

논문 2005-42CI-3-4

# 자기 조직 신경망에 의한 인지/감성 유형의 시계열 직관 예측과의 상관성 조사

(Investigation of Correlation Between Cognition/Emotion Styles and Judgmental Time-Series Forecasting Using a Self-Organizing Neural Network)

유 현 중\*, 박 흥 국\*\*, 조 태 경\*\*\*, 박 종 일\*\*\*\*

(Hyeon-Joong Yoo, Hung Kook Park, Taekyung Cho, and Jongil Park)

## 요 약

직관력은 의사결정시 자주 의존되나, 효과적인 의사결정지원 시스템의 개발 목적으로는 거의 고려되고 있지 않다. 본 연구는 의사결정자의 인지특성 및 감성특성과 시계열 직관 예측 간의 상관성을 자기조직 인공신경망에 의해 확인하고 비교함으로써, 시계열 직관 예측에 영향을 주는 의사결정자의 인지적 특성과 감성적 특성을 도출하고 궁극적으로는 효과적인 의사결정 환경을 조성하는데 공헌하고자 한다. 이 실험에 사용하는 인공신경망은 자기감독적용 알고리즘을 이용하는데, 이의 특징은 학습 기간 중 자기조직 층의 뉴런 클러스터 간에 정보를 교류함으로써 본질적으로 입력 벡터 간의 상관성을 이용할 수 있다는 것이다. 실험결과, 인지 특성과 감성 특성이 모두 시계열 예측과 상관성이 있는 것으로 나타났으며, 또한 인지 특성이 감성 특성보다 상관성이 높은 것으로 나타났다. 유형별로는, 개념적 인지유형이 분석적 또는 행동적 인지유형보다, 불쾌-이완 감성유형이 쾌활-각성 감성유형보다 시계열 직관 예측의 상관성이 높은 것으로 관찰되었다.

## Abstract

Although people frequently rely on intuition in managing activities, they rarely use it in developing effective decision-making support systems. In this paper, we investigate and compare the correlations between such characteristics as cognition and emotion characteristics and judgmental time-series forecasting accuracy by using a self-organizing neural network, and eventually aim to help build efficient decision-making atmosphere. The neural network used in this paper employs a self-supervised adaptive algorithm, and the feature of which is that it inherently can use correlation between input vectors by exchanging information between neuron clusters in the self-organizing layer during the training. Our experiments showed that both cognition and emotion characteristics had correlations with judgmental time-series forecasting, and that cognition characteristics had larger correlation than emotion characteristics. We also found that conceptual style had larger correlation than behavioral and analytical styles, and displeasure-sleepiness style had larger correlation than pleasure-arousal style with the forecasting.

**Keywords :** self-organizing neural network, self-supervised adaptive, correlation, emotion, cognition

## I. 서 론

\* 정회원, \*\*\* 평생회원, 상명대학교 정보통신공학과  
(Dept. of I&T Eng., Sangmyung University)

\*\* 정회원, 상명대학교 미디어기술학부  
(Div. of Media Technology)

\*\*\*\* 학생회원, 단국대학교 전자계산학과  
(Dept. of Comp. Sci., Dankook University)

접수일자: 2005년1월14일, 수정완료일: 2005년5월3일

직관력은 잘 알려진 인지능력이지만 효과적인 의사결정지원 시스템의 개발 목적으로는 거의 고려되고 있지 않다<sup>[1]</sup>. 합리적 의사결정에 비해 시계열 직관 예측(judgmental time-series forecasting)은 인과 관계가 아

년 동일 시계열 내에서 과거 데이터를 기반으로 미래를 예측하는 것이다. 직관 예측은 통계 예측을 사용할 수 없는 상황에서도 사용할 수 있다는 점에서 널리 사용되고 있으나, 많은 잠재적 오류를 내포하고 있다. 시계열 직관 예측의 정확성에 영향을 미치는 요소에 관해서는 명확한 분석이 이루어지지 않고 있으나, 한편, 의사결정 관련 문헌에서는 사람이 직관에 의존함으로써 발생할 수 있는 오류와 그로 인한 부정확성을 지적하고 있다<sup>1, 2</sup>. 이러한 연구 결과는 직관 또는 분석에 더 의존하는 경우에 있어 예측 정확성에 차이가 존재할 것이라는 가설을 성립하게 한다.

인지유형과 감성유형의 시계열 예측에 대한 상관성에 관한 연구는 많지 않다. 본 연구에서는 비감독 인공 신경망<sup>3, 4</sup>을 이용하여 사람의 인지유형 및 감성유형과 시계열 예측 간의 상관성 여부 확인 및 비교를 시도하기로 한다. 예를 들면, 동일한 시계열을 처리하는 방법이 분석적인 사람과 직관적인 사람 간에 다를 것이며, 이러한 차이가 시계열 예측에 영향을 주는가에 대한 연구를 수행하고자 한다. 그리하여, 궁극적으로 효과적인 의사결정환경의 인위적 조성에 기여하고자 한다.

