

# 개입 승법계절 ARIMA와 인공신경망모형을 이용한 해상운송 물동량의 예측\*

김창범\*\*

## Forecasting the Seaborne Trade Volume using Intervention Multiplicative Seasonal ARIMA and Artificial Neural Network Model

Chang-Beom Kim

### Abstract

The purpose of this study is to forecast the seaborne trade volume during January 1994 to December 2014 using the multiplicative seasonal autoregressive integrated moving average (ARIMA) along with intervention factors and an artificial neural network (ANN) model. Diagnostic checks of the ARIMA model were conducted using the Ljung-Box Q and Jarque-Bera statistics. All types of ARIMA process satisfied the basic assumption of residuals. The ARIMA(2,1,0) (1,0,1)<sub>12</sub> model showed the lowest forecast error. In addition, the prediction error of the artificial neural network indicated a level of 5.9% on hidden layer 5, which suggests a relatively accurate forecasts. Furthermore, the ex-ante predicted values based on the ARIMA model and ANN model are presented. The result shows that the seaborne trade volume increases very slowly.

*Key Words: seaborne trade volume, intervention ARIMA, artificial neural network model*

▷ 논문접수: 2015. 02. 02.      ▷ 심사완료: 2015. 03. 10.      ▷ 게재확정: 2015. 03. 26.

\* 본 논문은 『2015 경제학 공동학술대회』에서 발표된 논문을 수정·보완하였음.

\*\* 전남대학교 지역개발연구소 연구교수, cbkim-55@hanmail.net

## I. 서론

우리나라 해상운송 물동량은 1994년 3억 6천만톤, 1998년 4억 7천만톤, 2002년 6억 4천만톤, 2006년 8억 1천만톤, 2010년 9억 7천만톤, 2014년 11억 9천만톤에 이르고 있으며, 1998년과 2009년 전년대비 증감률이 감소한 것을 제외하면 꾸준한 증가세를 보이고 있다. 수입물동량은 1994년 2억 8천만톤, 1998년 3억 3천만톤, 2002년 4억 6천만톤, 2006년 5억 5천만톤, 2010년 6억 5천만톤, 2014년 7억 8천만톤으로 나타나고, 1998년과 2009년 전년대비 음의 성장률을 보인 것을 제외하면 꾸준한 증가세를 보이고 있다. 그리고 수출물동량은 1994년 8천만톤, 1998년 1억 4천만톤, 2002년 1억 8천만톤, 2006년 2억 6천만톤, 2010년 3억 2천만톤, 2014년 4억 1천만톤에 이르고 있으며, 1998년 외환위기 기간에 오히려 큰 폭의 증가세를 보이고 2009년 글로벌 금융위기 기간에는 큰 폭의 감소세를 보였다.

해상물동량에 대한 정확한 추정과 예측이 확보되어야만 항만·물류정책이 효율적으로 수립될 수 있다. 정확한 예측모형을 통해서 지속적인 물동량 증가가 예상되는 경우 정부에 의한 항만·물류정책은 규모가 확대되는 방향으로 추진되어야 하지만, 물동

량의 증가가 둔화되는 추세라면 현재의 정부정책은 수정되어야 할 것이다. 미래 지향적인 항만·물류 정책 수립을 위해서 해상물동량의 예측의 중요성은 매우 크다. 예측모형을 설정하여 해상물동량을 사전적으로 예측하는 노력은 정성적 분석에 의한 연구자의 주관에 배제하고, 예측의 일관성과 객관성을 확보할 수 있다(전찬영, 2007: 21). 컨테이너 물동량과 BDI 예측은 많은 연구가 이루어지고 있으나, 해상물동량 자체에 대한 예측 연구는 미흡하다. 선행연구를 살펴보면, 전찬영·송주미(2007)는 수출입 품목 10개를 선정한 후 상승지속형, 상승둔화형, 정체형·불규칙형, 불규칙 상승형 4개의 유형으로 구분하여 회귀분석과 인경신경망모형의 예측력을 비교·분석하였다. 김정훈(2008)은 전국 컨테이너 물동량을 수출입, 연안, 화적 물동량으로 구분하여 시계열을 모형을 구축한 후 물동량의 사전적 예측을 실시하였다. 이재득(2013)은 승법계절 ARIMA모형을 이용하여 부산항 물동량의 미래예측을 실시하였다. 유상록외 3인(2014)은 시계열분석과 인공신경망모형을 이용하여 미래 인천항의 해상교통량을 예측하여 계절에 따른 월별 교통량의 차이를 밝혔다.

