

Konteyner Elleçleme İçin Ekonometrik Tahminleme: ARMA Modeli Uygulaması¹

DOI: 10.26466/opus.485722

*

Elif Tuçe Bal * - Vahit Çalışır**

* Arş. Gör., İskenderun Teknik Üniversitesi, İskenderun/ Hatay / Türkiye

E-posta: etuce.isbilen@iste.edu.tr

ORCID: [0000-0003-1855-248X](https://orcid.org/0000-0003-1855-248X)

** Dr. Öğr. Üyesi, İskenderun Teknik Üniversitesi, İskenderun/ Hatay / Türkiye

E-posta: vahit.calisir@iste.edu.tr

ORCID: [0000-0001-6575-8988](https://orcid.org/0000-0001-6575-8988)

Öz

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. Aylık öngörüler ile kendi paylarını hesaplayan kullanıcıların, bu hesaplamalar sayesinde liman operasyonlarını yönetmelerinin de kolaylaşabileceği düşünülmektedir. Çalışmada amaç doğrultusunda kısa dönemli öngörülerde diğer yöntemlere göre çok daha iyi olan Box – Jenkins yöntemi seçilmiştir. Sonuç olarak kısa dönemli Türkiye'deki ithalat ve ihracat konteynerlerin toplamına yönelik öngörü yapılmış ve Akaike ve Schwarz bilgi kriterlerinin model seçiminde her zaman sağlıklı sonuçlar vermediği ortaya koyulmuştur. Ayrıca çalışmada deterministik trend ve mevsimsellik değişkenlerinin modele direkt dahil edilmiş ve öngörülerde bu değişkenlerin etkileri direkt olarak yansıtılmıştır.

Anahtar Kelimeler: Konteyner Elleçlemesi, Zaman Serisi Analizi, ARMA Modeli, Nicel Karar Verme

¹ Bu makale, birinci yazarın İskenderun Teknik Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü'nde Dr. Öğr. Üyesi Vahit ÇALIŞIR danışmanlığında hazırlanan "Konteyner Elleçleme İçin Ekonometrik Tahminleme: ARMA Modeli Uygulaması" başlıklı yüksek lisans tezinden üretilmiştir.

Econometric Forecasting For Container Handling: ARMA Model Application

*

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. 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 accordance with purpose, in this study, Box - Jenkins method, which is much better than other methods in short term forecasting, has been selected. As a result, short-term the sum of Turkey's import and export container is forecasted monthly and it has been shown that the Akaike and Schwarz information criteria do not always provide healthy results in the choice of model. In addition, deterministic trend and seasonality variables were included directly in the study and the effects of these variables were directly reflected in the model.

Keywords: Container Handling, Time Series Analysis, ARMA Model, Quantitative Decision Making

Giriş

Dünya ticaretinin hızlı ve istikrarlı büyümesinin temellerini atan deniz taşımacılığında hızla artan konteyner taşımacılığı, dünya ticaretinin dinamiklerini temsil eden önemli göstergelerdendir (Schulze ve Prinz, 2009). Konteyner hareketleri temelde, yükün çıkış ve varış noktalarında meydana gelen ekonomik faaliyetlere bağlı olan, yük akışının doğrudan sonucudur (Amoako, 2002). Konteynerizasyon neredeyse tüm ithal/ihraç malzemeleri, bileşenler ve üretilmiş mallar için tercih edilen taşıma formudur, konteynerizasyonun büyümesi konteyner terminal operasyonları üzerinde anlamlı etkiye ve konteyner terminallerinin gelecekteki altyapı gereklilikleri üzerinde de önemli sonuçlara sahiptir (Mak ve Yang, 2007).

Liman tesislerini geliştirmek ve yeni liman kurmak için en önemli sorunlardan biri konteynere olan talep hakkındaki bilgidir (Syafi, 2006). Gelecek talebi en iyi şekilde karşılamak için, planlayıcıların limanın içindeki ve dışındaki var olan altyapıyı değerlendirmeleri gerekmektedir (Patil ve Sahu, 2016) ki bu değerlendirme limanın inşası, iyileştirilmesi ve günlük operasyon yönetimi için çok önemlidir (Peng ve Chu, 2009).

Limanın inşası, iyileştirilmesi gibi projeler kaynak ve zaman yoğun olduğu için geriye döndürülemezler (Patil ve Sahu, 2016). Ayrıca liman yapılarının inşası edilmesi liman kullanıcıları için genellikle büyük zaman kaybı ya da liman tesislerine sınırlı ulaşım anlamına gelmektedir (Peng ve Chu, 2009). Bu yüzden limanların operasyonlarıyla ilgili ekonomik olmayan kararlardan kaçmak için karar vericiler ya da ilgili otoriteler güvenli bir yol ile ticaret hacminin ya da konteyner trafiğinin öngörüsünü yapmak zorundadırlar (Gökkuş, Yıldırım ve Aydın, 2017). Gelecek liman çıktısına yönelik doğru öngörü yapamamak ise, liman inşası ya da tesis gelişimi yatırımlarında büyük kayıplarla sonuçlanabilmektedir (Peng ve Chu, 2009).

Limanlarda konteyner çıktısının tahmini, liman yöneticilerine sadece limanı hacim, genel yerleşim planı ve alanlara bölme açılarından geliştirme ile ilgili stratejik karar alma konusunda yardım etmez ayrıca limanda operasyon planlama kararları, liman ekipmanlarının programlanması gibi taktiksel ve operasyonel kararlarda (kısa ve orta vadeli kararlar) da yardım eder (Xie, Zhang ve Wang, 2017).

