

계절성 ARIMA 모형을 이용한 항공화물 수요예측: 인천국제공항발 유럽항공노선을 중심으로

민경창 · 전영인 · 하헌구*
인하대학교 물류전문대학원

Forecasting the Air Cargo Demand With Seasonal ARIMA Model: Focusing on ICN to EU Route

MIN, Kyung-Chang · JUN, Young-In · HA, Hun-Koo*
Graduate School of Logistics, Inha University, Incheon 402-751, Korea

Abstract

This study develops a forecasting method to estimate air cargo demand from ICN(Incheon International Airport) to all airports in EU with Seasonal Autoregressive Integrated Moving Average (SARIMA) Model using volumes from the first quarter of 2000 to the fourth quarter of 2009. This paper shows the superiority of SARIMA Model by comparing the forecasting accuracy of SARIMA with that of other ARIMA (Autoregressive Integrated Moving Average) models. Given that very few papers and researches focuses on air route, this paper will be helpful to researchers concerned with air cargo.

본 연구는 2000년 1사분기부터 2010년 4사분기 까지 인천국제공항에서 출발하여 유럽내 모든공항에 도착한 항공화물의 시계열 자료를 바탕으로 SARIMA 모형을 활용, 수요예측 모형을 구축하였다. 또한 SARIMA 모형을 활용하여 구축한 예측모형을 기존에 주로 활용되어진 ARIMA 모형과 그 예측정확성을 비교 분석함으로써 SARIMA 모형의 정확성을 확인하였다. 현재 국내교통수요를 예측하는 부문에 있어서 SARIMA 모형을 활용한 경우는 극히 드물다. 또한 공항의 총 여객수나 화물량이 아닌 항공노선의 수요예측에 관한 연구 역시 찾아보기 힘들다. 이러한 상황 하에서, SARIMA 모형을 활용하여 인천국제공항 발 유럽노선의 항공화물 수요를 예측한 본 연구는 상당히 큰 의미가 있다고 생각된다.

Key Words

Air Cargo Demand, ARIMA, Seasonal ARIMA, Demand Forecasting, EU Air Cargo, Unit-root Test
항공화물수요, ARIMA, 계절성 ARIMA, 수요예측, 유럽항공화물, 단위근 검정

* : Corresponding Author
hkha@inha.ac.kr, Phone: +82-32-860-8232, Fax: +82-32-860-8226

Received 20 July 2012, Accepted 22 February 2013

I. 서론

1990년대 이후, 우리나라의 산업이 고도화됨에 따라 기존의 부피가 큰 품목과 더불어, 작은 부피의 고부가가치 제품인 반도체, 전자기기 등의 수출비중이 증가하고 있는 추세이다. 이러한 고부가가치 품목의 운송에 있어서 가장 중요한 특성 중 하나는 바로 신속성인데, 이러한 고부가가치 제품들의 수출량이 증가함에 따라 항공기를 이용한 교역량 역시 꾸준히 증가하는 추세를 보이고 있다.

지난 10년간 우리나라의 수출수단별 국제화물 수출량과 교역 상대국별 교역액을 살펴보면, 항공운송을 활용한 화물교역량이 꾸준히 증가함과 동시에 EU와의 교역이 크게 증가하였음을 알 수 있다. 2010년 현재 항공운송의 비중은 전체 교역량의 채 1%에도 미치지 못하지만, 운송되는 화물들의 특성상 교역액 비중은 20%이상 높게 올라가게 된다. 이렇듯 항공운송의 중요성이 대두되어 지고 있는데 반해, 그동안 항공화물에 대한 연구는 여객부문에 비해 더디게 진행되어져왔다. 교역상대의 관점에서 2010년 현재(교역액 기준), EU는 중국에 이어 두 번째로 큰 비중을 차지하는 교역상대가 되었으나, 기존의 주요 교역 상대국인 미국, 일본 그리고 중국에 비해 상대적으로 관심을 받지 못하였다. 이러한 현재의 상황에서 기존의 주요 교역 상대국에 대한 연구와 더불어 EU와의 교역에 대한 연구의 필요성이 높아지고 있다.¹⁾

본 연구에서는 기존에 주로 연구가 이루어져왔던 미국, 일본, 중국이 아닌 EU와의 교역과 관련하여 시계열 모형을 활용, 인천국제공항에서 출발하여 유럽전체공항의 도착하는 항공화물 수요의 예측에 대해 연구하였다. 유럽항공노선의 수요를 예측하는 것은 향후 항공사들의 경영전략을 수립하는데 있어서 뿐만 아니라, 항공관련 교통정책 수립에 있어서 큰 도움이 될 것이다. 만약 항공사들이 유럽 항공노선의 미래 수요를 알 수 있다면, 수요에 맞춰 공급량을 조절함으로써, 공급부족 시 발생하는 판매 손실을 막을 수 있고, 동시에 초과공급에 따른 손실을 줄일 수 있을 것이다. 더 나아가 향후 EU와의 항공협정에 있어서 큰 도움이 될 수 있을 것이다.

본 연구에서는 인천국제공항에서 출발하여 유럽전체 공항에 도착한 항공화물의 분기별 시계열 자료를 활용하

였다. 구체적인 기간은 2000년 1사분기부터 2010년 4사분기까지 총 44개의 분기별 항공화물 수송실적을 활용하였다. 인천국제공항이 개항하기 이전(2000년 3월 29일 이전)의 경우에는, 김포공항의 항공화물 수송실적을 활용하였다.

본 연구의 사용된 분석방법론은 시계열분석 기법(Time Series Analysis)이다. 구체적으로 시계열분석 기법 중에서도 시계열 자료가 계절성(Seasonality)이나 혹은 어떠한 주기적 특성(Periodicity)을 지니고 있을 경우에 적합한 Seasonal Autoregressive Integrated Moving Average(SARIMA) 기법을 사용하였다.

기존의 선행연구들 중 인천국제공항에서 출발하여 유럽공항의 도착하는 항공화물에 대한 논문들은 전무하고, 연구대상을 유럽공항이 아닌 다른 지역으로 확장하여도 항공수요에 대한 연구는 주로 여객분야에 대해 중점적으로 이루어져 왔고, 항공화물관련 연구는 상대적으로 적었다. 항공화물관련 연구 중에서도 특정 공항의 전체 화물수요를 예측하는 공항기준의 연구가 주를 이루어왔고, 노선별 예측에 관한 연구는 찾아보기가 힘들다. 이는 국내 뿐 아니라 해외의 경우에도 마찬가지이다.

Yoon J. S. et al. (2010)은 계절형 다변량 시계열 모형을 이용하여 우리나라 전체의 국제 항공화물 및 여객수요를 예측하였다. Totamane R. et al. (2009)은 The Weighted Majority Algorithm을 활용하여 항공화물 수요 및 load-factor를 예측 하였다. Chen C. F. et al. (2009)은 Holt-Winters 모형과 SARIMA 모형, 그리고 GRE 모형을 활용하여 항공기를 이용해 대만에 방문한 일본, 홍콩 미국인 방문객 수를 예측하였다. Wu M., Morrell P. (2007)은 회귀분석을 이용하여 중국공항들의 항공화물 물동량을 예측하였다. Coshall J. (2006)은 ARIMA 모형을 활용하여 항공기를 통해 유럽내 주요 16개 국가와 일본, 캐나다, 미국, 카나리아 제도도 출국하는 영국의 항공여객 수요를 예측하였다. Kim J. H. et al. (2005)는 SARIMA 모형, 회귀모형, 그리고 Harvey's Structural Time Series Model을 활용하여 호주의 방문한 방문객수를 체류기간별로 예측하였다. Jiang H. et al. (2003)은 회귀분석을 활용하여 중국, 홍콩, 대만의 주요공항들의 항공화물 수요를

1) 지난 2001년부터 2010년까지 EU와의 교역액은 동기간에 글로벌금융위기와 유럽재정위기가 발생하였음에도 불구하고, 연평균 약 12%씩 급격하게 증가하여 왔다. 이는 우리의 주요 교역상대국 중 중국을 제외하고는 가장 높은 수치이며, 글로벌 금융위기와 유럽재정위기가 발생하기 이전까지는 대 유럽 상품수출액은 연평균 21%씩 증가하여왔다. 글로벌 금융위기로 인하여 일시적으로 감소했던 교역액은 2010년부터 다시 증가하는 추세를 보이고 있다.

예측하였다. Lim C. et al. (2002)은 ARIMA 방법을 활용하여 홍콩, 말레이시아, 싱가포르에서 호주에 입국한 관광객 수요를 예측하였다.

논문의 방법론적인 측면에서 선행연구를 살펴보았을 때, 국내의 경우, 기타 여러 분야에서 SARIMA 모델을 활용한 연구들이 존재하지만, 항공수요를 예측하는데 있어서 SARIMA 모델을 활용한 경우는 찾아보기가 힘들다. 그나마 항공수요가 아닌 교통수요의 경우로 그 범위를 넓혔을 때, Lee J. M. et al. (2011)이 국내 철도여객부문의 수요를 예측하는데 활용한 경우와 Kim C. B. (2007)이 해상운송 물동량을 예측하는데 사용한 경우를 제외하고는 찾아보기 힘들다.

