

AKDENİZ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

Mahmut Burak ERTURAN

ZAMAN SERİLERİ İÇİN OPTİMİZE ARIMA – YSA HİBRİT MODELİ VE FİNANSAL
ZAMAN SERİLERİ İLE ÖRNEK UYGULAMALAR

Ekonometri Ana Bilim Dalı
Doktora Tezi

Antalya, 2017

AKDENİZ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

Mahmut Burak ERTURAN

ZAMAN SERİLERİ İÇİN OPTİMİZE ARIMA – YSA HİBRİT MODELİ VE FİNANSAL
ZAMAN SERİLERİ İLE ÖRNEK UYGULAMALAR

Danışman

Doç. Dr. Fahriye UYSAL

Ekonometri Ana Bilim Dalı

Doktora Tezi

Antalya, 2017

T.C.
Akdeniz Üniversitesi
Sosyal Bilimler Enstitüsü Müdürlüğüne,

Mahmut Burak ERTURAN'ın bu çalışması, jürimiz tarafından Ekonometri Ana Bilim Dalı Doktora Programı tezi olarak kabul edilmiştir.

Başkan : Prof. Dr. Sibel SELİM (İmza)

Üye (Danışmanı) : Doç. Dr. Fahriye UYSAL (İmza)

Üye : Yrd. Doç. Dr. Ayça BÜYÜKYILMAZ (İmza)

Üye : Yrd. Doç. Dr. Serkan ARAS (İmza)

Üye : Doç. Dr. Sezgin IRMAK (İmza)

Tez Başlığı: Zaman Serileri İçin Optimize ARIMA – YSA Hibrit Modeli ve Finansal Zaman Serileri ile Örnek Uygulamalar

Onay: Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.

Tez Savunma Tarihi : 19/06/2017

Mezuniyet Tarihi : 20/07/2017

(İmza)

Prof. Dr. İhsan BULUT

Müdür

AKADEMİK BEYAN

Doktora Tezi olarak sunduğum “Zaman Serileri İçin Optimize ARIMA – YSA Hibrit Modeli ve Finansal Zaman Serileri ile Örnek Uygulamalar” adlı bu çalışmanın, akademik kural ve etik değerlere uygun bir biçimde tarafımdan yazıldığını, yararlandığım bütün eserlerin kaynakçada gösterildiğini ve çalışma içerisinde bu eserlere atıf yapıldığını belirtir; bunu şerefimle doğrularım.

(İmza)

Mahmut Burak ERTURAN





T.C.
AKDENİZ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
TEZ ÇALIŞMASI ORJİNALLİK RAPORU



SOSYAL BİLİMLER ENSTİTÜSÜ MÜDÜRLÜĞÜ'NE

ÖĞRENCİ BİLGİLERİ	
Adı-Soyadı	Mahmut Burak ERTURAN
Öğrenci Numarası	20128605203
Enstitü Ana Bilim Dalı	Ekonometri
Programı	Doktora
Programın Türü	() Tezli Yüksek Lisans (X) Doktora () Tezsiz Yüksek Lisans
Danışmanın Unvanı, Adı-Soyadı	Doç. Dr. Fahriye UYSAL
Tez Başlığı	Zaman Serileri İçin Optimize ARIMA – YSA Hibrit Modeli ve Finansal Zaman Serileri ile Örnek Uygulamalar
Turnitin Ödev Numarası	829144000

Yukarıda başlığı belirtilen tez çalışmasının a) Kapak sayfası, b) Giriş, c) Ana Bölümler ve d) Sonuç kısımlarından oluşan toplam 115 sayfalık kısmına ilişkin olarak, 05/07/2017 tarihinde tarafımdan Turnitin adlı intihal tespit programından Sosyal Bilimler Enstitüsü Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Uygulama Esasları'nda belirlenen filtrelemeler uygulanarak alınmış olan ve ekte sunulan rapora göre, tezin/dönem projesinin benzerlik oranı;

alıntılar hariç % 4

alıntılar dahil % 4 'tür.

Danışman tarafından uygun olan seçenek işaretlenmelidir:

(X) Benzerlik oranları belirlenen limitleri aşmıyor ise;

Yukarıda yer alan beyanın ve ekte sunulan Tez Çalışması Orijinallik Raporu'nun doğruluğunu onaylarım.

() Benzerlik oranları belirlenen limitleri aşıyor, ancak tez/dönem projesi danışmanı intihal yapılmadığı kanısında ise;

Yukarıda yer alan beyanın ve ekte sunulan Tez Çalışması Orijinallik Raporu'nun doğruluğunu onaylar ve Uygulama Esasları'nda öngörülen yüzdeler sınırlarının aşılmasına karşın, aşağıda belirtilen gerekçe ile intihal yapılmadığı kanısında olduğumu beyan ederim.

Gerekçe:

Benzerlik taraması yukarıda verilen ölçütlerin ışığı altında tarafımda yapılmıştır. İlgili tezin orijinallik raporunun uygun olduğunu beyan ederim.

05/07/2017

(İmza)

Doç. Dr. Fahriye UYSAL

İÇİNDEKİLER

ŞEKİLLER LİSTESİ.....	iv
TABLOLAR LİSTESİ.....	vi
KISALTMALAR LİSTESİ.....	ix
ÖZET.....	x
SUMMARY.....	xii
GİRİŞ.....	1

BİRİNCİ BÖLÜM

ZAMAN SERİLERİ VE TEMEL KAVRAMLAR

1.1. Durağanlık.....	3
1.1.1. Dickey – Fuller Testi (DF).....	4
1.1.2. Güçlendirilmiş Dickey – Fuller Testi (ADF).....	5
1.1.3. KPSS Testi.....	6
1.2. Otokorelasyon ve Kısmi Otokorelasyon.....	6
1.2.1. Otokorelasyon Fonksiyonu (ACF).....	7
1.2.2. Kısmi Otokorelasyon Fonksiyonu (PACF).....	7
1.2.3. Korelogram.....	8
1.3. Beyaz Gürültü.....	9
1.4. Zaman Serilerinde Bileşenlere Ayırma.....	9
1.5. Zaman Serisi Modelleri.....	13

İKİNCİ BÖLÜM

ARIMA, YSA VE HİBRİT ARIMA – YSA MODELLERİ

2.1. ARIMA Modeli.....	14
2.1.1. Otoregresif Model.....	14
2.1.2. Hareketli Ortalamalar Modeli.....	15
2.1.3. Otoregresif Hareketli Ortalamalar Modeli.....	15
2.1.4. Otoregresif Entegre Hareketli Ortalamalar Modeli.....	16
2.1.4.1. Model Seçimi.....	17
2.2. Yapay Sinir Ağları Modeli.....	20

2.2.1. Tanım ve Temel Kavramlar.....	20
2.2.2. Ağ Mimarisi.....	24
2.2.2.1. Tek Katmanlı İleri Beslemeli Ağlar.....	24
2.2.2.2. Çok Katmanlı İleri Beslemeli Ağlar.....	24
2.2.2.3. Yinelemeli Ağlar.....	25
2.2.3. Öğrenme.....	26
2.2.3.1. Denetimsiz Öğrenme.....	26
2.2.3.2. Güçlendirilmiş Öğrenme.....	26
2.2.3.3. Denetimli Öğrenme.....	26
2.2.4. Eğitim.....	27
2.2.4.1. Geri Yayılım Metodu.....	27
2.3. Hibrit ARIMA – YSA Modelleri.....	29
2.3.1. Zhang’ın Hibrit ARIMA – YSA Modeli.....	30
2.3.2. Khashei ve Bijari’nin Hibrit ARIMA – YSA Modeli.....	31
2.3.3. Çarpımsal Hibrit ARIMA – YSA Modeli.....	32
2.3.4. Hareketli Ortalama Filtre Tabanlı Hibrit ARIMA – YSA Modeli.....	33

ÜÇÜNCÜ BÖLÜM

OPTİMİZE ARIMA – YSA HİBRİT MODELİ

3.1. Hibrit ARIMA – YSA Modellerinin Özellikleri.....	35
3.2. Bir Zaman Serisinin Sabit Bir Sayıyla Çarpımı.....	36
3.3. Zaman Serisinin Bileşenlere Ayrılması ve En Küçük Kareler Optimizasyonu.....	38
3.4. Doğrusal Hataların Aktarılarak Yeniden Modelleme Yapılması.....	39
3.5. Optimize ARIMA – YSA Hibrit Modeli.....	41

DÖRDÜNCÜ BÖLÜM

OPTİMİZE ARIMA – YSA HİBRİT MODELİ VE FİNANSAL ZAMAN SERİLERİ İLE ÖRNEK UYGULAMALAR

4.1. Finansal Zaman Serileri ve Finansal Piyasalar.....	46
4.1.1. Finansal Zaman Serileri İçin Kullanılan Modeller.....	46
4.1.2. Finansal Piyasalar.....	49

4.1.2.1. Altın.....	53
4.1.2.2. ABD Doları/Türk Lirası Kuru (USD/TRY).....	55
4.1.2.3. BIST 30 Endeksi.....	57
4.2. Veri Seti.....	59
4.3. Model.....	62
4.3.1. ARIMA Süreci.....	62
4.3.2. Yapay Sinir Ağları Süreci.....	64
4.3.3. Optimizasyon Süreci.....	68
4.3.4. Yapay Zaman Serisinin Oluşturulması ve YSA ile Modellenmesi Süreci.....	68
4.3.5. Optimize ARIMA – YSA Hibrit Modelin Oluşturulması.....	68
4.4. Sonuçlar.....	69
4.4.1. ARIMA Süreci.....	71
4.4.2. Yapay Sinir Ağları Süreci.....	78
4.4.3. Optimizasyon Süreci.....	85
4.4.4. Yapay Zaman Serisinin Oluşturulması ve YSA ile Modellenmesi Süreci.....	86
4.4.5. Optimize ARIMA – YSA Hibrit Modelin Oluşturulması.....	93
4.5. Sonuçların Karşılaştırılması.....	98
SONUÇ.....	110
KAYNAKÇA.....	112
EK 1- Spot Altın Fiyatı ARIMA Model Arama Süreci.....	122
EK 2- BIST 30 Endeksi ARIMA Model Arama Süreci.....	123
EK 3- USD/TRY Kuru ARIMA Model Arama Süreci.....	124
EK 4- ARIMA Modelleri için Artık Değerlerin Otokorelasyon ve Kısmi Otokorelasyon Değerleri İçinde Limit Değerleri Aşan Gecikmeler.....	125
EK 5- ARIMA Modelleri için Artıkların 95% Güven Aralığında Ljung Box Q Test Sonuçları.....	126
ÖZGEÇMİŞ.....	127

ŞEKİLLER LİSTESİ

Şekil 1.1. Örnek Otokorelasyon Fonksiyonu Korelogramı.....	8
Şekil 1.2. Örnek Kısmi Otokorelasyon Fonksiyonu Korelogramı.....	8
Şekil 1.3. Örnek Bir Zaman Serisi için Doğrusal Trend.....	11
Şekil 1.4. Örnek Bir Zaman Serisi için İkinci Dereceden Parabolik Trend.....	11
Şekil 1.5. Mevsimsellik Özelliği Taşıyan Örnek Bir Zaman Serisi.....	12
Şekil 1.6. Mevsimsellik Özelliği ve Trend Bileşeni Taşıyan Örnek Bir Zaman Serisi.....	12
Şekil 2.1. Biyolojik Bir Nöronun Yapısı.....	20
Şekil 2.2. Bir Yapay Nöronun Yapısı.....	21
Şekil 2.3. Eşik Fonksiyon Örneği.....	22
Şekil 2.4. Farklı Eğim Derecelerinde Lojistik Fonksiyon Örnekleri.....	23
Şekil 2.5. Tek Katmanlı İleri Beslemeli Yapay Sinir Ağı.....	24
Şekil 2.6. Tam Bağlantılı Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı.....	25
Şekil 2.7. Örnek Hata Düzlemi.....	29
Şekil 4.1. Spot Altın Haftalık Kapanış Fiyatları (29.12.1978 – 24.02.2017).....	60
Şekil 4.2. BIST 30 Endeksi Haftalık Kapanış Değerleri (10.01.1997 – 24.02.2017).....	61
Şekil 4.3. USD/TRY Kuru Haftalık Kapanış Değerleri (10.01.1997 – 24.02.2017).....	61
Şekil 4.4. Spot Altın Fiyatı Gerçek Değerler ve ARIMA Tahmin Değerleri.....	77
Şekil 4.5. BIST 30 Endeksi Gerçek Değerler ve ARIMA Tahmin Değerleri.....	77
Şekil 4.6. USD/TRY Kuru Gerçek Değerler ve ARIMA Tahmin Değerleri.....	78
Şekil 4.7. Spot Altın Fiyatı Gerçek Değerler ve YSA Tahmin Değerleri.....	83
Şekil 4.8. BIST 30 Endeksi Gerçek Değerler ve YSA Tahmin Değerleri.....	84
Şekil 4.9. USD/TRY Kuru Gerçek Değerler ve YSA Tahmin Değerleri.....	84
Şekil 4.10. Spot Altın Fiyatı Yapay Seri YSA Model Tahmin Değerleri ve Gerçek Değerler..	92
Şekil 4.11. BIST 30 Endeksi Yapay Seri YSA Model Tahmin Değerleri ve Gerçek Değerler..	92
Şekil 4.12. BIST 30 Endeksi Yapay Seri YSA Model Tahmin Değerleri ve Gerçek Değerler..	93
Şekil 4.13. Spot Altın Fiyatı Gerçek Değerler ve Optimize ARIMA – YSA Hibrit Model Değerleri.....	96
Şekil 4.14. BIST 30 Endeksi Gerçek Değerler ve Optimize ARIMA – YSA Hibrit Model Değerleri.....	97
Şekil 4.15. USD/TRY Kuru Gerçek Değerler ve Optimize ARIMA – YSA Hibrit Model Değerleri.....	97
Şekil 4.16. Spot Altın Fiyatı Gerçek Değerler ve Tahmin Değerleri.....	108

Şekil 4.17. BIST 30 Endeksi Gerçek Değerler ve Tahmin Değerleri.....	108
Şekil 4.18. USD/TRY Kuru Gerçek Değerler ve Tahmin Değerleri.....	109



TABLOLAR LİSTESİ

Tablo 4.1. 2016 Yılı Küresel Altın Talebi.....	53
Tablo 4.2. 2017 Mart Ayı İtibariyle Rezervlerinde En Çok Altın Bulunduran Devlet ve Diğer Kuruluşlar.....	54
Tablo 4.3. Küresel Döviz Piyasasında En Çok Paya Sahip Para Birimleri ve Yüzdelik Payları.....	56
Tablo 4.4. BIST 30 Endeksi Hisseleri ve Ağırlık Oranları.....	58
Tablo 4.5. BIST 30 Endeksi Hisseleri Sektörel Dağılım.....	58
Tablo 4.6. Spot Altın Fiyatı Serileri için Tanımlayıcı Bilgiler.....	71
Tablo 4.7. BIST 30 Endeksi Serileri için Tanımlayıcı Bilgiler.....	71
Tablo 4.8. USD/TRY Kuru Serileri için Tanımlayıcı Bilgiler.....	72
Tablo 4.9. Tahmin Modelleri için Bulunan En İyi ARIMA(p,d,q) Modelleri.....	72
Tablo 4.10. Spot Altın Fiyatı ARIMA Modelleri ile Bulunan Model Hata Değerleri.....	73
Tablo 4.11. BIST 30 Endeksi ARIMA Modelleri ile Bulunan Model Hata Değerleri.....	73
Tablo 4.12. USD/TRY Kuru ARIMA Modelleri ile Bulunan Model Hata Değerleri.....	74
Tablo 4.13. Spot Altın Fiyatı ARIMA Modelleri için AR(p) ve MA(q) Katsayıları.....	74
Tablo 4.14. BIST 30 Endeksi ARIMA Modelleri için AR(p) ve MA(q) Katsayıları.....	74
Tablo 4.15. USD/TRY Endeksi ARIMA Modelleri için AR(p) ve MA(q) Katsayıları.....	75
Tablo 4.16. Spot Altın Fiyatı ARIMA Modelleri Tahmin Değerleri, Gerçek Değerler ve Tahmin Hata Değerleri.....	75
Tablo 4.17. BIST 30 Endeksi ARIMA Modelleri Tahmin Değerleri, Gerçek Değerler ve Tahmin Hata Değerleri.....	76
Tablo 4.18. USD/TRY Kuru ARIMA Modelleri Tahmin Değerleri, Gerçek Değerler ve Tahmin Hata Değerleri.....	76
Tablo 4.19. Yapay Sinir Ağları Model Arama Sonuçları.....	79
Tablo 4.20. Spot Altın Fiyatı YSA Modelleri için Öğrenme Oranı ile Eğitim ve Doğrulama Setlerine Göre Hata Değerleri.....	79
Tablo 4.21. BIST 30 Endeksi YSA Modelleri için Öğrenme Oranı ile Eğitim ve Doğrulama Setlerine Göre Hata Değerleri.....	80
Tablo 4.22. USD/TRY Kuru YSA Modelleri için Öğrenme Oranı ile Eğitim ve Doğrulama Setlerine Göre Hata Değerleri.....	80
Tablo 4.23. Spot Altın Fiyatı YSA Modelleri için Model Hata Değerleri.....	81
Tablo 4.24. BIST 30 Endeksi YSA Modelleri için Model Hata Değerleri.....	81

Tablo 4.25. USD/TRY Kuru YSA Modelleri için Model Hata Değerleri.....	81
Tablo 4.26. Spot Altın Fiyatı YSA Modelleri için Gerçek Değerler, Tahmin Değerleri ve Hata Değerleri.....	82
Tablo 4.27. BIST 30 Endeksi YSA Modelleri için Gerçek Değerler, Tahmin Değerleri ve Hata Değerleri.....	82
Tablo 4.28. USD/TRY Kuru YSA Modelleri için Gerçek Değerler, Tahmin Değerleri ve Hata Değerleri.....	83
Tablo 4.29. Spot Altın Fiyatı Modelleri için Optimizasyon Sonuçları.....	85
Tablo 4.30. BIST 30 Endeksi Modelleri için Optimizasyon Sonuçları.....	85
Tablo 4.31. USD/TRY Kuru Modelleri için Optimizasyon Sonuçları.....	86
Tablo 4.32. Spot Altın Fiyatı Modelleri, Yapay Zaman Serisi Veri Setleri için Tanımlayıcı Bilgiler.....	86
Tablo 4.33. BIST 30 Endeksi Modelleri, Yapay Zaman Serisi Veri Setleri için Tanımlayıcı Bilgiler.....	87
Tablo 4.34. USD/TRY Kuru Modelleri, Yapay Zaman Serisi Veri Setleri için Tanımlayıcı Bilgiler.....	87
Tablo 4.35. Spot Altın Fiyatı Yapay Serileri için YSA Modelleri Öğrenme Oranları ile Eğitim ve Doğrulama Setleri Hata Değerleri.....	88
Tablo 4.36. BIST 30 Endeksi Yapay Serileri için YSA Modelleri Öğrenme Oranları ile Eğitim ve Doğrulama Setleri Hata Değerleri.....	88
Tablo 4.37. USD/TRY Kuru Yapay Serileri için YSA Modelleri Öğrenme Oranları ile Eğitim ve Doğrulama Setleri Hata Değerleri.....	89
Tablo 4.38. Spot Altın Fiyatı Yapay Serileri için YSA Model Hata Değerleri.....	89
Tablo 4.39. BIST 30 Endeksi Yapay Serileri için YSA Model Hata Değerleri.....	90
Tablo 4.40. USD/TRY Kuru Yapay Serileri için YSA Model Hata Değerleri.....	90
Tablo 4.41. Spot Altın Fiyatları için Gerçek Değerler, Yapay Seri YSA Modeli Tahmin ve Hata Değerleri.....	91
Tablo 4.42. BIST 30 Endeksi için Gerçek Değerler, Yapay Seri YSA Model Tahmin ve Hata Değerleri.....	91
Tablo 4.43. USD/TRY Kuru için Gerçek Değerler, Yapay Seri YSA Model Tahmin ve Hata Değerleri.....	91
Tablo 4.44. Spot Altın Fiyatı Optimize ARIMA – YSA Hibrit Modelleri, Model Hata Değerleri.....	93

Tablo 4.45. BIST 30 Endeksi Optimize ARIMA – YSA Hibrit Modelleri, Model Hata Değerleri.....	94
Tablo 4.46. USD/TRY Kuru Optimize ARIMA – YSA Hibrit Modelleri, Model Hata Değerleri.....	94
Tablo 4.47. Spot Altın Fiyatı için Gerçek Değerler ve Optimize ARIMA – YSA Hibrit Model Tahmin Değerleri ve Hata Değerleri.....	95
Tablo 4.48. BIST 30 Endeksi için Gerçek Değerler, Optimize ARIMA – YSA Hibrit Model Tahmin Değerleri ve Hata Değerleri.....	95
Tablo 4.49. USD/TRY Kuru için Gerçek Değerler Optimize ARIMA – YSA Hibrit Model Tahmin Değerleri ve Hata Değerleri.....	96
Tablo 4.50. ARIMA ve YSA Modelleri ile Optimizasyon Aşaması Sonrası ve Optimize ARIMA – YSA Modeli Toplam Hata Kare Değerleri.....	99
Tablo 4.51. Optimize ARIMA – YSA Modelinin ARIMA ve YSA Toplam Hata Kare Değerlerini İyileştirme Miktarları.....	100
Tablo 4.52. ARIMA, YSA ve Optimize ARIMA – YSA Modelleri için Ortalama Hata Kare Değerleri.....	101
Tablo 4.53. ARIMA, YSA ve Optimize ARIMA – YSA Modelleri için Ortalama Mutlak Yüzde Hata Değerleri.....	102
Tablo 4.54. Gerçek Değerler ile ARIMA, YSA ve Optimize ARIMA – YSA Hibrit Model Tahmin Değerleri.....	104
Tablo 4.55. ARIMA, YSA ve Optimize ARIMA – YSA Hibrit Model Tahminleri İçin Hata Değerleri.....	105
Tablo 4.56. Optimizasyon Aşaması Sonucu Varsayımsal Tahmin Hataları ve Optimize ARIMA – YSA Hibrit Modeli Tahmin Hataları.....	106
Tablo 4.57. Optimize ARIMA – YSA Modeli Tahminlerinin ARIMA ve YSA Model Tahminleri Mutlak Hata Değerini Azaltma Miktarı.....	107
Tablo 4.58. Optimize ARIMA – YSA Hibrit Modeli Tahminleri İçin Theil’s U İstatistikleri..	107

KISALTMALAR LİSTESİ

ABD	Amerika Birleşik Devletleri	INR	Hindistan Rupisi
ACF	Autocorrelation Function	JPY	Japon Yeni
AE	Absolute Error	KRW	Kore Wonu
AIC	Akaike Information Criteria	M	Momentum
AICc	Akaike Information Criteria Corrected	MAD	Mean Absolute Deviation
ARCH	Autoregressive Conditional Heteroskedasticity	MAE	Mean Absolute Error
APE	Absolute Percentage Error	MAPE	Mean Absolute Percentage Error
ARIMA	Autoregressive Integrated Moving Averages	MSE	Mean Squared Errors
ART	Adaptive Resonance Theory	MXN	Meksika Pezосу
AUD	Avustralya Doları	MYR	Malezya Ringiti
BIS	Bank of International Settlements	NOK	Norveç Kronu
BIST	Borsa İstanbul	NTD	Tayvan Doları
BRL	Brezilya Reali	NZD	Yeni Zelanda Doları
CAD	Kanada Doları	PACF	Partial Autocorrelation Function
CHF	İsviçre Frangı	PEN	Peru Nuevo Solu
CLP	Şili Pezосу	PHP	Filipin Pezосу
CNY	Çin Yuanı	PLN	Polonya Zlotisi
COP	Kolombiya Pezосу	RMSE	Root Mean Squared Errors
CZK	Çek Korunası	RON	Romen Leyi
DKK	Danimarka Kronu	RUB	Rus Rublesi
BM	Birleşmiş Milletler	SAR	Suudi Arabistan Riyali
ECB	European Central Bank	SARIMA	Seasonal ARIMA
EGARCH	Exponential GARCH	SBC	Schwarz Bayesian Criteria
EUR	Euro	SEK	İsveç Kronu
FARIMA	Fuzzy ARIMA	SGD	Singapur Doları
GA-SVM	Genetic Algorithm Support Vector Machines	SSE	Sum of Squared Errors
GARCH	Generalized Autoregressive Conditional Heteroskedasticity	STAR	Smooth Transition Autoregressive
GBP	İngiliz Poundu	SVM	Support Vector Machines
GJRGARCH	Glosten Jagannathan Runkle GARCH	SVR	Support Vector Regression
GMYO	Gayrimenkul Yatırım Ortaklığı	T.	Türkiye
GSYİH	Gayri Safi Yurt İçi Hasıla	THB	Tayland Bahtı
HKD	Hong Kong Doları	TRY	Türk Lirası
HQC	Hannan Quinn Criteria	TÜFE	Tüketici Fiyat Endeksi
HUF	Macar Forinti	TWD	Yeni Tayvan Doları
IDR	Endonezya Rupisi	USD	ABD Doları
iid	independent identically distributed	ÜFE	Üretici Fiyat Endeksi
ILS	İsrail Şekli	VAR	Vector Autoregressive ve diğerleri
		vd.	vesaire
		vs.	Yapay Sinir Ağları
		YSA	Güney Afrika Randı
		ZAR	

ÖZET

Zaman serisi analizi son yıllarda önemli bir araştırma alanı haline gelmiştir. Bir değişkenin geçmiş verilerinin analiz edilmesi ve geçmiş değerler arasındaki örüntülerin ortaya konulması, değişkenin gelecekte alacağı değerlerle ilgili öngörülerde bulunulması ve tahmin yapılmasına olanak sağlamaktadır. Zaman serilerinin modellenmesi amacıyla çok sayıda yöntem geliştirilmiştir. Ortaya konulan her bir yöntemin farklı varsayımları, farklı karakteristik özellikleri, güçlü ve zayıf yanları bulunmaktadır.

Zaman serisi analizi için ortaya konulan yöntemlerin geliştirilmesi amacıyla son zamanlarda birden fazla yöntemin bir arada kullanıldığı hibrit modeller geliştirilmektedir. Hibrit modeller farklı yöntemlerin güçlü yönlerinin bir arada kullanılmasıyla geçmiş değerleri daha iyi açıklayan ve gelecek değerler için daha isabetli tahminler elde edilen modeller geliştirilmesi amacıyla ortaya konulmaktadır. Literatürde yer alan başarılı hibrit model sınıflarından biri ARIMA ve Yapay Sinir Ağları yöntemlerini bir arada kullanan hibrit modellerdir. ARIMA modelleri doğrusal zaman serilerinin modellenmesinde güçlüyken, Yapay Sinir Ağları modelleri doğrusal olmayan zaman serilerinde başarılı sonuçlar vermektedir. Gerçek hayatta karşılaşılan zaman serileri genellikle doğrusal ve doğrusal olmayan karakterleri bir arada taşıdığından hibrit modeller çoğu zaman ARIMA ve YSA modellerinden daha iyi sonuç vermektedirler.

Bu tez çalışması Optimize ARIMA – YSA Hibrit Modelini ortaya koyarak zaman serisi analizi literatürüne katkıda bulunmayı amaçlamaktadır. Optimize ARIMA – YSA Hibrit Modeli zaman serisinin doğrusal ve doğrusal olmayan iki bileşenin toplamı olduğunu varsaymaktadır. Doğrusal bileşenin modellenmesi için ARIMA ve doğrusal olmayan bileşen için YSA modellerinden faydalanmaktadır. Model, zaman serisini doğrusal ve doğrusal olmayan bileşenlere en iyi şekilde ayırmak için optimizasyona başvurmaktadır. Optimizasyon sonucu bulunan doğrusal bileşenin model hata değerleri doğrusal olmayan kısma eklenerek, doğrusal olmayan bileşen YSA ile yeniden modellenmektedir. Hibrit model böylece model hatasını en aza indirerek daha iyi model değerleri elde etmeyi ve daha doğru gelecek tahminlerinde bulunmayı amaçlamaktadır.

Çalışmada Optimize ARIMA – YSA Hibrit Modeli üç ayrı finansal zaman serisi için uygulanmakta; Spot Altın Fiyatı, BIST 30 Endeksi ve ABD Doları/Türk Lirası Kuru haftalık kapanış değerleri için toplam otuz model kurulmakta ve bir adım ileri tahmin yöntemiyle toplam otuz haftalık kapanış değeri tahmininde bulunulmaktadır. Elde edilen model ve gelecek tahmin sonuçları, ARIMA ve YSA modelleriyle elde edilen sonuçlarla karşılaştırılmakta ve

bulgular tartışılmaktadır. Elde edilen bulgular Optimize ARIMA – YSA Hibrit Modelinin zaman serilerini ARIMA ve YSA yöntemlerinden daha iyi modellediğini ve gelecek tahmini konusunda her iki modelden de üstün olduğunu ortaya koymaktadır.

Anahtar Kelimeler: Zaman Serileri Analizi, ARIMA, Yapay Sinir Ağları, Optimize ARIMA – YSA Hibrit Modeli, Finansal Zaman Serileri.



SUMMARY

OPTIMIZED ARIMA – ANN HYBRID MODEL FOR TIME SERIES AND SAMPLE APPLICATIONS WITH FINANCIAL TIME SERIES

Time series analysis has become an important research area in recent years. Analyzing the past values and presenting the patterns in the past values of a variable, enable to foresight the future values of the variable and to forecast. Numerous methods have been developed to be able to model the time series. Each methods presented has different assumptions, different characteristics, strong and weak sides.

For the purpose of improving the presented methods for time series analysis, lately, hybrid models are developed in which more than one methods are used. Hybrid models are presented with the aim of developing models that explain the past values better and forecast the future values more accurate by using strengths of different methods. One of the successful hybrid model classes in the literature is hybrid models using ARIMA and Artificial Neural Networks together. ARIMA models are strong for linear time series modelling, whereas Artificial Neural Network models give successful results on nonlinear time series. Because time series encountered in real life show linear and nonlinear characteristics together, hybrid models mostly gives better results than ARIMA and ANN.

This thesis study aims to contribute in the time series literature by presenting Optimized ARIMA – ANN Hybrid Model. Optimized ARIMA – ANN Hybrid Model assumes that the time series is sum of linear and nonlinear components. Modelling the linear component is done by ARIMA models, and modelling the nonlinear component is done by ANN models. Model applies optimization to decompose the time series into linear and nonlinear components. Model errors of the linear component after optimization are added to nonlinear component, and the nonlinear part remodeled with ANN. In this way, hybrid model aims to get better model values and more accurate future forecasts by minimizing the model errors.

In the study, Optimized ARIMA – ANN Hybrid Model is applied to three different financial time series; totally thirty models are constructed for weekly closing values of Spot Gold Prices, BIST 30 Index and US Dollar/Turkish Lira cross and totally thirty weekly closing values are forecasted with one step forward forecasting method. Model and future forecast results are compared with the results of ARIMA and ANN models, and the findings are discussed. Obtained findings shows that Optimized ARIMA – ANN Hybrid Model, models the time series better than ARIMA and ANN models and is superior to both models in future forecasting.

Keywords: Time Series Analysis, ARIMA, Artificial Neural Networks, Optimized ARIMA – ANN Hybrid Model, Financial Time Series.



GİRİŞ

Zaman serisi analiz yöntemleri özellikle ekonomi ve finans alanlarında sıklıkla kullanılmaktadır. Zaman serisi analizi, geçmiş verilerin analiz edilip modellenerek gelecek için tahminlerde bulunulmasına olanak sağlar. Bu açıdan ülkelerin ekonomik göstergeleri (ÜFE, TÜFE, GSYİH, İşsizlik Oranı), piyasalar (Borsa, Emtia, Döviz Piyasası) ya da şirketlerin ekonomik verileri sıklıkla zaman serisi analizine tabi tutulmakta ve gelecek için öngörülerde bulunulmaktadır.

Zaman serisi analizi için farklı karakterlerde birçok model ve yöntem geliştirilmiştir. Bunlardan özellikle doğrusal karakterli zaman serileri için ARIMA modeli ön plana çıkarken, doğrusal olmayan zaman serileri için son yıllarda en çok kullanılan yöntemlerden birisi Yapay Sinir Ağları modelidir.

Literatürde son yıllarda yapılan çalışmalar, birden fazla modelin bir arada kullanıldığı hibrit modellerin, ayrı ayrı modellere göre çok daha başarılı sonuçlar verebildiğini göstermektedir. Tek bir modelin varsayımları ve karakteristik özellikleri gerçek hayatta karşılaşılan zaman serilerini açıklamakta yetersiz kalabilirken, farklı varsayımlara dayanan ve farklı özelliklerde modellerin beraberce kullanılması karşılaşılan zaman serilerini açıklamakta daha başarılı olabilmektedir. Hibrit modeller, zaman serisinin doğrusal ve doğrusal olmayan karakterleri bir arada taşıdığını varsayarak, doğrusal ve doğrusal olmayan modelleri birleştiren modeller olarak daha başarılıdır.

Bu tez çalışmasının amacı, zaman serileri için yeni bir model olarak Optimize ARIMA-YSA Hibrit Modeli ile literatüre önemli bir katkı sağlamaktır. Literatürde yer alan ARIMA – YSA Hibrit modelleri, serinin doğrusal ve doğrusal olmayan kısımlara ayrıştırılabilmesi için farklı varsayımlar ortaya koymaktadır. Hibrit modelleri birbirinden ayıran, serinin doğrusal ve doğrusal olmayan kısımları için yapılan varsayımlar ve bu bileşenleri elde etmek için kullanılan yöntemlerdir. Bu çalışmada ortaya konulan Optimize ARIMA – YSA Hibrit Modeli, zaman serisinin doğrusal ve doğrusal olmayan karakteri bir arada taşıdığını varsaymaktadır. Buna göre zaman serisi doğrusal bir zaman serisi ile doğrusal olmayan bir zaman serisinin toplamıdır. Optimize ARIMA – YSA Hibrit Modeli, diğer ARIMA – YSA Hibrit modellerden farklı olarak, serinin doğrusal ve doğrusal olmayan kısımlara en iyi şekilde ayrılabilmesi için optimizasyona başvurmaktadır. Böylece zaman serisinin doğrusal ve doğrusal olmayan bileşenleri için en iyi (optimum) değerlerin bulunması amaçlanmaktadır. Ayrıca doğrusal kısmın modellenmesi sonucu elde edilen hatalar doğrusal olmayan kısma eklenerek yeniden modellenmekte ve zaman

serisinin en az hatayla açıklanması hedeflenmektedir. Zaman serisinin doğrusal modellemesi için ARIMA ve doğrusal olmayan modellemeler için Yapay Sinir Ağları kullanılmaktadır.

Optimize ARIMA – YSA Hibrit Modelinin uygulaması için üç farklı özellikte finansal zaman serisi kullanılmaktadır. Spot Altın Fiyatları, USD/TRY Döviz Kuru ve BIST 30 Borsa Endeksi verileri kullanılarak modelleme ve gelecek tahminleri yapılmakta, elde edilen sonuçlar ARIMA ve YSA modelleriyle bulunan sonuçlarla karşılaştırılmaktadır.

Birinci bölümde zaman serileri ve temel kavramlar açıklanmaktadır. Zaman serileri ile ilgili; durağanlık, durağanlık testleri, otokorelasyon ve kısmi otokorelasyon fonksiyonları, beyaz gürültü ve zaman serilerinde bileşenlere ayırma gibi kavramlar ele alınmaktadır.

İkinci bölümde ARIMA, YSA ve ARIMA – YSA Hibrit modeller ele alınmaktadır. Öncelikle ARIMA modelleri yer almakta ve sırasıyla; Otoregresif (AR), Hareketli Ortalamalar (MA), Otoregresif Hareketli Ortalamalar (ARMA) ve Otoregresif Entegre Hareketli Ortalamalar (ARIMA) modelleri açıklanmakta, model seçim kriterleri ve artıkların analizi konularına değinilmektedir. Daha sonra, Yapay Sinir Ağları modeli kapsamında; temel kavramlar, nöron yapısı, ağ mimarisi, eğitim ve öğrenme konuları ele alınmaktadır. Son olarak Hibrit ARIMA – YSA Modelleri ile literatürde yer alan başlıca dört hibrit model açıklanmaktadır.

Üçüncü bölümde çalışmaya konu olan Optimize ARIMA – YSA Hibrit Modeli ortaya konulmaktadır. Öncelikle modeli ortaya çıkaran düşünceler ele alınmakta daha sonra model açıklanmakta ve son olarak modelin uygulanması adım adım verilmektedir.

Dördüncü bölüm uygulama ve sonuçların karşılaştırılması aşamalarını içermektedir. İlk olarak finansal zaman serileri ve finansal zaman serileri için literatürde kullanılan modeller ele alınmaktadır. Daha sonra finansal piyasa enstrümanları ve bunların başlıca özellikleri ile çalışmada hibrit modelin uygulanacağı Spot Altın Fiyatı, BIST 30 Endeksi ve ABD Doları/Türk Lirası Kuruyla ilgili bilgiler verilmektedir. Uygulamada kullanılacak veri setleri ve bunların özellikleri ile uygulama aşamasının süreçleri ve bu süreçlerde yapılacak işlemler açıklanmaktadır. Uygulama sonucunda elde edilen matematiksel sonuçlar ortaya konulmakta ve karşılaştırılmaktadır. Son olarak elde edilen karşılaştırmalı sonuçlar değerlendirilmekte, yorumlanmakta ve tartışılmaktadır.

BİRİNCİ BÖLÜM

ZAMAN SERİLERİ VE TEMEL KAVRAMLAR

Bir zaman serisi ilgilenilen belli bir büyüklüğün zamana göre sıralanmış değerlerinin bir kümesi olarak ifade edilebilir. Günlük hisse senedi fiyatları, haftalık faiz oranları, aylık işsizlik oranları, meteoroloji tarafından kaydedilen saatlik rüzgar hızları, en yüksek ve en düşük sıcaklıklar gibi veriler zaman serilerine örnek olarak verilebilir (Falk vd., 2012). Zaman serilerinin incelenme ve analiz edilmelerinin başlıca sebepleri arasında veri üreten mekanizmanın daha iyi anlaşılabilmesi, gelecek zaman değerlerinin tahmin edilebilmesi ve sistemin en uygun kontrolü gibi amaçlar sayılabilir (Falk vd., 2012: 1).

Zaman serisi analizi genellikle değişken ya da değişkenlerin zaman içerisinde aldıkları değerler içerisinde bulunan örüntülerin anlaşılabilir olarak gelecek zamanda alabileceği değerlerin tahmin edilmesi amacıyla yapılmaktadır. Zaman serisi analizinin yapılabilmesi için zaman serileriyle ilgili bazı temel kavramların bilinmesi gerekmektedir. Bunlar arasında durağanlık, doğrusallık, beyaz gürültü, otokorelasyon ve kısmi otokorelasyon fonksiyonları sayılabilir.

1.1. Durağanlık

Durağanlık zaman serileriyle ilgili en önemli kavramlardan biridir. Bir zaman serisinde tüm t değerleri için $(x_{t1}, x_{t2}, \dots, x_{tk})$ aralığında ortak dağılım $(x_{t1+t}, x_{t2+t}, \dots, x_{tk+t})$ aralığındaki dağılım ile birebir aynıysa buna kesin durağanlık denir. Burada k herhangi bir pozitif tamsayıdır. Diğer bir deyişle zaman kaydırılması durumunda serinin dağılımı değişmemektedir ve dağılım zamandan bağımsızdır. (Tsay, 2002: 23)

Bu sağlanması çok zor bir şarttır ve bunun yerine sıklıkla daha zayıf versiyonu kabul edilir. Zayıf durağanlık adı verilen bu varsayıma göre, serinin ortalaması ve varyansı zamandan bağımsız, yani sabittir. Ayrıca herhangi iki değeri arasındaki kovaryans bu değerlerin bulunduğu döneme değil, dönemler arasındaki farka bağlıdır. Bu koşullar aşağıdaki gibi ifade edilebilir:

$$E[x_t] = \mu \quad (1.1)$$

$$Var[x_t] = \sigma^2 \quad (1.2)$$

$$Cov[x_t, x_k] = Cov[x_{t+s}, x_{k+s}] = \eta_k \quad (1.3)$$

Bu şartların sağlanması serinin başlangıç noktasını x_t 'den x_{t+k} 'ya kaydırduğımızda ortalama, varyans ve kovaryans değerlerinin değişmemesi demektir.

Zaman serileri için durağanlık önemlidir. Eğer eldeki seri durağan olmayan bir seriyse, seriden alınan farklı veri setleri farklı özellikler gösterir. Bu durumda bu veri setlerinden elde

edilen bilgilerin genellenmesinde, model oluşturulmasında ve geleceğe yönelik tahmin yapılmasında sorunlarla karşılaşılabilir.

Zayıf durağan bir serinin verilerinin zaman grafiği belirli bir ortalama değer etrafında sabit dalgalanmalar şeklindedir. Durağan bir serinin sabit bir ortalama etrafında dalgalanması özelliğine ortalamaya dönüş (*mean reversion*) adı verilir ve finans piyasalarında sıklıkla kullanılmaktadır.

Bir zaman serisinin durağan olup olmadığını anlamak için kullanılan testler bulunmaktadır. Bunların başlıcaları: Dickey-Fuller Testi (DF), Genişletilmiş Dickey-Fuller Testi (ADF), Philips-Perron Testi (PP) ve Kwiatkowski-Phillips-Schmidt-Shin Testi (KPSS)'dir.

1.1.1. Dickey – Fuller Testi (DF)

Dickey ve Fuller (1979) tarafından ortaya atılan test en çok kullanılan birim kök testidir. Test, 1. dereceden otoregresif süreç (AR(1)) modeline dayanmaktadır. Buna göre, ϕ_1 , otoregresyon parametresi ve ε_t modelin beyaz gürültü özellikleri taşıyan, sistematik olmayan kısmı olmak üzere, model aşağıdaki gibi gösterilebilir.

$$y_t = \phi_1 y_{t-1} + \varepsilon_t \quad (1.4)$$

$$t = 1, \dots, T$$

Birim kök kavramı serilerin durağanlığını test etmek için sıklıkla kullanılan bir kavramdır. Yukarıda bahsedilen AR(1) sürecinde eğer ϕ_1 parametresi 1'e eşitse süreç aşağıdaki gibi olur:

$$y_t = y_{t-1} + \varepsilon_t \quad (1.5)$$

Bu durumda y_0 'dan başlamak üzere herhangi bir y_t değeri aşağıdaki gibi gösterilebilir:

$$y_t = y_0 + \sum_{j=1}^t \varepsilon_j \quad (1.6)$$

Serinin t zamanındaki varyansı ise Eşitlik 1.7'deki gibi olur:

$$Var(y_t) = \sum_{j=1}^t \sigma^2 = t\sigma^2 \quad (1.7)$$

Örneğin, t=1 için varyans $Var(y_1) = \sigma^2$ ise t=2 için varyans $Var(y_2) = 2\sigma^2$ olur. Bu durumda varyans t'ye bağımlıdır. Serinin varyansı zaman ilerledikçe sonsuza yakınsamaktadır. Varyans değişken olduğu için zaman serisi durağan olmayan bir seridir.

Dickey – Fuller Testi AR(1) süreci için birim kök hipotezi kurmakta ve eğer birim kök varsa serinin durağan olmadığını ortaya koymaktadır. Ancak tersi her zaman doğru değildir. Serinin AR(1) süreci birim kök içermese de seri durağan olmayabilir. Bu sebeple literatürde genellikle birim kök testleri diğer durağanlık testleriyle desteklenmektedir.

DF test istatistiğinin hesaplanması için Eşitlik 1.5'te her iki taraftan y_{t-1} terimi çıkarılır. Elde edilen $y_t - y_{t-1}$ serisi fark serisidir ve Δy_t olarak gösterilir.

$$\Delta y_t = \rho y_{t-1} + \varepsilon_t \quad (1.8)$$

Burada $\rho = \phi_1 - 1$ olur ve birim kök varlığı için $\rho = 0$ olmalıdır (Arltova ve Fedorova, 2016: 48).

Dickey – Fuller Testine göre hipotezler aşağıdaki gibidir:

H_0 : $\rho = 0$ Seri durağan değildir. Serinin birim kökü vardır,

H_1 : $\rho < 1$ Seri durağandır. Serinin birim kökü yoktur. (Uğurlu, 2009: 8)

Dickey – Fuller için test istatistiği,

$$\tau = \frac{\hat{\rho}}{S_{\hat{\rho}}} \quad (1.9)$$

olarak tanımlanır. Burada $\hat{\rho}$, ρ 'nun en küçük kareler tahmini ve $S_{\hat{\rho}}$ bu değer in standart hatasıdır. Test istatistiğinin eşik değerleri Dickey (1976) tarafından tablolaştırılarak yayınlanmıştır ancak bu yeterli olmamış ve MacKinnon (1991) tarafından bu tablolar genişletilerek tekrar yayınlanmıştır.

Dickey ve Fuller (1979) üç tip regresyon modeli ortaya koymuştur ve bunların her biri için ayrı test istatistikleri üretmiştir. Bunlar aşağıdaki gibidir:

$$\Delta y_t = \beta y_{t-1} + \varepsilon_t \quad (1.10)$$

$$\Delta y_t = \beta_0 + \beta y_{t-1} + \varepsilon_t \quad (1.11)$$

$$\Delta y_t = \beta_0 + \beta_1 t + \beta y_{t-1} + \varepsilon_t \quad (1.12)$$

Dikkat edilirse Eşitlik 1.10, Eşitlik 1.11'in özel bir hali ($\beta_0 = 0$), ve Eşitlik 1.11, Eşitlik 1.12'nin özel bir halidir ($\beta_1 = 0$). Yukarıdaki her bir model için kullanılan test istatistikleri sırasıyla τ , τ_{μ} ve τ_T olarak ifade edilir.

