10.11. Önraporlama

Zaman serisi için oluşturulan modelin, tahmin edilip kontrol amaçlı testlerden geçmesinden sonra ileriye dönük öngörü amacıyla kullanılabilir. Öngörü, modelin parametrelerinin doğru olarak belirlendiği varsayılarak yapılmaktadır (Akgül, 2003).

Zaman serileri analizinde amaç mümkün olduğu kadar doğru gelecek değere yakın önraporlar elde etmektir. Bu amacı gerçekleştirmenin bir yolu (3.185) nolu denklemde gösterildiği gibi gerçek ve öngörülen değer arasında ortalama kare hatayı minimum kılmaktır.

$$E_T = \left[(\hat{Y}_{T+h} - Y_{T+h})^2 \right] = \min \tag{3.185}$$

3.2.10.12. Durağanlık

Bir zaman serisinin ortalamasında sistematik bir değişme yoksa (trend yapmıyorsa), eğer varyansında sistematik bir değişme yoksa ve eğer düzenli periyodik değişmeler ortaya çıkarmıyorsa, seri durağandır denir. Durağan bir seride peş peşe gelen iki değer arasındaki fark, zamanın kendisinden kaynaklanmamakta sadece zaman aralığından kaynaklanmaktadır (Kutlar, 2005).

Zaman serilerinin durağanlık koşullarıyla ilgili özelliklerin tümüne veya bir kısmına sahip olması, "zayıf durağanlık", "güçlü durağanlık", ve "kesin durağanlık" olarak adlandırılan farklı durağanlık tanımlamalarının ortaya çıkmasına neden olmaktadır (Akgül, 2003).

Ortalama $E(Y_t) = \mu_Y$ (3.186)

Varyans $Var(Y_t) = \sigma_Y^2 = \gamma_0$ (3.187)

Kovaryans $Cov(Y_t, Y_{t-k}) = \gamma_k$ (3.188)

denklem (3.186), (3.187) ve (3.188)'de belirtilen özelliklere sahip ise zaman serisi *"zayıf durağan"* olarak adlandırılır. Zayıf durağan bir seride, sabit uzun dönem ortalama civarındaki dalgalanmalar ortalama olarak eski haline geri döner, zamanla değişmez sonlu bir varyansa sahiptir ve gecikmelerin uzunluğu arttıkça teorik

otokorelasyonlar azalır. Zaman serisinin zayıf durağanlıkta bahsedilen özelliklere sahip olmasının yanı sıra dağılımının zaman içinde değişmemesi özelliğine de sahip olması durumu *"güçlü durağanlık"* olarak adlandırılmaktadır. Güçlü durağanlık özelliklerine sahip olmasının yanı sıra bileşik dağılımının normal olması durumu ise *"kesin durağanlık"* olarak adlandırılmaktadır (Akgül, 2003).

Özellikle ekonomik zaman serilerinin önemli bir kısmının durağan-dışı olduğu bilinmektedir. Durağanlık için gerekli koşullardan biri veya daha fazlası sağlanamıyorsa seri durağan- dışı kabul edilir.

Bir zaman serisinin durağan-dışılığını ortaya çıkarmanın iki yolu vardır:

1. Serinin zaman yolu grafiğinde ve onun korelogramında ACF ve PACF katsayıları üzerinde yapılan sübjektif yargılara dayanmak.

2. Birim köklerin varlığı için formel istatistiksel testlere başvurmak.

3.2.10.13. Birim Kök Testleri

Bir seride trendin olmadığı ACF değerlerinin yavaşça azalmasından anlaşılır. Seride trendin varlığı, gerçek bir karakter olduğu veya serinin trend-durağan seri olup olmadığı bu fonksiyonun değerlerinden anlaşılır. Ancak bir seride birim kök ve birim köke yakınlık arasındaki farkı ACF değerleri ile fark etmek pek mümkün olmamaktadır. Bunu için daha geliştirilmiş testlerin kullanılması gerekmektedir (Kutlar, 2005).

1. DF Birim Kök Testi

Literatürde en yaygın kullanımı olan birim kök testidir. Monte-Carlo simülasyon çalışmalarına dayanarak hipotezlerde standart t tablosu yerine τ (tau) tablosunu kullanmışlardır (Dickey-fuller, 1979). Standart DF birim kök testi, sadece 1. mertebeden otoregresif süreçlere (AR(1)) uygulanmaktadır.

$$Y_t = \rho Y_{t-1} + e_t \qquad t=1,2,\ldots, \tag{3.189}$$

birinci dereceden otoregresif süreçte, e_t, ortalaması sıfır, varyansı, σ^2 olan bağımsız normal rastgele değişkenlerdir $\left[e_t NID(0,\sigma^2) \right]$.

DF birim kök testi, üç farklı model kalıbı dikkate alınarak test edilmektedir. (3.190)'da kesmesiz ve trendsiz model,

$$Y_t = \rho Y_{t-1} + \varepsilon_t \qquad t=1,2,\ldots. \qquad (3.190)$$

(3.191)'de kesmeli ve trendsiz model,

$$Y_t = \mu + \rho Y_{t-1} + \varepsilon_t \qquad t=1,2,\ldots. \qquad (3.191)$$

(3.192)'de kesmeli ve trendli model,

$$Y_t = \mu + \beta t + \rho Y_{t-1} + \varepsilon_t \qquad t=1,2,\ldots. \qquad (3.192)$$

olarak ifade edilir (Dickey ve Fuller, 1979). Üç modelde de $Y_0 = 0$ kabul edilmiştir.

Y_t'nin durağanlığını araştırmak için kurulacak hipotez,

$H_0 : |\rho| \geq 1$

$H_1 : |\rho| < 1$

şeklinde olacaktır. Eğer sıfır hipotezi kabul edilirse, Y_t serisi durağan-dışı kabul edilir.

1, 2 ve 3. modelin birinci farkı alınırsa,

$$\Delta Y_t = \delta Y_{t-1} + \varepsilon_t \qquad (3.193)$$

$$\Delta Y_t = \mu + \delta Y_{t-1} + \varepsilon_t \qquad (3.194)$$

$$\Delta Y_t = \mu + \beta t + \delta Y_{t-1} + \varepsilon_t \qquad (3.195)$$

(3.193), (3.194) ve (3.195) nolu denklemler elde edilir. Δ, fark alma operatörü, $\delta = \rho - 1$ olur. Hipotezler ise,

$H_0 : \delta = 0 (\rho = 1)$

$H_1 : \delta < 0 (\rho < 1)$

şeklinde olur. 1. model için τ-istatistiği, 2. model için τ_μ-istatistiği, 3. model için τ_τ-istatistiği kritik değerleri kullanılır. Eğer test istatistiği $t_{\hat{\delta}} > \tau$ ise seri durağan-dışıdır.

2. ADF Birim Kök Testi

Dickey-Fuller tarafından geliştirilen birim kök testleri yalnızca birinci-dereceden otoregresif süreçlere uygulanmaz. Daha yüksek dereceden otoregresif süreçlere de DF testlerini uygulamak mümkündür (Sevüktekin, 2010).

Y_t gibi bir zaman serisi $AR(p)$ süreci izlerken, $AR(1)$ süreci olarak ele alındığında, Y_t'nin dinamik yapısının yanlış tanımlanmasından dolayı hata terimi otokorelasyonlu olacaktır. Otokorelasyonlu hata terimi, hata teriminin saf rastsal olduğu varsayımına dayanan DF dağılımının kullanımını geçersiz kılar (İğde, 2010).

DF testinde dikkate alınan üç model kalıbı, bağımlı değişkenin gecikmeli değerleri modele dahil edilerek, ADF regresyonları,

$$\Delta Y_t = \delta Y_{t-1} + \sum_{j=1}^{p} \delta_i \Delta Y_{t-j} + \varepsilon_t \tag{3.196}$$

$$\Delta Y_t = \mu + \delta Y_{t-1} + \sum_{j=1}^{p} \delta_i \Delta Y_{t-j} + \varepsilon_t \tag{3.197}$$

$$\Delta Y_t = \mu + \beta t + \delta Y_{t-1} + \sum_{j=1}^{p} \delta_i \Delta Y_{t-j} + \varepsilon_t \tag{3.198}$$

(3.196), (3.197) ve (3.198) modelleri, DF denklemlerinin bağımlı değişkenin gecikmeli değerlerinin modele dâhil edilmesi ile genişletilmiş halidir. Dolayısıyla bu denklemlere de DF testini uygulamak mümkündür.

Bağımlı değişkenin gecikmeli değerlerinin başlangıçtaki DF denklemlerine ekstra terim olarak eklenmeleri bu denklemleri artırmaktadır. Bu yaklaşım sonucunda kalıntılardaki otokorelasyon ortadan kaldırılmış olacaktır. Modele yanlış gecikme dahil edilmesi, yapılacak testlerin gücünü azaltır. Seçilecek p-gecikme olması gerekenden büyük seçilirse tahminler eğilimli olacaktır. Birim kök testi uygulamak için kullanılacak bir denklemde gecikme sayısı (p)'nin ne olacağını belirlemek için genelde Akaike bilgi kriteri (AIC) ile Schwarz bilgi kriteri (SIC) kullamılır. Kalıntıların otokorelasyonlu olup olmadığını ortaya koymak için Breusch-Godfrey veya Lagrange çarpanları (LM) testleri uygulanabilir (Sevüktekin, 2010).

3. Phillips-Perron Birim Kök Testi

DF birim kök testi, rassal hataların (şokların) dağılımının istatistiksel olarak bağımsız ve sabit varyanslı olduğu rassal hatalar (şoklar) arasında otokorelasyon olmadığını varsaymaktadır. Phillips-Perron, DF tarafından geliştirilen bu varsayımı geliştirerek rassal şokların dağılımları ile ilgili yeni bir varsayımda bulunmaktadırlar. PP birim kök testi, DF test sürecine düzeltme faktörünün eklenmesine dayanmaktadır (Phillips ve Perron, 1988).

Phillips-Perron birim kök testi, ADF testinde olduğu gibi yardımcı regresyonların, kesmesiz ve trendsiz, kesmeli ve trendsiz ve kesmeli ve trendli olmasına göre yeniden düzenlenmektedir (Sevüktekin, 2010).

PP birim kök testi için kullanılabilecek en basit AR(1) süreci;

$$Y_t = \phi_1 Y_{t-1} + \varepsilon_t \tag{3.199}$$

(3.199) ile gösterilir. PP testi için kullanılan formül (3.200)'de gösterilmiştir;

$$Z_\alpha = T(\hat{\phi}_1 - 1) - CF \tag{3.200}$$

Burada, CF (Correction Factor), düzeltme faktörüdür. Düzeltme faktörü aşağıdaki şekilde hesaplanmaktadır.

$$CF = \frac{0.5(S_{T\ell}^2 - S_\varepsilon^2)}{\sum_{t=2}^{T}(Y_{t-1} - \bar{Y}_{-1})^2 / T^2} \tag{3.201}$$

Denklem (3.201)'de ilk olarak hesaplanan kısım σ_ε^2 hata teriminin varyansıdır. Ancak varyans hesaplanamadığından tutarlı tahmincisi (3.202)'deki şekilde hesaplanmaktadır.

$$S_\varepsilon^2 = T^{-1}\sum_{t=1}^{T}\hat{\varepsilon}_t^2 \tag{3.202}$$

Benzer olarak σ^2 uzun dönem varyans faktörü için de tutarlı tahminci hesaplanmalıdır.

$$S_{T\ell}^2 = S_\varepsilon^2 + 2\sum_{s=1}^{\ell} w_{s\ell} \sum \hat{\varepsilon}_t \hat{\varepsilon}_{t-s} / T \tag{3.203}$$

Denklem (3.203)', S_ε^2, σ_ε^2'nin bir tahmincisidir ve $S_{T\ell}^2$ uzun dönem varyans tahmincisidir. Ayrıca,

$$w_{s\ell} = 1 - s/(\ell + 1) \tag{3.204}$$

$$\bar{Y}_{-1} = \sum_{t=2}^{T} Y_t / (T-1) \tag{3.205}$$

$$\hat{\varepsilon}_t = Y_t - \hat{\phi}_1 Y_{t-1} \tag{3.206}$$

(3.204), (3.205) ve (3.206)'daki gibi hesaplanmaktadır.

4. KPSS Birim Kök Testi

Kwiatkowski, Phillips, Schmidt ve Shin tarafından önerilen KPSS birim kök testi, serideki deterministik trendin arındırılarak serinin durağanlaştırılmasını amaçlamaktadır (Kwiatkowski ve ark., 1992). Test, artıkların uzun dönem varyansının nonparametrik tahmincisine dayanmaktadır (Güvenek ve ark., 2010).

KPSS testinde kurulan birim kök hipotezi ADF testleri için kurulan hipotezlerden farklılık gösterir. Sıfır hipotezi serinin durağan olduğunu buna karşın alternatif hipotez ise seride birim kök olduğunu ima eder. Temel hipotezin testi için Lagrange Multiplier (LM) istatistiğini önermişlerdir (Yavuz, 2004). Sıfır hipotezindeki durağanlık temelde trend durağanlığı göstermektedir. Trendden arındırılan serideki birim kök olmama, serinin aslında trend durağanlığı gösterir (Sevüktekin, 2010).

$$Y_t = \beta t + w_t + \varepsilon_t \tag{3.207}$$

$$w_t = w_{t-1} + u_t$$

Denklem (3.207)'de, w_t, modelin rassal yürüyüşü, t, deterministik trendi, ε_t ise durağan hataları göstermektedir. Ayrıca $u_t \sim IID(0, \sigma_u^2)$'dur. Durağanlık hipotezi

u_t'nin varyansının sıfır olduğunu varsayar. KPSS testi için sıfır hipotezi zaman serisinin trend durağan olduğunu (birim kök yoktur) buna karşın alternatif hipotez ise zaman serisinin durağan olmadığını (birim kök vardır) ima eder.

KPSS test istatistiğinin hesaplanmasında ilk aşamada Y_t kesme ve trend üzerine regrese edildikten sonra elde edilen kalıntılar (ε_t) için (3.208)'de görüldüğü gibi kısmi süreç toplamı hesaplanır.

$$S_t = \sum_{t=1}^{T} \varepsilon_t \tag{3.208}$$

Eğer seride deterministik trend yoksa (ε_t), Y_t'in sadece kesme üzerine regresesi ile elde edilir. LM istatistiği aşağıdaki gibi hesaplanır.

$$LM = \sum_{t=1}^{T} S_t^2 / \hat{\sigma}_\varepsilon^2 \tag{3.209}$$

(3.209) nolu modelde, $\hat{\sigma}_\varepsilon^2$, ($\varepsilon_t$)'nin varyansıdır. $\hat{\sigma}_\varepsilon^2$, (3.210)'daki gibi hesaplanır.

$$\hat{\sigma}_\varepsilon^2 = \sum \varepsilon_i^2 / T \tag{3.210}$$

Ancak kalıntılar birbirleri ile otokorelasyonlu olabilirler. Bu nedenle $\hat{\sigma}_\varepsilon^2$'nin bir tutarlı tahmini, $S^2(\ell)$, hataları yardımı ile hesaplanabilir. Test istatistiği yeniden düzenlenerek denklem ((3.211)'de göründüğü şekilde olacaktır.

$$LM = \sum_{t=1}^{T} S_t^2 / S^2(\ell) \tag{3.211}$$

$S^2(\ell)$, (3.212)'deki gibi bulunur.

$$S^2(\ell) = \mathrm{T}^{-1} \sum_{t=1}^{T} \varepsilon_t^2 + 2\,\mathrm{T}^{-1} \sum_{s=1}^{\ell} w(s,\ell) \sum_{t=s+1}^{T} \varepsilon_t \varepsilon_{t-s} \tag{3.212}$$

$w(s,\ell)$, opsiyonal ağırlıklandırılmış fonksiyondur.

$$w(s,\ell) = 1 - s/(\ell+1) \tag{3.213}$$

denklem (3.213)'te beliritilen şekilde hesaplanır. KPSS test istatistiği (3.214)'te belirtilen şekilde elde edilir.

$$(KPSS)\hat{\eta}_{\mu} = T^{-2}\sum_{t=1}^{T} S_t^2 / S^2(\ell) \tag{3.214}$$

Eğer deterministik kısım olsaydı bu durumda $\hat{\eta}_{\mu}$ yerine $\hat{\eta}_{\beta}$ hesaplanır. Hesaplanacak değer simülasyon sonucu elde edilecek kritik değer ile karşılaştırılarak serinin yapısında birim kök olup olmadığına karar verilir (Sevüktekin, 2010).

3.2.10.14. Yapısal Kırılmalı Birim Kök Testleri

Makroekonomik değişkenlere ait zaman serilerinde herhangi bir dönemde başlayan ve belli bir süre etkisini sürdüren değişimler yapısal kırılma olarak adlandırılmaktadır. Makroekonomik değişkenler analiz dönemi içindeki politik sebepler, afetler, savaşlar, krizler ve teknolojik değişikliklerden etkilenirler ve bu etkiler seride yapısal kırılmalara neden olur (Elma, 2008).

Yapısal kırılmaları dikkate almayan testler, seride sapmaya, değişkenler arasında sahte regresyona neden olur. Bu sorunları ortadan kaldırmak için serideki yapısal kırılmaları dikkate alan testler geliştirilmiştir (Elma, 2008). Serilerde yapısal kırılma, sahte birim kök sürecine neden olduğundan birim kök testlerinin yanında yapısal kırılma testlerinin yapılması gerekmektedir (Barışık ve Çevik, 2008).

Literatürde yapısal kırılmaları dikkate alarak geliştirilmiş birçok birim kök testi söz konusudur. Bu testler, kırılma zamanının bilinmesi, bilinmemesi, kırılmanın tekli, ikili ve çoklu olmasına göre çeşitlilik göstermektedir (Yıldırım, 2010).

Uygulamada Perron (1989), Zivot-Andrews (1992), Perron (1997) ve Lumsdaine-Papell (1997) en sık kullanılan yapısal kırılmayı dikkate alan birim kök testleridir.

1. Perron (1989) Birim Kök Testi

Nelson ve Plosser 1982'deki çalışmasında Amerika'daki makroekonomik zaman serilerinin durağan olmadığını ortaya koymuşlardır. Ancak Perron 1989'da Amerika'daki birçok makroekonomik zaman serilerinin aslında belirli bir zamanda trend fonksiyonunun düzey (kesme) ve/veya eğiminde (trendde) görülen değişim (kırılma) dikkate alındığında, serilerin değişen bir deterministik trend fonksiyonu etrafında durağan olarak modellenebileceğini göstermiştir (Sevüktekin, 2010).

