



GRİ TAHMİN VE BOX-JENKINS YÖNTEMLERİ İLE ANTALYA LİMANI İÇİN AYLIK  
KONTEYNER TALEP TAHMİNİ  
MONTHLY CONTAINER DEMAND FORECAST FOR PORT OF ANTALYA USING GRAY  
PREDICTION AND BOX-JENKINS METHODS

Fatma Gül ALTIN<sup>1</sup>, Şeyma ÇELİK EROĞLU<sup>2</sup>

1. Dr. Öğr. Üyesi, Burdur Mehmet Akif Ersoy Üniversitesi, Bucak Zeliha Tolunay Uygulamalı Teknoloji ve İşletmecilik Yüksekokulu, gulaltin@mehmetakif.edu.tr, <https://orcid.org/0000-0001-9236-0502>
2. Doktora Öğrencisi, Burdur Mehmet Akif Ersoy Üniversitesi, SBE, sseymacelik@gmail.com, <https://orcid.org/0000-0003-4573-7690>

**Makale Türü** Article Type  
Araştırma Makalesi Research Article

**Başvuru Tarihi** Application Date  
17.02.2020 02.17.2020

**Yayına Kabul Tarihi** Admission Date  
14.10.2020 10.14.2020

**DOI**  
<https://doi.org/10.30798/makuiibf.689532>

### Öz

Konteyner taşımacılığının, denizyolu ticaretindeki önemi her geçen gün artmaktadır. Konteyner hacminin etkili tahmini ise liman planlaması ve işletimi için bir karar desteği sağlamaktadır. Bu nedenle liman yönetimlerinin geleceğe yönelik planları açısından tahminleme çalışmaları önemli bir rol oynamaktadır. Bu çalışmada, Antalya'da bulunan Port Akdeniz Limanı için yapılan tahmin modellerinde Ocak 2008-Aralık 2017 (120 ay) dönemi konteyner istatistikleri veri seti olarak kullanılmıştır. Liman işletmesinin yük talep tahmini, konteyner bazında ve mevsimsel farklılıklar dikkate alınarak, Ocak 2018-Aralık 2019 (24 ay) dönemi için yapılmıştır. Gri Tahmin ve Box-Jenkins yöntemlerinin kullanıldığı çalışmada, konteyner tahminleri Gri Model (1,1) ve ARIMA (0,1,0)x(0,1,1)<sub>12</sub> modelleri ile analiz edilmiştir. Tahmin sonuçları başarı kriterleri ile değerlendirildiğinde, Gri Model (1,1)'in MAPE ve MAE değerlerinin daha düşük olduğu gözlemlenmiştir. Ancak hem RMSE ve MSE hem de sapma değerleri dikkate alındığında ise; ARIMA (0,1,0)x(0,1,1)<sub>12</sub> modelinin daha iyi ve uygun tahmin değerleri verdiği tespit edilmiştir.

**Anahtar Kelimeler:** Konteyner, Tahminleme, Gri Model, ARIMA, Antalya Limanı

### Abstract

The importance of container transportation in maritime trade is increasing day by day. The effective prediction of container volume provides decision support for planning and operations of the ports. Therefore, forecasting are crucially important for the future plans of port management have an important place. In this study, container statistics for January 2008-December 2017 (120 months) period were used in the estimation models for Port Akdeniz Port in Antalya. The freight demand forecast of the port management is made for the period of January 2018-December 2019 (24 months), taking into consideration the seasonal differences on the basis of containers. In the study using Gray Estimation and Box-Jenkins (B-J) methods, container volumes estimations were carried out using Gray Model (1,1) and ARIMA (0,1,0)x(0,1,1)<sub>12</sub> models. As estimation results are evaluated with success criteria, it is observed that MAPE and MAE values of Gray Model (1,1) are lower. However, considering both RMSE and MSE and deviation values; it is determined that ARIMA (0,1,0)x(0,1,1)<sub>12</sub> model gives better and more suitable estimation values.

**Keywords:** Container, Forecasting, Gray Model, ARIMA, Port of Antalya

## **EXTENDED SUMMARY**

### **Research Problem**

The share of containers in maritime transportation is increasing day by day. An effective prediction of container volume provides decision support for planning and operations of ports. Therefore, forecasting for the future plans of port management are crucially important. In this study, container forecasting is aimed using Gray Forecast and Box-Jenkins (B-J) methods, which are thought to be useful for the future plan of Port Akdeniz Port in Antalya.

### **Research Questions**

The main subject of the study is to determine which of the Gray Model (1,1) and ARIMA (0,1,0)x(0,1,1)<sub>12</sub> models gives more suitable forecasting results for the container statistics data set for the period of January 2008-December 2017 (120 months).

### **Literature Review**

In addition to being the most reliable method of transportation, maritime transportation is the most economical and most preferred mode of transportation by providing the most freight carrying opportunity in a single trip. Global maritime trade has achieved a 2.6% increase in world maritime transport in 2018, following the 4.2% growth in 2017. Maritime trade volume has reached 11.83 billion tons, which corresponds to 1.55 tons per capita in the world and 83% of the global trade in tons (Denizcilik Sektör Raporu, 2019). Most of the world maritime trade volume is made by container ships. Container transportation, which provides a multi-purpose transportation opportunity, facilitates the integration of seaway, road and railways (Bayraktutan ve Özbilgin, 2013). Therefore, container demand forecasts have an important place in the future plans of port administrations.

### **Methodology**

In the study, container statistics for the period of January 2008-December 2017 (120 months) were used as the data set in the forecast models for Port Akdeniz. The freight demand forecast of the port management is conducted for the period of January 2018-December 2019 (24 months), taking into consideration the seasonal differences on the basis of containers. In the study, using Gray Estimation and Box-Jenkins (B-J) methods, container volumes estimations carried out using Gray Model (1,1) and ARIMA (0,1,0) x (0,1,1) <sub>12</sub> models.

### **Results and Conclusions**

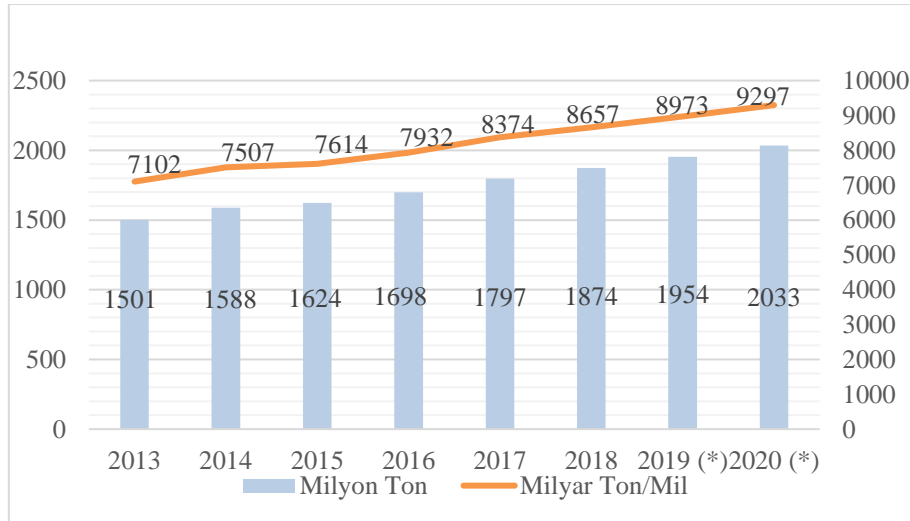
As the estimation results obtained in the study are evaluated in terms of MAPE, RMSE, MSE and MAE criteria; it is observed that the Gray Model (1,1) gives better results in terms of MAPE and MAE values. However, considering both RMSE and MSE and deviation values; it is determined that ARIMA (0,1,0)x(0,1,1)<sub>12</sub> model gives better and more suitable estimation values.

## 1. GİRİŞ

Denizyolu taşımacılığı en güvenilir taşıma yolu olmasının yanı sıra, tek seferde en fazla yük taşıma imkânı sağlayan en ekonomik ve en çok kullanılan taşımacılık modudur. Küresel deniz ticareti verilerine bakıldığında, 2017 yılında gerçekleşen %4,2 oranındaki büyümeden sonra, 2018 yılında dünya denizyolu taşımacılığında %2,6'lık bir yükseliş yaşanmıştır. Yaşanan bu artışla deniz ticaret hacmi, kişi başı 1,55 ton ve küresel ticaretin %83'üne karşılık gelen 11,83 milyar tonu yakalamıştır (Denizcilik Sektör Raporu, 2019).

Dünya deniz ticaret hacminin büyük bölümü de konteyner gemileri ile yapılmaktadır. Çok amaçlı bir taşıma imkânı sunan konteyner taşımacılığı, denizyolu ile karayolu ve demiryollarının bütünleşmesinde kolaylık sağlamaktadır. Bu nedenle konteyner taşımacılığı kapıdan kapıya taşımının en önemli unsuru haline gelmiştir (Bayraktutan ve Özbilgin, 2013). Grafik 1.'de 2013-2018 yılları dünya konteyner taşımacılık miktarları gösterilmiştir. 2019-2020 yılları ise öngörülen rakamlardır. Rakamlar incelendiğinde dünya konteyner taşımacılık miktarlarının her geçen yıl arttığı görülmektedir.

**Grafik 1.** Dünya Konteyner Taşımacılığı



**Kaynak:** (<https://clarksonsresearch.wordpress.com/>, 06.01.2020)

Tablo 1.'e göre 2018 yılında en fazla konteyner elleçlenen liman Ambarlı Limanı'dır. Çalışmaya konu olan Antalya Limanı ise 9. sırada yer almaktadır. Antalya Limanı Mersin ve İskenderun Limanlarından sonra Akdeniz Bölgesi ticaretinin önemli limanları arasında yer almaktadır.

