


ARIMA-ARIMAX Yöntemiyle Türkiye Havayolu Yolcu Talep Tahmin Modellemesi, Öngörüsü Ve Karşılaştırması

Using the ARIMA and ARIMAX Methodologies to Estimate, Model, Forecast, and Compare Airline Passenger Transportation Demand in Türkiye

Vahap Önen¹ 

¹(Doç. Dr.,) İstanbul Topkapı Üniversitesi, İktisadi ve İdari Bilimler Fakültesi/Havacılık Yönetimi, İstanbul, Türkiye

ÖZ

Havayolu yolcu talebinin belirlenmesi makro ve mikro ekonomik açıdan ülkelerin ekonomisine etki eden önemli bir girdi unsurudur. Bundan dolayı hemen hemen tüm ülkeler havayolu yolcu talebi tahmin ve öngörüsüne yönelik sürekli araştırmalar yapmaktadır. Bununla birlikte geçmişten günümüze tahmin ve öngörü modellerinde bir çok yeni yöntemler geliştirilmiştir. Bu çalışmanın amacı, güncel verilerin ışığı altında Türkiye havayolu yolcu sayısını ARIMA ve ARIMAX yöntemlerine dayalı olarak model tahminlemesi, öngörüsünün yapılması ve kullanılan ekonometrik modellerden hangisinin daha iyi olduğunun belirlenmesidir. Çalışmada kullanılan veriler 2010-2022 dönemleri çeyrek dönemlere ait olup; Devlet Hava Meydanları İşletmesinden (DHMI) gelen- giden toplam yolcu sayıları, ticari gelen-giden toplam uçak hareket sayısı, TUIK'ten Gayri Safi Milli Hasıla (GHSY) ve Birleşik Devletler Enerji Bilgi İşletmesinden Ham Petrol Alış Fiyatı ve kullanılarak sağlanmıştır. Toplanan veriler Eviews 10.00 yardımıyla analiz edilmişlerdir. Araştırmada tek değişkenli zaman serisi analizi Box-Jenkins metoduna dayalı ARIMA modellemesi ve daha sonra modele dışsal değişkenlerin ilave edilerek ARIMAX modeliyle toplam yolcu sayısı tahminlemesi ve öngörülere ortaya çıkarılmıştır. Yapılan çalışmada, ilk aşamada Covid-19 etkisi incelenmiş ve bu dönemde yapısal kırılmanın anlamlı bir etkisi olmadığı belirlenmiş, akabinde yapılan model tahmininde mevsimsel etkiyi de dikkate alan SARIMA (1,1,0)(1,1,2) modelinin en uygun model olduğu belirlenmiştir. İkinci çalışmada ARIMAX modellemesi yapılarak eklenen dışsal değişkenlerle birlikte en uygun modelin (1,1)(0,0) olduğu tespit edilmiş, dışsal değişkenlerden ülkeye giriş ve çıkış yapan ticari uçak sayısının, ve Gayri Safi Milli Hasılanın modeli anlamlı şekilde desteklediği, ham petrol fiyatı alış fiyatının ise yolcu sayısının belirlenmesine etkisinin anlamlı olmadığı belirlenmiştir. Yapılan her iki modelin öngörü analizleri sonucunda elde edilen Theil katsayıları, yansızlık oranları (Bias) varyans açıklama oranları, hataların ortalama kare kökü (RMSE), hataların mutlak ortalaması (MAE), hataların ortalama mutlak yüzdesi (MAPE) ve modeli açıklama gücü R kare değerlerinin oldukça iyi seviyede oldukları belirlenmiş olup bununla birlikte, yapılan model karşılaştırmaları neticesinde ARIMAX modelinin daha iyi öngörü gücü olduğu sonucuna ulaşılmıştır.

ABSTRACT

Determining air transportation demand is a very important input that impacts countries' economies in terms of both micro and macroeconomics. Thus, almost all countries continuously conduct research studies on estimating and forecasting airline passenger demand. However, new estimating and forecasting methods have been improved since the past. The purpose of this study is to estimate and forecast airline passenger demand based on the autoregressive integrated moving average (ARIMA) and ARIMA with explanatory variables (ARIMAX) methods in light of updated time series data and to determine the best model between the two econometric methods. The data used in the study belong to quarterly data between 2010-2022, in which the total incoming and outgoing airline passengers and total incoming and outgoing aircraft are obtained from Türkiye's General Directorate of State Airports Authority (DHMI), GDP values are obtained from the Turkish Statistical Institute (TurkSTAT), and crude oil import prices are obtained from the US Energy Information Administration (EIA). The collected data have been analyzed using the software program EViews 10.00. The study presents estimations and predictions for total number of airline passengers by first using ARIMA modeling based on the Box-Jenkins method for univariate time series analysis and then ARIMAX modeling by adding exogenous variables to the first model. The study first tested for effects from COVID-19 and found no significant structural break in the studied period. Thus, the seasonal ARIMA (1,1,0) x (1,1,2) effect model (SARIMA) was understood to have the best

Corresponding Author: Vahap Önen E-mail: vahaponen@topkapi.edu.tr

Submitted: 26.03.2023 • Accepted: 11.10.2023



This article is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0)

fit. The second part of the study added the exogenous variables to the model and found ARIMAX (1,1) x (0,0) to have the best fit. Therefore, while the number of aircraft movements and GDP variables are found to be significant and to support the model, imported crude oil price was found to not be significant and to not support the model. The forecasting analysis results found the Theil index; bias proportion; RMSE, MAE, and MAPE; variance, and covariance explanation ratios; and R square values to be at satisfactory levels for both models. When comparing the two models, the ARIMAX model is seen to perform better than the ARIMA model.

Anahtar Kelimeler: ARIMA-ARIMAX, Havayolu Yolcu Taşımacılığı, Model Tahmini ve Öngörüsü

JEL Kodları: M31 L93 R41

Keywords: ARIMA, ARIMAX, Passenger Transportation, Model Estimation, Model Forecasting

JEL Codes: M31 L93 R41.

EXTENDED ABSTRACT

The liberalizations in aviation and the deregulation of air rules have increased the demand for air transportation in recent years and had great impact on the different airlines that provide these services, triggering congestion at airports and airlines. The quickest effect from liberalizing air rules has been seen in air travel service-providing organizations, which has affected the cost structure in the sector and led to various alliances and airline mergers, as well as new companies entering the market (Janic, 2000).

The problem with measuring airline demand is complex. Total demand and market share for a particular airline are determined by many variables, such as the firm's price adjustments, advertising, number of flights, timing of flights, equipment, and other factors, as well as competitive environments and population densities of the same variables, business activities, environmental conditions, disposable personal income, and other issues. All these variables regarding decisions, competition, and environmental influences interact in the market to generate sales. From a marketing perspective, the problem of airline management involves anticipating the possible outcomes of these interactions for different marketing strategies. This allows a firm to choose the best strategy in light of the changing competitive and environmental conditions (Schultz, 1972).

The main purposes of this study involve how demand has been affected over the studied time period, whether COVID-19 has influenced demand structure or not, and using 52 quarters from time series data to create a model for estimating demand using not only the autoregressive integrated moving average (ARIMA) but also ARIMA with explanatory variables (ARIMAX) methods by adding exogenous variables. This has been done to reveal which of the two models is better and can accordingly forecast more precisely the near future demand. As a result, conducting this study is thought to be worthwhile and remarkable.

In general, airlines are divided into three categories regarding forecasting techniques: qualitative, quantitative, and decision analysis, and sometimes a combination of the first two can be used (Taneja, 1978). Time series analysis involves a ratio analysis, train projection, moving averages, spectral analysis, adaptive filtering, and Box-Jenkins methods. The details of all these methods are found in Montgomery and Johnson (1976), Box and Jenkins (1976), Brown (1963), Jenkins and Watts (1968), Anderson (2011), and Granger (1990). Econometric and time series are the methods most used to explain travel demand, and no differentiation is made between them. As seen in Table 1, Andreoni and Postorino (2006), Fernandes and Pacheco (2023), Kulendran and King (1997), Lim and McAleer (2002), and Lim et al. (2008) used univariate time series (i.e., ARIMA and/or ARIMAX) models in their studies. The ARIMA model has been used to determine air passenger transportation demand in Türkiye (Tortum et al., 2014b, p. 53), and their study's results found the model that best explains the monthly passenger series to be the seasonal ARIMA (6,1,1)x(12,0,12) method (SARIMA).

The study uses quarterly data from 2010-2022 quarters, in which the total number of incoming and outgoing airline passengers and total incoming and outgoing aircraft movement numbers have been obtained from Türkiye's General Directorate of State Airports Authority (DHMI), GDP from the Turkish Statistical Institute (TurkStat), and crude oil import prices from the US Energy Information Administration (EIA). More than 30 time-series datasets are considered sufficient for a forecasting model performed on a quarterly basis (Gujarati, 2014). The ARIMA and ARIMAX models were used by making use of the time series Box-Jenkins method for estimating the total number of domestic and international passengers transported by air at quarterly annual intervals. The EViews package program was used to determine the model estimating and forecasting.

Figure 3 provides graphical representations of the data of the related series. As seen in the figure, passenger demand increased until 2020, decreased in 2020 and 2021 due to the pandemic, and started to rise again as of 2022. In addition, demand was observed to fluctuate with seasonal characteristics. The number of aircraft movements for a similar course has also been included in the figure. The purchase price of crude oil is seen to fluctuate, and GDP is seen to have increased gradually since 2010, with this momentum increasing even more since 2018.

While the number of passengers was constant and no trend was found regarding the I(0) state of the passenger number difference series DPAS, the 3-lagged ADF unit root test results are greater than those for the t statistical absolute values (2.370) at 5% (1.947) and 10% (1.612) critical absolute values ($p < 0.05$); thus hypothesis H_0 was rejected, and no unit root was determined to exist for the series, which is constant and trendless. No unit root was found in the DPAS series I(0), while the series was seen to become stationary in the PAS series I(1). Figure 8 presents a graph of the DPAS series.

Structural break unit root tests were conducted to determine whether a structural break occurs in the DPAS. Table 15 presents the 12- and 4-lag analyses of the DPAS series resulting from the structural break ADF and Perron's unit root tests. As a result, hypothesis H_0 was rejected, as no root or structural break occurred in the 2020Q1 period.

When examining the correlogram structure of the DPAS series, autocorrelation was determined to be present in the series due to both the autocorrelation and partial autocorrelation having multiple values ($p < 0.05$). In addition, when examining the number of passengers, the graphs reveal a seasonality effect to also be seen in the series due to the number of passengers being lower in the winter months and higher in the summer period. Therefore, many trials will be required to select the most suitable model. Of course, the AR, MA, SAR, and SMA coefficients with the smallest coefficients that meet the need will be selected here. As a result, the most suitable model is selected by looking at the following criteria in terms of comparison (Asteriou & Hall, 2011, p. 278).

A total of 1,521 model trials were conducted using the E-Views Auto ARMA option. As a result of the trials, the most appropriate ARMA model (1,1)x(1,2) or ARIMA (p,d,q) SARIMA (P,D,Q) was determined as the SARIMA (1,1,1)x(1,1,2), with the smallest related AIC value being determined as 38.61861. The static estimation result for passenger demand was obtained within the 95% confidence interval for the ARIMA (1,1,1)x(1,1,2) model, as given in Figure 14. In addition, the average absolute error, average absolute error percentage, Theil index, and related bias ratio, variance ratio, and covariance ratio values as obtained for the estimation reliability have been included.

The performed tests revealed the aircraft movements ACN series, LGDP series, crude oil purchase price (AIOP) series to not have a stationary level and to be a unit root. The tests performed by taking the difference of one of the series showed the series to become stationary regardless of constancy or trend. The ADF unit root test results tables related to the subject are Tables 16, 17, and 18. As a result of the model trials, the crude oil purchase price (DAIOP) series was excluded from the equation as an exogenous variable due to the lack of significance.

As a result of the trials, the ARMA model (1,1)x(0,0) and ARIMA (1,1,1) were determined as the most suitable models, with the smallest AIC value being determined as 36.95815. The obtained model is AR(1) MA(1) DACN DLGDP(-1) for the DPAS series. When we the model is regressed, the following results are shown (Table 19). When considering the correlogram test results of the related series, Figure 16 shows no autocorrelation to be present.

Figure 17 shows the static estimation result of the passenger demand obtained within a 95% confidence interval for the ARIMAX model. In addition, the figure includes the average absolute error, average absolute error percentage, Theil index, and related bias, variance, and covariance ratios obtained for estimation reliability.

When examining the criteria in Table 20, the ARIMAX model's Theil inequality index, bias ratio, variance ratio, and covariance ratio, as well as RMSE, MAE, and MAPE values are seen to be smaller and the model's explanation ratio R^2 value to be higher in the ARIMAX model. The forecasting power of the ARIMAX model can be said to be better than the DPAS AR(1) MA(1) DACN DLGDP(-1) model. In light of this information, the ARIMAX model must be preferred when estimating the number of airline passengers.

1. Giriş

Havacılıkta yaşanan liberalleşmeler, kuralların düzensizleşmesi son yıllarda hava ulaşımına yönelik talebi artırarak bu hizmetleri sağlayan farklı hava yollarında büyük etkiler yapmış, hava limanlarında ve havayollarında tıkanıklıklara yol açmıştır. Kurallardaki serbestleşmenin en çabuk etkisi seyahat hizmeti gerçekleştiren kuruluşlarda görülerek sektörün maliyet yapısını etkileyerek, çeşitli ittifak faaliyetlerine, havayolu birleşmelerine ve pazara yeni firmaların girmesine yol açmıştır (Janic, 2000).

Havayolu talebini ölçme sorunu karmaşıktır. Belirli bir havayolu için toplam talep ve pazar payı, birçok değişken tarafından belirlenmekte olup bunlar; firmanın fiyat ayarlamaları, reklam, uçuş sayısı, uçuşların zamanlaması, ekipman ve diğer faktörler; aynı değişkenlerin rekabet ortamları ve nüfus yoğunlukları, iş faaliyetleri, harcanabilir kişisel gelir gibi çevresel koşullar ve diğer hususlar yer almaktadır. Tüm bu değişkenler; karar, rekabet ve çevresel etkiler satış üretmek için pazarda etkileşime girer. Pazarlama açısından, havayolu yönetiminin sorunu, farklı pazarlama stratejileri için bu etkileşimlerin olası sonuçlarını tahmin etmektir. Bu, firmanın değişen rekabet ve çevresel koşullar ışığında en iyi stratejiyi seçmesine olanak tanır (Schultz, 1972).

Operasyonel ve stratejik karar amaçlı olarak gelecekteki yolcu talebinin tahmini havalimanı planlamaları için önemli bir unsurdur. Kısa dönemli tahminlemeler ani operasyonel planlamalar için yeterli olmakla birlikte yeni hava limanı ya da mevcut havalimanını genişletilmesine yönelik büyük yatırım kararıyla ilgili stratejik planlamalar için uzun dönemli tahminleme yapılması gerekmektedir (Wadud, 2013). Doğru ve güvenilir bir havalimanı yolcu talep tahmini, havalimanı altyapısının geliştirilmesi ve uçuş ağları ile ilgili kısa vadeli ve uzun vadeli planlama ve karar verme için ayrılmaz bir bileşendir. Master planın belirlenmesindeki önemli adımlardan biri, tahmin tekniğine dayalı olarak gelecekteki talebin tahmin edilmesidir (Suryan, 2016).

