



İSKENDERUN TEKNİK

ÜNİVERSİTESİ

MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

**YÜKSEK
LİSANS
TEZİ**

**KONTEYNER ELLEÇLEME İÇİN
EKONOMETRİK TAHMİNLEME: ARMA
MODELİ UYGULAMASI**

Elif Tuçe BAL

DENİZ ULAŞTIRMA MÜHENDİSLİĞİ
ANABİLİM DALI

OCAK 2019



**KONTEYNER ELLEÇLEME İÇİN EKONOMETRİK TAHMİNLEME:
ARMA MODELİ UYGULAMASI**

Elif Tuçe BAL

**YÜKSEK LİSANS
DENİZ ULAŞTIRMA MÜHENDİSLİĞİ ANABİLİM DALI**

**İSKENDERUN TEKNİK ÜNİVERSİTESİ
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ**

OCAK 2019

Elif Tuçe BAL tarafından hazırlanan “KONTEYNER ELLEÇLEME İÇİN EKONOMETRİK TAHMİNLEME: ARMA MODELİ UYGULAMASI” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ / ~~OY ÇOKLUĞU~~ ile İskenderun Teknik Üniversitesi Deniz Ulaştırma Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Dr. Öğr. Üyesi Vahit ÇALIŞIR

Deniz Ulaştırma İşletme Mühendisliği, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/~~onaylamıyorum.~~


Dr. Öğr. Üyesi Vahit ÇALIŞIR

Başkan: Dr. Öğr. Üyesi Sedat BAŞTUĞ

Denizcilik İşletmeleri Yönetimi, İskenderun Teknik Üniversitesi

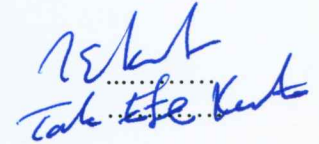
Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/~~onaylamıyorum.~~


.....
Sedat Baştuğ

Üye: Dr. Tarık Efe KENDİR

Assan Liman İşletmeleri A.Ş.

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/~~onaylamıyorum.~~


.....
Tarık Efe Kendir

Tez Savunma Tarihi: ...08/01/2019

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....
Prof. Dr. Tolga DEPCİ

Mühendislik ve Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

İskenderun Teknik Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülendiğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu,
- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.



Elif Tuçe BİL

08/01/2019

KONTEYNER ELLEÇLEME İÇİN EKONOMETRİK TAHMİNLEME:
ARMA MODELİ UYGULAMASI
(Yüksek Lisans Tezi)

Elif Tuçe BAL

İSKENDERUN TEKNİK ÜNİVERSİTESİ
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

Ocak 2019

ÖZET

Geleceği planlamada son derece önemli olan öngörü, denizcilik alanında yapılan yatırımların oldukça maliyetli ve geri döndürülemez olmasından dolayı bu alanda ayrı bir öneme sahiptir. Öngörülerin uzun dönemli olması yatırımlarda daha çok önem kazanırken kısa dönemli olması operasyonlarda ve liman kaynaklarının dağıtımında önem arz etmektedir.

Bu çalışmada amaç 2018'in son üç ayını ve 2019 yılını kapsayan zaman dilimi için Türkiye'deki ithalat ve ihracat konteynerlerin toplamına yönelik aylık öngörü yaparak liman yöneticilerine liman operasyonlarında karar alma noktasında katkı sağlamaktır. Çalışmada yıl içindeki değişimleri izleyebilmek için kısa dönemli aylık tahmin yapılmıştır. Çalışmada amaç doğrultusunda literatürde kısa dönemli öngörülerde diğer yöntemlere göre çok daha iyi olan, sistematik bir bakış açısı sağlayan, hesaplamada basit ve hızlı olan, dinamik yapıları kapsayan Box – Jenkins yöntemi seçilmiştir.

Makalenin en önemli sonuçlarından biri Box – Jenkins yönteminin aşamalarından biri olan modelin tahminlenmesi aşamasında kullanılan Akaike ve Schwarz bilgi kriterlerinin her zaman doğru sonuç vermeyeceği yanıtıcı olabileceği sonucudur. Liman yöneticilerinin aylık elleçlemeler hakkında bilgi sahibi olmalarını sağlamak için, çalışmada 2018'in son üç ayını ve 2019 yılını kapsayan zaman dilimi için Türkiye'deki ithalat ve ihracat konteynerlerin toplamına yönelik aylık öngörü yapılmıştır. Aylık öngörüler ile kendi paylarını hesaplayan kullanıcıların, bu hesaplamalar sayesinde liman operasyonlarını yönetmelerinin de kolaylaşabileceği düşünülmektedir. Çalışmada deterministik trend ve mevsimsellik değişkenlerinin modele direkt dahil edilmesi ve öngörülerde bu değişkenlerin etkilerinin direkt olarak yansıtılması başka çalışmalara da ilham verebileceği düşüncesi ile çalışmanın bilime katkısını ortaya koymaktadır.

Anahtar Kelimeler : Konteyner Elleçlemesi; Zaman Serisi Analizi; ARMA Modeli; Nicel Karar Verme
Sayfa Adedi : 134
Danışman : Dr. Öğr. Üyesi Vahit ÇALIŞIR

ECONOMETRIC FORECASTING FOR CONTAINER HANDLING:

ARMA MODEL APPLICATION

(M. Sc. Thesis)

Elif Tuçe BAL

ISKENDERUN TECHNICAL UNIVERSITY

ENGINEERING AND SCIENCE INSTITUTE

January 2019

ABSTRACT

Since investments in maritime sector are very costly and irreversible; forecasting, critical in planning the future, has a particular importance in this field. As long-term forecasting is more important in investments, short term forecasting is more important in operations and distribution of port resources.

The purpose of this study is to forecast monthly the sum of Turkey's import and export container, for the period from the ninth month of 2018 to the last month of 2019, and also to contribute to the decision-making of port managers in port operations. Short-term monthly estimations were made in order to follow the changes in the year. In accordance with this purpose, in this study, Box - Jenkins method, which includes dynamic structures, which is simple and fast in calculation, which is much better than other methods in short - term forecasts in the literature, has been selected.

One of the most important results of the article is that the Akaike and Schwarz information criteria used in the estimation of the model, which is one of the steps of the Box - Jenkins method, are not always accurate, it can be misleading. To ensure that port managers have knowledge about monthly handling, in this study, for the last three months of 2018 and the period covering 2019, it was made monthly forecasting for the sum of import and export containers in Turkey. It is thought that it will be also easier for the users to calculate their shares with monthly projections and manage the port operations through these calculations. In this study, direct contribution of deterministic trend and seasonality variables to the model and direct effects of these variables in projections are the contribution of the study to science with the idea that it can inspire other studies.

Key Words : Container Handling; Time Series Analysis; ARMA Model; Quantitative Decision Making

Page Number : 134

Supervisor : Assist. Prof. Dr. Vahit ÇALIŞIR

TEŞEKKÜR

Öğrenme süreci çok meşakkatli ve yorucu bir süreçtir. Bu süreçteki yönlendirmeler ve destekler oldukça önem arz etmektedir. Bu süreçte iktisat ve ekonometri öğrenmem konusunda beni yönlendiren ayrıca öğrenme sürecimde kendilerinden de ders aldığım ve başka hocalardan da ders almam konusunda bana yardımcı olan Doç. Dr. Sadık Özlen BAŞER, Prof. Dr. Hakan KAHYAOĞLU ve Doç. Dr. Ahmet İlkin BARAY'a çok teşekkür ediyorum. Elde ettiğim bilgi birikiminde katkıları oldukça önemli bir yer tutmaktadır. Bu süreçte özellikle tez yazımında bana destek olan, anlayışlı ve neşeli halleri ile her zaman sorularıma cevap veren danışman hocam Dr. Öğr. Üyesi Vahit ÇALIŞIR'a da çok teşekkür ederim.

Akademiye girdiğim andan beri bana her daim destek olan yardımlarını esirgemeyen Öğr. Gör. Kaptan Mustafa AKIN ve ailesine, oda arkadaşım Arş. Gör. Ramazan Özkan YILDIZ'a ve tüm mesai arkadaşlarıma çok teşekkür ediyorum.

Yüksek lisans eğitimim boyunca ve hayatımın her anında bana maddi ve manevi destek olan bugünlere gelmemde büyük emek veren ve fedakârlık gösteren aileme de yaptıkları her şey için çok teşekkür ediyorum. Bugün eğitim hayatımda bu kadar ilerleme kaydettiysen tartışmasız bu onların özverilerinin açık sonucudur.

Son olarak yüksek lisans dönemimde karşıma çıkan ve hayatımın en değerli parçalarından biri olan benden hiçbir zaman desteğini esirgemeyen sevgili eşime de çok teşekkür ediyorum.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	xi
ŞEKİLLERİN LİSTESİ.....	xv
SİMGELER VE KISALTMALAR.....	xvii
1. GİRİŞ.....	1
2. DENİZ TAŞIMACILIĞININ DÜNYA VE TÜRKİYE’DEKİ YERİ.....	3
2.1. Dünyada Deniz Yoluyla Taşınan Yükle İlgili Değişimler	3
2.1.1. Ticarete konteyner ile taşınan yük ile ilgili değişimler.....	5
2.1.2. Konteyner elleçleme performansında ilk 20 ülke	6
2.1.3. Konteyner elleçleme performansında ilk 20 liman.....	7
2.2. Türkiye’de Taşıma Türleri Arasında Denizyolunun Yeri	8
2.2.1. Türkiye konteyner elleçleme miktarları 2004-2018 (TEU).....	11
2.2.2. Ülkeler bazında konteyner elleçleme: ilk 20 ülke	13
2.2.3. Liman başkanlıkları bazında konteyner elleçleme miktarları.....	15
2.2.4. Limanlar bazında konteyner elleçleme miktarları	17
2.2.5. Limanlar bazında transit konteyner elleçleme miktarları	19
3. ZAMAN SERİLERİ	20
3.1. Zaman Serilerinin Tanımı.....	20
3.2. Zaman Serilerinin Bileşenleri.....	21

	Sayfa
3.3. Durağanlık	24
3.4. Rassal Yürüyüş	25
3.5. Durağanlığın Belirlenmesi.....	30
3.5.1. Grafik analizi	30
3.5.2. Otokorelasyon fonksiyonu (autocorrelation function - ACF) ve kısmi otokorelasyon fonksiyonu (partial autocorrelation function - PACF)	30
3.5.3. Birim kök testleri	34
3.6. Trend Durağan ve Fark Durağan Zaman Serileri	39
3.7. Kukla Değişkenler	42
3.8. Yapısal Kırılmalar	42
3.8.1. Çoklu kırılma noktası testi (Bai-Perron test)	44
3.9. Yapısal Kırılmalarda Kukla Değişkenlerin Kullanılması.....	45
3.10. Mevsimsellik	45
3.10.1. Deterministik mevsimsellik	46
3.10.2. Mevsimsellikten arındırma	47
3.10.3. Mevsimsel fark alma.....	47
4. LİMANLARDA ÖNGÖRÜ VE YAPILAN ÇALIŞMALAR.....	50
4.1. Öngörü	50
4.1.1. Öngörü horizonu ve öngörü sıklığı.....	50
4.1.2. Nokta öngörü ve öngörü aralığı	51
4.1.3. Kayan öngörü.....	52
4.1.4. Koşullu ve koşulsuz öngörü.....	52
4.1.5. Öngörü teknikleri.....	52
4.2. Konteyner Taşımacılığı, Ekonomi, Limanlar ve Öngörü	56
4.2.1. Konteynere olan talep hakkındaki bilginin önemi	56

	Sayfa
4.2.2. Ülke ve liman yönetimi boyutunda konteyner öngörüsünün önemi.....	57
4.3. Limanlarla İlgili Yük Tahminlerinde Kullanılan Yöntemler	58
4.4. Limanlarla İlgili Yük Tahminlerinde Yapılan Çalışmalar	59
4.4.1. Zaman serisi modellerinin kullanıldığı çalışmalar.....	59
4.4.2. Nedensellik analizinin kullanıldığı çalışmalar.....	69
4.4.3. Doğrusal olmayan modellerin kullanıldığı çalışmalar.....	71
4.4.4. Modellerin karşılaştırıldığı çalışmalar	73
4.4.5. Karma modellerin yer aldığı çalışmalar.....	74
4.4.6. Türk limanlarında yapılan çalışmalar	77
4.5. Öngörü Uzunluğunun ve Modelin Belirlenmesi	80
5. YÖNTEM.....	82
5.1. Box – Jenkins Yöntemi Otoregresif Tümlleşik Hareketli Ortalama Modeli (ARIMA)	82
5.1.1. Otoregresif (AR) model.....	83
5.1.2. Hareketli ortalama (MA) modeli	83
5.1.3. Otoregresif (tümlleşik) hareketli ortalama modeli (AR(I)MA).....	84
5.2. Otokorelasyon Fonksiyonu (ACF) ve Kısmi Otokorelasyon Fonksiyonu (PACF) ile Belirlenmesi	85
5.2.1. Otoregresif (AR) süreç.....	85
5.2.2. Hareketli ortalama (MA) süreci	87
5.2.3. Otoregresif hareketli ortalama (ARMA) süreci	88
5.3. Modelin Tahmin Edilmesi.....	90
5.4. Model Seçim Kriterleri.....	90
5.4.1. Belirleme katsayısı R^2	90
5.4.2. Düzeltilmiş $R^2(\bar{R}^2)$	91

	Sayfa
5.4.3. Akaike bilgi kriteri (AIC)	91
5.4.4. Schwarz bilgi kriteri (SIC).....	92
5.5. Modelin Kontrol Edilmesi / Hata Kontrolü.....	92
5.5.1. Jarque-Bera (JB) testi.....	93
5.5.2. Breusch-Pagan-Godfrey (BPG) testi	94
5.6. Örneklem Dışı Öngörüler Temelinde Model Seçim Kriterleri.....	95
6. ARAŞTIRMA BULGULARI	96
6.1. Grafik ve Korelogram Analizi.....	96
6.2. Durağanlık Testleri.....	98
6.3. Trendin Varlığının Ortaya Konulması.....	101
6.4. Deterministik Mevsimselliğin Ortaya Çıkarılması.....	104
6.5. Veri Setine Yapısal Kırılma Testinin Uygulanması	105
6.6. Otoregresif (AR) ve Hareketli Ortalama (MA) Terimlerinin Modele Eklenmesi	107
6.7. Oluşturulan Modellerin Tahminlenmesi ve Uygun Modellerin Seçilmesi.....	110
6.8. Öngöründe Kullanılan Modelin Seçilmesi	119
6.9. 2018'in Son Üç Ayına ve 2019'un Tamamına Ait Aylık Öngörülerin Yapılması.....	122
7. SONUÇ VE ÖNERİLER	123
KAYNAKLAR	126
ÖZGEÇMİŞ	133
DİZİN	134

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. Uluslararası deniz yoluyla taşınan yük miktarı (milyon ton)	4
Çizelge 2.2. Ülke Bazında Konteyner Elleçleme Miktarları İlk 20 Ülke (TEU).....	6
Çizelge 2.3. En çok elleçleme yapan ilk 20 liman (TEU)	7
Çizelge 2.4. Taşıma türlerine göre ihracat, 2000-2018	10
Çizelge 2.5. Taşıma türlerine göre ithalat, 2000-2018	11
Çizelge 2.6. Türkiye'nin konteyner elleçleme miktarları 2004-2018 (TEU)	12
Çizelge 2.7. Ülkeler bazında konteyner elleçleme: ilk 20 ülke (TEU).....	13
Çizelge 2.8. Ülkeler bazında ithalat ve ihracat konteyner elleçlemleri ilk 10 ülke karşılaştırması	14
Çizelge 2.9. Liman başkanlıkları bazında konteyner elleçleme miktarları (TEU)	15
Çizelge 2.10. Liman başkanlıkları bünyesinde yer alan limanlar.....	16
Çizelge 2.11. Türkiye'de konteyner elleçleyen limanların elleçleme miktarları (TEU)	17
Çizelge 2.12. Transit konteyner elleçlemeleri (TEU)	19
Çizelge 4.1. Öngörü ile ilgili yapılan çalışmalarda uygulanan yöntemler ve çalışmaların uygulandığı limanlar	60
Çizelge 4.2. Türkiye'de gerçekleştirilen projelerde kullanılan tahmin yöntemleri	79
Çizelge 5.1. Beyaz gürültü (WN), AR(1), AR(2), MA(1), MA(2) ve ARMA(1,1) süreçlerinin otokorelasyon ve kısmi otokorelasyon fonksiyonları	89
Çizelge 5.2. ARMA model için ACF ve PACF'nin davranışları	89
Çizelge 6.1. Veri setini korelogramı	97
Çizelge 6.2. Birim kök testlerinden elde edilen bulgular.....	99
Çizelge 6.3. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken olduğu regresyon analizi sonucu.....	101
Çizelge 6.4. Çizelge 3.3'te yer alan regresyona ait kalıntıların korelogramı	103

Çizelge	Sayfa
Çizelge 6.5. Çizelge 6.3'te yer alan regresyon analizinden çekilen hataların durağanlık analizi	103
Çizelge 6.6. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin bağımsız değişken olduğu regresyon sonuçları.....	105
Çizelge 6.7. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin ve yapısal kırılma kuklalarının bağımsız değişken olduğu regresyon sonuçları	107
Çizelge 6.8. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trendin, yapısal kırılma kuklalarının, AR(1), AR(2) ve AR(3) terimlerinin bağımsız değişken olduğu regresyon sonucunun korelogramı	107
Çizelge 6.9. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin ve yapısal kırılma kuklalarının bağımsız değişken olduğu regresyona ait korelogram	109
Çizelge 6.10. Modellerde kullanılan AR ve MA terimleri	110
Çizelge 6.11. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin ve yapısal kırılma kuklalarının, AR(1), AR(2) ve AR(4) terimlerinin bağımsız değişken olduğu modelin sonuçları (M1).....	111
Çizelge 6.12. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin ve yapısal kırılma kuklalarının, MA(2) teriminin bağımsız değişken olduğu modelin sonuçları (M2)	112
Çizelge 6.13. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin ve yapısal kırılma kuklalarının, AR(1), MA(1) ve MA(2) terimlerinin bağımsız değişken olduğu modelin sonuçları (M3).....	114
Çizelge 6.14. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin ve yapısal kırılma kuklalarının, AR(1), AR(2), AR(4), MA(5) ve MA(15) terimlerinin bağımsız değişken olduğu modelin sonuçları (M6)	115
Çizelge 6.15. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin ve yapısal kırılma kuklalarının, MA(1), AR(2) ve AR(4) terimlerinin bağımsız değişken olduğu modelin sonuçları (M8).....	116
Çizelge 6.16. Model tercih kriterleri.....	121
Çizelge 6.17. 2018/10 - 2019/12 zaman dilimine ait aylık öngörü.....	122

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Dünyada deniz yoluyla taşınan toplam yükün grafiği (2005-2017)	3
Şekil 2.2. Deniz yoluyla taşınan toplam yük miktarının dağılımı (2017).....	5
Şekil 2.3. Ticarete konteynerle taşınan yük	5
Şekil 2.4. Taşıma türlerinin gelişimi (2000-2018).....	8
Şekil 2.5. 2000 ve 2017 yılları için toplam ithalat ihracatta kullanılan taşıma türlerinin dağılımı	9
Şekil 2.6. Türkiye'nin konteyner elleçleme miktarları 2004-2018 (TEU)	12
Şekil 3.1. Konjonktürel dalgalanmaların dört evresi	22
Şekil 3.2. Genel mal satışları (aylık veri, milyar dolar).....	23
Şekil 3.3. Korelogram örnekleri.....	33
Şekil 3.4. Yapısal değişikliğin yer aldığı model örneği.....	43
Şekil 3.5. 1960'dan 1980'e Johnson & Johnson şirketinin logaritması alınmış çeyreklik verilerle hisse başına düşen kazancın örnek otokorelasyon fonksiyonları	48
Şekil 5.1. Pozitif işaretli AR(1) sürecinin otokorelasyon ve kısmi otokorelasyon fonksiyonları Şekil 6.3. Titreşim sistemi ve elemanları	86
Şekil 5.2. Negatif işaretli AR(1) sürecinin otokorelasyon ve kısmi otokorelasyon fonksiyonları Şekil 6.4. Harmonik kuvvetin cevabı ve farklı sönüm değerlerindeki hareketler	86
Şekil 5.3. AR(2) sürecinin otokorelasyon ve kısmi otokorelasyon fonksiyonları	87
Şekil 5.4. Negatif işaretli MA(1) sürecinin otokorelasyon ve kısmi otokorelasyon fonksiyonları	87
Şekil 5.5. ARMA(1,1) sürecinin otokorelasyon ve kısmi otokorelasyon fonksiyonları.	88
Şekil 6.1. Veri setinin grafiği.....	97
Şekil 6.2. Çizelge 6.3'te yer alan regresyona ait kalıntıların grafiği	102

Şekil	Sayfa
Şekil 6.3. Model 4 (a) ve Model 8'e (b) ait 2018 1. aydan 2018'in 9. ayına kadarki dönemi kapsayan modellerin öngörü aralıkları ve gerçekleşen değer ile karşılaştırmalar	118
Şekil 6.4. Model 1 (a), Model 6 (b) ve Model 8'e (c) ait 2018 1. aydan 2018'in 9. ayına kadarki dönemi kapsayan modellerin öngörü aralıkları ve gerçekleşen değer ile karşılaştırmaları	120



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

\$	ABD doları
σ	Standart sapma
μ	Ortalama
σ^2	Varyans
γ_k	Kovaryans
R^2	Belirleme Katsayısı
\bar{R}^2	Düzeltilmiş R^2

Kısaltmalar

Açıklamalar

ABD	Amerika Birleşik Devletleri
ACF	Otokorelasyon Fonksiyonu
ADF	Genişletilmiş Dickey-Fuller
AIC	Akaike Bilgi Kriteri
ALSSVM	Yaklaşık En Küçük Kareler Destek Vektör Makinası
ANN	Yapay sinir ağları
ANN-ABC	Yapay Sinir Ağları-Yapay Arı Kolonisi
ANN-LM	Yapay Sinir Ağları/ Levenberg-Marquardt Algoritmaları
AR	Otoregresif
ARMA	Otoregresif Hareketli Ortalama
ARIMA	Otoregresif Tümlleşik Hareketli Ortalama
ARIMAX	Dışsal Değişkenli Otoregresif Tümlleşik Hareketli Ortalama

Kısaltmalar**Açıklamalar**

ASHW	Toplamsal Mevsimsel Holt-Winters
BP	Geri Yayınım
BPG	Breusch-Pagan-Godfrey
BPNN	Geri Yayınımı Sinir Ağı
BP-ANN	Geri Yayınımı Yapay Sinir Ağları
CD-LSSVR	Klasik Ayırıştırma Modeli- En Küçük Kareler Destek Vektör Regresyonu
CEGA	Düzensiz etkin genetik algoritma
DF-GLS	Dickey Fuller-Genelleştirilmiş En Küçük Kareler
DTGM İBS	Deniz Ticareti Genel Müdürlüğü İstatistik Bilgi Sistemi
ES	Üstel düzleştirme
ESS	Açıklanan kareler toplamı
GA-BP	Geri Yayınımı - Genetik Algoritma
GP	Genetik programlama
GPI	Gayrisafi özel yatırım
GPS	Gayrisafi özel tasarruf
JB	Jarque-Bera
KPSS	Kwiatkowski-Phillips-Schmidt-Shin
LSSVM	En Küçük Kareler Destek Vektör Makinası
LSSVR	En Küçük Kareler Destek Vektör Regresyonu
MA	Hareketli Ortalamalar
MAE	Ortalama mutlak hata
MAPE	Ortalama mutlak yüzde hataları
MLP	Çok Katmanlı Algılayıcı
MNR-GA	Çoklu Doğrusal Olmayan Regresyon Modeli - Genetik Algoritma
MSHW	Çarpımsal Mevsimsel Holt-Winters
PACF	Kısmi Otokorelasyon Fonksiyonu
PP	Phillips-Perron
PPPR	Parametre Projeksiyon İzleme Regresyon

Kısaltmalar**Açıklamalar****PPPR – CEGA**

Parametre Projeksiyon İzleme Regresyon – Düzensiz etkin genetik algoritma

PPR – GA

Genetik Algoritmali Projeksiyon İzleme Regresyon

RBF-NN

Radyal Bazlı Fonksiyon Sinir Ağı

RMSE

Ortalama karesel hatanın karekökü

SARIMA

Mevsimsel Otoregresif Tümlşik Hareketli Ortalama

SARIMA-BPMevsimsel Otoregresif Tümlşik Hareketli Ortalama
- Geriye Yayılım**SARIMA-GP**Mevsimsel Otoregresif Tümlşik Hareketli Ortalama
- Genetik Programlama**SARIMA-LSSVR**Mevsimsel Otoregresif Tümlşik Hareketli Ortalama
- En Küçük Kareler Destek Vektör Regresyonu**SARIMA-SVM**Mevsimsel Otoregresif Tümlşik Hareketli Ortalama
- Destek Vektör Makinası**SARIMANT**

Dönüşüm ve müdahalenin olmadığı Mevsimsel Otoregresif Tümlşik Hareketli Ortalama

SD-LSSVR

Mevsimsel Ayırıştırma Modeli - En Küçük Kareler Destek Vektör Regresyonu

SIC

Schwarz Bilgi Kriteri

SMART – PPR

Akıllı Projeksiyon İzleme Regresyon

SVM

Destek Vektör Makinası

SVR

Destek Vektör Regresyonunu

TEU

Twenty-foot Equivalent Unit (20 Fit Konteyner Eşdeğer Birimi)

TSS

Toplam kareler toplamı

TUİK

Türkiye İstatistik Kurumu

TÜRKLİM

Türkiye Liman İşletmecileri Derneği

UNCTAD

Birleşmiş Milletler Ticaret ve Kalkınma Örgütü

VAR

Vektör Otoregresyon

VECM

Vektör Hata Düzeltme Modeli

1. GİRİŞ

Öngörü tüm alanlarda geleceği planlamada, kaynakların tahsis edilmesinde, yatırımların yapılmasında, stratejilerin belirlenmesinde son derece önemli bir yere sahiptir. Konu denizcilik olduğunda ise bu önem biraz daha artmaktadır. Denizcilik alanı ile ilgili özellikle yatırımlarda, gerek gemi alımı olsun gerekse yeni bir liman açılması, limanın iyileştirilmesi olsun ya da bu alana yönelik başka yatırımlarda, yatırımların oldukça yüksek maliyetli oluşu ve geri döndürülemez olması bu alanda öngörünün önemini katlamaktadır.

Denizcilik alanında yüklerin taşınmasında kullanılan kutu olarak da düşünülebilecek konteynerin tahmini ise konteynerin farklı taşıma modlarında da kullanılmasından da kaynaklı olarak daha çok alanı etkilemektedir. Denizcilik boyutunda özellikle konteyner limanı boyutunda düşünüldüğünde konteynerlerin elleçlenmesi, elleçlenen konteynerlerin istiflenmesi, konteynerlerin depolanması için yeterli alanın ayarlanması bu hizmetlerin sağlanması için gerekli alt yapı ve üst yapı ekipmanların sağlanması yeni bir limanın kurulması özellikle uzun dönemli tahminlerle belirlenmektedir. Kısa dönemli tahminler ise yılın belli aylarında benzer davranış sergileyen ortalamanın üzerindeki talebin karşılanması durumunda ekstra ekipmanların temini ve ekipmanların dağıtılması, liman operasyonlarının düzenlenmesi noktalarında önem kazanmaktadır.

Türkiye için yapılan çalışmalar incelendiğinde Türkiye'nin aylık konteyner elleçlemesine yönelik kısa dönemli öngörülerin bulunmadığı görülmüştür. Bu öngörülerin liman yöneticilerine Türkiye'deki elleçlemelerde kendi paylarını belirleyerek işlettikleri liman için kısa dönemli planlarında, strateji oluşturmalarında ve kaynaklarını dağıtma noktalarında katkı sağlayacağı düşünülmektedir. Türkiye'deki liman yöneticilerine bir yol göstermesi Türkiye gibi trend ve mevsimsellik içeren yapıya sahip veri setleri için de alternatif öngörü metodu oluşturması için bu çalışma yapılmıştır.

Çalışma için kısa dönemli öngörülerde diğer yöntemlere göre çok daha iyi sonuçlar veren ve Türkiye'nin 2004-2017 yıllarına ait veri setine uygun olan Box – Jenkins yöntemi seçilmiştir.

Çalışmanın ikinci bölümünde deniz taşımacılığını, özellikle konteyner ile ilgili bilgileri içeren dünya ve Türkiye'den toplanmış istatistiksel bilgiler yer alırken üçüncü bölümde uygulamada kullanılacak zaman serisi ile ilgili bilgiler verilmiştir. Dördüncü bölümde yöntemin seçilmesi için daha önceki çalışmalar taranmış ve çalışmaların incelenmesi ile kullanılacak yöntem belirlenmiştir. Seçilen Box – Jenkins yöntemi beşinci bölümde tanıtılmış, altıncı bölümde araştırmanın bulgularına yer verilmiş son bölümde ise sonuçlar ortaya koyulmuştur.




2. DENİZ TAŞIMACILIĞININ DÜNYA VE TÜRKİYE'DEKİ YERİ

2.1. Dünyada Deniz Yoluyla Taşınan Yükle İlgili Değişimler

Deniz yoluyla taşınan toplam yük miktarının bir önceki seneye göre değişimi incelendiğinde 2016-2017 yılı arasındaki değişim %4'e yakındır. Bu oran bir önceki yıllarla kıyaslandığında son 5 yılın en yüksek değerini ifade etmektedir. Bu değişim 2005-2006 yılından itibaren en düşük seviyesini 2008-2009 döneminde -%5 olarak görmüştür. En yüksek olduğu dönem %8 ile 2005-2006 dönemi iken bu dönemi %7 ile 2009-2010 dönemi izlemektedir. 2009-2010 döneminden sonra 2010-2011 ve 2011-2012 dönemlerinde gözlemlenen sırasıyla %4'lük ve %5'lik artış 2012-2013 ve 2013-2014 dönemlerinde yerini %3'e bırakmış ve 2014-2015 döneminde %2'ye düşmüştür. Son iki dönem için bu değerler yaklaşık %3 ve %4 olarak gerçekleşmiştir.

Dünyada deniz yoluyla taşınan yük miktarı 2005 yılında 7 109 milyon ton olarak gerçekleşmişken bu miktar 2017 yılı için 10 702 milyon tondur ki bu değer son 13 yılın en büyük değerini ifade etmektedir (Şekil 2.1). 2005 yılı ile 2017 yılı arasındaki değişim ise %50'dir. Bu değer son 13 yılda deniz yoluyla taşınan yükün milyon ton bazındaki artışının oranını ifade etmektedir.



Şekil 2.1. Dünyada deniz yoluyla taşınan toplam yükün grafiği (2005-2017) (UNCTAD (Birleşmiş Milletler Ticaret ve Kalkınma Örgütü), 2018)


UNCTAD deniz yoluyla taşınan yükleri konteyner, petrol ve doğalgaz, diğer kuru dökme yükler ve ana dökme yük olmak üzere dört gruba ayırmaktadır. Ana dökme yükler demir cevheri, tahıl ve kömürü içerirken; boksit/alümin ve fosfat diğer kuru dökme yüklerin içinde yer almaktadır.

2005-2017 yılları arasındaki değişimler incelendiğinde en fazla değişim %87 ile ana dökme yükte olurken, ana dökme yükü %83 ile konteyner takip etmektedir. Ayrıca petrol ve gazda %30 artış yaşanırken bu değişim diğer kuru yükler için %28'dir.

Çizelge 2.1. Uluslararası deniz yoluyla taşınan yük miktarı (milyon ton)(UNCTAD, 2018)

Yıllar	Diğer Kuru		Ana Dökme		Toplam
	Konteyner	Dökme Yükler	Yük	Petrol ve Gaz	
2005	1 001	1 975	1 711	2 422	7 109
2006	1 092	2 197	1 713	2 698	7 700
2007	1 215	2 232	1 840	2 747	8 034
2008	1 272	2 269	1 946	2 742	8 229
2009	1 134	2 060	2 022	2 642	7 858
2010	1 291	2 087	2 259	2 772	8 409
2011	1 411	2 188	2 392	2 794	8 785
2012	1 458	2 304	2 594	2 841	9 197
2013	1 532	2 392	2 761	2 829	9 514
2014	1 622	2 408	2 988	2 825	9 843
2015	1 660	2 471	2 961	2 932	10 024
2016	1 734	2 459	3 041	3 055	10 289
2017	1 834	2 526	3 196	3 146	10 702

Konteynerin 2005-2017 yılları için deniz yoluyla taşınan toplam yük miktarları arasından aldığı paylar incelendiğinde 2005 yılında %14 paya sahip iken bu payın 2017 yılında 1 834 milyon ton yük (Çizelge 2.1) ile %17'ye çıktığı görülmektedir (Şekil 2.2).




Şekil 2.2. Deniz yoluyla taşınan toplam yük miktarının dağılımı (2017)

2017 yılı için ana dökme yük ve diğer kuru yüklerin toplam payı %53'ü bulurken petrol ve doğalgaz %29'u oluşturmaktadır (Şekil 2.2).

2.1.1. Ticarete konteyner ile taşınan yük ile ilgili değişimler

Konteynerde taşınan yük TEU bazında hesapladığında 2017 yılında 2011'den beri en hızlı artış miktarı olan %6,4 büyüme ile 148 milyon TEU'ya ulaşmıştır, ayrıca konteyner talebindeki artış küresel ekonomik ortamda meydana gelen gelişimi yansıtmaktadır (UNCTAD, 2018).



Şekil 2.3. Ticarete Konteynerle Taşınan Yük (UNCTAD, 2018)

Konteynerle taşınan yükte özellikle 2009 yılında ciddi bir azalış gözlenmektedir. 2007 yılında gözlemlenen artışın ardından 2008 yılında da az miktarda artış göstermiş ancak 2009'da ciddi bir düşüş meydana gelmiştir ki bu durum 2008 yılındaki krizin gecikmeli etkisini yansıtmaktadır. Ayrıca 2015 yılındaki artış da diğer yıllardaki artışa göre oldukça düşüktür 2009 yılından sonra dikkat çeken bir diğer nokta 2015 yılıdır. 2015 yılında konteynere olan talepte meydana gelen sınırlı büyümenin zayıf Avrupa talebi, düşük emtia fiyatları gibi birçok faktöre bağlanabilmektedir (UNCTAD, 2016).

2.1.2. Konteyner elleçleme performansında ilk 20 ülke

Dünya limanlarında en fazla konteyner elleçlemesi yapılan ülkelerin başında yer alan Çin'de toplam elleçlemenin %28'i yapılmaktadır (Çizelge 2.2). Çin'i %6 ile Amerika Birleşik Devletleri (ABD) izlerken, ABD'yi de Singapur takip etmektedir. Konteyner elleçlemesinde ilk 10'da yer alan ülkeler toplam elleçlemenin %60'ını yaparken ilk 20 ülke %76'sını yapmaktadır.

Çizelge 2.2. Ülke bazında konteyner elleçleme miktarları ilk 20 ülke (TEU) (Unctadstat, 2018)

Sıra	Ülkeler	2014	2015	2016	2017
1	Çin	186 679 051	195 276 751	199 551 751	213 719 925
2	ABD	47 849 621	49 527 457	50 181 794	51 425 466
3	Singapur	34 688 000	31 710 200	32 668 000	33 600 000
4	Kore	24 818 667	25 354 352	26 152 977	27 427 000
5	Malezya	22 645 237	24 259 700	24 570 000	24 719 000
6	Japonya	21 139 091	20 577 013	20 784 617	21 904 443
7	Birleşik Arap Emirlikleri	20 223 612	21 233 200	20 613 200	21 280 900
8	Hong Kong (Çin)	22 300 000	20 114 000	19 580 000	20 770 000
9	Almanya	20 128 033	19 139 033	19 364 033	19 447 600
10	İspanya	14 213 268	14 271 905	15 267 905	17 065 000
11	Tayvan (Çin)	15 270 100	14 633 800	14 885 000	14 965 000
12	Hollanda	12 470 000	12 407 000	12 656 000	13 951 000
13	Endonezya	11 619 900	11 978 700	12 478 700	13 859 500
14	Hindistan	11 323 000	11 882 003	12 086 010	13 259 000
15	Vietnam	10 188 873	11 478 573	11 853 000	12 284 395
16	Belçika	11 061 400	11 237 600	11 489 909	11 857 009
17	Tayland	9 420 450	9 522 320	9 940 320	10 732 000
18	İtalya	10 247 049	10 018 365	10 264 840	10 698 030
19	Birleşik Krallık	9 360 203	9 596 908	9 765 908	10 530 328
20	Brezilya	10 321 436	10 300 068	9 925 574	10 049 282
21	Türkiye	9 341 316	8 832 076	8 580 942	9 927 385
	Dünya	687 091 443	695 811 428	710 067 396	752 714 321

Son dört yılın verileri incelendiğinde ilk 5 ülke (Çin, ABD, Singapur, Kore ve Malezya) sıralamasını korurken, 2014 yılında 6. sırada olan Hong Kong 2015 yılından itibaren Japonya ve Birleşik Arap Emirlikleri'nin gerisinde kalmıştır. Dünya sıralamasında 21. sırada yer alan Türkiye'nin payı ise %1'dir.

2.1.3. Konteyner elleçleme performansında ilk 20 liman

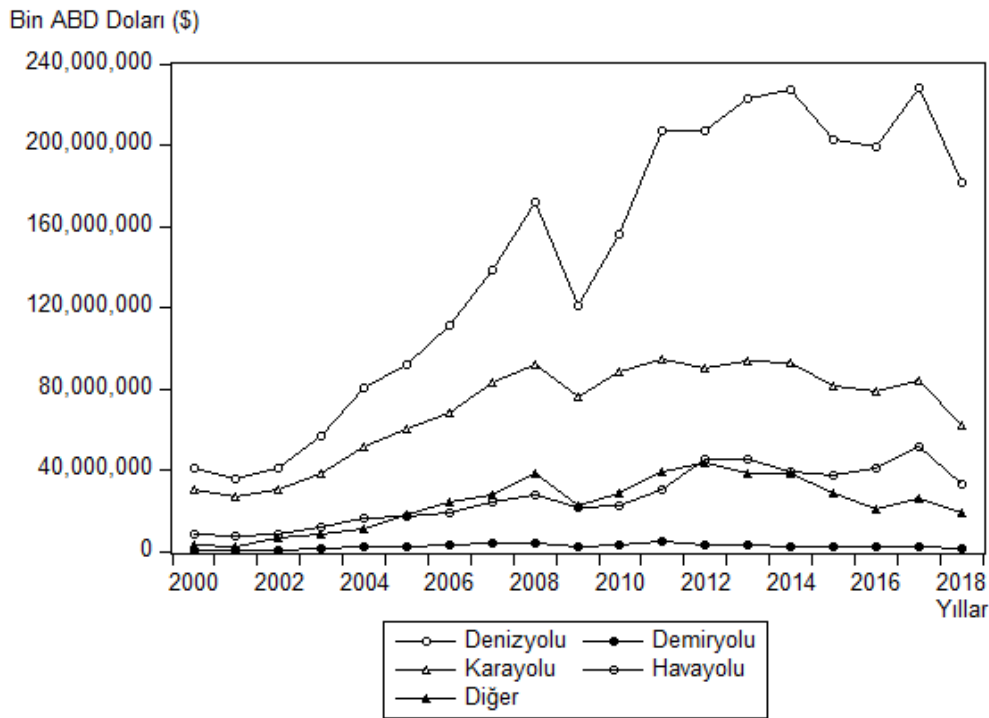
En çok elleçleme yapan ilk 20 liman arasında 8 Çin limanı yer alırken 8 limanın 6 tanesi ayrıca ilk 10 liman arasındadır (Çizelge 2.3). Dünyada en çok elleçleme yapan liman bir Çin limanı olan Shanghai limanıdır. Shanghai limanının elleçlemeleri ilk 20'de yer alan limanların toplam elleçlemesinin %12'sini oluştururken ilk 20'de yer alan Çin limanlarının toplam elleçleme oranı %49'dur.

Çizelge 2.3. En çok elleçleme yapan ilk 20 liman (TEU) (UNCTAD, 2018,2017)

Sıra	Limanlar	Ekonomi	2015	2016	2017
1	Shanghai	Çin	36 537 000	37 133 000	40 230 000
2	Singapore	Singapur	30 962 000	30 904 000	33 670 000
3	Shenzhen	Çin	24 204 000	23 979 000	25 210 000
4	Ningbo-Zhoushan	Çin	20 593 000	21 560 000	24 610 000
5	Busan	Kore	19 296 000	19 850 000	21 400 000
6	Hong Kong	Hong Kong	20 114 000	19 813 000	20 760 000
7	Guangzhou (Nansha)	Çin	17 457 000	18 858 000	20 370 000
8	Qingdao	Çin	17 465 000	18 010 000	18 260 000
9	Dubai	Birleşik Arap Emirlikleri	15 592 000	14 772 000	15 440 000
10	Tianjin	Çin	14 109 000	14 490 000	15 210 000
11	Rotterdam	Hollanda	12 235 000	12 385 000	13 600 000
12	Port Klang	Malezya	11 891 000	13 170 000	12 060 000
13	Antwerp	Belçika	9 650 000	10 037 000	10 450 000
14	Xiamen	Çin	9 179 000	9 614 000	10 380 000
15	Kaohsiung	Tayvan	10 264 000	10 465 000	10 240 000
16	Dalian	Çin	9 449 000	9 614 000	9 710 000
17	Los Angeles	Birleşik Devletler	8 160 000	8 857 000	9 340 000
18	Hamburg	Almanya	8 825 000	8 910 000	9 600 000
19	Tanjung Pelepas	Malezya	8 799 000	8 281 000	8 330 000
20	Laem Chabang	Tayland	6 821 000	7 227 000	7 760 000

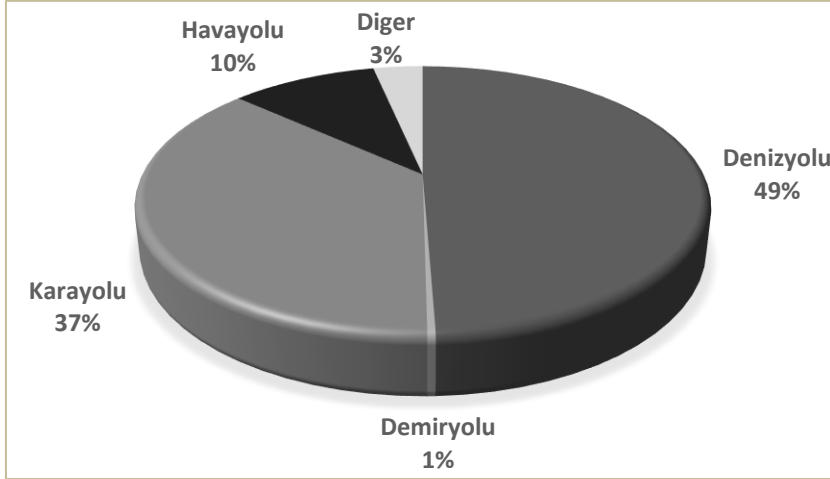
2.2. Türkiye’de Taşıma Türleri Arasında Denizyolunun Yeri

Türkiye’de ihracat ve ithalat yüklerinin taşımalarında kullanılan taşıma türleri denizyolu, demiryolu, karayolu, havayolu ve diğer olmak üzere beş gruba ayrılmaktadır. Taşıma türleri ile taşınan malların değerlerinin toplamı ile oluşturulan 2000-2017 aralığına ait veri seti incelendiğinde 2017 yılı ile 2000 yılı arasındaki artış kıyaslamasında ilk sırada %840 değişim ile diğer olarak ifade edilen denizyolu, demiryolu, karayolu ve havayolu dışında kalan taşıma türleri gelmektedir. Bu grubu %475 artış ile demir yolu, %523 artış ile havayolu ve %461 artış ile denizyolu takip ederken son sırada %175 ile karayolu yer almaktadır. Taşıma türlerinin gelişimini gösteren Şekil 2.4 2018 yılının ilk dokuz ayına ait değerlerin toplamını içermektedir.




