

경영정보학연구
제11권 제4호
2001년 12월

자기조직 신경망을 이용한 인지 및 감성 특성의 직관적 시계열 예측과의 상관성 조사*

유현중**, 박홍국***, 송병호****

Investigating the Correlation between Cognition and
Emotion Characteristics and Judgmental Time-Series Forecasting
Using a Self-Organizing Neural Network

Yoo, Hyeon-Joong, Park, Hung Kook, Song, Byoungho

Though people frequently rely on intuition in managing activities, they rarely use it in developing effective decision-making support systems. In this report, we investigate the correlations between characteristics of cognition and emotion and judgmental time-series forecasting accuracy, and compare their strengths by using a self-supervised adaptive neural network. Through the experiments, we hope to help find a desirable atmosphere for decision-making. Our experiments showed that both cognition characteristics and emotion characteristics had correlations with the time-series forecasting accuracy, and that cognition characteristics had larger correlation than emotion characteristics. We also found that conceptual style had larger correlation than behavioral or analytical styles with the accuracy.

* 이 논문은 2001년도 상명대학교 연구비에 의하여 연구되었음.

** 상명대학교 컴퓨터및정보통신학부

*** 상명대학교 소프트웨어학부

**** 상명대학교 소프트웨어학과

I. 서 론

시계열 직관 예측(judgemental time series forecasting)은 일상 생활에서 쉽게 대하는 문제이다. 기온은 아주 좋은 예가 될 수 있는데, 현재 기온은 과거 기온의 시계열 데이터를 기초로 예측을 할 수 있다. 이와 같이 인과 관계가 아닌 동일 시계열 내에서 과거 데이터를 기초로 미래 사건을 예측하는 것을 시계열 직관 예측이라고 한다. 주가, 유가, 판매량, 외환, 컴퓨터 사용자수, 인구 등 시계열 예측이 적용될 수 있는 사례는 매우 많다. 개인 또는 기업에서는 보다 정확한 예측을 위하여 통계 예측 기법을 사용하기도 하지만, 이러한 통계 예측에 비하여 직관 예측의 정확성이 떨어지지 않는다고 한다. 또한 직관 예측이 널리 사용되고 있는 이유는 통계 예측을 사용할 수 없는 상황에서 손쉽게 사용할 수 있다는 점이다. 외환 딜러는 매우 빠르게 직관적으로 예측을 해야 하는 상황에 있는 경우가 많다. 직관적인 판단에 의해 많은 금액을 거래하는 경우에는 적은 직관적 오류가 대단히 큰 손실을 초래할 수 있다. 이와 같이 시계열은 일상생활에서 쉽게 발생하며, 우리는 직관에 의해 예측을 하는 경우가 많지만, 동시에 많은 잠재적 오류를 내포하고 있기도 한다. 그럼에도 불구하고, 시계열 직관 예측에 관한 연구는 다른 연구에 비해 많지 않은 편이다.

본 연구에서는 사람의 인지 및 감성 유형에 따라 시계열 예측의 정확성에 차이가 있는지 고찰하기로 한다. 즉 동일한 시계열을 처리하는 방법이 분석적인 사람과 직관적인 사람 간에 다를 것이며, 이러한 차이가 시계열 예측의 정확성에 반영될 것이라는 점에 착안하여 연구를 수행하였다.

경영활동에 있어서 직관력은 잘 알려진 인지능력이지만 효과적인 의사결정지원시스템의

개발 목적으로는 거의 고려되고 있지 않다[Hoch, 1996]. 본 연구는 의사결정자의 특성에 따른 시계열 예측의 정확성을 인공신경망에 의해 비교 분석하여 시계열 직관 예측에 영향을 주는 의사결정자의 인지적 및 감성적 특성을 도출함으로써 효과적인 의사결정환경을 조성하는데 공헌하고자 한다.

II. 이론적 배경

2.1 의사결정과 인지유형

의사결정전략과정에서 의사결정자를 지원해야 할 필요성과 인지적 요건에 대한 연구는 Singh [1998]에 의하여 수행되었으며 의사결정지원기술과 인지적 지원도구의 지원이 의사결정의 효율성과 효과성을 증진시킴을 확인시켜주었다.

Kuo[1998]는 직관과 인지에 관한 연구조사를 통하여 최고경영층은 의사결정시에 수동적인 자세를 취하지 않고 문제 해결을 위해 감각에 의존하는 적극적인 자세를 보인다고 밝히고 있다. 문제 해결에 필요한 지식은 경영자의 마음속과 주변 세계에 분산되어 있으므로 동태적이고 비정형적인 문제상황을 처리하기에는 경영자의 직관이 효과적일 수 있다는 것이다. 또한 대부분의 기업들이 경영활동상의 주요 예측 도구로서 직관적 예측을 사용하고 있으며, 직관적 예측이 통계적보다 효율적이며 실증적 실험에서 입증되고 있다[임좌상, 1999].

Ruble and Cosier[1990]는 162명의 경영학 전공 학생들을 대상으로 인지유형이 의사결정성과에 미치는 영향을 연구하였다. Davis, Grove and Knowles[1990]는 96명의 대학원 학생들을 대상으로 한 실험에서 피실험자의 성격을 4개의 의사결정유형(decision-making style)으로 분류하여 의사결정태스크를 컴퓨터 모의 경영환경에서 수행하게 한 결과, 네 개 유형에 따라 비

용성과가 유의한 차이가 있음이 발견되었다.

