



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

物流學碩士 學位論文

컨테이너물동량 예측에 있어  
유전알고리즘을 이용한 인공신경망  
적용에 관한 연구

**A Study on Application of Neural Network using  
Genetic Algorithm in Container Traffic Prediction**



指導教授 申宰榮

20010年 2月

韓國海洋大學校 大學院

物流시스템學科

鄭 秀 賢

本 論 文 을 鄭 秀 賢 의 物 流 學 碩 士 學 位 論 文 으 로 認 准 함.

委 員 長    工 學 博 士    李 哲 榮    (인)

委    員    工 學 博 士    郭 圭 錫    (인)

委    員    工 學 博 士    申 宰 榮    (인)



2010年 2月

韓 國 海 洋 大 學 校 大 學 院  
物 流 시 스템 學 科

鄭 秀 賢

# 목 차

## ABSTRACT

제 1 장 서 론 .....	1
1.1 연구의 배경 및 목적 .....	1
1.2 선행 연구 .....	3
1.3 연구의 방법 및 구성 .....	7
제 2 장 방 법 론 .....	8
2.1 자기회귀이동평균모형(ARIMA) .....	8
2.2 인공신경망(ANN) .....	13
2.2.1 개요 .....	14
2.2.2 시간지연네트워크(TDNN) .....	21
2.3 유전알고리즘(GA) .....	26
2.4 Hybrid ARIMA-ANN .....	30
제 3 장 실증분석 .....	33
3.1 컨테이너물동량 자료 .....	36
3.2 ARIMA 분석 결과 .....	39
3.3 인공신경망 분석 결과 .....	41
3.4 Hybrid ARIMA-ANN 분석 결과 .....	49
제 4 장 결 론 및 향후 연구방향 .....	51
참고문헌 .....	53

## 표 목 차

<표 3-1> GA 관련 모수에 대한 사전분석 결과(MSE기준) .....	34
<표 3-2> 전체 실험 자료 .....	38
<표 3-3> ARIMA 분석 결과 .....	40
<표 3-4> ANN모형의 분석 자료에 대한 기초통계량 .....	41
<표 3-5> ANN모형의 입력 자료 .....	44
<표 3-6> Heuristic ANN 구조 .....	44
<표 3-7> ANN모형들에 대한 학습 결과(MSE 기준) .....	45
<표 3-8> 교차방식에 따른 예측결과(MAD 기준) .....	46
<표 3-9> TDNN_GA의 구조 .....	47
<표 3-10> MLP와 TDNN의 예측결과(MAD 기준) .....	48
<표 3-11> 부산 수입, 수출 물동량 예측결과 .....	50
<표 3-12> 인천 수입, 수출 물동량 예측결과 .....	50



## 그 립 목 차

<그림 2-1> Box and Jenkins 기법 .....	10
<그림 2-2> 인공신경망의 장점 .....	13
<그림 2-3> MLP .....	15
<그림 2-4> 노드간 연결방식에 따른 신경망 구분 .....	15
<그림 2-5> 뉴런의 기능 .....	16
<그림 2-6> 뉴런의 입력함수 .....	17
<그림 2-7> 활성화함수의 종류 .....	17
<그림 2-8> 인공신경망의 학습과정 .....	19
<그림 2-9> MLP와 TDNN의 차이 .....	22
<그림 2-10> Time delay line .....	23
<그림 2-11> TDNN .....	23
<그림 2-12> 유전알고리즘의 수행절차 .....	26
<그림 2-13> 문제의 표현 .....	27
<그림 2-14> 대표적인 교차연산 .....	28
<그림 2-15> 돌연변이 연산 .....	29
<그림 2-16> Hybrid ARIMA-ANN .....	31
<그림 3-1> 신경망 구조에 대한 검색체 표현 .....	34
<그림 3-2> 부산항 수입 물동량 .....	36
<그림 3-3> 부산항 수출 물동량 .....	36
<그림 3-4> 인천항 수입 물동량 .....	37
<그림 3-5> 인천항 수출 물동량 .....	37
<그림 3-6> 부산항 수입 물동량에 대한 백색잡음 .....	42
<그림 3-7> 부산항 수출 물동량에 대한 백색잡음 .....	42
<그림 3-8> 인천항 수입 물동량에 대한 백색잡음 .....	43
<그림 3-8> 인천항 수출 물동량에 대한 백색잡음 .....	43

# **A Study on Application of Neural Network using Genetic Algorithm in Container Traffic Prediction**

Su Hyun, Jeong

Department of Logistics Engineering  
Graduate School of Korea Maritime University



## **Abstract**

On this study, 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. The existing studies have been used the rule of thumb in topology design for network which had a great effect on forecasting performance of the artificial neural network. However, this study applies the genetic algorithm, known as the effectively optimal algorithm in the huge and complex sample space, as the alternative. And we use the time delayed neural network(TDNN) instead of multi-layer perceptron(MLP) which is the most popular neural network model. Finally, we use the hybrid methodology that combines both the linear ARIAM and the nonlinear ANN models, and compare the methodology with other models in performance for prediction.

# 제 1 장 서 론

## 1.1 연구의 배경 및 목적

항만은 예전부터 국가간 교역에 있어 주요 관문으로 자리매김해왔으며 세계경제의 국제화가 급격히 진전됨에 따라 그 역할에 대한 중요성은 날로 증가하고 있다. 세계 각국은 보다 현대적이고 효율적인 항만개발에 대한 수요급증에 직면하게 되었고, 이러한 변화에 효과적으로 대응하기 위해서는 체계적이며 항만개발 및 시설투자계획들이 요구된다. 그리고 항만서비스의 주요 고객이 되는 해운선사들은 운항선박의 대형화를 통해 규모의 경제를 획득하고자 한다. 이와 같은 경향은 선박의 기항지 축소로 이어지며 결국은 국내 혹은 국제 항만간의 경쟁을 가속화 시키고 있다. 오늘날 특정 항만이 이러한 경쟁에서 살아남기 위해서는 항만운영의 효율성 제고라는 목표달성이 최우선과제로 꼽히고 있다.

이처럼 항만운영자가 급격히 변화하는 해운시장 환경에 대해 효과적으로 대응하기 위해서는 물동량 예측에 관한 신뢰성 있는 정보를 바탕으로 수립된 항만개발 및 시설 투자계획 그리고 운영계획들이 필요하다. 또한 전체 항만시스템의 효율성 제고라는 목표를 달성하기 위해서라도 물동량에 관한 예측이 필수적으로 선행되어야 한다.

이처럼 예측의 정확성은 총 비용의 감소나 더 나은 고객서비스 제공에 있어 중요한 요인으로 작용하기 때문에 지금까지도 예측성과를 높이기 위한 다양한 예측기법이 개발되고 있다. 특히, 시계열자료 예측에 있어 대표적인 선형예측기법인 자기회귀이동평균(ARIMA; autoregressive integrated moving average)모형은 과거의 연구들을 통해 그 우수성을 입증 받았으며, 이후 반세기 동안 이와 같은 선형시스템에 의한 시계열 분석이 주류를 이루어 왔다. 그러나 선형시스템을 기반으로 한 전통적인 수요예측기법들로 설명하기 어려운 현상들이 실제 현실에서 다수 존재한다는 한계점으로 인해 새로운 예측기법 개발에 대한 노력들이 시작되었다. 대표적인 기법으로서 기계학습(machine learning)이라는 메커니즘을 기반으로 한 인공신경망(ANN; artificial neural network)모형이다. 이는 전통적인 수요예측기법에 대한 대안으로서 인식되기 시작하

면서 여러 분야에서 광범위하게 연구되고 있다. 특히, 인공신경망의 장점 중 하나인 만능 근사기(Universal Approximator)로서 기능은 주어진 자료에 대한 적합 능력이 매우 뛰어남을 의미한다.

그러나 인공신경망을 이용해 시계열의 예측성과를 ARIMA모형을 포함한 다양한 전통적인 수요예측기법들과 비교 평가한 과거 연구들을 보게 되면 각기 주장하는 바와 그 결론이 상반됨을 알 수 있다.

그래서 본 연구에서 인공신경망의 예측성과를 높이기 위한 선행연구들의 다양한 시도들을 바탕으로 컨테이너물동량 예측에 있어 정확성 높은 예측기법을 비교 검증하였다.



## 1.2 선행 연구

Lapedes & Farber(1987)의 연구에 의해서 처음으로 시계열 자료 분석에 인공신경망을 적용시키는 시도가 이루어졌다. 이 연구에서 오류역전파(back propagation) 알고리즘을 사용해 다층퍼셉트론(MLP; multi-layer perceptron)을 학습시킨 결과 해당 자료에 대한 적합은 물론이며 예측력에 있어서도 전통적인 수요예측기법들보다 더 우수한 성과를 보인다는 것을 밝혔다. 그 이후 많은 연구자들에 의해서 기계학습을 통한 인공신경망이 시계열예측에 있어 좋은 성과를 보임이 증명되었다.(Weigend et al, 1990; Sharda & Patil, 1992; Jhee & Lee, 1993)

그러나 White(1988), Fishwick(1989) 및 Ripley(1993)의 연구에서는 인공신경망이 기존의 통계적 방법들에 비해 더 좋은 예측성적을 보인다고 말할 수 없다는 연구결과를 발표하였다.

이와 같이 상반되는 연구결과들에 대해 Chatfield(1993)는 인공신경망이 새로이 등장한 유력한 예측기법임에 틀림없지만 체계적인 실증적 분석이 필요함을 강조하였고, 여러 연구자들에 의해서 인공신경망의 예측성적을 향상시키기 위한 다양한 시도들이 이루어져 왔다. 그 중 하나가 해당 시계열자료에 추세나 계절성을 제거하므로 인공신경망의 예측성적을 높이기 위한 시도이다.

Nelson et al.(1999)의 연구에서는 시계열 예측에 인공신경망을 적용할 경우, 원자료(raw data)를 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 인공신경망의 예측성적을 향상시키기 위해서는 시계열 자료에 포함되어 있는 계절성만 제거하는 것이 아니라 추세도 같이 제거하게 되면 원자료와 계절조정자료를 사용하는 것에 비해 더 좋은 예측성적을 보인다고 밝혔다.

전찬용과 송주미(2007)의 연구에서 국내 주요 수출입품목 10개를 선정하여 인공신경망모형과 회귀분석모형의 예측력을 비교하는 연구를 수행하였다. 이 연구에서는 해

당 시계열 자료에 존재하는 자체의 특성에 따라 상이한 결과를 보인다고 밝혔다. 뚜렷한 추세를 지니고 있는 ‘상속지속형’일 경우 회귀분석이 ‘불규칙 상승’, ‘상승 둔화’, ‘정체’의 경우처럼 일정한 추세가 있다고 보기 힘든 자료 같은 경우 인공신경망모형이 더 높은 예측성과를 보임을 밝혔다. 이처럼 해당 시계열이 가지고 있는 특성에 따라 상이한 결과를 보이고 있어, 시계열에 내재되어 있는 특성에 따라 예측기법이 개발이 되어야함을 보여주고 있다.

이지원(2008)의 연구에서는 부산항의 부두별 수입, 수출 물동량을 대상으로 인공신경망을 적용하였다. 여기에서 해당 시계열의 원자료, 추세성이 제거된 자료, 계절성이 제거된 자료 그리고 추세성과 계절성 모두 제거된 자료에 대한 인공신경망으로 분석을 수행하였고 그 결과를 ARIMA모형과 비교했다. 그 결과 뚜렷한 추세를 보이는 자료에 대해서는 ARIMA모형이 뛰어나고, 불규칙적 추세와 불규칙 정체의 자료에 대해서는 인공신경망이 뛰어난 결과를 보였다. 이 연구에서도 또한 시계열자료의 자체 특성을 고려해 적절한 자료변환을 한 뒤, 인공신경망으로 분석을 수행한 결과 보다 뛰어난 예측성과를 보임을 밝혔다.

그러나 Ghysels et al.(1996)의 연구에서는 단변량 시계열자료에 있어서도 계절성을 제거하는 과정에서 원치 않는 비선형특성을 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 인공신경망의 예측성과를 높이기 위해 사용되고 있는 추세성과 계절성에 대한 조정이 원자료에 대한 정보 손실 및 왜곡현상을 발생시킬 수 있기 때문에, 인공신경망을 적용하는 문제에 있어 원자료 변환에 대한 조심스러운 접근법이 필요하다고 말하고 있다.

그와 달리 Geman et al(1992)연구에서는 그동안 제시된 MLP관련 학습이론에 문제가 있는 것이 아니라, 주어진 문제를 MLP를 사용하여 표현하는데 어려움이 있다고 주장하였다. 즉 인공신경망을 적용하는 문제에 있어 적합한 인공신경망 모형의 선택 및 선택된 신경망의 적절한 구조를 결정하는 것이 가장 중요한 문제라는 것이다. 이와 같은 시도들 또한 다양한 연구자들에 의해서 수행되었다.

Hansen et al(1999)의 연구에서는 기존의 널리 사용되고 있는 MLP에 비해 시간패

턴인식에 있어 더 뛰어난 성능을 보이고 있는 시간지연신경망(TDNN; Time delayed neural network)을 사용하여 시계열자료에 대한 예측을 수행하였다. 그리고 인공신경망 적용에 있어 어려움 점 중 하나인 신경망 구조결정(network topology design)에 있어 과거의 연구들과 달리 유전알고리즘(GA; genetic algorithm)을 사용하였다. 인공신경망모형의 성과는 신경망구조에 의해서 많은 영향을 받게 되는데, 이러한 구조결정문제에 유전알고리즘을 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 신경망모형을 Heuristic NN이라 정의하였고, 그 결과 ARIMA모형과 Heuristic NN보다 네트워크 구조결정에 유전알고리즘을 사용한 Hybrid GA\_NN 모형이 더 좋은 예측성과를 보임을 밝혔다.

또한 Kim, H. J. and Shin, K. S.(2006)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 시계열 예측에 Hybrid ARIMA-ANN을 사용하였다. 이는 비선형자료 분석에 있어 장점을 보이지만 선형자료 분석에 각기 다른 결과를 보이는 인공신경망모형에 ARIMA모형을 결합시키므로 인공신경망모형을 단점을 보완하였다. 그 결과 ARIMA나 ANN을 개별적으로 사용하는 것보다 Hybrid ARIMA-ANN을 사용하는 것이 더 좋은 예측성과를 보임을 밝혔다.