이 후의 구성은 다음과 같다: 제 II장에서는 관련 연구를 비롯한 이론을 설명하고, 제 III장에서는 실험 방법, 제 IV장에서는 실험 결과 및 분석, 제 V장에서는 결론을 맺는다.

## II. 이론적 배경

### 1. 관련 연구

의사결정전략과정에서 의사결정자를 지원해야 할 필요성과 인지적 요건에 대한 연구는 Singh<sup>5</sup>에 의하여 수행되었으며 의사결정지원기술과 인지적 지원도구의 지원이 의사결정의 효율성과 효과성을 증진시킴을 확인시켜주었다. Kuo<sup>6</sup>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 문제 상황을 처리하기에는 경영자의 직관이 효과적일 수 있다는 것이다. 또한 대부분의 기업들이 경영활동상의 주요 예측 도구로서 직관적 예측을 사용하고 있으며, 직관적 예측이 통계적보다 효율적임이 실증적 실험에서 입증되고 있다<sup>7</sup>. Ruble

와 Cosier<sup>8</sup>는 162명의 경영학 전공 학생들을 대상으로 인지유형이 의사결정 성과에 미치는 영향을 연구하였다. Davis 등<sup>9</sup>은 96명의 대학원 학생들을 대상으로 한 실험에서 피실험자의 성격을 4개의 의사결정유형(decision-making style)으로 분류하여 의사결정 작업을 컴퓨터 모의 경영환경에서 수행하게 한 결과, 네 개 유형에 따라 비용성과가 유의한 차이가 있음을 발견했다. 또한 직관적 의사결정은 불확실성이 높거나, 과거 데이터나 경험이 없거나, 여러 변수들이 과학적으로 예측하기가 어렵거나, 시간에 제약이 있거나, 또는 대안들이 여러 개 있을 때 주로 사용하는 것으로 밝혀졌다<sup>10</sup>.

### 2. 자기감독적응 신경망

(Self-Supervised Adaptive Neural Network)

#### 가. 자기감독적응 알고리즘

Kohonen의 자기조직특징매핑(Self-Organized Feature Mapping)으로 대표되는 자기조직 신경망들은 비감독 알고리즘에 의해 학습된다<sup>3, 4</sup>. 자기조직 층의 뉴런들은 학습을 통해 이웃한 뉴런들끼리 비슷한 가중 벡터를 갖게 되기 때문에, 학습 후, 유사한 패턴 유형의 입력벡터들에 대해 특정 위치의 뉴런들이 다른 위치의 뉴런들에 비해 민감한 반응을 보이게 된다.

1990년 경, 영국의 Luttrell은 학습 시 자기조직 층에 있는 뉴런 클러스터들 간에 서로의 학습 상태에 대한 정보를 교환함으로써, 입력벡터 쌍 간의 상관성을 이용할 수 있는 다중 클러스터(Multi-cluster) 자기조직 알고리즘을 개발했다<sup>11</sup>. Luttrell은 이 알고리즘을 자기감독적응((Self-Supervised Adaptive, 이하 SSA) 알고리즘이라고 이름 붙였다. 자기감독적응 알고리즘이 입력 벡터 쌍 간의 상관성을 추출할 수 있는 능력은, 학습 중 분리된 클러스터에 있는 뉴런 쌍의 승리 빈도(Joint winning frequency)를 이용하여 이웃함수를 만들고 이에 의해 가중치를 갱신하므로써 달성된다. 식 (1)은 자기감독적응 알고리즘이 뉴런 클러스터 k의 이웃함수를 생성할 때 사용하는 공식이다.

$$P(y_k | y_1, y_2) = P_0(y_1, y_2) \left( 1 + \frac{y_k' - y_k}{\rho(y_1, y_2)} \frac{\partial \rho(y_1, y_2)}{\partial y_k} \right) \times \exp(-\pi \rho(y_1, y_2)(y_k' - y_k)^2)$$

for k = 1, 2 (1)

