

# 조합형 학습알고리즘의 신경망을 이용한 데이터의 효율적인 특징추출

조 용 현<sup>†</sup> · 윤 중 환<sup>††</sup> · 박 용 수<sup>†††</sup>

## 요 약

본 논문에서는 새로운 학습알고리즘의 비선형 주요성분분석 신경망을 이용한 영상데이터의 효율적인 특징추출에 대하여 제안한다. 제안된 학습알고리즘에서는 최적해로 수렴하는 과정에서 발생할 수도 있는 진동을 억제하여 빠른 속도의 수렴이 가능하도록 하기 위해 모멘트를 이용하였고, 국소최적해를 만났을 때 이를 벗어난 전역최적해로의 수렴을 위한 새로운 연결가중치의 설정을 위하여 동적터널링을 이용함으로써 빠른 수렴속도로 전역최적해에 수렴되도록 학습시킬 수 있다. 제안된 학습알고리즘을 이용한 신경망을 256×256 픽셀의 간암영상과 128×128 픽셀의 얼굴영상을 대상으로 실험한 결과, 기울기하강의 학습알고리즘을 이용한 기존 비선형 주요성분분석 신경망보다 우수한 수렴성과 특징추출 성능이 있음을 확인 할 수 있었다.

## An Efficient Extraction of Data Feature By Using Neural Networks of Hybrid Learning Algorithm

Yong-Hyun Cho<sup>†</sup> · Jung-Hwan Yun<sup>††</sup> · Yong-Soo Park<sup>†††</sup>

## ABSTRACT

This paper proposes an efficient feature extraction method of the image data using nonlinear principal component analysis (NLPCA) neural networks of a new learning algorithm. The proposed learning algorithm is a hybrid algorithm combined momentum and dynamic tunneling. The momentum is applied for high-speed convergence by restraining an oscillation in the process of converging to the optimal solution. Converging to the local minimum, the dynamic tunneling is also applied for estimating the new initial weights for converging to the global minimum. The proposed algorithm has been applied to a cancer image of 256×256 pixels and a face image of 128×128 pixels, respectively. The experiment results show that the proposed algorithm has better performances of the convergence and the nonlinear feature extraction than those using the conventional NLPCA neural networks.

**키워드 :** 비선형 주요성분분석(nonlinear principal component analysis), 신경망(neural networks), 모멘트(momentum), 동적터널링(dynamic tunneling)

### 1. 서 론

데이터압축에 있어서 일련의 과정은 고차원 공간으로부터 저차원 공간으로의 사상이라고 할 수 있으며, 이는 특징추출과 밀접한 관계가 있다. 특징추출은 인식이나 분류와 같은 문제에서 데이터의 사용을 용이하게 하기 위해 속성이나 두드러진 형상을 식별하기 위한 것이다. 이러한 데이터의 특징들을 추출하기 위한 많은 기법들이 제시되어 왔다[1, 2].

주요성분분석(principal component analysis : PCA)은 주어

진 입력데이터의 특징을 추출하는 기법으로 널리 이용되고 있으며, 이는 정상확률과정(stationary stochastic process)의 입력벡터와 특별한 차원의 출력벡터를 위한 최적의 선형변환(linear transform)을 결정하는 통계적 기법이다[1]. PCA를 위한 수치적 방법들에서는 입력데이터에 대한 선형관계를 나타내는 공분산행렬(covariance matrix)의 계산이 요구되며, 주요 특징을 추출하는데 이용되는 고유치(eigenvalue)와 그에 따른 고유벡터(eigenvector)를 계산하기 위한 수식적 과정이 필요하다. 특히 대규모의 데이터를 대상으로 할 때, 공분산행렬의 계산은 매우 복잡하고 부정확하게 이루어지며, 최대 유효 고유치에 일치하는 고유벡터만이 변환과정에 이용된다 할지라도 모든 고유치와 고유벡터들이 계산되어야 하는 불합리성도 존재한다. 따라서 기존의 수치적 기법들은 범용의 대규모 실

\* 본 연구는 1999년도 대구가톨릭대학교 학술연구조성비 지원에 의한 것임  
† 정 회 원 : 대구가톨릭대학교 컴퓨터정보통신공학부 교수  
†† 준 회 원 : (주)나라비전  
††† 준 회 원 : 대구기능대학 및 포항1대학 교수  
논문접수 : 2000년 9월 26일, 심사완료 : 2001년 3월 28일

시간 처리가 요구되는 응용문제에서는 매우 비효율적이다.

