

항만물동량 예측력 제고를 위한 ARIMA 및 인공신경망모형들의 비교 연구

신창훈* · † 정수현

*한국해양대학교 물류시스템공학과 교수, † 한국해양대학교 대학원

A Study on Application of ARIMA and Neural Networks for Time Series Forecasting of Port Traffic

Chang-Hoon Shin* · † Su-Hyun Jeong

*Department of Logistics Engineering, National Korea Maritime University, Pusan 606-791, Korea

† Graduate school of National Korea Maritime University, Pusan 606-791, Korea

요 약 : 예측의 정확성은 비용의 감소나 고객서비스의 제고를 위해 필수적으로 선행되어야 하기에 현재까지도 많은 연구자들에 의해 연구되고 있는 분야이다. 본 연구에서는 국내 항만의 컨테이너 물동량 예측에 있어 대표적인 비선형예측모형인 인공신경망모형과 ARIMA모형에 대한 비교연구를 수행하는데 목적을 두었고, 컨테이너 물동량 예측력 제고를 위해 ARIMA모형과 인공신경망(ANN)모형을 결합한 하이브리드모형을 사용해 다른 모형들과 예측성능을 비교하고자 한다. 특히 인공신경망모형의 네트워크 구조 설계에 부분에 있어 방대하며 복잡한 탐색공간에서도 전역해 찾기에 효과적인 기법으로 알려져 있는 유전알고리즘을 사용함과 동시에 인공신경망의 대표적인 모형으로 알려진 다층퍼셉트론(MLP)뿐만 아니라 시간지연네트워크(TDNN)를 사용해 예측성능을 비교하였다. 그 결과 ANN모형과 하이브리드모형이 ARIMA모형보다 더 뛰어난 예측성능을 보이는 것으로 나왔다.

핵심용어 : 컨테이너물동량, 예측, ARIMA모형, 인공신경망모형, 하이브리드모형, 다층퍼셉트론, 시간지연네트워크, 유전알고리즘

Abstract : The accuracy of forecasting is remarkably important to reduce total cost or to increase customer services, so it has been studied by many researchers. In this paper, the artificial neural network (ANN), one of the most popular nonlinear forecasting methods, is compared with autoregressive integrated moving average(ARIMA) model through performing a prediction of container traffic. It uses a hybrid methodology that combines both the linear ARIAM and the nonlinear ANN model to improve forecasting performance. Also, it compares the methodology with other models in performance for prediction. In designing network structure, this work specially applies the genetic algorithm which is known as the effectively optimal algorithm in the huge and complex sample space. It includes the time delayed neural network (TDNN) as well as multi-layer perceptron (MLP) which is the most popular neural network model. Experimental results indicate that both ANN and Hybrid models outperform ARIMA model.

Key words : Container traffic, forecasting, ARIMA model, ANN model, Hybrid model, MLP, TDNN, GA

1. 서 론

항만은 예전부터 국가간 교역의 주요 관문으로 세계경제의 국제화가 진전됨에 따라 그 역할에 대한 중요성이 날로 증가하고 있다. 항만의 중요성 증대와 함께 선박의 대형화 그리고 항만간의 경쟁심화와 같은 여러 환경변화에 발맞춰 효율적으로 항만을 운영하기 위해서는 보다 정확한 물동량 예측이 요구된다. 예측의 정확성은 비용의 감소나 고객서비스의 제고를 위해 필수적으로 선행되어야 하기에 현재까지도 많은 연구자들에 의해 연구되고 있다.

초기 시계열 예측연구에서는 선형시계열(linear time series) 모형을 기반으로 한 통계적 기법(statistical techniques)들이 주로 사용되었다. 그 중에서도 비교적 완벽한 이론 체계아래에서 뛰어난 성능을 보여주고 있는 자기회귀이동평균(ARMA; autoregressive moving average)모형이 많은 연구자들에 의해 사용되고 있다(지, 1995; Zhang, 2003). 이에 전(1999)은 중장기 항만물동량을 예측하기 위해 거시변수의 영향을 모형화한 수요함수를 추정해 사용하였고, 모·김(2003)은 이러한 구조적 모형과 ARIMA모형을 사용해 국내 수출입 물동량 예측에 대한 비교연구를 수행하였다.

* 대표저자: 종신회원, chshin@hhu.ac.kr 051)410-4333

† 교신저자 : 연회원, shjeong@hhu.ac.kr 051)410-4930

(주) 이 논문은 “컨테이너물동량 예측에 있어 인공신경망모형의 활용에 관한 연구”란 제목으로 “2010년 추계학술대회 한국항해항만학회 논문집(한국해양대학교, 2010.10.21-23, pp.140-141)”에 발표되었음.

그러나 이러한 통계적 기법들로 설명하기 어려운 현상들이 실제 현실에서 다수 존재한다는 점으로 인해 새로운 예측모형 개발을 위한 많은 노력들이 수행되었다. 이러한 노력들의 결과 중 하나가 기계학습(machine learning)이라는 메커니즘을 기반으로 한 인공지능망(ANN; artificial neural network)모형으로 다층퍼셉트론(MLP; Multi-layer perceptron)이 가장 대표적으로 사용되고 있다. 이는 전통적인 수요예측기법에 대한 대안으로서 인식되기 시작하면서 여러 분야에서 광범위하게 연구되고 있다. 전·송(2007)은 국내 주요 수출입품목을 선정해 ANN모형과 회귀분석모형의 예측력을 비교하였다.

그러나 Zhang(2003)은 우리가 접하는 대부분의 현실 자료들은 선형과 비선형특성이 섞여 있는 형태이기 때문에 특정 시계열자료 속에 내재되어 있는 특성 모두를 하나의 예측기법으로 설명하거나 식별하는데 어려움이 있다고 말하였고, ARIMA모형과 ANN모형을 결합한 하이브리드 ARIMA-ANN모형을 제시함과 동시에 그에 대한 실증분석을 수행하였다. 이러한 하이브리드모형 개발과 관련된 연구들의 주요 가정은 단일 예측모형보다 여러 예측모형들을 결합함으로써 더 좋은 성과를 보인다는 것이다. 이에 신 등(2008)의 연구에서 국내 주요 항만의 컨테이너물동량 예측에 하이브리드 ARIMA-ANN모형을 사용해 다른 예측모형과의 비교연구를 수행하였다.