또한 직관적 의사결정은 불확실성이 높거나, 과거 데이터나 경험이 없거나, 여러 변수들이 과학적으로 예측하기가 어렵거나, 시간에 제약이 있거나, 대안들이 여러 개 있을 때 주로 사용하는 것으로 밝혀졌다[Agor, 1986].

2.2 의사결정과 감성상태

감성과 감성은 서로 다른 뜻이며, 감성 또한 여러 의미로 사용될 수 있지만, 본 연구는 이를 구분하지 않고 의사결정분야에 한정하여 관련 이론을 고찰하였다. 감성은 심리학 분야를 중심으로 활발히 연구되고 있지만, 통제가 쉽지 않다는 점에서 의사결정분야에서는 그 중요성에 비해 연구가 많지 않은 편이다. 뿐만 아니라, 감성은 지속성, 강도, 통제과정에 영향을 미치는 다른 변수 등으로 인해 인위적 환경에서 통제의 어려움이 가중되고 있다. 특히 인위적으로 유발되는 감성상태는 우리가 일상생활에서 경험하는 감성상태보다 강도가 적은 경우가 보통이며, 짧은 시간에 유발되면서 또한 짧은 시간에 사라진다는 점에서 감성을 대상으로 한 연구의 어려움이 있다.

부정감성이 의사결정에 미치는 영향은 문제처리관점과 문제해결전략관점으로 나누어 해석할 수 있다고 한다. 문제처리관점에 대한 실증 연구에서는 사람들은 부정감성상태에서 의사결정을 할 경우 자신의 모든 능력을 문제해결에 집중하지 못한다고 한다. 부정감성상태에서는 자신의 감성을 긍정적인 상태로 전환하기 위한 노력도 병행하며 문제해결에는 잔여 능력이 활용되며, 그로 인해 작업성과가 저하되는 결과를 초래할 수 있다는 것이다. 문제해결전략관점에 따르면, 긍정감성상태에서 사람들은 문제를 단순하게 해결하는 경향이 있는 반면, 부정감성상태에서는 문제를 자세히 분석하고, 체계적이고 분석적으로 접근하는 경향이

있다고 한다.

앞서의 연구가 감성상태와 의사결정성과의 관계를 단정적으로 제시하고 있지 못하다는 점과 감성의 효과에 대한 연구가 많지 않은 실정이어서 이들의 상관관계를 지금까지 한번도 시도하지 않았던 자기조직 신경망 방법론으로 밝혀 보고자 한다.

2.3 자기감독적용 신경망(Self-Supervised Adaptive Neural Network)

Kohonen의 자기조직특징매핑(Self-Organized Feature Mapping, SOFM)으로 대표되는 자기조직 신경망들은 비감독 알고리즘에 의해 학습된다[Kohonen, 1996; Kohonen, 1988]. 자기조직 층의 뉴런들은 학습을 통해 이웃한 뉴런들끼리 비슷한 가중 벡터를 갖게 되기 때문에, 학습 후, 비슷한 패턴 유형의 입력 벡터들에 대해 특정 위치에 이웃한 뉴런들이 다른 위치의 뉴런들에 비해 강한 반응을 보이게 된다.

1990년 경, 영국의 Luttrell은 학습 시 자기조직 층에 있는 뉴런 클러스터들 간에 서로의 학습 상태에 대한 정보를 교환하므로써, 입력 벡터 쌍들 간의 상관성을 이용할 수 있는 다중 뉴런 클러스터 SOFM 알고리즘을 개발했다[Luttrell, 1992]. Luttrell은 이 알고리즘을 자기감독적용 알고리즘(Self-Supervised Adaptive Algorithm)이라고 이름 붙였다.

자기감독적용 알고리즘에 의해 학습된 신경망은, 입력되는 벡터 쌍에 대해 각 클러스터의 뉴런들이 쌍을 이뤄 반응하게 된다. 즉, 서로 다른 클러스터에 있는 특정 뉴런 쌍들은 특정 패턴 유형의 입력 벡터 쌍들에 대해서 강하게 반응하게 된다. 이러한 분리된 클러스터에 있는 뉴런들 간의 배타적인 짹짓기는 입력 벡터 쌍들 간에 상관성이 존재할 때 일어나며, 상관성이 없으면 비규칙적 짹짓기가 일어난다. 따라서, 학습 후, 자기감독적용 층의 클러스터들에

있는 뉴런들의 Joint Winning Probability Density Function 또는 Joint Winning Frequency의 분포를 확인하면 입력 벡터들 간의 상관성 정도를 판단할 수 있게 된다.

자기감독적용 신경망에 의한 수학적 모델을 사용한 이전의 실험들[유현중, 1998; Luttrell, 1992]에서 뉴런 클러스터들의 입력 벡터 쌍 간에 상관성이 있는 경우 기준의 자기조직 알고리즘들에 비해 벡터 양자기의 오차가 작았으며, 그 항상 정도는 두 입력 벡터들 간의 상관성과 식 (가)의 이웃 함수의 비대칭성(또는 기울기)의 함수임을 확인할 수 있었다.

$$\begin{aligned} P(y_k' | y_1, y_2) &\approx \\ P_o(y_1, y_2) &\left(1 + \frac{y_k' - y_k}{\rho_{y_1, y_2}} \frac{\partial \rho(y_1, y_2)}{\partial y_k} \right) \\ &\exp(-\pi \rho(y_1, y_2)(y_k' - y_k)^2) \\ \text{for } k &= 1, 2 \end{aligned} \quad (\text{가})$$

본 연구에서는 자기감독적용 알고리즘의 이러한 특성을 이용하여 시계열 예측 정확도에 대한 의사결정 파라미터들의 상관성 유무를 판단하고 그들의 상관도를 비교 분석하고자 한다.