해상물동량의 시계열자료는 계절적 변동과 예상하지 못한 사건들이 포함되어 있기 때문에 본 논문




그림 1. 해상물동량의 변동 추이(단위: %)

자료: SP-IDC(해양수산부 해운항만물류정보센터)

은 개입 승법계절 ARIMA모형을 도입하고 비교를 위해 인공신경망모형의 예측도 실시한다. 이를 통해 항만·물류정책에 필요한 기초자료를 제시하는데 목적을 두고, 본고는 다음과 같이 구성된다. 제 II장에서 개입 승법계절 ARIMA모형과 인공신경망모형에 대한 이론적 배경을 살펴보고, 제III장과 제 IV장에서는 개입 승법계절 ARIMA과 인공신경망모형의 추정을 통해 사후적 예측과 사전적 예측을 실시하고, 제V장에서 요약 및 결론을 제시한다.

## II. 이론적 배경

본고에서 ARIMA모형을 도입하는 이유는 다변량을 투입하여 예측하는 기법이 ARIMA모형과 같은 단일변량기법보다 더 우수한 예측성결과 보일 것으로 예상되지만, 많은 경우 단일변량기법의 예측력이 다변량기법보다 우수한 것으로 실증분석결과 밝혀지고 있다. 단일변량기법의 경우 흔히 이용되는 ARMA모형 대신 ARIMA모형을 이용하는 것은 ARMA모형은 시계열이 안정된 자료만을 분석할 수 있기 때문이다. 다시 말해서, 시계열의 분산이 불변이고 추세 및 계절변동이나 순환변동도 없어야만 한다는 안정조건을 충족하는 것만을 분석할 수 있으나 이 요건은 거의 충족되기 어렵다. 실제로 많은 시계열이 불안정한  $I(1)$  특성을 갖는 것으로 알려져 있다(모수원·김창범, 2003: 10-11). 이러한 문제를 해결하기 위하여  $ARMA(p, q)$  모형에 새로운 모수  $d$ 를 도입한  $ARIMA(p, d, q)$  모형을 이용한다. 더구나 많은 시계열들이 계절성을 갖고 있기 때문에 식 (1)~(2)와 같은 승법계절 ARIMA모형인  $ARIMA(p, d, q)(P, D, Q)_s$ 를 도입한다(여운방·손영숙, 1985: 125-126).

$$\psi_p(B)\Phi_p(B^s)\nabla^d\nabla_s^D z_t = \theta_q(B^s)\theta_Q(B^s)a_t \quad (1)$$

$$z_t = \frac{\theta_q(B^s)\theta_Q(B^s)}{\psi_p(B)\Phi_p(B^s)\nabla^d\nabla_s^D} \times a_t \quad (2)$$

여기서

$$\Phi_p(B^s) = (1 - \phi_1 B^s - \phi_2 B^{2s} - \dots - \phi_p B^{ps}),$$

$$\nabla_s^D = (1 - B^s)^D, \quad \nabla_d = (1 - B)^d$$

$$\theta_Q(B^s) = (1 - \theta_1 B^s - \theta_2 B^{2s} - \dots - \theta_Q B^{Qs}),$$

$$\psi_p(B) = (1 - \psi_1 B - \psi_2 B^2 - \dots - \psi_p B^p).$$

$\Theta(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$  임을 의미한다.

예상하지 못한 충격이 시계열 변수에 어떠한 영향을 미치는지 파악하고자 개발된 것이 개입 승법계절 ARIMA모형이다. 승법계절 ARIMA모형을 이용하여 시계열 과정의 모형을 구축한 후 시계열 추세에 영향을 미친 외부개입의 효과를 포함시킬 수 있다. 종속변수에 지속적 영향을 주는 계단 개입이  $t = i$ 시점 동안 지속적으로 발생했다고 가정하면 입력변수  $Y_{it}$ 는 다음과 같이 정의할 수 있다.

$$Y_{it} = \begin{cases} 0, & t < i \\ 1, & t \geq i \end{cases} \quad (3)$$

여기서 계단함수  $Y_{it}$ 는  $i$ 시점에서 발생된 개입요인이 그 시점 이후에도 효과가 지속적으로 유지되는 것을 의미한다.