Seasonal ARIMA 모형은 기존 수요예측에서 많이 활용되어진 ARIMA 모형의 단점을 보완한 모형으로써, 수요예측에 있어서 유용한 방법론으로 활용될 수 있다. 앞에서 살펴본바와 같이 아직까지 교통수요 예측부문에 있어서 SARIMA 모형은 그 효용성에 비해 실제로 많이 활용되어지지 않고 있는 것이 현실이다. 또한 노선별 항공화물에 대한 수요예측도 많이 이루어지지 않고 있는 것이 현재 항공화물 수요예측연구 부문의 현실이다. 본 연구는 그동안 상대적으로 연구가 적었던 노선별 항공화물 수요를, 국내 항공수요 예측에서 아직까지 많이 활용되어지지 않은 SARIMA 모형을 활용하여 예측한 하나의 사례로서 그 의의가 있다. 본 연구를 시작으로 항공수요 예측부문 뿐 아니라 다른 교통분야 수요 예측까지, 보다 많은 분야에서 SARIMA 모형이 활용될 것이라 기대된다.

II. 방법론

1. ARIMA 모형 및 SARIMA 모형

ARIMA(Autoregressive Integrated Moving Average) 모형은 'Y_t는 설명변수 X_t에 의해 설명된다.'는 방정식 모형이 아니라, 'Y_t는 자신의 과거값 혹은 시차값과 확률적 오차항에 의해 설명된다.'는 경제 시계열의 확률적 특성에 기반을 둔 예측방법론이다.

ARIMA 모형과 같은 Box-Jenkins 방법론을 활용하여 미래를 예측하기 위해서는 주어진 시계열 자료(time series data)가 안정적(stationary)인지 여부를 우선적으로 확인하여야 한다. 만약 시계열 자료가 안정적이지 않을 경우, 즉 불안정적일 경우에 차분(difference, 혹은 적분(Integrated))의 과정을 거쳐 자료를 반드시

안정적인 시계열로 바꾼 후 모형에 적용시켜야 하는데, ARIMA 모형이란 불안정적인 시계열 자료를 적분의 과정을 통해 안정적으로 변환시킨 후, ARMA모형에 적합시키는 모형을 의미한다.

ARIMA(p,d,q) 모형의 기본 형태는 식(1)과 같다.

$$(1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p)(1 - L)^d Z_t = \delta + (1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q) \epsilon_t \tag{1}$$

- Z_t : 원시계열 자료
- t : 시간을 나타내는 연산자
- ε_t : N(0,σ²)을 따르는 오차항, 백색잡음
- L : 후향연산자
- p : 자기회귀(Autoregressive)항의 차수
- q : 이동평균(Moving Average)항의 차수
- d : 차분의 차수
- δ : 상수

식(1)에서 1 - φ₁L - φ₂L² - ... - φ_pL^p 은 자기회귀(Auto-regressive; AR)항을 의미하고, 1 - θ₁L - θ₂L² - ... - θ_qL^q 은 이동평균(Moving Average; MA)항을 의미한다. 그리고 AR항과 MA항은 각각 식(2)와 같이 표현될 수 있다.

$$\phi_p(L) = 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p \tag{2}$$

$$\theta_q(L) = 1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q$$

위의 연산자를 사용하여 ARIMA(p,d,q) 모형을 식(3)과 같이 간단하게 표현 할 수 있다.

$$\phi_p(L)(1 - L)^d Z_t = \delta + \theta_q(L) \epsilon_t \tag{3}$$

ARIMA(p,d,q) 모형에서 만약 d=0이라면, ARMA(p,q)모형이 된다.

ARIMA 모형은 다양한 분야의 수요예측을 하는데 있어서 사용되고 있다. 하지만 시계열 자료의 주기적인 특성을 반영하기 힘들다는 ARIMA 모형의 단점으로 인하여, 만약 원시계열 자료가 주기적인 특성, 계절성을 지닌 경우에 ARIMA 모형을 적용시키기에는 다소 무리가 있다. 이러한 ARIMA 모형의 문제점을 보완하기 위하여 등장한 모형이 SARIMA 모형이다.

SARIMA 모형은 수요를 예측함에 있어서 ARIMA 모형에서처럼 예측하고자 하는 시점과 가까운 과거 자료들을 이용할 뿐만 아니라, 원 자료의 주기적인 특성을 감

안하여 그 이전 주기의 자료를 추가적으로 활용하게 된다. 이러한 접근을 통해 최근의 정보와 이전 주기의 정보를 모두 반영하는 특성을 갖게 된다.

SARIMA(p,d,q)(P,D,Q)s 모형은 식(4)와 같다.

$$\phi_p(L)\Phi_P(L^s)(1-L)^d(1-L^s)^D Z_t = \delta + \theta_q(L)\Theta_Q(L^s)\epsilon_t \quad (4)$$

- P : 계절AR항의 차수
- Q : 계절MA항의 차수
- D : 계절차분의 차수

식(4)는 기존의 식(3)에서 계절성 부문인 $\Phi_P(L^s)(1-L^s)^D Z_t = \delta + \theta_q(L^s)\epsilon_t$ 가 추가적으로 결합된 형태를 지닌다. 여기서 $\Phi_P(L^s)$ 과 $\Theta_Q(L^s)$ 은 각각 SAR 항과 SMA항을 의미하며 식(5)와 같이 표현될 수 있다.

$$\phi_p(L^s) = 1 - \phi_1 L^s - \phi_2 L^{2s} - \dots - \phi_p L^{ps} \quad (5)$$

$$\theta_q(L^s) = 1 - \theta_1 L^s - \theta_2 L^{2s} - \dots - \theta_q L^{qs}$$

앞서 언급한 바와 같이, Box-Jenkins 방법론(ARIMA, SARIMA 등)을 사용하기 위해서는 모형에 적용되는 시계열 자료가 반드시 안정적이어야 한다. 이러한 시계열 자료의 특성을 ‘안정성(Stationary)’라고 한다. Box-Jenkins 모형은 기본적으로 어느 시점에서나 특히 미래에 있어서 일정하다고 가정되어야 한다. 따라서 만약 시계열 자료가 안정적이지 않다면, 이 자료를 통해 추측된 어떠한 모형도 안정적이라고 판단할 수 없게 되고, 나아가 모형에 사용된 시계열 자료가 예측을 수행함에 있어서 유효한 기반을 제공할 수 없기 때문이다.

2. SARIMA 모형 추정 방법

주어진 시계열 자료를 보고 시계열이 어떠한 과정을 따르는지 구분하고, 더 나아가 모형 추정 및 미래 예측을 하기 위해서는 Figure 1과 같이 크게 식별(Identification), 추정(Estimation), 진단(Diagnostic), 예측(Forecasting) 이렇게 4단계를 거친다.

식별(Identification)단계에서는 SARIMA(p,d,q)(P,D,Q)s의 각각의 차수인, ‘p’, ‘d’, ‘q’, ‘P’, ‘D’, ‘Q’를 결정하게 된다. 우선 시계열 자료가 안정적인지 여부를 판

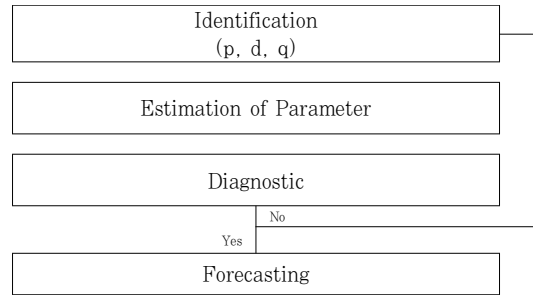


Figure 1. Flow chart of SARIMA

단하기 위해 안정성 검정을 실시해야 한다. 안정성 검정은 크게 그래프 분석, 상관도표 분석, 단위근 검정 등이 있는데 이러한 안정성 검정을 통하여 ‘d’와 ‘D’의 값이 결정된다. 다음으로는 시계열 자료의 상관도표(Correlogram)를 통해 확인할 수 있는 자기상관 함수(Autocorrelation function: ACF) 및 편 자기상관 함수(Partial Autocorrelation function: PACF)를 관찰하거나 DF-GLS 방법론을 활용하여, AR(Autoregressive)의 차수 ‘p’, MA(Moving Average)의 차수 ‘q’, SAR (Seasonal Autoregressive)의 차수 ‘P’, SMA(Seasonal Moving Average)의 차수인 ‘Q’의 값을 결정하게 된다.2)

Y_t 라는 변수의 시차 k 의 자기상관함수는 ρ_k 로 표시되고 식(6)과 같이 정의 된다.

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{\sum (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum (Y_t - \bar{Y})^2} \quad (6)$$

편자기상관 ρ_{kk} 은 k 시기만큼 떨어진 시계열 자료간의 상관관계를 의미하는 것으로서, 이때 중간변수들의 영향력은 통제되어진 상태이다. 편자기상관값이 중요한 이유는 두 시차 사이에 존재하는 중간변수들이 Y_t 와 Y_{t-k} 간의 상관관계에 큰 영향을 미칠 경우, 이러한 영향을 제거하여 상관관계를 파악할 수 있기 때문이다.

추정(Estimation) 단계는 식별의 단계를 통해서 찾아낸 ‘p’, ‘d’, ‘q’, ‘P’, ‘D’, ‘Q’의 적절한 값을 결정한 후, 선택된 차수에 의해 결정된 모형에 포함되어 있는 각 항, 즉, AR, MA, SAR, SMA항 각각의 모수를 추정하는 단계이다. 모수를 추정하는데 있어서 널리 사용되는 방법으로는 적률 추정법(Method of Moment Estimation),

2) 시계열 자료의 주기성을 나타내는 ‘s’의 경우에는, 시계열 자료가 월별, 분기별 등에 따라 월별의 경우에는 ‘12’, 분기별의 경우에는 ‘4’와 같이 특별한 과정 없이 바로 결정할 수 있다.