1.1.2. Güçlendirilmiş Dickey – Fuller Testi (ADF)

Güçlendirilmiş Dickey – Fuller Testi (ADF), Dickey – Fuller Testinden farklı olarak belli sayıda gecikmeli değeri de modele eklemektedir. Modele eklenen gecikmeli değerlerle her bir model aşağıdaki şekillere dönüştürülebilir:

$$\Delta y_t = \rho y_{t-1} + \sum_{i=1}^k y_i \Delta y_{t-i} + \varepsilon_t \quad (1.13)$$

$$\Delta y_t = \alpha_0 + \rho y_{t-1} + \sum_{i=1}^k y_i \Delta y_{t-i} + \varepsilon_t \quad (1.14)$$

$$\Delta y_t = \alpha_0 + \beta t + \rho y_{t-1} + \sum_{i=1}^k y_i \Delta y_{t-i} + \varepsilon_t \quad (1.15)$$

Yukarıdaki modellerle ilgili kullanılan test istatistikleri yine aynı test istatistikleri olup sırasıyla τ , τ_{μ} ve τ_T 'dir. (Uğurlu, 2009: 9)

1.1.3. KPSS Testi

Kwiatowski vd. (1992) tarafından ortaya atılan test modeli aşağıdaki gibi gösterilebilir:

$$y_t = d_t + r_t + \varepsilon_t \quad (1.16)$$

Burada r_t , varyansı σ_u^2 olan rassal yürüyüş (*random walk*) modelidir ve aşağıdaki gibi ifade edilebilir:

$$r_t = r_{t-1} + u_t \quad (1.17)$$

d_t bir deterministik eğilim (trend) olarak ifade edilmektedir ve aşağıdaki gibi gösterilir:

$$d_t = \sum_{i=0}^p \beta_i t^i \quad (1.18)$$

KPSS testi rassal yürüyüş modelinin varyansının (σ_u^2) 0 olduğu hipotezini Lagrange çarpımını kullanarak test etmektedir. Buna göre 0 hipotezi ve alternatif hipotez aşağıdaki gibidir:

$$H_0: \sigma_u^2 = 0$$

$$H_1: \sigma_u^2 > 1$$

Test istatistiği aşağıdaki gibi yazılmaktadır:

$$LM = \sum_{t=1}^T \frac{s_t^2}{\hat{\sigma}_\varepsilon^2} \quad (1.19)$$

Burada $s_t = \sum_{t=1}^T \hat{\varepsilon}_t$ 'dir. $t = 1, 2, \dots, T$ ve $\hat{\sigma}_\varepsilon^2$, ε_t değerinin varyansının (σ_ε^2) tahminidir.

Test istatistiği için kullanılacak kritik değerler Kwiatkowski vd. (1992) tarafından yayınlanmıştır (Arltova ve Fedorova, 2016: 52).

1.2. Otokorelasyon ve Kısmi Otokorelasyon

Herhangi iki rassal değişken X ve Y arasındaki korelasyon katsayısı aşağıdaki eşitlik ile ifade edilir:

$$\rho_{x,y} = \frac{Cov(X,Y)}{\sqrt{Var(X)Var(Y)}} = \frac{E[(X-\mu_x)(Y-\mu_y)]}{\sqrt{E(X-\mu_x)^2 E(Y-\mu_y)^2}} \quad (1.20)$$

Eşitlikte μ_x ve μ_y , X ve Y için ortalama değerleri ifade eder. Korelasyon katsayısı iki değişkenin birbirine doğrusal bağımlılığının ne kadar güçlü olduğunu ifade eder ve [-1,1] aralığında değerler alır. Korelasyon katsayısının 0 olması iki değişkenin tamamen bağımsız olduğunu gösterirken, 1'e yakın değerler güçlü pozitif bağımlılığı ve -1'e yakın değerler güçlü negatif bağımlılığı ifade etmektedir.

İki değişken için örneklem $\{(x_t, y_t)\}_{t=1}^T$ mevcutsa, korelasyon aşağıdaki gibi tahmin edilebilir:

$$\hat{\rho}_{x,y} = \frac{\sum_{t=1}^T (x_t - \bar{x})(y_t - \bar{y})}{\sqrt{\sum_{t=1}^T (x_t - \bar{x})^2 \sum_{t=1}^T (y_t - \bar{y})^2}} \quad (1.21)$$

Eşitlikte $\bar{x}$ ve $\bar{y}$ sırasıyla X ve Y örneklemlerinin ortalamalarını ifade etmektedir.

1.2.1. Otokorelasyon Fonksiyonu (ACF)

Otokorelasyon, bir zaman serisi için t zamanındaki değişkenin (y_t), gecikmeli değerleriyle (y_{t-l}) korelasyonu olup, korelasyonun genelleştirilmiş halidir. (Tsay, 2002: 23)

x_t ile x_{t-l} arasındaki korelasyon, x_t 'nin l gecikmeli otokorelasyonu olarak adlandırılır ve ρ_l ile gösterilir.

$$\rho_l = \frac{Cov(r_t, r_{t-l})}{\sqrt{Var(r_t)Var(r_{t-l})}} = \frac{Cov(r_t, r_{t-l})}{Var(r_t)} = \frac{\gamma_l}{\gamma_0} \quad (1.22)$$

Serinin zayıf durağan olduğu düşünülürse, varyans sabit olacağından, $Var(r_t) = Var(r_{t-l})$ dir. Ayrıca l gecikmeli otokorelasyon ile l ilerlemeli otokorelasyon aynı anlama gelmekte ($\rho_l = \rho_{-l}$) ve otokorelasyonun değeri her zaman için $-1 \leq \rho_l \leq 1$ olmaktadır.

Ele alınan belli bir örneklem için $\{(x_t)\}_{t=1}^T$, $\bar{x}$ örneklem ortalaması olmak üzere, x_t 'nin l gecikmeli otokorelasyonu,

$$\hat{\rho}_l = \frac{\sum_{t=l+1}^T (x_t - \bar{x})(x_{t-l} - \bar{x})}{\sum_{t=1}^T (x_t - \bar{x})^2} \quad (1.23)$$

eşitliği ile hesaplanabilir (Tsay, 2002: 24).

1.2.2. Kısmi Otokorelasyon Fonksiyonu

Kısmi otokorelasyon, otokorelasyondan farklı olarak, mevcut gözlem x_t ile k gecikmeli gözlem x_{t-k} için, aradaki gecikmelerin ($x_{t-k+1}, x_{t-k+2}, \dots, x_{t-1}$) etkileri ortadan kaldırılarak elde edilen otokorelasyondur (Brooks, 2008: 222).

k gecikmeli değer için kısmi otokorelasyon φ_{kk} ile gösterilir. Birinci derece gecikme ($k=1$) için arada otokorelasyonu etkileyen herhangi gecikme olmaması sebebiyle kısmi otokorelasyon, otokorelasyona eşittir.

$$\varphi_{11} = \rho_1 \quad (1.24)$$

Kısmi otokorelasyon, 2. gecikme için,

$$\varphi_{22} = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2} \quad (1.25)$$

ve daha yüksek gecikmeler için,

$$\varphi_{kk} = \frac{\rho_k - \sum_{j=1}^{k-1} \varphi_{k-1,j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \varphi_{k-1,j} \rho_j} \quad (1.26)$$


eşitlikleri ile hesaplanabilir. Burada, $k = 3, 4, 5, \dots$, $\varphi_{k,j} = \varphi_{k-1,j} - \varphi_{kk} \varphi_{k-1,k-j}$ ve $j = 1, 2, 3, \dots, k-1$ 'dir (Yüksel, 2015: 30).

1.2.3. Korelogram

Bir zaman serisinin gecikmeli serileriyle otokorelasyon ve kısmi otokorelasyon değerlerini gösteren grafiğe korelogram (*correlogram*) adı verilir. Korelogram grafiklerinde otokorelasyon ve kısmi otokorelasyon değerleriyle birlikte 95% güven aralığında otokorelasyon ve kısmi otokorelasyonun 0 kabul edildiği bantlar yer alır. Buna göre bu bantlar arasında yer alan değerler 95% güven aralığında beyaz gürültü süreci olarak kabul edilir. T gözlem sayısı olmak üzere bant değerleri aşağıdaki gibi hesaplanmaktadır (Levich ve Rizzo, 1998: 6):


$$\pm 1,96\sqrt{T} \quad (1.27)$$

Örnek otokorelasyon fonksiyonu (ACF) ve kısmi otokorelasyon fonksiyonu ($PACF$) korelogramları Şekil 1.1 ve Şekil 1.2’de gösterilmektedir.



Şekil 1.1. Örnek Otokorelasyon Fonksiyonu Korelogramı

Kaynak: Brockwell ve Davis, 2002: 97



Şekil 1.2. Örnek Kısmi Otokorelasyon Fonksiyonu Korelogramı

Kaynak: Brockwell ve Davis, 2002: 99

Şekil 1.1 ve Şekil 1.2’de yer alan korelogramlar incelendiğinde otokorelasyon fonksiyonu korelogramında 1 gecikmeli otokorelasyon değerinin sınır aralıkları dışında olduğu, kısmi otokorelasyon korelogramında ise 1 ve 2 gecikmeli kısmi otokorelasyon değerlerinin sınır aralıklarının dışına çıktığı görülmektedir.

Otokorelasyon fonksiyonu ve kısmi otokorelasyon fonksiyonu zaman serisi analizinde sıklıkla kullanılan fonksiyonlardır. Literatürde ACF ve PACF korelogramları ham zaman serisi verilerine uygulanarak seriye en uygun ARIMA modelinin tespit edilmesinde kullanılmaktadır. Ancak Akaike Bilgi Kriteri başta olmak üzere bazı model belirleme kriterlerinin kullanımının artmasıyla birlikte bu amaçlı kullanımı son yıllarda azalmaktadır.

ACF ve PACF değerleri ayrıca zaman serisinin modellenmesi sonucu elde edilen artık değerlere uygulanmaktadır. Hataların otokorelasyona sahip olup olmadıklarının tespiti hem en iyi modelin uygulanıp uygulanmadığını, hem de modelde göz ardı edilmiş bir mevsimsellik olup olmadığını ortaya koymaktadır.

1.3. Beyaz Gürültü

Eğer bir zaman serisi (r_t) sonlu ortalama ve varyanslı, bağımsız özdeşçe dağılmış (iid) rassal değişkenlerin bir dizisiyse buna beyaz gürültü adı verilir. (Tsay, 2002: 26). Eğer r_t normal dağılımlı, 0 ortalamalı ve varyansı σ^2 ise, buna Gauss beyaz gürültü adı verilir. Bir beyaz gürültü serisi için tüm gecikmelerin otokorelasyon fonksiyonları sıfırdır. Pratikte ise tüm otokorelasyon değerleri sıfıra yakınsa bu seriye beyaz gürültü serisi adı verilir. Bir diğer deyişle serideki değerler birbiriyle tamamen ilişkisizdir (Brooks, 2008: 209). Zaman serisi analizinde modelleme sonrası kalan artıkların beyaz gürültü serisi olması beklenir.

1.4. Zaman Serilerinde Bileşenlere Ayırma

Zaman serisi analizinde kullanılan en önemli yöntemlerden biri, serinin farklı özellikler taşıdığı düşünülen gizli bileşenlere ayrılmasıdır. Zaman serilerinin ayrıştırılması fikri çok eski olup, 17. yy. Astronomları tarafından gezegen yörünge hesaplamalarında kullanılmıştır. Zaman serilerinin ayrıştırılması ilk defa Persons (1919) tarafından açıkça ortaya konulmuş ve zaman serilerinin dört kısımdan oluştuğu ileri sürülmüştür. Bunlar (Dagum, 2010: 434):

- Uzun dönem eğilim veya trend
- Dairesel hareketler. Bu hareketler endüstriyel refah zamanlarında tepe noktasına ulaşırken, ekonomik bunalım dönemlerinde en alt seviyesine ulaşır. Bu yükseliş ve düşüşler iş döngüsünü (business – cycle) meydana getirir.

- Her bir yıl içerisindeki mevsimsel hareketler. Bunlar serinin doğasına bağlı olarak ortaya çıkmaktadır

- Artık varyasyonları. Bunlar bireysel olarak her bir değişkendeki değişimler veya savaşlar, ulusal felaketler gibi bir grup değişkeni etkileyen büyük olaylar sonucu ortaya çıkar.

Zaman serilerinde bileşenlere ayırma zaman içerisinde genelleştirilmiş ve klasik ayrıştırma adını almıştır. Klasik ayrıştırmaya göre bir zaman serisi üç kısma ayrılabilir. Bunlar (Anderson vd., 2010: 829):

- Trend bileşeni
- Mevsimsel bileşen
- Düzensiz bileşen veya Hata bileşeni

olarak ifade edilebilir.

Klasik ayrıştırma yönteminin iki şekli bahsedilebilir. Bunlar toplamsal model (*additive model*) ve çarpımsal modeldir (*multiplicative model*). Toplamsal modele göre bir zaman serisi; trend, mevsimsel bileşen ve düzensiz bileşenin toplamından oluşmaktadır.

$$Y_t = T_t + S_t + I_t \quad (1.28)$$

Y_t zaman serisinin t zamanındaki değerini göstermek üzere, T_t trend bileşeninin t zamanındaki değerini, S_t mevsimsel (*seasonal*) bileşeni ve I_t düzensiz (*irregular*) bileşeni göstermektedir. Diğer bir ayrıştırma şekli çarpımsal modeldir. Bu modelde bileşenlerin birbiriyle ilişkili olduğu düşünülür. Örneğin trend arttıkça mevsimsel döngüler de büyüyerek artıyor olabilir. Çarpımsal model aşağıdaki gibi gösterilmektedir:


$$Y_t = T_t S_t I_t \quad (1.29)$$

Trend bir zaman serisinde değerlerin uzun zaman diliminde gittikçe artması ya da azalması olarak ifade edilebilir. Bir serinin trendi doğrusal olabileceği gibi doğrusal olmayan (parabolik, üstel, logaritmik vs.) şekilde de olabilir. Trend serisi t değerine bağlı olarak artma ve azalmayı ifade ettiğinden serinin özellikleri zaman içerisinde değişmektedir ve bu sebeple durağan değildir. (Anderson vd., 2010: 840)

Şekil 1.3 ve Şekil 1.4'te, örnek zaman serileri için yapılan trend analizleri sonucu bulunan, sırasıyla doğrusal ve ikinci dereceden parabolik trend örnekleri yer almaktadır.


Zaman serileri, yıl içerisinde mevsimsel etkenler sebebiyle tekrarlayan bazı kalıplar içerebilir. Buna mevsimsellik adı verilmektedir. Bu tekrarlama yıl içerisinde aylara ya da mevsimlere bağlı olabileceği gibi daha küçük zaman birimlerinde de olabilir. Örneğin günlük trafik hacmi, günün yoğun saatlerinde tepe noktasına ulaşp diğer saatlerde azalarak bir gün içerisinde orta seviyede devam edip, gece saatlerinden sabaha kadar en düşük seviyeye ulaşarak

mevsimsel hareketler sergileyebilmektedir. Mevsimsel bir zaman serisi yine zaman içerisinde değişen özellikler gösterdiğinden durağan değildir.



Şekil 1.3. Örnek Bir Zaman Serisi (yeşil) için Doğrusal Trend (mavi)


Kaynak: Anderson vd., 2010: 812



Şekil 1.4. Örnek Bir Zaman Serisi (yeşil) için İkinci Dereceden Parabolik Trend (mavi)


Kaynak: Anderson vd., 2010: 816

Şekil 1.5 ve Şekil 1.6’da sırasıyla mevsimsellik barındıran ve mevsimsellik ile trend bileşenini bir arada taşıyan örnek zaman serileri yer almaktadır.



Şekil 1.5. Mevsimsellik Özelliği Taşıyan Örnek Bir Zaman Serisi

Kaynak: Anderson vd., 2010: 821



Şekil 1.6. Mevsimsellik Özelliği ve Trend Bileşeni Taşıyan Örnek Bir Zaman Serisi

Kaynak: Anderson vd., 2010: 823

Zaman serileri üzerinde düzensiz ve sistematik olmayan, öngörülemeyen veya açıklanamayan etkiler sonucu ortaya çıkan bileşen, düzensiz veya hata bileşeni olarak adlandırılır. Bu bileşen ekonometrik veya istatistiksel olarak belirlenemeyen kısmı ifade etmektedir.

Klasik zaman serisi ayrıştırmasına döngüsel bileşen de eklenerek bu ayrıştırma genişletilebilir. Döngüsel bileşen (C_t), mevsimsel bileşenle aynı özellikleri taşımakla birlikte

yılın mevsim veya ayları yerine daha uzun sürelerde tekrarlayan döngüleri ifade etmektedir. Bu durumda sırasıyla toplamsal ve çarpımsal ayrıştırmalar aşağıdaki gibi ifade edilebilir:

$$Y_t = T_t + C_t + S_t + I_t \quad (1.30)$$

$$Y_t = T_t C_t S_t I_t \quad (1.31)$$

1.5. Zaman Serisi Modelleri

Literatürde zaman serileri analizi için kullanılan birçok model bulunmaktadır. Zaman serisi analizinde zaman serisinin şu anki değeri serinin gecikmeli değerleriyle açıklanmaya çalışılmaktadır. Zaman serisi analizi için ortaya konulan modeller gecikmeli değerler ile şimdiki zaman değeri arasındaki ilişkiyi modellemeye çalışır ve bu ilişki modelinin yapısı ile modelde kullanılan varsayımlara göre birbirlerinden ayrılırlar.

De Gooijer ve Hyndman (2006) çalışmalarında 1982 – 2005 yılları arasında zaman serisi analizinde kullanılan modelleri gözden geçirmekte ve sınıflandırmaktadır. Literatürde, ARCH, GARCH gibi değişen varyanslı zaman serisi modelleri; ARMA, ARIMA gibi doğrusal zaman serisi modelleri; VAR, STAR, Yapay Sinir Ağları, SVM gibi doğrusal olmayan modellerle Gizli Markov Modelleri ve son yıllarda kullanımı artan Bulanık Mantık gibi birçok model ve model sınıfına rastlanmaktadır (De Gooijer ve Hyndman, 2006).

Bu modellerin varsayımları gerçek hayatta karşılaşılan zaman serilerinin özelliklerini genellikle tam olarak karşılayamadığından literatürde son yıllarda birden çok ve farklı özelliklerde modelin bir arada kullanıldığı hibrit modeller ortaya konulmaktadır. Analizi yapılan zaman serisi farklı özellikleri bir arada taşıyabileceğinden, oluşturulan hibrit modellerde özellikle farklı varsayımları ve farklı özellikleri olan modellerin kullanılması amaçlanmaktadır. Literatürde sıklıkla kullanılan hibrit model yapılarından biri doğrusal bir model ile doğrusal olmayan bir modelin bir arada kullanıldığı hibrit yapıdır.

Bu çalışmada ortaya konulan Optimize ARIMA – YSA Hibrit Modeli doğrusal bir model olan ARIMA ile doğrusal olmayan bir model olarak Yapay Sinir Ağlarını bir arada kullanarak her ikisinin gücünden faydalanmayı amaçlamaktadır.

İKİNCİ BÖLÜM

ARIMA, YSA VE HİBRİT ARIMA – YSA MODELLERİ

2.1. ARIMA Modeli

Box ve Jenkins (1976) tarafından ortaya atılan Otoregresif Entegre Hareketli Ortalamalar Modeli, Otoregresif (AR) ve Hareketli Ortalamalar (MA) modelinin bir arada kullanıldığı Otoregresif Hareketli Ortalamalar (ARMA) modeli temel alınarak geliştirilmiştir. ARMA modeli durağan zaman serilerine uygulanamamakta, ARIMA modeli ise zaman serisini ardışık fark alma yöntemiyle durağan hale getirerek ARMA modelini uygulamaktadır. ARIMA modeli ARMA modelinden farklı olarak seriyi durağan yapan bir entegre katsayı kullanır (d) ve bu süreç I(d) simgesi ile ifade edilir.

2.1.1. Otoregresif Model

Otoregresif modeller, bir zaman serisinin şu anki değeri x_t 'nin, p adet geçmiş değer $x_{t-1}, x_{t-2}, \dots, x_{t-p}$ ile açıklanabileceği fikrini temel almaktadır. Buna göre p'inci dereceden bir otoregresif model AR(p) ile gösterilir ve aşağıdaki şekilde ifade edilir (Shumway ve Stoffer, 2011: 57):

$$x_t = \varphi_1 x_{t-1} + \varphi_2 x_{t-2} + \dots + \varphi_p x_{t-p} + \omega_t \quad (2.1)$$

Bu eşitlik daha kompakt şekilde gösterilebilir:

$$x_t = \sum_{i=1}^p \varphi_i x_{t-i} + \omega_t \quad (2.2)$$

Burada x_t durağan bir zaman serisinin t zamanındaki değeri ve $\varphi_1, \varphi_2, \dots, \varphi_p$ sabit katsayılardır. Ayrıca $\varphi_p \neq 0$ 'dır. Eşitlikte serinin ortalaması, μ , sıfır kabul edilmektedir. Eğer ortalama sıfırdan farklıysa eşitlik aşağıdaki hali alır:

$$x_t - \mu = \varphi_1 (x_{t-1} - \mu) + \varphi_2 (x_{t-2} - \mu) + \dots + \varphi_p (x_{t-p} - \mu) + \omega_t \quad (2.3)$$

Aynı eşitlik aşağıdaki gibi ifade edilebilir:

$$x_t = \alpha + \varphi_1 x_{t-1} + \varphi_2 x_{t-2} + \dots + \varphi_p x_{t-p} + \omega_t \quad (2.4)$$

Burada, $\alpha = \mu(1 - \varphi_1 - \varphi_2 - \dots - \varphi_p)$ olur. Eşitlikle ifade edilen model çoklu regresyon modelinin aynısıdır. Çoklu regresyonda bir değişkenin değerini açıklamak için başka değişkenler kullanılırken, otoregresyon modelinde bir değişkenin değeri aynı değişkenin geçmiş değerleri kullanılarak modellenmektedir. Örneğin AR(1) ve AR(2) modelleri sırasıyla eşitlikteki gibidir:

$$x_t = \varphi_1 x_{t-1} + \omega_t \quad (2.5)$$

$$x_t = \varphi_1 x_{t-1} + \varphi_2 x_{t-2} + \omega_t \quad (2.6)$$

2.1.2. Hareketli Ortalamalar Modeli

Otoregresif modelin, eşitliğin sol tarafındaki x_t 'nin geçmiş değerleriyle doğrusal olarak ilişkilendirildiği yapıya alternatif olarak, modelin eşitliğin sağ tarafındaki beyaz gürültü terimi ω_t 'nin geçmiş değerlerine göre modellendiği hareketli ortalama modeli ortaya konulmuştur. Hareketli ortalama modeli zaman serisinin t zamanındaki değeri x_t 'yi, q adet geçmiş hata değeri $\omega_{t-1}, \omega_{t-2}, \dots, \omega_{t-q}$ ile açıklamaktadır. Buna göre q'inci dereceden bir hareketli ortalama modeli, MA(q), aşağıdaki şekilde ifade edilir (Shumway ve Stoffer, 2011: 59):

$$x_t = \omega_t + \theta_1 \omega_{t-1} + \theta_2 \omega_{t-2} + \dots + \theta_q \omega_{t-q} \quad (2.7)$$

Eşitlikte q gecikme sayısını göstermektedir. $\theta_p \neq 0$ olmak üzere $\theta_1, \theta_2, \dots, \theta_q$ gecikmeli hata değerlerinin katsayılarıdır.

Örnek olarak birinci ve ikinci dereceden hareketli ortalama modelleri MA(1) ve MA(2) aşağıdaki gibi gösterilebilir:

$$x_t = \omega_t + \theta_1 \omega_{t-1} \quad (2.8)$$

$$x_t = \omega_t + \theta_1 \omega_{t-1} + \theta_2 \omega_{t-2} \quad (2.9)$$

2.1.3. Otoregresif Hareketli Ortalamalar Modeli

Otoregresif Hareketli Ortalamalar Modeli, Otoregresif Model ile Hareketli Ortalamalar Modelinin bir arada kullanılmasıdır. Otoregresif Hareketli Ortalamalar modeline göre bir zaman serisinin t zamanındaki değeri x_t , bu serinin p adet gecikmeli değeri $x_{t-1}, x_{t-2}, \dots, x_{t-p}$ ile q adet geçmiş hata değerinin $\omega_{t-1}, \omega_{t-2}, \dots, \omega_{t-q}$ doğrusal bir bileşeni olarak ifade edilebilir. ARMA (p,q) ile gösterilen Otoregresif Hareketli Ortalamalar Modeli aşağıdaki gibi gösterilir (Shumway ve Stoffer, 2011: 60):

$$x_t = \varphi_1 x_{t-1} + \varphi_2 x_{t-2} + \dots + \varphi_p x_{t-p} + \omega_t + \theta_1 \omega_{t-1} + \theta_2 \omega_{t-2} + \dots + \theta_q \omega_{t-q} \quad (2.10)$$

$\varphi_1, \varphi_2, \dots, \varphi_p$ gecikmeli değerlerin ve $\theta_1, \theta_2, \dots, \theta_q$ geçmiş hata değerlerinin sabit katsayıları ve ω_t beyaz gürültü özellikleri taşıyan t zamanı için hata terimidir. Ayrıca $\varphi_p \neq 0$ ve $\theta_p \neq 0$ 'dır. Burada p ve q sırasıyla otoregresif ve hareketli ortalama dereceleridir.

Eğer ortalama (μ) sıfırdan farklıysa, eşitlik aşağıdaki gibi olur (Shumway ve Stoffer, 2011: 61):

$$x_t = \alpha + \varphi_1 x_{t-1} + \varphi_2 x_{t-2} + \dots + \varphi_p x_{t-p} + \omega_t + \theta_1 \omega_{t-1} + \theta_2 \omega_{t-2} + \dots + \theta_q \omega_{t-q} \quad (2.11)$$

Burada, $\alpha = \mu(1 - \varphi_1 - \varphi_2 - \dots - \varphi_p)$ 'dir. ARMA(p,q) modelinde $p = 0$ olması durumunda model hareketli ortalama modeli haline gelirken, $q = 0$ olması durumundaysa model otoregresif model halini alır.

2.1.4. Otoregresif Entegre Hareketli Ortalamalar Modeli

ARMA (p,q) modellerinin bir zaman serisine uygulanabilmesi için serinin durağan olması gerekmektedir. Oysa gerçek hayatta karşılaşılan zaman serilerinin çoğu durağan değildir. Durağan olmayan zaman serilerinin varyansı ve ortalaması zaman içinde değiştiğinden güvenilir sonuçlar elde edilememektedir. Bu sorunun üstesinden gelebilmek için serinin durağan hale getirilmesi gerekmektedir.

Zaman serilerinin durağan hale getirilmesi amacıyla sıklıkla kullanılan yöntem ardışık fark alma yöntemidir. Bu yöntemin çıkış noktası zaman serisinin bir trend bileşeni ve bir durağan bileşenden oluştuğu varsayımdır (Shumway ve Stoffer, 2011: 84). Gerçekten de gerçek hayatta karşılaşılan zaman serisi modellerinin çoğu trend bileşeni içermektedir. Bu varsayım dikkate alınarak bir zaman serisi x_t aşağıdaki gibi yazılabilir:

$$x_t = \mu_t + y_t \quad (2.12)$$

Eşitlikte μ_t trend bileşenidir ve $\mu_t = \beta_0 + \beta_1 t$ olarak ifade edilir. Trend bileşeni daha önce bahsedildiği gibi varyans ve ortalaması zamana bağlı olarak değiştiği için durağan değildir. Bu durumda serinin birinci derece farkı alınır,

$$\nabla x_t = x_t - x_{t-1} = \beta_0 + \beta_1 t + y_t - \beta_0 - \beta_1(t-1) - y_{t-1} = \beta_1 + y_t - y_{t-1} \quad (2.13)$$

olur. Eşitlik daha sade haliyle aşağıdaki gibidir:

$$\nabla x_t = \beta_1 + \nabla y_t \quad (2.14)$$

Eşitlikten de anlaşılabileceği gibi fark alma işlemi sonrası trend bileşeninin yarattığı durağan olmama durumu ortadan kaldırılmış olur. Benzer şekilde eğer trend ikinci dereceden, $\mu_t = \beta_0 + \beta_1 t + \beta_2 t^2$ formunda ise bu durumda birinci dereceden fark alma işlemi yeterli olmaz. Bu durumda serinin bir kez daha farkı alınır ve ikinci dereceden fark serisi $\nabla^2 x_t$ ile gösterilir. Durağan olmayan bir seriyi ardışık farklar alınarak durağan hale getiren modele entegre (*integrated*) model denir. Durağan hale gelene kadar d defa farkı alınan seri için entegre model I(d) ile gösterilir.

ARMA(p,q) modeline entegre model I(d) eklenerek model durağan olmayan zaman serileri için de kullanılabilir hale gelmekte ve Otoregresif Entegre Hareketli Ortalamalar Modeli, ARIMA (p,d,q), elde edilmektedir. Bir zaman serisi x_t için kurulan modelde serinin d'inci dereceden fark serisi $\nabla^d x_t$ bir ARMA(p,q) modeliyse, buna ARIMA(p,d,q) modeli adı verilir (Shumway ve Stoffer, 2011: 84).

Bir zaman serisi için d'inci dereceden fark $\nabla^d x_t = w_t$ olmak üzere, p'inci derece otoregresif, d'inci derece entegre ve q'inci derece hareketli ortalama ARIMA (p,d,q) modeli aşağıdaki gibi ifade edilebilir:

$$w_t = \varphi_1 w_{t-1} + \varphi_2 w_{t-2} + \dots + \varphi_p w_{t-p} + a_t + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q} \quad (2.15)$$

Burada a_t , d'inci derece fark serisi için t zamanındaki hata terimi, $\varphi_1, \varphi_2, \dots, \varphi_p$ yine aynı seri için gecikmeli değerlerin ve $\theta_1, \theta_2, \dots, \theta_q$ geçmiş hata değerlerinin katsayılarını ifade etmektedir.

2.1.4.1. Model Seçimi

Bir ARIMA(p,d,q) modeli oluşturulurken öncelikle modelin derecelerinin belirlenmesi, diğer bir deyişle, ARIMA(p,d,q) modeli için en uygun p, d ve q değerlerinin tespit edilmesi gerekmektedir.

İlk aşamada zaman serisinin durağan olup olmadığı tespit edilmektedir. Serinin durağan olup olmadığının anlaşılması için daha önce bahsedilen durağanlık testlerinden faydalanılmaktadır. Eğer zaman serisi durağansa fark alma işlemine gerek yoktur ve $d = 0$ kabul edilir. Serinin durağan olmadığı durumlarda serinin birinci farkı alınarak tekrar durağanlık testlerine başvurulur. Fark alma işlemi sonrasında seri durağan hale gelmişse $d = 1$ 'dir. Seri halen durağan halde değilse yeniden fark alma işlemi uygulanır ve seri durağan hale gelene kadar fark alınmaya devam eder. Zaman serisini durağan hale getiren en küçük fark değeri, d için en uygun değer kabul edilir. Zaman serisi durağan olduğu halde fark alınmaya devam edilmesi ve entegre derecesi d'nin artırılması zaman serisinde aşırı fark alma (*overdifferencing*) durumuna yol açabilir. Aşırı fark alma meydana geldiğinde zaman serisinde gerçekte olmayan korelasyonlar ortaya çıkabilmektedir. (Shumway ve Stoffer, 2011: 88)

Entegre dere-ce d için en uygun değer bulunduktan sonra en uygun otoregresif ve hareketli ortalama dereceleri p ve q bulunmalıdır. Literatürde ARIMA modelinin derecesini tespit etmek ve en iyi modeli bulmak amacıyla kullanılan bazı yöntemler bulunmaktadır.

Literatürde en iyi modelin tespiti için zaman serisinin otokorelasyon ve kısmi otokorelasyon fonksiyonları kullanılabilir. Bu fonksiyonların korelogramları serinin hangi geçmiş değerlerle bağıntılı olduğu hakkında fikir verebilmektedir. Ancak gerçek hayatta karşılaşılan zaman serileri ve bu serilerin otokorelasyon ve kısmi otokorelasyon korelogramları oldukça karmaşık olduğundan bu grafikleri yorumlamak ve en iyi modeli belirlemek oldukça zordur. Bu sebeplerle en iyi modelin belirlenmesi için daha nesnel modeller olan bilgi kriteri (*information criteria*) modelleri kullanılmaktadır (Brooks, 2008: 235).

Bilgi kriterlerinde amaç zaman serisinin en az terim kullanılarak en az hatayla modellenmesidir. Bu sebeple bilgi kriterleri iki etken üzerinde durmaktadır. Bunlardan birincisi hataların kareleri toplamının bir fonksiyonu olan bir terim ve ikincisi modele eklenen yeni katsayılar sonucu azalan serbestlik derecesi için bir ceza terimidir. Modele eklenen yeni bir

katsayı veya gecikme hata kareleri toplamını azaltarak pozitif yönde katkı sağlarken, aynı zamanda serbestlik derecesini azaltarak negatif bir etkide bulunmaktadır (Brooks, 2008: 236).

En çok kullanılan bilgi kriteri modelleri arasında Akaike Bilgi Kriteri (AIC), Düzeltilmiş Akaike Bilgi Kriteri (AICc), Schwarz Bayesian Kriteri (SBC) ve Hannan – Quinn Kriteri (HQC) sayılabilir. Bilgi kriteri modellerinin matematiksel ifadeleri aşağıdaki gibi gösterilmektedir:

- Akaike Bilgi Kriteri (AIC):

$$AIC = \ln(\hat{\sigma}^2) + \frac{2k}{T} \quad (2.16)$$

- Düzeltilmiş Akaike Bilgi Kriteri (AICc):

$$AICc = \ln(\hat{\sigma}^2) + \frac{2k}{T} + \frac{2k(k+1)}{T-k-1} \quad (2.17)$$

- Schwarz Bayesian Bilgi Kriteri (SBC):

$$SBC = \ln(\hat{\sigma}^2) + \frac{k}{T} \ln T \quad (2.18)$$

- Hannan – Quinn Bilgi Kriteri (HQC):

$$HQC = \ln(\hat{\sigma}^2) + \frac{k}{T} \ln(\ln(T)) \quad (2.19)$$

Eşitliklerde $\hat{\sigma}^2$ artıkların varyans tahmini olup aynı zamanda model için toplam hata karenin gözlem sayısına bölümüne eşittir. T değeri toplam gözlem sayısını ifade eder. k , modeldeki parametre sayısıdır ve bir ARIMA modeli için $k = p + q + 1$ olarak ifade edilebilir (Brooks, 2008: 233).

Bilgi kriterleri ile modeller karşılaştırılırken bilgi kriteri değeri en küçük olan model tercih edilmektedir. Genellikle modele eklenen her bir katsayı toplam hata kare değerini düşürmekte, bu sebeple eşitliklerde yer alan artıkların varyans tahmininin doğal logaritma değeri azalmaktadır. Diğer taraftan eşitliklerde varyans tahmininin doğal logaritması dışında kalan bölüm bilgi kriterinin ceza kısmını oluşturmaktadır ve eklenen her bir katsayı k değerini artırarak bilgi kriteri değerinde artışa sebep olmaktadır. (Falk vd., 2012: 288)

Eşitliklerden (2.16 – 2.19) de görülebileceği gibi bilgi kriteri modelleri birbirinden ceza değerleriyle ayrılırlar. SBC modeli AIC modelinden çok daha katı bir ceza uygularken HQC modelinin ceza katılığı bu ikisinin arasındadır.

Düzeltilmiş Akaike Bilgi Kriteri (AICc), Akaike Bilgi Kriterinin bir versiyonu olup sonlu gözlem sayısı olan ve özellikle gözlem sayısı az olan seriler için geliştirilmiştir. Hurvich ve Tsai (1989) çalışmasında AICc modelinin en iyi modeli bulmada AIC, SBC ve HQC modellerinden daha güçlü olduğunu ortaya konulmaktadır. AICc modeli AIC modeline ek bir ceza değeri getirmektedir. Eğer gözlem sayısı büyükse bu ceza terimi ($\frac{2k(k+1)}{T-k-1}$) ihmal edilebilir

bir değer almaktadır. Bu sebeple gerek büyük ve gerekse küçük gözlem büyüklüklerinde AIC yerine AICc modeli kullanılmaktadır (Snipes ve Taylor, 2014: 5).

ARIMA(p,d,q) modelleme sürecinde en iyi modelin bulunarak zaman serisine uygulanmasının ardından model sonucu elde edilen artık değerlerin incelenmesi ve uygulanan modelin uygunluğunun kontrol edilmesi gerekmektedir. Literatürde artıkların teşhis kontrolü (*residual diagnostic checking*) olarak adlandırılan süreç aynı zamanda ARIMA modelleme sürecinin de son aşamasını oluşturmaktadır.

ARIMA(p,d,q) ile yapılan modelleme sonucu elde edilen artıkların daha önce bahsedilen beyaz gürültü serisi özellikleri göstermesi beklenmektedir. Artıkların kontrol edilmesinin amacı, artık serinin beyaz gürültü özelliği gösterip göstermediğinin tespitidir. Bu sebeple artık seride gecikmeli değerlerle otokorelasyon olup olmadığına bakılmalıdır. Daha önce bahsedilen artıkların otokorelasyon korelogramı bu amaçla kullanılabilir. Hataların otokorelasyon korelogramında 95% güven aralığı için gecikmelerin kabaca 5%'inden fazlasının korelogram sınır değeri aşması veya gecikmelerden birinin sınır değeri fazlasıyla aşması durumunda eldeki artık serinin beyaz gürültü özelliği göstermediği düşünülür. Örneğin 40 gecikmeden 2 veya 3'ü sınır değeri aşıyorsa veya bir tanesi çok fazla aşıyorsa serinin istenilen beyaz gürültü özelliği göstermediği söylenebilir (Brockwell ve Davis, 2002: 164).

Gerçek hayatta karşılaşılan zaman serileri için bulunan en iyi modellerde dahi artık seri tam olarak beyaz gürültü formunda olmayabilir. Bu sebeple artıkların analizinde otokorelasyon korelogramı daha çok görsel bir muayene olarak kullanılmaktadır (Shumway ve Stoffer, 2011: 91).

Hata serisinin analizinde daha kesin sonuçlar elde etmek için istatistiki testlere başvurulmaktadır. Literatürde hataların analizinde en çok kullanılan test Ljung – Box Q Testi (LBQ)'dir. Ljung ve Box (1978) tarafından ortaya konulan test için istatistik değeri aşağıdaki gibi hesaplanmaktadır (Yürekli vd., 2005: 65):

$$Q(r) = n(n+2) \sum_{k=1}^m \frac{r_k(a)^2}{n-k} \quad (2.20)$$

Eşitlikte n gözlem sayısı, k otokorelasyon için gecikme değeri ve m otokorelasyon aranan gecikme sayısıdır. $r_k(a)$ ise k gecikme için otokorelasyon tahminidir. Örneğin 25. gecikmeye kadar otokorelasyon değerleri analiz ediliyorsa, $k = 1, 2, \dots, 25$ ve $m = 25$ 'tir. Ljung – Box Q Testi bir hipotez testidir ve ki-kare (χ^2) dağılımı ile test edilmektedir.

Ljung – Box Q Testi için otokorelasyon aranan gecikme sayısı (m) ile ilgili kesin bir kural olmamakla birlikte, çalışmalar testten en iyi performansı alabilmek için gecikme sayısının $m \approx \ln(T)$ olarak seçilmesi gerektiğini göstermektedir. Burada T gözlem sayısını ifade etmektedir (Tsay, 2002: 25).

2.2. Yapay Sinir Ağları Modeli


2.2.1. Tanım ve Temel Kavramlar

Bir yapay sinir ağı, biyolojik sinir ağlarının yapısını ve işlevselliğini taklit eden bir matematiksel modeldir (Krenker vd., 2011: 3). Yapay sinir ağı, işlevselliği biyolojik nörona dayanan, düğüm olarak adlandırılan basit işlem öğelerinin birbirine bağlı yapısı olarak tanımlanabilir. Ağın işlem gücü, ağırlık adı verilen, düğümler arası bağların kuvvetinde saklıdır ve öğrenme olarak adlandırılan, bir dizi eğitim kalıbına adaptasyon süreci ile elde edilir (Gurney, 1997: 13).

Yapay Sinir Ağları biyolojik sinir ağları ve bu ağları oluşturan yapılar temel alınarak ortaya konulmuştur. İnsan beyni yaklaşık 100 milyar sinir hücresinden (nöron) meydana gelmektedir. Nöronlar hücre duvarında meydana gelen kısa ömürlü elektrik sinyalleri ile iletişim kurmaktadır. Nöronlar arası bağlantılar sinaps adı verilen elektrokimyasal kavşaklarla birleşirler. Sinapslar, dentrit denilen hücrelerin dallarında bulurlar (Gurney, 1997: 13).

Her bir nöron, diğer nöronlardan gelen binlerce bağlantıya sahiptir ve sürekli olarak hücre gövdesine ulaşan yoğun sinyal akışı almaktadır. Bu sinyaller hücre gövdesinde birleşip toplanmakta ve belli bir eşik değeri geçildiğinde, kaba tabirle, nöron ateşlenmekte yani tepki olarak bir voltaj etkisi yaratmaktadır. Ortaya çıkan bu etki nöronun akson adı verilen kısmı aracılığıyla diğer nöronlara iletilmektedir (Gurney, 1997: 13).

Akson bir nöron hücresinin çıktı yoludur ve akson dalları sinaps kavşaklarıyla diğer nöronların girdi yolları olan dentritlerle birleşirler (Tan, 2004: 17). Biyolojik bir nöron ve elemanlarının temsili gösterimi aşağıdaki gibidir:




Şekil 2.1. Biyolojik Bir Nöronun Yapısı

Bir elektrik çıktısının üretilip üretilmeyeceğinin belirlenmesinde bazı sinyallerin ateşlemeyi engelleyici etkisi, diğerlerinin ise çıktı üretimini harekete geçirici etkisi etkindir. Bu

sebeple her bir nöronu birbirinden ayıran işlem kabiliyeti diğer nöronlarla olan sinaptik bağlantıların çeşidinde ve gücünde yatmaktadır (Gurney, 1997: 13).

Sinirsel yapının bir kısmı doğumda belirlenmektedir. Diğer kısımlar öğrenme yoluyla geliştirilmekte ve yeni bağlantılar kurulurken bazı diğer bağlantılar ortadan kalkmaktadır. Bu gelişim en çok hayatın erken dönemlerinde dikkat çekse de, sinirsel yapı hayat boyu değişmektedir. Sonraki dönemlerde değişim daha çok sinaptik kavşakların güçlenmesi veya zayıflaması şeklinde devam eder (Hagan vd., 2015: 4).

Yapay sinir ağları modelinin yapıtaşı nöron modelidir. Biyolojik nöron yapısından ilham alınarak modellenen yapay nöronda sinyal akışı Şekil 2.2’de olduğu gibi gösterilebilir. Yapay nöron modelinde nöronlar arası her bir bağlantı, kendine özgü bir ağırlıkla ifade edilir. j nöronundan çıkıp k nöronuna ulaşan bir sinyal için ağırlık değeri w_{kj} ile ifade edilmektedir. Biyolojik nöronlarda, nöronlar arası bağlantılarda bulunan sinapsların engelleyici veya destekleyici etkileri ağırlık değerleri olarak modellenmektedir. Ağırlıklar pozitif ve negatif değerler alabilmektedir. Pozitif ağırlık değerleri destekleyici, negatif ağırlık değerleri engelleyici etki olarak düşünülebilir.



Şekil 2.2. Bir Yapay Nöronun Yapısı

Diğer nöronlardan çıkan $x_1, x_2, \dots, x_m$ sinyalleri girdi olarak k nöronuna ulaşmadan önce sinaptik ağırlıklar $w_{k1}, w_{k2}, \dots, w_{km}$ ile çarpılırlar. Ağırlıklandırılmış girdi değerleri nöronda toplam fonksiyonu ile toplanır. Basit toplama işlemi olan bu fonksiyona doğrusal birleştirici (*linear combiner*) denmektedir (Haykin, 2008: 10).

Girdilerin toplanmasıyla elde edilen değer, bir aktivasyon fonksiyonundan geçerek çıktı değerini meydana getirir. Aktivasyon fonksiyonu, $\varphi(\cdot)$, nöronun çıktısını sınırlandırır ve belli bir aralıkta ifade edilmesini sağlar.

Bir k nöronu için çıktı değeri y_k , girdi değerleri $x_1, x_2, \dots, x_m$ ve her bir girdi için ağırlık değerleri $w_{k1}, w_{k2}, \dots, w_{km}$ olmak üzere; çıktının girdiler cinsinden ifadesi Eşitlik 4.1’de ifade edilmektedir (Haykin, 2008: 11):

$$y_k = \varphi(\sum_{j=1}^m w_{jk} x_j) \quad (2.21)$$

Bazı durumlarda nöron modeline bir eğilim (*bias*) değeri b_k eklenebilir. Eğilim aktivasyon fonksiyonuna giren net girdiyi düşürmek veya yükseltmek için kullanılır. Bu durumda çıktı değeri aşağıdaki şekilde olur:

$$y_k = \varphi(b_k + \sum_{j=1}^m w_{jk} x_j) \quad (2.22)$$

Literatürde kullanılan iki temel aktivasyon fonksiyonundan söz edilebilir. Bunlar Eşik Fonksiyonu ve Sigmoid Fonksiyondur.

- Eşik Fonksiyon (*Threshold Function*):


v_k , aktivasyon fonksiyonunun girdi değeri ve $v_k = \sum_{j=1}^m w_{jk} x_j$ olmak üzere, eşik fonksiyon aşağıdaki gibi tanımlanabilir:

$$\varphi(v) = \begin{cases} 1 & \text{if } v \geq 0 \\ 0 & \text{if } v < 0 \end{cases} \quad (2.23)$$

Böylece nöronun çıktısı aşağıdaki gibi gösterilebilir:

$$y_k = \begin{cases} 1 & \text{if } v_k \geq 0 \\ 0 & \text{if } v_k < 0 \end{cases} \quad (2.24)$$

Örnek bir eşik fonksiyon grafiği resimdeki gibidir:



Şekil 2.3. Eşik Fonksiyon Örneği

Kaynak: Haykin, 2008: 13

Eşik aktivasyon fonksiyonuna sahip nöron modeli literatürde McCulloch – Pitts modeli (Haykin, 2008: 14) veya perseptron (Krenker vd., 2011: 6) olarak adlandırılmaktadır. Perseptron genellikle sınıflandırma problemlerinde ve çoğunlukla çıktı katmanı nöronlarında kullanılmaktadır (Krenker vd., 2011: 6).


