

工學碩士 學位論文

신경망을 이용한 컨테이너 물동량 예측에
관한 연구

A Study on the Forecast of Container Volume
using Neural Network

指導教授 李 哲 榮

2002年 2月

韓國海洋大學校 大學院

物流시스템工學科

朴 盛 永

목 차

List of Tables	iii
List of Figures	iv
Abstract	v
1. 서론	1
1. 1 연구의 배경 및 목적	1
1. 2 연구의 범위	2
2. 예측 방법의 종류	4
2. 1 정성적 예측 방법	4
2. 1. 1 델파이법	4
2. 1. 2 시장조사법	5
2. 1. 3 패널조사법	5
2. 2 정량적 예측 방법	6
2. 2. 1 단순이동평균법	6
2. 2. 2 가중이동평균법	7
2. 2. 3 지수평활법	8
2. 2. 4 회귀분석	9
3. 신경망 이론	11
3. 1 신경망의 개요	11
3. 1. 1 신경망의 정의	11
3. 1. 2 신경망의 특징	12
3. 1. 3 신경망의 종류	13
3. 2 신경망의 모형	14
3. 2. 1 신경망의 구조	14

3. 2. 2 전달함수	15
3. 3 신경망의 학습알고리즘	16
3. 4 예측모형의 설계	18
3. 4. 1 데이터 변환	18
3. 4. 2 예측모형의 구조	19
4. 실험 및 평가	23
4. 1 입력벡터분석	24
4. 2 신경망을 이용한 물동량 예측	26
4. 2. 1 모델 1	26
4. 2. 2 모델 2	30
4. 3 일반적인 예측방법과의 비교	34
4. 3. 1 이동평균법을 이용한 예측	34
4. 3. 2 지수평활법을 이용한 예측	35
4. 3. 3 추세분석법을 이용한 예측	37
4. 3. 4 예측방법의 비교	38
5. 결론	41
참 고 문 헌	43

List of Tables

Table 3.1 신경망의 분류	13
Table 4.1 컨테이너항만 물동량에 관한 자료	23
Table 4.2 입력벡터분석의 오차비교	25
Table 4.3 모델1의 1995년도 자료의 변환	27
Table 4.4 모델1의 1996년도 자료의 변환	28
Table 4.5 모델1의 반복회수와 오차율비교	29
Table 4.6 모델2의 1995년도 자료의 변환	31
Table 4.7 모델2의 1996년도 자료의 변환	32
Table 4.8 모델2의 반복회수와 오차율비교	33
Table 4.9 이동평균법을 이용한 물동량 예측	35
Table 4.10 단순지수평활법을 이용한 물동량 예측	36
Table 4.11 이중지수평활법을 이용한 물동량 예측	37
Table 4.12 추세분석법을 이용한 물동량 예측	35
Table 4.13 예측방법의 비교	35

List of Figures

Fig. 2.1 예측의 종류	10
Fig. 3.1 도식화된 뉴런의 비교	12
Fig. 3.2 신경망의 기본구조도	14
Fig. 3.3 신경망의 대표적인 전달함수	15
Fig. 3.4 역전파 학습알고리즘의 학습과정	17
Fig. 3.5 역전파 학습알고리즘을 이용한 신경망구조	21
Fig. 4.1 신경망 학습알고리즘의 수렴결과	25
Fig. 4.2 모델1의 1995년도 신경망 학습알고리즘의 수렴결과	27
Fig. 4.3 모델1의 1996년도 신경망 학습알고리즘의 수렴결과	29
Fig. 4.4 신경망에 의한 예측물동량(입력자료=9)	30
Fig. 4.5 모델2의 1995년도 신경망 학습알고리즘의 수렴결과	31
Fig. 4.6 모델2의 1996년도 신경망 학습알고리즘의 수렴결과	33
Fig. 4.7 신경망에 의한 예측물동량(입력자료=3)	34
Fig. 4.8 예측방법에 따른 컨테이너 물동량 예측비교	39

*A Study on the Forecast of Container Volume
using Neural Network*

Sung-Young, Park

*Department of Logistics Engineering
Graduate School of Korea Maritime University*

Abstract

The forecast of a container traffic has been very important for port plan and development. Generally, Statistic methods, such as moving average method, exponential smoothing, regression analysis, have been much used for traffic forecasting. But, by considering various factors related to the port affect the forecasting of container volume, neural network of parallel processing system can be effective to forecast container volume based on various factors.

This study discusses the forecast of container volume by using the neural network with back propagation learning algorithm. Affected factors are selected to be based on impact vector on neural network, and these selected factors are used to forecast container volume. The proposed algorithm which forecasts using neural network is verified through comparing to statistic methods.

1. 서론

1.1 연구의 배경 및 목적

현재 전세계 대부분의 국가들의 산업은 IT(Information Technology)화 되어가고 있으며 그 중요성 또한 매우 크다고 할 수 있다. 그로 인해서 많은 자본과 기술이 정보화에 투자되는 있는 실정이다. 그러나, 아무리 이러한 정보화와 과학화가 현대의 산업을 이끌어 가더라도 무역활동에 있어서 항만은 없어서는 안 될 존재이며 그 중심에 있다. 우리 나라의 경우에도 국제무역규모에 있어서 수출입 화물의 95%이상이 해상 운송에 의해서 이루어지고 있는 실정이다. 그러므로 항만은 국제무역의 관문인 동시에 국가발전에 있어서 매우 중요한 역할을 하고 있다.

전세계적으로 홍콩, 싱가포르, 부산, 카오슝, 로테르담, 상하이 등 60여 개에 가까운 항들이 연간 100만 TEU이상의 컨테이너를 처리하고 있다. 그리고 이들 항만들은 매년 그 물량이 증가하고 있는 추세를 띄고 있다. 동북아 중심의 항만이 되기 위해서 한국, 일본, 중국 등 여러 동북아국가들은 지금도 보이지 않는 치열한 경쟁을 하고 있다. 항만의 물동량 예측은 이러한 중요한 시기에 있어서 항만의 개발과 항만계획의 수립에 있어서 매우 필요한 정보가 아닐 수 없다.

기존의 물동량 예측의 방법들은 단지 과거의 물동량의 흐름에 대하여 미래 물동량을 예측하는 시계열 자료에 의한 예측방법들이 대부분이었다. 하지만, 항만의 물동량은 독립적으로 존재하는 것이 아니며 많은 항만의 요소들과 유기적으로 밀접한 관계를 가지고 있다. 그러므로, 물동량 예측에 있어서 이러한 요소들을 이용하는 것은 당연하다. 기존의 예측방법들은 물동량에 영향을 주는 많은 요소들이 배제되었으며 이에 더 정확한 예측을 위해 이러한 요소의 이용이 필요하게 되었다.

컨테이너항만의 물동량에 영향을 미치는 다수의 입력변수들을 이용한 예측을 하기 위해서 본 논문은 다수의 요소를 동시에 처리하는 병렬처리시스템인 신경

망을 이용하여 컨테이너항만의 물동량의 예측하였다. 또한 예측에 사용되어진 항만의 관련 요소들을 신경망을 이용해서 중요도를 분석하였으며 중요도가 높은 변수를 이용하여 개선된 물동량의 예측을 하였다.

이에 본 연구는 컨테이너항만의 물동량 예측에 대한 중요성을 인식하고 새로운 물동량 예측방법을 제안한다.

1.2 연구의 범위

컨테이너항만의 물동량 예측 방법은 일반적으로 과거의 물동량의 추세에 따른 변화를 예측하는 통계적인 방법을 사용해 왔다. 그러나, 이러한 방법은 항만의 물동량 변화에 근본적으로 영향을 미치는 변수의 분석이 없었다. 이 결과로 IMF 나 경제과동, 경쟁항만의 급성장 등 급변하는 물동량 흐름을 예측하는 데 있어 큰 어려움을 갖고 있다.

이에 본 연구에서는 컨테이너항만 물동량 예측에 있어서 물동량에 영향을 주는 변수들을 찾아내어 입력변수로서 이용하며 다수의 입력변수를 병렬적으로 취급하여 예측할 수 있는 신경망을 이용한 물동량 예측 방법을 제안한다.

먼저 본 연구에서 제시하는 입력변수로는 컨테이너항만 물동량에 영향을 미치는 수입화물량, 수출화물량, 연안화물량, 환적화물량, 선박입항수, 선박출항수, 항만하역능력, 경제활동인구수, 1인당 국민총소득을 이용하여 컨테이너항만 물동량을 예측해 본다. 또한 이들의 입력변수의 영향벡터를 분석하여 항만물동량에 영향력이 있는 변수들을 선별하였다. 그리고, 항만 물동량에 관련된 중요도가 높은 변수들만을 이용하여 개선된 물동량 예측을 하였다. 또한 일반적으로 예측에 이용되었던 통계적인 방법들과 물동량예측을 한 결과를 비교해 본다.

본 연구의 구성은 다음과 같다.

2장에서는, 일반적으로 이용되는 예측의 방법에 대해서 살펴보기로 한다. 다음으로 3장에서는 본 연구에서 주로 다루고 있는 신경망에 대해서 설명하고 있다. 신경망의 기본개념과 본 연구에서 사용하고 있는 신경망 예측모델에 대해서 자세히 설명하도록 한다. 4장에서는 입력벡터분석의 과정과 신경망을 이용한 예측

을 하였으며 이러한 예측의 결과와 분석에 대해서 알아보도록 한다. 마지막으로 5장에서는 분석의 결과를 바탕으로 결론 및 추후과제에 대해서 살펴보고 본 논문을 맺도록 한다.

2. 예측 방법의 종류

예측(Forecasting)이란 과거의 자료를 근거로 미래의 발생결과를 예측하는 과정이다. 이것은 주관성이 개입되어 있는 추측(Predication)과 구별된다. 또한 “앞으로 이렇게 하겠다”라고 하는 계획과도 구별된다. 예측은 계획을 세우고 의사결정을 하는 데 있어서 매우 중요하다. 예측 방법은 예측에 사용되는 자료의 종류에 따라 크게 정성적인 예측 방법(Qualitative Method)과 정량적인 예측 방법(Quantitative Method)으로 나뉠 수 있다. 이번 장에서는 여러 예측 방법에 대해서 간략하게 알아보도록 하겠다.

2.1 정성적 예측 방법

주로 중장기의 예측에 적용되는 방법으로 예측하려는 주제에 대한 전문적인 지식이나 경험을 가지고 있는 전문가의 의견을 기초로 이루어지는 여러 방법들을 말한다. 일반적으로 외부의 요인이 중요한 역할을 할 때 장기예측에 사용된다. 또한 충분한 자료가 없는 경우 예측을 하게 되는 때에 이 방법을 사용하게 된다. 정성적 예측 방법의 예로는 델파이법(Delphi Method), 시장조사법(Market Research), 패널조사법 등이 있다.

본 연구에서는 과거자료를 이용하여 컨테이너항만의 물동량 예측을 하게 됨으로 정성적 예측 방법에 대한 연구는 하지 않는다.

2.1.1 델파이법

델파이법(Delphi Method)이란 그리스 델파이 신전에서 신탁을 받는 것과 같이 전문가 집단의 합치된 의견을 예측값으로 받으려는 방법이다. 각종 모임, 위원회나 회의를 통해 집단적 토론을 하면서 의견을 수렴해 나가는 방식은 민주적이지

만 집단 내 권위 있는 특정 전문가의 견해나 다수의 의견에 영향을 받아 구성원들이 자신의 의견을 내놓지 못하는 단점을 가지고 있다. 이러한 전문가의 영향과 집단내 분위기를 배제하여 자유롭게 의견을 개진할 수 있도록 서면에 의한 수요예측방법을 델파이법이라고 한다. 이 방법은 예측하려는 주제에 대한 전문가를 구성하여 한자리에 모이지 않고 서면이나 설문지에 의한 조사와 응답결과의 피드백(Feedback)을 반복하면서 의견을 수렴, 예측 결론을 도출해 내는 방법이다.