신창훈 외 3명(2008)연구에서는 Hybrid ARIMA-ANN모형을 국내 주요 항만의 컨테이너물동량 예측에 적용시켰다. 이 연구에서는 ARIMA모형, 인공신경망모형 그리고 Hybrid ARIMA-NN모형을 사용해 성과에 대한 비교연구를 수행한 결과로 대부분의 자료에서 ARIMA모형이 더 높은 예측성과를 보였다. 이는 인공신경망을 사용해 국내 컨테이너물동량을 예측하는데 있어 추가적인 실증적 분석이 요구됨을 나타내고 있다.

그래서 본 연구에서는 컨테이너물동량 예측에 있어 기존에 널리 사용되고 있는 MLP 대신 시간패턴인식에 효과적으로 알려진 TDNN을 사용하였다. 그리고 신경망의 구조 설계에 있어 기존의 선행연구들에서 주로 사용해 왔던 경험론적 방법론의 대안으로서 방대하며 복잡한 탐색공간에서 효과적으로 알려진 유전알고리즘(GA)을 사용하여 최적의 신경망구조를 설계하였다. 그리고 최종적으로는 Hybrid ARIMA-ANN모

형을 사용해 ARIMA모형과 예측성과를 비교하였다.



### 1.3 연구의 방법 및 구성

본 연구에서 국내 항만의 컨테이너 처리실적에 대한 시계열자료를 이용해 분석을 수행하였다. 대표적으로 많이 사용하고 있는 예측기법인 ARIMA모형을 중심으로 본 연구에서 제안한 방법을 사용해 예측성과를 비교하였다. 특히, 인공지능경망의 효과적인 학습을 위해서는 충분한 수의 관측치 확보가 무엇보다 중요한 문제이기 때문에 국내 항만 중에서 가장 많은 관측치를 확보할 수 있는 부산항과 인천항을 중심으로 분석을 수행하였다.

본 연구의 구성은 다음과 같다.

2장에서는 본 연구에서 사용되는 방법론들에 대해서 설명하였다. 3장에서는 본 연구에서 사용되는 컨테이너물동량자료를 포함한 다양한 자료와 실험방법에 관한 설명과 함께 분석 결과를 요약하였다. 그리고 4장을 마지막으로 본 연구의 결론과 함께 향후 연구방향들을 제시하였다.



## 제 2 장 방 법 론

### 2.1 자기회귀이동평균모형 (ARIMA)

시계열 분석에서 가장 많이 활용되고 있는 모형인 자기회귀이동평균(Autoregressive integrated moving average)모형은 선형시스템에 기반을 둔 통계학적 분석기법으로서 과거의 많은 연구들을 통해 그 우수성이 입증 되었으며, 이후 반세기 동안 시계열분석에서 있어 주류를 이루어 왔다. ARIMA모형은 Box and Jenkins(1976)에 의해서 이론적으로 체계화되었다. 이는 해당 시계열의 과거 경향에 기초한 확률과정에 대하여 특정한 모형을 설정을 한 뒤, 미래 경향을 설명하고 예측 하는 기법으로 모든 형태의 단변량(univariate) 시계열 분석에 적용가능하다.

#### 1) ARMA모형의 구조

시계열  $y_t$ 에 대한 ARMA모형의 일반적인 형태인 ARMA (p,q)는 아래 식 (1)과 같은 함수형태로 표현된다.

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \epsilon_t - \theta_1 \epsilon_{t-1} - \theta_2 \epsilon_{t-2} - \dots - \theta_q \epsilon_{t-q} \quad (1)$$

여기서  $\epsilon_t$ 는 평균이 0이고 분산이  $\sigma^2$ 인 백색잡음(white noise)을 의미한다.

식 (1)에서 보이는 것처럼 ARMA모형은 해당 단변량 시계열에 대한 자기회귀(AR; autoregressive)모형과 백색잡음의 이동평균(MA; moving average)모형에 대한 선형 관계식형태로 이루어져 있다.

차수가 p인 자기회귀모형 AR(p)의 형태는 아래 식 (2)처럼 표현된다.

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \epsilon_t \quad (2)$$

AR(p)모형은 현재 시점에서의 시계열 관측치인  $y_t$ 가 p개의 과거 관측치들과 현재 시점 t의 백색잡음  $\epsilon_t$ 의 합으로 표시되는 시계열을 분석하는데 적당하다.

그리고 차수가 q인 이동평균모형 MA(q)의 형태는 아래 식 (3)과 같다.

$$y_t = \epsilon_t - \theta_1\epsilon_{t-1} - \theta_2\epsilon_{t-2} \cdot \cdot \cdot \cdot \cdot - \theta_q\epsilon_{t-q} \quad (3)$$

MA(q)모형은 현재 시점에서의 시계열 관측치인  $y_t$ 가 현재 시점과 과거의 q개의 백색잡음  $\epsilon$ 의 합으로 표시되는 시계열을 분석하는데 적당하다.

ARMA모형의 또 다른 장점은 계절성 변동을 포함하는 시계열 자료에 대해서도 모형화가 가능하다는 것이다. 이는 보다 다양한 형태의 시계열 자료에 대해서도 효과적인 분석이 가능하며, 이를 계절 ARMA(seasonal ARIMA)모형이라 한다. 일반적인 형태인 ARMA (p,q)×(P,Q)<sub>s</sub>는 아래 식 (4)과 같이 표현된다.

$$y_t = \phi_1y_{t-1} + \phi_2y_{t-2} + \cdot \cdot \cdot \cdot \cdot + \phi_py_{t-p} \quad (4)$$

$$+ \Phi_sy_{t-s} + \Phi_{2s}y_{t-2s} + \cdot \cdot \cdot \cdot \cdot + \Phi_{Ps}y_{t-Ps} + \epsilon_t$$

$$- \theta_1\epsilon_{t-1} - \theta_2\epsilon_{t-2} - \cdot \cdot \cdot \cdot \cdot - \theta_q\epsilon_{t-q}$$

$$- \Theta_s\epsilon_{t-s} - \Theta_{2s}\epsilon_{t-2s} - \cdot \cdot \cdot \cdot \cdot - \Theta_{Qs}\epsilon_{t-Qs}$$

여기서 s는 계절변동 주기(seasonal length)라 하면 계절성 변동이 존재할 때, 분기별 자료일 경우 s = 4가 되고, 월별 자료일 경우 s = 12가 된다. 아래 식 (5)은 계절변동 주기 s를 가지고 있는 자기회귀모형 AR(P)<sub>s</sub>를 표현한 것이다.

$$y_t = \Phi_sy_{t-s} + \Phi_{2s}y_{t-2s} + \cdot \cdot \cdot \cdot \cdot + \Phi_{Ps}y_{t-Ps} + \epsilon_t \quad (5)$$

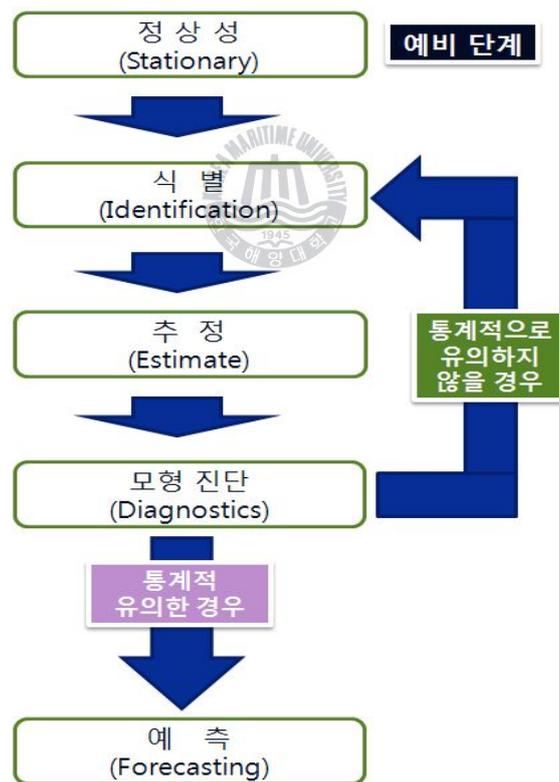
계절변동 주기 s를 가지고 있는 이동평균모형 MA(Q)<sub>s</sub>는 아래 식(6)과 같다.

$$y_t = \epsilon_t - \Theta_s\epsilon_{t-s} - \Theta_{2s}\epsilon_{t-2s} \cdot \cdot \cdot \cdot \cdot - \Theta_{Qs}\epsilon_{t-Qs} \quad (6)$$

2) 박스-젠킨스 기법(Box and Jenkins method)

ARIMA모형을 시계열 분석에 적용함에 있어 Box and Jenkins(1976)에 의해서 정립된 박스-젠킨스 기법이 많은 연구자들에 의해서 사용되어 왔다. 이는 시계열의 표준모형인 AR, MA, ARMA 등의 이론적 성질을 기초로 하여 시계열 자료로부터 최적의 모형을 결정하는 분석기법으로, 이 기법이 널리 사용되고 있는 이유로는 다른 방법론에 비해 비교적 완전한 이론적 체계를 갖추고 있으면서도 거의 모든 형태의 시계열 자료에 적용할 수 있는 있다는 점이다.

박스-젠킨스 방법은 기본적으로 <그림 2-1>와 같이 분석을 위한 예비단계를 포함한 총 5 단계로 구성되어 있다.



<그림 2-1> Box and Jenkins 기법

첫 번째 단계는 ARIMA 분석을 위한 예비 단계로서, 해당 시계열 자료에 대한 정상성(stationary) 여부를 판별한다. 여기서는 말한 정상성이란 시간의 변화에도 그 확률구조(probabilistic structure)가 변하지 않음을 말한다. 즉, 시간  $t$ 에 따른 해당 시계열의 평균이나 분산, 공분산 등이 일정한 형태를 보임을 말한다. 박스-젠킨스 기법에서는 분석의 대상이 되는 시계열 자료가 정상성을 보인다는 전제하에서 이루어지기 때문에 해당 시계열의 정상성 판별여부가 무엇보다 중요한 문제이다. 그러나 실제 현상에서 나타나는 시계열은 비정상(non-stationary)인 경우가 대부분이다. 이는 시간에 따라 변하는 확률구조를 가지고 있다는 의미로서 대표적인 경우가 해당 시계열이 추세(trend)성분을 지고 있는 경우이다. 그래서 주어진 시계열이 비정상성일 때 그 형태에 따라 적절한 방법을 통해 정상시계열로 변환시키는 작업이 수행되어야 하는데, 이를 비정상시계열의 정상화라고 한다. 이러한 방법은 크게 두 가지로 나눌 수 있다. 첫 번째는 추세를 지니고 있는 시계열에 대한 평균의 정상화이다. 이는 차분연산과 회귀모형의 적합 등을 통해 추세를 제거해 정상시계열로 만드는 과정이다. 그리고 두 번째는 해당 시계열에 대한 분산의 정상화이다. 이는 로그변환(logarithm transformation)이나 제곱근변환(square root transformation)을 통해 정상시계열로 만들 수 있다. 보통 분산의 변화가 심한 경우에는 제곱근변환보다는 로그변환이 더 효과적이라고 알려져 있다.

두 번째 단계인 식별(identification)에서는 주어진 시계열 자료를 기초로 시계열의 표준모형인 AR, MA, ARMA 모형 중에서 해당 시계열의 예측에 적합한 모형을 찾는다. 이는 시계열 자료가 가지고 있는 주요 특징이나 패턴들을 정확히 기술할 수 있는 모형을 선택함과 동시에 추정해야 할 모수의 수 즉, 차수를 결정하는 단계이다. 우선 해당 시계열 자료로부터 표본자기상관함수(SACF; sample autocorrelation function)와 표본편자기상관함수(SPACF; sample partial autocorrelation function)을 계산하고, 이것을 바탕으로 이론적 자기상관함수(ACF; autocorrelation function)와 편자기상관함수(PACF; partial autocorrelation function)에 따라 다른 형태를 갖는다는 이미 알려진 성질을 이용하여 시계열 자료가 생성되었다고 판단되는 모형과 차수를 결정한다.

세 번째 단계인 추정(estimation)에서는 식별단계에서 결정된 모형과 모수를 추정하는 단계로서, 기본적으로 최소제곱법(LS; least square method)과 최대우도법(ML;

maximum likelihood method) 등이 사용된다.

네 번째 단계인 진단(diagnostics)에서는 식별과 추정단계를 통해 확정된 모형과 모수에 대한 통계적으로 타당한지를 확인한다. 진단의 방법에는 오차항에 대한 백색잡음 여부를 파악하는 잔차분석(residuals)이 주로 이용된다. 그리고 모수를 단계별로 추가해 가는 단계적 적합(stepwise fitting)에서 모델 선택 기준으로 SBC(Schwarz's Bayesian criterion), AIC(Akaike Information Criterion) 통계량을 주로 사용한다.

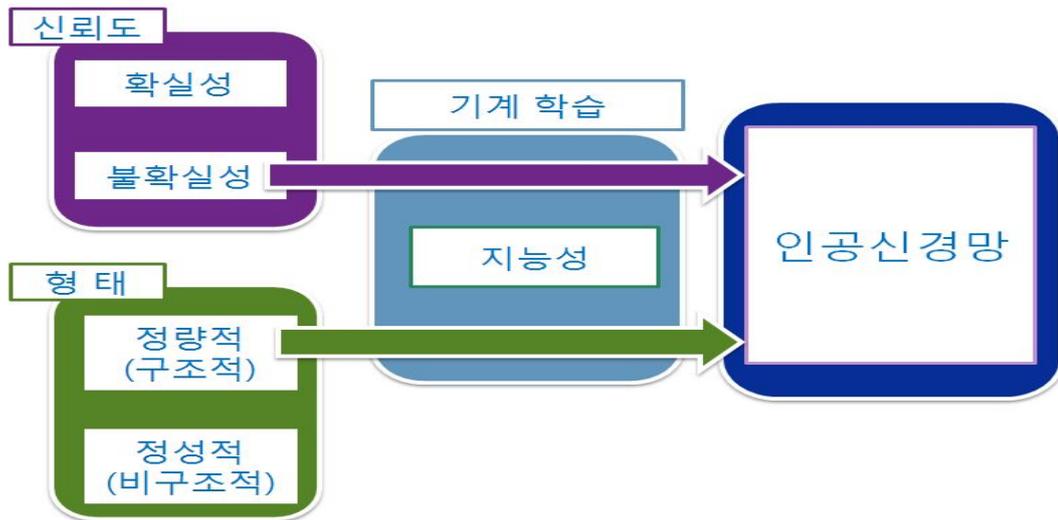
마지막 단계인 예측(forecasting)에서는 판별, 추정 그리고 진단의 세 단계를 거쳐 확정된 모형을 이용해 시계열의 미래 값을 결정하고 그 예측의 정확도를 평가한다.