- Sigmoid Fonksiyon (*Sigmoid Function*):

Sigmoid fonksiyon, aktivasyon fonksiyonu olarak açık ara en çok kullanılan fonksiyondur. Eşik fonksiyonu nöron sinyallerini ikili sistem değerleriyle (*binary*) sınırlandırdığı için sürekli ve azalan ya da artan sinyal oluşumu engellenmektedir. Sigmoid

fonksiyonlar bu sinyal yapısını yumuşatmakta ve belli bir aralıkta sürekli değerler almasına olanak sağlamaktadır (Gurney, 1997). Aktivasyon fonksiyonu olarak kullanılan en önemli sigmoid fonksiyonlardan biri lojistik (*logistics*) fonksiyondur. Lojistik fonksiyon aşağıdaki gibi gösterilebilir (Haykin, 2008: 14):

$$\varphi(v) = \frac{1}{1+e^{-av}} \quad (2.25)$$

Burada v aktivasyon fonksiyonunun girdi değeri, a ise fonksiyonun eğim parametresidir. a değeri değiştirilerek farklı eğim derecelerinde lojistik fonksiyonlar elde etmek mümkündür. Eğim parametresi sonsuza yaklaştıkça fonksiyon eşik fonksiyon haline yaklaşır. Eşik fonksiyon yalnızca 0 ve 1 değerlerini alabilirken, lojistik fonksiyon 0 ile 1 arasındaki değerleri alır. Şekil 2.4'te farklı eğim derecelerinde lojistik fonksiyonlar gösterilmektedir.



Şekil 2.4. Farklı Eğim Derecelerinde Lojistik Fonksiyon Örnekleri

Kaynak: Haykin, 2008: 13

Lojistik fonksiyon, aktivasyon fonksiyonunun alacağı değerleri 0 ile 1 arasında sınırlandırmaktadır. Ancak aktivasyon fonksiyonunun negatif değerler alması da istenebilir. Bu durumda sıklıkla kullanılan aktivasyon fonksiyonu hiperbolik tanjant (*hyperbolic tangent*) fonksiyonudur. v , aktivasyon fonksiyonunun girdisi olmak üzere, hiperbolik tanjant fonksiyonu aşağıdaki gibi ifade edilebilir:

$$\varphi(v) = \tanh(v) \quad (2.26)$$

Aktivasyon fonksiyonları seçilirken tersinir (*differentiable*), diğer bir deyişle, türevi alınabilir fonksiyonlar seçilmektedir. Yukarıda bahsedilen sigmoid fonksiyon örnekleri tersinir olduğu halde eşik fonksiyon tersinebilir değildir. Hataların geri yayılımı gibi öğrenme modellerinde aktivasyon fonksiyonlarının tersinir olması önem taşımaktadır.


2.2.2. Ağ Mimarisi

Yapay sinir ağları içerisinde yer alan nöronlar, nöronlar arası bağlantıların şekli ve nöronların oluşturduğu katmanlar yapay sinir ağının mimarisini (*architecture*) ortaya koyar. Genel olarak üç temel ağ mimari sınıfı tanımlanabilir. Bunlar, tek katmanlı ileri beslemeli ağlar, çok katmanlı ileri beslemeli ağlar ve yinelemeli ağlardır (Haykin, 2008: 21).

2.2.2.1. Tek Katmanlı İleri Beslemeli Ağlar

Katmanlı bir ağ yapısında nöronlar katmanlar halinde bulunurlar. Katmanlı ağların en basit yapısı olan tek katmanlı ileri beslemeli ağlarda bir girdi katmanı ve bir çıktı katmanı bulunmaktadır. Girdi katmanında yer alan nöronlarda herhangi bir işlem olmamakta, bu katmanlar sadece girdi verilerini çıktı katmanına ulaştırmaktadırlar (Haykin, 2008: 21).

Ağın tek katmanlı olarak adlandırılması tüm hesaplamaların tek katmanda, çıktı katmanında, yapılması sebebiyledir. Girdi katmanından alınan veriler çıktı katmanında yer alan nöronlarda işlenerek çıktı veya çıktılar meydana getirilir. Örnek bir tek katmanlı ileri beslemeli ağ Şekil 2.5'te gösterilmektedir.



Şekil 2.5. Tek Katmanlı İleri Beslemeli Yapay Sinir Ağı

2.2.2.2. Çok Katmanlı İleri Beslemeli Ağlar


Çok katmanlı ileri beslemeli ağların tek katmanlı ağdan farkı girdi ve çıktı katmanı arasında bir veya birden fazla “gizli” katman bulunmasıdır. Bu katmanlara gizli (*hidden*) katman denmesinin sebebi bu katmanların ağın girdi veya çıktı kısımlarından direk olarak görülmemesidir (Haykin, 2008: 22).

Girdi katmanından alınan girdi verileri gizli katmana ulaşarak işlenir ve çıktı değerleri oluşturulur. Bu katmanda elde edilen çıktılar, varsa ikinci gizli katmana, yoksa çıktı katmanına girdi olarak ulaşır. Çıktı katmanında işlenen veriler sonucu elde edilen çıktı değerleri aynı zamanda ağın çıktı değerleri olur.

İleri beslemeli ağlarda bir katmanda yer alan nöronlardan çıkan veriler sadece bir ileri katmandaki nöronlara girdi olarak ulaşabilir (Haykin, 2008: 22). Örneğin girdi katmanı, bir gizli katman ve çıktı katmanından oluşan bir çok katmanlı ileri beslemeli ağda; girdi katmanındaki bir nöronun çıktısı sadece gizli katmana, gizli katmandan çıkan çıktı değeri ise sadece çıktı katmanına girdi olarak ulaşabilir.

Çok katmanlı ileri beslemeli ağlarda bir katmanda yer alan nöronların tamamı bir sonraki katmanda bulunan nöronların tamamıyla bağlantılıysa buna tam bağlantılı (*fully connected*) ağ adı verilir. Eğer bu bağlantılardan bazıları eksikse bu ağ yapısı kısmi bağlantılı (*partially connected*) ağ olarak adlandırılır (Haykin, 2008: 23).

Çok katmanlı ileri beslemeli ağlar katmanlardaki nöron sayılarıyla tanımlanır. Örneğin girdi katmanında m , birinci gizli katmanda $h1$, ikinci gizli katmanda $h2$ ve çıktı katmanında q adet nöron bulunan bir ağ, $m-h1-h2-q$ ağ olarak tanımlanır. Tam bağlantılı çok katmanlı 4-3-1 ileri beslemeli bir yapay sinir ağı Şekil 2.6'da gösterilmektedir.



Şekil 2.6. Tam Bağlantılı Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı

2.2.2.3. Yinelemeli Ağlar

Yinelemeli ağların ileri beslemeli ağlardan farkı ağ yapısında en az bir adet geri besleme döngüsü bulundurmasıdır. İleri beslemeli ağlarda her bir nöron çıktısı sadece bir sonraki katman nöronlarına iletebilirken, yinelemeli ağlarda bu zorunluluk bulunmamaktadır. Örneğin tek katmanlı bir ağ her bir nöronun çıktısı değerlerinin tekrar girdi olarak nöronlara dönmesiyle yinelemeli ağ yapısı oluşturabilir. Bir nöronun çıktısı aynı nörona girdi olarak dönyorsa buna öz geri besleme denilir (Haykin, 2008: 23).

2.2.3. Öğrenme

İnsan beyninin öğrenme süreçleri olduğu gibi yapay sinir ağlarının da öğrenme süreçleri bulunmaktadır. Yapay sinir ağlarında öğrenme süreçleri denetimli öğrenme ve denetimsiz öğrenme olarak iki ana gruba ayrılabilir. Denetimsiz öğrenmeyi ise kendi içinde denetimsiz ve güçlendirilmiş öğrenme olarak ayırmak mümkündür.

2.2.3.1. Denetimsiz Öğrenme

Denetimsiz öğrenme, bir öğretici olmadan öğrenme (*learning without a teacher*) olarak ta adlandırılmaktadır. Denetimsiz öğrenmede ağın durumunu denetleyen dışsal bir öğretici bulunmamaktadır (Haykin, 2008: 36). Diğer bir deyişle, ağın eğitimi için belirgin çıktı değerleri bulunmamaktadır. Ağa verilen girdi değerlerinin belirli sınıflara ait olduğu varsayılır ve ağın girdileri bu sınıflara göre ayırması beklenir (Tan, 2004: 39). Bu sebeple bu tip öğrenme modelleri genellikle sınıflandırma amaçlı olarak kullanılmaktadır. Denetimsiz öğrenme yönteminin en çok bilinen modellerinden biri olarak Kohonen Kendi Kendine Organize Haritaları (*Kohonen Self Organizing Maps*) örnek gösterilebilir.

2.2.3.2. Güçlendirilmiş Öğrenme

Güçlendirilmiş öğrenmede denetimsiz öğrenmeden farklı olarak, ağın elde ettiği çıktı değerinin doğru yönde olup olmadığı bildirilir (Tan, 2004: 39). Ağın elde ettiği sonucun doğru, yanlış ya da ne kadar doğru olduğuna dair verilen uyarıyla doğru sonucun elde edilmesi beklenir. Güçlendirilmiş öğrenme problem çözümünde denetimsiz öğrenmeden daha kullanışlıdır.

2.2.3.3. Denetimli Öğrenme

Bir öğretici ile öğrenme (*learning with a teacher*) olarak ta isimlendirilen denetimli öğrenme en çok kullanılan yapay sinir ağı öğrenme metodudur. Ağ için, her örnekleme girdi değerleri ve istenen çıktı değerleri yer almak üzere, birçok örneklem sunulur. Ağ bu örneklemelerde yer alan girdi değerleri sonucu elde ettiği çıktı değerleriyle istenen çıktı değerleri arasındaki hatayı azaltarak istenen çıktı değerlerine ulaşmaya çalışır. Bunu yapabilmek için ağ yapısında nöronlar arası bağlantılarda bulunan ağırlık değerleri sürekli olarak değiştirilir. Ağırlık değerlerinin yinelemeli (*iterative*) olarak değiştirilerek yapılan öğrenme sürecine eğitim (*training*) adı verilir (Tan, 2004: 39).

2.2.4. Eğitim

Yapay sinir ağlarının denetimli ve denetimsiz öğrenme modelleri için kullanılan birçok eğitim metodu vardır. Denetimsiz eğitim için en çok kullanılan iki yöntem olarak Tuevo Kohonen (1982) tarafından geliştirilen Kohonen Kendi Kendine Organize Haritalar ile Gail Carpenter ve Stephen Grossberg (1987) tarafından ortaya konulan Adaptif Rezonans Teorisi (ART) sayılabilir. Denetimli öğrenme içinse birçok farklı yöntem geliştirilmiştir. Geri yayılım (*backpropagation*), bulanık mantık, uzman-sistem kuralları (*expert-system rules*), evrimsel hesaplama (*evolutionary computation*) ve istatistiksel yöntemler ağların denetimli eğitiminde kullanılan başlıca yöntemlerdir. Denetimli öğrenmede en yaygın kullanılan eğitim yöntemi ise geri yayılım metodudur (Priddy ve Keller, 2005).

2.2.4.1. Geri Yayılım Metodu

Hataların geri yayılımı için kullanılan geri yayılım metodu basitçe iki aşamadan oluşmaktadır. Birinci aşama ileri yayılım olarak adlandırılır. Bu aşamada öncelikle ağıdaki her ağırlığa küçük, rassal başlangıç değerleri verilmektedir (Gurney, 1997: 102). Girdi değerleri girdi katmanından gizli katman veya katmanlardan geçerek çıktı katmanına ulaşır. Bağlantılarda rassal başlangıç ağırlıklarıyla çarpılarak nöronlarda toplanır ve aktivasyon fonksiyonu sonucu nöronun çıktısını oluşturur. Elde edilen çıktı değeri bağlantılar aracılığıyla diğer katmandaki nöronlara ulaşırken aynı işlemlerden geçer. Son olarak çıktı katmanında elde edilen çıktı değeri veya değerleri ağına çıktısıdır. İleri yayılım denilen birinci aşamada elde edilen çıktı değeri veya değerleri ağına çıktısıdır. İleri yayılım denilen birinci aşamada elde edilen çıktı değeri veya değerleri ağına çıktısıdır. İleri yayılım denilen birinci aşamada elde edilen çıktı değeri veya değerleri ağına çıktısıdır.

İkinci aşama yönteme adını veren geri yayılım aşamasıdır. Geri yayılım modeli çıktı ve gerçek değer arasındaki hatayı ağ boyunca geri yayarak minimize etme prensibine dayanır. Ağına hatası ağ boyunca her bir nörona geri yayılırken hatayı en aza indirmek için nöronlar arası bağlantılarda yer alan ağırlıklar güncellenir. Ağırlıkların güncellenmesinden sonra birinci aşama olan ileri yayılım tekrar edilerek yeni hata değeri bulunur ve yeni hata değerine göre hata geri yayılarak tekrar ağırlıklar güncellenir. Ağ istenilen hata seviyesinde çıktı veya çıktılar üretene kadar bu döngü tekrarlanır (Tan, 2004: 41).

Hatanın geri yayılımı delta kuralı (*delta rule*) adı verilen yöntem kullanılarak yapılır. Çıktı nöron veya nöronlarındaki hata değerleri kullanılarak bir önceki katmandan gelen nöron bağlantıları için yeni ağırlık değerleri ve yine bir önceki katman nöronları için hata değerleri bulunur. Elde edilen bu hata değerleri kullanılarak daha önceki katman nöronlarıyla olan bağlantı ağırlıkları için yeni değerler ve daha önceki katman nöronları için hata değerleri tespit

edilir. Ağırlıkların güncellenmesi bu şekilde girdi nöronlarının bağlantı ağırlıkları da güncellenene kadar devam eder.

i nöronundan j nöronuna gelen bir bağlantının ağırlık değişiminin basitleştirilmiş ifadesi aşağıdaki gibidir (Tan, 2004: 42):

$$\Delta w_{ij} = \mu \delta_j x_i \quad (2.27)$$

Burada w'_{ij} , i nöronundan çıkarak j nöronuna gelen bağlantının eski ağırlık değeri ve Δw_{ij} bu değer üzerinde yapılacak güncellemeyi ifade etmektedir. δ_j , j nöronunun çıktı hata değeri ve x_i , i nöronunun çıktı değerini göstermektedir. Eşitlikte yer alan μ değeri öğrenme oranı olarak tanımlanan bir katsayıdır.

Eşitlikte j nöronu için verilen hata değeri δ_j aşağıdaki gibi hesaplanmaktadır (Tan, 2004: 42):

$$\delta_j = (\sum \delta_k w_k) o_j (1 - o_j) \quad (2.28)$$

Burada j nöronunun ürettiği çıktı değeri $1, 2, \dots, k$ nöronlarına ulaşmaktadır. w_k çıktının k nöronuyla bağlantısının ağırlık değeri ve δ_k , k nöronunun çıktı hata değeridir. o_j ise, j nöronu için çıktı değeri olarak tanımlanır. Ağırlık değerleri için bulunan güncelleme miktarı kullanılarak yeni ağırlık değeri w_{ij} aşağıdaki gibi hesaplanır:


$$w_{ij} = w'_{ij} + \Delta w_{ij} \quad (2.29)$$

Geri yayılım metodunun dayandığı delta kuralı hatayı dereceli azaltma (*gradient descent*) yöntemiyle azaltarak en az hatayı bulmaya çalışmaktadır. Bir nöronun çıktı hatasını nöronun girdilerine yayarken hatanın her girdiye göre kısmi türevi alınmaktadır. Bu sebeple girdiler ile çıktı arasında ilişkiyi kuran aktivasyon fonksiyonunun türevi alınabilir, tersinir bir fonksiyon olması gerekmektedir. Eşitlik 4.7, delta kuralının tersinir bir aktivasyon fonksiyonu varsayımı ile basitleştirilmiş halidir.

Eşitlikte verilen öğrenme oranı, μ , değeri dereceli azaltma ile en az hatanın aranmasında aramanın hızının kontrol edilmesini sağlar. μ değeri yüksek alınırsa hata daha hızlı azaltılarak arama yapılır ancak daha az doğruluk ile karşılaşılabilir. Diğer taraftan öğrenme oranı çok küçük olursa en az hata daha yüksek doğrulukla bulunabilir ancak süreç çok uzun zaman alabilir.

Öğrenme oranının etkisi bir kâse ve bir bilye ile örneklenebilir. Kâse hata düzlemi olarak kabul edilirse, aranan en küçük hata kâsenin dip noktasıdır ve bilye dereceli azaltma algoritmasıdır. Eğer bilye hızlı atılırsa kâsenin dip noktasını geçerek diğer tarafa çıkabilir ve en az hatayı atlamış olur. Diğer taraftan bilye yavaş atılırsa dip noktayı daha yüksek doğrulukla bulur ancak süreç daha yavaş işler (Tan, 2004: 42).

Dereceli azaltma ile ilgili bir diğer önemli konu, yöntemin hata düzleminde aranan en küçük hata noktası global minimum yerine yerel minimum (*local minimum*) bölgesine sıkışması veya global minimum bölgesine ulaşmak yerine yerel minimum bölgeleri arasında kararsız bir şekilde dalgalanmasıdır. Karşılaşılan problemlerde hata düzlemi genellikle düz bir kâse şeklinde değildir ve bilyenin düşebileceği girinti ve çıkıntılara sahiptir(Tan, 2004: 42). Örnek bir hata düzlemi Şekil 2.7’de verilmektedir:



Şekil 2.7. Örnek Hata Düzlemi

Kaynak: Gurney, 1997: 104

Şekil 2.7’de gösterilen hata düzleminde P noktasında bulunan geri yayılım algoritması en az hata değeri olan global minimum noktası M_0 yerine yerel minimum M_1 noktasına ulaşabilir ve diğer yerel minimum noktaları arasında kararsız bir şekilde gezinebilir. Dereceli azaltma algoritmasının yerel minimum noktasına sıkışması veya yerel minimum noktaları arasında kararsız bir şekilde dolaşması eşitliğe momentum (M) adı verilen bir parametre eklenerek önlenmektedir. Geri yayılım modelinin kararsız halde hata düzleminde gezinmesi, yerel minimum noktasına sıkışmasından daha tehlikelidir. Karşılaşılan problemlerde çoğu zaman yerel minimum noktasındaki hata değeri yeterli olmaktadır. Momentum en küçük hatanın aranmasında modelin arama yönünde ileri geri salınım yapmasını engellemektedir. Momentum terimiyle birlikte eşitliğe eski ağırlık değeri w'_{ij} ve bir önceki ağırlık değeri w''_{ij} de eklenmektedir. Buna göre ağırlık güncelleme değerleri aşağıdaki gibi olur (Tan, 2004: 42):

$$\Delta w_{ij} = (1 - M)\mu\delta_j x_i + M(w'_{ij} - w''_{ij}) \quad (2.30)$$

Dikkat edilirse momentum değeri 0 olarak kabul edildiğinde Eşitlik 2.30, Eşitlik 2.27 halini almaktadır.

2.3. Hibrit ARIMA – YSA Modelleri

Doğrusal zaman serisi modellemeleri için en yaygın kullanılan yöntem ARIMA yöntemidir. Birçok zaman serisi için oldukça uygun olan modelin seriyi doğrusal olarak ele alması aynı zamanda yöntemin zayıf yönü olarak karşımıza çıkar. Gerçek dünyada karşılaşılan

zaman serileri genellikle doğrusal olmamaktadır. Bu tip, doğrusal olmayan zaman serisi problemleri için sıklıkla kullanılan yöntemlerden birisi ise Yapay Sinir Ağlarıdır.

ARIMA ve YSA birbirinin zıttı birçok özelliğe sahiptir. Öncelikle ARIMA doğrusal bir modelken, YSA doğrusal olmayan bir modeldir. İkinci olarak ARIMA doğası gereği parametrik olduğu halde, YSA parametrik değildir. ARIMA kullanılırken problemin genel yapısı bilinmektedir. YSA kullanımında ise böyle bir bilgiye gerek yoktur. ARIMA modellerinin geliştirilmesinde istatistiki teoriler kullanılır ve modelin uygunluğu istatistiki yöntemlerle tespit edilir. Ancak YSA’da model oluşturmak için ön tanımlı herhangi bir teknik bulunmamaktadır. Ayrıca ARIMA anlamak ve uygulamak için daha basit bir model olduğu halde YSA dizaynı oldukça karmaşıktır (Mahalakshmi vd., 2014: 566).

ARIMA ve YSA modellerinin bir arada kullanılmalarının başlıca sebebi olarak, karşılaşılan zaman serilerinin doğrusal mı yoksa doğrusal olmayan mı olduğunun kesin olarak bilinmemesi ve zaman serilerinin çoğunlukla hem doğrusal hem de doğrusal olmayan karakteri bir arada taşınması gösterilebilir. Zhang (2003)’in belirttiği gibi ARIMA modelleri özellikle karmaşık doğrusal olmayan problemlerde yeterli sonuçlar veremezken, YSA modelleri de doğrusal serilere uygulandığında karmaşık sonuçlar verebilmektedir. Dolayısıyla çoğu zaman ARIMA ve YSA tek başına tatmin edici sonuçlar vermediği halde bir arada kullanıldıklarında daha iyi sonuçlar elde edilmektedir.

ARIMA ve YSA modellerinin birleştirildiği çalışmalar son yıllarda artış göstermektedir. Uygulamalarda elde edilen sonuçlar bu tür hibrit modellerin çoğunlukla ayrı ayrı modellerden elde edilen sonuçlara göre daha doğru tahminler verdiğini ortaya koymaktadır. Literatürde ARIMA ve YSA modellerinin bir arada kullanıldığı dört hibrit model şekline rastlanmaktadır.

2.3.1. Zhang’in Hibrit ARIMA – YSA Modeli

ARIMA ve YSA modellerinin bir arada kullanıldığı hibrit model ilk defa Zhang (2003) tarafından ortaya atılmıştır. Buna göre bir zaman serisi doğrusal ve doğrusal olmayan bileşenlerin toplamından oluşmaktadır ve aşağıdaki gibi gösterilebilir:

$$y_t = L_t + N_t \quad (2.31)$$

Burada y_t zaman serisini, L_t serinin doğrusal bileşenini ve N_t de serinin doğrusal olmayan kısmını ifade etmektedir. Serinin verileri kullanılarak bu iki bileşen tahmin edilmelidir. Öncelikle tüm seri ARIMA ile modellenerek elde edilen kestirim değerleri doğrusal bileşeni meydana getirir. ARIMA modelinin hata değerleri olarak ta ifade edilebilecek olan, doğrusal modelden geriye kalan artık değerler, sadece doğrusal olmayan ilişki içeren bileşene

aittir. e_t , t zamanı için doğrusal modelden kalan artık değer ve $\hat{L}_t$, ARIMA ile elde edilen kestirim değerleri olmak üzere artık değer serisi aşağıdaki gibi gösterilebilir.

$$e_t = y_t - \hat{L}_t \quad (2.32)$$

İlk aşama sonucu kalan artık değer serisi, serinin doğrusal olmayan kısmını ifade etmektedir. Bundan sonra, ikinci aşama olarak, e_t artık değer serisi YSA ile modellenir. n girdi düğümü olan bir YSA modeli için eşitlik aşağıdaki gibi ifade edilebilir:

$$e_t = f(e_{t-1}, e_{t-2}, e_{t-3}, \dots, e_{t-n}) + \varepsilon_t \quad (2.33)$$

Buradan elde edilen kestirimler $\hat{N}_t$ doğrusal olmayan kestirim değerlerini ifade etmektedir. Eşitlikte f YSA ile modellenen doğrusal olmayan fonksiyonu ve ε_t rassal hata terimlerini ifade eder.

İkinci aşama sonunda hibrit modelin tahmin değerleri,

$$\hat{y}_t = \hat{L}_t + \hat{N}_t \quad (2.34)$$

olarak bulunur.

Çalışmada (Zhang, 2003), 1700 – 1987 yılları arası yıllık güneş lekesi sayısı, 1821 – 1934 yılları arasında Kuzey Kanada – Mackenzie Nehri bölgesinde yıllık tuzağa takılan vaşak sayısının 10 tabanından logaritmik değerleri ve GBP/USD kurunun 1980 – 1993 yılları arası haftalık doğal logaritmik değerleri olmak üzere üç ayrı zaman serisi kullanılmaktadır. Seriler, zaman serisi çalışmalarında sıklıkla kullanılan seriler olduğu için tercih edilmektedir (Zhang, 2003). Model, Ortalama Mutlak Sapma (*MAD*) ve Ortalama Hata Kare (*MSE*) açısından ARIMA ve YSA ile karşılaştırılmakta ve hibrit modelin bazı tahminlerde başarısız olsa da tüm tahminler göz önüne alındığında tahmin doğruluğunu artırdığı saptanmaktadır.

Literatürde Zhang'ın (2003) hibrit modelinin aylık yağış miktarı (Mahalakshmi vd., 2014), rüzgar hızı (Cadenas ve Rivera, 2010), enerji tüketimi (Wang ve Meng, 2012), turizm geliri (Hwang ve Day, 2013) ve su kalitesi (Durdu, 2010) gibi bir çok zaman serisi için başarılı sonuçlar verdiği görülmektedir.

2.3.2. Khashei ve Bijari'nin Hibrit ARIMA – YSA Modeli

Khashei ve Bijari (2011) çalışmasında zaman serileri için yeni bir hibrit model ortaya koymaktadır. Zhang (2003)'in modelinde olduğu gibi bu modelde de zaman serisinin doğrusal ve doğrusal olmayan bileşenleri olduğu varsayılmaktadır. Diğer taraftan uyguladığı yöntem farklıdır. Birinci aşamada zaman serisi verisi ARIMA ile modellenmekte ve doğrusal kestirim değerleri elde edilmektedir.

$$\hat{L}_t = a_1 y_{t-1} + \dots + a_p y_{t-p} + b_1 e_{t-1} + \dots + b_q e_{t-q} + e_t \quad (2.35)$$

Model ikinci aşamasıyla Zhang (2003)'in modelinden farklılık arz eder. Buna göre zaman serisi, ARIMA modeliyle bulunan geçmiş hata değerleri, geçmiş gerçek değerler ve ARIMA modeliyle bulunan şimdiki zaman tahmin değerinin bir fonksiyonudur. Bunların girdi olarak alındığı bir YSA modeli kurularak serinin tahmin değerleri elde edilir.

$$\hat{y}_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}, \hat{L}_t, z_{t-1}, z_{t-2}, \dots, z_{t-m}) \quad (2.36)$$

Burada f yapay sinir ağı tarafından oluşturulan doğrusal olmayan fonksiyonu, $e_{t-1}, e_{t-2}, \dots, e_{t-n}$ geçmiş artık değerleri, $\hat{L}_t$ şimdiki zaman ARIMA model kestirimini ve $z_{t-1}, z_{t-2}, \dots, z_{t-m}$ ise geçmiş zaman gerçek değerleri ifade etmektedir. n ve m değerleri ağ yapısı için tercih edilen değerlerdir. Böyle bir yapay sinir ağında $n+m+1$ girdi bulunmaktadır.

Khashei ve Bijari (2011), uygulama için daha önce Zhang (2003)'in kullandığı zaman serileri seçilmiş ve yeni modelin söz konusu zaman serileri için ayrı ayrı ARIMA, YSA, ve Zhang (2003)'in ortaya koyduğu hibrit modelden çok daha iyi sonuçlar verdiği ortaya konulmaktadır. Literatürde bu modelin ayrıca su kalitesi tahmini (Yan ve Zou, 2013), hisse senedi endeksi tahmini (Elwasify, 2015), turist tahmini (Aslanargun vd., 2007), tedarik zinciri yönetimi (Aburto ve Weber, 2007) gibi alanlarda uygulandığı görülmektedir.

Bu model bir adım ileri tahminler için uygun, çok adım ileri tahminler içinse kullanılamayacak bir modeldir. Geçmiş gerçek değerler yerine geçmiş kestirim değerleri kullanıldığında modelin doğruluğu azalmaktadır (Babu ve Reddy, 2015).

2.3.3. Çarpımsal Hibrit ARIMA – YSA Modeli

Wang vd. (2013) tarafından ortaya konulan çarpımsal hibrit model Zhang (2003)'in toplamsal modeline karşıt olarak çarpımsal bir yapı ileri sürer. Buna göre zaman serisi doğrusal ve doğrusal olmayan iki serinin çarpımı şeklinde ifade edilebilir.

$$y_t = L_t N_t \quad (2.37)$$

Modelin oluşturulması iki aşamadan meydana gelmektedir. Öncelikle Zhang (2003)'in modelinde olduğu gibi, verilen zaman serisi ARIMA ile modellenmektedir. Elde edilen kestirim değerleri, $\hat{L}_t$, çarpımın doğrusal kısmını oluşturmaktadır. Bunun üzerine gerçek değerler elde edilen kestirim değerlerine bölünerek serinin doğrusal olmayan bileşeni elde edilir.

$$n_t = \frac{y_t}{\hat{L}_t} \quad (2.38)$$

İkinci aşamada, elde edilen n_t serisi yapay sinir ağı ile modellenerek doğrusal olmayan kestirimler ($\hat{N}_t$) hesaplanır. Hibrit modelin kestirimleri doğrusal ve doğrusal olmayan kestirimlerin çarpımıdır.

$$\hat{y}_t = \hat{L}_t \hat{N}_t \quad (2.39)$$

Wang vd. (2013), çalışmasında güneş lekesi veri seti, Kanada vaşak veri seti ve IBM şirketinin hisse fiyatı verileri olmak üzere üç ayrı zaman serisi üzerinde uygulama yapmaktadır. Çalışma sonucunda çarpımsal hibrit modelin ARIMA, YSA ve toplamsal hibrit modele göre büyük oranda tahmin kesinliğini artırdığı gösterilmektedir.

2.3.4. Hareketli Ortalama Filtre Tabanlı Hibrit ARIMA – YSA Modeli

2014'te Babu ve Reddy tarafından ortaya atılmıştır. Model bir bileşenlere ayırma aşaması ve ardından bu bileşenlere ARIMA ve YSA modellerinin uygulanması aşamalarından oluşur. Model, Zhang (2003)'in modeli gibi zaman serisinin doğrusal ve doğrusal olmayan bileşenlerden oluştuğunu varsayar. Ayrıca doğrusal bileşenin düşük volatiliteli ve doğrusal olmayan bileşenin yüksek volatiliteli olduğunu varsaymaktadır.

$$y_t = l_t + h_t \quad (2.40)$$

Burada l_t düşük volatiliteli bileşeni ve h_t yüksek volatiliteli bileşeni ifade eder. Model dört aşamada tamamlanmaktadır.

- İlk aşamada zaman serisi bir hareketli ortalama filtresinden geçirilerek yüksek ve düşük volatiliteli bileşenleri tespit edilmektedir. Kullanılan filtre aşağıdaki eşitlikteki gibidir:

$$y_{tr} = \frac{1}{m} \sum_{i=t-m+1}^t y_i \quad (2.41)$$

Burada y_{tr} düşük volatiliteli bileşeni ifade etmektedir ve yüksek volatiliteli bileşen, zaman serisinden düşük volatiliteli kısım çıkarılarak bulunabilir.

$$y_{res} = y_t - y_{tr} \quad (2.42)$$

- İkinci aşamada, doğrusal olduğu varsayılan düşük volatiliteli bileşen l_t , ARIMA ile modellenerek l_t kestirim değerleri elde edilir. Bu aşamanın Zhang (2003)'in modelinden en önemli farkı ARIMA modelinin tüm seriye ($y_{t-1}, y_{t-2}, \dots, y_{t-p}$) değil, filtre ile ayrılmış doğrusal bileşene ($l_{t-1}, l_{t-2}, \dots, l_{t-p}$) uygulanmasıdır.

- Üçüncü aşamada daha önce tespit edilmiş olan yüksek volatiliteli bileşen YSA ile modellenmektedir.

$$\hat{h}_t = f(h_{t-1}, h_{t-2}, \dots, h_{t-N}) + \varepsilon_t \quad (2.43)$$

Burada $\hat{h}_t$ doğrusal olmayan bileşenin kestirim değerleri ve N yapay sinir ağı için tercih edilen girdi sayısıdır.

- Son aşamada hibrit modelin kestirim değeri doğrusal ve doğrusal olmayan kestirim değerlerinin toplamı olarak tespit edilir.

$$\hat{y}_t = l_t + \hat{h}_t \quad (2.44)$$

Çalışmada (Babu ve Reddy, 2014) model, güneş lekesi verileri, elektrik fiyat verileri ve hisse senedi fiyat verileri olmak üzere üç ayrı zaman serisi üzerinde uygulanmaktadır. Modelin ARIMA ve YSA modellerine göre daha iyi sonuçlar verdiği ortaya konulmaktadır.



ÜÇÜNCÜ BÖLÜM

OPTİMİZE ARIMA – YSA HİBRİT MODELİ

ARIMA – YSA Hibrit Modelleri, ARIMA ve YSA modellerinin birbirinden farklı ancak birbirlerini tamamlayan özelliklerini bir arada kullanabilmek için geliştirilmiştir. İki modelin farklı özellikleriyle birlikte bir arada kullanılmalarının en önemli sebebi genellikle üzerinde çalışılan zaman serisini iki modelden birinin tek başına tam olarak açıklayamamasıdır. Günlük hayatta karşılaşılan zaman serileri genellikle birden fazla özelliği bir arada bünyesinde bulundurabilmektedir. Burada serinin en çok önem verilen özelliği genellikle serinin doğrusallığıdır. Genellikle gerçek hayatta karşılaşılan zaman serileri hem doğrusal hem de doğrusal olmayan özellikleri bir arada bulundurmaktadır. Bu sebeple tek başına doğrusal ya da doğrusal olmayan bir model bu serilerde yetersiz kalabilmektedir.

3.1. Hibrit ARIMA – YSA Modellerinin Özellikleri

İlk ARIMA – YSA Hibrit Modelini ortaya atan Zhang (2003), zaman serisini doğrusal ve doğrusal olmayan iki serinin toplamı olarak kabul etmektedir ($y_t = L_t + N_t$). Diğer taraftan Wang vd. (2013) zaman serisini doğrusal ve doğrusal olmayan iki serinin çarpımı olarak ifade eder ($y_t = L_t N_t$). Zhang (2003) doğrusal ve doğrusal olmayan kısımları ayırabilmek için öncelikle tüm seriyi ARIMA ile modeller. ARIMA ile modellenerek açıklanabilen kısmı serinin doğrusal kısmıdır. Seriden bu bileşen çıkarılarak bulunan kısım ise doğrusal olmayan kısımdır. Wang vd. (2013) de benzer şekilde önce tüm seriyi ARIMA ile modelleyerek, model ile açıklanabilen kısmı serinin doğrusal kısmı olarak kabul eder. Serinin tamamı, bu modellenen seriye bölünerek doğrusal olmayan kısım bulunur. Seriyi doğrusal ve doğrusal olmayan iki serinin toplamı olarak kabul eden Babu ve Reddy (2014), doğrusal ve doğrusal olmayan kısımları ayırabilmek için bir hareketli ortalama filtresi kullanır. Buna göre yüksek volatiliteli kısım doğrusal olmayan, düşük volatiliteli kısım ise doğrusal kısımdır. Bundan sonra, doğrusal olarak bulunan seri ARIMA ile ve doğrusal olmayan seri Yapay Sinir Ağları ile modellenir.

ARIMA – YSA hibrit modelleri genellikle zaman serisinin doğrusal ve doğrusal olmayan özelliklerine göre şekillenmektedir. Seri doğrusal ve doğrusal olmayan iki kısım olarak düşünülmekte, doğrusal olduğu varsayılan kısım ARIMA ile ve doğrusal olmayan kısım Yapay Sinir Ağları ile modellenmektedir. Hibrit modelleri birbirinden ayıran en önemli özellik serinin doğrusal ve doğrusal olmayan kısımlarının tespitidir.

Zaman serisini doğrusal ve doğrusal olmayan iki serinin toplamı olarak ifade eden iki modelden Zhang (2003)'in modeli öncelikle seriyi ARIMA ile modellemekte, modellenen

kısmı serinin doğrusal kısmı olarak kabul etmekte ve modellenemeyen kısım olan hata serisinde YSA ile doğrusal olmayan bir model aramaktadır. Ancak seri ARIMA ile modellendiğinde elde edilen artıklar serisi, daha önce bahsedilen beyaz gürültü serisi özellikleri taşımaktadır. Dolayısıyla ARIMA ile yapılan modellemeden kalan artık serisi değerlerinin, birbirinden bağımsız rassal değerler olduğu varsayılmaktadır. Artık serisi her ne kadar içinde ARIMA ile modellenemeyen, doğrusal olmayan ilişkiler barındırabilirse de, beyaz gürültü özelliği taşıdığından modellenmesi oldukça zor bir seridir.

Zaman serilerini doğrusal ve doğrusal olmayan kısımlar ile toplamsal olarak ifade eden bir diğer model Babu ve Reddy (2014) tarafından ortaya atılan modeldir. Model eldeki zaman serisine bir hareketli ortalama filtresi uygulamaktadır. Hareketli ortalama filtresi, belli bir nokta için belirlenen bir sayı miktarınca bu noktanın gerisindeki ve/veya ilerisindeki noktalara ait değerlerin ortalamasını alıp yeni değeri belirlemektedir. Bu filtre, zaman serilerinin düzgünleştirilmesi için kullanılabilen bir filtredir. Hareketli ortalama filtresi sonucu elde edilen zaman serisi içerisinde ARIMA ile doğrusal bağlantı aranırken, bu filtreden kalan artık serisi içerisinde YSA yöntemi ile doğrusal olmayan ilişkiler aranmaktadır. Son aşamada her iki modelin, model ve tahmin değerlerinin toplamı hibrit yöntemin model ve tahmin değerleri olmaktadır ($\hat{y}_t = \hat{l}_t + \hat{h}_t$). Hareketli ortalama filtresi sonucu elde edilen serinin tam olarak doğrusal bir seri olduğu varsayılamayacağı gibi, elde edilen artık serinin de tam olarak doğrusal olmayan bir seri olduğu düşünülememektedir.

Bu çalışmada ortaya konulan Optimize ARIMA – YSA Hibrit Modeli, bir zaman serisi doğrusal ve doğrusal olmayan iki serinin toplamı olarak varsayıldığında, serinin doğrusal ve doğrusal olmayan kısımlara en iyi nasıl ayrılabilceği düşüncesinden ortaya çıkmaktadır. Zaman serisi doğrusal ve doğrusal olmayan iki kısım olarak ifade edildiğinde, bu iki serinin ARIMA ve YSA ile modellenmesi sonucu elde edilen model değerleri toplamı olabilecek en az hatayı vermeli, böylece gerçek seriyi en iyi şekilde açıklamalıdır.

3.2. Bir Zaman Serisinin Sabit Bir Sayıyla Çarpımı

Zaman serilerinde en çok faydalanılan özelliklerden birisi zaman serilerinin aritmetik işlemlere uygunluğudur. Zaman serileri birden fazla zaman serisinin toplamı veya farkı, ya da birden fazla serinin çarpımı veya bölümü şeklinde ifade edilebilir. Benzer şekilde, bir zaman serisi bir sabitle çarpılarak ya da bölünerek te analiz edilebilir. Zaman serileri modelleme aşamasından önce veri ön işleme aşamasında: ölçekleme, logaritmik dönüşüm, karekök dönüşümü gibi işlemlerden geçirilerek modellenebilmektedir (Shumway ve Stoffer, 2011).

Modelleme sonucu elde edilen değerler ön işleme aşamasında uygulanan dönüşüm işlemlerinin tersi süreçten geçirilerek model değerleri bulunmaktadır. Özellikle en çok kullanılan yöntemlerden olan min – max normalizasyonu; YSA modellerinde gerekli olmakla birlikte, ARIMA modellerinde geniş aralıktaki zaman serilerinin işlem kolaylığı açısından uygulanabilmektedir. Serideki verileri bulundukları değer aralığından, belli bir değer aralığına ölçeklemek olan min – max normalizasyonu genellikle $[0,1]$ veya $[-1,1]$ aralığı için yapılmaktadır. Min – max normalizasyonunun en büyük avantajı veri setindeki bütün ilişkileri aynı şekilde korumasıdır (Priddy ve Keller, 2005: 16). Min – max normalizasyonu incelendiğinde bir zaman serisinin belli bir aralığa ölçeklendirildiğinde aldığı değerler ile, bu serinin 0'dan farklı sabit bir a sayısı ile çarpımı aynı aralığa ölçeklendirildiğinde aldığı değerlerin aynı olduğu görülebilir. YSA modellerinde kullanılan lojistik, hiperbolik tanjant gibi sigmoid aktivasyon fonksiyonları sebebiyle zaman serisinin $[-1,1]$ veya $[0,1]$ aralığına ölçeklendirilmesi gerekmektedir. ARIMA modellerinde ise ölçeklendirme isteğe bağlı olarak ve gerek duyulduğunda yapılmaktadır.

ARIMA modellerinde en çok kullanılan ölçeklendirme şekli, veri sayısının çok fazla basamak içerdiği durumlarda, işlem kolaylığı açısından, zaman serisinin 10'un katlarına bölünmesidir. Modellemeyi sonradan elde edilen değerler bölünen sayı ile çarpılarak gerçek değerlere ulaşılır. Zaman serisi analizinde kullanılan modeller serinin t zamanındaki değerini, gecikmeli değerlerle ifade eder. YSA modellerinde gecikmeli gerçek değerler kullanılırken, ARIMA modellerinde gecikmeli gerçek değerler, gecikmeli hata değerleri ve ardışık fark değerleri kullanılmaktadır. Bir zaman serisi 0'dan farklı sabit bir a sayısı ile çarpıldığında, gecikmeli gerçek değerler ile birlikte gecikmeli hata değerleri ve ardışık fark değerleri de aynı oranda büyümekte veya küçülmektedir. ARIMA modeli kurulurken bilgi kriterleri sonucu bulunan p , d ve q model değerleri, en uygun model ve modelde bulunan gecikmelerin katsayılar değişmemektedir (Deng vd., 1997: 249).

Bu sebeple, sabit sayı a ile çarpım model ilişkilerini değiştirmemekte ancak modeli a sayısı nispetinde genişletmekte veya daraltmaktadır. Gerek ARIMA, ve gerek YSA modelleri için; bir serinin modellenmesi, serinin 0'dan farklı bir sabitle çarpımı sonucu elde edilen serinin modellenerek bulunan sonuçların aynı sabite bölünmesi yoluyla da yapılabilir.

y_t bir zaman serisi, $a \neq 0$ bir sabit katsayı ve $z_t = ay_t$ bir başka zaman serisi olmak üzere ARIMA ve YSA modelleri için aşağıdaki eşitlikler yazılabilir:

$$ARIMA(z_t) = ARIMA(ay_t) = a ARIMA(y_t) \quad (3.1)$$

$$YSA(z_t) = YSA(ay_t) = a YSA(y_t) \quad (3.2)$$

3.3. Zaman Serisinin Bileşenlere Ayrılması ve En Küçük Kareler Optimizasyonu

Bir y_t zaman serisinin doğrusal bir L_t serisi ile doğrusal olmayan bir N_t serisinin toplamı olduğunu varsayalım. Ayrıca $0 \leq \alpha \leq 1$ olmak üzere doğrusal seri L_t , $L_t = \alpha y_t$ olarak ifade edilsin. Bu durumda $\beta = 1 - \alpha$ ve $0 \leq \beta \leq 1$ olmak üzere doğrusal olmayan seri $N_t = \beta y_t$ olarak ifade edilebilir.

L_t serisinin doğrusal bir seri olduğu kabul edildiğinden ARIMA ile modellenmelidir. Bu durumda seri kendi başına modellenebileceği gibi, y_t serisinin modellenmesi ve model değerlerin α sabitiyle çarpılmasıyla da modellenebilir.

$$ARIMA(L_t) = \alpha ARIMA(y_t) \quad (3.3)$$

Benzer bir ilişki doğrusal olmayan N_t serisi için de yazılabilir. N_t serisinin doğrusal olmayan bir seri olduğu kabul edildiğinden seri YSA ile modellenmelidir. N_t serisinin modellenmesi, y_t serisinin YSA ile modellenerek β katsayısıyla çarpılması yoluyla da yapılabilir. Buna göre:

$$YSA(N_t) = \beta YSA(y_t) \quad (3.4)$$

eşitliği yazılabilir. y_t serisi doğrusal ve doğrusal olmayan serilerin toplamıydı. Bu durumda serinin modellenmesi doğrusal seri L_t ve doğrusal olmayan seri N_t 'nin ayrı ayrı modellenerek toplanmasıyla elde edilebilir.

$$MODEL(y_t) = ARIMA(L_t) + YSA(N_t) \quad (3.5)$$

$$MODEL(y_t) = \alpha ARIMA(y_t) + \beta YSA(y_t) \quad (3.6)$$

y_t bir zaman serisi olmak üzere; y_t^{ARIMA} serinin ARIMA ile modellenmesi sonucu elde edilen model değerleri, ε_t^{ARIMA} ARIMA modelinin hata serisi, y_t^{YSA} YSA ile ulaşılan model değerleri ve ε_t^{YSA} YSA ile modelleme sonucu bulunan hata değerleri ise, eşitlik aşağıdaki gibi yazılabilir:

$$y_t = \alpha (y_t^{ARIMA} + \varepsilon_t^{ARIMA}) + \beta (y_t^{YSA} + \varepsilon_t^{YSA}) \quad (3.7)$$

Burada hata terimleri tek bir hata serisi olarak toplanırsa ($e_t = \varepsilon_t^{ARIMA} + \varepsilon_t^{YSA}$) eşitlik aşağıdaki gibi olur:

$$y_t = \alpha y_t^{ARIMA} + \beta y_t^{YSA} + e_t \quad (3.8)$$

Eşitlikte $0 \leq \alpha \leq 1$, $0 \leq \beta \leq 1$ ve $\alpha + \beta = 1$ 'dir. Eşitlikte yer alan modelde y_t serisinin gerçek değerleri bilindiğinden aynı serinin ARIMA ve YSA ile modelleme sonucu model değerleri de bulunabilir. Modelin bilinmeyenleri doğrusal serinin katsayısı α ve doğrusal olmayan serinin katsayısı β 'dir. Modelin y_t zaman serisi değerlerini en iyi açıklaması için hatanın en aza indirgenmesi gerekmektedir. Bu şartlar altında Eşitlik 3.8 kısıtlarla birlikte bir optimizasyon problemi haline gelmektedir.

Hata serisi e_t 'yi en aza indirmek ve gerçek değerleri en iyi açıklayan katsayıları bulmak için literatürde sıklıkla faydalanan en küçük kareler optimizasyonu kullanılabilir. En küçük kareler yöntemi, gözlem verileriyle beklenen veri değerleri arasındaki tutarsızlıkların karelerini en küçükleyerek parametrelerin tahmin edilmesini temel almaktadır.