최소제곱 추정법(Least Squares Estimation Method), 최대우도 추정법(Maximum Likelihood Estimation Method), 비선형 추정법(Nonlinear Estimation Method) 등이 있다. 이러한 방법론들을 통하여 모형을 추정할 때, 다양한 차수의 변화에 따라 변화하는 AIC(Akaike Information Criterion), SC(Schwarz Criterion), BIC (Bayesian Information Criterion) 등의 값을 비교하여 보다 작은 값을 갖는 모형을 추정함과 동시에 각 항의 모수에 대한 유의성 검정 결과 및 모델의 간결성을 고려하여 최종 모형의 차수를 선택하여야 한다.

진단(Diagnostic)의 단계란, 다양한 추정방법에 의해 추정된 모형의 추정량의 분포특성 등을 이용하여 유의성 검정을 시행한 후, 추정된 모수들이 유의할 경우, 추정된 모형이 주어진 시계열 자료를 잘 설명하는가를 판단하는 단계를 의미한다. 진단은 주로 잔차분석(Residual Analysis), 과대적합진단(Overfitting Diagnostics) 등에 의해서 판단된다. Figure 1에서 보이는 바와 같이 진단의 단계를 통해 추정모형이 이상이 없다고 판단되면, 예측(Forecasting) 단계로 넘어가 예측모델로서 예측에 활용되어지고, 만약 이상이 있다고 판단이 내려지게 되면, 식별의 단계로 돌아가 다시 모형을 추정하는 과정을 거치게 된다.

예측(Forecasting)의 단계는 최종단계로서, 앞선 세 단계에 걸쳐서 선택되어진 모델을 활용하여 미래수요를 예측하는 단계이다. 예측된 수요는 시간이 지난 후, 실제 수치와의 비교를 통해 모델의 검증을 할 수 있고, 또한 그 이후의 수요예측을 하는데 있어 참고할 수 있다.

III. 모형 추정

본 연구에 사용된 자료는 인천국제공항에서 출발하여 유럽전체공항에 도착한 항공화물의 분기별 시계열 자료로서, 매달 항공진흥협회에서 발간하고 있는 「항공통계」와 한국공항공사 정보관리팀으로부터 습득한 월별 자료 중 순수화물 물동량(ton)을 분기별 자료로 통합하였다. 구체적인 기간은 2000년 1월부터 2010년 12월까지의 시계열 자료를 2000년 1사분기부터 2010년 4사분기까지 총 44개의 분기별 항공화물 수송실적으로 통합하였다.³⁾

연구에 사용된 시계열 자료는 자연로그를 취하여 분석에 활용 되었다.

1. 안정성 검정

앞서 언급한 바와 같이, BOX-Jenkins방법론을 이용하기 위해서는 사용되어지는 시계열 자료가 안정적이여야만 한다. 그렇기 때문에 모형을 추정하기에 앞서, 시계열 자료가 안정적인지 여부를 확인하기 위해 안정성 검정을 시행하여야 한다. 또한 모형에 사용되는 시계열 자료가 분기별 자료이기 때문에, 추가적으로 계절 단위근 검정(Seasonal Unit root test)을 시행하여야만 한다.

본 연구에서는 상관도표(Corrgram) 분석과 대표적인 단위근 검정(Unit root test) 중 하나인 Augmented Dickiey-Fuller(ADF) 검정을 통해 시계열 자료의 안정성 여부를 확인하고, 추가적으로 Hylleberg-Engle-Granger-Yoo(HEGY) 검정(1990)을 통해 시계열이 계절 단위근을 가지고 있는지 여부를 확인하였다.

Table 1을 살펴보면 자기상관계수가 1차에서 높은 값(0.9080)으로 시작해서 시차가 길어질수록 감소해 나가고 있는 것으로 보아 시계열 자료가 불안정적임을 알 수 있다. 이는 곧 시계열자료가 평균에 대하여 불안정적이거나 분산에 대하여 불안정적, 혹은 둘 모두에 대해 불안정적이라는 것을 의미한다. Table 2는 원 시계열 자료에 대한 ADF 검정결과를 나타낸 것이다. ADF 검정은 임의행보(Random walk)과정에 표류경향(Drift)이 없을 경우와 있을 경우, 그리고 확정적(Deterministic) 추세와 확률적(Stochastic) 추세가 모두 존재할 수 있는 3가지 경우에 대해 모두 수행된다.

$$\Delta Y_t = \delta Y_{t-1} + \sum_{i=1}^m \alpha_i \Delta Y_{t-i} + u_t \quad (7)$$

$$\Delta Y_t = \beta_1 + \delta Y_{t-1} + \sum_{i=1}^m \alpha_i \Delta Y_{t-i} + u_t \quad (8)$$

$$\Delta Y_t = \beta_1 + \beta_2 t + \delta Y_{t-1} + \sum_{i=1}^m \alpha_i \Delta Y_{t-i} + u_t \quad (9)$$

식(7)은 표류경향(Drift)이 없는 임의행보(Random walk)모형, 식(8)은 표류경향이 있는 임의행보모형, 그리고 식(9)는 확정적 추세와 확률적 추세가 모두 존재하는 임의행보모형을 의미한다.

Table 2를 보면 표류경향이 있는 임의행보 모형의 경우에는 1% 수준 하에서 '시계열 자료가 단위근을 갖는다.'는, 즉, '시계열이 불안정적이다.'라는 귀무가설을 기각함을 알

3) 인천국제공항이 개항하기 이전(2000년 3월 29일 이전)에 경우에는, 김포공항의 항공화물 수송실적을 활용하였다.(단위: Ton)

Table 1. Correlogram of raw data

Lag	AC	PAC	Q	Prob>Q	Autocorrelation			Partial Autocorr.		
					-1	0	1	-1	0	1
1	0.9080	0.9315	38.808	0.0000						
2	0.8748	0.5064	75.687	0.0000						
3	0.7934	-0.1879	106.76	0.0000						
4	0.7571	0.3318	135.76	0.0000						
5	0.6531	-0.4535	157.9	0.0000						
6	0.5850	0.0648	176.13	0.0000						
7	0.4924	0.0746	189.39	0.0000						
8	0.4532	0.2573	200.93	0.0000						
9	0.3490	-0.3469	207.98	0.0000						
10	0.2875	0.0209	212.9	0.0000						
11	0.2024	-0.0489	215.41	0.0000						
12	0.1633	0.0861	217.1	0.0000						
13	0.0670	-0.2869	217.39	0.0000						
14	0.0084	-0.0904	217.4	0.0000						
15	-0.0644	-0.0429	217.69	0.0000						

* After log-transform

Table 2. Result of ADF unit-root test (raw data)

	tau value	p > t	lags
Random Walk	0.402	0.691	8
Random Walk with Drift	-2.606	0.007	8
Random walk with Drift and Trend	-0.672	0.975	8

* founded Lag value from DF-gls test (at STATA 11)

수 있다. 하지만 표류경향이 없는 임의행보모형과 확정적 추세와 확률적 추세가 모두 존재하는 임의행보모형의 경우에 모두 귀무가설을 기각할 수 없음을 알 수 있다. 그러므로 시계열 자료가 안정적이지 않다고 판단할 수 있다.

상관도표분석과 ADF 검정을 통해 원 시계열 자료가 안정적이지 못하다는 것을 확인하였으므로, 차분의 과정을 통해 자료를 안정적으로 변환시켜야만 한다. Table 3 과 Table 4는 시계열 자료를 1계 차분과 4계 계절 차분을 통해 변환된 시계열 자료에 대한 상관도 표와 ADF 검정 결과이다. Table 3을 살펴보면 자기상관이 거의 모든 시차에서 0주변을 떠돌고 있음을 알 수 있다. 또한 Table 4를 살펴보면 3가지 모두의 경우에 있어서 1% 수준 하에서 귀무가설이 기각됨을 알 수 있다.

추가적으로 1계 분기 차분과 4계 계절 차분을 통해 변환된 시계열 자료가 계절 단위원을 갖는지 여부를 판

악하기 위해 HEGY 검정을 추가로 실시하였다. HEGY 검정을 설명하기 위하여 우선 SARIMA 모형의 계절성 부분을 식(10)과 같이 변환해 보자.

$$\begin{aligned}
 (1-L^4) &= (1-L)(1+L+L^2+L^3) & (10) \\
 &= (1-L)(1+L)(1+L^2) \\
 &= (1-L)(1+L)(1-Li)(1+Li)
 \end{aligned}$$

이를 바탕으로 HEGY 검정의 기본적인 회귀식은 식 (11)과 같이 추정되고 실행된다.

$$\Phi(L)y_{4,t} = \pi_1 y_{1,t-1} + \pi_2 y_{2,t-1} + \pi_3 y_{3,t-2} + \pi_4 y_{3,t-1} + u_t \quad (11)$$

$$y_{1,t} = (1+L+L^2+L^3)y_t$$

$$y_{2,t} = -(1-L+L^2-L^3)y_t$$

Table 3. Correlogram of regular and seasonal differencing

Lag	AC	PAC	Q	Prob>Q	Autocorrelation			Partial Autocorr.		
					-1	0	1	-1	0	1
1	-0.0565	-0.0625	0.13432	0.7140						
2	0.0796	-0.0850	0.4081	0.8154						
3	0.0509	0.0894	0.52322	0.9138						
4	-0.4203	-0.5810	8.5928	0.0721						
5	0.0452	-0.0301	8.689	0.1221						
6	-0.1570	-0.0459	9.8836	0.1296						
7	-0.0096	0.0107	9.8882	0.1950						
8	-0.0466	-0.3413	10.000	0.2650						
9	-0.0523	-0.0257	10.146	0.3388						
10	0.1100	0.0469	10.813	0.3723						
11	-0.0484	0.1198	10.947	0.4477						
12	-0.0245	-0.4918	10.982	0.5304						
13	0.0388	0.0385	11.075	0.6045						
14	-0.0138	0.3838	11.087	0.6792						
15	0.1195	0.4379	12.039	0.6761						