Devlet ulaştırma dairesi seviyesinde ise konteyner hacmi öngörüsü bölgesel ve ulusal taşıma planları için temel olur (Chou, Chu ve Liang, 2008). Gelecek çıktılarının doğru öngörülmesi, hem özel sektörün hem de devlet sektörünün gelecek ilerlemelerini planlama ve yönetmeleri için önem arz etmektedir (Gosasang, Chandraprakakul ve Kiattisin, 2011).

Literatür Taraması

Genel olarak deniz yük çıktılarının öngörüsü için kullanılan nitel ve nicel olmak üzere iki metot bulunmaktadır; nicel yöntemler daha objektif ve hassas olduğu için giderek artan ilgi görmektedir (Xiao, Wang, Xiao, Xiao ve Hu, 2017).

Nitel öngörü metotları ise gelecekteki gelişimi tahmin edebilmek için öncelikli olarak tarihsel verileri kullanır ve kişilerin tecrübe, bilgi ve analizlerine dayanır; nitel öngörü metotlarının objektiflikten yoksun olmak ve tahminlerin yüzeysel olması gibi bazı kusurları bulunmaktadır (Zhang, Huang ve Zhao, 2013).

Limanlarda öngörü ile ilgili ilk çalışmalara 1980'li yıllardan itibaren rastlanmaktadır. Birçok çalışmada en doğru tahmini elde edebilmek için birçok yöntem uygulanmış ve kıyaslama kıstaslarına göre en iyi olan yöntem belirlenmiş ve ileriye yönelik öngörüler bu yöntem üzerinden yapılmıştır.

Çoğu çalışma tek bir yöntem içerirse de bazı çalışmalar birkaç yöntemin birleşmesiyle oluşan karma metottan oluşmaktadır. Öngörü için sadece tek bir yöntemin kullanıldığı modeller üç sınıfa ayrılmaktadır: zaman serisi modelleri, nedensellik analizi modelleri ve doğrusal olmayan dinamik öngörü modelleri (Mo vd., 2018).

Çalışma zaman serileri modeli üzerinden yapıldığı için literatürde öngöründe zaman serisi modellerinin kullanıldığı çalışmalara değinilecektir. Zaman serisi modelleri üstel düzleştirme (ES), Otoregresif Tümlleşik Hareketli Ortalama (ARIMA), Mevsimsel Otoregresif Tümlleşik Hareketli Ortalama (SARIMA), Vektör Otoregresyon (VAR) , Klasik Ayırıştırma Modeli ve Grey Modeli içermektedir (Mo vd., 2018).

Zaman serisi ile ilgili ilk çalışma Klein ve Verbeke'nin (1987) Antwerp limanında aylık verilerle tek değişkenli zaman serisi kullanarak yaptıkları Antwerp limanındaki çalışmadır. İkili çalışmalarında Box-Jenkins modelini kullanmış ve modele transfer işlevini eklemişlerdir. Gooijer ve Klein (1989) tarafından Antwerp limanındaki çelik trafiği akışı için yapılan bir başka çalışmada ise çok değişkenli zaman serisi modeli kullanılmıştır.

Özellikle ARIMA ve mevsimsellik eklenerek oluşturulan SARIMA modellerine çalışmalarda sıkça rastlanmaktadır. Modeller bazı çalışmalarda direkt tahmin yöntemi olarak kullanılırken bazılarında ise ARIMA ve SARIMA modelleri karşılaştırılmıştır. Tahmin yöntemi olarak SARIMA modelinin kullanıldığı çalışma olan Farhan ve Ong'un (2018) çalışması yirmi limanı kapsamaktadır. Çalışmada her limanın zaman serisi davranışları izlenmiş ve her liman için SARIMA modeli ile kısa dönemli öngörü yapılmıştır ve bu öngörüler sonucunda limanların etkinliklerini, kapasitelerini ve pazar paylarını arttırmak için birçok strateji önerilmiştir.

Modellerin karşılaştırıldığı çalışmaların başında Klein'nun (1996) Antwerp limanında yaptığı çalışma gelmektedir. Klein çalışmasında ARIMA, SARIMA ve Dönüşüm ve müdahalenin olmadığı Mevsimsel Otoregresif Tümlşik Hareketli Ortalama (SARIMANT) modellerinin karşılaştırmasını yapmıştır. Çalışmalarında Kore limanları için ARIMA ve SARIMA modellerini karşılaştıran Min ve Ha (2014) 1994'ten 2010'a kadarki kısmı kapsayan çeyreklik verileri kullanmıştır.

ARIMA ailesinin dışsal değişken eklenmiş modeli olan ARIMAX bazen karşılaştırma amaçlı ARIMA ve SARIMA'nın yanına dâhil olmuş bazen de tek öngörü yöntemi olarak kullanılmıştır. Öncelikli amacı Slovenya'nın Koper limanı için etkin öngörü modeli oluşturmak olan Intihar, Kramberger ve Dragan'ın (2017) bu amaçlara ulaşabilmek için dinamik faktörleri yani gözlemleri etkileyen makro değişkenleri bulup sonrasında bu dinamik faktörleri temel alarak ARIMAX modeli oluşturmuşlardır. Rashed, Meersman, Van De Voorde ve Vanelsländer'in çalışmalarında (2017) SARIMA, ARIMA, Müdahale Analizinin olduğu SARIMA ve ARIMA ((S)ARIMA-Intervention Analysis) ve Dışsal Değişkenli Otoregresif Tümlşik Hareketli Ortalama Modelleri (ARIMAX) karşılaştırılmıştır.

ARIMA, SARIMA ve ARIMAX modelleri bazı çalışmalarda ise diğer modelin daha iyi olduğunu göstermek için karşılaştırma amacıyla kullanılmıştır. Örnek olarak 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'nun (2002) gerçek konteyner miktarlarını kullanarak artan 40'lık konteynerlerin kullanımının etkisini modellemeyi amaçladığı çalışma verilebilir.