식 (1)에서  $y_k$ 는 클러스터 k의 승리 뉴런의 인덱스,

$y_k'$ 은  $y_k$ 를 포함하는 이웃 그룹(neighborhood group)의 뉴런들의 인덱스,  $\rho(y_1, y_2)$ 는  $(y_1, y_2)$  쌍의 조인트(Joint) 승리 빈도 함수,  $Po(y_1, y_2)$ 는  $(y_1, y_2)$  쌍의 조인트 승리 확률 함수를 각각 표시한다. 따라서, 자기감독적용 알고리즘은 학습 중 각 클러스터의 승리 뉴런 쌍과 그 이웃 뉴런 쌍들의 조인트 승리 빈도를 이용해서 이웃함수를 만든다. 이러한 이웃함수에 의해 학습된 신경망은 입력 벡터 쌍들에 대해 서로 다른 클러스터의 뉴런들이 차츰 규칙적인 짝을 이뤄 반응하게 되어, 비슷한 패턴 유형의 입력벡터 쌍에 대해서는 특정 뉴런 쌍이 강한 출력을 만들게 된다. 분리된 클러스터에 있는 뉴런들 간의 이러한 규칙적 짝짓기는 입력벡터 쌍 간에 상관성이 존재할 때 강하게 일어난다. 이전의 실험들<sup>[11], [12]</sup>은 입력벡터 쌍 간 상관도가 높을수록 자기감독적용 신경망 벡터 양자기의 오차가 작음을 보여주고 있다.

자기감독적용 신경망을 이용하여 인지특성과 감성특성의 시계열 직관 예측 정확도에 대한 상관성 분석을 시도하기 전에, 수학적 모델에 의해 생성한 입력 패턴을 사용하여 자기감독적용 알고리즘이 입력벡터 쌍 간 상관성을 이용하는 특성을 증명해보기로 한다.

나. SSA 알고리즘의 입력벡터 쌍 간

상관성 이용 특성 확인 실험

(1) 수학적 모델에 의한 입력 패턴 생성


자기감독적용 알고리즘의 상관성 이용 특성을 확인하기 위하여 서로 다른 난이도의 문제들, 즉, 세 개의 추계학적(stochastic) 모델을 사용하여 자기감독 층에 있는 분리된 뉴런 클러스터들에 대한 입력벡터 쌍 간에 제어된 상관성(controlled correlations)이 있는 2차원 입력벡터들을 만들기로 한다.

첫 번째 모델(모델 I)에서는, 우선  $[0.5, 0.5]^T$ 를 중심으로 하는 단위 원에 의해 정의되는 영역의 균등 분포로부터 랜덤하게 256개의 표본을 추출함으로써 첫 번째 클러스터용 2 차원 입력 표본( $X_1 = [X_{11}, X_{12}]^T$ ) 집합을 만든다. 두 번째 클러스터용 입력 표본( $X_2 = [X_{21}, X_{22}]^T$ ) 들은  $-\theta$ 와  $\theta$ 사이의 균등 분포(즉,  $\theta \sim u[-\theta, \theta]$ )로부터 랜덤하게 선정된 각도로  $X_1$ 을 원 중심을 기준으로 회전시켜 만든다. 입력벡터 쌍 간 높은 상관성을 갖는 문제와 낮은 상관성을 갖는 문제를 만들기 위해  $\theta$ 값으로 0.1과 0.9 라디안을 각각 사용한다.


위상적 이웃학습 알고리즘은 비균등 분포에 대해 성능이 저하되는 것으로 알려져 있기 때문에 모델 II에서

는 256개의 입력 표본들을 정규 분포로부터 추출한다. Box-Muller 기법을 사용하여 2차원 균등 분포로부터의 표본들을 (0,0)을 중심으로 하는 단위 편차의 정규 분포의 표본들로 매핑한다. 편의상, 변환된 표본들 중 단위 원 밖에 놓이게 되는 것들은 버린다. 그 다음에, 분포의 중심을  $[0.5, 0.5]^T$ 로 옮긴다.  $X_2$ 를 얻기 위해서는, 모델 I에서와 마찬가지로, 이 표본들을 분포의 중심을 기준으로 랜덤 각도로 회전시킨다.


모델 III은 AR(autoregressive) 모델과 유사하다: 첫 번째 클러스터용 입력벡터 256개를  $X_{11}, X_{12} \sim$



(a) 모델 I



(b) 모델 II



(c) 모델 III

그림 1. 수학적 모델들의 입력 패턴 분포(클러스터 1) 예

Fig. 1. Examples of the input pattern distributions of mathematical models.