## 2.2 인공신경망(ANN)

인공신경망모형은 생물학적 신경계를 단순화시켜서 만든 수학적 모형으로서 McCulloch & Pitts(1943)에 의해서 연구가 시작되었다. 이들 연구에서 인간의 두뇌(brain)를 신경세포(neuron)와 그 신경세포간의 연결(synapse)로 정의하였다. 그리고 신경세포를 마디(node)로, 신경세포간의 연결은 가지(arch)로 표현하므로 일종의 네트워크(network)형태로 표현하였다.

인공신경망모형은 특히 부정확한 정보 또는 불완전한 정보에 대한 추론능력이 기존의 방법보다 월등히 뛰어나며, 자체적으로 학습능력이 있기 때문에 자료의 변화 또는 상황의 변화에 따라 스스로의 기능을 개선시킬 수 있다. 또한 정량적인 변수뿐만 아니라 정성적인 변수도 동시에 고려할 수 있으며, 그와 함께 분석의 대상이 되는 자료에 대한 일련의 엄격한 가정이나 전제조건들이 요구되지 않기 때문에, 자료가 가지고 있는 고유 특성을 분석에 그대로 반영할 수 있다. 그래서 엄격한 가정하에서 수행되는 통계학적 접근법의 대안으로서 인공신경망의 성능을 검증하기 위한 많은 연구들이 수행되어 왔다.



<그림 2-2> 인공신경망의 장점

인공신경망의 장점을 간단히 정리하면 첫째, 병렬연산장치로서 복잡한 현상에 대한 빠른 연산이 가능하다는 점이다. 둘째, 결합허용능력을 지니고 있어 오차나 잡음(noise)에 대한 강인성(Robustness)이 뛰어나다. 셋째, 학습메커니즘의 목표값(target value)을 바탕으로 원하는 형태의 사상(mapping)을 만들 수 있다. 그리고 마지막으로 연상기억이 가능하기에 새로운 입력 자료나 일부 유실된 정보에서도 학습된 형태로서 유사한 결과들을 출력한다.

그래서 인공신경망의 초창기 연구들은 패턴인식(pattern recognition)과 관련된 분야에서 활발하게 논의가 이루어졌지만, 많은 연구자들에 의해 인공신경망이 가지고 있는 장점이 점차 부각되면서 그 적용분야가 차츰 확대되고 있다. 그래서 현재 패턴인식뿐만 아니라 군집화(clustering), 함수근사(function approximation), 예측(prediction), 최적화(optimization) 등과 같이 다양한 분야에 적용되기 시작하였다. 특히 예측부분에 있어서는 Lapedes & Farber(1987)에 의해서 시계열 자료 분석에도 인공신경망의 적용 가능성이 발견되었고, 현재 많은 연구자들에 의해서 활발하게 관련 연구들이 수행되고 있다.

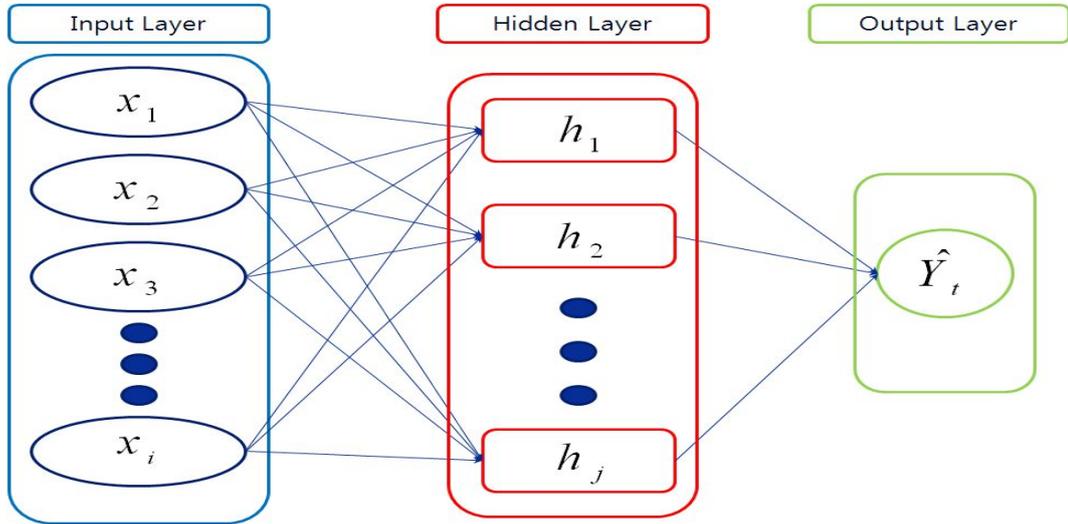


## 2.2.1 개요

### 1) 인공신경망의 구조

인공신경망에는 다양한 모형이 존재하지만, 일반적으로 가장 널리 사용되는 모형으로는 역전파 학습알고리즘(back-propagation learning algorithm)을 사용하는 다층퍼셉트론(MLP; multi-layer perceptron)이다. 이는 Rumelhart & McClelland(1986)의 연구에 의해서 대중화되었고, 현재에도 인공신경망의 표준 모형으로 사용되고 있다.

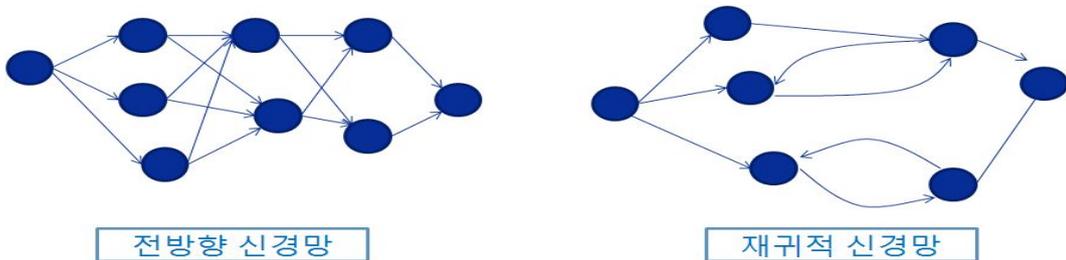
MLP는 각각 1개의 입력층(input layer)과 출력층(output layer) 그리고 입력층과 출력층 사이에 하나 이상의 은닉층(hidden layer)으로 구성되어 있다. <그림 2-3>에서 입력층, 출력층 그리고 은닉층 각각 1개씩으로 구성된 MLP를 그림으로 표현하였다.



<그림 2-3> MLP

각 층(layer)별로 하나 이상의 노드들이 존재하며, 이러한 노드들이 서로 연결되어 있어 있는 방향성 있는 네트워크임을 알 수 있다.

그리고 노드간의 연결방식(connection pattern)에 따라 크게 전방향 신경망(feed-forward neural network)과 재귀적 신경망(recurrent neural network) 이 두 가지로 나눌 수 있다. 이는 노드간 연결에 있어 순환적 혹은 피드백 연결이 존재하는지에 따라 구분되는데, <그림 2-4>에서 두 신경망모형을 차이점을 그림으로 표현하였다. 재귀적 신경망은 전방향 신경망과 달리 노드간 연결방식에 있어 순환적 연결을 가지고 있음을 알 수 있다.

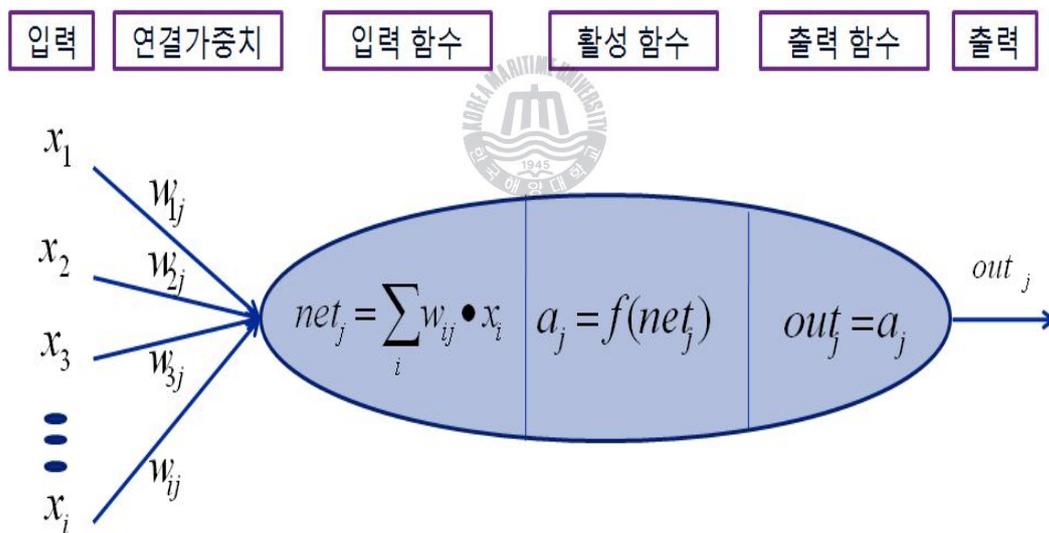


<그림 2-4> 노드간 연결방식에 따른 신경망 구분

정리하자면 <그림 2-3>에서 표현된 인공신경망은 입력층에  $i$ 개의 입력노드(input node)  $x_1, x_2, x_3, \dots, x_i$ , 은닉층에는  $j$ 개의 은닉노드(hidden node)  $h_1, h_2, \dots, h_j$  그리고 출력층에는 하나의 출력노드(output node)로 구성된 다층 전방향 신경망(multilayer feed-forward neural network)이다.

## 2) 뉴런(neuron)의 기능

뉴런은 인공신경망의 가장 중요한 부분으로서 기본적으로 많이 사용되는 MLP를 묘사한 <그림 2-3>에서 개별 노드에 해당하는 부분이다. 뉴런의 정보 처리과정은 입력함수, 활성화함수 그리고 출력함수 총 세 부분으로 나눌 수 있는데, <그림 2-5>에서 각각의 정보 처리과정을 그림으로 표현하였다.

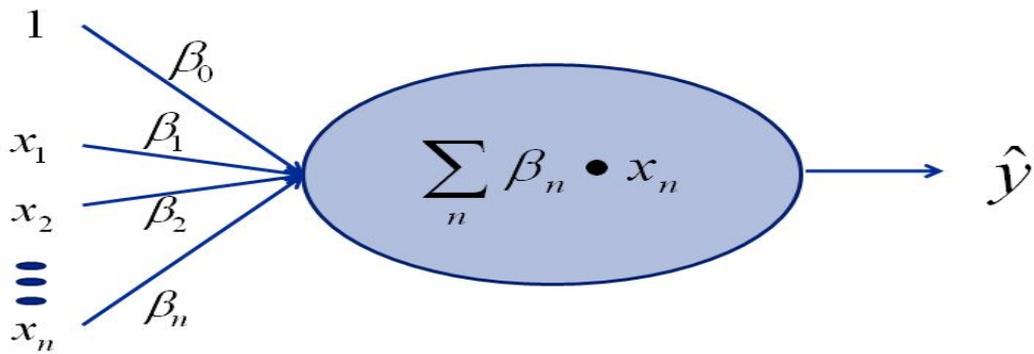


<그림 2-5> 뉴런의 기능

첫 번째는 입력함수(input function) 혹은 결합함수(combination function)라 불리는 부분으로 해당 뉴런으로 들어오는 입력값과 그에 대한 연결가중치(connect weight)를 곱한 뒤 총합을 하는 과정이다. <그림 2-6>에서는 입력함수만 작동하는 뉴런의 기능

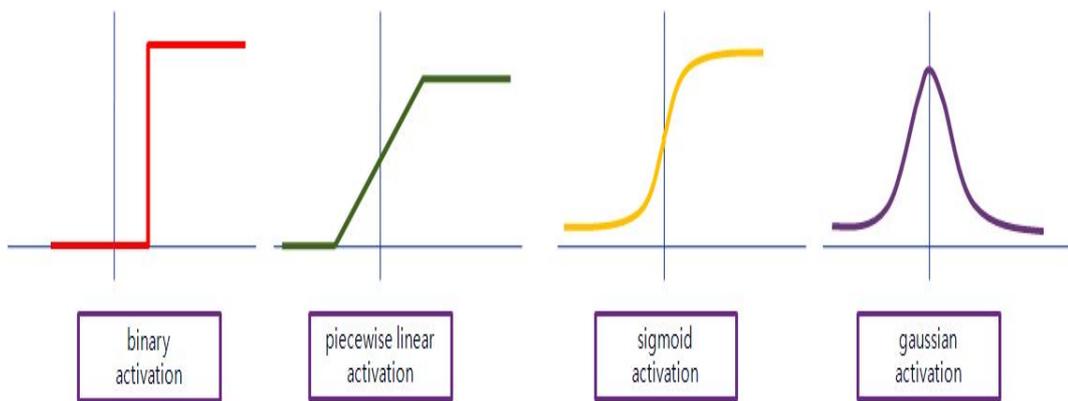
을 그림으로 표현하였다. 이는 식 (7)과 같은 일반적인 선형회귀식과 동일한 형태임을 알 수 있다.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \epsilon \quad (7)$$



<그림 2-6> 뉴런의 입력함수

두 번째는 활성화함수(activation function) 혹은 전이함수(transfer function)라 불리는 부분으로 입력함수의 결과값에 대한 비선형 사상(non-linear mapping)을 수행하는 부분으로 은닉층과 출력층의 범위를 일정한 범위로 제한하는 역할을 수행한다. <그림 2-7>에서는 인공지능망모형에 사용되는 다양한 활성화함수를 그림으로 표현하였다.