Perron (1989) yaklaşımı, zaman serisinde yapısal kırılmanın tek bir noktada olduğu ve bu kırılma zamanının (TB) varsayımını dikkate alarak dönüştürülen DF birim kök testini kullanır. Perron, 1929 büyük buhran ve 1973 petrol krizinin makroekonomik değişkenler üzerinde kalıcı bir etkiye sebep olduklarını belirtmiştir (Perron, 1989). Ayrıca 1929'dan sonra trend fonksiyonunun sabitinde ve 1973'den sonra trend fonksiyonun eğiminde tek bir kırılmaya sahip makroekonomik değişkenlerin trend durağan olduklarını ifade etmiştir.

Perron (1989) birim kök testi, yapısal kırılma noktasının tek olduğu ve bu kırılma noktasının bilindiği varsayımına dayanmaktadır. Perron (1989) testinin uygulanmasında kırılma noktası dışsal (egzojen) olarak belirlenmektedir. Ancak bu test, yapısal kırılmanın birden fazla olduğu durumlarda, kırılma noktasının bilinmediği ve trend fonksiyonunun doğrusal olmadığı durumlarda kullanılamamaktadır (Dilişen, 2007).

Perron (1989) birim kök testi, temel hipotez olarak üç farklı model öne sürmüştür.

Model (A): $$Y_t = \mu + dD(TB)_t + Y_{t-1} + e_t \quad (3.215)$$

Model (B): $$Y_t = \mu_1 + Y_{t-1} + (\mu_2 - \mu_1)DU_t + e_t \quad (3.216)$$

Model (C): $$Y_t = \mu_1 + Y_{t-1} + dD(TB)_t + (\mu_2 - \mu_1)DU_t + e_t \quad (3.217)$$

(3.215), (3.216) ve (3.217) nolu modellerde, Model (A), serinin düzeyindeki değişmeyi ifade eder ve Perron tarafından "Crash Model" olarak adlandırılır. Model (B), serinin eğimindeki değişmeyi ifade eder ve "Changing Model" olarak

adlandırılır. Model (C) ise serinin hem düzeyinde hem de eğiminde değişmeyi ifade eder.

(3.218) nolu denklemde, Kırılma zamanı (T_B) ile gösterilecek olursa serideki kırılma zamanı ($1 < T_B < T$) ifade eder ve önceden bilindiği varsayılır.

$$D(TB)_t = \begin{cases} 1 & t = T_B + 1 \\ 0 & t \neq T_B + 1 \end{cases} \qquad DU_t = \begin{cases} 1 & t > T_B \\ 0 & t \leq T_B \end{cases} \tag{3.218}$$

Alternatif Hipotezler ise, (3.219), (3.220) ve (3.221) nolu modellerde gösterildiği gibidir.

Model (A): $$Y_t = \mu_1 + \beta t + (\mu_2 - \mu_1)DU_t + e_t \tag{3.219}$$

Model (B): $$Y_t = \mu + \beta_1^t + Y_{t-1} + (\beta_2 - \beta_1)DT_t^* + e_t \tag{3.220}$$

Model (C): $$Y_t = \mu + \beta_1^t + (\mu_2 - \mu_1)DU_t + (\beta_2 - \beta_1)DT_t^* + e_t \tag{3.221}$$

$$DT_t^* = \begin{cases} t - T_B & t > T_B \\ 0 & t \leq T_B \end{cases}$$

Yukarıda belirtilen modellerde, $(\mu_2 - \mu_1)$, düzey değişimini, $(\beta_2 - \beta_1)$ ise eğim değişimini ifade etmektedir.

Perron (1989), ADF birim kök testine ilişkin regresyona gölge değişkenler ekleyerek söz konusu üç modeli geliştirmiştir.

$$Y_t = \mu + \beta t + \alpha Y_{t-1} + \sum_{i=1}^{k} c_i Y_{t-i} + \varepsilon_t \tag{3.222}$$

Temel ve alternatif hipotezler altında, (3.222) nolu denkleme gölge değişkenler eklenerek oluşturulan regresyonlar (3.223), (3.224) ve (3.225) nolu modellerde gösterildiği gibi ifade edilir;

$$Y_t = \mu^A + \theta^A DU_t + \beta^A t + d^A \,\mathrm{D(TB)}_t + \alpha^A Y_{t-1} + \sum_{i=1}^{k} c_i \Delta Y_{t-i} + \varepsilon_t \tag{3.223}$$

$$Y_t = \mu^B + \theta^B DU_t + \beta^B t + \gamma^B DT_t^* + \alpha^B Y_{t-1} + \sum_{i=1}^{k} c_i \Delta Y_{t-i} + \varepsilon_t \quad (3.224)$$

$$Y_t = \mu^C + \theta^C DU_t + \beta^C t + \gamma^C DT_t + d^C \, \mathrm{D(TB)}_t + \alpha^C Y_{t-1} + \sum_{i=1}^{k} c_i \Delta Y_{t-i} + \varepsilon_t \quad (3.225)$$

Temel hipotez altında Model (A), (B) ve (C)'nin elde edilmesi için parametrelere getirilen kısıtlamalar (3.226), (3.227) ve (3.228) nolu denklemlerde gösterilmiştir;

Model (A): $\alpha^A = 1, \beta^A = 0, \theta^A = 0$ (3.226)

Model (B): $\alpha^B = 1, \gamma^B = 0, \beta^B = 0$ (3.227)

Model (C): $\alpha^C = 1, \gamma^C = 0, \beta^C = 0$ (3.228)

Trend durağan sürecin alternatif hipotezleri altında ise; $\alpha^A, \alpha^B, \alpha^C < 1$; $\beta^A, \beta^B, \beta^C \neq 0$ ve $\theta^A, \theta^C, \gamma^B, \gamma^C \neq 0$ olması beklenmektedir. Temel hipotez altında d^A, d^C ve θ^B'nin sıfırdan anlamlı derecede farklı olması beklenirken, alternatif hipotezin sıfıra yakın olması istenmektedir.

Perron (1989) çalışmasında kırılmaların ya ani ya da kademeli olarak gerçekleştiği varsayımına dayanan iki yöntem ileri sürmüştür. Bu yöntemler toplamsal sapmalı (Additive Outlier) model ve kademeli sapmalı (Innovation Outlier) modeldir. Toplamsal sapmalı modelde kırılma zamanında anlık toplamsal bir etki vardır. Yani kırılmanın tamamının bir defada toplamsal olarak gerçekleştiği düşünüldüğünde toplamsal sapmalı modele başvurulur. Herhangi bir zaman serisinde ekonomik şokların yarattığı yapısal kırılmalar kademeli sapmalar biçiminde görülebilir. Başka bir ifadeyle seride şokların etkisiyle ortaya çıkan yapısal kırılma toplamsal sapmalı modelde olduğu gibi tek bir dönemde değil farklı dönemlerde aşamalı olarak ortaya çıkabilir.

Perron (1989) testi aşağıdaki adımlardan oluşur:

1. İlk olarak serinin grafiği incelenerek, hangi modele uygun olabileceğine karar verilir ve model oluşturulur.

2. Alternatif hipotez altında oluşturulan model, EKK yöntemi ile tahmin edilir. Tahmin sonucu elde edilen artıklar, trendden arındırılmış seriyi göstermektedir.

3. Artıklar, $e_t = y_t^i$ olarak tanımlandığında uygun test denklemi, ω_t'nin sıfır ortalama ve sabit varyanslı olma varsayımı altında (3.229)'da gösterilmiştir.

$$Y_t^i = \phi Y_{t-1}^i + \omega_t \tag{3.229}$$

Burada ω_t modelin hatalarını göstermektedir. Hipotezler ise aşağıdaki gibidir:

$H_0 : \phi = 1$

$H_1 : \phi < 1$

H_0 hipotezinin kabul edilmesi, trendden arındırma işleminin seriyi durağan hale getirmediğini, alternatif hipotezin kabul edilmesi ise trendden arındırma işleminin seriyi durağan hale getirdiğini ifade etmektedir.

4. Test istatistiği,

$$\tau = \frac{\hat{\phi} - 1}{sh(\hat{\phi})} \tag{3.230}$$

(3.230)'daki formül ile hesaplanır. Burada $\hat{\phi}$, modele ait parametre tahmini, $sh(\hat{\phi})$ ise parametre tahmininin standart hatasıdır. Hesaplanan test istatistik değeri, Perron (1989) tarafından hesaplanan kritik değer ile karşılaştırılır. Tablo kritik değerlerinin bulunmasında $[0-1]$ aralığında değer alan λ değerinden yararlanılır. λ değeri kırılma öncesi gözlem sayısının tüm gözlem sayısına oranıdır.

5. Karar aşamasında, hesaplanan test istatistik değerinin, Perron (1989) tablo kritik değerinden daha negatif olması durumunda, H_0 hipotezi reddedilmekte, aksi durumda H_0 hipotezi reddedilememektedir. H_0 hipotezinin reddedilmesi ile seride birim kökün bulunmadığı, analiz edilen serinin kırıklı bir trend doğrusu etrafında

durağan olduğu ve şokların geçici etkiye sahip oldukları, aksi halde ise serinin stokastik trende sahip olduğu sonucuna ulaşılır (Elma, 2008).

2. Zivot-Andrews (1992) Birim Kök Testi

Perron (1989) çalışmasında zaman serilerinde yapısal kırılmanın tek bir noktada gerçekleştiği ve kırılma zamanının (T_b) olarak bilindiği varsayımı Zivot-Andrews (1992) çalışmasında geliştirilerek kırılma zamanının bilinmediği varsayımı gibi yeniden ele alınmıştır. Perron (1989)'da kırılma zamanı egzojen (dışsal) olarak modele eklenirken, Zivot-Andrews (1992) yaklaşımında kırılma zamanı model tarafından endojen (içsel) olarak tahmin edilmektedir. Zivot-Andrews'a göre Perron (1989) 'daki gibi kırılma zamanı egzojen olarak alınırsa hipotez testlerinin sonuçları birim kökün reddi lehine değişecektir (Sevüktekin, 2010).

Zivot-Andrews (1992)'in her üç model için temel hipotez (3.231)'deki gibidir;

$$Y_t = \mu + Y_{t-1} + e_t \tag{3.231}$$

Alternatif hipotezler ise (3.232), (3.233) ve (3.234) nolu modellerde ifade edildiği gibidir;

Model (A) $$Y_t = \hat{\mu}^A + \hat{\theta}^A DU_t(\hat{\lambda}) + \hat{\beta}^A t + \hat{\alpha}^A Y_{t-1} + \sum_{j=1}^{k} \hat{c}_j^A \Delta Y_{t-j} + \hat{e}_t \tag{3.232}$$

Model (B) $$Y_t = \hat{\mu}^B + \hat{\beta}^B t + \hat{\gamma}^B DT_t^*(\hat{\lambda}) + \hat{\alpha}^B Y_{t-1} + \sum_{j=1}^{k} \hat{c}_j^B \Delta Y_{t-j} + \hat{e}_t \tag{3.233}$$

Model (C) $$Y_t = \hat{\mu}^C + \hat{\theta}^C DU_t(\hat{\lambda}) + \hat{\beta}^C t + \hat{\gamma}^C DT_t^*(\hat{\lambda}) + \hat{\alpha}^C Y_{t-1} + \sum_{j=1}^{k} \hat{c}_j^C \Delta Y_{t-j} + \hat{e}_t \tag{3.234}$$

$$DU_t(\lambda) = \begin{cases} 1 & t > T_B \\ 0 & t \le T_B \end{cases} \quad \text{ve} \quad DT_t^*(\lambda) = \begin{cases} t - T\lambda & t > T\lambda \\ 0 & t \le T_B \end{cases} \tag{3.235}$$

$\lambda = T_B / T$ olmak üzere kırılma zamanları (3.235)'teki gibi ifade edilmektedir (Zivot ve Andrews, 1992).

Zivot-Andrews (1992) yaklaşımında kırılma, zamanın herhangi bir noktada olduğu varsayılmaktadır. (λ)'nın değeri $2/T$'den $(T-1)/T$'ye kadar değişebilmektedir. Diğer bir anlamda genel olarak 0.001 ile 0.999 değerleri aralığında minimum t-istatistiğini bulmak için $(T-2)$ adet regresyon modeli tahmin edilmesi gerekir (Sevüktekin 2010).

Zivot-Andrews testinin uygulamasında öncelikle Model (C) tahmin edilmekte DU_t ile DT_t^* gölge değişkenlerine ait parametrelerin anlamlılığına uygun model seçilmektedir. DU_t ile DT_t^* gölge değişkenlerinin her ikisi de istatistiksel açıdan anlamlı iseler Model (C), sadece DU_t anlamlı ise Model (A) ve nihayet sadece DT_t^* anlamlı ise Model (B) 'nin tahmini uygundur. Yukarıdaki 1., 2. ve 3. no'lu modelden hangisinin daha üstün olduğu konusunda fikir birliği yoktur. Ancak uygulamada genellikle Model (A) ve Model (C) kullanılmaktadır. Diğer birim kök testlerinde olduğu gibi bu test de gecikme uzunluğuna duyarlıdır (Yavuz, 2006).

Zivot-Andrews testine göre birim kökün varlığı Y_{t-1}'in katsayısının istatistiksel açıdan anlamlılığı ile test edilir. Eğer t-istatistiği Zivot ve Andrews'in kritik değerinden daha büyükse (mutlak değer), ilgili değişkenin durağan olmadığı temel hipotezi reddedilir (Yavuz, 2006).

3. Lumsdaine-Papell (1997) Birim Kök Testi

Uzun süreli makro iktisadi serilerin tek kırılmalı birim kök testleriyle durağanlığının sınanması elde edilen sonuçların hatalı olmasına neden olabilmektedir. Böyle serilerde iki kırılma olması halinde Zivot-Andrews birim kök testinin gücü azalmaktadır. Bu nedenle Lumsdaine- Papell (1997), seride iki kırılmaya izin veren bir birim kök testi geliştirmişlerdir (Yılancı, 2009).

Lumsdaine- Papell (1997)'in geliştirmiş oldukları, farklı bilinmeyen zamanlar için deterministik trendde iki kırılmaya izin veren testin istatistikleri (3.236) denklemi yardımıyla hesaplanır. Zivot-Andrews testindeki modeller iki kırılmaya izin verip genişletilerek Model AA ve Model CC modeli olarak adlandırılmaktadır (Lumsdaine ve Papell, 1997). Model AA sadece düzeyde iki kırılmaya izin verirken,

Model CC hem düzeyde hem de eğimde iki kırılmaya izin vermektedir.

$$\Delta Y_t = \mu + \beta t + \theta DU1_t + \gamma DT1_t + \omega DU2_t + \psi DT2_t + \alpha Y_{t-1} + \sum_{i=1}^{k} c_i \Delta Y_{t-i} + \varepsilon_t \qquad (3.236)$$

$t = 1, \ldots T$

(3.237) ve (3.238)'de, $DU1_t$ ve $DU2_t$ sırasıyla $TB1$ ve $TB2$ zamanlarında serinin ortalamasında meydana gelen kırılmalar için $DT1_t$ ve $DT2_t$ ise trenddeki kırılmalar için kullanılan gölge değişkenlerdir.

$$DU1_t = \begin{cases} 1 & t > TB1 \\ 0 & t \le TB1 \end{cases} \quad \text{ve} \quad DU2_t = \begin{cases} 1 & t > TB2 \\ 0 & t \le TB2 \end{cases} \qquad (3.237)$$

$$DT1_t = \begin{cases} t - TB1 & t > TB1 \\ 0 & t \le TB1 \end{cases} \quad \text{ve} \quad DT2_t = \begin{cases} t - TB2 & t > TB2 \\ 0 & t \le TB2 \end{cases} \qquad (3.238)$$

(3.236) no'lu denklemden $DT1_t$ ve $DT2_t$'nin çıkarılmasıyla elde edilen, düzeyde iki kırılmaya izin veren model (3.239) şeklinde ifade edilir ve AA modeli olarak adlandırılır.;

$$\Delta Y_t = \mu + \beta t + \theta DU1_t + \omega DU2_t + \alpha Y_{t-1} + \sum_{i=1}^{k} c_i \Delta Y_{t-i} + \varepsilon_t \qquad (3.239)$$

(3.236) no'lu denklemden $DT2_t$'nin çıkarılmasıyla elde edilen, $TB1$ zamanında düzeyde ve eğimde bir kırılmaya, $TB2$ zamanında ise düzeyde kırılmaya izin veren model ise (3.240)'daki şekilde ifade edilir ve CA modeli olarak adlandırılır.;

$$\Delta Y_t = \mu + \beta t + \theta DU1_t + \gamma DT1_t + \omega DU2_t + \alpha Y_{t-1} + \sum_{i=1}^{k} c_i \Delta Y_{t-i} + \varepsilon_t \qquad (3.240)$$

Lumsdaine- Papell (1997) birim kök testinde α'nın t-istatistiği tüm olası kırılma tarih çiftleri için $(TB1, TB2)$ hesaplanır ve α'nın t-istatistiğinin en küçük olduğu tarih çiftleri tercih edilir. Elde edilen en küçük t-istatistiğinin, ilgili kritik değerden büyük olması halinde, serinin birim köklü olduğunu gösteren temel hipotez $(\alpha = 0)$ reddedilirken, tersi durumda serinin iki yapısal kırılma içeren durağan bir

sürece uygunluk gösterdiğini ifade eden alternatif hipotez ($\alpha < 0$) reddedilemez (Yılancı ve Öztürk, 2010).

4. Perron (1997) Birim Kök Testi

Perron 1997'deki çalışmasında 1989'daki çalışmasından farklı olarak kırılma zamanının önceden bilinmediğini içsel olarak belirlendiğini varsaymaktadır ve sadece tek bir kırılma noktasına izin vermektedir (perron, 1997). Aslında Perron'un 1997 tarihli makalesinin, 1989 tarihli makalesinin tamamlayıcısı olduğu söylenebilir (Dilişen, 2007).

Perron (1997), 1989 tarihli makalenin sonuçlarının doğrulanması için verilerle kırılma dönemleri arasında ilişki olduğunu varsayarak hareket etmiştir. Temel amaç, ilişkiyi kabul ederek sonuçlarının ne olduğunu ortaya çıkarmaktadır. Bu bağlamda Perron (1997) makalesinde üç model ve bunlara dayalı testler üzerinde durmaktadır.