Bu durumda optimizasyonun amacı hata kareler toplamının ($\sum e_t^2$) en küçüklenmesidir. Model kısıtları ise $0 \leq \alpha \leq 1$, $0 \leq \beta \leq 1$ ve $\alpha + \beta = 1$ olarak yazılabilir. Model çoklu doğrusal regresyon modeline benzemekle birlikte, katsayılarla ilgili kısıtlar modeli regresyondan ayırmaktadır.

3.4. Doğrusal Hataların Aktarılarak Yeniden Modelleme Yapılması

Optimizasyon problemi çözümlendiğinde zaman serisini en iyi açıklayan doğrusal ve doğrusal olmayan seri katsayıları, α ve β , bulunmaktadır. Zaman serisinin ARIMA ile modellenmesi ile elde edilen model ve hata değerlerinin α ile çarpımı ve aynı zaman serisinin YSA ile modellenmesi sonucu bulunan model ve hata değerlerinin β ile çarpımı toplanarak yeni model elde edilebilir.

Eşitlik 3.7'de model aşağıdaki gibi açıklanmıştır:

$$y_t = \alpha (y_t'^{ARIMA} + \varepsilon_t^{ARIMA}) + \beta (y_t'^{YSA} + \varepsilon_t^{YSA}) \quad (3.7)$$

Modelde ARIMA modeli ile ulaşılan hata serisinin α ile çarpımı olan $\alpha \varepsilon_t^{ARIMA}$ ve YSA modeli sonucu ortaya çıkan $\beta \varepsilon_t^{YSA}$ olmak üzere iki ayrı hata serisi bulunmaktadır. Bu noktada Zhang (2003)'in çalışmasında başvurduğu yöntem akla gelmektedir. Zhang (2003), hibrit modelinde ARIMA modelinden kalan artık seride YSA ile doğrusal olmayan ilişkiler aramaktadır. Modelde bulunan ARIMA hata değerlerinde doğrusal olmayan bağlantılar olabilir. Ancak daha önce bahsedildiği gibi ARIMA model hatası büyük oranda beyaz gürültü özelliği taşımaktadır ve modellenmesi oldukça güçtür.

Diğer bir yaklaşım, optimizasyon sonucu modelin YSA ile modellenmiş doğrusal olmayan ilişkilerin arandığı kısmına ε_t^{ARIMA} hata serisi eklenerek YSA ile yeniden modellenmesi olabilir. Bu durumda zaman serisi, hata terimi olmayan ve ARIMA ile açıklanabilen doğrusal bir kısım ile doğrusal olmayan ilişkilerin arandığı, YSA modellenen ikinci bir kısımdan oluşacaktır. YSA ile yapılan yeni modelleme sonucunda modeldeki hata terimi ikiden bire indirilmekte ve optimizasyon ile azaltılan toplam hatanın yeni model ile daha da azaltılması beklenmektedir.

Eşitlik 3.9'da ifade edilen model aşağıdaki gibi tekrar yazılabilir:

$$y_t = \alpha y_t'^{ARIMA} + \alpha \varepsilon_t^{ARIMA} + \beta y_t'^{YSA} + \beta \varepsilon_t^{YSA} \quad (3.9)$$

Buna göre eşitlikte sağ taraftaki son üç terim toplanarak yeniden YSA ile modellenecektir. Yeniden modellenecek olan seri z_t olarak gösterilirse,

$$y_t = \alpha y_t'^{ARIMA} + z_t \quad (3.10)$$

$$z_t = a \varepsilon_t^{ARIMA} + \beta y_t'^{YSA} + \beta \varepsilon_t^{YSA} \quad (3.11)$$

z_t serisi, $z_t = y_t - \alpha y_t'^{ARIMA}$ şeklinde gösterilebileceği gibi farklı şekillerde de gösterilebilir. $y_t'^{YSA} + \varepsilon_t^{YSA} = y_t$ olduğu düşünülürse, Eşitlik 3.11,

$$z_t = \alpha \varepsilon_t^{ARIMA} + \beta y_t \quad (3.12)$$

şeklinde ifade edilebilir. ARIMA hata serisi β sabitiyle çarpılır ve bölünürse,

$$z_t = a \frac{\beta}{\beta} \varepsilon_t^{ARIMA} + \beta y_t \quad (3.13)$$

elde edilir. Eşitlikte sağ taraf β parantezine alınırsa,

$$z_t = \beta \left(\frac{a}{\beta} \varepsilon_t^{ARIMA} + y_t \right) \quad (3.14)$$

olur. Eşitlikte parantez içinde yer alan bölüm yeni bir zaman serisi n_t olarak ifade edilebilir. Bu durumda

$$z_t = \beta n_t \quad (3.15)$$

$$n_t = \frac{a}{\beta} \varepsilon_t^{ARIMA} + y_t \quad (3.16)$$

olarak yazılabilir. Eşitlik 3.15, Eşitlik 3.10'da yerine konulursa yeni eşitlik,

$$y_t = \alpha y_t'^{ARIMA} + \beta n_t \quad (3.17)$$

şeklinde gösterilebilir. Eşitliğin sağ tarafında βn_t olarak ifade edilen kısım YSA modeli ile doğrusal olmayan bağlantıların aranacağı kısımdır. Bu kısmın YSA ile modellenmesi n_t serisinin YSA ile modellenerek, model ve hata değerlerinin β ile çarpılması işlemleriyle gerçekleştirilebilir.

$$YSA(\beta n_t) = \beta YSA(n_t) \quad (3.18)$$

$n_t = \frac{a}{\beta} \varepsilon_t^{ARIMA} + y_t$ olmak üzere, zaman serisi n_t 'nin YSA ile modellenmesi sonucu elde edilen model değerleri serisi $n_t'^{YSA}$ ve modelleme ile bulunan hata serisi ε_t^{YSA} ise, modelin son hali aşağıdaki gibidir:

$$y_t = \alpha y_t'^{ARIMA} + \beta (n_t'^{YSA} + \varepsilon_t^{YSA}) \quad (3.19)$$

$$y_t = \alpha y_t'^{ARIMA} + \beta n_t'^{YSA} + \beta \varepsilon_t^{YSA} \quad (3.20)$$

Zaman serisi modellerinin en önemli amacı geçmiş değerlerin modellenerek gelecek değerlerle ilgili tahmin yürütülmesidir. Gelecekteki bir $t = k$ zamanı için modelin tahmini y_k' aşağıdaki gibi gösterilebilir:

$$y_k' = \alpha y_k'^{ARIMA} + \beta n_k'^{YSA} \quad (3.21)$$

y_t serisinin ARIMA gelecek tahmin değeri $y_k'^{ARIMA}$, sabit katsayı α ile çarpılır, sonradan oluşturulan n_t zaman serisinin gelecek tahmini $n_k'^{YSA}$ sabit katsayı β ile çarpılır ve bu iki çarpım sonucu toplanarak modelin gelecek tahmin değeri bulunabilir.

3.5. Optimize ARIMA – YSA Hibrit Modeli

Optimize ARIMA – YSA Hibrit Modeli maddeler halinde aşağıdaki gibi ifade edilebilir:

- Varsayım 1: Bir zaman serisi y_t , doğrusal ve doğrusal olmayan iki serinin toplamı olarak ifade edilebilir. L_t doğrusal seri ve N_t doğrusal olmayan seri olmak üzere y_t zaman serisi aşağıdaki gibidir:

$$y_t = L_t + N_t \quad (3.22)$$

- Varsayım 2: $0 \leq \alpha \leq 1$, $0 \leq \beta \leq 1$, $\alpha + \beta = 1$ ve α, β sabit katsayılar olmak üzere, y_t serisini oluşturan doğrusal ve doğrusal olmayan seriler eşitliklerdeki gibi ifade edilir:

$$L_t = \alpha y_t \quad (3.23)$$

$$N_t = \beta y_t \quad (3.24)$$

Burada α katsayısı doğrusal kısmı meydana getiren katsayı olduğu için doğrusal katsayı, β katsayısı ise doğrusal olmayan kısmı belirten katsayı olduğundan doğrusal olmayan katsayı olarak nitelendirilir. Bu durumda zaman serisi doğrusal ve doğrusal olmayan iki serinin toplamı olarak aşağıdaki gibi gösterilebilir:

$$y_t = \alpha y_t + \beta y_t \quad (3.25)$$

- Zaman serisi y_t 'nin modellenmesi, doğrusal kısım αy_t 'nin ARIMA ile modellenmesi ve doğrusal olmayan kısım βy_t 'nin YSA ile modellenmesi ile yapılır. α ve β sabit katsayılar olduğundan doğrusal kısmın modellenmesi tüm serinin ARIMA ile modellenerek doğrusal katsayı ile çarpılması ve doğrusal olmayan kısmın modellenmesi de serinin YSA ile modellenerek doğrusal olmayan katsayı ile çarpılmasıyla bulunur.

$$ARIMA(\alpha y_t) = \alpha ARIMA(y_t) \quad (3.26)$$

$$YSA(\beta y_t) = \beta YSA(y_t) \quad (3.27)$$

y_t serisinin ARIMA ile modellenmesi ile bulunan model değerleri $y_t'^{ARIMA}$ ve hata değerleri ε_t^{ARIMA} , serinin YSA ile modellenmesi ile elde edilen model değerleri $y_t'^{YSA}$ ve aynı modelin hata değerleri ε_t^{YSA} olmak üzere eşitlik, Eşitlik 3.7'deki gibi gösterilebilir:

$$y_t = \alpha (y_t'^{ARIMA} + \varepsilon_t^{ARIMA}) + \beta (y_t'^{YSA} + \varepsilon_t^{YSA}) \quad (3.7)$$

Serinin ARIMA ve YSA ile modellemeleri yapılarak eşitlikte yerlerine konduğunda bilinmeyen olarak α ve β sabitleri kalmaktadır. Burada modelin, y_t zaman serisini en iyi açıklayan model haline getirilmesi için hatanın en küçüklenmesi gerekmektedir.

• Eşitlik 3.9’da hatayı en aza indiren α ve β katsayılarının bulunabilmesi için en küçük kareler optimizasyonu (*least squares optimization*) yöntemine başvurularak hata kareler en küçüklenir. Eşitlik 3.9’da hata terimleri toplanarak yalnız bırakılırsa, $e_t = \alpha \varepsilon_t^{ARIMA} + \beta \varepsilon_t^{YSA}$ olmak üzere,

$$y_t = \alpha y_t'^{ARIMA} + \alpha \varepsilon_t^{ARIMA} + \beta y_t'^{YSA} + \beta \varepsilon_t^{YSA} \quad (3.9)$$

$$y_t = \alpha y_t'^{ARIMA} + \beta y_t'^{YSA} + e_t \quad (3.28)$$

$$e_t = y_t - \alpha y_t'^{ARIMA} - \beta y_t'^{YSA} \quad (3.29)$$

olur. Optimizasyonun amaç fonksiyonu hata kare toplamının en küçüklenmesidir. Kısıtlar ise α ve β katsayılarının daha önce belirtilen özellikleridir. Optimizasyon problemi aşağıdaki gibi yazılabilir:

$$\text{Min } \sum e_t^2 = \sum (y_t - \alpha y_t'^{ARIMA} - \beta y_t'^{YSA})^2 \quad (3.30)$$

k. s.

$$0 \leq \alpha$$

$$0 \leq \beta$$

$$\alpha + \beta = 1$$

Optimizasyon probleminde $\alpha \leq 1$ ve $\beta \leq 1$ şartlarını belirtmeye gerek yoktur. Üçüncü kısıtla birlikte bu şartlar sağlanmaktadır. Optimizasyon problemi çözümlenerek α ve β için en iyi (*optimum*) değerler bulunur.

• Modelde en iyi α ve β değerleri kullanılarak model hatası en aza indirilmektedir. Ancak Zhang (2003)’in modelinde kullandığı yöntem düşünülürse, serinin doğrusal olarak kabul edilen kısmı $\alpha y_t'$ ’nin ARIMA ile modellenmesi sonucu kalan artık seri $\alpha \varepsilon_t^{ARIMA}$, da doğrusal olmayan ilişkiler bulunabilir. Tek başına beyaz gürültü serisi özelliği gösteren bu kısım, serinin doğrusal olmayan olarak kabul edilen kısmıyla birleştirilirse daha anlamlı doğrusal olmayan bağlantılar ortaya çıkabilir. y_t serisinin hatasız doğrusal kısmı $\alpha y_t'^{ARIMA}$ ayrılarak kalan kısım doğrusal olmayan bir modelleme için yeniden YSA sürecine girer. Serinin yeni doğrusal olmayan kısmı aşağıdaki gibi gösterilebilir:

$$\begin{aligned} \alpha \varepsilon_t^{ARIMA} + \beta y_t'^{YSA} + \beta \varepsilon_t^{YSA} &= \alpha \varepsilon_t^{ARIMA} + \beta y_t = \alpha \frac{\beta}{\beta} \varepsilon_t^{ARIMA} + \beta y_t \\ &= \beta \left(\frac{\alpha}{\beta} \varepsilon_t^{ARIMA} + y_t \right) \end{aligned} \quad (3.31)$$

Eşitlikte parantez içerisinde yer alan kısım bir n_t zaman serisi olarak ifade edilirse,

$$\beta \left(\frac{\alpha}{\beta} \varepsilon_t^{ARIMA} + y_t \right) = \beta n_t \quad (3.32)$$

$$n_t = \frac{\alpha}{\beta} \varepsilon_t^{ARIMA} + y_t \quad (3.16)$$

n_t serisi ARIMA hata serisi ϵ_t^{ARIMA} 'nın, optimizasyon sonucu bulunan α ve β katsayılarının bölümü $\frac{\alpha}{\beta}$ ile çarpılması ve orijinal seri y_t 'ye eklenmesiyle bulunur. n_t serisi bundan sonra anlatım kolaylığı açısından yapay (*artificial*) seri olarak adlandırılacaktır. Elde edilen yapay serinin doğrusal olmayan katsayı β ile çarpımı, y_t serisinin doğrusal olmayan ilişkiler içeren kısmını ifade etmektedir. Doğrusal olmayan kısmın tahmini, n_t serisinin YSA ile modellenerek çıkan sonuçların β katsayısıyla çarpımı sonucu elde edilir. n_t^{YSA} yapay serinin YSA ile modellenmesi sonucu ulaşılan model değerleri ve ϵ_t^{YSA} bu modelin hata değerleri olmak üzere, YSA ile yapılan modelleme sonucu Optimize ARIMA – YSA Hibrit Modeli ile modellenen y_t serisi aşağıdaki gibi ifade edilebilir:

$$y_t = \alpha y_t^{ARIMA} + \beta n_t^{YSA} + \beta \epsilon_t^{YSA} \quad (3.20)$$

y_t serisinin ARIMA ile modellenmesi sonucu ulaşılan model değerleri y_t^{ARIMA} doğrusal katsayı α ile çarpılır, yapay n_t serisinin model değerleri doğrusal olmayan katsayı β ile çarpılır ve bu iki çarpım toplanarak Optimize ARIMA – YSA Hibrit Model değerleri elde edilir. n_t serisinin YSA ile modellenmesi sonucu elde edilen hata değerleri ϵ_t^{YSA} , doğrusal olmayan katsayı β ile çarpılarak hibrit modelin hata değerleri bulunur. Optimize ARIMA – YSA Hibrit Modelin model değerleri y_t^{OAYH} ve hata değerleri e_t^{OAYH} ile gösterilirse model aşağıdaki gibi ifade edilebilir,

$$y_t = y_t^{OAYH} + e_t^{OAYH} \quad (3.33)$$

$$y_t^{OAYH} = \alpha y_t^{ARIMA} + \beta n_t^{YSA} \quad (3.34)$$

$$e_t^{OAYH} = \beta \epsilon_t^{YSA} \quad (3.35)$$

- Optimize ARIMA – YSA Hibrit Modelinin geleceğe yönelik tahmin değerleri; y_t serisinin ARIMA ile modellenmesi sonucu elde edilen tahmin değerlerinin doğrusal katsayı α ile çarpılması, n_t serisinin tahminlerinin doğrusal olmayan katsayı β ile çarpılması ve bu iki çarpımın toplanması ile elde edilir. Optimize ARIMA – YSA Hibrit Modelinin gelecek bir $t = k$ zamanı için tahmin değeri aşağıdaki gibi gösterilebilir:

$$y_k^{OAYH} = \alpha y_k^{ARIMA} + \beta n_k^{YSA} \quad (3.36)$$

Optimize ARIMA – YSA Hibrit Modeli diğer hibrit modellerden özellikle iki yönüyle farklılık göstermektedir. İlk olarak model, doğrusal ve doğrusal olmayan serilerin toplamı olarak kabul ettiği zaman serisini doğrusal ve doğrusal olmayan olarak en iyi şekilde ayırmak için en küçük kareler optimizasyonu kullanmakta ve model hatasını düşürmektedir. İkinci olarak, doğrusal kabul edilen kısmın hatalarını doğrusal olmayan olarak kabul edilen kısma aktararak bu bölümü yeniden modellemekte ve model hatasını bir miktar daha düşürmeyi hedeflemektedir. Optimize ARIMA – YSA Modelinin bir diğer özelliği zaman serisi y_t 'nin

YSA ile modelleme sonuçlarının modelde veya gelecek tahmininde doğrudan kullanılmamasıdır. y_t 'nin YSA ile elde edilen model değerleri sadece optimizasyon aşamasında doğrusal ve doğrusal olmayan katsayıların bulunmasında kullanılmaktadır. Hibrit model değerleri ve gelecek tahmin değerleri için yapay seri n_t 'nin YSA ile bulunan model değerleri ve gelecek tahmin değerleri kullanılmaktadır.

Optimize ARIMA – YSA Hibrit Modelinin uygulanması 7 aşamada aşağıdaki gibi ifade edilebilir:

a. ARIMA Modelleme Aşaması: Modellenecek olan zaman serisi y_t ARIMA ile modellenerek model ve hata değerleri y_t^{ARIMA} ve ϵ_t^{ARIMA} bulunur. Ayrıca hibrit modelin tahmin için kullanılacağı, $t = k$ zamanı için ARIMA modelinin tahmin değeri y_k^{ARIMA} bulunur.

b. YSA Modelleme Aşaması: Zaman serisi y_t YSA ile modellenerek model değerleri y_t^{YSA} bulunur. Hata değerleri ϵ_t^{YSA} ileriki aşamalarda veya hibrit modelin hata değerleri bulunurken kullanılmamaktadır. Aynı şekilde k zamanı için hibrit model tahmininde bu aşamadaki YSA model tahmini kullanılmamaktadır.

c. Optimizasyon Aşaması: Bulunan model değerleri y_t^{ARIMA} ve y_t^{YSA} ile modellenen serinin gerçek değerleri y_t kullanılarak en küçük kareler optimizasyonu ile doğrusal katsayı α ve doğrusal olmayan katsayı β için hata kareler toplamını en küçükleyen, optimum değerler bulunur.

d. Doğrusal Hataların Aktarılarak Yapay Serinin Bulunması Aşaması: Optimizasyon sonucu bulunan α ve β katsayıları ile ARIMA model hatası ϵ_t^{ARIMA} ve gerçek seri y_t kullanılarak yapay seri n_t elde edilir. Burada $n_t = \frac{\alpha}{\beta} \epsilon_t^{ARIMA} + y_t$ dir.

e. Yapay Serinin YSA ile Modellenmesi Aşaması: Yapay seri n_t , YSA ile modellenerek model değerleri n_t^{YSA} ve hata değerleri ϵ_t^{YSA} bulunur. Ayrıca hibrit modelin tahmin için kullanılacağı $t = k$ zamanı için tahmin değeri n_k^{YSA} bulunur.

f. Optimize ARIMA – YSA Hibrit Modelinin Oluşturulması: Birinci aşamada elde edilen ARIMA model değerleri y_t^{ARIMA} , optimizasyon sonucu bulunan doğrusal katsayı α ile çarpılır. Beşinci aşamada yapay serinin YSA ile modellenmesi ile bulunan n_t^{YSA} model değerleri en iyi doğrusal olmayan katsayı β ile çarpılır. İki çarpım toplanarak hibrit modelin tahmin değerleri elde edilir. Modelin hata değerleri yapay serinin YSA ile modellenmesinden kalan artık değerler ϵ_t^{YSA} ,nın doğrusal olmayan katsayı ile çarpılmasıyla bulunabilir.

$$y_t = y_t^{OAYH} + e_t^{OAYH} \quad (3.33)$$

$$y_t^{OAYH} = \alpha y_t^{ARIMA} + \beta n_t^{YSA} \quad (3.34)$$

$$e_t^{OAYH} = \beta \epsilon_t^{YSA} \quad (3.35)$$

g. Optimize ARIMA – YSA Modelinin Gelecek Tahmininin Bulunması: Modelin $t = k$ gelecek zaman tahmini y_k^{OAYH} ; birinci aşamada ARIMA ile elde edilen tahmin değeri y_k^{ARIMA} , beşinci aşamada yapay serinin YSA ile modellenmesiyle elde edilen tahmin değeri n_k^{YSA} ile doğrusal ve doğrusal olmayan katsayılar kullanılarak aşağıdaki eşitlik ile bulunur:

$$y_k^{OAYH} = \alpha y_k^{ARIMA} + \beta n_k^{YSA} \quad (3.36)$$

Burada $t = k$ zamanı için tahmin değeri arandığı varsayılmaktadır. Hibrit model bir adım öte (*one step forward*) ve çok adım öte (*multi step forward*) tahminler için kullanılabileceği gibi $t = k_1, k_2, \dots, k_n$ olacak şekilde çoklu tahmin için de kullanılabilir. Eğer çoklu gelecek tahmini aranıyorsa çoklu tahmin için birinci aşamada $y_{k_1}^{ARIMA}, y_{k_2}^{ARIMA}, \dots, y_{k_n}^{ARIMA}$ değerleri ve beşinci aşamada $n_{k_1}^{YSA}, n_{k_2}^{YSA}, \dots, n_{k_n}^{YSA}$ değerleri bulunarak hibrit modelin çoklu tahmin değerleri $y_{k_1}^{OAYH}, y_{k_2}^{OAYH}, \dots, y_{k_n}^{OAYH}$ elde edilebilir.

DÖRDÜNCÜ BÖLÜM

OPTİMİZE ARIMA – YSA HİBRİT MODELİ VE FİNANSAL ZAMAN SERİLERİ İLE ÖRNEK UYGULAMALAR

4.1. Finansal Zaman Serileri ve Finansal Piyasalar

Belirli bir zaman aralığında varlık fiyatlarının zamana göre oluşturduğu veri dizileri finansal zaman serileri olarak adlandırılır (Zhang, 2001: 1). Yıllardır birçok farklı türde finansal zaman serisi kayıt altına alınmakta ve üzerinde çalışılmaktadır. Özellikle son zamanlarda finansal piyasalardaki birçok işlem kaydedilmekte ve ortaya çıkan yüksek miktarda veriye ulaşmak mümkün olmaktadır (Chakraborti vd., 2007: 1).

Finansal zaman serileri doğası gereği gürültülü, durağan olmayan ve belirleyici bir şekilde kaotik olarak tanımlanmaktadır (Tay ve Cao, 2002: 847). Gürültü, finansal zaman serilerinde günlük rastgele değişimler şeklinde kendini gösterirken (Hussain vd., 2008: 1187), durağan olmama durumu serinin dağılımının zamanla değişmesi olarak karşımıza çıkmaktadır (Lu vd., 2009: 115). Ayrıca durağan olmama durumu sadece tek bir serinin ortalama ve varyans açısından değişimi değil aynı zamanda ilişkili olduğu düşünülen diğer serilerle ilişkisinin de zamanla değişimidir (Tay ve Cao, 2002: 847). Etkin piyasa hipotezine göre iyi işleyen ve iyi bilgilendirilen bir piyasada herhangi bir zamandaki fiyat; aynı zaman dilimindeki, haberler, diğer fiyatlar vs. gibi mevcut tüm bilgilerin bir sonucudur (Hussain vd., 2008: 1186; Strozzi ve Zaldivar, 2005: 464). Gelecekteki fiyat yine gelecekte yer alacak bilinmeyen, rassal bilgilerin sonucu olacağından etkin piyasa hipotezine göre geçmiş değerleri kullanmak gelecek değerleri tahmin etmede işe yaramaz (Strozzi ve Zaldivar, 2005: 464). Buna karşın özellikle son yıllarda yapılan birçok araştırma gerçekte piyasaların tam olarak etkin olmadığını (Hussain vd., 2008: 1187) ve belli bir seviyede tahmin edilebilir olduğunu (Yao ve Herbert, 2009: 1000) ortaya koymaktadır. Finansal zaman serilerinin bir taraftan başta ekonomik olmak üzere sosyal, politik ve daha bir çok açıdan önemli oluşu; diğer taraftan modelleme ve tahmininin zorluğu, finansal zaman serileriyle ilgili çalışmalarda geniş bir literatür ve çok sayıda model ortaya çıkmasına neden olmuştur.

4.1.1. Finansal Zaman Serileri İçin Kullanılan Modeller

Finansal zaman serileri için sıklıkla kullanılan modellerden biri değişen varyans tipi modellerdir. Engle (1982) tarafından ortaya atılan Otoregresif Koşullu Değişen Varyans (*ARCH*) ve daha sonra bu modelin geliştirilmesiyle ortaya çıkan (Bollerslev, 1986) Genelleştirilmiş Otoregresif Koşullu Değişen Varyans (*GARCH*) finansal zaman serileri için ve

özellikle volatilité tahmininde sıklıkla kullanılmaktadır. Ayrıca GARCH modelinin geliştirilmesiyle Üssel GARCH (Nelson, 1991), GJR GARCH (Glosten vd. 1993) gibi modeller de literatürde yer almaktadır.

Finansal zaman serilerinde, varlık fiyat serilerinin genellikle durağan olmadığı ancak varlık getiri serilerinin genelde durağan olduğu görülmektedir. Ancak getiri serileri heteroskedastik, yani değişen varyans özelliği taşımaktadır. ARCH/GARCH tipi modeller değişen varyansı bir bağımsız değişkenle tanımlayarak bu soruna çözüm aramaktadır (Glosten vd. 1993). Bu sebeple, genellikle getirilerin standart sapması veya varyansı olarak tanımlanan (Poon ve Granger, 2003: 480) volatilité serilerine sıklıkla GARCH tipi modeller uygulanmaktadır. Ham petrol (Wei vd., 2010), enerji (Wang ve Wu, 2012), borsa endeksleri (Sharma ve Vipul, 2016; Awartani ve Corradi, 2005; Fiszeder ve Perczak, 2016), spot altın (Bentes, 2015) gibi birçok finansal serinin volatilité tahmininde GARCH tipi modeller kullanıldığı görülmektedir.

Literatürde özellikle son yıllarda daha çok görülmeye başlanan yöntemlerden biri bulanık mantıktır. İlk defa Song ve Chissom (1993) tarafından ortaya atılan bulanık zaman serileri, borsa endeksleri (Cheng vd. 2008) ve döviz kurları (Leu vd., 2009; Korol, 2014) gibi finansal zaman serilerinin modellenmesinde kullanılabilmektedir. Makina Öğrenimi alanında Destek Vektör Makineleri (Vapnik, 1995) ve onun türevi olan Destek Vektör Regresyonu (Vapnik vd., 1996) son yıllarda finansal kestirim konusunda birçok araştırmada kullanılmaktadır (Rosowsky ve Smith, 2013). Devlet tahvili (Tay ve Cao, 2001), borsa endeksi (Kim, 2003; Huang vd. 2005), vadeli kur (Das ve Padhy, 2012), ham petrol (Ahmed ve Shabri, 2014) gibi finansal zaman serileri bunlara örnek olarak verilebilir. Bunlardan başka, yine finansal zaman serilerinin modellenmesi ve tahmini konusunda Gizli Markov Modeli (Dias vd. 2015), Rassal Yürüyüş (Moosa ve Burns, 2014), Genetik Algoritma (Majhi vd., 2009) gibi birçok modele literatürde rastlamak mümkündür.

Genelde zaman serileri için sıklıkla kullanılan Otoregresif Entegre Hareketli Ortalamalar (*ARIMA*) modeli finansal zaman serilerinin tahmini için de kullanılan başlıca yöntemlerdendir. İlk defa Box ve Jenkins (1976) tarafından ortaya atılan ARIMA modeli hisse senedi piyasası (Ariyo vd., 2014; Green, 2011; Konarasinghe vd., 2015; Alwadi, 2015; Paul vd., 2013), altın fiyatları (Khan, 2013; Guha ve Bandyopadhyay, 2016; Khalid vd. 2014; Abdullah, 2012), döviz piyasası (Babu ve Reddy, 2015; Nwankwo, 2014), ham petrol fiyatları (Akpanta ve Okorie, 2014), kömür fiyatları (Dong vd. 2010), doğal gaz fiyatları (Mishra, 2012), buğday fiyatları (Moghaddasi ve Badr, 2008) gibi bir çok finansal zaman serisinin modellenmesinde ve tahmininde kullanılmaktadır.

Özellikle doğrusal olmayan zaman serileri tahmini için etkili modellerden biri Yapay Sinir Ağlarıdır (Babu ve Reddy, 2014: 27). Son çalışmalar Yapay Sinir Ağları'nın sınıflandırma ve kestirim gücünü ortaya koymakta ve tüm sürekli fonksiyonları tahmin edebildiğini göstermektedir. Yapay Sinir Ağları finansal veri serilerinin kestirimi için başarılı bir şekilde kullanılmaktadır (Oancea ve Ciucu, 2014: 1402). Literatürde finansal zaman serilerinin yapay sinir ağları ile modellendiği çok sayıda çalışmaya rastlanmaktadır. Döviz kurları, (Hann ve Steurer, 1996; Panda ve Narasimhan, 2007; Ye, 2012), borsa endeksleri (Guresen vd. 2011; Patel ve Yalamalle, 2014), altın fiyatları (Parisi vd. 2008; Mombeini ve Yazdani-Chamzini, 2015), sebze fiyatları (Nasira ve Hamegeetha, 2012), ham petrol fiyatları (Sompui ve Wongsinlatam, 2014) ve doğal gaz fiyatları (Sotoudeh ve Farshad, 2012) gibi finansal zaman serileri bunlara örnek olarak verilebilir.

Finansal zaman serilerinin modellenme zorluğunun üstesinden gelebilmek için bazı çalışmacılar birden fazla modeli bir arada kullanarak daha iyi modeller bulma yoluna gitmektedirler. Birleşik, karma ya da hibrit olarak adlandırılabilen bu tür modellerin finansal zaman serileri konusunda kullanımı özellikle son yıllarda yaygınlık kazanmaktadır. Silva vd. (2010) finansal zaman serisine öncelikle Dalgacık Analizi (*Wavelet Analysis*) uygulamakta, gürültü olduğu varsayılan yüksek frekanslı fiyat hareketlerini ortadan kaldırmakta ve ardından seriyi Gizli Markov Modeli ile modelleyerek kestirim yapmaktadır. Tseng vd. (2001) Bulanık ARIMA (*FARIMA*) modelini ortaya koymakta ve bu model ile NTD/USD (Tayvan Doları/ Amerikan Doları) kurunu modellemektedir. Khemchandani vd. (2009) hisse fiyatları modellemesi ve tahmini için Düzenlenmiş En Küçük Kareler Bulanık Destek Vektör Regresyonu modelini ortaya atmaktadır. Huang vd. (2010) döviz kuru tahmini için Kaos Temelli Destek Vektör Regresyonu modelini uygulamaktadır. Aznarte vd. (2012) Bulanık Mantık modelini geliştirmek amacıyla Genetik algoritmaya başvurmuş ve hisse senedi modellemesi için Biyo-Esin Bulanık Modeli (*Bio – Inspired Fuzzy Model*) ortaya koymuştur. Guo vd. (2012) petrol fiyatlarının modellenmesi ve tahmini için, eğitim verisiyle bağlantılı olarak, parametre seçiminde Genetik Algoritmaya başvuran bir Destek Vektör Makineleri modeli olan GA-SVM (*Genetic Algorithm Support Vector Machines*) modelini ortaya atmaktadır. Kumbhar ve Argiddi (2015) ağırlıkların Genetik Algoritma ile optimize edildiği bir Yapay Sinir Ağı modeli ortaya atmış ve hisse senedi fiyatları üzerinde yapılan uygulamada hibrit modelin Yapay Sinir Ağı modelinden daha iyi sonuçlar verdiği saptanmıştır.

Finansal zaman serileri için kullanılan hibrit modellerden bir diğeri, ARIMA ve Yapay Sinir Ağları'nın beraber kullanıldığı modellerdir. Birden fazla modelin zaman serilerinde uygulanmasındaki en önemli sebep gerçek hayattaki zaman serilerinin doğrusal mı yoksa

doğrusal olmayan mı olduğunun tam olarak bilinmemesidir. Bu zaman serileri genellikle ne tamamen doğrusal ne de tamamen doğrusal olmayan karakterdedir (Mahalakshmi vd., 2014: 566). Hem kuramsal hem de deneysel bulgular farklı modellerin bir arada kullanılmasının, özellikle modellerin oldukça farklı olduğu durumlarda kestirim performansını artırmak için etkili bir yöntem olduğunu ortaya koymaktadır (Yan ve Zou, 2013: 60).

Tseng vd. (2002) Mevsimsel Arima (*SARIMA*) ve Geri Yayılım Yapay Sinir Ağlarını bir arada kullanmaktadır. Çalışmada zaman serisi önce ARIMA yöntemiyle modellenmektedir. Elde edilen tahmin ve hata değerleri iki ayrı zaman serisi halinde Geri Yayılım YSA ile modellenerek kestirim yapılmaktadır. Çalışmada makine endüstrisinin toplam geliri zaman serisi olarak alınmıştır. 1991 – 1995 yılları arası aylık değerler zaman serisi olarak alınırken 1996 yılı için 12 aylık değer tahmin için seçilmiştir. Hibrit modelin SARIMA modeline göre çok daha iyi sonuçlar verdiği görülmektedir.

4.1.2. Finansal Piyasalar

Varlıklar finansal piyasalarda fiyatlanır. Farklı finansal piyasalar farklı müşteri çeşitlerine göre farklı şekillerde hizmet vermektedir. Bu sebeple finansal piyasalar farklı özelliklerine göre sınıflandırılabilir. Buğday, taşıt, emlak, bilgisayar gibi fiziksel varlıkların alınıp satıldığı piyasalar fiziksel varlık piyasaları olarak adlandırılırken; hisse senedi, tahvil, bono gibi gerçek varlıklar üzerindeki hakları ifade eden varlıklar ve türev ürünlerinin el değiştirdiği piyasalar finansal varlık piyasaları olarak adlandırılırlar. Spot piyasalar, alınan ya da satılan varlıkların hemen veya kısa zamanda teslim edildiği piyasalarken, vadeli işlem piyasalarında katılımcılar bir varlığı belli bir vade sonunda almak veya satmak üzere anlaşır. Para piyasaları kısa vadeli ve yüksek likiditeli varlık piyasalarıdır. Sermaye piyasaları ise orta ve uzun vadeli varlıkların el değiştirdiği piyasalardır. Buradaki vade ayrımı için kesin bir kural olmasa da kısa vade genellikle 1 yıldan az süre için, orta vade 1 – 10 yıl arası için ve uzun vade 10 yıldan daha uzun süre için kullanılır. Birincil piyasalar bir varlığın ilk defa satışa çıkarıldığı piyasalardır. Örneğin bir hisse senedinin ilk defa piyasaya çıkarılması birincil piyasada olur. İkincil piyasalar ise hali hazırda piyasada olan bir varlığın yatırımcılar tarafından alınıp satıldığı piyasalardır (Brigham ve Houston, 2007: 145). Finansal piyasalarda işlem gören ve finansal zaman serileri analizine konu olan başlıca varlıklar arasında emtia, döviz, hisse senetleri ve bono – tahvil gibi borçlanma araçları sayılabilir.

Emtia (*commodities*), meta kelimesinin çoğulu olup piyasada alınıp satılan madde ve özellikle hammaddeler için kullanılmaktadır. Madencilik yoluyla üretilen değerli metaller ve endüstriyel metaller gibi, sondajla elde edilen petrol ve gaz; veya tarım üretimi olan mısır ve

pamuk gibi doğal kaynaklar emtia olarak adlandırılır. Emtia günlük olarak dünya çapında vadeli işlem borsalarında alınıp satılır. Emtia varlıklar içerisinde değerli metallerin ayrı bir yeri vardır. Diğer emtia varlıklarından farklı olarak değerli metaller piyasalarda döviz çiftleri gibi işlem görürler. Emtia fiyatları birincil olarak arz talep dengesine göre belirlenir. Basitçe, emtianın piyasada azlığı fiyatların yükselmesine, fazlalığı ise düşmesine sebep olur (Credit Suisse, 2012).

Piyasalarda yoğun işlem gören başlıca dört grup emtia sayılabilir. Bunlar: enerji grubu, değerli metaller, endüstriyel metaller ve tarım ürünleridir. Enerji grubu emtia, petrol, kalorifer yakıtı (*fuel – oil*), doğal gaz, dizel, benzin gibi enerji üreten kimyasal maddelerdir. Enerji grubu varlık fiyatları büyük oranda küresel ekonomik büyümeye bağlı olmakla birlikte, jeopolitik gelişmelere karşı da oldukça hassastır. Altın, gümüş, platin, paladyum gibi metaller değerli metaller grubunda yer alırlar. Bu metallerin piyasa talebi fiziksel talep ve yatırımcı talebi olarak ikiye ayrılabilir. Fiziksel talep metallerin hammadde olarak kullanıldığı endüstriyel ve kuyumculuk talebi olarak nitelendirilebilir ve talep büyük oranda ekonomik büyümeyle ilişkilidir. Diğer taraftan yatırımcı talebi bu metallerin yatırım aracı olarak kullanılmasından kaynaklandığından faiz oranı değişimleri ve döviz kurlarındaki hareketler gibi faktörlere bağlılık gösterir. Özellikle altın, piyasa belirsizliği durumlarında oldukça ilgi gösterilen bir yatırım aracıdır. Alüminyum, bakır, nikel, kurşun gibi metaller endüstriyel metal grubuna girerler. Endüstriyel metaller otomotiv, havacılık ve inşaat endüstrileri gibi alanlarda hammadde olarak kullanılmaktadırlar. Ekonomik göstergeler endüstriyel metal fiyatları üzerinde belirleyici etkiye sahiptir. Örneğin Çin endüstriyel metallerin en önemli alıcısıdır. Bu sebeple Çin'in ekonomik verileri fiyatlar üzerinde önemli etkiye sahiptir. Fosil kaynaklı emtiadan farklı olarak, tarım ürünleri yenilenebilir. Mısır, buğday, soya fasulyesi gibi bitkiler; soya yağı, gibi bitkisel yağlar ile şeker gibi bitki kökenli ürünler bu gruba girer. Tarım ürünü fiyatları arz – talep dengesiyle oluşur. Çoğu tarım ürünü en temel ihtiyaçlar için kullanıldığından ekonomik büyümeye bağlılığı azdır. Ancak diğer emtiadan farklı olarak fiyatlar hava şartları ve kullanılabilir su miktarıyla yakından ilişkilidir (Credit Suisse, 2012).

Bir para biriminin değerinin başka bir para birimi cinsinden ifadesine döviz kuru adı verilir. Döviz kurlarındaki değişimler ekonomiyi ve günlük hayatı etkiler. Döviz kurları özellikle uluslararası ticaretle yakından alakalıdır. Bir ülkenin para birimi değerlendirildiğinde (diğer para birimlerine göre değeri arttığında) ülkenin yurtdışındaki ürünleri pahalılaşırken, ülke içindeki dış kaynaklı ürünler ucuzlar. Aynı şekilde, para biriminin değeri azaldığında ülkenin ihraç ettiği ürünler yurt dışında ucuzlarken, yurt içinde ithal ürünlerin değeri artar (Mishkin ve Eakins, 2012: 345).

İthalatçılar, ihracatçılar, turistler ve hükümetler döviz kuru piyasasında para birimlerini alır ve satarlar. Hisse senedi ve emtia için organize ticaret zeminleri bulunmaktadır, ancak döviz kuru alışverişi bankalar, komisyoncular ve finansal kuruluşlardan oluşan küresel bir ağ içerisinde yapılmakta, çoğu al ve sat emirleri telefon veya bilgisayar yoluyla gerçekleşmektedir. Döviz kuru fiyatları spot ve vadeli (*forward*) olarak ikiye ayrılabilir. Spot fiyatlar satılan dövizin hemen (en geç iki günde) ulaştırıldığı alışverişler için geçerliken, vadeli fiyatlar vadeli alım – satım denilen, genellikle 30, 90 ya da 180 gün vadeli alım – satım işlemlerinin fiyatlarıdır (Brigham ve Houston, 2007: 626). Faiz oranları, enflasyon, uluslararası ticarete karşılaşılan kota ve vergi gibi bariyerler, ithalat ve ihracat talepleri ile üretimdeki artış ve azalmalar döviz fiyatlarını etkileyen başlıca faktörlerdir (Brigham ve Houston, 2007; Mishkin ve Eakins, 2012).

2016 yılı itibariyle tüm dünyada günlük ortalama döviz alışverişinin 5,1 trilyon dolar olduğu tahmin edilmektedir. Alışverişlerin 87,6%'sında Amerikan Doları, 31,3%'ünde Euro, 21,6%'sında Japon Yeni ve 21,2%'sinde gelişmekte olan ülke para birimleri kullanılmaktadır. (Her alışverişte iki para birimi kullanıldığından toplamı 200%'dür). Gelişmekte olan ülke para birimleri grubunda yer alan Türk Lirası'nın payı 1,4%'tür (Bank for International Settlements, 2016).

Hisse senedi bir şirketin belli bir yüzdelik payı anlamına gelmektedir. Hisse senedi sahibi, hisse senedinin piyasadaki değerinin artmasıyla veya firmanın kar payı dağıtması yoluyla kazanabilir. İki tür hisse senedinden bahsedilebilir. Adi (*common*) hisse senetleri sahiplerine eşit haklar sağlarken, imtiyazlı (*preferred*) hisse senetleri sahiplerine kâra ortaklık vs. gibi haklar sağlayabilmektedir. Hisse senedi piyasalarında alınıp satılan senetler genellikle adi senetlerdir. Hisse senetleri alım ve satımları organize borsalarda (*Organized Exchange*) veya tezgah üstü piyasalarda (*Over The Counter*) yapılmaktadır. Organize borsalar tezgâh üstü piyasalara göre daha organize, daha katı kuralları olan piyasalardır. Örneğin ABD'de New York Borsası (*New York Stock Exchange*) organize borsayken, NASDAQ (*National Association of Securities Dealers Automated Quotation System*) tezgah üstü piyasa sınıfındadır. Ancak son yıllarda elektronik ticaretin büyümesiyle bu iki piyasa arasındaki fark belirsizleşmeye başlamaktadır (Mishkin ve Eakins, 2012: 19).

Hisse senedi fiyatları firmanın performansı ile yakından ilgilidir, ancak fiyatları etkileyen başka faktörler de bulunmaktadır. Politik durumlar, ekonomik etkiler, sanayi, hisse senedinin bulunduğu ülkenin durumu gibi birçok faktör hisse senedi fiyatlarını etkilemektedir.

Hisse performanslarını tek tek incelemek yerine bir grup hissenin performansı beraberce değerlendirilebilir. Borsa endeksi (*stock market index*) adı verilen bu endeks sayesinde yatırımcılar grup olarak hisselerin gidişatını gözlemleyebilirler (Mishkin ve Eakins, 2012: 316).

Borsa endeksleri bir borsada seçilen hisselerin fiyat ortalaması (genellikle ağırlıklı ortalama) kullanılarak elde edilir. Bu seçim işlemi borsada en çok işlem gören hisseler alınarak yapılabileceği gibi, borsanın tamamı ya da belli sektörlerdeki hisseler seçilerek te yapılabilir. Örneğin Borsa İstanbul endekslerinden olan BIST 100 endeksinde Borsa İstanbul'da işlem gören piyasa değeri ve işlem hacmi en yük 100 hisse bir araya getirilirken, BIST Sınai Endeksinde, Borsa İstanbul'da yer alan endüstriyel şirketler yer almaktadır. Endekslere direk olarak yatırım yapılamamakla birlikte bu endeksleri temel alan fonlara yatırım yapılabilmektedir.

Bono; anlaşma, kontrat ya da garanti anlamlarına gelmektedir. Bono satın alan bir yatırımcı bononun yayıncısına borç vermektedir ve bono, yayıncının belirlenen bir süre sonunda anaparayı ve belirli bir faiz tutarını ödeyeceğine dair bir kontratı temsil etmektedir (Levinson, 2005: 58). Tahvil ve bono aynı şeyi ifade etmekle birlikte genellikle süresi bir yıldan az olanlar bono, bir yıldan fazla olanlar ise tahvil olarak adlandırılmaktadır.

Bono devlet veya şirketler tarafından piyasaya sürülen bir borçlanma aracıdır. Devlet tarafından piyasaya sürülen hazine bonoları (*treasury bonds*), şirketlerin piyasaya sürdüğü şirket bonoları (*corporate bonds*) olduğu gibi bazı ülkelerde yerel yönetimler tarafından piyasaya sürülen bonolar ve yabancı ülke bonoları da bulunmaktadır (Brigham ve Houston, 2007: 146).

Bonolar genellikle tek borçlanma aracı olarak kullanılmamaktadır. Bonoyu yayınlayan devlet veya şirket genellikle hali hazırda bankalara, finans şirketlerine, müşterilerine veya üreticilerine borçlanmış olmaktadır. Bono yayınlanmasının sebebi borçlanma kaynaklarını çeşitlendirmektir (Levinson, 2005: 60). Bono ve tahviller genellikle tezgâh üstü borsalarda veya büyük finansal kurumlar bünyesinde satılmaktadır (Brigham ve Houston, 2007: 209). Türkiye'de tahvil ve bonolara genellikle bankalar aracılığıyla ulaşılabilir. Bono ve tahvil fiyatlarındaki değişimlerin en önemli etkeni faiz oranlarıdır. Bono ve tahvil fiyatları faiz oranıyla ters orantılı olarak hareket eder (Levinson, 2005: 76)

Bu çalışmada uygulama aşamasında üç farklı finansal zaman serisi kullanılmaktadır. Bu zaman serilerinin seçiminde özellikle farklı türlerden finansal varlıklar olmasını dikkat edilmektedir. Uygulamaya konu olan altın emtia grubu bir finansal varlıkken, ABD Doları/Türk Lirası kuru döviz grubunda ve BIST 30 Endeksi hisse senedi grubunda değerlendirilen zaman serileridir.