2.1.2 시장조사법

시장조사법(Market Research)은 소비자 패널이나 광범위한 소비자를 대상으로 면접, 소비자패널, 설문지 등의 조사방법을 통해 수요조사를 행하는 방법이다. 이러한 방법은 새로운 제품이나 서비스를 시장에 출시할 때나 소비자의 의견조사를 할 때 주로 이용되는 방법이다. 이 방법은 정성적인 예측방법에 속하면서도 정량적인 예측방법에 가깝다.

2.1.3 패널조사법

패널조사법은 위원회 동의법이라고 하며 여러 사람이 함께 의견을 교환하고 토론하여 예측하는 것이 보다 좋은 결론을 얻을 수 있다는 가정에 기초하고 있다. 예측하려는 제품과 관련된 경영자, 판매원, 소비자 등으로 패널을 구성하여 델파이법과는 달리 완전 개방된 상태에서 자유롭게 의견을 제시하여 예측하는 방법이다. 이 방법은 패널구성원에 따라 예측결과가 큰 차이를 보이며 패널 내 권위 있는 사람의 영향력이 예측값에 많이 반영된다는 것이 단점이다.

2.2 정량적 예측 방법

정량적 예측 방법은 다시 두 가지로 나뉘게 되는 데, 과거의 수요를 분석하여 시간에 따른 수요의 패턴을 파악하고 이의 연장선상에서 미래의 수요를 예측하는 시계열 예측 방법(Time Series Analysis)과 수요에 영향을 주는 환경요인들을 파악하고 수요와 이들 요인들과의 인과 관계를 파악함으로써 미래의 수요를 예측하는 인과형 예측 방법(Causal Forecasting Method)이 그것이다.

시계열 예측 방법은 일정한 시간적 간격으로 나열된 과거의 자료에 나타난 수요의 패턴이 미래의 시간 간격에도 연속하여 적용된다는 가정에서 수요를 예측하는 방법이다. 여기서 패턴(Pattern)이라 함은 시계열 모양을 말하며 수년간의 과거 자료가 있을 때 그 자료 속에서 추세가 분명히 나타나며 비교적 안정적일 때 적합한 방법이다. 이러한 시계열 예측 방법의 예로는 단순이동평균법(Simple Moving Average Method), 가중이동평균법(Weighted Moving Average Method), 지수평활법(Exponential Smoothing) 등이 있다.

인과형 예측 방법은 원인과 결과의 관계로 이루어진 인과형 자료를 기초로 인과관계를 예측하기 위해서 사용되는 예측방법이다. 독립변수(Independent Variable)를 원인이 되는 변수라고 해서 원인변수라고 하며 종속변수(Dependent Variable)를 이러한 원인의 결과로 인한 결과변수라고도 한다. 이러한 인과형 예측방법의 예로는 회귀분석(Regression Analysis)과 상관분석 등이 있다.

2.2.1 단순이동평균법

단순이동평균법은 과거의 자료에서 추세변동이나 계절적인 변동이 포함되지 않고 설명할 수 없는 불규칙 변동만 크게 작용하는 경우의 수요예측에 적합한 기법이다. 이 때 이 불규칙 변동을 단순이동평균법에 의해 제거될 수 있다. 이 방법은 이동평균대상기간수에 따라 3기이동평균, 5기이동평균, 6기이동평균 등으로 나눌 수 있다. 여기서 수요예측값을 예측하려는 시점의 직전에 있는 일정기간의 실제수요 즉 예측하려고 하는 대상기간수의 실제수요를 동일한 비중으로

산술평균하여 계산한다.

$$F_t = \frac{\sum_{i=1}^n A_{t-i}}{n}$$

$F_t = t$ 기의 수요예측값

$A_{t-1} = t-i$ 기의 실제수요

$n =$ 기간수

2.2.2 가중이동평균법

가중이동평균법은 이동평균할 때 예측하려는 시점과 가까운 과거 자료에 더 가중치를 두어 예측하려는 방법이다. 단순이동평균법에서는 각 자료값에 동일한 가중치가 부여되었다. 이에 비해 가중이동평균에서는 예측하려는 시점의 직전에 N기간동안 가중치의 합이 1이 되도록 부여한다.

예를 들어 시계열 자료에 추세 또는 패턴이 있을 때는 예측하려는 시점과 가까운 곳에 있는 자료가 더 미래의 예측값을 잘 설명해 줄 수 있기 때문이다. 그래서 예측하려는 시점의 직전에 있는 자료에 높은 가중치를 부여하고 먼 과거의 실제값에는 점점 낮은 가중치를 부여하는 방법이다. 가중평균에는 기간을 길게 하면 불규칙한 시계열 변동을 평준화하는 효과를 낼 수 있으나 가중치의 결정을 예측자의 경험적인 판단에 의존해야 한다는 점에서 예측자의 주관에 개입될 여지가 많다.

$$F_t = \sum_{i=1}^n W_{t-i} \cdot A_{t-i}$$

$F_t = t$ 기의 수요예측값

$W_{t-i} = t-i$ 기의 가중치

$A_{t-i} = t-i$ 기의 실제수요

$n =$ 기간수

$$\sum_{i=1}^n W_{t-i} = 1$$

2.2.3 지수평활법

가중이동평균법과 마찬가지로 과거로 올라갈수록 자료의 중요성이 감소한다는 가정에서 과거 자료에 점점 낮은 가중치를 부여하는 방법이다. 그러나 이 방법은 가중이동평균법과는 달리 최근의 실제값에 가중치의 대부분을 부여하며 과거의 자료가 올라갈수록 지수적(Exponentially)으로 감소한다고 생각한다. 이 방법은 이동평균법과 마찬가지로 시계열자료에 추세나 계절적 변동이 적을 때 유용하며 단순이동평균법이나 가중이동평균법에 비해 과거의 자료수가 적을 때도 적용할 수 있다는 장점을 가지고 있다.

이 방법에 의한 당기 예측값의 계산은 그 시점에서의 전기예측값에 실제값과 예측값 차이의 일정비율을 더함으로써 이루어진다. 여기서 사용하는 일정 비율은 지수평활계수를 말하며 현재 관측된 수요에 대한 가중치를 나타낸다.

$$\text{당기 예측값} = \alpha \times \text{전기 실제값} + (1 - \alpha) \times \text{전기 예측값}$$

이것을 수식으로 일반화시키면 다음과 같다.

$$F_t = f_{t-1} + \alpha (A_{t-1} - F_{t-1})$$

$$F_t = t \text{ 기의 예측값}$$

$$F_{t-1} = t-1 \text{ 기의 예측값}$$

$$A_{t-1} = t-1 \text{ 기의 실제수요}$$

$$\alpha = \text{지수평활 계수}$$

다시 정리하면,

$$F_t = \alpha \times A_{t-1} + (1 - \alpha) \times F_{t-1}$$

위의 수식에 의해 당기 예측값을 계산하는 경우 최초의 예측값이 주어져야 되고 지수평활계수 α 가 결정되어야 한다. 초기 예측값은 그 이전의 과거 자료가 있으면 단순이동평균이나 가중이동평균으로 최초의 예측값을 계산하는 방법이 있으나 과거 자료가 없으면 정성적인 방법에 의한 예측값을 적용할 수 있으며 최초의 실제값을 예측값으로 이용하는 것도 하나의 방법이다.

이 방법에서 가장 어려운 것은 지수평활 계수 α 를 결정하는 문제이다. α 가 커지면 실제값에 비중을 많이 두어 예측하게 되어 예측값이 실제의 수요변화에 빠르게 반응하는 결과를 가져온다. 역으로 α 가 작아지면 예측값에 비중을 많이 두어 예측하게 된다. 그러므로 α 값이 크면 실제값의 움직임에 초점을 두어 보수적으로 예측하는 것이며 α 값이 작으면 예측값 즉 목표값에 비중을 두어 적극적으로 예측하는 것이다. α 의 수준을 얼마나 해야할 것인가에 대한 결정은 과거의 자료를 활용하여 α 의 수준을 달리하면서 여러 번 예측을 실시한 후 실제값을 반영한 예측값이 나오는 α 로 결정할 수 있다.

2.2.4 회귀분석

회귀분석 방법은 앞에서 설명된 예측 방법과 그 성격이 다르다. 이동평균법, 지수평활법, 분할법은 하나의 시계열 자료를 분석하여 예측을 하는 반면에, 회귀 분석 방법은 두 개 이상의 시계열 자료들간의 인과관계를 분석하여 독립 변수를 이용하여 종속 변수의 미래를 예측하는 방법이다.

회귀분석 방법의 일반적인 모형은 크게 두 종류로 분류되는데, 독립 변수가 하나인 경우는 단순회귀분석(Simple Regression Analysis)이라 하고, 독립 변수가 두 개 이상인 경우는 다중회귀분석(Multiple Regression Analysis)이라 한다. 아래의 수식의 F_i 는 단순회귀식을 F_t 는 다중회귀식을 나타낸다.

$$F_i = a + \beta x_i + e_i$$

$$F_t = a + \beta_1 X_{1t} + \beta_2 X_{2t} + \dots + \beta_n X_{nt} + e_i$$



Fig. 2.1 예측방법의 종류

3. 신경망 이론

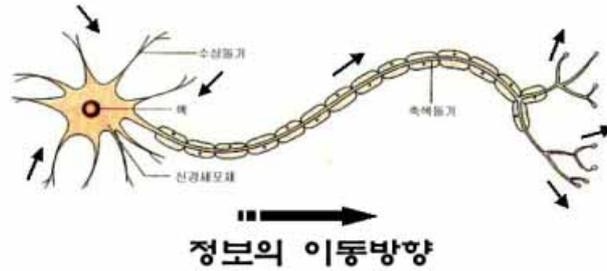
3.1 신경망의 개요

3.1.1 신경망의 정의

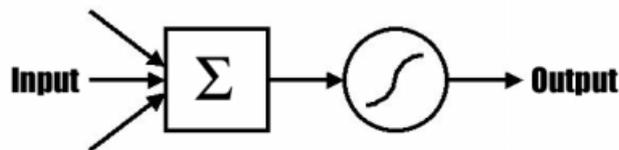
인간의 두뇌에 관한 탐구는 오래 전부터 계속되어 왔다. 컴퓨터의 발달과 더불어 인간과 같이 계산하고 판단하며 인식할 수 있는 컴퓨터를 통한 인공지능의 구현을 위하여 많은 노력이 경주되고 있다. 최근에는 패턴인식, 의사결정 등에서 컴퓨터보다 우수한 인간의 두뇌를 모방한 신경망에 대한 연구가 가속되고 있다.

신경망은 생물학적 신경계를 단순화시켜 수학적으로 모사한 모델로서 신경세포와 연결들로 구성되며 간단한 학습규칙을 적용하여 학습을 수행하는 자료 처리 시스템이라 할 수 있다. 신경망이 지식을 습득하는 과정은 마치 인간의 두뇌 활동과 마찬가지로 새로운 학습자료에 대해 자신을 변형시키고, 신경세포들의 지식 전달과 유사하게 지식을 병렬 분산 처리한다.

인간의 두뇌와 신경망의 가장 기본이 되는 단위는 뉴런이다. 뉴런의 기본적인 기능은 정보의 수용과 연산처리, 정보의 출력이며 다수의 뉴런들이 서로 결합되어 신경망을 이루고 있다. 인공적으로 이루어진 신경망의 이론을 보면 다수의 입력에 대해서 미리 결정된 비선형 함수에 의해서 출력이 이루어지는 형태가 된다. Fig. 3.1은 신경계의 뉴런과 인공적인 뉴런을 도식화한 것이다.



(a) 신경계의 뉴런



(b) 인공적인 뉴런

Fig. 3.1 도식화된 뉴런의 비교

3.1.2 신경망의 특징

신경망의 대표적인 특징으로는 학습능력과 일반화를 들 수가 있다.

신경망의 학습능력은 일반적으로 목표패턴이 주어지는 지도학습(Supervised learning)에서 잘 나타난다. 학습은 입력값에 대한 출력값들의 오차를 줄이면서 계속적인 반복을 통하여 연결가중치값들을 조절해 나간다. 이러한 학습은 신경망이 경험하는 환경에 따라 자신의 내적인 상태를 매우 간단한 규칙에 의해 변형시킴으로써 스스로 내적 지식을 축적하는 능력을 말하기도 한다. 기존의 프로그램들은 미리 정해진 알고리즘에 따라 수행되는 반면에 신경망은 입력값과 목표값이 주어지면 학습을 통하여 원하는 출력값을 얻어내는 형태이다.