Şekil 2.4. Taşıma türlerinin gelişimi (2000-2018) (TUİK)

Taşıma türleri ile taşınan malların toplam ithalat ve ihracat değerlerinin alındığı durum için oranlar incelendiğinde 2000 yılı için denizyolu, demiryolu, karayolu, havayolu ve diğer sırasıyla %494, %4, %368, %100 ve %34 iken 2017 yılı için sırasıyla %583, %5, %214, %131 ve %67’dir (Şekil 2.5).



a. 2000 yılı



b. 2017 yılı

Şekil 2.5. 2000 ve 2017 yılları için toplam ithalat ihracatta kullanılan taşıma türlerinin dağılımı (TUİK)

Şekil 2.5'te yer alan a ve b grafikleri incelendiğinde denizyolu ile taşınan malların değerindeki büyüme ve karayolu ile taşınan malların değerindeki azalma özellikle dikkat çekmektedir.

İhraç edilen malların değerlerinin taşıma türlerine göre dağılımını gösteren Çizelge 2.4 incelendiğinde 2017 yılı için denizyolunun %58 pay ile en büyük paya sahip olduğu denizyolunu %29 ile karayolunun takip ettiği görülmektedir. Demiryolu ile ihraç edilen toplam malların değeri tüm taşıma türleri içinde en düşük paya sahiptir.

Çizelge 2.4. Taşıma türlerine göre ihracat, 2000-2018 (değer: bin abd doları(\$)) (TÜİK)

Yıllar	Denizyolu	Demiryolu	Karayolu	Havayolu	Diğer	Toplam
2000	13 080 017	93 957	12 013 620	2 338 492	248 819	27 774 906
2001	15 521 220	173 592	13 219 437	2 263 689	156 277	31 334 216
2002	17 013 192	249 366	16 416 566	2 339 331	40 634	36 059 089
2003	23 233 359	394 459	20 306 073	3 227 575	91 370	47 252 836
2004	31 259 851	577 822	27 104 284	3 906 835	318 361	63 167 153
2005	35 425 856	756 935	31 602 012	3 978 592	1 713 013	73 476 408
2006	42 670 650	911 760	35 170 349	4 880 697	1 901 219	85 534 676
2007	52 174 049	1 081 911	44 482 360	7 018 292	2 515 138	107 271 750
2008	66 456 960	1 260 202	50 923 205	10 435 291	2 951 539	132 027 196
2009	47 145 609	906 923	42 392 616	9 764 289	1 933 175	102 142 613
2010	57 784 065	990 802	45 948 708	7 684 769	1 474 875	113 883 219
2011	73 576 384	1 242 610	50 257 713	8 577 891	1 252 272	134 906 869
2012	77 983 403	1 017 753	50 440 156	21 781 595	1 238 830	152 461 737
2013	82 930 885	956 521	53 674 535	12 960 697	1 279 999	151 802 637
2014	86 304 496	922 776	55 270 960	14 103 312	1 008 613	157 610 158
2015	78 036 876	806 721	46 708 755	17 275 523	1 010 997	143 838 871
2016	78 400 026	641 121	44 754 542	17 747 063	986 832	142 529 584
2017	91 315 378	684 183	45 809 929	16 991 627	2 191 823	156 992 940
2018*	76 838 149	466 431	34 532 567	10 306 899	899 066	123 043 112

* 2018 yılına ait değerler ilk dokuz ayı kapsamaktadır.

İthal edilen malların değerlerinin taşıma türlerine göre dağılımını gösteren Çizelge 2.5 incelendiğinde 2017 yılı için denizyolunun %59 pay ile en büyük paya sahip olduğu denizyolunu %16 ile karayolunun takip ettiği görülmektedir. Demiryolu ile ihraç edilen toplam malların değeri tüm taşıma türleri içinde en düşük paya sahiptir.

İthalat ile kıyaslandığında denizyolu ile taşınan malların değerinin payı hemen hemen aynı kalırken karayolu ile taşınan malın değerinde ciddi bir düşüş olduğu gözlenmektedir. Ayrıca diğer taşıma türleri ile taşınan ithal malların değerinin payı ihraç mallarının değerine göre oldukça yüksektir.

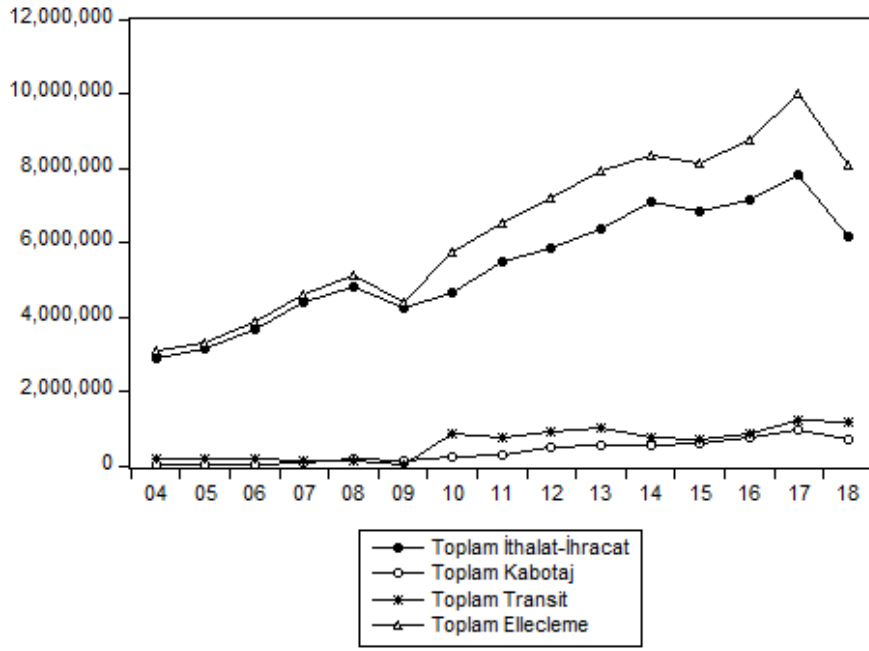
Çizelge 2.5. Taşıma türlerine göre ithalat, 2000-2018 (Değer: Bin ABD Doları(\$)) (TÜİK)

Yıllar	Denizyolu	Demiryolu	Karayolu	Havayolu	Diğer	Toplam
2000	27 558 493	229 889	18 301 107	5 892 215	2 521 117	54 502 821
2001	20 170 596	281 345	13 511 686	5 223 182	2 212 274	41 399 083
2002	23 720 891	460 443	14 201 483	6 366 104	6 804 876	51 553 797
2003	33 774 929	645 051	17 822 702	8 445 731	8 651 279	69 339 692
2004	49 465 830	1 254 518	23 979 223	12 294 583	10 545 612	97 539 766
2005	56 497 886	1 816 522	28 667 246	13 072 142	16 720 355	116 774 151
2006	68 354 704	2 196 112	32 694 202	13 710 656	22 620 501	139 576 174
2007	86 670 036	2 540 385	38 631 797	16 912 068	25 308 429	170 062 715
2008	105 743 822	2 573 376	41 296 201	16 898 462	35 451 714	201 963 574
2009	73 962 307	1 723 345	33 514 253	11 562 648	20 165 868	140 928 421
2010	98 629 933	2 454 604	42 442 194	15 131 613	26 885 987	185 544 332
2011	133 440 206	3 185 525	44 516 802	21 514 596	38 184 548	240 841 676
2012	129 029 330	2 346 113	39 414 333	23 797 146	41 958 219	236 545 141
2013	139 927 201	1 773 400	40 058 217	32 602 866	37 299 565	251 661 250
2014	141 381 287	1 206 626	37 300 980	24 696 997	37 591 227	242 177 117
2015	124 439 886	1 169 581	34 364 154	20 002 844	27 257 894	207 234 359
2016	120 376 825	1 428 154	34 306 874	22 969 452	19 536 930	198 618 235
2017	136 672 358	1 178 057	37 800 301	34 286 450	23 862 486	233 799 651
2018*	104 787 521	943 755	27 540 039	22 930 876	17 953 183	174 155 374

* 2018 yılına ait değerler ilk dokuz ayı kapsamaktadır.

2.2.1. Türkiye konteyner elleçleme miktarları 2004-2018 (TEU)

Toplam elleçleme içerisinde en büyük payı ithalat ve ihracat olan konteynerler almaktadır. 2004 yılı için 2 899 860 TEU olan bu miktarın 2004 yılı içindeki payı %93 iken, 2017 yılı için 7 842 079 TEU olan bu miktarın 2017 yılı içindeki payı ise %76'dır. İthalat ve ihracat konteynerlerin oranı düşerken kabotaj ve transit konteynerlerde artış olmuştur. Kabotaj için 2004 yılında 37 708 TEU ile %1 olan oran 2017 yılında 935 521 TEU ile %9'a ulaşmıştır. Transitte ise 2004 yılında 176 288 TEU ile %6 olan oran 2017 yılında 1 188 780 TEU ile %15'e ulaşmıştır.



Şekil 2.6. Türkiye'nin konteyner elleçleme miktarları 2004-2018 (TEU) (Deniz Ticareti Genel Müdürlüğü İstatistik Bilgi Sistemi (DTGM İBS))

Türkiye'nin 2004-2018 yıllarına ait olan konteyner elleçleme miktarları TEU bazında grafik olarak Şekil 2.6'da gösterilirken tek tek değerler olarak Çizelge 2.6'da ifade edilmiştir. Şekil 2.6'da 2018 yılı için gösterilen değer 2018 yılının ilk dokuz ayını kapsamaktadır. 2018'de ciddi bir düşüş yaşanmış gibi gözükmesinin en önemli sebebi de budur.

Çizelge 2.6. Türkiye'nin konteyner elleçleme miktarları 2004-2018 (TEU) (DTGM-İBS)

Yıllar	Toplam			Toplam Elleçleme
	İthalat-İhracat	Kabotaj	Transit	
2004	2 899 860	37 708	176 288	3 113 855
2005	3 119 466	18 322	174 421	3 312 208
2006	3 650 082	23 050	184 921	3 858 052
2007	4 375 112	61 417	145 739	4 582 267
2008	4 813 107	162 908	115 606	5 091 621
2009	4 249 875	142 025	12 542	4 404 442
2010	4 660 891	208 325	874 239	5 743 455
2011	5 461 078	305 256	757 171	6 523 506
2012	5 821 683	472 345	898 368	7 192 396
2013	6 365 622	544 496	989 815	7 899 933
2014	7 069 819	527 065	754 238	8 351 122
2015	6 848 853	606 064	691 481	8 146 398
2016	7 150 890	738 312	872 772	8 761 974
2017	7 842 079	935 521	1 232 937	10 010 536
2018*	6 168 777	715 173	1 188 780	8 072 730

* 2018 yılına ait değerler ilk dokuz ayı kapsamaktadır.

2.2.2. Ülkeler bazında konteyner elleçleme: ilk 20 ülke

Ülkeler bazında elleçleme verilerini içeren Çizelge 2.7 incelendiğinde ilk sırayı 1 311 562 TEU ile Yunanistan'ın aldığı görülmektedir. Yunanistan elleçleme miktarı ile tüm elleçlemenin %14'lük payına sahiptir. Yunanistanı 1 242 965 TEU ile Mısır takip etmektedir. Bu miktar toplam elleçlemenin yaklaşık %14'ünün Mısır varışlı ya da çıkışlı olduğunu ifade etmektedir.

Çizelge 2.7. Ülkeler bazında konteyner elleçleme: ilk 20 ülke (TEU) (DTGM-İBS)

Sıra	Ülkeler	Toplam İthalat-İhracat	Transit	Toplam Elleçleme
1	YUNANİSTAN	1 141 902	169 659	1 311 562
2	MISIR	1 184 592	58 373	1 242 965
3	İTALYA	629 518	40 220	669 738
4	ÇİN	366 278	153 521	519 799
5	İSRAİL	481 165	11 209	492 374
6	İSPANYA	397 009	28 730	425 739
7	BELÇİKA	409 521	12 001	421 522
8	MALTA	372 407	7 043	379 450
9	RUSYA FED.	222 900	125 737	348 637
10	LÜBNAN	292 093	16 741	308 834
11	ROMANYA	171 459	110 969	282 429
12	SİNGAPUR	222 127	31 370	253 497
13	GÜRCİSTAN	146 013	94 817	240 831
14	İNGİLTERE	232 132	5 582	237 714
15	SUUDİ ARABİSTAN	196 473	26 140	222 613
16	GÜNEY KORE	170 880	23 458	194 338
17	UKRAYNA	86 877	65 111	151 988
18	BULGARİSTAN	70 874	80 876	151 750
19	A.B.D.	122 469	1 575	124 044
20	CEZAYİR	103 983	18 064	122 047

Dikkat çeken bir başka nokta ise bazı ülkelerde toplam ithalat ihracat oranı fazla iken, bazı ülkeler için ise transit miktarının fazla oluşudur. Transit yükler Türkiye sınırlarına başka ülkeye gönderilmek üzere gelirler. Bulgaristan için bu oran %53 iken, Ukrayna için bu oran %43, Romanya ve Gürcistan için ise %39'dur. Bu ülkeleri Rusya Federasyonu %36, Çin ise %30 ile takip etmektedir.

Toplam transit konteyner elleçlemesi içerisinde en fazla transit elleçlemeye sahip olan ülke ise %13 ile Yunanistan olurken onu %12 ile Çin ve %10 ile Rusya Federasyonu takip etmektedir.

Ülkeler Bazında İthalat ve İhracat Konteyner Elleçlemeri İlk 10 Ülke

Ülkeler bazında ithal konteyner elleçleme verilerini gösteren Çizelge 2.8 incelendiğinde ithalat konteyner elleçlemesinde ilk sırada Mısır yer alırken onu Yunanistan ve İtalya'nın izlediği görülmektedir. İhracat konteynerde ise Mısır ile Yunanistan yer değiştirerek ihracat konteynerde Yunanistan ilk sıraya geçmiştir. Bir diğer dikkat çeken nokta ihracat konteynerde İsrail'in üçüncü sırada yer almasıdır. İsrail'in İthalat ve ihracat elleçlemede Çin'in önünde olması ancak toplam elleçlemede Çin'in gerisinde kalmasının sebebi transit konteyner elleçlemesinin Çin'den az olmasıdır.

Çizelge 2.8. Ülkeler Bazında İthalat ve İhracat Konteyner Elleçlemeri İlk 10 Ülke karşılaştırması

İthalat Elleçleme (DTGM-İBS)			İhracat Elleçleme (DTGM-İBS)		
Sıra	Ülkeler	İthalat Elleçleme	Sıra	Ülkeler	İhracat Elleçleme
1	MISIR	495 201	1	YUNANİSTAN	735 716
2	YUNANİSTAN	406 186	2	MISIR	689 390
3	İTALYA	363 297	3	İSRAİL	277 169
4	İSPANYA	302 687	4	İTALYA	266 220
5	İSRAİL	203 996	5	BELÇİKA	221 832
6	ÇİN	198 897	6	LÜBNAN	208 022
7	İNGİLTERE	190 446	7	MALTA	199 351
8	BELÇİKA	187 689	8	ÇİN	167 380
9	MALTA	173 056	9	RUSYA FED.	120 668
10	SUUDİ ARABİSTAN	128 810	10	GÜNEY KORE	112 649

2.2.3. Liman başkanlıkları bazında konteyner elleçleme miktarları

Liman başkanlıkları bazında konteyner elleçleme miktarlarını gösteren Çizelge 2.9 incelendiğinde ilk sırada Ambarlı liman başkanlığının yer aldığı ve bu liman başkanlığını sırasıyla Mersin ve Kocaeli liman başkanlıklarının takip ettiği görülmektedir.

Ambarlı liman başkanlığı toplam konteynerin %31'ini elleçlerken Mersin %16'sını, Kocaeli ise %13'ünü elleçlemektedir. Üç liman başkanlığının elleçleme toplamı toplam elleçlemenin neredeyse %60'ını kapsamaktadır. Üç liman başkanlığını sırasıyla %9 ile Tekirdağ, %8 ile Gemlik ve Aliağa, %6 ile İzmir, %4 ile İskenderun ve %2 ile Antalya takip etmektedir.

Çizelge 2.9 incelendiğinde dikkat çeken bir başka nokta ise ve Ambarlı liman başkanlıklarının özellikle transit elleçlemede ön sırada olduğudur. Tekirdağ transit konteynerlerin %48'ini elleçlerken Ambarlı transit yüklerin %45'ini elleçlemektedir. Toplam elleçlemede 4. sırada yer alan Tekirdağ transit elleçlemede ilk sıraya yükselmektedir.

Çizelge 2.9. Liman başkanlıkları bazında konteyner elleçleme miktarları 2017 (TEU) (DTGM-İBS)

Sıra	Liman Başkanlıkları	Toplam			Toplam Elleçleme
		İthalat-İhracat	Kabotaj	Transit	
1	AMBARLI	2 305 268	263 935	553 301	3 122 504
2	MERSİN	1 504 008	49 680	152	1 553 840
3	KOCAELİ	1 125 212	111 790	789 88	1 315 990
4	TEKİRDAĞ	201 707	140 376	594 398	936 481
5	GEMLİK	619 301	177 695	2 126	799 122
6	ALIAĞA	749 328	43 998	1 016	794 342
7	İZMİR	605 563	29 383	2 956	637 902
8	İSKENDERUN	443 110	4 971	0	448 081
9	ANTALYA	173 347	26 545	0	199 892
10	İSTANBUL	68 296	17 212	0	85 508
11	SAMSUN	32 395	33 532	0	65 927
12	BANDIRMA	1 722	27 087	0	28 809
13	TRABZON	3 554	7 865	0	11 419
14	YALOVA	9 244	0	0	9 244
15	KARABİGA	0	1 105	0	1 105
16	MARMARA A.	0	344	0	344
17	TAŞUCU	12	0	0	12
18	ÇEŞME	10	0	0	10

Kabotaj yük elleçleme noktasında ise Ambarlı'yı ikinci sırada takip eden Gemlik ve üçüncü sırada takip eden Tekirdağ liman başkanlıkları dikkat çekmektedir. Ambarlı liman başkanlığının kabotaj yük elleçleme oranı %28 iken Gemlik ve Tekirdağ liman başkanlıklarının sırasıyla %19 ve %16'dır. Üç liman başkanlığını ise %12 ile Kocaeli liman başkanlığı izlemektedir.

İthalat ihracat toplamının elleçlenmesinde ise toplam elleçlemede ilk üç sırada olan liman başkanlıkları yerini korumaktadır. İlk sırada %29 ile Ambarlı yer alırken Ambarlı liman başkanlığını %19 ile Mersin, %14 ile Kocaeli, %10 ile Aliağa, %8 ile Gemlik ve İzmir, %6 ile İskenderun %3 ile Tekirdağ, %2 ile Antalya takip etmektedir. Transit ve Kabotaj elleçlemelerinde ilk sıralarda yer alan Tekirdağ ithalat ihracat konteyner elleçlemelerinde 8. sıraya düşmektedir.

Çizelge 2.10. Liman başkanlıkları bünyesinde yer alan limanlar

Limn Başkanlığı	Limanlar				
ALİAĞA	Nemport	Ege Gübre (TCEEĞE)	APM Terminals	Akçansa	
AMBARLI	Marport	Kumport	Mardaş		
ANTALYA	Port Akdeniz				
BANDIRMA	Çelebi Bandırma				
ÇEŞME	Ulusoy Çeşme				
GEMLİK	Gemport	Borusan	Rodaport		
İSKENDERUN	Limak İskenderun	Assan Port			
İSTANBUL	Haydarpaşa				
İZMİR	İzmir				
KOCAELİ	Yılport	DP World Yarımca	Evyapport	Limaş	Safiport Derince
MERSİN	MIP (Mersin)				
SAMSUN	Samsunport				
TEKİRDAĞ	Asya Port				
TRABZON	Trabzon				

Liman başkanlıklarını ön sıralara taşınmasını sağlayan bünyelerinde yer alan limanlar olmaktadır. Çizelge 2.10 liman başkanlıklarının sınırları içerisinde yer alan limanları göstermektedir. Liman başkanlıklarının içinde yer alan limanlar bilgisi e-posta yolu ile Türklım Sektör Raporunun oluşmasında etkin rol oynayan, limanlar konusunda uzman ve Türkiye'de limanlar konusunda ilk sıralarda yer alan Prof. Dr. Soner Esmer'den elde edilmiştir.

2.2.4. Limanlar Bazında Konteyner Elleçleme miktarları

Konteyner elleçleyen limanların toplam elleçleme miktarlarının yer aldığı Çizelge 2.11 incelendiğinde ilk üçte sırasıyla Marport, MIP ve Kumport limanlarının yer aldığı görülmektedir. 2015, 2016 ve 2017 yılları için Marport ve MIP en yüksek konteyner miktarlarını elleçleyerek konumlarını korumuşlardır. 2015 ve 2017 yıllarında üçüncü sırada yer alan Kumport limanı ise 2016 yılında altıncı sıraya gerilemiştir.

Çizelge 2.11. Türkiye’de konteyner elleçleyen limanların elleçleme miktarları (TEU)
(Türklim 2017, 2018)

Sıra	Limanlar	2015	2016	2017
1	Marport	1 585 419	1 846 995	1 711 357
2	MIP	1 441 196	1 453 038	1 591 983
3	Kumport	1 169 019	664 787	1 063 246
4	Asya Port	129 297	694 107	1 002 133
5	İzmir	656 410	682 057	639 300
6	Yılport	375 003	396 099	499 283
7	Gemport	369 288	356 461	474 019
8	DP World	2 077	52 191	437 047
9	Evyap	605 385	688 496	369 659
10	Mardaş	335 576	291 138	357 264
11	Nemport	254 311	271 751	313 596
12	Ege Gübre	330 250	366 845	286 926
13	Limak İskenderun	139 168	243 745	269 583
14	Borusan	225 718	249 466	241 971
15	Port Akdeniz	178 515	172 036	200 117
16	Assan	91 272	131 051	188 132
17	Haydarpaşa	121 641	109 675	86 709
18	Roda Port	88 993	86 322	88 438
19	Samsunport	52 414	54 929	70 027
20	Ç. Bandırma	18 613	11 463	27 162
21	Limaş	13 311	13 583	16 038
22	Trabzon	19 033	14 045	9 944
23	Akçansa	1 195	1 291	189
24	Derince Safiport	407	2 002	-
	Türkiye Toplamı	8 207 405	8 911 073	10 165 981

2015 yılında toplam konteyner elleçlemesinde %19 paya sahip olan Marport bu payı 2016 yılında %21'e çıkarırken 2017 yılında bu pay %17'ye düşmüştür. MIP ise 2015 yılında %18 paya sahip iken 2016 ve 2017 yılları için yaklaşık %16 paya sahiptir. Kumport 2015'te yaklaşık %14 olan payını 2016 yılında %7'ye düşürmüştür 2017 yılında ise tekrar %10'a çıkarmıştır. 2016 yılında Kumportun daha az elleçleme yapması ile üçüncü sırada Asya Port yer almıştır. Türkiye sıralamasında ilk üçte yer alan limanlar toplam elleçlemenin 2015 yılı için %51'ini, 2016 yılı için %45'ini ve 2017 yılı için %43'ünü yapmışlardır.

Elleçleme payları incelendiğinde dikkat çeken limanlardan biri Temmuz 2015'te Tekirdağ liman başkanlığı altında hizmete giren Asya Port'tur. 2015 yılında hizmete girdiği için 2015 elleçlemeleri düşük olan Asya Port 2016 yılında toplam elleçleme payının %8'ini almış, 2017 yılında ise bu oranı %10'a çıkarmıştır. Bir diğer aşama kaydeden liman ise 2016 yılında resmi olarak hizmete açılan DP World Yarımca'dır. 2016 yılında 19. sırada olan liman 2017 yılında %4'lük pay ile 8. sıraya yerleşmiştir.

Asya Port ve Dp World Yarımca paylarını arttırırken toplam elleçlemeden aldığı payı elinde tutamayan limanlar da vardır bunlardan biri Evyap limanıdır. 2015 yılında %7 paya sahip olan liman 2016 yılında payını %8'e çıkarmış ancak 2017 yılında bu payı %4'e düşürmüştür.

Çizelge 2.9 ve Çizelge 2.11 birlikte incelendiğinde aralarında paralellik olduğu görülmektedir. Liman elleçlemelerinde ilk sırada olan Marport'un ve üçüncü sıradaki Kumport'un altında yer aldığı Ambarlı liman başkanlığını ilk sıraya taşımaları beklenen bir durumdur. Bu durum Mersin limanının yer aldığı Mersin Liman başkanlığı için de böyledir. Kocaeli liman başkanlığı altında yer alan DP World Yarımca ve Evyap limanlarının aynı bölgede yer alması bir limanın kan kaybederken diğerinin elleçlemesinde artış olmasında belki önemli ölçüde etkilidir. Tabii ki bu başka bir araştırma konusunu oluşturmaktadır. Bu durumun altında rekabetin yanında çok daha başka sebepler yatıyor olabilir.

2.2.5. Limanlar bazında transit konteyner elleçleme miktarları

Limanlar bazında transit konteyner elleçlemelerini gösteren Çizelge 2.12 incelendiğinde ilk sırada 825 036 TEU ile Asyaport'un yer aldığı görülmektedir. Asyaport'u 767 374 ile Marport ve 434 046 TEU ile Kumport takip etmektedir.

2015 yılında Marport, Kumport ve MIP'nin ardından dördüncü sırada olan Asyaport, 2016 yılında Marport'un ardından ikinci sırada yer almış 2017 yılında ise ilk sıraya yerleşmiştir. Asyaport'un yanında Limak İskenderun da 2015 2016 ve 2017 yıllarında transit yük elleçlemesinde artan miktarlara sahiptir. Ancak Limak İskenderun için sıralamada bir değişiklik olmamıştır.

Çizelge 2.12. Transit konteyner elleçlemeleri (TEU) (Türklim, 2018)

Limanlar	2015	2016	2017
Asyaport	106 048	583 312	825 036
Marport	788 508	852 753	767 374
Kumport	541 344	204 363	434 046
MIP	283 031	355 036	340 188
Mardaş	63 338	58 620	168 839
DP World	796	638	85 972
Limak İskenderun	6 708	10 475	12 447
Evyap	12 996	80 897	7 199
Ege Gübre	236	853	6 734
Assan	3 643	145	4 598
Gemport	4 118	1 817	2 644
Yılport	4 118	351	530
Nemport	446	675	406
Roda	64	441	217
Borusan	0	2 625	0

3. ZAMAN SERİLERİ

3.1. Zaman Serilerinin Tanımı

Zaman serilerinin tanımına geçmeden önce zaman kavramının özelliğinden bahsetmek gerekir. Zamanın var oluşu her şeyin aynı anda oluşunu engeller bu yüzden meydana gelen bir olayın ardından o olay ile bağlantılı diğer olaylar daha sonraki süreçlerde meydana gelir. Buna örnek olarak meydana gelen bir kaza verilebilir. Kaza bir t anında meydana gelir ve etkileri $t+1$, $t+3$ ve $t+79$ anlarında görülebilir. Bu anları belirginleştirmek için örneklemek gerekirse t anında meydana gelen kazadan dolayı oluşan yaralanma sonucu $t+1$ anında hastaneye gidilmesi, $t+3$ anında ameliyat olunması ve $t+79$ anında geçmişte t anında meydana gelen kazanın başka bir hastalığa zemin hazırlaması olarak düşünülebilir. Burada bir hastanın sağlık durumu inceleniyor gibi de düşünülebilir (Pankratz, 2012:1).

Bir değişkenin zaman içinde sıralı olarak gözlemlenmesi *zaman serisi* olarak ifade edilir; zaman serileri zaman içerisinde oluşan, ilgili iş ya da ekonomik süreçlerin gerçekleşen değerler kümesini içerir (Heij, de Boer, Franses, Kloek, ve van Dijk, 2004:562). Yukarıdaki örnekte hastanın sağlık durumunu ilgili iş olarak ele alırsak kazanın ilk olduğu ilk t anından itibaren aylık gözlem yapılması ve bunun her ay devam etmesi bu değerlerin kaydedilmesi zaman serisini meydana getirir. Zaman serileri araştırmacılara zaman içerisinde yığın veride meydana geldiği varsayılan değişikliklerin belirlenmesine imkân vermektedir; ortalaması belli bir sayının etrafında seyreden bir zaman serisini ele aldığımızda belli bir dönemde bu ortalama değişiyorsa bu durum araştırmacıya önemli bir bilgi verir (Ergün ve Gökse, 2013:55).

Zamana göre sıralanmış veriler arasındaki ilişkide, zaman tarafından üstlenilen rol tam olarak anlaşılmazsa kamu ve özel sektör politika eylemlerinin, ya da fizik, kimya ve biyoloji mekanizmalarının doğasının etkileri yanlış anlaşılabilir. Bu noktada önemli bir kavram olan zamana göre sıralanmış veriler arasındaki ilişkiyi ortaya koymak için yapılan çalışmalar yani zaman serileri analizleri ortaya çıkmaktadır. Örnekten gidersek $t+79$ anında hastanın sağlık durumundaki bozukluk için geçmişteki değerleri incelenecek ve t anındaki kazaya dönüş yapılarak t anındaki kazanın $t+79$ anındaki etkileri incelenecektir (Pankratz, 2012:1).

Zaman serilerinde yer alan olaylar arasında zamana göre yapılandırılmış ilişkileri açıklamak için zaman serileri analizlerinde amaç bazı değişken ya da olaylar arasındaki zamana göre yapılandırılmış ilişkileri açıklamak için kullanışlı bir yol (model) bulmaktır (Pankratz, 2012:1). Bu çalışmanın uygulama noktalarından biri burada ortaya çıkmaktadır. Çalışmada amaç konteyner elleçlemelerine ait zaman serilerinin incelenmesi ve bu zaman serilerinden bir model oluşturularak, oluşturulan modelin tahminlemede kullanılmasıdır.

3.2. Zaman Serilerinin Bileşenleri

Zaman serileri yapılarında bazı bileşenleri barındırmaktadır. Zaman serisi içerisinde bu bileşenleri doğru olarak ayrıştırabilmek, yorumlayabilmek zaman serisine uygulanacak olan işlemler için son derece önemlidir.

Kirchgässner ve Wolters (2007) Warren M. Persons'tan alıntı yaparak zaman serisi bileşenlerini:


- uzun dönemli gelişimi ifade eden, *trend*,
- bir yıldan uzun süren dönemi içeren döngüsel bileşeni gösteren, *konjonktür dalgalanmalar*,
- yıl içindeki artışları ve azalışları içeren bileşen, *mevsimsel dalgalanmalar* ve
- trende, konjonktür ve mevsimsel dalgalanmalara ait olmayan tüm hareketleri içeren bileşen, *kalıntı*

olmak üzere dörde ayırmışlardır.

Regresyon gibi bazı ekonometrik analizlerde yanlış yönlendirmeler yaparak ilişkili olmayan serileri ilişkilimiş gibi gösteren sahte regresyona yol açan en dikkat edilmesi gereken bileşenlerden biri trenddir (Gujarati, 2011:224). Trendin bir başka yanıltıcı özelliği varlığı durumunda serilerin durağanlığını etkilemesi ve konu ile ilgili yeterli bilgisi olmayan araştırmacıları trendden arındırma yerine fark alma işlemine yönlendirmesidir. Peki trend ne demektir? Zaman serileri uzun bir süre genel olarak yükselme, düşme ve sabit kalma eğiliminde olabilirler bu durum *uzun vadeli trend* ya da *basit trend* olarak adlandırılmaktadır (Adhikari ve Agraval, 2013:12).

İklim ve hava koşulları, geleneksel alışkanlıklar, gelenek ve görenekler mevsimsel değişimlere yol açan önemli faktörlerdendir. Bu faktörlerin önemi yıl içinde mevsim boyunca oluşan dalgalanmalar meydana getirmelerinden ileri gelmektedir ki bu dalgalanmalar zaman serilerinde mevsimsel değişimleri ortaya çıkarmaktadır (Adhikari ve Agraval, 2013:12). Ekonometri derslerinde sıkça dile getirildiği gibi mevsimsel etkiler özellikle yukarıdaki faktörlerden daha çok etkilenen çeyreklik ve aylık verilerde önem kazanmaktadır. Örneğin Türkiye için ocak ve şubat aylarında diğer aylara göre daha az konteyner elleçlenmektedir. Çeyreklik veriler ile tahmin yapacak araştırmacı bu bilgiyi dikkate almalı tahminlere yansıtmalıdır.


Orta vadeli değişimler zaman serilerinde farklı bir bileşen olan konjonktürel dalgalanmalar olarak tanımlanmaktadır, bu dalgalanmaları ise döngüler içinde tekrar eden koşullar meydana getirir. Genellikle iki ya da daha fazla yılı kapsayan konjonktürel dalgalanmalar Şekil 3.1’de de gösterildiği gibi gelişme (prosperity), gerileme (decline), bunalım (depression) ve canlanma (recovery) olmak üzere dört evreden oluşmaktadır (Adhikari ve Agraval, 2013:13). Denizcilik konjonktürel dalgalanmaların en net gözlemlenebileceği alanlardan biridir. Bu dalgalanmada en önemli noktalardan biri dalganın hangi evresinde olduğunun tespit edilebilmesidir. Bu tespit birçok fırsata kapı açmaktadır (Stopford, 2009).



Şekil 3.1. Konjonktürel dalgalanmaların dört evresi

Zaman serilerinin son bileşeni olan düzensiz ve rassal değişimler, düzenli olmayan ve özel örüntülerle tekrar etmeyen savaş, grev, deprem, sel, devrim gibi tahmin edilemeyen etkiler tarafından meydana gelir (Adhikari ve Agraval, 2013:13).

Açıklaması yapılan zaman serisi bileşenlerini kısaca özetlemek gerekirse trend bileşenini içeren zaman serisinin sürekli düşmesi, artması ya da sabit kalması beklenirken, mevsimsellik bileşenini içeren zaman serilerinin belli dönemlerde benzer davranış sergilemesi, konjonktürel dalgalanmalarda ise serinin belli süreler ile belli döngülerden geçmesi beklenir ancak bunların dışında kalanlar belli bir düzende hareket etmeyen davranışları ifade eder. Örneğin bir konteyner limanında liman işçilerinin greve gitmesi işleri aksatır ve elleçlemeleri düşürür. Bu durum diğer bileşenlerin aksine beklenmeyen bir durumdur ve düzensiz rassal değişmeyi ifade eder.



Şekil 3.2. Genel mal satışları (aylık veri, milyar dolar) (Evans M. K., 2003:189)

Bileşenlerden mevsimselliği ve trendi bir örnek grafik üzerinde görmek istenirse genel mal satışları grafiği Şekil 3.2 anlatılmak istenen ile ilişkili olarak incelenebilmektedir. Genel mal satışları grafiği incelendiğinde veri setinin yükselen bir trende sahip olduğu ve yıl içinde belli noktalarda benzer davranışlar sergilemesinden mevsimselliğin var olduğu gözlenmektedir. Ayrıca logaritmik şekilde artması verinin logaritmik yapıda olduğuna da işaret etmektedir. Bu yorumlar veri setinin grafiğinden çıkabileceğimiz ilk yorumlardır geçerliliklerinin incelenmesi gerekir.

3.3. Durağanlık

Durağanlık zaman serileri analizinde dikkat edilmesi gereken en önemli noktalardan biridir. Zaman serilerinin durağan olup olmasına göre uygulanan yöntemler farklılaşmaktadır. Örneğin Box – Jenkins yöntemi için zaman serisinin durağan bir yapıya sahip olması gerekmektedir. Durağanlık stokastik süreçlerin özel halidir. Gujarati (2004) rassal değişken olarak da ifade ettiği *stokastik süreci* zamana göre sıralanmış rassal değişkenlerin toplamı olarak ifade etmektedir.

Stokastik süreçlerin ifade edilmesi noktasında her zaman serisi gözleminin bir stokastik sürecin farklı üyeleri tarafından oluşturulduğu varsayılır ve zaman serilerinin gözlemlerini oluşturduğu varsayılan ilgili rassal değişkenler aynı sembol ile gösterilir; örneğin, zaman serisi y_1, \dots, y_T , T alt kümeyi içeren bir stokastik süreç iken y_t , T'nin bir alt kümesidir (Lütkepohl ve Krätzig, 2004:10).

Stokastik sürecin durağan olmasının bazı koşulları bulunmaktadır. Gujarati (2004) bu koşulları “Stokastik sürecin ortalaması ve varyansı sabitse ve iki zaman periyodu arasındaki kovaryans değeri kovaryansın hesaplandığı gerçek zamana değil de sadece iki zaman periyodu arasındaki uzaklık, aralık ya da gecikmeye bağlıysa o stokastik sürecin durağan olmasından söz edilebilir” şeklinde ifade etmektedir.

$$\text{Ortalama: } E(Y_t) = \mu \quad (3.1)$$

$$\text{Varyans: } \text{var}(Y_t) = E(Y_t - \mu)^2 = \sigma^2 \quad (3.2)$$

$$\text{Kovaryans: } \gamma_k = E[(Y_t - \mu)(Y_{t+k} - \mu)] \quad (3.3)$$

Eş. 3.1 durağan stokastik süreç tarafından oluşturulan bir zaman serisinin tüm elemanlarının aynı sabit ortalamaya sahip olduğunu yani durağan bir zaman serisinin trende sahip olamayacağını ifade etmektedir (Lütkepohl ve Krätzig, 2004:11).

Eş. 3.3, 3.2'yi kapsamaktadır, yani 3.3 sağlanıyorsa 3.2 koşulu da sağlanmaktadır. Bu yüzden çoğu kitapta koşul olarak 3.2 eşitliği verilmez durağanlığın koşulu olarak sadece 3.3 eşitliği ve 3.1 eşitliği gösterilir. 3.3 eşitliği aynı zamanda varyansın da zamanda değişmez olduğunu (Eş. 3.2) ifade etmektedir $k = 0$ için, varyans $\sigma_y^2 = E[(Y_t - \mu)]^2 = \gamma_0$ yani varyans t'ye bağlı değildir. Ayrıca, kovaryans $E[(Y_t - \mu)(Y_{t+k} - \mu)] = \gamma_k$ da t'ye bağlı değildir sadece sürecin iki üyesi arasındaki uzaklığı ifade eden k'ya bağlıdır (Lütkepohl ve Krätzig, 2004:11).

Shumway ve Stoffer (2011) zaman serisinin kesin durağan oluşunu “Eğer zaman serisi kesin durağan ise, değişkenlerin alt kümesinin çok değişkenli dağılım fonksiyonları, kayan kümedeki kaydırma parametresi k'nın tüm değerleri için değişkenlerin karşılıkları ile uyumlu olmalıdır” şeklinde ifade etmektedir. Bu ifade aslında olasılık dağılımının tüm momentlerinin, sadece ilk iki momenti olan ortalama ve varyansın değil, zamanda sabit olması durumunda söz konusu zaman serisinin kesin durağan olduğundan söz edilebildiğini ifade etmektedir (Gujarati, 2011:207).

Kesin durağanlığı deneysel olarak oluşturabilmek oldukça zordur, varsayılan genellikle kesin durağanlığın daha zayıf halini ifade eden zayıf durağanlıktır (Tsay, 2002:23). Aslında stokastik sürecin durağan olmasının bazı koşulları kısmında Gujarati tarafından yapılan durağanlık tanımı zayıf durağanlığı ifade etmektedir. Sözün özü şudur ki ortalamanın, varyansın sabit olması kovaryans değerinin ise gerçek zamana göre değil de iki zaman periyodu arasındaki uzaklığa bağlı olarak değişmesi gerekir. Bu çalışmanın uygulama kısmında kesin durağanlık durumu değil zayıf durağanlık durumu dikkate alınarak yapılmıştır.

3.4. Rassal Yürüyüş

Rassal yürüyüş ile ilgili bilgi vermeden önce rassal yürüyüşü tanımlama sürecinde yardımcı olması için gecikme operatörü ve otoregresif sürecin tanımlarından kısaca bahsetmek gerekir. Bu tanımlar rassal yürüyüş sürecinin formüllerinin anlaşılması noktasında okuyucuya yardımcı olacaktır.

Gecikme operatörü

Gecikme operatörlerine formüllerde sıkça rastlanmaktadır. Hansen'in (2006) kitabında yer alan ifadeler üzerinden konuyu açıklamak gerekirse $LY_t = Y_{t-1}$ ve $L^2 = LL$ 'dir ve bu durumda $L^2Y_t = LY_{t-1} = Y_{t-2}$ olur. İfadelerde gecikme operatörü L ile gösterilmekte ve L gecikmeyi ifade etmektedir. Bu ifadelerden yola çıkarak gecikme operatörü ile ilgili genel olarak $L^kY_t = Y_{t-k}$ ifadesi yazılabilmektedir.

Zaman serilerinde yer alan terimlerin geçmiş terimler ile ilişkili olup olmadığını anlama noktasında kullanılmaktadır. Bu durumu örnek ile ifade etmek gerekirse yılın on ikinci ayındaki sonuçların yılın on birinci ve onuncu aylardaki sonuçlarından etkilendiğini varsayalım ve ulaşılmak istenen sonuç on ikinci aya yönelik olsun. Bu durumda on birinci ay onikinci ayın bir gecikmelisini ifade ederken onuncu ay on ikinci ayın iki gecikmelisini ifade etmektedir.

Otoregresif (AR) süreçler

Otoregresif süreçleri (AR) açıklamak için bu kısımda öncelikle formülüne yer verilmiş ve sonrasında kafada daha net canlanması için örneklerle devam edilmiştir. Lütkepohl ve Krätzig (2004) kitaplarında p. dereceden y_t 'nin AR sürecini Eş. 3.4'teki gibi ifade etmektedir.

$$y_t = \alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p} + u_t \quad (3.4)$$

Eş. 3.4'te u_t ifade ederken, α sabit katsayıları ifade etmektedir. Bir önceki kısımda açıklanan gecikme operatörü kullanılarak bu süreci yazarlar ayrıca $(1 - \alpha_1 L - \dots - \alpha_p L^p)y_t = u_t$ ya da $\alpha(L)y_t = u_t$, $\alpha(L) = 1 - \alpha_1 L - \dots - \alpha_p L^p$ şeklinde ifade etmişlerdir. Eş. 3.4'te p değerinin üç olması üçüncü dereceden otoregresif süreci ifade ederken altı olması altıncı dereceden otoregresif süreci ifade etmektedir, yani bağımlı değişkenin değeri bağımlı değişkenin altıncı gecikmesinden etkilenmektedir.

Eş. 3.4'ten yola çıkarak otoregresif süreçlerde bağımlı değişkenin gecikmeli değerleri alınmaktadır sonucuna rahatlıkla ulaşılabilir. Çıkarılacak bir başka sonuç ise bağımlı değişkenin gecikmeli değerlerinin yanına sabit varyanslı sıfır ortalamalı beyaz gürültü sürecinin eklendiğidir.

Bu durumu Gujarati (2004) kitabında rassal yürüyüş davranışı sergileyen hisse senedi fiyatlarını örnek göstererek açıklamaktadır. IBM e göre yarınki hisse senedi fiyatları bugünün hisse senedi fiyatları AR(1) ile sadece rassal şokların (u_t) toplamıdır. Bu durum yazar tarafından Eş. 3.5'te yer alan şekli ile ifade edilmektedir.

$$y_{t+1} = y_t + u_t \quad (3.5)$$

Eş. 3.5'te y_{t+1} bağımlı değişkenin yarınki değerini ifade ederken y_t bağımlı değişkenin bugünkü değerini ifade etmektedir. Bu durum, bir zaman dilimi geriye atılarak, bağımlı değişkenin bugünkü değeri, dünün değerine şokların eklenmesiyle bulunur biçiminde değiştirilebilir.