Özellikle aylık verilerdeki mevsimsel hareketleri hesaba katan Schulze ve Prinz'in (2009) ise çalışmalarında Alman limanlarındaki konteyner aktarmalarının öngörüsünü yapmak için Holt-Winters Üstel Düzleştirme Modeli ile SARIMA modelini karşılaştırmıştır. 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.

Shu, Nguyen, Hsu, Lu ve Huang (2014) Hong Kong ve Kaoshiung limanları için hem yük hem de konteyner çıktılarının öngörüsünü ARIMA ve Grey Model ile yapmış ve bu iki modelin doğruluğunu arttırmak için kalıntılarında Fourier ile değişiklik yapmıştır. Pang ve Gebka (2017) çalışmalarında 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 çıktılarını öngörü amaçlı kullanmıştır.

Diğer zaman serisi modellerinin kullanıldığı çalışmalardan biri Venstra ve Haralambides (2001) ham petrol, demir cevheri, tahıl ve kömürün ana ticaret rotalarındaki akışının uzun dönemli öngörüsünü yapabilmek için vektör otoregresyon (VAR) modelini kullandığı çalışmadır. Bir başkasında Fourier ile düzeltilmiş kalıntılı Grey Verhulst Modelinin etkinliğini göstermek için Guo, Song ve Ye (2005) 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.

Zaman serilerinin, nedensellik analizi ve doğrusal olmayan modellerle karşılaştırıldığı çalışmalar da bulunmaktadır. Bunlardan biri Peng ve Chu'nun (2009) konteyner çıktılarını en iyi tahminleyen modeli bulmak için yaptıkları çalışmadır. Araştırmacılar Klasik Ayırıştırma 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. Bir başka çalışmada Chen ve Chen (2010) Tayvan'da yer alan Kaohsiung, Keelung ve Taichung limanlarıyla ilgili öngörü yapabilmek için Genetik Programlama, X-11 ve SARIMA'yı karşılaştırmıştır.

Patil ve Sahu (2016) ise çalışmalarında Tek Değişkenli ve Çok Değişkenli Toplamsal Regresyon Modeli ve Zaman Serisi Modellerin karşılaştırmasını yaparak Mumbai limanına gelen ve giden yüklerin tahminlemesini yapmayı amaçlamaktadır.

Bazı modellerde ise zaman serisi modelleri diğer modellerle birleştirilerek karma modeller oluşturulmuştur. Li, Chen ve Cui'nin (2008) Doğrusal Üstel Düzleştirme Modeli, Basit Hareketli Ortalama Metodu ve Elman Ağı'nı birleştirerek oluşturduğu doğrusal olmayan karma model bu duruma örnek teşkil etmektedir. Tian, Liu, Lai ve Wang (2013) tarafından yapılan çalışma ise, 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.

Xie, Wang, Zhao ve Lai (2013) tarafından yapılan çalışmada En Küçük Kareler Destek Vektör Regresyonu (LSSVR) temelinde SARIMA-LSSVR, Mevsimsel Ayırıştırma Modeli (X-12-ARIMA) – LSSVR (SD-LSSVR), Klasik Ayırıştırma Modeli - LSSVR (CD-LSSVR) olmak üzere üç farklı karma model oluşturulmuş ve bu modeller karşılaştırılmıştır.

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 oluşturulmuş ve model Geri Yayımlı Yapay Sinir Ağları (BP-ANN), SARIMA ve PPR ile karşılaştırılmıştır.

Mohamed Ismael ve Vandyck'in (2016) Cibuti sınırları içerisinde yer alan Doraleh limanı üzerinden yaptığı konteyner çıktısının öngörüm-

lenmesine yönelik olan çalışmada Üstel Düzleştirme Modeli, Grey Model, Doğrusal Regresyon Modelleri ve bu modellerin birleşimi kullanılmıştır. Chen, Chen ve Li (2016) çalışmalarında Pearl Eğrisi Modeli, Grey Model (GM(1,1)) ve Karesel Üstel Düzleştirme Modelini ve bu üç modelin birleşimini kullanmıştır.

Mo vd. (2018) çalışmalarında Veri İşlemenin Grup Metodunu (GMDH) tanıtmışlardır. Model orijinal konteyner çıktısı serisini doğrusal ve doğrusal olmayan şekilde ikiye ayırarak doğrusal olan kısmını SARIMA ile doğrusal olmayan kısmını ise Geriye Yayılımlı (BP) Sinir Ağları, Destek Vektör Makinası (SVM) ve Genetik Programlama (GP) ile tahmin etmektedir.

Türkiye’de yapılan çalışmalar incelendiğinde en çok kullanılan yöntemlerin başında regresyon analizi gelmektedir örnek olarak Akar ve Esmer (2017), Şengönül ve Esmer (2016) tarafından yapılan çalışmalar gösterilebilmektedir. Regresyon analizinin yanında akademik çalışmalarda doğrusal olmayan yöntemlere rastlanırken bazı çalışmalarda ise bu yöntemler karşılaştırılmıştır (Tür, Küçükosmanoğlu ve Küçükosmanoğlu, 2013).

Ayrıca sadece doğrusal olmayan yöntemlerin kullanıldığı ve karşılaştırıldığı çalışmalar da bulunmaktadır; Gökkuş, Yıldırım ve Aydın (2017), Yıldırım, Gökkuş ve Aydın (2017). Zaman serisinin kullanıldığı çalışmalara daha çok fizibilite raporlarından rastlanmaktadır, akademik çalışmalarda zaman serilerine rastlanmamıştır.