일반화는 학습이 이루어지고 난 다음에 경험한 것에 대해 다른 형태의 입력에 대하여 적절한 답을 얻어 낼 수 있음을 말한다. 이러한 능력은 입력값의 잡음이

나 구조적인 결함이 있음에도 신경망의 네트워크 상에서 적절한 답을 구할 수 있다.

3.1.3 신경망의 종류

일반적으로 신경망의 종류는 입력자료가 이진수(binary)의 형태를 가지거나 실수형태의 연속적인 값을 가지는 두 가지로 나뉘어진다. 또한 학습의 방법에 따라 지도학습(Supervised learning)모형과 비지도학습(Unsupervised learning)모형으로 나뉘는 데 이것은 연결강도를 반복적으로 조절하기 위한 학습과정 중에 출력값과 비교할 수 있는 목표값의 유무에 따라 구분되는 것이다. 지도학습은 결과값과 비교되는 목표값이 있는 형태를 말하며 교사학습(learning with teacher)이라고도 한다. 비지도학습은 자율학습이라고도 하며 스스로 입력자료의 범주나 특징을 발견해야만 된다. 비지도학습은 목표값없이 자기조직화에 의해 훈련하게 되고 결과값을 출력하게 된다. Table 3.1은 이러한 형태에 따라 패턴을 분류한 것이다.

Table 3.1 신경망의 분류

입력형태 (Input Type)	학습 (Learning)	모델 (Model)	알고리즘 (Algorithm)
이진값을 가진 형태 (Binary Input)	지도학습 (Supervised learning)	Hopfield	
		Hamming	Optimum classifier
	비지도학습 (Unsupervised learning)	Carpenter/Grossberg	Leader clustering Algorithm
연속값을 가진 형태 (Continuous valued Input)	지도학습 (Supervised learning)	Perceptron	Gaussian classifier
		Multi-layer perceptron	K-Nearest Neighbor Mixture
	비지도학습 (Unsupervised learning)	Kohonen Self-Organizing	K-means clustering algorithm
		SONN	Fuzzy c-means clustering algorithm

3.2 신경망의 모형

3.2.1 신경망의 구조

신경망의 구조는 크게 입력층과 은닉층, 출력층으로 나뉘며 은닉층의 수는 이론적으로 개수의 제한이 없으나 대부분 문제를 해결하는 데는 하나의 은닉층만으로도 충분한 것으로 알려져 있다. 이들 각각의 층 사이에는 연결강도 또는 가중치를 갖는 링크로 연결이 되어 있다. 입력층의 입력값은 입력층과 은닉층 사이의 가중치의 곱해지고 전달함수에 의해서 결과값을 얻게 된다. 입력층의 결과값은 은닉층의 입력값이 되고 은닉층과 출력층 사이의 가중치와 곱해진 다음 전달함수에 의해서 결과값을 얻게 된다. 이러한 전방향(feedforward)의 네트워크 형태가 기본적인 구조이며 반복적인 학습과정에 의해서 가중치의 값들의 변화가 이루어지게 되는 것이다. Fig. 3.2 는 신경망의 기본구조를 도식화한 것이다.

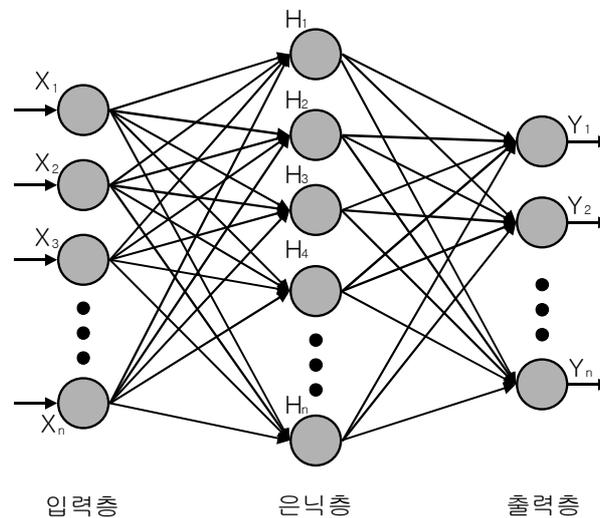


Fig. 3.2 신경망의 기본구조도

3.2.2 전달함수

신경망에서 주로 사용되는 전달함수(transfer function)로는 step 함수, signum 함수, sigmoid 함수, hyperbolic tangent 함수 등이 있다. 이 함수들은 $-\infty$ 에서 $+\infty$ 까지 모든 값을 변수로 받아들이며 주로 -1에서 +1 또는 0에서 +1사이의 값으로 출력하게 된다. 식 3.1은 역전파 알고리즘에 주로 이용되는 sigmoid 함수를 식으로 나타낸 것이며 0~1 사이의 값으로 출력하게 된다.

$$F(x) = \frac{1}{1 + \exp(-ax)} \quad (\text{식 3.1})$$

a 는 전달함수에 이용되는 경사변수(steeptness parameter)로써 수식의 전개를 간단히 하여 역전파 알고리즘의 적용에 편리하도록 하기 위하여 1 또는 1/2의 값이 주로 이용된다.

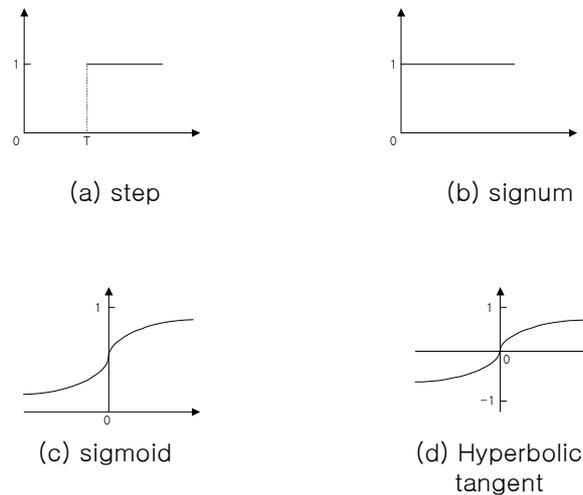


Fig. 3.3 신경망의 대표적인 전달함수

3.3 신경망의 학습알고리즘

신경망이 주어진 데이터의 특성을 학습하는 데 사용되는 학습알고리즘(learning algorithm)에는 여러 가지가 있는 데 가장 보편화 된 것 중에 하나가 역전파 학습알고리즘(Back propagation learning algorithm)이다. 이 알고리즘은 최소자승 알고리즘의 비선형적인 형태로 볼 수 있다.

학습 알고리즘의 기본원리는 다음과 같다.

입력층(input layer)의 각 노드에 입력패턴을 주면 은닉층(hidden layer) 사이의 연결강도가 곱해지고 전달함수에 의해 값이 변환된다. 이렇게 변환된 값이 은닉층의 입력값이 되고 다시 출력층(output layer) 사이의 연결강도와 곱해지고 출력층의 전달함수에 의해 값이 변환되어 출력값이 만들어진다. 이렇게 만들어진 출력값은 목표값과 비교되어 둘 사이의 오차값이 생기게 된다. 오차가 없으면 학습이 끝이 나게 된다. 하지만 오차가 있을 경우, 오차를 줄여나가는 방향으로 상위층에서 역전파하여 하위층으로 가중치값들이 조절되게 된다. Fig. 3.4는 역전파 학습알고리즘을 도식화한 것이다.

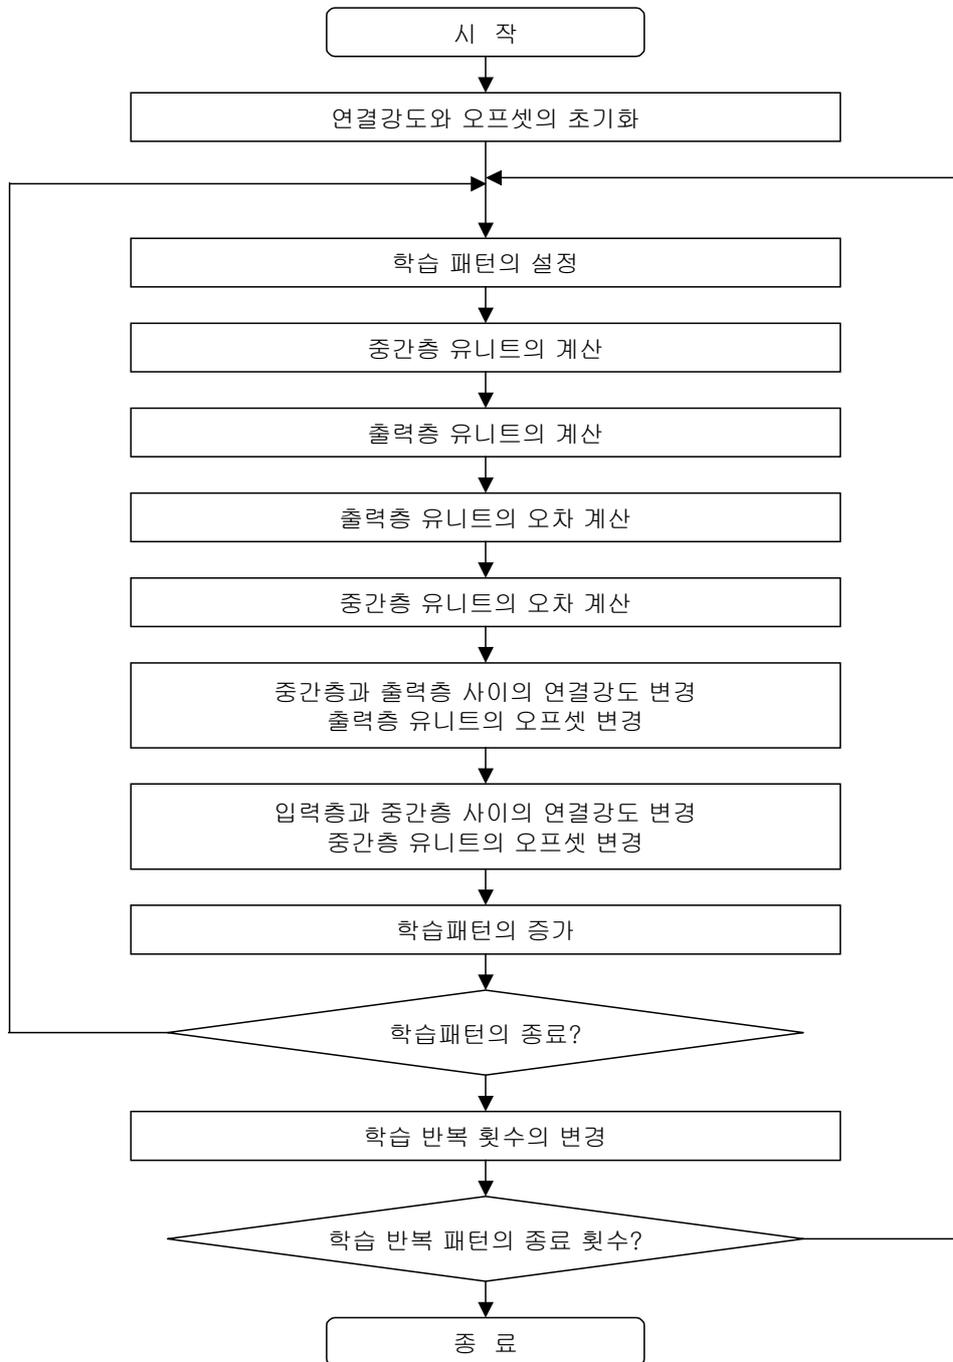


Fig. 3.4 역전과 학습알고리즘의 학습과정

3.4 예측모형의 설계

본 연구에서는 컨테이너항만 물동량 예측을 위한 자료로서 입력자료는 수입화물량, 수출화물량, 연안화물량, 환적화물량, 선박입항수, 선박출항수, 항만하역능력, 경제활동인구수, 1인당 국민총소득을 사용하였으며 목표자료로는 총화물량을 사용하기로 하였다. 신경망은 복잡한 형태의 시스템과정을 거치지 않더라도 선택적으로 출력에 영향을 미치는 연결강도값을 학습에 의하여 조절함으로써 예측모형을 구성할 수 있다. 본 연구에서 이를 이용하여 입력층에 $t - 1$ 기의 입력자료를 사용하고 출력층에 t 기의 목표자료를 사용하기로 한다. 즉, 현재의 총화물량은 전년도의 입력자료와 관련이 있는 것으로 가정하여 전년도의 입력자료를 입력층으로 구성하고 현재의 목표자료를 출력층으로 구성하였다. 본 모형은 목표자료를 두고 결과값과 비교하는 지도학습을 이용하고 있다. 학습과정 중에 종료조건으로는 출력값과 목표값의 오차를 줄여나가는 과정 가운데 오차율이 0.02가 되었을 때 종료하거나 반복횟수가 100,000번을 넘지 않는 범위에서 종료하는 것으로 하였다.