Konuyu pekiştirmek için bir başka örnekle de ifade etmek gerekirse dört kişilik bir ailenin aylık harcamasının bağımlı değişken olduğu bir durumu ele alalım. Ailenin üçüncü aydaki harcamasını etkileyen etmenlerin birinin de bir önceki yani ikinci aydaki harcamasına bağlı olduğunu var sayalım. Buradaki ikinci aydaki harcama bağımlı değişkenin bir önceki aydaki değerini ifade etmektedir yani birinci dereceden otoregresif süreçtir.

Eş. 3.5'in elde edilmesini Hill, Griffiths ve Lim (2011) kitaplarında Eş. 3.6'da yer alan eşitliklerle ifade etmişlerdir.

$$\begin{aligned} y_1 &= y_0 + u_1 \\ y_2 &= y_1 + u_2 = (y_0 + u_1) + u_2 = y_0 + \sum_{s=1}^2 u_s \\ &\cdot \\ &\cdot \\ &\cdot \\ y_t &= y_{t-1} + u_t = y_0 + \sum_{s=1}^t u_s \end{aligned} \quad (3.6)$$

Rassal yürüyüş modeli Eş. 3.6'da da ifade edildiği gibi bağımlı değişkenin ilk değerini içerir ve bu değer üzerine stokastik trend olarak da ifade edilen stokastik terimlerin toplamı ($\sum_{s=1}^t u_s$) eklenir. Stokastik trend olarak ifade edilir çünkü trend ya da eklenecek şokun yönü tahmin edilemez, y_t etkisinde kaldığı şokun etkisiyle aşağı ya da yukarı yönlü hareket eder (Hill, Griffiths ve Lim; 2011:481).

Hill, Griffiths ve Lim (2011) rassal yürüyüşlerin durağan olmamasının mantığını rassal yürüyüşün ortalaması ilk değere eşit olduğu ancak varyansının sürekli artarak sonunda sonsuza ulaştığını, ortalama sabit olmasına rağmen sürekli artan varyansın serinin ortalamasının sabit kalmasını engellediği durumundan yola çıkarak açıklamaktadır. Burada ilk bakışta dikkat çeken nokta serinin ortalamasının sabit kalmadığıdır bu durağanlığın koşullarından ilkinin sağlanmadığının açık göstergesidir.

Hill, Griffiths ve Lim (2011) kitaplarında rassal yürüyüşün sabit bir terimli, trendli ve hem sabit hem de trendli de olabileceğini ifade etmekte ve bu durumları Eş. 3.7, Eş. 3.8, Eş. 3.9, Eş. 3.10, Eş. 3.11 ve Eş. 3.12'deki gibi ifade göstermektedirler.

Bunları sırasıyla incelemek gerekirse sabit terimli rassal yürüyüş Eş. 3.7 deki gibi ifade edilmektedir.

$$y_t = \alpha + y_{t-1} + u_t \quad (3.7)$$

Eş. 3.7'de α sabit terimi, bir diğer deyiş ile kayan terimi ifade etmektedir. Yazarlara göre genellikle kayan terimli rassal yürüyüş modelleri yukarı ya da aşağı eğimli trend gösterirken, negatif kayan terim aşağı yönlü trendi ifade etmekte, pozitif kayan terim ise yukarı yönlü trendi ifade etmektedir. Bu davranışı daha iyi anlayabilmek için yazarlar trendin yer aldığı durumu ifade eden Eş. 3.8'de yer alan yolu izlemişlerdir.

$$\begin{aligned} y_1 &= \alpha + y_0 + u_1 \\ y_2 &= \alpha + y_1 + u_2 = \alpha + (\alpha + y_0 + u_1) + u_2 = 2\alpha + y_0 + \sum_{s=1}^2 u_s \\ &\cdot \\ &\cdot \\ &\cdot \\ y_t &= \alpha + y_{t-1} + u_t = t\alpha + y_0 + \sum_{s=1}^t u_s \end{aligned} \quad (3.8)$$

Eş. 3.8’de t zamandaki y değeri; y ’nin ilk değeri olan y_0 , stokastik trend bileşeni olan $\sum_{s=1}^t u_s$ ’den ve deterministik trend bileşeni olan $t\alpha$ ’dan oluşmaktadır, deterministik trend olarak adlandırılmasındaki temel sebep her t zamanında sabit α ’nın eklenmesidir. Bu durumun ortalaması Eş. 3.9’daki gibi varyansı da Eş. 3.10’daki gibi ifade edilmektedir (Hill, Griffiths ve Lim; 2011:481):

$$E(y_t) = t\alpha + y_0 + E(u_1 + u_2 + u_3 + \dots + u_t) = t\alpha + y_0 \quad (3.9)$$

$$var(y_t) = var((u_1 + u_2 + u_3 + \dots + u_t)) = t\sigma_u^2 \quad (3.10)$$

Durağanlık koşullarında yer alan sabit ortalama ve sabit varyans durumlarının Eş. 3.9 ve 3.10’da bozulduğu açıkça görülmektedir, sonuç olarak trendli rassal yürüyüşün durağan olmadığı ortaya koyulmuştur (Hill, Griffiths ve Lim; 2011:481).

Bir diğer durum ise sabit ve trendin birlikte yer aldığı durumdur. Bu durumun ifadesi ise Eş. 3.11’de gösterilmektedir:

$$y_t = \alpha + \delta t + y_{t-1} + u_t \quad (3.11)$$

Hill, Griffiths ve Lim (2011) sabit terimli rassal yürüyüşü ifade ederken kullanıldığı gibi burada da iç içe yerleştirme yaparak konuya açıklık getirmeye çalışmış ve zaman trendinin trend davranışını kuvvetlendirdiğini ortaya koymuştur:

$$\begin{aligned} y_1 &= \alpha + \delta + y_0 + u_1 \\ y_2 &= \alpha + \delta 2 + y_1 + u_2 = \alpha + 2\delta + (\alpha + \delta + y_0 + u_1) + u_2 = 2\alpha + 3\delta + y_0 + \sum_{s=1}^2 u_s \\ &\cdot \\ &\cdot \\ &\cdot \\ y_t &= \alpha + \delta t + y_{t-1} + u_t = t\alpha + \left(\frac{t(t+1)}{2}\right)\delta + y_0 + \sum_{s=1}^t u_s \end{aligned} \quad (3.12)$$

3.5. Durağanlığın Belirlenmesi

Durağanlık analizi temel olarak üç farklı şekilde yapılabilmektedir. Birinci yol grafik analizi, ikinci yol otokorelasyon fonksiyonu ve korelogramların incelenmesi ve üçüncü yol ise birim kök testlerinin yapılmasıdır. Serinin grafiğine bakmak ön bilgi edinmek açısından önemlidir ancak grafik analizi ile net bilgiye ulaşmak mümkün değildir. Durağanlığın belirlenmesinde otokorelasyon fonksiyonun ve korelogramların incelenmesi de bir yöntemdir ancak en güvenilir birim kök testleri uygulamaktır.

3.5.1. Grafik analizi

Chatfield'den alıntı yapan Gujarati (2011) kitabında zaman serisinin grafiğini çizmeden analize başlayan bir kişinin bela aradığını ifade etmektedir. Zaman serisinin grafiğini incelemek zaman serisinin durağan olup olmadığına dair ipucu verir, grafik incelemek daha sonra yapılacak testlerin başlangıç noktasıdır.

3.5.2. Otokorelasyon fonksiyonu (autocorrelation function - ACF) ve kısmi otokorelasyon fonksiyonu (partial autocorrelation function - PACF)

İstatistik, ekonometri ve tahminlemede ilgilenilen nokta tek bir değişken değildir, asıl dikkate alınan incelenen nokta ilgilenilen değişkenin diğer değişkenlerle olan ilişkisidir bu durumda da iki değişken arasındaki korelasyon ile ilgilenilir. Korelasyonu hesaplamak için öncelikle kovaryansı hesaplamak gerekir, formülü ise Eş. 3.13'teki gibidir (Evans, 2003:42).

$$\text{Kovaryans: } Cov(X, Y) = E[(X - E(X))(Y - E(Y))] \quad (3.13)$$

Beklenen değerler için X ve Y'nin ortalama değerleri yerine konulduğunda gerçek kovaryanstan örneklem kovaryansına geçiş olur ve bu haliyle Eş. 3.14'teki gibi ifade edilir (Evans, 2003:42). X ve Y'nin gerçek değerleri bilinmediği için eldeki veri setine göre ortalama değerleri kullanılır.

$$\text{Kovaryans: } Cov(X, Y) = \sum \frac{(X_i - \bar{X})(Y_i - \bar{Y})}{N-1} \quad (3.14)$$

Korelasyon katsayısı kovaryansın X ve Y'nin standart hatalarının çarpımına bölünmesiyle bulunur ve Eş. 3.15 ile ifade edilir (Evans, 2003:42).

$$\text{Korelasyon katsayısı: } \rho(X, Y) = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y} \quad (3.15)$$

Korelasyon katsayısı her zaman +1 ve -1 değerleri arasında yer alır. Korelasyon katsayısı +1 e yaklaştıkça pozitif yüksek korelasyonu -1 e yaklaştıkça negatif yönlü yüksek korelasyonu ifade eder. 0 a yaklaşması ise aralarında ilişkinin olmadığını göstergesidir (Evans, 2003:43).

Kovaryans ve korelasyon farklı iki değişken arasındaki (X ve Y) doğrusal ilişkiyi ölçerken otokovaryans ve otokorelasyon bir değişkenin gecikmeli değerleri ile arasındaki ilişkiyi (y_t ve y_{t-1} , y_t ve y_{t-2} , y_t ve y_{t-3} ... gibi) ölçmektedir (Hyndman and Athanasopoulos, 2013). Örnek ile durumu daha da netleştirmek gerekirse kovaryans ve korelasyonda harcama ve gelir arasındaki ilişki hesaba katılırken otokovaryans ve otokorelasyonda harcama ve geçmiş harcamalar arasında ilişki hesaba katılmaktadır.

Durağanlık testlerinden bir diğeri de otokorelasyon fonksiyonudur, k gecikmeli otokorelasyon fonksiyonu ρ_k şeklinde gösterilir ve Eş. 3.16 ile hesaplanır (Gujarati, 2004:808).

$$\text{k gecikmeli otokorelasyon fonksiyonu } (\rho_k): \rho_k = \frac{\rho_k}{\rho_0} = \frac{k \text{ gecikmeli kovaryans}}{\text{varyans}} \quad (3.16)$$

Durağan sonlu otoregresif süreçlerde derecelerdeki farklılıkların ayrımını otokorelasyon fonksiyonundan yakalamak mümkün değildir. Çünkü durağan olma özelliğine sahip tüm seriler 0'a yaklaşır ancak kesilme hiçbir zaman olmaz. Farklı derecelerden kasıt modelin her durumlarda aynı gecikme sayısına bağlı olarak kurulmamasıdır. Bazı durumlarda AR(1) süreci (otoregresif bir gecikmeli süreç) olabilecek iken bazı durumlarda AR(3), AR(4) gibi farklı dereceden süreçler de olabilir. Derecelerdeki farklılıkları yakalamak için ise kısmi otokorelasyon fonksiyonu kullanılmaktadır (Kirchgässner ve Wolters, 2007:52). İki değişken arasındaki kısmi otokorelasyon, diğer rassal değişkenlerin etkisinin yok edilmesiyle arta kalandır, konu ile ilgili notasyon Eş. 3.17'de verilmiştir.

$$y_t = \phi_{k1}y_{t-1} + \phi_{k2}y_{t-2} + \dots + \phi_{kk}y_{t-k} + U_t \quad (3.17)$$

ϕ_{kk} katsayıları k dereceli kısmi otokorelasyon katsayılarını ifade etmektedir ($k = 1,2,\dots$). Kısmi otokorelasyon katsayılarının özelliği $y_{t-1}, y_{t-2}, \dots, y_{t-k+1}$ in etkilerini yok ederek geriye kalan y_t ve y_{t-k} arasındaki otokorelasyonu ölmesinden gelmektedir ki bu sayede dereceler belirlenebilir (Kirchgässner ve Wolters, 2007:53).

Otokorelasyon ve kısmi otokorelasyon fonksiyonlarını ile ilgili karar vermek noktasında otokorelasyonları ve kısmi otokorelasyonları belirlenen gecikmeye kadar görülmesini sağlayan *korelogramlar* kullanılmaktadır (Ergün ve Göksu, 2013:150). Şekil 3.3'ün a şikkı beyaz gürültü (ortalama ve otokorelasyonun "0", varyansın ise sabit olduğu olduğu süreç) hata terimi u 'nun korelogramını göstermektedir. Şekilde AC otokorelasyonu ifade ederken PAC kısmi otokorelasyonu ifade etmektedir, ayrıca Q-stat Q istatistiğinin ve Prob da olasılığın kısaltılmasını ifade etmektedir. Beyaz gürültü süreci durağan bir süreç olduğu için Şekil 3.3'ün a şikkındaki diyagram incelendiğinde birçok gecikmede otokorelasyonun 0 a yaklaştığı görülmektedir (Gujarati, 2004:809).

Bir diğer örnek Şekil 3.3'ün b şikkı durağan olmayan rassal yürüyüş sürecinin (Heij ve diğerleri, 2004:580) korelogramını göstermektedir, korelogram incelendiğinde otokorelasyon değerlerinin durağan süreci ifade eden a şikkındaki korelograma göre çok farklı olduğu otokorelasyon değerlerinin 0'a çok uzak olduğu görülmektedir gecikmeler 33'den 60'a kadar çıkarıldığında da durum çok değişmeyerek otokorelasyon değerleri 0,70 civarında seyretmektedir ki bu değer oldukça yüksektir. Şekil 3.3'ün c şikkı ise gerçek değerlerden oluşmuş bir örnek olan 1970-1 ve 1991-4 dönemlerini kapsayan ABD'nin gayri safi yurtiçi hasılanın korelogramını göstermektedir, b şikkı ile kıyaslandığında otokorelasyon katsayısının nispeten düştüğü görülmektedir ancak bu durum serinin durağan olmadığı gerçeğini değiştirmemektedir, sonuç olarak ABD'ye ait olan gayri safi yurtiçi hasıla durağan değildir (Gujarati, 2004:810-811).

Sample: 2 500
Included observations: 499

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.022	-0.022	0.2335	0.629
		2	-0.019	-0.020	0.4247	0.809
		3	-0.009	-0.010	0.4640	0.927
		4	-0.031	-0.031	0.9372	0.919
		5	-0.070	-0.072	3.4186	0.636
		6	-0.008	-0.013	3.4493	0.751
		7	0.048	0.045	4.6411	0.704
		8	-0.069	-0.070	7.0385	0.532
		9	0.022	0.017	7.2956	0.606
		10	-0.004	-0.011	7.2059	0.696
		11	0.024	0.025	7.6102	0.748
		12	0.024	0.027	7.8993	0.799
		13	0.026	0.021	8.2502	0.827
		14	-0.047	-0.046	9.3726	0.806
		15	-0.037	-0.030	10.074	0.815
		16	-0.026	-0.031	10.429	0.843
		17	-0.029	-0.024	10.865	0.863
		18	-0.043	-0.050	11.807	0.857
		19	0.038	0.028	12.575	0.860
		20	0.099	0.093	17.739	0.605
		21	0.001	0.007	17.739	0.665
		22	0.065	0.060	19.923	0.588
		23	0.053	0.055	21.404	0.556
		24	-0.017	-0.004	21.553	0.606
		25	-0.024	-0.005	21.850	0.644
		26	-0.008	-0.008	21.885	0.695
		27	-0.036	-0.027	22.587	0.707
		28	0.053	0.072	24.068	0.678
		29	-0.004	-0.011	24.077	0.725
		30	-0.026	-0.025	24.445	0.752

a. Durağan sürecin korelogram

Sample: 2 500
Included observations: 499

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.992	0.992	493.86	0.000
		2	0.984	0.000	980.68	0.000
		3	0.976	0.030	1461.1	0.000
		4	0.969	0.005	1935.1	0.000
		5	0.961	-0.059	2402.0	0.000
		6	0.953	0.050	2862.7	0.000
		7	0.946	0.004	3317.3	0.000
		8	0.939	0.040	3766.4	0.000
		9	0.932	-0.009	4210.1	0.000
		10	0.927	0.055	4649.1	0.000
		11	0.921	0.018	5083.9	0.000
		12	0.916	0.039	5514.9	0.000
		13	0.912	0.002	5942.4	0.000
		14	0.908	0.056	6367.0	0.000
		15	0.905	0.061	6789.8	0.000
		16	0.902	0.000	7210.6	0.000
		17	0.899	0.006	7629.4	0.000
		18	0.896	0.030	8046.7	0.000
		19	0.894	0.053	8463.1	0.000
		20	0.892	0.013	8878.7	0.000
		21	0.890	-0.041	9292.6	0.000
		22	0.886	-0.040	9704.1	0.000
		23	0.882	-0.044	10113.	0.000
		24	0.878	-0.012	10518.	0.000
		25	0.873	-0.023	10920.	0.000
		26	0.867	-0.041	11317.	0.000
		27	0.860	-0.055	11709.	0.000
		28	0.853	-0.045	12095.	0.000
		29	0.846	-0.010	12476.	0.000
		30	0.839	0.008	12851.	0.000
		31	0.832	-0.006	13221.	0.000
		32	0.825	0.003	13586.	0.000
		33	0.819	-0.006	13946.	0.000

b. Durağan olmayan sürecin korelogramı

Sample: 1970-1 1991-4
Included observations: 88

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.969	0.969	85.462	0.000
		2	0.935	-0.058	166.02	0.000
		3	0.901	-0.020	241.72	0.000
		4	0.866	-0.045	312.39	0.000
		5	0.830	-0.024	378.10	0.000
		6	0.791	-0.062	438.57	0.000
		7	0.752	-0.029	493.85	0.000
		8	0.713	-0.024	544.11	0.000
		9	0.675	0.009	589.77	0.000
		10	0.638	-0.010	631.12	0.000
		11	0.601	-0.020	668.33	0.000
		12	0.565	-0.012	701.65	0.000
		13	0.532	0.020	731.56	0.000
		14	0.500	-0.012	758.29	0.000
		15	0.468	-0.021	782.02	0.000
		16	0.437	-0.001	803.03	0.000
		17	0.405	-0.041	821.35	0.000
		18	0.375	-0.005	837.24	0.000
		19	0.344	-0.038	850.79	0.000
		20	0.313	-0.017	862.17	0.000
		21	0.279	-0.066	871.39	0.000
		22	0.246	-0.019	878.65	0.000
		23	0.214	-0.008	884.22	0.000
		24	0.182	-0.018	888.31	0.000
		25	0.153	0.017	891.25	0.000

c. ABD gayri safi yurtiçi hasıla korelogramı 1970-I 1991-IV

Şekil 3.3. Korelogram örnekleri (Gujarati, 2004:809-811)

3.5.3. Birim kök testleri

Birim kök teriminin çıkış noktasını sezgisel olarak anlamak için Gujarati (2011) bu durumu Eş. 3.18'de yer alan denklemden yola çıkarak açıklamaya çalışmıştır.

$$y_t = \beta_1 + \beta_2 t + \beta_3 y_{t-1} + u_t \quad (3.18)$$

Yazar, Eş. 3.18'deki denklemin her iki tarafından y_{t-1} 'i çıkartarak Eş. 3.19'u elde etmiştir.

$$\begin{aligned} (y_t - y_{t-1}) &= \beta_1 + \beta_2 t + C y_{t-1} - y_{t-1} + u_t \\ \Delta y_t &= \beta_1 + \beta_2 t + (C - 1) y_{t-1} + u_t \end{aligned} \quad (3.19)$$

Eş. 3.19'da y_{t-1} yani β_3 'ün katsayısı $C - 1$ 'dir; eğer C , 1'e eşit olursa denklemdaki β_3 , 0'a eşit olur. Birim kök testinde amaç β_3 'ün 0'a eşit olup olmadığını test etmektir. β_3 'ün 0'a eşit olup olmadığını test ederken aslında C 'nin 1 olup olmadığına da bakılmış olunur. Bu noktada ortaya çıkan 1'den dolayı birim kök ifadesi kullanılır (Gujarati, 2011:211).

Birim kök problemlerinin açığa çıkarılmasında ARMA (Oto regresif Hareketli Ortalama) modelin oto regresif ya da hareketli ortalamalar polinomlarının durumlarına bakılmaktadır. Bu polinomların birim çembere çok yakın olması, 1'e çok yakın olmasını ifade etmektedir, ya da birim çember üzerinde olması birim kök problemlerinin açığa çıkmasına sebep olur. Polinomların değerlerine bakılarak modelleme ile ilgili önemli sonuçlara ulaşılabilmektedir. Oto regresif polinomun 1'e yakın kökünün olması ARMA modelini kurmadan önce fark alma işlemini gerekliliğini gösterirken hareketli ortalama polinomunun 1'e yakın kökünün bulunması fazla fark alındığının göstergesidir (Brockwell ve Davis, 2002:193).

Zaman serilerinde modelleri kurar modellerin durağanlığına, modellerin durağanlık özelliklerine ya da kaç defa farkının alınması gerektiği gibi bilgilere serilerin grafiklerine, otokorelasyonlarına, kısmi otokorelasyonlarına bakarak karar vermek her zaman kolay değildir, bu durumu daha netleştirmek için birim kökler için istatistiksel testler geliştirilmiştir (Lütkepohl ve Krätzig, 2004:22)

Birim kökler için birçok test geliştirilmiştir ancak bu kısımda sadece uygulama kısmında kullanılacak testler açıklanacaktır. Bu testler ise Genişletilmiş Dickey-Fuller (ADF), Phillips-Perron (PP), Dickey-Fuller Genelleştirilmiş En Küçük Kareler (DF-GLS) ve Kwiatkowski-Phillips-Schmidt-Shin (KPSS) testlerinden oluşmaktadır.

Genişletilmiş Dickey-Fuller Testi (ADF)

Genişletilmiş Dickey-Fuller testini açıklamaya başlamadan önce, ilk bakılması gereken test ADF'in yalın hali olan Dickey-Fuller (DF) testidir. DF'ten kısaca bahsedildikten sonra ADF testinin açıklaması yapılacaktır.

$$\Delta y_t = \beta_1 + \beta_2 t + \beta_3 y_{t-1} + u_t \quad (3.20)$$

Eş. 3.20'de bağımlı değişken (Δy_t), y_t 'nin ilk farkını ($y_t - y_{t-1}$) ifade ederken t , 1 den örneklemin sonuna kadar değer alan zaman ya da trend değişkenini ve u_t de hata terimini ifade etmektedir, eşitlikte y_t 'nin ilk farkı (Δy_t), trend değişkeni (t) ve y_t 'nin bir gecikmesi (y_{t-1}) ile regresyona tabi tutulmuştur (Gujarati, 2011:211).

Eş. 3.20'de özellikle dikkat edilen katsayı β_3 'tür. Hipotezler bu katsayı üzerinden oluşturulmaktadır. Birim kök hipotezi olarak ifade edilen H_0 hipotezi, β_3 'ün yani y_{t-1} 'in katsayısının sıfır olduğunu ifade ederken, $(C - 1)$ 'in ifade ettiği 1'e yakın olma ya da 1 olma durumu, alternatif hipotez ise β_3 'ün sıfırdan küçük olma durumu ifade etmektedir ($\beta_3 < 0$). H_0 hipotezinin ret edilememesi serinin durağan olmadığını göstergesidir (Gujarati, 2011:211).

Serinin durağan olması durumunda $\beta_3 = 0$ hipotezi t testi ile ölçülebilir ancak t testi için serinin durağan olması gerekir, durağan olmayan serilerde hipotez testi yapıldığı için t testi yerine bu hipotezi test edebilmek için τ (tau) kullanılmaktadır ve literatürde bu test Dickey-Fuller (DF) testi olarak yer almaktadır. Hipotezin değerlendirilmesi DF kritik değerlerine göre yapılmaktadır; β_3 için hesaplanan τ değeri, DF'in kritik değerlerinden yüksek ise H_0 hipotezi ret edilir, bu durum serinin durağanlığını gösterir; eğer kritik değerden düşük ise H_0 hipotezi ret edilemez bu durum ise serinin durağan olmadığını göstergesidir (Gujarati, 2011:211).

DF testi ve daha sonra açıklanacak ve uygulamada kullanılacak ADF ve PP testleri üç farklı şekilde uygulanabilirken (Eş. 3.21, Eş. 3.22 ve Eş. 3.23), DF-GLS ve KPSS iki farklı şekilde (Eş. 3.22 ve Eş. 3.23) uygulanabilir (Gujarati, 2011:212):

$$\text{Rassal yürüyüş: } \Delta y_t = \beta_3 y_{t-1} + u_t \quad (3.21)$$

$$\text{Kayan terimli rassal yürüyüş: } \Delta y_t = \beta_1 + \beta_2 t + \beta_3 y_{t-1} + u_t \quad (3.22)$$

$$\text{Kayan terim ve deterministik trendli rassal yürüyüş: } \Delta y_t = \beta_1 + \beta_2 t + \beta_3 y_{t-1} + u_t \quad (3.23)$$

Testlerin üç farklı uygulama biçimi varken hangi uygulama tipinin tercih edilmesiyle ilgili kullanılabilecek ipuçlarını Gujarati (2011) kitabında aşağıdaki gibi sıralamıştır, yazara göre;

- Eğer zaman serisi sıfır ortalama etrafında dalgalanıyorsa Eş. 3.21 'ün uygulanması,
- Eğer zaman serisi sıfırdan farklı bir ortalama etrafında dalgalanıyorsa Eş. 3.22'in uygulanması,
- Eğer zaman serisi doğrusal bir trend etrafında dalgalanıyorsa ki bazen trend ikinci dereceden de olabilir o zaman da Eş. 3.23'nin kullanılması uygun olmaktadır.

ADF testinin ortaya çıkışı DF testinin hata terimlerinin (u_t) ilintisiz olduğunu varsaymasından kaynaklanmaktadır. DF testinin başına gelen türkçe ifadesi ile genişletilmiş kelimesi bağımlı değişkenin gecikmelerinin eşitliklere eklenmesinden ileri gelmektedir ve bağımlı değişkenin eklenmesi ile yeni eşitlik Eş. 3.24'teki gibi olmaktadır (Gujarati, 2004:817):

$$\Delta y_t = \beta_1 + \beta_2 t + \delta y_{t-1} + \sum_{i=1}^m \alpha_i \Delta y_{t-i} + u_t \quad (3.24)$$

Eş. 3.24'deki u_t saf beyaz gürültü hata terimini ifade ederken, y_{t-1} 'nin farkı (Δy_{t-1}) y_t 'nin birinci gecikmesi ile ikinci gecikmesinin farkını ($y_{t-1} - y_{t-2}$), y_{t-2} 'nin farkı (Δy_{t-2}) y_t 'nin ikinci gecikmesi ile üçüncü gecikmesinin farkını ($y_{t-2} - y_{t-3}$) ifade etmektedir bu durum y_{t-3} , y_{t-4} ... için de aynı mantıkla devam etmektedir. Hata terimlerinin serisel olarak ilintisiz olmasını sağlayana kadar gecikmesi alınmış fark terimleri eklenmeye devam edilir, ADF testi DF testinde olduğu gibi y_{t-1} teriminin katsayısının (δ) sıfır olup olmadığını sorgular ve DF testi ile aynı asimptotik dağılımı izler böyle olunca aynı kritik değerler kullanılabilir (Gujarati, 2004:817).

Phillips-Perron (PP)

ADF testi DF testinin varsayımlarından biri olan hata terimlerinin (u_t) bağımsız özdeşçe dağılmış olması varsayımının gerçekleştirilmesi durumunu hesaba katarak gecikmesi alınmış fark terimlerini ekleyerek bu varsayımın gerçekleştirmediği durum için testi geliştirmiştir. Phillips ve Perron ise serisel korelasyon varsayımının geçerli olmadığı durum için ADF testi gibi gecikmesi alınmış fark terimleri ekleyerek bu durumu çözmek yerine parametrik olmayan istatistiksel yöntem kullanarak bu duruma çözüm getirmiştir (Gujarati, 2004:818).

Dickey-Fuller GLS (DF-GLS)

DF testi üzerinden ortaya çıkan bir başka test olan DF-GLS testinde genelleştirilmiş en küçük kareler regresyonu tarafından değiştirilmiş serilerde bulunan birim kökler için, değişikliğe uğramış DF t testi uygulanmaktadır. Elliott ve diğerleri DF-GLS testinin ADF testinden çok daha iyi olduğunu göstermişlerdir, testin uygulanışı ise Eş. 3.25'teki formu sergilemektedir (Farhan ve Ong, 2018).

$$\Delta y_t = \alpha + \delta t + \beta y_{t-1} + \zeta_1 \Delta y_{t-1} + \dots + \zeta_k \Delta y_{t-k} + u_t \quad (3.25)$$

Eş. 3.25'deki α sabiti, δ zaman trendinin katsayısını ve ζ de otoregresif sürecin gecikmelerini ifade etmektedir, bu test için de test edilecek katsayı bağımlı değişkenin bir gecikmesine (y_{t-1}) ait olan katsayıdır test için boş hipotez $H_0: \beta = 0$ iken alternatif hipotez $H_1: \beta \neq 0$ 'dır (Farhan ve Ong, 2018).

Kwiatkowski-Phillips-Schmidt-Shin (KPSS)

Zaman serilerinin durağanlığını test etmek için alternatif yöntemlerden biri de Denis Kwiatkowski, Peter C.B. Phillips, Peter Schmidt ve Yongcheol Shin (KPSS,1992) tarafından önerilen kendi soyadlarının baş harflerinden oluşan KPSS yöntemidir. Önerilen test durağanlığı ölçmek için olsa da diğer testlerin aksine boş hipotezi birim kökün varlığı değil zaman serisinin durağan oluşudur ($H_0: y_t \sim I(0)$) (Kirchgässner ve Wolters, 2007:178). KPSS testinin hipotezleri $H_0: \sigma_v^2 = 0$ ve $H_1: \sigma_v^2 \neq 0$ çiftlerine eşittir ve H_0 hipotezi ret edilemezse bu serinin durağan olduğunun göstergesidir (Lütkepohl ve Krätzig, 2004:63).

Doğrusal trendin var olmadığının varsayıldığı durumlarda zaman serisi için başlangıç formu Eş. 3.26'daki gibi ifade edilmektedir. Eşitlikte x_t rassal yürüyüştür yani x_t 'yi bağımlı değişken olarak düşündüğümüzde $x_t = x_{t-1} + v_t$ şeklinde ifade edilmektedir ve burada x_t 'ye ait kalıntıları ifade eden v_t durağandır ($v_t \sim \text{iid}(0, \sigma_v^2)$), ve ayrıca z_t 'de durağan bir süreci ifade etmektedir (Lütkepohl ve Krätzig, 2004:63).

$$y_t = x_t + z_t \quad (3.26)$$

KPSS testinin test istatistiği'nin formülü Eş. 3.27'de gösterilmiştir.

$$KPSS = \frac{1}{T^2} \sum_{t=1}^T S_t^2 / \hat{\sigma}_\infty^2, \quad (3.27)$$

Eş. 3.27'de $S_t = \sum_{j=1}^t \hat{\omega}_j$, iken $\hat{\omega}_t = y_t - \bar{y}$ 'ya eşittir.

$$\sigma_\infty^2 = \lim_{T \rightarrow \infty} T^{-1} \text{Var}(\sum_{t=1}^T Z_t) \quad (3.28)$$

Eş. 3.28 Z_t sürecinin uzun dönemli varyansının tahmininin formülünü ifade etmektedir. $\hat{\sigma}_\infty^2$ ise Z_t sürecinin uzun dönemli varyansının tahmincisidir. Eğer zaman serisinde trendin varlığından şüphelenilirse zaman serisi için başlangıç noktası Eş. 3.29'daki gibi olmaktadır (Lütkepohl ve Krätzig, 2004:64):

$$y_t = \mu_t t + x_t + z_t, \quad (3.29)$$

Eş. 3.29'daki regresyondan gelen kalıntılar ($\hat{\omega}_t$) Eş. 3.30'a eklenir:

$$y_t = \mu_t + \mu_0 t + \hat{\omega}_t \quad (2.30)$$

KPSS testi saf trend durağan süreç ve rassal yürüyüş eklenmiş süreç arasında ayırma yapmaya çalışır, ilk adımda y sabit ve deterministik trend ile regresyona tabi tutulur, ikinci adımda ise kalıntılar eklenir (Kirchgässner ve Wolters, 2007:178).

3.6. Trend Durağan ve Fark Durağan Zaman Serileri

Araştırmacılar durağan olmayan bir seri ile karşı karşıya kaldıklarında serinin farkını alma eğilimindedirler. Ancak bu yöntem her zaman geçerli değildir. Seriyi durağan olmaktan uzaklaştıran sebeplerin çok iyi belirlenmesi ve sebep üzerinden seriye uygun işlemin yapılması gerekmektedir.

Genelde trend durağan sürecin farkını alarak serinin durağanlaşacağı düşüncesi yaygındır ancak trend durağan süreçte serinin durağan olmamasının sebebi serinin sahip olduğu trend bileşeni olduğu için bu durumda seriye fark alma işlemi işe yaramaz seriyi trendden arındırmaz böyle bir durumda trend bileşeninin ayrıştırılması gerekir. Bu noktada bu ikisi arasındaki farkı iyi bilmek gerekmektedir. Bu bölümde trend durağan ve fark durağan süreçten kısaca bahsedilecektir.

Bazı serilerde serinin durağan olmamasının kaynağı deterministik trend olabilmektedir. Bu gibi durumlarda standart regresyon modeli durumu tanımlamak için kullanılabilir. Konuyu daha netleştirmek için örnek üzerinden gitmek gerekirse ortalama fonksiyonu olan μ_t doğrusal trend içeriyorsa, μ_t sabit ve trendin toplamına eşit ($\alpha_0 + \alpha_1 t$) olur, bu durumu eşitliğe dökmek istendiğinde deterministik doğrusal trendli model olan Eş. 3.31 ortaya çıkmaktadır. Eş. 3.31'deki kalıntıları ifade eden a_t sıfır ortalamalı beyaz gürültü sürecini ifade ederken; deterministik ikinci dereceden ortalama fonksiyonu, $\mu_t = \alpha_0 + \alpha_1 t + \alpha_2 t^2$, için ise Eş. 3.32 kullanılır (Wei, 2006:70):

$$Z_t = \alpha_0 + \alpha_1 t + a_t \quad (3.31)$$

$$Z_t = \alpha_0 + \alpha_1 t + \alpha_2 t^2 + a_t \quad (3.32)$$

Durağan olmama durumu deterministik trendden kaynaklanan zaman serilerini durağan yapmak için zaman serisinden trendi çıkarmak gerekmektedir. Serinin trendden ayıklanması için öncelikle serinin Eş. 3.33'teki gibi sabit ve deterministik trend ile regresyona tabi tutulması gerekmektedir (Gujarati, 2011:215).

$$y_t = A_1 + A_2 t + v_t \quad (3.33)$$

Regresyona tabi tutulan seriden elde edilen kalıntılar (Eş. 3.34) ise deterministik trendden arındırılmış zaman serisini ifade etmektedir durağan olmama durumu sadece trendden kaynaklanıyorsa elde edilen kalıntıların durağanlık özelliği göstermesi gerekir (Gujarati, 2011:215):

$$\hat{v} = y_t - a_1 - a_2 t \quad (3.34)$$

Bir serinin durağan olmama sebebi sadece deterministik trendden kaynaklanıyorsa trendden ayıklamak seriyi durağanlaştırır ancak sebep deterministik trend değil stokastik trend ise trendden ayıklamak seriyi durağanlaştırmaz, deterministik trend ayıklandıktan sonra serinin durağanlaşıp durağanlaşmadığını artıkları oluşturan seriye (\hat{v}) tekrar birim kök testleri uygulanarak anlaşılabilir. Eğer zaman serisi deterministik trendden ayıklandıktan sonra durağanlaşıyorsa bu duruma *trend durağan süreç* adı verilir, burada belirtilmesi gereken bir diğer önemli nokta ise deterministik trendde sahip zaman serisi durağan değildir ancak bir birim kök süreci de değildir (Gujarati, 2011:215).

Trendin tamamen tahmin edilip edilmemesi ya da değişken olup olmaması durumuna göre trendin hangi yapıda olduğu belirlenmektedir. Zaman serisi içerisindeki trendin, tamamen tahmin edilebilmesi ve değişkenlik göstermemesi durumunda trendin deterministik yapıda olduğundan söz edilebilir ve bu durum *deterministik trend* olarak ifade edilirken eğer tahmin edilemiyorsa, değişkenlik gösteriyorsa bu durumda *stokastik trendden* söz edilir. Özellikle stokastik trend kavramını daha iyi açıklayabilmek için Eş. 3.35 kullanılabilir (Gujarati, 2004:802).

$$y_t = \beta_1 + \beta_2 t + \beta_3 y_{t-1} + u_t \quad (3.35)$$

Bağımlı değişkenin sabit, trend(t), bağımlı değişkenin bir gecikmesi (y_{t-1}) ile regresyona tutulduğu Eş. 3.35'te u_t beyaz gürültü hata terimini ifade ederken, t kronolojik olarak ölçülen zamanı ifade etmektedir, Eş. 3.35'teki $\beta_1 = 0$, $\beta_2 = 0$, $\beta_3 = 1$ olursa Eş. 3.36 elde edilir ve bu eşitlik saf rassal yürüyüşü ifade eder (Gujarati, 2004:803).

$$y_t = y_{t-1} + u_t \quad (3.36)$$

Eş 3.36'daki kayma terimi olmayan rassal yürüyüş modeli durağan değildir, bu modelin durağan olabilmesi için Eş. 3.37'deki gibi farkının alınması gerekir, farkı alınarak durağanlaşan kayma terimi olmayan rassal yürüyüş modeli fark durağan süreç olur (Gujarati, 2004:803).

$$\Delta y_t = (y_t - y_{t-1}) = u_t \quad (3.37)$$

Eğer Eş. 3.35'te yer alan $\beta_1 \neq 0, \beta_2 = 0, \beta_3 = 1$ olursa Eş. 3.38 elde edilir, bu eşitlik kayan terimli saf rassal yürüyüş sürecini ifade eder ve durağan değildir (Gujarati, 2004:803).

$$y_t = \beta_1 + y_{t-1} + u_t \quad (3.38)$$

Eş. 3.38'de de Eş. 3.36'da yapıldığı gibi fark alınırsa Eş. 3.39 elde edilir:

$$(y_t - y_{t-1}) = \Delta y_t = \beta_1 + u_t \quad (3.39)$$

β_1 'in durumuna göre y_t pozitif ya da negatif trend sergilemektedir, bu trende stokastik trend adı verilir. Bu süreç de fark durağan süreçtir çünkü fark alınarak durağan olmayan y_t zaman serisi durağanlaştırılabilir. Eğer Eş. 3.35'te $\beta_1 \neq 0, \beta_2 \neq 0, \beta_3 = 1$ olursa, eşitlik hem kayan terimli rassal yürüyüşü hem de deterministik trendi içerir (Eş. 3.40) (Gujarati, 2004:803).

$$y_t = \beta_1 + \beta_2 t + \beta_3 y_{t-1} + u_t \quad (3.40)$$

Eş. 3.40 a fark alma işlemi uyguladığımızda elde ettiğimiz eşitlik hala deterministik trend içerdiği için y_t süreç durağan değildir (Eş. 3.41) (Gujarati, 2004:803).

$$\Delta y_t = \beta_1 + \beta_2 t + u_t \quad (3.41)$$

Çalışmanın uygulama kısmında kullanılacak Eş. 3.42'de $\beta_1 \neq 0, \beta_2 \neq 0, \beta_3 < 1$. Eş. 3.42'de deterministik trende ve durağan AR(1) sürecine sahip y_t zaman serisi yer almaktadır, ve seri deterministik trend etrafında durağandır (Gujarati, 2004:804).

$$y_t = \beta_1 + \beta_2 t + \beta_3 y_{t-1} + u_t \quad (3.42)$$

3.7. Kukla Değişkenler

Sayılarla belirtilen bağımsız değişkenleri modele koymak kolaydır. Ancak bağımlı değişkeni etkileyen her değişkeni direkt olarak modele koymak mümkün değildir. Örnek vermek gerekirse 2008 krizi birçok ülkenin dış ticaretini etkilemiştir. Ama bu durumu sayılarla ifade etmek mümkün değildir. Bu durum 2008 yılı sonrası dış ticarete düşüşlerin olmasına sebep olmuştur. Peki 2008 krizinden etkilenen bir ülkenin dış ticaretinin bağımlı değişken olduğu durumda 2008 krizini modele nasıl ekleyebiliriz? Böyle bir durumda 2008 krizi modele eklenmek istendiğinde 2008 yılı öncesine kadar 0, 2008 yılından sonra 1 olan kukla değişkenler oluşturulmaktadır. Bu bölümde, model kurmada kullanılacağı için, bu konuyla ilgili bilgi verilmektedir.


Gösterge değişken, kukla değişken, ikili ya da iki parçaya ayrılmış değişken olarak da ifade edilebilen değişkenler normal koşullarda numralandıramadığımız değerleri, niteliksel faktörleri, ekonometrik modellerde sayısal olarak ifade ederek açıklamak için kullanılırlar. Karakteristik özelliğin varlığını ya da yokluğunu, ya da koşulun sağlanıp sağlanmadığını göstermek için, genellikle sıfır ya da bir olmak üzere iki değer alırlar ve kukla değişkenleri ifade etmek için D harfi kullanılabilir (Hill, Griffiths ve Lim; 2011:259). Eğer karakteristik özellik ya da koşul sağlanıyorsa sayı olarak 1 değeri verilir sağlanmıyorsa 0 ile ifade edilir (Eş. 3.43).

$$D = \begin{cases} 1 & \text{Karakteristik özellik var ise} \\ 0 & \text{Karakteristik özellik yok ise} \end{cases} \quad (3.43)$$

3.8. Yapısal Kırılmalar

Bazı seriler belli bir ortalama etrafında dalgalanırken seriyi etkileyen bir sebepten dolayı farklı bir ortalama değer etrafında dalgalanmaya devam eder. Bir önceki bölümde bağımlı değişken olarak ifade edilen dış ticaret ve onu etkileyen 2008 krizinden örnek vermek gerekirse (ancak burada gerçek sayılar değil temsili sayılar kullanılacaktır); 2008 yılına kadar 100 etrafında dağılan dış ticaret 2008 yılından sonra 80 etrafında dağılıyorsa burada yapısal kırılmadan söz edilmektedir. 2008 krizi 100 etrafında dağılan dış ticaretin ortalamasını 80'e çekmiş seride kırılmaya sebep olmuştur. Konunun ayrıntısı ilerleyen satırlarda mevcuttur.

Üzerinde çalışılan zaman serinde kırılmadan şüpheleniliyorsa bu seriye birim kök testleri uygulanırken daha dikkatli davranılması gerekmektedir. Çünkü yapısal kırılmanın olduğu durumlarda birçok Dickey-Fuller testi seride birim kökün var olduğunu ortaya koyma eğilimindedir. Şekil 3.4'ü örnek olarak alırsak ilk değere y_0 verilen 0 değerinden sonra Eş. 3.44 kullanılarak oluşturulan özellikle normal ve bağımsız dağılmış 100 değerinin bulunduğu seride $t=1...50$ 'ye kadarki zaman sürecinde 0 ortalama etrafında dalgalanırken $t=51...100$ 'e kadar olan zaman diliminde 6 ortalama etrafında dalgalanmaktadır. Şekil 3.4'te aslında serinin sabit bir ortalama ve varyans etrafında dağıldığı açıkça görülmektedir ancak kırılmanın olması birim kök testlerinin yanılgılarına sebep olabilmektedir (Enders ,2015:227).



Şekil 3.4. Yapısal değişikliğin yer aldığı model örneği

$$y_t = 0.5y_{t-1} + \varepsilon_t + D_L \quad (3.44)$$

Eş. 3.44'te D_L kukla değişkeni ifade etmektedir, burada kukla değişkenlere değer verilirken alışılmışın aksine $t=1...50$ 'ye kadarki süre zarfı için kukla değişkene 0 değeri verilmiş $t=51...100$ 'e kadarki süre zarfı için ise 3 değeri verilmiştir, yorumlar yapılırken de bu değerlerin dikkate alınması gerekmektedir, ayrıca eşitlikte yer alan D_L 'de yer alan L seviye (level) anlamına gelmektedir (Enders ,2015:227).