**Tablo 1.** 2018 Yılı Limanlar Bazında Konteyner Elleçleme Miktarları (TEU)

LİMAN BAŞKANLIKLARI	İhracat	İthalat	Kabotaj Elleçleme	Transit Elleçleme	Toplam Elleçleme
AMBARLI	1.019.828	1.140.186	272.180	737.341	3.169.535
MERSİN	820.550	793.997	37.958	9.856	1.662.361
KOCAELİ	693.364	689.791	94.857	119.609	1.597.621
TEKİRDAĞ	140.202	167.022	157.318	619.654	1.084.196
ALİAĞA	498.122	417.053	29.274	256	944.705
GEMLİK	340.681	338.918	172.835	2.264	854.698
İZMİR	266.426	308.085	36.283	114	610.908
İSKENDERUN	253.965	251.389	6.945	0	512.299
ANTALYA	75.986	91.645	23.209	0	190.840
SAMSUN	13.533	16.061	39.641	0	69.235
İSTANBUL	12.506	24.797	18.164	90	55.557
YALOVA	24.162	17.564	0	0	41.726
BBANDIRMA	4	106	36.875	0	36.985
TRABZON	22	2.222	7.128	0	9.372
KARABİĞA	0	0	2.350	0	2.350
ZONGULDAK	675	0	0	0	675
MARMARA ADASI	0	0	644	0	644
İĞNEADA	0	194	0	0	194
BOTAŞ	81	0	0	0	81
KARASU	18	0	0	0	18
TOPLAM	4.160.124	4.259.029	935.661	1.489.184	10.843.998

**Kaynak:** <https://denizticareti.uab.gov.tr/>, 06.01.2020.

Talep tahmini tüm işletmelerin gelecek planlamaları için önemli limanlar için özellikle önemli olan yük talep tahminidir. (Akar ve Esmer, 2015). Yük miktarının tahmin edilenin altında kalması limanlarda atıl kapasitenin oluşmasına ve yatırımların gelecek yük hacmine göre projelendirilmesi nedeniyle yatırım finansmanının geri dönüşünün imkânsız hale gelmesine neden olmaktadır. Yük miktarının tahmin edilenin üzerinde olması durumunda ise limanlarda sıkışıklık oluşmakta ve liman yatırımlarının uzun sürmesinden dolayı yeni limanlar zamanında hizmete girememektedir (Kara, 2011).

Bu çalışmada limanlar için önemi vurgulanan yük talep tahmini üzerine bir uygulama yapılmıştır. Uygulama yapılacak liman olarak Ortadoğu Antalya Liman İşletmeleri A.Ş. tarafından işletilen Port Akdeniz seçilmiş, Ocak 2008-Aralık 2017 dönemine ait konteyner bazında yük talebi istatistikleri kullanılarak, Ocak 2018-Aralık 2019 dönemine ait konteyner bazında yük talebi tahmin değerlerinin elde edilmesi amaçlanmıştır. Çalışmada mevsimsel farklılıklar göz önünde bulundurularak, bu amaca yönelik sonuçlar verebilecek Gri Model (GM) (1,1) ve Box- Jenkins (B-J) modelleri kullanılmıştır. Modellerden elde edilen sonuçlar karşılaştırılarak değerlendirmeler yapılmıştır.

## 2. LİTERATÜR TARAMASI

Literatürde talep tahmin yöntemleri ile yapılan birçok çalışma bulunmaktadır. Ancak burada GM (1, 1) ve Zaman Serileri yöntemleri kullanılarak yük talep tahmini ile ilgili son yıllarda gerçekleştirilen çalışmalar özetlenmiştir.

Schulze ve Prinz (2009) Mevsimsel Bütünleşik Otoregresif Hareketli Ortalama (SARIMA) modeli ve Holt-Winters üstel düzeltme yaklaşımını kullanarak Alman limanlarında konteyner aktarımını

incelemişlerdir. Modeller üçer aylık verilerin mevsimsel davranışlarını dikkate alınarak tasarlanmış ve modellerde kullanılan veriler 1989'un ilk çeyreğinden 2006'nın dördüncü çeyreğine kadar uzanmaktadır. Çalışmada 2007 ve 2008 yılları için üç aylık tahminler ayrıntılı olarak verilmektedir. İki model karşılaştırıldığında SARIMA yaklaşımının, konteyner verimini modellemek için üstel düzeltme yaklaşımından daha iyi sonuçlar verdiği ortaya çıkmıştır. Tahmin sonuçlarına göre, Alman konteyner elleçlemede Kuzey Amerika'ya göre Asya ve Avrupa destinasyonları için daha güçlü bir büyüme olduğu görülmektedir.

Chen ve Chen (2010) Genetik Programlama (GP), Ayrışma yaklaşımı (X-11) ve Mevsimsel Bütünleşik Otoregresif Hareketli Ortalama (SARIMA) kullanarak limanlarda konteyner üretim hacmi için optimal bir tahmin modeli yaratmaya çalışmışlardır. Çalışmada bir tahmin modeli oluşturmak için Tayvan'ın ana limanlarından 29 yıllık geçmiş veri toplanmıştır. Tahmin ve gerçek veriler arasındaki Ortalama Mutlak Yüzde Hata seviyeleri her üç yaklaşım için de %4'tür. GP modeli tahminleri X-11 ve SARIMA'dan yaklaşık %32-36 daha iyi sonuç vermiştir. Bu sonuçlar GP'nin bu vaka için en uygun yöntem olduğunu göstermektedir. GP, Tayvan'ın büyük limanlarındaki konteyner üretiminin 2008 yılında yavaşça artacağını öngörmektedir. Tayvan hükümeti Temmuz 2008'de Çin ile doğrudan ulaşım başlattığından beri, Tayvan'daki konteyner taşımacılığı daha da önemli bir konu haline gelmiştir.

Rashed, Meersman, Voorde, ve Vanelslender (2017) Belçika'da bulunan Anvers limanının toplam konteyner tahmini için Ocak 1995-Mart 2015 dönemi aylık verileri kullanmışlardır. Konteyner tahmini için tek değişkenli zaman serisi yöntemlerinden Bütünleşik Otoregresif Hareketli Ortalama (ARIMA) ve ekonomik göstergeli ARIMAX modelleri kullanılmıştır. Farklı modellerin karşılaştırılarak, bir çıktı serisi olarak konteyner verimi için ARIMAX'ın ortalama mutlak yüzde hatasına dayanarak öngörmede daha doğru sonuçlar verdiği görülmüştür.

Wang ve Wang (2018) çalışmalarında Fujian kıyı limanlarının 2001-2016 yılları arasındaki zaman serisi verilerini kullanarak GM tahminini Markov zinciri ile birleştirmişlerdir. Çalışmada değişken dalgalanmaların rasgeleliğini yansıtmak için Markov Zinciri kullanılmış, tahmin değerleri düzeltilerek 2015'ten 2016'ya kadar liman kargolarının iş hacmi tahmin edilmiştir. Sonuçlar, Markov işlemi tarafından değiştirilen GM ortalama mutlak hatasının %5,4'ten %0,04'e düştüğünü göstermektedir. Bu durumda Gri Markov Zinciri'nin sonucunun tek gri tahminden daha doğru olduğu ifade edilebilir.

Gao, Chang, Fang, ve Fan (2019) bir limanın tarihsel veri kümesini derinlemesine öğrenerek, Uzun Kısa Süreli Bellek (LSTM) Tekrarlayan Yapay Sinir Ağı (RNN) yöntemi ile depolama alanına girecek konteynerlerin günlük hacimlerini tahmin etmişlerdir. LSTM modeli Python ve Tensorflow çerçeveleri ile oluşturulmuştur. LSTM ile ARIMA modeli ve Geri Yayılım (BP) Sinir Ağı modeli tahmin sonuçları arasında karşılaştırmalar yapılmıştır. Sonuçlar, LSTM RNN'nin yapısının, depolama sahasının günlük konteyner hacimlerini tahmin etmek için uygulanabileceğini ve tahmin boşluğunun diğer tahmin yöntemlerinden daha düşük olduğunu göstermektedir.

Guzey ve Akansel (2019) Türkiye'de bir limanın talep tahmin problemi için farklı yöntemler karşılaştırmışlardır. Çalışma için 2012-2017 dönemine (72 ay) ait üç veri türü (genel kargo, konteyner, araç) toplanmıştır. 2018-2019 yıllarına ilişkin üç veri türüne ilişkin Üstel Düzeltme, Holt Doğrusal, Toplamsal Holt-Winters, Çarpımsal Holt-Winters, ARIMA, Basit Doğrusal Regresyon, Çoklu Doğrusal Regresyon ve Destek Vektör Makinesi yöntemleri ile tahminler yapılmıştır. Analiz sonuçlarına göre Çarpımsal Holt Winter yöntemi konteyner ve araç elleçleme hacimleri için en iyi tahmin yöntemi olarak kabul edilirken, Destek Vektör Makinesi yöntemi genel kargo için en iyi tahmin değerlerini sağlamıştır.

Chan, Xu ve Qi (2019) Çin'deki Ningbo limanının konteyner hacmini farklı zaman serisi yöntemleri ile tahmin ederek sonuçları karşılaştırmışlardır. Çalışmada 2004-2015 yılları arasında konteyner üretim verileri kullanılmıştır. Bu ham verilerin %80'i (2004-2012) eğitim seti, %20 (2013-2015) ise test seti olarak belirlenmiştir. Daha sonra limanın konteyner üretimini tahmin etmek için altı zaman serisi yöntemi (Hareketli Ortalama, Çok Değişkenli Uyarlanabilir Regresyon Uzanımları, Bütünleşik Otoregresif Hareketli Ortalama, GM, Yapay Sinir Ağı, Destek Vektör Makinesi ve Destek Vektör Regresyonu) ile analizler yapılarak performanslar değerlendirilmiştir. Yöntemler karşılaştırıldığında bu çalışma için en kötü sonucu Hareket Ortalama verirken en iyi sonuca Destek Vektör Makinesi ve Destek Vektör Regresyonu ulaşmıştır.