<그림 2-7> 활성화함수의 종류

활성함수의 선택에 있어서는 해당 연구의 목적에 따라 각기 다른 형태의 활성함수를 사용하지만, 연속형 변수를 사용할 경우 시그모이드(sigmoid)함수가 가장 보편적으로 사용된다. 그 중에서 식 (8)과 같은 로지스틱함수와 식 (9)과 같은 쌍곡탄젠트 함수가 주로 사용된다.

$$\text{로지스틱스 함수 : } f(x) = \frac{1}{1+e^{-x}} \quad (8)$$

$$\text{쌍곡탄젠트 함수 : } f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (9)$$

마지막으로는 출력함수(output function)부분으로 해당 뉴런의 활성함수부분에서 나온 값을 다음 뉴런에 보내기 위해서 출력시키는 부분이다. 항등(identity)함수, softmax함수 등이 사용되는데, 일반적으로 항등함수가 주로 사용된다.

### 3) 인공신경망의 기계학습(machine learning)

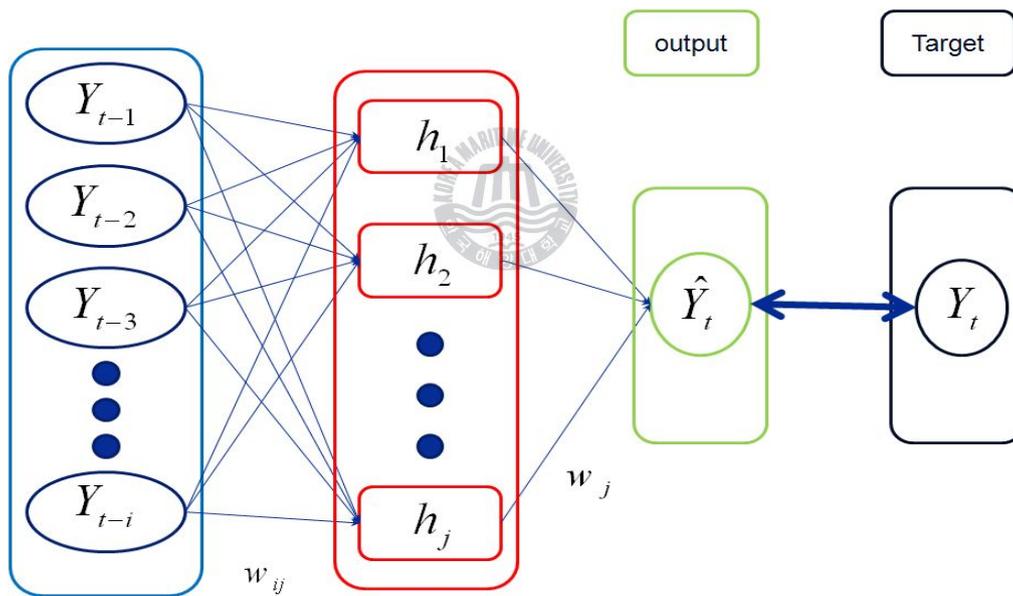
기계학습은 뉴런들의 정보처리과정과 그들의 연결을 통해 작동되는데, 연구자에 따라 같은 의미로서 훈련(training)이라는 표현을 사용한다. 여기서 말하는 기계학습이란 해당 네트워크의 목적함수(objective function)를 최소화해 시키는 방향으로 연결가중치를 지속적으로 조정해 나가는 과정이라 할 수 있다.

목적함수는 목표값(target value)과 출력값(output value)사이의 차이를 계산하기 위한 함수로서 연구자나 연구목적에 맞게 다양한 함수형태를 보이며, 목적함수의 다른 표현으로는 비용함수(cost function)라고 한다. 출력값이란 해당 입력패턴을 입력값(input value)을 사용해 인공신경망모형의 수행결과로서 나온 값이며, 목표값은 해당 입력패턴에 상응하는 정답(correct answer)을 말한다. 그래서 기계학습을 다르게 표현하면, 해당 입력패턴에 대한 목표값과 출력값사이의 차이를 최소화하는 방법으로 연결가중치를 조정해가는 일종의 과정이라 할 수 있다.

이러한 학습방법(learning paradigms)에는 감독학습(supervised learning), 비감독학

습(unsupervised learning) 그리고 이 두 개의 학습법을 합친 하이브리드 학습(hybrid learning)이 있다. 감독학습법은 학습과정 중에 교사(teacher)와 함께 하는 학습법으로 여기서는 말하는 교사란 목표값과 동일한 의미로 사용된다. 즉, 목표값과 출력값사이의 차이를 최소화시키는 방향으로 연결가중치를 조정하는 학습법이다. 이와 달리 비감독학습법은 목표값이 주어지지 않는 학습법으로서 자료 속에 존재하는 내재된 구조(underlying structure)나 입력패턴사이의 상관관계(correlation)을 파악한 뒤, 자료나 입력패턴에 대한 군집화를 수행하는 학습법이다.

<그림 2-8>은 시계열자료 예측에 사용되는 MLP에 대한 학습과정을 그림으로 표현한 것으로 입력층, 은닉층, 출력층 각각 1개씩으로 구성된 신경망이다.



<그림 2-8> 인공신경망의 학습과정

단일 변수의 시계열 자료를 사용한 입력층에서는 현 시점인  $y_t$ 을 예측하기 위해  $y_{t-1}$ 기부터  $y_{t-i}$ 까지 과거자료를 입력노드를 사용하고 있다. 그리고 각각의 입력노드는 은닉층에 존재하는 모든 은닉노드와 연결되어 있다. 이를 수식화 하면 다음 식

(10)과 같다.

$$y_t = \sum_{j=1}^n w_j f\left(\sum_{i=1}^m w_{ij} y_{t-i}\right) + \varepsilon_t \quad (10)$$

$m$ 개의 입력노드  $i$ 와  $n$ 개의 은닉노드  $j$  그리고 은닉층에서 사용되는 활성화함수  $f(\cdot)$ 으로 구성되어 있다.  $w_{ij}$ 는 입력노드  $i$ 에서 은닉노드  $j$ 로 가는 연결가중치이며,  $w_j$ 는 은닉노드  $j$ 에서 출력노드로 가는 연결가중치이다.

위의 식 (10)은 비선형 AR모형과 동일한 형태로서 아주 간단한 인공신경망 모형이지만, 많은 연구자들에 의해서 임의의 함수를 근사시키는데 탁월한 능력을 보임이 입증되었다.

#### 4) 인공신경망 구조 설계

인공신경망모형 사용에 있어 가장 어려운 점 중 하나가 인공신경망의 구조를 결정 문제이다. 이를 보통 네트워크 구조결정(network topology design)문제라고 하며, 입력노드의 수, 은닉층의 수, 은닉노드의 수의 결정과 함께 사용할 활성화함수를 선택하는 문제이다. 과거의 연구들을 보게 되면 주로 실험을 바탕으로 한 경험론적 방법론을 사용하고 있는데, 일부 연구자들에 의해서 구조결정문제에 대한 몇 가지 법칙들이 제안되었다.

입력노드의 수 결정에 있어 일반적으로 실험을 통한 경험론적 방법이 사용되지만 통계적 방법을 사용해 입력노드의 수를 결정한다. 대표적으로 Harvey(1984)의 연구에서 시계열분석에 적용되는 ARIMA에 차수인  $p, q$  값을 기본으로 입력노드의 수 결정하는데 아래 식(11)처럼 제안하였다.

$$\text{입력노드의 수 } n = \max(p, q + 1) \quad (11)$$

은닉층 같은 경우 Adya and Collopy(1995)연구에서 입력층, 은닉층, 출력층 각각 1

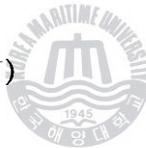
개 사용하는 것이 적절하다고 제안하였다. 은닉노드의 수 결정에 있어서는 실험을 통한 경험론적 방법이 사용되지만, 과거의 연구자들에 의해 몇 가지 법칙이 제안되었다. 대표적으로 방법으로는 masters(1995)연구에서 제안한 geometric pyramid rule이 있으며, 아래 식(12)과 같다.

$$\text{은닉노드의 수 } h = \sqrt{n \times m} \quad (12)$$

$n$ 은 입력노드의 수,  $m$ 은 출력노드의 수를 의미한다.

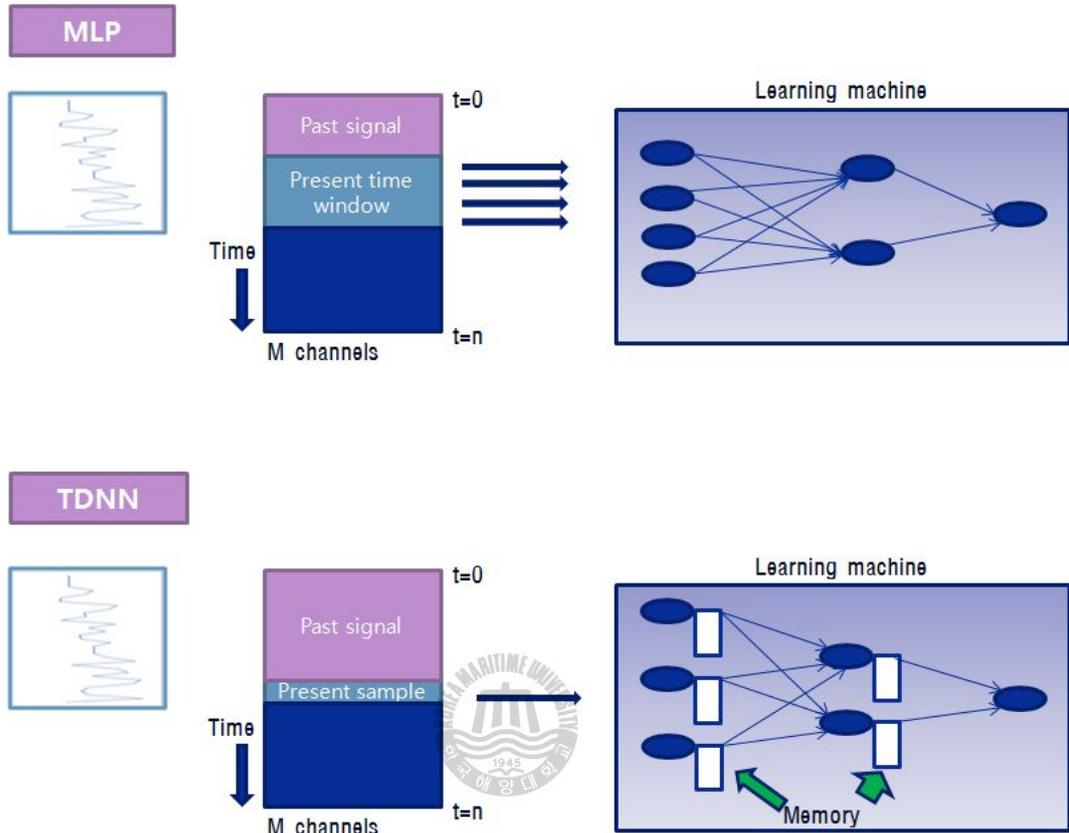
활성함수의 선택문제에서는 Kalman and Kwasny(1992)연구에서 시그모드함수의 여러 형태 중에서 쌍곡탄젠트함수를 사용하는 것이 적절하다고 제안하였다.

## 2.2.2 시간지연신경망(TDNN)



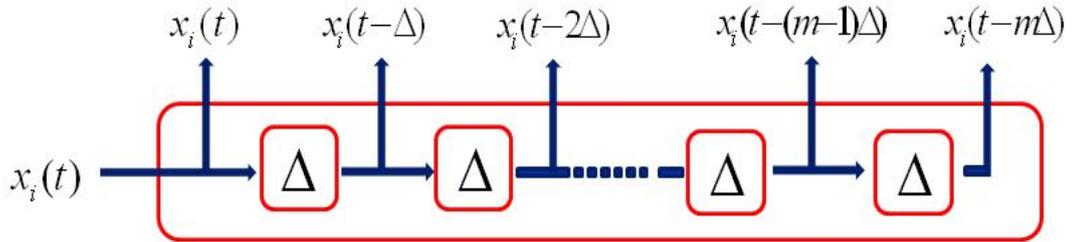
다층퍼셉트론(MLP)은 널리 사용되는 인공신경망모형이지만 시간에 따른 변화를 인식하고 분석하는 능력에 있어 그 한계점을 보인다고 알려져 있다. 그래서 시계열 예측에 있어 MLP모형의 대안으로서 시간지연신경망(TDNN; time delayed neural network)이 등장하게 되었다. TDNN은 음성인식(speech recognition)부분에 있어 Waibel et al(1989)의 연구에 의해서 처음 제안되었고, 이러한 음성인식과 음소분류(phoneme classification)에 있어 다른 인공신경망모형에 비해 탁월한 성과를 보임이 증명되었다.

<그림 2-9>에서 MLP와 TDNN의 차이점을 간략하게 그림으로 표현하였다.



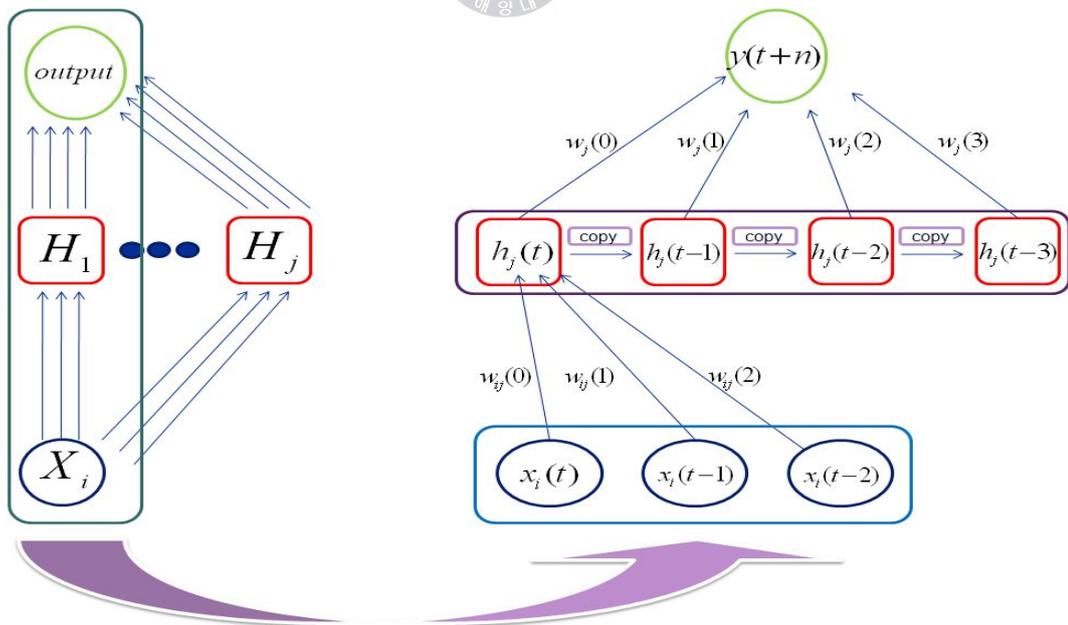
<그림 2-9> MLP와 TDNN의 차이

MLP와 TDNN은 전방향신경망이라는 점에서 기본적으로 유사한 모형이라 할 수 있지만, TDNN 같은 경우 출력층의 뉴런을 제외한 모든 뉴런들이 기억 구조(memory structure)를 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 더 나은 예측성과를 예상할 수 있다. 이러한 기억구조를 보통 시간지연라인(time delay line)이라 하는데, 아래 <그림 2-10>에서 TDNN에서 사용되는 시간지연연산자  $\Delta$ 을 가지는 delay line을 표현하였다.