III. 실험

3.1 입력 패턴 생성

실험에서는 정보통신학과 학부 3, 4학년과 정보통신대학원 학생 48명을 피험자로 하였으며, 피험자는 학부에서 의사결정 관련 과목을 사전에 수강한 학생이며 또한 피험자들은 신체적으로 건강해서 생체 신호 측정에 장애가 되는 문제가 없는 학생으로 하였다. 실험에 사용된 단일 변수는 Rowe[1994]의 의사결정에 관련된 인지 유형으로 분석적(Aalytic), 행동적(Behavioral), 개념적(Conceptual), 직접적(Direc-

tive)인 4가지 조건으로 나누어져 피험자가 분류되었다.

실험 과제는 시계열 예측 문제였다. 시계열 데이터는 M-Competition[Makridakis]에서 추출된 데이터를 사용하였다. 시계열 데이터는 PC 월별 판매 대수라고 피험자에게 알려 주고 피험자는 PC 판매 과장이라고 가정하면서 실험 과제를 수행하였다. 제공된 데이터는 40개로서 3년 4개월의 월별 판매량이며, 피험자는 그로부터 8개월의 판매량을 예측하도록 하였다. 본 연구에서는 시계열 이외의 인과 정보는 제공을 하지 않았다.

실험은 생체신호의 측정을 위하여 피험자 개인별로 실험을 수행하였다. 개인별 실험으로 인한 실험 조건의 차이는 최소화하도록 동일한 연구자가 진행하였으며, 실험 설명도 표준화하였다. 피험자의 인지유형을 판별하기 위해서 Rowe[1994]의 Decision Style Inventory를 사용하였다.

의사결정의 질은 의사결정의 정확성이며 실험 과제 내용상 예측의 정확성으로 측정된다. 입력 패턴 생성을 위한 구체적 실험절차는 다음과 같았다.

- ① 피험자가 실험실에 입장하면 실험 설명을 읽도록 한다.
- ② 연구자는 실험에 관하여 요약 설명을 한다.
- ③ 실험 과제에 앞서 주관 감성을 측정한다. 주관 감성의 사전 측정은 실험 이전에 발생한 피험자 감성의 차이로 인해 실험 통제의 효과를 왜곡되는 것을 방지하기 위한 절차이다.
- ④ 측정된 주관 감성 설문지를 회수하고 뇌파 측정을 위하여 준비를 하고 전극을 부착한다.
- ⑤ 실험 과제가 종료하고, 설문조사를 실시하여 주관 감성을 측정한다. 곧 이어, 본 연구

의 독립 변수인 인지유형을 측정한다.

3.1.1 변수의 설정

a. 독립 변수

인지유형(A, B, C, D)과 주관 감성이 독립 변수이며 인지유형은 Rowe[1994]의 의사결정 유형판별설문을 이용하여 판별하였다. 감성의 차원은 일차원적 개념이 아니라 다차원적 개념이다[Russel, 1989]. 화남, 짜증, 분노, 스트레스, 행복, 슬픔 등 다양하다. 본 연구에서는 쾌-불쾌, 각성-이완의 이차원으로 감성을 분류하였다. 기존의 연구[Russel, 1989]에 의해 2차원으로 분류된 감성을 나타내는 형용사 어휘를 사용하여 Likert 5점 평가척도에 의한 설문을 작성하였으며, 주관감성은 피험자의 감성을 이 설문으로 감성상태를 불쾌각성(i), 불쾌이완(ii), 쾌활각성(iii), 쾌활이완(iv)으로 분류하였다.

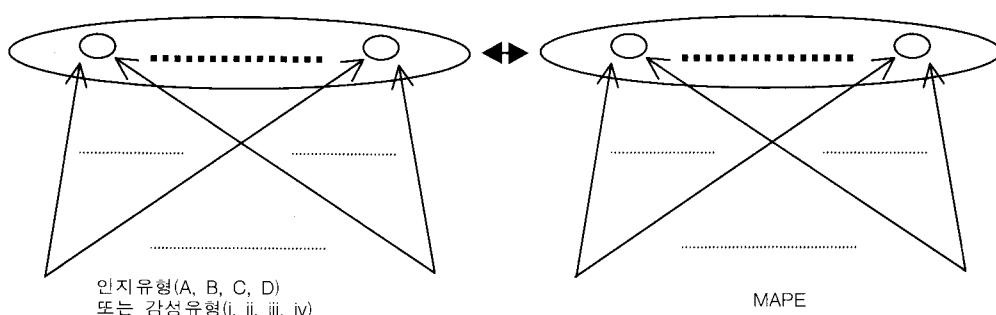
b. 종속 변수

정확성(Accuracy)을 종속변수로 설정했다. 시계열 예측의 정확성은 MAPE(Mean Absolute Percentage Error)를 통하여 측정하였다. MAPE는 시계열 예측에서 보편적으로 사용되는 도구이며, 예측과 실제 값과의 거리의 제곱을 백분율로 표시한다.