신경망은 학습을 통하여 연결강도의 가중치의 변화를 얻게 된다. 이를 이용하여 입력변수의 영향벡터를 분석할 수가 있게 되며 본 연구에서는 입력벡터 분석전의 물동량 예측과 입력벡터 분석 후의 물동량 예측의 두 가지 형태의 실험을 하여 비교하였다.

3.4.1 데이터 변환

본 연구에서 사용되는 자료들의 형태는 실수형태의 연속적인 값을 가진다. 그러나, 신경망 모델에 적용하기 위해서 0~1 사이의 값으로 변환되어야 한다. 이를 위해서 선형변환식을 이용하여 0.1~0.9 사이의 값으로 변환을 하였으며 학습한 이후의 예측값을 구하기 위하여 역변환하였다. 선형변환식의 식은 아래와 같다.

$$Y = \alpha \times X + \beta \quad (\text{식 3.2})$$

$$\alpha = \frac{0.8}{\max(X) - \min(X)} \quad (\text{식 3.3})$$

$$\beta = 0.1 - \alpha \times \min(X) \quad (\text{식 3.4})$$

$$X = \frac{(Y - \beta)}{\alpha} \quad (\text{식 3.5})$$

3.4.2 예측모형의 구조

신경망의 구조는 입력층과 은닉층, 출력층을 갖는 다층신경망 구조를 이용하였으며 은닉층 성분의 크기를 결정하는 일반적인 방법이 없으므로 반복적인 학습 과정을 통하여 적절한 크기로 정하였다. 입력층과 은닉층 사이의 전달함수는 역전과 학습알고리즘에 일반적으로 사용되는 시그모이드 함수(Sigmoid Function)를 선택하였으며 은닉층과 출력층 사이의 전달함수는 선형 함수(Linear Function)를 각각 이용하였다. 입력층의 성분들을 x_i , 은닉층의 성분들을 h_j , 출력층의 성분을 o_k 라고 표기하였다. 또한 입력층과 은닉층 사이의 연결강도를 w_{ij} , 은닉층과 출력층의 연결강도를 w_{jk} 로 표기하였다. 입력자료의 다른 패턴들을 구분하기 위하여 위 첨자 p 로 표기하였으며 p 번째 패턴의 입력자료 중 i 번째 성분은 x_i^p 로 표기된다.

초기단계에서 연결강도 w_{ij} , w_{jk} 와 오프셋 θ_j , θ_k 를 각각 임의의 값 $-0.5 \sim 0.5$ 로 초기화한다. 입력층의 성분 x_i , 입력층과 은닉층의 연결강도 w_{ij} 와 오프셋 θ_j 를 이용하여 은닉층의 성분인 h_j 를 구하게 되면 아래 식과 같다.

$$h_j^p = f_j \left(\sum_i w_{ij} x_i^p + \theta_j^p \right)$$

같은 방법으로 은닉층의 성분 h_j , 은닉층과 출력층의 연결강도 w_{jk} 와 오프셋 θ_k 를 이용하여 출력층의 성분인 o_k 를 구하게 되면 아래 식과 같다.

$$o_k^p = f_k(\sum_j w_{jk} h_j^p + \theta_k^p)$$

이렇게 전방향으로 구해진 출력층의 출력값인 o_k^p 와 목표값인 t_k^p 와의 오차로부터 연결강도 w_{jk} 와 출력층의 오프셋 θ_k^p 에 대한 오차 δ_k^p 를 구한다. 오차 δ_k^p 를 구하는 식은 아래와 같다.

$$\begin{aligned} \delta_k^p &= (t_k^p - o_k^p) f_k' (\sum_j w_{jk} h_j^p + \theta_k^p) \\ &= (t_k^p - o_k^p) \end{aligned}$$

구한 오차 δ_k^p 와 중간층과 출력층의 연결강도인 w_{jk} 와 은닉층 h_j 로부터 입력층과 은닉층의 연결강도 w_{ij} 와 은닉층의 오프셋 θ_j^p 에 대한 오차 δ_j^p 를 구한다. 오차 δ_j^p 를 구하는 식은 아래와 같다.

$$\begin{aligned} \delta_j^p &= f_j' (\sum_i w_{ij} x_i^p + \theta_j^p) \sum_k \delta_k^p w_{jk} \\ &= \sum_k \delta_k^p w_{jk} h_j^p (1 - h_j^p) \end{aligned}$$

위에서 구한 값들에 의해서 은닉층과 출력층 사이의 연결강도와 오프셋을 수정한다. 또한 같은 방법으로 입력층과 은닉층 사이의 연결강도와 오프셋을 수정한다. 수정하는 식은 아래와 같다.

$$\begin{aligned} w_{jk} &= w_{jk} + lr \times \delta_k^p \times h_j^p \\ w_{ij} &= w_{ij} + lr \times \delta_j^p \times x_i^p \\ \theta_k^p &= \theta_k^p + lr \times \delta_k^p \times h_j^p \\ \theta_j^p &= \theta_j^p + lr \times \delta_j^p \times x_i^p \end{aligned}$$

이때에 사용되는 lr 은 학습율이라고 하는데 초기값으로 0~1사이의 값으로 주어진다. 신경망이 반복적으로 학습을 하는 경우 학습율은 자체적으로 변환되는 적응성을 갖도록 하는 것이 효과적이다. 학습율은 일종의 오차 기울기의 하강단계의 크기라 할 수 있는데 작은 값을 갖는 경우는 오차 최소화를 위한 보장이 확실해지는 장점이 있지만 시간이 오래 걸리는 단점을 가진다. 큰 값을 갖는 경우는 최소점을 지나치는 불안정성을 나타내게 된다. 그러므로 학습이 잘 진행이 될 때는 구간의 크기를 증가시키도록 하였으며 학습이 잘 진행되지 않을 때에는 구간의 크기를 감소시키도록 하였다.

$$lr = lr \times 1.1 \quad (\text{학습이 잘 진행되는 경우})$$

$$lr = lr \times 0.5 \quad (\text{학습이 잘 진행되지 않는 경우})$$

입력층에 주어지는 입력값은 은닉층을 거쳐서 출력층에 전파되어 도달하게 되

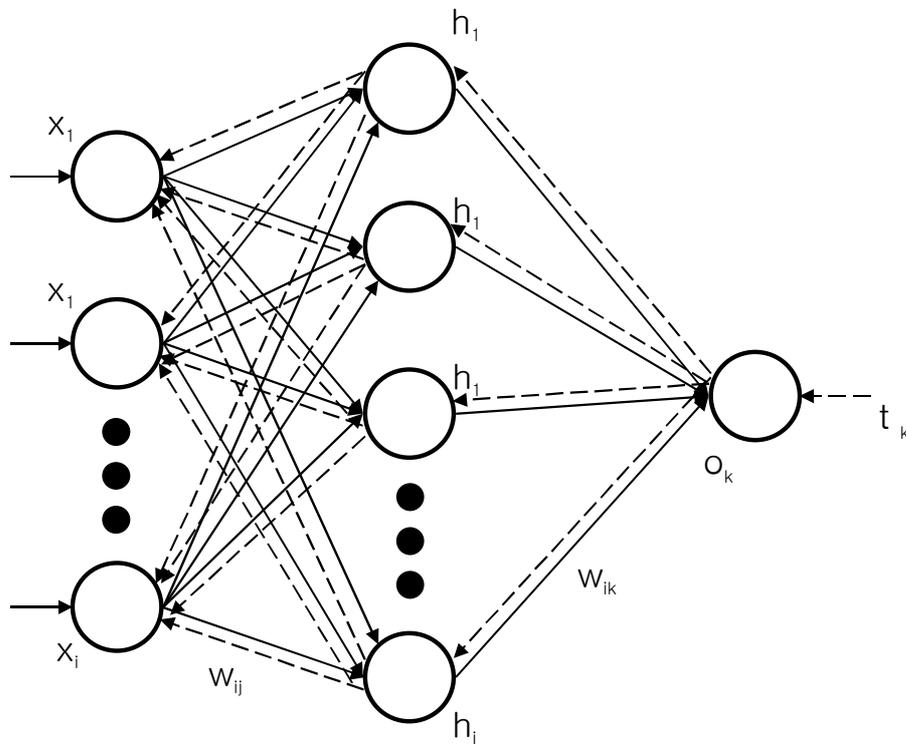


Fig. 3.5 역전파학습알고리즘을 이용한 신경망구조

고 이러한 출력값은 목표값과의 오차를 갖게 된다. 이 오차는 역방향으로 전파되어 각각의 노드사이의 연결강도와 오프셋을 조정해 나가는 게 된다. 이러한 반복적인 학습으로 일정한 수준까지 오차율을 감소시킬 수가 있다. 이렇게 학습이 이루어지고 난 뒤에 새로운 입력패턴에 대하여 출력패턴의 값들을 구할 수가 있다. Fig. 3.5는 역전파되는 예측모형을 도식화한 것이다.

4. 실험 및 평가

본 연구는 1990년부터 2000년까지의 항만에 관련된 자료를 바탕으로 신경망을 이용한 예측과 함께 일반적으로 사용되었던 통계적인 방법에 의한 예측도 함께 비교분석을 하였다. 우선 입력자료들의 영향력벡터분석에 대한 작업으로 9개의 입력자료에서 중요도가 높은 4개 입력자료를 선별하였다. 이를 바탕으로 두 가지 형태로 신경망을 이용하여 컨테이너항만의 물동량의 예측을 하였는데 모델 1은 기존의 9개의 입력자료를 이용한 예측이고 모델 2는 중요도가 높은 4개의 입력자료를 이용한 예측이다. 마지막으로 일반적인 통계적인 방법을 이용한 물동량 예측을 하여 이들을 서로 비교 분석하게 된다. Table 4.1은 1990년부터 2000년까지의 관련자료들이다.

Table 4.1 컨테이너항만 물동량에 관한 자료

변 수 \ 연 도	1990	1991	1992	1993	1994	1995	1996	1997	1998	1999	2000
수입화물(TEU)	1,046,000	1,135,242	1,190,457	1,343,620	1,653,106	1,915,988	2,066,106	2,306,343	2,507,380	2,851,993	3,356,450
수출화물(TEU)	1,348,000	1,431,793	1,530,077	1,597,031	1,797,553	2,025,691	2,191,285	2,404,981	2,650,518	2,894,817	2,691,322
연안화물(TEU)	0	0	0	0	98,492	116,736	168,922	171,907	310,301	299,945	238,817
환적화물(TEU)	75,000	70,344	77,967	191,060	297,004	429,649	471,984	585,929	634,205	931,601	1,026,560
선박입항수(천톤(G/T))	358,455	409,737	452,096	491,282	552,612	617,699	687,080	731,265	717,149	819,399	819,399
선박출항수(천톤(G/T))	357,874	409,361	454,234	489,516	551,278	615,238	692,517	737,057	725,591	821,831	821,831
항만하역능력(천톤)	224,323	248,365	275,650	267,677	274,831	285,200	295,257	357,351	416,254	417,561	423,522
경제활동인구(천명)	18,539	19,115	19,499	19,879	20,396	20,853	21,243	21,662	21,456	21,634	21,950
1인당국민총소득(천원)	4,170	5,000	5,610	6,270	7,230	8,350	9,160	9,800	9,400	10,170	10,890
총화물(TEU)	2,469,000	2,637,379	2,798,501	3,131,711	3,846,155	4,488,064	4,898,297	5,169,160	6,102,404	6,978,356	7,313,149

4.1 입력벡터분석

본 실험에서는 신경망의 학습이 수행되면서 입력과 출력사이의 관계를 반영하는 연결강도에 대하여 결과값에 미치는 영향에 대해서 알아보고 이에 입력변수의 중요도를 선별하는 실험을 하도록 한다. 종료조건을 만족하여 학습이 끝난 다음에 연결강도의 값은 입력과 출력패턴 사이의 밀접한 정도를 반영한다고 볼 수 있다. 그러므로 입력변수의 중요도에 따라 그 영향력의 크기는 달라질 것이다.