항만물동량 예측에 있어 ANN모형을 사용해 일반적인 통계적 기법들과 비교한 선행연구인 전·송(2007) 그리고 신 등(2008)의 연구들을 보게 되면, 대부분의 자료에서 ARIMA모형이 ANN모형과 하이브리드모형보다 뛰어난 예측성적을 보였다. 그래서 본 연구에서는 다양한 시도를 바탕으로 ANN모형과 하이브리드모형을 사용해 국내 항만의 컨테이너 물동량 자료에 대한 유효성을 검증하였다. 우선 ANN모형의 가장 대표적인 모형인 MLP는 시간패턴을 인식하는 문제에 있어 한계점을 지니고 있기 때문에 그에 대한 대안으로 MLP보다 시간패턴 인식능력이 더 뛰어난 시간지연네트워크(TDNN; time delayed neural network)를 사용해 이들 간의 성과를 비교하였다. 그리고 또한 신경망의 구조 설계에 있어 기존의 선행연구들에서 주로 사용해 왔던 탐색적인 방법론 대신에 방대하며 복잡한 탐색공간에서 효과적으로 알려진 유전알고리즘(GA; genetic algorithm)을 사용하여 최적의 신경망구조를 결정하였다.

본 연구의 구성은 다음과 같다. 2장에서는 시계열 예측과 관련된 인공지능망모형의 연구들과 함께 항만 물동량 예측에 적용한 기존 문헌들을 정리하였고, 3장에서 본 연구에서 사용되는 여러 방법론들에 대해서 설명하였다. 4장에서는 본 연구에서 사용되는 다양한 자료들과 실험방법에 대한 자세한 설명과 함께 분석의 결과들을 요약하였다. 마지막으로 5장에서 본 연구의 결론과 함께 향후 연구방향들을 제시하였다.

2. 이론적 고찰

Lapedes & Farber(1987)의 연구에 의해서 처음으로 시계열

자료 분석에 ANN모형을 적용시키는 시도가 이루어졌다. 이 연구에서 오류역전파(back propagation) 알고리즘을 사용한 MLP로 학습시킨 결과 해당 자료에 대한 적합은 물론이며 예측력에 있어서도 전통적인 수요예측기법들보다 더 우수한 성과를 보인다는 것이 밝혀졌다. 그 이후 많은 연구자들에 의해서 기계학습을 통한 ANN모형이 시계열예측에 있어 좋은 성과를 보임이 증명되었다(Weigend et al, 1990; Sharda & Patil, 1992; Jhee & Lee, 1993). 그러나 White(1988), Fishwick(1989) 그리고 Ripley(1993) 등의 연구에서는 ANN모형이 기존의 통계적 방법들에 비해 뛰어난 예측성적을 보이지 않음을 보였다.

이와 같이 상반되는 연구결과들에 대해 Chatfield(1993)는 ANN모형이 새로이 등장한 유력한 예측기법임에 틀림없지만 체계적인 실증적 분석이 필요함을 강조하였고, 여러 연구자들에 의해서 예측성적을 향상시키기 위한 다양한 시도들이 이루어져 왔다. 그 중 하나가 예측하고자 하는 원시계열자료에 추세나 계절성을 제거한 후 ANN모형으로 분석한 연구들이다. Nelson et al.(1999)의 연구에서는 ANN모형을 함에 있어 원자료를 그대로 사용하는 것보다 해당 자료 내에 존재하는 계절성을 제거한 계절조정자료(deseasonalized data)를 사용하는 것이 더 좋은 예측성적을 보인다고 밝혔다. 더 나아가 Zhang and Qi(2005)의 연구에서는 시계열 자료에 포함되어 있는 계절성만 제거하는 것이 아니라 추세도 같이 제거하게 되면 원자료와 계절조정자료를 사용하는 것에 비해 더 좋은 예측성적을 보인다고 밝혔다.

항만물동량 예측에 ANN모형을 적용한 전찬영과 송주미(2007)의 연구에서는 국내 주요 수출입품목 10개를 선정하여 ANN모형과 회귀분석모형의 예측력을 비교하였는데, 해당 시계열자료의 특성에 따라 상이한 결과를 보임을 밝혔다. 뚜렷한 추세를 지니고 있는 자료에서는 회귀분석모형이 더 좋은 성과를 보인 반면에 ‘불규칙 상승’, ‘상승 둔화’ 혹은 ‘정체’의 경우처럼 일정한 추세가 있다고 보기 힘든 자료에서는 ANN모형이 더 높은 예측성적을 보였다. 이는 ANN모형의 성과가 해당 시계열의 특성에 따라 많은 영향을 받고 있다는 점을 다시 말해주고 있는 부분이다.

그러나 Ghysels et al.(1996)의 연구에서는 단변량 시계열자료에 있어서도 계절성을 제거하는 과정에서 원치 않는 비선형 특성을 초래할 수 있다고 말했고, Ittig(1997)와 Miller and Williams(2004)의 연구에서는 시계열자료에 나타나는 추세의 형태에 따라 계절성분이 영향을 받기에 계절지수를 추정하는 과정에 과다추정(over-estimation)이 발생할 수 있다고 말하고 있다. 이는 ANN모형의 예측성적을 높이기 위해 사용되고 있는 추세성과 계절성에 대한 조정이 원자료에 대한 정보 손실 및 왜곡현상을 발생시킬 수 있기 때문에 원자료 변환에 대한 조심스러운 접근법이 필요하다 말하고 있다.

Geman et al.(1992)연구에서는 그동안 제시된 MLP관련 학습이론에 문제가 있는 것이 아니라, 주어진 문제를 MLP를 사용해 표현하는데 어려움이 있다고 주장하였다. 즉, 해당 문제에 있어 적합한 ANN모형의 선택과 함께 그 모형의 최적의

구조를 결정하는 것이 가장 중요한 문제라는 것이다. 이와 같은 노력들 또한 여러 연구자들에 의해서 수행되었다.

Hansen et al(1999)의 연구에서는 기존의 널리 사용되고 있는 MLP에 비해 시간패턴인식에 있어 더 뛰어난 성능을 보이고 있는 TDNN을 사용하여 시계열자료에 대한 예측을 수행하였다. 그리고 ANN모형 적용에 있어 어려움 점 중 하나인 신경망 구조결정(network topology design)에 있어 과거의 연구들과 달리 유전알고리즘(GA; genetic algorithm)을 사용하였다. ANN모형의 성과는 신경망구조에 의해서 많은 영향을 받게 되는데, 이러한 구조결정문제에 GA를 적용시키므로 신경망 구조 설계에 대한 자동화와 최적화를 동시에 달성할 수 있다. 이 연구에서는 네트워크 구조결정에 있어 선행연구들에서 주로 사용했던 경험론적 방법론(rules of thumb)을 적용시킨 ANN모형을 Heuristic Neural Network이라 정의하였고, 그 결과 ARIMA모형과 Heuristic Neural Network보다 유전알고리즘을 사용한 Hybrid GA_Neural Network 모형이 더 좋은 예측성과를 보임을 밝혔다.