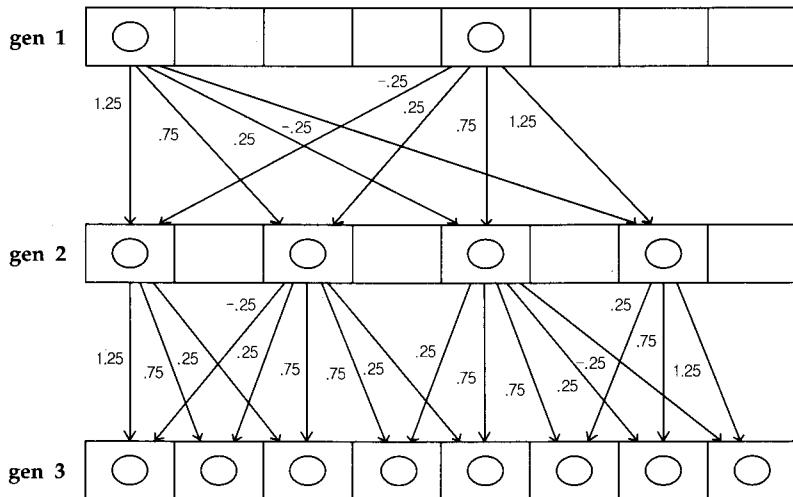
3.2 상관성 분석을 위한 자기감독적용 신경망의 구조

이 실험에서 사용한 자기감독적용 신경망은 <그림 1>에서와 같이 자기감독적용층에 두 개의 뉴런 클러스터를 갖는다. 첫째 클러스터에는 시계열 예측 실험 대상자의 인지유형(A, B, C, D) 또는 감성유형(i, ii, iii, iv)을 입력하고 둘째 클러스터에는 시계열 예측 실험으로부터 측정한 MAPE를 입력한다. 첫째 클러스터의 입력 벡터 구성 요소인 네 개의 인지유형 또는 감성유형은 해당 요소는 0.9가, 나머지 요소들은 0.1 이 할당된다. 예를 들면, 실험 대상자의 인지 유형이 'B' 또는 감성유형이 'ii'라면 <그림 1>의 왼쪽 클러스터에는 $[.1 .9 .1 .1]^T$ 가 입력된다. 오른쪽 뉴런 클러스터에는 MAPE 가 4개의 입력 노드에 동일하게 입력된다.

각 뉴런 클러스터의 뉴런 수는 <그림 2>에서와 같이, 초기에 2개에서 시작하여 학습이 진행되면서 4개 또는 8개로 증가된다. Luttrell은 각 뉴런 수에 대한 기간을 세대(generation)라고 불렀다. 세대가 바뀌면서 새로운 뉴런이 추가될 때 이들의 가중 벡터는 <그림 2>의 방식에 의해 기존 뉴런들의 가중 벡터들의 가중 평균을 할당한다. 이 방식은 학습 속도 향상과



<그림 1> 상관성 비교를 위한 자기감독적용 신경망의 구조(자기감독적용층 뉴런 클러스터 간 양방향 화살표는 학습 시 정보 교환을 표시함.)



<그림 2> 뉴런의 삽입과 가중 벡터 할당 방식

위상적 정렬에 도움이 된다. 이 보고서에서는 <그림 2>의 'gen2' 또는 'gen3' 까지 학습시킨다. 그 이상의 뉴런을 사용하지 않는 이유는 뉴런과 입력 노드 간의 연결의 수(즉, 가중치 수)를 입력 패턴 수에 비해 상대적으로 작게 하기 위해서이다. 그렇게 해야 주어진 문제에 대해 신경망에 지나친 유연성(flexibility)을 허용하지 않고 일반화(generalization) 특성을 확보할 수 있다.

3.3 실험 방법

- (1) 학습 epochs 수: 뉴런 클러스터 당 뉴런 수의 20 배로 하였다. 즉, 입력 패턴 세트를 $2 * 20 + 4 * 20 = 120$ 회 또는 $2 * 20 + 4 * 20 + 8 * 20 = 280$ 회 반복하여 신경망에 제시하며 가중 벡터를 갱신한다.
- (2) 입력 패턴 제시: 매 학습 epoch마다 전체 48개의 입력 패턴이 랜덤하게 shuffle 된 후 제시된다.
- (3) 학습 속도(learning rate): 0.1 ~ 0.01 범위에서 선형적으로 감소시킨다.

- (4) 성능 측정: 1) 학습의 최종 epoch에서 모든 입력 벡터와 복구(reconstruction) 벡터 간의 유clidean 거리의 제곱의 평균을 계산한다. 2) 매회 랜덤하게 가중치 벡터들을 초기화하면서 16회 반복하는 실험 전체에 대해 앞 항의 평균을 계산해서 성능 측정 값을 구한다.
- (5) 가중치 벡터의 초기화: 초기 가중치 벡터의 각 요소 값의 범위는 0.0 ~ 0.5로 제한한다.
- (6) 이웃 함수 계산: 이웃 함수의 크기는 직경을 3점으로 고정한다. 자기감독적용 알고리즘의 이웃 함수는 식 (가)에 의해 구해지므로 비대칭도 가능하다. 이 보고서에서는 계산량을 줄이고 이전의 실험들에서 확인된 결과를 이용하기 위해 식 (가)에 의해 이웃 함수를 생성하는 대신에 <표 1>의 다양한 기울기의 근사화된 비대칭 이웃 함수들로 실험한다. <표 1>에서 첫 번째 열은 근사화 이웃 함수의 이름을 나타낸다. 두 번째부터 네 번째 열은 3점 이웃 함수의 각 점의 값을 나타내는데, π_- , π_c , π_+ 는 각각 비대칭 이웃 함

수의 낮은 쪽, 가운데, 높은 쪽의 점 값을 나타낸다. 아래 행으로 갈수록 기울기가 증가함을 볼 수 있다.