구체적인 방법으로 입력패턴에 포함된 입력변수의 값들이 하나씩 제거되었다고 가정하여 실험을 한다. 즉, 해당 입력값을 0으로 놓은 다음 신경망의 반응을 원래의 결과값과 비교한다. 각각의 입력값을 제거한 신경망의 반응값과 원래 신경망의 반응값의 차이는 오차의 절대치평균으로 한다. 다음 식은 각 변수에 대한 오차의 절대치평균을 나타내고 있다.

$$T_j = \frac{\sum_{i=1}^n |P_{ij} - O_{ij}|}{n}$$

P_{ij} = i 번째 패턴에 대한 j 번째 입력요소의 벡터(일부입력 제거)

O_{ij} = i 번째 패턴에 대한 j 번째 입력요소의 벡터(설정치)

실험은 각 연도별로 입력변수에 대한 각 연도의 출력변수에 대한 신경망 학습으로 1990년부터 2000년까지의 데이터 값으로 실험을 하였다. 입력층과 은닉층, 출력층은 각각 하나의 층으로 구성되었으며 오차율 0.02과 반복회수 100,000회를 종료조건으로 반복 학습하였다. Fig. 4.1은 오차와 학습율을 보여주고 있다.

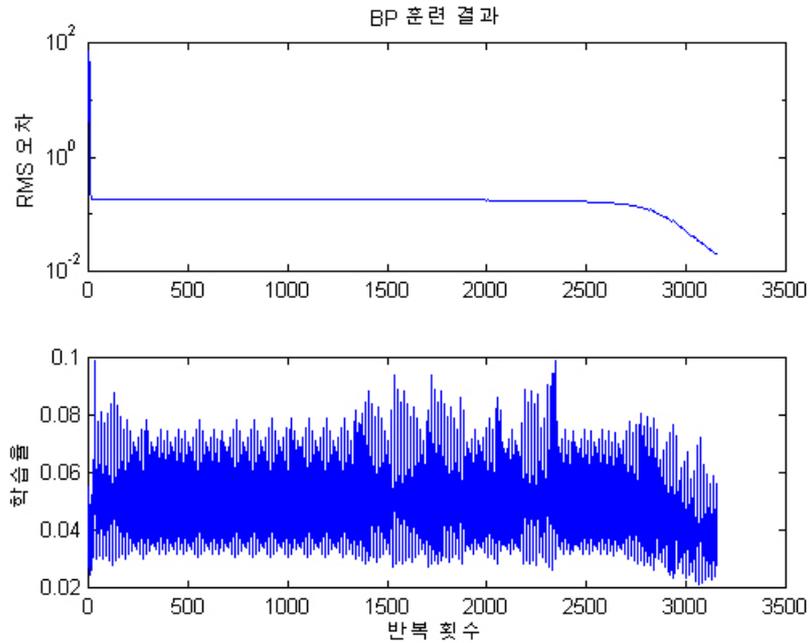


Fig. 4.1 신경망 학습알고리즘의 수렴결과

Table 4.2는 학습이 끝난 이후 각 연도별로 각 변수의 영향백터를 구하기 위한 절대오차를 나타낸 것이다.

Table 4.2 입력벡터분석의 오차비교

변수 \ 연도	T1	T2	T3	T4	T5	T6	T7	T8	T9
1990	0.25888	0.12907	0.04762	0.19373	0.14474	0.02718	0.04628	0.05030	0.03251
1991	0.26865	0.13236	0.04705	0.19078	0.14914	0.02797	0.04670	0.04980	0.03215
1992	0.27384	0.13656	0.04352	0.19052	0.15258	0.02863	0.04730	0.04933	0.03184
1993	0.28781	0.13639	0.04517	0.20787	0.15290	0.02853	0.04562	0.04793	0.03093
1994	0.31614	0.14011	0.04752	0.21860	0.15224	0.02831	0.04357	0.04558	0.02938
1995	0.33597	0.14453	0.04583	0.23289	0.15151	0.02804	0.04164	0.04327	0.02786
1996	0.34569	0.14802	0.04660	0.23368	0.15381	0.02852	0.04060	0.04190	0.02696
1997	0.36156	0.15130	0.04445	0.24369	0.15115	0.02794	0.04060	0.03993	0.02568
1998	0.37467	0.15700	0.04832	0.24368	0.14436	0.02670	0.04084	0.03845	0.02469
1999	0.38400	0.15290	0.04332	0.27075	0.14001	0.02561	0.03693	0.03477	0.02232
2000	0.42460	0.13661	0.03889	0.27243	0.13271	0.02421	0.03501	0.03282	0.02110
평균	0.33017	0.14226	0.04557	0.22715	0.14774	0.02742	0.04228	0.04310	0.02777

앞에서 설명한 방법에 의한 분석결과로 $T1 = 0.33017$, $T2 = 0.14226$, $T4 = 0.22715$, $T5 = 0.14774$ 의 결과로 영향력이 있는 변수로 나타나고 있다. 그러므로 신경망을 이용한 예측의 모델 2에 이용하게 될 중요한 변수로는 수입화물과 수출화물, 환적화물, 선박입항수로 나타났으며, 나머지 입력변수들은 상대적으로 영향력이 적은 변수로 나타났다.

4.2 신경망을 이용한 물동량 예측

4.2.1 모델 1

다음 모델은 항만에 관련된 9개의 입력자료를 가지고 신경망을 이용한 물동량 예측에 대한 예이다.

본 연구에서는 구축한 신경망에서는 입력층과 은닉층, 출력층이 각각 하나로 구성되었으며 입력층의 수는 9개, 은닉층의 수는 10개, 출력층의 수는 1개이다. 그리고 입력층과 은닉층의 전달함수로는 시그모이드 함수를 사용하였고 은닉층과 출력층의 전달함수로는 선형함수를 사용하였다. 학습의 종료조건으로는 오차율이 0.02이 되었을 때나 반복회수가 100,000번이 되었을 때 종료하는 것으로 하였다. 정확한 예측을 위해 어느 정도 학습이 이루어지는 과정이 필요하다. 경험이 쌓인 지식을 바탕으로 예측값을 얻어내기 위해서 초기의 예측값은 1994년까지의 학습으로 이루어진 이후 1995년도의 물동량을 예측하기로 한다.

예로 1995년도의 물동량의 예측값을 구하기 위해서 입력자료와 목표자료의 변환을 식 3.2를 사용하여 변환하였으며 Table 4.3에서 변환된 결과를 보여주고 있다. 학습을 끝난 결과 총 2,479회의 반복으로 오차율 0.02에 도달하고 있다. Fig. 4.2는 학습을 하는 과정중의 오차와 학습율을 보여주고 있다.

Table 4.3 모델1의 1995년도 자료의 변환

	1991	1992	1993	1994		1991	1992	1993	1994
수입화물	1,046,000	1,135,242	1,190,457	1,343,620		0.3175679	0.3361303	0.3476150	0.3794729
수출화물	1,348,000	1,431,793	1,530,077	1,597,031		0.3803839	0.3978129	0.4182559	0.4321823
연안화물	0	0	0	0		0.1	0.1	0.1	0.1
환적화물	75,000	70,344	77,967	191,060		0.1156000	0.1146315	0.1162171	0.1397405
선박입항수	358,455	409,737	452,096	491,282		0.1745586	0.1852253	0.1940359	0.2021866
선박출항수	357,874	409,361	454,234	489,516		0.1744378	0.1851471	0.1944806	0.2018193
항만하역능력	224,323	248,365	275,650	267,677		0.1466592	0.1516599	0.1573352	0.1556768
경제활동인구	18,539	19,115	19,499	19,879		0.1038561	0.1039759	0.1040558	0.1041348
1인당국민총소득	4,170	5,000	5,610	6,270		0.1008674	0.1010400	0.1011669	0.1013042
목표값	2,637,379	2,798,501	3,131,711	3,846,155		0.6485747	0.6820880	0.7513957	0.9

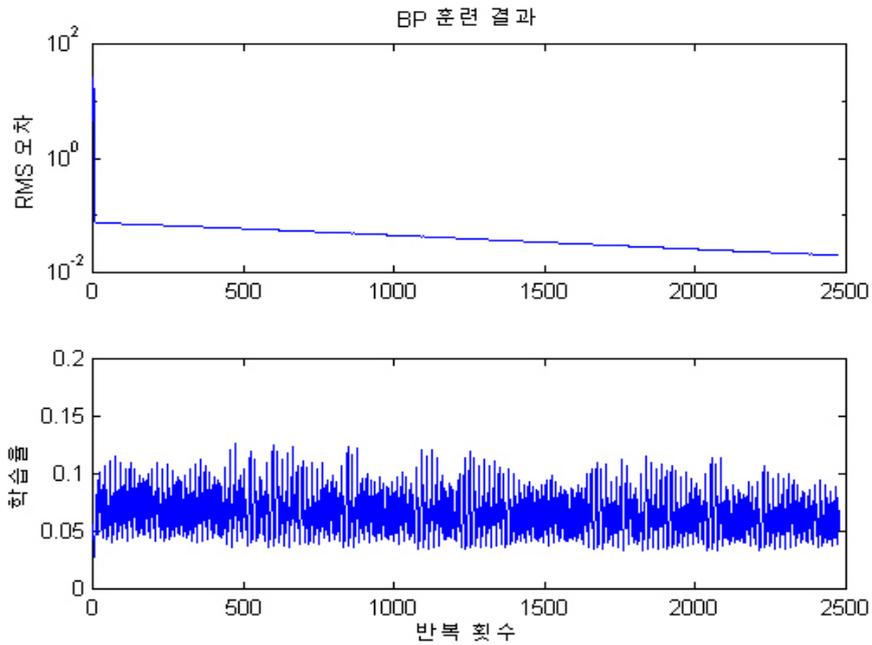


Fig. 4.2 모델1의 1995년도 신경망 학습알고리즘의 수렴결과

학습이 끝난 이후 일반화된 모델에 1995년도의 물동량을 예측하기 위해서 전

년도의 입력자료를 넣어서 나온 결과값은 1.0782182이며 이를 식 3.5의 역변환식을 이용해서 물동량 예측값 4,702,974 TEU를 얻을 수 있다.

다음의 예로 1996년도 물동량을 예측하는 과정에 대해서 알아보도록 한다. 신경망의 입력자료로는 9개의 변수를 사용하였으며 은닉층의 수는 10개를 두었다. 출력층은 총물동량을 결과값으로 하는 형태의 신경망 구조를 가지도록 하였으며 앞에서 학습을 했던 같은 형태의 구조이다. 표는 데이터의 자료를 선형변환식에 의해서 변환하는 것을 나타낸 것이다.