또한 Kim and Shin(2007)의 연구에서 네트워크 설계부분에 GA를 사용한 TDNN을 KOSPI 자료에 대해서 예측작업을 수행하였는데, 그 결과로서 GA를 사용한 TDNN이 GA를 사용하지 않는 것에 비해 더 좋은 예측성과를 보임을 밝혔다.

Zhang(2003)의 연구에서는 비선형자료 분석에 있어 장점을 보이지만 선형자료 분석에 있어 연구자들마다 각기 다른 결과를 보이는 ANN모형에 ARIMA모형을 결합시킨 그 단점을 보완하려는 시도로 하이브리드 ARIMA-ANN모형을 사용하였다. 그 결과 ARIMA모형이나 ANN모형을 개별적으로 사용하는 것보다 하이브리드 ARIMA-ANN모형을 사용하는 것이 더 좋은 예측성과를 보임을 밝혔다.

이에 대한 적용으로 신 등(2008)연구에서 국내 주요 항만의 컨테이너물동량 예측에 하이브리드 ARIMA-ANN모형을 사용해 다른 예측모형과의 비교연구를 수행하였다. 그러나 이 연구에서는 ARIMA모형, ANN모형 그리고 하이브리드 ARIMA-ANN모형을 사용해 그 성과를 비교한 결과를 보면 대부분의 자료에서 ARIMA모형이 더 높은 예측성과를 보였다. 이는 ANN모형을 사용해 국내 컨테이너물동량을 예측하는데 있어 추가적인 실증분석이 요구됨을 보여주고 있다.

이처럼 앞선 선행연구들은 해당 시계열의 특성에 따라 예측기법의 개발 및 적용이 되어야함을 시사하고 있다. 그러나 ANN모형을 적용함에 있어 가장 자주 사용되는 추세 및 계절성의 제거와 같은 원자료 변환은 정보손실 혹은 왜곡현상을 발생시킬 가능성이 있다. 이에 대한 대안으로 하이브리드모형을 제시할 수 있으며, 보다 효과적인 시계열분석을 위해 네트워크 구조 결정문제에 있어 GA를 사용하는 것이 필수적이라 할 수 있다.

3. 방법론

3.1 ARIMA, ANN & Hybrid model

ARIMA모형은 Box and Jenkins(1976)에 의해서 이론적으

로 체계화 된 후 시계열 분석에서 가장 많이 활용되고 있는 모형 중 하나이다. ARIMA모형은 뛰어난 예측성과를 보일 뿐만 아니라 다른 예측모형에 비해 정교한 이론적 토대를 가지고 있기에 실제 예측작업뿐만 아니라 새로운 시계열 예측모형의 개발에 있어서 개발된 모형의 성능을 평가하기 위한 기준 모형으로 사용되고 있다.

그러나 비선형시계열분석에 있어 ARIMA모형은 그 한계점을 지니고 있어 그에 대한 대안으로 ANN모형이 사용되고 있으며, 대표적으로 사용되고 있는 ANN모형은 MLP이다. MLP는 각각 1개의 입력층(input layer)과 출력층(output layer) 그리고 입력층과 출력층 사이에 하나 이상의 은닉층(hidden layer)으로 구성되어 있다. Fig. 1은 입력층에 n 개의 입력노드 $X(t), X(t-1), \dots, X(t-n)$ 와 은닉층에 m 개의 은닉노드 H_1, H_2, \dots, H_m 그리고 출력층에 하나의 노드로 구성되어 있는 MLP이다.




Fig. 1 MLP

이를 수식적으로 표현하며 아래 식 (1)과 같다.

$$\hat{Y}_{t+1} = \sum_{j=1}^m W_j f\left(\sum_{i=0}^n W_{ji} X(t-i)\right), i=0, \dots, n, j=1, \dots, m. \quad (1)$$

여기에서 W_{ji} 는 입력노드 i 와 은닉노드 j 의 연결가중치를 말하며, W_j 는 은닉노드 j 에서 출력노드로 가는 연결가중치를 말한다. 그리고 함수 $f(\cdot)$ 는 인공신경망모형에서 사용되는 비선형함수이다.

그러나 예측뿐만 아니라 다양한 분야에 있어 그 성능을 인정받아 널리 사용되는 MLP는 시간에 따른 변화를 인식하고 분석하는 능력에 있어 그 한계점을 보인다고 지적되고 있기에 시계열 자료 분석 및 예측에 있어 MLP모형의 대안으로서 TDNN이 소개되었다. TDNN은 음성인식부분에 있어 Waibel et al.(1989)의 연구에 의해서 처음 제안되었고, 이러한 음성인식과 음소분류에 있어 다른 인공신경망모형에 비해 탁월한 성과를 보임이 증명되었다.

MLP와 TDNN은 전방향(feed-forwarding)신경망이라는 점에서 기본적으로 유사한 모형이라 할 수 있지만, 출력층의 노드를 제외한 모든 노드들이 기억 구조(memory structure)를

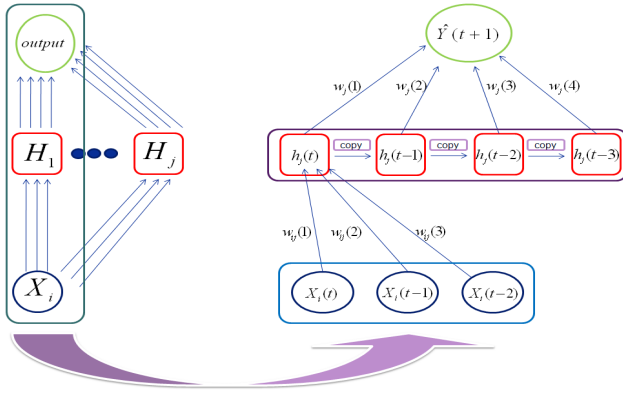


Fig. 2 TDNN

가진다는 점에서 차이를 보인다. MLP 같은 경우 연구자가 임의로 정한 시간창(time window) 내에서 학습이 이루어지는 반면에 TDNN 같은 경우 해당 시계열분석의 대상이 되는 표본내에서 자동적으로 최적의 시간창을 선택할 수 있는 구조를 가지고 있다. 그리고 있는 선택된 시간창내에서 목적함수를 최소화하는 방향으로 학습이 이루어지기 때문에 시계열분석에 있어 더 나은 예측성과를 예상할 수 있다. 이러한 기억구조를 보통 시간지연라인(time delay line)이라 하는데, 아래 식 (2)은 시간지연연산자 Δ 을 포함한 입력노드의 시간지연라인을 수식적으로 표현한 것으로 벡터형태를 띄고 있음을 알 수 있다.

$$X_i(t) = [X_i(t), X_i(t-\Delta), X_i(t-2\Delta), \dots, X_i(t-n\Delta)] \quad (2)$$

여기에서 i 는 특정 시계열의 개별 관측치를 의미하는 것이 아니라 특정 시계열자료를 의미한다. 이를 통해 TDNN은 단변량 분석뿐만 아니라 다변량 분석으로의 확장성을 지니고 있음을 알 수 있다.