<그림 2-10> time delay line

n-step ahead forecasting과 같은 시계열 예측에서는 현재 시점  $t$ 를 기준으로 해당 자료의 과거값들인 시계열  $y(t), y(t-1), \dots, y(1)$ 을 이용해 그에 상응하는 목표값인 관측치  $y(t+n)$ 로 근사시키기 위해 비선형 결합이 수행된다. 이처럼 목표값에 대응하는 입력값들이 벡터형태를 띠고 있음을 알 수 있다. Hassoun(1995)의 연구에서 이러한 delay line을 가지고 있는 TDNN구조가 벡터형태로 이루어진 입력변수에 대해서 효과적인 예측을 수행할 수 있다고 말하고 있다.



<그림 2-11> TDNN

위의 <그림 2-11>에서 표현된 TDNN은 전방향 신경망으로서 입력층에 하나의 입력노드, 은닉층에는  $j$ 개의 은닉노드를 가지고 있는 구조이다. 그리고 각각의 뉴런들이 기억구조를 지니고 있다.

각각의 입력노드들은 시간지연라인을 가지고 있으므로 아래 식(13)와 같은 벡터 형태를 보인다.

$$X_i(t) = [x_i(t), x_i(t-1), \dots, x_i(t-N)]^T, i = 1, 2, \dots, n \quad (13)$$

위의 그림에서 표현된 입력노드는 크기(size)가 3이며, 지연연산자  $\Delta$ 는 1인 시간지연라인을 가지고 있다. 그리고 입력벡터  $i$ 에서 특정 은닉노드  $j$ 에 가는 연결가중치 아래 식 (14)과 같다.

$$W_{ij}(t) = [w_{ij}(0), w_{ij}(1), \dots, w_{ij}(N)]^T, j = 1, 2, \dots, m \quad (14)$$

입력벡터  $X_i$ 와 연결가중치  $W_{ij}(t)$ 의 선형결합과 그 결과에 대한 비선형함수  $f(\cdot)$ 을 적용해 해당 은닉노드의 출력값  $h_j$ 을 계산하는 일련의 과정들은 아래 식(15)처럼 표현된다.

$$\begin{aligned} net_j(t) &= W_{ij}^T \cdot X_i(t) \\ h_j(t) &= f(net_j(t)) \end{aligned} \quad (15)$$

은닉층에 속한 은닉노드 또한 입력노드와 같이 시간지연구조를 가지고 있는데, 식 (15)으로 나온 결과값인  $h_j$ 을 바탕으로 나머지 은닉노드들은 미리 설정된 시간지연연산자와 시간지연라인의 크기에 따라 복제되는 구조를 띠고 있다. 위 그림에서 표현된 은닉노드는 크기가 4이며, 시간지연산자  $\Delta$ 가 1인 시간지연라인을 가지고 있다.

TDNN의 학습에 있어서는 기본적으로 오류역전파알고리즘이 사용되며, 목적함수를

최소화시키는 방향으로 가중치의 지속적인 조정과정이 이루어진다. 이와 같은 동적신경망(dynamic neural network)의 형태를 띠고 있는 TDNN은 입력-출력 사상(input-output mapping)에서 시간(time)이라는 변수가 가지는 관계를 적절히 모형화하기 위해 설계된 네트워크 구조임을 알 수 있다.



## 2.3 유전알고리즘(GA)

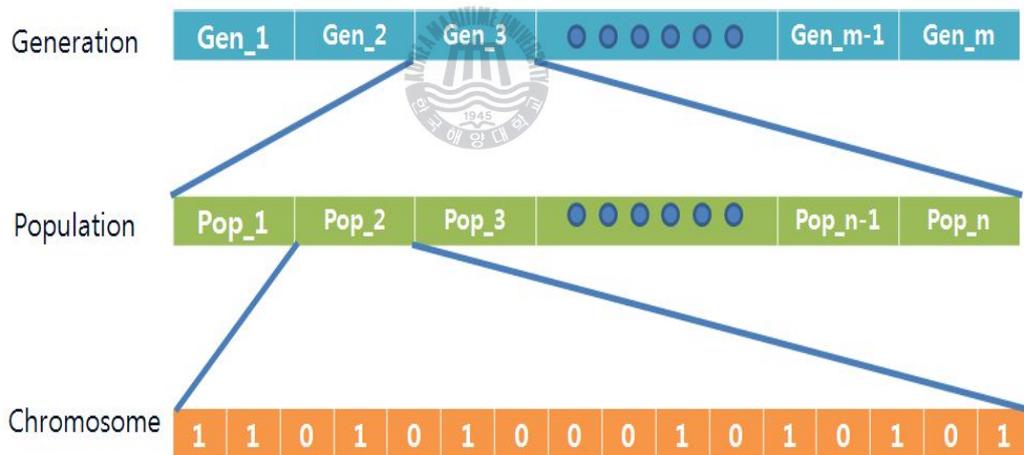
유전알고리즘(Genetic Algorithm)의 진화(evolution)를 표방한 확률적 탐색기법(stochastic search method)으로 특히, 방대하며 복잡한 탐색공간에서도 전역해(global optimum)찾기에 효과적인 기법으로 알려져 있다. 유전알고리즘에서 연구자가 임의로 정의한 목적함수를 토대로 선택(selection), 교차(crossover) 그리고 돌연변이(mutation) 연산자들이 작동하면서, 특정 종료규칙(termination criterion)에 만족될 때까지 계속적으로 작동되는 방식이다. <그림 2-12>는 유전알고리즘의 수행절차에 대해서 그림으로 표현하였다.



<그림 2-12> 유전알고리즘의 수행 절차

유전알고리즘을 단계별로 구분하자면 초기화(initialization), 선택(selection), 교차(crossover) 그리고 돌연변이(mutation) 총 4단계로 구성된다.

초기화단계에서는 문제의 표현(problem representation)부분과 초기값(population) 생성 그리고 적합도(fitness)를 계산하는 부분으로 구성되어 있다. 특정 문제에 대한 해(solution)라는 개념은 유전알고리즘에서는 염색체(chromosome)라 불린다. 이러한 해들의 집합 즉, 유전알고리즘에서의 염색체의 집단을 모집단(population)이라 부른다. 유전알고리즘은 염색체 수준이 아닌 모집단 수준에서 운영되는데, 이는 해당 알고리즘이 단일 해가 아닌 다수의 해를 동시에 고려한다는 의미이다. 이러한 특성은 지역 최적해(local optimum)로 수렴할 확률을 줄여주는 효과를 가져다준다. 모집단의 수는 연구자에 의해서 임의로 정해진다. <그림 2-13>에서 문제의 표현과 관련된 내용을 도식화하였다.

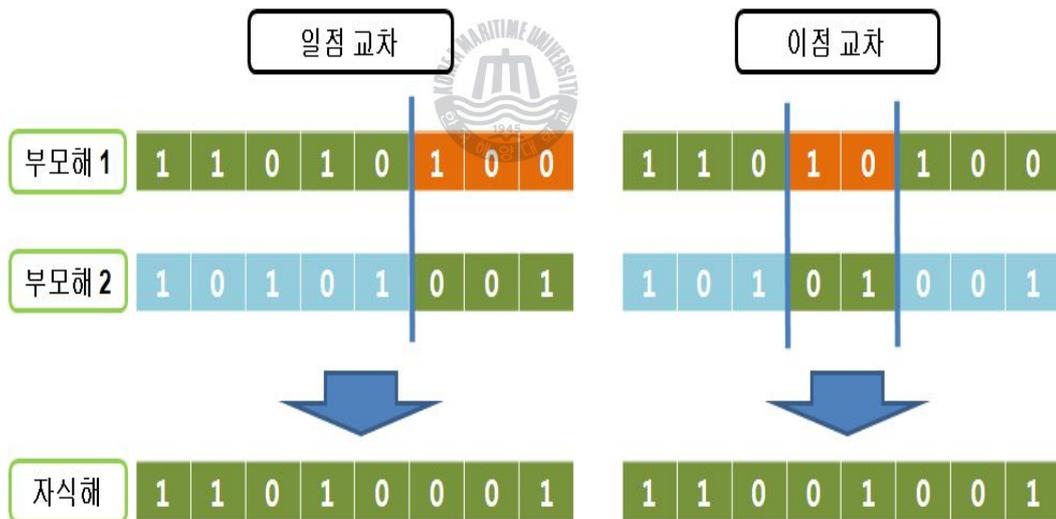


<그림 2-13> 문제의 표현

선택단계에서는 다음 세대로 넘겨줄 두 개의 염색체(혹은 해)를 고르기 위한 연산이 이루어진다. 이렇게 선택된 해를 부모해(parent)라 한다. 주로 사용되는 방식으로는 확률바퀴(roulette wheel)선택, 순위기반(ranking-based)선택, 그리고 토너먼트(tournament)선택 등이 있다. 그와 함께 우수한 해들과 열등한 해들 사이의 적합도 차

이를 조절함으로써 선택 확률을 조절 할 수 있는데, 이를 선택압(selection pressure)이라 한다. 선택압이 높을수록 수렴의 속도는 빠르나, 해당 탐색공간을 충분히 탐색했다고 보기 힘든 면이 있다. 반대로 선택압이 너무 낮게 되면 해집단의 평균 품질이 좋아지지 않을 가능성이 높아진다.

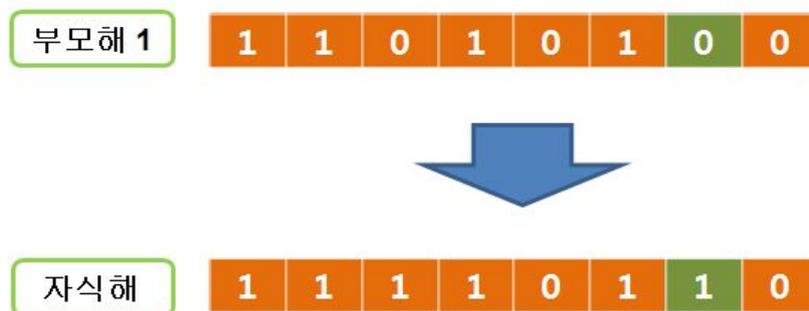
교차단계에서는 이전 세대에서 이루어진 선택연산을 통해 선정된 두 개의 부모해의 특징을 부분적으로 결합하여, 하나의 새로운 해를 만들어 내는 연산이 이루어진다. 이를 자식해(offspring)라고 한다. 교차연산은 유전알고리즘의 성능에 지대한 영향을 미치기 때문에 세심한 주의가 요구되는 단계이다. 주로 사용되는 교차연산으로는 일점교차(one-point crossover), 다점교차(multi-point crossover), 순환교차(cycle crossover) 그리고 균등교배(uniform crossover) 등이 있다. <그림 2-14>에서 기본적으로 많이 사용되는 교차연산인 일점교차와 이점교차를 그림으로 표현하였다.



<그림 2-14> 교차 연산

돌연변이단계에서는 두 개의 부모해로부터 나온 자식해를 임의로 변형시키는 연산이 이루어진다. 교차연산에서는 부모해로부터 받은 속성들을 부분적으로 이용하는 새로운 자식해를 만드는 반면에 돌연변이연산에서 부모해에 없는 속성을 도입하여 새로

운 자식해를 만들어 낸다. 이는 다음 세대의 자식해의 다양성을 높이는 역할을 한다. 돌연변이연산을 제어하는 모수로는 돌연변이율(mutation probability)이 있다. 만약 돌연변이율을 높이면 다양한 해를 생성할 수 있지만, 해집단의 수렴성이 떨어지게 되고 이는 수행시간이 길어지기 하고 적합도 개선의 속도를 늦추게 한다. <그림 2-15>에서는 간단한 돌연변이 연산을 그림으로 표현하였다.



<그림 2-15> 돌연변이 연산



## 2.4 Hybrid ARIMA-ANN

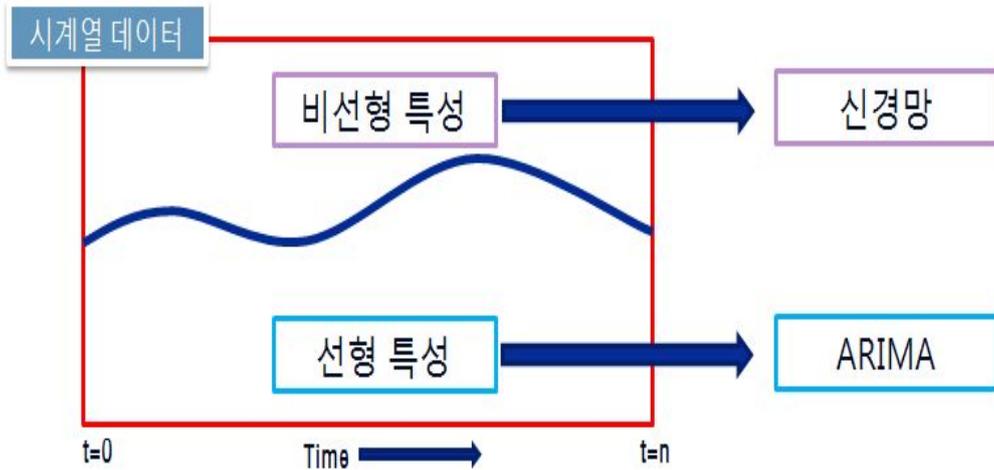
ARIMA와 인공신경망은 각자의 영역인 선형과 비선형 자료 분석에 있어 능력을 인정 받아왔다. 그러나 ARIMA모형을 복잡한 비선형 자료 분석에 사용할 경우 좋은 예측성과를 보장하기 힘들며, 인공신경망모형은 선형 자료 분석에 있어 연구자들 마다 각기 다른 연구결과 보이고 있다.