최근 대규모의 병렬계산과 학습, 그리고 일반화 속성을 가지는 신경망은 영상처리 분야에 많은 관심이 되어 왔다 [1-5]. 이러한 속성을 가진 신경망에 기반을 둔 여러 가지 PCA 기법들이 변환에 기반을 둔 방법들의 대안으로 이용되고 있다. 지금까지의 대부분 방법들[1-4]은 단층신경망을 이용하고 있으며, 헤비안(Hebbian)규칙의 학습알고리즘으로 입력력의 선형관계에 의해 연결가중치 벡터를 경신하고 있다. 하지만 이 방법들은 입력데이터의 분포가 선형적인 관계에 있을 때는 효율적인 특징추출이 가능하지만 비선형적인 관계가 존재할 경우 특징을 추출하는데 어려움이 있다[6, 7]. 결국 입력데이터의 비선형성이 강할 경우 PCA의 이용은 매우 비효율적이다.

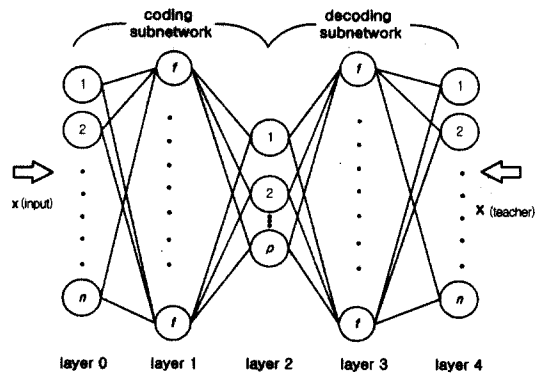
한편 단층신경망을 이용한 기존 PCA 기법의 제약을 해결하기 위하여 비선형 주요성분분석(nonlinear principal component analysis : NLPCA)을 위한 역전파(backpropagation : BP) 학습 알고리즘에 기반을 둔 다층신경망(multilayer perceptron : MLP)이 제안되었다[1-5]. 이는 n 차원 공간에서 m 차원 공간으로 데이터 집합이 쉽게 사상되도록 학습시킬 수 있기 때문이다. 그러나 기울기하강(steepest descent)의 속성을 이용하는 역전파 알고리즘은 학습파라미터의 설정에 따라 수렴속도와 견실성(robustness) 중 하나 이상의 제약을 가지며, 전역최소로의 수렴도 보장되어 있지 않다. 결국 기존에 이용되고 있는 신경망은 구조나 학습알고리즘에 따라서 특징들을 추출하는데 비현실적인 시간이 요구되거나 정확한 특징들을 추출하지 못하는 경우가 발생되어 이를 해결하기 위한 새로운 기법의 연구가 절실하게 요구된다.

Kramer는 비선형 특징들을 추출하기 위하여 5계층으로 구성되는 신경망을 제안하고 이를 여러 분야에 응용하였다 [6]. Tzovaras 등은 영상처리분야에서 스틸 이미지를 사용하여 부호화하고 복호화하는데 응용하였으며[8], Frate 등은 지구과학분야에서 기온과 증기의 대기 중 측면의 방사선 반전을 위해 이용하였다[9]. 그러나 Kramer의 NLPCA를 위한 신경망은 데이터 내에 존재하는 비선형 속성의 추출을 위해 5계층의 신경망을 이용하여 이를 학습시키는데 매우 오랜 시간이 걸린다는 제약이 있다[7-9]. 따라서 이러한 제약을 개선하기 위한 효율적인 학습알고리즘이 제안된다면 NLPCA를 위한 신경망은 더욱 더 잘 이용될 수 있을 것이다.

본 논문에서는 모멘트(momentum)와 동적터널링을 조합한 학습알고리즘을 제안하여 NLPCA를 위한 신경망을 효율적으로 학습시킴으로서 입력데이터의 주요특징을 보다 빠르고 정확하게 추출되도록 하였다. 제안된 학습알고리즘을 이용한 신경망을 256×256 픽셀의 간암영상과 128×128 픽셀의 얼굴영상들을 대상으로 시뮬레이션한 후 그 타당성을 확인하였으며, 기존의 역전파 알고리즘에 기반을 둔 Kramer의 NLPCA 신경망에 의한 결과와 비교 고찰하였다.