Tran (2019) Tayvan'daki 2007-2013 yılları arasındaki ithalat ve ihracat emtia miktarını veri olarak kullanarak bir Gri tahmin matematiksel modeli oluşturmaya çalışmıştır. Modelde 2014'ten 2018'e kadar beş yıllık zaman dilimi için Tayvan'daki en çok ithalat ve ihracatı yapılan emtiaların toplam değeri tahmin edilmek istenmiştir. Analiz sonuçları, Gri tahmin modellerinin kullanımının çok düşük bir ortalama mutlak yüzde hatasıyla sonuçlandığını ve bunun da pratikte doğru tahminler sağlamak için uygulanabilirliğini göstermektedir. Bu araştırma ayrıca, gelecek dönem için (2014-2017), en çok ihracatı ve ithalatı yapılan emtiaların değerinde istikrarlı bir artış olacağını göstermektedir.

Tang, Wu ve Gao (2019) çalışmalarında Çin'de bulunan Lianyungang ve Şanghai Limanlarının konteyner tahmini için GM, Üçlü Üstel Düzeltme modeli, Çoklu Doğrusal Regresyon modeli ve Geri Yayılım Sinir Ağı modellerini karşılaştırmışlardır. Etkili faktörler olarak; tüketim mallarının toplam perakende satışları, yerel şehrin gayri safi yurtiçi hasılası, ithalat ve ihracat ticaret hacmi, ikinci endüstrinin toplam çıktı değeri ve toplam duran varlık yatırımları kullanılmıştır. 1990-2011 arası veri setleri model oluşturmak için seçilmiştir ve 2012-2017 arası modellerin performansını değerlendirmek için kullanılmıştır. Dört modele göre de 2018'den 2020'ye kadar her iki limandaki konteyner üretim hacmi tahminleri yapılmıştır. Modeller karşılaştırıldığında, Geri Yayılım Sinir Ağı modeli konteyner üretim hacmi tahmini için hem Şanghai Limanı hem de Lianyungang Limanı için daha geçerli sonuçlar vermiştir.

Guo, Le, Wu, ve Wang (2019) çalışmaları ile tarihsel verilerin mevcut olmaması durumunda doğrudan nehir-deniz taşımacılığının navlun hacmini tahmin etmek için çok aşamalı bir yaklaşım geliştirmişlerdir. İlk olarak, Çin'deki Ningbo-Zhoushan limanı ile Ma'anshan limanı arasındaki güzergaha ilişkin 2011-2017 arası gemi trafik akışı, her bir navigasyon kanalının hız limiti, serbest akış

çalışma süresi, kanal uzunluğu, kanal kapasitesi verileri toplanmıştır. Daha sonra bu verilere dayanarak tüm başlangıç noktası (O-D) çiftleri arasında tarihsel navlun hacimleri matrisini elde etmek için (O-D) matris tahmin yöntemi kullanılmıştır. Daha sonra, bu O-D çiftleri arasında gelecekteki toplam navlun hacimleri Gri tahmin modeli kullanılarak tahmin edilmiş ve doğrudan nehir-deniz taşımacılığının paylaşım oranı Logit modeli kullanılarak tahmin edilmiştir.

### 3. YÖNTEM

Bu bölümde çalışmada kullanılan GM (1, 1) ve B-J tahminleme yöntemleri hakkında bilgi verilmiştir.

#### 3.1. Gri Sistem Teorisi ve Gri Tahminleme

Çalışmada kullanılan ilk yöntemin ait olduğu sistem Gri Sistem Teorisi 1982 yılında, Çinli Prof. Deng Julong tarafından geliştirilmiştir (Liu ve Forrest, 2007). Sistem ismini renklerin yorumlanmasından almaktadır. Renklerin koyuluğu, genel olarak bilgilerin netlik derecesini belirtmek için kullanılmaktadır (Liu ve Lin, 2006:3). Yöntemde adı geçen “gri” renk kavramı bir sistemdeki bilginin tam olarak bilinmediğini ifade ederken, “beyaz” renk bilgiye tam olarak sahip olduğunu “siyah” renk ise bilginin hiç bilinmediğini ifade etmektedir (Peker ve Baki, 2011: 6). Kısmen bilinen ve kısmen bilinmeyen bilgilerin yer aldığı bu sisteme Gri Sistem Teorisi denilmektedir (Lim, Anthony, Mun ve Wai, 2008). Sistem diğer yöntemlerden farklı olarak daha küçük gözlem grubu (minimum 4 gözlem değeri) ve daha zayıf bilgilerin olduğu problemlere de çözüm getirebilmektedir.

Gri tahmin yöntemi üç temel operatöre sahiptir. Bunlar; birikim üretme işlevi, ters birikim üretme işlevi ve gri modeli (GM) olarak isimlendirilmektedir (Yılmaz ve Yılmaz, 2013).

Çalışmada kullanılan Gri Tahmin Modeli olan GM (1,1), “Birinci Mertebeden Bir Değişkenli Gri Model” şeklinde ifade edilmektedir (Kayacan vd., 2007:220). Bu model sadece pozitif veri serilerine uygulanabilen, bir zaman serisi tahmin modelidir (Özkara, 2009:36). GM (1,1) modeli, aşağıda verilen temel adımlardan oluşmaktadır (Liu ve Lin, 2006).

1.Adım: Tek girdili ve tek çıktılı bir sistemin çıktılarının zaman dizisi; n örneklem büyüklüğüne sahip olan  $x^{(0)}$  (ham veri seti) dizisi olsun.

$$X^{(0)} = (x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)); \quad n \geq 4 \quad [1]$$

2.Adım: Bu diziyeye Birikimli Üretim İşlevi uygulanarak aşağıdaki monoton artan  $x^{(1)}$  dizisi elde edilebilir.

$$X^{(1)}(k) = (x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n)); \quad n \geq 4 \quad [2]$$

$$X^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i), \quad k = 1, 2, 3, \dots, n \quad [3]$$

3.Adım: Üretilen  $x^{(1)}$  dizisinden, bu dizinin ardışık ortalama dizisi  $Z^{(1)}$  serisi oluşturulmaktadır. Eşitlik 5'teki seri ardışık iki verinin ortalamasını gösteren seridir.

$$Z^{(1)} = (z^{(1)}(1), z^{(1)}(2), \dots, z^{(1)}(n)) \quad [4]$$

$$z^{(1)}(k) = 0.5 x^{(1)}(k) + 0.5 x^{(1)}(k-1) \quad k=2,3, \dots, n \quad [5]$$

4.Adım: GM (1,1) modelinin gri diferansiyel denklemi oluşturulur. Denklem,

$$x^{(0)}(k) + az^{(1)}(k) = b \quad k = 2,3, \dots, n \quad [6]$$

şeklinde ifade edilir. Burada k zaman noktalarını,  $a$  gelişme katsayısını, b ise sürücü katsayısını ifade etmektedir.

5.Adım: Beyazlaştırma denklemi ise şu şekilde hesaplanmaktadır.

$$\frac{dx^{(1)}(k)}{dt} + ax^{(1)}(k) = b \quad [7]$$

6.Adım: Gri diferansiyel denklemde yer alan a ve b parametrelerinin hesaplanması için en küçük kareler yöntemi (EKK) veya parametrik yöntem kullanılmaktadır. Burada genellikle önerilen ve daha sık kullanılan EKK yöntemine göre denklem çözümlenmiştir.

$$x^{(0)}(k) = -az^{(1)}(k) + b \quad k = 2,3, \dots, n \quad [8]$$

$$Y = \begin{pmatrix} x^{(0)}(1) \\ x^{(0)}(2) \\ \vdots \\ M \\ x^{(0)}(n) \end{pmatrix} \quad B = \begin{pmatrix} -z^{(1)}(1) & 1 \\ -z^{(1)}(2) & 1 \\ \vdots & \vdots \\ M & M \\ -z^{(1)}(n) & 1 \end{pmatrix} \quad \hat{a} = \begin{pmatrix} a \\ b \end{pmatrix} \quad [9]$$

$$Y = B \hat{a} \quad [10]$$

$$B^T Y = B^T B \hat{a} \quad [11]$$

$$(B^T B)^{-1} B^T Y = \hat{a} \quad [12]$$

$$\hat{a} = \begin{pmatrix} a \\ b \end{pmatrix} \text{ ise; } \begin{pmatrix} a \\ b \end{pmatrix} = (B^T B)^{-1} B^T Y \text{ olur.} \quad [13]$$

7.Adım: Beyazlaştırma denklemine göre  $x^{(1)}(k)$  ifadesi bir k zamanı için çözdürülebilir. Elde edilen a ve b değerleri de göz önüne alınarak eşitlik 14 ve 15'teki gri modeller oluşturulabilir.

$$x_p^{(1)}(k+1) = \left[ x^{(0)}(1) - \frac{b}{a} \right] e^{-ak} + \frac{b}{a} \quad [14]$$

Burada  $x_p^{(1)}(k+1)$ , k+1 zamanı için tahmin edilen x' in birikimli (kümülatif) değeridir.