시계열 분석에 효과적인 인공신경망모형의 적용을 위해서는 시계열자료 속에 내재되어 있는 여러 가지 수요의 특성을 고려해야한다는 것을 앞서 본 선행연구들을 통해 알 수 있다. 그리고 Markham and Rakes(1998)는 인공신경망의 성과는 두 해당 시계열 자료 속에 내재되어 있는 잡음 수준(noise level)과 분석 대상이 되는 표본의 크기(sample size)에 영향을 받는다고 말하고 있다. 이는 분석의 대상이 되는 시계열에 대한 정확한 이해 없이 인공신경망을 사용한다는 것은 적절하지 않음을 말하고 있다. 그러나 현실 문제에 있어 해당 시계열 자료에 내재되어 있는 모든 특성을 완벽하게 이해한다는 것은 불가능하다. 현실에 존재하는 대부분의 시계열 자료들은 아래 식(16)처럼 선형과 비선형적인 특성이 혼합되어 있는 형태를 띠고 있다.

$$y_t = L_t + N_t \quad (16)$$

여기서  $L_t$ 는 시계열 자료에 존재하는 선형적 특성을 말하며,  $N_t$ 는 비선형적 특성을 말한다. 그래서 시계열 자료 속에 내재되어 있는 선형과 비선형특성들을 동시에 모형화하기 위해서 서로 다른 특성을 지니고 있는 예측 모형을 결합해서 사용하므로 예측성과를 향상시킬 수 있다.

그래서 본 연구에서 Zhang(2003)의 연구에서 제시한 ARIMA모형과 인공신경망을 결합한 hybrid ARIMA-ANN을 사용하였다. <그림 2-16>에서 본 연구에서 사용된 hybrid ARIMA-ANN을 간략하게 도식화하였다.



<그림 2-16> Hybrid ARIMA-ANN

Hybrid ARIMA-ANN의 절차는 크게 두 단계로 나눌 수 있다.

단계 1에서는 해당 시계열에 내재되어 있는 선형적인 특성을 모형화하기 위해 ARIMA모형을 적합 시킨다. 적합화 된 선형모형  $\hat{L}_t$ 으로부터 계산되어지는 오차  $e_t$ 에 비선형적 특성이 남게 될 것이다. 이와 같은 과정은 아래 식 (17)과 같다.

$$e_t = y_t - \hat{L}_t \quad (17)$$

단계 2에서는 ARIMA 모형을 적합시킨 후에 나온 오차  $e_t$ 에 대해서 신경망 분석을 수행한다. 이와 같은 과정은 아래 식 (18)과 같다.

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) + \epsilon_t \quad (18)$$

위의 식(18)에 있는 함수  $f(\cdot)$ 는 인공신경망모형에서 사용되는 비선형함수이며,  $\epsilon_t$ 는 확률적 오차(random error)이다. 그리고 인공신경망모형의 입력값으로 현재 시점 t를 기준으로 해서 과거 t-n개의 예측오차가 사용된다. 최종적으로 ARIMA모형을 사

용하여 적합시켜 나온 추정값  $\hat{L}_t$ 과 그로 인해 생성된 예측오차들 사이에 존재하는 비선형 관계를 밝히기 위해 인공신경망모형을 사용해 나온  $\hat{N}_t$ 을 더하므로 원시계열에 대한 추정치  $\hat{y}_t$ 을 생성하게 된다. 이는 아래 식 (19)과 같다.

$$\hat{y}_t = \hat{L}_t + \hat{N}_t \quad (19)$$

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.

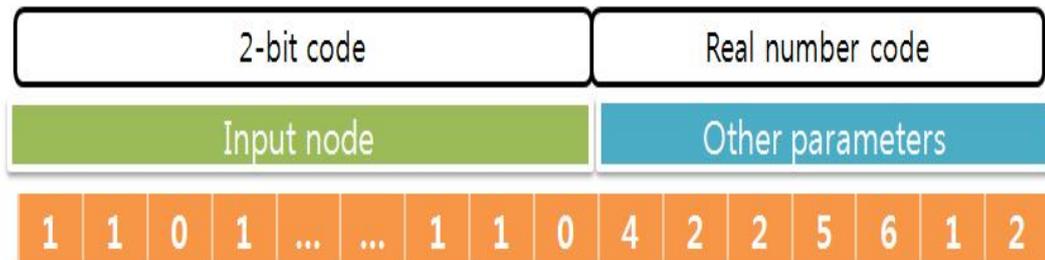


### 제 3 장 실증분석

ANN모형은 일반적인 통계 기법의 대안으로 많은 관심을 받고 있지만, 통계 기법과 달리 분석 자료에 대해 이론적으로 설명할 수 있는 능력과 분석 결과에 대한 타당성을 검증할 수 있는 능력에 있어 그 한계점을 보이고 있다. 이러한 단점을 보완하기 위해 분석 대상이 되는 시계열 자료에 대해서 학습자료(training data set), 교차검증자료(cross-validation data set), 그리고 검정자료(test data set)들로 나눈 뒤 분석을 수행하는데 이를 자료 분할(data partitioning)이라 한다. 학습자료는 실제 신경망 학습에 사용되는 자료이며, 교차검증자료와 검정자료는 모형의 타당성을 검증하기 위해 사용되는 자료로서 신경망 학습에는 실제로 사용되지 않는 자료(hold-out sample)들이다.

본 연구 또한 자료 분할을 한 뒤 실험을 수행하였다. 실험방법은 먼저 교차검증자료에 대해서 목적함수 즉, 오차값을 최소화는 방향으로 학습자료를 이용해 노드간 연결 가중치들을 조정한다. 이는 학습자료를 가지고 신경망 학습을 시킨다는 의미로서 신경망 학습에 대한 타당성을 검증하기 위해 교차검증자료가 사용된다. 다음 단계로는 특정 종료조건을 만족해 학습이 종료된 ANN모형에서 나온 출력값들의 타당성을 검증하는 부분으로서 검정자료가 사용된다. 이를 통해 실제 시계열 예측에 사용될 모형을 선택하게 된다.

본 연구에서는 ANN모형의 성능을 향상시키기 위한 노력으로서 신경망 구조결정에 있어 GA를 사용하였다. 입력노드의 수와 은닉노드의 수 그리고 각각의 노드에 대한 시간지연라인의 크기 결정에 대해서 GA를 사용해 예측성과를 비교하였다. 아래 <그림 3-1>에서는 본 연구에서 사용되는 염색체를 그림으로 표현하였다. 입력노드의 선택에 있어서만 해당 노드를 사용할지 아님 사용하지 않을지 결정하기 하기 위한 신호로서 1과 0을 사용하는 2진수 코드를 사용하였고, 나머지 신경망 구조 모수에 대해서는 실수코드를 사용하였다. 전체적으로 일차원 배열(one-dimensional)구조를 가진 염색체이다. 그 반면에 은닉층의 수는 하나로 고정하였고, 활성화함수는 쌍곡탄젠트함수만 사용하였다.



<그림 3-1> 신경망 구조에 대한 염색체 표현

본 연구에서 사용되는 GA의 관련 모수값으로 세대수는 100세대, 모집단의 수는 100개로 정하였다. 그리고 선택방식은 확률바퀴를 사용하였다. 그리고 나머지 모수값은 사전 분석을 수행한 결과로서 교차율은 0.5, 돌연변이율은 0.1로 정하였다. <표 3-1>에 그 내용을 간단하게 정리하였다.

<표 3-1> GA 관련 모수에 대한 사전분석 결과(MSE기준)

교차율 \ 돌연변이율	0.2	0.5	0.8
0.01	0.8678	0.8681	0.8504
0.05	0.7641	0.8637	0.7555
0.1	1.2990	<b>0.7366</b>	0.8800

위의 표에서 나온 값은 검증자료에 대한 평균제곱오차(MSE; mean square error)로서 식(20)과 같이 계산된다.  $A_i$ 는 실제값(actual value)이며,  $F_i$ 는 예측값(forecast value)을 말한다.

$$MSE = \sum_{t=1}^n (A_t - F_t)^2 / n \quad (20)$$

ANN모형을 사용해 시계열자료를 분석하기 전에 먼저 해당 입력 자료들에 대한 정규화(normalization) 과정이 수행된다. 이러한 과정으로 얻게 되는 정규화 된 입력자료(normalized input data)들이 실제 ANN모형의 분석에 사용된다. 정규화과정과 관련된 식(21)은 아래와 같다.

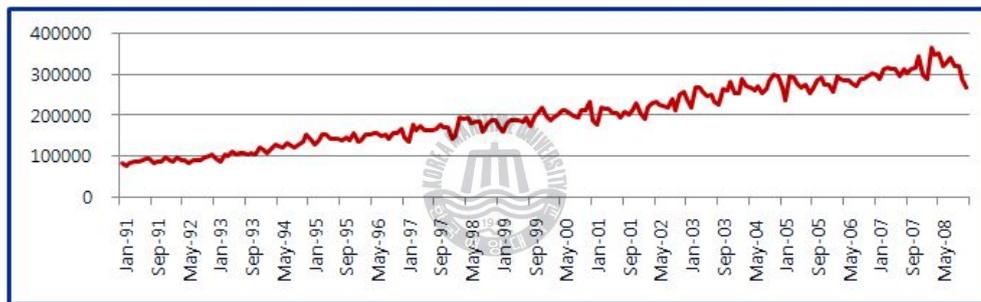
$$\begin{aligned} \text{Normalized data}_t(i) &= \text{Amp}(i) \times \text{Raw data}_t(i) + \text{Off}(i) \\ \text{Amp}(i) &= (\text{UpperBound} - \text{LowerBound}) / (\text{Max}(i) - \text{Min}(i)) \\ \text{Off}(i) &= \text{UpperBound} - \text{Amp}(i) \times \text{Max}(i) \end{aligned} \quad (21)$$

그리고 GA의 여러 연산자들 중 그 성과에 큰 영향을 주는 교차방식에 따라 ANN 모형의 예측성과가 어떤 영향을 받는지를 알아보기 위해 대표적인 교차방식 중 일점 교차방식과 이점교차방식을 사용해 예측성과를 비교하였다.

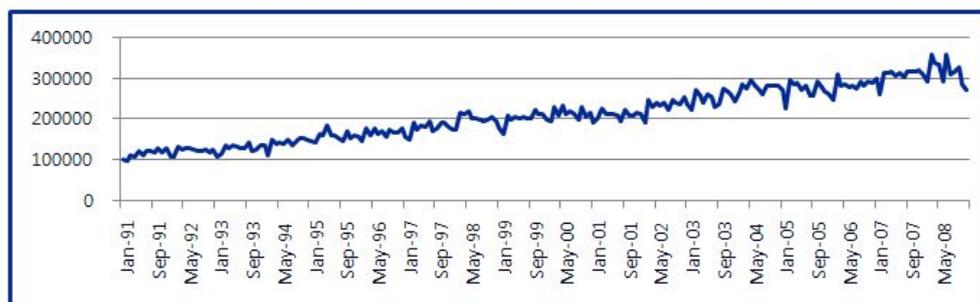
### 3.1 컨테이너물동량 자료

본 연구에 사용된 컨테이너물동량자료는 국토해양부가 운영하는 해운항만 물류정보 센터(SP-IDC)에서 수출, 수입 컨테이너 물동량 자료를 수집하였다. 여기서 말한 수입, 수출 물동량은 환적과 국내 연안운송을 제외한 물동량으로 관측기간은 1991~2008년 까지 총 216개 관측치를 대상으로 분석을 수행하였다.

<그림 3-2>, <그림 3-3>는 부산항의 수입과 수출의 물동량을 그래프로 나타내었다. 그래프를 살펴보면 부산항의 수입과 수출물동량은 뚜렷한 증가 추세를 보임을 알 수 있다.



<그림 3-2> 부산항 수입 물동량

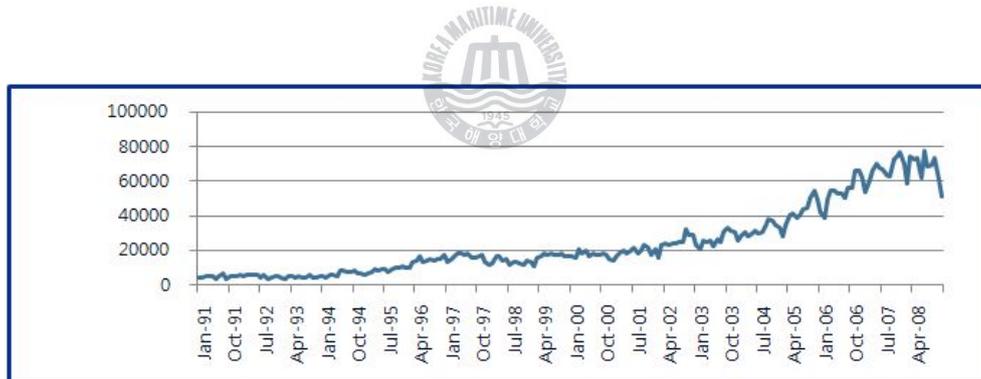


<그림 3-3> 부산항 수출 물동량

<그림 3-4>, <그림 3-5>는 인천항의 수입과 수출의 물동량을 그래프로 나타내었다. 인천항의 수입과 수출물동량은 또한 부산항의 물동량처럼 뚜렷한 증가 추세를 보이지만, 선형추세(linear trend)를 보이는 부산항과 달리 곡선적 추세(quadratic trend) 변화나 지수적인 추세(exponential trend)변화를 보이고 있다.