## 2. 모멘트와 동적터널링을 조합한 비선형 주요성분 분석을 위한 신경망의 효율적인 학습알고리즘

NLPCA는 PCA와 같은 방법으로 다변량 데이터의 분석을 위한 새로운 기법이다. 이는 실험데이터 분석과 가시화, 그리고 차원 축소를 목적으로 변수들간의 상호관계를 제거하고 식별하기 위해 사용된다. PCA는 단순히 변수들 간의 선형적인 특성만을 식별하지만, NLPCA는 선형뿐만 아니라 비선형적인 특성도 구분할 수 있다. NLPCA 신경망에서는 입력층의 데이터가 출력층에서 재구성되는 동일사상을 수행하도록 학습된다. 이는 실제 입력데이터의 분포와 유사한 특징공간을 생성함으로써 차원을 축소시키기 위함이다. (그림 1)은 NLPCA를 위한 신경망의 구조를 나타낸 것이다.



(그림 1) NLPCA를 위한 신경망 구조

그림에서 1계층과 2계층으로 이루어진 부분 망은 입력데이터를 특징공간으로 사상하는 부호화 망이다. 여기서 특징층인 2계층의 뉴런의 수 p는 입력층 뉴런의 수 n보다 적은 수를 가지게 한다. 또한 그림의 2계층에서 4계층까지는 입력데이터의 주요특징들을 출력층으로 사상하는 복호화 망이다. 일반적으로 비선형 사상을 위해 부호화 망과 복호화 망에서의 각 1계층과 3계층은 비선형 함수를 사용해야 한다. 이때 널리 이용되는 함수로는 S-자형(sigmoidal) 함수로  $f(x) = 1/(1 + e^{-x})$ 이다. 나머지 계층들은 선형이나 비선형의 함수가 이용될 수 있다.

NLPCA를 위한 신경망의 입력-출력 함수관계를 나타내면 다음과 같다. 즉,

$$\sigma(x) = \sum_{i=1}^n \bar{w}_i f(\underline{w}_i x + \underline{\theta}_i) + \bar{\theta} \quad (1)$$

이다. 여기서  $\bar{w}_i$ 와  $\bar{\theta}$  및  $\underline{w}_i$ 와  $\underline{\theta}_i$ 는 각각 상위 및 하위 계층의 연결가중치와 임계치(thresholds) 값들이다.  $\sigma(x)$ 는 선형 또는 비선형 출력의 범용 근사화기(universal approximator)로 n이 충분히 크다면 임의의 정확성을 가진 어떤 경계함수(bounded function)도 근사화할 수 있다. NLPCA를 위

한 신경망에서 각각  $a_i(l)$ 를  $l$ 계층의  $i$ 번째 뉴런 활성화 함수,  $u_i(l)$ 를  $l$ 계층의 연결강도와  $l-1$ 계층의 입력값의 곱으로 계산되는 가중된 합,  $w_{ij}(l)$ 를  $l$ 계층의  $i$ 번째 뉴런과  $l-1$ 계층의  $j$ 번째 뉴런 사이의 연결강도, 그리고  $\theta_i(l)$ 를  $l$ 계층의 뉴런  $i$ 를 위한 바이어스(bias)라 할 때,  $a_i(l)$ 과  $u_i(l)$ 는 각각 다음과 같이 나타낼 수 있다. 즉,

$$a_i(l) = \begin{cases} fu_i(l) & \text{if } l=1 \text{ or } l=3 \\ u_i(l) & \text{if } l=2 \text{ or } l=4 \end{cases} \quad (2)$$

$$u_i(l) = \sum_{j=1}^{n_{l-1}} w_{ij}(l)a_j(l-1) + \theta_i(l) \quad (3)$$

이다. 이때  $n_l$ 은  $l$ 계층의 뉴런의 수이며, 0번째 계층의 활성화 함수  $a_i(0)$ 는 입력  $x_i$ 로 정의된다. 여기서 학습은 입력데이터의 값과 출력층의 뉴런 출력값 사이의 평균자승오차를 정의하여 이를 최소화하는 것이다. 평균자승오차(mean square error)  $E(w)$ 을 수식으로 나타내면 다음과 같다. 즉,