İlk model olan Innovational Outlier modeli, sabit terimdeki değişikliğin testine olanak veren modeldir ve bu değişikliğin yavaş olduğu varsayılmaktadır. Model,

$$Y_t = \mu + \theta DU_t + \beta t + \delta D(T_B)_t + \alpha Y_{t-1} + \sum_{i=1}^{k} c_i \Delta Y_{t-i} + e_t \qquad (3.241)$$

(3.241)'deki gibi oluşturulur, en küçük kareler yöntemi ile tahmin edilir ve $\alpha = 1$ sınaması için t-testi yapılmaktadır. Gölge değişkenler, (3.242)'deki şekilde oluşturulmaktadır.

$$DU_t = \begin{cases} 1 & t > T_B \\ 0 & t \le T_B \end{cases} \qquad \text{ve} \qquad D(TB)_t = \begin{cases} 1 & t = T_B + 1 \\ 0 & t \ne T_B + 1 \end{cases} \qquad (3.242)$$

(2.243) nolu modelde, kırılma döneminde hem sabitte hem de eğimde kırılmanın varlığı incelenir.

$$Y_t = \mu + \theta DU_t + \beta t + \gamma DT_t + \delta D(T_B)_t + \alpha Y_{t-1} + \sum_{i=1}^{k} c_i \Delta Y_{t-i} + e_t \qquad (3.243)$$

modeli oluşturularak t-testi yapılmaktadır. Gölge değişken (3.244)'te görüldüğü şekilde oluşturulmaktadır.

$$DT_t = \begin{cases} 1 & t > T_B \\ 0 & t \le T_B \end{cases} \tag{3.244}$$

Üçüncü modelde, eğimde bir kırılmaya izin verilmektedir. Kırılmanın ani bir şekilde meydana geldiği farz edilmektedir ve Perron (1989) testindeki "Additive Outlier" modele karşılık gelmektedir. Testte iki adımlı bir yaklaşım izlenmektedir. İlk adım olarak, (3.245) nolu model kurulur.

$$Y_t = \mu + \beta t + \gamma DT_t^* + \tilde{Y}_t \tag{3.245}$$

Modeldeki kukla değişken, (3.246)'da görüldüğü şekilde oluşturulmaktadır. Kurulan model EKK yöntemi ile tahmin edilmekte ve tahmin sonucu artık terimler elde edilmektedir. $\tilde{Y}_t$ ile simgelenen artıklar, trendden arındırılmış seriyi göstermektedir.

$$DT_t^* = \begin{cases} t - T_B & t > T_B \\ 0 & t \le T_B \end{cases} \tag{3.246}$$

İkinci adımda, (3.247)'de gösterilen test denklemi EKK yöntemi ile tahmin edilmekte ve $\alpha = 1$ sınaması için t-testi uygulanmaktadır.

$$\tilde{Y}_t = \alpha \tilde{Y}_{t-1} + \sum_{i=1}^{k} c_i \Delta \tilde{Y}_{t-i} + e_t \tag{3.247}$$

Her üç modelde de kırılma dönemini gösteren T_B'nin ve gecikme uzunluğunu gösteren k'nın bilinmediği varsayılmaktadır. Ayrıca $\alpha = 1$ sınamasında Zivot-Andrews (1992) test yaklaşımında olduğu gibi t-istatistiğinin minimum olduğu dönem seçilir.

Gecikme uzunluğunun doğru seçilmesi, testin büyüklüğünü ve gücünü etkilemesi nedeniyle önem kazanmaktadır. k ile gösterilen gecikme uzunluğunu içsel olarak seçmek için önerilen yöntemler şöyle sıralanabilir:

a) t-sig ile gösterilen yöntemde istatistiksel olarak anlamlı katsayıya sahip son gecikme seçilerek %10 anlamlılık seviyesinde çift taraflı normal dağılım değeri dikkate alınır.

b) F-sig ile gösterilen yöntemde kısıtlı – kısıtsız regresyon yaklaşımı kullanılarak seçim yapılabilir. Son eklenenler istatistiksel olarak önemsiz olana kadar F testi yapılabilir. %10 anlamlılık seviyesinde χ^2 dağılım değeri dikkate alınır.

Perron (1997), gecikme uzunluğunun seçiminde genelden özele yönteminin kullanılmasını önermektedir. (AIC) gibi bilgi kriterlerinin ARMA süreçlerinde testin büyüklüğünü ve gücünü bozduğu için kullanılmasının uygun olmadığını, ayrıca AIC'in küçük gecikmelerin seçilmesine ve sonuçta da artıkların serisel korelasyon sergilemesine neden olduğunu da vurgulamaktadır.

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

4.1. Yapısal Kırılma Birim Kök Testi Sonuçları

TPF verileri için, yaygın kullanımları nedeniyle Zivot-Andrews tek kırılmalı birim kök testi ve Lumsdaine-Papell iki kırılmalı birim kök testi tercih edilmiştir. Yapısal kırılma test sonuçları WINRATS 8.0 paket programı ile elde edilmiştir.

Çizelge 4.1. Zivot – Andrews Birim Kök Testi

		MODEL A	MODEL B	MODEL C
Test İstatistiği		-4.13	-3.21	-5.77
Kritik Değerler	%1	-5.34	-4.80	-5.57
	%5	-4.93	-4.42	-5.08
	%10	-4.58	-4.11	-4.82
Kırılma Tarihi		03.2010	04.2007	09.2010
Gecikme Uzunluğu		2	2	2

Çizelge 4.1.'de görüldüğü gibi Model A'ya göre yapısal kırılma Mart – 2010 tarihinde, Model B'ye göre Nisan – 2007 tarihinde, Model C'ye göre ise Eylül – 2010 tarihinde gerçekleşmiştir. Model A ve Model B için elde edilen test istatistikleri sırasıyla -4,13 ve -3,21'dir. Elde edilen test istatistikleri kritik değerlerle karşılaştırıldığında Model A ve Model B'ye göre serinin durağan olmaması yapısal kırılmadan kaynaklanmamaktadır. Model C'ye göre ise test istatistiği, kritik değerlerden büyük olduğu için serinin durağan olmaması yapısal kırılmadan kaynaklanmaktadır.

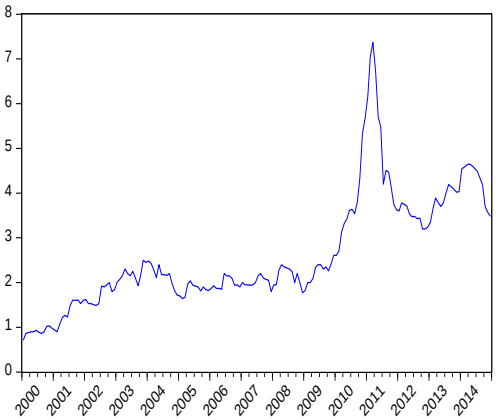
Çizelge 4.2. Lumsdaine – Papell Birim Kök Testi

		MODEL AA	MODEL CC
Test İstatistiği		-4.88	-6.11
Kritik Değerler	%1	-6.74	-7.19
	%5	-6.16	-6.75
	%10	-5.89	-6.48
Kırılma Tarihleri		02.2010	08.2010
		04.2012	10.2012
Max. Gecikme Uzunluğu		2	2

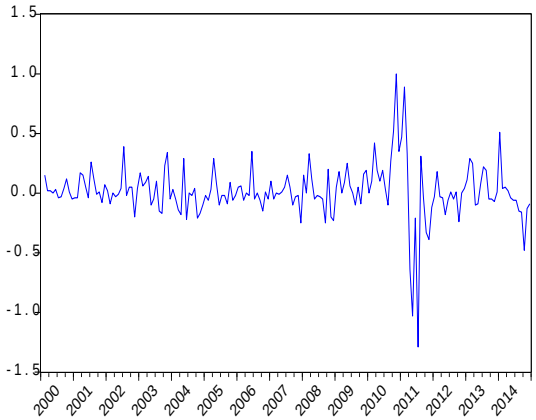
Seride içsel olarak belirlenen iki yapısal kırılmaya izin veren Lumsdaine-Papell birim kök testinin sonuçları Çizelge 4.2.'de görüldüğü gibidir. Tablodaki değerlerden de görüldüğü üzere her iki model için hesaplanan test istatistikleri, (David, 2003)'te belirtilen %1, %5 ve %10 anlamlılık düzeylerindeki kritik değerlerden küçük olduğu için serinin yapısal kırılma olmadan birim köklü olduğunu gösteren temel hipotez kabul edilir. Model AA için yani düzeyde kırılmalar, Şubat-2010 ve Nisan-2012 tarihlerinde, Model CC için yani hem düzey hem de eğimde kırılmalar, Ağustos-2010 ve Ekim-2012 tarihlerinde gerçekleşmiştir.

4.2. Çoklu Regresyon ile Model Tahmini

Çoklu Regresyon model tahmini için EVIEWS 8.0 paket programından faydalanılmıştır. Zaman serilerinde Çoklu Regresyon Analizi yapılabilmesi için serilerin aynı dereceden durağanlık şartını sağlaması gerekir. Aksi takdirde sahte regresyon durumuyla karşılaşılmaktadır. Bu nedenle bağımlı ve bağımsız değişkenlere ADF durağanlık testi yapılmıştır ve serilerin durağan olmadığı, birinci farkını aldıktan sonra durağanlaştığı gözlenmiştir. Serilerin birim kök testi sonuçları ve grafikleri aşağıda belirtildiği gibidir.



Şekil 4.1. TPF verilerinin zaman yolu grafiği



Şekil 4.2. DTPF verilerinin zaman yolu grafiği

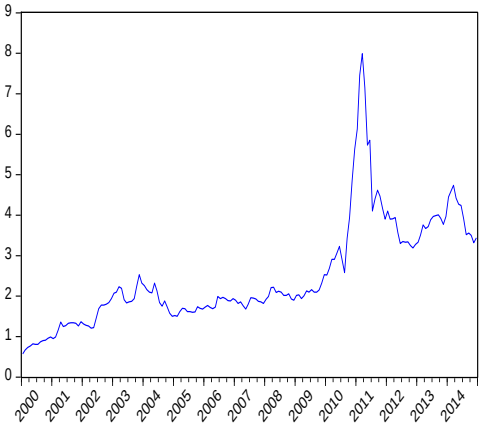
Şekil 4.1.'de TPF_t serisine ait gözlem değerleri, belirli bir ortalama etrafında ve sabit bir saçılım göstermediği görülebilir. Zaman içerisinde kesikli bir trende sahip olduğu görülmektedir. Ayrıca 2010 yılından itibaren geçici bir ani bir artış gerçekleşmiştir. Bu ani artış nedeniyle TPF_t verilerinin sapan değerli (outlier) bir zaman serisi kalıbı sergilediğini söyleyebiliriz. Bu durum serinin durağan-dışı olduğu izlenimi vermektedir.

TPF_t verilerinin birinci farkı alındıktan sonraki dağılımı $DTPF_t$ ismiyle Şekil 4.2.'de gösterilmiştir. 2010-2012 yılları arasında bir salınım olsa da seri, belirli bir ortalama etrafında sabit bir varyansa sahip olduğu söylenebilir. Bu nedenle TPF verilerinin birinci farkının durağan olduğunu söyleyebiliriz.

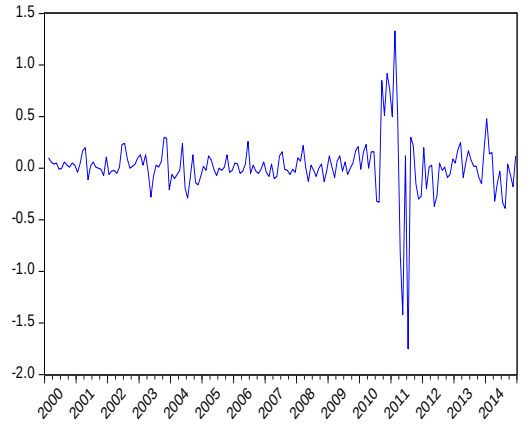
Çizelge 4.3. TPF ve DTPF verileri için ADF birim kök testi

TPF (Kesmeli ve Trendli)				**DTPF (Kesmeli ve Trendli)**		
Test İstatistiği		-2.7855	**Olasılık***	**Test İstatistiği**	-9.3341	**Olasılık***
Kritik Değerler	%1	-4.0104	**0.2047**	**Kritik Değerler**	-4.0104	**0.0000**
	%5	-3.4353			-3.4353	
	%10	-3.1416			-3.1416	
TPF (Kesmeli ve Trendsiz)				**DTPF (Kesmeli ve Trendsiz)**		
Test İstatistiği		-1.9299	**Olasılık***	**Test İstatistiği**	-9.3504	**Olasılık***
Kritik Değerler	%1	-3.4672	**0.3180**	**Kritik Değerler**	-3.4672	**0.0000**
	%5	-2.8776			-2.8776	
	%10	-2.5754			-2.5754	
TPF (Kesmesiz ve Trendsiz)				**DTPF (Kesmesiz ve Trendsiz)**		
Test İstatistiği		-0.3150	**Olasılık***	**Test İstatistiği**	-9.3509	**Olasılık***
Kritik Değerler	%1	-2.5780	**0.6273**	**Kritik Değerler**	-2.5780	**0.0000**
	%5	-1.9426			-1.9426	
	%10	-1.6155			-1.6155	

TPF_t ve $DTPF_t$ verileri için yapılan ADF birim kök testi sonuçları, Çizelge 4.3.'te gösterilmiştir. Her üç model (kesmeli ve trendli, kesmeli ve trendsiz, kesmesiz ve trendsiz) için TPF_t verilerinin birim kök içerdiği (durağan-dışı), $DTPF_t$ verilerinin ise durağan olduğu görülmektedir. Sonuç olarak TPF_t verilerinin birinci farkı alındığı zaman durağanlaştığı görülmektedir. (Olasılık = 0.0000)



Şekil 4.3. DPF verilerinin zaman yolu grafiği



Şekil 4.4. DDPF verilerinin zaman yolu grafiği

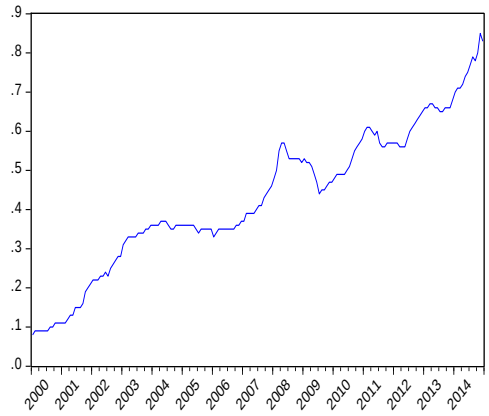
Şekil 4.3. incelendiğinde DPF_t serisinin Şekil 4.1.'deki TPF_t serisiyle benzerlik gösterdiği görülmektedir. Yine aynı şekilde Şekil 4.4. de $DDPF_t$ serisi Şekil 4.2'deki, $DTPF_t$ serisine benzer bir dağılım göstermektedir. Bazı sapmalara rağmen ortalama etrafında sabit bir salınım gösterdiğinden durağanlaştığını söyleyebiliriz.

Çizelge 4.4. DPF ve DDPF verileri için ADF birim kök testi

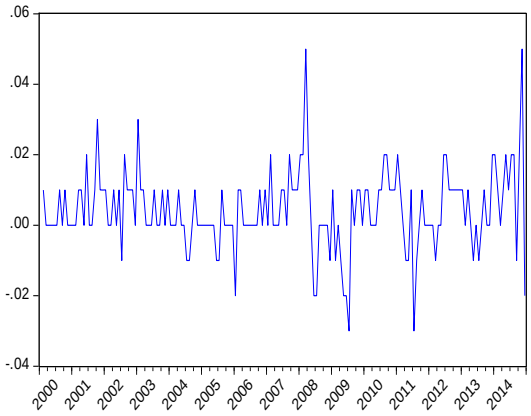
DPF (Kesmeli ve Trendli)				**DDPF (Kesmeli ve Trendli)**		
Test İstatistiği		-2.9910	**Olasılık***	**Test İstatistiği**	-9.9620	**Olasılık***
Kritik Değerler	%1	-4.0104	**0.1377**	**Kritik Değerler**	-4.0104	**0.0000**
	%5	-3.4353			-3.4353	
	%10	-3.1416			-3.1416	
DPF (Kesmeli ve Trendsiz)				**DDPF (Kesmeli ve Trendsiz)**		
Test İstatistiği		-2.0680	**Olasılık***	**Test İstatistiği**	-9.9842	**Olasılık***
Kritik Değerler	%1	-3.4672	**0.2580**	**Kritik Değerler**	-3.4672	**0.0000**
	%5	-2.8776			-2.8776	
	%10	-2.5754			-2.5754	
DPF (Kesmesiz ve Trendsiz)				**DDPF (Kesmesiz ve Trendsiz)**		
Test İstatistiği		-0.4562	**Olasılık***	**Test İstatistiği**	-9.9878	**Olasılık***
Kritik Değerler	%1	-2.5780	**0.5765**	**Kritik Değerler**	-2.5780	**0.0000**
	%5	-1.9426			-1.9426	
	%10	-1.6155			-1.6155	

DPF_t ve $DDPF_t$ verileri için yapılan ADF birim kök testi sonuçları, Çizelge 4.4.'te gösterilmiştir. Her üç model (kesmeli ve trendli, kesmeli ve trendsiz, kesmesiz

ve trendsiz) için DPF_t verilerinin birim kök içerdiği (durağan-dışı), $DDPF_t$ verilerinin ise durağan olduğu görülmektedir. Sonuç olarak DPF_t verilerinin birinci farkı alındığı zaman durağanlaştığı görülmektedir. (Olasılık = 0.0000)



Şekil 4.5. TBF verilerinin zaman yolu grafiği



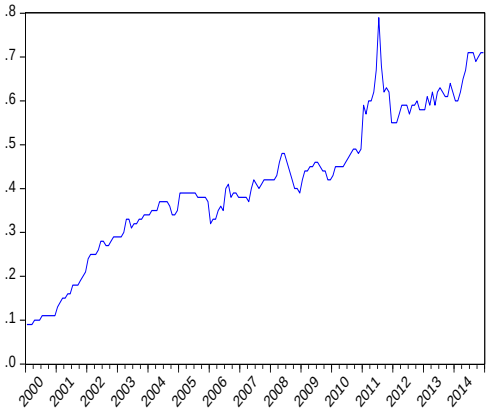
Şekil 4.6. DTBF verilerinin zaman yolu grafiği

Şekil 4.5.'te TBF_t verilerinin artan bir trende sahip olduğu görülmektedir. Sabit bir ortalama ve varyansa sahip olmadığı için durağan değildir. Şekil 4.6.'da TBF_t verilerinin birinci farkı alınmış hali görülmektedir. Sabit ortalama ve varyansa sahip olduğu için durağan olduğu söylenebilir.