4.1.2.1. Altın

Altın eski zamanlardan bu yana değerli olan bir maddedir. İnsanlar altını mücevher olarak ve para olarak kullanmışlardır. Altın güzelliğin ve zenginliğin sembolü olarak değerlendirilmektedir. Ancak bunların yanında altın birçok teknoloji alanında da kullanılmaktadır. Korozyon direnci ve biçimlendirilebilir olması uzay teknolojilerinden nano teknolojiye kadar birçok alanda kullanılmasına yol açmaktadır (Wang, 2012: 11). Ekonomik anlamda tarihte para birimi olarak kullanılan altın, 19. yy. sonlarında birçok ülkede kabul edilen altın standardı (*gold standard*) ile para birimlerine temel kabul edilmiştir. İlerleyen yıllarda uygulamadan kaldırılan altın standardına göre ülkeler para birimlerini belli bir altın miktarına göre sabitlemekteydiler (Cooper, 1982: 3).

Yatırım anlamında bakıldığında altın, hisse senedi ve bonolardan farklılık arz etmektedir. Gerek hisse senedi ve gerekse bono, bünyesinde belli bir risk taşıdığı halde altının doğal değeri yatırımcı için belli bir güven sunmaktadır. Altına yatırım yapmanın doğrudan ve doğrudan olmayan yolları bulunmaktadır. Altın yatırımı doğrudan fiziksel olarak satın alma yoluyla yapılabileceği gibi, altın temelli fonlar veya altın madenciliği yapan firmaların hisselerinin alımı yoluyla da yapılabilmektedir (Wang, 2012: 25).

Dünyada altın talebi mücevherat, sanayi, yatırım amaçlı ve merkez bankaları ve diğer kuruluşların talepleri olarak dörde ayrılabilir. 2016 yılı itibariyle dünya altın talebi rakamları Tablo 4.1’de yer almaktadır.

Tablo 4.1. 2016 Yılı Küresel Altın Talebi

Toplam Altın Talebi (Ton)	4.315,0
Mücevherat	2.040,3
Teknoloji	323,4
Yatırım	1.574,2
Merkez Bankaları ve Diğer Kurumlar	377,2

Kaynak: Gold Data and Statistics, 2017

Hükümetler ve merkez bankaları hazinelerinde döviz, altın ve diğer varlıklardan oluşan bir portföy bulundurmaktadırlar. Merkez bankalarının hazinede altın bulundurmalarının sebebi bireysel yatırımcılarla aynı şekilde portföyü çeşitlendirmek ve riski kontrol etmektedir (Wang, 2012: 27). Altın bireysel bir yatırımcı için nasıl güvenilir bir varlıksa merkez bankaları için de aynı şeyi ifade eder. 2017 Mart ayı itibariyle en çok altın bulunduran hükümet ve diğer kuruluşlar Tablo 4.2’de gösterilmektedir.

Tablo 4.2. 2017 Mart Ayı İtibariyle Rezervlerinde En Çok Altın Bulunduran Devlet ve Diğer Kuruluşlar

Sıra	Ülke/Kuruluş	Ton	Toplam Rezerve Göre Yüzde
1	ABD	8.133,5	75%
2	Almanya	3.377,9	69%
3	IMF	2.814,0	-
4	İtalya	2.451,8	68%
5	Fransa	2.435,9	64%
6	Çin	1.842,6	2%
7	Rusya	1.680,1	17%
8	İsviçre	1.040,0	6%
9	Japonya	765,2	2%
10	Hollanda	612,5	64%
11	Hindistan	557,8	6%
12	Avr. Mrk. Bankası (ECB)	504,8	27%
13	Türkiye	427,8	16%
14	Tayvan	423,6	4%
15	Portekiz	382,5	55%
16	Suudi Arabistan	322,9	2%
17	Birleşik Krallık	310,3	9%
18	Lübnan	286,8	21%
19	İspanya	281,6	17%
20	Avusturya	280,0	46%
21	Kazakistan	267,7	36%
22	Belçika	227,4	37%
23	Filipinler	196,3	10%
24	Venezuela	187,5	65%
25	Cezayir	173,6	6%
26	Tayland	152,4	3%
27	Singapur	127,4	2%
28	İsveç	125,7	9%
29	Güney Afrika	125,3	11%
30	Meksika	120,1	3%
31	Libya	116,6	7%
32	Yunanistan	112,8	65%
33	Kore	104,4	1%
34	Uls. Ödm. Bankası (BIS)	104,0	-
35	Romanya	103,7	10%
36	Polonya	103,0	4%
37	Irak	89,8	8%
38	Avustralya	79,9	5%
39	Kuveyt	79,0	9%
40	Endonezya	78,1	3%

Kaynak: Gold Data and Statistics, 2017

Gelecek bir zaman için yapılan fiyat anlaşmaları olan vadeli işlem sözleşmeleri dışında, dünya çapında piyasalarda ortaya çıkan anlık fiyatlar spot fiyatlar olarak adlandırılır. Altın dünya çapında borsalarda hafta beş gün 24 saat boyunca alınıp satılmaktadır. Fiyatlar genellikle ABD Doları cinsinden USD/Ons olarak verilir ve uluslararası piyasalarda XAU/USD olarak gösterilir. Ons bir İngiliz ağırlık birimidir ve 1 ons yaklaşık olarak 28,35 gramdır.

Bir ABD borsa endeksi olan Dow Jones Sanayi Endeksinin ve dolar fiyatlarının altın fiyatlarını negatif yönde, küresel para arzının ise pozitif yönde etkilediği; ayrıca ekonomik krizlerin altına talebi artırdığı ve fiyatlara pozitif yönde etkisi olduğu düşünülmektedir (Topçu, 2010: 26).

4.1.2.2. ABD Doları/ Türk Lirası Kuru (USD/TRY)

ABD Doları döviz piyasasında en büyük paya sahip para birimidir. ABD Dolarının döviz piyasasında bu kadar dominant olmasının sebepleri 1944'te Bretton Woods'da yapılan Birleşmiş Milletler Para ve Finans Konferansı'na kadar uzanmaktadır. Bu konferansta 44 ülkenin imzasıyla 1 ons altın 35\$'a endekslenmiş ve ABD Doları zaman içerisinde en yaygın ve güvenilir para birimi haline gelmiştir. 1971 yılında Bretton – Woods sistemi çökmesine rağmen sistemin ABD Dolarına etkisi devam etmiştir (İskenderoğlu, 1988; Levinson, 2005).

ABD Doları dünyada merkez bankaları rezervlerinde en çok kullanılan para birimidir. 2016 rakamlarıyla dünya merkez bankaları rezervlerinde yer alan para birimlerinin 63,96%'sı ABD Doları'dır. En yakın rakibi Euro'nun payı 19,74%'tür (IMF COFER, 2017).

ABD Doları 87,58% ile dünya döviz piyasası içinde en yüksek paya sahip para birimidir. Bu sebeple ABD Dolarında meydana gelen değişimler tüm para birimlerini etkilemektedir. 2001 yılından itibaren 3 yıllık aralarla dünya döviz piyasasında en çok paya sahip para birimleri ve yüzdelik payları Tablo 4.3'te gösterilmektedir.

Tablo 4.3'te yer alan en dikkat çekici para birimlerinden biri Türk Lirasıdır. Uluslararası döviz piyasasında 2001 yılında 0,04% olan Türk Lirası'nın payı 2016 yılında 1,44%'e yükselmiştir. Pazar payı yaklaşık 41 kat yükselen Türk Lirası bu dönemde Pazar payını yaklaşık 500 kat yükselten Çin Yuanı'ndan sonra pazar payı en çok artan para birimidir. Türk Lirası'nın 2016 yılı itibarıyla en çok işlem gören 16. para birimi olduğu görülmektedir.

Diğer döviz kurları gibi USD/TRY kuru da bir çapraz kurdur ve her iki para birimini ayrı ayrı etkileyen faktörler kurun değerini etkilemektedir. Döviz kurlarını etkileyen başlıca faktörler arasında enflasyon ve faiz oranı bulunmaktadır. ABD'deki enflasyon ve faiz oranı değişimleri veya beklentileri kurun Dolar tarafını etkilerken, Türkiye'de yaşanan enflasyon ve faiz oranı değişimleri veya bu değişimlerle ilgili beklentiler kurun Türk Lirası tarafını etkilemektedir. Bunlar dışında bütçe açığı, dış ve iç borçlar, üretim maliyeti, gayri safi milli hâsıla, işsizlik verileri, ülkelerin politik ve ekonomik performansları ile dünya çapında etki gösteren jeopolitik ve makroekonomik olaylar gibi birçok faktör kuru etkileyebilmektedir (Patel vd., 2014: 53).

Tablo 4.3. Küresel Döviz Piyasasında En Çok Paya Sahip Para Birimleri ve Yüzdelik Payları

Para Birimi	2001		2004		2007		2010		2013		2016	
	Pay (%)	Sıra	Pay (%)	Sıra	Pay (%)	Sıra	Pay (%)	Sıra	Pay (%)	Sıra	Pay (%)	Sıra
USD	89,86	1	88,01	1	85,60	1	84,86	1	87,04	1	87,58	1
EUR	37,91	2	37,41	2	37,04	2	39,04	2	33,41	2	31,39	2
JPY	23,53	3	20,83	3	17,25	3	18,99	3	23,05	3	21,62	3
GBP	13,05	4	16,50	4	14,87	4	12,88	4	11,82	4	12,80	4
AUD	4,32	7	6,02	6	6,62	6	7,59	5	8,64	5	6,87	5
CAD	4,49	6	4,20	7	4,29	7	5,28	7	4,56	7	5,14	6
CHF	5,98	5	6,03	5	6,82	5	6,30	6	5,16	6	4,80	7
CNY	0,01	35	0,10	29	0,45	20	0,86	17	2,23	9	3,99	8
SEK	2,50	8	2,19	8	2,70	9	2,19	9	1,76	11	2,22	9
NZD	0,56	16	1,06	13	1,90	11	1,59	10	1,96	10	2,05	10
MXN	0,83	14	1,11	12	1,31	12	1,26	14	2,53	8	1,92	11
SGD	1,05	12	0,91	14	1,17	13	1,42	12	1,40	15	1,81	12
HKD	2,24	9	1,76	9	2,70	8	2,37	8	1,45	13	1,73	13
NOK	1,46	10	1,38	10	2,10	10	1,32	13	1,44	14	1,67	14
KRW	0,80	15	1,14	11	1,16	14	1,52	11	1,20	17	1,65	15
TRY	0,04	30	0,11	28	0,18	26	0,74	19	1,32	16	1,44	16
RUB	0,35	19	0,63	17	0,75	18	0,90	16	1,60	12	1,15	17
INR	0,23	21	0,32	20	0,71	19	0,95	15	0,99	20	1,14	18
BRL	0,48	17	0,27	21	0,39	21	0,68	21	1,10	19	1,00	19
ZAR	0,94	13	0,72	16	0,91	15	0,72	20	1,11	18	0,97	20
DKK	1,19	11	0,87	15	0,84	16	0,57	22	0,79	21	0,84	21
PLN	0,45	18	0,38	19	0,76	17	0,81	18	0,70	22	0,70	22
TWD	0,27	20	0,42	18	0,36	22	0,48	23	0,46	23	0,63	23
THB	0,15	24	0,20	22	0,20	25	0,19	26	0,32	27	0,36	24
MYR	0,07	26	0,05	30	0,13	28	0,28	25	0,40	25	0,36	25
HUF	0,02	33	0,19	23	0,27	23	0,43	24	0,42	24	0,30	26
SAR	0,07	27	0,04	32	0,06	32	0,08	34	0,10	34	0,30	27
CZK	0,19	22	0,15	24	0,21	24	0,19	27	0,36	26	0,28	28
ILS	0,10	25	0,11	26	0,15	27	0,15	31	0,18	29	0,28	29
CLP	0,18	23	0,12	25	0,11	30	0,16	29	0,30	28	0,25	30
IDR	0,05	28	0,11	27	0,11	29	0,15	30	0,17	30	0,20	31
COP	0,03	31	0,04	33	0,05	33	0,10	32	0,11	33	0,16	32
PHP	0,04	29	0,04	31	0,11	31	0,17	28	0,15	31	0,14	33
RON	0,00	37	0,00	40	0,05	34	0,07	33	0,12	32	0,10	34
PEN	0,02	32	0,01	35	0,02	36	0,03	36	0,06	35	0,08	35
Diğer	6,56		6,59		7,65		4,68		1,61		2,10	
Toplam	200,00		200,0		200,0		200,0		200,0		200,0	

Kaynak: Bank for International Settlements, 2016

Döviz kurlarını etkileyen çok sayıda faktör olduğundan, bu faktör ya da faktörlerle ilgili beklentilerde oluşan her bir değişiklik kurları etkilemekte ve kurların oynaklığının yüksek olmasına yol açmaktadır (Mishkin ve Eakins, 2012: 362).

4.1.2.3. BIST 30 Endeksi

Borsa endeksleri bir borsada oluşan fiyat hareketlerinin yönünün topluca izlenebilmesini sağlamaktadır. Borsa endeksi genellikle belli bir hisse senedi örneğinden yola çıkarak piyasanın tüm performansını göstermek için oluşturulan istatistiki bir göstergedir. Borsa endekslerinin belli başlı kullanım alanları aşağıdaki gibidir (Dağlı, 2000: 191):

- Endeksler hisse senedi fiyatlarının zaman içindeki toplu değişimini ortaya koyarlar.
- Yatırımcıların eldeki portföylerinin verimini hesaplayabilmelerini sağlar. Yatırımcılar kendi portföyleriyle endeksi karşılaştırarak portföy performansını piyasa performansı ile kıyaslayabilirler.
- Endeksler borsa ile ekonomik göstergelerdeki değişimler arasında karşılaştırma yapılmasında kullanılabilir.
- Sermaye piyasaları için beta katsayısının hesaplanmasında endekslerden faydalanılabilir.
- Endekslerden faydalanılarak endekse dayalı opsiyon ve vadeli işlem sözleşmeleri ile yatırım fonları gibi araçlar geliştirilebilir.
- Eldeki alternatif yatırım araçlarının karşılaştırılmasında endeksler kullanılabilir.

Borsa İstanbul bünyesinde hesaplanan ve sıklıkla kullanılan başlıca endeksler BIST 100, BIST 50 ve BIST 30 pay endeksleridir. Ancak bunlar dışında BIST Yıldız, BIST Kurumsal Yönetim gibi farklı sınıflandırmalarla oluşturulan; BIST Sınai, BIST Telekomünikasyon gibi sektörel; ve BIST Antalya, BIST Bursa gibi yerel endeksler de bulunmaktadır.

Borsa endeksleri, bileşen hisselerine verdikleri ağırlıklara göre; fiyat ağırlıklı (*price weighted*), piyasa değeri ağırlıklı (*value weighted*) veya eşit ağırlıklı (*equally weighted*) olarak ayrılırlar. Endeksler aynı zamanda endeks değeri hesaplama şekline göre aritmetik ortalamalı ve geometrik ortalamalı şeklinde de ikiye ayrılmaktadır (Dağlı, 2000: 192).

BIST 30 endeksi “Yıldız Pazar ve Ana Pazar’da işlem gören şirketlerle, Kolektif Yatırım Ürünleri ve Yapılandırılmış Ürünler Pazarı’nda işlem gören gayrimenkul yatırım ortaklıkları ve girişim sermayesi yatırım ortaklıkları arasından seçilen 30 paydan oluşur” (Borsa İstanbul, 2016). BIST 30 Endeksi, piyasa değeri ağırlıklı veya diğer adıyla kapitalizasyon ağırlıklı olup aritmetik ortalamalı bir endekstir. 31 Mart 2017 tarihi itibarıyla endekste yer alan hisseler yüzde ağırlıklarına göre Tablo 4.4’te yer almaktadır:

Tablo 4.4. BIST 30 Endeksi Hisseleri ve Ağırlık Oranları

PAY KODU	PAY ADI	AĞIRLIK (%)	PAY KODU	PAY ADI	AĞIRLIK (%)
GARAN	GARANTİ BANKASI	11,20	TOASO	TOFAŞ	2,05
AKBNK	AKBANK	11,12	ENKAI	ENKA İNŞAAT	1,93
TUPRS	TÜPRAŞ	6,94	YKBNK	YAPI VE KREDİ BANKASI	1,86
BIMAS	BİM MAĞAZALAR	6,38	SISE	ŞİŞE CAM	1,82
EREGL	EREĞLİ DEMİR ÇELİK	6,21	TTKOM	TÜRK TELEKOM	1,68
ISCTR	İŞ BANKASI (C)	5,80	ULKER	ÜLKER BİSKÜVİ	1,54
TCELL	TURKCELL	5,78	ASELS	ASELSAN	1,49
SAHOL	SABANCI HOLDİNG	5,63	FROTO	FORD OTOSAN	1,41
KCHOL	KOÇ HOLDİNG	5,37	TAVHL	TAV HAVALİMANLARI	1,32
HALKB	T. HALK BANKASI	3,98	SODA	SODA SANAYİİ	1,12
EKGYO	EMLAK KONUT GMYO	3,52	TKFEN	TEKFEN HOLDİNG	0,96
ARCLK	ARÇELİK	2,40	KOZAL	KOZA ALTIN	0,55
THYAO	TÜRK HAVA YOLLARI	2,37	KRDMD	KARDEMİR (D)	0,50
VAKBN	VAKIFLAR BANKASI	2,10	OTKAR	OTOKAR	0,48
PETKM	PETKİM	2,10	DOHOL	DOĞAN HOLDİNG	0,39
TOPLAM					100,00

Kaynak: BIST Pay Endeksleri, 2017

Hisselerin ağırlıkları sektörel olarak ifade edilirse endeksin sektörel ağırlık dağılımı Tablo 4.5'te yer almaktadır.

Tablo 4.5. BIST 30 Endeksi Hisseleri Sektörel Dağılımı

Sektör	Ağırlık (%)
Bankacılık	36,06
Holding	15,29
Petrokimya	9,03
Telekomünikasyon	8,95
Demir - Çelik	7,27
Perakende	6,38
Otomotiv	3,94
Ulaştırma	3,69
Gayrimenkul Yatırım Ortaklığı	3,52
Dayanıklı Tüketim	2,40
İnşaat	1,93
Gıda	1,54
TOPLAM	100,00

Kaynak: BIST Pay Endeksleri, 2017

4.2. Veri Seti

Uygulamada Optimize ARIMA – YSA Modeli ile modellenerek ARIMA ve YSA modelleriyle karşılaştırılmak üzere üç ayrı finansal zaman serisi seçilmiştir. Finansal zaman serilerinin seçiminde üç önemli kriter gözetilmektedir. Bunlardan birincisi zaman serisi modeline konu olacak finansal varlıkların farklı özellikte olmalarıdır. Seçilen finansal varlıklardan altın, emtia grubunda ve kıymetli madenler olarak adlandırılan finansal varlıklardandır. BIST 30 Endeksi hisse senedi endeksleri grubunda yer almakta ve ABD Doları/ Türk Lirası çaprazı da döviz grubunda yer almaktadır. Seçilen finansal varlıkların farklı gruplarda yer alması finansal varlıkların farklı özelliklerde ve farklı dinamiklerle hareket eden zaman serilerine sahip olmaları demektir. Bu durum Optimize ARIMA – YSA Modelinin farklı karakterde zaman serileriyle sınanması demek olup modelin performansı için daha genel bilgiler verecektir.


İkinci önemli kriter olarak, seçilen finansal varlıkların hem küresel piyasalarda tanınan ve işlem gören, hem de Türkiye'deki finans piyasasını ve Türkiye ekonomisini etkileyen varlıklar olması hedeflenmektedir. Spot Altın küresel piyasalarda en yoğun işlem gören varlıklardan olmakla birlikte Türkiye'deki altın fiyatlarını da doğrudan etkilemektedir. BIST 30 Endeksi İstanbul Borsası'na ait bir endekstir ancak küresel piyasaların İstanbul Borsası'nı değerlendirmek için en çok kullandığı birkaç endeksten biridir. Benzer şekilde USD/TRY kuru hem Türkiye finans piyasalarını ve Türk ekonomisini etkilemektedir, hem de uluslararası piyasalarda sıklıkla işlem gören çaprazlardan biridir.

Üçüncü kriter, seçilen zaman serilerinin farklı sayıda veri içermesidir. Farklı veri sayıları içeren farklı büyüklükteki zaman serileri seçilerek Optimize ARIMA – YSA Hibrit Modelinin farklı büyüklükteki veri setleri için sınanması sağlanmaktadır.

Bu üç önemli kriter gözetilerek seçilen veri setleri modellenmelerinin ardından gelecek tahmini için kullanılmaktadır. Her bir veri seti için seçilen tahmin yapılacak zaman sayısı, sonuçların yüzde olarak daha kolay ifade edilebilmesi için on olarak belirlenmiştir. Yine serilerin eşit şartlarda değerlendirilebilmesi için her üç zaman serisi için de aynı dönemler tahmin değerleri olarak belirlenmektedir. Ayrıca modellerin değerlendirilmesinde farklılık olmaması amacıyla veriler her üç veri seti için de haftalık kapanış değerleri olarak alınmaktadır.


Spot Altın fiyatları www.gold.org adresinden alınmıştır. Dünya Altın Konseyi (*World Gold Council*) resmi sitesi olan adreste altınla ilgili çok sayıda veriye ulaşmak mümkündür. Siteden spot altın için haftalık kapanış fiyatları alınmıştır. Veri seti 29.12.1978 Cuma kapanış fiyatıyla başlamakta ve 24.02.2017 kapanış fiyatıyla son bulmaktadır. Toplam veri seti 1992 veriden oluşmaktadır. Veri setinin son 10 haftalık kısmı 10 ayrı model ile tahmin edilecektir.

Buna göre tahmin edilecek haftalar 25.12.2016 haftalık kapanış ile 24.02.2017 haftalık kapanış arasındaki haftalık kapanış değerleridir. Veri seti Şekil 4.1’de verilmektedir.




Şekil 4.1. Spot Altın Haftalık Kapanış Fiyatları (29.12.1978 – 24.02.2017)

BIST 30 Endeks verileri www.investing.com adresinden alınmıştır. Site, dünya çapında 21 dilde ve 28 ülkeye özel olarak yayınlanmakta; finansal haberler, canlı fiyatlar, analizler, grafikler ve finansal araçlarla son yıllarda finansal verilerin takibi için en önemli kaynaklardan biri olmaktadır. BIST 30 Endeks verileri 10.01.1997 Cuma gününün kapanış değeriyle başlayarak 24.02.2017 Cuma kapanış fiyatıyla son bulmaktadır. Toplam veri sayısı 1042 olup son 10 haftanın verileri tahmin edilmek üzere seçilmiştir. BIST 30 veri seti Şekil 4.2’de gösterilmektedir:



Şekil 4.2. BIST 30 Endeksi Haftalık Kapanış Değerleri (10.01.1997 – 24.02.2017)

USD/TRY döviz kuru verileri için yine www.investing.com adresi kullanılmaktadır. Veriler 11.02.2005 tarihli haftalık kapanış değeriyle başlamakta ve 24.02.2017 Cuma günü haftalık kapanış değeriyle sona ermektedir. Toplam veri sayısı 629 olup, son 10 haftalık kapanış verisi gelecek tahmini için kullanılmaktadır. Uygulamada kullanılacak olan veri seti Şekil 4.3'tedir:



Şekil 4.3. USD/TRY Kuru Haftalık Kapanış Değerleri (10.01.1997 – 24.02.2017)

4.3. Model

4.3.1. ARIMA Süreci

Hibrit modelin ilk adımı olarak, her bir tahmin için veri seti (geçmiş değerler) öncelikle ARIMA ile modellenmektedir. ARIMA modelleme süreci XLSTAT (XLSTAT Forecast, sürüm 18.06.37287) programı kullanılarak yapılmaktadır. ARIMA sürecinde ilk adım veri setine en uygun p, d ve q değerlerinin tespitidir.

Öncelikle serinin durağan olup olmadığı kontrol edilerek seriyi durağan yapan en küçük d değeri bulunur. Bunun için eldeki seri ADF ve KPSS testlerine tabi tutulmaktadır. Eğer seri durağan ise d değeri 0'dır. Eğer seri durağan değilse serinin birinci derece fark serisi bulunur. Elde edilen seri yeniden ADF ve KPSS testlerine tabi tutulur. Bu süreç veri serisini durağan yapan en küçük d değeri bulunana kadar devam eder. Eğer KPSS ve ADF testlerinden farklı sonuçlar alınırsa her iki test te seriyi durağan olarak tespit edene kadar süreç uygulanmaya devam eder.

Modelin entegre değeri (d) bulunduktan sonra p ve q değerlerinin bulunması gerekmektedir. Genel olarak p ve q değerlerinin seçiminde kullanılabilen birçok yöntem olmakla birlikte en çok kullanılan yöntem Düzeltilmiş Akaike Bilgi Kriteri'dir. Düzeltilmiş Akaike Bilgi Kriteri farklı p ve q değerlerine göre modelleri sınamakta ve karşılaştırmaktadır. Ancak burada bir başka sorun hangi p ve q değerlerinin karşılaştırılacağıdır. p ve q değerleriyle ilgili bir sınır olmamasından dolayı karşılaştırma yapılacak p ve q değerleri veri sayısının bir eksiği miktara kadar ulaşabilir. Literatürde yer alan çalışmalarda ve piyasada kullanılan programların çoğunda bu sorun p ve q 'nun alabileceği değerlerin belli bir sayı ile sınırlandırılması yoluyla çözümlenmektedir. Her ne kadar gerçek hayatta karşılaşılan problemlerin çoğu için tespit edilen en iyi p ve q değerleri belli rakamları aşmasa da bu tip bir sınırlandırma çok sağlıklı olmayabilir. Bu çalışmada en iyi p ve q değerlerinin bulunması için Hyndman ve Khandakar (2008) tarafından ortaya atılan ve en iyi modeli bulmak için adım adım arama yapan algoritmadan faydalanılmaktadır. Bu algoritma R yazılım paketinde auto.ARIMA olarak yer almaktadır.

Algoritmaya göre öncelikle fark alma yöntemleri ve durağanlık testlerinden faydalanılarak modelin entegre katsayısı (d) bulunur. $d \geq 1$ ise, p ve q değerleri için arama işlemi başlatılır. Birinci aşamada ARIMA(1,d,0), ARIMA(0,d,1), ARIMA(0,d,0) ve ARIMA(2,d,2) modelleri kurularak her bir model için bilgi kriter değerleri bulunur. Bilgi kriteri değeri en küçük olan model şimdiki (*current*) model olarak tanımlanır. İkinci aşamada, ilk aşamada bulunan en iyi p ve q değerlerine göre $[p-1, p, p+1]$ ve $[q-1, q, q+1]$ aralığındaki modeller için tekrar arama yapılır. Bulunan en iyi model şimdiki model olarak kabul edilir. Eğer bulunan

model birinci aşamada bulunan modelle aynıysa, bu model en iyi ARIMA modeli olarak kabul edilerek arama sonlandırılır. Eğer yeni bir model elde edildiyse, ikinci aşama tekrar edilir. Arka arkaya iki arama sonucunda aynı model bulunana kadar ikinci aşama tekrar edilmektedir.

Bu çalışmada Hyndman ve Khandakar (2008)'in modelinden farklı olarak ilk aşamadaki aramaya ARIMA(1,d,1), ARIMA (1,d,2), ARIMA (0,d,2), ARIMA (1,d,2), ARIMA(2,d,0) ve ARIMA (2,d,1) modelleri de eklenmektedir. Buna göre p ve q değerleri [0,2] aralığında olacak şekilde ilk arama yapılır. Bu durumda (0,d,0), (0,d,1), (0,d,2), (1,d,0), (1,d,1), (1,d,2), (2,d,0), (2,d,1) ve (2,d,2) modelleri için AICc değerleri bulunarak en iyi model belirlenir. Belirlenen modeldeki p ve q değerlerinin bir eksiği ve bir fazlası kullanılarak yeni bir arama yapılır. Örneğin p=1 ve q=2 bulunduyorsa bir sonraki arama p=[0,2] ve q=[1,3] değer aralıkları için yapılır. Arka arkaya 2 aramada aynı değerler bulunduğu anda arama sonlandırılır ve bulunan değerler en iyi p ve q değerleri olarak kabul edilir.

Bulunan p,d ve q değerlerine göre seri modellenmektedir. Son aşama olarak model sonucu elde edilen artık serisi Ljung – Box Q Testi ile sınanarak beyaz gürültü özelliği gösterip göstermediği kontrol edilmektedir. Artık seri, beyaz gürültü özelliği göstermiyorsa bulunan modelde hata olabileceği için modelleme aşaması tekrar edilmelidir.

Bu çalışmada Mevsimsel ARIMA (SARIMA) modelleri kullanılmamakta ve uygulamaya konu olan finansal zaman serilerinde bir mevsimsellik olduğu düşünülmemektedir. Ancak göz ardı edilen herhangi bir mevsimsellik olup olmadığını tespit için modelleme sonucu elde edilen artıkların otokorelasyon fonksiyonu (ACF) ve kısmi otokorelasyon fonksiyonu (PACF) grafikleri kontrol edilmektedir. Artıklarda göz ardı edilen bir mevsimsellik olduğundan söz edebilmek için artıkların otokorelasyon fonksiyonu grafiğinde limit değerleri aşan otokorelasyon değerlerine bakılmaktadır. Limiti aşan değerler 3, 6, 9 veya 4, 8, 12 gibi belli periyotlarda tekrar ediyorsa göz ardı edilmiş bir mevsimsellikten bahsedilebilir.

ARIMA ile yapılan modellemeler sonucu model ve hata değerleriyle birlikte; toplam hata kare, ortalama hata kare, ortalama mutlak yüzde hata gibi hata değerleri ve AIC, AICc, SBC gibi bilgi kriter değerleri elde edilmektedir. Ayrıca modelin otoregresif ve hareketli ortalama katsayıları ile artıkların otokorelasyon ve kısmi otokorelasyon değerleri elde edilmektedir.

Her bir ARIMA modelinde bir adım öte tahminle bir sonraki haftalık kapanış değeri için tahmin değerine ulaşılmaktadır. Burada elde edilen model değerleri ve gelecek tahmini, Optimize ARIMA – YSA Hibrit Modelinde kullanılacağı gibi; aynı zamanda zaman serisinin ARIMA ile tahmini olduğundan, hibrit modelin değerlendirilmesi ve karşılaştırılması amacıyla da kullanılmaktadır.

4.3.2. Yapay Sinir Ağları Süreci

Optimize ARIMA – YSA Hibrit Modelin ikinci aşması olarak eldeki zaman serisi Yapay Sinir Ağları ile modellenmektedir. Bu çalışmada yapay sinir ağı modellemesi için Alyuda Neurointelligence (Alyuda Neurointelligence, sürüm 2.2 (577)) programı kullanılmaktadır. Yapay Sinir Ağı ile modelleme için öncelikle probleme uygun mimari belirlenmektedir.

Yapay Sinir Ağı modellemesi sonucunda yapılacak tahmin bir adım ileri (*one step forward*) tahmin olduğundan dolayı çıktı sayısı 1 olmalıdır. Dolayısıyla çıktı katmanındaki nöron sayısı 1'dir. Her bir değer için hangi gecikmeli değerlerin modele alınacağına göre girdi sayıları belirlenir. Özellikle finansal ve ekonomik zaman serilerinde sıklıkla karşılaşılabilen bir durum serinin mevsimsel etkiler içermesidir. Uygulamanın ARIMA modelleme aşamasında zaman serilerinin mevsimsellik barındırdığı düşünülmemekte, ancak göz ardı edilen herhangi bir mevsimsellik durumuyla karşılaşılması için model artık değerlerinin otokorelasyon fonksiyonları kontrol edilmektedir. Benzer şekilde YSA ile modelleme aşamasında, seride herhangi bir mevsimsellik düşünülmemekle birlikte ağ mimarisi var olabilecek bir mevsimsellik durumunu modelleyebilecek şekilde oluşturulmalıdır. Teorik olarak seride yer alabilecek bir mevsimsellik durumu YSA ile doğrudan tespit edilerek modellenabilmektedir (Crone ve Dhawan, 2007; Zhang ve Qi, 2005). Bu sebeple literatürde mevsimsellik içerebileceği düşünülen serilerde modele girdi olarak alınan gecikmeli değer sayısı kullanıcı tarafından belirlenebilmekte; örneğin aylık veriler için 12, çeyrek yıllık veri setleri için 4 gibi girdi sayıları kullanılabilir (Huang vd., 2004). Girdi sayısını belirlerken dikkate alınması gereken bir başka husus girdi sayısının çok az ya da çok fazla olmamasıdır. Girdi sayısı çok az alınırsa yetersiz bilgidir dolayısıyla model istenilen doğruluk seviyesine ulaşamayabilir. Eğer girdi sayısı çok fazla alınırsa model karmaşık hale geleceğinden modelleme çok uzun sürebilir ve aşırı uyum (*overfitting*) ile karşılaşılabılır. Aşırı uyum, geçmiş değerlerle oluşturulan modelin çok iyi uyumu sonucu yeni verilerde modelin daha yüksek tahmin hatası vermesi olarak tanımlanabilir.

Çalışmada kullanılan veriler her üç örnek için de haftalık kapanış değerleridir. Bir yılda ortalama 52 hafta olduğu düşünülürse her bir veri için bir yıllık veya yarım yıllık döngü çok sayıda girdi sebebiyle modeli karmaşık hale getirecektir. Bu sebeple geçmiş çeyrek yıl (*quarter*) girdi olarak alınmakta ve modelin girdi sayısı 13 olarak belirlenmektedir. Böylece modelde önceden varsayılmayan bazı mevsimsel ilişkiler varsa bunların da modellenmesi amaçlanmaktadır.

Modelde aşırı karmaşıklığa yer vermemek için bir adet gizli katmana (*hidden layer*) yer verilmektedir. Gizli katmanda bulunması gereken nöron sayısı ile ilgili literatürde birçok başparmak kuralı (*rule of thumb*) bulunmaktadır. Literatürde gizli nöron sayısının tespiti için en çok kullanılan yöntem, başparmak kuralları kullanılarak bazı aday modeller bulunması ve bu aday modeller arasında deneme yanılma yoluyla performans karşılaştırması yapılmasıdır (Costea, 2012: 27; Panchal vd., 2011: 333). Kaastra ve Boyd (1996), geometrik piramit kuralına göre, n adet girdi ve m adet çıktı nöronu olan 3 katmanlı bir ağ yapısı için $\sqrt{nm}$ adet gizli nöron olması gerektiğini ifade etmektedir. Bu tez çalışmasında ağ yapıları 13 girdi ve 1 çıktı nöronundan oluştuğundan, bu kural gizli nöron sayısını $\sqrt{13} \approx 4$ olarak vermektedir. Diğer taraftan Chakra vd. (2013) gizli nöron sayısının girdi ve çıktı nöron sayısının toplamının yarısı olması gerektiğini savunmaktadır. Bu durumda gizli nöron sayısı $\frac{13+1}{2} = 7$ olarak bulunmaktadır. Bir başka kural gizli nöron sayısının girdi ve çıktı büyüklüğünün $2/3$ 'ü kadar olması gerektiğini ortaya koyarken, gizli nöron sayısının girdi ve çıktı nöron sayıları arasında ve girdi nöron sayısının iki katından küçük olması gerektiğini ifade etmektedir (Panchal vd., 2011: 333). Girdi nöron sayısının fazla olması aşırı uyum sorununa yol açabileceği gibi, bu sayının az olması da yetersiz uyum (*under fitting*) sorununa yol açabilmektedir (Panchal vd., 2011: 333). Bahsedilen başparmak kuralları dikkate alınarak modelin gizli katmanı; 4, 5, 6, 7, 8 ve 9 gizli nöron sayısı için karşılaştırma yapılmakta ve her bir varlık serisi için en iyi ağ yapısı bulunmaktadır. Karşılaştırmaların uygulanmasında Fontes vd. (2013) çalışmasından faydalanılmıştır. Karşılaştırmalarda her bir finansal varlık serisi modeli için 10 defa olmak üzere, söz konusu ağ yapıları ile 10.000 iterasyon yapılarak ağ mimarileri karşılaştırılmaktadır. Her karşılaştırmada veri setinin eğitim ve doğrulama verileri rassal olarak yeniden dağıtılmakta ve ağ mimarileri için ortalama performans değerleri bulunmaktadır. Verilerin %80'i eğitim setine ve %20'si doğrulama setine ayrılmaktadır. Böylece her bir finansal varlık serisi için farklı ağ mimarileri ile toplam 100 deneme yapılmaktadır. Ağ mimarilerinin performans karşılaştırması için belirlilik katsayısı (R^2) kullanılmaktadır.

Denemeler sonucu bulunan en iyi modelin kullanılması için, veri seti programa yüklendikten sonra verilerin eğitim seti (*training set*), doğrulama seti (*validation set*) ve test seti olarak ayrılması gerekmektedir. Doğrulama seti ağın hatası ve ağırlıkların yeniden düzenlenmesi için kullanılmaktadır. Test setinde yer alan veriler ağın eğitiminde ya da öğrenmede kullanılmamakta, ağın öğrenmesi tamamlandıktan sonra modelin başarısının ölçülmesi için diğer modellerle karşılaştırma için kullanılmaktadır. Bu durumda test setinde, tahmin edilecek değer yer alacak olup her modelde sadece bir gelecek tahmini yapıldığından

sadece 1 veri test seti olarak ayrılmaktadır. Kalan verilerin %80'i eğitim setine ve %20'si doğrulama setine ayrılmaktadır. Program, verileri bu setlere rassal şekilde dağıtmaktadır.

Yapay Sinir Ağlarında kullanılan birçok aktivasyon fonksiyonu olmakla birlikte en çok kullanılan fonksiyonlar sigmoid fonksiyon grubundaki hiperbolik tanjant ve lojistik fonksiyonlardır. Hangi fonksiyonun kullanılacağıyla ilgili bir kural yoktur. Program gizli katmanlar için hiperbolik tanjant fonksiyonunu ve çıktı katmanı için lojistik fonksiyonu önermektedir. Çalışmada bu fonksiyonlar programın önerdiği şekilde kullanılmaktadır. Girdi katmanında veriler doğrudan iletildiği için herhangi bir aktivasyon fonksiyonu bulunmamaktadır.

Yapay Sinir Ağı modeliyle ilgili bir diğer önemli konu en iyi modelin nasıl elde edileceğidir. Yapay Sinir Ağı modelleri iteratif yöntemlerdir. Hatalar ağırlıkların her iterasyonda güncellenmesi yoluyla azaltılmaya çalışılır. En iyi ağ modelini belirlemek için doğrulama setinin (*validation set*) hatasına başvurulur. Her iterasyonda hata azaltılmaya çalışılsa da iterasyon sayısı arttıkça hatalar azalabileceği gibi arta da bilir. Dolayısıyla daha çok iterasyon daha az hata anlamına gelmemektedir.

Kullanılan yazılım iterasyonların nerede durdurulacağı ile ilgili bazı seçenekler sunmaktadır. Bunlardan biri önceden belirlenmiş bir hata elde edilince iterasyonun durması, bir diğeri ise yine önceden belirlenen iki iterasyon arası hata değişim değerine ulaşıldığında iterasyonun sonlandırılmasıdır. Önceden belli bir hata oranı belirlemek elde edilebilecek en küçük hatayı bulmayı engelleyebileceğinden bu çalışmada bu seçeneklerden faydalanılmamaktadır.

Yazılımın sunduğu diğer bir seçenek belli bir iterasyon sayısı önceden belirlenerek bu sayı içerisinde bulunan en iyi ağın tespit edilmesidir. İterasyon sayısının sınırlandırılmaması çok fazla zaman kaybına yol açabileceğinden bu çalışmada bu yöntem uygulanmaktadır. En iyi modelin belli bir iterasyon sayısı içinde bulunması aynı zamanda öğrenme oranına bağlıdır. Eğer öğrenme oranı düşükse belirlenen iterasyon sayısı en iyi modeli bulmak için yeterli olmayabilir. Böyle bir durumda ağ, belirlenen son iterasyon sonucunu en iyi model kabul edecektir. Hata azaltılmaya devam etmekte, ancak iterasyon sayısı sınırına takılmaktadır. Diğer taraftan öğrenme oranı yüksekse yazılım en iyi modeli belirlenen iterasyon sayısına göre çok kısa bir zamanda bulacaktır. Bu durumda bulunan modelin doğruluğu yeterli olmayabilir ve öğrenme oranı belirlenen sınır iterasyon sayısı geçilmeyecek şekilde azaltılarak model doğruluk oranı artırılabilir. Bu sebeple iterasyon sayısı için belirlenen üst sınırla birlikte bir de alt sınır belirlenmelidir.

Bu çalışmada hem çok fazla zaman kaybı yaşanmaması hem de en iyi ağı bulunabilmesi için iterasyon sayısı için alt ve üst değerler 10.000 ve 100.000 olarak seçilmiştir. İstenen iterasyon sınırlarında en iyi modelin bulunabilmesi için öğrenme oranı değiştirilmektedir. Modelleme sonucunda elde edilen en iyi ağ modeli 10.000 iterasyonun altında bulunmuşsa öğrenme değeri azaltılarak yeniden modellenmekte, 100.000'inci iterasyonda bulunmuşsa öğrenme oranı artırılarak yeniden modellenmektedir. Böylece en iyi modelin bulunduğu iterasyon sayısı $10.000 < n < 100.000$ olması sağlanmaktadır.

Kullanılan yazılımın öğrenme oranı için önerdiği rakam 0,3 ve momentum için önerdiği rakam 0,9'dur. Uygulamalarda momentum değeri değiştirilmemektedir. Herhangi bir finansal varlıkla ilgili kurulan ilk modelde, modellemeye 0,3 öğrenme oranı ile başlanmaktadır. Sonuç 100.000 iterasyon içerisinde bulunacak şekilde öğrenme oranı artırılmakta ya da azaltılmaktadır. Uygun öğrenme oranı bulunduktan sonra, aynı finansal varlık için kurulan ikinci modelde öğrenme oranı olarak ilk modeldeki öğrenme oranı alınarak başlanmakta, gerekli olursa artırılıp azaltılmaktadır. Öğrenme oranının artırılıp azaltılması, 0-1 aralığında 0,1 birim artırıp azaltarak, 1-2 aralığında 0,5 birim artırılıp azaltılarak ve 2'den büyük durumlarda 1 birim azaltılıp artırılarak gerçekleştirilmektedir.

Çalışmada öğrenme için Geri Yayılım yöntemi kullanılmaktadır. Program iki alternatif Geri Yayılım yöntemi sunmaktadır. Bunlardan Online Geri Yayılım (*Online Back Propagation*) veri setindeki her örnekleme farklı ağırlık değerleri vermekte, iterasyonlar sonucu ağırlık değerleri her iterasyon için aynı değerlere ulaşmaktadır. Diğer taraftan Yığın Geri Yayılım (*Batch Back Propagation*) yönteminde her örneklem için aynı ağırlık değerleri kullanılır. Ağırlık değerleri her iterasyondan sonra güncellenerek hata azaltılmaya çalışılır. Bu çalışmada yığın geri yayılım yöntemi kullanılmaktadır.

YSA ile yapılan modelleme sonucunda bulunan en iyi model ile birlikte, model değerleri ve tahmin değeri elde edilir. Kullanılan program gerçek ve model değerlerin grafiğini, gerçek ve model değerlerin saçılım grafiğini, iterasyonlar boyunca mutlak hatanın değişim grafiğini ve iterasyonlar boyunca ağı hata değerinin değişim grafiğini vermektedir. Ayrıca eğitim, doğrulama ve test veri setleri ile tüm veri setinin ortalama model ve hata değerleri gibi sonuçlar elde edilmektedir. Kullanılan YSA modeli 13 girdili olduğundan veri setlerinde yer alan ilk 13 veri için herhangi bir model veya hata değeri bulunmamaktadır.

YSA modeliyle bulunan model ve hata değerleri Optimize ARIMA – YSA Hibrit Modelinin ileriki aşamalarında kullanıldığı gibi, hibrit modelin YSA modeliyle karşılaştırılmasında da kullanılmaktadır. YSA modeliyle elde edilen gelecek tahmin değeri ise

hibrit modelde kullanılmamakta, sadece serinin YSA tahmini olarak modellerin karşılaştırılmasında kullanılmaktadır.

4.3.3. Optimizasyon Süreci

Optimizasyon sürecinde ARIMA ve YSA ile bulunan model değerleri kullanılarak model hatasını minimum hale getirecek en iyi doğrusal (α) ve doğrusal olmayan (β) katsayının bulunması hedeflenmektedir. Hatanın minimize edilmesi için En Küçük Kareler Optimizasyonu yöntemi tercih edilmektedir. Bu şekilde hata kareler toplamını en küçük yapan α ve β değerleri bulunmaktadır. Aynı zamanda $\alpha \geq 0$, $\beta \geq 0$ ve $\alpha + \beta = 1$ eşitlik ve eşitsizlikleri problemin kısıtları olmaktadır. YSA, veri setindeki ilk 13 değeri modellemediğinden optimizasyon ilk 13 veri olmadan yapılmaktadır.

Optimizasyon süreci MS Excel programının Solver eklentisi kullanılarak tamamlanmaktadır. Program optimizasyon için 2 seçenek sunmaktadır. Bunlardan Doğrusal Programlama seçeneği problemi çözmekte yetersiz kalmaktadır. Bu sebeple optimizasyon için diğer alternatif olan GRG Nonlinear (Doğrusal Olmayan Genelleştirilmiş Azaltılmış Eğitim) yöntemine başvurulmaktadır.

Optimizasyon sonucunda en iyi doğrusal ve doğrusal olmayan katsayı ile en küçüklenen toplam hata kare değerleri elde edilir.

4.3.4. Yapay Zaman Serisinin Oluşturulması ve YSA ile Modellenmesi Süreci

Optimizasyon sürecinde elde edilen α ve β değerleri kullanılarak $\frac{\alpha}{\beta}$ katsayısı bulunur. Bulunan katsayı ARIMA ile yapılan modellemede elde edilen hata serisi ε_t^{ARIMA} ile çarpılarak modellenen zaman serisi y_t 'ye eklenir. Böylece yapay zaman serisi n_t elde edilmektedir.