$$E(w) = \frac{1}{P} \sum_{p=0}^P E_p(w)$$

$$E_p(w) = \frac{1}{n} \sum_{i=1}^n (a_{i,p}(4) - x_{i,p})^2 \quad (4)$$

이다. 여기서  $n$ 은 출력층의 뉴런 수이고,  $P$ 는 학습데이터의 패턴 수이며,  $a_{i,p}(4)$ 는 계층 4에서  $p$ 번째 패턴에 대한  $i$ 번째 뉴런의 활성화함수이다.  $E(w)$ 을 최소화하기 위한 가중치의 경신은 역전파 알고리즘을 이용하며, 그 가중치 경신식은 다음과 같다. 즉,

$$w_{ij}(t+1) = w_{ij}(t) + \beta \delta_i(l) a_j(l-1) \quad (5)$$

이다. 여기서  $\beta$ 는 학습율이며,  $\delta_i(l)$ 을 위한 계산식은

$$\delta_i(4) = a_i(4) - x_i \quad (6)$$

$$\delta_i(l) = d_i(l) \sum_{j=1}^{n_{l+1}} \delta_j(l+1) w_{ij}(l+1), \quad l=1,2,3$$

$$d_i(l) = \begin{cases} 1 & \text{if } l=2 \\ f'(u_i(l)) & \text{otherwise} \end{cases} \quad (7)$$

이다. 여기서  $f'$ 은 비선형 활성화 함수  $f$ 의 미분을 의미한다. 이상에서 보면 NLPCA를 위한 신경망의 학습과정은 오차함수  $E(w)$ 를 가중치  $w_{ij}$ 에 대해 미분하는 기울기하강법을 이용하여 뉴런사이의 연결가중치를 구하는 과정이다. 그러나 이 기법에서는 식 (5)에서 나타났듯이 연결가중치의 경신에 있어서 단순히 오차에 대한 미분값만을 고려하였으며, 과거의 속성을 반영하는 모멘트 항은 고려되지 않았다. 따라서 최소화 과정에서 발생하는 발진을 없애기 위해 학습 알고리즘에 모멘트 항[10]을 추가하면 모멘트가 가지는 속성을 그대로 얻을 수 있을 것이다. 즉, 식 (5)에 따라 가중

치를 경신하면 전역최소해으로 수렴하는 과정에서 발진이 일어나 그 수렴시간이 오래 걸리는 경우도 발생한다. 이러한 단점을 보완하기 위해 모멘트 항이 추가된 수정된 경신식을 제안하였다. 따라서 모멘트항이 추가된 제안된 연결가중치 경신식은 다음과 같다. 즉,

$$w_{ij}(t+1) = w_{ij}(t) + \beta \delta_i(l) a_j(l-1) + \alpha \Delta w_{ij}(t-1) \quad (8)$$

이다. 여기서,  $\alpha$ 는 모멘트이고,  $\Delta w_{ij}(t-1)$ 는 이전의 연결가중치 변화량을 나타낸 것이다.

한편, 동적터널링 알고리즘은 Yao에 의해서 제안되었다 [11]. 이는 동적최적화와 동적터널링과정으로 구성된다. 여기서 동적최적화는 초기상태로부터 국소최소값 중의 한 값을 찾는 과정이며, 동적터널링은 동적최적화에서 찾았던 국소최소값보다도 더 작은 새로운 초기상태를 찾는 과정이다. 결국 동적터널링은 동적최적화에 의해 국소최소에 빠지는 것을 막아준다. 따라서 NLPCA를 위한 신경망에서 연결가중치  $w$ 에 대한 오차함수  $E(w)$ 를 최소화하는 문제를 살펴보자. 이 문제는  $(\partial E_p(w)/\partial w)$ 를 이용하여  $E(w)$ 의 국소최소값  $w^*$ 를 찾는 것으로 변형될 수 있다. 즉,  $\Delta_p w = -\alpha (\partial E_p(w)/\partial w)$ 는 동적최적화와 동일하다. 동적터널링은 동적최적화에서 구해진  $w^*$ 에다 결정론적으로나 임의로 설정되는 교란벡터(perturbation vector)  $\epsilon$ 이 추가된 새로운 시작점에서 출발하는 것으로 다음과 같은 미분방정식의 형태로 주어진다.

$$\Delta_p w = -(\partial E_p(w)/\partial w) [1 / [(w-w^*)^T (w-w^*)]^\gamma - \xi E_p^*(E_p^{\wedge}(w))] \quad (9)$$