<그림 3-4> 인천항 수입 물동량



<그림 3-5> 인천항 수출 물동량

ANN모형에 적용에 있어 분석의 대상되는 원시계열을 학습자료, 교차검증자료 그리고 검정자료 이 세 부분으로 분할하는데, 본 연구에서 분석대상이 되는 자료의 크기 변화에 따른 예측성과를 비교하기 위해 각기 다른 구간을 가지는 자료를 대상으로 실험을 수행하였다. 특히, 예측기간의 변화에 따른 성능평가를 확인하기 위해 Case A와 Case B로 나누어서 분석을 수행하였다. Case A는 1991~2004년까지는 학습자료,

2005~2006년은 교차검증자료 그리고 2007~2008년은 검정자료로 사용하였다. Case B는 1991~2002년까지는 학습자료, 2003~2005년은 교차검증자료, 그리고 2006~2008년은 검정자료로 사용하였다. <표 3-2>에 실험대상이 되는 항만물동량 자료에 대해서 간략하게 정리해 놓았다.

<표 3-2> 전체 실험 자료

자 료 (총 216개)		Training	Cross-validation	Test
Case A (총 216개)	구 간	1991년~2004년	2005년~2006년	2007년~2008년
	관측치 수	168	24	24
Case B (총 216개)	구 간	1991년~2002년	2003년~2005년	2006년~2008년
	관측치 수	144	36	36



### 3.2 ARIMA 분석 결과

해당 실험 자료별 박스-젠킨스 기법을 적용해 분석을 수행하였고, 각각의 모형들은 AIC와 SBC통계량을 기준으로 선택되었다. 자료별 ARIMA모형의 변화를 보게 되면 인천 수입 물동량 자료를 제외한 나머지 자료들에 있어서는 적합구간을 달리 해도 거의 비슷한 구조를 띠고 있는 것을 확인 할 수 있다. 이는 적합구간에 사용되는 자료들이 동일한 확률구조를 지니고 있음을 의미한다. 그러나 각각 자료들에 따라 비정상 시계열의 정상화과정에서 분산의 정상화를 위해 로그변환을 사용한 여부에 있어 정반대의 결과를 보이고 있다.

예측부분에 있어서는 인천 수입/수출 모두 Case B에서 더 높은 예측성과를 보이는 반면에 부산 수입/수출 같은 경우 적합구간과 예측구간의 크기에 따라 결과를 보인다. 전체적으로 부산 수입 물동량을 제외한 나머지 자료들에 대해서는 적합구간의 성과가 좋으면 예측구간에서 또한 좋은 성과를 보인다. 즉, 적합구간의 오차인 평균절대오차(MAE; mean absolute error)가 작으면 예측구간의 오차인 평균절대편차(MAD; mean absolute deviation) 또한 작아진다는 말이다. MAD와 MAE를 구하는 과정은 아래 식(22)과 같다.  $A_t$ 는 실제값이며,  $F_t$ 는 예측값이다.

$$MAD = \frac{1}{n} \sum_{t=1}^n |A_t - F_t| \quad (22)$$

<표 3-3> ARIMA 분석 결과

자 료		ARIMA model	모형진단			예측
			AIC	SBC	MAE	MAD
부산 수입	Case A	ARIMA(0,1,1)(0,1,1)s	446	448	<b>7,304</b>	20,745
	Case B	Log ARIMA(0,1,1)(0,1,1)s	682	685	9,841	<b>14,902</b>
부산 수출	Case A	Log ARIMA(0,1,1)(1,1,1)s	450	454	<b>8,482</b>	<b>14,509</b>
	Case B	ARIMA(0,1,1)(0,1,1)s	685	689	9,517	16,518
인천 수입	Case A	Log ARIMA(0,1,1)(0,1,1)s	405	407	3,577	9,904
	Case B	ARIMA(1,1,0)(0,1,1)s	588	591	<b>2,750</b>	<b>6,923</b>
인천 수출	Case A	Log ARIMA(0,1,1)(0,1,1)s	399	401	2,963	11,863
	Case B	ARIMA(0,1,1)(0,1,1)s	576	580	<b>2,185</b>	<b>5,286</b>

### 3.3 인공신경망 분석 결과

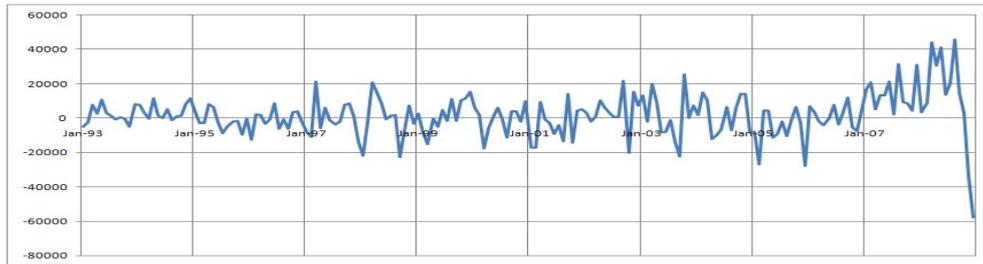
해당 컨테이너물동량 자료에 ARIMA모형을 적합 시킨 후 계산된 예측오차 즉, ARIMA모형의 백색잡음은 본 연구에서 사용되는 Hybrid ARIMA-ANN모형에 있어 ANN모형의 입력자료로 사용된다.

아래 <표 3-4>은 ANN모형의 학습을 위해 사용되는 훈련자료와 교차검증자료에 대한 기초통계량이다.

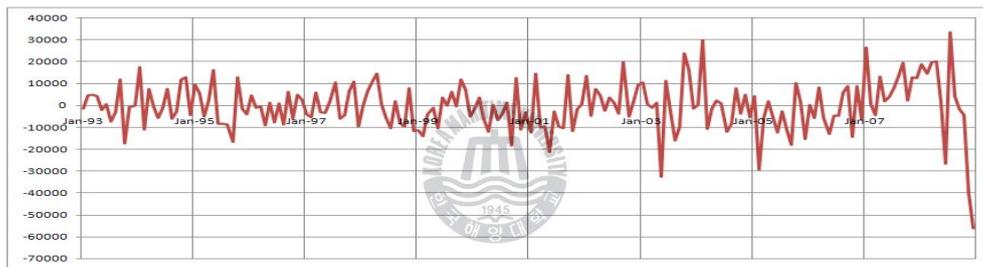
<표 3-4> ANN모형의 분석 자료에 대한 기초통계량

자 료			평균	표준편차	왜도	첨도
부산 수입	Case A	훈련	730	9161	-0.11	0.30
		교차검증	-2848	9721	-1.15	1.61
	Case B	훈련	-467	8586	-0.22	0.98
		교차검증	-2248	12177	-0.15	-0.15
부산 수출	Case A	훈련	-432	9218	0.16	0.95
		교차검증	-4252	9801	-0.49	0.26
	Case B	훈련	476	8500	0.12	-0.39
		교차검증	-457	13078	-0.53	1.29
인천 수입	Case A	훈련	-173	2537	0.01	0.12
		교차검증	459	4283	-0.42	-0.90
	Case B	훈련	92	2470	0.23	0.94
		교차검증	528	3333	0.04	-0.12
인천 수출	Case A	훈련	-99	1879	-0.09	0.67
		교차검증	836	3699	0.41	-0.38
	Case B	훈련	179	1584	-0.06	0.92
		교차검증	518	2826	0.44	0.41

<그림 3-6>와 <그림 3-7>은 부산항 수입/수출 물동량에 대한 ARIMA의 백색잡음을 그림으로 표현하였다.

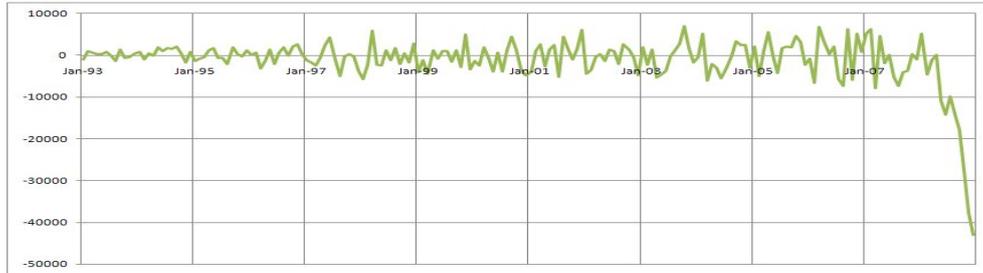


<그림 3-6> 부산항 수입 물동량에 대한 백색잡음

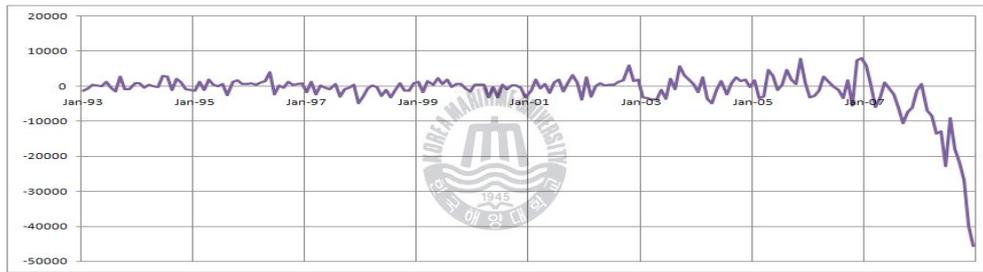


<그림 3-7> 부산항 수출 물동량에 대한 백색잡음

<그림 3-8>와 <그림 3-9>은 인천항 수입/수출 물동량에 대한 ARIMA의 백색잡음을 그림으로 표현하였다.



<그림 3-8> 인천항 수출 물동량에 대한 백색잡음



<그림 3-9> 인천항 수출 물동량에 대한 백색잡음

<표 3-5>에서는 ANN모형에 사용된 입력자료들에 대해서 간략하게 정리해 놓았다. 이는 분석대상이 되는 전체 실험자료를 간략하게 나타낸 <표 3-2>과 비교해 각각의 학습자료의 관측치의 수가 줄어든 사실을 확인 할 수 있다. 이는 시계열 자료에 ARIMA모형을 적합시켜 발생한 현상으로 1991년 1월부터 수집된 월별 자료에 대해서 ARIMA(0,1,1)(0,1,1)<sub>s</sub>을 적합 시킬 경우, 92년 2월부터 예측치가 생성되기 때문에 1991년과 1992년 총 24개의 관측치가 제외되었다.

<표 3-5> ANN모형의 입력자료

자 료 (총 216개)		Training	Cross-validation	Test
Case A (총 216개)	구 간	1993년~2004년	2005년~2006년	2007년~2008년
	관측치 수	144	24	24
Case B (총 216개)	구 간	1993년~2002년	2003년~2005년	2006년~2008년
	관측치 수	120	36	36

본 연구에서는 신경망 구조결정문제에 있어 자동화 및 최적화를 위해 GA를 사용하였고, 그 결과를 기존의 연구들에서 제안한 몇 가지 법칙들을 이용해 구조를 결정한 방법들과 비교하였다. 선행 연구들에서 제안한 법칙을 이용한 경우 Heuristic ANN 하고 아래 <표 3-6>에서 간략하게 묘사하였다.

<표 3-6> Heuristic ANN 구조

자 료	입력층		은닉 노드	은닉층	
	line size	Delay		line size	Delay
heuristic MLP	3	1	3	-	-
heuristic TDNN	3	1	3	3	1

각 모형별 신경망 학습에 대한 결과를 보게 되면, 먼저 heuristic MLP와 heuristic TDNN의 학습능력을 비교하면 heuristic MLP가 학습자료에 대한 그 적합능력이 뛰어난 것을 알 수 있다. 그리고 인천 수출을 제외한 모든 자료들에 있어 GA를 사용한 TDNN이 가장 높은 적합능력을 보여주고 있다.

<표 3-7> ANN모형들에 대한 학습 결과(MSE 기준)

자 료			heuristic MLP	heuristic TDNN	TDNN_GA	
					일점교차	이점교차
부산 수입	Case A	훈련	0.1153	0.1500	0.0417	0.0452
		교차검증	0.1492	0.1873	0.1485	0.3027
	Case B	훈련	0.1009	0.0988	0.0848	0.0918
		교차검증	0.2079	0.1944	0.3886	0.2132
부산 수출	Case A	훈련	0.0689	0.0798	0.0323	0.0321
		교차검증	0.8879	0.1466	0.2340	0.1267
	Case B	훈련	0.1627	0.2047	0.1145	0.1107
		교차검증	0.3969	0.3374	0.4556	0.3411
인천 수입	Case A	훈련	0.1197	0.1427	0.1006	0.1067
		교차검증	0.3506	0.5040	0.4447	0.2692
	Case B	훈련	0.0827	0.1055	0.0621	0.0558
		교차검증	0.1703	0.1951	0.2221	0.3301
인천 수출	Case A	훈련	0.0938	0.1116	0.1285	0.1234
		교차검증	0.4288	0.4364	0.5853	0.4966
	Case B	훈련	0.0825	0.1768	0.1326	0.1566
		교차검증	0.2379	0.5169	0.3894	0.9136

GA의 교차연산방식에 따라 해당 신경망모형의 예측성과가 어떻게 변화하는지 확인하고자 하였다. <표 3-8>을 보면 각각의 자료별 특정한 패턴을 보인다는 것을 알 수 있다. 부산 수입과 인천 수출자료 같은 경우 일점교차연산을 하였을 때 뛰어난 예측성과를 보이고 있으며, 부산 수출과 인천 수입자료 같은 경우 이점교차연산에서 더 좋은 예측성과를 보이고 있다.

<표 3-8> 교차방식에 따른 예측결과(MAD 기준)

자 료		일점 교차	이점 교차
부산 수입	Case A	<b>16,764</b>	17,678
	Case B	<b>13,263</b>	16,667
부산 수출	Case A	16,270	<b>12,882</b>
	Case B	16,264	<b>15,336</b>
인천 수입	Case A	10,246	<b>9,384</b>
	Case B	6,454	<b>5,523</b>
인천 수출	Case A	<b>10,623</b>	10,987
	Case B	<b>4,532</b>	5,046

<표 3-9>은 해당 자료별 GA를 사용해 얻게 된 TDNN의 최적화 된 구조이다. 해당 실험 자료별 특정한 패턴 없이 각기 다양한 구조를 띠고 있다. 그러나 특정 자료에 있어 GA로 최적화 된 입력층 혹은 은닉층노드의 시간지연라인의 크기가 앞에서 정의한 Heuristic ANN 구조와 동일한 형태를 띠고 있다.