Fig. 2는 입력노드의 시간지연라인의 크기와 시간지연연산자 Δ 는 각각 3과 2이며, 은닉노드의 시간지연라인의 크기와 시간지연연산자 Δ 는 각각 4와 2인 구조를 띄고 있는 TDNN이다.

은닉노드 j 에서 출력노드로 출력되는 값인 $h(t)_j$ 은 아래 식 (3)과 같이 계산된다. 그래서 특정 은닉노드 j 의 시간지연라인은 현재의 $h(t)_j$ 와 함께 이전 단계들에서 이미 계산된 $h_j(t-1), h_j(t-2), \dots$ 들이 포함된 형태를 띤 벡터형태이다.

$$h(t)_j = f(W_{ji}^T X_i(t)), \quad i = 1, \dots, n \quad (3)$$

여기에서 $W_{ji}(t)$ 는 특정 입력노드의 시간지연라인과 은닉노드의 간의 연결가중치를 의미하며, 아래 식 (4)과 같이 벡터 형태를 띄고 있다.

$$W_{ji}(t) = [W_{ji}(t), W_{ji}(1), W_{ji}(2), \dots, W_{ji}(n)] \quad (4)$$

그러나 Zhang(2003)은 대부분의 시계열 자료 y_t 는 선형적인 특성 L_t 과 비선형적인 특성 N_t 이 혼합되어 있는 형태 즉, $y_t = L_t + N_t$ 와 같은 형태를 띄고 있다고 가정하였고, 이러한

특성을 가진 시계열을 분석함에 있어 단일 예측모형으로 모든 특성을 식별하기 어렵다고 말했다. 그래서 시계열 자료 속에 내재되어 있는 선형과 비선형특성들을 동시에 모형화하기 위해 서로 다른 특성을 지니고 있는 예측 모형을 결합한 하이브리드 ARIMA-ANN모형을 제시하였다.

하이브리드 ARIMA-ANN모형의 절차는 크게 두 단계로 나눌 수 있다. 첫 번째 단계에서 해당 시계열에 내재되어 있는 선형적인 특성을 추정하기 위해 ARIMA모형을 사용한다. 이를 통해 ARIMA모형을 통해 추정된 선형적인 특성 \hat{L}_t 을 아래 식 (5)을 통해 오차 e_t 을 계산한다.

$$e_t = y_t - \hat{L}_t \quad (5)$$

두 번째 단계에서는 위에 단계에서 계산된 오차 e_t 을 ANN모형에 학습시킨 뒤 예측을 수행한다. 이는 예측오차자료에 내재되어 있는 비선형 관계를 식별하기 위해 ANN모형을 사용하는 것으로 아래 식 (6)과 같다.

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) + \epsilon_t \quad (6)$$

함수 $f(\cdot)$ 는 ANN모형에서 사용되는 비선형함수이며, ϵ_t 는 확률적 오차(random error)이다. 즉, ANN모형의 입력값으로 현재 시점 t 을 기준으로 ARIMA모형으로 분석한 후 나온 $t-n$ 개의 예측오차를 입력자료로 사용한다는 의미이다. 최종적으로 ARIMA모형을 사용하여 적합시켜 나온 추정값 \hat{L}_t 과 ANN모형을 사용해 나온 \hat{N}_t 을 더하므로 원시계열에 대한 추정치 \hat{y}_t 을 구한다.

$$\hat{y}_t = \hat{L}_t + \hat{N}_t \quad (7)$$

이는 각기 다른 특성을 지니고 있는 예측 모형을 사용하므로 인해 시계열 자료 속에 내재되어 있는 선형적 패턴과 비선형적 패턴을 독립적으로 모형화 할 수 있으며, 이들의 결합으로 인해 전체 예측성과를 향상시킬 수 있다.

3.2 GA

GA는 진화를 표방한 확률적 탐색기법(stochastic search method)이다. GA에서 연구자가 임의로 정의한 목적함수를 토대로 선택(selection), 교차(crossover) 그리고 돌연변이(mutation) 연산자들이 작동하면서, 특정 종료규칙(termination criterion)에 만족될 때까지 단계적인 반복연산이 수행되는 알고리즘이다.

ANN모형의 네트워크 구조 결정 문제와 관련된 과거 연구들을 보면, 모든 경우의 수를 고려하는 탐색적 방법을 사용하거나 몇몇 연구자들에 의해 제안된 어렵짐작으로 결정(Rules of thumb)하는 법칙들을 이용해 실제 분석에서 사용되는 입력노드 혹은 은닉노드의 수와 같은 구조 모수를 결정하였다. 그러나 고려해야 할 구조 모수가 증가하면 할수록 엄청난 크기로 탐색공간이 증가하며, ANN모형 또한 비선형모형이기에

매번 분석시 최적해를 보장하기 힘들기에 이러한 방법들은 그 한계점을 지니고 있다. 그래서 Hansen et al(1999)과 Kim and Shin (2007) 등의 연구에서는 방대하며 복잡한 탐색공간에서도 전역해(global optimum)찾기에 효과적인 기법으로 알려져 있는 GA를 사용해 최적화 된 네트워크 구조를 결정하였고, 그 결과 GA를 사용하지 않는 경우보다 뛰어난 성과를 보임을 밝혔다.

4. 실증분석

4.1 실험 설계

본 연구에서는 총 3가지의 예측모형들을 사용해 그 성과들에 대한 비교연구를 수행하였다. 첫 번째 예측모형은 일반적으로 사용하는 ANN모형으로 다른 모형들과의 구분을 위해 Naïve ANN모형이라 하였다. 나머지 두 모형은 하이브리드 AR-ANN모형과 하이브리드 ARIMA-ANN모형이다. 그리고 이들 예측모형들마다 사용되는 ANN모형에 있어 각기 다른 ANN모형인 MLP와 TDNN를 사용해 그에 따른 비교연구를 수행하였다.