Şekil 3.4'te yer alan düz çizgi serinin deterministik trende sahipmiş gibi gözüktüğünü vurgulamaktadır, bu durum kırılmanın varlığı aslında olmayan bir trendi varmış gibi göstermektedir. Bu gibi durumlarda en uygun yöntem Eş. 3.45'te ifade edilen en küçük kareler denklemdir (Enders, 2015:227).

$$y_t = a_0 + a_2 t + e_t \quad (3.45)$$

Kırılma dikkate alınmadığında Şekil 3.4'ten de açıkça görülebileceği gibi Eş. 3.45'teki a_0 'ın uygun değeri negatif iken a_2 'nin uygun değeri pozitifdir olmaktadır, ancak bu örnekte en uygun model kırılmanın da dikkate alındığı Eş. 3.44'tür, yani basit AR(1) modelini uygulamak ve kukla değişken D_L 'ye göre kesme teriminin değişmesine izin vermektir (Enders ,2015:227).

Konunun başlarında yapısal kırılmadan şüphelenildiği durumlarda dikkatli davranılması gerektiğinden bahsedilmişti. Bu durum özellikle durağan süreç, yapısal kırılmaya sahip ise daha çok önem kazanmaktadır; böyle bir durumda örneklem büyüklüğü artsa bile testler, genellikle birim kök hipotezi H_0 'ı ret edemezler ve birim kökün var olduğunu öne sürerler (Kirchgässner ve Wolters, 2007:176).

3.8.1. Çoklu kırılma noktası testi (Bai-Perron test)

Zaman serilerinde çoklu yapısal kırılmaları bulmak ve istatistiksel anlamlılıklarını test etmek için yöntem bilim geliştiren Bai ve Perron tarafından önerilen yöntem bilim model kuranlara kırılma tarihlerini önceden bilmeye gerek duymadan içsel olarak yapısal kırılmaları tahmin etmeyi sağlamaktadır (Weideman, Inglesi-Lotz ve Heerden, 2017).

Testin çalışma mantığını daha iyi anlayabilmek için $t = 1,2,3 \dots T$ 'ye kadar giden M yapısal kırılmalı bir zaman serisini dikkate alındığını varsayalım. Böyle bir durumda bu zaman serisi $m+1$ kısımdan oluşur, katsayılarından bazıları tüm zaman serisi boyunca (ya da tüm kısımlar boyunca) sabit kalırken, diğerleri birinci kısımdan $m+1$. kısma kadar her ayrı kısımda tahmin edilir. Normal koşullarda kırılma noktalarının hesaplanması için çok sayıda en küçük kareler işlemi yapmak gerekmektedir. Bai ve Perron ise bu noktada her T zaman noktasının kırılma noktası olamayacağı mantığı ile yola çıkarak farklı bir bakış açısı geliştirmiştir. Bu ikiliye göre birinci ve ikinci zaman noktası kırılma noktası olamamaktadır çünkü bölümlerin minimum uzunlukta belirlenmiş olması gerekmektedir (Weideman, Inglesi-Lotz ve Heerden, 2017).

3.9. Yapısal Kırılmalarda Kukla Değişkenlerin Kullanılması

Bu konuya açıklık getirebilmek için, 1959-2007 dönemlerini içeren Amerika Birleşik Devletlerine ait gayrisafi özel yatırım (GPI) ve gayrisafi özel tasarruf (GPS) veri setlerini içeren yatırım fonksiyonu (Eş. 3.50) kullanılacaktır. Eş. 3.50’de yer alan B_1 sabitin katsayısını ifade ederken B_2 marjinal yatırım eğilimini ifade etmektedir (Gujarati, 2011:55).

$$GPI_t = B_1 + B_2GPS_t + u_t, \quad B_2 > 0 \quad (3.50)$$

1981-1982 yıllarında Amerika Birleşik Devletleri durgunluğun etkisi altında kalmış, bu durum Eş. 3.50’de yer alan yatırım tasarruf ilişkisine yönelik tahminlemeyi yaparken durgunluğun etkisi ile yapısal değişikliğin olmuş olma ihtimalinin göz önüne alınması gerekliliğini ortaya çıkarmıştır. Yapısal değişikliğin söz konusu olma ihtimalinin olduğu bu durumda durumu aydınlatmak için kukla değişkenlerin kullanılması gerekmektedir. Yapısal kırılmanın olup olmadığını test etmek için Eş. 3.50’ye *Recession84* kukla değişkeni eklenmiş ve yatırım fonksiyonunu Eş. 3.51’deki gibi tekrar kurulmuştur (Gujarati, 2011:55).

$$GPI_t = B_1 + B_2GPS_t + B_3Recession84_t + u_t \quad (3.51)$$

Eş. 3.51’de yer alan *Recession84* durgunluğun başladığı 1981 ve daha sonrası için 1 değerini, 1981 öncesi için 0 değerini almıştır. *Recession84* katsayısını ifade eden B_3 ise 1981’den beri ortalama yatırım düzeyinin ne kadar değiştiğini ifade etmektedir katsayının anlamlı çıkması kırılmanın var olduğunu ifade ederken yatırım tasarruf ilişkisinin bu durumdan etkilendiğini göstermektedir (Gujarati, 2011:56).

3.10. Mevsimsellik

Zaman serileri her aya ya da çeyreğe göre ölçüldüğünde bir yılın üzerinde tekrar eden ve uzun vadede ortalaması olan örüntüler içerebilmektedir. Bu durum her yıl aynı dönemde bir satışçının satışlarının düşmesi olarak canlandırmak mümkündür. Mevsimsel bileşen özellikle kısa dönemli tahminlerde önemli bir rol oynamaktadır, uzun dönemli tahminlerde ise baş rol olarak trend ile karşılaşmak mümkündür. (Heij ve diğerleri, 2004:604).

Zaman serilerinde mevsimselliğin kontrolünde en önemli nokta bu serilerin otokorelasyonlarında özellikle mevsim gecikmelerinde ve mevsim gecikmelerinin katlarında – aylık veriler için 12, 24, 36 ve devamı için; çeyreklik veriler için 4, 8, 12 ve devamı için – pozitif yükselmelerin yer almasıdır (Heij ve diğerleri, 2004:604). Tarım, inşaat ve seyahat sektörleri gibi hava durumunun etkisinde kalan ve bundan dolayı mevsimsellik formunu açık bir şekilde gösteren ekonomik süreçler mevsimsellik etkisinin gözlemlendiği ekonomik süreçlere örnek olarak gösterilebilmektedir (Enders, 2015:96).

Hansen (2006) mevsimsel verilerle baş etmenin üç popüler yöntemini kitabında şu şekilde sıralamaktadır:

- Mevsimselliğin örneklem boyunca değişmediği durumlarda her mevsim için kukla değişken kullanmak (bu yöntem bu çalışmaya uygun olduğu için uygulama kısmında kullanılmıştır)
- Mevsimsellikten arınmış veri seti kullanmak; mevsimsellikten arınmış veri seti filtrelenmiş veri setidir ve verinin zaman serisi korelasyonlarını değiştirir
- Mevsimsel fark operatörüne başvurmak; s 'in mevsimlerin sayısını ifade ettiğini varsayarsak (sıklıkla $s = 4$ ya da $s = 12$) $\Delta_s Y_t = Y_t - Y_{t-s}$ olur ve $\Delta_s Y_t$ serisi açık bir şekilde mevsimsellikten uzaklaşır. Bu yöntem stokastik trend durumunda yapılan uygulamanın mevsimsellik durumunda uygulanması olarak düşünülebilmektedir.

3.10.1. Deterministik mevsimsellik

Trend bileşeninde söz konusu olan deterministik ve stokastik olma durumu mevsimsellik bileşeni için de geçerlidir ve bu ikisi mevsimsellik bileşeni için de ayrılmalıdır. Deterministik bileşenleri ayırmak için mevsim kukları kullanılabilir. Konunun daha çok netleşmesi için Eş. 3.52'de deterministik trend ve mevsimsel bileşen içeren bir otoregresif model örnek olarak verilmiştir. Çeyreklik veriler olduğu için ve sabit de kullanıldığı için üç kukla değişken oluşturulmuştur (Heij ve diğerleri, 2004:605).

$$y_t = \alpha + \beta t + \alpha_2 D_{2t} + \alpha_3 D_{3t} + \alpha_4 D_{4t} + \phi y_{t-1} + \varepsilon_t \quad (3.52)$$

D_{2t} 'yi örnek olarak vermek gerekirse; D_{2t} , Eş. 3.52'de yılın ikinci çeyreğine düşen gözlemlere 1 değerinin geri kalanına ise 0 değerinin verildiğini ifade eden bir kukla değişkendir; bu durum D_{3t} için üçüncü çeyrek olarak D_{4t} içinse dördüncü çeyrek olarak ifade edilebilmektedir (Heij ve diğerleri, 2004:605).

Eş. 3.52'de yılın ilk çeyreği referans çeyrek olarak kullanıldığı için α_2 , α_3 ve α_4 farksal kesme katsayısıdır; ikinci, üçüncü ve dördüncü çeyrekteki ortalamaların birinci çeyrekteki ortalamadan ne kadar farklı olduğunu gösterir; α ilk çeyrekteki ortalamayı ifade etmektedir (Gujarati, 2011:58).

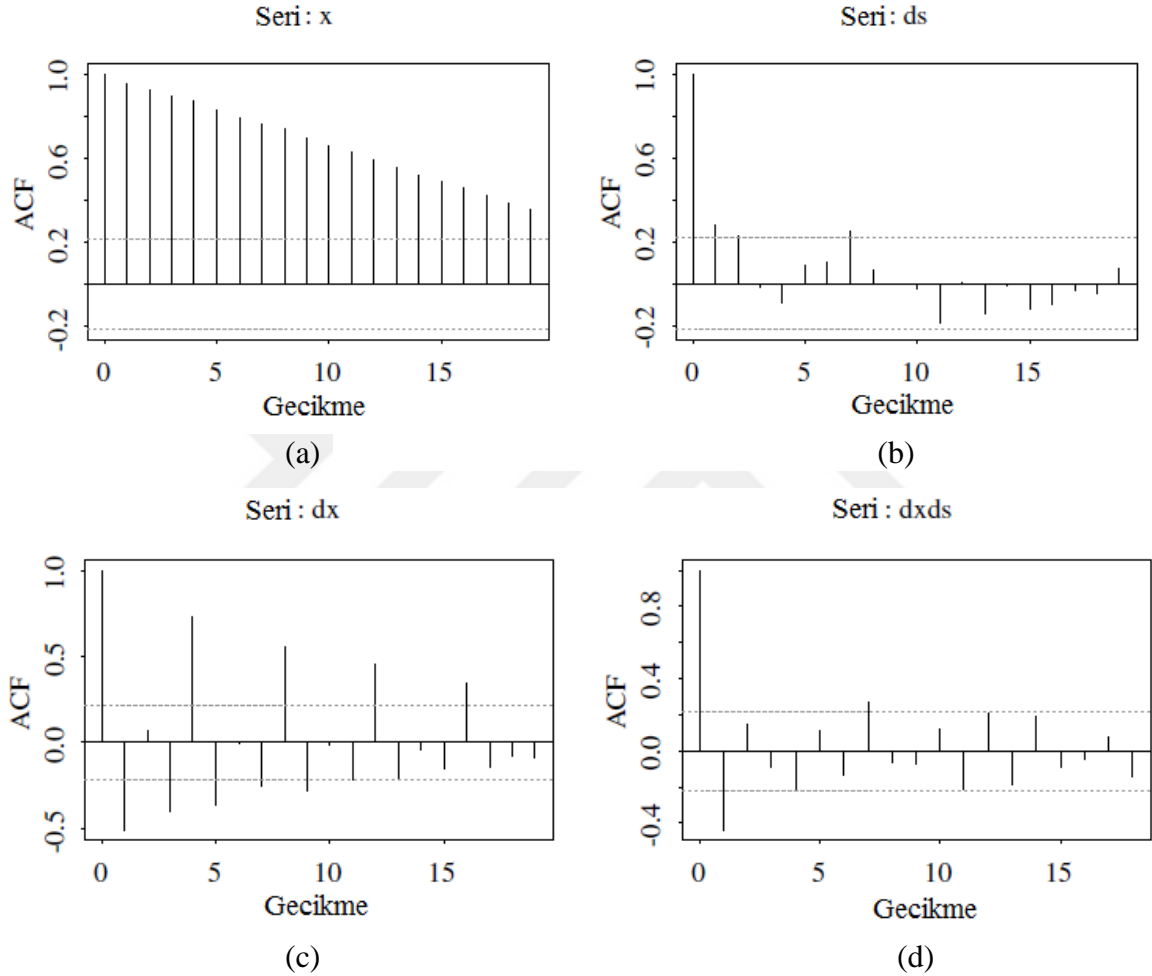
3.10.2. Mevsimsellikten arındırma

Mevsimsellikten arındırma zaman serisinden mevsimselliğin çıkarılmasıdır özellikle mevsimselliğin ikinci dereceden önemli olduğu durumlarda uygulanmaktadır (Tsay, 2002:62). Mevsimselliğin birinci dereceden önemli olduğu durumlarda seriyi mevsimsellikten arındırmak birçok araştırmacı için sorun teşkil edebilmektedir. Veriyi mevsimsellikten arındırmak veride yer alan mevsimsel örüntüleri tamamen ortadan kaldırmak anlamını taşısa bile mevsimsellikten arındırma tüm mevsimsellik örüntüleri ortadan kaldırmamış olabilmektedir (Enders, 2015:96). Tahminleme gibi uygulamalarda mevsimsellik veri setinin diğer karakteristik özellikleri gibi önemlidir ve özellikle bu yüzden ele alınması gerekmektedir (Tsay, 2002:62).

3.10.3. Mevsimsel fark alma

Bazı seriler yapılarında stokastik trend gibi stokastik mevsimsellik barındırmaktadır. Bu durumda stokastik trendde olduğu gibi fark alma işleminin uygulanması gerekmektedir. Ancak burada fark alma işlemi stokastik trendde olduğundan biraz farklıdır. Stokastik mevsimsellikte fark alma işlemi çalışılan veri tipinin sıklığına göre değişir. Şöyle ki aylık verilerle çalışılıyorsa mevsimsellik aynı aylar boyunca görülecektir. Aynı aylar arasında fark alma işlemi uygulamak için 12. gecikmesini dikkate almak gerekir. Çünkü 12. gecikme aynı aya denk gelmektedir. Bu durum çeyreklik verilerle çalışılması durumunda 4. gecikme olmaktadır. Konuyu daha net anlamak için Şekil 3.5'te yer alan örneği incelemek faydalı olacaktır.

Şekil 3.5'te yer alan x_t serisinin serinin üstel büyümesinin ele almak ve serinin değişkenliğini dengede tutmak için logaritması alınmıştır. Şekil 3.5'in a'sında yer alan grafik logaritmik hisse başına düşen kazancı çeyreklik verilerle ifade eden x_t serisinin otokorelasyon fonksiyonunu göstermektedir, otokorelasyon fonksiyonundan serinin güçlü serisel korelasyona sahip olduğu görülmektedir (Tsay, 2002:62).



Şekil 3.5. 1960'dan 1980'e Johnson & Johnson şirketinin logaritması alınmış çeyreklik verilerle hisse başına düşen kazancın örnek otokorelasyon fonksiyonları, x_t logaritmik kazancı, dx ilk farkı alınmış seriyi, ds mevsimsel farkı alınmış seriyi, $dxds$ hem normal farkı hem de mevsimsel farkı alınmış seriyi ifade etmektedir

Güçlü serisel korelasyona sahip x_t serisinin kullanılması için serinin ilk farkının alınması gerekmektedir [$\Delta x_t = x_t - x_{t-1} = (1 - B)x_t$], Şekil 3.5'in c'si x_t serisinin ilk farkının otokorelasyon fonksiyonunu göstermektedir, otokorelasyon fonksiyonu incelendiğinde 4 ve 4'ün katlarındaki gecikmelerde otokorelasyonların güçlendiği görülmektedir, bu durum zaman serisinde mevsimselliğin var olduğunu kanıttır. Box, Jenkins ve Reinsel'in yöntemi izlendiğinde zaman serisinin bir farkının daha alınması gerekmektedir Eş. 3.53 ise fark alma işlemini ifade etmektedir (Tsay, 2002:62):

$$\Delta_4(\Delta x_t) = (1 - B^4)\Delta x_t = \Delta x_t - \Delta x_{t-4} = x_t - x_{t-1} - x_{t-4} + x_{t-5} \quad (3.53)$$

$\Delta_4 = (1 - B^4)$ işlemi mevsimsel fark olarak adlandırılır, genel olarak s dönemselik ile mevsimsel zaman serisi y_t için mevsimsel fark Eş. 3.54 ile ifade edilmektedir (Tsay, 2002:62).

$$\Delta_s y_t = y_t - y_{t-s} = (1 - B^s)y_t \quad (3.54)$$

Yaygın olarak kullanılan fark işlemi $\Delta y_t = y_t - y_{t-1} = (1 - B)y_t$ serinin normal farkını almak olarak ifade edilir. Fark alınırken ard arda olan değerler üzerinden işlem yapılır. Şekil 3.5'in b'si mevsimsel farkı alınmış seriyi ifade ederken d'si hem normal farkı hem de mevsimsel farkı alınmış serinin ($\Delta_4 \Delta x_t$) otokorelasyon fonksiyonunu göstermektedir (Tsay, 2002:63).

4. LİMANLARDA ÖNGÖRÜ VE YAPILAN ÇALIŞMALAR

Limanlar için yapılan öngörünün öneminden ve daha önce yapılan çalışmalardan bahsedilmeden önce öncelikle öngörü ile ilgili kısa bilgi verilecek sonrasında konuya devam edilecektir.

4.1. Öngörü

Gelecekteki bazı olay ve olayların tahminlenmesi olarak tanımlanan *öngörü*, ticaret, endüstri, ekonomi, politika ve finans gibi birçok alan için önem arz etmekte bu alanlarda çözülmesi gereken problem olarak karşılaşılmaktadır (Montgomery, Jennings ve Kulahci, 2008:1).

4.1.1. Öngörü horizonu ve öngörü sıklığı

Öngörüleme yaparken dikkat edilmesi gereken iki nokta *öngörü horizonu* ve *öngörü sıklığı*dır; öngörü horizonu öngörülerin yapılması gerektiği gelecek dönemlerin sayısı olarak ifade edilirken, öngörü horizonunun belirlenmesi öngörünün yapılmasının planlandığı zaman dilimine göre değişirken öngörünün yapılacağı alan da horizonun belirlenmesinde önemlidir (Montgomery ve diğerleri, 2008:5).

Analiz ve öngörülerde trend ve döngü kavramları önemli rol oynarken, öngörü horizonları dört farklı uzunlukta belirlenebilmektedir (Carnot, Koen ve Tissot, 2005:4):

- Öngörü horizonu iki çeyreği başka bir deyişle altı ayı kapsıyorsa çok kısa dönemli öngörü,
- Altı aydan iki yıla kadar uzanan bir zaman dilimini kapsıyorsa kısa dönemli öngörü,
- İki yıldan beş yıla kadar uzanan bir zaman dilimini kapsıyorsa (bu zaman dilimi bazen on yıl olarak da kabul edilebilir) orta vadeli öngörü
- Beş ya da on yıldan daha uzun bir zaman dilimini kapsıyorsa uzun vadeli öngörü olarak ifade edilmektedir.

Stratejik planlama gibi konularda uzun vadeli öngörüler önem arz ederken operasyon yönetimi, projelerin bütçelenmesi gibi faaliyetler için kısa ve orta vadeli öngörüler önem arz etmektedir. Ayrıca kısa ve orta vadeli öngörülerde istatistiksel modeller oldukça kullanışlıdır. Kısa ve orta vadeli öngörümlemelerde geçmiş verilerde yeralan örüntüler tanımlanır, modellenir ve bu modellerden sonuç çıkarılır. Geçmiş verilerin kullanılmasının sebebini ise geçmiş verilerin genellikle eylemsizlik göstermesi ve çarpıcı bir şekilde hızlı değişmemesi oluşturmaktadır (Montgomery ve diğerleri, 2008:2).

Bir örnek üzerinden öngörü horizonunu ifade etmek gerekirse; x_1, x_2, \dots, x_N gözlemlerini içeren bir zaman serisi ele alınmış olsun (bu zaman serisi bir limana ait on yılı kapsayan aylık gözlem olarak da düşünülebilir) ve x_{N+h} gibi bir gelecek değeri ile ilgi öngörü yapılmak istensin, burada tamsayı olan h öngörü horizonunu (tahmin edilmesi istenen kısım dokuz ay olsun) ifade etmektedir ve N anında (bu değer de onun yılın on ikinci ayını kapsayan son değer yani 120. değer) h adım uzaklık için yapılan x_{N+h} (x_{120+9}) öngörüsü, $\hat{x}_N(h)$ ($\hat{x}_{120}(9)$) ile gösterilmektedir (Chatfield, 2000).

Yeni öngörülerin hazırlanma sıklığı, *öngörü sıklığı* olarak ifade edilmektedir, Her ay daha önce yapılan öngörüler yenileniyor ve öngörüler güncelleniyor ise bu durumda öngörü sıklığı bir ay olmaktadır (Montgomery ve diğerleri, 2008:5).

4.1.2. Nokta öngörü ve öngörü aralığı

Öngörü denildiğinde akla genellikle gerçekleşecek değeri en iyi tahmin ettiği düşünülen tek bir değer gelmektedir. Bu değer istatistikçiler tarafından nokta tahmin ya da nokta öngörü olarak ifade edilmektedir, ancak bu tek öngörü biçimi değildir. Nokta öngörüler ile gelecekte gerçekleşecek öngörü değerini öngörebilmek mümkün değildir. Bu nedenle öngörü yapılırken, öngörü hatasının ne kadar büyük olabileceği ihtimalinde (öngörü aralığı) dikkate alınması bu ihtimal (öngörü aralığı) ile birlikte öngörü yapılması var olan bir uygulamadır. Kara vermede nokta tahminden daha çok faydalı olan öngörü aralığı gelecek gözlemler için değer aralığından meydana gelmektedir (Montgomery ve diğerleri, 2008:4-5).

4.1.3. Kayan öngörü

Kayan öngörü sisteminde öngörü yapılırken sistem her öngörü öncesinde kendini günceller ve yapılan güncelleme üzerinden yeni öngörü yapılır. Öngörü horizonunun her zaman T dönem uzunluğunda olduğu ve öngörünün her zaman periyodu için gözden geçirilip düzeltildiği bir durumda kayan öngörü yaklaşımı kullanılmış olur, T dönem uzunluğu üzerinden örneğe devam edilmek istenirse; bu örnekte sistem $T - 1$ için güncelleme yaparak T dönemi için öngöründe bulunur. (Montgomery ve diğerleri, 2008:5).

4.1.4. Koşullu ve koşulsuz öngörü

Öngörüler koşullu ya da koşulsuz olabilirler, koşulsuz durumda gelecekteki durumla ilgili varsayımda bulunurken düz bir varsayımda bulunulurken koşullu durumda bu varsayımın gerçekleşmesi bir başka olayın gerçekleşme ihtimaline bağlanır, birçok öngörü koşul temelinde yapılmaktadır. Reel gayri safi yurtiçi hâsıla gelecek yıl %4 büyüyecek cümlesi koşulsuz bir durumu ifade ederken, ABD'nin merkez bankası sıkı politika uygulamaz ise reel gayri safi yurtiçi hâsıla gelecek yıl %4 büyüyecek cümlesi koşullu durumu ifade etmektedir. İkinci cümlede %4 büyümenin koşulu ABD'nin Merkez Bankasının tutumuna bağlıdır. (Evans, 2003:19).

4.1.5. Öngörü teknikleri

Nitel ve nicel olmak üzere yaygın olarak kullanılan iki öngörü tekniği türü bulunmaktadır. *Nitel öngörü*, özellikle yeni bir ürününü piyasaya sürmek isteyen firma örneğinde olduğu gibi geçmiş verilerin olmadığı ya da az olduğu durumlarda kullanılmaktadır. Nitel öngörülerde öznellik söz konusudur, işin uzmanından öngörü ile ilgili görüş alınır. Yeni bir ürünü piyasaya sürmek isteyen firmayı ele aldığımızda elinde veri olmayan firma satış ve pazarlama personelinden uzman görüşü alarak konu ile ilgili öngörü yapar (Montgomery ve diğerleri, 2008:3).

Nitel öngörü tekniğinin aksine *nicel öngörü* tekniklerinde geçmiş verilerden ve öngörü modellerinden faydalanılmaktadır. Öngörü modeli verilerde yer alan örüntüleri özetlerken değişkenin önceki ve şimdiki değerleri arasında ilişkiyi istatistiksel olarak açıklayarak veri setinin geçmişteki ve şimdiki davranışlarını geleceğe aktarır (Montgomery ve diğerleri, 2008:3). Nicel öngörü modelleri Zaman Serileri ve Sebep-Sonuç olmak üzere ikiye ayrılmaktadır (Chambers ve diğerleri, 1971; Abraham and Ledolter, 1983; Twirly ve Batista, 2016).

Bağımlı değişkenin en az bir bağımsız değişken ile açıklayıcı ilişki sergilediğini varsayan *Sebep-Sonuç Modellerinin* amacı bağımlı ve bağımsız değişkenlerin ilişkilerinin formunu belirleyerek bağımlı değişkenin öngörüsünü yapmaktır. Bağımsız tek değişkenin bulunduğu durumda regresyon modeli basit regresyon modeli olarak ifade edilmektedir ve bu modelinde regresyon parametreleri ve bağımlı değişkenler doğrusaldır(Gosasang, Chandraprakakul ve Kiattisin, 2011). Çalışmalarda sıkça karşılaşılan tekniklerden biri ve ana özelliği öğrenme yeteneği ve öğrendikleri ile performans geliştirmek olan sinir ağı modeli sebep sonuç modelinin bir tekniğini ifade etmektedir (Haykin, 1999 ve Skapura, 1996; Gosasang ve diğerleri, 2011).

Otoregresif Hareketli Ortalamalar Modeli, Üssel Düzleştirme, Extrapolasyon, Doğrusal Tahminleme, Trend Tahminleme, Büyüme Eğrisi ve Box-Jenkins gibi modelleri içine alan *Zaman Serileri Modellerinde* değişkenler eşit aralıklarla ayrılmış sıralı zaman dilimlerinden oluşmaktadır, öngörü değerleri geçmiş değerlere bağlıdır (Gosasang ve diğerleri, 2011).

Öngörü metodları olasılık modeline bağlı olmayan bir algoritma kuralı olabilirken, bir veri seti için özel model tanımlayarak bu modelde en iyi öngörü koşulunu bulmaktan da meydana geliyor olabilmektedir. Bu metodlar şimdiki ve geçmiş değerlerden öngörü değerleri hesaplamaktadırlar (Chatfield, 2000).

Zaman Serilerinde Öngörü Metotları

Genel anlamda zaman serilerinde öngörü metodu:

- Subjektif temele dayanarak yapılan *objektif öngörü*,
- Veri setine tek boyutlu modelin uyarlanması ve zaman serisi örüntüsünün extrapolasyonunu temel alan *tek değişkenli metotlar* ve,
- En az iki değişkenin eş zamanlı gözlemlerine ve çok değişkenli zaman serisi modellerine dayanan *çok değişkenli metotlar*

olmak üzere üç sınıfa ayrılmaktadır (Palit ve Popovic, 2005:50).

Öngörülenecek değişkenin tahminleyici ya da açıklayıcı değişken olan en az iki zaman serisi ile öngörüsünün yapılması durumuyla çok değişkenli metotlarda karşılaşılmaktadır. Bu metotta değişkenler karşılıklı birbirlerine bağımlı ise bu gibi durumlarda birden çok denklemlili çok değişkenli modeller kullanılabilir (Chatfield, 2000).

Öngörü metotları tek değişkenli ya da çok değişkenli metottan sonra öngörülen değerler üzerinden düzeltmeyi, ayarlamayı sağlayacak objektif öngörünün eklenmesi ile yukarıdaki metotların birleşimden oluşan metotları içerebilirler. Metotların birleşimi ile oluşan öngörü metodu istatistiksel verilerle oluşturulan öngörülere bu alanda uzman kişilerin bilgi birikimi ve katkılarının dahil olmasını sağlar (Palit ve Popovic, 2005:50).

Öngörü Sürecindeki Faaliyetler

Süreç en az bir girdiyi en az bir çıktıya dönüştüren birbirleri ile ilişkili faaliyetler serisi olarak adlandırılmaktadır. Tüm çalışma süreçlerinde olduğu gibi öngörümleme sürecinde de faaliyetler belli bir sıraya göre yapılmaktadır. Öngörümleme sürecinde yer alan faaliyetleri Montgomery ve diğerleri (2018) aşağıdaki gibi sıralamaktadır;

1. *Problemin Tanımlanması*: Öngörünün, öngörü talebinde bulunan tarafın beklentilerini nasıl karşılayabileceği ile ilgili bir kanı, fikir ortaya konulması problemin tanımlanma faaliyetini içerir.
2. *Veri Toplanması*: Öngörünün yapılabilmesi için problemin çözümünde yer alacak değişkenler ile ilgili kayıtlara ulaşılması gerekmektedir veri toplama faaliyeti bu kayıtlara ulaşılmasıdır.
3. *Veri Analizi*: Kullanılacak öngörü modeli için en önemli ilk adım olan veri analizi faaliyetinde veri setinin grafiği incelenerek veri setinde trend, mevsimsellik, kırılmalar, sapan değerler gözlemlenir.
4. *Model'in Seçimi ve Kurulması*: Bu aşamada modellerin seçimi yapılarak seçilen modellerin parametrelerini belirlemek amacıyla modellerin tahminlemesi yapılır.
5. *Model Geçerleme*: Modellerin parametrelerinin belirlenmesinin ardından modellerin performanslarının izlenerek öngörü modellerinin değerlendirilmesi gerekmektedir bu aşamada modellerin performansları izlenerek modeller ile ilgili değerlendirme yapılmaktadır.
6. *Öngörü Modelinin Yerleştirilmesi*: Modelin performansının gözlenmesinden sonra model ile öngörünün yapılması öngörü talebinde bulunanlar için öngörülerin elde edilmesi öngörü modelinin yerleştirilmesi faaliyetinde yapılmaktadır.
7. *Öngörüsü Yapılan Modelin Performansının İzlenmesi*: Öngörüler yapıldıktan sonra elde edilen sonuçların gerçekleşen değerle ne kadar uyum içinde olduğu model geçerlemede modelin gösterdiği performansın hala geçerli olup olmadığı öngörü modelinin performansının izlenmesi aşamasında yapılmaktadır.

4.2. Konteyner Taşımacılığı, Ekonomi, Limanlar ve Öngörü

Taşıma ağlarının kilit noktası olarak limanlar navlun hareketlerinde taşıma modları arasında merkez gibi hareket ederken (Patil ve Sahu, 2016) özellikle son yıllarda TEU bazında ölçülen ve dünya ticaretinin artmasının temellerini atan konteyner taşımacılığı ile de limanlar lojistik zincirlerin önemli bağlantı noktalarından biri haline gelmiştir (Schulze ve Prinz, 2009, Twrdy ve Batista, 2016).

Konteyner operasyonlarının yapıldığı konteyner limanları konteyner taşımacılığının artmasından önemli derece etkilenmektedir. Bu etki limanlarda hem operasyonel olarak hem de limanların gelecekte ihtiyaç duydukları alt yapı gereksinimleri olarak ortaya çıkmaktadır (Mak ve Yang, 2007).

Konteyner taşımacılığına neredeyse tüm mal grupları için tercih edilebilen bir taşıma formu olarak rastlamak mümkün iken (Mak ve Yang, 2007) bu mal gruplarının akışı malların çıkış ve varış noktalarında meydana gelen ekonomik faaliyetlerin doğrudan sonucudur (Amoako, 2002). Mal gruplarından beslenen çıkış ve varış noktalarının beslendiği alan limanın hinterlandı olarak ifade edilirken, hinterlandda gözlemlenen ekonomik faaliyetler, ekonomideki gelişmeler konteyner terminallerinin artan miktarda kullanılmasında etkilidir. Günümüzde konteyner ile taşınan malların artmasından dolayı, konteyner terminalleri büyük ölçüde kullanılmaktadır (Gosasang, Yip ve Chandraprakaikul, 2018).

4.2.1. Konteynere olan talep hakkındaki bilginin önemi

Konteynere olan talep hakkındaki bilgi limanlar için oldukça önemli bir yer tutmaktadır. Limanlar inşa maliyetleri oldukça yüksek olduğu için ve sorun olması durumunda ya da limana talep olmaması durumunda limanı başka bir limana dönüştürmek oldukça zor olduğundan dolayı liman maliyetleri batık maliyet olarak nitelendirilmekte ve geri dönüşü çok zor olmakta hatta geri dönüştürülemez olabilmektedir. Maliyetlerin yanında bir başka problem de liman inşalarının uzun sürmesi ve bu süre boyunca limanlara ulaşımın olmaması ya da sınırlı olmasıdır (Peng ve Chu, 2009, Chen ve Chen, 2010). Bahsedilen sorunlardan dolayı limanların planlama ve geliştirilmelerinde, projelerin değerlendirilmesinde güvenilir, doğru sistematik analiz ve yük öngörüsü oldukça önemlidir (Syafi'i, 2006, Patil ve Sahu, 2016).

Yapılan doğru ve güvenilir yük öngörülleri ile gelecek talebi en iyi şekilde karşılamak için, planlayıcıların limanın içindeki ve dışındaki var olan altyapıyı değerlendirmeleri ve değerlendirme sonucunda gerekli adımları atmaları limanları geri döndürülemez zaman ve yatırım maliyetlerinden kurtama noktasında önem teşkil etmektedir (Patil ve Sahu, 2016). Bu yüzden liman otorite ya da karar vericilerin ticaret hacmi ya da yük trafiğinin öngörüsü ile ilgili güvenli bir yol bulmaları şarttır (Gökkuş, Yıldırım ve Aydın, 2017).

4.2.2. Ülke ve liman yönetimi boyutunda konteyner öngörüsünün önemi

Konteyner hacminin öngörümü mikro düzey olarak ifade edilen limanları yöneten şirketler bazında ve makro düzey olarak ifade edilen ulaştırma bakanlığı bazında ayrı ayrı öneme sahiptir. Mikro düzeyde liman şirketleri olarak düşünüldüğünde şirketlerin operasyon, pazarlama, finans, muhasebe gibi fonksiyonlarında gelecekle ilgili genişleme, yenileme yatırımlarında konteyner hacmi öngörülleri ile en önemli girdi olarak karşılaşılmaktadır. Makro düzeyde yani ulaştırma bakanlığı seviyesinde konteyner hacmi öngörüsü bölgesel ve ulusal taşıma planları için temel olur (Chou ve diğerleri, 2008).

Konteyner terminallerinin yönetiminde giderek artan oranda önemli bir rol oynayan konteyner çıktısının öngörüsü (Mak ve Yang, 2007) kısa ve orta vadeli karar olarak ifade edilen taktiksel ve operasyonel kararlarda da liman yöneticilerine katkı sağlamaktadır. Taktiksel ve operasyonel kararlar limanda operasyon planlama kararları, liman ekipmanların dağıtımını programlanması gibi kararları kapsamaktadır. Bu durum konteyner hacminin tahmininin liman yöneticilerine sadece stratejik karar alma noktasında yol göstermediğinin ifadesidir (Xie, Zhang ve Wang, 2017).

Konteyner hacminin öngörüsünü sadece liman otoritesi ve ulaştırma bakanlığı yani devlet kurumu boyutunda değerlendirmek çok doğru değildir. Çünkü bu durumdan özellikle yük hacmindeki değişimlerden liman paydaşları olan gemi sahipleri, gemi operatörleri, kiracılar ve ilişkili taraflar da etkilenir. Bu durum limanlara operasyonel verimlilik olarak yansırken liman paydaşlarına sermaye karlılığı olarak yansımaktadır. Bu yüzden yük çıktısı öngörüsünün makro ve mikro düzeyde araştırmaların merkezinde olması şaşılacak bir durum değildir (Patil ve Sahu, 2017).

4.3. Limanlarla İlgili Yük Tahminlerinde Kullanılan Yöntemler

Önceki başlıklarda sarf edilen cümlelerden sonra bu konunun önemi daha çok anlaşılmaktadır ve konunun öneminden dolayı doğru güvenilir yük hacmi öngörüsünün aslında önemli bir problem olduğu ortaya koyulmaktadır. Konuyla ilgili olan taraflar doğru öngörü için ciddi çabalar sarf etmektedir (Xiao, Wang, Xiao, Xia ve Hu, 2017).

Limanların çıktılarını ifade eden veri setlerinin yapıları birbirlerinden farklı olmakla birlikte uygulamda limanların farklı mevsimsel karakteristik özellikleri bulunmaktadır (Chou et al., 2003; Peng, 2006; Xie ve diğerleri, 2017). En küçük ayrılabilen zaman dilimi yıllık ve aylık olarak ayrılan veri setlerinin uzunlukları 10 ile 30 yıl arasında değişmektedir (Xie ve diğerleri, 2017). Kapasite dağılımı yapan firmalar için en büyük avantajlardan biri çeyreklik yani üçer aylık verilerin kullanılmasının sonucu olarak kontrol edilebilen zaman periyodu için mevsimsel etkilerin yakalanabilmesidir (Schulze ve Prinz, 2009). Limanların veri seti ile ilgili dikkat çekilmesi gereken bir nokta liman çıktılarının bazı olaylardan etkilenmesi ve bu etki sonucu kırılmaların meydana gelmesidir. Kırılmaya sebep olan örneklere finansal krizler, büyük ölçekli yük transferleri, liman işçilerinin greve gitmesi gibi durumlar verilebilmektedir (Xie ve diğerleri, 2017).

Limanlardaki yük akışı ile ilgili öngörülerde bulunulurken nitel ve nicel olmak üzere iki metot kullanılmaktadır. Nicel metotlar istatistiki verilerden kaynaklı olarak uygulanmasının yanında nitel metotlara göre daha hassa ve objektif oldukları için nicel metotlara göre giderek daha çok ilgi görmektedirler (Xiao ve diğerleri, 2017). Nicel metotlarda tarihsel verilerden yararlanılarak matematiksel istatistiksel metotlar uygulanarak öngörü yapılırken, Delphi gibi metotları içeren nitel metotlarda, tarih verilerin varlığından yararlanmanın yanında konu ile ilgili kişilerin bilgi tecrübe ve analizlerinden faydalanılmaktadır. Nitel metotlar nicel metotlara göre subjektif ve yüzeyseldir (Zhang, Huang ve Zhao, 2013).

4.4. Limanlarla İlgili Yük Tahminlerinde Yapılan Çalışmalar

Limanlarda öngörü ile ilgili ilk çalışmalara 1980'li yıllardan itibaren rastlanmaktadır. Yıllara göre sıralanan çalışmaların yer aldığı Çizelge 4.1 çalışmalarda kullanılan yöntemleri ve çalışmaların uygulandığı limanları göstermektedir. Birçok çalışmada en doğru tahmini elde edebilmek için birçok yöntem uygulanmış ve kıyaslama kıstaslarına göre en iyi olan yöntem belirlenmiş ve ileriye yönelik tahminler bu yöntem üzerinden yapılmıştır. Çoğu çalışma tek bir yöntem içerse de bazı çalışmalar birkaç yöntemin birleşmesiyle oluşan karma metottan oluşmaktadır. Mo ve diğerleri (2018), öngörü için sadece tek bir yöntemin kullanıldığı modelleri zaman serisi modelleri, nedensellik analizi modelleri ve doğrusal olmayan dinamik öngörü modelleri olmak üzere üç sınıfa ayırmaktadır. Çalışmada bu sınıflamaya uyularak yapılan çalışmalar incelenmiştir.

4.4.1. Zaman serisi modellerinin kullanıldığı çalışmalar

Zaman serisi modelleri üstel düzleştirme (ES), Otoregresif Tümlleşik Hareketli Ortalama (ARIMA), Mevsimsel Otoregresif Tümlleşik Hareketli Ortalama (SARIMA), Vektör Otoregresyon (VAR) , Klasik Ayrıştırma Modeli ve Grey Modeli içermektedir (Mo ve diğerleri, 2018). Klein ve Verbeke'nin (1987) Antwerp limanında aylık verilerle tek değişkenli zaman serisi kullanarak yaptıkları Antwerp limanındaki çalışmalarında öncelikle Box-Jenkins analizi kullanmışlar sonrasında transfer işlevi modelini kurup ilerlemişlerdir. Gooijer ve Klein (1989) tarafından Antwerp limanındaki çelik trafiği akışı için yapılan bir başka çalışmada çok değişkenli zaman serisi modeli kullanılmış ve bu model çelik trafiği akışı için bu modelin kullanışlı bir araç olduğunu göstermiştir. Ayrıca bu modelin liman planlayıcılarının kısa dönemli tahminleri için çok yardımcı olacağı vurgulanmıştır.

Özellikle ARIMA ve mevsimsellik eklenerek oluşturulan SARIMA modellerine çalışmalarda sıkça rastlanmaktadır. Bu çalışmalardan biri de Klein'nın (1996) Antwerp limanında yaptığı çalışmadır. Klein çalışmasında ARIMA, SARIMA ve Dönüşüm ve müdahalenin olmadığı Mevsimsel Otoregresif Tümlleşik Hareketli Ortalama (SARIMANT) modellerinin karşılaştırmasını yapmıştır. Çalışmada asıl amaç öngörüler yapılırken kullanılan dönüşüm ve müdahalenin yararlılığını ortaya koymaktır. Çalışmanın sonucu olarak uygun dönüşüm ve müdahalenin olduğu durumlarda öngörü performansında dikkate değer artışın olduğu ortaya konmuştur.