* After log-transform

Table 4. Result of ADF unit-root test (data after regular and seasonal differencing were applied)

	tau value	p > t	lags
Random Walk	-4.658	0.000	3
Random Walk with Drift	-4.539	0.000	3
Random walk with Drift and Trend	-4.556	0.001	3

* founded Lag value from DF-gls test (at STATA 11)

Table 5. Result of HEGY test (data after regular and seasonal differencing were applied)

	Frequency			lags
	Zero ($t : \pi_1 = 0$)	Biannual ($t : \pi_2 = 0$)	Annual ($F : \pi_3 = 0 \cap \pi_4 = 0$)	
No-constant	-4.658 (0.0000)	-5.232 (0.0000)	43.037 (0.0000)	0
Constant	-4.539 (0.0000)	-5.159 (0.0000)	42.059 (0.0000)	0
Constant, Trend	-4.556 (0.0000)	-5.095 (0.0000)	41.474 (0.0000)	0
Constant, Trend, Seasonal Dummies	-4.556 (0.0000)	-5.095 (0.0000)	41.474 (0.0000)	0

* founded Lag value, AIC and BIC from DF-gls test (at STATA 11)

* t-values of 'Constant, Trend', 'Constant, Trend, Seasonal Dummies' were same. but, critical values were different

$$y_{3,t} = -(1 - L^2)y_t$$

$$y_{4,t} = (1 - L^4)y_t$$

각 주기의 단위근의 존재는 식(11)의 $\pi_1, \pi_2, \pi_3, \pi_4$ 의

추정치들에 의해 결정된다. 식(10)과 식(11)을 바탕으로 만약 $L=1$ (비계절주기, 영빈도(zero frequency))에서 단위근이 존재한다면 $\pi_1 = 0$, $L=-1$ (반년 주기)에서 단위근이 존재한다면 $\pi_2 = 0$, $L=\pm 1$ (1년 주기)에서 단위

근이 존재한다면 $\pi_3 = \pi_4 = 0$ 이라는 것을 추론할 수 있다.⁴⁾ 그러므로 $H_0 : \pi_1 = 0$, $H_0 : \pi_2 = 0$, $H_0 : \pi_3 = \pi_4 = 0$ 에 대한 가설검정을 통하여 단위근의 존재여부를 확인할 수 있다. 만약 ' $\pi_1 \neq 0$ ', ' $\pi_2 \neq 0$ ', ' $\pi_3 \neq 0$, $\pi_4 \neq 0$ ' 이라면, y_t 는 정상적인 시계열이라고 판단할 수 있다.

Table 5는 1계 분기 차분 및 4계 계절 차분된 자료에 대한 HEGY 검정 결과를 나타낸다. HEGY 검정 결과 모든 쿠무가설이 기각됨을 알 수 있다. 그러므로 1계 차분 및 4계 계절 차분된 자료는 계절 단위근도 갖지 않고, 안정적이라고 판단 할 수 있다.

2. 모형 추정

SARIMA(p,d,q)(P,D,Q)s 모형을 추정하는데 있어서 핵심적인 사항은 바로 'p', 'd', 'q', 'P', 'D', 'Q'의 값을 찾는 것이다. 우선 'd'와 'D'의 값은 앞서 수행한 안정성 검정을 통해 'd=1', 그리고 'D=1'이라는 것을 알 수 있었다. 다음으로는 'p', 'q', 'P', 'Q'의 값을 추정하여야 한다. 'p', 'q', 'P', 'Q' 각각의 값을 결정하는데 있어서 크게 3가지 원칙이 있다. 첫 번째로, Akaike Information Criterion(AIC)와 Bayesian Information Criterion(BIC)의 값을 살펴보아야 하고, 두 번째로는, 각 항들의 계수들의 z-value를 확인해야 한다. 그리고 마지막으로, 모델의 간결성(parsimonious) 여부이다.

첫 번째 원칙인 AIC와 BIC의 추정식은 식(12)와 같다.

$$AIC = -2 \times \ln(\text{likelihood}) + 2 \times k \tag{12}$$

$$BIC = -2 \times \ln(\text{likelihood}) + \ln(N) \times k$$

k : 모수의 수

N : 관측수

식(12)를 살펴보면, AIC와 BIC의 값은 우도값이 높을수록 작아지고, 모형내 모수의 수가 많아질수록 높아진다는 것을 알 수 있다. 그러므로 각 AIC와 BIC는 절대 값이 높을수록(값이 더욱 '음(-)'일수록), 모형의 적

절성도 높아진다는 것을 의미한다.⁵⁾

두 번째로, 모형추정을 통해 각 항들, 즉 AR항, MA항, SAR항과 SMA항들의 계수를 추정해볼 수 있다. 그리고 여기서 추정된 계수들에 대한 유의성 검정을 통해 계수들의 적절성 여부와 더 나아가, 모형의 적절성 여부를 판단해야 한다.

마지막으로 확인하여야 할 것이 모델의 간결성인데, 모델의 간결성은 곧 실용성과 연결된다고 할 수 있다. 어떠한 모델이 아무리 높은 예측력을 갖고 있다 하더라도, AR항, MA항, SAR항과 SMA항들의 차수가 너무 높게 되면, 실제 이를 활용하는데 있어서 실용성이 떨어지게 된다. 그러므로 모델을 추정하는데 있어서 최대한 간결하게 하는 것을 원칙으로 한다.

앞서 시계열 자료의 안정성 검정을 통해 우리는 '1계 분기 차분 및 4계 계절 차분된 시계열 자료'가 안정적인 것을 알았고, 그 과정인 ADF검정과 HEGY검정을 통해 최적의 lag값을 알아냈다. 일반적인 단위근이 존재하는지 여부를 확인하기 위한 ADF 검정 과정에서 최적의 lag값이 '3'임을 알아냈고,⁶⁾ 계절 단위근의 존재여부를 파악하기 위한 HEGY 검정을 통해 계절파트의 최적의 lag값은 '0'임을 알 수 있었다.⁷⁾

앞서 언급한 바와 같이 SARIMA 모형은 일반적인 ARIMA(p,d,q)모형에 계절파트가 포함된 모형이다. 결국 SARIMA(p,d,q)(P,D,Q)s에서 'p'와 'q'는 일반적인 ARIMA에서의 lag값이고, 'P'와 'Q'는 계절파트의 lag값을 의미한다. 같은 의미에서, ADF 검정과정에서 추정된 최적의 lag값을 'p'와 'q'의 값으로 파악하고, HEGY 검정과정에서 추정된 최적의 lag값을 'P'와 'Q'의 값으로 결정할 수 있다. 이러한 과정을 통해 'p'와 'q'의 최대 값은 '3'이라는 결론을 얻을 수 있다.⁸⁾ 이러한 과정을 통해 일단 최적의 모형으로 판단되는 모형이 SARIMA(3,1,3)(0,1,0)₄ (이하, Model(1))이다. 그렇다고 해서 이렇게 선택되어진 모형이 최적의 모형이라고 할 수는 없다.

앞서 언급한바와 같이 AIC와 BIC의 값, 계수에 대한 t-value, 그리고 간결성의 원칙을 바탕으로 선택되어진 모형이 과연 적절한지 여부를 살펴보아야 한다.

4) S. Hylleberg, R.F. Engle and C.w.J. Granger, and B.S. Yoo, Seasonal Integration And Cointegration, Journal of Econometrics 44(1990) 215-238. North-Holland

5) 모수의 계수가 많아진다는 것은 '항(term)'의 수가 증가함을 의미하고, '항'의 수가 증가할수록 '우도값(likelihood)값이 높아지는 성향이 있다. 그렇기 때문에 '모수의 수'와 '우도값' 사이에는 trade-off 관계가 형성된다. 이런 의미에서 볼 때, AIC와 BIC의 값은 이러한 trade-off 관계를 감안해서 모델을 선택할 수 있게 해준다.

6) DF-gls test

7) AIC 및 BIC 값을 활용

8) df-gls검정을 통해 ('p'와 'q'의) 최적 lag값은 3이라는 것을 알아냈었다.