Türkiye’ye yönelik yapılan çalışmalarda daha çok uzun dönemli öngörü yapılmıştır. Kısa dönemli öngörü çalışması olarak Tür, Küçükosmanoğlu ve Küçükosmanoğlu’nun (2013) Antalya limanı için yaptığı çalışma ile karşılaşılmaktadır. Bu çalışma dışında kısa dönemli ve Türkiye’deki tüm limanları kapsayan çalışma bulunmamaktadır. Bu durum bu çalışmanın motivasyonunu oluştururken, ARIMA yönteminin kısa dönemli tahminlerde diğer yöntemlere kıyasla daha iyi oluşu yöntem olarak ARIMA’nın seçilmesinin uygun olacağı düşüncesini doğurmuştur.

ARIMA’nın, 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 yönetebilmesi (Shu, Nguyen, Hsu, Lu ve Huang, 2014), dinamik

yapıları kapsayan esnekliği ile kısa dönemli öngörülerde doğal avantaj elde etmesi (Farhan ve Ong, 2018) bu düşünceyi pekiştirmiştir.

Yöntem

Çalışmanın amacı 2018'in son üç ayı ve 2019 yılı için TEU bazında Türkiye'de elleçlenecek olan konteyner miktarının öngörüsünü 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 (Box – Jenkins) modeli uygulanmak istenmiş ancak veri setinin analizi ile en uygun modelin kukla değişkenleri, deterministik trend ve mevsimselliği içeren otoregresif ve hareketli ortalama terimlerinden oluşan model olduğu ortaya koyulmuştur.

Otoregresif (AR) Model

Otoregresif modellerde bağımlı değişkenin gecikmeli değerleri alınmaktadır. p . dereceden otoregresif süreç aşağıdaki şekilde ifade edilmektedir (Carnot, Koen ve Tissot, 2005):

$$y_t = a_1y_{t-1} + a_2y_{t-2} + \dots + a_p y_{t-p} + \varepsilon_t$$

Eşitlikteki ε_t beyaz gürültüyü ifade ederken, a_1 'den a_p kadar olan katsayılar bilinmeyen parametreleri ifade etmektedir (Heij vd., 2004). p 'nin 1 olması durumu basit AR(1) modelini ifade ederken aynı mantıkla ilerlendiğinde AR(2) modeli p 'nin 2 olduğu durumu ifade eder, eşitlik ise AR(p) modelini ifade etmektedir.

Hareketli Ortalama (MA) Süreci

Hareketli ortalama (MA) modelinde bağımlı değişken yalnızca gözlemlenemeyen şoklara göre açıklanır; gözlemlenemeyen veri ile model tahmin etmek mümkün değildir ancak daha önceki hatalar kullanılabilir; bir gecikmeli hareketli ortalama modelinde (MA(1)) en son olan öngörü hatası kullanılırken iki gecikmelide (MA(2)) son iki öngörü hatası kullanılır (Evans, 2003).

q dereceli hareketli ortalama (MA(q)) ise aşağıdaki gibi ifade edilmektedir (Carnot vd., 2005).

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

ARMA Modeli

Otoregresif ve hareketli ortalama modellerinin birleşmesi ile ARMA(p, q) modeli oluşmaktadır. Model aşağıdaki şekilde ifade edilmektedir (Carnot vd., 2005):

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

Durağanlık

Zamana göre sıralanmış rassal değişkenlerin toplamına rassal ya da stokastik süreç adı verilmektedir (Gujarati, 2004). 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 skotastik sürecin durağan olmasından söz edilebilir (Gujarati, 2004). Otoregresif (AR) ve hareketli ortalamalardan (MA) meydana gelen Box – Jenkins yönteminin uygulanması için zaman serisinin öncelikle durağan olması gerekmektedir. Durağanlık analizi birim kök testi ile yapılabilir.

Birim Kök Testi Genişletilmiş Dickey-Fuller ADF

Birim kökler için istatistiksel testler geliştirilmiştir (Lütkepohl ve Krätzig, 2004). Bu çalışmada birim kök testlerinden biri olan Genişletilmiş Dickey-Fuller (ADF) testi kullanılacaktır.

ADF testi DF testinin genişletilmiş halidir bu yüzden öncelikle DF testinden bahsedilecektir. Aşağıdaki eşitlikte Δy_t , y_t 'nin ilk farkını ifade ederken ($\Delta y_t = y_t - y_{t-1}$); 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, trend değişkeni ve y_t 'nin bir gecikmesi ile regresyona tabi tutulmuştur (Gujarati, 2011).

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

Birim kök hipotezi olarak ifade edilen H_0 hipotezi, β_3 'ün yani y_{t-1} 'in katsayısının sıfır olduğudur, alternatif hipotez ise β_3 'ün sıfırdan küçük olmasıdır, $\beta_3 < 0$, H_0 hipotezinin ret edilememesi serinin durağan olmadığını ifade etmektedir (Gujarati, 2011).

$\beta_3 = 0$ hipotezi normal koşullarda t testi ile ölçülebilir ancak t testi için serinin durağan olması gerekir, bu yüzden t testi yerine bu hipotezi test edebilmek için τ (tau) kullanılmaktadır, literatürde bu teste Dickey-Fuller (DF) testi denilmektedir (Gujarati, 2011).