$u[-0.5,0.5]$ 에 의해 정의되는 정사각형의 균등 분포로부터 랜덤하게 추출한다. 그 다음에 같은 분포로부터 랜덤 벡터  $N$ 을 추출한다. 그 다음, 두 번째 클러스터용 입력 벡터  $X_2$ 를 식 (2)에 보인 바와 같이 차이 벡터 ( $X_1 - N$ )의 임의의 비율( $\alpha$ )을  $N$ 에 더하여 계산한다.

$$X_2 = \alpha(X_1 - N) + N = \alpha X_1 + (1 - \alpha)N \quad (2)$$

$X_1$ 으로부터  $X_2$ 까지의 거리는  $\alpha$ 와 역관계이므로  $\alpha$ 가 클수록 두 벡터는 가까워진다. 입력벡터 쌍 간 상관성이 높은 경우와 낮은 경우의 데이터를 만들기 위해  $\alpha$ 값으로 0.9와 0.1을 각각 사용하였다. 식 (2)는 시간 영역에서 두 벡터가 연속적 표본이 되는 1차 AR 모델에 해당한다.

그림 1은 모델 I, 모델 II, 모델 III으로 생성한 입력 패턴의 분포들을 보여 준다.

(2) 자기감독적응 신경망 학습 방법

수학적 모델에 의해 생성한 입력벡터 쌍의 좌표를 그림 2에서와 같이 각 뉴런 클러스터에 입력한다. 두 뉴런 클러스터 간의 양방향 화살표는 식 (1)에 의해 제공되는 이들 간의 정보 교환을 나타낸다. 입력벡터  $P$ 의




그림 2. 제어된 상관성 입력 패턴 학습용 자기감독적응 신경망

Fig. 2. The self-supervised adaptive neural network for training controlled correlational input patterns.

표 1. 근사화 비대칭 이웃함수들의 점 값들  
Table 1. The point values of the approximate asymmetric neighborhood functions.

이웃함수	$\pi_-$	$\pi_c$	$\pi_+$	비고
W3	0.20	0.60	0.20	대칭
W4	0.15		0.25	
W5	0.10		0.30	
W6	0.05		0.35	

윗 첨자와 아래 첨자는 각각 뉴런 클러스터와 입력벡터 요소의 인덱스이다.

자기감독적응 알고리즘의 이웃함수는 식 (1)에 의해 구해지므로 비대칭이 가능하다. 이 실험에서는 자기감독적응 알고리즘의 가장 큰 특징 중 하나인 비대칭성의 효과를 확인하는데 식 (1)에 의해 이웃함수를 생성하는 대신에 표 1의 다양한 기울기의 근사화된 비대칭 이웃함수들을 사용한다. 이웃함수의 크기는 표 1에서와 같이 직경을 3 점으로 고정한다.

표 1에서 첫 번째 열은 근사화 이웃함수의 이름을 나타낸다. 두 번째부터 네 번째 열은 3 점 이웃함수의 각 점의 값을 나타내는데,  $\pi_-$ ,  $\pi_c$ ,  $\pi_+$ 는 각각 비대칭 이웃함수의 낮은 쪽, 가운데, 높은 쪽의 점 값을 나타낸다. 이들은 볼록한(convex) 모양의 공통점을 갖고 있고, 이웃함수의 번호가 증가함에 따라 기울기가 증가함을 볼 수 있다.

근사화 비대칭 이웃함수의 적용 요령은: i) 학습 중식 (1)에 의해 결정된 이웃함수의 기울기 방향을 확인하고, ii) 그 기울기 방향에 표 1의 근사화 비대칭 이웃함수의 기울기 방향을 일치시켜 적용한다.

학습이 진행됨에 따라 클러스터 당 뉴런 수를 그림 3에서 보는 것과 같이 초기에 2개에서 시작하여, 4개, 8개, 16개로 증가시킨다(편의상 그림 3에는 3 세대까지만 표시) -- Luttrell은 각 뉴런 수에 대한 학습기간을 세대(generation)로 구분해서 불렀다. 새로운 세대로 바뀌면서 추가되는 뉴런의 가중벡터는 그림 3과 같이 기존 뉴런들의 가중 벡터들의 가중 평균을 할당한다. 이




그림 3. 뉴런의 삽입과 가중 벡터 할당 방식  
Fig. 3. The method of inserting neurons and assigning their weight vectors.

러한 뉴런 삽입 및 가중벡터 부여 방식은 학습 속도 향상과 위상적 정렬을 돕는다. 이 실험에서는 4 세대까지 학습시킨다.

학습 기(epoch) 수는 뉴런 클러스터 당 뉴런 수의 50 배를 곱해서 계산하며, 그 횟수만큼 입력 패턴 집합을 반복 제시한다. 즉, 4 세대(gen 4)까지 학습시키는 경우  $1,500 = (2 + 4 + 8 + 16) * 50$  회 반복하여 입력 패턴 집합을 신경망에 제시하며 가중 벡터를 갱신한다. 매 학습 기마다 전체 256개의 입력 패턴을 랜덤하게 섞은 후 제시한다. 가중 벡터의 각 요소 값은 0.0 ~ 0.5 범위로 제한하여 초기화한다.