Havayolu taşımacılığı, turizm talebi tahminine yönelik ürün ve hizmetlerin tahminin doğruya çok yakın bir şekilde sağlamayı gerektirir zira, bu ürün ve hizmetlerin sağlanması için gereken satın alma ve tedarik yönetiminin doğru şekilde planlanmasını gerektirir. Buna ilaveten uzun vadeli yolcu sayısının kesin bir tahmini oteller, ulaşım terminaleri gibi gerekli altyapıların geliştir-

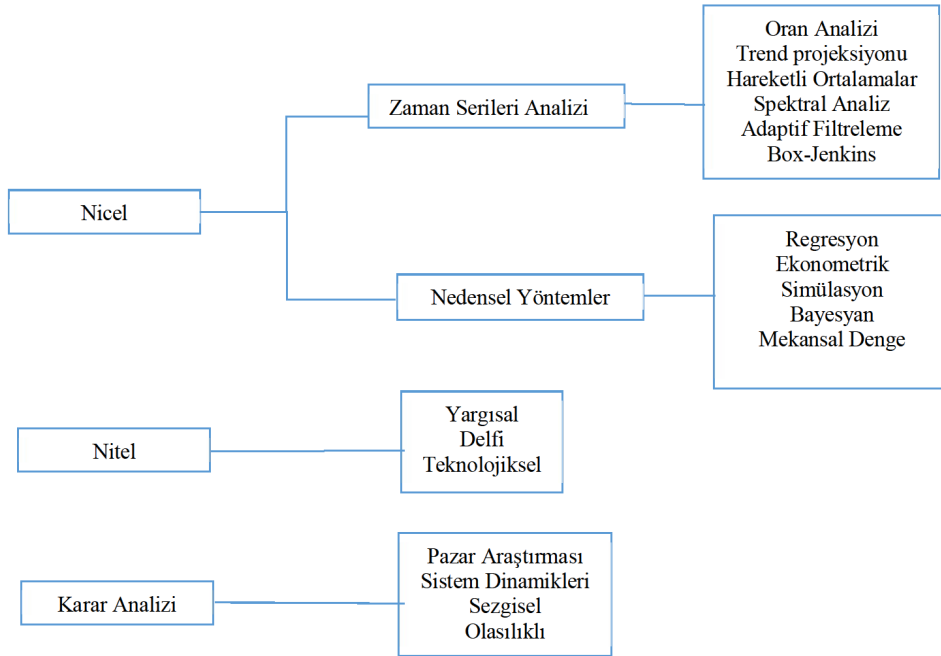
ilmesine yardımcı olabilir. Nicel yöntemlerin çoğu tahmin yapmak için geçmiş tarihi verileri kullanır ve bazıları test pazarlarından alınan verileri kullanır. Talebi tahmin edebilmesi tedarik, işgücü planlaması, fiyatlandırılma ve pazarlama stratejilerinin tanımlanması için kullanılabilir Ghalehkhondabi vd., (2019). Havayolları haricinde, tur operatörleri, oteller ve tatil köyleri, kurvaziyer tur sağlayıcıları ve eğlence tesisleri ve turistik mağazalar talebin kendi bölgelerinde doğru bir tahmin edilmesini beklemektedirler. Yolcu taşımacılığı hacminin tahmin edilmesi aynı zamanda turizm talep tahmininin ayrılmaz bir parçasıdır ve turizm endüstrisinin stratejik planlamasında önemli bir faktördür (Andreoni ve Postorino, 2006; Manrai vd., 2014; Milenkovic vd., 2013; Tsai vd., 2009).

Havayolu yolcu talebinin doğru şekilde modellenmesi ve tahmin edilmesinin havayolu taşımacılığı sektöründe doğrudan ve dolaylı olarak faaliyet gösteren kuruluşlara önemli bir katkı sağlacağı düşünülmektedir. Zaman serileri kapsamında yapılan çalışmalarda, zaman serisinin en az otuz ve üzeri olması tavsiye edilmektedir. Ülkemizde bu alanda daha önceden yapılan çalışmada yıllık bazda ve toplam on altı yıllık bir seri üzerinden bir çalışma yapıldığı ve modellemenin bu seri üzerinden yapıldığı belirlenmiştir. Geçen zaman süresinde talep yapısının ne şekilde etkilendiği, Covid-19 döneminin talep yapısında bir etkisi olup olmadığını belirlenmesi, kullanılan zaman serisinin elli iki dönemlik daha uzun süreli veriyi kapsaması, havayolu yolcu talebinin ARIMA modellemesiyle yanı sıra dışsal değişkenler ilave edilerek ARIMAX modellemesiyle yapılması ve her iki modelden hangisinin daha iyi olduğunun ortaya çıkarılması ve buna bağlı olarak yakın gelecekteki tahmin öngörülerinin daha hassas olarak belirlenmesi çalışmanın temel amacı olarak belirlenmiş olup bu açıdan çalışmanın kayda değer olarak değerlendirilmesi yapılmıştır.

2. Kavramsal Çerçeve

2.1. Havayollarında Tahminleme Yöntemleri

Genel olarak ele alındığında havayolları tahminleme teknikleri Şekil 1'de yer aldığı üzere üç kategoriye ayrılmakta olup bunlar; nitel, nicel ve karar analizleri biçiminde olup bazen ilk ikisinin kombinasyonu da kullanılabilir Taneja (1978). Bu teknikler makro ve mikro seviyede kullanılabilirler. Herhangi bir seviyede ortaya çıkan tahminleme problemine yönelik olarak üç zaman boyutu önemli olmakta olup bunlar; zaman periyodu, tahminleme ufku ve tahminleme entervalleridir Benton (1972). Nicel tahmineleme yöntemleri ağırlıklı olarak mevcut tarihsel verilere, geniş derecede tarihsel eğilimlerin devamlılığına bağlıdır.



Şekil 1. Havayolu Çalışmalarında Yer Alan Tahmin Yöntemleri

Çalışmada ekonometri yönünden zaman serisi analizlerinin amacı genellikle iki noktada toplanmaktadır. Birincisi gözlenen serinin artısını veren tahmini mekanizmayı modellemek ve anlamak, ikincisi ise serinin geçmişine bakarak serinin tahmini veya kestirimidir (Cryer, 1986). Zaman serisi, zaman içinde gözlenen ölçümlerin bir dizisidir. Eğer elimizde geçmiş yıllara ait veriler bulunuyorsa zaman serileri yardımıyla bu verileri kullanarak gelecek yıllar hakkında öngöründe bulunabiliriz. Bu da bize önemli bilgiler kazandırmaktadır (Yılmaz, 2003). Zaman serilerine ilişkin veriler stokastiktir, diğer bir ifadeyle, zamanın belli anlarında

rastsal değerler alırlar ve aldıkları bu değerlerin önceden kestirilebilmesi mümkün değildir (Tortum, Gözcü ve Çodur, 2014a:39-54). Zaman serilerinin özelliği, verilerin zamana göre sıralanması ve ardışık gözlemlerin genellikle birbirlerine bağımlı olmasıdır. Dönemler arasındaki bu bağımlılık sayesinde güvenilir öngörüler oluşturulabilmektedir (Vandaele, 1983).

Zaman serileri analizi; oran analizi, tren projeksiyonu, hareketli ortalamalar, spektral analiz, adaptif filtreleme, Box-Jenkins yöntemlerini içerir. Tüm bu yöntemlerin detayı Montgomery ve Jhonson (1976); Box ve Jenkins (1976); Brown (1963); Jenkins ve Watts (1968); Anderson (2011); ve Granger (1990) çalışmalarında yer almaktadır. Ekonometrik ve zaman serileri seyahat talebini açıklamada en çok kullanılan yöntemlerdir ve aralarında bir farklılaştırma yapılmamaktadır. Tablo 1'de Ortuzar ve Simonetti (2008) tarafından zaman serileri kullanılarak yapılan, ayrışık talep modelleri hariç literatürde havacılık alanında yapılan çalışmaları özetlemektedir.

Tablo 1. Havayolu ve Turizm Alanında Zaman Serileri Çalışmaları

Çalışmayı Yapan	Ülke veya Şehir	Açıklayıcı Faktörler	Veri Tipi	Fonksiyonel Biçim	Gözlem Sayısı	Tahmin Modeli
Havayolu						
Wadud (2011)	Khulna, Bangladesh	GDP per capita, ratio of air to road travel time population	Cities, panel	Log-Log	2 cities x 365 years	Fixed effect panel with AR errors
DfT (2009)	UK	GDP of UK and abroad, consumer expenditure in the UK, fares in UK and abroad, imports, exports, exchange rates	Markets, panel	Log-log	21 markets x various lengths, 18 years maximum	ECM for each market
Dargay and Hanly (2002)	UK	Fare, per capita income, exchange rate, relative prices, per capita tarde	Countries, panel	Log-log	20 countries x 11 years	Dynamic for each country
Profillidis (2000)	Rhodes, Greece	Exchange rates	Country, time series	Quadratic	22 years	OLS, fuzzy regression
BTCE (1995)	Australia international	GDP, income, airfare, exchange rate	Cities, panel	Log-log	2 markets x 24 cities x 32 quarters	Dynamic, for each market and city
BaFail (2004)	Saudi Arabia	GDP, CPI per capita, income, exchange rate, etc.	Cities, panel	Linear	5 cities x 18 years	ANN for each city
Alam and Karim (1998)	Bangladesh	GDP and population of cacthman, ratio of road to air travel time, dummy	Cities, panel	Log-log	6 cities x 5 years	Pooled OLS
Abed vd., (2001)	Saudi Arabia International	Non-oil GDP, CPI, imports, population	Country time series	Linear	22 years	OLS
Abbas (2004)	Cairo Egypt	Population, foreign tourist	Cities, time series	Linear	11 years	OLS
Alexseev and Seixa (2009)	Brazil	GDP, fare per km, dummy	Country, time series	Log-log	20 years	OLS, ANN
Tsekeris (2009)	Greece Islands	GDP, population, tourism, relative frequency, time and capacity relative to ferries	Islands, panel	Log-log	7 cities x 21 years	Dynamic panel-GMM
Cheze vd., (2010)	World	GDP, jet fuel price, shock dummies,	Regional panel	Log-log	8 regions x 28 years	Dynamic panel - GMM
Andreoni and Postorino (2006)	Reggio-Calabria Italy	Univariate, Multivariate: income per capita, aircraft movements	City, time series	Log-log	16 years	ARIMA, ARIMAX
Fernandes and Pacheo (2007)	Brazil	Univariate	Country, time series	Log	Not specified	Exponential Smoothing
Turizm						
Kullendran and King (1997)	Australia-inbound	Univariate; Multivariate: GDP/GNP, airfare	Countries, panel	Log-log	4 countries x 64 quarters	ARIMA, ECM for each country
Lim and McAleer (2002)	Australia-inbound	Univariate	Countries, panel	Log	3 countries 60 quarters	ARIMA for each country
Lim vd., (2008)	Japan-Outbound	Income	Countries, panel	Log-log	2 countries x 100 quarters	ARIMAX for each country

Tablo 1 incelendiğinde pek çok sayıda açıklayıcı değişkenin araştırmacılar tarafından havayolu yolcu talebinin belirlenmesinde kullanıldığı görülmektedir. Bunlar GYSH, gelir, bilet ücreti, döviz kuru, seyahat süresi, nüfus, ithalat, ihracat ve uçuş sıklığı sayılabilir. GYSH, gelir ilgili ülkede yaşanan ekonomik faaliyetleri temsil etmektedir. Gelişmekte olan ülkelerde GYSH aynı zamanda seyahat edebilme kabiliyetini göstermektedir. Nüfus ayrıca önemli bir değişkendir çünkü havayoluyla seyahat edeceklerin potansiyel kümesini açıklamaktadır. Nüfus verileri hazır bir şekilde elde edilebilmesine karşın çoğu araştırmada açıklayıcı faktörler listesinden çıkartılmıştır. Zira nüfus değerleri konjoktürel ve GYSH, kişi başına gelir gibi diğer değişkenlerle yüksek derecede korelasyonlu çıkmaktadır. Uçak ücreti, kilometre başına maliyet veya jet yakıt fiyatı, talep tahmini modellemesine dahil edildiğinde, uçmayı alıkoyan negatif etkiye sahip olan parametrelerdir. Bunun yanı sıra Dargay ve Hanly (2002) döviz kurlarının ve göreceli tüketici fiyatlarının ülkeler ve şehirler arası seyahat talebinin etkisinde önemli etkisi olduğunu belirlemişlerdir. Profodilis ise boş zamanlara yönelik seyahat talebinin tahmininde döviz kurlarını kullanmıştır çünkü bu tür destinasyon yerlerinin talebinde ucuz ve pahalılık belirleyici faktör olmaktadır. Tablo 1’de görüldüğü üzere; Andreoni ve Postorino (2006), Fernandes ve Pacheco (2023), Kulendran and King (1997), Lim ve McAleer (2002), Lim vd.,(2008) çalışmalarında tek değişkenli zaman serileri (ARIMA/ARIMAX) modelleri kullanmışlardır.

Dünya havacılık sektöründe gelişmekte olan ülkelerdeki yolcu artış eğilimlerini belirlemek için çeşitli öngörü senaryoları mevcuttur. Bu gelişim öngörülerini uçak üreticileri, IATA, ICAO gibi uluslararası havacılık otoriteleri tarafından düzenli olarak hazırlanmakta ve güncellenmektedir. IATA’nın 2023 yılı persepektifinde yolcu taşımacılığının 522 milyar dolar gelir elde etmesi beklendiği, yolcu sayısının 2019’dan bu yana ilk kez dört milyarı aşması ve 4,2 milyar yolcunun uçuşması, bununla birlikte, yolcu talebinin yolcu kapasitesinden (+%18,0) daha hızlı artmasına (+%21,1) rağmen, bir miktar daha düşük enerji maliyetleri tüketiciye yansıtıldığı için yolcu verimlerinin azalması (%-1,7) öngörülmektedir IATA (2022).

2.2. Literatür Taraması

Andreoni ve Postorino (2006), hava taşımacılığı talebini tahmin etmek için çok değişkenli ARIMA modelini kullanmıştır. Bu çalışmada İtalya’da Reggio Calabria bölgesel havaalanındaki talep seviyeleri, hem tek değişkenli hem de çok değişkenli zaman serisi modelleri ile tahmin edilmiştir. Singapur’daki turizm talebini tahmin etmek için Chu (2008) tarafından otoregresif kesirli entegre hareketli ortalama (ARFIMA) yaklaşımı kullanılmıştır. Bu modelde ekonomik ve siyasi şok değişikliklerin etkisi de modelde analiz edilmiştir. İlaveten Chu (2009) turizm talebini tahmin etmek için ARMA tabanlı yöntemleri kullanılmıştır. Çalışmasında, Kore, Hong Kong, Japonya, Tayland, Tayvan, Singapur, Filipinler, Yeni Zelanda ve Avustralya’ya gelen uluslararası ziyaretçi sayısını gösteren turizm talebini tahmin etmek için üç tek değişkenli ARMA tabanlı model uygulamıştır. Krasic ve Gatti (2009) Hırvatistan’daki Porec bölgesinin deniz turizmi talebi, gelen turist hacmini bulmak için ARIMA’yı uygulamışlardır. Dünya’da Hassan ve Quadi (2018) Sudi Arabistan havayolları yolcu sayısının belirlenmesinde ARIMA modeli kullanmış ve en uygun modelin ARIMA (1,1,3) (1,0,3) olduğunu belirlemiş, Chudy-Laskowska ve Pisula (2017), Polonya’da bir havalimanı için mevsimsel yolcu tahminlemesi için mevsimsellikten arındırılmış ARIMA modelini kullanmışlardır. Gong (2010) yolcu taşımacılığı talebini tahmin etmek için genel regresyon ve sinir ağı modeli ARIMA modeli ile kullanarak birleştirdi. Pekin-Şangay hattı uçuş talebine yönelik tarihsel veriler önerilen modelin talebin hem doğrusal hem de doğrusal olmayan yönlerini yakalayabildiğini göstermektedir. Box-Jenkins SARIMA modeli, Loganathan ve Ibrahim (2010) tarafından Malezya’ya gelen uluslararası turist sayısını tahmin etmek için kullanılmıştır. Güneydoğu Asya Ülkeleri Birliği (ASEAN) ülkelerinden Malezya’ya yönelik turizm talebini tahmin etmek için Nanthakumar vd., (2012) SARIMA yaklaşımını kullanmıştır. Box-Jenkins metodolojisi, Karadağ turizm talebini tahmin etmek için Bigovic (2012) tarafından SARIMA modellerinde de kullanılmıştır. Karadağ’a turist gelişlerinin ve gecelik konaklamalarının kısa vadeli akışları tahmin edilmiş ve önerilen modelin etkinliği Modifiye Box-Pierce ve Jarque-Bera test istatistikleri ile gösterilmiştir. ARIMA modeli ayrıca demiryolu yolcu talebini tahmin etmek için Milenkovic vd., (2013) tarafından uygulanmış, yazarlar, SARIMA (0,1,1) (0,1,1)_{x12} modelinin, klasik ARIMA modelleriyle karşılaştırıldığında yolcu akışlarının aylık yinelenen modeli daha iyi açıkladığını göstermiştir. Daha yakın tarihli bir çalışmada Türkiye’de İstanbul metropol alanı için yolcu talebini tahmin etmek amacıyla Anvari vd., (2016) tarafından Box-Jenkins ARIMA modeli geliştirilmiştir (2016).