DF testi hata terimlerinin (u_t) ilintisiz olduğunu varsayar (Gujarati, 2004). Her zaman durum böyle olmadığı için Dickey ve Fuller hata terimlerinin ilintili olduğu durumlar için de Genişletilmiş Dickey-Fuller testini geliştirmişler (Gujarati, 2004). Buradaki genişletilmiş ifadesi bağımlı değişkenin gecikmelerinin eşitliklere eklenmesinden ileri gelmektedir ve yeni eşitlik aşağıdaki gibi olmaktadır (Gujarati, 2004):

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

Eşitlikte u_t saf beyaz gürültü hata terimidir, $\Delta y_{t-1} = y_{t-1} - y_{t-2}$, $\Delta y_{t-2} = y_{t-2} - y_{t-3}$..., hata terimlerini 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). ADF testi üç farklı şekilde uygulanabilmektedir (Gujarati, 2011):

1. Rassal yürüyüş: $\Delta y_t = \beta_3 y_{t-1} + u_t$
2. Kayan terimli rassal yürüyüş: $\Delta y_t = \beta_1 + \beta_2 t + \beta_3 y_{t-1} + u_t$
3. Kayan terim ve deterministik trendli rassal yürüyüş:

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

Bazı zaman serileri durağan değildir. Durağan olmaları için zaman serisinin farkının alınması gerekmektedir. Otoregresif Tümlleşik Hareketli Ortalama Modelinde (ARIMA) yer alan tümlleşik (integrated) Otoregresif Hareketli Ortalama Modeli kurulurken zaman serisinin durağanlaştırılması için farkının alındığının göstergesidir. Eğer zaman serisi birinci dereceden tümlleşik ise bu zaman serisinin durağanlaştırılması için bir farkının alındığının göstergesidir bunu $I(1)$ olarak da ifade edebiliriz. Eğer zaman seri 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.

Zaman serilerinin birinci dereceden bütünlleşik olma durum diğer durumlara göre daha çok rastlanılan bir durumdur. Zaman serisinin durağanlaştırmak için d kere farkını aldığımızda ve bunun için ARMA(p,q) modeline başvurduğumuzda orijinal zaman serisinin ARIMA(p,d,q) olduğunu ifade edebiliriz ki bu otoregresif tümlleşik hareketli ortalama modelidir, burada p otoregresif terimlerin sayısını, d durağanlaştırmak için serinin kaç defa farkının alındığını, q ise hareketli ortalama terimlerinin sayısını göstermektedir (Gujarati, 2004). Örneğin 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).

Box – Jenkins Yönteminin Basamakları

Zaman serisinin durağan olduğu ortaya koyulduktan sonra ya da durağan olmayan zaman serisi durağanlaştırdıktan sonra yöntem uygulanabilmektedir. Yöntem üç kısma ayrılmaktadır: (1) modelin tanımlanması, (2) modelin tahmin edilmesi, (3) modelin kontrol edilmesi/hata kontrolü; bu üç aşamadan sonra istenilen model elde edilirse o zaman öngörü yapılabilir ve modelin performansı gözlenebilir (Pankratz, 2012).


1. **Modelin Tanımlanması:** İlk adım olan modelin tanımlanması aşamasında araştırmacı görsel olarak zaman serisinin grafiğini,

- otokorelasyon fonksiyonunu, kısmi otokorelasyon fonksiyonunu değerlendirir; bu değerlendirme araştırmacıya zaman serisindeki uç değerler, kayıp değerler ve yapısal kırılmalarla ilgili bilgi sağlar (Enders, 2015). Bu adımda ayrıca gecikmelerin dereceleri, zaman serisinin durağanlığına göre fark alınıp alınmayacağı belirlenir.
2. **Modelin Tahmin Edilmesi:** Uygun gecikmelerin belirlenmesinin ardında bu aşamada modelde yer alan otoregresif ve hareketli ortalama terimlerinin parametreleri belirlenir (Gujarati, 2004). Bu aşamada önemli olan iyi uyuma sahip durağan ve cimri (az sayıda değişken kullanımı) olan modelin seçilmesidir (Enders, 2015).
 3. **Modelin Kontrol Edilmesi/Hata Kontrolü:** Bu aşamada modelin yeteri kadar iyi olup olmadığı, model için önemli olmayan değişkenlerin modele dâhil edilip edilmediği, dâhil edilmesi gereken değişkenlerin modelde yer alıp almadığı değerlendirilir (Pankratz, 2012). Seçilen modelin basit şekilde test edilmesindeki yöntemlerden biri artıkların (hataların) beyaz gürültü olup olmadığıdır, eğer artıklar beyaz gürültü ise modeli kabul edebiliriz değil ise en baştan başlanması gerekir (Gujarati, 2004).

Bulgular

Araştırmada kullanılacak olan veri seti Deniz Ticareti Genel Müdürlüğü İstatistik Bilgi Sisteminden elde edilmiştir. 2004-2018 yıllarına ait hazırlanan aylar bazında ihracat ve ithalat toplam TEU istatistikleri toplanmıştır. Toplam elleçlemelere kabotaj ve transit yükler dahil edilmemiştir. 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 ve 2019 yılı için aylık öngörü yapılmıştır. Analizler için EViews programı kullanılmıştır.

Box – Jenkins yönteminin uygulanması için ilk şart serinin durađan olmasıdır. Durađan olmayan bir seriye bu yöntem uygulanmamaktadır. Bu yüzden Box – Jenkins yönteminin ilk aşaması olan modelin tanımlanması aşamasında ilk yapılacaklardan biri veri setinin grafiđine bakarak veri setinin durađanlıđı, yapısı hakkında ön bilgi edinmektir.



Şekil 1. Veri Setinin Grafiđi

Veri setine ait Şekil 1’de yer alan grafik incelendiđinde serinin artan bir trende sahip olduđu ve durađan olmadıđı izlenimi uyanmaktadır. Grafiđin aylara göre deđiřimi incelendiđinde ise 1. ve 2. aylar yıl bazında elleçlemenin en düşük olduđu aylar olarak gözlenmektedir. Veri setinin belli dönemlerde benzer davranıřlar sergilemesi mevsimsellik řüphesi 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.