<표 3-9> TDNN\_GA의 구조

자 료		입력층		은닉 노드	은닉층	
		line size	Delay		line size	Delay
부산 수입	Case A	3	5	2	7	4
	Case B	10	6	1	11	3
부산 수출	Case A	6	5	2	6	4
	Case B	3	5	11	7	1
인천 수입	Case A	2	2	5	9	5
	Case B	8	5	5	4	1
인천 수출	Case A	7	5	8	3	6
	Case B	3	6	7	7	5

<표 3-10>에서 인공신경망모형에 따른 자료별 예측성과를 MAD 기준으로 나열하였다. 부산 수입을 제외하고는 GA를 사용한 TDNN이 다른 모형과 비교해 더 좋은 예측성과를 보인다. heuristic TDNN이 더 좋은 성과를 보인 부산 수입 또한 GA를 사용한 TDNN과 예측성과면에서 비교해 큰 차이를 보이지 않음을 알 수 있다.

<표 3-10> MLP와 TDNN의 예측결과(MAD 기준)

자 료		MLP	TDNN	TDNN_GA
부산 수입	Case A	20,101	<b>16,561</b>	16,764
	Case B	15,193	14,705	<b>13,263</b>
부산 수출	Case A	15,255	13,305	<b>12,882</b>
	Case B	15,918	17,468	<b>15,336</b>
인천 수입	Case A	11,204	9,959	<b>9,384</b>
	Case B	7,693	6,630	<b>5,523</b>
인천 수출	Case A	11,050	13,641	<b>10,623</b>
	Case B	4,969	5,011	<b>4,532</b>



### 3.4 Hybrid ARIMA\_ANN 분석 결과

앞에서 분석한 ARIMA모형과 ANN모형에 대한 각각의 예측치를 더해 Hybrid ARIMA\_ANN모형에 대한 최종 예측치를 계산하였고, 이를 다른 모형들과 비교하였다. 그리고 각 모형별 분석의 편의를 위해 평균절대비율오차(MAPE; Mean Absolute Percentage Error)를 사용하였고, 식(23)과 같이 계산된다.  $A_t$ 는 실제값이며,  $F_t$ 는 예측값이다.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (23)$$

부산항 수입, 수출 물동량자료에 있어 전체적으로 GA를 사용한 Hybrid ARIMA\_TDNN모형이 예측성과면에서 더 좋은 결과를 보인다. 그러나 부산 수입의 Case A 같은 경우 GA를 사용하지 않은 Hybrid ARIMA\_TDNN모형에서 더 좋은 결과를 보이고 있다. 그리고 인천항 수입, 수출 물동량자료에 있어 모든 자료에서 GA를 사용한 Hybrid ARIMA\_TDNN모형이 예측성과면에서 더 좋은 결과를 보인다. 그리고 각 자료별 GA를 사용한 Hybrid ARIMA\_TDNN모형과 ARIMA모형의 MAPE를 비교한 결과 부산항자료에 비해 인천항자료에서 오차가 큰 폭으로 줄어들음을 확인할 수 있다.

<표 3-11> 부산 수입, 수출 물동량 예측결과

자 료		모형	MAD	MAPE	자 료		모형	MAD	MAPE
부산수입	Case A	ARIMA	20,745	0.0650	부산수출	Case A	ARIMA	14,509	0.0474
		ARIMA_MLP	20,101	0.0630			ARIMA_MLP	15,255	0.0501
		ARIMA_TDNN	<b>16,561</b>	<b>0.0521</b>			ARIMA_TDNN	13,305	0.0439
		ARIMA_TDNN with GA	16,764	0.0527			ARIMA_TDNN with GA	<b>12,882</b>	<b>0.0421</b>
	Case B	ARIMA	14,902	0.0482		Case B	ARIMA	16,518	0.0530
		ARIMA_MLP	15,193	0.0489			ARIMA_MLP	15,918	0.0512
		ARIMA_TDNN	14,705	0.0473			ARIMA_TDNN	17,468	0.0561
		ARIMA_TDNN with GA	<b>13,263</b>	<b>0.0433</b>			ARIMA_TDNN with GA	<b>15,336</b>	<b>0.0498</b>



<표 3-12> 인천 수입, 수출 물동량 예측결과

자 료		모형	MAD	MAPE	자 료		모형	MAD	MAPE
인천수입	Case A	ARIMA	9,904	0.1525	인천수출	Case A	ARIMA	11,863	0.1863
		ARIMA_MLP	11,204	0.1717			ARIMA_MLP	11,051	0.1745
		ARIMA_TDNN	9,959	0.1527			ARIMA_TDNN	13,641	0.2129
		ARIMA_TDNN with GA	<b>9,792</b>	<b>0.1473</b>			ARIMA_TDNN with GA	<b>10,623</b>	<b>0.1681</b>
	Case B	ARIMA	6,923	0.1047		Case B	ARIMA	5,286	0.0840
		ARIMA_MLP	7,693	0.1151			ARIMA_MLP	4,969	0.0795
		ARIMA_TDNN	6,630	0.1011			ARIMA_TDNN	5,011	0.0817
		ARIMA_TDNN with GA	<b>5,523</b>	<b>0.0885</b>			ARIMA_TDNN with GA	<b>4,532</b>	<b>0.0736</b>

## 제 5 장 결론 및 향후 연구방향

시계열 분석 및 예측은 과거부터 활발히 연구되어 온 분야이다. 특히 예측의 정확성은 모든 의사결정과정의 기초적인 요소로서 작용하는 부분으로 오늘날까지 많은 연구자들에 의해 예측의 정확성을 높이기 위한 연구들이 지속적으로 진행되어 오고 있다. 그 중 Box and Jenkins(1976)의 연구로 인해 체계화 된 이론을 가지고 있는 ARIMA모형이 많은 연구자나 실무자들에 의해서 광범위하게 사용되고 있다. 최근에는 시계열 예측에 있어 ANN모형의 적용가능성이 발견되었고, 그 이후로 활발한 연구 활동들이 진행되어 오고 있다.

본 연구에서 항만의 컨테이너물동량에 대한 정확성 높은 예측을 위해 ARIMA모형과 ANN모형을 결합한 Hybrid ARIMA\_ANN을 사용하였다. 선형성과 비선형성이 혼재되어 있는 현실 자료에 대한 효과적인 분석을 위해 선형에서 우수한 성과를 보이는 ARIMA모형과 비선형에서 우수한 성과를 보이는 ANN모형을 결합한 모형으로 두 모형의 장점들을 동시에 사용할 수 있는 형태이다.

그리고 시간패턴인식능력에 있어 MLP보다 뛰어나다고 알려진 TDNN을 사용하였고, 인공신경망의 단점 중 하나인 구조결정문제에 있어 GA를 사용해 최적화 된 신경망의 구조를 결정하였다. 이는 궁극적으로 인공신경망모형의 예측성과를 향상시키기 위한 노력 중 하나이다.

그 결과 대부분의 항만물동량자료들에 대해 GA를 사용한 Hybrid ARIMA\_TDNN 모형이 다른 모형에 비해 높은 예측력을 보였고, 경험론적 방법을 사용해 신경망 구조를 결정하는 것보다 GA를 사용할 경우 ANN모형의 예측성과가 향상됨을 보였다. 그러나 본 연구에서 사용된 자료들에 대해 특정 예측모형이 항상 우세한 결과를 보이지 않음을 확인하였다. 이는 각각의 자료 속에 내재되어 있는 자체 특성에 따라 적절한 예측기법이 개발이 되어야 함을 의미하지만, 본 연구에서 사용된 제한적인 자료 분석을 통해 일반화 된 결론을 도출하는데 한계점이 존재하기에 향후 연구로서 다양한 자료들에 대한 추가 분석이 요구된다.

그리고 본 연구에서 신경망 구조결정문제에 있어 GA의 교차연산방식인 일점교차와

이점교차에 따라 자료별 ANN모형의 성과가 달라진다는 점을 확인하였다. 일반적으로 이점교차를 포함한 다점교차는 일점교차보다 교란(perturbation)의 정도가 크기 때문에 보다 넓은 탐색공간을 탐색할 수 있다. 그러나 교란이 강하면 수렴성이 떨어져 주어진 시간내에 제대로 수렴하지 않을 가능성이 있다. 그래서 향후 연구로서 교차연산 뿐만 아닌 다른 GA 관련 연산자들과 해당 모수에 대한 추가적인 조정작업이 요구된다.

GA를 사용해 최적화 된 TDNN모형의 구조가 heuristic ANN모형의 입력층과 은닉층노드의 시간지연라인의 크기와 유사한 형태를 띠고 있는 경우, GA를 사용한 ANN모형이라도 heuristic ANN모형과 비교해 항상 더 나은 예측성적을 보이지 않음을 확인하였다. 이는 구조결정 문제에 있어 다른 무엇보다 각각의 노드 특히, 입력노드에 사용되는 시간지연라인의 크기가 인공신경망모형의 예측성적에 결정적인 요인으로 작용하고 있다는 것을 의미한다. 그러나 이 또한 제한적인 자료분석을 통해 일반화된 결론을 도출한다는 것에 대한 한계점이 존재하기 때문에 향후 연구로서 다양한 자료에 대한 추가분석이 요구된다.

마지막으로 본 연구에서 수행한 컨테이너물동량의 예측은 단변량 시계열 자료를 사용했지만 정확성 높은 예측모형을 개발하기 위해서는 다변량 시계열 자료를 이용한 컨테이너물동량 예측에 관한 연구들이 필수적으로 요구된다.

## 참 고 문 헌

문병로(2008), “쉽게 배우는 유전 알고리즘,” 한빛미디어.

박성용, 이철영(2002), “신경망을 이용한 컨테이너 물동량 예측에 관한 연구,” 한국항해항만학회지 제 26권 제2호, pp.183-188.

신창훈, 강정식, 박수남, 이지훈(2007), “하이브리드 ARIMA-신경망 모델을 통한 컨테이너물동량 예측에 관한 연구,” 한국항해항만학회지 제 32권 제1호, pp.81-88.

이지원(2008), “컨테이너 물동량을 이용한 인공신경망과 ARIMA 모형의 예측력 비교에 관한 연구,” 한국해양대학교 석사학위논문.

전찬용과 송주미(2007), “인공신경망모형의 항만물동량 예측 적용에 관한 연구,” 해운물류연구, 제53호, pp.65-82.



지원철(1995), “신경망을 이용한 시계열 분석: M-1 Competition Data에 대한 예측성과 분석,” 한국전문가시스템학회지 창간호, pp.135-148.

지원철(1999), “신경망을 이용한 시계열의 분해분석,” 대한산업공학회지, 제 25권 제1호, pp.111-124.

최중욱, 심기창, 정윤(1995), “시계열 데이터 성격과 Time-Delay신경망 예측력,” 자연과학연구, 제 2권, pp.339-354.

해운항만 물류 정보센터, 인터넷 웹사이트(<http://www.spidc.go.kr>).

Adya, M. and Collopy, F.(1995), "Does AI Research Aid Prediction? A Review and Evaluation," ICIS 1995 Proceedings, pp.123-140.

Box, G. E. P. and Jenkins, G. M.(1976), "Time series Analysis Forecasting and Control," Holden-Day, San Francisco.

Chatfield, C.(1993), "Neural networks: Forecasting breakthrough or passing fad?," International Journal of Forecasting 9, pp.1-3.

Fishwick, P. A.(1989), "Neural network models in simulation: A comparison with traditional modeling approaches," Proceedings of Winter Simulation Conference, pp.702 - 710.

Geman, G., Bienenstock, E. and Doursat, R.(1992), "Neural Networks and Bias/Variance Dilemma," Neural Computation, Vol. 4, No. 1, pp.1-58.

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, pp.374-386.

Hansen, J. V., McDonald, J. B and Nelson, R. D(1990), "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.

Hassoun, M.(1995), "Fundamentals of Artificial Neural Networks" MIT press, Cambridge, MA.

Ittig, P. T.(1997), "A seasonal index for business," Decision Science, Vol. 28, No.2, pp.335-355.

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.

Kalman, B. L. and Kwasny. S. C.(1992), "Why Tanh: choosing a sigmoidal function- Neural Networks," Proceedings of the International Joint Conference on Neural Networks, Baltimore, MD IEEE, New York.

Kim, H. J. and Shin, K. S.(2006), "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.

Lapedes, A. and Farber, R.(1987), "Nonlinear Signal Processing Using Neural Networks: Prediction and System Modeling," Los Almos National Laboratory, Technical Report, LA-UR-87-2662.

Markham, I. S. and Rakes, T. R.(1998), "The effect of sample size and variability of data on the comparative performance of artificial neural networks and regression," Computers and Operations Research, Vol. 25, No. 4, pp.251-263.

Master, T.(1995), "Advanced Algorithms for neural networks," John Wiley and Sons, New York.

Matignon, R.(2005), "Neural Network Modeling using SAS Enterprise Miner,"

AuthorHouse, Bloomington, Ind.

McCulloch, W. S. and Pitts, W.(1943), "A logical calculus of the ideas immanent in nervous activity," Bulletin of Mathematical Biology, Vol. 5, No. 4, pp.115-133.

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.

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.

Principe, J. C., Euliano, N. R. and Lefebvre, W. C.(2000), "Neural and adaptive systems: fundamentals through simulations," Journal of Forecasting, John Wiley and Sons, New York.

Ripley, B. D.(1993), "Statistical Aspects of Neural Networks," Proceedings of SemStat, Chapman & Hall, London.

Rumelhart, D. E. and McClelland, J. L.(1986), "Parallel distributed processing: Explorations in the microstructure of cognition," MIT Press Cambridge, Massachusetts.

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.

Waibel, A., Hanazawa, T., Hinton, G., Shikano, K. and Lang, K.(1990), "Phoneme Recognition Using Time Delay Neural Networks," IEEE Transactions on Acoustics, Speech and Signal Process, Vol. 37, No. 3, pp.328-339.

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.

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.

Zhang, G. P.(2003), "Time series forecasting using a hybrid ARIMA and neural network model," Neurocomputing, Vol. 50, No. 2, pp.159-175.

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.