Table 4.4 모델1의 1996년도 자료의 변환

	1991	1992	1993	1994	1995	1991	1992	1993	1994	1995
수입화물	1,046,000	1,135,242	1,190,457	1,343,620	1,653,106	0.286450	0.302357	0.312200	0.339501	0.394667
수출화물	1,348,000	1,431,793	1,530,077	1,597,031	1,797,553	0.340282	0.355217	0.372737	0.384672	0.420415
연안화물	0	0	0	0	98,492	0.1	0.1	0.1	0.1	0.117556
환적화물	75,000	70,344	77,967	191,060	297,004	0.113369	0.112539	0.113898	0.134057	0.152941
선박입항수	358,455	409,737	452,096	491,282	552,612	0.163895	0.173036	0.180586	0.187571	0.198503
선박출항수	357,874	409,361	454,234	489,516	551,278	0.163791	0.172969	0.180968	0.187257	0.198265
항만하역능력	224,323	248,365	275,650	267,677	274,831	0.139986	0.144271	0.149135	0.147714	0.148989
경제활동인구	18,539	19,115	19,499	19,879	20,396	0.103304	0.103407	0.103476	0.103543	0.103635
1인당국민총소득	4,170	5,000	5,610	6,270	7,230	0.100743	0.100891	0.101000	0.101117	0.101289
목표값	2,637,379	2,798,501	3,131,711	3,846,155	4,488,064	0.570114	0.598834	0.658229	0.785579	0.9

학습이 종료되는 조건으로는 반복회수가 2,044회가 되었을 때 오차율제한 0.02에 도달하였다. 학습이 종료된 이후에 1996년의 물동량을 예측하기 위해서 1995년의 입력자료를 신경망 구조에 넣게 되면 결과값이 1.20028488이 나오게 되고 선형변환식에 의해서 예측물동량은 5,161,433 TEU 값을 얻게 된다. Fig. 4.3은 학습이 진행되는 과정중에 오차와 학습율을 나타내는 그래프이다.

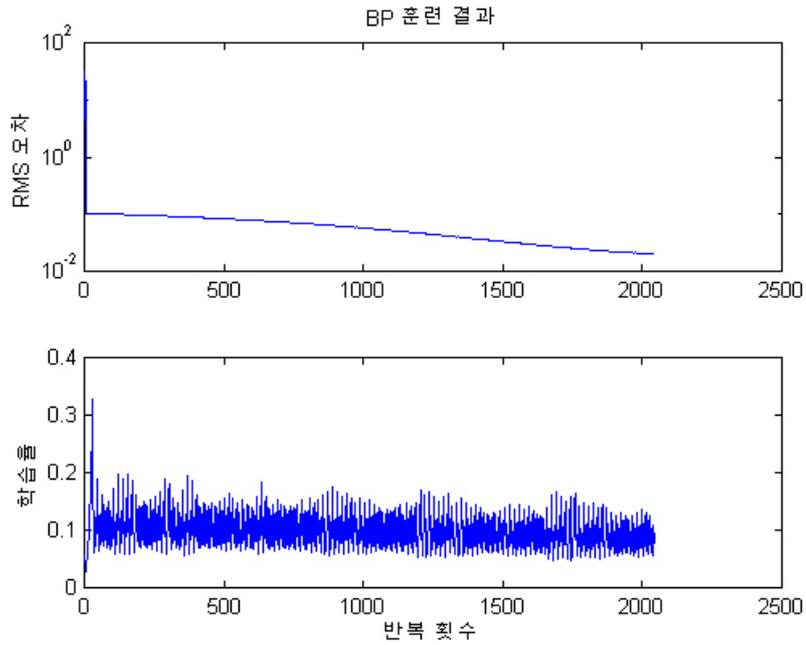


Fig. 4.3 모델1의 1996년도 신경망 학습알고리즘의 수렴결과

이러한 방법으로 2001년까지의 물동량 예측값을 구할 수가 있으며 Table 4.5는 각 연도별 종료조건을 만족하는 결과를 보여주고 있다. Fig. 4.4는 이러한 방법으로 구한 예측값과 실제값을 그래프로 보여주고 있다.

Table 4.5 모델1의 반복회수와 오차율비교

	1995	1996	1997	1998	1999	2000	2001
반복회수	2,479	2,044	51,070	2,059	1,642	2,153	8,376
오차율	0.02	0.02	0.02	0.02	0.02	0.02	0.02

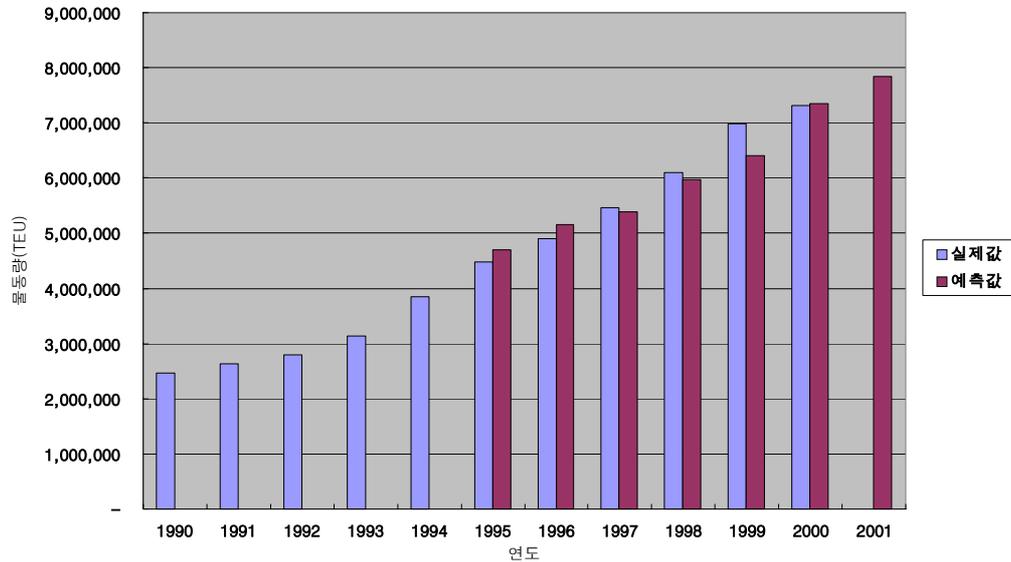


Fig. 4.4 신경망에 의한 예측물동량(입력자료=9)

4.2.2 모델 2

다음 모델은 기존의 9개의 입력자료에서 영향력분석을 하고 난 뒤에 4개의 중요한 입력변수인 수출화물량, 수입화물량, 환적화물량, 선박입항수를 이용하여 입력변수가 수정된 이후 신경망을 다시 구성하여 물동량을 예측하였다.

본 모델의 신경망 구성은 입력층과 은닉층, 출력층 각각 1개의 층으로 구성되었으며 은닉층의 수는 9개로 하였다. 은닉층의 크기는 일반적으로 정하는 방법이 없으므로 반복학습과정을 통해서 적절한 수를 정하였다. 전달함수로는 시그모이드 함수와 선형함수를 사용하였으며 학습의 종료조건으로는 오차율 0.02이하로 떨어졌을 때 종료를 하거나 반복회수 100,000번이 넘지 않는 범위에서 학습을 종료하도록 하였다.

예로서 1995년도 물동량의 예측값을 구하기 위해서 입력자료와 목표자료의 변환을 식 3.2를 사용하여 다음과 같이 변환하였다.

Table 4.6 모델2의 1995년도 자료의 변환

	1991	1992	1993	1994		1991	1992	1993	1994
수입화물	1,046,000	1,135,242	1,190,457	1,343,620		0.3067171	0.3256253	0.3373240	0.3697754
수출화물	1,348,000	1,431,793	1,530,077	1,597,031		0.3707034	0.3884570	0.4092809	0.4234668
환적화물	75,000	70,344	77,967	191,060		0.1009865	0.1	0.1016151	0.1255767
선박입항수	358,455	409,737	452,096	491,282		0.1610435	0.1719089	0.1808837	0.1891862
목표값	2,637,379	2,798,501	3,131,711	3,846,155		0.6438906	0.6780283	0.7486272	0.9

학습이 끝난 결과 총 6,247회의 반복으로 오차율 0.02에 도달하여 종료하였다. Fig 4.5는 학습을 하는 과정중의 오차와 학습율을 보여주고 있다. 학습이 끝난 이후 일반화된 모델에 1995년도의 물동량을 예측하기 위해서 전년도의 입력자료를 넣어서 나온 결과값은 1.088754이며 이를 식 3.5의 역변환식으로 물동량 예측값을 구하면 4,620,871 TEU를 얻을 수 있다.

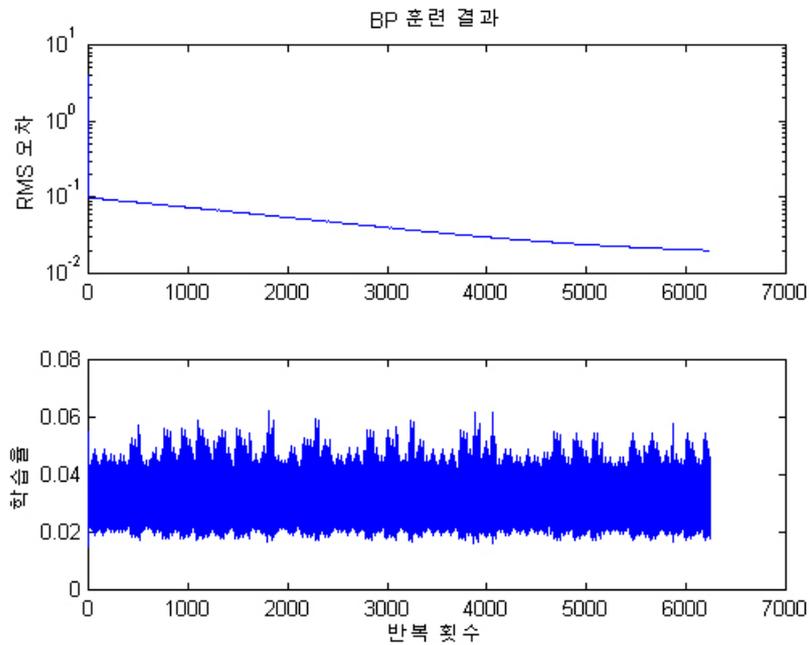


Fig. 4.5 모델2의 1995년도 신경망 학습알고리즘의 수렴결과

같은 방법으로 1996년의 물동량을 예측해 보기로 한다. 신경망의 구조는 앞에서 한 신경망 구조와 같으며 Table 4.7은 선형변환식에 의해 입력자료가 변환하는 것을 보여주고 있다.

Table 4.7 모델2의 1996년도 자료의 변환

	1991	1992	1993	1994	1995	1991	1992	1993	1994	1995
수입화물	1,046,000	1,135,242	1,190,457	1,343,620	1,653,106	0.276681	0.292841	0.302840	0.330576	0.386620
수출화물	1,348,000	1,431,793	1,530,077	1,597,031	1,797,553	0.331370	0.346543	0.364341	0.376466	0.412778
환적화물	75,000	70,344	77,967	191,060	297,004	0.100843	0.1	0.101380	0.121860	0.141046
선박입항수	358,455	409,737	452,096	491,282	552,612	0.152174	0.161460	0.169131	0.176227	0.187333
목표값	2,637,379	2,798,501	3,131,711	3,846,155	4,488,064	0.564862	0.594039	0.654380	0.783757	0.9

Fig. 4.6은 학습이 진행되는 오차와 학습율을 그래프로 나타내고 있다. 학습이 끝났을 때 반복회수가 2,856회에 오차율이 0.02로 수렴하게 되었으며 학습이 끝난 이후 새로운 입력값으로 얻어낸 결과값은 1.04092985이며 변환식에 의해 예측물동량 5,266,300 TEU라는 값을 얻어낼 수가 있다.