<표 1> 근사화 비대칭 이웃 함수들의 점 값들

이웃함수	π_-	π_c	π_+	비고
W3	0.20	0.60	0.20	대칭
W4	0.15		0.25	
W5	0.10		0.30	
W6	0.05		0.35	

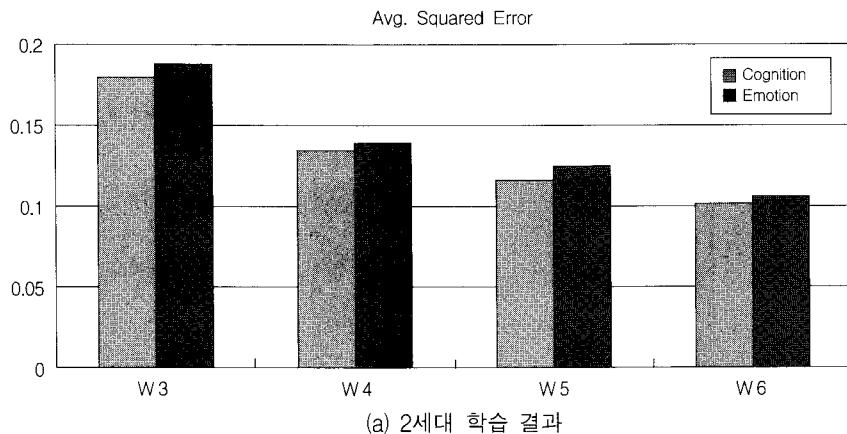
증식(가)에 의해 결정된 이웃 함수의 기울기 방향을 확인한다. 2) 그 방향에 맞춰 <표 1>의 근사화 비대칭 이웃 함수의 기울기 방향을 일치시켜 적용한다. 각 근사화 비대칭 이웃 함수에 대한 실험은 따로 따로 수행된다.