Durađanlıđ Testi

Veri setinin durađanlıđını test etmek amacıyla veri setine Geniřletilmiş Dickey-Fuller (ADF) testi uygulanmıřtır. %1, %5 ve %10 seviyelerinde göre kritik deđerler üç durum için deđerlendirilmiřtir. Birinci durum sabitin dikkate alındıđı durumu ifade ederken, ikinci durum sabit ve dođrusal trendin dikkate alındıđı durumu, üçüncü durum ise sabit ve dođrusal trendin dikkate alınmadıđı durumu ifade etmektedir.

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 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.

Modele Trendin ve Mevsimsellik Değişkenlerinin Eklenmesi

Yapılan ADF testi sonucunda zaman serisinin durağanlığının trendden ayıklanma sonucunda sağlanacağını ortaya koyulmuştur. Bu çalışmada seriyi trendden ayıklama yolu değil modele trend ekleyerek modeli durağanlaştırma yolu izlenmiştir. Modele trend değişkeni eklendiğinde Tablo 1’de gösterilen sonuçlar elde edilmiştir.

Tablo 1. 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	.0000
@TREND	2598.356	59.64699	43.56224	.0000

Bu sonuç modelde trend değişkeninin anlamlılığını ortaya koymaktadır. Bir diğer önemli nokta modelde deterministik mevsimselliğin yer alıp almadığıdır. Deterministik mevsimselliğin ölçülmesi için ise modele her ayı temsil eden kukla değişkenler eklenmiştir. Trend ve mevsimsel kukla değişkenler eklendiğinde ortaya çıkan sonuçlar Tablo 2’de gösterilmiştir. Kukla değişkenlerin eklendiği durumlarda regresyonda hata çıkmaması için iki alternatif yol izlenmektedir bunlardan biri sabiti çı-

karmak ikincisi ise on iki aya göre değil de on bir aya göre kukla değişken koymaktır. Bu çalışmada ilk yol tercih edilmiştir.

Tablo 2. Toplam ithalat ihracat elleçlemesinin (TEU) bağımlı değişken, trend ve mevsimsel kukla değişkenlerin bağımsız değişken olduğu regresyon sonuçları

Bağımsız Değişken	Katsayı	Standart		Olasılık Değeri
		Hata	t-İstatistik	
@TREND	2587.372	52.83704	48.96890	.0000
D1 (Ocak)	199556.9	9766.138	20.43356	.0000
D2 (Şubat)	180044.4	9788.552	18.39336	.0000
D3 (Mart)	230436.0	9811.200	23.48704	.0000
D4 (Nisan)	228378.0	9834.079	23.22312	.0000
D5 (Mayıs)	252183.3	9857.189	25.58370	.0000
D6 (Haziran)	243881.2	9880.527	24.68302	.0000
D7 (Temmuz)	240038.5	9904.092	24.23630	.0000
D8 (Ağustos)	241225.2	9927.882	24.29775	.0000
D9 (Eylül)	218894.8	9951.896	21.99529	.0000
D10 (Ekim)	234283.5	9976.132	23.48440	.0000
D11 (Kasım)	215992.5	10000.59	21.59798	.0000
D12 (Aralık)	231711.4	10025.26	23.11275	.0000

Olasılık değerlerine göre tüm sonuçlar anlamlı çıkmıştır. Bu durum seride deterministik mevsimselliğin varlığını ortaya koymaktadır. Deterministik mevsimselliğin varlığının göz ardı edilmemesi için modele mevsimsellik kuklaları da eklenmiştir.

Veri Setine Yapısal Kırılma Testinin Uygulanması

Veri setinin grafiği incelendiğinde dikkat çeken bir başka nokta da seride kırılmaların bulunma ihtimalinin olduğudur. Bu durumu test etmek için trend ve mevsimsel kuklaların eklenmesi ile oluşan regresyonun kalıntılarına çoklu kırılma noktası testi olan Bai-Perron testi uygulanmıştır. 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 bu kırılma noktaları modele eklenmiştir. 2008'in 12. ayına işaret eden

kırılma 2008 krizini ifade ederken 2015'in 1. ayına işaret eden kırılma sektörel durgunluğa işaret etmektedir. Kırılma noktalarının eklenmesi ile oluşan yeni model Tablo 3'te gösterilmektedir.

Tablo 3. 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	3781.794	101.4098	37.29218	.0000
D1 (Ocak)	183543.4	7052.009	26.02711	.0000
D2 (Şubat)	162836.4	7087.520	22.97509	.0000
D3 (Mart)	212033.7	7124.299	29.76204	.0000
D4 (Nisan)	208781.2	7162.324	29.14992	.0000
D5 (Mayıs)	231392.1	7201.576	32.13076	.0000
D6 (Haziran)	221895.6	7242.036	30.63995	.0000
D7 (Temmuz)	216858.5	7283.684	29.77319	.0000
D8 (Ağustos)	216850.8	7326.498	29.59814	.0000
D9 (Eylül)	193325.9	7370.459	26.22983	.0000
D10 (Ekim)	207520.2	7415.546	27.98448	.0000
D11 (Kasım)	188034.8	7461.739	25.19986	.0000
D12 (Aralık)	209594.6	7388.740	28.36676	.0000
2008 Krizi	-98494.97	7818.017	-12.59846	.0000
Sektörel Durgunluk	-64554.82	7258.441	-8.893758	.0000

Tablo 3'te 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.

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

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 Tablo 4'te gösterilmiştir.

Tablo 4. Modellerde kullanılan AR ve MA terimleri

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

İlk 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 değerlendirilmeye alınmamıştır. Gerçek değerlerin öngörü aralığının dışına çıktığı modeller ise 4., 5., 7. ve 9. modellerdir.