실험은 두 단계로 나뉘 수행되었다. 첫 단계에서는 앞서 언급한 3가지 예측모형별로 시계열자료 속에 내재되어 있는 선형적인 특성 \hat{L}_t 을 추정함과 동시에 ANN모형에 사용할 새로운 자료를 생성한다. 여기에서 하이브리드모형들은 AR모형이나 ARIMA모형으로 \hat{L}_t 을 추정한 뒤, 이를 통해 ANN모형에 사용될 자료인 예측오차들을 계산하였다. Naïve ANN모형 같은 경우 차분을 통해 추세만 제거하였으며, 이 자료를 ANN모형의 입력자료로 사용하였다. AR모형과 ARIMA모형의 분석과정에서는 SAS 9.1이 사용되었다. 두 번째 단계에서는 앞 단계에서 생성된 자료를 바탕으로 ANN모형에 대한 학습 및 예측을 수행하여 비선형적인 특성 \hat{N}_t 을 추정하는데, NeuroSolutions 5.07이 사용되었다. 그리고 입력노드와 은닉노드의 수 그리고 각각의 노드들에 대한 시간지연라인 같은 인공신경망의 여러 구조모수들을 구하기 위해 GA를 적용하여 최종 구조를 결정하였으며, NeuroSolutions에서 제공하는 GA를 사용하였다. 그래서 각 단계별로 추정한 \hat{L}_t 와 \hat{N}_t 을 합해 최종 추정치 \hat{y}_t 을 계산하였다.

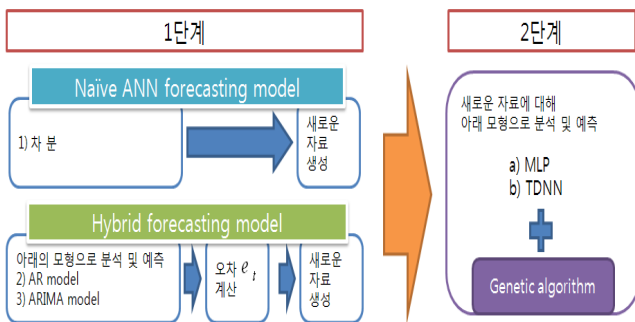


Fig. 3 Experiment design

GA의 탐색공간은 아래와 같이 정하였다. 입력노드와 은닉노드의 기억 구조는 각각 1~20개까지로 두었고, 각각의 노드들의 시간지연의 크기는 1~10까지로 정하였다. 그리고 마지막으로 은닉노드의 개수는 1~25개까지로 정하였다. 그리고 각각의 세대수와 모집단의 수는 100으로 정하였다. 나머지 네트워크 구조에 있어 은닉층의 수는 하나로 고정하였고, 활성화함수는 쌍곡탄젠트함수를 사용하였다. 그리고 GA의 연산자들과 관련해서는 선택방식으로는 확률바퀴를 사용하였고, 교차방식은 일점교차방식을 사용해 총 10회 반복실험을 수행하였다. 그리고 나머지 모수값인 교차율은 0.5, 돌연변이율은 0.1로 정하였다. 목적함수식은 아래 식과 같으며, 실제값(actual value)인 A_t 에 예측값(forecast value) F_t 을 뺀 뒤 나오는 오차값을 제공하여 그 평균을 구한 평균제곱오차(MSE; mean square error)을 사용하였다.

$$MSE = \sum_{t=1}^n (A_t - F_t)^2/n \tag{8}$$

그리고 사전적으로 실험에 사용되는 자료들을 학습(training) 자료, 교차검증(cross-validation)자료 그리고 검정(test)자료로 나눈 뒤 분석을 수행하였다. ANN모형의 학습과정은 교차검증자료에 대해서 목적함수 즉, MSE를 최소화하는 방향으로 노드간 연결 가중치들을 조정하였다. 이러한 학습과정에 있어 종료조건으로는 최대 1000회에 걸쳐 단계적인 연산이 수행되며, 과다적합(over-fitting)을 방지하기 위해 MSE값이 증가하는 순간 학습과정이 종료되게 하였다. 그리고 이러한 과정을 통해 나온 선택된 인공신경망 모형들에 대해서 검정자료를 사용해 최종적인 ANN모형을 선택하였다.

4.2 자료

본 연구에 사용된 항만별 컨테이너물동량자료는 환적과 국내 연안운송을 제외한 수입, 수출 물동량으로 국토해양부가 운영하는 해운항만 물류정보 센터(SP-IDC)에서 수집하였다. 효과적인 인공신경망의 학습을 위해 보다 많은 수의 관측치 확보가 무엇보다 중요한 문제이기 때문에 국내 항만 중 가장 긴 역사를 지니고 있는 부산항과 인천항을 중심으로 자료를

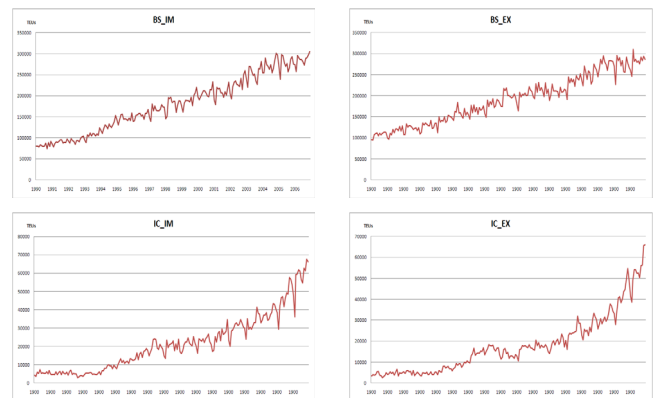


Fig. 4 Time plot of data set

수집하였다. 그 결과 총 관측기간은 1991~2006년까지 월별 자료로 총 192개 관측치를 대상으로 분석을 수행하였다.

자료분할에 있어 1991~2002년까지 학습자료, 2003~2004년까지 교차검증자료 그리고 2005~2006년까지 검정자료로 나누는 뒤 시계열의 선형적인 특성 \hat{L}_t 을 추정하기 위해 AR과 ARIMA모형에 대한 분석을 수행하였다. Table 1은 각 자료에 대한 AR와 ARIMA모형의 식별결과이며, AIC을 기준으로 최종 모형을 결정하였다. 이를 통해 다음 단계에 사용될 ANN모형의 자료를 생성하였으며, 특히 ARIMA모형은 최종 예측모형의 성과비교에 있어 기준 모형으로 사용되었다.