Table 6. Estimated model

		Model(1)		Model(2)	
		SARIMA(3,1,3)(0,1,0) ₄		SARIMA(1,1,3)(0,1,0) ₄	
		coef (Std. Err.)	z-value (p) z	coef (Std. Err.)	z-value (p) z
AR	AR(1)	0.8311468 (0.4724744)	1.76 (0.079)	0.6230746 (0.1325155)	4.70 (0.000)
	AR(2)	-0.2284318 (0.5306256)	-0.43 (0.667)	-	-
	AR(3)	-0.0682654 (0.1523445)	-0.45 (0.654)	-	-
MA	MA(1)	-1.099807 (0.3152403)	-3.49 (0.000)	-0.9625017 (0.087687)	-10.98 (0.000)
	MA(2)	1.099853 (0.3152514)	3.49 (0.000)	0.9625016 (0.087688)	10.98 (0.000)
	MA(3)	-1.000013 (0.0000353)	-0.00028 (0.000)	-0.999999 (0.00000681)	-150000 (0.000)
SAR		-	-	-	-
SMA		-	-	-	-
Constant term		-0.0055904 (0.0036183)	-1.55 (0.122)	-0.0048725 (0.0039451)	-1.24 (0.217)
Number of obs		39		39	
Likelihood		49.1337		48.55653	
AIC		-82.26739		-87.11307	
BIC		-68.9589		-78.79526	

우선 모형을 추정하는데 있어서 앞서 추정한 최적의 'p'와 'q'의 값이 '3'이고, 'P'와 'Q'의 값이 '0'이라는 것에서 출발하여 간결성의 원칙을 따르기 위해 각 항들의 값의 범위를 식(13)과 같이 정의하였다.⁹⁾

$$\begin{aligned}
 p: 0 \leq p \leq 3 & \quad (13) \\
 q: 0 \leq q \leq 3 \\
 P: 0 \leq P \leq 0 \\
 Q: 0 \leq Q \leq 0
 \end{aligned}$$

Table 6은 식(13)에서 정의한 조건에 따라 선택 가능한 총 15개의 모형 중, 사전적으로 적합할 것이라고 판단되었던 Model(1)과 15개의 선택가능 모형 중 AIC와 BIC의 값 및 Z-test¹⁰⁾ 결과에 의해 최적으로 선택

된 Model(2)를 나타낸 것이다.¹¹⁾

사전적으로 최적의 모형으로 판단되었던 Model(1)의 경우, Z-test에 따라 MA항들은 유의미한 것으로 나타났으나, AR항들이 무의미 한 것으로 나타났다. 또한 AIC와 BIC의 값 역시 Model(2)의 비례 높게 나타났다. 그렇기 때문에 사전적으로 선택된 Model(1)의 경우, Model(2)에 비해 적합하지 못하다고 판단되어진다. 또한 다른 13개의 모델을 살펴본 결과, 역시 Model(2)가 가장 적합하다고 판단되었다. 그러므로 본 연구의 결과, 인천국제공항에서 출발하여 유럽 전체 공항의 도착한 분기별 화물량의 수요를 예측하기 위한 최적의 모델은 SARIMA(1,1,3)(0,1,0)₄ 으로 나타났다.

최적의 모델로 추정된 SARIMA(1,1,3)(0,1,0)₄ 모형은 식(14)와 같이 나타낼 수 있다.

$$\begin{aligned}
 \Delta Y_t - \Delta Y_{t-4} \\
 = 0.6230746(\Delta Y_{t-1} - \Delta Y_{t-5}) + \epsilon_t + 0.9625017\epsilon_{t-1} \\
 - 0.9625016\epsilon_{t-2} + 0.999999\epsilon_{t-3} - 0.0048725 \quad (14)
 \end{aligned}$$

$$\begin{aligned}
 \Delta Y_t = Y_t - Y_{t-1} \\
 \epsilon_t = N(0, \sigma^2) \text{을 따르는 오차항, 백색잡음}
 \end{aligned}$$

식(14)를 Y_t에 관해 나타내면,

$$\begin{aligned}
 Y_t = 1.6230746 Y_{t-1} - 0.6230746 Y_{t-2} + Y_{t-4} \\
 - 1.6230746 Y_{t-5} + 0.6230746 Y_{t-6} + \epsilon_t \\
 + 0.9625017\epsilon_{t-1} - 0.9625016\epsilon_{t-2} + 0.999999\epsilon_{t-3} \\
 - 0.0048725 \quad (15)
 \end{aligned}$$

식(15)에 나타난 바와 같이, SARIMA(1,1,3)(0,1,0)₄에서 물동량 Y_t는 Y_{t-1}, Y_{t-2}, Y_{t-4}, Y_{t-5}, Y_{t-6}과 ε_{t-1}, ε_{t-2}, ε_{t-3}의 값에 의해 결정된다. 즉, 시계열 자료가 분기별 자료인 것을 감안하였을 때 예측시점을 기준으로 1년 이내의 경우, 1분기전과 2분기전, 그리고 예측시점 기준 1년 이전의 경우, 4분기전과 5분기

9) '간결성의 원칙'을 따르기 위해 lag값의 범위를 추정한 앞서 추정한 lag값보다 작거나 같은 범위에 있는 lag값들을 모형추정에 활용하였다. ('간결성의 원칙'을 떠나서 추정된 lag값보다 큰 값을 넣어서 살펴보면 'p'와 'q'의 경우 단위근이 존재하는 형태의 시계열로 나타났고, 'P'와 'Q'의 경우 AIC와 BIC의 값이 급격히 떨어지는 결과를 나타내었다.)

10) 본 연구에서 Maximum Likelihood Estimation을 통해 모형이 추정되어졌는데, 이때 n>30이므로, 정규분포를 따른다고 가정하여 Z-test를 실시하였다.

11) 총 16개의 가능한 모델 중, SARIMA(0,1,0)(0,1,0)₄를 제외하면 총 15개의 모델의 경우가 발생한다. Table 6에 제시된 Model(2)를 제외하고는 나머지 14개 모델 모두, Z-value 검정(유의수준 5% 수준 하)에 결과, 탈락되었다.

전, 그리고 6분기전의 물동량이 예측시점의 물동량을 결정짓는 것으로 추정된다고 할 수 있다. 앞서 언급한바와 같이 항공화물은 계절성을 갖는 화물종 하나이다. 계절성을 띄는 시계열 자료의 경우, 예측에 있어서 최근 과거 값보다 전년도 동분기의 값이 더 설명력이 높게 되는데, 식(15)에 나타난 바와 같이 SARIMA(1,1,3)(0,1,0)₄의 경우, 전년도 동분기 값인 Y_{t-4} 가 추정에 활용되어 지게 된다. 또한 예측시점과 동일분기인 Y_t 와 Y_{t-4} 를 기준으로 최근 2분기의 값인 Y_{t-1} , Y_{t-2} , 그리고 Y_{t-5} , Y_{t-6} 의 값이 각각 추정에 활용되게 된다. 그러므로 본 연구에서 최적모형으로 추정된 SARIMA(1,1,3)(0,1,0)₄를 바탕으로 항공화물의 물동량은 예측시점으로부터 직전분기와 2분기 전 물동량, 그리고 직전년도 동분기의 물동량과 그 시점의 직전분기와 2분기 전의 물동량에 의해 설명된다고 추정된다. Y_{t-1} , Y_{t-2} , Y_{t-4} , Y_{t-5} , Y_{t-6} 각각의 계수를 살펴보면, 직전년도 동분기인 Y_{t-4} 의 경우 계수가 '1'인 것을 알 수 있다. 그러므로 SARIMA(1,1,3)(0,1,0)₄의 경우 물동량은 직전년도 동일분기의 물동량이 그대로 유지되면서, 나머지 Y_{t-1} , Y_{t-2} , 그리고 Y_{t-4} , Y_{t-5} , 추가적으로 ϵ_{t-1} , ϵ_{t-2} , ϵ_{t-3} 값들에 의해 변동된다고 추론할 수 있다

3. 모형 검증

1) 잔차항의 자기상관여부 진단

앞선 식별과 추정의 단계를 통해 SARIMA(1,1,3)(0,1,0)₄ 라는 모형을 추정하였다. 진단의 단계에서는 추정된 모형을 통해 자기상관(Autocorrelation)이 존재하는지 여부를 확인하여 자기상관이 존재한다면, 추정의 단계로 돌아가 다시 모형을 추정하게 되고, 자기상관이 나타나지 않는다면 해당모형이 유의미하다는 진단을 내릴 수 있다.

Table 7은 SARIMA(1,1,3)(0,1,0)₄의 잔차항의 Q 통계량을 나타낸 표이다. 표에서 시차에 따른 Q-통계량을 살펴보면 5% 유의수준 하에서 잔차항 사이에 자기상관이 존재하지 않는다는 귀무가설을 기각하지 못하는 것을 알 수 있다.¹²⁾ 즉, SARIMA(1,1,3)(0,1,0)₄ 모형에 대한 선택이 적절하였다고 할 수 있다.

Table 7. Q-value of SARIMA(1,1,3)(0,1,0)₄ residual

Lag	Q	Prob>Q
1	3.4556	0.0630
2	4.8527	0.0884
3	9.9835	0.0187
4	10.859	0.0282
5	10.867	0.0541
6	10.868	0.0925
7	11.228	0.1290
8	12.549	0.1283
9	12.801	0.1718
10	14.995	0.1323
11	15.464	0.1622
12	17.177	0.1833
13	16.829	0.2073
14	16.862	0.2636
15	16.891	0.3254

2) ARIMA 모형과의 비교

이 연구의 목적인 항공화물 수요예측에 있어서 SARIMA 모형의 선택이 과연 적절한지 여부를 파악하기 위해 시계열 분석 기법 중 가장 널리 사용되어 지고 있는 방법론인 ARIMA 모형과의 비교를 통해 그 적절성 여부를 파악해 보았다.¹³⁾ 구체적인 비교 방법은 SARIMA 모형에 추정된 것과 동일한 2000년 1사분기부터 2010년 4사분기까지 총 44개의 분기별 항공화물수송실적을 활용하여 ARIMA 모형을 추정한 후, 추정된 모형을 바탕

Table 8. ARIMA(1,1,1) model

		ARIMA	
		ARIMA(1,1,1)	
		coef (Std. Err.)	z-value (p) z
AR	AR(1)	-0.9999575 (0.0014024)	-713.04 (0.000)
MA	MA(1)	1.00958 (0.1604287)	6.29 (0.000)
Constant term		0.0225061 (0.011024)	2.04 (0.041)
Number of obs		43	
Likelihood		49.79973	
AIC		-91.59946	
BIC		-84.55466	

12) 시차3과 4를 제외하고는 귀무가설이 기각됨을 알 수 있다. 즉, SARIMA(1,1,3)(0,1,0)₄를 통해 추정된 값들의 잔차항 간에는 자기상관이 존재하지 않는다고 판단할 수 있다.