8.Adım: Tahmin değerlerinin birikimli olmayan değerleri için Ters Birikimli Üretim İşlemi uygulanmaktadır.



$$x^{(0)}(k+1) = \left[ x^{(0)}(1) - \frac{b}{a} \right] e^{-ak} (1 - e^{-a}) \quad [15]$$

### 3.1.1. Toplamsal ve Çarpımsal Ayırıştırma Modelleri

GM (1,1) modelinin uygulama adımları incelendiğinde, zaman serisi verilerinin zaman içerisinde nasıl bir seyir izlediğini (trend, mevsimsellik vb.) ayırıştıran bir adım içermediği görülmektedir. Fakat çalışmanın uygulamasında kullanılacak olan yük verilerinin mevsimsellik içerdiği bilinmektedir. Bu sebeple GM (1,1) modeli ile daha doğru bir tahmin yapılabilmesi için, hem GM (1,1) tahmin modelini elde etmek için kullanılan verilere, hem de elde edilen geleceğe yönelik tahmin değerlerine ayırıştırma işlemlerinin uygulanması gerekmektedir. Bu çalışmada, literatürde yaygın olarak kullanılan mevsimsel ayırıştırma modellerinden “Toplamsal ve Çarpımsal Ayırıştırma Modelleri” kullanılmıştır. Bu modellerin genel gösterimi sırasıyla Eşitlik 16 ve Eşitlik 17’de olduğu gibidir (Yolsal, 2010):

$$X_t = T_t + C_t + S_t + E_t \quad [16]$$

$$X_t = T_t * C_t * S_t * E_t \quad [17]$$

Burada;  $X_t$ ,  $C_t$ ,  $S_t$  ve  $E_t$  sırasıyla; zaman serisinin t dönemindeki gözlem değerlerini, konjonktür bileşenini, mevsimsel bileşenini ve tesadüfi (rassal) hareketler bileşenini temsil etmektedir.

Toplamsal ayırıştırma modelinde yazılan bileşenlerden herhangi birinin etkisi yok ise o bileşenin değeri 0 olarak kabul edilmektedir. Mevsimsellik trendden bağımsız olduğu için dalgalanma büyüklüğü zaman içinde değişmemekte, yani sabit kalmaktadır. Çarpımsal ayırıştırma modelinde ise yazılan bileşenlerden herhangi birinin etkisi yok ise o bileşenin değeri 1 olarak kabul edilmekte ve bir serinin mevsimsel dalgalanmasının büyüklüğü serinin trendine bağlı olarak zaman içinde artış ya da azalış göstermektedir (Özkara, 2009).

Bahsedilen iki model içinde zaman serilerini mevsim etkisinden arındırma işlemi farklılık göstermektedir. Bu modellerden toplamsal ayırıştırma modelinin kullanılması durumunda, orijinal serideki diğer bileşenlerin tahmin edilen mevsim bileşenlerinden farkı alınıp mevsimsel düzeltmesi yapılmış seriye ulaşılırken, çarpımsal ayırıştırma modelinin kullanılması durumunda ise orijinal seri tahmin edilen mevsim bileşenlerine oranlanarak mevsimsel düzeltme yapılmaktadır. Tahmin edilen mevsim bileşenlerine ise mevsimsel faktörler (seasonal factors) adı verilmektedir (Yolsal, 2010).

### 3.2. Box- Jenkins Yöntemi

Çalışmada kullanılacak ikinci yöntem olan Box-Jenkins (B-J) Yöntemi 1976 yılında George Box ve Gwilym Jenkins tarafından geliştirilmiştir (Goh ve Law, 2002). B-J yöntemi modellerinde temel yaklaşım; incelenen değişkenin bugünkü değerinin, geçmiş değerlerinin ağırlıklı toplamı ve rassal şokların bileşimine dayanmasıdır (Çuhadar, Güngör, ve Göksu, 2009). Zaman serilerinin modellenmesi ve öngörülmesi için kullanılan bu yöntemin ön koşulu durağanlıktır (Meciarova, 2007). Yöntemde zaman serilerinin durağanlığı korelogram ile tespit edilmektedir. Seride durağanlık olmaması

durumunda ise durağanlık elde edilinceye kadar serinin farkı alınmaktadır. Sonrasında durağan seri üzerinden uygun model tespit edilerek öngörüleme yapılmaktadır

B-J yönteminin amacı örneklem verilerini türetebilen bir istatistik modeli belirlemek ve tahmin etmektir. Bu amaç doğrultusunda yöntemin gerekli gördüğü durağanlık varsayımının, eldeki verilerden türetilen herhangi bir modelin de durağan ve kararlı olabilmesi, dolayısıyla da kestirim için gerekli bir alt yapı sağlayabilmesine dayandığı söylenebilir (Gujarati, 1995). Bu yöntem ARIMA modeli olup uluslararası bilim dünyasında B-J tekniği olarak bilinmektedir (Özdemir ve Bahadır, 2010: 354). Birçok model yapısına sahip olan bu yöntemin, çalışmadaki uygulamasında mevsimsel model SARIMA (P, D, Q)/çarpımsal mevsimsel bütünleşik otoregresif hareketli ortalamayı ifade eden ARIMA (p, d, q) x (P, D, Q)S modeli kullanılmıştır. Modelin genel gösterimi Eşitlik 18’de görüldüğü gibidir (Halim ve Biso, 2008):

$$\beta_p(B)\Phi_p(B^S)(1-B)^d(1-B^S)^D y_t = \theta_q(B)\Theta_q(B^S)\varepsilon_t \quad [18]$$

Eşitlikte yer alan  $(1-B)^d$  ifadesi  $\Delta^d$  operatörüne,  $(1-B^S)^D$  ifadesi de  $\Delta_s^D$  operatörüne eşittir.

$$\beta_p(B)\Phi_p(B^S)\Delta^d\Delta_s^D y_t = \theta_q(B)\Theta_q(B^S)\varepsilon_t \quad [19]$$

Bu eşitliğe, farkı alınmış seriyi ifade eden  $w_t$  serisinin (eşitlik 20) eklenmesiyle, model eşitlik 21’de verildiği şekilde ifade edilebilecektir (Li, Campbell, Haswell, Sneeuwjagt, ve Venables, 2003; 152).

$$w_t = (1-B)^d(1-B^S)^D y_t = \Delta^d\Delta_s^D y_t \quad [20]$$

$$\beta_p(B)\Phi_p(B^S)w_t = \theta_q(B)\Theta_q(B^S)\varepsilon_t \quad [21]$$

Burada; p, d, q ve P, D, Q sırasıyla mevsimsel olmayan AR, fark, MA ve mevsimsel AR, fark, MA derecelerini göstermektedir.  $y_t$  herhangi t dönemindeki zaman serisi veri grubunu,  $\varepsilon_t$  bir t döneminde normal dağılım gösteren hata değerlerini, B ( $B^m y_t = y_t - m$ ) geri kaydırma operatörünü, m geriye gidilecek değeri ve s mevsimsel dereceyi göstermektedir. Ayrıca  $\beta$ ,  $\theta$  ve  $\Phi$ ,  $\Theta$  sırasıyla mevsimsel olmayan AR, MA ve mevsimsel AR, MA modeli katsayılarını temsil etmektedir. Son olarak  $\Delta^d$  ve  $\Delta_s^D$  ise sırasıyla mevsimsel olmayan fark alma operatörü ve mevsimsel fark alma operatörünü simgelemektedir.

### 3.3. Model Öngörü Değerlendirme Kriterleri

Çalışmada ele alınan üç yöntemin model öngörü başarısını ölçmek için MSE (Mean Squared Error- Ortalama Hata Kare), RMSE (Root Mean Squared Error-Hata Karelerinin Ortalama Kökü), MAPE (Mean Absolute Percentage Error-Ortalama Mutlak Yüzde Hata) ve MAE-MAD (Mean Absolute Deviation- Ortalama Mutlak Sapma) kriterleri kullanılmıştır. Bu kriterlerin hesaplanabilmesi

için kullanılan formüller Eşitlik 22, 23, 24 ve 25'te verilmiştir (Sallehuddin, Shamsuddin, Mohd, ve Abraham, 2007):

$$MSE = \frac{1}{n} * \sum_{t=1}^n (y_t - \hat{y}_t)^2 \quad [22]$$

$$RMSE = \sqrt{\frac{1}{n} * \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad [23]$$

$$MAPE = \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| * \frac{100}{n} \quad [24]$$

$$MAE - MAD = \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{n} \quad [25]$$


Burada  $y_t$  gerçekleşen değeri,  $\hat{y}_t$  öngörülen değeri, n öngörülen dönem sayısını ifade etmektedir. Bu eşitliklerde yer alan formüller ile elde edilen kriter değerleri hangi modelde daha küçük değerler veriyor ise o model en uygun model olarak seçilmelidir.

#### 4. UYGULAMA

Çalışmada, Ortadoğu Antalya Liman İşletmeleri A.Ş. tarafından işletilen Port Akdeniz limanına ait Ocak 2008- Aralık 2017 (120 ay) arası konteyner bazında yük talebi istatistikleri veri grubu olarak kullanılmaktadır. Bu veri grubu ile Ocak 2018-Aralık 2019 (24 ay) döneminde gerçekleşecek konteyner istatistikleri tahmin edilmektedir.

Uygulamada kolaylık sağlaması açısından, üzerinde incelemeler yapılacak olan zaman serisi KONTEYNER olarak adlandırılmıştır. Bu seriye ilişkin değerler Grafik 2.'de verildiği gibidir.

**Grafik 2.** KONTEYNER Serisi Zaman Yolu Grafiği



Grafik 2. incelendiğinde konteyner değerlerinin durağan olmadığı, zamana göre artan bir eğilime sahip olduğu açıkça görülmektedir. Ayrıca serideki değerlerin her yılın bazı dönemlerinde ciddi artış ve ciddi azalışlar gösterdiği görülmektedir. Bu durum ele alınan zaman serisinin mevsimsel etki taşıdığını ortaya koymaktadır. Bu yüzden tahmin değerlerinin elde edilebilmesinde kullanılacak

yöntemlerin mevsimsel etki ve trende göre değerlendirilmesi yapıp, sırasıyla gri tahmin yöntemi için GM (1,1) ve B-J yöntemi için SARIMA(p,d,q)x(P,D,Q) modelleri kullanılmıştır. Ayrıca GM (1,1) modelinin mevsimselliği tam olarak sağlayamaması sebebiyle, model mevsimsel ayrıştırma ile beraber değerlendirilmiştir.