Çizelge 4.1. Öngörü ile ilgili yapılan çalışmalarda uygulanan yöntemler ve çalışmaların uygulandığı limanlar

Yıl	Yazar(lar)	Yöntem	Uygulama Yer(ler)i
1987	Dagenais M. G. ve Martin F.	Yazarların öngörü yöntemi uluslararası ticarete genel eğilimler, emtia etkisi, ticari ortak etkisi, koyteynerizasyon etkisi ve hinterlant etkisi gibi farklı etkileri göz önüne almaktadır.	Montreal Limanı
1987	Klein, A. ve Verbeke, A.	Transfer işlevi ile Box-Jenkins Metodu	Antwerp Limanı
1989	Gooijer de, J. G. ve Klein, A.	Çok Değişkenli Zaman Serisi Modeli	Antwerp Limanı
1996	Klein, A	Otoregresif Tümlşik Hareketli Ortalama (ARIMA), Mevsimsel Otoregresif Tümlşik Hareketli Ortalama (SARIMA), Dönüşüm ve Müdahalenin Olmadığı Mevsimsel Otoregresif Tümlşik Hareketli Ortalama (SARIMANT) (Karşılaştırma)	Antwerp Limanı
2001	Fung, K. F.	Yapısal Vektör Hata Düzeltme Modeli (VECM)	Hong Kong Limanı
2001	Veenstra, A. W., ve Haralambides, H. E.	Vektör Otoregresyon (VAR)	Ana Ticaret Rotaları (Ham petrol, demir cevheri, tahıl ve kömürün ana ticaret rotalarındaki akışının tahmin edilmesi)
2002	Amoako, J.	Dinamik Ekonometrik Model ve Otoregresif Tümlşik Hareketli Ortalama (ARIMA)	Avustralya'daki tüm limanlar
2002	Fung, M. K.	Yapısal Hata Düzeltme Modeli (ECM)	Hong Kong Konteyner Terminaleri
2003	Seabrooke, W., Hui, E. C., Lam, W. H., ve Wong, G. K.	Regresyon Analizi	Hong Kong Limanı

Çizelge 4.1. (Devam)Öngörü ile ilgili yapılan çalışmalarda uygulanan yöntemler ve çalışmaların uygulandığı limanlar

Yıl	Yazar(lar)	Yöntem	Uygulama Yer(ler)i
2004	Hui, E. C., Seabrooke, W., ve Wong, G. K.	Eş bütünlük Hata Düzeltme Modeli	Hong Kong
2004	Lam, W. H. K., Asce, M., Ng, P. L. P., Seabrooke, W., ve Hui, E. C. M.	Sinir Ağları (NN), Regresyon Analizi (Karşılaştırma)	Hong Kong
2005	Guo, Z., Song, X., ve Ye, J.	Doğrusal Zaman Serisi Modeli, Lojistik Fonksiyon, Orijinal Grey Modeli (GM(1,1)), Düzeltilmiş Kalıntılı Grey Verhulst Modeli (GVM), Fourier ile düzeltilmiş kalıntılı Grey Verhulst Modeli (Karşılaştırma)	Çin Limanı
2006	Syafi'i, S	Vektör Hata Düzeltme Modeli (VECM)	Endonezya
2007	Mak, K. L., ve Yang, D. H.	Yaklaşık En Küçük Kareler Destek Vektör Makinası (ALSSVM), Destek Vektör Makinası (SVM), En Küçük Kareler Destek Vektör Makinası (LSSVM), Radyal Bazlı Fonksiyon Sinir Ağı (RBF-NN) (Karşılaştırma)	Hong Kong
2007	Liu, C. J., & Zhang, Q. N.	Geri Yayınımı (BP) Sinir Ağı	Belirtilmemiş
2007	Liu, Z., L. Ji, Y. Ye, and Z. Geng.	Radyal Bazlı Fonksiyon Sinir Ağı (RBF-NN)	Shanghai Limanı
2008	Chou, C. C., Chu, C. W., & Liang, G. S.	Değiştirilmiş Regresyon Modeli	Tayvan (Tayvan'ın ithal konteynerlerini dikkate almaktadır)
2008	Li, J., Chen, Y., ve Cui, X.	Doğrusal Üstel Düzleştirme Modeli, Basit Hareketli Ortalama metodu ve Elman Ağı (Karma Model)	Çin Limanları

Çizelge 4.1. (Devam)Öngörü ile ilgili yapılan çalışmalarda uygulanan yöntemler ve çalışmaların uygulandığı limanlar

Yıl	Yazar(lar)	Yöntem	Uygulama Yer(ler)i
2009	Peng, W. Y., ve Chu, C. W.	Klasik Ayırıştırma Modeli, Trigonometrik Regresyon Modeli, Mevsimsel Kukla Değişkenli Regresyon Modeli, Grey Model, Karma Grey Model, ve Mevsimsel Otoregresif Tümlleşik Hareketli Ortalama (SARIMA) (Karşılaştırma)	Keelung, Taichung ve Kaohsiung Limanları
2009	Schulze, P. M., ve Prinz, A.	Mevsimsel Otoregresif Tümlleşik Hareketli Ortalama (SARIMA) ve Holt-Winters Üstel Düzleştirme Modeli (Karşılaştırma)	Almanyadaki Limanlar
2010	Chen, S. H., ve Chen, J. N.	Genetik Programlama, X-11 ve Mevsimsel Otoregresif Tümlleşik Hareketli Ortalama Modeli (SARIMA) (Karşılaştırma)	Kaohsiung Limanı Keelung Limanı, ve Taichung Limanı
2011	Diaz, R., Talley, W., ve Tulpule, M.	The Tioga Grup Metodu, Birleşmiş Milletler Metodu ve Winters Metodu (Karşılaştırma)	Amerika Birleşik Devletleri Konteyner Limanları
2011	Shin, C. H., & Jeong, S. H.	Otoregresif Tümlleşik Hareketli Ortalama (ARIMA), Yapay Sinir Ağı (ANN), ve ARIMA ve ANN 'nin Birleştirilmesi/Karma Model. (Üçünün karşılaştırılması)	Belirtilmemiş
2011	Gosasang, V., Chandraprakaikul, W., ve Kiattisin, S.	Sinir Ağları-Çok Katmanlı Algılayıcı (MLP) and Doğrusal Regresyon (Karşılaştırma)	Bangkok Limanı
2011	Goulielmos, A.M. ve Kaselimi, E.	Yeniden Boyutlandırılmış Aralık Analizi (Rescaled Range Analysis)	Pire Limanı
2012	Van Dorsser, J. C. M., Wolters, M., ve Van Wee, G. P.	Sistem Dinamikleri Modeli, Nitel Öngörü, Sebep-Sonuç İlişkisi (Sıralı)	Le Havre – Hamburg Bölgesi
2013	Ping, F. F., ve Fei, F. X.	Geri Yayınımlı (BP) Sinir Ağı ve Genetik Algoritma (GA-BP)(Karma Model)	Guangdong

Çizelge 4.1. (Devam)Öngörü ile ilgili yapılan çalışmalarda uygulanan yöntemler ve çalışmaların uygulandığı limanlar

Yıl	Yazar(lar)	Yöntem	Uygulama Yer(ler)i
2013	Chen, C. P., Liu, Q. J., & Zheng, P.	Grey Markov Modeli	Fujian Limanı
2013	Tian, X., Liu, L., Lai, K. K., ve Wang, S.	Mevsimsel Otoregresif Tümlşik Hareketli Ortalama Modeli (SARIMA), Vektör Otoregresyon (VAR) ve Radyal Bazlı Fonksiyon Sinir Ağı (RBF-NN) (Karma Model-TEI@I)	Hong Kong Limanı
2013	Tür, R., Küçükosmanoğlu, A., & Küçükosmanoğlu, Ö.	Doğrusal Regresyon Modeli ve Bulanık Sinir Ağı (Karşılaştırma)	Antalya Limanı
2013	Twrdy, E., ve Batista, M.	Markov Zinciri Modeli	Koper, Trieste, Venedik, Ravenna ve Rijeka Limanları
2013	Zhang, C., Huang, L., ve Zhao, Z.	Grey Öngörü Modeli ve Lojistik Büyüme Eğrisi (Karma Model)	Çin
2013	Xie, G., Wang, S., Zhao, Y., & Lai, K. K.	Mevsimsel Otoregresif Tümlşik Hareketli Ortalama Modeli-En Küçük Kareler Destek Vektör Regresyonu (SARIMA-LSSVR), Mevsimsel Ayrıştırma Modeli/X-12-ARIMA - En Küçük Kareler Destek Vektör Regresyonu (SD-LSSVR), Klasik Ayrıştırma Modeli- En Küçük Kareler Destek Vektör Regresyonu (CD-LSSVR) (Karşılaştırma)	Shanghai Limanı ve Shenzhen Limanı
2014	Twrdy, E., & Batista, M.	Markov Zinciri Modeli	Koper, Trieste, Venice, Ravenna ve Rijeka Limanları
2014	Dragan, D., Kramberger, T., & Intihar, M.	Holt-Winters Üstel Düzleştirme Modeli, Klasik Ayrıştırma Metodu ve Otoregresif Tümlşik Hareketli Ortalama Modeli (ARIMA)	Kuzey Adriyatik Limanları: Koper (Slovenya), Venedik, Trieste ve Ravenna (İtalya)

Çizelge 4.1. (Devam)Öngörü ile ilgili yapılan çalışmalarda uygulanan yöntemler ve çalışmaların uygulandığı limanlar

Yıl	Yazar(lar)	Yöntem	Uygulama Yer(ler)i
2014	Min, K. C., & Ha, H. K.	Mevsimsel Otoregresif Tümlşik Hareketli Ortalama Modeli (SARIMA), Otoregresif Tümlşik Hareketli Ortalama Modeli (ARIMA) (Karşılaştırma)	Kore Limanları
2014	Shu, M. H., Nguyen, T. L., HSU, B., Lu, C., & Huang, J. C.	Otoregresif Tümlşik Hareketli Ortalama Modeli (ARIMA), Grey Model ve bu iki modelin kalıntılarında Fourier ile deęişiklik uygulanmasıyla oluşan modeller (Karşılaştırma)	Hong Kong Limanı ve Kaohsiung Limanı
2015	Akar, O., & Esmer, S.	Çoklu Regresyon Analizi	Türkiye'deki Konteyner Terminalleri
2015	Geng, J., Li, M. W., Hong, W. C., Zheng, T. J., Niu, X. Y., & Ma, S. L.	Parametre Projeksiyon İzleme Regresyon Modeli (Parameter Projection Pursuit Regression (PPPR))	Shanghai Limanı
2015	Huang, A., Lai, K., Li, Y., & Wang, S.	Projeksiyon İzleme Regresyonu (Projection Pursuit Regression (PPR)) ve Genetik Programlama (GP) Algoritması PPR-GP(Karma Model), Geri Yayımlı Yapay Sinir Ağları (BP-ANN), Mevsimsel Otoregresif Tümlşik Hareketli Ortalama Modeli (SARIMA), Standart Projeksiyon İzleme Regresyonu (Projection Pursuit Regression (PPR))	Qingdao Limanı
2016	Mohamed Ismael, H., & Vandyck, G. K.	Üstel Düzleştirme Modeli, Grey Model, Doğrusal Regresyon Modeli ve Bu modellerin kombinasyonları (Karşılaştırma)	Doraleh Konteyner Limanı
2016	Patil, G. R., & Sahu, P. K.	Tek Deęişkenli ve Çok Deęişkenli Toplamsal Regresyon Modeli ve Zaman Serisi Modeli (Karşılaştırma)	Mumbai Limanı
2016	Chen, Z., Chen, Y., & Li, T.	Pearl Eğrisi Modeli, GM(1,1) ve Karesel Üstel Düzleştirme Modeli (Karma Model)	Dalian

Çizelge 4.1. (Devam)Öngörü ile ilgili yapılan çalışmalarda uygulanan yöntemler ve çalışmaların uygulandığı limanlar

Yıl	Yazar(lar)	Yöntem	Uygulama Yer(ler)i
2016	Twrdy, E., & Batista, M.	Markov Zinciri Yıllık Büyüme Oranı Modeli, Zaman Serileri Trend Modeli, Dönemsellik Terimli Zaman Serileri Trend Modeli (Karşılaştırma)	Koper, Trieste, Venedik, Ravenna, and Rijeka
2016	Sengönül, G., & Esmer, S.	Regresyon Modeli	Karadeniz'de Konteyner Elleçleyen Limanlar
2017	Gökkuş, Ü., Yıldırım, M. S., & Aydın, M. M.	Yapay Sinir Ağları/Yapay Arı Kolonisi (ANN-ABC), Yapay Sinir Ağları/ Levenberg-Marquardt Algoritmaları (ANN-LM), Çoklu Doğrusal Olmayan Regresyon Modeli/Genetik Algoritma (MNR-GA), En Küçük Kareler Destek Vektör Makinası (LSSVM) (Karşılaştırma)	İstanbul, İzmir, ve Mersin Limanları
2017	Xiao, Y., Wang, S., Xiao, M., Xiao, J., & Hu, Y.	Sinir Ağları ve Kesikli Dalgacık Tekniği (TEI@I metodolojisi temelinde Karma Öngörü Modeli)	Tianjin Limanı
2017	Pang, G., & Gebka, B.	Mevsimsel Ototregresif Tümlşik Hareketli Ortalama Modeli (SARIMA), Toplamsal Mevsimsel Holt-Winters (ASHW), Çarpımsal Mevsimsel Holt-Winters (MSHW), Vektör Hata Düzeltme Modeli (VECM) (Karşılaştırma)	Tanjung Priok Limanı
2017	Patil, G. R., & Sahu, P. K.	Dinamik Regresyon Modeli	Hindistan'daki Ana Limanlar: Kolkata, Paradip, Visakhapatnam, Chennai, Tuticorin, Cochin, New Mangalore, Mormugao, Mumbai, JNPT ve Kandla
2017	Xie, G., Zhang, N., & Wang, S.	Veri Niteliğinin Analizi (Data Characteristic Analysis / DCA) ve En Küçük Kareler Destek Vektör Regresyonu (LSSVR) (Karma Model)	Singapore Limanı ve Los Angeles Limanı

Çizelge 4.1. (Devam)Öngörü ile ilgili yapılan çalışmalarda uygulanan yöntemler ve çalışmaların uygulandığı limanlar

Yıl	Yazar(lar)	Yöntem	Uygulama Yer(ler)i
2017	Intihar, M., Kramberger, T., & Dragan, D.	Dinamik Faktör Analizi ve Dışsal Değişkenli Otopregresif Tümlşik Hareketli Ortalama Modeli (ARIMAX)	Koper Limanı
2017	Rashed, Y., Meersman, H., Van de Voorde, E., & Vanelslender, T.	(Mevsimsel) Otopregresif Tümlşik Hareketli Ortalama ((S)ARIMA), Müdahale Analizinin olduğu (Mevsimsel) Otopregresif Tümlşik Hareketli Ortalama ((S)ARIMA-Intervention Analysis), Dışsal Değişkenli Otopregresif Tümlşik Hareketli Ortalama Modeli (ARIMAX) (Karşılaştırma)	Antwerp Limanı
2017	Yıldırım, M. S., Gökkuş, Ü. ve Aydın, M. M.	Yapay Sinir Ağları - Yapay Arı Kolonisi (ANN-ABC), Geri Yayınımlı Yapay Sinir Ağları (ANN-BP) ve Çoklu Doğrusal Regresyon (MLR) (Karşılaştırma)	Belirtilmemiş
2018	Farhan, J., & Ong, G. P.	Mevsimsel Otopregresif Tümlşik Hareketli Ortalama Modeli (SARIMA)	Antwerp, Buenos Aires, Busan, Callao, Durban, Hamburg, Hong Kong, Jeddah, Kaohsiung, Long Beach, Los Angeles, Melbourne, New York, Rotterdam, San Antonio, Santos, Shanghai, Singapore, Veracruz, Yokohama
2018	Mo, L., Xie, L., Jiang, X., Teng, G., Xu, L., & Xiao, J.	Veri İşlemenin Grup Metodu (GMDH)(Karma Model): Mevsimsel Otopregresif Tümlşik Hareketli Ortalama Modeli (SARIMA), Geriye Yayılımlı (BP) Sinir Ağları, Destek Vektör Makinası (SVM), Genetik Programlama (GP)	Xiamen ve Shanghai Limanları
2018	Gosasang, V., Yip, T. L., & Chandraprakaikul, W.	Delphi Metodu, Vektör Hata Düzeltme Modeli (VECM)	Bangkok Limanı

Avustralya'nın uluslararası konteyner ticaretini, dinamik ekonometrik model (çok terimli dağıtılmış gecikme modelleri) ve ARIMA modeli olmak üzere iki farklı model kullanarak analiz eden Amoako (2002) gerçek konteyner miktarlarını kullanarak (40'lık konteyner 2 TEU olarak değil tek konteyner olarak düşünülmüştür) artan 40'lık konteynerlerin kullanımının etkisini modellemeyi amaçlamıştır. Çalışmanın sonunda Amoako ticaretin yükselebileceğini ancak artan 40'lık konteyner kullanımının kullanılan konteyner miktarını düşüreceği sonucuna ulaşmış ve bu sonucun farklı türde yatırım yapma konusunda liman planlamacıları için önemli olduğunu vurgulamıştır.

Özellikle aylık verilerdeki mevsimsel hareketleri hesaba katan Schulze ve Prinz'in (2009) çalışmalarında Alman limanlarındaki konteyner aktarmalarının öngörüsünü yapmak için Holt-Winters Üstel Düzleştirme Modeli ile SARIMA modelini karşılaştırmıştır. Karşılaştırma sonucunda SARIMA modeli Holt-Winters Üstel Düzleştirme modelinden daha iyi performans sergilemiştir. Yapılan tahminleme ise Almanya'nın konteyner elleçlemesinin özellikle Asya ve Avrupa için güçlü bir şekilde artacağını gösterirken Almanya ile Kuzey Amerika arasındaki aktarmaların 2008'in sonuna kadar oldukça küçük artışlar sergileyeceğini göstermiştir.

Holt-Winters Üstel Düzleştirme modelinin kullanıldığı Dragan, Kramberger ve Intihar'ın (2014) çalışması bu modeli ARIMA ve Klasik Ayrıştırma Metodu ile kıyaslamaktadır. Çalışmada Kuzey Adriyatik Limanları olan Slovenya'da yer alan Koper limanı ile İtalya'da yer alan Venedik, Trieste ve Ravenna limanlarının on yıllık çeyreklik verileri kullanılmıştır. Çalışmada hangi liman olduğuna bakılmaksızın yani her liman için en iyi model ARIMA modeli olmuştur.

Çalışmalarında Kore limanları için ARIMA ve SARIMA modellerini karşılaştıran Min ve Ha (2014) 1994'ten 2010'a kadarki kısmı kapsayan çeyreklik verileri kullanmıştır. Çalışmada çeyreklik verilerle kısa dönemli talep tahmini için yeni yöntem geliştiren ikili çalışmalarında öngörü modeli olarak SARIMA modelinin üstünlüğünü ortaya koymuştur.

Shu, Nguyen, Hsu, Lu ve Huang (2014) Hong Kong ve Kaoshiung limanları için hem yük hem de konteyner çıktılarının öngörüsünü Otoregresif Tümlşik Hareketli Ortalama Modeli (ARIMA), Grey Model ile yapmış ve bu iki modelin doğruluğunu arttırmak için kalıntılarında Fourier ile deęişiklik yapmıştır. Çalışmanın sonucu Fourier ile deęişiklik yapılmış ARIMA modelin Grey modelden çok daha iyi olduğunu ortaya koymuştur.

Zaman serilerinin yer aldığı bir başka karşılaştırmalı çalışma Pang ve Gebka (2017) tarafından yapılmıştır. Pang ve Gebka çalışmalarında Mevsimsel Otoregresif Tümlşik Hareketli Ortalama Modeli (SARIMA), Toplamsal Mevsimsel Holt-Winters (ASHW), Çarpımsal Mevsimsel Holt-Winters (MSHW) ve Vektör Hata Düzeltme Modellerini (VECM) Endonezya'nın en büyük limanı olan Tanjung Priok limanının konteyner çıktıları için öngörü amaçlı kullanmıştır. Çalışmada MSHW tüm konteyner çıktıları için en doğru sonucu üretirken VECM terminaller için en doğru sonucu üretmiştir.

Çalışmalarında ayrıca zaman serileri ile konteyner çıktılarının öngörümlemesinde makroekonomik göstergelerin etkisini inceleyen Intihar, Kramberger ve Dragan'ın (2017) öncelikli amacı Slovenya'nın Koper limanı için etkin öngörü modeli oluşturmaktır. Bu amaçlara ulaşabilmek için araştırmacılar öncelikle dinamik faktörleri yani gözlemleri etkileyen makro deęişkenleri bulup sonrasında bu dinamik faktörleri temel alarak Dışsal Deęişkenli Otoregresif Tümlşik Hareketli Ortalama Modeli (ARIMAX) oluşturmuşlardır. Çalışma öngörü modelinde makroekonomik göstergeleri (gayri safi yurtiçi hâsıla, ihracat, ithalat, satın alma gücü deęeri ve işsizlik oranı) kullanmanın öngörünün doğruluğunu arttırdığını göstermiştir.

Rashed, Meersman, Van De Voorde ve Vanelander (2017) tarafından yapılan çalışmada (Mevsimsel) Otoregresif Tümlşik Hareketli Ortalama ((S)ARIMA), Müdahale Analizinin olduğu (Mevsimsel) Otoregresif Tümlşik Hareketli Ortalama ((S)ARIMA-Intervention Analysis) ve Dışsal Deęişkenli Otoregresif Tümlşik Hareketli Ortalama Modelleri (ARIMAX) karşılaştırılmıştır. Çalışmanın amacı gelecekteki talebin kısa süreli dalgalanmalarının belirsizliği ve deęişkenliği ile başa çıkabilecek planlama aracı sağlayabilmektir. Bu amaç için Antwerp limanının aylık verilerinden yararlanılmıştır. Çalışmada öngörü performansında Mevsimsel Otoregresif Tümlşik Hareketli Ortalama Modeli, müdahale analizinin olduğu Mevsimsel Otoregresif Tümlşik Hareketli Ortalama Modelini geride bırakmıştır ve ARIMAX öngörümlemede en iyi model olmuştur.

Tahmin yöntemi olarak SARIMA modelinin kullanıldığı bir başka çalışma olan Farhan ve Ong'un (2018) çalışması Antwerp, Buenos Aires, Busan, Callao, Durban, Hamburg, Hong Kong, Jeddah, Kaohsiung, Long Beach, Los Angeles, Melbourne, New York, Rotterdam, San Antonio, Santos, Shanghai, Singapore, Veracruz, Yokohama limanlarından oluşan yirmi limanı kapsamaktadır. Çalışmada her limanın zaman serisi davranışları izlenmiş ve her liman için SARIMA modeli ile kısa dönemli öngörümleme yapılmıştır ve bu öngörümle sonucunda limanların etkinliklerini, kapasitelerini ve pazar paylarını arttırmak için birçok strateji önerilmiştir. Bu stratejiler işletme iş gücü uygulamalarının arttırılması, özgün teknolojilerin kurulması, terminallerin yeniden yapılandırılması ve genişlemesi gibi uygulamaları içermektedir.

Veenstra ve Haralambides (2001) ham petrol, demir cevheri, tahıl ve kömürün ana ticaret rotalarındaki akışının uzun dönemli öngörüsünü yapabilmek için vektör otoregresyon (VAR) modeli kullanmış ve deneysel sonuçlar modelin oldukça küçük tahmin hataları ile öngörü yapabildiğini göstermiştir.

Fourier ile düzeltilmiş kalıntılı Grey Verhulst Modelinin etkinliğini göstermek için Guo, Song ve Ye (2005) çalışmalarında Doğrusal Zaman Serisi Modeli, Lojistik Fonksiyon, Orijinal Grey Modeli (GM(1,1)), Düzeltilmiş Kalıntılı Grey Verhulst Modeli (GVM) ve Fourier ile düzeltilmiş kalıntılı Grey Verhulst Modelini Çin limanının konteyner çıktısının öngörüsünde kullanmıştır. Çalışmanın deneysel sonuçları Fourier ile düzeltilmiş kalıntılı Grey Verhulst Modelinin öngörü hatasının diğer modellerdeki öngörü hatalarından daha düşük olduğunu göstermiştir.

4.4.2. Nedensellik analizinin kullanıldığı çalışmalar

Nedensellik analizi modelleri regresyon ve esneklik katsayı analizlerini içermektedir (Mo ve diğerleri, 2018). Regresyon temelli modeller standart eklemeli doğrusal ve doğrusal olmayan regresyon modellerini, hata düzeltme regresyonunu, logaritmik doğrusal regresyonu, trigonometrik regresyonu, çok değişkenli doğrusal regresyonu ve değiştirilmiş regresyon modellerini içermektedir (Patil ve Sahu, 2017).

Yaptığı çalışmanın amaçlarından biri de Hong Kong elleçleme servislerine olan talebi tahmin etmek için sistematik bir bakış açısı sağlamak olan Fung (2002), bu amaca ulaşmak için yapısal hata düzeltme modelini kullanmıştır. Hükümet makamları tarafından açıklanan öngörülerden çok daha doğru öngörüler elde etmiş ve gelecekteki talebi karşılayabilmek için yeni bir terminalin inşa edilmesi gerektiği önerisinde bulunmuştur.

Fung'un (2001) Hong Kong limanı konteyner çıktısı öngörümlemesine yönelik bir başka çalışmada Vektör Hata Düzeltme Modeli ile öngörü yapmıştır. Araştırmacı çalışma sonucunda hükümet makamları tarafından açıklanan öngörülerden daha yüksek doğruluğa sahip öngörüler elde ederken yeni terminal inşası önerisinde bulunmuştur.

Seabrooke, Hui, Lam ve Wong (2003) çalışmalarında Hong Kong limanının gelişimi ve yükün gelişimini öngörebilmek için regresyon analizi araç olarak kullanmışlardır. Regresyonda bağımsız değişkenler olarak ekonomik göstergeler kullanılmıştır. Çalışmanın sonuçları göstermiştir ki Güney Çin Bölgesi'ndeki sürekli artış komşu limanların varlığına rağmen Hong Kong limanının yük hacminin artmasına sebep olacaktır ancak bu artış sürekli olmakla birlikte azalan miktarlarda olması beklenmektedir. Ayrıca çalışma Hong Kong limanının bölgedeki rolü hakkında da yorum yapmaktadır.

Hui, Seabrooke ve Wong (2004) tarafından yapılan Hong Kong limanına yönelik bir başka çalışmada Eş Bütünleşik Hata Düzeltme Modeli kullanılmıştır. Eş bütünleşik modelin kullanılmasındaki temel amaç serilerin durağan olmamasından kaynaklanan sahte regresyon olgusundan uzaklaşabilmektir. Çalışmada ayrıca Shenzhen limanı ile Hong Kong limanı arasında kıyaslama yapılmış ve artan yük trafiğinin Shenzhen limanına doğru kaymasından söz edilmiş ancak Shenzhen limanının tahminlemenin yapıldığı on yıllık süre zarfında Hong Kong limanının yerini alamayacağından söz edilmiştir.

Konuyla ilgili bir başka çalışma Syafi'i (2006) tarafından Endonezya'daki konteyner çıktılarının öngörüsüne yönelik yapılmıştır. Araştırmacı çalışmada Vektör Hata Düzeltme Modelini kullanmış ve anlamlı sonuçlar elde etmiş ve ortalama %11,69 yıllık büyüme ile 2015 yılı için 18 712 042 TEU'luk konteyner çıktısı tahmin etmiştir.

Chou ve diğeri (2008) Tayvan'ın ithal konteynerler hacmini tahminlemek için deđiştirilmiř regresyon modeli önermiř ve bu modeli geleneksel regresyon modeli ile karşılařtırmıřtır. Karşılařtırma sonucunda deđiştirilmiř regresyon modelinin tahminleme hatası geleneksel yöntemin tahminleme hatasından daha az çıkmıřtır.

Van Dorsser, Wolters ve Van Wee (2012) çalışmalarında Le Havre – Hamburg bölgesi için çok uzun dönemli tahmin yapmak amacıyla yeni bir yöntem geliřtirmiřtir. Öngörü yöntemi Sistem Dinamikleri, Nitel Öngörü ve Nedensellik iliřkisinin birleřmesine dayanmaktadır. Öngörü sonucuna göre Le Havre – Hamburg bölgesindeki liman çıktıları yüzyılın ilk yarısında azalan miktarlarda artarken, yüzyılın sonuna dođru hacim sabit kalacak hatta azalacaktır.

Patil ve Sahu (2017) Hindistan'daki ana limanların yük taleplerini tahmin etmek için Dinamik Regresyon Modeli olarak bilinen model geliřtirdiler. Öngörü sonuçlarını hükümet makamları tarafından yayınlanan sonuçlarla karşılařtıran arařtırmacılar, Kolkata, JNPT ve Kandla limanları için hükümet makamlarının sonuçlarını daha iyimser olduđunu Paradip, Visakhapatnam, Chennai, Tuticorin, Cochin, New Mangalore, ve Mumbai limanları için öngörülerin birbirine yakın olduđunu ifade etmektedir.

Gosasang ve diğeri (2018) tarafından yapılan çalışmada nicel Vektör Hata Düzeltme Modelinden önce nitel Delphi Metodu kullanılarak ekonomik faktörler deđerlendirmeye sunulmuş belirlenmiştir. Verilerin toplanmasının ardından Vektör Hata Düzeltme Modeli ile Bangkok limanının ithal ihraç konteyner çıktısı tahminlemesi yapılmıştır. Asıl amaçlarından biri limanın konteyner terminallerinin gelecek planlama ve yönetimi ile ilgili bilgilendirme olan çalışmada konteyner terminalinin gelişimi ile ilgili üç ayrı senaryo analiz edilip deđerlendirilmiş ve en uygun seçenek belirlenmiştir.

4.4.3. Doğrusal olmayan modellerin kullanıldığı çalışmalar

Ekonomik modeller doğrusal varsayımlar üzerine inşa edilirler, böyle olunca orijinal veri setinin içerisinde yer alan doğrusal olmayan örüntüleri, doğrusal varsayım ile inşa edilen modeller tahmin edemez, bu durum öngörü performansının düşmesine neden olur (Xie ve diğeri, 2017).

Limanlardaki konteyner çıktılarının zaman serilerinde doğrusal olmayan karakteristiklerin tahminlenmesi için yapay zekâ modelleri kullanılır, yapay zekâ modelleri Geri Yayınımı (BP) Sinir Ağı ve genetik programlamayı (GP) gibi modelleri içermektedir (Xie ve diğerleri, 2017). Doğrusal olmayan dinamik öngörü modelleri ayrıca yapay sinir ağlarını (ANN), ve Destek Vektör Regresyonunu (SVR) da içermektedir (Mo ve diğerleri, 2018).

Mak ve Yang (2007) Hong Kong'da yaptıkları çalışmalarında Yaklaşık En Küçük Kareler Destek Vektör Makinası (ALSSVM) modelini geliştirmiş ve bu modeli Destek Vektör Makinası (SVM), En Küçük Kareler Destek Vektör Makinası (LSSVM) ve Radyal Bazlı Fonksiyon Sinir Ağı (RBF-NN) modelleriyle karşılaştırmışlardır. Hong Kong konteyner çıktılarının tahmininde iyi bir performans sergileyen model standart destek vektör makinası, en küçük kareler destek vektör makinası ve radyal bazlı fonksiyon sinir ağı gibi diğer yapay zekâ ile öğrenme algoritmaları ile karşılaştırıldığında yüksek bilgisayarlı devir ve iyi tahmin doğruluğu elde etmiştir.

Ping ve Fei (2013) Guangdong üzerinden yaptıkları çalışmalarında Geri Yayınımı (BP) Sinir Ağını ve Genetik Algoritmayı (GA) içeren modelleri birleştirerek GA-BP sinir ağı modelini oluşturmuştur. Çalışmanın sonuçları göstermiştir ki GA-BP sinir ağı modeli daha yüksek doğruluğa sahiptir ancak geleneksel BP ağı modelinden çok daha fazla zaman harcamaktadır.

Geng ve diğerleri (2015) grubu tarafından Shanghai limanında yapılan çalışmada verilerdeki doğrusal olamama durumu ve dalgalı sinyallerle baş edebilmek için Parametre Projeksiyon İzleme Regresyon Modeli (Parameter Projection Pursuit Regression (PPPR)) modeli kullanılmıştır. Çalışmanın sonucunda düzensiz etkin genetik algoritmalarını (CEGA) da içine alan PPPR – CEGA modeli oluşturulmuştur ve oluşturulan model Geri Yayınımı Sinir Ağı (BPNN), geleneksel Akıllı Projeksiyon İzleme Regresyon (SMART – PPR) ve Genetik Algoritmalı Projeksiyon İzleme Regresyon (PPR – GA) modelleri ile karşılaştırılmıştır. Diğer modellerde yer alan problemlerin çözümü olan model, liman çıktısı tahmini için geçerli bir yöntem olarak yerini almıştır.

Xiao ve diğerleri (2017) tarafından çalışmalarında Tianjin limanı için TEI@I metodolojisi temelinde Karma Öngörü Modeli oluşturmuştur. Çalışmada orijinal zaman serileri, bileşenlerin mevsimsel analizi temelinde kesikli dalgacık tekniği kullanılarak farklı bileşenlerine ayrılmış ve ayrılan bileşenler esnek doğrusal olmayan modelleme kabiliyetinden dolayı Radyal Bazlı Fonksiyon Sinir Ağı (RBF-NN) ile tahmin edilmiştir. Çalışmanın sonuçları kesikli dalgacık tekniğinin kullanılmasının aylık oynaklığın çözümlenmesi yeteneğini geliştirdiği ve daha iyi performans sergilediğini ortaya koymuştur. Model özellikle mevsimsel örüntülerdeki ve konjonktür dalgalanmalardaki oynaklığı daha doğru şekilde seçip almaktadır.

Xie ve diğerleri (2017) çalışmalarında birçok doğrusal olmayan nitelik içeren karmaşık yapıdaki verileri incelemiş ve mevsimsel nitelikleri yakalayabilmek için yaygın kullanılan mevsimsel ayırma metodu olan X-12-ARIMA metodunu kullanmışlardır. Singapore ve Los Angeles limanlarının verilerine uygulanan çalışmada limanlardaki konteyner çıktılarının ayrışan bileşenlerini tahmin etmek için ise En Küçük Kareler Destek Vektör Regresyonu (LSSVR) modelini kullanmış ve çalışma sonuçlarında önerilen karma modelin diğer modellerden daha iyi performans sergilediğini ortaya koymuşlardır.

4.4.4. Modellerin karşılaştırıldığı çalışmalar

Zaman serisi modelleri, regresyon modelleri ve doğrusal olmayan modeller arasında seçim yapılmasına dayanan birçok çalışma bulunmaktadır. Çalışmalarda bazen iki farklı yapı karşılaştırılırken bazen üçü de karşılaştırmaya dâhil edilmektedir. Bu çalışmalardan biri doğrusal olmayan model ile regresyon analizini karşılaştıran ve Hong Kong'da Lam, Asce, Ng, Seabrooke ve Hui (2004) tarafından yapılan çalışmadır. Sinir ağları modeli ile regresyon analizini karşılaştıran çalışmada sinir ağları modeli regresyon analizinden üstün çıkmıştır.

Chen ve Chen (2010) Tayvan'da yer alan Kaohsiung, Keelung ve Taichung limanlarıyla ilgili öngörü yapabilmek için Genetik Programlama, X-11 ve SARIMA'yı karşılaştırmış ve sonunda en iyi performansı sergileyen Genetik Programlamayı limanların öngörüsünde kullanmıştır.

Peng ve Chu (2009) konteyner çıktıları en iyi tahminleyen modeli bulmak için çıktıkları yolda Klasik Ayrıştırma Modeli, Trigonometrik Regresyon Modeli, Mevsimsel Kukla Değişkenli Regresyon Modeli, Grey Modeli, Karma Grey Modeli ve SARIMA modellerini kullanmış ve modelleri Keelung, Taichung ve Kaohsiung limanlarına uygulamıştır. Sonuç olarak mevsimsel değişimlere sahip konteyner çıktılarının tahmininde Klasik Ayrıştırma Modeli en iyi model olmuştur. Keelung, Kaohsiung limanları için Klasik Ayrıştırma Modeli en iyi model olurken Taichung limanı için Klasik Ayrıştırma Modeli ile birlikte SARIMA modeli de en iyi performansı göstermiştir. Çalışmada SARIMA modelinin iyi performans göstermemesinin nedeni olarak gözlemlerin sınırlı sayıda olması gösterilmiştir.

Çalışmalarında Bangkok limanının gelecekteki konteyner çıktıları tahmin etmek için sinir ağları metodu ile doğrusal regresyon modelini karşılaştıran Gosasang ve diğerleri (2011) çıkan sonuçlar ışığında Sinir Ağları-Çok Katmanlı Algılayıcı (MLP) metodunun Bangkok limanı için en iyi yöntem olduğunu ortaya koymuştur.

Patil ve Sahu (2016) çalışmalarında Tek Değişkenli ve Çok Değişkenli Toplamsal Regresyon Modeli ve Zaman Serisi Modellerin karşılaştırmasını yaparak Mumbai limanına gelen ve giden yüklerin tahminlemesini yapmayı amaçlamışlardır. Çalışma sonuçlarına göre çok değişkenli modellerin tek değişkenli modellere göre daha iyi performans göstermiştir. Regresyon modellerinin tahminleri zaman serileri modellerinin tahminlerine göre daha iyimser tutum sergilemiştir ve zaman serisi modelleri regresyon modellerine göre daha umut verici bulunmuştur.

4.4.5. Karma modellerin yer aldığı çalışmalar

Konteyner verilerinin zaman serileri genellikle karmaşık bir yapıya sahiptir, böyle olunca doğrusal varsayımlar temelinde tek değişkenli modeller ya da doğrusal olmaya dinamik modeller genellikle tatmin edici öngörü performansı sergileyemez; bu soru çözmek için karma modeller geliştirilmiştir (Mo ve diğerleri, 2018).

Li, Chen ve Cui (2008) çalışmalarında Doğrusal Üstel Düzleştirme Modeli, Basit Hareketli Ortalama Metodu ve Elman Ağı'nı birleştirerek doğrusal olmayan karma bir model oluşturmuşlardır. Doğrusal Üstel Düzleştirme Modeli ve Basit Hareketli Ortalama Metodu trendi göstermede olumlu etkiye sahip olduğu için bu iki yöntem doğrusal olmayan karma öngörü metodunda birleştirilmiştir. Bir çeşit yapay sinir ağı olan Elman ağı zaman serileri tahmininde olumlu etkiye sahip olduğu için kıvrımlara uyum sağlayabilmektedir. Elman ağı farklı etki ve tahmin edilen değerler arasındaki ilişkinin eşleştirilmesini modele yansıtan, yöntemin ana kısmıdır. Elman ağı ile farklı tek değişkenli metotlar bir araya getirilir ve yeni doğrusal olmayan yöntem öngörümlemede daha yüksek doğruluğa ulaşır.

Tian, Liu, Lai ve Wang (2013) tarafından yapılan çalışma liman lojistik servisleri için, özellikle liman konteyner çıktıları için, TEI@I metodolojisi temelinde bütünleşik tahminleme modeli sunmaktadır. Hong Kong limanının aylık konteyner çıktılarının kullanıldığı çalışmada, TEI@I metodolojisi çerçevesinde bütünleşik tahminleme modeli SARIMA, VAR ve RBF sinir ağları tekniklerinin birleştirici kullanımları ile formüle edilmiştir. Deneysel sonuçlar TEI@I bütünleşik modelin etkinliğini ortaya koymuştur.

Xie, Wang, Zhao ve Lai (2013) tarafından yapılan çalışmada En Küçük Kareler Destek Vektör Regresyonu (LSSVR) temelinde Mevsimsel Ototregresif Tümüleşik Hareketli Ortalama Modeli-En Küçük Kareler Destek Vektör Regresyonu (SARIMA-LSSVR), Mevsimsel Ayrıştırma Modeli/X-12-ARIMA - En Küçük Kareler Destek Vektör Regresyonu (SD-LSSVR), Klasik Ayrıştırma Modeli- En Küçük Kareler Destek Vektör Regresyonu (CD-LSSVR) olmak üzere üç farklı karma model oluşturulmuştur ve bu modeller karşılaştırılmıştır. Önerilen modellerin etkinliği Shanghai ve Shenzhen limanlarının konteyner çıktıları üzerinden ölçülmüştür. Sonuç olarak önerilen karma modeller tek modellerden daha iyi öngörü performansı göstermiştir. Modeller SARIMA, SD ve CD olarak değerlendirildiğinde SARIMA diğer modellerden daha iyi tahminleme performansı göstermiştir. Araştırma ayrıca ayrıştırmanın limanlardaki konteyner çıktısı tahminlerinde etkili bir yol olduğunu ortaya koymuştur.

Huang, Lai, Li ve Wang (2015) tarafından Qingdao limanında yapılan bir başka çalışmada Projeksiyon İzleme Regresyonu (PPR) ve Genetik Programlama (GP) Algoritması ile PPR-GP karma modeli oluşturulmuştur. Geri Yayımlı Yapay Sinir Ağları (BP-ANN), Mevsimsel Otoregresif Tümlşik Hareketli Ortalama Modeli (SARIMA) ve Standart Projeksiyon İzleme Regresyonu (PPR) ile karşılaştırılan model diğer modellerden üstün gelmiştir. Ayrıca çalışmada aykırı değerlerin bulunmasını sağlayan araştırmacılar tarafından geliştirilen yeni aykırı değer işleme algoritmasından da söz edilmektedir.

Mohamed Ismael ve Vandyck'in (2016) Cibuti sınırları içerisinde yer alan Doraleh limanı üzerinden yaptığı konteyner çıktısının öngörülenmesine yönelik olan çalışmada Üstel Düzleştirme Modeli, Grey Model, Doğrusal Regresyon Modelleri ve bu modellerin birleşimi kullanılmıştır. Sonuçların karşılaştırılması Regresyon ve Grey modellerin diğer modellerden daha doğru sonuçlar ortaya koyduğunu göstermiştir. Ayrıca çalışma daha iyi sonuçların Regresyon Modeli ile sağlanabileceğine vurgu yapmıştır.

Chen, Chen ve Li (2016) çalışmalarında Pearl Eğrisi Modeli, Grey Model (GM(1,1)) ve Karesel Üstel Düzleştirme Modelini ve bu üç modelin birleşimini kullanmış ve bu modellerin karşılaştırmasını Dalian'ın verileri üzerinden yapmıştır. Çalışmanın sonuçları üç modelin birleşimi ile oluşan karma modelin en iyi olduğunu göstermiştir.

Mo ve diğerleri (2018) çalışmalarında Veri İşlemenin Grup Metodunu (GMDH) tanıtmışlardır. Model orijinal konteyner çıktısı serisini doğrusal ve doğrusal olmayan şeklinde ikiye ayırarak doğrusal olan kısmını SARIMA ile doğrusal olmayan kısmını ise Geriye Yayımlı (BP) Sinir Ağları, Destek Vektör Makinası (SVM) ve Genetik Programlama (GP) ile tahmin etmektedir. Modelin uygulaması için Xiamen ve Shanghai limanları'nın verilerini kullanan araştırmacılar, oluşturulan modelin SARIMA, SARIMA-SVM, SARIMA-GP ve SARIMA-BP'den daha iyi olduğunu ortaya koymuş ve oluşturulan model ile limanlar için aylık öngörüde bulunmuşlardır.

4.4.6. Türk limanlarında yapılan çalışmalar

Türkiye’de yapılan çalışmalar incelendiğinde en çok kullanılan yöntemlerin başında regresyon analizi gelmektedir. Regresyon analizinin yanında akademik çalışmalarda doğrusal olmayan yöntemlere de rastlanmaktadır. Tür, Küçükosmanoğlu ve Küçükosmanoğlu’nun (2013) yaptığı çalışma Doğrusal Regresyon Modeli ile Bulanık Sinir Ağı Modellerinin karşılaştırılmasını Antalya limanı için kısa dönemli tahminin yapılmasını içermektedir. Çalışmada Antalya limanından temin edilen 2008-2011 yıllarını kapsayan aylık veri seti tahmin için kullanılırken 2012 yılı için aylık olarak tahminde bulunulmuştur. Karşılaştırma sonucunda Bulanık Sinir Ağı Modelinin Doğrusal Regresyon Modelinden çok daha iyi sonuçlar ortaya koymuştur.

Akar ve Esmer (2015) tarafından yapılan çalışmada Türkiye’deki konteyner limanları için öngörülede bulunulmuş ve Çoklu Regresyon Analizi metodu kullanılmıştır. Bağımsız değişken olarak Türkiye’nin Gayri Safi Milli Hasılasının, dış ticaret miktarının ve nüfusunun kullanıldığı çalışmada 2010-2014 yılları tahmin için kullanılırken 2015-2023 yılları için de öngörü yapılmıştır. Araştırmaya göre 2023 yılında konteyner elleçleme miktarının 12,7 TEU’ya yaklaşması beklenmektedir. Ayrıca Türkiye’deki limanların kapasitelerinin öngörülen miktarlarla da karşılaştırıldığı çalışmada Türk limanlarının öngörülere karşılayabileceği ve kapasite sorunu yaşamayacağı sonucuna da ulaşılmıştır.

Karadeniz’deki limanlar üzerine bir çalışma yapan Şengönül ve Esmer (2016) çalışmalarında regresyon modeli ile 2035 yılına kadar uzanan uzun dönemli konteyner talep öngörümlemesi yapmışlardır. Tahminleme süreci için 2004-2013 yıllarına ait veri setlerini kullanan araştırmacılar çalışmalarında bağımlı değişken olarak karadeniz bölgesi konteyner elleçlemesini bağımsız değişkenler olarak Türkiye’nin konteyner elleçlemesini, Gayri Safi Yurtiçi Hasılasını, ithalat, ihracat ve nüfusunu kullanmışlardır.