다음으로 인공신경망 분석기법은 주어진 데이터에 대해 두뇌의 신경(뉴런) 활동을 모방함으로써 특정 현상을 예측하는 알고리즘의 한 종류로 인공지능, 마케팅, 재무, 산업공학 영역에서 주로 활용하는 데이터마이닝 기법 중 하나이다. 주로 등급예측, 패턴인식 및 시계열데이터 패턴 추정 등을 위한 분석방법론으로 활용된다(윤영삼, 2008: 14).

인공신경망모형은 입력층(Input Layer), 은닉층(Hidden Layers), 출력층(Output Layer)로 구성된다. 초기 임의의 연결 가중치로부터 산출값을 계산한 후, 실제 관측값과 비교하여 오차를 최소화하는 방향으로 각 입력에 연결된 가중치를 계속적으로 조정하며, 올바른 산출결과를 위해 서 학습을 진행한다(유상록의 3인, 2014: 34).

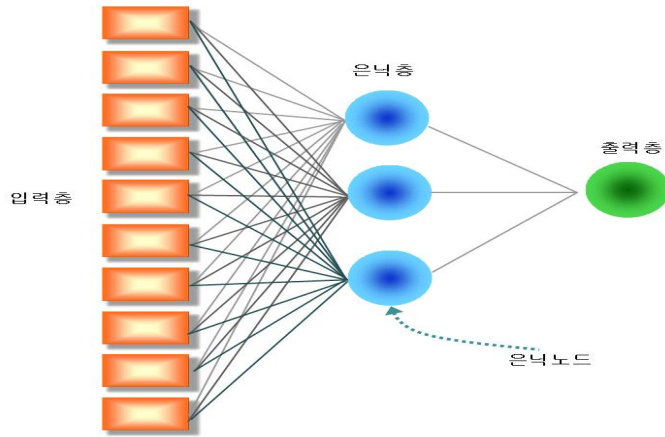


그림 2. 인공신경망모형의 구성

입력층:  $X_1, X_2$ , 은닉층:  $H_1, H_2$ , 출력층:  $O$

$$H_1 = f_1(a_1 + w_{11}X_1 + w_{21}X_2)$$

$$H_2 = f_2(a_2 + w_{12}X_1 + w_{22}X_2)$$

$$O = g(a_0 + w_{10}X_1H_1 + w_{20}X_2H_2)$$

주:  $w$ 는 가중치를 의미함.

### Ⅲ. 개입 승법계절 ARIMA와 인공신경망모형을 이용한 사후적 예측

본고는 해상운송 물동량의 예측을 위해서 해양수

산부 해운항만물류정보센터에서 추출한 1994년 1월부터 2014년 12월까지의 해상 수출입물동량을 이용하였다. 해상 물동량은 <그림 3>에서 보는 것처럼 외환위기와 글로벌 금융위기 기간에 물동량이 일시적으로 감소한 것으로 나타났다. 이러한 충격들에




그림 3. 해상운송 물동량의 추이(자연대수)




그림 4. 해상운송 물동량의 추이(1차 차분)




그림 5. 자기상관도표

의해 추세를 이탈하는 시점을 개입변수 적용시점으로 설정하였다.

〈그림 3〉은 해상운송 물동량의 추이를 보여주고 있는데, 시간의 흐름에 따른 추세성이 존재하고 매년 주기적이고 반복적인 추세와 계절성을 불안정적 시계열로 나타나고 있다. 따라서 1차차분을 취한 결과 〈그림 4〉에서와 같이 안정적인 시계열로 전환됨을 알 수 있다.

그리고 〈그림 5〉의 자기상관도표 결과를 살펴보면, 해상운송 물동량의 수준변수의 자기상관함수 값은 느리게 0에 접근하여 불안정적이지만, 자기상관계수가 1차차분 후 시차1 이후 급격한 감소를 보임에 따라 AR(Autoregressive) 과정임을 알 수 있다.

또한 자료들이 강한 계절성을 갖는 것으로 나타남에 따라 식별단계를 거쳐 승법계절 ARIMA모형인  $ARIMA(p,d,q)(P,D,Q)_s$  모형을 도입한다. 개입 승법계절 ARIMA모형의 선정은 추정계수의 유의성을 확보하고 모형의 설정오류 검정을 반복적으로 수행하여 결정한다.