Havacılık sektörü alanında ülkemizdeki uygulamalara bakıldığında Balık (2015:115) yaptığı çalışmada Türkiye’nin uçak sayısı ile hava kargo ile taşınan yükü arasında dış ticaret hacmi arasında ihracatı, ithalatı, gayri safi milli hasılası, istihdamı ve e-ticaret arasında pozitif ve anlamlı ilişkiler tespit etmiştir. Yurtiçi hava taşımacılığı talebinin modellenmesi ve senaryolar değerlendirilmesi çalışmasında Ozan, Başkan, Haldenbilen ve Ceylan (2014: 322) havayolu yolcu talebi çok değişkenli regresyon yöntemi ile gelir ve jet yakıtı fiyatlarına bağlı olarak modellemeye çalışmışlardır. Çalışmada indeksleme yöntemi ile talebin aylık değişimleri başarı ile modellenmiş ve tahminler yapılarak çalışmanın sonucunda gelir değişkeninin talebi pozitif etkilediği görülürken jet yakıt fiyatları ile talep arasında ters orantılı ilişki tespit edilmiştir. Ülkemizde havayolu yolcu ulaşım talebinin belirlenmesine yönelik ARIMA modeli kullanılmış olup yapılan çalışma sonucunda (Tortum, Gözcü ve Codur, 2014b: 53) aylık yolcu serisini en iyi açıklayan modelin SARIMA (6,1,1) (12,0,12) olarak tespit edilmiştir.

3. Tasarım ve Yöntem

3.1. Veri Seti

Havayolu ile 2020-2022 yılı sonu üçer aylık toplam yurt içi ve yurt dışı taşınan yolcu sayıları ve yurt içi yurt dışı gelen giden uçak sayıları Devlet Hava Meydanları İşletmesinden (DHMI) (www.dhmi.gov.tr, 2022) sağlanmıştır. Araştırma modelinde yer alan dışsal değişkenlerden Gayri Safi Milli Hasıla (GSYH), TUIK'ten (www.tuik.com.tr, 2023) ve “dolar” cinsinden ham petrol birim alış fiyatını içeren 52 çeyrek dönem zaman serisi Birleşik Devletler Enerji Bilgi İşletmesinden (www.eia.gov/outlooks/steo/realprices, 2023) alınarak gerçekleştirilmiştir. Tahmin modeli üçer aylık dönem bazındada gerçekleştirildiğinden 30'un üzerinde zaman serisi veri seti yeterlidir Gujarati (2014).

3.2. Araştırma Yöntemi

Yıllık çeyrek periyotlarla havayolu ile taşınan iç hat ve dış toplam yolcu sayısı tahminlenmesine yönelik zaman serisi Box-Jenkins yönteminden faydalanılarak ARIMA ve ARIMAX modelleri kullanılmıştır. Modellerin belirlenmesi ve tahmin yapılmasına yönelik olarak Eviews paket programından faydalanılmıştır.

3.2.1 Arıma

Zaman serileri analizinde en tanınmış yöntem Box-Jenkins (1976) yöntemidir. ARMA modellerinin kolayca analiz edilmesinde bu yöntemin büyük katkısı olduğundan bazen ARMA modellerine Box-Jenkins modelleri denilmektedir. Bu yapıda otoregresif AR(p) hareketli ortalama MA(q), otoregresif hareketli ortalama ARMA(p,q) ve ARIMA(p,d,q) modelleri bulunmaktadır (Kutlar, 2017: 22). Otoregresif modellerde (AR) p'inci mertebede otoregresif sürece sahip gözlenen yt serisi yt değerlerinin p dönem geriye doğru giden ağırlıklı ortalaması ile bozucu terimin toplam değerine eşittir. Bir otoregresif sürece sahip denklem aşağıdaki gibi yazılır:

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

Hareketli ortalama modellerde (MA) q mertebesindeki bir hareketli ortalama sürecinde her gözlenen yt , q değerine kadar gecikmesi uzanan bozucu terimlerin ağırlıklı ortalamasından ibarettir.

$$y_t = \mu + u_t - \theta_1 u_{t-1} - \theta_2 u_{t-2} \dots - \theta_q u_{t-q} \quad (2)$$

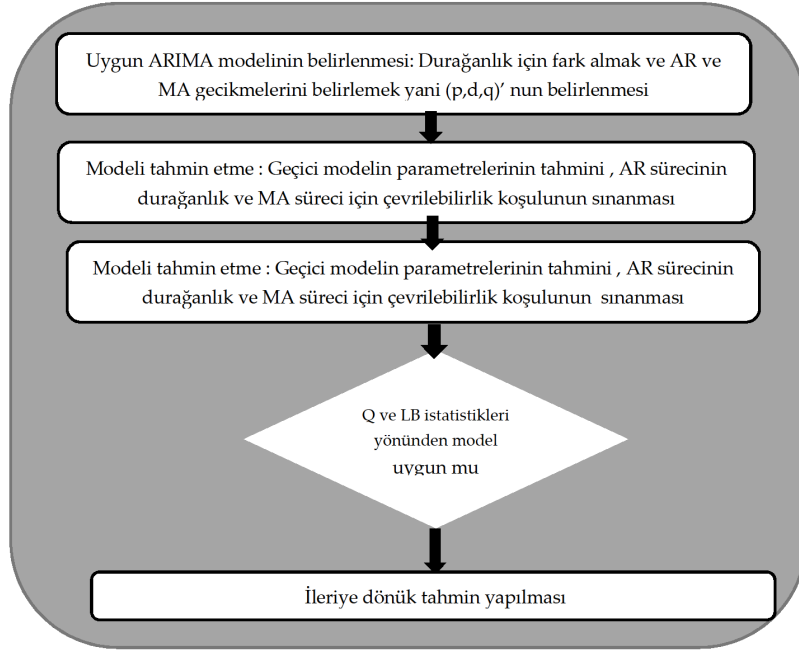
Denklemden zaman boyunca bozucu terimler bağımsız beyaz gürültü sürecini oluşturur. Otoregresif ve hareketli ortalama modeli (ARMA) çoğu durumda seriler tek başına AR(p) veya MA(p) süreçleri tarafından ifade edilemezler. Bu seriler otoregresif ve hareketli ortalama modellerinin birleşimi şeklinde ifade edilir. Bir ARMA (p, q) modeli,

$$y_t = m + \alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p} + u_t - \theta_1 u_{t-1} - \dots - \theta_q u_{t-q} \quad (3)$$

şeklinde gösterilebilir. Ardışık bağlanım ve bütünselleşmiş hareketli ortalama modelleri ARMA(p,q) modellerinin bir derece farklı türüdür ve sıkça kullanılmaktadır (Kutlar, 2017: 23). Bu modellerin ARMA modellerinden farkı, durağan olmayan serinin d'inci mertebede farkı alınarak durağan hale getirilmesidir. Özellikle bazı makro değişkenler doğası gereği durağan olmadıkları için, farklarının alınması gerekir ve bu tür serilerin türevinin alınması zorunludur. Bunun için bu modellerde esas seri yerine birinci veya d'inci mertebede farkı alınan seri için, yapılan ARMA tahmini, aslında ARIMA tahminidir.

3.2.1.1 Box Jenkins Yönteminin Temel Adımları

ARIMA modelinin geçerliliğini sınamak için, gerek Q gerekse LB istatistikleri ile seride, otokorelasyonun varlığı test edilir. Zaman serisi alanında yaygınlıkla kullanılan ve mümkün olduğunca az parametre içermeyi öngören Box-Jenkins yönteminin temel adımları aşağıdaki Şekil 1'deki gibi gösterilebilir (Bozkurt, 20113:58).



Şekil 2. Box-Jenkins İşlem Adımları

3.2.2 SARIMA

Zaman serilerinde gözlenen sorunlardan biri de mevsimseliktir. Mevsimlik değişimler eşit zaman aralıkları ile tekrarlanan düzenli değişimlerdir. Mevsimsel modellerde birbirini izleyen gözlem değerleri ve birbirini izleyen yılların aynı aylarına ait gözlem değerleri arasında ilişki bulunmaktadır. Zaman serilerinin mevsimsel etkilerden arındırılmasına yönelik farklı yöntemler geliştirilmiştir. Bunlardan bazıları, Census X-11, Census X-12, Tramo/Seats ve hareketli ortalama prosedürleridir (Subaşı, 2005).

Box-Jenkins ARIMA yöntemi mevsimsel etkiyi gözetmeyen (p,q,d) ARIMA yöntemi olarak düşünülmüştür. Halbuki, mevsimsellik havayolu yolcu tahminlemede veya turistlerin geliş sayılarının belirlenmesinde zaman serilerinde kullanılan oldukça yaygın bir unsurdur. Bu nedenle zaman serilerinde aylık, çeyrek periyot, altı aylık ve yıllık mevsimsel kalıpları dikkate alan ARIMA (P,D,Q)_s modeli geliştirilmiştir. Mevsimsel olmayan ARIMA (p,d,q) yönetimiyle mevsimsel ARIMA (P,D,Q)_s yönteminin birleştirilmesi yoluyla mevsimsel ARIMA şu şekilde ifade edilir: SARIMA (p,d,q)x(P,D,Q)_s Tsui, Balı ve Gow (2011).

3.2.3 ARIMAX

ARIMA metodu kolayca yapılabilmesi ve tatminkâr sonuçlar üretmesi nedeniyle geniş çevrelerce kullanılan yaygın bir uygulama haline gelmiştir Yücesan (2018). Ancak bu yönteminde bazı eksiklikleri bulunmaktadır. Temel sorunları açıklama eksiliği bunlardan bir tanesidir. Zira yöntemde sadece tek bir değişken yer almaktadır. ARIMAX metodunda ise birden çok bağımsız değişkenin yer alması olasıdır (Fan vd., 2009; Jalalkamali vd., 2015). ARIMAX metodunun inşasında ilk adım dışsal değişkenin yer alacağı uygun ARIMA modelinin belirlenmesidir. ARIMAX modeli dışsal değişkenin modele eklenmeden önce serinin durağan hale getirilmesini gerektirir. İkinci adımda dönüştürülmüş değişken ARIMA modeline dahil edilir ki burada gecikme uzunluğu ayrıca tahminlenir. ARIMAX modelinin parametrelerinin tahmini için lineer olmayan en küçük kareler yöntemi kullanılır (Bierens, 1987). Nihayetinde ARIMA modeli bir yazılım vasıtasıyla verilere uyumlu hale getirilebilir. ARIMAX yönteminde Bağımlı değişken olan Y_t' yi sadece geçmiş verileriyle birlikte tahmin etmek yerine, Y_t'yi hem geçmiş değerleriyle hem de açıklayıcı değişkenler olan X_t değişkenleri ile tahmin edilmesi amaçlanır. Böylece ARIMA yöntemine göre daha isabetli sonuçlar elde edilir (Cool vd., 2009; Neter vd., 1996). ARIMAX yöntemi (Bierens, 1987) tarafından geliştirilmiştir. ARIMAX yöntemi eşitlik 4'de ifade edilmiştir.

$$(1 - \sum_{s=1}^p \alpha L^s) \Delta y_t = \mu + \sum_{s=1}^q \alpha \beta_s + L^s + x_t + (1 + \sum_{s=1}^r \gamma L^s) e^t \quad (4)$$

L gecikme operatörüdür.

$$\gamma_s L^s = y_{(t-s)}, \Delta y_t = y_t - y_{t-1}, \mu \in R, \alpha_s \in R, \beta_s \in R^k \text{ ve } \gamma_s \in R \quad (5)$$

bilinmeyen parametrelerdir, e^t hatayı temsil eder (Arya vd., 2015). ARIMAX modeli dört bölümden oluşur. Bu bölümler sırasıyla Auto Regressive (AR), Integrated (I), Moving Average (MA), ve Dışsal değişken (X) olarak adlandırılır (Sutthichaimethee ve Ariyasajjajorn 2017).

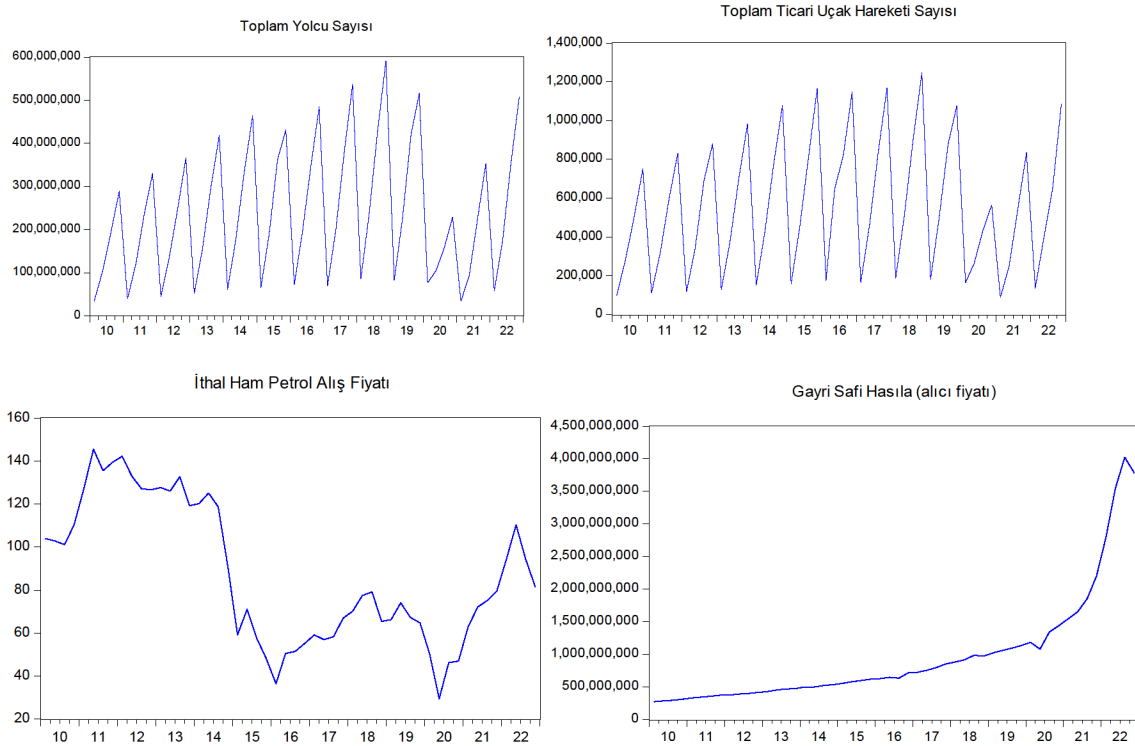
3.2.2 Modelin Öngörü Gücünün Değerlendirilmesi

Uygun olan tahmin modelini belirledikten sonra modelin, ileriye dönük öngöründe faydalanmak amacıyla öngörü testlerine ihtiyaç bulunmaktadır. Şayet belirlenen model tahmin modelinin öngörü kabiliyeti yapılan testlerde istenilen anlamlılık seviyesinde çıkmaz ise, geleceğe yönelik tahminlerde kullanılmamalıdır. Çeşitli modellerin her birine ait öngörülen ve gerçek yolcu sayılarına ait hata paylarını da içerecek gerçek ve tahmini değer çıktıkları yer almaktadır. Uç değerleri belirlemek için kalıntıların dağılım grafikleri, yanlılık(bias), kovaryans değeri kullanılmaktadır. Çalışmada tahmin doğruluklarını yapmak ve modelin gelecek tahmin gücünü belirlemek için ortalama mutlak yüzde hata (MAPE) değeri ve Theil katsayısı istatistiği kullanılmıştır. Lewis (1982) yılı çalışmasında, MAPE değeri %10'un altında olan modelleri çok iyi, %10–20 arasında olan modelleri iyi, %20-50 arasında olan modelleri kabul edilebilir ve %50'nin üzerinde olan modelleri ise yanlış ve hatalı olarak sınıflandırmıştır. Theil katsayısının sıfıra yakın olması beklenir (Vergil ve Özkan, 2007). Katsayı kendi içinde üçe ayrılmakta olup "Bias" oranı sistematik hatayı gösterir. Sıfıra ne kadar yakınsa tahmin sonuçlarına o kadar güvenilebilir. İkinci katsayı kovaryans oranı ise sistematik olmayan hatayı gösterir. Diğer katsayılara göre daha büyük elde edilirse, gerçekleşen hatanın sistematik olmadığına işaret etmiş olacaktır (Bozkurt 2013:186). Kovaryans oranı değeri kendi kontrolümüz dışında modelde meydana gelen değişkenliğin açıklamasını göstermektedir.