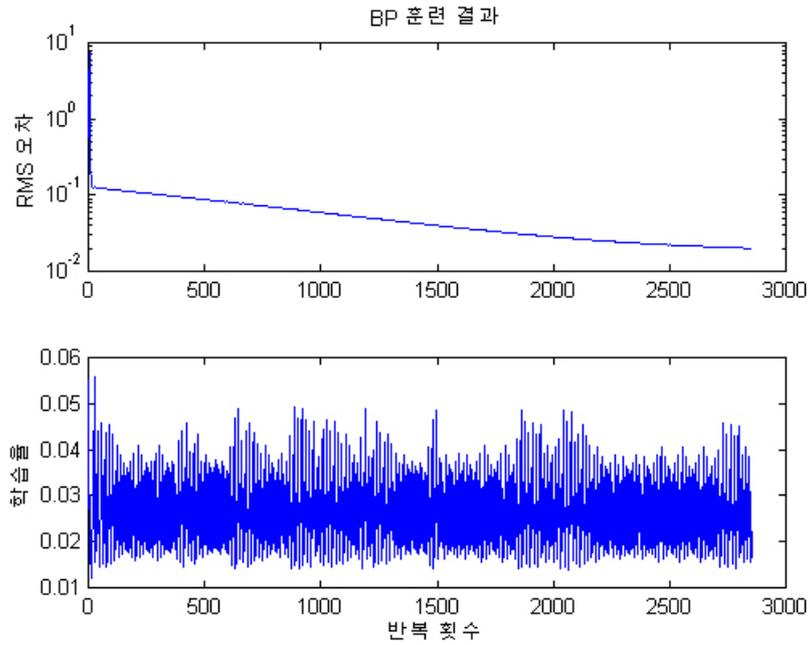


Fig. 4.6 모델2의 1996년도 신경망 학습알고리즘의 수렴결과

이러한 방법으로 2001년까지의 물동량 예측값을 구할 수가 있으며 Table 4.8 는 각 연도별 종료조건을 만족하는 결과를 보여주고 있다. Fig 4.7는 이러한 방법으로 구한 예측값과 실제값을 그래프로 보여주고 있다.

Table 4.8 모델2의 반복회수와 오차율비교

	1995	1996	1997	1998	1999	2000	2001
반복회수	6,247	2,856	91,496	47,790	888	1,001	1,407
오차율	0.02	0.02	0.02	0.02	0.02	0.02	0.02

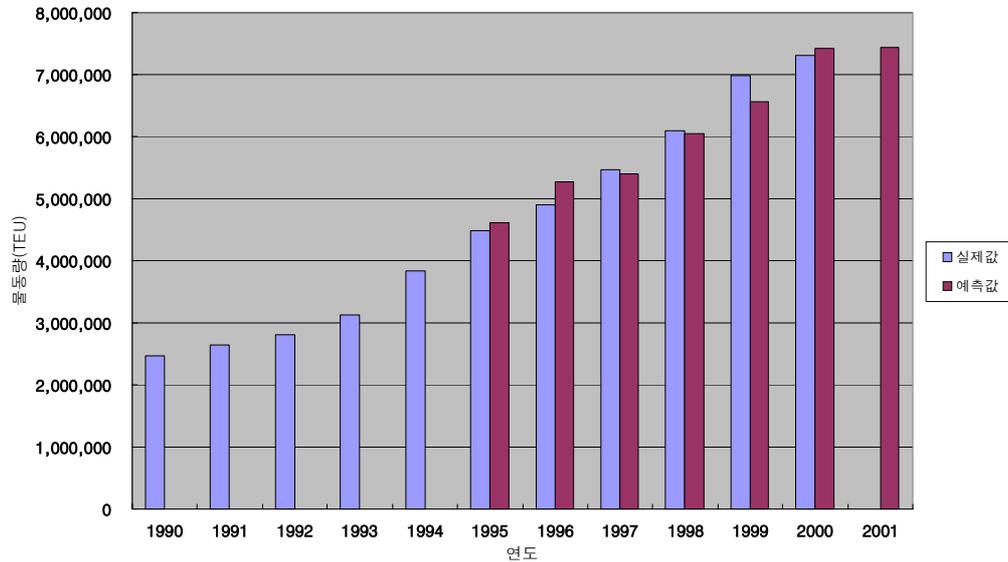


Fig. 4.7 신경망에 의한 예측물동량(입력자료=4)

4.3 일반적 예측방법과의 비교

이상에서 신경망을 이용한 방법으로 컨테이너 물동량을 예측해 보았다. 본 절에서는 일반적으로 예측에서 사용되고 있는 통계적인 방법을 이용해서 물동량을 구해보고 앞의 실험에서 구한 예측값들과 비교해 보도록 한다.

4.3.1 이동평균법을 이용한 물동량 예측

본 연구에 사용된 컨테이너 물동량 자료는 급격한 변화가 없고 일정한 추세로 증가하는 모형을 띄고 있다. 그러므로 일반적으로 많이 사용하는 이동평균법을 이용하여 예측을 하였으며 단순이동평균법과 가중이동평균법을 모두 이용하여 그 예측치들을 비교하여 보았다.

단순이동평균법은 3년단위로 데이터 값들을 평균하여 구하였다. 데이터 값들이 증가하는 추세를 띄고 있으므로 가중이동평균에서는 가장 가까운 연도의 데

이터값에 더 많은 비중을 두기 위해서 예측 연도에 가장 가까운 값부터 0.7, 0.2, 0.1의 가중치를 차례로 대입하여 계산을 하였다. Table 4.9는 단순이동평균법과 가중이동평균법을 이용한 컨테이너 물동량의 예측을 보여주고 있다.

Table 4.9 이동평균법을 이용한 물동량 예측

	실제값	단순이동평균법		가중이동평균법	
		예측값	오차	예측값	오차
1990	2,469,000	-	-	-	-
1991	2,637,379	-	-	-	-
1992	2,798,501	-	-	-	-
1993	3,131,711	2,634,960	496,751	2,733,327	398,385
1994	3,846,155	2,855,864	990,291	3,015,636	830,519
1995	4,488,064	3,258,789	1,229,275	3,598,501	889,563
1996	4,898,297	3,821,977	1,076,320	4,224,047	674,250
1997	5,469,160	4,410,839	1,058,321	4,711,036	758,124
1998	6,102,404	4,951,840	1,150,564	5,256,878	845,526
1999	6,978,356	5,489,954	1,488,402	5,855,345	1,123,012
2000	7,313,149	6,183,307	1,129,842	6,652,246	660,903
2001		6,797,970		7,125,116	

표에서 보듯이 일정하게 증가하는 데이터의 값에 가중치를 두어서 이동평균하는 방법이 더욱 좋은 값을 가지게 되었다. 아래에서 가중이동평균법과 신경망을 이용한 방법과의 비교를 해 보도록 한다.

4.3.2 지수평활법을 이용한 물동량 예측

과거의 데이터값으로 미래의 값을 예측할 때 최근의 자료에 많은 가중값을 부여하는 면에서는 가중이동평균법과 유사하지만 최근의 자료에 더 많은 비중을 두고 있으며 계산 시에 2개의 데이터 값만으로도 예측이 가능하다는 장점이 있다. 본 연구에서는 단순지수평활법을 이용한 예측과 더불어 데이터 값이 일정한 추세를 띄고 있으므로 이중지수평활법을 이용한 예측도 하였다.

지수평활법의 지수평활계수인 α 값을 구하는 것은 매우 중요한 문제이다. 단순

지수평활법의 α 값은 평균제곱오차(MSE : mean squared error)가 가장 작은 값을 선택하였다. Table 4.10은 단순지수평활법에 의한 예측을 보여주고 있으며 α 값은 가장 좋은 값을 나타내고 있는 0.8과 0.9, 0.95를 이용한 방법을 보여주고 있다. 지수평활계수인 α 는 표에서 보듯이 α 값이 0.95가 되었을 때 가장 좋은 값을 나타내고 있으며 이 때의 MSE 값은 284,437,208,189로 가장 적은 값을 가지게 되었다.

Table 4.10 단순지수평활법을 이용한 물동량 예측

	실제값	$\alpha = 0.8$		$\alpha = 0.9$		$\alpha = 0.95$	
		예측값	오차	예측값	오차	예측값	오차
1990	2,469,000	2,469,000	-	2,469,000	-	2,469,000	-
1991	2,637,379	2,469,000	168,379	2,469,000	168,379	2,469,000	168,379
1992	2,798,501	2,612,122	186,379	2,620,541	177,960	2,628,960	169,541
1993	3,131,711	2,770,544	361,167	2,780,705	351,006	2,790,024	341,687
1994	3,846,155	3,077,536	768,619	3,096,610	749,545	3,114,627	731,528
1995	4,488,064	3,730,862	757,202	3,771,201	716,863	3,809,579	678,485
1996	4,898,297	4,374,484	523,813	4,416,378	481,919	4,454,140	444,157
1997	5,469,160	4,819,725	649,435	4,850,105	619,055	4,876,089	593,071
1998	6,102,404	5,371,745	730,659	5,417,255	695,149	5,439,506	662,898
1999	6,978,356	5,992,805	985,551	6,032,889	945,467	6,069,259	909,097
2000	7,313,149	6,830,523	482,626	6,883,809	429,340	6,932,901	380,248
2001		7,240,755		7,270,215		6,932,901	

추세가 있는 경우에 이를 이용하는 이중지수평활법에는 브라운법과 홀트법이 있는데 본 연구에서는 홀트법을 이용하였으며 아래에 보는 식과 같다.

$$F'_t = F_t + T_t$$

$$F_t = \alpha D_{t-1} + (1-\alpha)F_{t-1}$$

$$T_t = \beta(F_t - F_{t-1}) + (1-\beta)T_{t-1}$$

F'_t 는 t 기의 예측치를 나타내며 단순지수평활법에 그 추세가 더해지는 형태를 나타내고 있다. α 와 β 값은 0~1사이의 값으로 하는 것이 일반적이며 여기서

는 0.95값을 적용하였다. 표는 이중지수평활법을 이용한 예측을 나타내고 있다.

Table 4.11 이중지수평활법을 이용한 물동량 예측

	실제값	이중지수평활법			
		Ft	Tt	F't	오차
1990	2,469,000	2,469,000	2,469,000		
1991	2,637,379	2,469,000	123,450	2,592,450	44929
1992	2,798,501	2,628,960	158,135	2,787,095	11406
1993	3,131,711	2,790,024	160,917	2,950,941	180770
1994	3,846,155	3,114,627	316,418	3,431,045	415110
1995	4,488,064	3,809,579	676,025	4,485,604	2460
1996	4,898,297	4,454,140	646,134	5,100,274	201977
1997	5,469,160	4,876,089	433,159	5,309,248	159912
1998	6,102,404	5,439,506	556,904	5,996,411	105993
1999	6,978,356	6,069,259	626,110	6,695,369	282987
2000	7,313,149	6,932,901	851,765	7,784,667	471518
2001		7,294,137	385,762	7,679,899	

지수평활법을 이용한 예측에 있어서 추세조정을 이용한 이중지수평활법이 훨씬 더 좋은 값을 가지고 있으므로 신경망을 이용한 예측과 비교하기로 한다.

4.3.3 추세분석법을 이용한 물동량 예측

시계열적인 모형의 자료에서 일정한 수준으로 증가를 하는 추세를 보이고 있으므로 선형추세모형을 적용하는 것이 적합할 것이다. 이것은 일반적으로 이용되고 있는 단순회귀분석과 같으며 독립변수를 시간으로 하고 종속변수를 총물동량으로 해서 회귀식을 만드는 것이다. 각 연도별로 그 이전의 자료들을 이용하여 선형회귀식을 도출해 내었으며 이를 이용하여 각각의 물동량 예측치값들을 구해 낼수 있었다.

Table 4.12는 추세분석을 이용한 물동량 예측을 나타내고 있다.

Table 4.12 추세분석법을 이용한 물동량 예측

	실제값	예측값	오차
1990	2,469,000	-	-
1991	2,637,379	-	-
1992	2,798,501	-	-
1993	3,131,711	2,964,461	167,250
1994	3,846,155	3,296,462	549,694
1995	4,488,064	3,951,142	536,922
1996	4,898,297	4,633,954	264,343
1997	5,469,160	5,186,575	282,585
1998	6,102,404	5,757,757	344,647
1999	6,978,356	6,364,372	613,984
2000	7,313,149	7,086,381	226,768
2001		7,678,747	

4.3.4 예측방법의 비교

신경망을 이용한 예측방법과 일반적인 예측방법과의 비교를 통하여 예측방법의 우수함을 나타내고 있다. 신경망을 이용한 방법으로는 입력벡터분석이전의 모델 1과 입력벡터분석이후의 모델 2를 서로 비교하였으며 일반적인 예측방법으로는 이동평균법중에서 우수한 값을 나타내었던 가중이동평균법을 비교하였다. 또한 지수평활법에서는 추세를 조정해서 나타낼 수 있는 이중이동평균법을 비교하였고 추세분석법에서 예측한 모형도 함께 비교하였다.