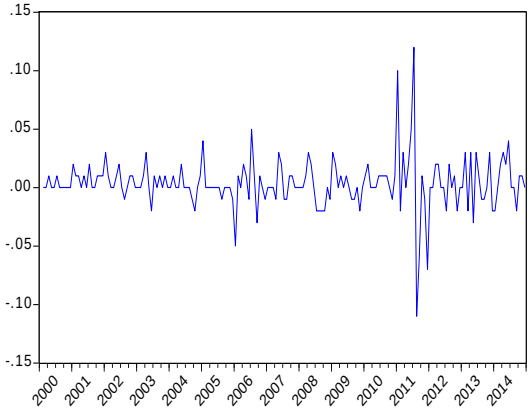
Çizelge 4.5. TBF verileri için ADF birim kök testi

TBF (Kesmeli ve Trendli)				**DTBF (Kesmeli ve Trendli)**		
Test İstatistiği		-1.9616	**Olasılık***	**Test İstatistiği**	-9.6201	**Olasılık***
Kritik Değerler	%1 %5 %10	-4.0104 -3.4353 -3.1416	**0.6178**	**Kritik Değerler**	-4.0104 -3.4353 -3.1416	**0.0000**
TBF (Kesmeli ve Trendsiz)				**DTBF (Kesmeli ve Trendsiz)**		
Test İstatistiği		-0.0640	**Olasılık***	**Test İstatistiği**	-9.6357	**Olasılık***
Kritik Değerler	%1 %5 %10	-3.4672 -2.8776 -2.5754	**0.9504**	**Kritik Değerler**	-3.4672 -2.8776 -2.5754	**0.0000**
TBF (Kesmesiz ve Trendsiz)				**DTBF (Kesmesiz ve Trendsiz)**		
Test İstatistiği		2.9892	**Olasılık***	**Test İstatistiği**	-8.7977	**Olasılık***
Kritik Değerler	%1 %5 %10	-2.5780 -1.9426 -1.6155	**0.9993**	**Kritik Değerler**	-2.5780 -1.9426 -1.6155	**0.0000**

TBF_t ve $DTBF_t$ verileri için yapılan ADF birim kök testi sonuçları, Çizelge 4.5.'te gösterilmiştir. Her üç model (kesmeli ve trendli, kesmeli ve trendsiz, kesmesiz ve trendsiz) için TBF_t verilerinin birim kök içerdiği (durağan-dışı), $DTBF_t$ verilerinin ise durağan olduğu görülmektedir. Sonuç olarak TBF verilerinin birinci farkı alındığı zaman durağanlaştığı görülmektedir. (Olasılık = 0.0000)



Şekil 4.7. TMF verilerinin zaman yolu grafiği



Şekil 4.8. DTMF verilerinin zaman yolu grafiği

Şekil 4.7.'de TMF_t verilerinin artan bir trende sahip olduğu görülmektedir. Sabit bir ortalama ve varyansa sahip olmadığı için durağan değildir. Şekil 4.8.'de TMF_t verilerinin birinci farkı alınmış hali görülmektedir. Sabit ortalama ve varyansa sahip olduğu için durağan olduğu söylenebilir.

Çizelge 4.6. TMF verileri için ADF Birim kök testi

TMF (Kesmeli ve Trendli)				**DTMF (Kesmeli ve Trendli)**		
Test İstatistiği		-3.2783	**Olasılık***	**Test İstatistiği**	-13.2086	**Olasılık***
Kritik Değerler	%1	-4.0104	**0.0732**	**Kritik Değerler**	-4.0104	**0.0000**
	%5	-3.4353			-3.4353	
	%10	-3.1416			-3.1416	
TMF (Kesmeli ve Trendsiz)				**DTMF (Kesmeli ve Trendsiz)**		
Test İstatistiği		-1.0751	**Olasılık***	**Test İstatistiği**	-13.2439	**Olasılık***
Kritik Değerler	%1	-3.4672	**0.7253**	**Kritik Değerler**	-3.4672	**0.0000**
	%5	-2.8776			-2.8776	
	%10	-2.5754			-2.5754	

Çizelge 4.6. **(devam)**

TMF (Kesmesiz ve Trendsiz)				**DTMF (Kesmesiz ve Trendsiz)**		
Test İstatistiği		1.6121	**Olasılık***	**Test İstatistiği**	-12.9464	**Olasılık***
	%1	-2.5780			-2.5780	
Kritik	%5	-1.9426	**0.9738**	**Kritik Değerler**	-1.9426	**0.0000**
Değerler	%10	-1.6155			-1.6155	

TMF_t ve $DTMF_t$ verileri için yapılan ADF birim kök testi sonuçları, Çizelge 4.6.'da gösterilmiştir. Her üç model (kesmeli ve trendli, kesmeli ve trendsiz, kesmesiz ve trendsiz) için TMF_t verilerinin birim kök içerdiği (durağan-dışı), $DTMF_t$ verilerinin ise durağan olduğu görülmektedir. Sonuç olarak TMF_t verilerinin birinci farkı alındığı zaman durağanlaştığı görülmektedir. (Olasılık = 0.0000)

Başlangıç olarak kullanılan Çoklu Regresyon modeli (4.1)'de belirtilen şekilde kurulmuştur,

$$DTPF_t = \beta_1 + \beta_2 DPF_t + \beta_3 TBF_t + \beta_4 TMF_t + \beta_5 TPF_{t-1} +$$

$$= \beta_6 DPF_{t-1} + \beta_7 TBF_{t-1} + \beta_8 TMF_{t-1} + \varepsilon_t \qquad (4.1)$$

(4.1) nolu modelde, bağımlı değişken, Türkiye pamuk fiyatları (TPF_t), bağımsız değişkenler, Dünya pamuk fiyatları (DPF_t), Türkiye buğday fiyatları (TBF_t), Türkiye mısır fiyatları (TMF_t), Türkiye pamuk fiyatlarının bir gecikmeli değeri (TPF_{t-1}), Dünya pamuk fiyatlarının bir gecikmeli değeri (DPF_{t-1}), Türkiye buğday fiyatlarının bir gecikmeli değeri (TBF_{t-1}), Türkiye mısır fiyatlarının bir gecikmeli değeri (TMF_{t-1}) olarak seçilmiştir.

Veri setimiz 2000-2014 yıllarına ait aylık pamuk, buğday ve mısır fiyatlarından oluşmaktadır. Toplam veri sayısı (n) 180 adettir. Ancak modelinin tahmin gücünü test etmek ve diğer yöntemlerle kıyaslayabilmek amacıyla toplam veri sayısının %10'u test amaçlı olarak ayrılmış ve analize dâhil edilmemiştir. Bu nedenle 2000 ile 2013 yılının yedinci ayına kadar olan toplam 162 adet veri, analize tabi tutulmuş, 2013'ün yedinci ayından 2014'ün on ikinci ayına kadar olan toplam 18 adet veri ise test amaçlı olarak analize dâhil edilmemiştir.

(4.1) nolu model EKK yöntemi ile tahmin edilmiştir. Tahmin sonuçları incelenmiş ve modelin, otokorelasyon, çoklu doğrusal bağlantı ve değişen varyans varsayımlarını sağlamadığı gözlenmiştir. Değişkenler durağan olmadığı için birinci farkı alınarak durağanlaştırılmış şekilde model (4.2)'deki gibi oluşturulmuştur.

(4.2) nolu Çoklu Regresyon modelinde, bağımlı değişken, Türkiye pamuk fiyatlarının birinci farkı ($DTPF_t$), bağımsız değişkenler Dünya pamuk fiyatlarının birinci farkı ($DDPF_t$), Türkiye buğday fiyatlarının birinci farkı ($DTBF_t$), Türkiye mısır fiyatlarının birinci farkı ($DTMF_t$), birinci farkı alınmış Türkiye pamuk fiyatlarının gecikmeli değeri ($DTPF_{t-1}$), birinci farkı alınmış Dünya pamuk fiyatlarının gecikmeli değeri ($DDPF_{t-1}$), birinci farkı alınmış Türkiye buğday fiyatlarının gecikmeli değeri ($DTBF_{t-1}$), birinci farkı alınmış Türkiye mısır fiyatlarının gecikmeli değeri ($DTMF_{t-1}$) olarak seçilmiştir.

$$DTPF_t = \beta_1 + \beta_2 DDPF_t + \beta_3 DTBF_t + \beta_4 DTMF_t + \beta_5 DTPF_{t-1} +$$

$$= \beta_6 DDPF_{t-1} + \beta_7 DTBF_{t-1} + \beta_8 DTMF_{t-1} \qquad (4.2)$$

Model (4.2)'ye regresyon analizi uygulanmış ancak varsayımları yine sağlamadığı görülmüştür. Ayrıca tahmini modelin hata terimleri grafiği incelenmiş ve bazı değerlerin aşırı sapma gösterdiği görülmüştür. Bu nedenle hem varsayımları sağlamak hem de modelin performansını arttırmak için Çoklu Regresyon modeline aşırı sapma gösteren dönemleri dikkate almak için (4.3) nolu eşitlikte belirtilen kukla değişkenler eklenmiştir. (4.4)'te ise oluşturulan kukla değişkenlerin tarihi ve parantez içinde sırası belirtilmiştir.

D1 = 01.11.2002 (t = 35)

D2 = 01.12.2007 (t = 96)

D3 = 01.09.2008 (t = 105)

D4 = 01.09.2010 (t = 129)

D5 = 01.11.2010 (t = 131)

D6 = 01.12.2010 (t = 132)

D7 = 01.02.2012 (t = 146) (4.3)

$$D1 = \begin{cases} 1 & t = 35 \\ 0 & diğer \end{cases}$$

$$D2 = \begin{cases} 1 & t = 96 \\ 0 & diğer \end{cases}$$

$$D3 = \begin{cases} 1 & t = 105 \\ 0 & diğer \end{cases}$$

$$D4 = \begin{cases} 1 & t = 129 \\ 0 & diğer \end{cases}$$

$$D5 = \begin{cases} 1 & t = 131 \\ 0 & diğer \end{cases}$$

$$D6 = \begin{cases} 1 & t = 132 \\ 0 & diğer \end{cases}$$

$$D7 = \begin{cases} 1 & t = 146 \\ 0 & diğer \end{cases}$$

(4.4)

Kukla değişkenler eklendikten sonra Çoklu Regresyon modelinin son hali (4.5) nolu modelde görüldüğü şekilde belirlenmiştir.

$$DTPF_t = \beta_1 + \beta_2 DDPF_t + \beta_3 DTBF_t + \beta_4 DTMF_t + \beta_5 DTPF_{t-1} +$$

$$= \beta_6 DDPF_{t-1} + \beta_7 DTBF_{t-1} + \beta_8 DTMF_{t-1} + \beta_9 D1 + \beta_{10} D2 +$$

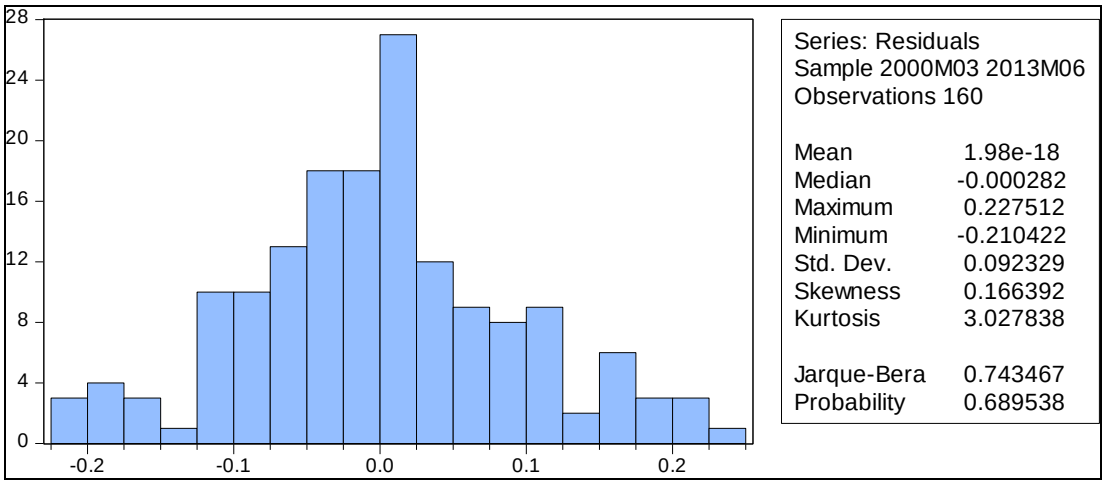
$$= \beta_{11} D3 + \beta_{12} D4 + \beta_{13} D5 + \beta_{14} D6 + \beta_{15} D7 \quad (4.5)$$

Çizelge 4.7. Çoklu Regresyon Modeli Tahmin Sonuçları

Bağımlı Değişken: DTPF				
Bağımsız Değişkenler	**Katsayı**	**Standart Hata**	**t-istatistiği**	**Olasılık**
C (Sabit)	0.000506	0.008540	0.059279	0.9528
DDPF	0.698465	0.033825	20.64925	0.0000
DTBF	-0.075549	0.841365	-0.089793	0.9286
DTMF	-0.345871	0.395741	-0.873983	0.3836
DTPF(-1)	0.039523	0.071379	0.553698	0.5806
DDPF(-1)	0.040986	0.059715	0.686371	0.4936
DTBF(-1)	1.387676	0.861145	1.611432	0.1093
DTMF(-1)	0.951808	0.372749	2.553484	0.0117
D1	-0.250421	0.097269	-2.574519	0.0110
D2	-0.234489	0.097295	-2.410081	0.0172
D3	-0.233132	0.097802	-2.383717	0.0184
D4	-0.339026	0.103795	-3.266302	0.0014
D5	0.298871	0.101574	2.942393	0.0038
D6	-0.265699	0.104843	-2.534250	0.0123
D7	0.312175	0.098394	3.172701	0.0018
R^2	0.842190	**Bağımlı Değişken Ort.**		0.018250
Düzeltilmiş R^2	0.826954	**Bağımlı Değişkenin Std. Sap.**		0.232418
Tahminin Std. Hatası	0.096683	**Akaike Bilgi Kriteri**		-1.745691
Hata Kareleri Top.	1.355412	**Schwarz Bilgi Kriteri**		-1.457394
En Çok Benzerlik	154.6553	**Hannan-Quinn Kriteri**		-1.628624
F-istatistik	55.27350	**Durbin-Watson istatistik**		1.913645
Olasılık(F-istatistik)	0.000000			

Çoklu Regresyon Modeli tahmin sonuçları çizelge 4.7'de gösterilmiştir. Modelin tahmin denklemi ise (4.6)'da görüldüğü gibi düzenlenir;

$$\mathbf{DTPF_t} = 0.000506 + 0.698465\mathbf{DDPF_t} - 0.075549\ \mathbf{DTBF_t} - 0.345871\ \mathbf{DTMF_t}$$
$$= + 0.039523\mathbf{DTPF_{t-1}} + 0.040986\ \mathbf{DDPF_{t-1}} + 1.387676\ \mathbf{DTBF_{t-1}}$$
$$= + 0.951808\ \mathbf{DTMF_{t-1}} - 0.250421\mathbf{D1} - 0.234489\mathbf{D2} - 0.233132\mathbf{D3}$$
$$= - 0.339026\mathbf{D4} + 0.298871\mathbf{D5} - 0.265699\mathbf{D6} + 0.312175\mathbf{D7} \qquad (4.6)$$



Şekil 4.9. Hata Terimlerinin Dağılımı

Şekil 4.9.'da hata terimlerinin dağılımı gösterilmiştir. Hata terimlerinin normal dağılıp dağılmadığının tespiti için Jarque-Bera testi uygulanmış ve hata terimlerinin normal dağıldığını iddia eden temel hipotez kabul edilmiştir. (Prob. > 0.05)

Çizelge 4.8. Değişen Varyans Testi

Heteroskedasticity Test: Breusch-Pagan-Godfrey			
F-statistic	0.657186	Prob. F(14,145)	0.8124
Obs*R-squared	9.546631	Prob. Chi-Square(14)	0.7945
Scaled explained SS	7.949675	Prob. Chi-Square(14)	0.8919
Heteroskedasticity Test: White			
F-statistic	1.192753	Prob. F(42,117)	0.2297
Obs*R-squared	47.96834	Prob. Chi-Square(42)	0.2436
Scaled explained SS	39.94421	Prob. Chi-Square(42)	0.5616

Çoklu Regresyon modelinin hata terimlerinin sabit varyanslı olup olmadığının tespiti için Breusch-Pagan-Godfrey ve White testi uygulanmıştır. Çizelge 4.8.'de elde edilen sonuçlara göre, her iki test için hata terimlerinin varyansının sabit olduğunu iddia eden temel hipotez reddedilememiş ve değişen varyans probleminin olmadığı sonucuna ulaşılmıştır. (Prob. > 0.05)

Çizelge 4.9. Otokorelasyon testi

Breusch-Godfrey Serial Correlation LM test			
F-statistic	0.651151	Prob. F(2,143)	0.5230
Obs*R-squared	1.443970	Prob. Chi-Square(2)	0.4858

Çoklu Regresyon modelinden elde edilen hata terimleri arasında otokorelasyon olup olmadığının ortaya çıkarılması için Breusch-Godfrey LM testi uygulanmıştır. Çizelge 4.9.'da görüldüğü gibi hata terimleri arasında bir ilişki olmadığını iddia eden temel hipotez reddedilememiş ve hata terimleri arasında otokorelasyon olmadığı sonucuna ulaşılmıştır. (Prob. > 0.05)

Çizelge 4.10. Çoklu Doğrusal Bağlantı Testi

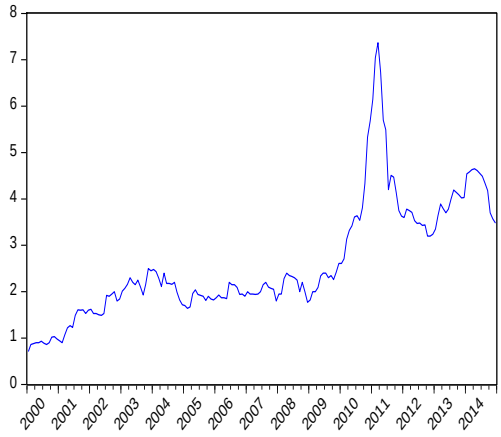
Varyans Büyütme Faktörü (VIF)	
Değişken	**Centered VIF**
C (Sabit)	--
DDPF	1.577184
DTBF	1.307803
DTMF	1.285775
DTPF(-1)	4.688790
DDPF(-1)	4.909302
DTBF(-1)	1.372248
DTMF(-1)	1.130204
D1	1.005829
D2	1.006362
D3	1.016881
D4	1.145319
D5	1.096832
D6	1.168569
D7	1.029229

Çoklu Regresyon modelinde kullanılan bağımsız değişkenlerin birbirleriyle ilişkili olup olmadığını yani çoklu doğrusal bağlantıya sahip olup olmadığını tespit etmek için varyans büyütme faktörü ölçütü kullanılmıştır. Birçok literatürde VIF katsayılarının 5'ten büyük olması ($VIF > 5$), çoklu doğrusal bağlantının bir işareti olarak kabul edilmiştir. Çizelge 4.10.'da görüldüğü üzere bütün değişkenler için VIF

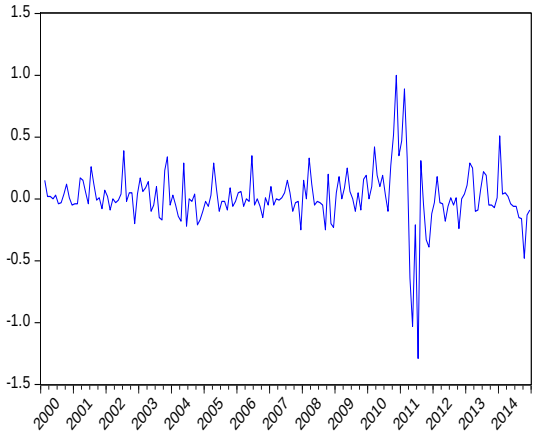
katsayıları 5'ten küçük olduğu görülmektedir. Bu sonuç modelde kullanılan bağımsız değişkenler arasında bir ilişki olmadığını göstermektedir.