IARIMA1모형, IARIMA2모형, IARIMA3모형은 각각  $ARIMA(0,1,1)(2,0,2)_{12}$ ,  $ARIMA(2,1,0)(1,0,1)_{12}$ ,  $ARIMA(0,1,1)(1,0,1)_{12}$ 이다. 모형의 적합도는 Ljung-Box  $Q$  통계량과 Jarque-Bera 통계량으로 검증한다.

Ljung - Box  $Q$ :

$$N(N+2) \sum_{j=1}^k \frac{\gamma(j)}{(N-j)} \sim \chi^2(k)$$

Jarque - Bera:

$$N \left[ \frac{(Ku)^2}{24} + \frac{(Sk)^2}{6} \right]$$

여기서  $N$ 은 표본 수,  $k$ 는 시차,  $\gamma$ 는 자기상관 계수,  $Sk$ 는 왜도(Skewness),  $Ku$ 는 첨도(Kurtosis),  $s$ 는 표준편차를 의미한다.

〈표 1〉에서 Ljung-Box  $Q$ 통계량을 통하여 자기상관이 존재하지 않음을 알 수 있으며,  $J.B.$ (Jarque-Bera) 통계량이 잔차항이 정규분포한다는 가설을 기각하지 못함으로써 잔차항이 정규분포한다는 사

실을 확인할 수 있었다.

그리고 〈그림 6〉에서 보는 것처럼 해상운송 물동량의 ACF(자기상관함수)와 PACF(편자기상관함수)가 각각 시차 1이후에 빠르게 감소하여 모형이 안정적임을 파악할 수 있다.

개입 ARIMA의 추정을 통한 예측실적(forecasting performance)의 정확도는  $RMSE$ (root mean squared error),  $MSE$ (mean squared error),  $MAE$ (mean absolute error),  $ME$ (mean error) 4가지 통계량으로 판단한다.

모형예측능력을 비교하는 데 있어서 Meese and Rogoff(1983)과 MacDonald and Taylor(1983, 1994)에서와 같이  $RMSE$ 와  $MSE$ 를 주요 기준으로 한다. 그것은  $RMSE$ 와  $MSE$ 가 상대적으로 큰 예측

표 1. 개입 승법계절 ARIMA모형 추정결과

모형	AR과 MR의 시차	계수	t값	모형의 적합도
IARIMA1	MA(1)	-0.7099***	-14.529	$R^2=0.984$ $Q=19,013(0.954)$ $J.B.=1,516(0.469)$
	SAR(12)	0.3885*	1.884	
	SAR(24)	0.5887**	2.874	
	SMA(12)	-0.2626*	-1.790	
	SMA(24)	-0.4257**	-2.262	
	IMF	-0.0149***	-3.136	
	GLOBAL	-0.0374***	-5.583	
IARIMA2	AR(1)	-0.6736***	-10.605	$R^2=0.985$ $Q=34,795(0.336)$ $J.B.=1,434(0.488)$
	AR(2)	-0.2928***	-4.541	
	SAR(12)	0.9823***	67.715	
	SMA(12)	-0.8149***	-18.780	
	IMF	-0.0185***	-2.575	
	GLOBAL	-0.0433***	-4.568	
IARIMA3	MA(1)	-0.7038***	-14.726	$R^2=0.986$ $Q=18,729(0.978)$ $J.B.=2,196(0.334)$
	SAR(12)	0.9852***	61.315	
	SMA(12)	-0.7934***	-17.091	
	IMF	-0.0179***	-3.801	
	GLOBAL	-0.0381***	-5.648	

주: 1) “\*\*\*”, “\*\*”, “\*”는 각각 1%, 5%, 10% 수준에서 유의함을 의미함.

2)  $Q$ 통계량과  $J.B.$ 통계량의 괄호 안은 유의수준을 의미함.




그림 6. ACF(자기상관함수)와 PACF(편자기상관함수)

오류를 밝히는 데 좋은 척도가 되기 때문이다. 또한  $ME$ 는 모형의 체계적 편의를 보이는 데 유용하기 때문에 도입한다. 그러나  $ME$ 는 평방근 부호가 없어 계산상 편리한 점은 있으나 정(+)의 오차들과 부(-)의 오차들이 서로 상쇄됨으로써 실제의 적합도를 제대로 반영할 수 없다는 단점을 가지고 있기 때문에  $MAE$ 도 도입한다(김창범, 2007: 154).