Gökkuş, Yıldırım ve Aydın (2017) çalışmalarında İstanbul, İzmir ve Mersin limanlarının konteyner trafiğinin öngörülenmesi için Yapay Sinir Ağları/Yapay Arı Kolonisi (ANN-ABC), Yapay Sinir Ağları/ Levenberg-Marquardt Algoritmaları (ANN-LM), Çoklu Doğrusal Olmayan Regresyon Modeli/Genetik Algoritma (MNR-GA) ve En Küçük Kareler Destek Vektör Makinası (LSSVM) modellerini karşılaştırdılar. Çalışmalarında Gayri Safi Yurtiçi Hasılayı, nüfusu, enflasyon oranını, yakıt fiyatını, toplam ihracat ve ithalatı bağımsız değişken olarak kullanan araştırmacılar İzmir ve İstanbul limanları için LSSVM en iyi model olarak bulurken ANN-ABC ve ANN-LM'yi ise Mersin limanı için en iyi olarak buldular. 2016 - 2023 yılları için öngörü sonuçları İzmir ve Mersin için sırasıyla %60 ve %67 konteyner trafiğinde artış gösterirken İstanbul için %95 artış göstermektedir.

Türkiye'deki limanların kullanıldığı bir başka çalışma ise Yıldırım, Gökkuş ve Aydın (2017) tarafından yapılmıştır. Araştırmacılar çalışmalarında Yapay Sinir Ağları/Yapay Arı Kolonisi (ANN-ABC) yöntemini kullanmış ve modeli geliştirirken Gayri Safi Yurtiçi Hasılayı, toplam ithalat ihracatı ve nüfusu bağımsız değişken olarak kullanmışlardır. Modeli, Geri Yayımlı Yapay Sinir Ağları (BP-ANN) ve Çoklu Regresyon Modelleri ile kıyaslayan araştırmacılar Yapay Sinir Ağları/Yapay Arı Kolonisi (ANN-ABC) Modelinin diğerlerinden çok daha iyi performans sergilediği sonucunu ortaya koymuşlardır.

Akademik çalışmalar dışında Türkiye'deki limanlarla ilgili öngörü örneklerine fizibilite raporlarında da rastlanmaktadır (Çizelge 4.2).

Çizelge 4.2. Türkiye’de gerçekleştirilen projelerde kullanılan tahmin yöntemleri (Ulaştırma Bakanlığı, 2010)

Yıl	Çalışmayı Yapan Kurum	Çalışmanın Adı	Kullanılan Yöntem
1990	Japan International Cooperation Agency	For Study on the Development Project of Filyos Port in the Republic of Turkey	Doğrusal (Lineer) Regresyon
1997	D.E.Ü. Deniz Bilimleri ve Teknolojisi Enstitüsü	Kuzey Ege Limanı Fizibilite Etüdü	Zaman Serisi ve Doğrusal, logaritmik ve üstel regresyon
1997	The overseas Coastal Area Development Institute of Japan – Nippon Keoi, Co., Ltd.	The Master Plan Study for the Port Development at the Sea of Marmara in The Republic of Turkey	Çoklu Doğrusal Regresyon
1998	SAPROF Team for the Overseas Economic Cooperation Fund, Japan.	Special Assistance for Project Formation for İzmir Port Development Project in Republic of Turkey, Final Report	Zaman Serisi
2000	The Overseas Coastal Area Development Institute of Japan	Final Report for the Study on the Nationwide Port Development Master Plan in the Republic of Turkey (ULIMAP)	Doğrusal Regresyon, Logaritmik Regresyon
2005	Sener, Dolsar, Euroestudios ortak girişimi	North Aegean (Çandarlı) Port Feasibility Study	Eğilim Analizi (Multiplicative Model)
2005	Ulaştırma Bakanlığı & İstanbul Teknik Üniversitesi	Ulaştırma Ana Planı Stratejisi	Logaritmik regresyon
2005	TCT, Alatec, Idom Ortak Girişimi	Feasibility Study of the Construction of Container Port of Mersin, Master Plan,2005	Çoklu Regresyon
2005	Eser Mühendislik Müşavirlik A.Ş.	Çandarlı Limanı Fizibilite Raporu	Regresyon Analizi
2007	TINA Türkiye Ortak Girişimi	TINA Türkiye (Türkiye’nin Ulaştırma Altyapısı İhtiyaç Değerlendirmesi Teknik Yardım Çalışması)	Yolcu ve yük taşımacılığına yönelik iki farklı yöntem kullanılmıştır. Metodolojiler verilerin mevcudiyeti doğrultusunda, projenin akışı süresince uyarlanmış ve geliştirilmiştir.
2007	D.E.Ü. Deniz İşletmeciliği ve Yönetimi Y.O.	Türk Limancılık Sektör Raporu – Vizyon 2023	Doğrusal Regresyon
2010	Altınok-Areas-Csm Konsorsiyum	Technical Assistance for Construction of a New Port in Çandarlı (İzmir) in Turkey	Regresyon Analizi
2010	Altınok-Areas-Csm Konsorsiyum	Technical Assistance for Construction of Container Port in Mersin	Zaman Serisi
2010	Yüksel Proje Uluslararası A.Ş. ve Belde Proje ve Danışmanlık TİC. LTD. ŞTİ. Ortak Girişimi	Ulaştırma Kıyı Yapıları Master Plan Çalışması – Sonuç Raporu	Çoklu regresyon Analizi

4.5. Öngörü Uzunluğunun ve Modelin Belirlenmesi

Çalışmalar incelendiğinde kısa dönemli öngörü çalışmalarındansa uzun dönemli öngörü çalışmalarının daha fazla olduğu dikkat çekmektedir. Kısa dönemli öngörü modelleri limanlarda mevsimsel konteyner çıktılarını öngörebilmek için kullanılmaktadır (Farhan ve Ong, 2018). Kısa dönemli öngörülerin hedefi daha çok terminal operatörleri ve liman yetkilileridir bunun sebebi ise operasyon kararlarının ve verilen hizmetlerin birim zamana düşen konteyner hareketlerinin sayısına bağlı olmasıdır (Rashed ve diğerleri, 2017). Bir ya da iki yıllık kısa süreleri kapsayan kısa dönemli tahminler, genelde ilave ekipman ve materyallerin satın alınması personel ve makinaların yerleştirilmesi ve ayarlanmasını içeren günlük liman operasyonları faaliyetlerinde kullanılır (Peng ve Chu, 2009).

İmalat endüstrisinin aksine konteyner terminallerinin kapasitesi, kısa dönemde talepte meydana gelen mevsimsel dalgalanmaya cevap verebilmek için stok tutma, dış kaynak kullanımı, fazla mesai gibi uygulanabilen stratejiler ile yükseltilemez (Peng ve Chu, 2009). Bu sebepten dolayı kısa dönemli öngörüler konteyner limanının trafiğinin kontrol edilmesi ve programlanması için ve karar vermede ve planlamada terminal operatörleri için son derece önemlidir (Xiao ve diğerleri, 2015). Klein ve Verbeke (1987) çalışmalarında Prof. F.Sun-Kens'in cümlesine yer vererek yatırım planlaması amacıyla kullanılmayan kısa dönemli tahminin liman otoritesi açısından bütçe tahminlemesi (örneğin; liman masrafları ve değişken giderlerin kategorileştirilmesi) için liman kullanıcıları açısından kısa dönemli planlama (örneğin; envanter ve iş gücünün planlanması) için hala önemli olduğunu vurgulamaktadır.

Çalışmalar incelendiğinde dikkat çeken bir başka nokta tüm Türk limanlarını içine alan kısa dönemli bir öngörü modelinin daha önce yapılmamış olmasıdır. Bu durum bu tezin ortaya çıkışında önemli motivasyonlardan birini oluşturmaktadır.

Zaman serisi modellerini oluşturmak, analiz etmek ve tahminlemek için sistematik bir bakış açısı sağlaması tek değişkenli modelin avantajıdır, örneğin çok değişkenli regresyon modelini dikkate aldığımızda bu modelin oluşması için başka bağımsız değişkenlerin de kullanılması gerekmektedir (Rashed ve diğerleri, 2017). Diğer ekonometrik modellerin kısıtlayıcı yapısından dolayı zaman serisi modelleri benzerlerinden üstün olma eğilimindedir; örneğin diğer modeller zaman serilerinin dinamik yapısını kapsamazlar ve yapısal değişkenlerde uygunsuz kısıtlamalar dayatırlar (Farhan ve Ong, 2018).

Zaman serisi modelleri hesaplamada basit ve hızlıdır ve özellikle kısa dönemli öngörülerde diğer modellerden daha iyi olma olasılıkları yüksektir (Geng ve diğerleri, 2015). ARIMA kısa dönemli liman çıktılarının öngörüsünde kullanılabilen yöntemlerden biridir (Farhan ve Ong, 2018). Diğer modellerin aksine, ARIMA, zaman serisinin geçmişteki değerleri ile önceki hata terimlerinin öngörü için bilgi içerdiğini varsaydığı veri setlerinin, bilinmeyen altında yatan ekonomik model ya da yapısal ilişkilerini etkili bir şekilde yönetebilir (Shu, Hsu, Nguyen, Lu ve Huang, 2014). Dinamik yapıları kapsayan esnekliği ile ARIMA modeller kısa dönemli öngörülerde doğal avantaj elde eder (Farhan ve Ong, 2018). Özellikle kısa dönemli tahminlerde ARIMA modelinin diğer modellerden daha etkili olması bu çalışmada ARIMA modelinin kullanılmasına sebep olmuştur.

5. YÖNTEM

5.1. Box – Jenkins Yöntemi Otoregresif Tümlleşik Hareketli Ortalama Modeli (ARIMA)

Çalışmada yöntem olarak seçilen Box – Jenkins olarak da bilinen ARMA yöntemi ilk kez George E. P. Box ve Gwilym Jenkins tarafından otoregresif (AR) ve hareketli ortalamaların (MA) öngörümleme yaparken kullanılması ile ortaya çıkmıştır ve bu iki araştırmacı bu yöntemle ünlenmişlerdir (Evans, 2003:227, Enders, 2015:76). Box ve Jenkins'ın geliştirdiği yöntem modelin tanımlanması, modelin tahmin edilmesi ve modelin kontrol edilmesi/hata kontrolü olmak üzere üç kısma ayrılmaktadır; bu üç aşamadan sonra istenilen modelin elde edilmesi durumunda elde edilen model ile öngörü yapılarak modelin performansı izlenir (Pankratz, 2012:16).

1. *Modelin Tanımlanması*: İlk adım olan modelin tanımlanması aşaması veri setinin analizini yani daha çok araştırmacının görsel olarak zaman serisinin grafiğini, otokorelasyon fonksiyonunu, kısmi otokorelasyon fonksiyonunu değerlendirmesini bu değerlendirmeler sonucunda araştırmacının veri setini anlamasını ve veri setinin yapısına göre adımların belirlenmesini modele AR ve MA terimlerinin eklenmesini ihtiyaç var ise fark alma, trendden arındırma gibi işlemlerin yapılmasını içermektedir ayrıca bu değerlendirme araştırmacıya zaman serisindeki uç değerler, kayıp değerler ve yapısal kırılmalarla ilgili bilgi sağlamaktadır (Enders, 2015:76).
2. *Modelin Tahmin Edilmesi*: Uygun gecikmelerin belirlenmesi ve modelin oluşturulmasının ardından bu kısımda yapılması gereken modelde yer alan bağımsız değişkenlerin parametrelerinin belirlenmesidir, burada önemli olan az sayıda değişken içeren ancak optimum sonucu veren modelin bulunmasıdır (Gujarati, 2004:840-841, Enders, 2015:76).
3. *Modelin Kontrol Edilmesi/Hata Kontrolü*: Bu aşamada amaç modelin öngörümleme için uygun olup olmadığını test etmektir. Bu amaç doğrultusunda modelin kalıntılarına (hatalarına) bazı testler yapılarak modelin uygunluğu incelenir (Pankratz, 2012:16, Gujarati, 2004:841).

4. *Öngörü*: Bu aşamada parametreleri belirlenerek hataları kontrol edilen model ile öngörü yapılır. ARIMA modelini diğer modellerden ayıran en önemli özellik modelin kısa dönemli öngörülerde diğer modellere göre çok daha iyi öngörü yapmasıdır (Gujarati, 2004:841).

Modelin tahmin edilmesi aşamasında da belirtildiği gibi Box ve Jenkins yönteminin önemli prensiplerden biri olan *tutumluluk (parsimony) prensibidir*, bu prensibe göre zaman serisinin davranışını en az parametre ile açıklayan uygun model aranmaktadır (Pankratz, 2012:17).

5.1.1. Otoregresif (AR) model

Rassal yürüyüş başlığında da bahsedildiği gibi stokastik süreç y_t Eş. 5.55'teki gibi yazıldığında p . dereceden otoregresif olarak ifade edilebilir (Carnot ve diğerleri, 2005:88):

$$y_t = a_1 y_{t-1} + a_2 y_{t-2} + \dots + a_p y_{t-p} + \varepsilon_t \quad (5.55)$$

Eş. 5.55'teki ε_t beyaz gürültüyü ifade ederken Eş. 5.55'te yer alan a_1 'den a_p kadar olan katsayılar bilinmeyen parametreleri ifade etmektedir (Heij ve diğerleri, 2004:539). p 'nin 1 olması durumu basit AR(1) sürecini ifade ederken Eş. 5.56'daki gibi gösterilebilir. Aynı mantıkla ilerlendiğinde AR(2) süreci p 'nin 2 olduğu durumu ifade eder ve Eş. 5.57'deki gibi ifade edilir. Eş. 5.56 ve Eş. 5.57'de yer alan ε_t beyaz gürültü sürecini ifade etmektedir.

$$y_t = a_1 y_{t-1} + \varepsilon_t \quad (5.56)$$

$$y_t = a_1 y_{t-1} + a_2 y_{t-2} + \varepsilon_t \quad (5.57)$$

5.1.2. Hareketli ortalama (MA) modeli

Hareketli ortalama (MA) modelinde bağımlı değişken kalıntılar olarak ifade edilen gözlemlenemeyen şoklara göre açıklanır; gözlemlenemeyen veri ile modeli tahmin etmek mümkün olmadığı için daha önceki hatalar kullanılmaktadır; bir gecikmeli hareketli ortalama modelinde (MA(1)) son öngörü hatası kullanılırken (Eş. 5.58) iki gecikmelide ise (MA(2)) son iki öngörü hatası kullanılmaktadır (Eş. 5.59) (Evans, 2003:235).

$$y_t = \varepsilon_t + b_1 \varepsilon_{t-1} \quad (5.58)$$

$$y_t = \varepsilon_t + b_1\varepsilon_{t-1} + b_2\varepsilon_{t-2} \quad (5.59)$$

MA(1) ve MA(2) den yola çıkarak MA(q) yani q dereceli hareketli ortalama Eş. 5.60'daki gibi ifade edilmektedir ((Carnot ve diğerleri), 2005:88).

$$y_t = \varepsilon_t + b_1\varepsilon_{t-1} + b_2\varepsilon_{t-2} + \dots + b_q\varepsilon_{t-q} \quad (5.60)$$

5.1.3. Otoregresif (tümleşik) hareketli ortalama modeli (AR(I)MA)

Eş 5.61'deki gibi Eş. 5.55 ile Eş 5.60 birleştirildiğinde hem AR hem de MA terimlerini içeren y_t , ARMA(p, q) sürecini izlemektedir (Carnot ve diğerleri, 2005:88).

$$y_t - a_1y_{t-1} - a_2y_{t-2} - \dots - a_py_{t-p} = \varepsilon_t + b_1\varepsilon_{t-1} + b_2\varepsilon_{t-2} + \dots + b_q\varepsilon_{t-q} \quad (5.61)$$

3.6 başlığının altında da belirtildiği gibi bazı zaman serileri stokastik trende sahiplerdir ve tahminleme yapabilmek için öncelikle zaman serilerinin farkının alınması gerekir. Otoregresif Tümleşik Hareketli Ortalama Modelinde (ARIMA) yer alan tümleşik (integrated) Otoregresif Hareketli Ortalama Modeli kurulurken zaman serisinin durağanlaştırılması için farkının alındığının göstergesidir. Eğer zaman serisi birinci dereceden tümleşik ise bu zaman serisinin durağanlaştırılması için bir farkının alındığının göstergesidir bunu $I(1)$ olarak da ifade edebiliriz. Eğer zaman serisi zaten durağan ise yani hiç farkı alınmamışsa bu az önce bahsettiğimiz Otoregresif Hareketli Ortalama Modelini (ARMA) ifade etmektedir bu durum ise $I(0)$ olarak gösterilir. Bazı durumlarda zaman serisinin bir farkını almak durağanlaştırmak için yeterli olmayabilir bu durumda zaman serisine bir fark alma işlemi daha uygulanır bu durum ise $I(2)$ şeklinde ifade edilebilir.

Bir önceki paragrafta bahsedildiği gibi 1 ya da 2 keredede değil zaman serisinin d kere farkı alındığı varsayıldığında bu durumun $ARMA(p,q)$ gibi bir model üzerinden ifade edilmesi istenirse model $ARMA(p,d,q)$ şeklinde ifade edilir. Bu ifade otoregresif tümleşik hareketli ortalamayı göstermektedir ifade d . dereceden tümleşiktir. Ayrıca ifadede p otoregresif terimlerin sayısını, d durağanlaştırmak için serinin kaç defa farkının alındığını, q ise hareketli ortalama terimlerinin sayısını göstermektedir. İfadenin özel hallerinde ise; $ARIMA(p,0,0)$ saf otoregresif durağan $AR(p)$ süreci ifade ederken, $ARIMA(0,0,q)$ saf hareketli ortalama $MA(q)$ sürecini ifade etmektedir (Gujarati, 2004:840).

5.2. Otokorelasyon Fonksiyonu (ACF) ve Kısmi Otokorelasyon Fonksiyonu (PACF) ile Belirlenmesi


Zaman serisi modellerin tanımlanması ve tahminlenmesinde özellikle p ve q 'nun belirlenmesinde otokorelasyon fonksiyonu ve kısmi otokorelasyon fonksiyonu oldukça önem arz etmektedir. Bu fonksiyonlar sürecin AR, MA ya da ARMA oluşuna göre farklılık gösterirken bazı durumlarda modeldeki gecikme terimlerinin katsayılarının farklı oluşu da fonksiyonları etkilemektedir. Fonksiyonların inceleme aşamasına gelmeden önce zaman serisinin durağan olması ya da durağanlaştırılmış olması gerektiğinin belirtilmesi gerekmektedir.

5.2.1. Otoregresif (AR) süreç


Eş. 5.56'da ifade edilen $AR(1)$ sürecinde, y_{t-1} 'nin katsayısı (a_1) pozitif ise, yakınsamanın aynı yönde olması beklenirken, y_{t-1} 'nin katsayısı (a_1) negatif ise otokorelasyonlar sıfır etrafında azalan salınımlı bir yol izlemektedir (Enders, 2015:60). Kısmi otokorelasyon fonksiyonunda ise birinci gecikmenin otokorelasyonunun y_{t-1} 'nin katsayısı ile aynı yönde olması ve birinci gecikmeden sonra ani bir düşüş sergilemesi beklenmektedir.

Şekil 5.1 ve Şekil 5.2'de $AR(1)$ sürecinin otokorelasyon ve kısmi otokorelasyon fonksiyonları gösterilmektedir. Şekil 5.1'deki modelde, y_{t-1} 'in katsayısı (a_1) pozitif işaretli olduğu için otokorelasyon fonksiyonu aynı yönde azalarak 0'a yaklaşırken, kısmi otokorelasyon fonksiyonunda birinci gecikmenin otokorelasyonu y_{t-1} 'in katsayısı (a_1) ile aynı işaretlidir (pozitif işaretli) ve birinci gecikmeden sonra ani düşüş gözlenmektedir.


Şekil 5.2'deki modelde, y_{t-1} 'in katsayısı (a_1) negatif işaretli olduğu için otokorelasyon fonksiyonu salınarak + ve - yönlerinde azalarak 0'a yaklaşırken, kısmi otokorelasyon fonksiyonunda birinci gecikmenin otokorelasyonu y_{t-1} 'in katsayısı (a_1) ile aynı işaretlidir (negatif işaretli) ve birinci gecikmeden sonra ani düşüş gözlenmektedir. Her iki şekilde de otokorelasyon katsayısının azalarak sifira yaklaşması sürecin otoregresif süreç olduğunun göstergesi iken kısmi otokorelasyon fonksiyonunda birinci gecikmeden sonraki ani düşüş sürecin bir gecikmeli otoregresif süreç (AR(1)) olduğunu göstermektedir. AR(2) durumunda ise kısmi otokorelasyon fonksiyonunda ikinci gecikmeden sonra ani düşüş görülmektedir (Şekil 5.3).



Şekil 5.1. Pozitif işaretli AR(1) sürecinin otokorelasyon ve kısmi otokorelasyon fonksiyonları (Enders, 2015:61)




Şekil 5.2. Negatif işaretli AR(1) sürecinin otokorelasyon ve kısmi otokorelasyon fonksiyonları (Enders, 2015:61)



Şekil 5.3. AR(2) sürecinin otokorelasyon ve kısmi otokorelasyon fonksiyonları (Enders, 2015:61)

5.2.2. Hareketli ortalama (MA) süreci


Şekil 5.4. Eş. 5.58’de ifade edilen MA(1) sürecinin otokorelasyon ve kısmi otokorelasyon fonksiyonlarını göstermektedir. MA(1) sürecine ait Şekil 5.4, AR(1) ve AR(2) süreçlerini içeren Şekil 5.1, Şekil 5.2 ve Şekil 5.3 ile karşılaştırıldığında açıkça görülmektedir ki MA süreci AR sürecinin tam tersi bir yol izlenmektedir. AR sürecinin otoregresif fonksiyonunda gözlemlenen durum MA sürecinin kısmi otokorelasyon fonksiyonunda gözlemlenmektedir.



Şekil 5.4. Negatif işaretli MA(1) sürecinin otokorelasyon ve kısmi otokorelasyon fonksiyonları (Enders, 2015:61)

5.2.3. Otoregresif hareketli ortalama (ARMA) süreci

Şekil 5.5 hem AR(1) hem de MA(1) terimlerini içermektedir. ARMA(1,1) durumunda AR ve MA olduğu gibi keskin düşüşler karşılaşılmamakta aksine her iki fonksiyon da azalarak devam etmektedir. Şekil olarak ifade edilen otokorelasyon ve kısmi otokorelasyon fonksiyonlarının sayı ile ifade edilmiş hali Çizelge 5.1’de gösterilmektedir. Az önce şekil üzerinde açıklanan keskin düşüşler burada da açıkça görülmektedir. Çizelgede lag sözcüğü gecikmeyi ifade ederken ACF ve PACF’in başlarında yer alan S harfi İngilizce sample kelimesinin ilk harfi olup örneklem kelimesi yerine kullanılmıştır, ayrıca WN white noise yani beyaz gürültünün kısaltmasıdır.



Şekil 5.5. ARMA(1,1) sürecinin otokorelasyon ve kısmi otokorelasyon fonksiyonları (Enders, 2015:61)

Çizelge 5.1. Beyaz gürültü (WN), AR(1), AR(2), MA(1), MA(2) ve ARMA(1,1) süreçlerinin otokorelasyon ve kısmi otokorelasyon fonksiyonları (Heij ve diğerleri, 2004:549)

Lag	WN		AR(1)		AR(2)	
	SACF	SPACF	SACF	SPACF	SACF	SPACF
1	-0.010	-0.010	0.833	0.833	0.907	0.907
2	0.008	0.008	0.681	-0.045	0.713	-0.618
3	-0.114	-0.114	0.534	-0.072	0.481	-0.049
4	-0.074	-0.077	0.433	0.059	0.262	0.045
5	-0.034	-0.035	0.365	0.043	0.080	-0.056
6	0.038	0.026	0.312	-0.001	-0.060	-0.064
7	-0.087	-0.105	0.247	-0.062	-0.158	-0.017
8	-0.076	-0.096	0.215	0.076	-0.206	0.083
9	0.018	0.018	0.213	0.092	-0.211	-0.023
10	-0.001	-0.018	0.206	-0.022	-0.193	-0.081

Lag	MA(1)		MA(2)		ARMA(1,1)	
	SACF	SPACF	SACF	SPACF	SACF	SPACF
1	0.543	0.543	0.688	0.688	0.911	0.911
2	0.050	-0.347	0.353	-0.229	0.742	-0.513
3	0.002	0.248	0.014	-0.254	0.593	0.295
4	-0.025	-0.231	-0.017	0.325	0.480	-0.116
5	-0.037	0.162	-0.020	-0.118	0.401	0.126
6	0.018	-0.069	-0.012	-0.138	0.336	-0.137
7	0.009	0.012	-0.026	0.152	0.278	0.101
8	-0.075	-0.117	-0.074	-0.160	0.244	0.068
9	-0.080	0.064	-0.086	-0.017	0.233	0.023
10	-0.050	-0.094	-0.103	0.039	0.228	-0.021

Otokorelasyon fonksiyonu (ACF) ve kısmi otokorelasyon fonksiyonu (PACF) ile ilgili anlatılanlar Çizelge 5.2’de özetlenmiştir.

Çizelge 5.2. ARMA model için ACF ve PACF’nin davranışları ((Shumway ve Stoffer), 2011:108)

	AR(p)	MA(q)	ARMA(p, q)
ACF	Azalarak sona erer	Gecikme q ’den sonra kesilir	Azalarak sona erer
PACF	Gecikme p ’den sonra kesilir	Azalarak sona erer	Azalarak sona erer

5.3. Modelin Tahmin Edilmesi

Zaman serisi modelinin kurulabilmesi için modelin parametrelerinin belirlenmesi gerekmektedir. Veri seti üzerinden belirlenen parametreler modelde yer alan değişkenlerin veri seti üzerinden tahminlenmesi ile elde edilmektedir. Tahminleme aşamasında elde edilen parametrelerin hata karelerin toplamını en aza indirmesi beklenmektedir, tahminleyici olarak genellikle en çok olabilirlik ya da en küçük kareler kullanılır, ARMA(p,q) modellerinde ise en çok olabilirlik yöntemi kullanılmaktadır (Palit ve Popovic, 2005:45).

5.4. Model Seçim Kriterleri

Rekabet eden modeller arasından en uygun modeli seçmek ya da modelleri karşılaştırmak için kullanılan birçok yöntem bulunmaktadır, bu bölümde kullanılacak olan kriterler özellikle tartışılacaktır bunlar ise: R^2 , düzeltilmiş R^2 (\bar{R}^2), Akaike Bilgi Kriteri (AIC) ve Schwarz Bilgi Kriteridir (SIC).

5.4.1. Belirleme katsayısı R^2

R^2 ile gösterilen belirleme katsayısı, bağımlı değişkendeki bağımsız değişken tarafından açıklanan tüm değişimin oranını verir R^2 Eş. 5.62'deki gibi hesaplanır.

$$R^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS} \quad (5.62)$$

Eş. 5.62'de ESS açıklanan kareler toplamını ifade ederken $\sum(\hat{Y}_i - \bar{Y})^2$ şeklinde hesaplanır, TSS toplam kareler toplamını ifade ederken $\sum y_i^2 = \sum(Y_i - \bar{Y})^2$ ile hesaplanır ve toplam kareler toplamı ile açıklanan kareler toplamının farkını veren hata kareler toplamı $\sum e_i^2$ şeklinde hesaplanır (Gujarati, 2011:13).

R^2 , 0 ile 1 arasında değer almaktadır. Değerin 1 olması bağımsız değişkenlerin bağımlı değişkeni tamamen açıkladığını ifade ederken, değer 1'e yakın olması daha iyi bir uyumu gösterir, R^2 'lerin karşılaştırılabilmesi için modellerdeki bağımlı değişkenlerin aynı olması gerekmektedir (Gujarati, 2004:536).

5.4.2. Düzeltilmiş R^2 (\bar{R}^2)

R^2 modele yeni bir değişkenin eklenmesi ile arttığı için bu durum araştırmacıda yeni bir değişken ekleme isteğini arttırabilir düşüncesi ile değişken sayısını hesaba katan düzeltilmiş R^2 ortaya çıkmıştır, \bar{R}^2 ile gösterilen düzeltilmiş R^2 Eş. 5.63 ile hesaplanmaktadır (Gujarati, 2011:14).

$$\bar{R}^2 = 1 - (1 - R^2) \frac{n - 1}{n - k} \quad (5.63)$$

Eş. 5.63'te n gözlem sayısını ifade ederken k bağımlı değişken sayısını ifade etmektedir.

5.4.3. Akaike bilgi kriteri (AIC)

Model seçim kriterlerinden bir diğeri olan Akaike bilgi kriterleri ile de yeni bir bağımsız değişken eklenmesi durumuna önlem alınmak istenmiştir. Ancak bu kriterde yeni bir değişkenin eklenmesinin bedeli düzeltilmiş R^2 'ye göre daha fazladır. Kriterin formülü Eş. 5.64'teki gibi ifade edilmektedir (Gujarati, 2004:537).

$$AIC = e^{2k/n} \frac{\sum \hat{u}_i^2}{n} = e^{2k/n} \frac{RSS}{n} \quad (5.64)$$

Matematiksel uygunluk açısından Eş. 5.64, Eş 5.65'teki gibi yazılabilmektedir, eşitlikte $\ln AIC$ AIC değerinin doğal logaritmasını ifade ederken $2k/n$ ise ceza faktörünü yani yeni bir değişkenin eklenmesinin bedelini ifade etmektedir

$$\ln AIC = \left(\frac{2k}{n} \right) + \ln \left(\frac{RSS}{n} \right) \quad (5.65)$$

Eş. 5.64 ve Eş. 5.65'te n gözlem sayısını ifade ederken k bağımlı değişken sayısını ifade etmektedir.

Model kıyaslamalarında AIC değeri düşük olduğu modelin tercih edilmesi gerekmektedir; kriter özellikle, AR(p) modelinde p 'nin yani gecikmenin uzunluğunun belirlenmesinde de kullanılmaktadır (Gujarati, 2004:537).

5.4.4. Schwarz bilgi kriteri (SIC)

Akaike Bilgi Kriterlerinden daha sert ceza uygulayan Schwarz Bilgi Kriterinin formülü Eş. 5.66'da ifade edilmiştir

$$SIC = n^{k/n} \frac{\sum \hat{u}_i^2}{n} = n^{k/n} \frac{RSS}{n} \quad (5.66)$$

Bu formülün logaritmik hali ise Eş. 5.67 gösterilmiştir burada $[(k/n)\ln n]$ ceza faktörünü ifade etmektedir. AIC gibi SIC'de de daha az SIC değerine sahip olan model seçilmesi gereken modeldir (Gujarati, 2004:538):

$$\ln SIC = \frac{k}{n} \ln n + \ln \left(\frac{RSS}{n} \right) \quad (5.67)$$

5.5. Modelin Kontrol Edilmesi / Hata Kontrolü

Modellerin öngörülerde kullanılabilmesi için bir takım şartları sağlamaları gerekmektedir. Bu şartların kontrolü ise parametre tahminlemesinden sonra yapılmakta ve modeller bu şartlara göre değerlendirilmektedir. Bu şartlar arasındaki en temel varsayımı ise ε_t 'nin beyaz gürültü, ε_t 'lerin sıfır ortalama ve sabit varyans ile korelasyonsuz rassal şoklar olması durumu, sürecindeki şartları sağlamasıdır (Wei, 2006:152). Boş hipotezin reddinin modelin geçerli olmadığını ifade ettiği tanı testleri zaman serisi analizlerinde modelin ampirik geçerliliğinin kontrolünde oldukça kullanışlıdır. Eğer modelin tanı testlerinde boş hipotez red edildi ise bu modelin yeniden düzenlenmesi gerektiğinin göstergesidir. Öte yandan bazı durumlarda birden çok model bu testleri başarı ile geçebilir bu durumda devreye modellerin öngörü performansı girmektedir ve öngörü performanslarına göre model seçimi yapılmaktadır. Heij ve diğerleri (2004:571) ARMA sürecinde geçen tüm tanı testlerini aşağıdaki gibi sıralamışlardır:

- Zaman serisinin durağanlığının test edilmesi (zaman serisinin grafiğinin oluşturulması ve serinin korelogramı)
- Uç değerlerin ve değişen varyansın test edilmesi (zaman serisine ve modelin kalıntılarına ait grafik ve histogram, modelin kalıntılarına Jarque-Bera ve Breusch-Pagan testlerinin uygulanması)
- ARMA modelinin gecikme yapısının testi (ACF, PACF, ek gecikmeler ile ilgili t ve F testleri, AIC ve SIC)
- Kalıntıların otokorelasyonlarının test edilmesi (modelin kalıntıları ile ilgili PACF, Ljung-Box Testi, Breusch-Godfrey Testi)
- Öngörü performansının değerlendirilmesi ve rakip modellerin performanslarının kıyaslanması

Kalıntıları analiz etmek için ilk adım olarak grafik araçlarını kullanmak modelin olası kusurlarını görmek için her zaman faydalıdır; kalıntıların grafiklerinin oluşturulması ortalama ve varyansı gösterirken; korelogram kalıntılar arasındaki korelasyonun kontrol edilmesi için kullanılabilir, kalıntıların histogramı normal dağılım ile karşılaştırılabilir (Heij ve diğerleri, 2004:571).

5.5.1. Jarque-Bera (JB) testi

Modelin öngörülerde kullanılabilmesi için dikkat edilmesi gereken en önemli noktalardan biri hata terimlerinin normal dağılımlı olup olmadığıdır. Normallik dağılımını ölçen birçok test bulunmaktadır ancak çalışmada diğer çalışmalarda yaygın olarak kullanılan Jarque-Bera testi kullanıldığı için bu testten bahsedilmiştir. Jarque-Bera testinin formülü 5.68’te verilmiştir (Gujarati, 2011:128):

$$JB = n \left[\frac{S^2}{6} + \frac{(K - 3)^2}{24} \right] \sim \chi^2_2 \quad (5.68)$$

Eş. 5.68’de n örneklem büyüklüğünü gösterirken, S skewness katsayısını, K ise kurtosis katsayısını ifade etmektedir, normal dağılmış değişkenler için S ’nin 0 a K ’nin ise 3’e eşit olması gerekmektedir ki bu durumda JB istatistiği 0’a eşit olur, JB testinin 0’a yaklaşması daha iyi normallik varsayımı anlamına gelmektedir (Gujarati, 2011:128).

JB testini hipotezleri S için $H_0: E(u_t^s)^3 = 0$ ve $H_1: E(u_t^s)^3 \neq 0$ iken K için $E(u_t^s)^4 = 3$ ve $E(u_t^s)^4 \neq 3$ 'dir. H_0 hipotezinin ret edilememesi hataların normal dağıldığının göstergesi iken, hipotezin ret edilmesi hataların normal dağılmadığının göstergesidir. Hataların normal dağılım göstermemesi modelin öngörü için uygun olmadığını gösterdiği için bu durumda modelin tekrar kurulması gerekmektedir (Lütkepohl ve Krätzig, 2004:46).

5.5.2. Breusch-Pagan-Godfrey (BPG) testi

Breusch-Pagan-Godfrey testi, boş hipotezin kalıntılarda değişen varyansın olmadığı durumu ifade ettiği alternatif hipotezinde ise kalıntılarda değişen varyansın olduğu durumu ifade ettiği Lagrange çarpanı testidir.

BPG testinin çalışma mantığında yardımcı regresyonlardan faydalanılmaktadır. Test edilen modelden elde edilen kalıntıların test edilen modelde yer alan açıklayıcı değişken ve p dereceye kadar kalıntıların gecikmelerinin alınıp regresyona tabi tutulması ile test uygulanmaktadır. Testin değerlendirilmesi aşamasında dikkat edilmesi gereken nokta testin test istatistiğinin p serbestlik derecesi ile χ^2 dağılımına sahip olduğu ve yardımcı regresyonun çoklu korelasyon katsayısı R^2 ile T'nin (gözlem sayısı) çarpılması ile elde edilmiştir. Hesaplanan test istatistiği değeri χ^2 değerinden daha küçük bir değere sahip ise H_0 hipotezi ret edilir yani veri setinde değişen varyans vardır. Hesaplanan test istatistiği değeri χ^2 değerinden daha büyük bir değere sahip ise H_0 hipotezi ret edilemez yani veri setinde değişen varyans yoktur. Bu testin bir başka uygulanma şekli ise yardımcı regresyondaki gecikmesi alınmış tüm kalıntıların anlamlılığını test etmek için F testinin kullanılmasıdır (Kirchgässner ve Wolters, 2007:18).

5.6. Örneklem Dışı Öngörüler Temelinde Model Seçim Kriterleri

Model seçimi aşamasında birden fazla modelin geçerlilikleri sağlanması modeller arasında seçim yapma noktasında farklı kriterleri de eklemeyi gerektirmektedir. Bu kriterlerinden biri de modelin gerçekleşen değerleri ne kadar doğruluk payı ile öngörebildiğidir. Doğruluk payının ölçülebilmesi için veri seti modeli oluşturmak için ‘tahmin örnekleme’ ve öngörülerin değerlendirilmesi için ‘öngörü örnekleme’ olmak üzere iki kısma ayrılır. Sadece tahmin örnekleme kullanılarak modeller tahmin edilir ve sonrasında tahmin edilen modeller öngörü örneklemindeki y değerlerini öngörü için kullanılır. Olası değerlendirme kriterleri ortalama karesel hatanın karekökü (RMSE), ortalama mutlak hata (MAE) ve ortalama mutlak yüzde hatalarıdır (MAPE). Kriterlerin formülleri Eş. 5.69, Eş. 5.70 ve Eş. 5.71’de ifade edilmiştir (Heij ve diğerleri, 2004:280, Tsay, 2002:163).

$$RMSE = \left(\frac{1}{n_f} \sum_{i=1}^{n_f} (y_i - \hat{y}_i)^2 \right)^{1/2} \quad (5.59)$$

$$MAE = \frac{1}{n_f} \sum_{i=1}^{n_f} |y_i - \hat{y}_i| \quad (5.60)$$

$$MAPE = \frac{1}{n_f} \sum_{i=1}^{n_f} \left| \frac{\hat{y}_i}{y_i} - 1 \right| \quad (5.61)$$


Eşitliklerde n_f gözlem sayısını ifade ederken \hat{y}_i tahmin edilen değerleri ifade etmektedir (Heij ve diğerleri, 2004:280). Uygulamada Eş. 5.59, Eş. 5.60 ya da Eş. 5.61’den herhangi biri seçildiğinde, seçilen kriter her bir modele uygulanmakta ve elde edilen değerlerden en küçük olanı en iyi model olarak seçilmektedir (Tsay, 2002:163).

6. ARAŞTIRMA BULGULARI

Araştırmada kullanılacak olan veri seti Deniz Ticareti Genel Müdürlüğü İstatistik Bilgi Sisteminden elde edilmiştir. Sitede yer alan konteyner istatistikleri sekmesi kullanılarak 2004-2018 yıllarına ait hazırlanan aylar bazında elleçleme excel dosyalarından aylar ve TEU bazında toplam ihracat ve ithalat istatistikleri elde edilmiştir. Toplam elleçlemelere kabotaj ve transit yükler dahil edilmemiştir. Ayrıca modelde olağan ekonomik koşulların sabit kaldığı varsayılmıştır. Çalışmanın amacı Türkiye'nin 2018'in son üç ayı ve 2019 yılı için aylık konteyner elleçleme öngörüsü oluşturmaktır. Yapılmak istenen öngörü kısa vadeli öngörü olduğu için bu gibi durumlarda en çok kullanılan ve daha doğru sonuçlar ortaya koyan öngörü yöntemi olan mevsimsel ARIMA modeli uygulanmak istenmiş ancak veri setinin analizi ile en uygun modelin kukla değişkenleri, deterministik trend ve mevsimselliği içeren otoregresif hareketli ortalama modeli olduğu ortaya koyulmuştur. Çalışmada öncelikle 2004'ün ilk ayından 2017'nin son ayına kadar olan veri seti kullanılarak model oluşturulmuş, oluşturulan model üzerinden 2018 yılının ilk dokuz ayı için öngörü yapılmış ve yapılan öngörü 2018'in ilk dokuz ayına ait gerçek değerleri ile karşılaştırılmıştır. Modelin tutarlı sonuçlar göstermesinin ardından, 2004'ün ilk ayından 2017'nin son ayına kadar olan veri ile 2018 yılının son üç ayı ve 2019 yılı için aylık öngörü yapılmıştır. Analizler için EViews programı kullanılmıştır.

6.1. Grafik ve Korelogram Analizi

Box – Jenkins yönteminin uygulanması için ilk şart serinin durağan olmasıdır. Durağan olmayan bir seriye bu yöntem uygulanamamaktadır. Bu yüzden Box – Jenkins yönteminin ilk aşaması olan modelin tanımlanması aşamasında ilk yapılacaklardan biri veri setinin grafiğine bakarak veri setinin durağanlığı, yapısı hakkında ön bilgi edinmektir. Grafik (Şekil 6.1) incelendiğinde serinin artan bir trende sahip olduğu ve durağan olmadığı izlenimi uyanmaktadır. Grafiğin aylara göre değişimi incelendiğinde 1. ve 2. aylar yıl bazında elleçlemenin en düşük olduğu aylar olarak gözlenmektedir. Veri setinin belli dönemlerde benzer davranışlar sergilemesi mevsimsellik şüphesi uyandırmaktadır. Grafikte dikkat çeken bir başka nokta ise belli dönemlerde elleçlemenin düşmesi ve düşüş sonrası yükselme eğilimine devam etmesidir. Bu durumun veri setinde meydana gelen kırılmaların göstergesi olma ihtimali oldukça yüksektir.



Şekil 6.1. Veri setinin grafiği

Grafiğin incelenmesi ile edinilen ön bilgiden sonra daha detaylı bilgilere ulaşabilmek için yapılabilecek bir diğer işlem veri setinin korelogramının incelenmesidir. Veri setinin korelogramını incelemek ilk inceleme için serinin durağan olup olmadığının göstergesi olurken durağan olduğuna karar verilen bir seri için gecikmelerin sayısı ve gecikmelerin otoregresif sürece mi yoksa hareketli ortalamalar sürecine mi dahil olduğu ile ilgili varsayımda bulunulmasına katkı sağlar.

Çizelge 6.1. Veri setini korelogramı

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.943	0.943	152.11	0.000	
2	0.915	0.232	296.19	0.000	
3	0.882	0.001	430.74	0.000	
4	0.852	0.007	557.07	0.000	
5	0.832	0.097	678.43	0.000	
6	0.808	-0.004	793.52	0.000	
7	0.795	0.081	905.53	0.000	
8	0.774	-0.018	1012.6	0.000	
9	0.763	0.066	1117.2	0.000	
10	0.756	0.076	1220.4	0.000	
11	0.745	0.014	1321.5	0.000	
12	0.743	0.070	1422.6	0.000	
13	0.709	-0.251	1515.2	0.000	
14	0.685	-0.041	1602.3	0.000	
15	0.656	-0.038	1682.7	0.000	
16	0.638	0.079	1759.2	0.000	
17	0.624	0.034	1832.9	0.000	
18	0.602	-0.057	1901.9	0.000	
19	0.591	0.028	1968.9	0.000	
20	0.572	-0.006	2032.1	0.000	
21	0.561	0.014	2093.3	0.000	
22	0.551	0.009	2152.7	0.000	
23	0.540	0.002	2210.1	0.000	
24	0.534	0.031	2266.7	0.000	
25	0.500	-0.165	2316.7	0.000	
26	0.478	-0.029	2362.6	0.000	
27	0.454	0.028	2404.4	0.000	
28	0.437	0.012	2443.4	0.000	
29	0.432	0.099	2481.8	0.000	
30	0.416	-0.038	2517.6	0.000	
31	0.406	-0.019	2551.9	0.000	
32	0.392	0.004	2584.1	0.000	
33	0.386	0.040	2615.6	0.000	
34	0.372	-0.064	2645.1	0.000	
35	0.371	0.103	2674.6	0.000	
36	0.366	-0.005	2703.6	0.000	

Korelogram (Çizelge 6.1) incelendiğinde ilk dikkat çeken nokta otokorelasyonların yavaş yavaş azaldığı ve sıfırı kesmediğidir. Bu durum veri setinin durağan olmadığı bir göstergesidir. Serinin durağan olmadığı konusunda şüpheler artarken durağan olup olmadığı noktasında kullanılacak bir diğer yöntem ise seriye durağanlık testlerinin yapılmasıdır.