학습 속도 (learning rate)는 0.1 ~ 0.001 범위에서 선형적으로 감소시킨다. 학습 후, 성능 측정을 위하여 학습의 최종 기 (epoch)에서 모든 입력벡터와 복구 (reconstruction) 벡터 간의 유클리드 거리의 제곱의 패턴 당 평균(average squared error)을 계산한다. 위 실험

를 16회 반복하는데, 매회 랜덤하게 초기화시킨 가중 벡터들을 사용한다. 16회 실험의 평균을 계산해서 평균 제곱 오차 값을 구한다.

(3) 학습 결과 및 분석

그림 4는 각 수학적 모델에 의해 생성된 입력 패턴 세트들에 대한 16 회 학습 후의 평균 제곱 오차를 보여 준다.


위 그림 4에서 가로축과 세로축은 각각 표 1의 근사화 이웃함수와 패턴 당 평균 제곱 오차이다. 그림 4(a)와 그림 4(b)에서의 각 이웃함수별 막대는 각각  $\theta$ 가 0.1(고 상관도) 또는 0.9(저 상관도) 라디안일 때의 결과이다. 그림 4(c)에서 각 이웃함수별 막대는 각각  $a$ 가 0.1(저 상관도) 또는 0.9(고 상관도)일 때의 결과이다. 세 실험 결과에서 다음의 몇 가지 중요한 사실을 관찰할 수 있다. 첫째, 기존의 자기조직 알고리즘에서와 같이 이웃함수가 대칭(W3)인 경우 입력 벡터 간 상관도와 이 신경망 벡터 양자기의 성능은 무관하다. 둘째, 모든 비대칭성 근사화 이웃함수에 대해, 입력 벡터 간 상관도가 낮은 경우에서보다 높은 경우에 자기감독적용 신경망 벡터 양자기의 오차가 작다. 셋째, 근사화 이웃함수의 비대칭성을 증가시킴에 따라 오차가 감소한다. 넷째, 그림 4(a)와 그림 4(b)에서는 근사화 이웃함수 기울기 증가에 따라 입력 벡터 간 상관성이 낮은 경우와 높은 경우의 성능 차이가 증가함을 관찰할 수 있다. 그러므로, 자기감독적용 알고리즘이 입력벡터 쌍 간 상관성 이용 능력이 있음을 알 수 있다.

본 연구에서는 자기감독적용 알고리즘의 위와 같은 특성을 이용하여 시계열 직관 예측 정확도에 대한 파라미터들의 상관도를 비교하고자 한다.

III. 실험

1. 입력 패턴 생성

이 실험에서는 정보통신공학전공 3, 4학년과 대학원 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<sup>[13]</sup>의 의사결정에 관련된 인지 유형으로 분석적 (Analytic), 행동적 (Behavioral), 개념적



(a) 모델 I (4 gens)                      (b) 모델 II (4gens)

(c) 모델 III (4gens)

그림 4. 각 수학적 모델에 대한 4세대 학습 결과 (평균 제곱오차)

Fig. 4. The results of training for 4 generations for each mathematical model. (Average squared error)

(Conceptual), 직접적(Directive)인 4가지 조건으로 나뉘어 피험자가 분류되었다.

실험 과제는 시계열 예측 문제였다. 시계열 데이터는 M-Competition<sup>[14]</sup>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. 측정하고자 하는 생체신호는 뇌파(EEG)이며 의사결정과 관련된 생리적 반응 특성을 도출하고 뇌파는 alpha와 beta 주파수 대역으로 분석을 목적으로 하였다. 개인별 실험으로 인한 실험 조건의 차이는 최소화하도록 동일한 연구자가 진행하였으며, 실험 설명도 표준화하였다. 피험자의 인지유형을 판별하기 위해서 Rowe<sup>[13]</sup>의 의사결정유형판별설문(decision style inventory)을 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 통계의 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. 곧이어, 본 연구의 독립 변수인 인지유형을 측정한다.

본 실험에 앞서 예비 실험을 2차례 걸쳐 수행하였다. 제1차 실험은 EEG 측정도구 및 실험절차에 대한 검증이었으며 이어 감성상태에 따른 의사결정성과, 인지유형에 따른 의사결정성과, 뇌파의 변화와 의사결정성과 간의 유의적 관계성 검증을 위한 2차 실험을 실시하였는데 실험 결과를 ANOVA에 의해 분석하였는데 그 통계적 유의성을 찾을 수 없었다. 이는 통제되지 않은 외생변수의 영향이 크게 작용하였을 가능성으로 보고 통제되지 않은 외생변수의 영향을 크게 받을 수밖에 없는 생체신호의 측정은 본 실험 대상에서 제외하였다.