〈그림 7〉과 〈표 3〉에서 3가지 개입 승법계절

ARIMA모형의  $ME$ ,  $MAE$ ,  $RMSE$ ,  $MSE$ 값이 모두 10% 미만으로 나타나 예측실적이 매우 우수함을 알 수 있다. 3가지 모형 중에서도 두 번째 모형인  $ARIMA(2,1,0)(1,0,1)_{12}$ 의 예측오류가 가장 낮게 나타나 가장 우수한 예측모형으로 파악되었다.

다음으로 인공지능경망모형을 이용한 해상운송 물동량의 예측오류가 〈그림 8〉와 〈표 4〉에 제시되어 있다. 모든 입력층에서 개입 ARIMA모형 보다  $RMSE$

표 2. 해상운송 물동량 예측오류 측정 척도와 통계량

예측오류 측정 척도	통계량
$ME_t$	$\frac{\sum_{i=1}^{N_t} e_{it}}{N_t}$
$MAE_t$	$\frac{\sum_{i=1}^{N_t}  e_{it} }{N_t}$
$RMSE_t$	$\sqrt{\frac{\sum_{i=1}^{N_t} e_{it}^2}{N_t}}$
$MSE_t$	$\frac{\sum_{i=1}^{N_t} e_{it}^2}{N_t}$

주:  $e_{it}$ 는 실제치  $y_t$ 와 예측치  $\hat{y}_{it}$ 의 차이,  $N_t$ 는 예측기간의 예측수를 의미함.




그림 7. 개입 승법계절 ARIMA모형에 의한 예측오류

를 기준으로 한 예측오류 값이 개입 ARIMA모형에 비해서는 예측능력이 떨어진 것으로 분석되었다. 하지만 예측오류의 값이 10%으로 미만으로 나타나


사전적 예측에는 무리가 없는 것으로 판단된다(김민수의 2인, 2012: 71).




표 3. 개입 승법계절 ARIMA모형에 의한 예측오류

모형	예측오류 측정 척도	예측오류 값
IARIMA1	<i>ME</i>	0.0301
	<i>MAE</i>	0.0423
	<i>RMSE</i>	0.0516
	<i>MSE</i>	0.0026
IARIMA2	<i>ME</i>	0.0229
	<i>MAE</i>	0.0366
	<i>RMSE</i>	0.0450
	<i>MSE</i>	0.0020
IARIMA3	<i>ME</i>	0.0353
	<i>MAE</i>	0.0428
	<i>RMSE</i>	0.0519
	<i>MSE</i>	0.0027

(a) H=2



(b) H=3






그림 8. 인공신경망모형에 의한 예측오류

표 4. 인공지능경망모형에 의한 예측오류


	H=2	H=3	H=4	H=5	H=6	H=7
<i>ME</i>	0.0487	0.0275	0.0268	0.0194	0.0267	0.0240
<i>MAE</i>	0.0624	0.0502	0.0499	0.0476	0.0499	0.0491
<i>RMSE</i>	0.0725	0.0608	0.0605	0.0585	0.0606	0.0595
<i>MSE</i>	0.0052	0.0037	0.0036	0.0034	0.0036	0.0035

#### IV. 개입 승법계절 ARIMA와 인공지능경망모형을 이용한 사전적 예측


〈그림 9〉와 〈표 5〉는 개입 승법계절 ARIMA모형을 이용한 해상운송 물동량의 사전적 예측치를 보여주고 있다. 해상운송 물동량의 경우 모형별로

2015년부터 2019년까지 4.54 %에서 4.99%의 연평균 증가율을 보이고 있다. IARIMA1의 경우 2015년 12억 3천만톤, 2016년 13억톤, 2017년 13억 6천만톤, 2018년 14억 3천만톤, 2019년 15억톤, IARIMA2의 경우 2015년 12억 2천만톤, 2016년 12억 8천만톤, 2017년 13억 4천만톤, 2018년 14억톤, 2019년 14억 6천만톤으로 나타났다. 그리고 IARIMA3의 경

(a) IARIMA1



(b) IARIMA2



(c) IARIMA3




그림 9. 개입 승법계절 ARIMA모형을 이용한 사전적 예측치


우는 2015년 12억 3천만톤, 2016년 12억 9천만톤, 2017년 13억 5천만톤, 2018년 14억 2천만톤, 2019년 14억 8천만톤으로 분석되었다.