4.3. Box – Jenkins ARIMA İle Model Tahmini

TPF serisiyle ARIMA model tahmini için EVIEWS 8.0 paket programından faydalanılmıştır. Öncelikle TPF serisinin grafiği ve korelogramı incelenmiştir. Durağanlık testi yapılmış ve sonuçlar aşağıdaki belirtildiği gibidir.



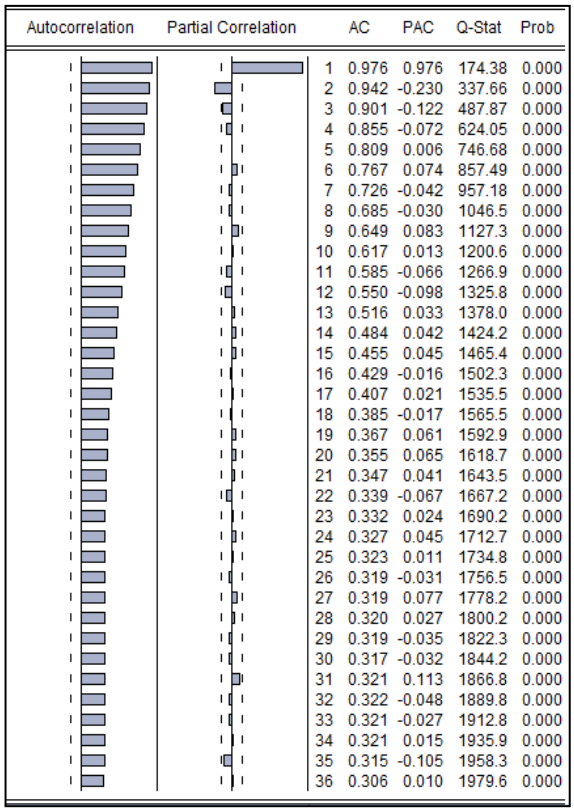
Şekil 4.10. TPF verilerinin zaman yolu grafiği



Şekil 4.11. DTPF verilerinin zaman yolu grafiği

Şekil 4.10.'da TPF_t serisine ait gözlem değerleri, belirli bir ortalama etrafında ve sabit bir saçılım göstermediği görülebilir. Zaman içerisinde kesikli bir trende sahip olduğu görülmektedir. Ayrıca 2010 yılından itibaren geçici bir ani bir artış gerçekleşmiştir. Bu ani artış nedeniyle TPF_t verilerinin sapan değerli (outlier) bir zaman serisi kalıbı sergilediğini söyleyebiliriz. Bu durum serinin durağan-dışı olduğu izlenimi vermektedir.

TPF_t verilerinin birinci farkı alındıktan sonraki dağılımı $DTPF_t$ ismiyle Şekil 4.11.'de gösterilmiştir. 2010-2012 yılları arasında bir salınım olsa da seri, belirli bir ortalama etrafında sabit bir varyansa sahip olduğu söylenebilir. Bu nedenle TPF verilerinin birinci farkının durağan olduğunu söyleyebiliriz.



	AC	PAC	Q-Stat	Prob
1	0.976	0.976	174.38	0.000
2	0.942	-0.230	337.66	0.000
3	0.901	-0.122	487.87	0.000
4	0.855	-0.072	624.05	0.000
5	0.809	0.006	746.68	0.000
6	0.767	0.074	857.49	0.000
7	0.726	-0.042	957.18	0.000
8	0.685	-0.030	1046.5	0.000
9	0.649	0.083	1127.3	0.000
10	0.617	0.013	1200.6	0.000
11	0.585	-0.066	1266.9	0.000
12	0.550	-0.098	1325.8	0.000
13	0.516	0.033	1378.0	0.000
14	0.484	0.042	1424.2	0.000
15	0.455	0.045	1465.4	0.000
16	0.429	-0.016	1502.3	0.000
17	0.407	0.021	1535.5	0.000
18	0.385	-0.017	1565.5	0.000
19	0.367	0.061	1592.9	0.000
20	0.355	0.065	1618.7	0.000
21	0.347	0.041	1643.5	0.000
22	0.339	-0.067	1667.2	0.000
23	0.332	0.024	1690.2	0.000
24	0.327	0.045	1712.7	0.000
25	0.323	0.011	1734.8	0.000
26	0.319	-0.031	1756.5	0.000
27	0.319	0.077	1778.2	0.000
28	0.320	0.027	1800.2	0.000
29	0.319	-0.035	1822.3	0.000
30	0.317	-0.032	1844.2	0.000
31	0.321	0.113	1866.8	0.000
32	0.322	-0.048	1889.8	0.000
33	0.321	-0.027	1912.8	0.000
34	0.321	0.015	1935.9	0.000
35	0.315	-0.105	1958.3	0.000
36	0.306	0.010	1979.6	0.000

Şekil 4.12. TPF Verilerinin Korelogramı

Şekil 4.12. incelendiğinde hesaplanan otokorelasyon katsayılarının oldukça yüksek değerli olduğu görülmektedir. Ayrıca Portmanteau testi sonucunda %1, %5 ve %10 anlamlılık düzeylerine göre serilerin istatistiksel olarak anlamlı bir otokorelasyona sahip olduğu görülmektedir. (Prob. = 0.000)

Çizelge 4.11. TPF ve DTPF verileri için ADF birim kök testi

TPF (Kesmeli ve Trendli)				**DTPF (Kesmeli ve Trendli)**		
Test İstatistiği		-2.7855	**Olasılık***	**Test İstatistiği**	-9.3341	**Olasılık***
Kritik Değerler	%1	-4.0104	**0.2047**	**Kritik Değerler**	-4.0104	**0.0000**
	%5	-3.4353			-3.4353	
	%10	-3.1416			-3.1416	
TPF (Kesmeli ve Trendsiz)				**DTPF (Kesmeli ve Trendsiz)**		
Test İstatistiği		-1.9299	**Olasılık***	**Test İstatistiği**	-9.3504	**Olasılık***
Kritik Değerler	%1	-3.4672	**0.3180**	**Kritik Değerler**	-3.4672	**0.0000**
	%5	-2.8776			-2.8776	
	%10	-2.5754			-2.5754	

Çizelge 4.11. **(devam)**

TPF (Kesmesiz ve Trendsiz)				**DTPF (Kesmesiz ve Trendsiz)**		
Test İstatistiği		-0.3150	**Olasılık***	**Test İstatistiği**	-9.3509	**Olasılık***
	%1	-2.5780			-2.5780	
Kritik	%5	-1.9426	**0.6273**	**Kritik Değerler**	-1.9426	**0.0000**
Değerler	%10	-1.6155			-1.6155	

TPF_t ve $DTPF_t$ verileri için yapılan ADF birim kök testi sonuçları, Çizelge 4.11.'de gösterilmiştir. Her üç model (kesmeli ve trendli, kesmeli ve trendsiz, kesmesiz ve trendsiz) için TPF_t verilerinin birim kök içerdiği (durağan-dışı), $DTPF_t$ verilerinin ise durağan olduğu görülmektedir. Sonuç olarak TPF_t verilerinin birinci farkı alındığı zaman durağanlaştığı görülmektedir. (Olasılık = 0.0000)

Çizelge 4.12. TPF ve DTPF verileri için Phillips-Perron Birim Kök testi

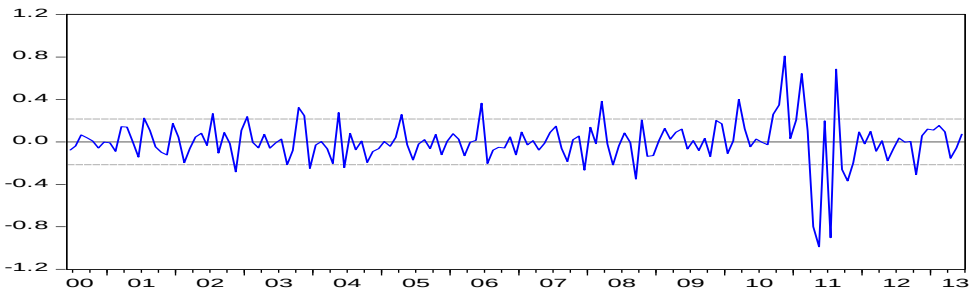
TPF (Kesmeli ve Trendli)				**DTPF (Kesmeli ve Trendli)**		
Test İstatistiği		-2.6933	**Olasılık***	**Test İstatistiği**	-9.4854	**Olasılık***
	%1	-4.0101			-4.0104	
Kritik Değerler	%5	-3.4351	**0.2407**	**Kritik Değerler**	-3.4353	**0.0000**
	%10	-3.1416			-3.1416	
TPF (Kesmeli ve Trendsiz)				**DTPF (Kesmeli ve Trendsiz)**		
Test İstatistiği		-1.9353	**Olasılık***	**Test İstatistiği**	-9.5006	**Olasılık***
	%1	-3.4670			-3.4672	
Kritik Değerler	%5	-2.8775	**0.3156**	**Kritik Değerler**	-2.8776	**0.0000**
	%10	-2.5754			-2.5754	
TPF (Kesmesiz ve Trendsiz)				**DTPF (Kesmesiz ve Trendsiz)**		
Test İstatistiği		-0.2499	**Olasılık***	**Test İstatistiği**	-9.5032	**Olasılık***
	%1	-2.5780			-2.5780	
Kritik Değerler	%5	-1.9426	**0.5950**	**Kritik Değerler**	-1.9426	**0.0000**
	%10	-1.6155			-1.6155	

Çizelge 4.13. TPF ve DTPF verileri için KPSS Birim Kök testi

TPF (Kesmeli ve Trendli)			DTPF (Kesmeli ve Trendli)	
Test İstatistiği		0.1016		0.0420
Kritik Değerler	(%1)	0.2160	(%1)	0.2160
	(%5)	0.1460	(%5)	0.1460
	(%10)	0.1190	(%10)	0.1190
TPF (Kesmeli ve Trendsiz)			**DTPF (Kesmeli ve Trendsiz)**	
Test İstatistiği		1.2533		0.0511
Kritik Değerler	(%1)	0.7390	(%1)	0.7390
	(%5)	0.4630	(%5)	0.4630
	(%10)	0.3470	(%10)	0.3470

Çizelge 4.12. ve Çizelge 4.13.'te TPF_t ve $DTPF_t$ verilerine Phillips-Perron ve KPSS birim kök testleri uygulanmıştır. Phillips-Perron ve KPSS birim kök testlerinden elde edilen sonuçların, ADF birim kök testi sonucunda elde sonuçlarla aynı olduğu yani TPF_t verilerinin durağan olmadığı, $DTPF_t$ verilerinin ise durağan olduğu görülmüştür.

En uygun ARIMA(p,d,q) tahmin modelini elde etmek için Çizelge 3.27. 'de belirtilen kriterler göz önüne alınarak yapılan tahmin modelleri içinde en uygun modelin ARIMA(3,1,2) modeli olduğu tespit edilmiştir. ARIMA(3,1,2) modeliyle yapılan analizlerden elde edilen sonuçlar incelendiğinde şekil 4.13'te görüldüğü gibi bazı kalıntı değerlerinin aşırı sapma gösterdiği gözlenmiştir. Ayrıca hata terimlerinin normal dağılmadığı ve otokorelasyon testlerinin de anlamlı çıktığı yani hataların birbiriyle ilişkili olduğu görülmüştür. Hem otokorelasyon sorununu ortadan kaldırmak için hem de modelin performansını arttırmak için hata grafiğindeki sapma gösteren dönemler için kukla değişkenler oluşturulmuştur.



Şekil 4.13. ARIMA(3,1,2) modelinin hatalarının grafiği

Aşağıda, oluşturulan kukla değişkenlerin tarihi ve parantez içinde sırası belirtilmiştir.

D1 = 01.11.2010 (t = 131)

D2 = 01.02.2011 (t = 134)

D3 = 01.04.2011 (t = 136)

D4 = 01.05.2011 (t = 137)

D5 = 01.07.2011 (t = 139)

D6 = 01.08.2011 (t = 140)

D7 = 01.10.2011 (t = 142)

$$D1 = \begin{cases} 1 & t = 131 \\ 0 & diğer \end{cases}$$

$$D2 = \begin{cases} 1 & t = 134 \\ 0 & diğer \end{cases}$$

$$D3 = \begin{cases} 1 & t = 136 \\ 0 & diğer \end{cases}$$

$$D4 = \begin{cases} 1 & t = 137 \\ 0 & diğer \end{cases}$$

$$D5 = \begin{cases} 1 & t = 139 \\ 0 & diğer \end{cases}$$

$$D6 = \begin{cases} 1 & t = 140 \\ 0 & diğer \end{cases}$$

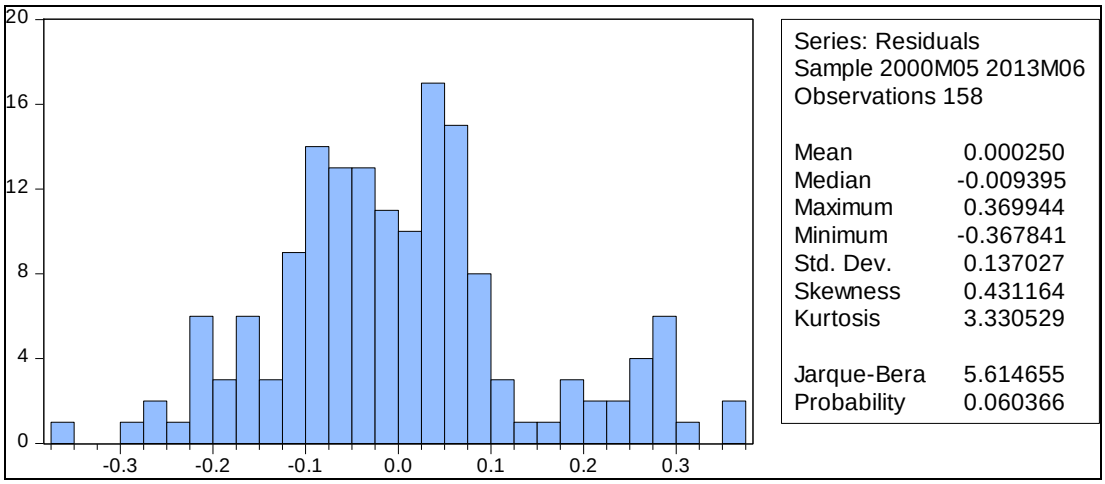
$$D7 = \begin{cases} 1 & t = 142 \\ 0 & diğer \end{cases}$$

Çizelge 4.14. ARIMA Modeli Tahmin Sonuçları

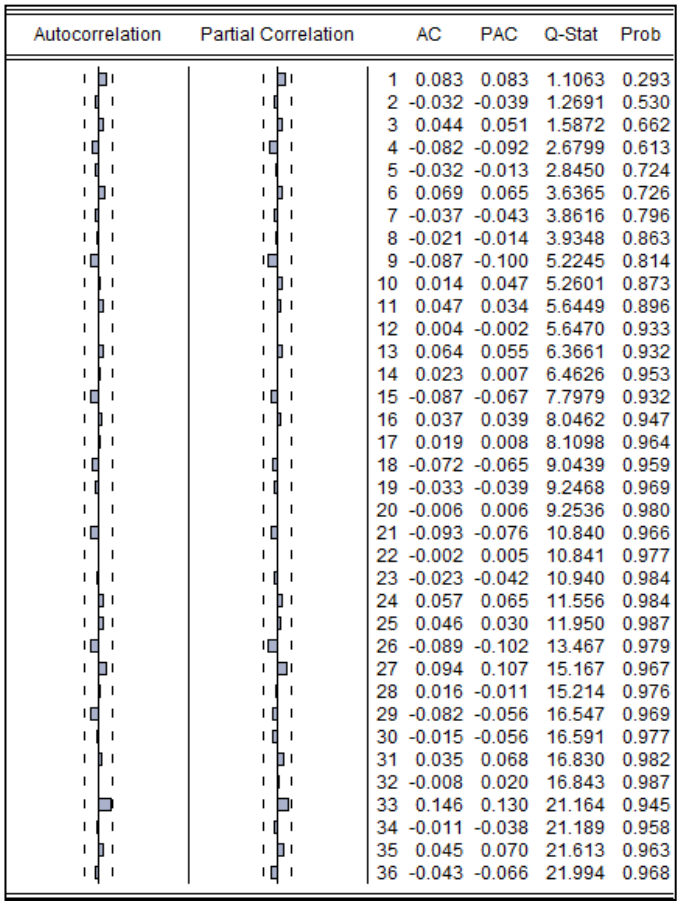
Bağımlı Değişken: DTPF				
Bağımsız Değişkenler	**Katsayı**	**Standart Hata**	**t-istatistiği**	**Olasılık**
C (Sabit)	0.027269	0.018150	1.502476	0.1351
D1	0.732958	0.138607	5.288015	0.0000
D2	0.646178	0.138791	4.655769	0.0000
D3	-0.748440	0.143354	-5.220933	0.0000
D4	-1.006328	0.141477	-7.113043	0.0000
D5	-1.246148	0.140615	-8.862125	0.0000
D6	0.353086	0.140793	2.507842	0.0132
D7	-0.226778	0.136570	-1.660533	0.0990
AR(1)	-0.039803	0.082671	-0.481465	0.6309
AR(2)	-0.795213	0.043884	-18.12064	0.0000
AR(3)	0.371547	0.083498	4.449800	0.0000
MA(1)	0.341994	0.020360	16.79756	0.0000
MA(2)	0.976965	0.015285	63.91854	0.0000
R^2	0.656779	**Bağımlı Değişken Ort.**		0.018228
Düzeltilmiş R^2	0.628374	**Bağımlı Değişkenin Std. Sap.**		0.233894
Tahminin Std. Hatası	0.142584	**Akaike Bilgi Kriteri**		-0.979069
Hata Kareleri Top.	2.947896	**Schwarz Bilgi Kriteri**		-0.727084
En Çok Benzerlik	90.34648	**Hannan-Quinn Kriteri**		-0.876735
F-istatistik	23.12231	**Durbin-Watson istatistik**		2.006023
Olasılık(F-istatistik)	0.000000			

Çizelge 4.14.'te kukla değişkenli ARIMA(3,1,2) tahmin modelinin sonuçları gösterilmiştir.