4. Bulgular

4.1. Tanımsal İstatistikler

İlgili serilere ait verilerin grafiksel gösterimi Şekil 3'te yer almaktadır. Şekil 3'de görüldüğü üzere 2010 yılı itibarıyla yolcu talebinin 2020 yılına kadar arttığı, 2020 ve 2021 yılında pandemi nedeniyle azalmaya gittiği ve 2022 yılı itibarıyla tekrar yükselişe geçtiği görülmektedir. Ayrıca talebin mevsimsel özellik göstererek dalgalandığı görülmektedir. Benzer seyrin uçak hareket sayısı grafiğinde de yer almaktadır. Ham Petrol alış fiyatının ise dalgalı seyir izlediği, GYSH'ın ise 2010 itibarıyla yavaş yavaş yükselerek arttığı 2018 itibarıyla ise bu ivmenin daha da yükseldiği görülmektedir. Serilere yönelik tanımsal istatistikler ise aşağıda Tablo 2'de yer almaktadır.



Şekil 3. Serilerin Grafiksel Gösterimi (2010-2022 Dönemi 3 Aylık Dönemler İtibarıyla)

Tablo 2. Tanımsal İstatistikler


İstatistikler	ACN	AIOP	GDP	PAS
Ortalama	559022.7	87.14648	9.74E+08	2.38E+08
Medyan	507786.5	78.25000	6.41E+08	2.12E+08
En yüksek	1246812.	145.5100	4.02E+09	5.90E+08
En düşük	89278.00	29.43000	2.74E+08	33480595
Standart Sapma	345957.5	32.58307	8.69E+08	1.57E+08
Çarpıklık	0.307091	0.241411	2.185983	0.453727
Basıklık	1.900202	1.737934	7.345347	2.069518
Jarque-Bera	3.438016	3.956180	82.32496	3.660088
Olasılık	0.179244	0.138333	0.000000	0.160407
Toplam	29069179	4531.617	5.07E+10	1.24E+10
Hata Karelerin Toplamı	6.10E+12	54144.46	3.85E+19	1.25E+18
Gözlem sayısı	52	52	52	52

4.2. Normallik Testleri

Tablo 2’de tanımsal istatistikleri gösterilen her bir serinin, yapılan Jarque-Bera test sonucuna göre %95 anlamlılık seviyesinde bakıldığında ACN, AIOP, PAS olasılıklık değerleri sırasıyla (0.17; 0.13; 0.16) olup %95 anlamlılık seviyesinde (p değerleri > 0.05) oldukları için bu serilerin normal dağıldıkları söylenebilir. Gayri Safi Milli Hasıla olasılık değeri (0.00) olup %95 anlamlılık seviyesinde ($p < 0.5$) olduğu için H_0 hipotezi red edilerek bu serinin normal dağılmadığı belirlenmiştir. GDP serisini normal dağılıma çevirmek için serinin logaritması alınmış ve ilgili sonuçları Tablo 3 ve Şekil 4’te yer almaktadır.


Tablo 3. Log (Gayri Safi Milli Hasıla)

İstatistikler	GDP
Ortalama	20.43222
Medyan	20.27881
En yüksek	22.11534
En düşük	19.42862
Standart Sapma	0.686352
Çarpıklık	0.731240
Basıklık	2.933793
Jarque-Bera Testi	4.643662
Olasılık	0.098094
Toplam	1062.475
Hata Karelerin Toplamı	24.02501
Gözlem sayısı	52

**Şekil 4.** LDGP Histogram ve Tanımsal İstatistikleri

Serinin logaritmik dönüşümü sonucunda yapılan Jarque-Bera testi sonucuna göre LGDP serisinin olasılık değeri (0.09) olup ($p > 0.05$) olduğundan bu seri de normal dağılıma uygun hale getirilmiştir. ARIMA yöntemiyle tek değişkenli yöntemle yolcu sayısının tahminini için serinin öncelikle durağan olup olmadığına bakılması gerekmektedir. Bununla ilgili serinin otekorelasyonlu olup olmadığına bakılması gerekir. Otekorelasyonu görebilmek için serinin Korelogram’ı Şekil 5’de yer almaktadır.

Date: 01/29/23 Time: 14:41
 Sample: 2010Q1 2022Q4
 Included observations: 51



Şekil 5. Yolcu Talebi Korelogramı

Şekil 6'de görüldüğü üzere %95 anlamlılık seviyesinde H_0 hipotezi red edilerek seride otokorelasyon olduğu tespit edilmektedir. Buna göre serinin ilk önce bağımlı değişkenin 1 gecikmeli halinin regresyon sonuçları Tablo 4'de yer almaktadır.

Tablo 4. DPAS Durağanlık Analizi

Dependent Variable: DPAS				
Method: Least Squares				
Date: 02/12/23 Time: 21:24				
Sample (adjusted): 2010Q2 2022Q4				
Included observations: 51 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.93E+08	53103562	3.638520	0.0007
@TREND	1459629.	1507782.	0.968064	0.3379
PAS(-1)	-0.953523	0.145821	-6.539017	0.0000
R-squared	0.471187	Mean dependent var		9252519.
Adjusted R-squared	0.449153	S.D. dependent var		2.12E+08
S.E. of regression	1.57E+08	Akaike info criterion		40.63968
Sum squared resid	1.18E+18	Schwarz criterion		40.75332
Log likelihood	-1033.312	Hannan-Quinn criter.		40.68310
F-statistic	21.38464	Durbin-Watson stat		1.936691
Prob(F-statistic)	0.000000			

Elde edilen regresyon sonuçlarına göre serinin durağan olmadığına karar verilerek otokorelasyonu kaldırmak için birim kök testleri uygulanır. Bu durumda seride bağımlı değişkenin gecikmeli durumlarını eklemek gerekiyor. Yapılan denemelerde serinin 4. gecikmedeki farkında serinin durağan hale geldiği, ve olasılık değerlerinin $p > 0.05$) olduğu tespit edilmiştir. İlgili regresyon denklemi tahmin sonuçları Tablo 5 de ve Korolegram diyagramı Şekil 6'da yer almaktadır.

Tablo 5. DPAS Serisi 4 Gecikmeli Durağanlık Analizi

Dependent Variable: DPAS				
Method: Least Squares				
Date: 02/12/23 Time: 21:33				
Sample (adjusted): 2011Q2 2022Q4				
Included observations: 47 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	82112233	34410384	2.386263	0.0218
@TREND	466811.3	601675.5	0.775852	0.4424
PAS(-1)	-0.378467	0.136872	-2.765111	0.0086
DPAS(-1)	0.055709	0.161393	0.345176	0.7318
DPAS(-2)	-0.047752	0.140272	-0.340424	0.7353
DPAS(-3)	-0.137786	0.124801	-1.104052	0.2762
DPAS(-4)	0.755847	0.114662	6.591945	0.0000
R-squared	0.946354	Mean dependent var	9940504.	
Adjusted R-squared	0.938307	S.D. dependent var	2.16E+08	
S.E. of regression	53771194	Akaike info criterion	38.57498	
Sum squared resid	1.16E+17	Schwarz criterion	38.85053	
Log likelihood	-899.5120	Hannan-Quinn criter.	38.67867	
F-statistic	117.6041	Durbin-Watson stat	1.987319	
Prob(F-statistic)	0.000000			

Date: 02/12/23 Time: 21:35
 Sample: 2010Q1 2025Q4
 Included observations: 47
 Q-statistic probabilities adjusted for 4 dynamic regressors

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob*
		1 -0.001 -0.001	1.E-05	0.997	
		2 -0.118 -0.118	0.7145	0.700	
		3 0.026 0.026	0.7503	0.861	
		4 -0.044 -0.059	0.8545	0.931	
		5 0.007 0.014	0.8575	0.973	
		6 0.180 0.170	2.6872	0.847	
		7 0.052 0.059	2.8426	0.899	
		8 -0.289 -0.264	7.7902	0.454	
		9 -0.069 -0.073	8.0792	0.526	
		10 -0.046 -0.098	8.2127	0.608	
		11 -0.027 -0.027	8.2578	0.690	
		12 -0.121 -0.208	9.2180	0.684	
		13 0.085 0.077	9.7019	0.718	
		14 -0.050 0.005	9.8780	0.771	
		15 -0.091 -0.015	10.475	0.789	
		16 0.059 -0.017	10.735	0.826	
		17 -0.012 -0.028	10.747	0.869	
		18 -0.069 -0.076	11.123	0.889	
		19 0.013 -0.043	11.137	0.919	
		20 0.114 0.009	12.245	0.907	
		21 -0.157 -0.147	14.437	0.850	
		22 0.038 0.014	14.573	0.880	
		23 -0.013 -0.082	14.589	0.909	
		24 -0.121 -0.122	16.065	0.886	
		25 0.043 0.014	16.262	0.907	
		26 0.002 -0.100	16.262	0.930	
		27 -0.003 -0.003	16.264	0.948	
		28 -0.080 -0.093	17.046	0.948	
		29 0.017 -0.066	17.083	0.961	
		30 0.018 0.005	17.126	0.971	
		31 0.023 -0.037	17.204	0.978	
		32 0.010 -0.063	17.220	0.985	
		33 0.075 0.001	18.150	0.983	
		34 0.036 0.040	18.378	0.987	
		35 0.032 0.021	18.577	0.990	
		36 0.010 -0.117	18.599	0.993	

*Probabilities may not be valid for this equation specification.

Şekil 6. DPAS 4 Gecikmeli Serinin Korelgramı

Otokolerasyonun kalkmasından ve serinin durağan hale getirilmesinden sonra, seride sabit, trend veya her ikisinin olup olmayacağına yönelik yapılan wald testi sonuçları Tablo 6,7,8, ve 9'da yer almaktadır.

Tablo 6. Wald 1. Testi

Wald Test: Equation: Untitled			
Test Statistic	Value	df	Probability
F-statistic	2.702010	(3, 40)	0.0583
Chi-square	8.106031	3	0.0439
Null Hypothesis: C(1)=C(2)=C(3)=0 Null Hypothesis Summary:			
Normalized Restriction (= 0)	Value	Std. Err.	
C(1)	82112233	34410384	
C(2)	466811.3	601675.5	
C(3)	-0.378467	0.136872	
Restrictions are linear in coefficients.			

F testi ve ki kare testi sonuçlarına göre H_0 red edilerek sabit, trend olabilir, stokastik trend olmayabilir. Sabitin varlığı altında deterministik trendin varlığı sınarak $C(1)=0$ kısıtı kaldırılır.

Tablo 7. Wald 2. Testi

Wald Test: Equation: Untitled			
Test Statistic	Value	df	Probability
F-statistic	3.844031	(2, 40)	0.0297
Chi-square	7.688063	2	0.0214
Null Hypothesis: C(2)=C(3)=0 Null Hypothesis Summary:			
Normalized Restriction (= 0)	Value	Std. Err.	
C(2)	466811.3	601675.5	
C(3)	-0.378467	0.136872	
Restrictions are linear in coefficients.			

F testi ve kıkare testi sonuçlarına göre trend H_0 tekrardan red edilerek hem sabit hem de trend olabilir. Bunun için de trend kaldırılarak sabit ve stokastik trend araştırılır.

Tablo 8. Wald 3. Testi

Dependent Variable: DPAS Method: Least Squares Date: 02/16/23 Time: 22:15 Sample (adjusted): 2011Q2 2022Q4 Included observations: 47 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	90025610	32704083	2.752733	0.0088
PAS(-1)	-0.356390	0.133230	-2.674993	0.0107
DPAS(-1)	0.022952	0.155014	0.148063	0.8830
DPAS(-2)	-0.076172	0.134746	-0.565301	0.5749
DPAS(-3)	-0.161567	0.120389	-1.342038	0.1870
DPAS(-4)	0.738486	0.111910	6.598911	0.0000
R-squared	0.945546	Mean dependent var	9940504.	
Adjusted R-squared	0.938906	S.D. dependent var	2.16E+08	
S.E. of regression	53509535	Akaike info criterion	38.54736	
Sum squared resid	1.17E+17	Schwarz criterion	38.78355	
Log likelihood	-899.8630	Hannan-Quinn criter.	38.63624	
F-statistic	142.3869	Durbin-Watson stat	1.937791	
Prob(F-statistic)	0.000000			

Tablo 9. Wald Testi

Wald Test: Equation: Untitled			
Test Statistic	Value	df	Probability
F-statistic	3.788826	(2, 41)	0.0309
Chi-square	7.577653	2	0.0226
Null Hypothesis: C(1)=C(2)=0 Null Hypothesis Summary:			
Normalized Restriction (= 0)	Value	Std. Err.	
C(1)	90025610	32704083	
C(2)	-0.356390	0.133230	
Restrictions are linear in coefficients.			

Yapılan wald testi sonucu aşağıdaki gibi olup yapılan test sonucuna göre %95 anlamlık seviyesine göre F istatistiği ve ki kare istatistiğine göre ($p > 0.05$) olup seride hem sabitin hem de deterministik trendin olması gerektiği anlaşılmıştır.

4.3. Birim Kök Testleri

Yolcu sayısını gösteren PAS serisinin 4 gecikmeli sabit terim ve trend üzerinden yapılan ADF birim kök testi sonuçları Tablo 10’da gösterilmekte olup buna göre; %1, %5, %10 anlamlılık seviyelerinde t istatistik değeri(2.765) sırasıyla mutlak değerce (4.165), (3.508), (3.184) değerlerinden küçük olduğu için PAS serisinin I (0) olmadığı görülmüştür.

Tablo 10. ADF Birim Kök testi sabit için 1. Fark testi

Null Hypothesis: PAS has a unit root Exogenous: Constant, Linear Trend Lag Length: 4 (Automatic - based on SIC, maxlag=4)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-2.765111	0.2169
Test critical values:	1% level		-4.165756	
	5% level		-3.508508	
	10% level		-3.184230	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation Dependent Variable: D(PAS) Method: Least Squares Date: 02/13/23 Time: 21:55 Sample (adjusted): 2011Q2 2022Q4 Included observations: 47 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
PAS(-1)	-0.378467	0.136872	-2.765111	0.0086
D(PAS(-1))	0.055709	0.161393	0.345176	0.7318
D(PAS(-2))	-0.047752	0.140272	-0.340424	0.7353
D(PAS(-3))	-0.137786	0.124801	-1.104052	0.2762
D(PAS(-4))	0.755847	0.114662	6.591945	0.0000
C	82112233	34410384	2.386263	0.0218
@TREND("2010Q1")	466811.3	601675.5	0.775852	0.4424
R-squared	0.946354	Mean dependent var		9940504.
Adjusted R-squared	0.938307	S.D. dependent var		2.16E+08
S.E. of regression	53771194	Akaike info criterion		38.57498
Sum squared resid	1.16E+17	Schwarz criterion		38.85053
Log likelihood	-899.5120	Hannan-Quinn criter.		38.67867
F-statistic	117.6041	Durbin-Watson stat		1.987319
Prob(F-statistic)	0.000000			

Bu nedenle serinin farkı alınarak benzer şekilde serinin durağanlığına bakılacaktır.

Is dpas c @trend dpas(-1) regresyonu sonucunda serinin durağan olmadığı görülerek bağımlı değişkenin gecikmeli hali denkleme sokulmuş ve yapılan araştırmada bağımlı değişkenin 3. gecikmesinde yapılan regresyon tahmininde serinin durağan hale geçtiği belirlenmiştir.

Is ddpas c @trend dpas(-1) ddpas(-1) ddpas(-2) ddpas(-3)

Date: 02/16/23 Time: 22:27
Sample: 2010Q1 2022Q4
Included observations: 47
Q-statistic probabilities adjusted for 1 dynamic regressor

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob*	
		1	0.102	0.102	0.5238	0.469
		2	-0.071	-0.082	0.7818	0.676
		3	0.011	0.028	0.7884	0.852
		4	-0.057	-0.069	0.9648	0.915
		5	-0.027	-0.010	1.0038	0.962
		6	0.118	0.114	1.7829	0.939
		7	-0.014	-0.042	1.7937	0.970
		8	-0.317	-0.306	7.7179	0.461
		9	-0.111	-0.061	8.4643	0.488
		10	-0.064	-0.081	8.7207	0.559
		11	-0.035	-0.021	8.7991	0.640
		12	-0.101	-0.177	9.4652	0.663
		13	0.083	0.093	9.9354	0.699
		14	-0.027	-0.012	9.9876	0.763
		15	-0.060	-0.048	10.249	0.804
		16	0.083	-0.024	10.754	0.824
		17	0.015	-0.042	10.772	0.868
		18	-0.034	-0.061	10.865	0.900
		19	0.050	-0.005	11.071	0.921
		20	0.130	0.042	12.513	0.897

*Probabilities may not be valid for this equation specification.