Table 1 Result of AR and ARIMA model identification

자료	적합모형	$(p,d,q)(P,D,Q)_{12}$
부산 수입	ARMA	$(0,1,1)(0,1,1)_{12}$
	AR	$(1,1,0)(1,0,0)_{12}$
부산 수출	ARMA	$(0,1,1)(0,1,1)_{12}$
	AR	$(3,1,0)(1,1,0)_{12}$
인천 수입	ARMA	$(0,1,1)(1,0,0)_{12}$
	AR	$(1,1,0)(1,0,0)_{12}$
인천 수출	ARMA	$(1,1,0)(0,1,1)_{12}$
	AR	$(1,1,0)(1,1,0)_{12}$

4.3 인공신경망모형의 결과 분석

비선형 특성 \hat{N}_t 을 추정하기 위해 앞선 단계에서 생성된 자료를 바탕으로 ANN모형으로 분석을 수행하였다. Table 2에 ANN모형의 학습결과를 요약하였다.

Table 2 Result of ANN model identification

자료	예측 모형	ANN 모형	신경망 구조			MSE ¹⁾	AIC
			입력노드 기억구조 (size : delay)	은닉 노드	은닉노드 기억구조 (size : delay)		
부산 수입	Naïve ANN	MLP	16 : -	24	-	0.0888	586
		TDNN	4 : 2	18	12 : 1	0.0772	555
	Hybrid AR-ANN	MLP	10 : -	10	-	0.1746	101
		TDNN	17 : 7	7	10 : 7	0.2015	231
수출	Hybrid ARIMA-ANN	MLP	18 : -	15	-	0.2130	366
		TDNN	7 : 8	12	15 : 8	0.2560	523
부산 수입	Naïve ANN	MLP	13 : -	10	-	0.1352	45
		TDNN	2 : 5	24	12 : 1	0.1383	676
	Hybrid AR-ANN	MLP	4 : -	22	-	0.3041	275
		TDNN	15 : 7	3	17 : 7	0.3789	178
수출	Hybrid ARIMA-ANN	MLP	17 : -	10	-	0.3159	135
		TDNN	2 : 10	4	19 : 9	0.3620	155
인천 수입	Naïve ANN	MLP	10 : -	22	-	0.0622	642
		TDNN	7 : 1	6	3 : 2	0.0719	73
	Hybrid AR-ANN	MLP	15 : -	16	-	0.0649	41
		TDNN	19 : 7	10	7 : 7	0.0433	470
수출	Hybrid ARIMA-ANN	MLP	17 : -	11	-	0.0870	135
		TDNN	17 : 7	6	7 : 7	0.0806	244
인천 수입	Naïve ANN	MLP	18 : -	17	-	0.2084	231
		TDNN	20 : 8	2	3 : 1	0.1658	37
	Hybrid AR-ANN	MLP	16 : -	15	-	0.2036	145
		TDNN	6 : 7	13	18 : 7	0.1307	605
수출	Hybrid ARIMA-ANN	MLP	18 : -	20	-	0.1782	802
		TDNN	7 : 7	6	17 : 7	0.1306	255

우선 MSE기준으로 ANN모형의 학습결과를 비교해 보면, 부산 자료에서는 Naïve ANN모형에서 생성된 자료 즉, 추세만 제거한 자료를 사용할 경우 가장 뛰어난 학습성적을 보였다. 그러나 인천 자료에서는 사용된 예측모형별 뚜렷한 차이를 보이지 않는다.

그리고 GA를 사용해 선택된 ANN모형의 네트워크 구조를 보면 사전에 예상했던 것 보다 다소 복잡한 형태를 띠고 있음을 알 수 있다. 예로 부산 수입 자료의 경우 Naïve ANN모형의 MLP 같은 경우 총 408개의 연결가중치이며, TDNN 같은 경우 총 288개의 연결가중치에 대해서 학습이 이루어졌다. 이는 ANN모형의 고유의 특성이라 볼 수 있다. 구조와 관련된 다른 특이점한 점으로 첫째, 사용된 자료에 따른 입력노드와 은닉노드의 시간지연(delay)의 변화이다. 예로 부산 수입 자료의 경우 Naïve ANN모형에서의 입력노드와 은닉노드의 시간지연의 크기는 각각 2와 1이며, 하이브리드 AR-ANN모형에서는 각각 7이며, 하이브리드 ARIMA-ANN모형에서는 각각 8로 점점 증가하는 추세를 보이고 있다. Naïve ANN모형에서 생성된 자료는 추세만 제거된 자료로 정보손실 측면에서 가장 적은 편에 속하며, 하이브리드 ARIMA-ANN모형은 가장 많은 편에 속한다. 이는 해당 자료의 특성에 있어 학습과정에서 정보손실이 많은 자료를 사용할 경우 보다 많은 수의 시간지연이 필요함을 알 수 있다. 두 번째는 사용되는 ANN모형에 따른 네트워크 구조의 복잡성의 변화이다. 앞선 결과에서도 전체적으로 TDNN보다 MLP를 사용할 경우 더욱 복잡한 네트워크 구조를 보였다. 그리고 또한 MLP에서 보다 더 많은 수의 은닉노드를 사용하고 있는 것을 알 수 있다. 이는 TDNN의 구조적인 특징인 입력노도와 은닉노드의 기억지연 라인으로 인한 효과로 볼 수 있다.

Table 3 Result of ANN model

구분	자료	ANN 모형	MSE	구분	자료	ANN 모형	MSE	
부산 수입	Naïve ANN	MLP	0.1711	인천 수입	Naïve ANN	MLP	0.5777	
		TDNN	0.2208			TDNN	0.6079	
	Hybrid AR-ANN	MLP	0.5154		Hybrid AR-ANN	MLP	1.6371	
		TDNN	2.6677			TDNN	1.1313	
	수출	Hybrid ARIMA-ANN	MLP		1.1387	Hybrid ARIMA-ANN	MLP	1.9754
			TDNN		1.8118		TDNN	1.4392
부산 수출	Naïve ANN	MLP	0.4557	인천 수출	Naïve ANN	MLP	0.6153	
		TDNN	0.7107			TDNN	0.5657	
	Hybrid AR-ANN	MLP	1.0894		Hybrid AR-ANN	MLP	4.5431	
		TDNN	1.4340			TDNN	3.7898	
	수출	Hybrid ARIMA-ANN	MLP		0.8435	Hybrid ARIMA-ANN	MLP	4.3116
			TDNN		0.8335		TDNN	2.8283

Table 3에 총 10회 반복실험을 통해 나온 학습의 결과로 결

1) ANN모형의 분석과정에서 사용되는 자료들은 정규화 된 입력자료(normalized input data)들로 NeuroSolutions에서 자동적으로 변환된다.

정된 네트워크 구조에 대한 모형별 예측성과를 요약한 것이다. 전체적으로 추세만 제거한 자료를 사용한 경우 가장 낮은 MSE를 보였다.