Şekil 4.14.'te hata terimlerinin dağılımı gösterilmiştir. Hata terimlerinin normal dağılıp dağılmadığının tespiti için Jarque-Bera testi uygulanmış ve hata terimlerinin normal dağıldığını iddia eden temel hipotez kabul edilmiştir. (Prob. > 0.05)



Şekil 4.14. Hata Terimlerinin Dağılım Tablosu



	AC	PAC	Q-Stat	Prob
1	0.083	0.083	1.1063	0.293
2	-0.032	-0.039	1.2691	0.530
3	0.044	0.051	1.5872	0.662
4	-0.082	-0.092	2.6799	0.613
5	-0.032	-0.013	2.8450	0.724
6	0.069	0.065	3.6365	0.726
7	-0.037	-0.043	3.8616	0.796
8	-0.021	-0.014	3.9348	0.863
9	-0.087	-0.100	5.2245	0.814
10	0.014	0.047	5.2601	0.873
11	0.047	0.034	5.6449	0.896
12	0.004	-0.002	5.6470	0.933
13	0.064	0.055	6.3661	0.932
14	0.023	0.007	6.4626	0.953
15	-0.087	-0.067	7.7979	0.932
16	0.037	0.039	8.0462	0.947
17	0.019	0.008	8.1098	0.964
18	-0.072	-0.065	9.0439	0.959
19	-0.033	-0.039	9.2468	0.969
20	-0.006	0.006	9.2536	0.980
21	-0.093	-0.076	10.840	0.966
22	-0.002	0.005	10.841	0.977
23	-0.023	-0.042	10.940	0.984
24	0.057	0.065	11.556	0.984
25	0.046	0.030	11.950	0.987
26	-0.089	-0.102	13.467	0.979
27	0.094	0.107	15.167	0.967
28	0.016	-0.011	15.214	0.976
29	-0.082	-0.056	16.547	0.969
30	-0.015	-0.056	16.591	0.977
31	0.035	0.068	16.830	0.982
32	-0.008	0.020	16.843	0.987
33	0.146	0.130	21.164	0.945
34	-0.011	-0.038	21.189	0.958
35	0.045	0.070	21.613	0.963
36	-0.043	-0.066	21.994	0.968

Şekil 4.15. Hata terimlerinin karelerinin korelogramı

Şekil 4.15.'te görüldüğü gibi ARIMA tahmin modelinin hata terimleri arasındaki korelasyon katsayıları istatistiksel olarak anlamsız bulunmuştur. (Prob>0.05)

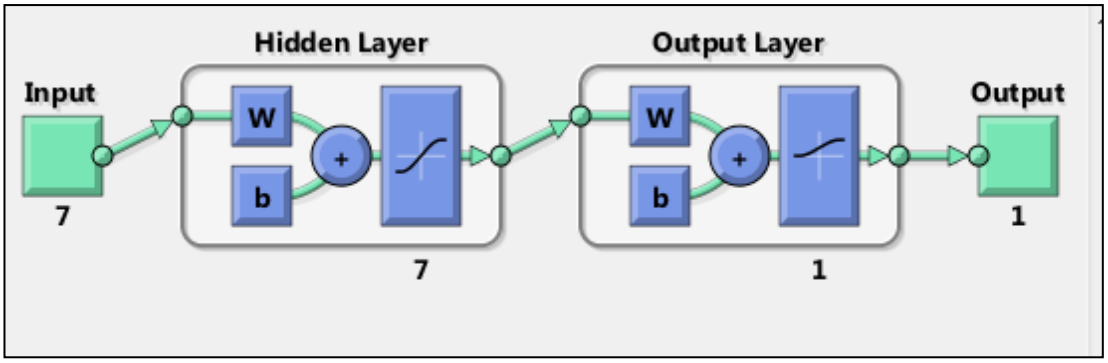
4.4. YSA ile Model Tahmini

Pamuk fiyatlarının YSA ile tahmininde MATLAB R2012B paket programından faydalanılmıştır. Uygulamalar için hem MATLAB programlama dili hem de Neural Network/Data Manager (nntool) eklentisi kullanılmıştır.

Girişler (inputs), Dünya pamuk fiyatları (DPF_t), Türkiye buğday fiyatları (TBF_t), Türkiye mısır fiyatları (TMF_t), Türkiye pamuk fiyatlarının bir gecikmeli değeri (TPF_{t-1})Dünya pamuk fiyatlarının bir gecikmeli değeri (DPF_{t-1}), Türkiye buğday fiyatlarının bir gecikmeli değeri (TBF_{t-1}), Türkiye mısır fiyatlarının bir gecikmeli değeri (TMF_{t-1}) olarak seçilmiştir. Çıkış (Target) ise Türkiye pamuk fiyatları (TPF_t) olarak seçilmiştir.

2000-2014 yıllarına ait aylık TPF_t, DPF_t, TBF_t ve TMF_t verileri TUİK ve başta İzmir Ticaret Borsası olmak yüksek işlem hacmine sahip ticaret borsalarının web sitelerinden elde edilmiştir.

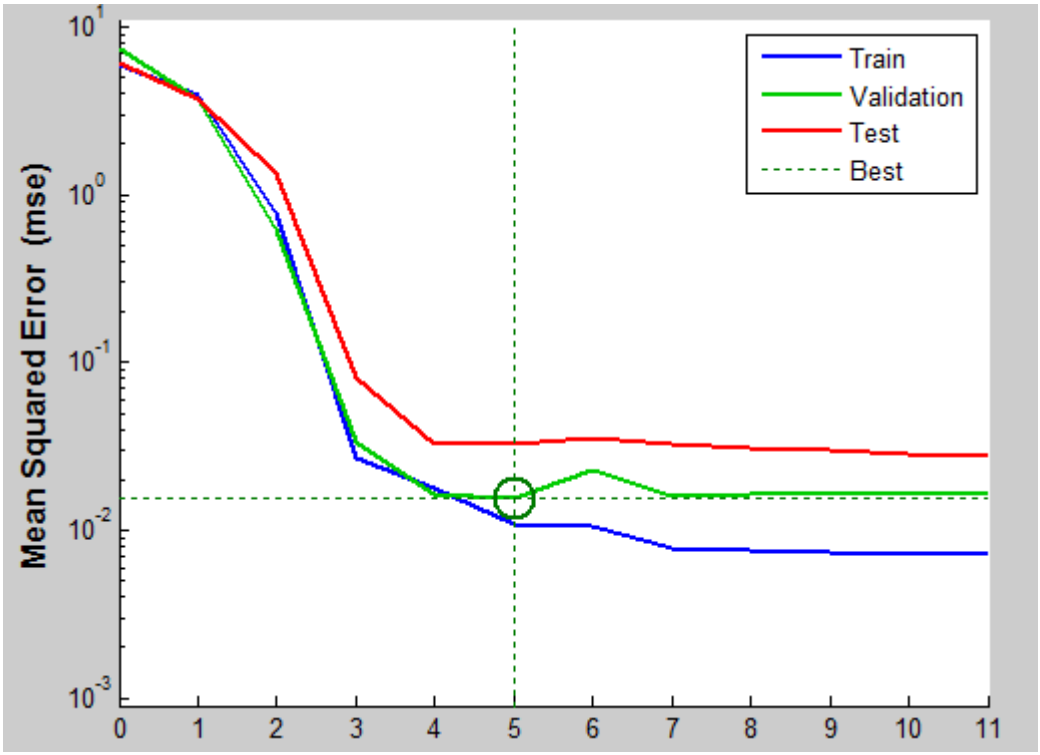
Yapılan denemeler sonucunda en uygun ağ mimarisi, Şekil 4.16.'da görüldüğü gibi 7 parametreden oluşan giriş katmanı, 7 nörona sahip bir gizli katman ve 1 çıkış katmanı olmak üzere (7-7-1) olarak oluşturulmuştur.



Şekil. 4. 16 YSA Ağ Mimarisi

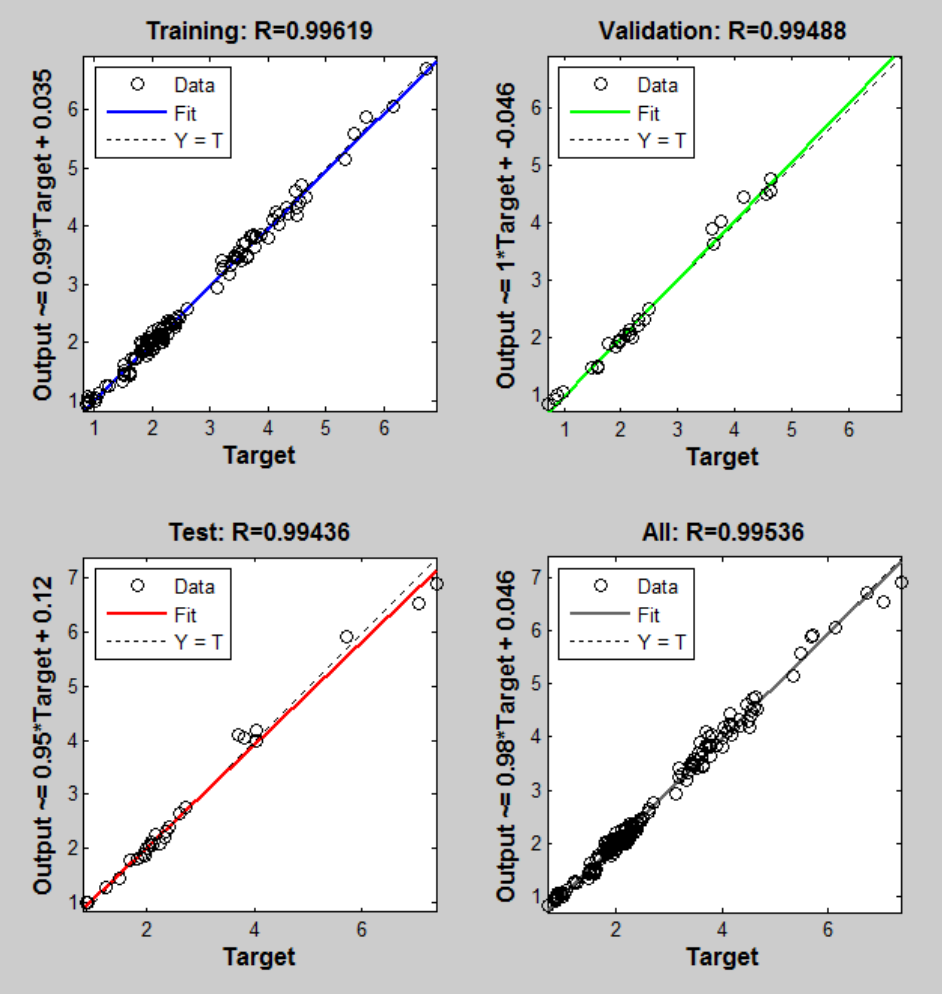
180 değerden oluşan veri setinin % 80'i eğitim veri seti, %10'u geçerlilik (validation) veri seti ve %10'u test veri seti olarak üç kısma ayrıştırılmıştır. Aktivasyon fonksiyonu olarak, giriş katmanı ile gizli katman arasında hiperbolik tanjant fonksiyonu, gizli katman ile çıkış katmanı arasında sigmoid fonksiyonu kullanılmıştır.

Öğrenme stratejisi olarak öğretmenli, diğer ismiyle danışmanlı öğrenme stratejisi kullanılmıştır. Ayrıca literatürde zaman serilerinde başarılı sonuçlar verdiği için kullanımı yaygın olan ileri beslemeli geri yayılımlı ağ tipi kullanılmıştır. Yapılan denemeler sonucunda en iyi neticeyi verdiği için Levenberg-Marquardt Backpropagation (LM) öğrenme algoritması tercih edilmiştir. Şekil 4.17.'de eğitim seti, validation (geçerlilik) seti ve test veri setinin, Yapay Sinir Ağının eğitilmesi sona erdikten sonra elde edilen hata kareleri ortalamaları gösterilmiştir.



Şekil 4.17. Hata Kareler Ortalaması

Şekil 4.18.'de ise eğitim seti, validation (geçerlilik) seti ve test veri setinden ağın eğitimi sonucunda elde edilen sonuçların regresyon grafikleri gösterilmiştir. Elde edilen tahmin sonuçlarının gerçekleşen değerlere çok yakın olduğu grafiklerden rahatça görülebilmektedir.



Şekil 4.18. Eğitim, Validation ve Test Veri Setlerinin Regresyon Grafikleri

Ayrıca YSA analizinin performansını ölçmek için MSE, RMSE, SSE ve MAPE performans kriterleri dikkate alınmış ve tahmin gücü hakkında fikir edinilmiştir.

4.5. Tahmin Sonuçlarının Karşılaştırmalı Olarak İncelenmesi

Çizelge 4.15.'te analize dâhil edilmeyen 07.2013-12.2014 tarihlerini kapsayan 18 aylık serinin gerçekleşen değeriyle YSA, ARIMA ve Çoklu Regresyon tahmin değerleri sırasıyla verilmiştir. YSA tahmin değerlerinin, ARIMA ve Çoklu Regresyon yöntemlerinden elde edilen tahmini değerlerden daha başarılı olduğunu söylemek mümkündür. ARIMA yönteminden elde edilen tahmini değerlerin diğer iki yönteme göre daha kötü bir performans sergilediğini söyleyebiliriz.

Çizelge 4.15. Gerçek ve Tahmini Değerler

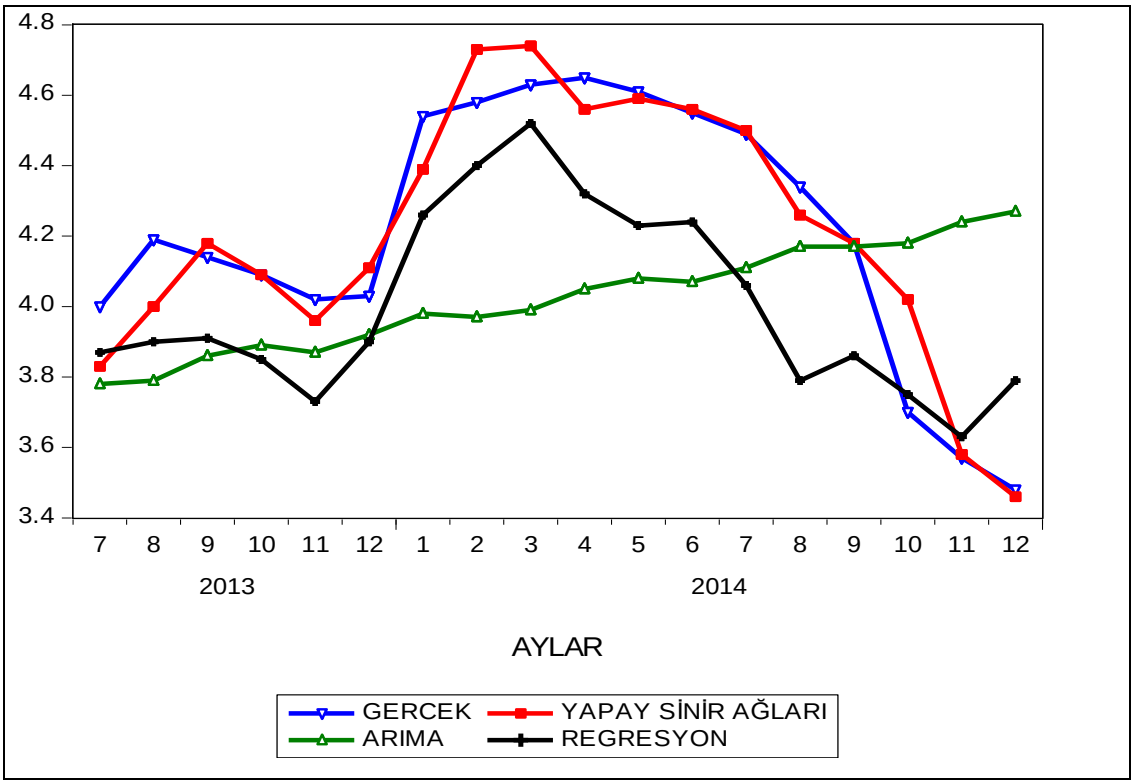
Tarih	Gerçekleşen Değer	YSA Tahmin değerleri	ARIMA Tahmin değerleri	Çoklu Regresyon Tahmin değerleri
07.2013	4.00	3.83	3.78	3.87
08.2013	4.19	4.00	3.79	3.90
09.2013	4.14	4.18	3.86	3.91
10.2013	4.09	4.09	3.89	3.85
11.2013	4.02	3.96	3.87	3.73
12.2013	4.03	4.11	3.92	3.90
01.2014	4.54	4.39	3.98	4.26
02.2014	4.58	4.73	3.97	4.40
03.2014	4.63	4.74	3.99	4.52
04.2014	4.65	4.56	4.05	4.32
05.2014	4.61	4.59	4.08	4.23
06.2014	4.55	4.56	4.07	4.24
07.2014	4.49	4.50	4.11	4.06
08.2014	4.34	4.26	4.17	3.79
09.2014	4.18	4.18	4.17	3.86
10.2014	3.70	4.02	4.18	3.75
11.2014	3.57	3.58	4.24	3.63
12.2014	3.48	3.46	4.27	3.79

Çizelge 4.16.'daki performans kriterleri incelendiğinde elde edilen değerler, ileri sürüdüğümüz açıklamaları destekler niteliktedir. Literatürde yaygın kullanılan MAPE, SSE, MSE ve RMSE performans kriter sonuçları incelendiğinde YSA yönteminin en küçük değerlere sahip olduğu görülmektedir.

Çizelge 4.16. Tahmin Yöntemlerinin Performans Karşılaştırması

	MAPE	SSE	MSE	RMSE
YSA	**2.0190***	**0.2517***	**0.0140***	**0.1183***
ARIMA	9.7112	3.8053	1.2114	1.1006
ÇOKLU REG.	6.0429	1.4851	0.0825	0.2872

Şekil 4.19.'da analizde kullanılan yöntemlerin son 18 aylık döneme ait verileri tahmin etmede gösterdikleri performans, grafiksel olarak gösterilmiştir. Grafikte de görüldüğü gibi YSA yönteminin, gerçek gözlem değerlerini başarılı bir şekilde tahmin ettiği görülmektedir.