IV. 실험 결과 및 분석

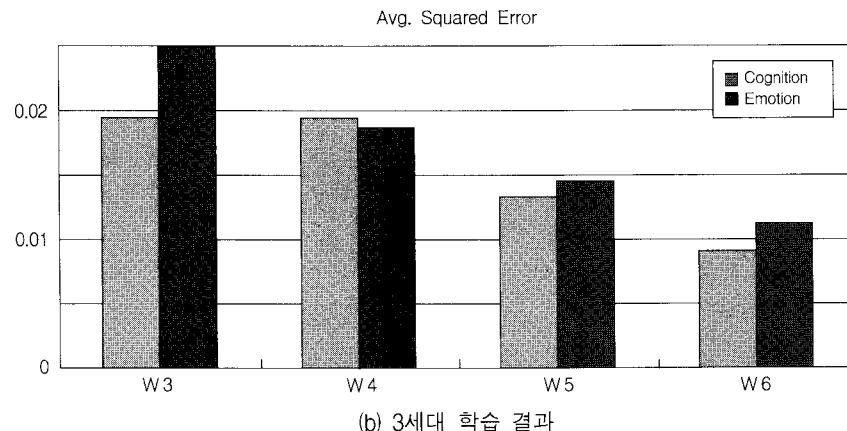
4.1 실험 결과

(7) 근사화 비대칭 이웃 함수의 적용: 1) 학습

<그림 3>은 인지특성 또는 감성특성과 시계

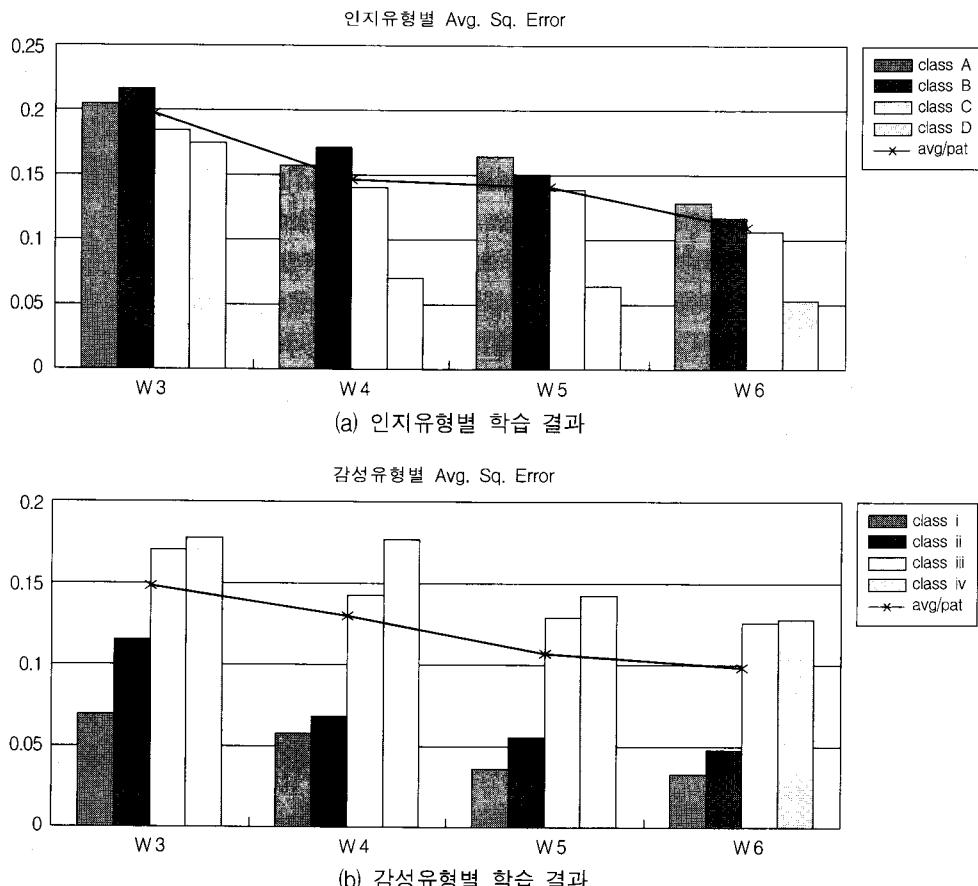


(a) 2세대 학습 결과



(b) 3세대 학습 결과

<그림 3> 인지특성 및 감성특성과 시계열 예측 정확도에 대한
자기감독적용 신경망의 학습 결과



<그림 4> 인지 및 감성의 각 유형과 시계열 예측 정확도에 대한 자기감독적용 신경망의 학습 결과

열 예측 정확도 간의 상관성 조사를 위해 자기감독적용 신경망을 학습시킨 결과를 보여준다. 그레프 (a)와 (b)는 각각 2세대 또는 3세대 동안 학습시킨 경우이다. 각 그레프의 수평축은 <표 1>의 근사화 이웃 함수를 표시한다. 각 이웃함수별 두 개의 막대는 각각 인지특성과 감성특성에 대한 실험 결과이다. 각 데이터는 최종 학습 기(epoch)에서 입력 패턴 당 평균 오차 제곱을 계산해서 구했다. 여기서의 오차는 복구 벡터와 입력 패턴 간의 유clidean(Euclid) 거리를 의미한다. 각 실험결과 데이터는 신뢰성을 위해 매 회 랜덤하게 초기화된 가중 벡터

를 사용하여 16회 반복한 실험을 평균해서 구했다. <그림 3>에서 2세대 학습의 경우보다 3세대 학습의 경우가 오차가 작은 이유는 세대 증가에 따라 뉴런 당 입력 패턴 수가 감소하기 때문이다.

<그림 4>의 그레프 (a)와 (b)는 시계열 예측 정확도에 대한 인지특성 및 감성특성의 각 유형별 상관성을 조사하기 위해, 각 유형별로 자기감독적용 신경망을 학습시킨 후의 평균 제곱 오차를 보여준다. 막대 그레프는 각 유형에 대한 데이터를 보여주며, 꺾은선 그레프는 이들로부터 계산한 패턴 당 평균값을 보여준다. 이

평균 값이 <그림 3>에서와 다른 이유는, 신경망의 학습은 뉴런 당 패턴 수, 입력 분포 등에 의해 영향을 받기 때문이다.

4.2 실험결과 분석

이 실험에서는 수학적 모델 또는 필드(field) 데이터를 사용했던 이전의 실험들[유현중, 1998; Luttrell, 1992; Yoo, 1999]에서 일관성있게 관찰된 자기감독적용 신경망의 다음과 같은 특성들을 이용하여 시계열 예측 정확도에 대한 파라미터들의 영향을 분석하고자 한다:

- A. 입력 벡터 쌍 간 상관성이 존재하는 경우,
 - A-1 기울기가 큰 근사화 이웃 함수를 사용 할수록 자기감독적용 신경망 벡터 양 자기의 성능이 향상되었다.
 - A-2 입력 벡터 쌍 간 상관도가 높을수록, 자기감독적용 신경망 벡터 양자기의 오차가 작았다.
 - A-3 입력 벡터 쌍 간 상관도가 높을수록 큰 기울기의 근사화 이웃 함수의 사용에 의한 자기감독적용 신경망 벡터 양자기의 성능 향상이 뚜렷했다.
- B. 입력 벡터 쌍 간 상관성이 없는 경우, 자기감독적용 신경망 벡터 양자기의 성능은 이웃함수의 기울기와 무관하거나 기울기 증가에 따라 오히려 오차가 커졌다.

(1) 인지특성과 감성특성의 시계열 예측 정확도에 대한 상관성 유무

<그림 3>과 <그림 4>에서 보는 바와 같이

<표 2> 유형별 클래스 당 패턴 수

특성	Cognition				Emotion			
	A	B	C	D	i	ii	iii	iv
유형	A	B	C	D	i	ii	iii	iv
패턴 수	12	14	17	5	7	9	13	19

이웃 함수의 기울기가 증가함에 따라 자기감독적용 신경망 벡터 양자기의 성능 향상이 뚜렷하다. 그러므로, 위 A-1과 B에 근거하여, <그림 3>과 <그림 4>의 실험 결과는 인지특성과 감성특성이 모두 시계열 예측 정확도와 상관성이 있음을 의미한다고 볼 수 있다.

(2) 인지특성과 감성특성의 시계열 예측 정확도에 대한 상관성 비교

인지특성 벡터와 감성특성 벡터의 요소 수 및 벡터의 크기를 정규화했으므로 두 입력에 대한 복구 오차 측정 결과는 직접 비교 가능하다. <그림 3>에서 인지특성이 감성특성 보다 거의 모든 근사화 비대칭 이웃 함수에 대해 오차가 작음을 볼 수 있다. 그러므로, 전반적으로 인지특성의 시계열 예측 정확도에 대한 상관도가 감성특성 보다 상대적으로 높다고 할 수 있다. 그러므로, 위 A-2에 근거하여, 인지특성이 감성특성 보다 시계열 예측 정확도에 대한 상관도가 높다고 볼 수 있다.