예측성과의 차이가 예측모형에 의해 생성된 자료와 사용된 ANN모형에 따라 어떻게 변화하는지를 통계적으로 확인하기 위해 2-way ANOVA분석을 수행하였다. 예측성과의 차이를 검증하기 위해 각 요인들의 주효과와 두 요인간의 상호작용효과를 살펴보았다. 아래 Table 4의 내용처럼 예측모형에 의해 생성된 자료에 따른 주효과는 통계적으로 유의하게 나타난 반면에 사용된 ANN모형에 따른 주효과는 유의하지 않은 것으로 나타났다. 그리고 또한 두 요인간의 상호작용효과 또한 통계적으로 유의하지 않은 것으로 나타났다. 이는 인공신경망모형의 예측성과는 사용되는 입력 자료에 따라 많은 영향을 받고 있음을 시사하고 있으며, 사용된 ANN모형인 MLP와 TDNN에 따른 성과차이는 나타나지 않음을 시사하고 있다.

Table 4 ANOVA table

소스	자유도	제곱합	평균제곱	F값	유의확률
예측모형	2	12.30561	6.15280	4.64	0.0236
ANN모형	1	0.00116	0.00116	0.00	0.9767
예측모형*ANN모형	2	0.43051	0.21526	0.16	0.8513
오차	18	23.84683	1.32482		
합계	236	36.58411			

사용된 ANN모형에 따른 각 예측모형의 MSE 평균을 그림으로 그려보면 다음 Fig. 5와 같다. 평균값의 분포를 살펴보면 앞선 결과와 같이 예측모형별 차이는 존재하지만 사용된 ANN모형별로 차이가 없음을 알 수 있다.




Fig. 5 Mean difference between groups

4.4 예측모형간의 성과비교

4.2에서 AR과 ARIMA모형을 통해 추정된 \hat{L}_t 와 4.3에서 ANN모형을 통해 추정된 \hat{N}_t 을 통해 최종 예측치 \hat{y}_t 을 추정하였다. 그리고 예측모형간의 효과적인 비교를 위해 MSE뿐만 아니라 절대 백분율 오차의 평균(Mean absolute percentage error; MAPE)도 사용하였다.

$$MAPE = 100\% \times \left(\sum_{t=1}^n |(A_t - F_t)/A_t| \right) / n \quad (9)$$

부산 자료에 대한 예측모형간의 비교를 Table 5에 요약하였는데, 대부분의 예측모형이 ARIMA모형보다 뛰어난 예측성과를 보였다. 특히, 부산 수입에서는 Naive ANN모형들이 가장 높은 예측성과를 보인 반면에 부산 수출에서는 4.3의 하이브리드 ARIMA-ANN모형이 가장 높은 성과를 보였다. 그리고 전체적으로 TDNN보다 MLP를 사용한 경우에 더 높은 예측성과를 보였다.

Table 5 Result of forecasting model(Busan)

구분	예측 모형	MSE	MAPE
부산 수입	ARIMA	0.1192	25.83%
	MLP	0.0470	13.57%
	TDNN	0.0606	16.27%
	Hybrid AR-MLP	0.0737	21.61%
	Hybrid AR-TDNN	0.3814	51.00%
	Hybrid ARIMA-MLP	0.0890	21.93%
부산 수출	Hybrid ARMA-TDNN	0.1415	25.10%
	ARIMA	0.0778	21.95%
	MLP	0.1487	29.02%
	TDNN	0.2319	44.37%
	Hybrid AR-MLP	0.1086	18.98%
	Hybrid AR-TDNN	0.1430	19.47%
부산 수출	Hybrid ARIMA-MLP	0.0625	15.11%
	Hybrid ARIMA-TDNN	0.0617	15.35%

Table 6은 인천자료에 대한 예측모형간의 성과비교로 앞선 부산자료와 같이 대부분의 예측모형이 ARIMA모형보다 뛰어난 예측성과를 보였다. 그러나 부산 자료와 달리 예측오차를 측정하는 각기 다른 척도인 MSE와 MAPE에 따라 다른 결과를 보이고 있다. MSE 기준으로 보면, 인천 수입과 수출자료 모두에서 Naive ANN모형들이 가장 높은 예측성과를 보였다. 그리고 전체적으로 MLP보다 TDNN를 사용한 경우에 더 높은 예측성과를 보였다.

Table 6 Result of forecasting model(Incheon)

구분	예측 모형	MSE	MAPE
인천 수입	ARIMA	0.4453	30.88%
	MLP	0.2618	29.91%
	TDNN	0.2755	30.70%
	Hybrid AR-MLP	0.4635	42.16%
	Hybrid AR-TDNN	0.3203	33.03%
	Hybrid ARIMA-MLP	0.4138	38.20%
인천 수출	Hybrid ARIMA-TDNN	0.3015	27.12%
	ARIMA	0.4909	29.25%
	MLP	0.1005	15.59%
	TDNN	0.0924	16.50%
	Hybrid AR-MLP	0.4636	43.01%
	Hybrid AR-TDNN	0.3867	38.79%
인천 수출	Hybrid ARIMA-MLP	0.4827	43.29%
	Hybrid ARIMA-TDNN	0.3166	30.75%

5. 결 론

본 연구에서는 국내 항만 컨테이너 물동량 자료에 대한 ARIMA모형, ANN모형 그리고 하이브리드모형에 대한 비교 연구를 수행하였다. 예측모형의 성과를 비교했을 때, ANN모형과 하이브리드모형들이 ARIMA모형보다 뛰어난 예측성능을 보였다. 본 연구와 유사한 신 등(2008)의 연구에서는 ARIMA모형과 ANN모형을 비교했을 때, ARIMA모형이 뛰어난 예측성능을 보였다는 결과와 상반되는 결론이다. 이러한 결과는 GA를 사용해 네트워크의 구조를 결정하는 것이 ANN모형의 성과에 많은 영향을 준다는 점을 시사하고 있다.

그러나 모든 자료들에 있어 특정 예측모형이 항상 우수한 결과를 보이지 않기 때문에 실제 예측모형 적용시 많은 문제점을 내포하고 있다. 이는 자료가 가지고 있는 여러 특성에 따라 ANN모형에 대한 추가적인 분석이 요구되지만, 본 연구에서는 적은 수의 자료를 바탕으로 실험을 수행하였기에 일반화된 결론을 도출하기에는 한계가 있다. 또한 MLP의 대안으로 제기된 TDNN이 더 좋은 학습결과 및 예측성능을 보일 것이라는 예상과 달리 실험 자료에 따라 각기 다른 결과를 보였고, 이 부분에서 또한 추가적인 자료에 대한 실험을 통해 심층적인 분석이 수행되어야 한다.