#### 4.1. Konteyner İstatistiklerinin Gri Tahmin Yöntemi ile Tahmin Edilmesi

Analizi yapılacak, KONTEYNER serisi mevsimsellik barındırdığı için öncelikle veri grubuna ayrıştırma uygulanmıştır. Ayrıştırma işlemi SPSS Statistics 21.0 programı kullanılarak hem toplamsal ayrıştırma hem de çarpımsal ayrıştırma için gerçekleştirilmiştir. Yapılan ayrıştırma işlemi ile uygulamada kullanılmak üzere; KONTEYNER serisinin mevsimsellikten arındırılmış halini temsil eden “St bileşeni” ve “Mevsimsel Endeks (Faktör)” değerleri elde edilmiştir. Fakat her iki ayrıştırma yöntemi ile elde edilen GM (1,1) modeli sonuçlarının RMSE, MSE ve MAE-MAD değeri bakımından incelenmesi üzerine; toplamsal yöntem ile gri tahmin modeli uygulamasının, öngörü başarısının daha güçlü olduğu gözlenmiştir. Bu yüzden makalede sadece toplamsal ayrıştırma ile elde edilen GM (1,1) modeline ilişkin bulgulara yer verilmektedir. GM (1,1) modeli, parametre değerleri Tablo 3.’te verilmiştir.

Tablo 3’teki ardışık ortalama dizisi Z(1)(k) bağımsız değişken, X(0)(k) dizisi bağımlı değişken kabul edilerek oluşturulan diferansiyel denklemin EKK yöntemi kullanılarak tahmin edilmesi ile elde edilen gelişme (a) ve sürücü katsayısı (b) değerleri bulunarak GM (1,1) modeli elde edilmiştir.

Oluşturulan GM (1,1) modeli diferansiyel denkleminin EXCEL programı ile çözülmesi sonucu edilen katsayı tahmin değerleri Tablo 2.’de görülmektedir.

**Tablo 2.** Toplamsal Ayrıştırma ile Gri Tahmin Modeli Diferansiyel Denkleminin Katsayıları Tahmini

Değişkenler	b	a
Katsayılar	8723,337387	-0,006520432
p Değerleri	2,67E-25	2,59E-13

Hesaplanan bu  $\alpha$  ve b katsayılarının, öngörü değerinin elde etmede kullanılan denklemde (Eşitlik 15’ te) yerine konulması ile GM (1,1) modeli aşağıda verildiği şekilde oluşturulmuştur.

$$x^{(0)}(k+1) = \left[ x^{(0)}(1) - \frac{8723,337387}{(-0,006520432)} \right] e^{-(-0,006520432)k} (1 - e^{-(-0,006520432)}) \quad [26]$$

Elde edilen bu modelin gelecek her k dönemi için uygulanması sonucunda da birikimli olmayan gri tahmin öngörü değerleri elde edilmektedir. Fakat burada elde edilen değerler ayrıştırılmış seri (St) üzerinden hesaplandığı için mevsimsel dalgalanma gösteren gerçek veri setini temsil etmeyecektir. Bu yüzden toplamsal ayrıştırma yöntemi ile elde edilen mevsimsel faktörlerin (Tablo 4.) bu seriye eklenmesi gerekmektedir. Böylece orijinal veri setini temsil edebilecek nitelikte, mevsimsel etki barındıran konteyner istatistiği öngörü değerlerine ulaşılmış olacaktır.

**Tablo 3.** Toplamsal Ayrıştırma ile GM (1,1) Modelinin Parametre Değerleri

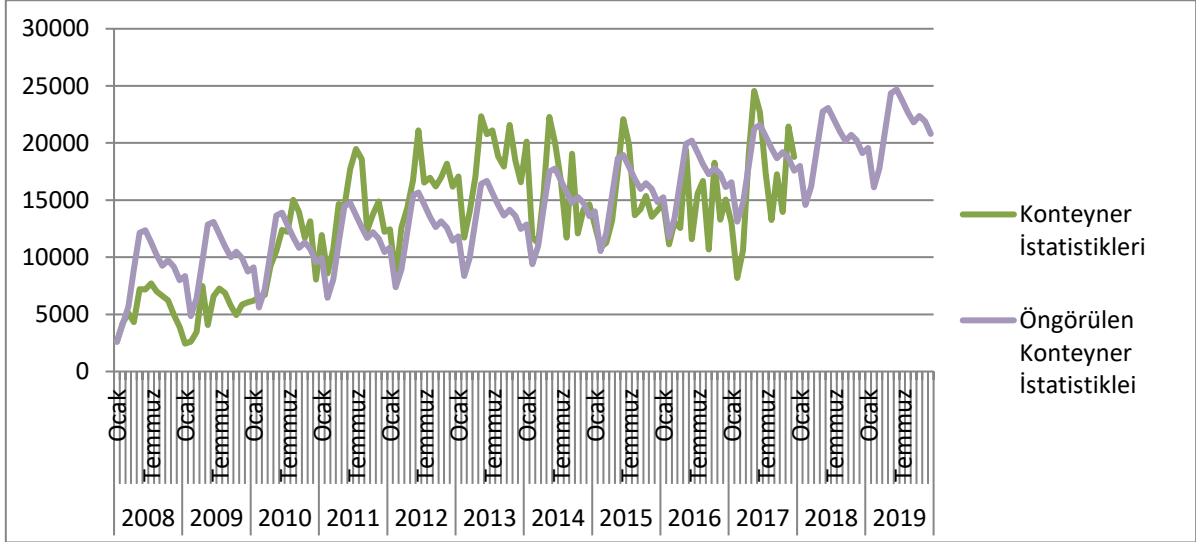
Tarih	St Bileşeni (X(0)(k))	X(1)(k)	Z(1)(k)	Tarih	St Bileşeni	X(1)(k)	Z(1)(k)	Tarih	St Bileşeni	X(1)(k)	Z(1)(k)
Oca.08	3684	3684	3684	May.11	11311	322178	316522	Eyl.14	18997	976745	967247
Şub.08	8872	12556	8120	Haz.11	14385	336563	329370	Eki.14	11597	988342	982544
Mar.08	8255	20811	16683	Tem.11	17272	353835	345199	Kas.14	14349	1002691	995517
Nis.08	4284	25095	22953	Ağu.11	17514	371348	362591	Ara.14	16023	1018714	1010703
May.08	4042	29137	27116	Eyl.11	12290	383638	377493	Oca.15	13900	1032614	1025664
Haz.08	3830	32967	31052	Eki.11	13286	396924	390281	Şub.15	15502	1048116	1040365
Tem.08	5512	38479	35723	Kas.11	15011	411935	404430	Mar.15	14404	1062520	1055318
Ağu.08	5946	44424	41451	Ara.11	13620	425555	418745	Nis.15	13162	1075682	1069101
Eyl.08	6538	50962	47693	Oca.12	13529	439084	432319	May.15	14384	1090066	1082874
Eki.08	5733	56695	53829	Şub.12	12869	451953	445518	Haz.15	18721	1108787	1099426
Kas.08	5100	61795	59245	Mar.12	15757	467710	459831	Tem.15	17645	1126432	1117609
Ara.08	5300	67095	64445	Nis.12	14271	481981	474845	Ağu.15	12627	1139058	1132745
Oca.09	3520	70615	68855	May.12	13526	495507	488744	Eyl.15	14130	1153188	1146123
Şub.09	7252	77867	74241	Haz.12	17766	513273	504390	Eki.15	14868	1168056	1160622
Mar.09	6592	84459	81163	Tem.12	14329	527602	520437	Kas.15	13686	1181742	1174899
Nis.09	7447	91906	88182	Ağu.12	15884	543485	535543	Ara.15	15487	1197229	1189486
May.09	893	92799	92352	Eyl.12	16133	559618	551552	Oca.16	15834	1213063	1205146
Haz.09	3247	96046	94422	Eki.12	16517	576135	567877	Şub.16	15769	1228832	1220947
Tem.09	5040	101086	98566	Kas.12	18327	594462	585299	Mar.16	16196	1245028	1236930
Ağu.09	5802	106887	103986	Ara.12	17556	612018	603240	Nis.16	12521	1257549	1251288
Eyl.09	5668	112555	109721	Oca.13	18148	630166	621092	May.16	16232	1273781	1265665
Eki.09	4457	117012	114784	Şub.13	16366	646532	638349	Haz.16	8235	1282016	1277898
Kas.09	6004	123016	120014	Mar.13	17093	663625	655078	Tem.16	13346	1295362	1288689
Ara.09	7445	130461	126739	Nis.13	17006	680631	672128	Ağu.16	15623	1310984	1303173
Oca.10	7275	137736	134098	May.13	19179	699810	690220	Eyl.16	10612	1321596	1316290
Şub.10	11149	148885	143310	Haz.13	17419	717229	708519	Eki.16	17794	1339390	1330493
Mar.10	9835	158720	153802	Tem.13	18892	736121	726675	Kas.16	13439	1352829	1346110
Nis.10	9216	167936	163328	Ağu.13	17761	753881	745001	Ara.16	16436	1369265	1361047
May.10	7363	175299	171617	Eyl.13	17863	771744	762813	Oca.17	14091	1383356	1376310
Haz.10	9034	184333	179816	Eki.13	21101	792845	782295	Şub.17	12828	1396184	1389770
Tem.10	10020	194353	189343	Kas.13	18582	811427	802136	Mar.17	13727	1409911	1403047
Ağu.10	13961	208313	201333	Ara.13	17950	829377	820402	Nis.17	19007	1428918	1419414
Eyl.10	13884	222197	215255	Oca.14	21210	850587	839982	May.17	21388	1450306	1439612
Eki.10	11213	233410	227804	Şub.14	16367	866954	858770	Haz.17	19333	1469639	1459972
Kas.10	13294	246704	240057	Mar.14	14389	881343	874148	Tem.17	15111	1484750	1477194
Ara.10	9427	256131	251418	Nis.14	15490	896833	889088	Ağu.17	12191	1496940	1490845
Oca.11	13025	269156	262643	May.14	19112	915945	906389	Eyl.17	17208	1514148	1505544
Şub.11	13233	282389	275772	Haz.14	16620	932565	924255	Eki.17	13483	1527631	1520890
Mar.11	13856	296245	289317	Tem.14	14518	947083	939824	Kas.17	21580	1549211	1538421
Nis.11	14622	310867	303556	Ağu.14	10666	957748	952415	Ara.17	20173	1569384	1559298

**Tablo 4.** Toplamsal Ayrıştırma İle Elde Edilen 12 Aylık Mevsimsel Faktör Değerleri

Aylar	Mevsimsel Faktör (Endeks) Değerleri
Ocak	-1079,99645
Şubat	-4645,65386
Mart	-3137,36682
Nisan	38,05910
Mayıs	3171,07762
Haziran	3353,92948
Temmuz	2213,37762
Ağustos	1062,22577
Eylül	70,37392
Ekim	483,81836
Kasım	-139,28349
Aralık	-1390,56127

Ocak 2008- Aralık 2017 dönemi (120 aylık) konteyner değerleri ve gri tahmin modeli ile elde edilen Ocak 2008- Aralık 2019 dönemi (144 aylık) konteyner istatistikleri öngörü değerleri Grafik 3.'te verildiği gibidir.