〈그림 10〉과 〈표 6〉은 인공지능망을 이용한 해상물동량의 사전적 예측결과를 보여주고 있다. 인공지능망을 이용한 해상물동량의 사전적 예측을 실

표 5. 개입 승법계절 ARIMA모형을 이용한 사전적 예측치(단위: 천만 R/톤, %)

	IARIMA1		IARIMA2		IARIMA3	
	물동량	증가율	물동량	증가율	물동량	증가율
2015년	123.16	-	122.15	-	123.10	-
2016년	129.64	5.26	128.01	4.79	129.18	4.94
2017년	136.09	4.97	133.92	4.61	135.34	4.77
2018년	142.82	4.95	139.87	4.45	141.58	4.62
2019년	149.62	4.76	145.88	4.30	147.92	4.48
CAGR	4.99		4.54		4.70	

(a) H=5






그림 10. 인공신경망모형을 이용한 사전적 예측치

시한 결과, 은닉층의 수에 따라 모형별로 2015년부터 2019년까지 2.00%에서 2.44%의 연평균 증가율을 보였다. 은닉층 5의 경우는 2015년 12억 1천만 톤, 2016년 12억 4천만톤, 2017년 12억 6천만톤,

2018년 12억 9천만톤, 2019년 13억 1천만톤으로 분석되었으며, 은닉층 7의 경우는 2015년 12억 1천만 톤, 2016년 12억 4천만톤, 2017년 12억 7천만톤, 2018년 12억 9천만톤, 2019년 13억 1천만톤으로 분

표 6. 인공신경망모형을 이용한 사전적 예측치(단위: 천만 R/T톤, %)

	H=5		H=6		H=7	
	물동량	증가율	물동량	증가율	물동량	증가율
2015년	120.59	-	120.99	-	120.74	-
2016년	123.50	2.41	124.39	2.81	123.81	2.54
2017년	126.12	2.12	127.57	2.56	126.62	2.27
2018년	128.46	1.86	130.53	2.32	129.13	1.98
2019년	130.51	1.60	133.24	2.08	131.36	1.73
CAGR	2.00		2.44		2.13	

석되었다.

## V. 요약 및 결론

본고는 개입요소가 추가된 승법계절 ARIMA모형과 인공신경망모형을 이용하여 해상물동량을 추정하고 사전적 예측을 실시하여 실제 예측치를 도출하였다. 해상운송 물동량은 외환위기와 글로벌 금융위기 기간에 물동량이 일시적으로 감소한 것으로 나타났다. 이러한 충격들에 의해 추세를 이탈하는 시점을 개입변수 적용시점으로 설정하였다. 자기상관도표를 통해서 수준변수는 추세와 계절성이 나타나 불안정적이나 1차차분 변수는 안정적인 시계열로 전환됨을 알 수 있었다. 개입 ARIMA의 추정결과 자기상관이 존재하지 않고, 정규성을 갖는 것으로 나타났다. 개입 승법계절 ARIMA모형과 인공신경망모형의 MAE와 RMSE 값이 모두 10% 미만으로 나타나 예측실적이 매우 우수함을 알 수 있었다. 특히 ARIMA(2,1,0)(1,0,1)<sub>12</sub>의 예측오류가 가장 낮게 나타나 가장 우수한 예측모형으로 파악되었다. 개입 ARIMA모형을 이용한 해상운송 물동량의 사전적 예측치 결과, 해상운송 물동량의 경우 모형별로 2015년부터 2019년까지 4.54%에서 4.99%의 연평균 증가율을 보였다. IARIMA2의 경우 2015년 12억 2천만톤, 2016년 12억 8천만톤, 2017년 13억 4천만톤, 2018년 14억톤, 2019년 14억 6천만톤으로 나타났다. 그리고 인공신경망을 이용한 해상물동량의 사전적 예측을 실시한 결과, 은닉층의 수에 따라 모형별로 2015년부터 2019년까지 2.00%에서 2.44%의 연평균 증가율을 보였다. 은닉층 5의 경우 2015년 12억 1천만톤, 2016년 12억 4천만톤, 2017년 12억 6천만톤, 2018년 12억 9천만톤, 2019년 13억 1천만톤으로 분석되었다.