Elde edilen yeni serinin YSA ile modellenmesi orijinal serinin YSA ile modellenmesiyle aynı aşamaları içerir. Modellemede kullanılan ağ mimarisi, öğrenme yöntemi, aktivasyon fonksiyonu gibi model parametreleri ile model sonucu elde edilen çıktı türleri ikinci aşamadaki YSA modellemesiyle aynıdır. Yapay serinin YSA ile modellenmesi sonucu elde edilen model ve hata değerleri ile gelecek tahmin değeri Optimize ARIMA – YSA Hibrit Modeli sürecinin bir sonraki aşamasında kullanılmaktadır.

4.3.5. Optimize ARIMA – YSA Hibrit Modelin Oluşturulması

Optimize ARIMA – YSA Hibrit Modelin model değerleri, her bir ARIMA model değerinin α ile ve YSA (n_t için) model değerinin β ile çarpılıp, bu çarpımların toplanmasıyla bulunur. Gelecek tahmini ise benzer şekilde ARIMA modeli tahminin α ve YSA (n_t)

tahmininin β ile çarpılarak toplanmasıyla elde edilir. Gerçek değerler ve elde edilen model değerler kullanılarak Optimize ARIMA – YSA Hibrit Modeli için model ve gelecek tahmini hata değerleri hesaplanmaktadır.

YSA ile ARIMA modellemelerinin bir farkı olarak, ARIMA modeli eldeki serinin tamamını modellerken YSA modeli baştan girdi sayısınca veriyi modellememektedir. Bu sebeple, Optimize ARIMA – YSA Hibrit Modelin elde edilmesi aşamalarının bazılarında YSA girdi sayısı olan ilk 13 veri işlemlere dahil edilirken, bazılarında işlem dışında tutulmaktadır.

Birinci aşamada ARIMA ile yapılan modelleme sonucunda ilk 13 veri için model ve hata değerleri elde edilir. İkinci aşamada seri YSA ile modellendiğinden ilk 13 veri için model ve hata değerleri bulunmamaktadır. Üçüncü aşama olan optimizasyon aşamasında YSA modeli sonuçlarında ilk 13 veri için model değerleri olmadığından bu veriler için ARIMA model değerleri de işleme alınmaz. Dördüncü aşamada yapay zaman serisi n_t oluşturulurken ilk 13 veri için ARIMA hata değerleri de işleme alınır ve yapay zaman serisinin ilk 13 değer için de karşılıkları elde edilmiş olur. Ancak yapay serinin YSA ile yapılan modellemesi sonucu bu ilk 13 veri için model ve hata değerleri elde edilmez. Son aşamada hibrit model değerleri oluşturulurken dördüncü aşamada yapay serinin YSA ile modellenmesi sonucu bulunan model değerlerinde ilk 13 veri olmadığından birinci aşamada ARIMA ile bulunan ilk 13 verinin model değerleri işleme alınmaz. Model sonuçlarının karşılaştırılması esnasında Optimize ARIMA – YSA Modeli ve YSA modeli ilk 13 değer için model değeri bulundurmadığından ARIMA model sonuçları hesaplanırken ilk 13 verinin model değerleri kullanılmamaktadır.

4.4. Sonuçlar

Bu çalışmada üç ayrı finansal varlığın haftalık kapanış değerleri için 10 adet gelecek tahmini yapılmakta ve her tahmin için ayrı model kurulmaktadır. Böylece her finansal zaman serisi için 10 adet olmak üzere toplam 30 adet model kurulmaktadır. t zamanındaki veri y_t 'yi tahmin için kullanılacak veri seti $y_1, y_2, \dots, y_{t-1}$ olurken, $t+1$ zamanı için yapılan tahminde veri seti $y_1, y_2, \dots, y_{t-1}, y_t$ olmaktadır. Bu sebeple her üç veri setinde tahmin için ayrılan son 10 veriden 9'u aynı zamanda kendinden sonraki haftaların tahmininde modelleme içerisinde kullanılmaktadır. Her üç finansal zaman serisi için modellemeler aynı aşamalardan geçmektedir.

Modelleme ve sonuçlarda her model hangi haftanın kapanış değerini tahmin etmek için kurulduysa o haftanın Cuma günü tarihiyle gösterilmektedir. Örneğin 17.02.2017 tarihiyle gösterilen model 13.02.2017 Pazartesi günü başlayan haftanın kapanış değerini tahmin amacıyla kurulmuş olan modeldir.

Model ve tahmin hatalarının değerlendirilmesinde bazı hata değerlendirme modelleri kullanılmaktadır. Bu çalışmada hataların tanımlanması için kullanılan modeller aşağıdaki gibidir:

- Toplam Hata Kare (*Sum of Squared Errors*): Modellerin gerçek veri setiyle karşılaştırılması için kullanılmaktadır. Aşağıdaki gibi tanımlanır:

$$SSE = \sum_{i=1}^n (y_i - y'_i)^2 \quad (4.1)$$

- Ortalama Hata Kare (*Mean Squared Errors*): Modelin gerçek veri setine göre performansı için kullanılmaktadır. Toplam hata karenin veri setine göre ortalamasıdır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2 \quad (4.2)$$

- Karekök Ortalama Hata Kare (*Root Mean Squared Error*): Model performansı tespiti için kullanılmaktadır. Ortalama hata kare değerinin kareköküdür.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (4.3)$$

- Ortalama Mutlak Hata (*Mean Absolute Error*): Modelleme hatası için kullanılmaktadır. Bu çalışmada özellikle YSA modellerinde kullanılan yazılım tarafından eğitim ve doğrulama serileri için hesaplanmaktadır.

$$MAE = \frac{\sum_{i=1}^n |y_i - y'_i|}{n} \quad (4.4)$$

- Ortalama Mutlak Yüzde Hata (*Mean Absolute Percentage Error*): Model hatasını yüzdelik olarak ifade etmektedir.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left(\frac{y_i - y'_i}{y_i} \right) \quad (4.5)$$

- Mutlak Hata (*Absolute Error*): Tek bir gerçek değer için yapılan tahmin hatasının sayısal büyüklüğü için kullanılmaktadır.

$$AE = |y_i - y'_i| \quad (4.6)$$

- Mutlak Yüzde Hata (*Absolute Percentage Error*): Gerçek bir değer için yapılan tahmin hatasını yüzdelik olarak ifade etmektedir.

$$APE = 100 \left| \frac{y_i - y'_i}{y_i} \right| \quad (4.7)$$

- Theil's U İstatistiği: Tahmin performansının değerlendirilmesi için kullanılmaktadır. Model tahminlerinin naive model (rassal yürüyüş modeli) ile kıyaslanması sağlanmaktadır. İstatistik değeri 1'den küçükse, model rassal yürüyüş modelinden daha iyidir ve güvenilir olduğu kabul edilir.

$$Theil's U = \sqrt{\frac{\sum_{t=1}^{n-1} \left(\frac{F_{t+1} - Y_{t+1}}{Y_t} \right)^2}{\sum_{t=1}^{n-1} \left(\frac{Y_{t+1} - Y_t}{Y_t} \right)^2}} \quad (4.8)$$

4.4.1. ARIMA Süreci

ARIMA sürecinde 23.12.2016 Cuma ile biten hafta ile 24.02.2017 Cuma günü kapanan hafta arasındaki 10 hafta için Spot Altın, BIST 30 Endeksi ve USD/TRY Döviz kuru haftalık kapanış değerleri modellenmekte ve söz konusu kapanış değerleri için tahminler yapılmaktadır. Her bir zaman serisi için kurulan toplam 30 modelde kullanılan veri setleriyle ilgili tanımlayıcı bilgiler Tablo 4.6, Tablo 4.7 ve Tablo 4.8’de yer almaktadır.

Tablo 4.6. Spot Altın Fiyatı Serileri için Tanımlayıcı Bilgiler

Hafta	Kullanılan Veri Sayısı	En Küçük	En Büyük	Ortalama	Standart Sapma
23.12.2016	1982	217,6000	1875,2500	598,6250	402,2234
30.12.2016	1983	217,6000	1875,2500	598,8936	402,2998
06.01.2017	1984	217,6000	1875,2500	599,1693	402,3858
13.01.2017	1985	217,6000	1875,2500	599,4598	402,4925
20.01.2017	1986	217,6000	1875,2500	599,7574	402,6095
27.01.2017	1987	217,6000	1875,2500	600,0597	402,7338
03.02.2017	1988	217,6000	1875,2500	600,3539	402,8460
10.02.2017	1989	217,6000	1875,2500	600,6630	402,9805
17.02.2017	1990	217,6000	1875,2500	600,9784	403,1248
24.02.2017	1991	217,6000	1875,2500	601,3004	403,2794

Tablo 4.7. BIST 30 Endeksi Serileri için Tanımlayıcı Bilgiler

Hafta	Kullanılan Veri Sayısı	En Küçük	En Büyük	Ortalama	Standart Sapma
23.12.2016	1032	1155,00	114061,79	47794,94	33776,41
30.12.2016	1033	1155,00	114061,79	47839,88	33790,92
06.01.2017	1034	1155,00	114061,79	47885,97	33807,06
13.01.2017	1035	1155,00	114061,79	47930,42	33820,96
20.01.2017	1036	1155,00	114061,79	47980,30	33842,72
27.01.2017	1037	1155,00	114061,79	48031,76	33866,94
03.02.2017	1038	1155,00	114061,79	48084,29	33892,90
10.02.2017	1039	1155,00	114061,79	48142,47	33928,43
17.02.2017	1040	1155,00	114061,79	48199,18	33961,39
24.02.2017	1041	1155,00	114061,79	48257,70	33997,51

Tablo 4.8. USD/TRY Kuru Serileri için Tanımlayıcı Bilgiler

Hafta	Kullanılan Veri Sayısı	En Küçük	En Büyük	Ortalama	Standart Sapma
23.12.2016	1032	1,1526	3,5190	1,8151	0,5474
30.12.2016	1033	1,1526	3,5190	1,8178	0,5512
06.01.2017	1034	1,1526	3,5277	1,8206	0,5550
13.01.2017	1035	1,1526	3,6445	1,8235	0,5594
20.01.2017	1036	1,1526	3,7230	1,8266	0,5641
27.01.2017	1037	1,1526	3,7655	1,8297	0,5689
03.02.2017	1038	1,1526	3,8775	1,8330	0,5744
10.02.2017	1039	1,1526	3,8775	1,8359	0,5787
17.02.2017	1040	1,1526	3,8775	1,8389	0,5830
24.02.2017	1041	1,1526	3,8775	1,8417	0,5869

Sürecin ARIMA aşamasında her bir modelleme için en iyi ARIMA(p,d,q) modeli bulunmaktadır. En iyi ARIMA(p,d,q) modelinin bulunması bölüm 4.3.1.' de anlatılan adım arama yöntemiyle yapılmaktadır. Spot Altın Fiyatı, BIST 30 Endeksi ve USD/TRY Kuru modelleri için yapılan aramalar ve bulunan en iyi modeller AICc değerleriyle birlikte Ek 1, Ek 2 ve Ek 3'te yer almaktadır.

Spot Altın Fiyatı, BIST 30 Endeksi ve USD/TRY Kuru modelleri için aramalar sonucu bulunan en iyi ARIMA(p,d,q) modelleri Tablo 4.9'da gösterilmektedir.

Tablo 4.9. Tahmin Modelleri için Bulunan En İyi ARIMA(p,d,q) Modelleri

Hafta	En İyi ARIMA(p,d,q) Modeli		
	Spot Altın Fiyatı	BIST 30 Endeksi	USD/TRY Kuru
23.12.16	(2,1,2)	(2,1,2)	(2,1,2)
30.12.16	(2,1,2)	(2,1,2)	(2,1,2)
06.01.17	(2,1,2)	(2,1,2)	(2,1,2)
13.01.17	(2,1,2)	(2,1,2)	(2,1,2)
20.01.17	(3,1,2)	(2,1,2)	(2,1,2)
27.01.17	(2,1,2)	(2,1,2)	(2,1,2)
03.02.17	(2,1,2)	(2,1,2)	(2,1,2)
10.02.17	(2,1,2)	(2,1,2)	(2,1,2)
17.02.17	(2,1,2)	(2,1,2)	(2,1,2)
24.02.17	(2,1,2)	(2,1,2)	(3,1,2)

Tüm modeller için seriyi durağan yapan en küçük entegre değer $d=1$ olarak bulunmaktadır. p ve q değerleri için yapılan en iyi model aramalarında Spot Altın Fiyatı modelleri arasında 20.01.2017 haftası için kurulan model ARIMA(3,1,2) bulunmaktadır. Ayrıca USD/TRY Kuru için kurulan modeller içinde 24.02.2017 haftası için elde edilen model

ARIMA(3,1,2) olarak bulunurken, Spot Altın Fiyatları ve USD/TRY Kuru için bulunan diğer modeller ile BIST 30 Endeksi için bulunan en iyi modellerin tamamı ARIMA(2,1,2) olarak tespit edilmektedir. 30 modelin 28'inde aramalar 2 aşamada sonlanırken sadece 2 model için en iyi model araması 3 aşama sürmektedir.

Spot Altın Fiyatı, BIST 30 Endeksi ve USD/TRY Kuru serilerinin ARIMA ile yapılan modellemeleri sonucu elde edilen model hata değerleri sırasıyla Tablo 4.10, Tablo 4.11 ve Tablo 4.12'de verilmektedir.

Tablo 4.10. Spot Altın Fiyatı ARIMA Modelleri ile Bulunan Model Hata Değerleri

Hafta	Toplam Hata Kare (SSE)	Ortalama Hata Kare (MSE)	Ortalama Hata Karelerin Karekökü (RMSE)	Ortalama Mutlak Yüzde Hata (%) (MAPE)
23.12.2016	774715,9482	391,0732	19,7756	1,789%
30.12.2016	774697,6623	390,8666	19,7703	1,788%
06.01.2017	775061,7335	390,8531	19,7700	1,788%
13.01.2017	775990,6338	391,1243	19,7769	1,788%
20.01.2017	775423,5139	390,6416	19,7647	1,792%
27.01.2017	776134,7890	390,8030	19,7687	1,788%
03.02.2017	776311,8391	390,6954	19,7660	1,787%
10.02.2017	777481,4511	391,0872	19,7759	1,787%
17.02.2017	777661,0701	390,9809	19,7732	1,787%
24.02.2017	777738,8625	390,8235	19,7693	1,787%

Tablo 4.11. BIST 30 Endeksi ARIMA Modelleri ile Bulunan Model Hata Değerleri

Hafta	Toplam Hata Kare (SSE)	Ortalama Hata Kare (MSE)	Ortalama Hata Karelerin Karekökü (RMSE)	Ortalama Mutlak Yüzde Hata (%) (MAPE)
23.12.2016	4708594102,1590	4567016,5879	2137,0579	3,978%
30.12.2016	4678671917,0589	4533596,8189	2129,2245	3,985%
06.01.2017	4681239472,1589	4531693,5839	2128,7775	3,982%
13.01.2017	4683308634,5282	4529312,0257	2128,2180	3,980%
20.01.2017	4709836185,3373	4550566,3626	2133,2057	3,983%
27.01.2017	4715030820,5641	4551188,0507	2133,3514	3,980%
03.02.2017	4716190274,9857	4547917,3336	2132,5847	3,978%
10.02.2017	4746693797,3794	4572922,7335	2138,4393	3,980%
17.02.2017	4747254209,2594	4569060,8366	2137,5362	3,978%
24.02.2017	4749650897,6025	4566972,0169	2137,0475	3,976%

Tablo 4.12. USD/TRY Kuru ARIMA Modelleri ile Bulunan Model Hata Değerleri

Hafta	Toplam Hata Kare (SSE)	Ortalama Hata Kare (MSE)	Ortalama Hata Karelerin Karekökü (RMSE)	Ortalama Mutlak Yüzde Hata (MAPE)
23.12.2016	0,7423	0,0012	0,0347	1,352%
30.12.2016	0,7427	0,0012	0,0346	1,351%
06.01.2017	0,7427	0,0012	0,0346	1,349%
13.01.2017	0,7538	0,0012	0,0348	1,353%
20.01.2017	0,7605	0,0012	0,0350	1,354%
27.01.2017	0,7628	0,0012	0,0350	1,354%
03.02.2017	0,7737	0,0012	0,0352	1,356%
10.02.2017	0,8150	0,0013	0,0361	1,365%
17.02.2017	0,8150	0,0013	0,0361	1,363%
24.02.2017	0,8180	0,0013	0,0361	1,363%

Her bir model için uygulanan ARIMA modelleri sonucu, modellerdeki AR(p) ve MA(q) katsayıları bulunmaktadır. Her model için bulunan otoregresif ve hareketli ortalamalar model katsayıları Tablo 4.13, Tablo 4.14 ve Tablo 4.15’de gösterilmektedir.

Tablo 4.13. Spot Altın Fiyatı ARIMA Modelleri için AR(p) ve MA(q) Katsayıları

Hafta	AR(1)	AR(2)	AR(3)	MA(1)	MA(2)
23.12.2016	0,4111	-0,9314		-0,4240	0,9762
30.12.2016	0,4135	-0,9334		-0,4255	0,9775
06.01.2017	0,4140	-0,9339		-0,4257	0,9775
13.01.2017	0,4147	-0,9335		-0,4259	0,9773
20.01.2017	0,3912	-0,9213	-0,0303	-0,4292	0,9778
27.01.2017	0,4145	-0,9332		-0,4258	0,9772
03.02.2017	0,4145	-0,9329		-0,4257	0,9771
10.02.2017	0,4150	-0,9333		-0,4258	0,9770
17.02.2017	0,4151	-0,9332		-0,4258	0,9769
24.02.2017	0,4152	-0,9330		-0,4258	0,9770

Tablo 4.14. BIST 30 Endeksi ARIMA Modelleri için AR(p) ve MA(q) Katsayıları

Hafta	AR(1)	AR(2)	MA(1)	MA(2)
23.12.2016	-1,0308	-0,9581	1,0114	0,9872
30.12.2016	-1,0321	-0,9657	1,0180	1,0000
06.01.2017	-1,0322	-0,9659	1,0180	1,0000
13.01.2017	-1,0326	-0,9661	1,0181	1,0000
20.01.2017	-1,0334	-0,9660	1,0183	1,0000
27.01.2017	-1,0334	-0,9663	1,0183	1,0000
03.02.2017	-1,0331	-0,9661	1,0182	1,0000
10.02.2017	-1,0343	-0,9664	1,0185	1,0000
17.02.2017	-1,0343	-0,9663	1,0185	1,0000
24.02.2017	-1,0341	-0,9660	1,0184	1,0000

Tablo 4.15. USD/TRY Endeksi ARIMA Modelleri için AR(p) ve MA(q) Katsayıları

Hafta	AR(1)	AR(2)	AR(3)	MA(1)	MA(2)
23.12.2016	0,0227	-0,9701		0,0088	1,0000
30.12.2016	0,0226	-0,9707		0,0087	1,0000
06.01.2017	0,0227	-0,9707		0,0087	1,0000
13.01.2017	0,0235	-0,9678		0,0091	1,0000
20.01.2017	0,0218	-0,9671		0,0093	1,0000
27.01.2017	0,0218	-0,9679		0,0093	1,0000
03.02.2017	0,0241	-0,9678		0,0091	1,0000
10.02.2017	0,0065	-0,9532		0,0253	0,9845
17.02.2017	0,0060	-0,9530		0,0256	0,9845
24.02.2017	0,0066	-0,9508	-0,0033	0,0236	0,9835

Her bir modelleme için artıkların otokorelasyon ve kısmi otokorelasyon fonksiyonları incelenerek limit değerleri aşan otokorelasyon ve kısmi otokorelasyon değerleri tespit edilmekte ve bu değerlerin hangi gecikmeli verilere ait olduğu saptanarak seride göz ardı edilen bir mevsimsellik durumu olup olmadığı anlaşılmaktadır. Otokorelasyon ve kısmi otokorelasyon fonksiyonlarına göre limit değerleri aşan gecikmeler Ek 4’te yer almaktadır. Bulunan sonuçlar incelendiğine modellerde göz ardı edilen bir mevsimsellik durumu olmadığı anlaşılmaktadır.

Her modelleme sonucunda artık serilere Ljung – Box Q testi uygulanmakta ve artık serilerinin beyaz gürültü özelliği gösterdiği tespit edilmektedir. Modeller için Ljung – Box Q test değerleri Ek 5’de görülebilir.

ARIMA ile yapılan modellemeler sonucunda gelecek tahmin değerleri elde edilmektedir. Gelecek tahmin değerleri, gerçek değerler ve bu tahminlerin gerçek verilere göre hata değerleri Tablo 4.16, Tablo 4.17 ve Tablo 4.18’de gösterilmektedir.

Tablo 4.16. Spot Altın Fiyatı ARIMA Modelleri Tahmin Değerleri, Gerçek Değerler ve Tahmin Hata Değerleri

Hafta	Gerçek Değer	ARIMA Tahmini	Mutlak Yüzde Hata (APE)	Mutlak Hata (AE)
23.12.2016	1131,35	1129,93	0,126%	1,42
30.12.2016	1145,90	1126,83	1,664%	19,07
06.01.2017	1175,85	1145,37	2,592%	30,48
13.01.2017	1190,35	1180,32	0,843%	10,03
20.01.2017	1200,55	1193,05	0,625%	7,50
27.01.2017	1184,85	1198,17	1,124%	13,32
03.02.2017	1215,20	1181,03	2,812%	34,17
10.02.2017	1228,30	1214,91	1,090%	13,39
17.02.2017	1241,95	1233,06	0,716%	8,89
24.02.2017	1253,65	1244,66	0,717%	8,99
ORTALAMA			1,231%	14,73


Tablo 4.17. BIST 30 Endeksi ARIMA Modelleri Tahmin Değerleri, Gerçek Değerler ve Tahmin Hata Değerleri

Tarih	Gerçek Değer	ARIMA Tahmini	Mutlak Yüzde Hata (APE)	Mutlak Hata (AE)
23.12.2016	94209,98	95541,33	1,413%	1331,35
30.12.2016	95498,58	93893,04	1,681%	1605,54
06.01.2017	93891,90	95350,69	1,554%	1458,79
13.01.2017	99607,09	94424,58	5,203%	5182,51
20.01.2017	101342,67	99067,70	2,245%	2274,97
27.01.2017	102563,05	101486,09	1,050%	1076,96
03.02.2017	108530,99	102970,42	5,123%	5560,57
10.02.2017	107123,70	107887,81	0,713%	764,11
17.02.2017	109112,23	107553,28	1,429%	1558,95
24.02.2017	108377,63	109224,45	0,781%	846,82
ORTALAMA			2,119%	2166,06


Tablo 4.18. USD/TRY Kuru ARIMA Modelleri Tahmin Değerleri, Gerçek Değerler ve Tahmin Hata Değerleri

Tarih	Gerçek Değer	ARIMA Tahmini	Mutlak Yüzde Hata (APE)	Mutlak Hata (AE)
23.12.2016	3,5169	3,4968	0,572%	0,0201
30.12.2016	3,5277	3,5241	0,103%	0,0036
06.01.2017	3,6445	3,5381	2,919%	0,1064
13.01.2017	3,7230	3,6412	2,197%	0,0818
20.01.2017	3,7655	3,7174	1,276%	0,0481
27.01.2017	3,8775	3,7720	2,720%	0,1055
03.02.2017	3,6976	3,8876	5,139%	0,1900
10.02.2017	3,6953	3,6911	0,115%	0,0042
17.02.2017	3,6290	3,6842	1,521%	0,0552
24.02.2017	3,6070	3,6339	0,747%	0,0269
ORTALAMA			1,731%	0,0642


Spot Altın Fiyatı, BIST 30 Endeksi ve USD/TRY Kuru için kurulan ARIMA modelleri ile elde edilen tahmin değerleri ve gerçek değerler sırasıyla Şekil 4.4, Şekil 4.5 ve Şekil 4.6'da yer almaktadır.



Şekil 4.4. Spot Altın Fiyatı Gerçek Değerler ve ARIMA Tahmin Değerleri



Şekil 4.5. BIST 30 Endeksi Gerçek Değerler ve ARIMA Tahmin Değerleri



Şekil 4.6. USD/TRY Kuru Gerçek Değerler ve ARIMA Tahmin Değerleri

4.4.2. Yapay Sinir Ağları Süreci

ARIMA ile modelleme süreci tamamlandıktan sonra zaman serisi Yapay Sinir Ağları ile modellenmektedir. YSA modelleme sürecinin ilk adımı olarak her bir finansal varlık serisi için en iyi model belirlenmektedir. Gizli nöron sayısı 4 ve 9 arasında değiştirilerek elde edilen farklı ağ mimarileri arasında yapılan denemeler sonucu elde edilen sonuçlar ve bulunan en iyi ağ mimarileri Tablo 4.19’da yer almaktadır. Tablo 4.19’da elde edilen değerler, her bir model için yapılan 10 deneme ve her bir finansal varlık için toplam 100 deneme için elde edilen ortalama değerleri ifade etmektedir. Her denemede ağ mimarileri 10.000 iterasyon sonucu bulunan belirlilik katsayıları (R^2) ile karşılaştırılmaktadır.

Tablo 4.19. Yapay Sinir Ağları Model Arama Sonuçları

	Mimari	Eğitim Verileri Mutlak Hata (Ortalama)	Doğrulama Verileri Mutlak Hata (Ortalama)	Belirlilik Katsayısı (R2) (Ortalama)
SPOT ALTIN FIYATI	[13-4-1]	21,06	21,03	0,99457
	[13-5-1]	20,69	20,62	0,99472
	[13-6-1]	19,87	19,91	0,99502
	[13-7-1]	20,20	20,12	0,99492
	[13-8-1]	20,09	20,11	0,99497
	[13-9-1]	20,45	20,42	0,99478
BIST 30 ENDEKSİ	[13-4-1]	2147,19	2211,76	0,99343
	[13-5-1]	2135,37	2203,93	0,99349
	[13-6-1]	2082,95	2152,53	0,99374
	[13-7-1]	2135,56	2200,59	0,99350
	[13-8-1]	2099,40	2165,83	0,99367
	[13-9-1]	2117,96	2185,69	0,99353
USD/TRY KURU	[13-4-1]	0,0343	0,0369	0,99306
	[13-5-1]	0,0332	0,0354	0,99339
	[13-6-1]	0,0321	0,0346	0,99374
	[13-7-1]	0,0336	0,0359	0,99331
	[13-8-1]	0,0333	0,0357	0,99340
	[13-9-1]	0,0332	0,0357	0,99340

Yapılan denemeler sonucu her bir finansal varlık serisi için en iyi model 13-6-1 olarak bulunmaktadır. Spot Altın Fiyatı, BIST 30 Endeksi ve USD/TRY Kuru için elde edilen her bir modelde, kullanılan öğrenme oranı ile modelin eğitim ve doğrulama setlerine göre hata değerleri Tablo 4.20, Tablo 4.21 ve Tablo 4.22’de yer almaktadır.

Tablo 4.20. Spot Altın Fiyatı YSA Modelleri için Öğrenme Oranı ile Eğitim ve Doğrulama Setlerine Göre Hata Değerleri

		EĞİTİM SETİ (TRAINING SET)		DOĞRULAMA SETİ (VALIDATION SET)	
Tarih	Öğrenme Oranı	Ortalama Mutlak Hata (MAE)	Ortalama Mutlak Yüzde Hata (MAPE)	Ortalama Mutlak Hata (MAE)	Ortalama Mutlak Yüzde Hata (MAPE)
23.12.2016	1,00	11,7425	1,9428%	13,3763	2,1519%
30.12.2016	1,00	11,3615	1,8020%	11,9858	1,8363%
06.01.2017	1,00	11,7392	1,8738%	12,0189	1,9674%
13.01.2017	3,00	12,0473	1,9684%	11,8038	1,9044%
20.01.2017	2,00	11,8476	1,9157%	12,1451	1,9189%
27.01.2017	2,00	11,4842	1,8138%	12,1883	1,8742%
03.02.2017	1,00	11,6999	1,8916%	12,1771	1,9065%
10.02.2017	4,00	11,4122	1,7901%	11,8820	1,8764%
17.02.2017	1,00	11,4974	1,7968%	12,5658	2,0326%
24.02.2017	2,00	11,3527	1,8181%	12,6033	1,8996%

Tablo 4.21. BIST 30 Endeksi YSA Modelleri için Öğrenme Oranı ile Eğitim ve Doğrulama Setlerine Göre Hata Değerleri

Tarih	Öğrenme Oranı	EĞİTİM SETİ (TRAINING SET)		DOĞRULAMA SETİ (VALIDATION SET)	
		Ortalama Mutlak Hata (MAE)	Ortalama Mutlak Yüzde Hata (MAPE)	Ortalama Mutlak Hata (MAE)	Ortalama Mutlak Yüzde Hata (MAPE)
23.12.2016	0,40	1468,80	4,566%	1620,05	5,135%
30.12.2016	0,30	1524,51	5,168%	1464,81	4,794%
06.01.2017	0,40	1487,24	4,569%	1551,00	4,627%
13.01.2017	0,30	1512,23	5,086%	1507,43	5,121%
20.01.2017	1,00	1572,40	6,969%	1621,57	6,954%
27.01.2017	0,30	1561,51	5,856%	1522,42	5,993%
03.02.2017	0,30	1512,68	4,645%	1466,44	4,723%
10.02.2017	0,40	1471,96	4,515%	1650,95	5,103%
17.02.2017	0,80	1469,07	4,500%	1614,19	4,659%
24.02.2017	0,30	1522,61	4,706%	1479,51	4,654%

Tablo 4.22. USD/TRY Kuru YSA Modelleri için Öğrenme Oranı ile Eğitim ve Doğrulama Setlerine Göre Hata Değerleri

Tarih	Öğrenme Oranı	EĞİTİM SETİ (TRAINING SET)		DOĞRULAMA SETİ (VALIDATION SET)	
		Ortalama Mutlak Hata (MAE)	Ortalama Mutlak Yüzde Hata (MAPE)	Ortalama Mutlak Hata (MAE)	Ortalama Mutlak Yüzde Hata (MAPE)
23.12.2016	0,40	0,0248	1,364%	0,0265	1,460%
30.12.2016	0,30	0,0244	1,352%	0,0274	1,467%
06.01.2017	0,60	0,0243	1,347%	0,0288	1,626%
13.01.2017	0,60	0,0239	1,324%	0,0287	1,564%
20.01.2017	1,00	0,0244	1,342%	0,0262	1,426%
27.01.2017	1,00	0,0237	1,315%	0,0278	1,489%
03.02.2017	0,60	0,0239	1,331%	0,0282	1,480%
10.02.2017	0,60	0,0245	1,333%	0,0279	1,508%
17.02.2017	0,30	0,0241	1,313%	0,0302	1,642%
24.02.2017	1,00	0,0243	1,329%	0,0267	1,457%

YSA ile yapılan modellemeler sonucunda her bir model için elde edilen toplam hata kare, ortalama hata kare, ortalama hata karelerin karekökü ve ortalama mutlak yüzde hata değerleri Tablo 4.23, Tablo 4.24 ve Tablo 4.25’de yer almaktadır.

Tablo 4.23. Spot Altın Fiyatı YSA Modelleri için Model Hata Değerleri

Hafta	Toplam Hata Kare (SSE)	Ortalama Hata Kare (MSE)	Ortalama Hata Karelerin Karekökü (RMSE)	Ortalama Mutlak Yüzde Hata (MAPE)
23.12.2016	781847,1985	397,0783	19,9268	1,985%
30.12.2016	749735,3905	380,5763	19,5084	1,809%
06.01.2017	774777,5797	393,0886	19,8265	1,893%
13.01.2017	796782,7069	404,0480	20,1009	1,956%
20.01.2017	799304,9537	405,1216	20,1276	1,916%
27.01.2017	758262,7664	384,1250	19,5991	1,826%
03.02.2017	760825,2777	385,2280	19,6272	1,895%
10.02.2017	792920,8779	401,2757	20,0319	1,807%
17.02.2017	807633,1726	408,5145	20,2117	1,844%
24.02.2017	756033,9004	382,2214	19,5505	1,834%

Tablo 4.24. BIST 30 Endeksi YSA Modelleri için Model Hata Değerleri

Hafta	Toplam Hata Kare (SSE)	Ortalama Hata Kare (MSE)	Ortalama Hata Karelerin Karekökü (RMSE)	Ortalama Mutlak Yüzde Hata (MAPE)
23.12.2016	4696455197,0952	4608886,3563	2146,8317	4,680%
30.12.2016	4700000166,7522	4607843,3007	2146,5888	5,093%
06.01.2017	4714907239,1194	4617930,6945	2148,9371	4,580%
13.01.2017	4698691974,0367	4597545,9629	2144,1889	5,093%
20.01.2017	4951428068,2032	4840105,6385	2200,0240	6,966%
27.01.2017	4926612545,4824	4811145,0639	2193,4323	5,884%
03.02.2017	4753141347,9691	4637211,0712	2153,4185	4,662%
10.02.2017	4791831318,9060	4670400,8956	2161,1110	4,632%
17.02.2017	4743970920,1283	4619251,1394	2149,2443	4,531%
24.02.2017	4792402204,2707	4661869,8485	2159,1364	4,695%

Tablo 4.25. USD/TRY Kuru YSA Modelleri için Model Hata Değerleri

Hafta	Toplam Hata Kare (SSE)	Ortalama Hata Kare (MSE)	Ortalama Hata Karelerin Karekökü (RMSE)	Ortalama Mutlak Yüzde Hata (MAPE)
23.12.2016	0,7871	0,0013	0,0360	1,383%
30.12.2016	0,7577	0,0013	0,0353	1,375%
06.01.2017	0,7639	0,0013	0,0355	1,382%
13.01.2017	0,7692	0,0013	0,0355	1,372%
20.01.2017	0,7603	0,0013	0,0353	1,358%
27.01.2017	0,7243	0,0012	0,0344	1,350%
03.02.2017	0,7590	0,0012	0,0352	1,360%
10.02.2017	0,8029	0,0013	0,0362	1,368%
17.02.2017	0,8123	0,0013	0,0364	1,379%
24.02.2017	0,7642	0,0012	0,0353	1,354%

Yapay Sinir Ağları ile yapılan modelleme süreçleri sonunda her hafta için gelecek tahmin değerleri elde edilmektedir. Bu değerler hibrit model tahmininde kullanılmamakta, ancak zaman serisinin YSA tahminleri olarak karşılaştırma amacıyla kullanılmaktadır. YSA ile yapılan modellemeler sonucu bulunan tahmin değerleri ve bu değerlerin gerçek değerlere göre hata değerleri Tablo 4.26, Tablo 4.27 ve Tablo 4.28.'de yer almaktadır.

Tablo 4.26. Spot Altın Fiyatı YSA Modelleri için Gerçek Değerler, Tahmin Değerleri ve Hata Değerleri

Tarih	Gerçek Değer	YSA Tahmini	Mutlak Yüzde Hata (APE)	Mutlak Hata (AE)
23.12.2016	1131,35	1126,65	0,416%	4,70
30.12.2016	1145,90	1135,52	0,906%	10,38
06.01.2017	1175,85	1148,31	2,342%	27,54
13.01.2017	1190,35	1183,40	0,584%	6,95
20.01.2017	1200,55	1195,34	0,434%	5,21
27.01.2017	1184,85	1206,91	1,862%	22,06
03.02.2017	1215,20	1175,24	3,289%	39,96
10.02.2017	1228,30	1218,47	0,800%	9,83
17.02.2017	1241,95	1229,40	1,011%	12,55
24.02.2017	1253,65	1245,07	0,684%	8,58
ORTALAMA			1,233%	14,78


Tablo 4.27. BIST 30 Endeksi YSA Modelleri için Gerçek Değerler, Tahmin Değerleri ve Hata Değerleri


Tarih	Gerçek Değer	YSA Tahmini	Mutlak Yüzde Hata (APE)	Mutlak Hata (AE)
23.12.2016	94209,98	95387,06	1,249%	1177,08
30.12.2016	95498,58	94311,88	1,243%	1186,70
06.01.2017	93891,90	95751,71	1,981%	1859,81
13.01.2017	99607,09	94514,31	5,113%	5092,78
20.01.2017	101342,67	98523,39	2,782%	2819,28
27.01.2017	102563,05	100371,45	2,137%	2191,60
03.02.2017	108530,99	102042,97	5,978%	6488,02
10.02.2017	107123,70	105890,83	1,151%	1232,87
17.02.2017	109112,23	106144,23	2,720%	2968,00
24.02.2017	108377,63	106471,71	1,759%	1905,92
ORTALAMA			2,611%	2692,21

Tablo 4.28. USD/TRY Kuru YSA Modelleri için Gerçek Değerler, Tahmin Değerleri ve Hata Değerleri


Tarih	Gerçek Değer	YSA Tahmini	Mutlak Yüzde Hata (APE)	Mutlak Hata (AE)
23.12.2016	3,5169	3,4568	1,710%	0,0601
30.12.2016	3,5277	3,5233	0,126%	0,0044
06.01.2017	3,6445	3,4812	4,481%	0,1633
13.01.2017	3,7230	3,6152	2,895%	0,1078
20.01.2017	3,7655	3,6911	1,977%	0,0744
27.01.2017	3,8775	3,7742	2,663%	0,1033
03.02.2017	3,6976	3,8762	4,830%	0,1786
10.02.2017	3,6953	3,6855	0,265%	0,0098
17.02.2017	3,6290	3,7189	2,477%	0,0899
24.02.2017	3,6070	3,6265	0,541%	0,0195
ORTALAMA			2,196%	0,0811

Şekil 4.7, Şekil 4.8 ve Şekil 4.9’da sırasıyla; Spot Altın Fiyatı, BIST 30 Endeksi ve USD/TRY Kuru için YSA ile elde edilen tahmin değerleri ile gerçek değerler yer almaktadır.

**Şekil 4.7. Spot Altın Fiyatı Gerçek Değerler ve YSA Tahmin Değerleri**



Şekil 4.8. BIST 30 Endeksi Gerçek Değerler ve YSA Tahmin Değerleri



Şekil 4.9. USD/TRY Kuru Gerçek Değerler ve YSA Tahmin Değerleri

4.4.3. Optimizasyon Süreci

ARIMA ve YSA modellemelerinin ardından bu modeller ile elde edilen tahmin değerleri kullanılarak doğrusal ve doğrusal olmayan katsayılar bulunmaktadır. Tablo 4.29, Tablo 4.30 ve Tablo 4.31’de her bir model için ARIMA ve YSA ile elde edilen hata kareler toplamı, bulunan optimum α ve β değerleri ile optimizasyon sonucu elde edilen hata kare toplamaları yer almaktadır.

Tablo 4.29. Spot Altın Fiyatı Modelleri için Optimizasyon Sonuçları

Hafta	ARIMA Toplam Hata Kare (SSE)	YSA Toplam Hata Kare (SSE)	Doğrusal Katsayı (α)	Doğrusal Olmayan Katsayı (β)	Optimizasyon Sonucu Toplam Hata Kare (SSE)
23.12.2016	774098,2540	781847,1985	0,5396	0,4604	753350,7015
30.12.2016	774079,4094	749735,3905	0,2532	0,7468	746573,7068
06.01.2017	774443,2558	774777,5797	0,5030	0,4970	760750,0985
13.01.2017	775371,7988	796782,7069	0,6457	0,3543	766153,5372
20.01.2017	774810,2934	799304,9537	0,7240	0,2760	770643,9800
27.01.2017	775516,0781	758262,7664	0,3629	0,6371	750055,4027
03.02.2017	775693,1043	760825,2777	0,3893	0,6107	750649,3916
10.02.2017	776862,4171	792920,8779	0,5682	0,4318	754891,6875
17.02.2017	777041,9166	807633,1726	0,7113	0,2887	771009,8269
24.02.2017	777119,7267	756033,9004	0,3499	0,6501	747435,5494
Ortalama	775503,6254	777812,3824	0,5047	0,4953	757151,3882

Tablo 4.30. BIST 30 Endeksi Modelleri için Optimizasyon Sonuçları

Hafta	ARIMA Toplam Hata Kare (SSE)	YSA Toplam Hata Kare (SSE)	Doğrusal Katsayı (α)	Doğrusal Olmayan Katsayı (β)	Optimizasyon Sonucu Toplam Hata Kare (SSE)
23.12.2016	4768400634,4570	4696455197,0952	0,5075	0,4925	4617802062,8484
30.12.2016	4738040780,8350	4700000166,7522	0,5239	0,4761	4575980527,8012
06.01.2017	4740582584,8459	4714907239,1194	0,5158	0,4842	4577924557,9101
13.01.2017	4742619662,5930	4698691974,0367	0,3771	0,6229	4585757427,0729
20.01.2017	4769425897,2257	4951428068,2032	0,6151	0,3849	4624520860,2592
27.01.2017	4774628040,0331	4926612545,4824	0,5941	0,4059	4632815778,4097
03.02.2017	4802370698,1488	4753141347,9691	0,4997	0,5003	4611398018,5348
10.02.2017	4806575310,2680	4791831318,9060	0,5528	0,4472	4655510141,7601
17.02.2017	4807084237,4546	4743970920,1283	0,4689	0,5311	4629844342,8891
24.02.2017	4809452836,8147	4792402204,2707	0,5184	0,4816	4645210982,4959
Ortalama	4775918068,2676	4776944098,1963	0,5173	0,4827	4615676469,9981

Tablo 4.31. USD/TRY Kuru Modelleri için Optimizasyon Sonuçları

Hafta	ARIMA Toplam Hata Kare (SSE)	YSA Toplam Hata Kare (SSE)	Doğrusal Katsayı (α)	Doğrusal Olmayan Katsayı (β)	Optimizasyon Sonucu Toplam Hata Kare (SSE)
23.12.2016	0,7343	0,7871	0,7878	0,2122	0,7302
30.12.2016	0,7347	0,7577	0,6042	0,3958	0,7175
06.01.2017	0,7347	0,7639	0,7102	0,2898	0,7248
13.01.2017	0,7459	0,7692	0,6476	0,3524	0,7360
20.01.2017	0,7526	0,7603	0,5435	0,4565	0,7341
27.01.2017	0,7549	0,7243	0,3525	0,6475	0,7115
03.02.2017	0,7658	0,7590	0,4686	0,5314	0,7353
10.02.2017	0,8070	0,8029	0,4776	0,5224	0,7819
17.02.2017	0,8070	0,8123	0,5248	0,4752	0,7832
24.02.2017	0,8101	0,7642	0,3080	0,6920	0,7529
Ortalama	0,7647	0,7701	0,5425	0,4575	0,7407

4.4.4. Yapay Zaman Serisinin Oluşturulması ve YSA ile Modellenmesi Süreci

Optimizasyon sürecinin tamamlanmasının ardından elde edilen doğrusal ve doğrusal olmayan katsayılar kullanılarak yapay zaman serisi (n_t) oluşturulmaktadır. Her bir model için elde edilen yapay zaman serileri ile ilgili tanımlayıcı bilgiler Tablo 4.32, Tablo 4.33 ve Tablo 4.34’de verilmektedir.

Tablo 4.32. Spot Altın Fiyatı Modelleri, Yapay Zaman Serisi Veri Setleri için Tanımlayıcı Bilgiler

Hafta	Kullanılan Veri Sayısı	En Küçük	En Büyük	Ortalama	Standart Sapma
23.12.2016	1982	208,40	1983,72	599,15	403,45
30.12.2016	1983	214,94	1901,19	599,04	402,44
06.01.2017	1984	209,66	1965,04	599,63	403,36
13.01.2017	1985	203,30	2058,60	600,32	405,08
20.01.2017	1986	196,98	2155,99	601,04	407,44
27.01.2017	1987	213,13	1918,92	600,33	403,14
03.02.2017	1988	212,60	1924,11	600,65	403,32
10.02.2017	1989	207,28	2000,00	601,31	404,53
17.02.2017	1990	198,27	2132,52	602,20	407,50
24.02.2017	1991	213,38	1916,58	601,57	403,66

Tablo 4.33. BIST 30 Endeksi Modelleri, Yapay Zaman Serisi Veri Setleri için Tanımlayıcı Bilgiler

Hafta	Kullanılan Veri Sayısı	En Küçük	En Büyük	Ortalama	Standart Sapma
23.12.2016	1032	1155,00	116841,81	47879,64	33882,33
30.12.2016	1033	1155,00	117616,95	47938,07	33928,03
06.01.2017	1034	1155,00	117846,81	47990,54	33957,69
13.01.2017	1035	1155,00	117522,78	48026,54	33952,91
20.01.2017	1036	1130,19	121387,57	48164,86	34225,52
27.01.2017	1037	1143,71	121096,65	48214,01	34233,66
03.02.2017	1038	1155,00	117189,15	48181,35	34020,82
10.02.2017	1039	1155,00	118189,81	48267,89	34118,76
17.02.2017	1040	1155,00	117152,01	48299,47	34094,37
24.02.2017	1041	1155,00	118030,12	48380,12	34179,51

Tablo 4.34. USD/TRY Kuru Modelleri, Yapay Zaman Serisi Veri Setleri için Tanımlayıcı Bilgiler

Hafta	Kullanılan Veri Sayısı	En Küçük	En Büyük	Ortalama	Standart Sapma
23.12.2016	619	0,9668	3,8379	1,8278	0,5793
30.12.2016	620	1,0788	3,6182	1,8231	0,5611
06.01.2017	621	1,0651	3,6355	1,8268	0,5670
13.01.2017	622	1,0926	3,7763	1,8280	0,5676
20.01.2017	623	1,1136	3,7914	1,8297	0,5696
27.01.2017	624	1,1384	3,7825	1,8310	0,5712
03.02.2017	625	1,1116	3,9698	1,8364	0,5807
10.02.2017	626	1,1113	3,9760	1,8393	0,5845
17.02.2017	627	1,1019	3,9966	1,8429	0,5901
24.02.2017	628	1,1345	3,9255	1,8433	0,5893

Elde edilen yapay zaman serileri YSA ile modellenmektedir. Modelleme sonucunda eğitim ve doğrulama setleri için ayrı ayrı olmak üzere model hata değerleri Tablo 4.35, Tablo 4.36 ve Tablo 4.37’de gösterilmektedir.