13) 안정성 검정의 과정 중, 원 시계열 자료가 계절차분의 과정을 거치지 않고서는 시계열 자료가 안정적으로 변환되지 않는 특성을 알 수 있다. 이는 계절차분의 과정을 나타낼 수 없는 ARIMA 모형을 예측모형으로 사용함이 적절치 못함을 의미하지만, SARIMA 모형과의 비교를 위해서 사전적으로 안정적이라 전제하고 ARIMA 모형을 추정하였다.

으로 2011년 1사분기부터 2011년 4사분기까지의 수요를 예측하여, SARIMA 모형의 예측치와 함께 실제 수송량과의 비교를 통해 적합성 여부를 판단하였다. Table 8은 수송실적을 활용하여 추정된 ARIMA(1,1,1) 모형을 나타낸 것이다. Table 8을 살펴보면, 본 연구에서 최적의 모델로 추정된 SARIMA(1,1,3)(0,1,0)₄ 모형과 비교해서 AIC와 BIC의 값이 모두 낮게 나타났다.

만약 ARIMA 모형을 추정하는 과정에서 어떠한 문제점도 발생하지 않았을 경우라면 우리는 본 연구의 모형을 추정하는데 있어서 ARIMA모형이 SARIMA모형보다 더 적합하고 나아가서 ARIMA(1,1,1)이 SARIMA(1,1,3)(0,1,0)₄ 모형보다 더 적합하다고 결론지을 수 있으나, 앞서 언급한 바와 같이 ARIMA모형을 추정하는 과정에서 단위근 문제가 있음을 확인하였다. 이는 곧, ARIMA 모형을 추정하는 과정 상에 이미 문제가 있었음을 의미하기 때문에, ARIMA 모형의 AIC와 BIC의 값은 모형의 적합도를 평가하는데 적절하지 않다고 할 수 있다.

Table 9는 SARIMA(1,1,3)(0,1,0)₄ 모형과 ARIMA

(1,1,1)모형을 활용하여 2011년 1사분기부터 4사분기까지의 수송량을 예측하여 실제 수송량과 비교해 놓은 것이다. 예측정확도를 살펴보면 예측되어진 2011년 1사분기에서 4사분기까지 모든 시점에서 SARIMA(1,1,3)(0,1,0)₄ 모형의 예측치가 ARIMA(1,1,1)모형을 활용한 예측치보다 정확도가 높게 나타났다. 모형의 추정과정 상에서 ARIMA 모형을 본 연구의 추정 모형으로 활용하는데 문제점이 있음을 알 수 있었고, 그 문제점을 차치하고서라도 SARIMA모형으로 추정된 모형이 ARIMA 모형으로 추정된 모형보다 예측의 정확도가 더 높은 것을 알 수 있었다.

Figure 2는 SARIMA(1,1,3)(0,1,0)₄ 모형의 예측치와 ARIMA(1,1,1)모형의 예측치를 실제 물동량과 비교한 그래프이다. Figure 2에 나타난바와 같이, 예측시점 이전의 경우, SARIMA(1,1,3)(0,1,0)₄ 모형의 예측치가 ARIMA(1,1,1) 모형의 예측치보다 실제 물동량에 더욱 가까웠고, 예측시점(2010년 4사분기) 이후에도 ARIMA(1,1,1) 모형은 물동량을 과도하게 예측하는 경

Table 9. Comparison between SARIMA(1,1,3)(0,1,0)₄ model and ARIMA(1,1,1) model

	Actual Volume	SARIMA(1,1,3)(0,1,0) ₄			ARIMA(1,1,1)		
		Forecasting	Accuracy	Error	Forecasting	Accuracy	Error
2011 1Q	48352	51308.69	94.24%	2956.69	58800.07	82.23%	10448.07
2011 2Q	51139	54236	89.15%	3097	64795.9	74.62%	13656.9
2011 3Q	48630	49663.54	97.36%	1033.54	61507.75	78.61%	12877.75
2011 4Q	54086	57450.89	84.16%	3364.89	67779.23	71.34%	13693.23
RMSE (2000 1Q - 2010 4Q)		1385.73			6368.94		

*Unit : ton




Figure 2. Comparison of forecasting accuracy between SARIMA(1,1,3)(0,1,0)₄ and ARIMA(1,1,1)

향을 보였으나, SARIMA(1,1,3)(0,1,0)₄ 모형은 매우 높은 예측정확도를 보이고 있음을 알 수 있다. 이렇듯 상대적으로 SARIMA 모형의 추정모형이 ARIMA 모형을 활용한 추정모형보다 더 높은 정확도를 보이는 이유는 크게 두가지로 예상된다. 첫 번째는 항공화물의 계절성을 감안하기에는 ARIMA 모형 자체가 갖는 모형의 한계 때문이다. 서두에 언급한 바와 같이, ARIMA 모형은 예측시점을 기준으로 가까운 과거 값들만 감안할 수 있고, 전년도 동분기와 같이 주기적인 값들을 감안할 수가 없기 때문이다. 항공화물과 같이 계절성을 띄는 시계열 자료의 경우, 상대적으로 ARIMA 모형의 예측 정확도는 SARIMA 모형에 비해 떨어질 수밖에 없다. 두 번째로는, 모형에 활용된 시계열 자료가 안정적이지 못하였기 때문으로 예상된다. 본 연구에 활용된 시계열 자료의 경우, 계절 차분을 하지 않고서는 시계열 자료가 안정적으로 변환되지 않으나, ARIMA 모형의 특성상 계절차분을 할 수가 없다. 그러므로 ARIMA(1,1,1) 모형의 경우 1계 분기 차분을 하였음에도 불구하고 자료가 안정적으로 변환되지 못하였다. 자료가 안정적이어야 하는 기본적인 조건이 만족되지 않았기 때문에 상대적으로 ARIMA(1,1,1) 모형의 예측 정확도가 SARIMA(1,1,3)(0,1,0)₄ 모형에 비해 떨어지게 나타난 것으로 예상된다.

3) 기존의 SARIMA 모형과의 비교

기존의 SARIMA 모형을 추정하였던 다른 연구들과 본 연구의 가장 큰 차이점 중 하나는 SARIMA (p,d,q)

(P,D,Q)s 에서 ‘p’, ‘q’, ‘P’, ‘Q’의 값을 찾는 과정에서 ‘간결성의 원칙’을 적용시킨 방법이다. 기존의 많은 연구들은 안정성 검정 이후, 시계열 자료가 안정적이라고 판단되면, 각 항들의 lag값을 추정하는 과정에서 lag값의 범위를 식(16)과 같이 정하고 추정하였다.

$$\begin{aligned}
 p: 0 \leq p \leq 1 & \quad (16) \\
 q: 0 \leq q \leq 1 \\
 P: 0 \leq P \leq 1 \\
 Q: 0 \leq Q \leq 1
 \end{aligned}$$

모형을 추정하는데 있어서 간결성의 원칙을 따르는 이유는 각 항들의 lag값들이 커져서 모형이 복잡해질 경우 발생할 수 있는 실용성이 떨어지게 되는 문제를 피하기 위함이다. 그런 의미에서 ‘p’, ‘q’, ‘P’, ‘Q’ 각각의 값이 작을수록 좋다고 할 수 있다. 하지만 식(16)과 같은 범위를 가져가기에 앞서 과연 식(16)의 범위를 가져갈 경우, ADF-test상에서 단위근이 존재할 수도 있다는 점을 간과해서는 안된다. ADF-test는 lag값에 따라 귀무가설의 기각 여부가 바뀔 수 있다. 그렇기 때문에 lag값을 추정할 때, 반드시 ADF-test 과정에서 적용된 lag값이 적용되어야 하며, 혹은 선택 가능한 범위의 lag값들을 적용시켜 다시 ADF-test를 통해 단위근의 존재 여부를 파악해야 한다. 하지만 대부분의 선행연구들을 살펴보면 이러한 과정을 건너뛰고, 간결성의 원칙이라는 명목 하에 식(16)과 같이 최대한 간단한 범위 하에서만 lag값을 찾고 있다. 그렇기 때문에 간결성을 위해 어떠




Figure 3. Comparison of forecasting accuracy between SARIMA(1,1,3)(0,1,0)₄ and SARIMA(1,1,1)(0,1,1)₄

한 사전적 검증과정 없이 식(16)과 같은 방식으로 lag값을 추정하는 것은 문제가 있다고 할 수 있다.

Table 10은 동일한 수송실적을 가지고 식(16)의 범위 하에서 추정한 SARIMA 모형이다. 이를 살펴보면 앞서 ARIMA(1,1,1) 모형의 AIC와 BIC값이 SARIMA(1,1,3)(0,1,0)₄ 모형의 값보다 낮았던 것처럼 SARIMA(1,1,1)(0,1,0)₄ 모형의 AIC와 BIC의 값이 SARIMA(1,1,3)(0,1,0)₄ 모형의 값보다 더 낮게 나타났다. 하지만 모형의 lag값을 추정하는 과정에서 해당 lag에서 단위근이 존재하지 않는다는 것을 확인할 수 없기 때문에, 추정된 SARIMA(1,1,1)(0,1,0)₄ 모형의 AIC와 BIC의 값을 SARIMA(1,1,3)(0,1,0)₄ 모형을 통해 구한 값과 비교하는 것은 앞서 ARIMA모형의 경우와 마찬가지로 적절하지 않다.