6.2. Durağanlık Testleri

Veri setinin durağanlığını test etmek amacıyla veri setine Augmented Dickey-Fuller (ADF), Phillips-Perron (PP), Dickey-FullerGLS (DF-GLS) ve Kwiatkowski-Phillips-Schmidt-Shin (KPSS) testleri uygulanmıştır. Testler ADF ve PP için sadece sabitin olduğu, trend ve sabitin birlikte olduğu ve trend ve sabitin olmadığı durumlar için yapılırken DF-GLS ve KPSS için sadece sabitin olduğu ve trend ve sabitin birlikte olduğu durumlar için yapılmıştır.

Çizelge 6.2’de tüm testler tek bir tabloda gösterilmiştir. Tabloda durumlara göre %1, %5 ve %10 için kritik değerler, test istatistiği ve olasılık değerleri belirtilmiş olup serinin durağanlığının ortaya koyulduğu sonuçların belli olması için o sonuçlarda kalın harfler kullanılmıştır. Testlerle ilgili ayrıntılı açıklamalar ise aşağıdadır.

ADF testinde H_0 hipotezi birim kökün varlığını yani veri setinin durağan olmadığını ifade ederken alternatif hipotez birim kökün olmadığını yani veri setinin durağan olduğunu ifade etmektedir. Seriyeye uygulanan ADF testi sonuçları (Çizelge 6.2) sadece sabitin olduğu, trend ve sabitin birlikte olduğu ve trend ve sabitin olmadığı durumlar için sırasıyla 0,9598, 0,0025 ve 0,9973 olasılık değerleri ile %1 anlamlılık düzeyinde sadece sabitin olduğu ve trend ve sabitin olmadığı durumlar için H_0 hipotezinin ret edilemediğini, trend ve sabitin birlikte olduğu durum için H_0 hipotezinin ret edildiğini göstermektedir. Trend ve sabitin bulunduğu durumda H_0 hipotezinin ret edilmesi, trend ve sabitin bulunduğu durumda serinin durağan olduğunun göstergesidir.

Çizelge 6.2. Birim kök testlerinden elde edilen bulgular

Durumlara göre %1, %5 ve %10 seviyelerinde göre kritik değerler														
Sabitin dikkate alındığı durum			Sabit ve doğrusal trendin dikkate alındığı durum			Sabit ve doğrusal trendin dikkate alınmadığı durum			Uygulanan Testler					
%1	%5	%10	%1	%5	%10	%1	%5	%10	ADF	PP	DF-GLS	KPSS	t-İstatistik	Olasılık Değeri
-3,472813	-2,880088	-2,576739	-	-	-	-	-	-	X	-	-	-	0,038004	0,9598
-	-	-	-4,014288	-3,437122	-3,142739	-	-	-	X	-	-	-	-4,437250	0,0025
-	-	-	-	-	-	-2,579967	-1,942896	-1,615342	X	-	-	-	2,535647	0,9973
-3,469691	-2,878723	-2,576010	-	-	-	-	-	-	-	X	-	-	-1,095832	0,7171
-	-	-	-4,013946	-3,436957	-3,142642	-	-	-	-	X	-	-	-6,607882	0,0000
-	-	-	-	-	-	-2,578883	-1,942745	-1,615438	-	X	-	-	2,978597	0,9993
-2,579967	-1,942896	-1,615342	-	-	-	-	-	-	-	-	X	-	2,077648	%10 <
-	-	-	-3,500800	-2,964000	-2,674000	-	-	-	-	-	X	-	-3,886920	< %1
0,739000	0,463000	0,347000	-	-	-	-	-	-	-	-	-	X	1,601247	< %1
-	-	-	0,216000	0,146000	0,119000	-	-	-	-	-	-	X	0,071298	%10 <

PP testinde H_0 hipotezi birim kökün varlığını yani veri setinin durağan olmadığını ifade ederken alternatif hipotez birim kökün olmadığını yani veri setinin durağan olduğunu ifade etmektedir. Seriyeye uygulanan PP testi sonuçları (Çizelge 6.2) sadece sabitin olduğu, trend ve sabitin birlikte olduğu ve trend ve sabitin olmadığı durumlar için sırasıyla 0,7171, 0,0000 ve 0,9993 olasılık değerleri ile %1 anlamlılık düzeyinde sadece sabitin olduğu ve trend ve sabitin olmadığı durumlar için H_0 hipotezinin ret edilemediğini, trend ve sabitin birlikte olduğu durum için H_0 hipotezinin ret edildiğini göstermektedir. PP testinde de ADF testiyle benzer sonuç elde edilmiştir. Sonuç olarak trend ve sabitin bulunduğu durumda H_0 hipotezinin ret edilmesi, PP testinde de trend ve sabitin bulunduğu durumda serinin durağan olduğunun göstergesidir.

DF-GLS testinde H_0 hipotezi birim kökün varlığını yani veri setinin durağan olmadığını ifade ederken alternatif hipotez birim kökün olmadığını yani veri setinin durağan olduğunu ifade etmektedir. DF-GLS testinde ADF ve PP testlerinde olduğu gibi olasılık değerleri bulunmamaktadır. Bu testteki yorumlar kritik değer ve anlamlılık düzeyleri üzerinden yapılmaktadır. Sadece sabitin bulunduğu durum için test istatistiği 2,077648 olup %10'luk anlamlılık düzeyindeki -1,615438 kritik değerinden oldukça büyüktür (Çizelge 6.2). Bu durum H_0 hipotezinin %10'luk anlamlılık düzeyinde ret edilemeyeceğini gösterirken veri setinin durağan olmadığını ifade etmektedir. Trend ve sabitin birlikte olduğu durum için test istatistiği -3,886920 olup %1'lik anlamlılık düzeyindeki -3,500800 kritik değerinden küçüktür (Çizelge 6.2). Bu durum H_0 hipotezinin %1'lik anlamlılık düzeyinde ret edildiğini gösterirken veri setinin trend ve sabitin birlikte olduğu durum için durağan olduğunu ifade etmektedir.

KPSS testinde diğer testlerden farklı olarak H_0 hipotezi birim kökün olmadığını yani veri setinin durağan olduğunu ifade ederken alternatif hipotez birim kökün varlığını yani veri setinin durağan olmadığını ifade etmektedir. KPSS testi diğer testlerin sağlaması olarak da düşünülmektedir. KPSS testinde DF-GLS testinde de olduğu gibi olasılık değerleri bulunmamaktadır. KPSS testinde de yorumlar kritik değer ve anlamlılık düzeyleri üzerinden yapılmaktadır.

Sadece sabitin bulunduğu durum için test istatistiği 1,601247 olup %1'lik anlamlılık düzeyindeki 0,739000 kritik değerinden oldukça büyüktür (Çizelge 6.2). Bu durum H_0 hipotezinin %1'lik anlamlılık düzeyinde ret edildiğini gösterirken veri setinin durağan olmadığını ifade etmektedir. Trend ve sabitin birlikte olduğu durum için test istatistiği 0,071298 olup %10'luk anlamlılık düzeyindeki 0,119000 kritik değerinden küçüktür (Çizelge 6.2). Bu durum H_0 hipotezinin %10'luk anlamlılık düzeyinde ret edilemediğini gösterirken veri setinin durağan olduğunu ifade etmektedir.

ADF, PP, DF-GLS ve KPSS testlerinin ortak noktası serileri durağan olmamaya iten durumun trendin varlığı olarak göstermesidir. Bu da seriden trendin çıkarılması durumunda serinin durağanlaşacağını göstergesidir. Bu noktada serinin durağan olmamasının kaynağının trend olması durumunda serinin farkını almanın yanlış bir uygulama olacağını olması gerekenin trendden arındırmak olması gerektiğini hatırlatmak uygun olacaktır.

6.3. Trendin Varlığının Ortaya Konulması


Zaman serisinin durağanlığının incelenmesi için yapılan çalışmalarda serinin trend bileşeni içerdiğine ve bu trendin ayıklanması durumunda serinin durağanlaşacağına dair çıkarımlarda bulunulmuştu. Şimdi ise bu çıkarımın geçerliliğini test etmek için önce zaman serisinin bağımlı değişken, trend ve sabitin ise bağımsız değişken olduğu bir model kurularak trend bileşenin anlamlılığına bakılacak devamında ise kurulan modelin durağanlığına bakılacaktır.

Çizelge 6.3. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken olduğu regresyon analizi sonucu

Bağımsız Değişken	Katsayı	Standart Hata	t-İstatistik	Olasılık Değeri
C (Sabit)	225468,3	5759,616	39,14641	0,0000
@TREND (Trend Bileşeni)	2598,356	59,64699	43,56224	0,0000

Çizelge 6.3'te yer alan toplam ithalat ihracat elleçlemesinin bağımlı değişken, sabit ve trendin bağımsız değişken olduğu regresyon analizinde R^2 'nin değeri 0,92'dir. R^2 değerinin bu kadar büyük çıkması trendin elleçlemenin büyük bir kısmını açıkladığının göstergesidir. Ayrıca trende ait olasılık değerinin 0,0000 oluşu regresyonda trendin anlamlı bir değer taşıdığını ifade etmektedir.


Trendin elleçlemede önemli bir yere sahip olduğunun bulunmasından sonra bir diğer önemli nokta regresyona konularak bir nevi ayıklanan trend bileşeninden arta kalan hataların hala durağan olmayan davranışlar sergileyip sergilemediğidir. Bunun cevabını bulmak için ise regresyondan çekilen hataların grafiğine ve korelogramına bakılacak sonrasında ise durağanlık testleri uygulanacaktır.



Şekil 6.2. Çizelge 6.3'te yer alan regresyona ait kalıntıların grafiği

Şekil 6.2 kalıntıların grafiğini göstermektedir. Grafik incelendiğinde kalıntıların durağan olduğu izlenimi uyanmaktadır. Grafikte dikkat çeken bir başka nokta da kalıntılarda kırılmanın meydana geldiğidir. Bu durumun kesinleştirilmesi için veri setine kırılma testi uygulanacaktır. Kırılmanın var olduğuna dair izlenim veri seti ilk incelendiğinde de oluşmuştu. Ayrıca belirtmelidir ki grafiğe bakmak ön fikir elde etmek içindir daha detaylı bilgi korelogramın incelenmesinden ve testlerin uygulanmasından sonra elde edilecektir.

Çizelge 6.4. Çizelge 6.3'te yer alan regresyona ait kalıntıların korelogramı



Çizelge 6.4'te regresyondan çekilen kalıntıların korelogramını gösterilmektedir. Korelogramda otokorelasyonlar yavaş yavaş değil hızlı bir şekilde azalmakta ve sıfırı kesmektedir. Bu durum durağanlığın göstergesidir. Durağanlığın analizinde kullanılan bir başka yöntem daha önce de bahsedildiği üzere durağanlık testlerinin uygulanmasıdır.

Çizelge 6.5 regresyondan çekilen hatalara uygulanan durağanlık testlerinin sonuçlarını göstermektedir. Bu çizelgede dört testle de uyum sağlaması açısından sadece sabitin dikkate alındığı durum kullanılmıştır.

Çizelge 6.5. Çizelge 6.3'te yer alan regresyon analizinden çekilen hataların durağanlık analizi

Sabitin dikkate alındığı durum			Uygulanan Testler					
%1	%5	%10	ADF	PP	DF-GLS	KPSS	t-İstatistik	Olasılık Değeri
-3,469933	-2,878829	-2,576067	X	-	-	-	-4,449918	0,0004
-3,469691	-2,878723	-2,576010	-	X	-	-	-6,627204	0,0000
-2,578967	-1,942757	-1,615431	-	-	X	-	-3,051449	< %1
0,739000	0,463000	0,347000	-	-	-	X	0,071298	>%10

Çizelge 6.5'te açıkça görülmektedir ki regresyondan çekilen hatalar durağanlık özelliği göstermektedir yani trend bileşenini bağımlı değişkenden ayırmak - regresyonda bağımsız değişken olarak trend eklendiğinde bağımlı değişkenin içerisindeki, bağımlı değişkeni etkileyen etkenlerden biri belirlenmiş ve etkisi ayrıştırılmış olur - seriyi durağanlaştırmaktadır.

Yapılan üç uygulama kalıntılarının durağanlığını göstermektedir. Verideki durağan olmama durumu trendden kaynaklı olduğu durumda seride trendin etkisini yok etmek için trendden ayıklama işlemi uygulanır. Ancak bu çalışmada seriyi trendden ayıklama yöntemi yerine trendi bir bileşen olarak denkleme dâhil etme yolu izlenmiştir. Amaç trendin etkisinin öngörüye direkt olarak yansımalarının istenmesidir.

Seriye trend değişkeninin eklenmesi ile serinin durağan hale gelmesi seride yer alan trendin deterministik trend olduğunu göstermektedir. Deterministik trendin eklenmesi ile durağan olmama durumu değişmeseydi bu durumda seride stokastik trendin varlığından söz edilecek ve seriyi durağanlaştırmak için fark alma işlemi uygulanacaktı.

6.4. Deterministik Mevsimselliğin Ortaya Çıkarılması

Trendin ortaya konmasından sonra seride aranacak bir başka bileşen mevsimselliklidir. Deterministik mevsimselliğin varlığının ortaya konması için ise mevsimsel kukla değişkenlerin oluşturulması gerekmektedir. Kukla değişkenler her ay için ayrı olmak üzere toplam on iki adet oluşturulmuştur. Örneğin ocak ayı için kukla değişken oluşturulurken ocak ayı için yapılan gözlemler 1 ile ifade edilirken diğer aylara denk gelen gözlem 0 olarak ifade edilmiştir. Bu sistem diğer aylar için de aynı şekilde uygulanmıştır.

Kukla değişkenler oluşturulurken dikkat edilmesi gereken en önemli noktalardan biri her ay için ayrı ayrı kukla değişkenlerin oluşturulması durumunda sabit terimin modelden çıkarılması gerektiğidir. Eğer sabit terim çıkarılmaz ise bu durumda kukla değişkenlerden birinin modele eklenmemesi gerekir. Bu çalışmada her ay için ayrı ayrı kukla değişken oluşturulmasından dolayı sabit terim regresyondan çıkarılmıştır. Çalışmada D1 ile ifade edilen değişken ocak ayını ifade ederken D2'den D12'ye kadar devam eden değişkenler sırasıyla diğer ayları ifade etmektedir. Çalışmada her ay için ayrı kukla değişken oluşturulmasının sebebi ise aylık veri seti kullanılmasıdır.

Çizelge 6.6. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin bağımsız değişken olduğu regresyon sonuçları

Bağımsız Değişken	Katsayı	Standart Hata	t-İstatistik	Olasılık Değeri
@TREND (Trend Bileşeni)	2587,372	52,83704	48,96890	0,0000
D1 (Ocak)	199556,9	9766,138	20,43356	0,0000
D2 (Şubat)	180044,4	9788,552	18,39336	0,0000
D3 (Mart)	230436,0	9811,200	23,48704	0,0000
D4 (Nisan)	228378,0	9834,079	23,22312	0,0000
D5 (Mayıs)	252183,3	9857,189	25,58370	0,0000
D6 (Haziran)	243881,2	9880,527	24,68302	0,0000
D7 (Temmuz)	240038,5	9904,092	24,23630	0,0000
D8 (Ağustos)	241225,2	9927,882	24,29775	0,0000
D9 (Eylül)	218894,8	9951,896	21,99529	0,0000
D10 (Ekim)	234283,5	9976,132	23,48440	0,0000
D11 (Kasım)	215992,5	10000,59	21,59798	0,0000
D12 (Aralık)	231711,4	10025,26	23,11275	0,0000

Çizelge 6.6'da yer alan regresyon sonuçları mevsimsel kukla değişkenlerinin anlamlılığını ortaya koyarken deterministik trendin varlığını ifade etmektedir. Değişkenlerin anlamlı olduğu sonucuna $H_0 = 0$ ve $H_1 \neq 0$ hipotezleri altında olasılık değerlerinin 0,000 oluşundan ve bu olasılık değeri sonucunda H_0 hipotezinin ret edilmesinden ulaşılmaktadır, burada uygulanan test ise tablodan da açıkça görülebileceği gibi t-testidir. Mevsimsel kukla değişkenlerin eklenmesiyle 0,92 olan R^2 değeri 0,94'e yükselmiş ve modelin bağımlı değişkeni açıklama oranı biraz daha artmıştır. Ayrıca bir diğer önemli nokta olan deterministik mevsimselliği modelden arındırma ya da modele dahil etme hususunda deterministik trendde uygulandığı gibi deterministik mevsimsellikte de arındırma işlemi değil modele dahil etme işlemi uygulanacaktır.

6.5. Veri Setine Yapısal Kırılma Testinin Uygulanması

Veri setinin ilk hali incelendiğinde ve daha sonra trendin varlığına dair inceleme yaparken kalıntıların incelemesi sırasında dikkat çeken kalıntılardaki kırılmanın varlığının tespit edilmesi için modele çoklu kırılma noktası testi olan Bai-Perron testi uygulanmıştır.

Bai-Perron testi toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin bağımsız değişken olduğu durum için uygulanmış ve sonuç olarak test farklı kırılma noktaları bulmuştur. Bulunan kırılma noktaları kukla değişkenler haline getirilip modele eklenmiş ve anlamlı olan kukla değişkenler modele dâhil edilmiştir.

Kırılma noktalarının modele dâhil edilmesi için oluşturulan kukla değişkenler mevsimsel kukla değişkenlerin oluşturulması mantığına dayanmaktadır. Burada önemli olan nokta olayın gerçekleştiği yani kırılmanın olduğunun var sayıldığı tarihten itibaren 1 değerini vermek öncesini ise 0 değerini vermektir.

Kırılma noktası olarak test 2008'in 12. ayına, 2014'ün 10. ayına, 2012'nin 7. ayına ve 2015'in 1. ayına işaret etmektedir. Tüm bu noktalardan oluşan kukla değişkenlerin modele konması ile 2008'in 12. ayına ve 2015'in 1. ayına işaret eden kırılma noktaları model içerisinde anlamlı bulunmuş ve modele eklenmiştir (Çizelge 6.7). 2008'in 12. ayında olan kırılmanın sebebi 2008 krizine bağlanırken ve 2015'in 1. ayında olan kırılma noktası özellikle denizcilik sektörünü etkileyen krize bağlanmıştır.

Bölüm 2'de yer alan istatistikler hem 2008 krizi zamanında hem de 2015 yılı için tüm dünyada düşüş yaşandığını göstermektedir.

Çizelge 6.7. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin ve yapısal kırılma kuklalarının bağımsız değişken olduğu regresyon sonuçları

Bağımsız Değişken	Katsayı	Standart Hata	t-İstatistik	Olasılık Değeri
@TREND (Trend Bileşeni)	3781,794	101,4098	37,29218	0,0000
D1 (Ocak)	183543,4	7052,009	26,02711	0,0000
D2 (Şubat)	162836,4	7087,520	22,97509	0,0000
D3 (Mart)	212033,7	7124,299	29,76204	0,0000
D4 (Nisan)	208781,2	7162,324	29,14992	0,0000
D5 (Mayıs)	231392,1	7201,576	32,13076	0,0000
D6 (Haziran)	221895,6	7242,036	30,63995	0,0000
D7 (Temmuz)	216858,5	7283,684	29,77319	0,0000
D8 (Ağustos)	216850,8	7326,498	29,59814	0,0000
D9 (Eylül)	193325,9	7370,459	26,22983	0,0000
D10 (Ekim)	207520,2	7415,546	27,98448	0,0000
D11 (Kasım)	188034,8	7461,739	25,19986	0,0000
D12 (Aralık)	209594,6	7388,740	28,36676	0,0000
2008 Krizi	-98494,97	7818,017	-12,59846	0,0000
Sektörel Kriz	-64554,82	7258,441	-8,893758	0,0000

Çizelge 6.7’de yer alan regresyonun sonuçları incelendiğinde daha önce de belirtildiği gibi yapısal kırılmalara bağlı oluşturulan kuklalar 0,0000 olasılık değerleri ile anlamlı bulunmuştur, burada da diğer regresyonlardaki bağımsız değişkenlerin anlamlılığını test ederken olduğu gibi $H_0 = 0$ ve $H_1 \neq 0$ hipotezleri ve t-testi kritik değerleri ışığında anlamlılık test edilmiştir. Ayrıca kırılmalar için eklenen kukla değişkenler 0,94 olan R^2 değerini 0,97’ye yükseltmiştir.

6.6. Otoregresif (AR) ve Hareketli Ortalama (MA) Terimlerinin Modele Eklenmesi

Uygulamaya başlarken de belirtildiği üzere bu model oluşturulurken mevsimsel ARIMA modeli olur mu düşüncesi ile yola çıkılmıştı. Ancak modelin yapısı trendin, mevsimsellikten ve yapısal kırılmalardan kaynaklı kukla değişkenlerin, otoregresif (AR) ve hareketli ortalama (MA) terimlerinin yer aldığı modelin kurulmasının daha uygun olacağını gösterdi. ARIMA modeli ile ARMA modeli arasındaki fark ilk veri setinin durağan olmaması ve bu durağanlığın kaynağının stokastik trend olması sebebiyle farkının alınmasıdır. ARMA modeli fark alınmamış model iken ARIMA modeli farkın alındığı modeldir.

Çizelge 6.8. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trendin, yapısal kırılma kuklalarının, AR(1), AR(2) ve AR(3) terimlerinin bağımsız değişken olduğu regresyon sonucunun korelogramı

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob*
		1	-0.011	-0.011	0.0216
		2	-0.035	-0.035	0.2303
		3	-0.022	-0.023	0.3129
		4	0.020	0.018	0.3829
		5	-0.030	-0.031	0.5430
		6	-0.041	-0.041	0.8363
		7	0.025	0.022	0.9440
		8	-0.071	-0.076	1.8474
		9	-0.098	-0.100	3.5677
		10	-0.054	-0.061	4.0854
		11	-0.056	-0.074	4.6539
		12	0.417	0.419	36.524
		13	-0.054	-0.065	37.066
		14	-0.085	-0.090	38.420
		15	-0.194	-0.238	45.434
		16	-0.090	-0.164	46.968
		17	0.042	0.083	47.308
		18	-0.153	-0.160	51.783
		19	-0.000	-0.031	51.783
		20	-0.050	-0.035	52.268
		21	-0.094	-0.072	53.974
		22	-0.090	-0.067	55.546
		23	0.056	0.040	56.156
		24	0.325	0.106	77.157
		25	0.015	0.050	77.205
		26	-0.087	-0.116	78.735
		27	-0.104	-0.044	80.933
		28	-0.113	-0.135	83.559
		29	0.103	0.014	85.734
		30	-0.114	-0.075	88.416
		31	0.045	-0.033	88.829
		32	-0.060	-0.050	89.578
		33	-0.034	-0.041	89.821
		34	-0.073	-0.068	90.946
		35	0.077	0.005	92.223
		36	0.262	0.012	107.02

Bu çalışmada kullanılan veri setinin ilk hali durağan değildi ancak durağan olmamasının sebebi stokastik trendden ziyade deterministik trend idi. Durum böyle olunca fark alma işlemine gerek kalmadı ve sorun trend değişkeninin modele eklenmesi ile çözüldü.

Mevsimsellik ile ilgili soru işaretlerinin oluşmasındaki ana sebep modele tren, yapısal kırılma kuklaları ve otoregresif (AR) bağımsız değişkenler eklendikten sonra korelogramda on ikinci gecikmeye ait otokorelasyonda ve on ikinin katlarında yer alan otokorelasyonlarda yer alan yüksek korelasyon ve bu korelasyonlarda gözlemlenen düzenli yavaş azalmadır (Çizelge 6.8). Bu gözlemin ardından mevsimsellik kısmı ile ilgili mevsimselliğin deterministik mi yoksa stokastik mi olduğu ile ilgili sorular açığa çıkmış ve cevaplarını bulmak için modele mevsimsel kukla değişkenler eklenmiştir.

Otoregresif ve hareketli ortalamaların gecikmelerine karar verildiği bir noktada böyle bir durumun yaşanmasının ardından modelin oluşturulması için trend değişkeninin eklenme aşamasına dönülmüş ve trendden sonra mevsimsel kukla değişkenler eklenerek model kurmaya devam edilmiştir. Mevsimsel kukla değişkenlerin eklenmesinin ardından yapısal kırılma kuklalarının eklenmesi ile modele otoregresif ve hareketli ortalamaların gecikmelerinin eklenerek ARMA modelinin oluşturulmasına geçilmiştir.

ARMA modelinin oluşturulması aşamasında öncelikle korelograma bakmak yapısını incelemek ve inceleme sonucunda gecikmelere karar vermek ön fikir elde etme açısından faydalıdır. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin ve yapısal kırılma kuklalarının bağımsız değişken olduğu regresyona ait korelogram Çizelge 6.9'da gösterilmektedir.

Çizelge 6.9. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin ve yapısal kırılma kuklalarının bağımsız değişken olduğu regresyona ait korelogram

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.348	0.348	20.701	0.000
		2	0.382	0.296	45.747	0.000
		3	0.149	-0.059	49.597	0.000
		4	-0.045	-0.228	49.947	0.000
		5	-0.151	-0.155	53.918	0.000
		6	-0.070	0.131	54.779	0.000
		7	-0.119	0.029	57.278	0.000
		8	-0.051	-0.035	57.743	0.000
		9	-0.005	-0.013	57.748	0.000
		10	0.078	0.105	58.846	0.000
		11	0.024	-0.025	58.947	0.000
		12	0.071	-0.025	59.872	0.000
		13	-0.136	-0.238	63.281	0.000
		14	-0.086	-0.010	64.648	0.000
		15	-0.271	-0.124	78.310	0.000
		16	-0.206	-0.036	86.275	0.000
		17	-0.139	0.072	89.941	0.000
		18	-0.146	-0.086	93.975	0.000
		19	-0.088	-0.083	95.476	0.000
		20	-0.016	-0.029	95.528	0.000
		21	0.008	0.063	95.540	0.000
		22	0.034	0.003	95.765	0.000
		23	0.098	0.047	97.672	0.000
		24	-0.012	-0.134	97.700	0.000
		25	-0.056	-0.071	98.336	0.000
		26	-0.093	-0.061	100.06	0.000
		27	-0.155	-0.045	104.92	0.000
		28	-0.133	-0.074	108.54	0.000
		29	0.008	0.105	108.55	0.000
		30	-0.017	-0.014	108.61	0.000
		31	0.019	-0.143	108.69	0.000
		32	0.028	-0.078	108.86	0.000
		33	0.076	0.074	110.08	0.000
		34	0.011	-0.010	110.11	0.000
		35	0.095	0.013	112.05	0.000
		36	-0.076	-0.166	113.30	0.000

Çizelge 6.9 incelendiğinde otokorelasyonlarda gözlemlenen artıp azalan kıvrımlardan otoregresif gecikmelerin model için daha uygun olduğu gözlenmektedir. Kısmi otokorelasyonlar incelendiğinde ise otoregresif gecikmelerin 1., 2. ve 4. gecikmeleri içine aldığı düşüncesi uyanmaktadır. Bu gözlemler modeli oluştururken ön fikir elde etme hususunda değer kazanmaktadır. Ancak modelin oluşturulması sırasında birçok alternatif düşünülüp, alternatifler modelleştirilip ölçütler ışığında değerlendirilmelidir.

Çalışma kapsamında ilk olarak dokuz adet model oluşturulmuştur. Oluşturulan dokuz modelin hepsinde temel değişkenler olarak trend, mevsimsel kukla değişkenler ve yapısal kırılma kuklaları kullanılmış, temel değişkenlere AR ve MA terimleri eklenerek modeller oluşturulmuştur.

AR ve MA terimleri eklenirken özellikle korelogramdan yararlanılmış gecikmelerdeki anlamlılıklara bakılarak terimler eklenmiştir. Oluşturulan dokuz modelde yer alan AR ve MA terimleri Çizelge 6.10'da gösterilmiştir.

Çizelge 6.10. Modellerde kullanılan AR ve MA terimleri

	Otoregresif (AR)			Hareketli Ortalama (MA)			
Model 1 (M1)	AR(1)	AR(2)	AR(4)				
Model 2 (M2)					MA(2)		
Model 3 (M3)	AR(1)				MA(1)	MA(2)	
Model 4 (M4)	AR(1)	AR(2)	AR(16)		MA(4)	MA(5)	MA(15) MA(27)
Model 5 (M5)	AR(1)	AR(2)	AR(4)	AR(15)	MA(5)	MA(13)	
Model 6 (M6)	AR(1)	AR(2)	AR(4)		MA(5)	MA(15)	
Model 7 (M7)	AR(1)	AR(2)			MA(4)	MA(5)	MA(15)
Model 8 (M8)	AR(2)	AR(4)			MA(1)		
Model 9 (M9)	AR(2)	AR(4)			MA(1)	MA(5)	MA(15) MA(16)

Modele ait Akaike ve Schwarz bilgi kriterleri değerlendirilmeden önce ilk olarak modellerle 2004'ün birinci ayından 2017'nin on ikinci ayına kadar uzanan gözlemlerle tahminleme yapılarak parametreler belirlenip modeller oluşturulmuş sonrasında 2018'in birinci ayından 2018'in dokuzuncu ayına kadarki dönem için öngörü yapılmış ve gerçekleşen değerlerle karşılaştırma yapılmıştır. Yapılan bu karşılaştırma ile gerçekleşen değerlerin, modelin öngördüğü aralık içinde kalmadığı modeller değerlendirmeye alınmamıştır. Gerçek değerlerin öngörü aralığının dışına çıktığı modeller ise 4., 5., 7. ve 9. modellerdir.

6.7. Oluşturulan Modellerin Tahminlenmesi ve Uygun Modellerin Seçilmesi

Modellerin öncelikle geçerli olabilmeleri için model hatalarının normal dağılımlı ve sabit varyanslı olmaları gerekmektedir. Bu yüzden dört modelin değerlendirilmeden çıkarılmasının ardından geriye kalan modellerin kalıntıları öncelikle normallik testi olan Jarque-Bera (JB) ve değişen varyans testi olan Breusch-Pagan-Godfrey (BPG) testlerine tabi tutulmuş ve bu testten geçen modellerin ise 2018'in birinci ayından 2018'in dokuzuncu ayına kadar geçen aralığı tahmin etme durumlarına yani Ortalama karesel hatanın karekökü (RMSE), Ortalama mutlak hata (MAE) ve Ortalama mutlak yüzde hatalarına (MAPE) ve bilgi kriterlerine bakılarak karar verilmiştir.

Çizelge 6.11. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin ve yapısal kırılma kuklalarının, AR(1), AR(2) ve AR(4) terimlerinin bağımsız değişken olduğu modelin sonuçları (M1)

Bağımsız Değişken	Katsayı	Standart Hata	t-İstatistik	Olasılık Değeri
@TREND (Trend Bileşeni)	3807,013	155,8311	24,43039	0,0000
D1 (Ocak)	184032,9	9476,471	19,41999	0,0000
D2 (Şubat)	161977,9	10085,30	16,06080	0,0000
D3 (Mart)	210846,3	9019,889	23,37571	0,0000
D4 (Nisan)	207120,8	9571,186	21,64003	0,0000
D5 (Mayıs)	229519,8	8959,353	25,61789	0,0000
D6 (Haziran)	220044,9	10012,10	21,97791	0,0000
D7 (Temmuz)	214992,4	8797,168	24,43882	0,0000
D8 (Ağustos)	214904,9	9561,005	22,47723	0,0000
D9 (Eylül)	191509,7	9337,407	20,50995	0,0000
D10 (Ekim)	205606,4	9995,390	20,57013	0,0000
D11 (Kasım)	186148,5	10637,13	17,49988	0,0000
D12 (Aralık)	208420,8	10519,49	19,81282	0,0000
2008 Krizi	-98371,44	12954,60	-7,593551	0,0000
Sektörel Kriz	-67955,76	10662,02	-6,373630	0,0000
AR(1)	0,252382	0,079696	3,166814	0,0019
AR(2)	0,398422	0,080310	4,961046	0,0000
AR(4)	-0,248126	0,078763	-3,150299	0,0020
	Kriter	Değer	Kriter	Değer
	R²	0,979008	AIC	22,77609
	\bar{R}^2	0,976473	SIC	23,12940
	BPG	21,76461	JB	1,077663
	BPG Olasılık	0,0836	JB Olasılık	0,583429
	RMSE	23041,66	MAE	19573,50
	MAPE	2,884454		

Çizelge 6.11 toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin ve yapısal kırılma kuklalarının, AR(1), AR(2) ve AR(4) terimlerinin bağımsız değişken olduğu modelin sonuçlarını göstermektedir. Çizelge 6.11 incelendiğinde tüm bağımsız değişkenler istatistiksel olarak anlamlı bulunmuştur. Modelde korelogramdan yola çıkarak AR(1), AR(2) ve AR(4) terimleri modele eklenmiştir.

H_0 hipotezinin kalıntılarda değişen varyansın görülmediği yönünde olduğu Breusch-Pagan-Godfrey (BPG) testinin bu model için olasılık değeri 0,0836'dır. Bu durumda %5 anlamlılık düzeyinde H_0 hipotezi ret edilemez yani modelin kalıntılarında değişen varyans görülmemektedir. H_0 hipotezinin kalıntıların normal dağıldığını ifade ettiği Jarque-Bera (JB) testi için olasılık değeri 0,583429'dur. Bu durumda %5 anlamlılık düzeyinde H_0 hipotezi ret edilemez yani modelin kalıntıları normal dağılmaktadır. Sonuç olarak Model 1, ikinci eleme aşaması olan kalıntıların normal dağılması ve değişen varyanslı olmaması aşamasını da geçmiştir.

Çizelge 6.12. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin ve yapısal kırılma kuklalarının, MA(2) teriminin bağımsız değişken olduğu modelin sonuçları (M2)

Bağımsız Değişken	Katsayı	Standart Hata	t-İstatistik	Olasılık Değeri
@TREND (Trend Bileşeni)	3831,713	130,5623	29,34777	0,0000
D1 (Ocak)	183707,2	8892,647	20,65833	0,0000
D2 (Şubat)	161998,1	9730,105	16,64917	0,0000
D3 (Mart)	210764,7	8154,242	25,84724	0,0000
D4 (Nisan)	207462,2	9134,389	22,71222	0,0000
D5 (Mayıs)	230023,2	8164,661	28,17303	0,0000
D6 (Haziran)	220476,8	9211,043	23,93614	0,0000
D7 (Temmuz)	215389,8	8359,617	25,76551	0,0000
D8 (Ağustos)	215332,1	8490,169	25,36253	0,0000
D9 (Eylül)	191757,4	8687,281	22,07335	0,0000
D10 (Ekim)	205901,7	9926,788	20,74203	0,0000
D11 (Kasım)	186022,5	9104,515	20,43189	0,0000
D12 (Aralık)	208634,5	10235,79	20,38284	0,0000
2008 Krizi	-101688,0	10916,50	-9,315079	0,0000
Sektörel Kriz	-67690,30	9654,120	-7,011546	0,0000
MA(2)	0,522227	0,068315	7,644385	0,0000
	Kriter	Değer	Kriter	Değer
	R^2	0,977578	AIC	22,81844
	\bar{R}^2	0,975202	SIC	23,13455
	BPG	26,55160	JB	0,149326
	BPG Olasılık	0,0220	JB Olasılık	0,928056
	RMSE	22658,32	MAE	17192,76
	MAPE	2,555990		

Oluşturulan ikinci modelde AR terimleri yerine MA terimleri kullanılmış ancak MA(1) ve MA(4) terimleri istatistiksel olarak anlamlı olmadığı için modelden çıkarılarak sadece MA(2) teriminin yer aldığı yeni bir model kurulmuştur (Çizelge 6.12). Model 2 incelendiğinde bağımsız değişkenlerin anlamlı olduğu görülmektedir.

H_0 hipotezinin kalıntılarda değişen varyansın görülmediği yönünde olduğu Breusch-Pagan-Godfrey (BPG) testinin bu model için olasılık değeri 0,0220'dır. Bu durumda %5 anlamlılık düzeyinde H_0 hipotezi ret edilir yani modelin kalıntılarında değişen varyans görülmektedir. H_0 hipotezinin kalıntıların normal dağıldığını ifade ettiği Jarque-Bera (JB) testi için olasılık değeri 0,928056'dur. Bu durumda %5 anlamlılık düzeyinde H_0 hipotezi ret edilemez yani modelin kalıntıları normal dağılmaktadır. Sonuç olarak Model 2, ikinci eleme aşaması olan kalıntıların normal dağılması ve değişen varyanslı olmaması aşamasında kalıntıların normal dağılması kısmından geçmiş ancak kalıntılarda görülen değişen varyans durumundan dolayı bir sonraki aşamaya geçememiştir.

Çizelge 6.13'te yer alan üçüncü modelde bağımsız değişken AR ve MA terimleri olarak AR(1), MA(1) ve MA(2) kullanılmıştır. Model 3'te, %5 anlamlılık düzeyinde tüm bağımsız değişkenler anlamlı bulunmuştur.

H_0 hipotezinin kalıntılarda değişen varyansın görülmediği yönünde olduğu Breusch-Pagan-Godfrey (BPG) testinin bu model için olasılık değeri 0,0346'dır. Bu durumda %5 anlamlılık düzeyinde Model 2'de olduğu gibi H_0 hipotezi ret edilir yani modelin kalıntılarında değişen varyans görülmektedir. H_0 hipotezinin kalıntıların normal dağıldığını ifade ettiği Jarque-Bera (JB) testi için olasılık değeri 0,540107'dur. Bu durumda %5 anlamlılık düzeyinde H_0 hipotezi ret edilemez yani modelin kalıntıları normal dağılmaktadır. Sonuç olarak Model 3, ikinci eleme aşaması olan kalıntıların normal dağılması ve değişen varyanslı olmaması aşamasında kalıntıların normal dağılması kısmından geçmiş ancak kalıntılarda görülen değişen varyans durumundan dolayı bir sonraki aşamaya geçememiştir.

Çizelge 6.13. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin ve yapısal kırılma kuklalarının, AR(1), MA(1) ve MA(2) terimlerinin bağımsız değişken olduğu modelin sonuçları (M3)

Bağımsız Değişken	Katsayı	Standart Hata	t-İstatistik	Olasılık Değeri
@TREND (Trend Bileşeni)	3838,135	192,3940	19,94935	0,0000
D1 (Ocak)	183777,6	11385,76	16,14100	0,0000
D2 (Şubat)	162016,7	11515,87	14,06899	0,0000
D3 (Mart)	210757,4	10827,09	19,46575	0,0000
D4 (Nisan)	207274,5	11208,98	18,49184	0,0000
D5 (Mayıs)	229752,7	10444,69	21,99708	0,0000
D6 (Haziran)	220164,6	11524,72	19,10368	0,0000
D7 (Temmuz)	215051,0	10562,22	20,36039	0,0000
D8 (Ağustos)	214967,0	11194,62	19,20271	0,0000
D9 (Eylül)	191351,3	11145,18	17,16898	0,0000
D10 (Ekim)	205414,8	12114,91	16,95554	0,0000
D11 (Kasım)	185703,6	11999,50	15,47594	0,0000
D12 (Aralık)	208334,9	12629,68	16,49566	0,0000
2008 Krizi	-102053,1	16097,45	-6,339706	0,0000
Sektörel Kriz	-67530,09	13010,57	-5,190401	0,0000
AR(1)	0,433867	0,141743	3,060932	0,0026
MA(1)	-0,240060	0,120941	-1,984937	0,0490
MA(2)	0,481365	0,073462	6,552613	0,0000
	Kriter	Değer	Kriter	Değer
	R²	0,979252	AIC	22,76524
	\bar{R}^2	0,976746	SIC	23,11855
	BPG	24,99988	JB	1,231975
	BPG Olasılık	0,0346	JB Olasılık	0,540107
	RMSE	24040,55	MAE	19138,04
	MAPE	2,853401		

Oluşturulan altıncı modelde (Çizelge 6.14) AR ve MA terimleri olarak AR(1), AR(2), AR(4), MA(5) ve MA(15) terimleri kullanılmıştır. Bağımsız değişkenler arasında MA(5) değişkeni dışında diğer tüm değişkenler %5 anlamlılık düzeyinde anlamlıdır. Ancak MA(5) bağımlı değişkeni %5'te anlamlı değildir, olasılık değeri 0,0614 olduğu için katsayının anlamsız olduğunu ifade eden H_0 hipotezi ret edilemez. Bu modelde MA(5) anlamsız olduğu halde modelden çıkarılmamıştır. MA(5)'in olmadığı yeni bir model oluşturulup 2018 birinci aydan 2018 dokuzuncu aya kadarki dönem için gerçek değer ve tahmin edilen değer karşılaştırılması yapıldığında gerçek değerlerin aralık içinde kalmadığı görülmüştür.

Çizelge 6.14. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin ve yapısal kırılma kuklalarının, AR(1), AR(2), AR(4), MA(5) ve MA(15) terimlerinin bağımsız değişken olduğu modelin sonuçları (M6)

Bağımsız Değişken	Katsayı	Standart Hata	t-İstatistik	Olasılık Değeri
@TREND (Trend Bileşeni)	3815,562	130,9822	29,13039	0,0000
D1 (Ocak)	181423,7	7765,417	23,36303	0,0000
D2 (Şubat)	159494,6	8395,616	18,99737	0,0000
D3 (Mart)	209163,5	7577,087	27,60474	0,0000
D4 (Nisan)	204782,6	8335,901	24,56634	0,0000
D5 (Mayıs)	228451,5	8022,784	28,47534	0,0000
D6 (Haziran)	218914,3	8057,442	27,16920	0,0000
D7 (Temmuz)	213942,6	7236,488	29,56443	0,0000
D8 (Ağustos)	214009,6	7636,638	28,02406	0,0000
D9 (Eylül)	190767,0	7686,709	24,81777	0,0000
D10 (Ekim)	204442,6	8647,201	23,64264	0,0000
D11 (Kasım)	184578,1	9587,530	19,25189	0,0000
D12 (Aralık)	206580,2	8573,042	24,09648	0,0000
2008 Krizi	-97335,50	10547,19	-9,228567	0,0000
Sektörel Kriz	-69457,75	8717,889	-7,967267	0,0000
AR(1)	0,226577	0,083802	2,703734	0,0077
AR(2)	0,402633	0,083116	4,844217	0,0000
AR(4)	-0,260201	0,080445	-3,234508	0,0015
MA(5)	-0,164132	0,087071	-1,885046	0,0614
MA(15)	-0,244903	0,096534	-2,536962	0,0122
	Kriter	Değer	Kriter	Değer
	R²	0,980911	AIC	22,71169
	\bar{R}^2	0,978313	SIC	23,10218
	BPG	19,63059	JB	1,816520
	BPG Olasılık	0,1422	JB Olasılık	0,403225
	RMSE	24325,71	MAE	18795,66
	MAPE	2,767313		

H_0 hipotezinin kalıntılarda değişen varyansın görülmediği yönünde olduğu Breusch-Pagan-Godfrey (BPG) testinin model 6 için olasılık değeri 0,1422'dir. Bu durumda %5 anlamlılık düzeyinde H_0 hipotezi ret edilemez yani modelin kalıntılarında değişen varyans görülmemektedir.

H_0 hipotezinin kalıntıların normal dağıldığını ifade ettiği Jarque-Bera (JB) testi için olasılık değeri 0,403225'dur. Bu durumda %5 anlamlılık düzeyinde H_0 hipotezi ret edilemez yani modelin kalıntıları normal dağılmaktadır. Sonuç olarak Model 6, ikinci eleme aşaması olan kalıntıların normal dağılması ve değişen varyanslı olmaması aşamasını da geçmiştir.