본 연구에서 가장 핵심이 되는 부분으로 하이브리드모형의 유효성 검증은 들 수 있는데, 사전적으로 가장 좋은 성과를 보일 것이라고 예상했던 하이브리드모형들에 대한 실험결과를 보면 추세만 제거한 자료를 사용한 Naïve ANN모형보다 월등히 앞선 성과를 보이지 않았다. 이는 Zhang(2003)이 제안한 하이브리드모형들이 항상 좋은 성과를 보장하지 않으며, 이러한 하이브리드모형 또한 원자료에 대한 정보 손실 및 왜곡현상을 발생시킬 수 있다는 것을 의미한다. 이는 Taskaya-Temizel & Casey(2005)가 제기한 문제로서 시계열 자료에 포함되어 있는 선형과 비선형적인 특성이 단순한 가법적인 관계로 형성되어 있다는 가정은 위험성을 내포하고 있다고 서술한 것과 같은 맥락이다.

후 기

본 논문은 한국해양대학교의 2009년 1학기 해외과건교수 지원에 의하여 수행된 연구결과입니다.

참 고 문 헌

[1] 모수원, 김창범(2003), “해상물동량의 추정과 예측,” 해운물류연구, 제37호, pp.1-18.
 [2] 신창훈, 강정식, 박수남, 이지훈(2008), “하이브리드 ARIMA-신경망 모델을 통한 컨테이너물동량 예측에 관한 연구,” 항해항만학회지, 제32권, 제1호, pp.81-88.
 [3] 전찬영(1999), “교차검증을 통한 우리나라 중장기 항만물동량 예측,” 해양정책연구, 제14권, pp.127-157.

[4] 전찬영, 송주미(2007), “인공신경망모형의 항만물동량 예측 적용에 관한 연구,” 해운물류연구 제53호, pp.65-82.
 [5] 지원철(1995), “신경망을 이용한 시계열 분석: M1 - Competition Data에 대한 예측성과 분석,” 한국전문가시스템학회지 창간호, pp.135-148.
 [6] Box, G. E. P. and Jenkins, G. M.(1976), “Time Series Analysis Forecasting and Control,” Holden-Day, San Francisco.
 [7] Chatfield, C.(1993), “Neural Networks: Forecasting Breakthrough or Passing Fad?,” International Journal of Forecasting Vol. 9, No.1, pp.1-3.
 [8] Fishwick, P. A.(1989), “Neural Network Models in Simulation: A Comparison with Traditional Modeling Approaches,” Proceedings of Winter Simulation Conference, pp.702 - 710.
 [9] Geman, G., Bienenstock, E. and Doursat, R.(1992), “Neural Networks and Bias/Variance Dilemma,” Neural Computation, Vol. 4, No. 1, pp.1-58.
 [10] Ghysels, E., Granger, C. W. J and Siklos, P. L.(1996), “Is Seasonal Adjustment a Linear or Nonlinear Data Filtering Process?,” Journal of Business & Economic Statistics, Vol. 14, No. 3, pp.374-386.
 [11] Hansen, J. V., McDonald, J. B and Nelson, R. D(1999), “Time Series Prediction with Genetic-Algorithm Designed Neural Networks: An Empirical Comparison With Modern Statistical Models,” Computational Intelligence, Vol. 15, No. 3, pp.171-184.
 [12] Ittig, P. T.(1997), “A Seasonal Index for Business,” Decision Science, Vol. 28, No.2, pp.335-355.
 [13] Jhee, W. C. and Lee, J. K.(1993), “Performance of Neural Networks in Managerial Forecasting,” International Journal of Intelligent Systems in Accounting and Finance Management, Vol. 2, No. 1, pp.55-71.
 [14] Kim, H. J. and Shin, K. S.(2007), “A Hybrid Approach based on Neural Networks and Genetic Algorithms for Detecting Temporal Patterns in Stock Markets,” Applied Soft Computing Journal, Vol. 7, No. 2, pp.569-576.
 [15] Lapedes, A. and Farber, R.(1987), “Nonlinear Signal Processing using Neural Networks: Prediction and System Modeling,” Los Alamos National Laboratory, Technical Report, LA-UR-87-2662.
 [16] Miller, D. M and Williams, D.(2004), “Damping Seasonal Factors: Shrinkage Estimators for the X-12-ARIMA Program,” International Journal of Forecasting, Vol. 20, No. 4, pp.529-549.
 [17] Nelson, M., Hill, T., Remus, T. and O'Connor, M.(1999),

- “Time Series Forecasting using NNs: Should the Data be Deseasonalized First?,” *Journal of Forecasting*, Vol. 18, No. 5, pp.359-367.
- [18] Ripley, B. D.(1993), “Statistical Aspects of Neural Networks,” In *Networks and Chaos : Statistical and Probabilistic Aspects* ed Barndorff-Nielsen, O. E., Jensen, J. L. and Kendall, W. S., London.
- [19] Sharda, R. and Patil, R. B.(1992), “Connectionist Approach to Time Series Prediction: An Empirical Test,” *Journal of Intelligent Manufacturing*, Vol. 3, No. 5, pp.317-323.
- [20] Taskaya-Temizel, T. and Casey, M. C.(2005), “A Comparative Study of Autoregressive Neural Network Hybrids,” *Neural Networks*, Vol.18 pp.781-789.
- [21] Waibel, A., Hanazawa, T., Hinton, G., Shikano, K. and Lang, K.(1989), “Phoneme Recognition using Time Delay Neural Networks,” *IEEE Transactions on Acoustics, Speech and Signal Process*, Vol. 37, No. 3, pp.328-339.
- [22] Weigend, A. S., Rumelhart, D. E. and Huberman, B. A.(1990), “Backpropagation, Weight-elimination and Time Series Prediction,” *Connectionist Models: proceedings of the 1990 Summer School*, pp.105-116.
- [23] White, H.(1988), “Economic Prediction using Neural Networks: The Case of IBM Daily Stock Returns,” *Proceedings of the IEEE International Conference on Neural Networks*, 2, pp.451-458.
- [24] Zhang, G. P.(2003), “Time Series Forecasting using a Hybrid ARIMA and Neural Network Model,” *Neurocomputing*, Vol. 50, No. 2, pp.159-175.
- [25] Zhang, G. P. and Qi, M.(2005), “Neural Network Forecasting for Seasonal and Trend Time Series,” *European Journal of Operational Research*, Vol. 160, No. 2, pp.501-514.

원고접수일 : 2011년 1월 24일

심사완료일 : 2011년 2월 24일

원고채택일 : 2011년 2월 25일