Şekil 7. Korelegram

DDPAS serisinin sabit, trend ve stokastik trendin araştırılmasına yönelik yapılan wald test sonuçları sırasıyla aşağıdaki sonuçlar elde edilmiştir. DDPAS serisi sabit ve trendin olmadığı stokastik trendin varlığının test edildiğinde ilgili sonuçları Tablo 11,12 ve 13'de görülmektedir.

Tablo 11. Wald Test

Wald Test: Equation: Untitled			
Test Statistic	Value	df	Probability
F-statistic	0.142778	(3, 41)	0.9337
Chi-square	0.428335	3	0.9343
Null Hypothesis: C(1)=C(2)=C(3)=0 Null Hypothesis Summary:			
Normalized Restriction (= 0)	Value	Std. Err.	
C(1)	1681173.	19818086	
C(2)	120931.7	634437.1	
C(3)	-0.093419	0.475831	
Restrictions are linear in coefficients.			

F testi ve ki-kare test sonuçlarına göre H_0 red edilemez, yani sabit ve trend olmayabilir. Sabitin olduğu, trendin olmadığı ve stokastik trendin olduğu test sonuçları Tablo 12’de yer almaktadır.

Tablo 12. Wald Test

Wald Test: Equation: Untitled			
Test Statistic	Value	df	Probability
F-statistic	0.045664	(2, 41)	0.9554
Chi-square	0.091327	2	0.9554
Null Hypothesis: C(2)=C(3)=0 Null Hypothesis Summary:			
Normalized Restriction (= 0)	Value	Std. Err.	
C(2)	120931.7	634437.1	
C(3)	-0.093419	0.475831	
Restrictions are linear in coefficients.			

F testi ve ki-kare test sonuçlarına göre H_0 red edilemez. Sabit ve stokastik trendin olmadığı trendin olduğu test sonuçları Tablo 13’de gösterilmektedir.

Tablo 13. Wald Test

Wald Test: Equation: Untitled			
Test Statistic	Value	df	Probability
F-statistic	0.200604	(2, 42)	0.8190
Chi-square	0.401207	2	0.8182
Null Hypothesis: C(1)=C(2)=0 Null Hypothesis Summary:			
Normalized Restriction (= 0)	Value	Std. Err.	
C(1)	5094175.	8396197.	
C(2)	-0.109760	0.462644	
Restrictions are linear in coefficients.			

F testi ve ki-kare test sonuçlarına göre H_0 reddedilemez hem sabit hem trend hem de stokastik trendin olmadığını sonucuna varırız. Yukarıdaki tablo sonucuna göre DDPAS serisinin 3 gecikmeli halinde sabit ve trendsiz yapılan ADF birim kök testi sonuçları Tablo 14’de yer almaktadır.

Yolcu sayısı fark DPAS serisinin I(0) halinde sabit ve trend yok iken 3 gecikmeli ADF birim kök test sonuçlarına t istatistik mutlak değeri (2.370) %5, %10 kritik mutlak değerlerinden sırasıyla (1.947), (1.612) değerlerinden büyük ve $p < 0.05$ olduğu için H_0 hipotezi red edilerek sabit ve trendsiz de serinin birim kökü olmadığı tespit edilmiştir. DPAS serisi I(0) da birim kök yoktur veya PAS serisi I(1) halinde seri durağan hale geçmiştir. DPAS serisinin grafiği Şekil 8’de yer almaktadır.

Tablo 14. DPAS Birim Kök testi

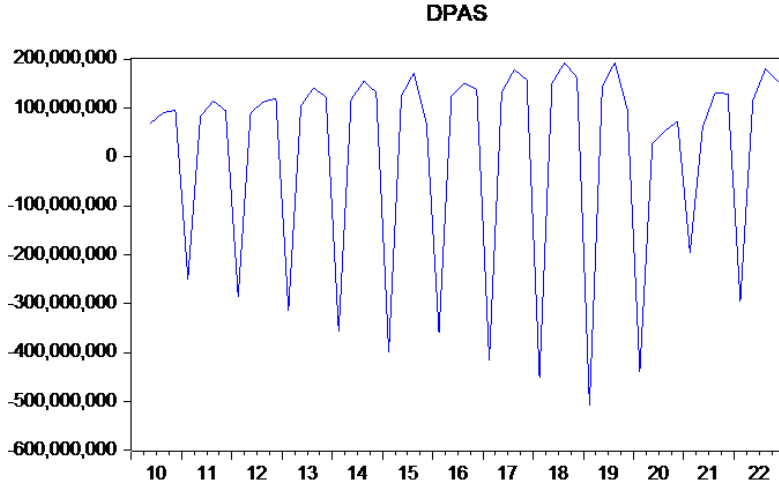
Null Hypothesis: DPAS has a unit root Exogenous: None Lag Length: 3 (Fixed)				
		t-Statistic	Prob.*	
Augmented Dickey-Fuller test statistic		-2.370186	0.0187	
Test critical values:				
	1% level	-2.615093		
	5% level	-1.947975		
	10% level	-1.612408		
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation Dependent Variable: D(DPAS) Method: Least Squares Date: 02/16/23 Time: 23:17 Sample (adjusted): 2011Q2 2022Q4 Included observations: 47 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
DPAS(-1)	-1.083801	0.457264	-2.370186	0.0223
D(DPAS(-1))	-0.177482	0.345151	-0.514215	0.6097
D(DPAS(-2))	-0.450322	0.231964	-1.941344	0.0588
D(DPAS(-3))	-0.719442	0.117957	-6.099212	0.0000
R-squared	0.974372	Mean dependent var		8582646.
Adjusted R-squared	0.972585	S.D. dependent var		3.43E+08
S.E. of regression	56874189	Akaike info criterion		38.63185
Sum squared resid	1.39E+17	Schwarz criterion		38.78931
Log-likelihood	-903.8484	Hannan-Quinn criter		38.69110
Durbin-Watson stat	1.761109			

4.3.1 Yapısal Kırılmalı Birim Kök Testi

Yolcu sayısı farkı serisinde (DPAS) yapısal kırılma var olup olmadığına yönelik yapısal kırılmalı birim kök testleri yapılmıştır. Yapılan yapısal kırılmalı ADF ve Perron birim kök testlerinde DPAS serisinin 12 ve 4 gecikmeli analizi sonucunda; sabitte, hem sabit ve trendli sonuçları Tablo 15’de sunulmakta olup buna göre serinin hem sabit hem de trendli modelinde %1, %5 ve %10 anlamlılık seviyelerinde birim kök olmadığı, 2020Q1 döneminde de yapısal kırılma olmadığı belirlenerek H_0 red edilmiştir.

Tablo 15. Yapısal Kırılma Birim Kök Testleri Tablosu

Anlamlılık Düzeyi	ADF Sabitli $t = -8.791270$, $p = 0.01$	Perron Sabitli $t = -8.847073$ Seçilen Kırılma Periyodu 2020Q1	Perron Trendli $t = -9.127680$ Seçilen Kırılma Periyodu 2020Q1	ADF Sabit ve trendli $t = -8.696333$, $p = 0.01$	Perron Sabit ve trendli $t = -8.985027$ Seçilen Kırılma Periyodu 2020Q1
%1	-4.949133	-5.92	-5.45	-5.347598	-6.32
%5	-4.443649	-5.23	-4.83	-4.859812	-5.59
%10	-4.193627	-4.92	-4.48	-4.607324	-5.29
ADF istatistiği	-8.791 > -4.949 , -4.443 , -4.193			-8.696 > -5.347 , -4.859 , -4.607	
Perron istatistiği	-8.847 > -5.92 , -5.23 , -4.92		-9.127 > -5.45 , -4.83 , -4.48		-8.985 > -6.32 , -5.59 , -5.29
ADF Karar	%1, %5 ve %10 anlamlılık seviyelerinde red edilir. H_0 red edilir		%1, %5 ve %10 anlamlılık seviyelerinde red edilir.		%1, %5 ve %10 anlamlılık seviyelerinde red edilir.
Perron Karar	2020Q1 döneminde yapısal kırılma yoktur.		2020Q1 döneminde yapısal kırılma yoktur.		2020Q1 döneminde yapısal kırılma yoktur.



Şekil 8. DPAS Grafiği

4.4. ARIMA Model Tahmini

Yolcu talebi serisinin farkının DPAS korelogramı ise Şekil 9’da görülmektedir .

Date: 02/17/23 Time: 22:03
Sample: 2010Q1 2022Q4
Included observations: 51

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.244	-0.244	3.2267	0.072
		2 -0.429	-0.519	13.363	0.001
		3 -0.259	-0.794	17.147	0.001
		4 0.912	0.652	64.937	0.000
		5 -0.230	-0.159	68.048	0.000
		6 -0.396	0.021	77.489	0.000
		7 -0.251	-0.007	81.349	0.000
		8 0.847	0.031	126.45	0.000
		9 -0.217	-0.041	129.49	0.000
		10 -0.387	-0.165	139.37	0.000
		11 -0.244	-0.102	143.41	0.000
		12 0.774	-0.252	184.94	0.000
		13 -0.179	-0.034	187.21	0.000
		14 -0.335	0.090	195.41	0.000
		15 -0.215	0.137	198.87	0.000
		16 0.674	-0.130	233.97	0.000
		17 -0.152	0.035	235.81	0.000
		18 -0.284	0.058	242.41	0.000
		19 -0.178	0.057	245.09	0.000
		20 0.567	-0.162	273.11	0.000
		21 -0.128	-0.062	274.59	0.000
		22 -0.233	-0.003	279.64	0.000
		23 -0.158	-0.106	282.03	0.000
		24 0.464	-0.003	303.55	0.000

Şekil 9. Yolcu Talebinin Fark Korelogramı

DPAS serisi korelogram yapısına bakıldığında gerek otokorelasyon ve kısmi otokorelasyon bir çok değerlerinin ($p < 0.05$) olduğu için seride otokorelasyon olduğu belirlenmiştir. Ayrıca yolcu sayısı grafiğine bakıldığında kış aylarında yolcu sayılarının daha düşük olduğu yaz döneminde ise daha fazla olduğu grafiklerden görüldüğü için seride mevsimsellik etkisinin de görüldüğünü grafiklerden söylenebilir. Bu nedenle en uygun model seçimi için bir çok denemelerinin yapılması gerekecektir. Tabii burada ihtiyaca cevap veren en küçük katsayılı AR, MA, SAR, SMA katsayıları seçilecektir. Sonuçta kıyaslama açısından şu kriterlere bakılarak en uygun olan model seçilir (Asteriou ve Hall, 2011:278).

1. İstatiksel olarak anlamlı katsayılar,
2. En küçük Sigma² (volatility),
3. En yüksek düzeltilmiş R²,

4. En Küçük AIC ve,
5. En Küçük SBIC


Eviews Auto ARMA seçeneği kullanılarak 1521 model denemesi yapıldığı ve yapılan denemeler sonucunda en uygun Tablo 16'da görüldüğü üzere ARMA modeli (1,1) (1,2) ya da ARIMA (p,d,q) SARIMA (P,D,Q) olarak SARIMA (1,1,1) (1,1,2) olarak belirlenmiş ilgili en küçük AIC değeri 38.61861 olarak tespit edilmiştir.

Tablo 16. Modelin Çıktısı

Dependent Variable: DPAS				
Method: ARMA Maximum Likelihood (BFGS)				
Date: 02/18/23 Time: 21:55				
Sample: 2010Q2 2022Q4				
Included observations: 51				
Convergence achieved after 98 iterations				
Coefficient covariance computed using outer product of gradients				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.688559	0.066251	10.39323	0.0000
SAR(4)	1.000000	1.03E-05	97509.17	0.0000
MA(1)	-1.000000	5.740212	-0.174210	0.8625
SMA(4)	-0.390820	0.134786	-2.899566	0.0058
SMA(8)	-0.604698	0.134612	-4.492169	0.0000
SIGMASQ	1.94E+15	3.61E+14	5.366199	0.0000
R-squared	0.955875	Mean dependent var	9252519.	
Adjusted R-squared	0.950972	S.D. dependent var	2.12E+08	
S.E. of regression	46868583	Akaike info criterion	38.61861	
Sum squared resid	9.88E+16	Schwarz criterion	38.84588	
Log likelihood	-978.7745	Hannan-Quinn criter.	38.70546	
Durbin-Watson stat	1.805196			
Inverted AR Roots	1.00	.69	-.00+1.00i	-.00-1.00i
	-1.00			
Inverted MA Roots	1.00	1.00	.62+.62i	.62+.62i
	.00-1.00i	-.00+1.00i	-.62-.62i	-.62-.62i
	-1.00			

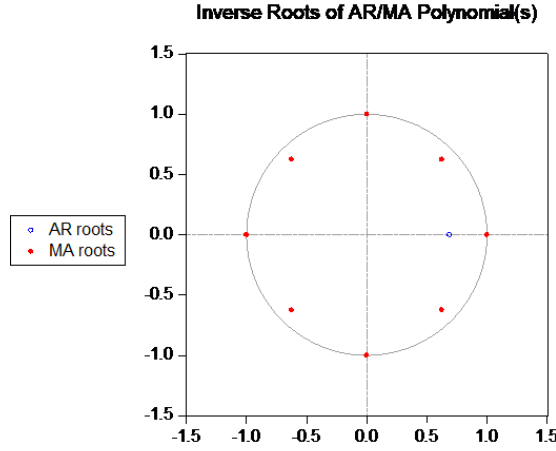
Modelin çıktısından görüleceği üzere SIGMASQ değeri pozitif çıkmış olup F istatistiği değerine baktığımızda bu değer $0,001 < 0,05$ olup modelin anlamlı olduğunu söylenebilir. Konuyla ilgili model seçim kriterlerini gösteren sonuçlar Ek-1 'de yer almaktadır. En düşük Akaike değerlerini içeren en iyi 20 modele ait sonuçlar Şekil 10'daki grafikte gösterilmektedir

Akaike Information Criteria (top 20 models)



Şekil 10. Akaike Kriterine Göre En İyi 20 Modelin Grafiği

Model AR/MA (1,1)(1,2) yapısını gösteren grafik Şekil 11’de yer almakta olup denklemin köklerinin bir (1) değerinden büyük olmadığı görülmektedir. Çıktıda görüleceği gibi kökler çemberin üzerindedir.



Şekil 11. Çok Terimli AR/MA Ters Kökleri

Kalıntıların korelogramları ise Şekil 12’de yer almaktadır. Şekilde görüldüğü üzere oto korelasyon ve kısmi oto korelasyon katsayıları alt ve üst sınırlar içerisinde olup veriler %95 seviyesinde elde edilmiştir.


Date: 02/18/23 Time: 22:46
 Sample: 2010Q1 2022Q4
 Included observations: 51
 Q-statistic probabilities adjusted for 5 ARMA terms

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.054	0.054	0.1574	
		2 -0.143	-0.147	1.2931	
		3 -0.034	-0.018	1.3600	
		4 0.054	0.037	1.5283	
		5 -0.063	-0.078	1.7616	
		6 -0.031	-0.011	1.8195	0.177
		7 -0.066	-0.083	2.0847	0.353
		8 0.010	0.007	2.0916	0.554
		9 -0.084	-0.105	2.5488	0.636
		10 -0.143	-0.145	3.8997	0.564
		11 -0.013	-0.022	3.9104	0.689
		12 0.026	-0.038	3.9559	0.785
		13 0.068	0.060	4.2815	0.831
		14 -0.070	-0.096	4.6409	0.864
		15 -0.103	-0.110	5.4340	0.860
		16 0.146	0.125	7.0788	0.793
		17 0.011	-0.079	7.0887	0.852
		18 -0.078	-0.043	7.5825	0.870
		19 0.034	0.012	7.6786	0.905
		20 0.111	0.049	8.7547	0.890
		21 -0.079	-0.089	9.3169	0.900
		22 -0.000	0.026	9.3169	0.930
		23 -0.060	-0.073	9.6651	0.942
		24 0.016	-0.029	9.6907	0.960
		25 0.016	0.005	9.7181	0.973
		26 -0.016	-0.015	9.7452	0.982
		27 -0.007	0.003	9.7513	0.988
		28 -0.040	-0.077	9.9430	0.992
		29 -0.000	-0.007	9.9430	0.995
		30 -0.005	-0.018	9.9457	0.997
		31 0.001	0.002	9.9459	0.998
		32 0.056	0.022	10.393	0.998
		33 0.042	-0.013	10.659	0.999
		34 0.004	0.061	10.662	0.999
		35 0.008	-0.009	10.672	1.000
		36 -0.052	-0.093	11.152	1.000

Şekil 12. Kalıntıların Kolegramı

Kalıntıların korelogramları ise Şekil 13’de yer almaktadır. Şekilde görüldüğü üzere otokorelasyon ve kısmi otokorelasyon katsayıları alt ve üst sınırlar içerisinde olup veriler %95 seviyesinde elde edilmiştir

Modelin kalıntıların, tahmin, gerçek ve uyarlanmış değerlerini gösteren grafiği Şekil 13’de gösterilmektedir.