Oluşturulan Modellerin Tahminlenmesi ve Uygun Modellerin Seçilmesi ve Öngörü Sonuçları

Modellerin öncelikle geçerli olabilmeleri için model hatalarının normal dağılımlı ve sabit varyanslı olmaları gerekmektedir. Bu yüzden dört modelin elenmesinin ardından geriye kalan modellerin kalıntıları öncelikle normallik testi olan Jarque-Bera (JB) ve değişen varyans testi olan Breusch-Pagan-Godfrey (BPG) testlerine tabi tutulmuştur.

Tablo 5. Modeller Ait Değerler

	M1	M2	M3	M6	M8
JB (Olasılık)	0.58343	0.92806	0.54011	0.40323	0.70315
BPG (Olasılık)	0.0836	0.0220	0.0346	0.1422	0.0829
RMSE	23041.6	22658.32	24040.55	24325.71	22508.99
MAE	19573.5	17192.8	19138.0	18795.7	17834.7
MAPE	2.88445	2.55599	2.85340	2.76731	2.63410

Bu testten geçen modellerin ise 2018'in birinci ayından 2018'in doku-zuncu ayına kadar geçen aralığı tahmin etme durumlarına yani Ortalama karesel hatanın karekökü (RMSE), Ortalama mutlak hata (MAE) ve Ortalama mutlak yüzde hatalarına (MAPE) bakılarak karar verilmiştir. Karar verme sırasında kullanılan bir diğer değerlendirme aracı Akaike ve Schwarz bilgi kriterleri ancak burada değerler birbirine çok yakın olduğu için dikkate alınmamıştır. Ayrıca ilk elemde daha düşük bilgi kriteri değerine sahip olan bazı modellerin elenmiş olması bu kriterlerin güvenilirliğini etkilemiştir.

Tablo 5'te yer alan verilere göre değerlendirme yapıldığında tüm modellerin JB olasılıkları 0.05 olasılık değerinin üzerindedir bu kalıntıların normal dağıldığını ifade eden H_0 hipotezinin ret edilemeyeceğini gösterir sonuç olarak tüm modellerin hataları normal dağılmaktadır. Bir eşitliğin model ifade etmesi için ikinci önemli nokta modelin hatalarında değişen varyansın görülmemesidir. Bu durumun tespiti için yapılan test ise BPG testidir. Bu testin H_0 hipotezi kalıntıların hatalarında değişen varyansın olmadığıdır. BPG testinin olasılık değerlerine bakıldığında H_0 hipotezi Model 2 (M2) ve Model 3 (M3) için ret edilirken Model 1(M1), Model 6 (M6) ve Model 8 (M8) için ret edilemez. Bu durum da M1, M6 ve M8 için hatalarda değişen varyans durumunun gözlenmediğinin göstergesidir. Sonuç olarak çalışmaya model olarak M1, M6 ve M8 uygundur.

Bu modeller arasından tercih yapmak için de en önemli kriterler RMSE, MAE ve MAPE'dir. Burada en uygun model bu değerlerin en düşük olduğu modeldir. Değerler karşılaştırıldığında en düşük değerler M8'e aittir. Bu yüzden 2018'in son ayını ve 2019 yılını kapsayan öngörü modeli için M8 seçilmiştir. Bu modele ait öngörü değerleri Tablo 6'da gösterilmektedir.

Tablo 6. Öngörü Sonuçları

Zaman	Öngörü Üst Sınırı	Öngörü Deęeri	Öngörü 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

Sonuçlar

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 dięer modellere göre çok daha iyi olan ARMA modeli seçilmiş ve bu model üzerinden öngöründe bulunulmuştur.

Box – Jenkins yöntemi olarak da geçen ARMA modelinin uygulanması için öncelikle zaman serisinin duraęan olması gerekmektedir. Bu yüzden öncelikle zaman serisine ADF birim kök testi uygulanmış ve duraęan olup olmadığına bakılmıştır. ADF testi sonuçları serinin trend duraęan olduğunu ortaya koyduğu için modele trend deęişkeni eklenmiştir.

Aylık verilerle çalışıldığı için trend deęişkeninden sonra mevsimselliğin varlığı mevsimsel kukla deęişkenlerle sınanmış ve kukla deęişkenler anlamlı bulunduğu için kukla deęişkenler de modele eklenmiştir.

Kukla deęişkenlerin 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 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.

Çalışmanın 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.

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.

Çalışmanın bir başka amacı ve bu amaç doğrultusundaki sonucu ise Türkiye için aylık öngörü yaparak liman yöneticilerinin aylık elleçlemeler hakkında bilgi sahibi olmalarını sağlamaktır. 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.

Bu çalışmanın devamı olarak doğrusal trende ve mevsimsellik etkilerine maruz kalan veri seti için burada kullanılan yöntem ile öngörü yapılabilir bilgi kriterlerinin geçerlilikleri test edilebilir. Bir başka seçenek olarak Türkiye'nin aylık elleçlemeleri başka yöntemlerle öngörülerek bu çalışmada bulunan değerler ile karşılaştırılabilir.

EXTENDED ABSTRACT

**Econometric Forecasting For Container Handling:
Arma Model Application**

*

Elif Tuçe Bal - Vahit Çalışır

İskenderun Technical University

Rapidly increasing container transportation is an important indicator representing the dynamics of world trade (Schulze and Prinz, 2009). Containerization growth has meaningful effect on container terminal operations and also has critical results on future infrastructure requirements of container terminals (Mak and Yang, 2007).

One of the most important problems for developing port facilities and establishing new ports is information about the demand for the container (Syafi, 2006). To meet future demand in the best way, planners should consider the existing infrastructure both inside and outside of the port; such projects cannot be reversed because they are resource and time intensive (Patil and Sahu, 2016). So to avoid uneconomic decisions regarding the operations of ports, decision-makers or related authorities have to forecast trade volume or container traffic in a safe way (Gökkuş, Yıldırım and Aydın, 2017).