여기서,  $\xi$ 는 터널링페널티(tunneling penalty)로  $\|\frac{\partial E_p}{\partial w}\|/\lambda$ 보다 같거나 큰 값을 가지나 시뮬레이션에서는 적당한 상수로 설정하였으며,  $\lambda$ 는 작은 양수값이다. 그리고  $\gamma$ 의 값은  $(\partial E_p(w)/\partial w)$ 의 원점  $w^*$ 의 차수보다 크거나 같은 값을 가진다. 또한  $E_p^{\wedge}(w) = E_p(w) - E_p(w^*)$ 로 정의되며,  $E_p^*(\cdot)$ 는 다음과 같이 두 개의 분리된 구분선형(piecewise linear)함수로 정의된다.

$$E_p^*(z) = \begin{cases} z & (z \geq 0) \\ 0 & (z < 0) \end{cases} \quad (10)$$

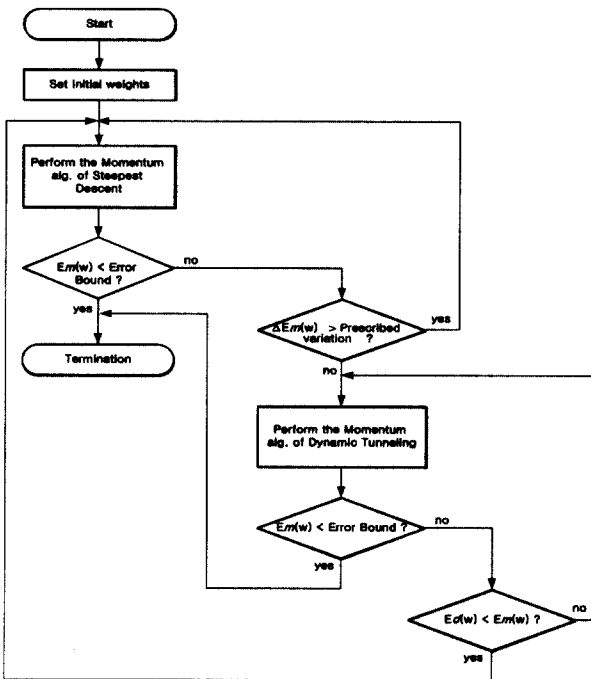
식 (9)에서, 우편 첫 번째 항의 분모  $[(w-w^*)^T (w-w^*)]^\gamma$  항은 동적최적화로부터 구해진 국소최소해인 평형상태  $w^*$ 를 제거하기 위한 것이며, 두 번째 항은 더 낮은 값을 가지는 즉,  $E_p(w^{(0)}) \leq E_p(w^*)$ 인 새로운 초기상태  $w^{(0)}$ 를 찾기 위한 것이다. 그러므로 동적터널링에 의한 학습알고리즘의 연결가중치 경신식은 식 (9)와 같으며, 여기서 4계층, 3계층, 2계층, 그리고 1계층의  $(\partial E_p(w)/\partial w)$ 는 다음의 식과 같이 정의된다. 즉,

$$\partial E_p(w)/\partial w_{ij}(l) = -\beta \delta_i(l) a_j(l-1) \quad l = 4,3,2,1 \quad (11)$$

이다. 여기서  $\delta_i(l)$ 은 각각 식 (6)과 (7)로 주어진다. 따라서 식 (9)와 (11)이 조합된 동적터널링과 모멘트에 기초한 제안된 NLPCA 신경망의 학습알고리즘에서 각 계층의 연결가중치 경신식은 다음과 같다. 즉,

$$w_{ij}(t+1) = w_{ij}(t) + \beta \delta_i(l) a_j(l-1) [1 / [(w-w^*)^T(w-w^*)]^{\gamma} - \xi E_p^*(E_p^{\wedge}(w))] + \alpha t w_{ij}(t-1), \quad l = 4, 3, 2, 1 \quad (12)$$

이다. 결국 제안된 NLPCA 신경망의 학습알고리즘은 먼저 모멘트 항을 이용한 식 (8)의 경신식으로 학습을 수행하다가 오차의 변화가 일어나지 않거나 그 변화량이 설정치 이하이면 국소최소값에 수렴된 것으로 가정하고 다음의 동적터널링과 모멘트를 조합한 식 (12)의 경신식으로 학습을 수행한다. 이 과정의 반복수행으로 신경망을 학습하면 빠른 시간 내에 학습이 가능하여 효과적으로 데이터의 비선형 주요성분분석이 가능할 것이다. (그림 2)는 제안된 학습알고리즘의 흐름도를 요약 도시한 것이다. 그림에서  $E_m(w)$  및  $E_d(w)$ 는 각각 모멘트를 가진 기울기하강과 모멘트 및 동적터널링에 의해서 계산되는 전체 오차함수 값이다.