Şekil 13. Kalıntılar, Gerçek ve Tahmini Değerlerinin Dağılımı

4.5. Tahmin Modeli

Modelin Tahmin modeli aşağıdaki gibidir.

LS(OPTMETHOD=OPG) DPAS AR(1) SAR(4) MA(1) SMA(4) SMA(8)

Tahmin Denklemi

Modelin tahmin denklemi ise şu şekilde yazılmaktadır.

DPAS = 0 + [AR(1)=C(1),SAR(4)=C(2),MA(1)=C(3),SMA(4)=C(4),SMA(8)=C(5)]


4.6. Modelin Katsayıları

Tahmin modelin katsayıları ise;

DPAS = 0 + [AR(1)=0.688553208017,SAR(4)=0.999998301786,MA(1)=-1,SMA(4)=-0.388332275541,SMA(8)=-0.603170367784].


4.7. Tahminleme

Elde edilen yolcu talebi ARIMA (1,1,1) (1,1,2) modelinin %95 güven aralığı içinde yapılan statik tahminleme sonucu Şekil 14'de yer almaktadır. Ayrıca tahmin güvenilirliğine yönelik elde edilen Ortalama Mutlak Hata, Ortalama Mutlak Hata Yüzdesi, Theil katsayısı ve buna bağlı Bias oranı, varyans oranı ve kovaryans oranı değerleri yer almaktadır.



Şekil 14. ARIMA Modeli Tahmini (DPAS, DPASF)

Tehil Eşitsizlik katsayısının 0.117 buna bağlı olarak Bias Oranı değeri 0.02 olup sıfır değerine yakın olması modelin iyi olduğunu belirtmekte, modelin serideki değişkenliğin (varyans oranı) 0.16'sını öngörememesi ve %79'a kadar sistematik olmayan hata yüzdesinin (kovaryans oranı) mevcut olması sebebiyle modelin tahmin gücünün yüksek olduğu belirlenerek modelin uygun bir model olduğu söylenilebilir. Elde edilen tahmin modeline göre yapılan dinamik tahminleme sonucunda 2022Q4 -2025Q4 arasında tahmini Türkiye'nin havayolu yolcu talebi elirlenmiş olup ilgili grafiği gerçek ve tahmini yolcu sayısını gösteren grafikler Şekil 15'de gösterilmiştir.



Şekil 15. 2023 - 2025 Çeyrek Yılları Türkiye'nin Yolcu Talebi Tahmini

4.8. ARIMAX Modellemesi

Çeyrek periyotlarla ülkemizi içerden ve dışardan gelen ticari uçak sayısı (ACN) dışsal değişken olarak belirlenmiştir. Söz konusu değişkenleri denkleme sokmadan önce de bu serilerin durağan hale getirilmesi gerekmektedir. Sırasıya durağanlık ve birim kök testleri her bir seri için yapıldığında aşağıdaki bulgular tespit edilmiştir.

4.8.2 Gelen Uçak Hareket Sayıları Serisinin Durağanlık Testleri

Yapılan testlerde ACN serisinin level halinde durağan olmadığı ve birim kök olduğu tespit edilerek serinin 1 farkı alınarak yapılan testlerde, sabit ve trend olmadan serinin durağan hale geldiği belirlenmiş olup kritik mutlak değerin (2.87) sırasıyla %1, %5, %10 anlamlılık seviyelerinde (2.6), (1.94), (1.61) değerlerinden büyük olarak tespit edilmiş olup H_0 hipotezi red edilmiştir. Konuyla ilgili yapılan ADF birim kök test sonuç tablosu Tablo 17'de belirtildiği gibidir.

Tablo 17. ADF Birim Kök Testi

Null Hypothesis: DACN has a unit root				
Exogenous: None				
Lag Length: 3 (Automatic - based on SIC, maxlag=10)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-2.871625	0.0050
	1% level		-2.615093	
	5% level		-1.947975	
Test critical values:	10% level		-1.612408	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation				
Dependent Variable: D(DACN)				
Method: Least Squares				
Date: 02/05/23 Time: 18:55				
Sample (adjusted): 2011Q2 2022Q4				
Included observations: 47 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
DACN(-1)	-1.423678	0.495774	-2.871625	0.0063
D(DACN(-1))	0.070400	0.373287	0.188594	0.8513
D(DACN(-2))	-0.279847	0.249780	-1.120374	0.2688
D(DACN(-3))	-0.636584	0.126236	-5.042790	0.0000
R-squared	0.981501	Mean dependent var		22838.23
Adjusted R-squared	0.980210	S.D. dependent var		801506.5
S.E. of regression	112753.9	Akaike info criterion		26.18507
Sum squared resid	5.47E+11	Schwarz criterion		26.34253
Log-likelihood	-611.3491	Hannan-Quinn critter.		26.24432
Durbin-Watson stat	1.975780			

4.8.3 Gayri Safi Milli Hasıla Durağanlık Testleri

Yapılan testlerde LGDP serisinin level halinde durağan olmadığı ve birim kök olduğu tespit edilerek serinin 1 farkı alınarak yapılan testlerde, sabitte serinin 1 gecikmeli halinde durağan hale geldiği belirlenmiş olup kritik mutlak değerin (3.31) sırasıyla %5, %10 anlamlılık seviyelerinde (2.92), (2.60), (1.61) değerlerinden büyük olarak tespit edilmiş olup H_0 hipotezi red edilmiştir. Konuyla ilgili yapılan ADF birim kök test sonuç tablosu Tablo 18'de belirtildiği gibidir.

Tablo 18. Birim Kök Testi

Null Hypothesis: DLGDP has a unit root Exogenous: Constant Lag Length: 1 (Fixed)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-3.316869	0.0194
Test critical values:				
	1% level		-3.571310	
	5% level		-2.922449	
	10% level		-2.599224	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation Dependent Variable: D(DLGDP) Method: Least Squares Date: 03/10/23 Time: 00:00 Sample (adjusted): 2010Q4 2022Q4 Included observations: 49 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
DLGDP(-1)	-0.584642	0.176263	-3.316869	0.0018
D(DLGDP(-1))	-0.171701	0.156788	-1.095112	0.2792
C	0.029841	0.012690	2.351487	0.0230
R-squared	0.347419	Mean dependent var		-0.002000
Adjusted R-squared	0.319046	S.D. dependent var		0.072686
S.E. of regression	0.059980	Akaike info criterion		-2.730340
Sum squared resid	0.165490	Schwarz criterion		-2.614514
Log-likelihood	69.89332	Hannan-Quinn criter.		-2.686395
F-statistic	12.24468	Durbin-Watson stat		1.820648
Prob(F-statistic)	0.000055			

4.8.4 Ham Petrol Alış Fiyatı Durağanlık Testleri

Yapılan testlerde, Ham Petrol Alış Fiyatı (AIOP) serisinin level halinde durağan olmadığı ve birim kök olduğu tespit edilerek serinin 1 farkı alınarak yapılan testlerde, sabit ve trendsiz serinin 1 gecikmeli halinde durağan hale geldiği belirlenmiş olup kritik mutlak değerin (5.67) sırasıyla, %1, %5, %10 anlamlılık seviyelerinde (2.61), (1.94), (1.61) değerlerinden büyük olarak tespit edilmiş olup H_0 hipotezi red edilmiştir. Konuyla ilgili yapılan ADF test sonuçları Tablo 19'da yer almaktadır.

Tablo 19. ADF Birim Kök Testi

Null Hypothesis: DAIOP has a unit root Exogenous: None Lag Length: 0 (Automatic- based on SIC, maxlag=1)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-5.676983	0.0000
Test critical values:				
	1% level		-2.612033	
	5% level		-1.947520	
	10% level		-1.612650	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation Dependent Variable: D(DAIOP) Method: Least Squares Date: 03/10/23 Time: 16:56 Sample (adjusted): 2010Q3 2022Q4 Included observations: 50 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
DAIOP(-1)	-0.806351	0.142039	-5.676983	0.0000
R-squared	0.396599	Mean dependent var		-0.234400
Adjusted R-squared	0.396599	S.D. dependent var		14.47435
S.E. of regression	11.24351	Akaike info criterion		7.697256
Sum squared resid	6194.407	Schwarz criterion		7.735497
Log-likelihood	-191.4314	Hannan-Quinn criter.		7.711818
Durbin-Watson stat	1.959175			

4.9. Modelin Tahmini

Yapılan model denemeleri sonucunda, Ham Petrol Alış Fiyatını temsil eden DAIOP serisinin anlamlı olmadığı için dışsal değişken olarak denklemeden çıkarılmış ve yapılan denemeler sonucunda Şekil 16’da görüldüğü üzere ARMA modeli (1,1) (0,0) ya da ARIMA (1,1,1) en uygun model olarak belirlenmiş ilgili en küçük AIC değeri 36.95815 olarak tespit edilmiştir. Elde edilen model DPAS serisinin AR(1) MA(1) DACN DLGDP(-1) olup modeli regresyona koyduğumuzda aşağıdaki sonuçlar Tablo 20’de gösterilmektedir. İlgili serinin kolegram testi sonuçlarına bakıldığında otokorelasyonun olmadığı Şekil 16’da görülmektedir.

Date: 03/11/23 Time: 22:11
 Sample: 2010Q1 2022Q4
 Included observations: 50
 Q-statistic probabilities adjusted for 2 ARMA terms

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob*
. .	. .	1	0.001	0.001	3.E-05
. .	. .	2	-0.016	-0.016	0.0145
* .	* .	3	-0.098	-0.098	0.5441 0.461
. *	. *	4	0.139	0.140	1.6416 0.440
. .	. .	5	-0.004	-0.009	1.6425 0.650
* .	* .	6	-0.107	-0.116	2.3205 0.677
. .	. .	7	-0.015	0.016	2.3334 0.801
. .	. .	8	0.046	0.025	2.4648 0.872
. .	* .	9	-0.046	-0.072	2.6003 0.919
* .	* .	10	-0.131	-0.103	3.7126 0.882
* .	* .	11	-0.077	-0.072	4.1130 0.904
. .	* .	12	-0.055	-0.095	4.3229 0.932
. .	. .	13	0.016	0.005	4.3405 0.959
* .	* .	14	-0.149	-0.138	5.9414 0.919
. .	. .	15	-0.005	-0.019	5.9431 0.948
. .	. .	16	-0.042	-0.057	6.0761 0.965
. .	. .	17	0.033	-0.020	6.1614 0.977
* .	* .	18	0.126	0.157	7.4517 0.964
. .	. .	19	0.024	0.007	7.5017 0.976
. .	. .	20	0.017	-0.015	7.5279 0.985
* .	* .	21	-0.111	-0.121	8.6320 0.979
. *	. *	22	0.135	0.093	10.327 0.962
. *	. .	23	0.090	0.072	11.108 0.961
. .	* .	24	-0.043	-0.082	11.291 0.970

Şekil 16. ARIMA Modelinin Korelagramı

Tablo 20. ADF Birim Kök Testi

Dependent Variable: DPAS				
Method: ARMA Maximum Likelihood (OPG - BHHH)				
Date: 03/08/23 Time: 14:20				
Sample: 2010Q3 2022Q4				
Included observations: 50				
Convergence achieved after 28 iterations				
Coefficient covariance computed using outer product of gradients				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-3740228.	2466890.	-1.516171	0.1366
DACN	441.2591	7.686589	57.40636	0.0000
DLGDP(-1)	96012002	32483437	2.955722	0.0050
AR(1)	-0.373107	0.152932	-2.439696	0.0188
MA(1)	-0.372905	0.186591	-1.998516	0.0519
SIGMASQ	5.12E+14	1.06E+14	4.827918	0.0000
R-squared	0.988557	Mean dependent var		8067568.
Adjusted R-squared	0.987257	S.D. dependent var		2.14E+08
S.E. of regression	24117617	Akaike info criterion		36.95815
Sum squared resid	2.56E+16	Schwarz criterion		37.18760
Log likelihood	-917.9538	Hannan-Quinn criter.		37.04553
F-statistic	760.2510	Durbin-Watson stat		1.988471
Prob(F-statistic)	0.000000			
Inverted AR Roots	-.37			
Inverted MA Roots	.37			

Bu sonuçlara göre dışsal değişkenlerden ülkeye gelen-giden uçak sayısının DACN serisinin ve bir gecikmeli hali ile logaritması alınmış gayri safi milli hasıla DLGDP serisinin anlamlı olduğu görülmüş olup modelin açıklanma oranı düzeltilmiş R kare oranı 0.99 olarak görülmüştür. Mevcut modelin statik tahmin gücüne bakıldığında aşağıdaki grafik sonuçlar elde edilmektedir.

4.10. Tahmin Modeli

LS(OPTMETHOD=OPG) DPAS AR(1) MA(1) C DACN DLGDP(-1)

4.11. Tahmin Denklemi


DPAS = C(1) + C(2)*DACN + C(3)*DLGDP(-1) + [AR(1)=C(4),MA(1)=C(5)]

4.12. Modelin Katsayıları

DPAS = -3740227.90397 + 441.259077523*DACN + 96012001.5236*DLGDP(-1) + [AR(1)=-0.373107018659,MA(1)=-0.372905388462]

4.13. Tahminleme

Elde edilen yolcu talebi ARIMAX modelinin %95 güven aralığı içinde yapılan statik tahminleme sonucu Şekil 17’de yer almaktadır. Ayrıca tahmin güvenilirliğine yönelik elde edilen Ortalama Mutlak Hata, Ortalama Mutlak Hata Yüzdesi, Theil katsayısı ve buna bağlı Bias oranı, varyans oranı ve kovaryans oranı değerleri yer almaktadır.



Şekil 17. ARIMAX Modeli Tahmini

Theil Eşitsizlik katsayısının 0.06 buna bağlı olarak Bias Oranı değeri 0.0001 olup sıfır değerine oldukça yakın olması modelin iyi olduğunu belirtmektedir. Modelin serideki değişkenliğin (varyans oranı) sadece 0.015’ini öngörememesi ve %9’a kadar sistematik olmayan hata yüzdesinin (kovaryans oranı) mevcut olması sebebiyle modelin tahmin gücünün yüksek olduğu belirlenerek modelin uygun bir model olduğu söylenilebilir.

4.14. ARIMA VE ARIMAX Modellerinin Karşılaştırılması

Yapılan her iki çalışma sonucunda elde edilen SARIMA ve ARIMAX modellerinin Tablo 21’de belirtilen kriterlere göre karşılaştırılması yer almaktadır.

Tablo 20’de yer alan kriterler incelendiğinde, ARIMAX modelinin Theil Eşitsizlik katsayısının, Bias oranının, kendi kontrolümüzde olan değişkenlik sapmasını gösteren varyans oranı ve kendi kontrolümüz dışındaki değişkenliği gösteren kovaryans oranının RMSE, MAE, MAPE değerlerinin daha küçük olduğu ve modelin açıklanma oranı R kare değerinin ARIMAX modelinde daha yüksek olması sebebiyle ARIMAX modelinin DPAS AR(1) MA(1) DACN DLGDP(-1) modelinin tahmin gücünün daha iyi olduğu söylenebilir. Bu bilgiler ışığında havayolu yolcu sayısının tahmininde ARIMAX modeli tercih edilmelidir.