**Grafik 3.** GM (1,1) Modeli İle Elde Edilen 2008-2019 Dönemi Konteyner İstatistikleri Öngörü Değerleri ve Gerçekleşen Konteyner İstatistikleri Dağılımı



#### 4.2. Konteyner Bazında Yük Talebinin B-J Yöntemi ile Tahmin Edilmesi


Çalışmanın bu kısmında, KONTEYNER serisi B-J yöntemi metodolojisinde bahsedildiği gibi adım adım incelenerek ve uygun ARIMA modeli tespit edilecektir. İncelemeler sonucu uygunluğu tespit edilen ARIMA modelleri, kontrol verisi olan örneklem veri grubu (2015 Ocak-2017 Aralık) üzerinde uygulanacaktır. Ayrıca modellerin öngörü doğruluğu, model uygulugu adımı belirlenen kriterler üzerinden de değerlendirilecektir. Böylece uygun bulunan alternatif bütün modeller arasında hangisinin gerçek değerlere daha yakın sonuçlar verdiği saptanmış olacaktır. Yapılan bütün bu değerlendirmelerin ardından en uygun model de belirlenmiş olacaktır. Sonuç olarak belirlenen model ile 2018 Ocak ve 2019 Aralık dönemi gerçekleşecek konteyner istatistikleri tahmin edilebilecektir.

##### 4.2.1. Belirleme Adımı

Analizi yapılacak, zaman serisinin, B-J yönteminde kullanılan modellerden hangisine uygun olduğu kararının verilebilmesi için serinin durağanlığı ve mevsimsel etki taşıyıp taşımadığının belirlenmesi gerekmektedir.

Çalışmanın uygulama bölümünün başında verilen Grafik 2. ile serinin korelogram grafiğini veren Grafik 4. incelendiğinde; serinin durağan olmadığı, serideki değerlerin belirli dönemlerde ciddi artış ve azalışlar gösterdiği, serinin durağan süreç korelogramında olması gerektiği gibi, birinci veya ikinci gecikmede sıfırı kesmediği görülmektedir. Ayrıca korelogram değerlerinin dönemsel olarak güven aralıkları dışına çıkması serinin mevsimsel etki taşıdığını desteklemektedir.

**Grafik 4. KONTEYNER Serisi Korelogramı**




KONTEYNER serisinde durağanlığın sağlanması amacı ile ilk olarak serinin logaritması alınmıştır. Doğal logaritması alınmış seri (LNKONTEYNER) üzerine yapılan analizler (zaman yolu grafiği, korelogram ve birim kök testi (ADF, PP)) sonucunda, serinin bu durumda da durağan olmadığı belirlenmiştir. Fakat KONTEYNER serisine göre belli bir ortalama çevresinde seyir sağlandığı yani serinin durağanlığa yakınlığı görüldüğü için devam eden uygulama adımlarının LNKONTEYNER serisi üzerinden yapılması kararı alınmıştır.

Uygulamanın devam eden adımında, analiz sonuçlarında tutarlılık sağlayabilmek ve seriyi durağanlaştırabilmek için serinin farkı alınarak incelemeye devam edilmiştir. Serinin birinci farkı alınmış hali (DLNKONTEYNER) üzerinden yapılan analizler sonucunda ise; birinci farkta durağanlaşan seride mevsimsel etkinin hala devam ettiği belirlenmiştir. Bu sebeple serinin mevsimsel farkı da alınarak, Grafik 4'teki mevsimsellikten de arındırılmış durağan seri (S12DLNKONTEYNER) elde edilmiştir.

S12DLNKONTEYNER serisine ait zaman yolu ve korelogram grafiği, sırasıyla aşağıda verilen Grafik 5. ve Grafik 6.'da görüldüğü gibidir.

**Grafik 5.** S12DLNKONTEYNER Serisi Zaman Yolu Grafığı



**Grafik 6.** S12DLNKONTEYNER Serisi Korelogramı

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.513	-0.513	29.004	0.000
		2 0.025	-0.324	29.072	0.000
		3 0.097	-0.079	30.137	0.000
		4 -0.161	-0.188	33.061	0.000
		5 0.141	-0.035	35.349	0.000
		6 -0.084	-0.071	36.164	0.000
		7 0.028	-0.026	36.255	0.000
		8 0.045	0.030	36.494	0.000
		9 0.021	0.142	36.545	0.000
		10 -0.036	0.085	36.702	0.000
		11 0.130	0.268	38.742	0.000
		12 -0.384	-0.299	56.804	0.000
		13 0.236	-0.218	63.690	0.000
		14 0.100	0.045	64.947	0.000
		15 -0.212	-0.053	70.645	0.000
		16 0.103	-0.202	72.015	0.000
		17 -0.003	-0.045	72.015	0.000
		18 -0.012	-0.031	72.034	0.000
		19 -0.007	-0.042	72.040	0.000
		20 -0.009	0.038	72.050	0.000
		21 -0.047	0.012	72.353	0.000
		22 0.029	-0.060	72.471	0.000
		23 0.060	0.131	72.973	0.000
		24 -0.080	-0.175	73.878	0.000
		25 0.085	0.011	74.905	0.000
		26 -0.142	-0.009	77.811	0.000
		27 0.117	-0.106	79.808	0.000
		28 0.045	-0.005	80.107	0.000
		29 -0.141	0.075	83.078	0.000
		30 0.117	0.008	85.149	0.000
		31 -0.017	0.072	85.196	0.000
		32 -0.091	-0.088	86.484	0.000
		33 0.142	0.021	89.677	0.000

Verilen grafikler incelendiğinde; serinin birim kökten kurtulmasının dışında artık mevsimsel etki de barındırmadığı görülmektedir. Bu da serinin model belirleme aşamasına hazır hale geldiğini göstermektedir.

Doğru ve yeterli tahmin sonuçlarını verecek modeli belirlemek için öncelikle kullanılacak modelin mevsimsel ve mevsimsel olmayan AR ve MA süreçlerinin derecelerini (mevsimsel P, D, Q ve mevsimsel olmayan p, d, q) belirlemek gerekmektedir. Model derecelerini belirlemek için S12DLNKONTEYNER serisi korelogramından yararlanılacaktır.

#### 4.2.2.Tahminleme Adımı

Belirleme adımında kullanılan S12DLNKONTEYNER korelogramından yola çıkarak AR, MA, SAR ve SMA süreçleri için alternatif derece (p, q, P, Q) değerleri belirlenip alternatif modeller oluşturulmuştur. Örneğin; p=2 olarak belirlenen derecenin 0 ve 1 değerleri için de değerlendirilmesi yapılmıştır. Yapılan değerlendirmeler sonucu; uygun sonuçlar vereceği düşünülen 23 adet SARIMA modeli belirlenmiştir.



Belirlenen tahmin sonuçları incelendiğinde belirlenen 23 modelden 13 tanesi anlamlı bulunmaktadır. Anlamlı bulunan bu modellerden ARIMA(2,1,0)x(1,1,0)12 ve ARIMA(2,1,0)x(0,1,0)12 modellerinin AR süreci parametreleri toplamı  $\beta_1 + \beta_2 > 1$  olduğundan, bu modeller durağanlığı ihlal etmektedir. Bu durumda anlamlı bulunan ve bir sonraki adıma geçen model sayısı 11'e düşmektedir.

#### 4.2.3. Tanı Koyma Adımı-Model Uygunluğu Araştırması

B-J yönteminin üçüncü adımı olan bu adımda ise tahmin adımı sonrasında seçilen on bir modelin; model uygunluğu kriterleri Ayarlı R2, AIC ve SIC ile değerlendirilmesi yapılmış ve kestirim için en uygun modelin hangisi olduğu belirlenmiştir. Burada yapılan değerlendirmeler örneklem veri grubu olarak seçilen 2015 Ocak-2017 Aralık dönemi (36 ay) üzerinden hesaplanmıştır. Bu hesaplamalar sonucunda en düşük AIC ve SIC değerlerini veren model 15. modeldir. Fakat bu modelin Ayarlı R2 bakımından değerlendirilmesi yapıldığında ise en yüksek değeri sağladığı görülmektedir. Bu yüzden uygun model seçiminde bütün kriterler birlikte değerlendirilerek uygun tahmin sonuçlarını vereceği düşünülen 6, 11, 16, 17 ve 18. modeller üzerinden analize devam edilecektir.

Ayarlı R2, AIC ve SIC kriterleri üzerinden değerlendirmeler yapıldıktan sonra da seçilen model sayısı bire düşürülemediği için model öngörü başarısını ortaya koyacak MAPE, RMSE, MSE ve MAE-MAD kriterlerine başvurulması gerekmektedir.