Çizelge 6.15. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin ve yapısal kırılma kuklalarının, MA(1), AR(2) ve AR(4) terimlerinin bağımsız değişken olduğu modelin sonuçları (M8)

Bağımsız Değişken	Katsayı	Standart Hata	t-İstatistik	Olasılık Değeri
@TREND (Trend Bileşeni)	3822,193	148,8863	25,67190	0,0000
D1 (Ocak)	183529,6	9271,482	19,79507	0,0000
D2 (Şubat)	161664,3	9898,673	16,33191	0,0000
D3 (Mart)	210650,1	8626,851	24,41796	0,0000
D4 (Nisan)	206983,5	9362,845	22,10690	0,0000
D5 (Mayıs)	229649,9	8697,589	26,40386	0,0000
D6 (Haziran)	220112,3	9639,549	22,83430	0,0000
D7 (Temmuz)	215135,6	8466,153	25,41126	0,0000
D8 (Ağustos)	215029,0	9245,809	23,25692	0,0000
D9 (Eylül)	191468,2	8978,941	21,32415	0,0000
D10 (Ekim)	205618,6	9925,643	20,71589	0,0000
D11 (Kasım)	185912,9	10314,30	18,02478	0,0000
D12 (Aralık)	208251,8	10299,55	20,21951	0,0000
2008 Krizi	-99918,85	12227,94	-8,171354	0,0000
Sektörel Kriz	-68636,38	10494,09	-6,540477	0,0000
MA(1)	0,217695	0,085400	2,549127	0,0118
AR(2)	0,440162	0,081552	5,397320	0,0000
AR(4)	-0,203326	0,083770	-2,427193	0,0164
	Kriter	Değer	Kriter	Değer
	R^2	0,978349	AIC	22,80624
	\bar{R}^2	0,975733	SIC	23,15954
	BPG	21,79595	JB	0,704361
	BPG Olasılık	0,0829	JB Olasılık	0,703153
	RMSE	22508,99	MAE	17834,66
	MAPE	2,634102		

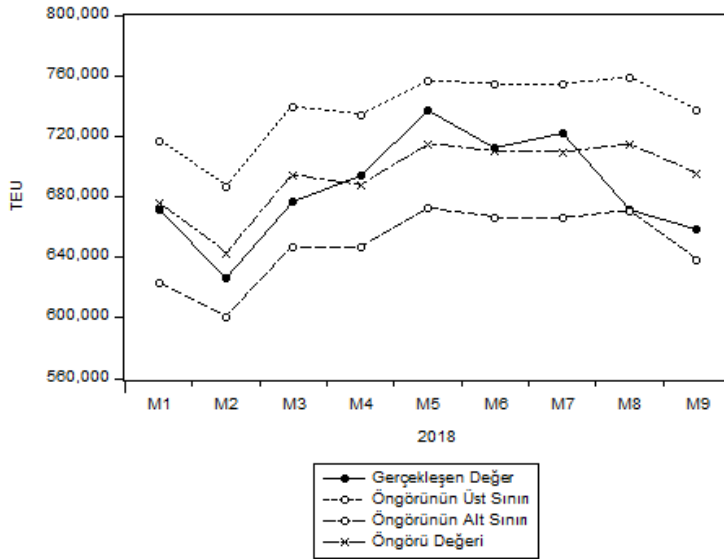
İlk aşamayı geçip ikinci aşamaya kalan bir diğer model olan 8. model, AR ve MA terimlerinden MA(1), AR(2) ve AR(4) bağımlı değişkenlerini içermektedir (Çizelge 6.15). Modelin %5 anlamlılık düzeyinde tüm bağımlı değişkenleri anlamlıdır yani olasılık değerleri 0,05'ten küçük değerlere sahiptir. H_0 hipotezinin kalıntılarda değişen varyansın görülmediği yönünde olduğu Breusch-Pagan-Godfrey (BPG) testinin bu model için olasılık değeri 0,0829'dur. Bu durumda %5 anlamlılık düzeyinde H_0 hipotezi ret edilemez yani modelin kalıntılarında değişen varyans görülmemektedir. H_0 hipotezinin kalıntıların normal dağıldığını ifade ettiği Jarque-Bera (JB) testi için olasılık değeri 0,703153'tür. Bu durumda %5 anlamlılık düzeyinde H_0 hipotezi ret edilemez yani modelin kalıntıları normal dağılmaktadır. Sonuç olarak Model 8, ikinci eleme aşaması olan kalıntıların normal dağılması ve değişen varyanslı olmaması aşamasından geçen üçüncü model olmuştur.

Modellemeye başlarken belirlenen dokuz model öncelikle ortaya koydukları öngörü aralığının gerçek değeri tamamen içine alıp almadıkları ile ele alınmış ve gerçek değerlerin aralık dışında kaldığı modeller elenmiştir. Başlarken böyle bir eleme yapılmasını akla getiren durum her yeni bağımsız değişken eklendiğinde daha düşük Akaike ve Schwarz değerlerinin ortaya çıkması ve ortaya çıkan daha düşük değerler sonucunda modellerin gerçekten bilgi kriterleri yüksek olan modellerden daha iyi olup olmadığının merak edilmesidir. Bilgi kriterleri değerleri diğer modellere göre daha düşük olan modellerin hepsinin çok daha iyi sonuçlar sergilemediğini görmek böyle bir ön eleme yapılmasını gerekli kılmıştır.

Olağan sıra izlenseydi bilgi kriteri değerleri daha yüksek olan model elenecek bu durum da yanlış öngörülere zemin hazırlayacaktı. Bu durumu daha açık ifade etmek için model 4'ü ele alalım. Model 4'ün Akaike bilgi kriteri değeri 22,64822 iken Model 8'in Akaike bilgi kriteri değeri 22,80624'tür. Bilgi kriterlerinin ölçüt olduğu eleme sisteminde Model 4'ün tercih edilip Model 8'in elenmesi gerektirir. Bir de bu modellerin öngörü yeteneklerine bakalım (Şekil 6.3).



(a)



(b)

Şekil 6.3. Model 4 (a) ve Model 8'e (b) ait 2018 1. aydan 2018'in 9. Ayına kadarki dönemi kapsayan modellerin öngörü aralıkları ve gerçekleşen değer ile karşılaştırmaları

Modellerin öngörü yetenekleri incelendiğinde bilgi kriterlerine göre elenmesi gereken Model 8'in Model 4'ten çok daha iyi öngörü yaptığı görülmektedir. Model 4'te gerçek değer öngörü aralıklarının dışına çıkarken Model 8'de öngörü aralıklarının içinde kalmaktadır. Bu durumu göz ardı etmemek için baştan kontrol yapılmış ve ilk eleme kriteri olarak uygulanmıştır.


Modellerin öngörü yeteneğine göre yapılan ilk elemelerden sonra modelin oluşması için en önemli kriterlerden olan kalıntıların normal dağılması ve kalıntılarda değişen varyans olmaması durumu incelenmiş ve bu durumları sağlamayan modeller de elenmiştir. İlk elemelerde dokuzdan beşe düşen model sayısı bu eleme ile iki daha azalmış ve en son üç model kalmıştır.

6.8. Öngörüde Kullanılan Modelin Seçilmesi

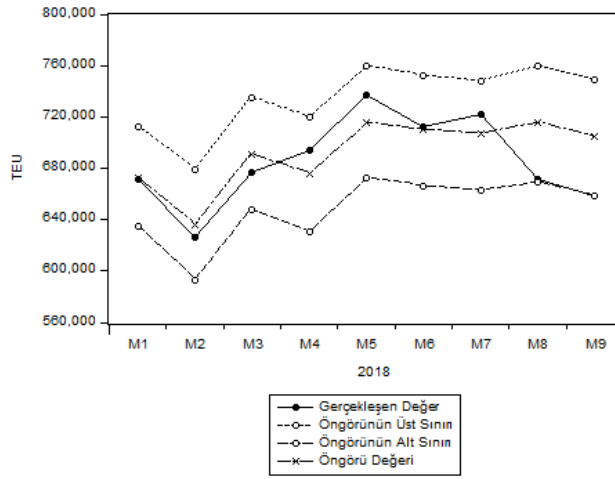
Son üçe kalan model değişen varyansın varlığını test eden Breusch-Pagan-Godfrey ve normalliği test eden Jarque-Bera (JB) testlerini geçtikleri için aslında öngörü için uygun olduklarını göstermişlerdir. Bu aşamada amaç öngörü için en sağlıklı sonucu verecek modelin seçilmesidir.

Son aşamada 2018'in onuncu ayından 2019'un 12. ayına kadarki dönemin öngörüsünde kullanılacak modeli belirlemek için yapılacak işlem; 2018'in birinci ayından dokuzuncu ayına kadarki dönem için öngörü yapmak ve bu öngörü sonuçlarının gerçekleşen değerlerle karşılaştırılması sonucu ortaya çıkan RMSE, MAE ve MAPE değerlerini karşılaştırmaktır. 2018'in birinci ayından dokuzuncu ayına kadarki dönem için öngörü, 2004'ün birinci ayından 2017'nin on ikinci ayına kadarki süreyi kapsayan gözlemlerden oluşan veri seti ile yapılan tahmin ve tahmin sonucunda bulunan parametreler ile yapılmıştır.


Şekil 6.4 Model 1, Model 6 ve Model 8'e ait 2018'in 1. ayından 2018'in 9. ayına kadarki dönemi kapsayan modellerin öngörü aralıkları ve gerçekleşen değer ile karşılaştırılmalarını göstermektedir. Ayrıca devamında modellere ait RMSE, MAPE, MAE, AIC ve SIC değerleri Çizelge 6.16'te verilmiştir. Bu şekil ve çizelgenin birlikte verilmesindeki amaç çizelgeden yararlanırken modellere ait grafiklerin de dikkate alınmasıdır.



(a)



(b)



(c)

Şekil 6.4. Model 1 (a), Model 6 (b) ve Model 8'e (c) ait 2018 1. aydan 2018'in 9. ayına kadarki dönemi kapsayan modellerin öngörü aralıkları ve gerçekleşen değer ile karşılaştırmaları

Çizelge 6.16. Model tercih kriterleri

	Model 1	Model 6	Model 8
RMSE	23041,66	24325,71	22508,99
MAPE	2,884454	2,767313	2,634102
MAE	19573,50	18795,66	17834,66
AIC	22,77609	22,71169	22,80624
SIC	23,12940	23,10218	23,15954

Akaike ve Showarz bilgi değerleri incelendiğinde değerlerin birbirlerine çok yakın olduğu görülmektedir. Bu durumda öngörünün doğruluğu ile de direkt ilgili oldukları için RMSE, MAPE ve MAE ile yorum yapmak çok daha uygun olacaktır. Bu değerler ile yorum yaparken de grafiği dikkate almak oldukça önemlidir. Hatalar çok az olsa bile hataların bir noktadan sonra gerçek değerden oldukça uzaklaşması doğru öngörü açısından sorun olması ihtimali yüksektir. Bu yüzden bu değerlerle birlikte grafikler de dikkate alınmıştır.

Şekil 6.4'ün a'sında gösterilen Model 1'e ait grafikte gerçek değer alt ve üst sınırların arasındadır ancak şöyle bir problem vardır ki gerçek değere yakın sonuçlara yakın sonuçlar elde etme yeteneği biraz düşüktür. Ayrıca RMSE; MAPE ve MAE açısından bakıldığında da sadece RMSE değeri için en iyi ikinci performansı göstermiştir. MAPE ve MAE için ise en kötü performansı sergilemiştir.

Şekil 6.4'ün b'sinde gösterilen Model 6'ya ait grafikte aslında ortalama öngörü değerleri gerçek değerlere oldukça yakındır ancak son aylarda gerçek değer alt sınıra oldukça yaklaşmıştır. RMSE; MAPE ve MAE açısından bakıldığında ise RMSE değerinde en kötü performansı sergilerken MAPE ve MAE'de en iyi ikinci performansı sergilemektedir.

Şekil 6.4'ün c'sinde gösterilen Model 8'e ait grafikte ortalama öngörü değerleri gerçek değerlere zaman zaman Model 6'ya göre daha uzaktır ancak genel Model 8'in son aylarına ait öngörülerini Model 6'ya göre daha iyidir. Ayrıca RMSE, MAPE ve MAE değerleri Model 1 ve Model 6'ya göre çok daha iyidir. RMSE, MAPE ve MAE değerlerine göre Model 8 en iyi performansı sergilemektedir.

Tüm bu yorumlar dikkate alındığında 2018'in son üç ayına ait ve 2019'un tamamına ait aylık öngörülerin Model 8 ile yapılmasına karar verilmiştir.

6.9. 2018'in Son Üç Ayına ve 2019'un Tamamına Ait Aylık Öngörülerin Yapılması

Öncelikle model performansını değerlendirmek için 2004'ün ilk ayından 2017'nin son ayına kadarki dönemi içeren veri seti üzerinden tahminleme yapıldı ve bu tahmin üzerinden 2018'in ilk dokuz ayı için öngörü yapıldı. Bulunan öngörü değerleri 2018'in ilk dokuz ayına ait gerçek değerlerle karşılaştırıldı.

Bu bölümde yapılacak olan ise 2004'ün ilk ayından 2017'nin son ayına kadarki dönemi içeren veri setine ait modeli kullanarak 2018'in son üç ayı ve 2019 yılı için aylık öngörü yapmaktır. Öngörü için seçilen Model 8 ile yapılan öngörü sonuçları Çizelge 6.17'de gösterilmektedir.

Çizelge 6.17. 2018/10 - 2019/12 zaman dilimine ait aylık öngörü

Zaman	Öngörünün Üst Sınırı	Öngörü Değeri	Öngörünün Alt Sınırı
2018/10	761713,9	714369,8	662258,5
2018/11	744646,0	698086,8	640422,0
2018/12	772067,9	724340,8	676236,2
2019/01	748806,5	703509,7	656308,3
2019/02	730354,2	684233,5	639981,8
2019/03	796463,1	736554,3	694371,7
2019/04	785947,9	737638,5	694244,6
2019/05	805989,1	762804,9	716577,8
2019/06	804194,6	757715,4	710670,4
2019/07	801457,3	754904,4	709841,2
2019/08	805720,3	759641,7	713343,8
2019/09	786838,5	739975,6	691304,7
2019/10	805237,7	758980,0	703200,8
2019/11	790250,6	743494,6	696640,4
2019/12	822321,9	769795,3	725782,2

7. SONUÇ VE ÖNERİLER

2018'in son üç ayı ve 2019'un tamamını kapsayan Türkiye'nin toplam ithalat ihracat elleçlemesi için aylık öngöründe bulunmanın amaçlandığı çalışmada kısa dönemli öngörülerde diğer modellere göre çok daha iyi olan ARMA modeli seçilmiş ve bu model üzerinden öngöründe bulunulmuştur.

Modelin uygulanma aşamasını kısaca özetlemek gerekirse; Box – Jenkins yöntemi olarak da bilinen ARMA modelinin uygulanması için öncelikle zaman serisinin durağan olması gerekmektedir. Bu yüzden öncelikle zaman serisine ADF, PP, DF-GLS ve KPSS birim kök testleri uygulanmış ve durağan olup olmadığına bakılmıştır. Testlerin sonuçları serinin trend durağan olduğunu ortaya koyduğu için modele trend değişkeni eklenmiştir.

Aylık verilerle çalışıldığı için trend değişkeninden sonra mevsimselliğin varlığı mevsimsel kukla değişkenlerle sınanmış ve kukla değişkenler anlamlı bulunduğu için kukla değişkenler de modele eklenmiştir.

Kukla değişkenlerin modele eklenmesinin ardında seride yer alabilecek kırılmalar için çoklu kırılma testi olan Bai-Perron testi seriye uygulanmış ve test sonucunda ortaya çıkan kırılma noktalarından serinin 2008 krizinden ve 2014'ün sonu 2015'in başında sektörde meydana gelen durgunluktan etkilendiği görülmüştür ve bu noktalar da kukla değişken olarak modele eklenmiştir.

Trendin, mevsimsel kukla değişkenlerin ve yapısal kırılma kukla değişkenlerinin temel olduğu modele AR ve MA terimleri eklenmiş ve dokuz model elde edilmiştir. Elde edilen dokuz model için 2004'ün birinci ayından 2017'nin son ayına kadarki dönemi içine alan veri seti üzerinden tahminleme yapılmış, tahminleme ile elde edilen parametrelerle 2018'in ilk ayından 2018'in dokuzuncu ayına kadarki dönem için öngörü yapılmış ve elde edilen öngörü değerleri ile gerçekleşen değerler karşılaştırılmıştır. Karşılaştırma sonucunda gerçek değerlerin öngörü aralığının dışında kaldığı 4., 5., 7. Ve 9. modeller model seçim kriterleri aşamasına geçmemiş bu aşamada elenmiştir.

Bir sonraki aşamaya geçen 1., 2., 3., 6. ve 8. modellerin kalıntıları modellerin geçerliliklerinin test edilmesi için normallik testi olan Jarque-Bera (JB) ve değişen varyans testi olan Breusch-Pagan-Godfrey (BPG) testlerine tabi tutulmuş ve değişen varyans testini geçemeyen 2. ve 3. model elenmiştir.

Geriye kalan 1., 6. ve 8. modeller 2018'in ilk ayından 2018'in dokuzuncu ayına kadarki dönem için yaptıkları öngörünün doğruluğunu ifade eden RMSE, MAE ve MAPE üzerinden değerlendirilmiş ve uygun model olarak 8. model seçilmiş ve bu model üzerinden 2018'in son üç ayı ve 2019'un tamamı için aylık öngörü yapılmıştır.

Araştırmanın bilimsel katkısı

Çalışmaya akademik pencereden bakıldığında makalenin en önemli sonuçlarından biri Box – Jenkins yönteminin aşamalarından biri olan modelin tahminlenmesi aşamasında kullanılan Akaike ve Schwarz bilgi kriterlerinin her zaman doğru sonuç vermeyeceği yanıtıcı olabileceği sonucudur. Bu durum bu yöntemi kullanacak diğer araştırmacılar için oldukça önem teşkil etmektedir. Sebebi ise çok daha iyi öngörü yapabilecek modellerin bu kriterler ile elenmesinin öngörülerin tutmamasına sebebiyet verme ihtimalidir. Çalışmada bu durumun ortaya çıkarılması daha düşük değerlerin elde edildiği modellerden şüphelenilmesi ile olmuştur. Oluşan şüphelerden dolayı çalışmada modelin tahmin edilmesi aşamasında düşük Akaike ve Schwarz bilgi kriterleri değerlerine sahip olan modeller direkt olarak seçilmemiş son aşamaya giderek öngörü yapılmış ve gerçek değerlerle karşılaştırılmıştır. Karşılaştırma sonucunda düşük Akaike ve Schwarz bilgi kriterleri değerlerine sahip olan modellerin öngörülerinin öngörü aralığının dışında kaldığı görülmüş ve bu modeller elenmiştir. Bu yöntemin kullanılması ile Akaike ve Schwarz bilgi kriterleri değerlerinin yanıtıcı olma olasılığı en aza indirilmeye çalışılmıştır.

Normal koşullarda deterministik trendin yer aldığı durumlarda iki farklı seçenek araştırmacının karşısına çıkmaktadır; bunlardan biri trendi ayıklamak, ikincisi ise trendi modele eklemektir. Trendin modele eklendiği çalışmalar daha az rastlanılan çalışma örneğidir. Tabi bu noktada çalışmada kullanılan veri setinin yapısı son derece önemlidir. Bu çalışmada veri setinde gözlemlenen deterministik trend ve mevsimsellik değişkenleri modele direkt eklenmiş ve bu yolla çalışmada yer alan veri setine benzer veri setleri ile karşılaştırılması durumunda araştırmacılara bir alternatif sunulmak istenmiştir.

Araştırmanın uygulamaya katkısı

Çalışmaya uygulayıcılar açısından bakıldığında; çalışmada uygulayıcılara yol göstermesi açısından 2018'in son üç ayı ve 2019 yılı için aylık öngörü yapılmıştır. Aylık öngörülerin önemi liman operasyonlarında daha çok ortaya çıkmaktadır. Çalışmada liman yöneticilerine bu öngörüler ile ekipman ve personel gibi liman operasyonlarını ilgilendiren dağılımları yapmalarına katkı sağlanmaya çalışılmıştır. Çalışmada liman bazında aylık zaman serisi verileri bulunmadığı için aylık zaman serisi verilerine ulaşılan Türkiye'nin 2004 – 2018 veri setleri kullanılmış ve bu veri setleri üzerinden öngörü yapılmıştır. Limanlar bazında yöneticilerden ise bu verilerden yararlanma noktasında Türkiye'deki paylarına göre kendi öngörü miktarlarını belirlemeleri beklenmektedir.

Araştırmanın kısıtları ve gelecekteki araştırmalar için öneriler

Çalışma her öngörüde olduğu gibi bazı kısıtlardan oluşmaktadır. Çalışmanın ilk kısıtı veri setlerinin derlenmesi esnasında kabotaj ve transit yük elleçlemelerinin veri setinde yer alan elleçleme miktarlarına eklenmeyerek sadece ithalat ve ihracat elleçlemelerinin veri setinde yer alan elleçleme miktarları içinde yer almasıdır. Bunu yapmaktaki en önemli amaç daha sonra yapılacak çalışmalarda eklenecek dış ticaret gibi değişkenlerin bağımlı değişken üzerindeki direkt etkilerini görebilmektir. Ayrıca bir başka kısıt da öngörünün yapıldığı süre boyunca ülkenin ekonomik durumunun değişmeyeceği yani ülkenin kriz gibi ekonomiyi derinden etkileyebilecek oluşumlardan etkilenmeyeceğidir. Bu durum farklı bakış açısı ile düşünüldüğünde ise ülkeler arası ticaret anlaşmaları ile elleçlemelerde ani yükselmelerin olmayacağıdır ya da savaşlar sonucu elleçlemelerin düşmeyeceğidir.

Bu çalışmadan yola çıkarak Box – Jenkins yöntemi ile öngörü yapacak araştırmacılara en büyük öneri ve uyarı modeller arasında seçim yaparken Akaike ve Schwarz bilgi kriterleri değerlerine dikkat etmeleri gerektiğidir. Bu durumun onları yanlış öngörüden kurtarabilme noktasında önemli olduğu düşünülmektedir. Bu çalışmadan yola çıkarak çalışmada kullanılan veri setlerine farklı yöntemler uygulayarak yapılacak öngörüler ile bu çalışmada kullanılan öngörü değerleri karşılaştırılarak daha iyi öngörü yapan modellerin elde edilmesi ya da çalışmada kullanılan veri setine yakın veri setlerinde kukla değişkenler ve trend ile uygulanan yönetimin de denenmesi ve bu yöntemin başka yöntemlerle karşılaştırılması araştırmacılara yapılabilecek bir başka öneriyi oluşturmaktadır.

KAYNAKLAR

- Adhikari, R., ve Agrawal, R. K. (2013). *An Introductory Study on Time Series Modeling and Forecasting*. Germany: LAP Lambert Academic Publishing.
- Akar, O., ve Esmer, S. (2015). Türkiye'deki Konteyner Terminalleri için Yük Talep Analizi. *Journal of ETA Maritime Science*, 3(2), 117-122.
- Amoako, J. (2002). Forecasting Australia's international container trade. In *25th Australian Transport Research Forum, Canberra October 2002*.
- Antoshin, S., Berg A. ve Souto M. (2008). Testing for Structural Breaks in Small Samples. *International Monetary Fund Working Paper*.
- Brockwell, P. J., ve Davis, R. A. (2002). *Introduction to Time Series and Forecasting* (İkinci Baskı). New York: Springer.
- Carnot, N., Koen V. ve Tissot, B. (2005). *Economic Forecasting*. New York: Palgrave Macmillan
- Chatfield, C. (2000). *Time Series Forecasting*. Birleşik Krallık: Chapman ve Hall/CRC.
- Chen, S. H., ve Chen, J. N. (2010). Forecasting container throughputs at ports using genetic programming. *Expert Systems with Applications*, 37(3), 2054-2058.
- Chen, C. P., Liu, Q. J., ve Zheng, P. (2013). Application of grey-markov model in predicting container throughput of fujian province. In *Advanced Materials Research* (Vol. 779, pp. 720-723). Trans Tech Publications.
- Chen, Z., Chen, Y., ve Li, T. (2016). Port cargo throughput forecasting based on combination model. In *Joint International Information Technology, Mechanical and Electronic Engineering Conference (JIMEC 2016)* (pp. 148-154).
- Chou, C. C., Chu, C. W., ve Liang, G. S. (2008). A modified regression model for forecasting the volumes of Taiwan's import containers. *Mathematical and Computer Modelling*, 47(9-10), 797-807.
- Dagenais, M. G., ve Martin, F. (1987). Forecasting containerized traffic for the port of Montreal (1981-1995). *Transportation Research Part A: General*, 21(1), 1-16.
- Diaz, R., Talley, W., ve Tulpule, M. (2011). Forecasting empty container volumes. *The Asian Journal of Shipping and Logistics*, 27(2).
- Dragan, D., Kramberger, T., ve Intihar, M. (2014). A comparison of Methods for Forecasting the Container Throughput in North Adriatic Ports. In *Conference IAME*.
- Enders, W. (2015). *Applied Econometric Times Series* (Dördüncü Baskı). New York: John Wiley & Sons Inc.

- Ergün, U., ve Göksu, A. (2013). *Applied Econometrics with Eviews Applications*. International Burch University.
- Evans M. K. (2003). *Practical Business Forecasting*. Oxford: Blackwell Publishing
- Farhan, J., ve Ong, G. P. (2018). Forecasting seasonal container throughput at international ports using SARIMA models. *Maritime Economics & Logistics*, 20(1), 131-148.
- Fung, K. F. (2001). Competition between the ports of Hong Kong and Singapore: A structural vector error correction model to forecast the demand for container handling services. *Maritime Policy and Management*, 28(1), 3–22.
- Fung, M. K. (2002). Forecasting Hong Kong's container throughput: An error-correction model. *Journal of Forecasting*, 21(1), 69-80.
- Geng, J., Li, M. W., Hong, W. C., Zheng, T. J., Niu, X. Y., ve Ma, S. L. (2015, October). Port throughput forecasting by using PPPR with chaotic efficient genetic algorithms and CMA. In *Systems, Man, and Cybernetics (SMC), 2015 IEEE International Conference on* (pp. 1633-1638). IEEE.
- Gooijer de, J. G., ve Klein, A. (1989). Forecasting the Antwerp maritime steel traffic flow: A case study. *Journal of Forecasting*, 8(4), 381–398.
- Gosasang, V., Chandraprakaikul, W., ve Kiattisin, S. (2011). A comparison of traditional and neural networks forecasting techniques for container throughput at Bangkok port. *The Asian Journal of Shipping and Logistics*, 27(3), 463-482.
- Gosasang, V., Yip, T. L., ve Chandraprakaikul, W. (2018). Long-term container throughput forecast and equipment planning: the case of Bangkok Port. *Maritime Business Review*, 3(1), 53-69
- Goulielmos, A.M. ve Kaselimi, E. (2011) ‘A non-linear forecasting of container traffic: the case-study of the Port of Piraeus, 1973–2008’. *Int. J. Shipping and Transport Logistics*, 3(1), 72–99.
- Gökkuş, Ü., Yıldırım, M. S., ve Aydın, M. M. (2017). Estimation of con-tainer traffic at seaports by using several soft computing meth-ods: A case of Turkish seaports. *Discrete Dynamics in Nature and Society*, 2017, 1-15
- Gujarati, D. N. (2004). *Basic econometrics*. United States Military Academy, West Point: The Mc-Graw Hill.
- Gujarati, D. (2011). *Econometrics by example*. Hampshire, UK: Palgrave Macmillan.
- Guo, Z., Song, X., ve Ye, J. (2005). A Verhulst model on time series error corrected for port throughput forecasting. *Journal of the Eastern Asia society for Transportation studies*, 6, 881-891.
- Heij, C., de Boer, P., Franses, P. H., Kloek, T., ve van Dijk, H. K. (2004). *Econometric methods with applications in business and economics*. Oxford University Press.

- Hill, R. C., Griffiths, W. E., ve Lim, G. C. (2011). *Principles of Econometrics* (Dördüncü Baskı). ABD: John Wiley & Sons.
- Huang, A., Lai, K., Li, Y., ve Wang, S. (2015). Forecasting container throughput of Qingdao port with a hybrid model. *Journal of Systems Science and Complexity*, 28(1), 105-121.
- Hui, E. C., Seabrooke, W., ve Wong, G. K. (2004). Forecasting cargo throughput for the port of Hong Kong: error correction model approach. *Journal of urban planning and development*, 130(4), 195-203.
- Hyndman, R. J. ve Athanasopoulos, G. (2013). *Forecasting: principles and practice*. Melbourne, Australia: OTexts
- İnternet: Deniz Ticareti Genel Müdürlüğü İstatistik Bilgi Sistemi (DTGM İBS). URL: https://atlantis.udhb.gov.tr/istatistik/istatistik_konteyner.aspx Son Erişim Tarihi: 30.11.2018
- İnternet: Türkiye İstatistik Kurumu (TUİK). URL: http://www.tuik.gov.tr/PreTablo.do?alt_id=1046, Son Erişim Tarihi: 05.12.2018
- İnternet: Hansen, B. E. (2006). *Econometrics. Working Paper*. URL: <http://www.ssc.wisc.edu/~bhansen/econometrics/Econometrics2006.pdf> Son Erişim Tarihi: 15.11.2018
- İnternet: UNCTADstat. (2018). <http://unctadstat.unctad.org/wds/ReportFolders/reportFolders.aspx> Son Erişim Tarihi: 10.11.2018
- İnternet: T.C. Ulaştırma Bakanlığı Demiryolları Limanlar ve Hava Meydanları İnşaatı Genel Müdürlüğü. (2010). *Ulaştırma Kıyı Yapıları Master Plan Çalışması Sonuç Raporu*. http://www.kugm.gov.tr/BLSM_WIYS/DLH/tr/DOKUMAN_SOL_MENU/Master_Plan_Calismalari/20110527_122412_10288_1_10315.pdf Son Erişim Tarihi: 10.12.2018
- İnternet: Birleşmiş Milletler Ticaret ve Kalkınma Örgütü (UNCTAD). (2016). *Review of Maritime Transport 2016*. New York: Birleşmiş Milletler. https://unctad.org/en/PublicationsLibrary/rmt2016_en.pdf Son Erişim Tarihi: 05.11.2018
- İnternet: Birleşmiş Milletler Ticaret ve Kalkınma Örgütü (UNCTAD). (2018). *Review of Maritime Transport 2018*. New York: Birleşmiş Milletler. https://unctad.org/en/PublicationsLibrary/rmt2018_en.pdf Son Erişim Tarihi: 05.11.2018
- Intihar, M., Kramberger, T., ve Dragan, D. (2017). Container Throughput Forecasting Using Dynamic Factor Analysis and ARIMAX Model. *Promet-Traffic&Transportation*, 29(5), 529-542.

- Kirchgässner, G., ve Wolters, J. (2007). *Introduction to modern Time series Analysis*. Berlin: Springer.
- Klein, A., ve Verbeke, A. (1987). The design of an optimal short term forecasting system for sea port management: an application to the port of Antwerp. *International Journal of Transport Economics/Rivista internazionale di economia dei trasporti*, 14(1), 57-70.
- Klein, A. (1996). Forecasting the Antwerp maritime traffic flows using transformations and intervention models. *Journal of Forecasting*, 15(5), 395-412.
- Lam, W. H. K., Asce, M., Ng, P. L. P., Seabrooke, W., ve Hui, E. C. M. (2004). Forecasts and Reliability Analysis of Port Cargo Throughput in Hong Kong. *Journal of Urban Planning and Development*, (130), 133–144.
- Li, J., Chen, Y., ve Cui, X. (2008, April). Port Throughput Forecast Based on Nonlinear Combination Method. In *WSEAS International Conference. Proceedings. Mathematics and Computers in Science and Engineering* (No. 7). World Scientific and Engineering Academy and Society.
- Liu, C. J., ve Zhang, Q. N. (2007). Dynamic prediction of container throughput based on the time series BP neural network (BP NN). *Port & Waterway Engineering*, 1, 001.
- Liu, Z., L. Ji, Y. Ye, and Z. Geng. (2007). “Combined Forecast Method of Port Container Throughput Based on RBF Neural Network.” *Journal of Tongji University (Natural Science)* 6:739–744.
- Lütkepohl, H., ve Krätzig, M. (2004). *Applied time series econometrics*. Cambridge University Press.
- Mak, K. L., ve Yang, D. H. (2007). Forecasting Hong Kong's Container Throughput with Approximate Least Squares Support Vector Machines. In *World Congress on Engineering* (pp. 7-12).
- Min, K. C., ve Ha, H. K. (2014). Forecasting the Korea's Port Container Volumes With SARIMA Model. *Journal of Korean Society of Transportation*, 32(6), 600-614.
- Mo, L., Xie, L., Jiang, X., Teng, G., Xu, L., ve Xiao, J. (2018). GMDH-based hybrid model for container throughput forecasting: Selective combination forecasting in nonlinear subseries. *Applied Soft Computing*, 62, 478-490.
- Montgomery, D. C., Jennings, C. L. ve Kulahci, M. (2008). *Introduction to Time Series Analysis and Forecasting*. Canada: John Wiley & Sons, Inc.
- Mohamed Ismael, H., ve Vandyck, G. K. (2016). Forecasting Container Throughput at the Doraleh Port in Djibouti through Time Series Analysis. In *Proceedings of the 2015 International Conference on Applied Mechanics, Mechatronics and Intelligent Systems (AMMIS2015)* (pp. 341-350).

- Palit, A. K. ve Popovic, D. (2005). *Computational Intelligence in Time Series Forecasting Theory and Engineering Applications*. London: Springer.
- Pang, G., ve Gebka, B. (2017). Forecasting container throughput using aggregate or terminal-specific data? The case of Tanjung Priok Port, Indonesia. *International Journal of Production Research*, 55(9), 2454-2469.
- Pankratz, A. (2012). *Forecasting with dynamic regression models (Vol. 935)*. John Wiley & Sons, Inc.
- Patil, G. R., ve Sahu, P. K. (2016). Estimation of freight demand at Mumbai Port using regression and time series models. *KSCE Journal of Civil Engineering*, 20(5), 2022-2032.
- Patil, G. R., ve Sahu, P. K. (2017). Simultaneous dynamic demand estimation models for major seaports in India. *Transportation Letters*, 9(3), 141-151
- Peng, W. Y., ve Chu, C. W. (2009). A comparison of univariate methods for forecasting container throughput volumes. *Mathematical and Computer Modelling*, 50(7-8), 1045-1057.
- Ping, F. F., ve Fei, F. X. (2013). Multivariant forecasting mode of Guangdong province port throughput with genetic algorithms and Back Propagation neural network. *Procedia-Social and Behavioral Sciences*, 96, 1165-1174.
- Rashed, Y., Meersman, H., Van de Voorde, E., ve Vanelslander, T. (2017). Short-term forecast of container throughput: an ARIMA-intervention model for the port of Antwerp. *Maritime Economics & Logistics*, 19(4), 749-764.
- Schulze, P. M., ve Prinz, A. (2009). Forecasting container transshipment in Germany. *Applied Economics*, 41(22), 2809-2815.
- Seabrooke, W., Hui, E. C., Lam, W. H., ve Wong, G. K. (2003). Forecasting cargo growth and regional role of the port of Hong Kong. *Cities*, 20(1), 51-64.
- Sengönül, G., ve Esmer, S. (2016). Container Transportation At The Black Sea: An Evaluation of The Ports In Turkey. *Karadeniz Arastirmalari*, (49), 139-141
- Shin, C. H., ve Jeong, S. H. (2011). A study on application of ARIMA and neural networks for time series forecasting of port traffic. *Journal of Navigation and Port Research*, 35(1), 83-91.
- Shu, M. H., Huang, Y. F., ve Nguyen, T. L. (2013). Forecasting models for the cargo throughput at Hong Kong Port and Kaohsiung Port. *Recent Researches in Applied Economics and Management*. WSEAS Press, Chania, Crete Island, Greece, 507.
- Shu, M. H., Nguyen, T. L., HSU, B., Lu, C., ve Huang, J. C. (2014). Forecasting Cargo Throughput with Modified Seasonal ARIMA Models. *WSEAS Transactions on Mathematics*, 13, 171-181.

- Shumway, R. H., ve Stoffer, D. S. (2011). *Time Series Analysis and Its Applications With R Examples* (Üçüncü Baskı). New York: Springer.
- Syafi'i, S. (2006). Multivariate autoregressive model for forecasting the demand of container throughput in Indonesia. *Media Teknik Sipil*, 6(2), 129-136.
- Tian, X., Liu, L., Lai, K. K., ve Wang, S. (2013). Analysis and forecasting of port logistics using TEI@ I methodology. *Transportation Planning and Technology*, 36(8), 685-702.
- Tür, R., Küçükosmanoğlu, A., ve Küçükosmanoğlu, Ö. (2013). Antalya Limanı Konteyner Trafikinin Bulanık Sinir Ağı ile Tahmini. *Dokuz Eylül Üniversitesi Denizcilik Fakültesi Dergisi*, 5(2), 109-120
- Türkiye Liman İşletmecileri Derneği (TÜRKLİM). (2017). *Türk Limancılık Sektörü 2017 Raporu*.
- Türkiye Liman İşletmecileri Derneği (TÜRKLİM). (2018). *Türk Limancılık Sektörü 2018 Raporu*.
- Tsay, R. S. (2002). *Analysis of Financial Time Series Financial Econometrics*. Canada: John Wiley & Sons, Inc.
- Twrdy, E., ve Batista, M. (2013). A Dynamical Model of Container Throughput of The North Adriatic Multiport Gateway Region. *Pomorstvo / Journal of Maritime Studies*, 27(2), 361–367.
- Twrdy, E., ve Batista, M. (2014). Competition between container ports in the Northern Adriatic. *International Journal for Traffic and Transport Engineering*, 4(4), 363-371.
- Twrdy, E., ve Batista, M. (2016). Modeling of container throughput in Northern Adriatic ports over the period 1990–2013. *Journal of Transport Geography*, 52, 131-142.
- Van Dorsser, J. C. M., Wolters, M., ve Van Wee, G. P. (2012). A Very Long Term Forecast of the Port Throughput in the Le Havre-Hamburg Range up to 2100. *European Journal of Transport and Infrastructure Research (EJTIR)*, 12 (1), 2012.
- Veenstra, A. W., ve Haralambides, H. E. (2001). Multivariate autoregressive models for forecasting seaborne trade flows. *Transportation Research Part E: Logistics and Transportation Review*, 37(4), 311-319.
- Wei, W. W. S. (2006). *Time Series Analysis Univariate and Multivariate Methods* (İkinci Baskı). ABD: Pearson Education, Inc.
- Weideman, J., Inglesi-Lotz, R., ve Van Heerden, J. (2017). Structural breaks in renewable energy in South Africa: A Bai & Perron break test application. *Renewable and Sustainable Energy Reviews*, 78, 945-954.

- Xiao, Y., Wang, S., Xiao, M., Xiao, J., ve Hu, Y. (2017). The analysis for the cargo volume with hybrid discrete wavelet modeling. *International Journal of Information Technology & Decision Making*, 16(03), 851-863.
- Xie, G., Wang, S., Zhao, Y., ve Lai, K. K. (2013). Hybrid approaches based on LSSVR model for container throughput forecasting: a comparative study. *Applied Soft Computing*, 13(5), 2232-2241.
- Xie, G., Zhang, N., ve Wang, S. (2017). Data characteristic analysis and model selection for container throughput forecasting within a decomposition-ensemble methodology. *Transportation Research Part E: Logistics and Transportation Review*, 108, 160-178.
- Yıldırım, M. S., Gökkuş, Ü. ve Aydın, M. M. (2017, September). Comparison of the Prediction Performances of the Soft Computing Regression Models for a Sea Port Cargo Throughput. ICADET. II. International Conference on Advanced Engineering Technologies, 578-58.
- Zhang, C., Huang, L., ve Zhao, Z. (2013). Research on combination forecast of port cargo throughput based on time series and causality analysis. *Journal of Industrial Engineering and Management*, 6(1 LISS 2012), 124–134.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : BAL, Elif Tuçe
 Uyuđu : T.C.
 Doğum tarihi ve yeri : 11.02.1990, Kırıkkale
 Medeni hali : Evli
 Telefon : 0 (326) 613 10 44
 e-mail : etuce.isbilen@iste.edu.tr



Eđitim

Derece	Eđitim Birimi	Mezuniyet Tarihi
Yüksek lisans	İskenderun Teknik Üniversitesi / Deniz Ulaştırma Mühendisliđi	Devam ediyor
Lisans	Dokuz Eylül Üniversitesi/ Denizcilik İşletmeleri ve Yönetimi	2013
Lise	Sırrı Yırcalı Anadolu Lisesi	2008

İş Deneyimi

Yıl	Yer	Görev
2015-Halen	İskenderun Teknik Üniversitesi	Araştırma Görevlisi

Yabancı Dil

İngilizce

Yayımlar

Bal, E , Çalışır, V . (2018). Konteyner Elleçleme İçin Ekonometrik Tahminleme: ARMA Modeli Uygulaması. *OPUS Uluslararası Toplum Araştırmaları Dergisi*, 9 (16), 2067-2096.

DİZİN

A

ACF · 30, 85, 88, 89, 93
 ADF · 35, 36, 37, 98, 99, 100,
 101, 103, 123
 AR · 25, 26, 27, 31, 34, 37, 82,
 83, 85, 86, 87, 96, 97, 107,
 108, 109, 110
 ARIMA · 59, 60, 62, 64, 68, 82,
 84, 85
 ARIMAX · 66, 68
 ARMA · 34, 53, 84, 88

B

Birim kök · 30, 34, 35, 37, 40,
 43, 44, 98, 99, 100
 Birim kök hipotezi · 35, 44
 Birim kök testi · 30, 34, 35, 40,
 43, 99, 123
 Box – Jenkins · 1, 2, 24, 51, 53,
 59, 60, 82, 83, 96, 123, 124
 Breusch-Pagan-Godfrey · 93, 94,
 110, 112, 113, 115, 117, 119,
 124

Ç

Çoklu kırılma noktası testi · 44,
 105, 123

D

Deterministik mevsimsellik · 46,
 96, 104, 105, 108, 124
 Deterministik trend · 29, 36, 38,
 39, 40, 41, 46, 96, 104, 105,
 108, 124
 DF GLS · 35, 36, 37, 98, 99, 100,
 101, 103
 Durağanlık · 24, 25, 29, 30, 31,
 34, 40, 98, 102, 103, 104

F

Fark durağan · 39, 41

G

Gecikme operatörü · 25, 26

J

Jarque-Bera · 93, 110, 112, 113,
 116, 117, 119, 124

K

Korelogram · 30, 32, 33, 92, 93,
 96, 97, 98, 102, 103, 107, 108,
 109, 111
 Korelasyon katsayısı · 31, 86, 94
 Kovaryans · 24, 25, 30, 31
 KPSS · 35, 36, 37, 38, 98, 99,
 100, 101, 103
 Kukla değişken · 42, 43, 44, 45,
 46, 47, 62, 74, 96, 104, 105,
 106, 107, 108, 109, 111, 112,
 114, 115, 116, 123

M

MA · 34, 61, 75, 82, 83, 85, 87,
 97, 107, 108, 110

P

PACF · 30, 85, 88, 89, 93
 PP · 35, 36, 37, 98, 99, 100, 101,
 103

R

Rassal yürüyüş · 25, 27, 28, 29,
 32, 36, 38, 40, 41, 83

S

SARIMA · 60, 62, 63, 64, 65, 66,
 68, 75, 76
 Stokastik mevsimsellik · 47
 Stokastik trend · 28, 29, 40, 41,
 46, 47, 84, 104, 107, 108
 Stokastik süreç · 24, 25, 28, 83

T

Trend durağan · 38, 39, 40, 123

Y

Yapısal kırılma · 42, 43, 44, 45,
 82, 105, 106, 107, 108, 109,
 111, 112, 114, 115, 116, 123



TEKNOVERSİTE



teknoversite **AYRICALIĞINDASINIZ**

İSTE