Tablo 21. SARIMA ARIMAX Modelleri Karşılaştırması

Kriterler	SARIMA	ARIMAX
Theil Eşitsizliği	0.11	0.068
Bias Oranı	0.03	0.0001
Varyans Oranı	0.16	0.015
Kovaryans Oranı	0.80	0.98
Hataların Ortalama Karekökü	48361917	29444677
Ortalama Mutlak Hata	391610928	19844665
Ortalama Mutlak Hata Yüzdesi	35.50	15.58
Düzeltilmiş R kare	0.95	0.98

5. Sonuç ve Tartışma

Önceki dönemde ülkemizde yıllar bazında havayolu yolcu tahmin modeli 2014 yılında geliştirilmiş olmakla birlikte zaman serilerinin daha iyi tahminleme ve model öngörüsü yapılmasına yönelik zaman serisinin otuz ve üzerinde olması tavsiye edilmesi dikkate alındığında bu çalışma daha yeni ve aynı zamanda daha geniş zaman serisini (dört aylık çeyrek periyotlar) kullanmıştır. Benzer şekilde havayolu yolcu sayısı tahmin ve öngörü modeli ARIMA ve dışsal değişkenler ilave edilerek ARIMAX yöntemiyle yapılarak her iki model karşılaştırılmıştır. Ayrıca mevcut çalışmada Covid-19 döneminin modelin tahmininde etkisi olup olmadığı da incelenmiştir.

Yapılan çalışma neticesinde, tek değişkenli zaman serisinin analizinde, Covid-19 döneminin modelin tahminine etkisi olmadığı SARIMA (1,1,0)(1,1,2) modelinin en uygun model olduğu ve modelin tahmin gücünün yüksek olduğu görülmüş, daha sonra dışsal değişkenlerin modele dahil edilerek ülkeye gelen ve giden ticari uçak sayıları ile, Gayri Safi Milli Hasılabın birlikte ele alan ARIMAX (1,1)(0,0) modelinin en uygun model tahmin gücünün iyi olduğu belirlenmiştir. Her iki modelin karşılaştırmalar sonucunda ARIMAX modelinin ve öngörü gücünün daha iyi olduğu neticesine varılmıştır.

Yapılan çalışmada kullanılan dışsal değişkenler ve analiz yöntemleri Andreoni ve Postorino nun İtalya da şehir çifti arasında yapılan çalışma ile benzerlik göstermekle birlikte ilgili çalışmada sadece 16 yıllık veri kullanıldığı, açıklayıcı değişken olarak ise kişi başına gelir ve uçak hareketlerinin yer aldığı çalışma sonucunda ise tek değişkenli ARIMA modelinin daha iyi olduğu belirlenmiştir.

Diğer yandan tahmin modelleme yöntemlerinde bir çok yeni yaklaşımlar bulunmaktadır, yapay sinir ağları (ANN), Meta Sezgisel gibi yöntemlerle bunlardan bazıları olup bu yöntemlerle de mevcut çalışmanın yapılarak karşılaştırmaların yapılması önerilmektedir. İlaveten, çalışmada kullanılan açıklayıcı değişkenler dışında başka değişkenler de belirlenebilir, ham petrol fiyatı yerine uçak yakıt fiyatları, ihracat, ithalat miktarları ve diğerleri kullanılarak çalışma yenilenebilir.

Yapılan çalışma tek değişkenli zaman serileri kapsamında ele alınmış bununla birlikte çalışmanın panel zaman verileri kapsamında incelenerek birim etkisi ve zaman etkisinin incelenmesi ayrıca faydalı olacaktır.

Hakem Değerlendirmesi: Dış bağımsız.

Çıkar Çatışması: Yazar çıkar çatışması beyan etmemişlerdir.

Finansal Destek: Yazar finansal destek beyan etmemişlerdir.

Peer Review: Externally peer-reviewed.

Conflict of Interest: Author declared no conflict of interest.

Financial Disclosure: Author declared no financial support.

Yazarın ORCID ID'si / ORCID ID of the author

Vahap Önen 0000-0001-8592-9430

KAYNAKLAR / REFERENCES

Abbas, K. A. (2004). Conceptual and Regression Models for Passenger Demand Prediction: A Case Study of Cairo Airport and Egyptair. *Airlines Magazine*. E-zine ed., Issue 26.

- Abed, S. Y., A. O. BaFail, and S. M. (2001). Jasimuddin. An Econometric Analysis of International Air Travel Demand in Saudi Arabia. *Journal of Air Transport Management*, Vol. 7, 2001, pp. 143–148.
- Alam, M. J. B., and D. M. Karim (1998). Air Travel Demand for Domestic Air Transportation in Bangladesh. *Journal of Civil Engineering*, Vol. CE26, No. 1, pp. 1–13.
- Alekseev, K. P. G., and J. M. Seixa (2009). A Multivariate Neural Forecasting Modeling for Air Transport Preprocessed Decomposition: A Brazilian Application. *Journal of Air Transport Management*, Vol. 15, pp. 212–216.
- Andreoni, A. and Postorino, M.N. (2006), “A multivariate ARIMA model to forecast air transport demand”, Proceedings of the Association for European Transport and Contributors, pp. 1-14.
- Anderson, T. W. (2011). *The statistical analysis of time series*. John Wiley & Sons.
- Anvari, S., Tuna, S., Canci, M. and Turkay, M. (2016). “Automated Box–Jenkins forecasting tool with an application for passenger demand in urban rail systems”, *Journal of Advanced Transportation*, Vol. 50 No. 1, pp. 25-49.
- Arya, P.; Paul, R. K.; Kumar, A.; Singh, K. N.; Sivaramne, N.; Chaudhary, P. (2015) Predicting pest population using weather variables: an ARIMAX time series Framework, *International Journal of Agricultural and Statistics Sciences*, 11(2),381-386.
- Asteriou, D. ve Hall, S.G. (2011). ARIMA models and the Box–Jenkins methodology. *Applied Econometrics*, 2(2), 265-286.
- BaFail (2004). BaFail, A. Applying Data Mining Techniques to Forecast Number of Airline Passengers in Saudi Arabia (domestic and international travels). *Journal of Air Transport*, Vol. 9, No. 1, pp. 100–115.
- Balık, M. (2015). *Hava Kargo Taşımacılığı Ve Türkiye'deki Gelişimini Etkileyen Faktörler*, Afyon Kocatepe Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisan Tezi.
- Bierens H J. 1987. ARMAX model specification testing, with an application to unemployment in *the Netherlands*. *Journal Econometrics* 35: 161-90.
- Benton, W. K. (1972). *Forecasting for management*. Reading, Mass: Addison-Wesley Publishing Company.
- Bigovic, M. (2012). “Demand forecasting within Montenegrin tourism using Box-Jenkins methodology for seasonal ARIMA models”, *Tourism and Hospitality Management*, Vol. 18 No. 1, pp. 1-18.
- Box, G.E.P ve Jenkins, G.M. (1976) *Time Series Analysis Forecasting and Control*. Revised Edition, Holden. DayInc., California, 170p.
- Bozkurt, H.Y. (2013). *Zaman Serileri Analizi*, Ekin Yayınevi, Kocaeli.
- Brown, R. G. (1963). *Smoothing, forecasting, prediction*. Engle-wood Cliffs.
- BTCE (1995). *Demand Elasticities for Air Travel to and from Australia*. BTCE Working Paper 20. Bureau of Transport and Communications Economics, Canberra, Australia.
- Cheze, B., P. Gastineau, and J. Chevallier (2010). *Forecasting Air Traffic and Corresponding Jet-Fuel Demand Until 2025*. Les cahiers de l'économie–77, Institut Francais du Petrole, Rueil-Malmaison, France.
- Chudy-Laskowska, K. ve Pisula, T. (2017, January). Seasonal Forecasting for Air Passenger Traffic. In *4th international multidisciplinary scientific conference on social sciences and arts SGEM 2017* (pp. 681-692).
- Chu, F.-L. (2008). “A fractionally integrated autoregressive moving average approach to forecasting tourism demand”, *Tourism Management*, Vol. 29 No. 1, pp. 79-88.
- Chu, F.-L. (2009). “Forecasting tourism demand with ARMA-based methods”, *Tourism Management*, Vol. 30 No. 5, pp. 740-51.
- Cools, M., Moons, E., & Wets, G. (2009). Investigating the variability in daily traffic counts through use of ARIMAX and SARIMAX models: assessing the effect of holidays on two site locations. *Transportation Research Record: Journal of the Transportation Research Board*, (2136), 57-66.
- Cryer, J.D. (1986). *Time series analysis* (Vol. 286). Boston: Duxbury Press.
- Dargay, J., and M. Hanly (2002). *The Determinants of the Demand for International Air Travel to and from the UK*. Presented at Annual Conference of the University Transport Studies Group, Napier, New Zealand, 2002.
- DfT (2009). *UK Air Passenger Demand and CO2 Forecasts*. Department for Transport (DfT), London.
- DHMI (2022). www.DHMI.org.tr, (Erişim Tarihi: Aralık 2022).
- EIA (2022). www.eia.gov/outlooks/steo/realprices, (Erişim Tarihi, Aralık 2022).
- Granger, C. W. J. (1990). Spectral analysis. *Time Series and Statistics*, 263-267.
- Gujarati, D. (2014). *Econometrics by example*. Macmillan International Higher Education.
- Ghalekhondabi, I., Ardjmand, E., Young, W. A., & Weckman, G. R. (2019). A review of demand forecasting models and methodological developments within tourism and passenger transportation industry. *Journal of Tourism Futures*, 5(1), 75-93.
- Gong, W. (2010). “ARMA-GRNN for passenger demand forecasting”, 2010 Sixth International Conference on Natural Computation, IEEE, pp. 1577-81.
- Fan, J., Shan, R., Cao, X., & Li, P. (2009). The analysis to tertiary-industry with ARIMAX model. *Journal of Mathematics Research*, 1(2), 156.
- Fernandes, E., and R. R. Pacheco (2007). *Air Transportation Analysis: Passenger Demand in Brazil*. Airlines Magazine. E-zine ed., Issue 33, 2023. <http://www.airlines.nl/index.php/magazine/volumes-115/volume-13/issue-33/>. Erişim Tarihi: Şubat 2023.
- Hassan, S.A. ve Quadi, A.T. (2018). *Forecasting Passenger Numbers in Saudi Arabian Airlines Flights*, *International Journal of Engineering Science Invention (IJESI) ISSN (Online): 2319 – 6734, ISSN (Print): 2319 – 6726*.
- IATA (2022). <https://www.iata.org/en/pressroom/2022-releases/2022-12-06-01/#:~:>Erişim Tarihi (15.02.2023).
- Janic M., (2000). An assessment of risk and safety in civil aviation. *Journal of Air Transport Management* 6 (1), 43-50.

- Jenkins, G. M., & Watts, D. G. (1968). *Spectra Analysis and Its Applications*, Holden-Day.
- Johnson, L. A., Montgomery, D. C., & Gardiner, J. S. (1976). *Forecasting and time series analysis*. Ed: Mc Graw Hill.
- Krasic, D. and Gatti, P. (2009), "Forecasting methodology of maritime passenger demand in a tourist destination", *PROMET-Traffic & Transportation*, Vol. 21 No. 3, pp. 183-90.
- Kulendran, N., and M. L. King (1997). Forecasting International Quarterly Tourist Flows Using Error-Correction and Time-Series Models. *International Journal of Forecasting*, Vol. 13, 1997, pp. 319–327.
- Kutlar, A. (2017). Adım Adım Eviews ile Panel Veri Ekonometrisi Uygulamaları. Kocaeli: *Umuttepe Yayınları*.
- Lewis, C. D. (1982). *Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting*. Butterworth-Heinemann.
- Lim, C., and M. McAleer (2002). Time Series Forecasting of International Travel Demand for Australia. *Tourism Management*, Vol. 23, pp. 389–396.
- Lim, C., J. C. H. Min, and M. McAleer (2008). Modelling Income Effects on Long and Short Haul International Travel from Japan. *Tourism Management*, Vol. 29, pp. 1099–1109.
- Loganathan, N. and Ibrahim, Y. (2010), "Forecasting international tourism demand in Malaysia using Box Jenkins Sarima application", *South Asian Journal of Tourism and Heritage*, Vol. 3 No. 2, pp. 50-60.
- Manrai, K.A., Srinidhi, S.K. and Manrai, A. (2014), "International air transport demand: drivers and forecasts in the Indian context", *Journal of Modelling in Management*, Vol. 9 No. 3, pp. 245-60.
- Milenkovic, M., Bojovic, N., Macura, D. and Nuhodzic, R. (2013). "Kalman filtering applied to forecasting the demand for railway passenger services", 16th International Conference on Transport Science, Riga.
- Nanthakumar, L., Subramaniam, T. and Kogid, M. (2012). "Is' Malaysia Truly Asia'? Forecasting tourism demand from ASEAN using SARIMA approach", *Tourismos*, Vol. 7 No. 1, pp. 367-81.
- Neter, J., Kutner, M. H., Nachtsheim, C. J., & Wasserman, W. (1996). *Applied linear statistical models* (Vol. 4, p. 318). Chicago: Irwin. network modeling approach for sales forecasting. *International Journal of Production*.
- Ortúzar, J., & Simonetti, C. (2008). Modelling the demand for medium-distance air travel with the mixed data estimation method. *Journal of Air Transport Management*, 14(6), 297-303.
- Ozan, C., Başkan, Ö., Haldenbilen, S. ve Ceylan, H. (2014). Yurtiçi hava taşımacılığı talebinin modellenmesi ve senaryolar altında değerlendirilmesi.
- Profillidis, V. A. (2000). Econometric and Fuzzy Models for the Forecast of Demand in the Airport of Rhodes, *Journal of Air Transport Management*, Vol. 6, pp. 95–100.
- Schultz, R. L. (1972). Studies of Airline Passenger Demand: A Review. *Transportation Journal*, 48-62.
- Sutthichaimethee, P., & Ariyasajakorn, D. (2017). Forecasting energy consumption in short-term and long-term period by using arimax model in the construction and materials sector in thailand. *Journal of Ecological Engineering*, 18(4).
- Subaşı, D.B. (2005). Enflasyonun ARIMA Modelleri İle Tahminlenmesi:1994–2005 Türkiye Uygulaması, Yüksek Lisans Tezi, Dumlupınar Üniversitesi, Sosyal Bilimler Enstitüsü, İktisat Anabilim Dalı, Kütahya.
- Suh, S.S., Park, J. W., Song, G. S. ve Cho, S. G. (2014). A Study of Air Freight Forecasting Using the ARIMA Model. *Journal of Distribution Science*, 12(2), 59-71.
- Suryan, V. (2017, January). Econometric forecasting models for air traffic passenger of indonesia. In *Journal of the Civil Engineering Forum Vol* (Vol. 3, No. 1).
- Tuik (2023). <https://www.tuik.org.tr>, (Erişim Tarihi: 2023, Şubat).
- Taneja, N. K. (1978). Airline Traffic Forecasting. *Lexington MA: Lexington Books*, 344, 1988-92.
- Tortum, A., Gözcü, O. ve Codur, M. Y. (2014a). Türkiye’de Hava Ulaşım Talebinin Arıma Modelleri ile Tahmin Edilmesi. *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 4(2), 39-54.
- Tortum, A., Gözcü, O. ve Çodur, M.Y. (2014b). "Türkiye’de Hava Ulaşım Talebinin Arıma Modelleri ile Tahmin Edilmesi." *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi* 4.2.
- Tsai, T.-H., Lee, C.-K. and Wei, C.-H. (2009), "Neural network based temporal feature models for short-term railway passenger demand forecasting", *Expert Systems with Applications*, Vol. 36 No. 2, pp. 3728-36.
- Tsekeris, T. (2009). Dynamic Analysis of Air Travel Demand in Competitive Island Markets. *Journal of Air Transport Management*, Vol. 15, pp. 267–273.
- Tsui, W.H.K., Balli, H.Ö., & Gow, H. (2011). *Forecasting airport passenger traffic: the case of Hong Kong International Airport*. Aviation Education and Research Proceedings (ISSN 1176-0729), vol 2011, pp 54-62.
- Vandaele, W. (1983). *Applied time series and Box-Jenkins models* (No.04; HB3730, V3.).
- Vergil, H. ve Özkan, F. (2007). Döviz Kurları Öngörüsünde Parasal Model ve Arıma Modelleri: Türkiye Örneği. *Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (13), 211-231.
- Yılmaz, A. (2003). *Zaman Serileri Analizi*, Bıçaklar Kitapevi, Ankara.
- Yücesan M. (2018). "YSA, ARIMA ve ARIMAX Yöntemleriyle Satış Tahmini: Beyaz Eşya Sektöründe bir Uygulama" , *Isarder*, DOI: 10.20491/isarder.2018.414.
- Wadud, Z. (2013). Simultaneous modeling of passenger and cargo demand at an airport. *Transportation research record*, 2336(1), 63-74.
- Wadud, Z. (2011). Modeling and Forecasting Passenger Demand for a New Domestic Airport with Limited Data. In *Transportation Research*

Record: Journal of the Transportation Research Board, No. 2214, Transportation Research Board of the National Academies, Washington, D.C., 2011, pp. 59–68.