가. 변수의 설정

(1) 독립 변수

인지유형(A, B, C, D)과 주관 감성이 독립변수이며 인지유형도 Rowe의 의사결정유형판별설문을 이용하여 판별하였고, 주관감성은 피험자의 감성을 Likert 5점 평가척도에 의한 설문으로 감성상태를 불쾌각성(i), 불쾌이완(ii), 쾌활각성(iii), 쾌활이완(iv)으로 분류하였다.

(2) 종속 변수

정확성(accuracy)을 종속변수로 설정했다. 시계열 예측의 정확성은 MAPE (Mean Absolute Percentage Error)를 통하여 측정하였다. MAPE는 시계열 예측에서 보편적으로 사용되는 도구이며, 예측 값이 실제 값으로부터 떨어진 편차를 절대적 백분율로 표시한 값이며,

$$MAPE = | \text{예측값} - \text{실제값} | / \text{실제값} \times 100$$

으로 측정된다.

2. 상관성 비교용 자기감독적용 신경망

이 실험에서 사용한 자기감독적용 신경망은 그림 5에서와 같이 자기감독적용층(또는 자기조직층)에 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 측정된 MAPE를 입력한다. 첫째 클




그림 5. 상관성 비교를 위한 자기감독적용 신경망의 구조 (자기감독적용층 뉴런 클러스터 간 양방향 화살표는 학습 시 정보교환을 표시함)

Fig. 5. The structure of the self-supervised adaptive neural network for comparing correlations. (The bidirectional arrow between neuron clusters in the self-supervised adaptive layer indicates the exchange of information during training.)

러스터의 입력벡터 구성 요소인 네 개의 인지유형 또는 감성유형은 해당 요소에는 0.9가, 나머지 요소들에는 0.1이 할당된다. 예를 들면, 실험 대상자의 인지 유형이 'B' 또는 감성유형이 'ii'라면 그림 5의 왼쪽 클러스터에는  $[1 \ 0.9 \ 0.1 \ 0.1]^T$  을 입력한다. 오른쪽 뉴런 클러스터에는 MAPE가 4개의 입력 노드에 동일하게 입력된다.

각 뉴런 클러스터의 뉴런 수는 초기에 2개에서 시작하여, 학습이 진행되면서, 총 입력 패턴 수(48개)를 감안하여, 4개 또는 8개까지 증가시킨다. 입력 패턴 수 대 연결(connection) 수(즉, 가중치 수)의 비를 적당히 크게 해야 일반적으로 신경망에 지나친 유연성(flexibility)을 허용하지 않고 신경망의 일반화(generalization) 특성을 확보할 수 있다<sup>[15]</sup>.

### 3. 실험 방법

학습 기(epoch) 수, 입력 패턴 제시 방법, 학습 속도, 가중 벡터 초기화 방법, 성능 측정 방법, 이웃함수 계산 및 근사화 비대칭 이웃함수 적용 방향 결정 방법 등은 2.2절에서와 같다.

## IV. 실험 결과 및 분석


### 1. 실험 결과

그림 6은 인지특성 및 감성특성과 시계열 예측 정확도 간의 상관성 조사를 위해 자기감독적용 신경망을 학습시킨 결과를 보여준다. 그림 6(a)와 그림 6(b)의 그래프는 각각 2 세대 또는 3 세대 동안 학습시킨 경우이다. 바꿔 말하면, 뉴런 클러스터 당 뉴런 수를 2개에서 시작하여 각각 4개 또는 8개까지 증가시키며 학습시킨 결과이다. 각 그래프의 수평축은 표 1 의 근사화 이웃함수를 표시한다. 각 이웃함수별 막대들은 각각 인지특성과 감성특성에 대한 실험 결과이다.

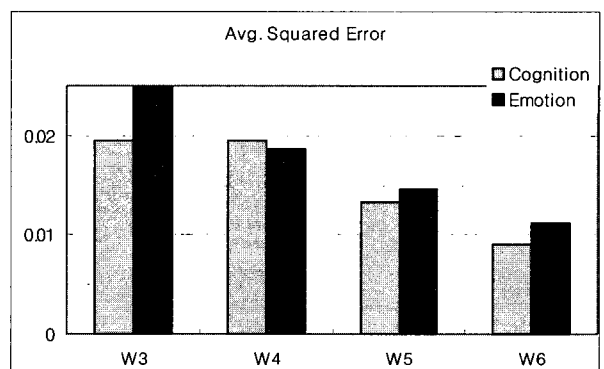
그림 7(a)와 그림 7(b)의 그래프는 시계열 예측 정확도에 대한 인지특성 및 감성특성 각각의 유형별 상관성을 조사하기 위해, 각 유형별로 자기감독적용 신경망을 학습시킨 후의 평균 제곱 오차를 보여준다. 막대그래프는 각 유형에 대한 데이터를 보여주며, 꺾은선 그래프는 이들로부터 계산한 패턴 당 평균 오차를 보여준다.