Tablo 4.35. Spot Altın Fiyatı Yapay Serileri için YSA Modelleri Öğrenme Oranları ile Eğitim ve Doğrulama Setleri Hata Değerleri

		EĞİTİM SETİ (<i>TRAINING SET</i>)		DOĞRULAMA SETİ (<i>VALIDATION SET</i>)	
Tarih	Öğrenme Oranı	Ortalama Mutlak Hata (<i>MAE</i>)	Ortalama Mutlak Yüzde Hata (<i>MAPE</i>)	Ortalama Mutlak Hata (<i>MAE</i>)	Ortalama Mutlak Yüzde Hata (<i>MAPE</i>)
23.12.2016	1,00	24,57	3,867%	25,46	4,076%
30.12.2016	2,00	14,78	2,360%	16,61	2,538%
06.01.2017	1,00	23,47	3,817%	24,79	3,888%
13.01.2017	1,00	32,30	5,240%	34,82	5,460%
20.01.2017	1,50	41,83	6,706%	44,25	7,609%
27.01.2017	1,00	18,26	2,934%	17,31	2,744%
03.02.2017	0,80	18,55	2,983%	19,74	3,096%
10.02.2017	0,60	26,50	4,212%	25,96	3,967%
17.02.2017	0,90	38,84	6,261%	42,42	6,664%
24.02.2017	2,00	17,45	2,748%	18,07	2,899%

Tablo 4.36. BIST 30 Endeksi Yapay Serileri için YSA Modelleri Öğrenme Oranları ile Eğitim ve Doğrulama Setleri Hata Değerleri

		EĞİTİM SETİ (<i>TRAINING SET</i>)		DOĞRULAMA SETİ (<i>VALIDATION SET</i>)	
Tarih	Öğrenme Oranı	Ortalama Mutlak Hata (<i>MAE</i>)	Ortalama Mutlak Yüzde Hata (<i>MAPE</i>)	Ortalama Mutlak Hata (<i>MAE</i>)	Ortalama Mutlak Yüzde Hata (<i>MAPE</i>)
23.12.2016	1,00	2776,75	8,310%	2979,35	8,558%
30.12.2016	1,00	2954,65	9,487%	3314,94	10,024%
06.01.2017	1,00	3052,66	9,189%	3277,77	10,973%
13.01.2017	1,00	3001,23	9,495%	3385,36	10,185%
20.01.2017	1,00	4209,21	14,376%	5056,45	16,122%
27.01.2017	0,80	4262,39	13,569%	4335,56	12,577%
03.02.2017	1,00	2997,56	10,707%	3046,91	10,095%
10.02.2017	0,80	3216,59	9,245%	3369,18	10,049%
17.02.2017	0,40	2974,48	9,368%	2924,78	9,102%
24.02.2017	0,80	3109,67	9,345%	3514,03	10,371%

Tablo 4.37. USD/TRY Kuru Yapay Serileri için YSA Modelleri Öğrenme Oranları ile Eğitim ve Doğrulama Setleri Hata Değerleri

		EĞİTİM SETİ (<i>TRAINING SET</i>)		DOĞRULAMA SETİ (<i>VALIDATION SET</i>)	
Tarih	Öğrenme Oranı	Ortalama Mutlak Hata (<i>MAE</i>)	Ortalama Mutlak Yüzde Hata (<i>MAPE</i>)	Ortalama Mutlak Hata (<i>MAE</i>)	Ortalama Mutlak Yüzde Hata (<i>MAPE</i>)
23.12.2016	1,00	0,1053	5,966%	0,1155	6,106%
30.12.2016	0,60	0,0588	3,254%	0,0666	3,604%
06.01.2017	0,80	0,0594	3,331%	0,0760	4,212%
13.01.2017	0,80	0,0531	2,934%	0,0574	3,208%
20.01.2017	0,80	0,0425	2,372%	0,0483	2,543%
27.01.2017	0,80	0,0336	1,842%	0,0304	1,740%
03.02.2017	1,00	0,0443	2,445%	0,0479	2,564%
10.02.2017	0,80	0,0450	2,477%	0,0569	2,966%
17.02.2017	0,60	0,0505	2,759%	0,0593	3,318%
24.02.2017	0,50	0,0351	1,892%	0,0380	2,106%

Spot Altın Fiyatı, BIST 30 Endeksi ve USD/TRY Kuru için elde edilen yapay serilerin YSA ile yapılan modellemeleri sonucu bulunan model hata değerleri Tablo 4.38, Tablo 4.39 ve Tablo 4.40’da yer almaktadır.

Tablo 4.38. Spot Altın Fiyatı Yapay Serileri için YSA Model Hata Değerleri

Hafta	Toplam Hata Kare (<i>SSE</i>)	Ortalama Hata Kare (<i>MSE</i>)	Ortalama Hata Karelerin Karekökü (<i>RMSE</i>)	Ortalama Mutlak Yüzde Hata (<i>MAPE</i>)
23.12.2016	3472504,0181	1763,5876	41,9951	3,909%
30.12.2016	1267480,7339	643,3912	25,3652	2,396%
06.01.2017	3121479,4414	1583,7034	39,7958	3,831%
13.01.2017	6114800,9517	3100,8118	55,6849	5,284%
20.01.2017	10152031,6003	5145,4798	71,7320	6,886%
27.01.2017	1768803,2322	896,0503	29,9341	2,896%
03.02.2017	1927244,2159	975,8199	31,2381	3,006%
10.02.2017	3987542,1695	2017,9869	44,9220	4,163%
17.02.2017	8653651,7055	4377,1632	66,1601	6,341%
24.02.2017	1675224,3457	846,9284	29,1020	2,778%

Tablo 4.39. BIST 30 Endeksi Yapay Serileri için YSA Model Hata Değerleri

Hafta	Toplam Hata Kare (SSE)	Ortalama Hata Kare (MSE)	Ortalama Hata Karelerin Karekökü (RMSE)	Ortalama Mutlak Yüzde Hata (MAPE)
23.12.2016	16998206374,3766	8632913,3440	2938,1820	8,360%
30.12.2016	18988471943,5315	9638818,2454	3104,6446	9,594%
06.01.2017	20020156406,3783	10157359,9221	3187,0613	9,544%
13.01.2017	19742542924,5957	10011431,5033	3164,0846	9,632%
20.01.2017	40339539078,7223	20445787,6729	4521,7019	14,722%
27.01.2017	38293400832,5250	19398885,9334	4404,4166	13,371%
03.02.2017	18558165219,9701	9396539,3519	3065,3775	10,584%
10.02.2017	22405690101,6070	11338911,9947	3367,3301	9,406%
17.02.2017	18302373561,6842	9257649,7530	3042,6386	9,315%
24.02.2017	21728386017,9329	10985028,3205	3314,3670	9,550%

Tablo 4.40. USD/TRY Kuru Yapay Serileri için YSA Model Hata Değerleri

Hafta	Toplam Hata Kare (SSE)	Ortalama Hata Kare (MSE)	Ortalama Hata Karelerin Karekökü (RMSE)	Ortalama Mutlak Yüzde Hata (MAPE)
23.12.2016	13,7086	0,0226	0,1504	5,994%
30.12.2016	4,4146	0,0073	0,0853	3,324%
06.01.2017	4,6409	0,0076	0,0874	3,506%
13.01.2017	3,4991	0,0058	0,0758	2,989%
20.01.2017	2,3348	0,0038	0,0619	2,407%
27.01.2017	1,3130	0,0022	0,0464	1,821%
03.02.2017	2,4720	0,0040	0,0636	2,469%
10.02.2017	2,9173	0,0048	0,0690	2,574%
17.02.2017	3,3542	0,0055	0,0739	2,871%
24.02.2017	1,5965	0,0026	0,0510	1,935%

Yapay serinin (n_t) Yapay Sinir Ağları ile modellenmesiyle her bir hafta için yeni tahmin değerleri elde edilmektedir. Elde edilen tahmin değerleri ve gerçek değerlere nispetle hata değerleri Tablo 4.41, Tablo 4.42 ve Tablo 4.43'te yer almaktadır.

Tablo 4.41. Spot Altın Fiyatları için Gerçek Değerler, Yapay Seri YSA Modeli Tahmin ve Hata Değerleri

Tarih	Gerçek Değer	YSA Tahmini (n_t)	Mutlak Yüzde Hata (APE)	Mutlak Hata (AE)
23.12.2016	1131,35	1134,77	0,303%	3,42
30.12.2016	1145,90	1141,36	0,396%	4,54
06.01.2017	1175,85	1151,95	2,033%	23,90
13.01.2017	1190,35	1191,47	0,094%	1,12
20.01.2017	1200,55	1202,04	0,124%	1,49
27.01.2017	1184,85	1188,60	0,317%	3,75
03.02.2017	1215,20	1182,07	2,726%	33,13
10.02.2017	1228,30	1219,59	0,709%	8,71
17.02.2017	1241,95	1236,49	0,440%	5,46
24.02.2017	1253,65	1237,77	1,267%	15,88
ORTALAMA			0,841%	10,14


Tablo 4.42. BIST 30 Endeksi için Gerçek Değerler, Yapay Seri YSA Model Tahmin ve Hata Değerleri

Tarih	Gerçek Değer	YSA Tahmini (n_t)	Mutlak Yüzde Hata (APE)	Mutlak Hata (AE)
23.12.2016	94209,98	94583,13	0,396%	373,15
30.12.2016	95498,58	95579,96	0,085%	81,38
06.01.2017	93891,90	95301,86	1,502%	1409,96
13.01.2017	99607,09	95241,28	4,383%	4365,82
20.01.2017	101342,67	97761,43	3,534%	3581,24
27.01.2017	102563,05	101883,29	0,663%	679,76
03.02.2017	108530,99	103017,70	5,080%	5513,29
10.02.2017	107123,70	105603,42	1,419%	1520,28
17.02.2017	109112,23	105890,43	2,953%	3221,80
24.02.2017	108377,63	106914,78	1,350%	1462,85
ORTALAMA			2,136%	2220,95


Tablo 4.43. USD/TRY Kuru için Gerçek Değerler, Yapay Seri YSA Model Tahmin ve Hata Değerleri

Tarih	Gerçek Değer	YSA Tahmini (n_t)	Mutlak Yüzde Hata (APE)	Mutlak Hata (AE)
23.12.2016	3,5169	3,5497	0,932%	0,0328
30.12.2016	3,5277	3,5388	0,315%	0,0111
06.01.2017	3,6445	3,5397	2,875%	0,1048
13.01.2017	3,7230	3,6448	2,102%	0,0782
20.01.2017	3,7655	3,7661	0,016%	0,0006
27.01.2017	3,8775	3,7917	2,213%	0,0858
03.02.2017	3,6976	3,8613	4,427%	0,1637
10.02.2017	3,6953	3,6942	0,030%	0,0011
17.02.2017	3,6290	3,6408	0,325%	0,0118
24.02.2017	3,6070	3,5938	0,367%	0,0132
ORTALAMA			1,360%	0,0503


Yapay Serinin YSA ile elde edilen tahmin ve gerçek değerleri her bir finansal zaman serisi için Şekil 4.10, Şekil 4.11 ve Şekil 4.12’de gösterilmektedir.



Şekil 4.10. Spot Altın Fiyatı Yapay Seri YSA Model Tahmin Değerleri ve Gerçek Değerler



Şekil 4.11. BIST 30 Endeksi Yapay Seri YSA Model Tahmin Değerleri ve Gerçek Değerler



Şekil 4.12. BIST 30 Endeksi Yapay Seri YSA Model Tahmin Değerleri ve Gerçek Değerler

4.4.5. Optimize ARIMA – YSA Hibrit Modelin Oluşturulması

Optimize ARIMA – YSA Hibrit Modeli değerleri, ARIMA ile bulunan model değerlerin doğrusal katsayı (α) ve yapay seri n_t için YSA ile elde edilen değerlerin doğrusal olmayan katsayı (β) ile çarpılarak toplanmasıyla bulunmaktadır. Modellerin elde edilmesinin ardından, her bir hafta için Optimize ARIMA – YSA Hibrit Modeli ile elde edilen model hata değerleri Tablo 4.44, Tablo 4.45 ve Tablo 4.46’da yer almaktadır.

Tablo 4.44. Spot Altın Fiyatı Optimize ARIMA – YSA Hibrit Modelleri, Model Hata Değerleri

Hafta	Toplam Hata Kare (SSE)	Ortalama Hata Kare (MSE)	Ortalama Hata Karelerin Karekökü (RMSE)	Ortalama Mutlak Yüzde Hata (MAPE)
23.12.2016	736060,2873	373,8244	19,3345	1,790%
30.12.2016	707260,1997	359,0153	18,9477	1,789%
6.1.2017	771033,5151	391,1890	19,7785	1,897%
13.1.2017	767581,7302	389,2402	19,7292	1,850%
20.1.2017	773341,1593	391,9621	19,7980	1,848%
27.1.2017	717950,8818	363,7036	19,0710	1,842%
3.2.2017	718774,3844	363,9364	19,0771	1,833%
10.2.2017	743482,1826	376,2562	19,3973	1,786%
17.2.2017	721261,8793	364,8264	19,1004	1,803%
24.2.2017	707782,2860	357,8272	18,9163	1,803%

Tablo 4.45. BIST 30 Endeksi Optimize ARIMA – YSA Hibrit Modelleri, Model Hata Değerleri

Hafta	Toplam Hata Kare (SSE)	Ortalama Hata Kare (MSE)	Ortalama Hata Karelerin Karekökü (RMSE)	Ortalama Mutlak Yüzde Hata (MAPE)
23.12.2016	8799604743,0407	4469073,0031	2114,0182	4,250%
30.12.2016	8312897672,1212	4219745,0112	2054,2018	4,461%
6.1.2017	8338727559,1604	4230709,0610	2056,8688	4,316%
13.1.2017	8828181994,2275	4476765,7172	2115,8369	4,534%
20.1.2017	8877724706,2466	4499607,0483	2121,2277	4,681%
27.1.2017	8816954447,0437	4466542,2731	2113,4196	4,345%
3.2.2017	9000625266,2201	4557278,6158	2134,7784	5,197%
10.2.2017	8722691432,0883	4414317,5264	2101,0277	4,108%
17.2.2017	8924779639,4036	4514304,3194	2124,6892	4,595%
24.2.2017	8727763247,0821	4412418,2240	2100,5757	4,239%

Tablo 4.46. USD/TRY Kuru Optimize ARIMA – YSA Hibrit Modelleri, Model Hata Değerleri

Hafta	Toplam Hata Kare (SSE)	Ortalama Hata Kare (MSE)	Ortalama Hata Karelerin Karekökü (RMSE)	Ortalama Mutlak Yüzde Hata (MAPE)
23.12.2016	0,6161	0,0010	0,0319	1,271%
30.12.2016	0,6916	0,0011	0,0338	1,320%
6.1.2017	0,6040	0,0010	0,0315	1,262%
13.1.2017	0,6894	0,0011	0,0337	1,317%
20.1.2017	0,6822	0,0011	0,0334	1,304%
27.1.2017	0,7095	0,0012	0,0341	1,334%
3.2.2017	0,6981	0,0011	0,0338	1,317%
10.2.2017	0,7964	0,0013	0,0361	1,348%
17.2.2017	0,7574	0,0012	0,0351	1,363%
24.2.2017	0,7643	0,0012	0,0353	1,337%

Modellemeler esnasında birinci aşamada ARIMA ile elde edilen gelecek tahmin değeri ve dördüncü aşamada yapay serinin YSA ile modellenmesiyle bulunan gelecek tahmin değeri kullanılarak Optimize ARIMA – YSA Hibrit Modelinin tahmin değeri elde edilmektedir. Modellemeler sonucunda elde edilen tahmin değerleri ve gerçek değerler ile birlikte, doğrusal ve doğrusal olmayan katsayılar ve tahmin hataları Tablo 4.47, Tablo 4.48 ve Tablo 4.49’da gösterilmektedir.

Tablo 4.47. Spot Altın Fiyatı için Gerçek Değerler ve Optimize ARIMA – YSA Hibrit Model Tahmin Değerleri ve Hata Değerleri

Tarih	Gerçek Değer	Optimize ARIMA - YSA Hibrit Modeli Tahmini	Mutlak Yüzde Hata (APE)	Mutlak Hata (AE)
23.12.2016	1131,35	1132,16	0,072%	0,81
30.12.2016	1145,90	1137,68	0,717%	8,22
6.1.2017	1175,85	1148,64	2,314%	27,21
13.1.2017	1190,35	1184,27	0,511%	6,08
20.1.2017	1200,55	1195,53	0,418%	5,02
27.1.2017	1184,85	1192,07	0,610%	7,22
3.2.2017	1215,20	1181,66	2,760%	33,54
10.2.2017	1228,30	1216,93	0,925%	11,37
17.2.2017	1241,95	1234,05	0,636%	7,90
24.2.2017	1253,65	1240,18	1,075%	13,47
ORTALAMA			1,004%	12,08


Tablo 4.48. BIST 30 Endeksi için Gerçek Değerler, Optimize ARIMA – YSA Hibrit Model Tahmin Değerleri ve Hata Değerleri

Tarih	Gerçek Değer	Optimize ARIMA - YSA Hibrit Modeli Tahmini	Mutlak Yüzde Hata (APE)	Mutlak Hata (AE)
23.12.2016	94209,98	95045,36	0,887%	835,38
30.12.2016	95498,58	94696,18	0,840%	802,40
6.1.2017	93891,90	95328,01	1,530%	1436,11
13.1.2017	99607,09	94817,74	4,808%	4789,35
20.1.2017	101342,67	98626,44	2,680%	2716,23
27.1.2017	102563,05	101623,36	0,916%	939,69
3.2.2017	108530,99	102994,07	5,102%	5536,92
10.2.2017	107123,70	106860,75	0,245%	262,95
17.2.2017	109112,23	106716,37	2,196%	2395,86
24.2.2017	108377,63	108169,16	0,192%	208,47
ORTALAMA			1,940%	1992,34


Tablo 4.49. USD/TRY Kuru için Gerçek Değerler Optimize ARIMA – YSA Hibrit Model Tahmin Değerleri ve Hata Değerleri

Tarih	Gerçek Değer	Optimize ARIMA - YSA Hibrit Modeli Tahmini	Mutlak Yüzde Hata (APE)	Mutlak Hata (AE)
23.12.2016	3,5169	3,5080	0,253%	0,0089
30.12.2016	3,5277	3,5299	0,062%	0,0022
6.1.2017	3,6445	3,5386	2,906%	0,1059
13.1.2017	3,7230	3,6425	2,163%	0,0805
20.1.2017	3,7655	3,7397	0,686%	0,0258
27.1.2017	3,8775	3,7848	2,392%	0,0927
3.2.2017	3,6976	3,8736	4,761%	0,1760
10.2.2017	3,6953	3,6927	0,071%	0,0026
17.2.2017	3,6290	3,6636	0,953%	0,0346
24.2.2017	3,6070	3,6124	0,150%	0,0054
ORTALAMA			1,440%	0,0535


Her bir finansal varlık için Optimize ARIMA – YSA Hibrit Modeli ile elde edilen tahmin değerleri ve gerçek değerler Şekil 4.13, Şekil 4.14 ve Şekil 4.15’te verilmektedir.



Şekil 4.13. Spot Altın Fiyatı Gerçek Değerler ve Optimize ARIMA – YSA Hibrit Model Değerleri



Şekil 4.14. BIST 30 Endeksi Gerçek Değerler ve Optimize ARIMA – YSA Hibrit Model Değerleri



Şekil 4.15. USD/TRY Kuru Gerçek Değerler ve Optimize ARIMA – YSA Hibrit Model Değerleri

Optimize ARIMA – YSA Hibrit Modelinin, model ve tahmin değerlerinin elde edilmesiyle modelleme süreci tamamlanmaktadır.

4.5. Sonuçların Karşılaştırılması

Çalışmada üç farklı tür finansal zaman serisi; Spot Altın Fiyatları, BIST 30 Endeksi ve ABD Doları/ Türk Lirası döviz kuru kullanılarak Optimize ARIMA – YSA Modeli ile ARIMA ve YSA modelleri karşılaştırılmaktadır. Her bir veri seti, 25.12.2016 ile 24.02.2017 tarihleri arasındaki 10 haftanın her birinin tahmini için ayrı ayrı modellenmektedir. Her bir modelleme sonucunda bir sonraki haftalık kapanış değeri için tahmin yapılmaktadır. Çalışmada her bir finansal zaman serisinin farklı haftaları için 10 adet olmak üzere toplam 30 modelleme ve 30 tahmin yapılmaktadır.

Zaman serilerinin modellenmesi karşılaştırılırken modelin performansı iki açıdan değerlendirilmektedir. Öncelikle modelin eldeki verileri ne kadar iyi açıkladığı önem taşımaktadır. Modelin eldeki zaman serisine uygunluğu toplam hata kare veya ortalama hata kare ile ölçülebilir. Optimize ARIMA – YSA Hibrit Modeli, toplam hata kare değerini optimizasyon aşamasında en küçüklemektedir. Ayrıca modelde, ARIMA ile yapılan doğrusal modellemeden kalan hataların, doğrusal olmayan kısma eklenerek yeniden modellenmesi ile hatanın daha da azaltılması hedeflenmekte ve toplam hata karenin de azalması beklenmektedir.

Tablo 4.50’de her bir hafta tahmini için ARIMA ve YSA modellerinin toplam hata kareleri ile, optimizasyon aşaması sonucu toplam hata kare değerleri ve Optimize ARIMA – YSA Hibrit Modeli sonucu toplam hata kare değerleri yer almaktadır. Her bir hafta için en düşük toplam hata kare değeri mavi renkle gösterilmektedir.

Tablo 4.50. ARIMA ve YSA Modelleri ile Optimizasyon Aşaması Sonrası ve Optimize ARIMA – YSA Modeli Toplam Hata Kare Değerleri

	Hafta	ARIMA Toplam Hata Kare (SSE)	YSA Toplam Hata Kare (SSE)	Optimizasyon Sonucu Toplam Hata Kare (SSE)	Optimize ARIMA – YSA Modeli Toplam Hata Kare (SSE)
SPOT ALTIN FİYATI	23.12.2016	7,74x10 ⁵	7,82x10 ⁵	7,53x10 ⁵	7,36x10 ⁵
	30.12.2016	7,74x10 ⁵	7,50x10 ⁵	7,47x10 ⁵	7,07x10 ⁵
	06.01.2017	7,74x10 ⁵	7,75x10 ⁵	7,61x10 ⁵	7,71x10 ⁵
	13.01.2017	7,75x10 ⁵	7,97x10 ⁵	7,66x10 ⁵	7,68x10 ⁵
	20.01.2017	7,75x10 ⁵	7,99x10 ⁵	7,71x10 ⁵	7,73x10 ⁵
	27.01.2017	7,76x10 ⁵	7,58x10 ⁵	7,50x10 ⁵	7,18x10 ⁵
	03.02.2017	7,76x10 ⁵	7,61x10 ⁵	7,51x10 ⁵	7,19x10 ⁵
	10.02.2017	7,77x10 ⁵	7,93x10 ⁵	7,55x10 ⁵	7,43x10 ⁵
	17.02.2017	7,77x10 ⁵	8,08x10 ⁵	7,71x10 ⁵	7,21x10 ⁵
	24.02.2017	7,77x10 ⁵	7,56x10 ⁵	7,47x10 ⁵	7,08x10 ⁵
	Ortalama	7,76x10 ⁵	7,78x10 ⁵	7,57x10 ⁵	7,36x10 ⁵
BIST 30 ENDEKSİ	23.12.2016	4,77x10 ⁹	4,70x10 ⁹	4,62x10 ⁹	4,55x10 ⁹
	30.12.2016	4,74x10 ⁹	4,70x10 ⁹	4,58x10 ⁹	4,30x10 ⁹
	06.01.2017	4,74x10 ⁹	4,71x10 ⁹	4,58x10 ⁹	4,32x10 ⁹
	13.01.2017	4,74x10 ⁹	4,70x10 ⁹	4,59x10 ⁹	4,58x10 ⁹
	20.01.2017	4,77x10 ⁹	4,95x10 ⁹	4,62x10 ⁹	4,60x10 ⁹
	27.01.2017	4,77x10 ⁹	4,93x10 ⁹	4,63x10 ⁹	4,57x10 ⁹
	03.02.2017	4,80x10 ⁹	4,75x10 ⁹	4,61x10 ⁹	4,67x10 ⁹
	10.02.2017	4,81x10 ⁹	4,79x10 ⁹	4,66x10 ⁹	4,53x10 ⁹
	17.02.2017	4,81x10 ⁹	4,74x10 ⁹	4,63x10 ⁹	4,64x10 ⁹
	24.02.2017	4,81x10 ⁹	4,79x10 ⁹	4,65x10 ⁹	4,54x10 ⁹
	Ortalama	4,78x10 ⁹	4,78x10 ⁹	4,62x10 ⁹	4,53x10 ⁹
USD/TRY KURU	23.12.2016	7,34x10 ⁻¹	7,87x10 ⁻¹	7,30x10 ⁻¹	6,16x10 ⁻¹
	30.12.2016	7,35x10 ⁻¹	7,58x10 ⁻¹	7,17x10 ⁻¹	6,92x10 ⁻¹
	06.01.2017	7,35x10 ⁻¹	7,64x10 ⁻¹	7,25x10 ⁻¹	6,04x10 ⁻¹
	13.01.2017	7,46x10 ⁻¹	7,69x10 ⁻¹	7,36x10 ⁻¹	6,89x10 ⁻¹
	20.01.2017	7,53x10 ⁻¹	7,60x10 ⁻¹	7,34x10 ⁻¹	6,82x10 ⁻¹
	27.01.2017	7,55x10 ⁻¹	7,24x10 ⁻¹	7,11x10 ⁻¹	7,09x10 ⁻¹
	03.02.2017	7,66x10 ⁻¹	7,59x10 ⁻¹	7,35x10 ⁻¹	6,98x10 ⁻¹
	10.02.2017	8,07x10 ⁻¹	8,03x10 ⁻¹	7,82x10 ⁻¹	7,96x10 ⁻¹
	17.02.2017	8,07x10 ⁻¹	8,12x10 ⁻¹	7,83x10 ⁻¹	7,57x10 ⁻¹
	24.02.2017	8,10x10 ⁻¹	7,64x10 ⁻¹	7,53x10 ⁻¹	7,64x10 ⁻¹
	Ortalama	7,65x10 ⁻¹	7,70x10 ⁻¹	7,41x10 ⁻¹	7,01x10 ⁻¹

Tablo 4.50’de görülebileceği gibi Spot Altın, BIST 30 ve USD/TRY için Optimize ARIMA – YSA Hibrit Modeli ile elde edilen toplam hata kare değerleri ARIMA ve YSA modellerinin toplam hata kare değerlerinden küçüktür. Modellemeler içerisinde sadece USD/TRY kur değerinin 24.02.2017 haftası tahmini için yapılan modellemede YSA ile elde edilen hata kare değeri Optimize ARIMA – YSA Hibrit Modeli ile bulunan toplam hata kare değeriyle aynı görünmektedir.

Diğer taraftan, Spot Altın tahmin modellerinin 7’sinde, BIST 30 ve USD/TRY tahmin modellerinin 8’inde optimizasyon aşamasından sonra, doğrusal hataların aktarılarak yapay serinin oluşturulması ve YSA ile yapılan yeniden modellemenin hata kareler toplamını daha da düşürdüğü tespit edilmektedir. Ayrıca her üç finansal varlık için yapılan modellemelerde hibrit model hata kare toplamının ortalaması optimizasyon aşaması sonucu elde edilen hata kare toplamı ortalamasından küçük olduğu görülebilir. Bu anlamda modelde sadece optimizasyonla sınırla kalmayıp, doğrusal hataların aktarılarak yapay seri oluşturulması ve YSA ile yeniden modellenmesi süreciyle modelin iyileştirildiği söylenebilir.

Optimize ARIMA – YSA Hibrit Modelinin toplam hata kare değerlerini, ARIMA ve YSA modellerine göre ne kadar azalttığı Tablo 4.51’de görülmektedir:

Tablo 4.51. Optimize ARIMA – YSA Modelinin ARIMA ve YSA Toplam Hata Kare Değerlerini İyileştirme Miktarları

Finansal Zaman Serisi	ARIMA Modeline Göre Toplam Hata Kare Değerinde Azalma (Ortalama)	YSA Modeline Göre Toplam Hata Kare Değerinde Azalma (Ortalama)
Spot Altın Fiyatı	5,04%	5,32%
BIST 30 Endeksi	5,14%	5,16%
USD/TRY Kuru	8,34%	8,99%

Tablo 4.51’de görülebileceği gibi, Optimize ARIMA – YSA Hibrit Modeli Spot Altın ve BIST 30 Kuru modellemelerinde hata kare toplamını ARIMA ve YSA modellerine göre 5% dolaylarında azaltırken, USD/TRY Kurunda bu modellere göre hata 8-9% oranında azaltılmaktadır.

Ortalama hata kare, toplam hata karenin veri sayısına bölünmesiyle elde edildiğinden model performanslarını kıyaslamada toplam hata kare ile aynı sonuçları vermektedir. Modellerin ortalama hata kare değerleri Tablo 4.52’de yer almaktadır.

Tablo 4.52. ARIMA, YSA ve Optimize ARIMA – YSA Modelleri için Ortalama Hata Kare Değerleri

Tarih	Ortalama Hata Kare (MSE)								
	Spot Altın Fiyatı (x10 ³)			BIST 30 Endeksi (x10 ⁶)			USD/TRY Kuru (x10 ⁻³)		
	ARIMA	YSA	Optimize ARIMA – YSA Hibrit Modeli	ARIMA	YSA	Optimize ARIMA – YSA Hibrit Modeli	ARIMA	ANN	Optimize ARIMA – YSA Hibrit Modeli
23.12.16	3,931	3,971	3,738	4,621	4,609	4,469	1,212	1,299	1,017
30.12.16	3,929	3,806	3,590	4,587	4,608	4,220	1,210	1,248	1,139
06.01.17	3,929	3,931	3,912	4,585	4,618	4,231	1,208	1,256	0,993
13.01.17	3,932	4,040	3,892	4,582	4,598	4,477	1,225	1,263	1,132
20.01.17	3,927	4,051	3,920	4,604	4,840	4,500	1,234	1,246	1,118
27.01.17	3,929	3,841	3,637	4,604	4,811	4,467	1,235	1,186	1,161
03.02.17	3,928	3,852	3,639	4,627	4,637	4,557	1,251	1,240	1,141
10.02.17	3,931	4,013	3,763	4,626	4,670	4,414	1,316	1,310	1,299
17.02.17	3,930	4,085	3,648	4,622	4,619	4,514	1,314	1,323	1,234
24.02.17	3,929	3,822	3,578	4,620	4,662	4,412	1,317	1,243	1,243
Ortalama	3,930	3,941	3,732	4,608	4,667	4,426	1,252	1,261	1,148

Modellerin hata açısından değerlendirilmesinde kullanılan başlıca iki kriterden bahsedilebilir. Ortalama hata kare (MSE), hatayı sayısal büyüklük olarak tespit ederken, ortalama mutlak yüzde hata (MAPE) hatayı gerçek değere göre oran olarak değerlendirmektedir. Tek bir noktanın tahmini değerlendirilirken bu iki hata değerlendirme modeli arasında bir ayrım gözükmemektedir.

Ancak birden çok noktanın yer aldığı model değerlendirmelerinde yöntemler arasında farklılıklar ortaya çıkmaktadır. Özellikle gerçek değerlerin kendi arasında önemli büyüklük farklılıkları olduğunda bu ayrım daha çok ortaya çıkmaktadır. Ortalama mutlak yüzde hata hatayı gerçek değerlerin bir oranı olarak ifade ettiğinden gerçek veri setinde yer alan küçük değerlerin hataları küçük de olsalar gerçek veriye göre yüksek bir oran ifade edebilmektedir (Chen ve Yang, 2004). Ortalama hata kare ise hatayı sayısal değer olarak aldığından, veri setindeki görece büyük verilerin hataları yüzde olarak düşük de olsa sayısal olarak daha büyük önem ifade etmektedir. Ortalama mutlak yüzde hata yönteminde veri küçüldükçe hataya verilen önem artmakta, veri sıfıra yaklaşırken yüzde hata sonsuza yakınsamaktadır (Chen vd., 2017). Bu durumda ortalama mutlak yüzde hata yönteminin, ortalama hata kare yöntemine göre küçük verilerdeki hatayı daha çok cezalandırdığı söylenebilir.

Hata tespit yöntemlerinin farkının anlaşılabilmesi için $z_1 = 1$ ve $z_2 = 100$ olmak üzere 2 verili bir z_t zaman serisi düşünölsün. Bu zaman serisinin modellenmesi amacıyla kullanılan 2 model M^1 ve M^2 olsun. Modellemelerle elde edilen değerler $M_1^1 = 2$, $M_2^1 = 104$, $M_1^2 = 4$ ve $M_2^2 = 101$ olsun. Bu sonuçlara göre M^1 modeli için ortalama hata kare değeri 17 ve ortalama

mutlak yüzde hata değeri 52% olarak elde edilir. Diğer taraftan M^2 modeli için ortalama hata kare 5 ve ortalama mutlak yüzde hata 150,5% olarak bulunur. Modeller karşılaştırılırsa; serideki küçük veri z_1 'i daha iyi modelleyen M^1 modeli daha düşük ortalama mutlak yüzde hata değeri verirken, serideki yüksek değer olan z_2 'yi daha iyi modelleyen M^2 modeli daha düşük ortalama hata kare değeri vermektedir.

Optimize ARIMA – YSA Hibrit Modeli optimizasyon aşamasında en küçük kareler optimizasyonu kullanmaktadır. Bu aşamada kullanılan optimizasyonun doğası gereği hibrit model hataları sayısal olarak değerlendirmektedir. Tablo 4.53'te her bir haftalık kapanış değeri tahmini için yapılan modellemeler sonucu elde edilen ortalama mutlak yüzde hata değerleri gösterilmektedir.

Tablo 4.53. ARIMA, YSA ve Optimize ARIMA – YSA Modelleri için Ortalama Mutlak Yüzde Hata Değerleri

Tarih	Ortalama Mutlak Yüzde Hata (MAPE)								
	Spot Altın Fiyatı			BIST 30 Endeksi			USD/TRY Kuru		
	ARIMA	YSA	Optimize ARIMA – YSA Hibrit Modeli	ARIMA	YSA	Optimize ARIMA – YSA Hibrit Modeli	ARIMA	YSA	Optimize ARIMA – YSA Hibrit Modeli
23.12.16	1,786%	1,984%	1,790%	3,949%	4,680%	4,250%	1,349%	1,383%	1,271%
30.12.16	1,786%	1,809%	1,789%	3,957%	5,093%	4,461%	1,347%	1,375%	1,320%
06.01.17	1,786%	1,893%	1,897%	3,954%	4,580%	4,316%	1,345%	1,382%	1,262%
13.01.17	1,786%	1,956%	1,850%	3,952%	5,093%	4,534%	1,349%	1,372%	1,317%
20.01.17	1,790%	1,916%	1,848%	3,955%	6,966%	4,681%	1,350%	1,358%	1,304%
27.01.17	1,785%	1,826%	1,842%	3,953%	5,884%	4,345%	1,350%	1,350%	1,334%
03.02.17	1,785%	1,895%	1,833%	3,951%	4,662%	5,197%	1,352%	1,360%	1,317%
10.02.17	1,785%	1,807%	1,786%	3,953%	4,632%	4,108%	1,361%	1,368%	1,348%
17.02.17	1,785%	1,844%	1,803%	3,950%	4,531%	4,595%	1,359%	1,378%	1,363%
24.02.17	1,784%	1,834%	1,803%	3,948%	4,695%	4,239%	1,360%	1,354%	1,337%
Ortalama	1,786%	1,876%	1,824%	3,952%	5,082%	4,473%	1,352%	1,368%	1,317%

Tablo 4.53'de görüldüğü gibi Spot Altın Fiyatları ve BIST 30 Endeksi için en düşük ortalama mutlak yüzde hata değerlerine ARIMA modeliyle ulaşıldığı söylenebilir. USD/TRY Kurunda ise en düşük değerler çoğunlukla Optimize ARIMA – YSA Hibrit Modeli ile ortaya konulan hata değerleridir. Modeller ortalama hata kare yöntemiyle değerlendirildiğinde tüm modeller için Optimize ARIMA – YSA Hibrit Modeli en küçük hata değerlerini verirken, aynı modellerin ortalama mutlak yüzde hata ile değerlendirilmesi Spot Altın Fiyatı ve BIST 30 Endeksi için ARIMA modelinin hata değerlerini daha düşük göstermektedir.

Bu çalışmada ele alınan zaman serileri için tanımlayıcı istatistiklere bakıldığında USD/TRY Kurunda en büyük değerin en küçük değere oranı 3,36, BIST 30 Endeksi verilerinde bu oran 98,75 ve Spot Altın Fiyatları için 8,62 olduğu görülmektedir. Ortalama mutlak yüzde hatanın serideki küçük değerleri daha çok cezalandırdığı düşünülürse ARIMA modelinin serilerdeki küçük değerleri diğer modellere göre daha iyi modellediği sonucuna varmak mümkündür.

Bir modelin performansının ölçümünde modelin gerçek veri setini açıklama gücüyle birlikte bir diğer önemli ölçüt modelin gelecek zaman verilerini tahmin etme gücüdür. Veri setini açıklamada başarılı olan bir model gelecek tahmininde başarısızsa modelin faydalı olmadığı söylenebilir. Çünkü zaman serisi modellemelerinde amaç eldeki verilerde yer alan örüntüleri tespit ederek serinin gelecekteki değerlerini tahmin etmektir. Eğer bir model, modellemede başarısız ama gelecek tahmininde başarılıysa modelin gelecek tahminlerinin şans eseri başarılı olduğu düşünülebilir. Modelin geçmiş verilerle yapılan modellemedeki başarısı gelecek tahminindeki başarısına bir dayanak oluşturur.

Optimize ARIMA – YSA Hibrit Modeli ile yapılan modellemeler sonucu her finansal varlık için 10 model kurulmakta ve 10 adet gelecek tahmini yapılmaktadır. Her üç seri için de 25.12.2016 ile 24.02.2017 tarihleri arasındaki haftalık kapanış değerleri tahmin edilmektedir. Tablo 4.54’te sırasıyla her üç seri için gerçek değerler, ARIMA tahmin değerleri, YSA tahmin değerleri ve Optimize ARIMA – YSA Modeli tahmin değerleri yer almaktadır. Tablo 4.55 ise gerçek değerlere nispetle ARIMA, YSA ve Optimize ARIMA – YSA Hibrit Modelin tahmin hatalarını göstermektedir.

Tablo 4.54. Gerçek Değerler ile ARIMA, YSA ve Optimize ARIMA – YSA Hibrit Model Tahmin Değerleri

	Tahmin Değerleri				
	Tarih	Gerçek Değer	ARIMA Tahmini	YSA Tahmini	Optimize ARIMA – YSA Hibrit Model Tahmini
SPOT ALTIN FİYATLARI	23.12.16	1131,35	1129,93	1126,65	1132,16
	30.12.16	1145,90	1126,83	1135,52	1137,68
	06.01.17	1175,85	1145,37	1148,31	1148,64
	13.01.17	1190,35	1180,32	1183,40	1184,27
	20.01.17	1200,55	1193,05	1195,34	1195,53
	27.01.17	1184,85	1198,17	1206,91	1192,07
	03.02.17	1215,20	1181,03	1175,24	1181,66
	10.02.17	1228,30	1214,91	1218,47	1216,93
	17.02.17	1241,95	1233,06	1229,40	1234,05
	24.02.17	1253,65	1244,66	1245,07	1240,18
BIST 30 ENDEKSI	23.12.16	94209,98	95541,33	95387,06	95045,36
	30.12.16	95498,58	93893,04	94311,88	94696,18
	06.01.17	93891,90	95350,69	95751,71	95328,01
	13.01.17	99607,09	94424,58	94514,31	94817,74
	20.01.17	101342,67	99067,70	98523,39	98626,44
	27.01.17	102563,05	101486,09	100371,45	101623,36
	03.02.17	108530,99	102970,42	102042,97	102994,07
	10.02.17	107123,70	107887,81	105890,83	106860,75
	17.02.17	109112,23	107553,28	106144,23	106716,37
	24.02.17	108377,63	109224,45	106471,71	108169,16
USD/TRY KURU	23.12.16	3,5169	3,4968	3,4568	3,5080
	30.12.16	3,5277	3,5241	3,5233	3,5299
	06.01.17	3,6445	3,5381	3,4812	3,5386
	13.01.17	3,7230	3,6412	3,6152	3,6425
	20.01.17	3,7655	3,7174	3,6911	3,7397
	27.01.17	3,8775	3,7720	3,7742	3,7848
	03.02.17	3,6976	3,8876	3,8762	3,8736
	10.02.17	3,6953	3,6911	3,6855	3,6927
	17.02.17	3,6290	3,6842	3,7189	3,6636
	24.02.17	3,6070	3,6339	3,6265	3,6124

Tablo 4.55. ARIMA, YSA ve Optimize ARIMA – YSA Hibrit Model Tahminleri İçin Hata Değerleri

	Tarih	Mutlak Yüzde Hata (APE)			Mutlak Hata (AE)		
		ARIMA	YSA	Optimize ARIMA – YSA Hibrit Modeli	ARIMA	YSA	Optimize ARIMA – YSA Hibrit Modeli
SPOT ALTIN FİYATLARI	23.12.16	0,126%	0,416%	0,072%	1,42	4,70	0,81
	30.12.16	1,664%	0,906%	0,717%	19,07	10,38	8,22
	06.01.17	2,592%	2,342%	2,314%	30,48	27,54	27,21
	13.01.17	0,843%	0,584%	0,511%	10,03	6,95	6,08
	20.01.17	0,625%	0,434%	0,418%	7,50	5,21	5,02
	27.01.17	1,124%	1,862%	0,610%	13,32	22,06	7,22
	03.02.17	2,812%	3,289%	2,760%	34,17	39,96	33,54
	10.02.17	1,090%	0,800%	0,925%	13,39	9,83	11,37
	17.02.17	0,716%	1,011%	0,636%	8,89	12,55	7,90
	24.02.17	0,717%	0,684%	1,075%	8,99	8,58	13,47
	ORTALAMA	1,231%	1,233%	1,004%	14,73	14,78	12,08
BIST 30 ENDEKSİ	23.12.16	1,413%	1,249%	0,887%	1331,35	1177,09	835,38
	30.12.16	1,681%	1,243%	0,840%	1605,54	1186,70	802,40
	06.01.17	1,554%	1,981%	1,530%	1458,79	1859,81	1436,11
	13.01.17	5,203%	5,113%	4,808%	5182,51	5092,78	4789,35
	20.01.17	2,245%	2,782%	2,680%	2274,97	2819,28	2716,23
	27.01.17	1,050%	2,137%	0,916%	1076,96	2191,60	939,69
	03.02.17	5,123%	5,978%	5,102%	5560,57	6488,02	5536,92
	10.02.17	0,713%	1,151%	0,245%	764,11	1232,87	262,95
	17.02.17	1,429%	2,720%	2,196%	1558,95	2968,00	2395,86
	24.02.17	0,781%	1,759%	0,192%	846,82	1905,92	208,47
	ORTALAMA	2,119%	2,611%	1,940%	2166,06	2692,21	1992,34
USD/TRY KURU	23.12.16	0,572%	1,710%	0,253%	0,0201	0,0601	0,0089
	30.12.16	0,103%	0,126%	0,062%	0,0036	0,0044	0,0022
	06.01.17	2,919%	4,481%	2,906%	0,1064	0,1633	0,1059
	13.01.17	2,197%	2,895%	2,163%	0,0818	0,1078	0,0805
	20.01.17	1,276%	1,977%	0,686%	0,0481	0,0744	0,0258
	27.01.17	2,720%	2,663%	2,392%	0,1055	0,1033	0,0927
	03.02.17	5,139%	4,830%	4,761%	0,1900	0,1786	0,1760
	10.02.17	0,115%	0,265%	0,071%	0,0042	0,0098	0,0026
	17.02.17	1,521%	2,477%	0,953%	0,0552	0,0899	0,0346
	24.02.17	0,747%	0,541%	0,150%	0,0269	0,0195	0,0054
	ORTALAMA	1,731%	2,196%	1,440%	0,0642	0,0811	0,0535

Optimize ARIMA – YSA Hibrit Modeli, ARIMA ve YSA modeline göre gelecek tahminlerinde çok daha başarılıdır. Spot Altın Fiyatı için yapılan tahminlerde 10 değer 8'ini diğer modellere göre daha iyi tahmin ederken, 2 tahminde YSA modelinin daha iyi olduğu görülmektedir. Aynı şekilde BIST 30 Endeksi için 10 tahminin 8'inde Optimize ARIMA – YSA Modelinin diğer modellere göre daha başarılı olduğu görülmektedir. USD/TRY Kuru için yapılan tahminlerin tamamında Optimize ARIMA – YSA Hibrit Modeli diğer iki modelden daha iyi tahminler ortaya koymaktadır.

Optimize ARIMA – YSA Hibrit Modelinde optimizasyon aşaması sonunda herhangi bir tahmin yapılmamaktadır. Ancak doğrusal hataların doğrusal olmayan bileşene eklenerek yeniden modellenmesi sürecinin tahmin performansına etkisini tespit etmek mümkündür. Tablo 4.56'da optimizasyon aşaması sonucu tahmin yapılırsa elde edilecek hata değerleri ve Optimize ARIMA – YSA Modeli tahmin hata değerleri karşılaştırmalı olarak verilmektedir.

Tablo 4.56. Optimizasyon Aşaması Sonucu Varsayımsal Tahmin Hataları ve Optimize ARIMA – YSA Hibrit Modeli Tahmin Hataları

	Optimizasyon Aşaması Sonucu Varsayımsal Tahmin Hatası (Mutlak Yüzde Hata)			Optimize ARIMA - YSA Hibrit Modeli Tahmin Hatası (Mutlak Yüzde Hata)		
	Spot Altın Fiyatları	BIST 30 Endeksi	USD/TRY Kuru	Spot Altın Fiyatları	BIST 30 Endeksi	USD/TRY Kuru
23.12.16	0,259%	1,333%	0,814%	0,072%	0,887%	0,253%
30.12.16	1,098%	1,472%	0,112%	0,717%	0,840%	0,062%
06.01.17	2,468%	1,760%	3,372%	2,314%	1,530%	2,906%
13.01.17	0,751%	5,147%	2,443%	0,511%	4,808%	2,163%
20.01.17	0,572%	2,452%	1,596%	0,418%	2,680%	0,686%
27.01.17	1,594%	1,491%	2,683%	0,610%	0,916%	2,392%
03.02.17	3,103%	5,551%	4,975%	2,760%	5,102%	4,761%
10.02.17	0,965%	0,120%	0,193%	0,925%	0,245%	0,071%
17.02.17	0,801%	2,115%	1,975%	0,636%	2,196%	0,953%
24.02.17	0,696%	0,442%	0,604%	1,075%	0,192%	0,150%
ORTALAMA	1,231%	2,188%	1,877%	1,004%	1,940%	1,440%

Tablo 4.56 incelendiğinde, Optimize ARIMA – YSA Hibrit Modelinde, doğrusal kısmın hatalarının doğrusal olmayan kısma eklenerek tekrar modellenmesi sürecinin elde edilecek tahmin hatalarını azalttığı ve modeli iyileştirdiği görülmektedir. 30 modelin 26'sında hataların aktarılması süreci tahmin hatalarını azaltmaktadır.