How cite this article / Atıf Biçimi

Önen, V. (2023). Using the ARIMA and ARIMAX methodologies to estimate, model, forecast, and compare airline passenger transportation demand in Türkiye. *Journal of Transportation and Logistics*, 8(2), 242-273. <https://doi.org/10.26650/JTL.2023.1270944>

Ek-1

Tablo 22. Model Seçim Kriter Tablosu

Dependent Variable: DPAS				
Date: 02/18/23 Time: 22:13				
Sample: 2010Q1 2022Q4				
Included observations: 51				
Model	LogL	AIC*	BIC	HQ
(1,1)(1,2)	-978.774778	38.618619	38.845892	38.705467
(1,2)(1,2)	-978.328554	38.640335	38.905488	38.741658
(2,1)(1,2)	-978.383360	38.642485	38.907637	38.743807
(4,0)(0,2)	-978.727005	38.655961	38.921114	38.757284
(2,1)(2,2)	-978.267669	38.677163	38.980195	38.792961
(1,3)(1,2)	-978.312471	38.678920	38.981952	38.794718
(0,3)(1,2)	-979.316210	38.679067	38.944220	38.780390
(0,4)(1,2)	-978.680853	38.693367	38.996398	38.809164
(4,0)(1,2)	-978.690256	38.693736	38.996767	38.809533
(5,0)(2,1)	-978.157424	38.712056	39.052966	38.842328
(1,5)(1,1)	-978.238654	38.715241	39.056152	38.845513
(1,2)(2,1)	-980.308230	38.717970	38.983122	38.819292
(3,2)(0,2)	-979.363381	38.720133	39.023164	38.835930
(0,5)(1,2)	-978.375204	38.720596	39.061507	38.850868
(4,2)(0,2)	-978.614048	38.729963	39.070873	38.860235
(3,3)(0,2)	-978.656859	38.731642	39.072552	38.861913
(1,1)(1,0)	-983.679780	38.732540	38.884056	38.790439
(5,1)(0,2)	-978.777957	38.736390	39.077301	38.866662
(6,0)(2,0)	-978.869654	38.739986	39.080897	38.870258
(4,2)(2,0)	-978.883445	38.740527	39.081438	38.870799
(1,2)(1,0)	-983.055418	38.747271	38.936666	38.819645
(2,1)(1,0)	-983.072972	38.747960	38.937354	38.820333
(0,7)(1,1)	-978.199960	38.752940	39.131729	38.897686
(3,2)(2,2)	-978.221432	38.753782	39.132571	38.898528
(2,3)(2,2)	-978.224312	38.753895	39.132684	38.898641
(0,2)(1,2)	-982.263331	38.755425	38.982698	38.842273
(4,1)(1,1)	-980.267213	38.755577	39.058608	38.871374
(1,3)(2,1)	-980.282101	38.756161	39.059192	38.871958
(5,2)(0,2)	-978.296364	38.756720	39.135510	38.901467
(0,6)(1,2)	-978.346693	38.758694	39.137483	38.903440
(1,1)(1,1)	-983.350618	38.758848	38.948242	38.831221
(6,1)(0,2)	-978.354040	38.758982	39.137771	38.903729
(2,2)(2,2)	-979.414150	38.761339	39.102250	38.891611
(1,2)(2,2)	-980.503274	38.764834	39.067866	38.880632
(0,0)(1,2)	-984.526500	38.765745	38.917261	38.823644
(6,1)(2,0)	-978.600752	38.768657	39.147446	38.913404
(1,1)(2,0)	-983.604842	38.768817	38.958212	38.841191
(0,4)(1,1)	-981.613919	38.769173	39.034326	38.870496
(4,0)(0,0)	-983.716796	38.773208	38.962602	38.845581
(3,1)(0,2)	-981.742377	38.774211	39.039363	38.875533
(7,0)(2,0)	-978.756675	38.774772	39.153561	38.919518
(5,1)(0,0)	-981.833242	38.777774	39.042927	38.879097
(0,6)(1,1)	-979.884763	38.779795	39.120705	38.910067
(1,2)(1,1)	-982.886879	38.779878	39.007151	38.866726
(8,0)(2,0)	-977.895638	38.780221	39.196889	38.939442
(2,0)(1,2)	-982.916400	38.781035	39.008309	38.867883
(5,1)(1,1)	-979.958425	38.782683	39.123594	38.912955
(1,2)(2,0)	-983.018966	38.785057	39.012331	38.871905
(2,1)(2,0)	-983.043302	38.786012	39.013285	38.872860
(2,2)(1,0)	-983.051730	38.786342	39.013616	38.873190
(1,3)(1,0)	-983.054362	38.786446	39.013719	38.873294
(4,1)(0,0)	-983.122492	38.789117	39.016391	38.875965
(5,0)(0,0)	-983.148524	38.790138	39.017412	38.876986
(0,9)(1,1)	-977.157348	38.790484	39.245031	38.964180
(8,0)(0,2)	-978.174181	38.791144	39.207813	38.950366
(3,4)(1,2)	-978.182464	38.791469	39.208137	38.950690
(3,5)(1,1)	-978.228490	38.793274	39.209942	38.952495
(2,6)(1,1)	-978.230024	38.793334	39.210003	38.952556
(0,2)(2,2)	-982.261467	38.794567	39.059720	38.895890
(3,0)(1,2)	-982.263434	38.794644	39.059797	38.895967
(5,3)(0,2)	-978.274134	38.795064	39.211732	38.954285
(1,1)(2,1)	-983.289059	38.795649	39.022923	38.882497
(4,4)(1,2)	-977.315295	38.796678	39.251225	38.970374
(0,1)(1,2)	-984.338021	38.797569	38.986964	38.869943
(3,5)(2,0)	-978.341139	38.797692	39.214360	38.956913
(4,0)(0,1)	-983.341189	38.797694	39.024967	38.884542

Tablo 22. Sayfa 2

(0,3)(1,0)	-984.350864	38.798073	38.987468	38.870446
(5,4)(0,1)	-978.389043	38.799570	39.216239	38.958792
(0,0)(2,2)	-984.425759	38.801010	38.990405	38.873383
(1,0)(1,2)	-984.434812	38.801365	38.990760	38.873738
(2,5)(1,2)	-978.451439	38.802017	39.218686	38.961239
(0,0)(2,1)	-985.489899	38.803525	38.955041	38.861424
(3,3)(0,1)	-981.503793	38.804070	39.107102	38.919868
(5,1)(2,2)	-978.578590	38.807004	39.223672	38.966225
(4,3)(2,2)	-977.590097	38.807455	39.262002	38.981151
(2,1)(2,1)	-982.594522	38.807628	39.072781	38.908951
(4,4)(0,2)	-978.623437	38.808762	39.225430	38.967983
(4,0)(1,0)	-983.630095	38.809023	39.036297	38.895871
(0,4)(2,1)	-981.638133	38.809339	39.112370	38.925136
(1,3)(2,2)	-980.656034	38.810041	39.150951	38.940312
(6,1)(1,2)	-978.718755	38.812500	39.229168	38.971721
(5,1)(0,1)	-981.771310	38.814561	39.117593	38.930358
(3,3)(1,1)	-980.789147	38.815261	39.156171	38.945533
(5,2)(0,0)	-981.790367	38.815309	39.118340	38.931106
(6,1)(0,0)	-981.806327	38.815934	39.118966	38.931732
(2,5)(2,2)	-977.807349	38.815974	39.270522	38.989670
(8,1)(1,0)	-978.808413	38.816016	39.232684	38.975237
(1,5)(2,1)	-979.814094	38.816239	39.195028	38.960986
(0,5)(1,0)	-982.815222	38.816283	39.081436	38.917606
(1,3)(1,1)	-982.881469	38.818881	39.084034	38.920204
(2,2)(1,1)	-982.881823	38.818895	39.084048	38.920218
(1,4)(1,0)	-982.883143	38.818947	39.084099	38.920269
(2,0)(2,2)	-982.908173	38.819928	39.085081	38.921251
(1,7)(1,2)	-977.908371	38.819936	39.274483	38.993632
(4,1)(0,1)	-982.921415	38.820448	39.085600	38.921770
(3,1)(1,2)	-981.937735	38.821088	39.124119	38.936885
(5,0)(0,1)	-982.966252	38.822206	39.087358	38.923529
(0,3)(1,1)	-983.975259	38.822559	39.049833	38.909407
(2,3)(1,0)	-982.975829	38.822582	39.087734	38.923904
(0,0)(1,0)	-987.981458	38.822802	38.898560	38.851752
(6,4)(0,1)	-977.983752	38.822892	39.277439	38.996588
(0,8)(1,2)	-977.984001	38.822902	39.277449	38.996598
(7,0)(2,2)	-978.005845	38.823759	39.278306	38.997455
(5,5)(0,1)	-978.011822	38.823993	39.278540	38.997689
(2,2)(2,0)	-983.015036	38.824119	39.089272	38.925442
(6,2)(0,0)	-981.015204	38.824126	39.165036	38.954398
(1,3)(2,0)	-983.017309	38.824208	39.089361	38.925531
(7,1)(1,2)	-978.033329	38.824836	39.279384	38.998532
(3,1)(2,0)	-983.037375	38.824995	39.090148	38.926318
(5,3)(0,0)	-981.037903	38.825016	39.165926	38.955288
(0,2)(2,1)	-984.053332	38.825621	39.052894	38.912469
(3,2)(1,0)	-983.056338	38.825739	39.090891	38.927061
(3,3)(0,0)	-983.058731	38.825833	39.090985	38.927155
(1,9)(1,0)	-978.083569	38.826807	39.281354	39.000503
(2,0)(2,1)	-984.108999	38.827804	39.055078	38.914652
(4,5)(2,0)	-978.110926	38.827879	39.282427	39.001575
(5,0)(1,0)	-983.111182	38.827889	39.093042	38.929212
(5,3)(1,2)	-978.116897	38.828114	39.282661	39.001810
(4,2)(0,0)	-983.118048	38.828159	39.093311	38.929481
(6,0)(0,0)	-983.145920	38.829252	39.094404	38.930574
(2,6)(2,1)	-978.147086	38.829297	39.283845	39.002993
(6,2)(2,1)	-978.173291	38.830325	39.284872	39.004021
(4,3)(1,2)	-979.186895	38.830859	39.247527	38.990080
(2,7)(1,1)	-978.247520	38.833236	39.287783	39.006932
(8,1)(0,2)	-978.262180	38.833811	39.288358	39.007507
(4,6)(1,1)	-977.273410	38.834251	39.326678	39.022422
(0,1)(2,2)	-984.288741	38.834853	39.062126	38.921701
(0,8)(1,1)	-979.312613	38.835789	39.252457	38.995010
(0,3)(2,0)	-984.317674	38.835987	39.063261	38.922835
(7,2)(0,2)	-978.324213	38.836244	39.290791	39.009940
(4,5)(1,2)	-977.335668	38.836693	39.329119	39.024863
(4,0)(1,1)	-983.346214	38.837106	39.102259	38.938429
(7,1)(1,1)	-979.349986	38.837254	39.253923	38.996476
(0,7)(2,2)	-978.354731	38.837440	39.291988	39.011136
(1,0)(2,2)	-984.358071	38.837571	39.064845	38.924419
(3,2)(0,0)	-984.383863	38.838583	39.065856	38.925431
(0,1)(2,1)	-985.386499	38.838686	39.028081	38.911060

Tablo 22. Sayfa 3

(7,1)(0,0)	-981.394271	38.838991	39.179901	38.969263
(2,4)(2,1)	-980.429664	38.840379	39.219168	38.985126
(1,0)(2,1)	-985.434956	38.840587	39.029981	38.912960
(0,0)(1,1)	-987.441501	38.840843	38.954480	38.884267
(2,4)(1,2)	-980.452940	38.841292	39.220081	38.986038
(9,1)(1,0)	-978.476423	38.842213	39.296760	39.015909
(0,10)(1,2)	-976.514408	38.843702	39.374007	39.046348
(7,1)(1,0)	-980.515548	38.843747	39.222536	38.988494
(6,3)(0,2)	-978.545959	38.844940	39.299487	39.018635
(10,0)(2,0)	-977.550449	38.845116	39.337542	39.033286
(4,4)(1,0)	-980.588431	38.846605	39.225394	38.991352
(2,2)(2,1)	-982.604771	38.847246	39.150277	38.963043
(1,4)(2,1)	-981.622706	38.847949	39.188860	38.978221
(9,1)(2,0)	-977.639400	38.848604	39.341030	39.036775
(3,3)(1,0)	-982.661830	38.849484	39.152515	38.965281
(3,0)(2,1)	-983.679174	38.850164	39.115316	38.951486
(0,2)(1,0)	-986.705169	38.851183	39.002699	38.909082
(5,5)(1,2)	-976.708357	38.851308	39.381613	39.053953
(0,6)(2,2)	-979.710588	38.851396	39.268064	39.010617
(1,6)(2,1)	-979.714637	38.851554	39.268223	39.010776
(0,0)(2,0)	-987.725252	38.851971	38.965607	38.895395
(11,1)(0,0)	-977.736556	38.852414	39.344840	39.040585
(2,5)(1,0)	-981.760120	38.853338	39.194248	38.983610
(11,0)(0,0)	-978.776010	38.853961	39.308508	39.027657
(8,1)(2,0)	-978.808358	38.855230	39.309777	39.028926
(4,1)(2,0)	-982.835320	38.856287	39.159319	38.972084
(0,3)(2,1)	-983.837421	38.856369	39.121522	38.957692
(5,0)(1,1)	-982.838800	38.856424	39.159455	38.972221
(2,8)(1,1)	-977.845207	38.856675	39.349101	39.044845
(5,4)(1,2)	-977.856719	38.857126	39.349552	39.045297
(3,4)(0,0)	-982.857553	38.857159	39.160190	38.972956
(3,4)(2,2)	-978.867878	38.857564	39.312111	39.031260
(3,2)(1,1)	-982.869225	38.857617	39.160648	38.973414
(2,3)(1,1)	-982.872305	38.857737	39.160769	38.973535
(7,0)(0,0)	-982.883345	38.858170	39.161202	38.973968
(7,2)(0,0)	-980.889447	38.858410	39.237199	39.003156
(0,4)(2,2)	-981.900843	38.858857	39.199767	38.989129
(4,1)(1,2)	-981.918177	38.859536	39.200447	38.989808
(6,0)(0,1)	-982.920480	38.859627	39.162658	38.975424
(1,8)(2,1)	-977.925213	38.859812	39.352238	39.047983
(3,2)(2,0)	-982.931972	38.860077	39.163109	38.975875
(0,1)(1,0)	-987.932360	38.860093	38.973729	38.903517
(6,0)(0,2)	-981.932637	38.860103	39.201014	38.990375
(2,4)(1,0)	-982.944123	38.860554	39.163585	38.976351
(6,2)(0,1)	-980.948833	38.860739	39.239528	39.005485
(1,0)(1,0)	-987.951848	38.860857	38.974494	38.904281
(3,5)(1,0)	-980.966706	38.861439	39.240229	39.006186
(7,4)(0,1)	-977.976582	38.861827	39.354253	39.049997
(7,2)(1,1)	-978.978331	38.861895	39.316443	39.035591
(3,2)(0,1)	-983.979898	38.861957	39.127109	38.963279
(5,4)(0,0)	-980.980499	38.861980	39.240770	39.006727
(6,3)(0,0)	-980.983346	38.862092	39.240881	39.006839
(2,0)(1,0)	-987.014021	38.863295	39.014811	38.921194
(2,3)(2,0)	-983.017259	38.863422	39.166453	38.979219
(7,2)(1,2)	-978.020685	38.863556	39.355982	39.051727
(7,3)(1,2)	-977.021926	38.863605	39.393910	39.066250
(3,1)(2,1)	-983.028042	38.863845	39.166876	38.979642
(3,4)(2,1)	-980.034568	38.864101	39.280769	39.023322
(1,5)(1,0)	-983.048416	38.864644	39.167675	38.980441
(5,5)(0,2)	-978.057436	38.864997	39.357424	39.053168
(1,9)(1,1)	-978.069367	38.865465	39.357892	39.053636
(4,2)(1,0)	-983.072377	38.865583	39.168615	38.981381
(8,0)(1,2)	-979.103557	38.866806	39.321353	39.040502