(그림 2) 제안된 NLPCA 신경망의 학습알고리즘 흐름도

한편, 실험에서 추출된 특징들의 질을 평가하기 위해 다음의 PSNR(peak signal to noise ratio)을 이용하였다. 즉,

$$PSNR = 20 * \log_{10} (255/RMSE) \quad (13)$$

이다. 여기서 RMSE는  $(\sum(x_i - x_o)^2 / \text{전체픽셀수})^{1/2}$ 이며,  $x_i$ 는 입력픽셀의 값이고,  $x_o$ 는 재구성된 픽셀의 값이다.

### 3. 시뮬레이션 결과 및 분석

제안된 학습알고리즘의 NLPCA를 위한 신경망의 성능을 평가하기 위해 5계층의 전향신경망을 구성하였다. 이 신경망에서 각 뉴런간의 초기 연결가중치는 난수발생기를 이용하여 각각 -0.5에서 +0.5사이 임의의 값으로 설정하였다. 학습은 전체 반복회수가 20,000회 이상이거나 전체 오차함수 값이 설정치 이하일 때 종료되도록 하였다.

제안된 학습알고리즘의 5계층 전향신경망을 256×256 픽셀의 간암영상과 128×128 픽셀의 얼굴영상을 대상으로 펜티엄 III-700 컴퓨터를 이용하여 시뮬레이션한 후 그 타당성을 확인하였으며, 기존의 기울기하강에 기초한 NLPCA를 위한 학습알고리즘의 5계층 전향신경망 결과들과 비교하였다.

#### 3.1 간암영상

데이터의 주요특징추출을 위해 256×256 픽셀의 간암영상을 이용하였다. 실험에 이용된 영상은 한 개의 학습표본으로 64(8×8)개 픽셀을 가지는 전체 1024개의 표본을 연속으로 정렬하여 이용하였다. 실험에서 전체 신경망의 입력뉴런과 출력뉴런수는 각각 64개로 구성하였으며, 종료를 위한 전체 오차함수의 설정치는  $10^{-3}$ 으로 하였다.

<표 1>은 특징층의 뉴런수를 40개로 고정하고 은닉층 뉴런수에 따라 학습시킨 결과, 주어진 학습알고리즘의 종료조건을 만족할 때의 반복회수 및 CPU 시간과 PSNR의 값을 나타낸 것이다.  $N_c$ ,  $N_m$ ,  $N_d$ , 그리고  $C_t$ 는 각각 전체 반복회수, 모멘트를 가진 기울기하강과 동적터널링에 의한 반복회수, 그리고 CPU 시간을 나타낸다. 표에서 보는 것처럼 최적해로 수렴했을 때 기존 알고리즘이나 제안된 알고리즘 사이의 PSNR값 차이는 거의 없으나, 반복회수는 제안된 알고리즘이 기존의 알고리즘보다 평균적으로 약 6.5배 정도와 수렴시간은 평균적으로 약 5배 정도 더 개선되었음을 알 수 있다. 특히, 제안된 학습알고리즘의 경우 동적터널링 과정이 수행되지는 않아 국소최소해에 빠지는 경우

<표 1> 은닉층 뉴런수의 변화에 따른 결과

알고리즘 뉴런수	기존 알고리즘			제안된 알고리즘		
	$N_c$	$C_t$	PSNR	$N_c(N_m, N_d)$	$C_t$	PSNR
70	731	1250	78.131165	88(88,0)	202	78.109444
75	617	1139	78.133644	118(118,0)	293	78.108963
80	741	1454	78.133812	86(86,0)	228	78.095589
85	601	1245	78.132477	96(96,0)	272	78.101196
90	673	1465	78.132973	101(101,0)	296	78.125229
95	626	1433	78.131973	92(92,0)	287	78.109558
100	587	1412	78.132919	109(109,0)	369	78.119209
110	544	1961	78.131195	112(112,0)	399	78.122131
120	649	1922	78.133049	93(93,0)	366	78.127068


가 없으나 모멘트가 가지는 우수한 속성으로 빠른 수렴특성을 확인할 수 있다. 따라서 제안된 알고리즘을 이용한 신경망은 은닉층의 뉴런수의 변화에도 기존의 알고리즘을 이용한 신경망보다 상대적으로 우수한 수렴속성과 성능의 향상을 확인할 수 있다.