Şekil. 4.19. Gerçek ve Tahmini Değerlerin Grafiksel Gösterimi

5. SONUÇLAR ve ÖNERİLER

5.1. Sonuçlar

Bu tez çalışmasında, geleneksel istatistiksel yöntemler içinde yaygın kullanımı olan Box-Jenkins ARIMA yöntemi ve Çoklu Regresyon Analizi ile mühendislik alanında geniş bir kullanım alanı olan özellikle son yıllarda iktisadi araştırmalarda da kullanılmaya başlanan Yapay Sinir Ağları yönteminin tahmin sonuçlarının karşılaştırmalı olarak incelenmesi amaçlanmıştır.

Yöntem karşılaştırmasında kullanılan zaman serisi verileri, 2000-2014 yıllarına ait aylık Türkiye pamuk fiyatları, Dünya pamuk fiyatları, Türkiye buğday fiyatları ve Türkiye mısır fiyatlarından oluşmaktadır. Toplam 180 adet verinin 01.2000 ile 06.2013 tarihlerini kapsayan bölümü analize dâhil edilmiş, 07.2013 ile 12.2014 tarihlerini kapsayan son 18 aylık kısım öngörü için modele dâhil edilmemiştir.

İlk olarak verilerin durağanlık koşulunu sağlayıp sağlamadığı araştırılmıştır. Bu amaçla verilere, ADF, Phillips-Perron ve KPSS birim kök testleri uygulanmış ve durağan olmadıkları görülmüştür. Verileri durağanlaştırmak için birinci farkları alınmış, tekrar birim kök testleri uygulanmış ve birinci farkları alındığında serilerin durağan olduğu sonucuna ulaşılmıştır.

Türkiye pamuk fiyat verilerine yapısal kırılmalı birim kök testi uygulanmıştır. Öncelikle tek bir yapısal kırılmaya izin veren Zivot-Andrews yapısal kırılma birim kök testi uygulanmıştır. Düzeyde kırılmayı ifade eden Model A, Eğimde kırılmayı ifade eden Model B ve her ikisinde de kırılmayı ifade eden Model C için yapılan birim kök testleri sonucunda, Model A'ya göre yapısal kırılma Mart – 2010 tarihinde, Model B'ye göre Nisan – 2007 tarihinde, Model C'ye göre ise Eylül – 2010 tarihinde gerçekleşmiştir. Ayrıca Model A ve Model B için bulunan test istatistikleri kritik değerlerden küçük olduğu için serinin durağan olmamasının yapısal kırılmalardan kaynaklanmadığını ileri süren temel hipotez kabul edilmiştir. Ancak Model C için bulunan test istatistik değeri kritik değerlerden büyük olduğu için serinin durağan olmama sebebinin yapısal kırılma olduğu sonucuna ulaşılmıştır. Ayrıca iki yapısal kırılmaya izin veren Lumsdaine-Papell yapısal kırılma birim kök

testi uygulanmıştır. Düzeyde kırılmayı ifade eden Model AA, düzey ve eğimi birlikte dikkate alan Model CC için yapılan birim kök testleri sonucunda, Model AA'ya göre yapısal kırılmalar Şubat – 2010 ve Nisan – 2010 tarihlerinde, Model CC'ye göre ise Ağustos – 2010 ve Ekim – 2012 tarihlerinde gerçekleşmiştir. Model AA ve Model CC için bulunan test istatistikleri kritik değerlerden küçük olduğu için serinin durağan olmamasının yapısal kırılmalardan kaynaklanmadığını ileri süren temel hipotez kabul edilmiştir.

Çoklu Regresyon Analizi için bağımlı değişken, aylık Türkiye pamuk fiyatları, açıklayıcı değişkenler ise aylık Dünya pamuk fiyatları, aylık Türkiye buğday fiyatları, aylık Türkiye mısır fiyatları ve bütün değişkenlerin birinci gecikmeli değerlerinden oluşmaktadır. Öncelikle modelde kullanılan değişkenlerin durağan olup olmadığı incelenmiştir. Durağan olmayan serilerle yapılan analizlerde sahte regresyon durumu ortaya çıkmakta ve elde edilen tahminler yanıltıcı olmaktadır. Değişkenlere ADF birim kök testi yapılmış ve birim kök içerdikleri görülmüştür. Değişkenlerin birinci farkı alındıktan sonra tekrar birim kök testi uygulanmış ve bütün değişkenlerin birinci farklarının durağan olduğu görülmüştür. Birinci farkları alınmış değişkenlere Çoklu Regresyon Analizi uygulandıktan sonra elde edilen tahmin değerlerinin varsayımları sağlayıp sağlamadığı kontrol edilmiştir. Yapılan testler sonucunda varsayımları sağlamadığı tespit edilmiştir. Ayrıca hata terimlerinin normal dağılmadığı gözlenmiştir. Tahmin modelinin hata terimleri grafiği incelenmiş ve bazı değerlerin aşırı sapma gösterdiği görülmüştür. Hem varsayımları sağlamak hem de modelin performansını arttırmak için aşırı sapma gösteren dönemler için kukla değişkenler oluşturulmuştur. Kukla değişkenli yeni model analize tabi tutulmuş ve varsayımları sağlayıp sağlamadığı tekrar test edilmiştir.

Çoklu Regresyon modelinin hata terimlerinin sabit varyanslı olup olmadığının tespiti için Breusch-Pagan-Godfrey ve White testi uygulanmıştır. Hata terimlerinin varyansının sabit olduğunu iddia eden temel hipotez reddedilememiş ve değişen varyans probleminin olmadığı sonucuna ulaşılmıştır. Çoklu Regresyon modelinden elde edilen hata terimleri arasında otokorelasyon olup olmadığının ortaya çıkarılması için Breusch-Godfrey LM testi uygulanmıştır. Hata terimleri

arasında bir ilişki olmadığını iddia eden temel hipotez reddedilememiş ve hata terimleri arasında otokorelasyon olmadığı sonucuna ulaşılmıştır. Çoklu Regresyon modelinde kullanılan bağımsız değişkenlerin birbirleriyle ilişkili olup olmadığını yani çoklu doğrusal bağlantıya sahip olup olmadığını tespit etmek için varyans büyütme faktörü ölçütü kullanılmıştır. Bütün VIF katsayıları 5'ten küçük bulunduğu için çoklu doğrusal bağlantıya sahip olmadığına karar verilmiştir.

Zaman serilerinde tek değişkenli öngörü teknikleri içinde en yaygın kullanımı olan yöntem Box-Jenkins ARIMA metodudur. Türkiye pamuk fiyatları serisinin birinci farkı alınıp durağan hale getirildikten sonra en uygun AR ve MA süreçlerini tespit etmek için denemeler yapılmış ve en iyi tahmin modelinin ARIMA (3,1,2) olduğuna karar verilmiştir. Ancak yapılan testlerle hata terimlerinin normal dağılmadığı ve otokorelasyon testlerinin de anlamlı çıktığı yani kalıntıların birbiriyle ilişkili olduğu görülmüştür. Ayrıca bazı kalıntı değerlerinin aşırı sapma gösterdiği gözlenmiştir. Hem otokorelasyon sorununu ortadan kaldırmak için hem de modelin performansını arttırmak için aşırı sapma gösteren dönemler için kukla değişkenler oluşturulmuştur. ARIMA (3,1,2) modeli, kukla değişkenler de eklendikten sonra tekrar analiz edilmiştir. Elde edilen sonuçlara, Jarque-Bera testi uygulanmış ve hata terimlerinin normal dağıldığını iddia eden temel hipotez kabul edilmiştir. Ayrıca Portmanteau testleri sonucunda ARIMA tahmin modelinin hata terimleri arasındaki korelasyon katsayıları istatistiksel olarak anlamsız bulunmuştur.

Geleneksel istatistik yöntemlerinin yanı sıra Yapay Sinir Ağlarıyla da uygulama yapılmıştır. Çeşitli ağ tiplerinin, gizli katman sayısının, gizli katmandaki nöron sayısının, öğrenme algoritmalarının, aktivasyon fonksiyonlarının farklı kombinasyonlarıyla denemeler yapılıp en uygun ağ mimarisi oluşturulmaya çalışılmıştır. Yapılan denemeler sonucunda en uygun ağ mimarisi, giriş katmanında 7, tek gizli katman, gizli katmanda 7 ve çıkış katmanında 1 nöron olmak üzere (7,7,1) olarak seçilmiştir. 180 değerden oluşan veri setinin % 80'i eğitim veri seti, %10'u geçerlilik (validation) veri seti ve %10'u test veri seti olarak üç kısma ayrıştırılmıştır. Aktivasyon fonksiyonu olarak, giriş katmanı ile gizli katman arasında hiperbolik tanjant fonksiyonu, gizli katman ile çıkış katmanı arasında sigmoid fonksiyonu kullanılmıştır. Öğrenme stratejisi olarak öğretmenli öğrenme, ağ tipi

olarak ileri beslemeli geri yayılımlı ağ ve öğrenme algoritması olarak da Levenberg – Marquardt Backpropagation (LM) öğrenme algoritması tercih edilmiştir.

Her üç tahmin yönteminden elde edilen katsayılarla, analize dâhil edilmeyen 07.2013 – 12.2014 tarihlerini kapsayan 18 aylık dönemle ilgili tahmin değerleri elde edilmiştir. YSA, ARIMA ve Çoklu Regresyon Analizi yöntemlerinin 18 aylık dönemle ilgili tahmin değerlerini karşılaştırmak için MAPE, SSE, MSE ve RMSE performans kriterleri hesaplanmıştır. Performans kriterleri için hesaplanan değerlerin minimum olması tercih edilmektedir. Elde edilen sonuçlar YSA'nın en iyi performansa sahip olduğunu göstermiştir. ARIMA modeli ise diğer modellere göre daha zayıf bir performans sergilemiştir.

5.2. Öneriler

İktisadi zaman serileri genelde durağan – dışı bir sürece sahiptirler. Geleneksel istatistiksel yöntemler, bazı kısıtlara ve varsayımlara sahip olmalarına rağmen bir takım düzenlemelerle başarılı bir şekilde öngörülerde bulunabilmektedirler. Son yıllarda geniş bir kullanım alanı bulan Yapay Sinir Ağları, insan beyninin çalışma prensibine göre sonuçlar üretmektedir. Herhangi bir varsayıma ve kısıtlamaya ihtiyaç duymadan sonuç üretebilmesi, karışık matematiksel modellere ihtiyaç duymaması, hatta eksik verilerle dahi çalışabilmesi, YSA'yı diğer analiz yöntemlerinden daha avantajlı hale getirmektedir. Belki de en önemli özelliği öğrenme kabiliyetine ve hafızaya sahip olmasıdır. Öğrenme kabiliyeti sayesinde ileriye yönelik öngörülerde sağlıklı sonuçlar üretebilmektedir. Ayrıca analiz sonucunda elde edilen katsayıları, benzer konularda yapılacak analizlerde kullanmak için belleğinde saklayarak araştırmacıya büyük kolaylıklar sağlamaktadır.

Bu tez çalışmasında elde edilen sonuçlar, Yapay Sinir Ağları metodunun iktisadi konularda, özellikle de ekonometrik zaman serisi modellerinde diğer alternatif modellere göre daha başarılı sonuçlar verdiğini göstermiştir. Geleceğe yönelik olarak başarılı iktisadi kararlar almada ve politika belirlemede Yapay Sinir Ağları metodolojisinden daha fazla istifade edilmesi ve kullanımının yaygınlaştırılması düşünülebilir.

KAYNAKLAR

ABDRAHMAN, N, H,. LEE, M, H,. LATIF, M, T,. and SUHARTONO,. 2013. Forecasting Of Air Pollution Index With Artificial Neural Network. Jurnal Teknologi, 63(2): 59-64.

ABUDU, S,. CUI, C, L,. KING, J, P,. and ABUDUKADEER, K,. 2010. Comparison Of Performance Of Statistical Models In Forecasting Monthly Streamflow Of Kizil River, China. Water Science And Engineering, 3(3): 269-281.

ADEBIYI, A, A,. ADEWUMI, A, O,. and AYE, C, K,. 2014. Comparison Of ARIMA And Artificial Neural Networks Models For Stock Price Prediction. Hindawi Publishing Corporation Journal Of Applied Mathematics, 1-7.

ADIYAMAN, F,. 2007. Talep Tahmininde Yapay Sinir Ağlarının Kullanılması. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul, 98s.

AKAIKE, H,. 1973. Information Theory and An Extension of The Maximum Likelihood Principle. InB.N. Petro and F. Csaki ed. 2nd International Symposium on Information Theory, 267-281.

AKAYTAY, A., 2010. Bağımsız Denetimin Etkinliğini Arttırma Aracı Olarak Yapay Sinir Ağları: Analitik Bir İnceleme. Sakarya Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, Sakarya, 185s.

AKGÜL, I., 2003. Zaman Serilerinin Analizi ve ARIMA Modelleri. DER Yayınları, İstanbul, 251s.

AKKAYA, Ş,. PAZARLIOĞLU, M, V,. Ekonometri I. Berk Masa Üstü Yayıncılık, İzmir, 581s.

ALİZADEH, M,. 2011. Yapay Sinir Ağları İle Fiyat Tahmin Analizi. İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul, 90s.

ANONİM, 2011. http://www.dunya.com/guncel/ham-petroldeki-artis-pamuk-fiyatlarini-ziplatti-1159774h.htm

ANONİM, 2013. Pamuk Raporu, Gümrük ve Ticaret Bakanlığı, Kooperatifçilik Genel Müdürlüğü.

ANONİM, 2014a. http://www.tarispamuk.com.tr

ANONİM, 2014b. http://www.upk.org.tr/

ANONİM, 2014c. Gıda Tarım ve Hayvancılık Bakanlığı, Pamuk Araştırma İstasyonu, Nazilli/AYDIN.

ANONİM, 2014d. http://teknogezegen.com/yapay-sinir-aglari/

ANONİM, 2015a. http://www.mathworks.com

ANONİM, 2015b. http://www.biyolojidersnotlari.com

ANONİM, 2015c. http://tr.wikipedia.org/wiki/pamuk

ARABACI, Ö., 2007. Makroekonomik Zaman Serisi ve Yapay Sinir Ağı Uygulamaları. Uludağ Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, Bursa, 198s.

ASİLKAN, Ö,. IRMAK, S,. 2009. İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları İle Tahmin Edilmesi. Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, 14(2): 375-391.

ATASEVEN, B., 2007. "Satış Öngörü Modellemesi Tekniği Olarak Yapay Sinir Ağlarının Kullanımı: "Petkim'de Uygulanması".Celal Bayar Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Manisa, 118s.

AZAD, A, K,. MAHSIN, M,. 2011. Forecasting Exchange Rates Of Bangladesh Using ANN And ARIMA Models: A Comparative Study. International Journal Of Advanced Engineering Sciences And Technologies, 10(1): 31-36.

BARIŞIK, S,. ÇEVİK, E, İ,. 2008. Yapısal Kırılma Testleri Türkiye'de İşsizlik Histerisinin Analizi: 1923-2006 Dönemi. KMU İİBF Dergisi, 8(14): 109-134.

BAŞ, N., 2006. Yapay Sinir Ağları Yaklaşımı ve Bir Uygulama. Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul, 114s.

BATMAN, M, A., 2001. Elektrik Üretimi İçin Güneş Pillerinin Kullanımında Verimi Arttırıcı Yeni Bir Yöntem. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, İstanbul, 2001, 104s.

BAYATA, H, F,. HATTATOĞLU, F,. 2010. Yapay Sinir Ağları ve Çok Değişkenli İstatistik Yöntemlerle Trafik Kaza Modellemesi. Erzincan Üniversitesi, Fen Bilimleri Enstitüsü Dergisi, 3(2): 207-219.

BAYIR, F., 2006. Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama. İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, İstanbul, 122s.

BAYRU, P., 2007. Elektronik Basında Tüketici Tercihleri Analizi: Yapay Sinir Ağları İle Lojit Modelin Performans Değerlendirilmesi. İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, İstanbul, 224s.

BİÇEN, C., 2006. Box Jenkins Zaman Serisi Analiz Yöntemi İle İleri Beslemeli Yapay Sinir Ağları Tahminlerinin Karşılaştırılması. Hacettepe Üniversitesi, Sağlık Bilimleri Enstitüsü, Yüksek Lisans Tezi, Ankara, 104s.

BOX, G, E, P,. JENKINS, G, M,. 1976. Time Series Analysis Forecasting and Control. Holden Day, San Francisco, 575s.

BOX, G, E, P,. PIERCE, D, A,. 1970. Distribution of Residual Correlations in Autoregressive-Integrated Moving Average Time Series Models. *Journal of The American Statistical Association*, 65: 1509–1526.

BOZKURT, H, Y,. 2013. Zaman Serileri Analizi. Ekin Yayınevi, Bursa, 261s.

BROOMHEAD, D. ve LOWE, S., 1988. Radial Basis-Functions, Multi-Variable Functional Interpolation and Adaptive Networks. Royal Signals and Radar Establishment Memorandum, No: 4148, 1-31.

CHATTOPADHYAY, S,. JHAJHARIA, D,. and CHATTOPADHYAY, G,. 2011. Trend Estimation And Univariate Forecast Of The Sunspot Numbers: Development And Comparison Of ARMA, ARIMA And Autoregressive Neural Network Models. Comptes Rendus Geoscience, 343: 433-442.

CONTRERAS, J,. ESPINOLA, R,. NOGALES, F, J,. and CONEJO, A, J,. 2003. Arıma Models To Predict Next-Day Electricity Prices. IEEE Transactions On Power Systems, 18(3): 1014-1020.

ÇELİK, B., 2008. Yapay Sinir Ağları Metodolojisi İle Zaman Serisi Analizi: Teori ve Uygulama. Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, İstanbul, 224s.

ÇELİK, M, K,. 2010. Bankaların Finansal Başarısızlıklarının Geleneksel ve Yeni Yöntemlerle Öngörüsü. YÖNETİM VE EKONOMİ, 17(2): 135-143.

ÇUHADAR, M,. GÜNGÖR, İ,. ve GÖKSU, A,. 2009. Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi Dergisi, 14(1): 99-114.