결론적으로 해상운송 물동량 증가율이 크지 않은 것으로 예측됨에 따라 항만물류정책은 항만배후단지에 신규 물동량 창출을 위한 신성장동력 산업의

육성, 획기적인 마케팅 전략을 통한 항만배후단지 내 글로벌기업의 유치, 항만시설 공급량의 합리적 조절과 항만의 효율적 운영에 초점을 맞추어야 한다. 향후 연구에서는 해상운송 물동량을 수출입으로 나누고 항만별로 비교·분석이 이루어져야 할 것이며, 경제변수들로 구성된 구조적 모형과의 예측력 비교도 병행되어야 할 것이다.

## 참고문헌

- 김민수·김기용·박성식(2012), “ARIMA-Intervention 시계열모형을 활용한 제주 국내선 항공여객수요 추정”, 『한국항공운항학회지』, 제20권 제1호, 63-74.
- 김정훈(2008), “전국 컨테이너 항만물동량에 관한 예측”, 『해운물류연구』, 제59호, 175-194.
- 김창범(2007), “해상운송의 물동량 예측과 항만물류정책”, 『한국항만경제학회지』, 제23권 제1호, 149-162.
- 모수원·김창범(2003), “해상물동량의 추정과 예측”, 『해운물류연구』, 제37호, 1-18.
- 이재득(2013), “승법계절 ARIMA 모형에 의한 부산항 컨테이너 물동량 추정과 예측”, 『한국항만경제학회지』, 제29권 제3호, 1-23.
- 유상록·김종수·정중식·정재용(2014), “인공신경망과 시계열분석을 이용한 해상교통량 예측”, 『해양환경안전학회지』, 제20권 제1호, 33-41.
- 윤영삼(2008), “국내외 경제환경 변화가 국내 IT산업 수출에 미치는 영향”, 『산은조사연구』, 1-21.
- 여운방·손영숙(1985), 『승법 계절ARIMA 모형의 구조식별 방법』, 한국개발연구원.
- 조삼현(2009), “신항과 북항의 철도물동량 예측에 따른 철도운송 활성화 방안에 관한 연구”, 『한국항만경제학회지』, 제25집 제4호, 131-146.
- 전찬영(2007), “우리나라 환적물동량 예측에 관한 소고”, 『월간해양수산』, 제272호, 1-22.
- 전찬영·송주미(2007), “인공신경망모형의 항만물동량 예측 적용에 관한 연구”, 『해운물류연구』, 제53호, 65-82.
- MacDonald, R. and Taylor, M.P.(1983), The Monetary Approach to the Exchange Rate, *IMF Staff Papers*, 40, 89-107.
- MacDonald, R. and Taylor, M.P.(1994), “The Monetary Model of the Exchange Rate; Long-Run Relationships, Short-run Dynamics and How to Beat

a Random Walk,” *Journal of International Money and Finance*, 13, 276-290.

Meese, R.A. and Rogoff, K.(1983), “Empirical Exchange Rate Models of the Seventies: Do They Fit Out of Sample?” *Journal of International Economics*, 14, 3-24.

Pradhan, R.P.(2010), “Forecasting Exchange Rate in India: An Application of Artificial Neural Network Model,” *Journal of Mathematics Research*, 20, 111-117.

<https://www.spidc.go.kr:10443>(해양수산부 해운항만물류 정보센터)

## 개입 승법계절 ARIMA와 인공지능망모형을 이용한 해상운송 물동량의 예측

김창범

### 국문요약

본고는 개입 승법계절 ARIMA모형과 인공지능망모형을 이용하여 해상운송 물동량을 추정하고 사전적 예측치를 도출하였다. 개입 ARIMA의 추정결과 오차항에서 자기상관이 존재하지 않고 정규성이 존재함으로써 오차항의 기본가정이 잘 충족되고 있음을 확인하였다. 그리고 개입 승법계절 ARIMA모형과 인공지능망모형에 대해 예측실적 오류를 *ME*, *MAE*, *RMSE*, *MSE*로 측정한 결과 ARIMA (2,1,0)(1,0,1)<sub>12</sub>이 가장 우수한 예측모형임을 확인할 수 있었다. 2015년부터 2019년까지의 기간에 대해 개입 ARIMA모형을 이용한 해상운송 물동량의 사전적 예측치 결과 4.54%에서 4.99%의 연평균 증가율을 보였고, 인공지능망모형을 이용한 예측결과 2.00%에서 2.44%까지의 연평균 증가율을 나타냈다.

주제어 : 해상운송 물동량, 개입 ARIMA모형, 인공지능망모형