<표 2>는 은닉층을 110개로 고정하고 특징층의 뉴런수를 변화시키면서 학습한 결과, 표 1에서와 마찬가지로 반복회수, CPU 시간, 그리고 PSNR의 값을 각각 나타낸 것이다. 표에서 보면 제안된 알고리즘이 기존의 알고리즘보다 반복회수 면에서는 평균 약 4.1배정도, 수렴시간도 평균 약 3.3배정도 개선되었음을 알 수 있다. <표 1>과 마찬가지로 국소최소해에 빠지는 경우가 발생하지 않아 모멘트 항만이 이용되었다. 또한 특징층의 뉴런수가 10개인 경우 PSNR 측면에서 제안된 알고리즘이 우수하지만, 나머지 뉴런개수에 따른 PSNR값은 차이가 거의 없다는 것을 알 수 있다.

<표 2> 특징층 뉴런수의 변화에 따른 결과

알고리즘 뉴런수	기존 알고리즘			제안된 알고리즘		
	$N_c$	$C_t$	PSNR	$N_c(N_m, N_g)$	$C_t$	PSNR
10	8573	16387	76.317009	3171(3171,0)	8079	78.130394
20	1060	1139	78.132034	176(176,0)	689	78.119362
30	676	2194	78.131287	105(105,0)	462	78.129669
40	544	1961	78.131195	112(112,0)	399	78.122131

(그림 3)은 간암영상을 대상으로 기존의 NLPCA와 제안된 알고리즘을 이용한 NLPCA에서 전체 오차값의 변화를 나타낸 것이다. 여기서 학습율은 0.001로 은닉층 뉴런수는 110개, 특징층 뉴런수는 40개로 설정하였다. 그림에서 제안된 알고리즘의 반복수는 50회 정도부터 오차값이 거의 일정하게 유지되며, 기존의 알고리즘보다 빠른 수렴속도를 확인할 수가 있다.



(그림 3) 반복수에 따른 오차값의 변화

(그림 4)에서는 간암의 원영상과 2가지 알고리즘의 NLPCA로 복원된 영상을 나타내었다. (a)는 원영상이고 (b)와 (c)는 각각 학습의 종료조건이 만족되었을 때 40개의 주요특징을 추출한 후, 이들을 이용하여 복원한 영상이다. 그림에서 보면, 기존 알고리즘의 NLPCA에 의해 복원된 영상 (b)가 상대적으로 제안된 알고리즘의 NLPCA를 이용한 영상(c) 보다 잡음이 현저하게 많아 데이터 내의 특징들을 충분히 잘 추출되지 못하

였다. 따라서 제안된 알고리즘을 이용한 NLPCA 신경망은 기존의 기술기하강에 기초한 NLPCA 신경망에 비해 영상데이터 내에 포함된 선형 및 비선형의 특징들을 효과적으로 잘 추출할 수 있다. 한편 원래의 영상과 복원된 영상을 정량적으로 비교하였다. 이를 위하여 원래영상을 기준으로 복원된 각 영상을 픽셀단위로 비교하였다. 이용된 정합도 계산식은  $100 - \frac{1}{256 \times 256} \sum_{i=1}^{256 \times 256} |x_i - y_i|$ 이다. 여기서  $x_i$ 와  $y_i$ 는 각각 원래 영상과 복원 영상의 i번째 픽셀값이다. (그림 4)에서 기존 NLPCA와 제안된 NLPCA에 의해 복원된 영상의 정합도는 각각 89.6과 93.6으로 제안된 기법에 의한 복원영상이 원래 영상에 훨씬 더 가까워 우수한 특징추출 속성이 있음을 확인할 수 있다.



(a) 원영상 (b) 기존 NLPCA (c) 제안된 NLPCA  
(그림 4) 2 가지 학습알고리즘에 따른 복원된 256×256 픽셀의 간암영상들

3.2 얼굴영상

다음의 실험에서는 256×256 픽셀의 간암영상에 비해 규모가 작은 128×128 픽셀의 얼굴영상을 이용하여 실험하였다. 간암영상의 실험과 마찬가지로 64픽셀을 한 개의 학습표본으로 하는 전체 256개의 표본을 가지도록 연속으로 이용하였으며 입력뉴런과 출력뉴런수는 각각 64개로 하고 허용오차함수의 설정치를  $10^{-3}$ 으로 하였다.