ÇUHADAR, M., 2006. Turizm Sektöründe Talep Tahmini İçin Yapay Sinir Ağları Kullanımı ve Diğer Yöntemlerle Karşılaştırmalı Analizi (Antalya İlinin Dış

Turizm Talebinde Uygulama). Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, Isparta, 174s.
DAVID, D., B., LUMSDAINE, R., L., and PAPELL, D., H., 2003. Unit Roots, Postwar Slowdowns and Long-Run Growth: Evidence From Two Structural Breaks. Empiricial Economics, 303-319.
DEMİR, R., 2007. Yapay Sinir Ağları Yardımı İle Şirket Birleşmelerinin Kestirimi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul, 91s.
DIAZ-ROBLES, L, A,. ORTEGA, J, C,. FU, J, S,. REED, G, D,. CHOW, J, C,. WATSON, J, G,. and MONCADA-HERRERA, J, A,. 2008. A Hybrid ARIMA And Artificial Neural Networks Model To Forecast Particulate Matter In Urban Areas: The Case Of Temuco, Chile. Atmospheric Environment, 42: 8331-8340.
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, Vol: 74(366): 427-431.
DİLİŞEN, B,. 2007. Yapısal Kırılma Durumunda Geliştirilen Birim Kök Testleri ve Uygulaması. Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, İstanbul, 87s.
DOĞAN, A,. 2002. Yapay Zeka. Kariyer Yayıncılık, İstanbul, 134s.
DOĞAN, G., 2010. Yapay Sinir Ağları Kullanılarak Türkiye'deki Özel Bir Sigorta Şirketinde Portföy Değerlendirmesi. Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Ankara, 116s.
DOĞAN, Z,. 2000. Zaman Serilerinin Analizinde ARIMA ve Deterministik Modellerin İncelenmesi. Harran Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Şanlıurfa, 161s.
ELMA, Ç, A,. 2008. Yapısal Kırılmalar Altında Birim Kök Testleri ve Eşbütünleşme Analizi: Para Talebi İstikrarı. Gazi Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Ankara, 84s.
ELMAS, B,. YAKUT, E,. ve ALKAN, Ö,. 2011. İşletmelerin Mali Başarısızlığının Yapay Sinir Ağları ve Lojistik Regresyon Modeli İle Tahmin Edilmesi. Finans Politik ve Ekonomik Yorumlar, 48(560): 45-56.
ELMAS, Ç., 2010. Yapay Zeka Uygulamaları. Seçkin Yayıncılık, Ankara, 424s.
ERDOĞAN, G,. 2006. Yapay Sinir Ağları İle İktisadi ve Finansal Zaman Dizilerinin Kestirimi. Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Ankara, 2006, 138s.
ERİLLİ, N, A,. EĞRİOĞLU, E,. YOLCU, U,. ALADAĞ, Ç, H,. ve USLU, V, R,. 2010. Türkiye'de Enflasyonun İleri ve Geri Beslemeli Yapay Sinir Ağlarının Melez Yaklaşımı İle Öngörüsü. Doğuş Üniversitesi Dergisi, 11(1), 42-55.
ERSÖZ, S,. YAMAN, N,. ve BİRGÖREN, B,. 2008. Müşteri İlişkileri Yönetiminde Verilerin Yapay Sinir Ağları İle Modellenmesi ve Analizi. Gazi Üniversitesi, Mühendislik Mimarlık Fakültesi Dergisi, 23(4): 759-767.
FAHIMIFARD, S, M,. HOMAYOUNIFAR, M,. SABOUHI, M,. and MOGHADDAMNIA, A, R,. 2009. Comparison Of ANFIS, ANN, GARCH And ARIMA Tecniques To Exchange Rate Gorecasting. Journal Of Applied Sciences, 9(20): 3641-3651.
GUJARATİ, D, N,. 2000. Temel Ekonometri. Literatür Yayıncılık, İstanbul, 849s.
GÜRİŞ, S,. ÇAĞLAYAN, E,. 2010. Ekonometri Temel Kavramlar. DER Yayınları, İstanbul, 807s.

GÜRSAKAL, G,. 2005. GSMH Zaman Serileri. Uludağ Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Bursa, 94s.

GÜVENEK, B,. ALPTEKİN, V,. ve ÇETİNKAYA, M,. 2010. Enflasyon ve Dolaylı Vergilerden Elde Edilen Gelirler Arasındaki İlişkinin VAR Yöntemiyle Analizi. Kamu-İş; 11(3): 1-28.

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

HAMZAÇEBİ, C., 2011. Yapay Sinir Ağları. Ekin Yayınevi, Bursa, 133s.

HEBB, D., 1949. The Organization of Behavior.

HOPFIELD, J., 1982. Neural Networks and Physical Systems With Emergent Collective Computational Abilities, Proceedings of the National Academy of Sciences, 79, 2554-2558s.

İĞDE, E,. 2010. Yapısal Değişiklik Altında Birim Kök Testleri ve Bazı Makro İktisadi Değişkenler Üzerine Uygulamalar. Çukurova Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Adana, 103s.

KAPUCUGİL, A,. 2005. Halka Arzların İlk Gün Fiyat Performanslarının Tahmininde Yapay Sinir Ağlarının Kullanımı. Dokuz Eylül Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, İzmir, 135s.

KARAHAN, M., 2011. İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu İle Ürün Talep Tahmini Uygulaması. Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, Konya, 141s.

KAYNAR, O,. TAŞTAN, S,. 2009. Zaman Serileri Analizinde MLP Yapay Sinir Ağları ve ARIMA Modelinin Karşılaştırılması. Erciyes Üniversitesi, İktisadi ve İdari Bilimler Fakültesi Dergisi, Sayı: 33, 161-172.

KILIÇ, A,. 2013. Türkiye'de Pamuğun Uluslararası Rekabet Analizi ve Rekabet Koşullarını Etkileyen Faktörlerin Belirlenmesi. Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Adana, 216s.

KIRAÇ, N., 2011. Türkiye'de Faaliyet Gösteren Ticari Bankaların Finansal Risklerinin Yapay Sinir Ağları Yaklaşımı İle Belirlenmesi. Çukurova Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Adana, 41s.

KOHONEN, T., 1972. Correlation Matrix Memories. Computers, IEEE Transactions on. C-21(4): 353-359.

KORKMAZ, Ö,. MAHİROĞLU, A,. 2007. Beyin, Bellek ve Öğrenme. Kastamonu Eğitim Dergisi. 15(1): 93-104.

KUO, K, C,. CHANG, C, Y,. and LIN, W, C,. 2013. To Predict Military Spending In China Based On ARIMA And Artificial Neural Networks Models. Przeglad Elektrotechniczny, 89(3b): 176-181.

KUTLAR, A,. 2005. Uygulamalı Ekonometri. Nobel Yayın Dağıtım, Ankara, 429s.

KÜÇÜKÖNDER, H., 2011. Yapay Sinir Ağları ve Tarımda Bir Uygulama. Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Kahramanmaraş, 147s.

KWIATKOWSKI, D,. PHILLIPS, P, C, B,. SCHMIDT, P,. and SHIN, Y,. 1992. Testing The Null Hypothesis Of Stationarity Against The Alternative Of A Unit Root. Journal Of Econometrics, Vol: 54, 159-178.

LJUNG, G. M,. BOX, G, E, P,. 1978. On A Measure of Lack of Fit In Time Series Models. *Biometrika,* 65: 297–303.

LUMSDAİNE, R, L,. PAPELL, D, H,. 1997. Multiple Trend Breaks And The Unit-Root Hypothesis. The Review Of Economics And Statistics, 79(2): 212-218.

MBAREK, M, B,. FEKI, R,. 2013. GDP And Unemployment Rate In Turkey: An Empiricial Study Using Neural Networks. International Journal Of Economics, Finance And Management, 2(1): 154-159.

McCULLOCH, W, S,. ve PITTS, W., 1943. A Logical Calculus Of Ideas Immanent in Nervous Activity. Bulletin of Mathematical Biophysics, (5), 115-133.

MINSKY, M., ve PAPERT, S., 1987. Perceptrons, An Introduction to Computational Geometry. The MIT Press, 308s.

MIRSOLTANI, S, M,. NIAKI, S, T, A,. 2013. Forecasting Energy Price And Consumption For Iranian Industrial Sectors Using ANN And ANFIS. Iranian Journal Of Economic Studies, 2(1): 73-102.

MISHRA, G, C,. SINGH, A,. 2013. A Study On Forecasting Prices Of Groundnut Oil In Delhi By Arima Methodology And Artificial Neural Networks. Agris On-line Papers In Economics And Informatics, 5(2): 25-34.

MOROVA, N,. TERZİ, S,. 2010. Trafik Kaynaklı Gürültünün Yapay Sinir Ağları İle Tahmini. e-Journal Of New World Sciences Academy, 6(1): 486-496.

NABİYEV, V, V,. 2012. Yapay Zeka. Seçkin Yayıncılık. Ankara, 775s.

ÖNDER, A,. HASGÜL, Ö,.2009. Yabancı Ziyaretçi Sayısının Tahmininde Box-Jenkins Modeli, Winters Yöntemi ve Yapay Sinir Ağlarıyla Zaman Serisi Analizi. İstanbul Üniversitesi, İşletme İktisadı Enstitüsü Yönetim Dergisi, Sayı: 62, 62-83.

ÖZDEMİR, Ö., 2008. Zaman Serisi Modellemesinde Yapay Sinir Ağlarının Kullanımı ve Bir Uygulama. Anadolu Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Eskişehir, 110s.

ÖZGEN, D., 2007. Yapay Sinir Ağları Analizi ve Türk Finans Piyasaları: İMKB 30 Endeksi Uygulaması. Marmara Üniversitesi, Bankacılık ve Sigortacılık Enstitüsü, Marmara Üniversitesi, İstanbul, 125s.

ÖZKAN, F,. 2012. Döviz Kuru Tahmininde Parasal Model ve Yapay Sinir Ağları Karşılaştırması. Business and Economics Research Journal, 3(1): 27-39.

ÖZTEMEL, E., 2012. Yapay Sinir Ağları. Papatya Yayıncılık, İstanbul, 232s.

PAO, H, T,. 2007. A Comparison Of Neural Network And Multiple Regression Analysis In Modeling Capital Structure. Expert Systems With Applications, 35, 720-727.

PERRON, P,. 1989. The Great Crash, The Oil Price Shock, And The Unit Root Hypothesis. Econometrica, 57(6): 1361-1401.

PHILLIPS, P, C, B,. PERRON, P,. 1988. Testing For A Unit Root In Time Series Regression. Biometrika, Vol: 75, 335-346.

POLAT, Ö., 2009. Türkiye'nin Dış Ticaret Verilerinin Öngörüsünde Yapay Sinir Ağları ve Box-Jenkins Modellerinin Karşılaştırmalı Analizi. Atatürk Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, Erzurum, 161s.

RUMELHART, D.E., HINTON, G, E,. and WILLIAMS, R, j,. 1986. Learning Representations By Back-Propagating Error. Nature Publishing Group, 323, 533-536s.

SAFI, S, K,. 2013. Artificial Neural Networks Approach To Time Series Forecasting For Electricity Consumption In Gaza Strip. IUG Journal Of Natural And Engineering Studies, 21(2): 1-22.

SARAÇ, T,. 2004. Yapay Sinir Ağları. Gazi Üniversitesi, Endüstri Mühendisliği Bölümü, Seminer Projesi. Ankara, 75s.
SAYGILI, Y, S., 2008. İstatistiksel Yöntemlerle Yapay Sinir Ağları Uygulamalarının Karşılaştırılması: Milli Savunma Bakanlığı Bütçesinin Öngörülmesi. Kara Harp Okulu, Savunma Bilimleri Enstitüsü, Ankara, 93s.
SCWARZ, G. 1978. Estimating The Dimensions of A Model. The Annals of Statistical, Vol: 6, 461-464.
SEVÜKTEKİN, M,. 2013. Ekonometriye Giriş. DORA Basım-Yayın, Bursa, 601s.
SEVÜKTEKİN, M., NARGELEÇEKENLER, M., 2010. Ekonometrik Zaman Serileri Analizi EViews Uygulamalı. Nobel Yayın Dağıtım, Ankara, 591s.
TARI, R,. 2002. Ekonometri. AlfaYayınları. İstanbul, 407s.
TOLON, M,. TOSUNOĞLU, N, G,. 2008. Tüketici Tatmini Verilerinin Analizi: Yapay Sinir Ağları ve Regresyon Analizi Karşılaştırması. Gazi Üniversitesi, İktisadi ve İdari Bilimler Fakültesi Dergisi, 10(2): 247-259.
TURING, A, M,. 1950. Computing Machinery and Intelligence. Mind 49: 433-460.
TÜRKYILMAZ, A., 2007. Müşteri Memnuniyet İndeks Modeli Önerisi ve Model Tahmininde Kısmi En Küçük Kareler ve Yapay Sinir Ağları Metodu Kullanımı. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, İstanbul, 109s.
UCAL, M, Ş,. 2006. Ekonometrik Model Seçim Kriterleri Üzerine Kısa Bir İnceleme. Cumhuriyet Üniversitesi, İktisadi ve İdari Bilimler Fakültesi Dergisi, Cilt 7(2): 41-57
USTA, A, S., 2007. Yapay Sinir Ağları Uygulaması Kullanılarak Üretici Fiyat Endeksi (ÜFE) Değerlerinin Öngörü Modellemesi ve Analizi. Yıldız Teknik Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, İstanbul, 99s.
ÜNLÜ, U,. YILDIZ, B,. ve YALAMA, A,. 2009. İlk Halka Arzlarda Uzun Dönem Getirilerinin Tahmini: Yapay Sinir Ağları İle İMKB İçin Ampirik Bir Çalışma. İstanbul Üniversitesi, İktisat Fakültesi, Ekonometri ve İstatistik Dergisi, Sayı: 10, 29-47.
VAZIRI, M,. 1997. Predicting Caspian Sea Surface Water Level By ANN And ARIMA Models. Journal Of Waterway, Port, Coastal And Ocean Engineering. 123(4): 158-162.
VURAL, B, B., 2007. Yapay Sinir Ağları İle Finansal Tahmin. Ankara Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Ankara, 161s.
WERBOS, P. J., 1974. Beyond Regression: New Tools For Prediction and Analysis in the Behavioral Sciences, PhD Thesis, Harvard University, 906s.
WOOLDRIDGE, J, M,. 2013. Introductory Econometrics A Modern Approach. Dördüncü Basımdan Çeviri, Cilt 1, Nodel Akademik Yayıncılık, Ankara, 609s.
YAVUZ, N, Ç,. 2004. Durağanlığın Belirlenmesinde KPSS ve ADF Testleri: İMKB Ulusal-100 Endeksi İle Bir Uygulama. İktisat Fakültesi Mecmuası, 239-247.
YAVUZ, N, Ç,. 2006. Türkiye'de Turizm Gelirlerinin Ekonomik Büyümeye Etkisinin Testi: Yapısal Kırılma ve Nedensellik Analizi. Doğuş Üniversitesi Dergisi, 7(2): 162-171.
YILANCI, V,. 2009. Yapısal Kırılmalar Altında Türkiye İçin İşsizlik Histerisinin Sınanması. Doğuş Üniversitesi Dergisi, 10(2): 324-335.
YILANCI, V,. ÖZTÜRK, Z, A,. 2010. Türkiye İle En Büyük Beş Ticaret Ortağının Hisse Senedi Piyasaları Arasındaki Entegrasyon İlişkisinin Analizi: Yapısal

Kırılmalı Birim Kök ve Eşbütünleşme Analizi. Erciyes Üniversitesi, İktisadi ve İdari Bilimler Fakültesi Dergisi, Sayı:36: 261-279.

YILDIRIM, B,. 2010. Yapısal Kırılma Durumunda Birim Kök Testleri ve Gelir Yakınsaması Analizi: Avrupa Birliği'ne Üye ve Aday Ülkeler İçin. İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, İstanbul, 175s.

YILDIZ, D., 2009. Zaman Serileri Analizi ve Yapay Sinir Ağları İle Tahmin: Yabancı Portföy Yatırımları Üzerine Uygulama. Ankara Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, Ankara, 203s.

YURTOĞLU, H., 2005. Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği. Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü, DPT Uzmanlık Tezi, Yayın No: DPT: 2683, 104s.

ZADEH, L, A., 1965. Fuzzy Sets "Information and Control. Vol: 8, No: 3, 338-353.

ZİVOT, E,. ANDREWS, D, W, K,. 1992. Further Evidence On The Great Crash, The Oil-Price Shock, And The Unit-Root Hypothesis. Journal Of Business Economic Statistics,10(3): 251-270.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Levent KAYA
Uyruğu : T.C.
Doğum Yeri ve Tarihi : Diyarbakır - 1975
Telefon : 506 234 54 35
Faks : 0 414 318 35 34
e-mail : lekaya@harran.edu.tr

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Anadolu Teknik Lisesi, Diyarbakır	1993
Üniversite	: İnönü Üniversitesi, İİBF, Ekonometri Böl. Malatya	1999
Yüksek Lisans	: Harran Üni. Fen Bil. Ens. Zootekni ABD., Ş.Urfa	2008
Doktora	: Harran Üni. Fen Bil. Ens. Tarım Eko. ABD. Ş.Urfa	2015

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2002-	Harran Üniversitesi İİBF	Araştırma Görevlisi

UZMANLIK ALANI: Ekonometri, İstatistik

YABANCI DİLLER: İngilizce

YAYINLAR

DOĞAN, Z., **KAYA, L.**, ÖZTÜRK, İ., ŞENGÜL, T. 2006. AB Sürecinde Türkiye Hayvancılık Politikaları ve Bir Örneklemesi Olan GAP Bölgesi Hayvancılığına Ait Bazı Parametrelerin Karşılaştırmalı Olarak İncelenmesi. Ziraat Mühendisliği Dergisi, Sayı:346, s.14-21.

KAYA, L., DOĞAN, Z. 2008. Farklı Kekik Ekstratlarının Bıldırcınların Lökosit Hücrelerindeki DNA Hasarı Üzerine Etkilerinin Kruskal-Wallis Testi İle İncelenmesi. Zootekni Öğrenci Kongresi; s.18-23. SAMSUN.

KAYA, L., DOĞAN, Z. 2010. Hayvancılık Denemelerinde Birden Fazla Değişken İçeren Setler Arasındaki İlişkinin Kanonik Korelasyon Analizi İle Belirlenmesi. EKEV Akademi Dergisi, Yıl:14, Sayı:43; s.349-366.

EREN, G., BİLGİÇ, A., KARLI, B., **KAYA. L.,** SAYASLAN, A., KESKİN, G., GÜNDEN. C. 2010. GD'li ve GD'siz Mısır Gevreğinde Fiyat Artış Simülasyonlarının Tüketici Satın Alma Olasılıklarına Etkileri. Türkiye IX. Tarım Ekonomisi Kongresi, s. 281-288. ŞANLIURFA.

KARLI, B., BİLGİÇ, A., **KAYA, L.**, MİRAN, B., ÇELİK, Ş., SAYASLAN, A., EREN, G., 2010. Farklı Fiyat Senaryolarının GD'li ve GD'siz Mısır Yağı Satın Alma Olasılıklarına Etkileri. Türkiye IX. Tarım Ekonomisi Kongresi, s. 289-296. ŞANLIURFA.

DOĞAN, Z., ORHAN, H., **KAYA, L.**, ÖZTÜRK, İ., YURTSEVEN, S., 2012. Determination of relationship between nutrient and milk yield components of German fawn X hair crossbred by canonical correlation analysis. African Journal of Agricultural Research. Vol. 7(6), pp. 964-969.