In general qualitative and quantitative methods are used for prediction of throughput; because quantitative methods are more objective and precise, they attract increasing attention (Xiao, Wang, Xiao, Xiao and Hu, 2015).

The first studies on the forecasting in ports have been observed since the 1980s. Many methods have been applied to obtain the most accurate estimation in many studies and the best method have been determined by criteria and predictions have been made by this method.

Although most studies involve a single method, some studies consist of a combination of several methods called hybrid method. Models using only one method for prediction are divided into three type: time series

models, causal analysis models and nonlinear dynamic forecasting models (Mo et al., 2018).

Regression analysis is the most commonly used method at studies conducted in Turkey for instance Akar and Esmer (2017), Őengönül and Esmer (2016). In addition to regression analysis, nonlinear methods are found in academic studies also in some studies these methods are compared (Tür, Küçükosmanođlu and Küçükosmanođlu, 2013).

There are also studies that use only nonlinear methods and compare them Gökkuş; Yıldırım and Aydın (2017), Yıldırım, Gökkuş and Aydın (2017). The time series models are mostly used in feasibility reports. No time series models were found in academic studies.

Long-term predictions are much more common in studies on Turkey. As a short-term forecasting study in the literature; Tür, Küçükosmanođlu and Küçükosmanođlu's (2013) study for the port of Antalya is taken part. There are no studies involving short-term and all ports in Turkey. This is the starting point of the study. Because ARIMA method is better than other methods in short term estimations, ARIMA model selected

In order to implement the ARMA model, which is also referred to as the Box - Jenkins method, the time series must be stationary. Therefore, ADF unit root test was applied to time series. As the results of the ADF test revealed that series was trend stationary, a trend variable was added to the model.

In the study because monthly data is used, after trend variable, seasonality tested with seasonal dummy variables and dummy variables are found to be significant. Thus dummy variables are also added to the model.

After the addition of dummy variables to the model, for breakpoint in the series Bai-Perron test, structural breakpoint test, applied to the series. The test result showed that the series is affected by the 2008 crisis and the recession, at the end of 2014 and the beginning of 2015, in the sector and these points are added to the model as dummy variable

AR and MA terms are added to the Model, composed of the trend, seasonal dummy variables and structural breakpoint dummy variables; and nine models are obtained.

Nine models are estimated with data set, from the first month of 2004 to the last month of 2017. The period from the first month of 2018 until the ninth month of 2018 is forecasted with parameters, obtained by estimation and the predicted values and the actual values are compared. As a result of comparison; 4., 5., 7. and 9. models, which the actual value falls outside the prediction range, eliminated at this stage.

For testing the validity of models; residuals of 1., 2., 3., 6. and 8. models, moving to the next step, are tested by Jarque-Bera (JB) test, normality test, and Breusch-Pagan-Godfrey (BPG) test, heteroscedasticity test. Because 2. and 3. models do not pass the Breusch-Pagan-Godfrey test, they are eliminated.

For the period from the first month of 2018 to the ninth month of 2018, remaining models 1, 6 and 8 are evaluated by RMSE, MAE ve MAPE, which express the accuracy of models' forecasting. 8. model selected as suitable model and for the period from the ninth month of 2018 to the last month of 2019 monthly forecast is done with this model.

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.

Models with low Akaike and Schwarz information criteria values are not directly selected in the study, like the last stage, models were predicted and results were compared with actual values. As a result of the comparison, it is seen that the models with low Akaike and Schwarz information criteria values are outside the foresight range and these models have been eliminated. By using this method, it has been tried to minimize the probability of being misleading values of Akaike and Schwarz information criteria.

Another aim of the study and the results of this goal, by making monthly estimates for Turkey, is to ensure that the knowledge of port managers about the monthly handling. 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 projec-

tions are the contribution of the study to science with the idea that it can inspire other studies.

As a continuation of this study, the data set exposed to linear trend and seasonality effects can be predicted by the method used here and validity of information criteria can be tested. As another option Turkey's monthly handling can be forecasted by other methods and results can be compared to the values found in this study.

Kaynakça/References

- 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*.
- Carnot, N., Koen V. ve Tissot, B. (2005). *Economic Forecasting*. New York: Palgrave Macmillan.
- 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, 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.
- Deniz Ticareti Genel Müdürlüğü İstatistik Bilgi Sistemi. (2018, Kasım). https://atlantis.udhb.gov.tr/istatistik/istatistik_konteyner.aspx
- 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*. John Wiley & Sons Inc, New York., 517.
- 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.
- 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.
- Gökkuş, Ü., Yıldırım, M. S., ve Aydın, M. M. (2017). Estimation of container traffic at seaports by using several soft computing methods: 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.
- 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.
- 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.
- 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.

- 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.
- Lütkepohl, H., ve Krätzig, M. (Eds.). (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.
- 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 (AM-MIS2015)* (pp. 341-350).
- 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.
- 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.
- 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.
- 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.
- 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.
- Sengönül, G., ve Esmer, S. (2016). Container transportation at the black sea: An evaluation of the ports in Turkey. *Karadeniz Araştırmaları*, 49, 131-140.
- 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 trafiğinin bulanık sinir ağı ile tahmini. *Dokuz Eylül Üniversitesi Denizcilik Fakültesi Dergisi*, 5(2), 109-120
- 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.
- 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.
- 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.
- Yıldırım, M. S., Gökkuş, Ü. ve Aydın, M. M. (2017). 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*, 578-581

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.

Kaynakça Bilgisi / Citation Information

Bal, E. T. ve Çalıřır, V. (2018). Konteyner elleçleme için ekonometrik tahminleme: Arma modeli uygulaması. *OPUS–Uluslararası Toplum Arařtırmaları Dergisi*, 9(16), 2067-2096. DOI: 10.26466/opus.485722