Table 11은 SARIMA(1,1,3)(0,1,0)₄ 모형과 SARIMA(1,1,1)(0,1,1)₄ 모형을 활용하여 2011년 1

사분기부터 4사분기까지의 수송량을 예측하여 실제 수송량과 비교해 놓은 것이다. 2011년 1사분기에서 4사분기까지 모든 시점에서 SARIMA(1,1,3)(0,1,0)₄ 모형의 예측치가 SARIMA(1,1,1)(0,1,0)₄ 모형의 예측치보다 높은 정확도를 보이고 있다.

Figure 3은 SARIMA(1,1,3)(0,1,0)₄ 모형의 예측치와 SARIMA(1,1,1)(0,1,1)₄ 모형의 예측치를 실제 물동량과 비교한 그래프이다. Figure 3에 나타난바와 같이, 예측시점 이전의 경우, SARIMA(1,1,3)(0,1,0)₄ 모형의 예측치와 SARIMA(1,1,1)(0,1,1)₄ 모형의 예측치 모두 높은 예측정확도를 지니고 있음을 알 수 있다. 하지만, 예측시점(2010년 4사분기) 이후에도 SARIMA(1,1,1)(0,1,1)₄ 모형의 경우 ARIMA(1,1,1) 모형만큼은 아니었지만 역시 상대적으로 물동량을 과도하게 예측하는 경향을 보였다. 상대적으로 SARIMA(1,1,3)(0,1,0)₄ 모형이 더 높은 예측정확도를 보이고 있음을 알 수 있다. 이러한 예측치의 차이를 보이는 가장 큰 이유는 추정과정 상에서 간결성의 원칙을 지키기 위해 정한 각 항들의 차수 값의 범위인 식(16)의 기준 때문인 것으로 보인다. 물론 모형을 간결하게 하기 위해 낮은 차수로 범위를 정하는 것이 맞긴 하지만, 식(16)과 같이 지나치게 낮은 범위로 정하다 보니, 모형은 간결해 지지만, 실제 예측정확도가 상대적으로 떨어지는 Trade-off가 발생한 것으로 보인다. 실제 본 연구에서 최적모형으로 선택한 SARIMA(1,1,3)(0,1,0)₄ 모형 역시, 간결한 모형으로 볼 수 있다. 두 모형 모두 간결성의 조건을 만족한 상황에서 식(13)의 조건에 따른 SARIMA(1,1,3)(0,1,0)₄ 모형을 통한 예측치가 기존의 식(16)의 조건을 따른 SARIMA(1,1,1)(0,1,0)₄ 모형의 예측치보다 더 정확도가 높았다. 그러므로 본 연구에서 제시하고 있는 새로운 조건 식(16)과 추정모형 SARIMA

Table 10. SARIMA(1,1,1)(0,1,1)₄ model

구분		SARIMA	
		SARIMA(1,1,1)(0,1,1) ₄	
		coef (Std. Err.)	z-value (p > z)
AR	AR(1)	-0.5396034 (0.2353683)	-2.29 (0.022)
MA	MA(1)	0.4404862 (0.1647623)	2.67 (0.008)
SAR		-	-
SMA	SMA(1)	-1.000006 (0.0000289)	-350000 (0.000)
Constant term		-0.0045291 (0.0028662)	-1.58 (0.114)
Number of obs		39	
Likelihood		50.70959	
AIC		-91.41918	
BIC		-83.10138	

Table 11. Comparison between SARIMA(1,1,3)(0,1,0)₄ model and SARIMA(1,1,1)(0,1,1)₄ model

	Actual Volume	SARIMA(1,1,3)(0,1,0) ₄			SARIMA(1,1,1)(0,1,1) ₄		
		Forecasting	Accuracy	Error	Forecasting	Accuracy	Error
2011 1Q	48352	51308.69	94.24%	2956.69	54183.99	89.24%	5831.99
2011 2Q	51139	54236	89.15%	3097	56102.82	86.18%	4963.82
2011 3Q	48630	49663.54	97.36%	1033.54	53901.09	89.71%	5271.09
2011 4Q	54086	57450.89	84.16%	3364.89	60364.46	80.10%	6278.46
RMSE (2000 1Q - 2010 4Q)		1385.73			2804.63		

*Unit : ton

(1,1,3) (0,1,0)₄ 모형이 기존의 SARIMA 모형 추정 방법과 추정모형보다 더 적합하다고 판단된다.

4. 시사점

본 연구는 2000년 1사분기부터 2010년 4사분기 까지 인천국제공항에서 출발하여 유럽내 모든 공항에 도착한 항공화물의 시계열 자료를 바탕으로 SARIMA 모형을 활용, 수요예측 모형을 구축하였다. 앞서 서문에 언급한바와 같이 현재 국내교통수요를 예측하는 부문에 있어서 SARIMA 모형을 활용한 경우는 극히 드물다. 또한 공항의 총 여객수나 화물량이 아닌 항공노선의 수요예측에 관한 연구 역시 찾아보기 힘들다. 이러한 상황에서, SARIMA 모형을 활용하여 인천국제공항 발 유럽노선의 항공화물 수요를 예측한 본 연구는 상당히 큰 의미가 있다고 생각된다.

본 연구를 통해 항공화물과 같이 계절성을 보이는 시계열 자료의 수요예측에 있어서는 기존의 주로 사용되어진 ARIMA 모형보다 SARIMA모형이 더 유용하다는 것을 확인할 수 있었다. 서두에 언급한 바와 같이, ARIMA 모형은 예측시점을 기준으로 가까운 과거 값들만 감안할 수 있고, 전년도 동분기와 같이 주기적인 값들을 감안할 수가 없기 때문이다. 그렇기 때문에 본 논문의 연구결과와 같이, 항공화물과 같이 계절성을 띠는 시계열 자료의 경우, 상대적으로 ARIMA 모형의 예측 정확도는 SARIMA 모형에 비해 떨어지는 것으로 나타났다. 또한 SARIMA 모형을 추정하는데 있어서, 각 항들의 lag값을 결정하는 새로운 접근방법을 제시함으로써, 향후 SARIMA 모형을 추정함에 있어 그 정확성을 높이는 데 기여할 수 있다고 판단된다.

하지만 본 연구에서, 모델추정에 사용된 SARIMA 모형과 lag값을 추정하는 과정에서 제시된 접근방법이 언제나 기존의 방법론들보다 우월하다고 판단할 수 없다. 시계열 자료의 특성에 따라 수요예측의 적합한 방법론이 다를 수 있기 때문이다. 그러므로 본 연구의 결과를 가지고 SARIMA 모형이 ARIMA 모형보다 언제나 우월한 방법론이고, 또한 lag값 추정에 있어서 본 연구의 사용된 접근방식이 기존의 방식들보다 더 나은 접근방식이라고 단정 지을 수는 없다.¹⁴⁾ 하지만, 향후 수요예측 연구에 있어서 본 연구에 사용된 방법론이 또 다른 하나의 방

법론으로 사용되기에는 그만큼 가치가 있다고 판단된다.

본 연구를 통해, 기존의 ARIMA 모형과 더불어 SARIMA 모형이 향후 수요예측을 하는데 있어서 유용한 방법론으로 활용될 수 있는 가치가 있음을 알 수 있었고, 앞으로는 SARIMA 모형을 활용한 수요예측이 더욱 많이 활용되어 질것으로 예상된다.

IV. 결론

지난 10년간 항공을 통한 수출량은 연평균 5.8%로, 해상운송의 연평균 증가율보다 높게 나타나고 있다. 이러한 상황에서 항공화물의 대한 수요예측 역시 기존에 비해 그 중요성이 높아지고 있다.

지금까지 항공수요에 대한 예측은 주로 화물보다는 여객에 초점이 맞춰져 중점적으로 이루어져 왔다. 화물수요에 대한 연구들은 대부분 공항의 물동량에 대한 것들이고, 노선에 대한 연구는 찾아보기 힘들다. 물론 공항의 물동량에 대한 연구를 통해 향후 공항의 운영측면에서 큰 도움이 된다. 하지만, 항공사와 같이 실제 운송을 담당하는 측면에서 바라보면, 항공노선에 따른 수요예측 역시 중요하다. 실제 노선에 대한 수요가 예측이 가능하다면, 그에 맞추어 공급량을 조절함으로써 항공사의 이윤을 극대화 할 수 있고, 또한 장기적 관점에서 높은 수요증가가 예상되는 노선에 관해서는 운항횟수를 늘리는 등에 대해 미리 준비를 할 수 있기 때문이다. 그러므로 기존의 연구들과 함께 노선별 항공화물의 수요에 대한 연구 역시 관심을 갖고 비중있게 다루어져야 한다.

본 연구는 SARIMA 모형을 이용하여, 인천국제공항에서 출발하여 유럽전지역에 위치한 공항들에 도착한 순 화물량을 바탕으로 수요를 예측하여 보았고, 이를 기존 ARIMA 모형의 결과와, 기존의 SARIMA 모형의 차수를 추정하는 방법을 따른 결과와 비교함으로써 본 논문에서 제시하고 있는 방법론의 정확도를 검증해 보았다. 모형을 추정하는데 활용된 기간인 2000년 1사분기부터 2010년 4사분기까지의 RMSE 값과 실제 예측을 실시한 2011년 1사분기부터 2011년 4사분기까지의 예측값을 비교하였을 때, 본 논문에서 제시하고 있는 모델이 가장 예측력이 높고, 반대로 ARIMA모형이 가장 낮은 예측력을 나타냈다. 이는 계절성을 감안할 수 있는 SARIMA 모형의 장점이 그대로 나타난 것으로, 항공화물

14) 계절성을 지닌 시계열 자료의 수요 예측에 있어서는 SARIMA 모형이 보다 우월하다고 할 수 있으나, 그렇지 않은 시계열 자료의 경우, 경우에 따라 추정과정에서 보다 간편한 ARIMA 모형이 더 나을 수도 있다.