그런데, <그림 3>에서의 데이터와 달리 <그림 4>에서는 인지유형별 학습 오차의 평균이 감성유형별 학습 오차 평균 보다 큼을 볼 수 있다(꺽은 선 그래프 참조). <그림 3>과 <그림 4>의 데이터가 다른 이유는, 신경망의 학습 오차는 뉴런 당 패턴 수, 입력 패턴 분포 등에 의해 영향을 받기 때문이다. <표 2>의 감성유형별 패턴 수와 <그림 4b>의 각 근사화 이웃 함수별 막대 그래프의 추세가 뉴런 당 패턴 수의 이러한 관계를 보여준다고 할 수 있다. 그러므로, 인지특성과 감성특성의 시계열 예측 정확도에 대한 상관도 비교는 <그림 4> 보다

는 <그림 3>에 의해 판단하는 것이 더 정확할 것이다.

(3) 인지유형 및 감성유형별 시계열 예측 정확도에 대한 상관성 비교

이 보고서에서는 <표 2>에서 보는 바와 같이 인지특성 또는 감성특성의 유형별 패턴 수가 충분치 않고 비슷하지도 않기 때문에 자기조직 신경망에 의한 유형별 비교는 정확하지 않을 수 있음을 미리 밝혀둔다.

인지유형별 학습결과에서 C 유형의 뉴런 당 표본 수가 A 유형이나 B 유형에서 보다 많음에도 불구하고 오차가 항상 더 작음을 볼 수 있다. 따라서, C 유형의 상관성이 A나 B 유형 보다 높은 것으로 본다. A 유형과 B 유형 사이에서는 A 유형이 근사화 이웃함수의 기울기에 의한 영향이 불분명하므로 B 유형의 상관성이 높다고 볼 수 있다. 따라서, A, B, C 인지유형들의 시계열 예측 정확도에 대한 상관도는 대략적으로 C 유형, B 유형, A 유형 순으로 큰 것으로 판단된다. D 유형은 뉴런 당 패턴 수가 다른 유형과 차이가 많아 비교가 곤란하다.

감성유형별 상관도 비교에 대해서는 <그림 4b>의 막대그래프의 추세가 <표 2>의 뉴런 당 패턴 수의 추세를 단순 반영하고 있으므로, 위와 같은 분석 시도가 적절치 않다. 이러한 추세의 일치는 시계열 예측 정확도가 전반적으로 감성유형에 그다지 영향을 받지 않음을 의미한다고 볼 수 있으며, 이는 앞 항에서의 분석과 일치한다. 그러나, 유형 ii와 iii에 대해서는 이들의 오차의 차이가 이웃 함수의 기울기 증가에 따라 뚜렷해지고 있으므로, 위 A-3에 근거하여, 클래스 ii의 상관도가 클래스 iii의 상관도 보다 높은 것으로 판단된다. 또한, 위 B에 근거하여, 모든 유형이 시계열 예측 정확도와 상관성을 갖고 있다고 할 수 있

다. 그러므로, 앞에서 인성과 감성이 모두 시계열 예측 정확도와 상관성이 있다는 분석과 일치한다.

V. 토의 및 결론

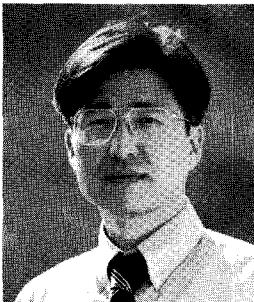
본 실험에서는 자기감독적용 신경망이 본질적으로 입력 간의 상관성을 이용하여 학습하는 특징을 이용하여 데이터 간 상관성 유무 판단 및 상관성 비교를 수행하는 독창적 방법을 시도했다. 실험 결과로서 인지적, 감성적 특성과 의사결정성과 간에는 어떠한 형태로든 상관성이 존재하고 있음을 발견한 것이다. 자기감독적용 신경망은 이 상관성이 시계열 예측 정확도에 긍정적 영향을 주는 것인지 또는 부정적 영향을 주는 것인지에 대한 정보는 제공하지 않으나, 오차와 함께 분석된다면 역으로 피해야 할 인지적 또는 감성적 상태도 도출할 수 있을 것이다. 이 실험에서는 패턴 수집을 위한 실험 자체의 어려움으로 패턴 수가 부족한 편이었고 유형별 뉴런 당 패턴 수의 차이가 커기 때문에 <그림 4>로부터 유형별 상관성 비교가 미흡했다. 추후 표본 수가 보충된다면 이에 대한 보다 정확한 분석이 가능할 것이다.

자기감독적용 신경망의 뉴런들은 유사한 입력에 대해 특정 이웃 그룹 뉴런들의 반응이 민감하도록 학습되며, 서로 다른 뉴런 클러스터에 있는 특정 뉴런 쌍들이 유사한 입력에 대해 짹을 이루도록 학습된다. 따라서, 자기감독적용 신경망은 학습 후 뉴런들의 Joint Winning Probability Density Function 또는 Joint Winning Frequency 분포가 입력 간의 상관성에 관한 정보를 가질 수 있을 것으로 본다. 이들을 Discriminant Analysis에 의해 분석하여 입력 벡터들 간의 상관도를 측정하는데 대한 연구를 계획하고 있다.