### 2. 실험 결과 분석

수학적 모델을 사용했던 앞의 실험에서 확증할 수 있었던 자기감독적용 신경망의 특성을 이용하여 시계열



(a) 2세대 학습 결과



(b) 3세대 학습 결과

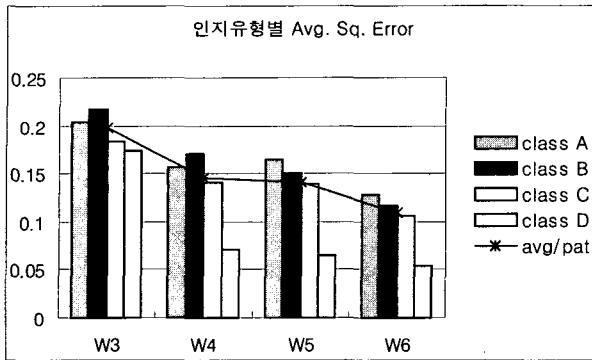
그림 6. 인지 특성 및 감성 특성과 시계열 예측 정확도에 대한 자기감독적용 신경망 학습 결과

Fig. 6. The training results of the self-supervised adaptive network for the cognition and emotional characteristics and the accuracy of time-series forecasting.


예측 정확도에 대한 파라미터들의 영향을 분석한다.

인지특성 벡터와 감성특성 벡터의 요소 수 및 벡터의 크기가 같으므로 두 입력에 대한 복구 오차 측정 결과는 직접 비교 가능하다. 그림 6에서 인지특성이 감성특성 보다 거의 모든 근사화 비대칭 이웃함수에 대해 오차가 작음을 볼 수 있다. 그러므로 전반적으로 인지특성의 시계열 예측 정확도에 대한 상관도가 감성특성 보다 상대적으로 높다고 할 수 있다.

한편, 그림 6에서의 데이터와 달리 그림 7에서 인지 유형별 학습 오차의 평균이 감성유형별 학습 오차 평균 보다 큰(꺾은 선 그래프 참조) 이유는, 전체 패턴에 대해 학습시킬 때와 유형별로 학습시킬 때의 뉴런당 패턴 수, 입력 패턴 분포 등이 다르기 때문이다. 표 2의 감성 유형별 패턴 수와 그림 7(b)의 각 근사화 이웃함수별 막대그래프의 추세의 일치는 오차가 뉴런당 패턴 수에 의해 직접 영향을 받음을 보여준다고 할 수 있다. 그러



(a) 인지유형별 학습 결과



(b) 감성유형별 학습 결과

그림 7. 인지 및 감성의 각 유형과 시계열 예측 정확도에 대한 자기감독적응 신경망 학습결과

Fig. 7. The training results of the self-supervised adaptive network for each cognition style and emotion style and the accuracy of time-series forecasting.

표 2. 유형별 패턴 수  
Table 2. The number of patterns for each style.

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

므로 인지특성과 감성특성의 시계열 예측 정확도에 대한 상관도 비교는 그림 7의 꺾은 선 그래프보다는 그림 6에 의해 판단하는 것이 더 정확할 것이다.

표 2에서 보는 바와 같이 C 유형의 뉴런당 표본 수가 A 유형이나 B 유형에서 보다 많음에도 불구하고, 그림 7(a)에서 C 유형의 오차가 항상 더 작음을 볼 수 있다. 따라서, C 유형의 상관성이 A 나 B 유형보다 높을 수 있다. A 유형과 B 유형 사이에서는 A 유형이 근사화 이웃함수의 기울기에 의한 영향이 불분명하므로

B 유형의 상관성이 높을 수 있다. 따라서 A, B, C 인지 유형들의 시계열 예측 정확도에 대한 상관도는 대략적으로 C 유형 > B 유형 > A 유형 순으로 판단된다. D 유형은 뉴런당 패턴 수가 다른 유형과 차이가 많아 비교가 곤란하다.

그림 7(b)의 감성유형별 막대그래프의 추세에는 표 2의 뉴런당 패턴 수의 추세가 단순 반영되어 있다. 각 유형별 막대그래프의 기울기와 유형 iii과 유형 iv 간의 패턴 수 차이가 최대(6)임을 감안할 때, 감성유형별 상관도는 i, ii > iv > iii의 순서인 것으로 판단할 수 있다.