Gelecek tahminlerinde Optimize ARIMA – YSA Hibrit Modelinin tahmin hatalarını ne kadar azalttığı Tablo 4.57'de verilmektedir.

Tablo 4.57. Optimize ARIMA – YSA Modeli Tahminlerinin ARIMA ve YSA Model Tahminleri Mutlak Hata Değerini Azaltma Miktarı

Finansal Zaman Serisi	ARIMA Modeline Göre Mutlak Hatada Azalma (Ortalama)	YSA Modeline Göre Mutlak Hatada Azalma (Ortalama)
Spot Altın Fiyatı	17,94%	18,23%
BIST 30 Endeksi	8,02%	26,00%
USD/TRY Kuru	16,69%	34,07%

Tablo 4.57’de görüldüğü gibi Optimize ARIMA – YSA Hibrit Modeli, YSA modeline göre hataları 18% - 34% aralığında azaltırken, ARIMA modeline göre hatalar 8% - %18 oranlarında azaltılmaktadır.


Optimize ARIMA – YSA Hibrit Modeli ile her bir finansal varlık serisi için elde edilen tahminlerin Theil’s U istatistik değerleri Tablo 4.58’de yer almaktadır.

Tablo 4.58. Optimize ARIMA – YSA Hibrit Modeli Tahminleri İçin Theil’s U İstatistikleri


	Spot Altın Fiyatları	BIST 30 Endeksi	USD/TRY Kuru
Theil's U	0,8848	0,9144	0,9074

Tablo 4.58’de yer alan değerler incelendiğinde Optimize ARIMA – YSA Hibrit Modelinin rassal yürüyüş modelinden daha iyi sonuçlar verdiği görülmekte ve modelin güvenilir olduğu tespit edilmektedir.


Spot Altın Fiyatı, BIST 30 Endeksi ve USD/TRY Kuru için; gerçek değerler, ARIMA ve YSA tahmin değerleri ile Optimize ARIMA – YSA Modeli tahmin değerleri Şekil 4.16, Şekil 4.17 ve Şekil 4.18’de gösterilmektedir.



Şekil 4.16. Spot Altın Fiyatı Gerçek Değerler ve Tahmin Değerleri



Şekil 4.17. BIST 30 Endeksi Gerçek Değerler ve Tahmin Değerleri



Şekil 4.18. USD/TRY Kuru Gerçek Değerler ve Tahmin Değerleri

SONUÇ

Bu tez çalışmasında zaman serileri için Optimize ARIMA – YSA Hibrit Modeli ortaya konulmakta ve bazı finansal zaman serilerine uygulanarak, sonuçlar ARIMA ve YSA modelleriyle karşılaştırılmaktadır. Optimize ARIMA – YSA Hibrit Modeli zaman serisini doğrusal ve doğrusal olmayan iki bileşenin toplamı olarak varsaymaktadır. Model, doğrusal bileşenin modellenmesi için ARIMA yönteminden ve doğrusal olmayan bileşen için YSA modelinden faydalanmaktadır. Doğrusal ve doğrusal olmayan bileşenlerin en iyi tahmininin yapılması için ARIMA ve YSA model değerleri kullanılarak en küçük kareler optimizasyonu yapılmaktadır. Optimizasyon sonucu bulunan katsayılarla, zaman serisinin doğrusal ve doğrusal olmayan bileşenleri tespit edilmektedir. Optimize ARIMA – YSA Modeli zaman serisinin daha iyi açıklanabilmesi için doğrusal bileşenin hatalarını doğrusal olmayan bileşene aktararak elde edilen seriyi yeniden YSA ile modellemektedir. Böylece serinin doğrusal olmayan bileşeni yeniden düzenlenmektedir. Modellemeler sonucu elde edilen doğrusal ve doğrusal olmayan model değerlerinin toplamı, hibrit model değerleri olurken; doğrusal ve doğrusal olmayan bileşenlerden elde edilen gelecek tahmin değerlerinin toplamı, hibrit modelin gelecek tahmin değerlerini vermektedir.

Optimize ARIMA – YSA Hibrit Modelinin uygulanması için Spot Altın Fiyatı, BIST 30 Endeksi ve ABD Doları/Türk Lirası Kuru için haftalık kapanış değerleri kullanılmaktadır. Kullanılan finansal zaman serilerinin özellikle farklı özelliklerde ve farklı veri sayılarında olmasına dikkat edilmiştir. Her bir finansal varlık için son 10 haftalık kapanış değeri tahmin edilmekte ve bu sebeple her bir finansal varlık için 10 model kurulmaktadır.

Modellemeler sonucunda Optimize ARIMA – YSA Hibrit Modelinin toplam hata kare değerini düşürerek geçmiş değerleri daha iyi modellediği ortaya konulmaktadır. Modelin, en küçük kareler optimizasyonu sonucu olarak toplam hata kare değerini düşürmesi, beklenen bir sonuçtur. Ancak 30 modelin 23'ünde, optimizasyon aşamasına ek olarak, doğrusal bileşenin hatalarının doğrusal olmayan bileşene aktarılması ve YSA ile yeniden modellenmesiyle hata kareler toplamının daha da düşürüldüğü tespit edilmektedir. Toplam hata kare değerinin bu yöntemle daha da düşürülmesinin, Spot Altın Fiyatı modellerinin 70%'inde, BIST 30 Endeksi modellerinin 80%'inde ve USD/TRY Kuru modellerinin 80%'inde gözlemlenmesi; durumun uygulanan zaman serisine ait bir özellik değil, hibrit modelin bir özelliği olduğunu ortaya koymaktadır.

Yeni bir model olarak geliştirilen Optimize ARIMA – YSA Hibrit modeli, modelleme aşamasında ARIMA ve YSA modellerinden daha iyi olduğu gibi, modellemeler sonucu yapılan

gelecek tahminlerinin doğruluğu açısından da ARIMA ve YSA modellerinden daha iyi sonuçlar verdiği görülmektedir. Optimize ARIMA – YSA Hibrit Modeli, Spot Altın Fiyatı tahminlerinin 80%'inde, BIST 30 Endeksi tahminlerinin 80%'inde ve USD/TRY Kuru tahminlerinin 100%'ünde ARIMA ve YSA modellerine göre daha başarılıdır. Kurulan 30 modelin 26'sında hibrit modelin gelecek tahminlerinin, optimizasyon aşaması ile sonlanacak bir modelin gelecek tahminlerinden daha iyi olduğu gözlemlenmektedir. Bu sebeple, optimizasyon aşaması sonrası doğrusal olmayan bileşenin yeniden düzenlenmesi ve YSA ile modellenmesi sürecinin gelecek tahmini hatalarını azalttığı sonucuna varmak mümkündür.

Optimize ARIMA – YSA Hibrit Modelinin hem modelleme aşamasında hem de gelecek tahmini aşamasında başarılı olması tutarlıdır. Modelleme aşamasındaki başarı, gelecek tahmini aşamasındaki başarının rastlantı olmadığını ortaya koyarken; gelecek tahminindeki başarı, modelleme aşamasındaki başarının sonuç verdiği anlamına gelmektedir.

Finansal zaman serileri, yüksek volatiliteli, modellenmesi ve tahmin edilmesi zor serilerdir. Bu sebeple literatürde yer alan birçok zaman serisi modeli finansal zaman serileri ile kullanıldığında yetersiz kalabilmektedir. Uygulama aşamasında elde edilen sonuçlar, geliştirilen Optimize ARIMA – YSA Hibrit Modelinin finansal zaman serilerinin modellenmesi ve gelecek tahmini yapılması için kullanılabilecek güçlü bir model olduğunu, ARIMA ve YSA modellerine göre daha iyi sonuçlar verdiğini göstermektedir. Uygulama için seçilen üç farklı finansal varlık serisi, farklı karakterlerde ve farklı sayılarda veri içeren zaman serileridir. Optimize ARIMA – YSA Hibrit Modelinin her üç finansal varlık için de başarılı sonuçlar vermesi, hibrit modelin birbirinden farklı özelliklerde finansal zaman serileri için uygulanabilirliğini ortaya koymaktadır.

Optimize ARIMA – YSA Hibrit Modeli daha fazla araştırmaya açık bir modeldir. Modelin farklı finansal ya da finansal olmayan zaman serilerine uygulanması ve farklı veri sayıları içeren serilerin modellenmesi, modelin genel geçerliği açısından faydalı olacaktır. Çalışmada verilerin haftalık kapanış değerleri olarak seçildiği düşünülürse; model aylık, günlük, saatlik kapanış değerleri gibi farklı değerlere uygulanarak sonuçları karşılaştırılabilir. Ayrıca bu çalışmada bir adım ileri tahminler yapılmakta ve modeller buna göre oluşturulmaktadır. Model gelecek çalışmalarda çok adım ileri tahmin ve modelleme performansının ölçülmesi için kullanılabilir. Optimize ARIMA – YSA Hibrit Modeli, doğrusal zaman serisi için ARIMA ve doğrusal olmayan zaman serisi için YSA modelini kullanmaktadır. Modeldeki doğrusal ve doğrusal olmayan bileşenler için farklı yöntemler kullanılarak hibrit modelin bundan sonraki çalışmalarda geliştirilmesi mümkün olabilecektir.

KAYNAKÇA

- Abdullah, L. (2012). "ARIMA Model for Gold Bullion Coin Selling Prices Forecasting". *International Journal of Advances in Applied Sciences*, 1(4): 153-158.
- Aburto, L., ve Weber, R. (2007). "Improved Supply Chain Management Based on Hybrid Demand Forecasts". *Applied Soft Computing*, 7(1): 136-144.
- Ahmed, R. A. ve Shabri, A. B. (2014). "Daily Crude Oil Price Forecasting Model Using ARIMA, Generalized Autoregressive Conditional Heteroscedastic and Support Vector Machines". *American Journal of Applied Sciences*, 11(3): 425-432.
- Akpanta, A. C. ve Okorie, I. E. (2014). "Application of Box-Jenkins Techniques in Modelling and Forecasting Nigeria Crude Oil Prices". *International Journal of Statistics and Applications*, 4(6): 283-291.
- Alwadi, R. (2015). "Forecasting Short Term Financial Data". *European Scientific Journal*, 11(25): 1857-7881.
- Anderson, D. R., Dennis, J. S. ve Williams, T. A. (2010). *Statistics for Business and Economics*. South Western, Mason, OH.
- Ariyo, A. A., Adewumi, A. O. ve Ayo, C. K. (2014). "Stock Price Prediction Using the ARIMA Model". *Computer Modelling and Simulation (UKSim), 2014 UKSim-AMSS 16th International Conference on* (106-112). Cambridge.
- Arltova, M. ve Fedorova, D. (2016). "Selection of Unit Root Test on the Basis of Length of the Time Series and Value of AR(1) Parameter". *Statistika*, 96(3): 47-64.
- Aslanargun, A., Mammadov, M., Yazici, B. ve Yolacan, S. (2007). "Comparison of ARIMA Neural Networks and Hybrid Models in Time Series: Tourist Arrival Forecasting". *Journal of Statistical Computation and Simulation*, 77(1): 29 – 53.
- Awartani, B. M. A. ve Corradi, V. (2005). "Predicting The Volatility of The S&P-500 Stock Index Via GARCH Models: The Role of Asymmetries". *International Journal of Forecasting*, 21: 167-183.
- Aznarte, J. L., Alcala-Fdez, J., Arauzo-Azofra, A. ve Benitez, J. M. (2012). "Financial Time Series Forecasting with a Bio-Inspired Fuzzy Model". *Expert Systems with Applications*, 39: 12302-12309.
- Babu, C. N. ve Reddy, B. E. (2014). "A Moving-Average Filter Based Hybrid ARIMA-ANN Model for Forecasting Time Series Data". *Applied Soft Computing*, 23: 27-38.
- Babu, A. S. ve Reddy, S. K. (2015). "Exchange Rate Forecasting Using ARIMA, Neural Network and Fuzzy Neuron". *Journal of Stock Forex Trading*, 4(3): 1-5.

- Bank for International Settlements. (2016). *Triennial Central Bank Survey: Foreign Exchange turnover in April 2016*. Bank for International Settlements, Basel.
- Baydar, G. (2013). “Gençlerin gündelik yaşamında sosyal medya”. *Yeni Medya Çalışmaları I. Ulusal Kongresi Kongre Kitabı*. 7-8 Mayıs 2013, Kocaeli, s. 132-142.
- Bentes, S. R. (2015). “Forecasting Volatility in Gold Returns Under the GARCH, IGARCH and FIGARCH Frameworks: New Evidence”. *Physica A*, 438: 355-364.
- Bollerslev, T. (1986). “Generalized Autoregressive Conditional Heteroskedasticity”. *Journal of Econometrics*, 31: 307-327.
- Borsa İstanbul. (2016). “BIST Pay Endeksleri Temel Kuralları”. Borsa İstanbul, İstanbul.
- Box, G. E. P. ve Jenkins, G. M. (1976). *Time Series Analysis: Forecasting and Control*. Holden-day Inc, San Francisco, CA.
- Brigham, E. F. ve Houston, J. F. (2007). *Fundamentals of Financial Management*. Thomson South-Western, Mason, OH.
- Brockwell, P. J. ve Davis, R. A. (2002). *Introduction to Time Series and Forecasting, Second Edition*. Springer-Verlag, New York.
- Brooks, C. (2008). *Introductory Econometrics for Finance*. Cambridge University Press, New York.
- Cheng, C. H., Chen, T. L., Teoh, H. J. ve Chiang, C. H. (2008). “Fuzzy Time-Series Based on Adaptive Expectation Model for TAIEX Forecasting”. *Expert Systems with Applications*, 34: 1126-1132.
- Cadenas, E. ve Rivera, W. (2010). “Wind Speed Forecasting in Three Different Regions of Mexico, Using a Hybrid ARIMA – ANN Model”. *Renewable Energy*, 35: 2732-2738.
- Carpenter, G. A. ve Grossberg, S. (1987). “A massively parallel architecture for a self-organizing neural pattern recognition machine”. *Computer Vision, Graphics, and Image Processing*, 37: 54-115.
- Chen, Z. ve Yang, Y. (2004). “Assessing Forecast Accuracy Measures”. *Technical Report 2004 – 2010*. Iowa State University, Department of Statistics & Statistical Laboratory, Iowa, s:1-26.
- Chen, C., Twycross, J. ve Garibaldi J. M. (2017). “A new accuracy measure based on bounded relative error for time series forecasting”. *Plos One*, 12(3): 1-23.
- Chakra, C. N.C., Song, K. Y., Saraf, D. N. ve Gupta, M. M. (2013). “Production Forecasting of Petroleum Reservoir Applying Higher-Order Neural Networks (HONN) With Limited Reservoir Data”. *International Journal of Computer Applications*, 72(2): 23-35.
- Chakraborti, A., Patriarca, M. ve Santhanam, M. S. (2007). “Financial time-series analysis: A brief overview”. A., Chatterjee ve B. K., Chakrabarti (Ed.). *Econophysics of Markets*

- and Business Networks: *Proceedings of the Econophys-Kolkata III*. Springer, Milan, s. 51-67.
- Cooper, R. N. (1982). "The Gold Standard: Historical Facts and Future Prospects". *Brookings Papers on Economic Activity*, 1982(1): 1-45.
- Costea, A. (2012). "Applying Fuzzy C-Means And Artificial Neural Networks For Analyzing The Non-Banking Financial Institutions' Sector in Romania". *Journal of Applied Quantitative Methods*, 7(3): 26-32.
- Credit Suisse. (2012). *Commodities – An Introduction*. Credit Suisse, Zürich.
- Crone, S. F. ve Dhawan, R. (2007). "Forecasting Seasonal Time Series with Neural Networks: A Sensitivity Analysis of Architecture Parameters". *Proceedings of International Joint Conference on Neural Networks, IJCNN'07*. IEEE Computer Society Press, Florida, ABD, s. 2099-2104.
- Dagum, E. B. (2010). "Time Series Modelling and Decomposition". *Statistica*, 70(4): 433-457.
- Dağlı, H. (2000). "Hisse Senedi Piyasa Endeksleri ve Türkiye". *Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 3(4): 189-206.
- Das, S. P. ve Padhy, S. (2012). "Support Vector Machines for Prediction of Futures Prices in Indian Stock Market". *International Journal of Computer Applications*, 41(3): 22-26.
- De Gooijer, J. G. ve Hyndman, R. J. (2006). 25 Years of Time Series Forecasting. *International Journal of Forecasting*. 22: 443-473.
- Deng, K., Moore, A. W. ve Nechyba, M. C. (1997). "Learning to Recognize Time Series: Combining ARMA models with Memory-based Learning". *Proceedings 1997 IEEE International Symposium on Computational Intelligence in Robotics and Automation CIRA'97*. 10-11 Temmuz 1997, California, s. 246-251.
- Dias, J. G., Vermunt, J. K. ve Ramos, S. (2015). "Clustering Financial Time Series: New Insights from an Extended Hidden Markov Model". *European Journal of Operational Research*, 243: 852-864.
- Dickey, D. A. ve Fuller, W. A. (1979). "Distribution of the Estimators for Autoregressive Time Series with a Unit Root". *Journal of the American Stat. Association*, 74: 427-431.
- Dickey, D. A. (1976). *Estimation and Hypothesis Testing in Nonstationary Time Series*. Yayınlanmamış Doktora Tezi. Iowa State University, ABD.
- Dong, B., Li, X. ve Lin, B. (2010). "Forecasting Long-Run Coal Price in China: A Shifting Trend Time-Series Approach". *Review of Development Economics*, 14(3): 499-519.
- Durdu, Ö. F. (2010). "A Hybrid Neural Network and ARIMA Model for Water Quality Time Series Prediction". *Engineering Applications of Artificial Intelligence*, 23: 586-594.

- Elwasify, A. I. (2015). "A Combined Model between Artificial Neural Networks and ARIMA Models". *International Journal of Recent Research in Commerce Economics and Management*, 2(2): 134-140.
- Engle, R. F. (1982). "Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation". *Econometrica*, 50(4): 987-1007.
- Falk, M., Marohn, F., Michel, R., Hofmann, D., Macke, M., Spachmann, C. ve Englert, S. (2012). *A First Course on Time Series Analysis Examples with SAS*. Chair of Statistics, University of Würzburg, Würzburg.
- Fiszeder, P. ve Perczak, G. (2016). "Low and High Prices Can Improve Volatility Forecasts During Periods of Turmoil". *International Journal of Forecasting*, 32: 398-410.
- Fontes T., Silva L. M., Pereira S. R. ve Coelho M. C. (2013). "Application of Artificial Neural Networks to Predict the Impact of Traffic Emissions on Human Health". Correia L., Reis L.P. ve Cascalho J. (Ed.) *Progress in Artificial Intelligence. EPIA 2013. Lecture Notes in Computer Science*, vol 8154. Springer, Berlin, s. 21-29.
- Glosten, L. R., Jagannathan, R. ve Runkle, D. E. (1993). "On the Relation Between the Expected Value and the Volatility of the Nominal Excess Return on Stocks". *Journal of Finance*, 48: 1779-1801.
- Green, S. (2011). *Time Series Analysis of Stock Prices Using the Box-Jenkins Approach*. Yayınlanmamış Yüksek Lisans Tezi. Jack N. Averitt College of Graduate Studies, Georgia Southern University, Georgia.
- Guha, B. ve Bandyopadhyay, G. (2016). "Gold Price Forecasting Using ARIMA Model". *Journal of Advanced Management*, 4(2): 117-121.
- Guo, X., Li, D. ve Zhang, A. (2012). "Improved Support Vector Machine Oil Price Forecast Model Based on Genetic Algorithm Optimization Parameters". *AASRI Procedia*, 1: 525-530.
- Guresen, E., Kayakutlu, G. ve Daim, T. U. (2011). "Using Artificial Neural Network Models in Stock Market Index Prediction". *Expert Systems with Applications*, 38: 10389-10397.
- Gurney, K. (1997). *An Introduction to Neural Networks*. UCL Press, Londra.
- Hann, T. H. ve Steurer, E. (1996). "Much Ado About Nothing? Exchange Rate Forecasting: Neural Networks vs. Linear Models Using Monthly and Weekly Data". *Neurocomputing*, 10: 323-339.
- Hagan, M. T., Demuth, H. B., Beale, M. H. ve De Jesus, O. (2015). "Neural Network Design 2nd Edition". <http://hagan.okstate.edu/NNDesign.pdf>. (erişim tarihi: 15.02.2017).

- Haykin, S. (2008). *Neural Networks and Learning Machines Third Edition*. Pearson Prentice Hall, New Jersey.
- Huang, S. C., Chuang, P. J., Wu, C. F. ve Lai, H. J. (2010). "Chaos-Based Support Vector Regressions for Exchange Rate Forecasting". *Expert Systems with Applications*, 37: 8590-8598.
- Huang, W., Nakamori, Y. ve Wang, S., (2004). "A General Approach Based on Autocorrelation to Determine Input Variables of Neural Networks For Time Series Forecasting". *Journal of Systems Science and Complexity*, 17(3): 297-305.
- Huang, W., Nakamori, Y. ve Wang, S., (2005). "Forecasting Stock Market Movement Direction with Support Vector Machine". *Computers & Operations Research*, 32: 2513-2522.
- Hurvich, C. M. ve Tsai C. (1989). Regression and Time Series Model Selection in Small Samples. *Biometrika*, 76(2): 297-307.
- Hussain, A. J., Knowles, A., Lisboa, P. J. G. ve El-Deredy, W. (2008). "Financial Time Series Prediction Using Polynomial Pipelined Neural Networks". *Expert Systems with Applications*, 35: 1186-1199.
- Hwang, K. P. ve Day, Y. J. (2013). "Tourism Revenue Forecasting: A Hybrid Model Approach". *Actual Problems of Economics*, 141(3): 473-483.
- Hyndman, R. J. ve Khandakar, Y. (2008). "Automatic Time Series Forecasting: The Forecast Package for R". *Journal of Statistical Software*, 27(3): 1-22.
- İskenderoğlu, L. (1988). "Uluslararası Para Sisteminin Sorunları ve İyileştirme Çalışmaları". TCMB Tartışma Tebliği, No:8807.
- Kaasra, I. ve Boyd, M. (1996). "Designing a Neural Network For Forecasting Financial and Economic Time Series". *Neurocomputing*, 10: 215-236.
- Khalid, B., Sultana, M. ve Zaifi, F. (2014). "Forecasting Gold Price: Evidence from Pakistan Market". *Research Journal of Finance and Accounting*, 5(3): 70-74.
- Khan, M. M. A. (2013). "Forecasting of Gold Prices (Box Jenkins Approach)". *International Journal of Emerging Technology and Advanced Engineering*, 3(3), 662-670.
- Khashei, M. ve Bijari, M. (2011). "A Novel Hybridization of Artificial Neural Networks and ARIMA Models for Time Series Forecasting". *Applied Soft Computing*, 11: 2664-2675.
- Khemchandani, R., Jayadeva ve Chandra, S. (2009). "Regularized Least Squares Fuzzy Support Vector Regression for Financial Time Series Forecasting". *Expert Systems with Applications*, 36: 132-138.
- Kim, K. J. (2003). "Financial Time Series Forecasting Using Support Vector Machines". *Neurocomputing*, 55: 307-319.

- Kohonen, T. (1982). "Self-organized formation of topologically correct feature maps". *Biological Cybernetics*, 43(1): 59-69.
- Konarasinghe, W. G. S., Abeynayake, N. R. ve Gunaratne, L. H. P. (2015). "ARIMA Models on Forecasting Sri Lankan Share Market Returns". *International Journal of Novel Research in Physics Chemistry & Mathematics*, 2(1): 6-12.
- Korol, T. (2014). "A Fuzzy Logic Model for Forecasting Exchange Rates". *Knowledge-Based Systems*, 67: 49-60.
- Krenker, A., Bester, J. ve Kos, A. (2011). "Introduction to the Artificial Neural Networks". K., Suzuki (Ed.). *Artificial Neural Networks – Methodological Advances and Biomedical Applications*. Intech, Rijeka, s. 1-18.
- Kumbhar, G. V. ve Argiddi, R. V. (2015). "Stock Market Index Prediction by Hybrid Neuro-Genetic Data Mining Technique". *International Journal of Advanced Research in Computer and Communication Engineering*, 4(5): 318-322.
- Kwiatkowski, D., Phillips, P. C. B., Schmidt, P., Shin, Y. (1992). "Testing the Null Hypothesis of Stationarity Against the Alternative of a Unit Root". *Journal of Econometrics*, 54: 159–178.
- Leu, Y., Lee, C. P. ve Jou, Y. Z. (2009). "A Distance-Based Fuzzy Time Series Model for Exchange Rates Forecasting". *Expert Systems with Applications*, 36: 8107-8114.
- Levich, R. M., ve Rizzo, R. C. (1998). "Alternative Tests for Time Series Dependence Based on Autocorrelation Coefficients". <http://pages.stern.nyu.edu/~rlevich/wp/LR1.pdf>. (erişim tarihi: 25.02.2017).
- Levinson, M. (2005). *The Economist Guide to Financial Markets*. Profile Books, Londra.
- Lu, C. J., Lee, T. S. ve Chiu, C. C. (2009). "Financial Time Series Forecasting Using Independent Component Analysis and Support Vector Regression". *Decision Support Systems*, 47: 115-125.
- Mackinnon, J. G. (1991). "Critical Values for Cointegration Tests". R. F., Engle ve C. W. J., Granger (Ed.). *Long-Run Economic Relationships: Readings in Cointegration*. Oxford University Press, Oxford, s. 267–276.
- Mahalakshmi, N., Umarani, P. R. ve Selvaraj, R. S. (2014). "Research Article Forecasting the Tamil Nadu Rainfall Using Hybrid ARIMA–ANN Model". *International Journal of Recent Scientific Research Research*, 5(3): 566-569.
- Majhi, R., Panda, G., Majhi, B. ve Sahoo, G. (2009). "Efficient Prediction of Stock Market Indices Using Adaptive Bacterial Foraging Optimization (ABFO) and BFO Based Techniques". *Expert Systems with Applications*, 36: 10097-10104.

- Merh, N., Saxena, V. P. ve Pardasani, K. R. (2010). "A Comparison Between Hybrid Approaches of ANN and ARIMA for Indian Stock Trend Forecasting". *Business Intelligence Journal*, 3(2): 23-43.
- Mishkin, F. S. ve Eakins, S. G. (2012). *Financial Markets and Institutions*. Pearson Prentice Hall, Boston.
- Mishra, P. (2012). "Forecasting Natural Gas Price - Time Series and Nonparametric Approach". *Proceedings of the World Congress on Engineering 2012 Vol I*, 4-6 Temmuz 2012, Londra, s. 490-497.
- Moghaddasi, R. ve Badr, B. R. (2008). "An Econometric Model for Wheat Price Forecasting in Iran". *Proceedings: International Conference on Applied Economics – ICOAE 2008*, 15-17 Mayıs 2008, Kastoria, s. 671-678.
- Mombeini, H. ve Yazdani-Chamzini, A. (2015). "Modeling Gold Price via Artificial Neural Network". *Journal of Economics, Business and Management*, 3(7): 699-703.
- Moosa, I. ve Burns, K. (2014). "The Unbeatable Random Walk in Exchange Rate Forecasting: Reality or Myth?". *Journal of Macroeconomics*, 40: 69-81.
- Nasira, G. M. ve Hemaeeetha, N. (2012). "Forecasting Model for Vegetable Price Using Back Propagation Neural Network". *International Journal of Computational Intelligence and Informatics*, 2(2): 110-115.
- Nelson, D. B. (1991). "Conditional Heteroskedasticity in Asset Returns: A New Approach". *Econometrica*, 59: 347-370.
- Nwankwo, S. C. (2014). "Autoregressive Integrated Moving Average (ARIMA) Model for Exchange Rate (Naira to Dollar)". *Academic Journal of Interdisciplinary Studies*, 3(4): 429-432.
- Oancea, B. ve Ciucu, S. (2014). "Time Series Forecasting Using Neural Networks". *Challenges of the Knowledge Society*, 1402-1408.
- Panchal, G., Ganatra, A., Kosta, Y. P. ve Panchal, D. (2011). "Behaviour Analysis of Multilayer Perceptrons with Multiple Hidden Neurons and Hidden Layers". *International Journal of Computer Theory and Engineering*, 3(2): 332-337.
- Panda, C. ve Narasimhan, V. (2007). "Forecasting Exchange Rate Better with Artificial Neural Network". *Journal of Policy Modeling*, 29: 227-236.
- Parisi, A., Parisi, F. ve Diaz, D. (2008). "Forecasting Gold Price Changes: Rolling and Recursive Neural Network Models". *Journal of Multinational Financial Management*, 18: 477-487.

- Patel, P. J., Patel, N. J. ve Patel, A. R. (2014). "Factors affecting Currency Exchange Rate, Economical Formulas and Prediction Models". *International Journal of Application or Innovation in Engineering & Management*, 3(3): 53-56.
- Patel, M. B. ve Yalamalle, S. R. (2014). "Stock Price Prediction Using Artificial Neural Network". *International Journal of Innovative Research in Science, Engineering and Technology*, 3(6): 13755-13762.
- Paul, J. C., Hoque, S. ve Rahman, M. M. (2013). "Selection of Best ARIMA Model for Forecasting Average Daily Share Price Index of Pharmaceutical Companies in Bangladesh: A Case Study on Square Pharmaceutical Ltd.". *Global Journal of Management and Business Research Finance*, 13(3): 15-26.
- Poon, S. H., ve Granger, C. W. J. (2003). "Forecasting Volatility in Financial Markets: A Review". *Journal of Economic Literature*, 151: 478-539.
- Priddy, S. ve Keller, P. E. (2005). *Artificial Neural Networks: An Introduction*. SPIE Press, New York.
- Priyadarshini, E. (2014). "Predictive Analysis of Exchange Rates Using Hybrid Models". *Applied Mathematical Sciences*, 8(160): 7987-7992.
- Rosowsky, Y. I. ve Smith, R. E. (2013). "Rejection Based Support Vector Machines for Financial Time Series Forecasting". *Proceedings of International Joint Conference on Neural Networks, Dallas, Texas, USA, August 4-9, 2013*. 1161-1167.
- Sağıroğlu, Ş. (1998). "Artificial neural networks in robotic applications". *International Journal of Mathematical and Computational Applications*, 3(2): 87-92.
- Sharma, P. ve Vipul (2016). "Forecasting Stock Market Volatility Using Realized GARCH Model: International Evidence". *The Quarterly Review of Economics and Finance*, 59: 222-230.
- Shumway, R. H. ve Stoffer, D. S. (2011). *Time Series Analysis and Its Applications with R Examples*. Springer, New York.
- Silva, E. G. S., Legey, L. F. L. ve Silva, E. A. S. (2010). "Forecasting Oil Price Trends Using Wavelets and Hidden Markov Models". *Energy Economics*, 32: 1507-1519.
- Snipes, M. ve Taylor, D. C. (2014). Model Selection and Akaike Information Criteria: An Example From Wine Ratings and Prices. *Wine Economics and Policy*, 3: 3-9.
- Sompui, M. ve Wongsinlatam, W. (2014). "Prediction Model for Crude Oil Price Using Artificial Neural Networks". *Applied Mathematical Sciences*, 8(80): 3953-3965.
- Song, Q. ve Chissom, B. S. (1993). "Fuzzy Time Series and Its Models". *Fuzzy Sets and Systems*, 54(3): 269-277.

- Sotoudeh, M. ve Farshad, E. (2012). "Application of Neural Network for Forecasting Gas Price in America". *The Journal of Mathematics and Computer Science*, 4(2): 216-226.
- Strozzi, F. ve Zaldivar, J. M. (2005). "Non-Linear Forecasting in High-Frequency Financial Time Series". *Physica A*, 353: 463-479.
- Tan, C. N. W. (1998). "An Artificial Neural Networks Primer with Financial Applications Examples in Financial Distress Predictions and Foreign Exchange Hybrid Trading System". <http://www.smartquant.com/references/NeuralNetworks/neural28.pdf>. (erişim tarihi: 20.02.2017).
- Tay, F. E. H. ve Cao, L. (2001). "Application of Support Vector Machines in Financial Time Series Forecasting". *Omega*, 29: 309-317.
- Tay, F. E. H. ve Cao, L. J. (2002). Modified Support Vector Machines in Financial Time Series Forecasting. *Neurocomputing*, 48: 847-861.
- Topçu, A. (2010). *Altın Fiyatlarını Etkileyen Faktörler*. Araştırma Raporu, Sermaye Piyasası Kurulu Araştırma Dairesi, Ankara.
- Tsay, R. S. (2002). *Analysis of Financial Time Series*. Wiley, New York.
- Tseng, F. M., Tzeng, G. H., Yu, H. C. ve Yuan, B. J. C. (2001). Fuzzy ARIMA Model for Forecasting the Foreign Exchange Market. *Fuzzy Sets and Systems*, 118: 9-19.
- Tseng, F. M., Yu, H. C. ve Tzeng, G. H. (2002). "Combining Neural Network Model with Seasonal Time Series ARIMA Model". *Technological Forecasting & Social Change*, 69: 71-87.
- Uğurlu, E. (2009). "Durağanlık ve Birim Kök Sınamaları". https://www.researchgate.net/publication/281647245_Duraganlik_Birim_Kok_Sinamaları-Stationarity_Unit_Root_Tests. (erişim tarihi: 15.01.2017).
- Vapnik, V. (1995). *The Nature of Statistical Learning*. Springer-Verlag, New York.
- Vapnik, V., Golowich, S. E., ve Smola, A. (1996). "Support Vector Method for Function Approximation, Regression Estimation, and Signal Processing". *Advances in Neural Information Processing Systems* 9, 2-5 Aralık 1996. Denver, CO, s.281-287.
- Wang, L. (2012). *Investment in Gold: An Empirical Study of the Gold Return from 90s to 21st*. Yayınlanmamış Yüksek Lisans Tezi. Department of Economics, Copenhagen Business School, Danimarka.
- Wang, L., Zou, H., Su, J., Li, L. ve Chaudrhy, S. (2013). "An ARIMA-ANN Hybrid Model for Time Series Forecasting". *Systems Research and Behavioral Science*, 30: 244-259.
- Wang, X. ve Meng, M. (2012). "A Hybrid Neural Network and ARIMA Model for Energy Consumption Forecasting". *Journal of Computers*, 7(5): 1184-1190.

- Wang, Y. ve Wu, C. (2012). “Forecasting Energy Market Volatility Using GARCH Models: Can Multivariate Models Beat Univariate Models?”. *Energy Economics*, 34: 2167-2181.
- Wei, Y., Wang, Y. ve Huang, D. (2010). “Forecasting Crude Oil Market Volatility: Further Evidence Using GARCH-Class Models”. *Energy Economics*, 32: 1477-1484.
- Yan, H. ve Zou, Z. (2013). “Application of a Hybrid ARIMA and Neural Network Model to Water Quality Time Series Forecasting”. *Journal of Convergence Information Technology*, 8(4): 59-70.
- Yao, J. T. ve Herbert, J. P. (2009). “Financial Time-Series Analysis With Rough Sets”. *Applied Soft Computing*, 9: 1000-1007.
- Ye, S. (2012). “RMB Exchange Rate Forecast Approach Based on BP Neural Network”. *Physics Procedia*, 33: 287-293.
- Yüksel, D. (2015). *Arap Baharı’ndan Etkilenen Yakın ve Ortadoğu Ülkeleri ile Türkiye Arasındaki İthalat ve İhracat Miktarlarının ARIMA Modelleri ile İncelenmesi*. Yayınlanmamış Yüksek Lisans Tezi. Sosyal Bilimler Enstitüsü, Dokuz Eylül Üniversitesi, Türkiye.
- Yürekli, K., Kurunç, A. ve Öztürk, F. (2005). “Testing the Residuals of an ARIMA Model on the Çekerek Stream Watershed in Turkey”. *Turkish Journal of Engineering and Environmental Sciences*, 29: 61-74.
- Zhang, Y. (2001). *Prediction of Financial Time Series with Hidden Markov Models*. Yayınlanmamış Yüksek Lisans Tezi. The School of Computing Science, Shandong University, Çin.
- Zhang, G. P. (2003). “Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model”. *Neurocomputing*, 50: 159-175.
- Zhang, G. P. ve Qi, M. (2005). “Neural Network Forecasting for Seasonal and Trend Time Series”. *European Journal of Operational Research*. 160: 501–514.
- “BIST Pay Endeksleri”. <http://www.borsaistanbul.com/endeksler/bist-pay-endeksleri>. (erişim tarihi: 24.02.2017)
- “Gold Data and Statistics”. <http://www.gold.org/statistics>. (erişim tarihi: 23.01.2017)
- “IMF Releases Data on the Currency Composition of Foreign Exchange Reserves Including Holdings in Renminbi”. <http://www.imf.org/en/News/Articles/2017/03/31/pr17108-IMF-Releases-Data-on-the-Currency-Composition-of-Foreign-Exchange-Reserves>. (erişim tarihi: 24.04.2017)

EK 1 - SPOT ALTIN FİYATI ARIMA MODEL ARAMA SÜRECİ

		Katsayılar			HAFTA									
		p	d	q	23.12.16	30.12.16	06.01.17	13.01.17	20.01.17	27.01.17	03.02.17	10.02.17	17.02.17	24.02.17
1. ARAMA	0	1	0											
	0	1	1		17477,22	17485,05	17493,40	17503,56	17511,99	17520,11	17528,52	17538,58	17546,91	17555,23
	0	1	2		17478,89	17486,71	17495,10	17505,27	17513,68	17521,77	17530,20	17540,24	17548,58	17556,88
	1	1	0		17477,16	17484,99	17493,34	17503,51	17511,94	17520,05	17528,46	17538,52	17546,85	17555,17
	1	1	1		17479,02	17486,85	17495,21	17505,37	17513,80	17521,90	17530,32	17540,37	17548,71	17557,01
	1	1	2		17480,89	17488,71	17497,09	17507,27	17515,68	17523,77	17532,20	17542,24	17550,58	17558,88
	2	1	0		17478,93	17486,76	17495,13	17505,30	17513,72	17521,81	17530,24	17540,28	17548,62	17556,92
	2	1	1		17480,91	17488,74	17497,12	17507,29	17515,71	17523,80	17532,23	17542,27	17550,61	17558,91
	2	1	2		17456,81	17464,59	17473,32	17483,50	17493,29	17499,48	17507,74	17518,53	17526,79	17534,80
	1	1	1		17479,02	17486,85	17495,21	17505,37	17513,80	17521,90	17530,32	17540,37	17548,71	17557,01
2. ARAMA	1	1	2		17480,89	17488,71	17497,09	17507,27	17515,68	17523,77	17532,20	17542,24	17550,58	17558,88
	1	1	3		17482,72	17490,52	17498,95	17509,14	17517,57	17525,62	17534,11	17544,13	17552,43	17560,72
	2	1	1		17480,91	17488,74	17497,12	17507,29	17515,71	17523,80	17532,23	17542,27	17550,61	17558,91
	2	1	2		17456,81	17464,59	17473,32	17483,50	17493,29	17499,48	17507,74	17518,53	17526,79	17534,80
	2	1	3		17457,00	17464,80	17473,50	17483,69	17516,31	17499,75	17507,98	17518,65	17552,80	17538,44
	3	1	1		17482,72	17490,57	17498,95	17509,18	17517,59	17525,68	17534,12	17544,15	17552,47	17560,76
	3	1	2		17457,06	17464,87	17473,57	17483,77	17491,87	17499,82	17508,05	17542,99	17527,06	17535,56
	3	1	3		17481,97	17493,14	17476,37	17511,44	17494,63	17502,57	17510,81	17521,55	17529,82	17537,82
	2	1	1						17515,71					
	2	1	2						17493,29					
3. ARAMA	2	1	3						17516,31					
	3	1	1						17517,59					
	3	1	2						17491,87					
	3	1	3						17494,63					
	4	1	1						17513,72					
	4	1	2						17493,29					
	4	1	3						17518,72					
	En İyi Model				(2,1,2)	(2,1,2)	(2,1,2)	(2,1,2)	(3,1,2)	(2,1,2)	(2,1,2)	(2,1,2)	(2,1,2)	(2,1,2)

EK 4 - ARIMA MODELLERİ İÇİN ARTIK DEĞERLERİN OTOKORELASYON VE KİSMİ OTOKORELASYON DEĞERLERİ İÇİNDE LİMİT DEĞERLERİ AŞAN GECİKMELER

	Hafta	Otokorelasyon Değeri Limit Değeri Aşan Gecikmeli Veriler	Kısmi Otokorelasyon Değeri Limit Değeri Aşan Gecikmeli Veriler
SPOT ALTIN FİYATI	23.12.16	15,16,17,21,24,25	15,16,17,21,24,25
	30.12.16	15,16,17,21,24,25	15,16,17,21,24,25
	06.01.17	15,16,17,21,24,25	15,16,17,21,24,25
	13.01.17	15,16,17,21,24,25	15,16,17,21,24,25
	20.01.17	15,16,17,21,24,25	15,16,17,21,24,25
	27.01.17	15,16,17,21,24,25	15,16,17,21,24,25
	03.02.17	15,16,17,21,24,25	15,16,17,21,24,25
	10.02.17	15,16,17,21,24,25	15,16,17,21,24,25
	17.02.17	15,16,17,21,24,25	15,16,17,21,24,25
	24.02.17	15,16,17,21,24,25	15,16,17,21,24,25
BIST 30 ENDEKSİ	23.12.16	14	14
	30.12.16	14	14
	06.01.17	14	14
	13.01.17	14	14
	20.01.17	14	14
	27.01.17	14	14
	03.02.17	14	14
	10.02.17	14	14
	17.02.17	14	14
	24.02.17	14	14
USD/TRY KURU	23.12.16	6,17	6,17,28
	30.12.16	6,17	6,17,28
	06.01.17	6,17	6,17,28
	13.01.17	6,17	6,17,28
	20.01.17	6,17	6,17,28
	27.01.17	6,17	6,17,28
	03.02.17	6,17	6,17,28
	10.02.17	6,17	6,17,28
	17.02.17	6,17	6,17,28
	24.02.17	-	17,27

EK 5 - ARIMA MODELLERİ İÇİN ARTIKLARIN 95% GÜVEN ARALIĞINDA LJUNG BOX Q TESTİ SONUÇLARI

	Hafta	T	ln(T)	m	Q(m)	p Değeri
Spot Altın Fiyatı	23.12.16	1982	7,59	8	8,8711	0,3533
	30.12.16	1983	7,59	8	8,8496	0,3551
	06.01.17	1984	7,59	8	9,0723	0,3362
	13.01.17	1985	7,59	8	9,7376	0,2839
	20.01.17	1986	7,59	8	8,9342	0,3479
	27.01.17	1987	7,59	8	9,8779	0,2737
	03.02.17	1988	7,59	8	9,8140	0,2783
	10.02.17	1989	7,60	8	9,9633	0,2676
	17.02.17	1990	7,60	8	9,9417	0,2691
	24.02.17	1991	7,60	8	9,8641	0,2747
BIST 30 Endeksi	23.12.16	1032	6,94	7	3,1611	0,8697
	30.12.16	1033	6,94	7	3,5121	0,8339
	06.01.17	1034	6,94	7	3,5573	0,8291
	13.01.17	1035	6,94	7	3,6601	0,8180
	20.01.17	1036	6,94	7	3,7814	0,8046
	27.01.17	1037	6,94	7	3,6080	0,8237
	03.02.17	1038	6,95	7	3,6510	0,8190
	10.02.17	1039	6,95	7	3,3012	0,8558
	17.02.17	1040	6,95	7	3,3411	0,8518
	24.02.17	1041	6,95	7	3,4108	0,8446
USD/TRY Kuru	23.12.16	619	6,43	6	5,1339	0,5268
	30.12.16	620	6,43	6	5,4030	0,4933
	06.01.17	621	6,43	6	5,4235	0,4908
	13.01.17	622	6,43	6	6,2594	0,3948
	20.01.17	623	6,43	6	6,8316	0,3367
	27.01.17	624	6,44	6	6,6183	0,3576
	03.02.17	625	6,44	6	7,8510	0,2492
	10.02.17	626	6,44	6	5,3054	0,5053
	17.02.17	627	6,44	6	5,2792	0,5085
	24.02.17	628	6,44	6	4,2938	0,6370

Ö Z G E Ç M İ Ş

Adı ve SOYADI : Mahmut Burak ERTURAN

Doğum Yeri - Tarihi: Nevşehir – 09.05.1983

Eğitim Durumu

Mezun Olduğu Lise : Aldemir – Attila Konuk Anadolu Lisesi, Antalya, 2000

Lisans Diploması : Orta Doğu Teknik Üniversitesi, Mühendislik Fakültesi, Makine Mühendisliği Bölümü, Ankara, 2009

Yüksek Lisans Diploması : Akdeniz Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Ana Bilim Dalı, Antalya, 2012

Tez Konusu : Network Veri Zarflama Analizi ve Türkiye'de Demiryolları Üzerine Bir Uygulama

Doktora Diploması : Akdeniz Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Ana Bilim Dalı, 2017

Tez Konusu : Zaman Serileri İçin Optimize ARIMA – YSA Hibrit Modeli ve Finansal Zaman Serileri ile Örnek Uygulamalar

Yabancı Dil : İngilizce

Bilimsel Faaliyetler

Makaleler:

Erturan, M. B. ve Uysal, F. (2013). “Türkiye’de Demiryolu Taşımacılığının Etkinliği Üzerine Veri Zarflama Analizi ve Network Veri Zarflama Analizinin Karşılaştırılması”. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1): 419-437.

Bildiriler:

Uysal, F. ve Erturan, M. B. (2016). “Volatility Forecast with Artificial Neural Networks as Univariate Time Series, Examples with Stock Market Indexes”. *World Conference on Business, Economics and Management*, 12-14 Mayıs 2016, Antalya.

İş Deneyimi

Çalıştığı Kurumlar : Devlet Su İşleri 13. Bölge Müdürlüğü, Antalya/ Makine Mühendisi (2010 – Devam Ediyor)

E-Posta : burak.erturan@gmail.com