〈참 고 문 헌〉

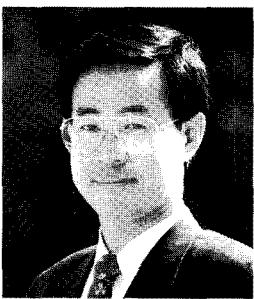
- [1] 유현중, Pimmel, R., "자기감독적용 방식에 의한 SOFM의 성능향상," *한국정보과학회*, 25, 1575-1580, 1998.
- [2] 임좌상, 박홍국, "예측지원시스템에 의한 직관적 예측의 행태에 관한 연구," *한국경영과학회지*, 24-1, 79-98, 1999.
- [3] Agor, W.H., "The logic of intuition: How top executives make important decisions," *Organizational Dynamics*, 14-3, 5-23, 1986.
- [4] Davis, D.L., Grove, S.J. and Knowles, P.A., "An experimental application of personality type as an analogue for decision-making style," *Psychological Report*, 66-1, 167-184, 1990.
- [5] Hoch, S.J., Schkade, "A Physiological Approach to Decision Support Systems," *Management Science*, 42-1, 51-64, 1996.
- [6] Kohonen, T., Oja, E., Simula, O., Vsa, A., and Kangas, J., "Engineering applications of the self-organizing map," *Proceedings of IEEE*, 84, 1358-1384, 1996.
- [7] Kohonen, T., *Self-Organization and Associative Memory*, 2nd Ed., Springer-Verlag, 1988.
- [8] Kuo, Feng-Yang, "Managerial intuition and the development of executive support systems," *Decision Support Systems*, 24, 89-103, 1998.
- [9] Luttrell, S.P., "Self-supervised adaptive networks," *IEE Proc.-F*, 139, 371-377, 1992.
- [10] Makridakis, Spyros, Forecasting Competition, http://www.insead.fr/Research/Forecast_Compet.
- [11] Rowe, A.J. et al., *Managerial Decision Making*, Prentice Hall, 1994.
- [12] Ruble, Thomas L. and Cosier, Richard A., "Effects of Cognitive Styles and Decision Setting on Performance," *Organizational Behavior and Human Decision Process*, 46-2, 283-312, 1990.
- [13] Russel, J.A., Weiss, A. and Mendelsohn, G.A., "Affect Grid: A Single-Item of Pleasure and Arousal," *Journal of Personality and Social Psychology*, 57-3, 493-502, 1989.
- [14] Singh, D.T., "Incorporating cognitive aids into decision support systems: the case of the strategy execution process," *Decision Support Systems*, 24, 145-163, 1998.
- [15] Yoo, H.J. and Pimmel, R., "Short term load forecasting using a self-supervised adaptive neural network," *IEEE Trans. on Power Systems*, 14, 779-784, 1999.

◆ 저자소개 ◆



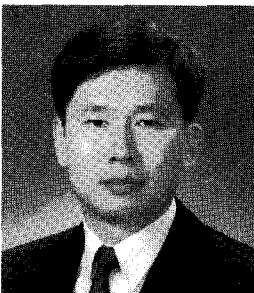
유현중 (Yoo, Hyeon-Joong)

1996년부터 상명대학교 컴퓨터및정보통신학부 교수로 재직 중이다. 서강대학교에서 전자공학과 학사학위(1982), 미국 미주리대학에서 컴퓨터 및 전기공학과 석사(1991) 및 박사(1995) 학위를 취득하였다. 국방과학연구소 연구원(1982~1989), 삼성전자 산전개발사업부 부장(1996)으로 근무하였고, (주)ACN Tech.(1999)와 (주)알파텔레콤 (1999~2001) 연구소장을 겸직하였다. 또한, 미국 앨러바마 대학에서 visiting scholar(1992~1995)로 연구하였다. 주요 관심분야는 비디오 신호처리, 패턴인식, 인공신경망 응용 등이다.



박홍국 (Park, Hung Kook)

현재 상명대학교 소프트웨어학부 교수로 재직중이며, 정보통신대학원장, 뇌정보통신연구소장을 맡고 있다. 국제학술지인 Communications of AIS의 Associate Editor, 한국감성과학회 편집위원장으로 봉사하고 있다. 서울대학교 경영학과를 졸업하고 (1977), 미국 클레어몬트대학의 The Peter Drucker Graduate School of Management에서 경영학 석사(1985), 정보시스템 박사학위(1990)를 취득하였다. 주요 관심분야는 감성 컴퓨터, 전자상거래와 ERP, DSS/EIS, Groupware 등의 의사결정지원분야이며 최근에는 Internet Telephony 에도 많은 관심을 가지고 있다. Information & Management, European Journal of OR, Journal of International Information Management 등 국내외 학술지에 다수의 논문을 발표하였다.



송병호 (Song, Byoung-ho)

1985년 서울대학교 컴퓨터공학과 공학사와 1987년 서울대학교 대학원 컴퓨터공학과 공학석사를 취득하였으며, 1987년 동 대학원에서 공학박사를 취득하였다. 현재 상명대학교 소프트웨어학과 조교수와 전자정부기반구조점검반 표준점검팀장으로 재직 중이다. 주요 관심분야는 데이터베이스, 멀티미디어 정보검색, 전자문서, 한글처리, 디지털 게임 등이다.

◆ 이 논문은 2001년 1월 20일 접수하여 1차 수정을 거쳐 2001년 11월 25일 게재 확정되었습니다.