Uygun sonuç vereceği düşünülen beş modelin örneklem grubu üzerinden analizi ile elde analiz değerleri Tablo 5.'te görüldüğü gibidir.

**Tablo 5.** Aday Modellerin Öngörü Başarı Kriter Değerleri

Model No	Model	MAPE	MAE-MAD	RMSE	MSE
6	ARIMA(0,1,0)x(1,1,1)12	17,12	2373,14	2944,18	8668196
11	ARIMA(1,1,0)x(1,1,0)12	26,54	3715,16	4558,22	20777370
16	ARIMA(2,1,0)x(0,1,1)12	14,51	2158,81	2794,93	7811634
17	ARIMA(1,1,0)x(0,1,1)12	17,92	2557,83	3025,8	9155466
18	ARIMA(0,1,0)x(0,1,1)12	15,68	2195,53	2718,02	7387633

Tablo 5. incelendiğinde MAPE ve MAE kriter değerlerinde en düşük değerleri, model numarası 16 olan ARIMA(2,1,0)x(0,1,1)12 modelinin sağladığı görülmektedir. RMSE ve MSE kriter değerinde ise model numarası 18 olan ARIMA(0,1,0)x(0,1,1)12 modelinin daha düşük değeri sağladığı gözlenmektedir. Bütün kriter değerleri bakımından yaklaşık sonuç verdikleri için analizin son kısmı olan grafiksel yorumlama ve model hata karelerinin incelemesine her iki model üzerinden devam edilmiştir.

Yapılan incelemeler sonucu zaman yolu grafiği bakımından her iki model de birbirine yakın düzeyde ham veri ile uyumlu bulunmuştur. Fakat modellere ait hata kareleri değerlerinin, korelogram üzerinden incelenmesi sonucunda en uygun olan modelin (model 18) ARIMA(0,1,0)x(0,1,1)12 olduğuna karar verilmiştir.

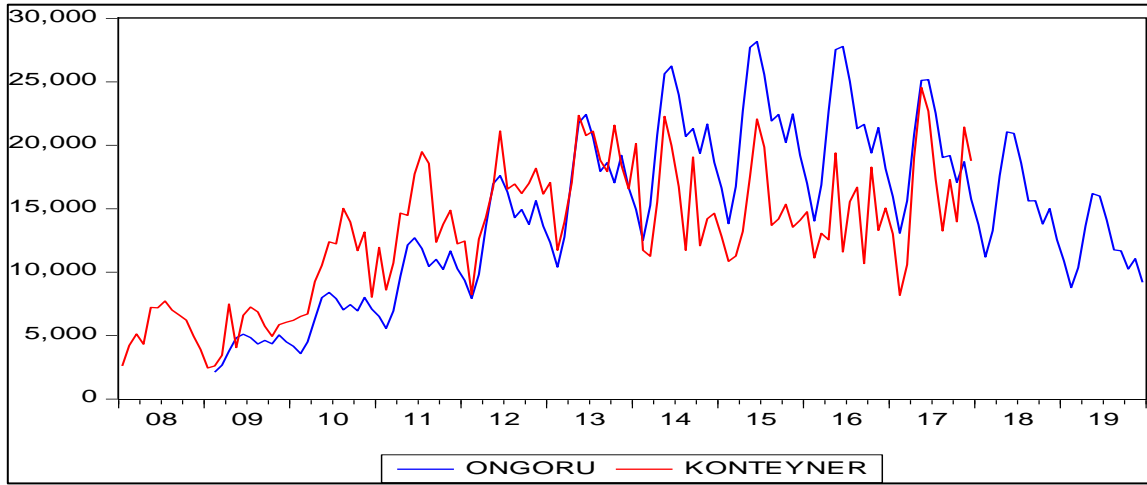
Kestirim adımı için uygun bulunan bu model, %15.58'lik MAPE değeri ile maksimum uygunluk seviyesi olan %50 seviyesinin oldukça altında seyretmektedir. Bu durumda ARIMA(0,1,0)x(0,1,1)12 modeli doğru ve yeterli öngörü sonuçları verebilecek modelleme başarısına sahiptir sonucuna ulaşılmaktadır.

#### 4.2.4. Kestirim-Öngörü Adımı

B-J yönteminin bu adımında geleceğe yönelik kestirim için uygun olduğu belirlenen ARIMA(0,1,0)x(0,1,1)<sub>12</sub> modeli ile 2018 Ocak -2019 Aralık (24 ay) döneminin konteyner bazında yük talebi değerleri öngörülmektedir. Öngörü değerlerine EViews 7 programı yardımı ile seçilen model üzerinden yapılan uygulama sonucu ulaşılmıştır.

Öngörülen yük değerleri (ONGORU) serisinin hem 2019 yılsonuna kadar nasıl bir seyir izleyeceğini hem de KONTEYNER serisi ile uyumunu görebilmek için bu iki seri değerlerinin birlikte incelendiği Grafik 7. aşağıda verilmektedir.

**Grafik 7. KONTEYNER ve ONGORU Değerleri Seyri**



Grafik 7.'de görüldüğü üzere devam eden yıllar içinde mevsimsel dalgalanma etkisi devam etmektedir. Öngörülen değerlerinde, orijinal veri setinde olduğu gibi yılın bahar ve yaz aylarını içeren dönemlerinde daha yüksek değerlere ulaştığı ve şubat ayında en düşük değeri gösterdiği gözlenmektedir. Buna göre öngörü değerleri izlediği bu seyir ile gerçek veri grubuna uyum sağlamış olduğunu göstermektedir. Ayrıca yapılan tahminleme ile yeterli ve tutarlı bir tahmin gerçekleştirildiğini kanıtlamaktadır.

#### 4.3. Model Sonuçlarının Karşılaştırılması ve Değerlendirmesi

“Toplamsal Ayrıştırma ile GM (1,1) Modeli” ve “ARIMA(0,1,0) x(0,1,1)<sub>12</sub> Modeli” model başarı kriter değerleri Tablo 6.'da verilmiştir.

**Tablo 6.** Toplamsal Ayrıştırma ile GM (1,1) ve ARIMA(0,1,1)x(0,1,1)<sub>12</sub> Modelleri Karşılaştırılması

Uygunluk Kriteri	Toplamsal Ayrıştırma ile GM (1,1) Modeli	ARIMA(0,1,0)x(0,1,1) <sub>12</sub> Modeli
RMSE	2765,08	2718,02
MSE	7645652	7387633
MAE-MAD	1084,06	2195,53
MAPE	8,099	15,68

Tablo 6. incelendiğinde GM (1,1) modelinin; MAE ve MAPE değerlerinin daha düşük olduğu görülmektedir. RMSE ve MSE değerleri ARIMA modelinde daha düşük seyrederken gri modelin de yakın değerlerde seyrettiği gözlenmektedir.

Modeller ile elde edilen öngörü değerleri, gerçekleşen değerler ve modellere ait sapma değerleri ise aşağıdaki Tablo 7.'de verilmiştir.

**Tablo 7.** GM (1,1) ve ARIMA(0,1,1)x(0,1,1)<sub>12</sub> Modelleri İle Elde Edilen Öngörü Değerleri, Gerçekleşen Değerler ve Sapma Değerleri

Tarih		Gri Tahmin Yöntemi Öngörü Değerleri	Box Jenkins Yöntemi Öngörü Değerleri	Gerçekleşen Değerler	Gri Tahmin Sapma Değerleri	Box Jenkins Sapma Değerleri
Yıl	Ay					
2018	Ocak	18008,18	13755,02	14671	-3337,18	915,98
2018	Şubat	14567,47	11187,70	9667	-4900,47	-1520,7
2018	Mart	16201,53	13267,68	11259	-4942,53	-2008,68
2018	Nisan	19503,54	17591,67	17990	-1513,54	398,33
2018	Mayıs	22763,98	21045,47	20761	-2002,98	-284,47
2018	Haziran	23075,09	20938,93	21062	-2013,09	123,07
2018	Temmuz	22063,63	18603,11	17540	-4523,63	-1063,11
2018	Ağustos	21042,41	15613,11	15008	-6034,41	-605,11
2018	Eylül	20181,35	15630,69	13276	-6905,35	-2354,69
2018	Ekim	20726,44	13802,73	18546	-2180,44	4743,27
2018	Kasım	20235,84	15009,89	14068	-6167,84	-941,89
2018	Aralık	19117,94	12559,22	12431	-6686,94	-128,22
2019	Ocak	19562,75	10886,62	15400	-4162,75	4513,38
2019	Şubat	16132,21	8792,02	9515	-6617,21	722,98
2019	Mart	17776,51	10352,84	10361	-7415,51	8,16
2019	Nisan	21088,84	13629,75	18116	-2972,84	4486,25
2019	Mayıs	24359,65	16190,33	13822	-10537,65	-2368,33
2019	Haziran	24681,20	15994,40	12447	-12234,2	-3547,4
2019	Temmuz	23680,25	14109,62	14380	-9300,25	270,38
2019	Ağustos	22669,62	11758,06	11637	-11032,62	-121,06
2019	Eylül	21819,21	11688,01	13657	-8162,21	1968,99
2019	Ekim	22375,02	10248,11	10411	-11964,02	162,89
2019	Kasım	21895,22	11065,54	11544	-10351,22	478,46
2019	Aralık	20788,17	9193,35	9534	-11254,17	340,65

Tablo 7 incelendiğinde; ARIMA(0,1,0)x(0,1,1)<sub>12</sub> modeli öngörü değerlerinin, gerçekleşen değerler karşısında GM(1,1) modeline göre daha az sapma gösterdiği tespit edilmiştir. Gri modelin, 36 aylık örneklem veri grubu (Ocak 2015- Aralık 2017) üzerinden yapılan analizler sonucunda daha başarılı sonuçlar vermesine rağmen gerçek veriler karşısında beklenen başarıyı gösteremediği tespit edilmiştir.