과 같이 계절성을 지니는 시계열 자료의 경우, 기존의 대표적인 시계열 분석모형인 ARIMA 모형보다 SARIMA 방법론이 더 적합하다고 할 수 있다. 또한 기존의 SARIMA 예측방법을 따른 결과와 본 연구에서 제시하고 있는 방법론을 따른 결과를 비교하였을 때, 본 연구에서 제시하고 있는 방법론을 따른 모델의 결과가 더 적합하게 나타났다. 이는 향후, SARIMA 모형을 활용하여 모델을 추정하는데 있어서, 본 논문에서 제시하고 있는 방법론이 SARIMA 모형의 예측 정확도를 더욱 높여줄 수 있을 것으로 기대된다.

본 연구는 기존의 공항중심의 연구와는 다르게 노선 중심의 연구라는 차별성을 가지고 있으나, 특정 하나의 노선이 아닌 하나의 경제권 내의 모든 노선을 하나의 노선으로 통합한 물동량을 활용하여 연구하였기 때문에, 이에 따른 한계점을 지니고 있다. 그러므로 향후 특정 세부 노선간의 항공수요를 예측하는 연구의 필요성과 더불어 기존 공항중심의 수요예측에 있어서 SARIMA 모형을 활용하는 연구가 이루어져야 할 것이다. 이러한 공간적인 한계점과 더불어서 EU와의 FTA 체결 등과 같이 유럽 물동량에 영향을 미칠 수 있는 외부 요소들의 효과를 감안하지 못한 점 역시 본 연구의 한계점이라 할 수 있다. 항공화물을 통한 교역량의 경우, GDP, 유가, 환율 등과 같이 다른 경제지표들에 의해 영향을 많이 받는다. 하지만 본 연구에 활용된 SARIMA 모형의 경우, 다른 시계열 분석 모형들과 같이 과거의 수요가 미래에 꾸준하다는 전제하에 과거의 물동량 자신의 값을 바탕으로 미래의 물동량을 예측하는 것이기 때문에, 다른 경제요인들의 변화에 따른 구체적인 변화 정도를 설명할 수 없다는 단점과 동시에 장기수요를 예측하는데 있어서는 회귀분석에 비해 정확도가 떨어진다는 단점이 존재한다.

그럼에도 불구하고 본 연구는 공항중심의 연구에 편중되어 있던 기존의 항공화물 관련 연구와는 다르게 노선중심의 연구라는데 있어서 충분한 가치가 있고, 또한 계절성이라는 특성을 가지고 있는 항공화물의 특성을 감안하여 기존 교통수요관련 연구에서 그다지 활용되어 지지 않았던 SARIMA 모형을 활용하였다는 점에서 역시 연구가치가 있다고 판단된다. 또한, 항공화물의 영향

을 미치는 GDP, 유가, 환율 등과 같은 다른 요인들에 의한 효과는 나타낼 수 없지만, 인과분석 모델에 경우 발생할 수 있는 문제점들, 즉, 독립변수를 예측하는 과정에서 발생할 수 있는 편의 등을 피할 수 있을 뿐만 아니라, 상대적으로 단기간의 수요예측에 있어서 보다 높은 정확도를 보인다는 점에서 그 연구가치가 충분하다고 판단된다. 추가적으로 항공화물 시장의 경우, 지금까지 꾸준히 성장해왔고 앞으로도 꾸준히 성장할 것으로 예상되는 시장이기에 항공화물 수요예측에 있어서는 상대적으로 장기간에 대한 예측도 가능하다고 판단된다.¹⁵⁾

항공화물 수요를 예측하는데 있어서, 본 연구에서 활용한 SARIMA 모형이 가장 적합한 모형이라고 단언할 수는 없다. 연구의 목적에 따라, 회귀분석과 같은 인과분석 모델이나 다른 분석모형이 더 적합할 수 있다. 하지만 본 연구를 통해, 시계열 분석 방법론을 활용하여 항공화물 수요와 같이 계절성을 지닌 시계열 자료의 수요를 예측하는데 있어서는, SARIMA 모형이 기존의 ARIMA 모형보다 더 적합하다는 결론과 더불어 본 연구에서 제시하고 있는 SARIMA 모형의 추정방법이 기존의 그것보다 더 나을 수 있다는 결론을 내릴 수 있다. 향후, 항공화물 뿐 아니라, 계절성을 지닌 시계열 자료의 경우, 그 수요를 예측하는데 있어서 SARIMA 모형이 보다 유용하고 비중있게 활용되어 지기를 기대함과 동시에 본 논문에서 제시하고 있는 모델추정 방법론의 많은 활용역시 기대된다.

ACKNOWLEDGEMENT

This work was supported by Inha University and National Research Foundation of Korea Grant Funded by the Korean Government (MOEHRD)(NRF-2011-413-B00008).

REFERENCES

Box G. E. P., Jenkins G. M., Reinsel G. C. (1976), Time series analysis, forecasting and control, Sanfrancisco; Holden Day.

15) 장기수요예측에 있어서 시계열 분석은 외부효과를 감안할 수 없기 때문에 회귀분석에 비해 예측정확도가 떨어지는 단점이 있다. 하지만, 예측대상의 과거의 추세가 미래에도 꾸준히 진행될 경우에는 시계열 분석을 통한 예측 역시 장기수요예측에 있어서 높은 정확도를 가질 수 있다. 반대로 회귀모형의 경우, 외부효과에 대한 영향을 감안할 수 있는 장점을 갖지만, 만약 해당 변수의 예측치의 예측정확도가 보장되지 않을 경우에는 이 역시 장기수요예측에 있어서 적합하지 않을 수 있다. 그러므로 장기수요예측을 하는데 있어서 예측대상의 변화와 특성을 정확히 파악함과 동시에, 예측대상에 영향을 줄 것으로 예상 되는 변수들에 대한 정확한 예측 역시 반드시 선행되어야 한다.

- Chen C. F., Chang Y. H., Chang Y. W. (2009), Seasonal ARIMA forecasting of inbound air travel arrivals to Taiwan, *Transportmetrica*, 5:2, pp.124-140.
- Coshall J. (2006), Time Series Analyses of UK Outbound Travel by Air, *Journal of Travel Research*, Vol.44, February, pp.335-347.
- Dickey D. A., Fuller W. A. (1979), Distribution of the estimators for autoregressive time series with a unit root, *Journal of the American Statistical Association*, 74(366), pp.427-431.
- Hylleberg S., Engle R. F., Granger C. W. J. Yoo B. S. (1990), Seasonal Integration and Cointegration, *Journal of Econometrics* 44, pp.215-238.
- Jiang H., Ren L., Hansman R. J. (2003), Market and Infrastructure analysis of future air cargo demand in China, *American Institute of Aeronautics and AST*, Vol.6793-6862, No.1.
- Kim J. H., Moosa I. A. (2005), Forecasting international tourist flows to Australia: a comparison between the direct and in direct methods, *Tourism Management*, Vol.26, pp.69-78.
- Lee H. Y., Yoon M. G. (2008), A Study of Forecasting Airline's Demand for the Revenue Management, *Journal of the Aviation Management Society of Korea*, Vol.6, No.1.
- Lee J. M., Kwon Y. J. (2011), A Study on Dynamic Change of Transportation Demand Using Seasonal ARIMA Model, *J. Korean Soc. Transp.*, Vol.29, No.5, Korean Society of Transportation, pp.139-155.
- Lim C., McAleer M. (2000), A seasonal analysis of Asian tourist arrivals to Australia, *Applied Economics*, 32:4, pp.499-509.
- Lim C., McAleer M. (2002), Time series forecasts of international travel demand for Australia, *Tourism Managemnet*, Vol.23, pp.389-396.
- Totamane R., Dasgupta A., Mulukutla R. N., Rao S. (2009), Air cargo Demand Prediction, System Conference, 2009 3rd Annual IEEE.
- Wu M., Morell P. (2007), China's air cargo demand ; Future Market Development and Implications, *Proceedings of the internationa air transportation conference*, Vol.29.
- Wu S. (2010), Lag Length Selection in DF-gls Unit Root Tests, *Communications in Statistics - Simulation and Computation*, 39:8, pp.1590-1604.
- Yoon J. S., Huh N. K., Kim S. Y., Hur H. Y. (2010), A Study on International Passenger and Freight Forecasting Using the Seasonal Multivariate Time Series Models, *Communications of the Korean Statistical Society*, Vol.17, No.3, pp.473-481.
- ☞ 주 작 성 자 : 민경창
 ☞ 교 신 저 자 : 하현구
 ☞ 논문투고일 : 2012. 7. 20
 ☞ 논문심사일 : 2012. 11. 6 (1차)
 2013. 1. 23 (2차)
 2013. 2. 22 (3차)
 ☞ 심사판정일 : 2013. 2. 22
 ☞ 반론접수기한 : 2013. 10. 30
 ☞ 3인 익명 심사필
 ☞ 1인 abstract 교정필