### V. 결 론

절대적 기준 데이터가 없는 경우, 기존의 인공신경망에 의해 상관도 값을 측정하는 것은 불가능하다. 이 논문에서는 상관도를 직접 측정하는 대신에, 자기감독적응 신경망이 본질적으로 입력 간의 상관성을 이용하는 특징을 이용하여 상관성 유무 판단 및 상관성 비교를 수행하는 독창적 방법을 시도하였다. 실험 결과, 인지 및 감성적 특성과 의사결정성과 간에는 상관성이 존재하고 있음을 발견하였으며, 인지특성이 감성특성보다 상관도가 높았고, 유형별로는 개념적 인지유형이 분석적이거나 행동적 유형보다 높았고, 불쾌-이완 감성유형이 쾌활-각성 감성유형보다 상관도가 높은 것으로 관찰되었다.

학습된 자기감독적응층 뉴런들로부터 입력 벡터들 간의 상관도를 정량적으로 추출하기 위해 판별식 분석(Discriminant Analysis)에 의해 상관성 정보 분석 및 상관도를 측정하는 연구를 진행하고 있다.

### 참 고 문 헌

- [1] S. Hoch, "A Physiological approach to decision support systems", *Management Science*, vol. 42, no. 1, pp. 51-64, 1996.
- [2] A. Tversky, A. and D. Kahneman, "Judgement under uncertainty: heuristics and biases", *Science*, 185, pp. 1124-1131, 1974.
- [3] T. Kohonen, E. Oja, O. Simula, A. Vsa, and J. Kangas, "Engineering applications of the self-organizing map", *Proceedings of IEEE*, vol. 84, pp. 1358-1384, 1996.
- [4] T. Kohonen, *Self-Organization and Associative*



Memory, Second Edition, Springer-Verlag, 1988.

- [5] D. Singh, "Incorporating cognitive aids into decision support systems: the case of the strategy execution process", *Decision Support Systems*, 24, pp. 145-163, 1998.
- [6] F.-Y. Kuo, "Managerial intuition and the development of executive support systems", *Decision Support Systems*, 24, pp. 89-103, 1998.
- [7] 임좌상, 박홍국, "예측지원 시스템에 의한 직관적 예측의 행태에 관한 연구", *한국경영과학회지*, 제 24권 제1호, pp. 79-98, 1999.
- [8] T. Ruble, and R. Cosier, "Effects of cognitive styles and decision setting on performance", *Organizational Behavior and Human Decision Process*, vol. 46, no. 2, pp. 283-312, 1990.
- [9] D. Davis, S. Grove and P. Knowles, "An experimental application of personality type as an analogue for decision-making style", *Psychological Report*, vol. 66, no. 1, pp. 167-184, 1990.
- [10] W. Agor, "The logic of intuition: How top executives make important decisions", *Organizational Dynamics*, vol. 14, no.3, pp. 5-23, 1986.
- [11] S. Luttrell, "Self-supervised adaptive networks", *IEE Proc.-F*, vol. 139, pp. 371-377, 1992.
- [12] 유현중, R. Pimmel, "자기감독적응 방식에 의한 SOFM의 성능향상", *한국정보과학회*, vol. 25, no. 11, pp. 1575-1582, 1998.
- [13] A. Rowe, *Managerial Decision Making*, Englewood Clifff, NJ: Prentice Hall, 1994.
- [14] Makridakis and Spyros, *Forecasting Competition*, <http://www.insead.fr/Research/ForecastCompet>.
- [15] Hagan, Demuth, and Beale, *Neural Network Design*, PWS, 1996.

저 자 소 개



**유 현 중(정회원)**  
 1982년 서강대학교 전자공학 학사  
 1991년 미주리대학교 전기 및 컴퓨터공학 석사  
 1996년 미주리대학교 전기 및 컴퓨터공학 박사

<주관심분야 : 영상처리, 패턴인식, 인공신경망 응용>



**박 흥 국(정회원)**  
 1977년 서울대학교 경영학 학사  
 1985년 미국 Claremont 대학교 경영학 석사  
 1990년 미국 Claremont 대학교 정보과학과 박사

<주관심분야 : 멀티미디어통신, 임베디드시스템, 의사결정지원시스템>



**조 태 경(평생회원)**  
 1984년 한양대학교 전자통신 공학과 학사  
 1986년 한양대학교 전자통신 공학과 석사  
 2001년 한양대학교 전자통신 공학과 박사

<주관심분야 : 초고속정보통신망, SoC>

**박 종 일(학생회원)**

1996년 단국대학교 전자계산학과 학사  
 1999년 단국대학교 전자계산학과 석사  
 2000년~ 단국대학교 전자계산학과 박사과정  
 <주관심분야 : 신경망, 음성인식, 영상처리, 멀티미디어보안>