Gri modelin en önemli avantajı az sayıda veri grubu üzerinde etkili sonuçlar vermesidir. Bu çalışmada yapılan analiz sonuçları veri sayısının artması ile gri modeldeki sapmaların artmasına neden olduğu sonucunu ortaya çıkarmaktadır. GM (1,1) modelinde gerçek değerlerden sapmanın fazla olmasının bir başka sebebi ise modelin mevsimsel bileşen barındırmamasından kaynaklanıyor olabileceğidir.

## 5. SONUÇ VE ÖNERİLER

Dünya ticaret hacminin %80'den fazlası denizyolu taşımacılığı ile yapılmaktadır. Konteyner taşımacılığının ise denizyolu ticaretindeki önemi her geçen gün artmaktadır. Bu çalışmada, limanların geleceğe yönelik yatırım planlarında büyük gereklilik haline geldiği düşünülen yük talep tahmini uygulaması yapılmıştır. Uygulama Ortadoğu Antalya Liman İşletmeleri A.Ş. tarafından işletilen Port

Akdeniz Limanı için yapılmış, tahmin için Ocak 2008-Aralık 2017 (120 ay) dönemi konteyner istatistikleri veri grubu olarak kullanılmıştır.

Konteyner, kuru, sıvı, genel yük ve kruvaziyer şeklinde çeşitli taşımacılık faaliyetleri gösteren işletmenin yük talep tahmini, konteyner bazında olmak üzere Ocak 2018- Aralık 2019 dönemini içeren 24 aylık dönem için yapılmıştır.

Belirlenen veri grubu ve yöntemler ile yapılan analizler sonucu, her yöntem için çalışma amacına en uygun tahmin sonuçlarını verecek model belirlenmiştir. Buna göre gri tahmin yöntemi ile yapılan analizlerde mevsimsel ayrıştırma uygulanmış ardından GM (1,1) tahmin modeli ile analizler yapılmıştır. B-J yönteminde ise ayrıca mevsimsel ayrıştırma uygulanmadan, mevsimsel bileşeni içinde barındıran ARIMA(0,1,0)x(0,1,1)<sub>12</sub> modeli kullanılmıştır.

Elde edilen tahmin sonuçları MAPE, RMSE, MSE ve MAE kriterleri bakımından değerlendirildiğinde; Gri Model (1,1)'in MAPE ve MAE bakımından daha iyi sonuçlar verdiği gözlemlenmiştir. Fakat hem RMSE ve MSE kriterleri hem de Tablo 7' de yer verilen sapma değerleri dikkate alındığında ise; ARIMA (0,1,0)x(0,1,1)<sub>12</sub> modelinin daha başarılı ve uygun tahmin sonuçları verdiği tespit edilmiştir.

Yapılan analizler sonucunda her iki modelin de konteyner bakımından yük talep tahmininde başarılı sonuçlar verdiği söylenebilir. Bu sebeple; yük talep tahmini yapan karar vericilerin tahminleme modellerini karar verme sürecinde yardımcı bir araç olarak kullanmalarının yol gösterici olacağı düşünülmektedir. Öte yandan gelecekte yapılacak Antalya Limanı'nın farklı faaliyetleri (genel yük, kuru, sıvı vs.) ile birlikte ve farklı tahmin yöntemleri kullanılarak daha kapsamlı değerlendirmesi yapılabilir. Ayrıca yöntemler aynı dönemlerde diğer büyük limanlar için de uygulanarak bulguların genellenebilirliği test edilebilir.

## **KAYNAKÇA**

- Akar, O. ve Esmer, S. (2015). Cargo Demand Analysis of Container Terminals in Turkey, *Journal of ETA Maritime Science*, 3(2), 117-122.
- Bayraktutan, Y. ve Özbilgin, M. (2013). Limanların Uluslararası Ticarete Etkisi ve Kocaeli Limanlarının Ülke Ekonomisindeki Yeri, *Kocaeli Üniversitesi Sosyal Bilimler Dergisi*, 26, 11-41.
- Chan, H.K., Xu, S. ve Qi, X. (2019). A Comparison of Time Series Methods for Forecasting Container Throughput, *International Journal of Logistics Research and Applications*, 22(3), 294-303.
- Chen, S.H. ve Chen, J.N. (2010). Forecasting Container Throughputs at Ports Using Genetic Programming, *Expert Systems with Applications*, 37(3), 2054–2058.

- Çuhadar, M., Güngör, İ. ve Göksu A. (2009). Turizm Talebinin Yapay Sinir Ağları ile Tahmini ve Zaman Serisi Yöntemleri ile Karşılaştırmalı Analizi: Antalya İline Yönelik Bir Uygulama, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 14(1), 99- 114.
- Denizcilik Sektör Raporu (2019). İMEAK Deniz Ticaret Odası, İstanbul.
- Gao, Y., Chang, D., Fang, T. ve Fan, Y. (2019). The Daily Container Volumes Prediction of Storage Yard in Port with Long Short-Term Memory Recurrent Neural Network, Journal of Advanced Transportation, 1, 1-11.
- Goh, C. ve Law, R. (2002). Modeling And Forecasting Tourism Demand For Arrivals With Stochastic Nonstationary Seasonality And Intervention, Tourism Management, 23(5), 499-510.
- Gujarati, D. N. (1995). Basic Econometrics. 3. Edition. New York: MC Graw- Hill Higher.
- Guo, Z., Le, W., Wu, Y. ve Wang, W. (2019). A Multi-Step Approach Framework for Freight Forecasting of River-Sea Direct Transport without Direct Historical Data, Sustainability, 11(15), 1-15.
- Guzey, H. ve Akansel, M. (2019). A Comparison of SVM and Traditional Methods for Demand Forecasting in A Seaport: A Case Study, International Journal of Scientific and Technological Research, 5(3), 168-176.
- Halim, S. ve Bisono, I. N. (2008). Automatic Seasonal Auto Regressive Moving Average Models and Unit Root Test Detection, International Journal of Management Science and Engineering Management, 3(4), 266-274.
- Julong, D. (1989). Introduction to Grey System Theory, The Journal of Grey System, 1, 1- 24.
- Kara, A. (2011), İzmir (Alsancak) Limanı Gelecek Talep Tahmini İçin Bir Yöntem Önerisi, Yayınlanmamış Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi.
- Kayacan, E., Ulutaş, B., Büyüksalvarcı ve A., Kaynak, O. (2007). Gri Sistem Kuramı ve Finansman Uygulamaları: İMKB Örneği, 11. Ulusal Finans Sempozyumu, 17-20 Ekim 2007, Zonguldak, 215- 229.
- LI, Y., Campbell, E.P., Haswell, D., Sneeuwjagt, R.J. ve Venables, W.N. (2003). Statistical Forecasting of Soil Dryness Index in The Southwest of Western Australia, Forest Ecology and Management, 183: 147-157.
- Lim, D., Anthony, P., Mun, H.C., Wai, N.K. (2008). Assessing the Accuracy of Grey System Theory Against Artificial Neural Network in Predicting Online Auction Closing Price,

- Proceedings of the International Multi Conference of Engineers and Computer Scientists (IMECS), 1, 1-7.
- Liu, S. ve Lin, Y. (2006). Grey Information. London: Springer.
- Liu, S. ve Forrest, J. (2007). The Current Developing Status on Grey System Theory, The Journal of Grey System, 2, 111- 123.
- Meciarova, Z. (2007). Modeling and Forecasting Seasonal Time Series, Journal of Information, Control and Management Systems, 5(1), 73-80.
- Özdemir, M. A. ve Bahadır, M. (2010). Denizli’de Box Jenkins Tekniği ile Küresel İklim Değişikliği Öngörülleri, Uluslararası Sosyal Araştırmalar Dergisi, 12(3), 352-362.
- Özkara, Y., (2009). Mevsimsel Ayırıştırma Temelli Gri Tahmin Yöntemi İle Aylık Elektrik Yük Tahmini, Yayınlanmamış Yüksek Lisans Tezi, Gazi Üniversitesi.
- Peker, İ. ve Baki, B. (2011). Gri İlişkisel Analiz Yöntemiyle Türk Sigortacılık Sektöründe Performans Ölçümü, International Journal of Economic and Administrative Studies, 4(7), 1- 18.
- Rashed, Y., Meersman, H., Voorde, E.V. ve Vanelslander, T. (2017). Short-Term Forecast of Container Throughout: 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.
- Sallehuddin, R., Shamsuddin, S. M., Mohd, S. Z. M. ve Abraham A. (2010). Forecasting Time Series Data Using Hybrid Grey Relational Artificial Neural Network And Auto Regressive İntegrated Moving Average Model, Neural Network World, 6 (7), 573-605.
- Tang, S., Wu, S. ve Gao, J. (2019). An Optimal Model based on Multifactors for Container Throughout Forecasting, Journal of Civil Engineering, 23(9), 4124-4131.
- Tran, T.T. (2019). Applying Grey System Theory to Forecast The Total Value of Imports and Exports of Top Traded Commodities in Taiwan, International Journal of Analysis and Applications, 17(2), 282-302.
- Wang, Y. ve Wang, Z. (2018). Combined Throughout Prediction of Fujian Coastal Ports Based on Grey Model and Markov Chain, Advances in Economics, Business and Management Research, 68, 97-104.
- Yılmaz, H. ve Yılmaz, M. (2013). Gri Tahmin Yöntemi Kullanılarak Türkiye’nin Co2 Emisyon Tahmini, Mühendislik ve Fen Bilimleri Dergisi, 31, 141- 148.

---

Yolsal, H. (2010). Mevsimsel Düzeltmede Kullanılan İstatistiki Yöntemler Üzerine Bir İnceleme, *Öneri Dergisi*, 9(33), 245-257.

Erişim: 06.01.2020, <https://clarksonsresearch.wordpress.com/>.

Erişim: 06.01.2020, <https://denizticareti.uab.gov.tr/>.