아래의 그림은 이러한 여러 예측방법을 이용한 예측을 그래프로 나타내고 있다.

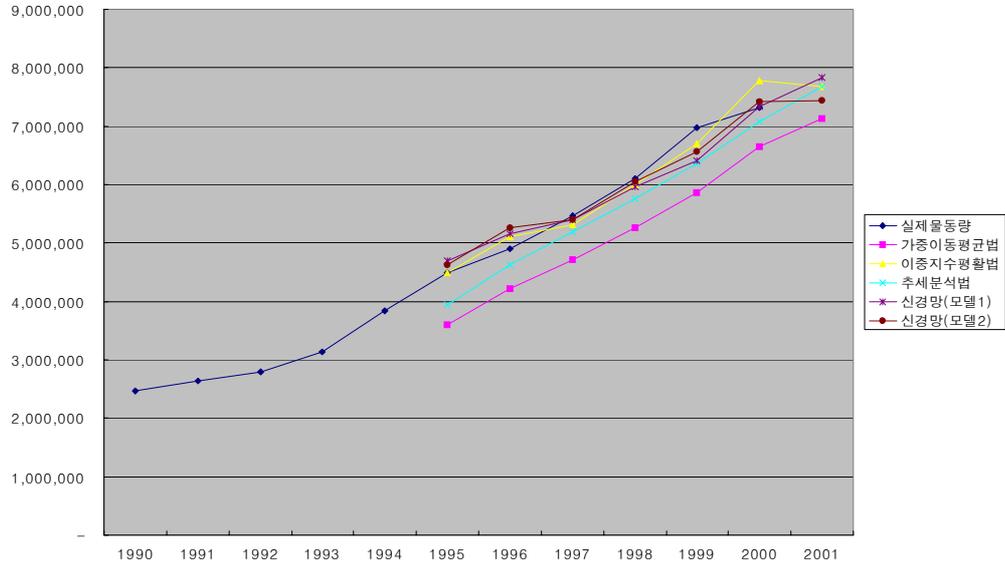


Fig. 4.8 예측방법에 따른 컨테이너 물동량 예측비교

예측한 모형의 정확도를 알아보기 위해서 절대평균오차 (MAD : Mean Absolute Deviation)를 이용하여 비교하였으며 신경망의 학습이 이루어진 이후에 1995년도부터 2000년도의 예측치값들을 서로 비교하였다. Table 4.13은 비교 데이터의 값을 나타내고 있다.

Table 4.13 예측방법의 비교

		1995	1996	1997	1998	1999	2000	MAD
실제 물동량		4,488,064	4,898,297	5,469,160	6,102,404	6,978,356	7,313,149	
가중이동평균법	예측치	3,598,501	4,224,047	4,711,036	5,256,878	5,855,345	6,652,246	
	오차	889,563	674,250	758,124	845,526	1,123,012	660,903	825,230
이증지수평활법	예측치	4,485,604	5,100,274	5,309,248	5,996,411	6,695,369	7,784,667	
	오차	2,460	201,977	159,912	105,993	282,987	471,518	204,141
추세분석법	예측치	3,951,142	4,633,954	5,186,575	5,757,757	6,364,372	7,086,381	
	오차	536,922	264,343	282,585	344,647	613,984	226,768	378,208
신경망(모델1)	예측치	4,702,974	5,161,433	5,396,772	5,967,049	6,412,310	7,345,428	
	오차	214,910	263,136	72,388	135,355	566,046	32,279	214,019
신경망(모델2)	예측치	4,620,871	5,266,300	5,407,401	6,055,954	6,563,686	7,425,503	
	오차	132,807	368,003	61,759	46,450	414,670	112,354	189,340

위의 표에서 보듯이 절대평균오차값을 살펴보면 신경망을 이용한 예측 모델2가 189,340으로 실제값과 가장 가까운 예측값을 구하는 것을 알 수 있다. 다음으로 이중지수평활법을 이용한 예측이 204,141의 값으로 매우 우수한 예측을 하고 있다. 신경망 모델 1은 214,019 추세분석법은 378,208 가중이동평균법은 825,230의 값으로 나타나고 있다. 신경망을 이용한 예측방법 뿐만 아니라 선형적인 데이터의 추세조정을 이용한 예측방법인 이중지수평활법을 이용한 예측도 매우 근사한 값을 나타내고 있다.

5. 결론

세계무역경제가 더욱 활성화되고 있는 시점에서 무역의 중심이 되고 있는 컨테이너항만의 중요성은 당연시되고 있다. 이러한 가운데 항만의 물동량 예측은 항만의 개발과 계획수립에 있어서 매우 중요한 정보인 것이다. 본 연구는 이를 인지하고 과거의 통계적인 방법의 예측이 아닌 신경망 모델을 이용하여 컨테이너항만의 물동량을 예측해 본다.

본 논문의 연구방법은 다층신경망을 이용하여 예측모형을 설계하였으며 신경망을 이용한 입력변수의 영향력벡터분석과 컨테이너 물동량 예측을 하였다. 신경망에서 목표값으로 항만의 컨테이너 총물동량을 이용하였고 초기의 입력값으로 항만의 물동량과 관련이 있는 변수인 수입화물량, 수출화물량, 연안화물량, 환적화물량, 선박입항수, 선박출항수, 항만하역능력, 경제활동인구수, 1인당 국민총소득을 이용하였다. 역전과 학습알고리즘을 이용하여 반복학습 시킴으로써 과거의 자료에 대한 충분한 지식과 경험을 바탕으로 미래의 물동량을 예측하는 방법으로 연구를 하였으며 중요도가 높은 변수를 선별하기 위하여 신경망을 이용하여 입력변수들의 영향력벡터분석을 하였다. 또한 신경망을 이용한 예측모형의 타당성을 검증하기 위해서 같은 자료를 이용하여 일반적으로 예측에 이용되는 통계적인 예측방법으로 컨테이너항만의 물동량 예측을 하였으며 이러한 결과들을 각각 비교 분석하였다.

본 논문의 결과로 입력벡터분석에서 중요도가 높은 변수로서 수입화물량, 수출화물량, 환적화물량, 선박입항수가 선별되었다. 신경망을 이용한 물동량 예측에서 모델1은 초기의 9개의 입력변수를 이용하여 물동량 예측을 하였고 모델2는 입력벡터분석 후 중요도가 높은 변수를 이용하여 다시 개선된 물동량 예측을 하였다. 일반적으로 예측에 사용되는 통계적인 모형과 비교하기 위해서 같은 데이터를 이용해서 컨테이너 물동량 예측치를 구했으며 절대치평균오차로 그 비교를 하였다. 일반적인 예측방법으로는 가중이동평균법, 이중지수평활법, 추세분석법을 신경망과 비교하였으며 선형적인 추세를 보이는 데이터의 결과로 신경망모델과 이중지수평활법이 우수한 것으로 나타나고 있다. 절대치평균오차값은 신경망

모델1이 214,019, 신경망 모델2는 189,340, 이중지수평활모형이 204,141, 추세분석법은 378,208, 가중이동평균법은 825,230을 각각 나타내었다.

본 논문의 추후과제로는 더 좋은 예측모형의 구현을 위해서 신경망의 입력변수 선정에 있어서 컨테이너 물동량에 밀접한 관련 있는 변수의 선정이 필요하다. 입력변수의 영향벡터분석으로 더 좋은 입력자료를 선별하기는 하지만 초기에 입력변수의 선정은 전문가의 지식이나 기존의 데이터를 바탕으로 한 데이터의 선정이 필요하다고 할 수 있겠다. 또한 신경망을 이용한 물동량 예측방법의 신뢰성을 검증할 필요가 있다. 본 논문에서 비교한 일반적인 예측방법 뿐만 아니라 다른 많은 예측방법들을 이용한 검증이 이루어져야 할 것이다.

참 고 문 헌

- 1) 서혜숙, 제2형 당뇨병의 예측과 위험인자분석을 위한 신경망과 로지스틱 회귀 모델의 비교연구, 서울대학교 대학원 석사논문, 2000.
- 2) 강상규, 인공신경망 모형을 이용한 우리나라 증권시장에서의 주가의 비선형적 규칙성에 관한 연구, 서울대학교 대학원 석사논문, 1997.
- 3) 김다윗, 신경망 분리모형과 사례기반추론을 이용한 기업 신용평가, 한국과학기술원 석사논문, 1996.
- 4) 정현, Data Mining 기법을 이용한 인공 신경망 입력변수 선정에 관한 연구, 서울대학교 대학원, 1999.
- 5) 유병태, 서울대학교 대학원 석사논문, 신경망을 적용한 공통 원인 고장 영향 벡터 평가에 관한 연구, 1995.
- 6) 오남선, 神經網理論과 Kalman Filter 降雨豫測模型의 比較研究, 서울대학교 대학원 박사논문, 1996.
- 7) 구자윤, 퍼지 신경회로망을 이용한 선박 접이안 제어, 한국해양대학교 대학원 박사논문, 1995.
- 8) 구자윤, 이철영, 선박 접이안의 퍼지학습제어, 한국항해학회지, 18-2, 1994.
- 9) 강구철, 유전자 알고리즘을 이용한 인공신경망 입력변수 선정에 관한 연구 : 신용평가에의 적용, 동국대학교 대학원 석사논문, 1997.
- 10) 신성석, 신경 회로망의 함수 사상 특성에 관한 연구, 서울대학교 대학원 석사논문, 1990.
- 11) James A. Freeman, David M. Skapura, "Neural Networks : Algorithms, Applications, and Programming Techniques", Addison-Wesley Publishing Co., 1991.
- 12) S. Haykin, Neural Networks : Macmillan, 1994.
- 13) Matthew Z. Neural Networks in Artificial Intelligence. Ellis Horwood Ltd, 1990.

- 14) 김대수, 신경망 이론과 응용(I)(II), 1992.
- 15) 이철영, 항만물류시스템, 효성출판사, 1997.
- 16) 이현엽, 문경일, MATLAB을 이용한 퍼지-뉴로, 아진출판사 1999.
- 17) 이상배, 퍼지-뉴로제어 시스템, 교학사, 1999.
- 18) 조용준, 허준, 최인규, Neural Connection을 이용한 데이터마이닝 신경망분석, SPSS 아카데미, 1999.
- 19) 해운항만백서, 해운항만청, 1996.
- 20) 해운항만통계연보, 해운항만청, 각연호.

감사의 글

활시위를 당겼다가 놓은 것처럼 그렇게 저의 대학원 2년이 지나갔습니다. 되돌아보면 많은 아쉬움과 보람이 남습니다. 지금까지 보낸 대학원 생활이 앞으로의 사회생활에서 큰 힘이 될 것입니다. 대학원 2년의 작은 결실로 남게 된 저의 논문에 도움을 주신 많은 분들께 감사의 마음을 전합니다.

먼저, 대학원 석사과정을 무사히 마칠 수 있도록 이끌어 주신 이철영 지도교수님의 은혜에 진심으로 감사드립니다. 아울러 논문 심사과정에서 많은 지도와 충고를 아낌없이 해주신 신재영 교수님과 김환성 교수님께도 깊은 감사를 드립니다. 그리고, 항상 뜨거운 교육열의로 물류시스템공학과를 이끄시는 학과 교수님들께도 감사의 마음을 전하며 항상 건강하시기를 바랍니다.

또한 저의 논문에 많은 관심과 조언을 아끼지 않은 물류체계실험실의 선배님들과 후배들에게도 감사의 마음을 전합니다. 대학원 내에 많은 선배님들과 후배들 그리고 저를 많이 생각해 주고 아껴주는 93학번 동기들에게도 고마운 마음을 전합니다.

마지막으로, 어려운 가정에서도 항상 믿음으로 저를 지켜봐 주신 부모님께 깊은 감사를 드립니다.