<표 3> 은닉층 뉴런수의 변화에 따른 결과

알고리즘 뉴런수	기존 알고리즘			제안된 알고리즘		
	$N_c$	$C_t$	PSNR	$N_c(N_m, N_g)$	$C_t$	PSNR
70	8052	3442	78.130943	850(850,0)	489	78.129539
75	6643	3055	78.13089	876(876,0)	542	78.127449
80	7571	3688	78.131126	778(778,0)	511	78.128433
85	6159	3194	78.131233	893(893,0)	623	78.130630
90	6752	3688	78.131165	757(757,0)	558	78.128113
95	7555	4394	78.131172	740(740,0)	578	78.128731
100	6706	4164	78.131134	903(903,0)	756	78.130661
110	5803	3837	78.131180	799(799,0)	717	78.127609
120	6146	4492	78.131195	787(787,0)	784	78.129471

<표 3>에서도 <표 1>과 마찬가지로 특징층의 뉴런수를 40개로 고정하고 은닉층 뉴런수에 따라 학습시킨 결과, 주어진 종료조건이 만족될 때의 반복회수와 CPU 시간과 PSNR의 값을 나타낸 것이다. 주어진 조건에 수렴하는 동안 제안된 알고리즘에서는 <표 1>처럼 국소최소해로의 수렴은 발생되지 않아 모멘트의 속성만 이용되었다. 또한 기존 알고리즘이나 제안된 알고리즘 사이의 PSNR값을 비교


해보면 거의 유사한 값을 가진다. 하지만 반복회수와 수렴 시간 면에서는 각각 제안된 알고리즘은 기존의 알고리즘보다 평균적으로 약 8.3배 정도와 약 6.2배 정도 개선되었음을 알 수 있어 그 우수한 성능을 확인할 수 있다.

<표 4>는 은닉층 뉴런수를 110개로 고정하고 특징층 뉴런수의 변화 따라 학습시킨 결과, <표 2>에서와 마찬가지로 주어진 학습 종료조건이 만족될 때의 반복회수와 CPU 시간과 PSNR의 값을 나타낸 것이다. 여기서도 제안된 알고리즘이 기존의 알고리즘보다 반복회수와 수렴시간에서 평균적으로 약 7.2배 및 약 5.5배 정도 개선됨을 알 수 있다. 그리고 기존 알고리즘에서 특징층 뉴런수가 10개, 20개인 경우는 주어진 조건에 수렴되지 않아 학습 반복수가 20000 까지 되었다. 이런 경우에 제안된 알고리즘에서는 동적터널링 과정이 10번 반복되어 주어진 조건으로 수렴한다는 것을 알 수가 있었다. 특히 표에서 뉴런수가 10개인 경우 동적터널링 과정이 수행되었다. 이는 영상데이터 내의 비선형성이 많고 적응에 따라거나 특징층의 뉴런수에 따라서 국소최소해가 존재하며, 그에 따라 동적터널링이 수행될 수도 있고 안될 수도 있다는 것을 확인할 수 있다. <표 4>에서 기존 알고리즘과 제안된 알고리즘을 비교하여 볼 때 PSNR 값에서는 특징층 뉴런수가 10개와 20개일 때 제안된 알고리즘이 기존의 알고리즘보다 우수하며, 나머지의 뉴런수에 대해서는 거의 유사한 값을 가짐을 알 수 있다.

<표 4> 특징층 뉴런수의 변화에 따른 결과

알고리즘 뉴런수	기존 알고리즘			제안된 알고리즘		
	$N_c$	$C_t$	PSNR	$N_c(N_m, N_{at})$	$C_t$	PSNR
10	20000	13346	74.532257	6926(6916,10)	4480	77.776726
20	20000	14848	76.749329	2973(2973,0)	3148	78.131065
30	16268	13484	78.130821	1371(1371,0)	1508	78.130990
40	5803	3837	78.131180	799(799,0)	717	78.132416

한편, (그림 5)는 얼굴영상을 대상으로 기존의 NLPCA 알고리즘과 제안된 알고리즘을 각각 이용한 오차값의 변화를 나타낸 것이다. 이때도 (그림 2)에서와 마찬가지로 학습율은 0.001로 은닉층 뉴런수는 110개, 특징층 뉴런수는 40개로 설정하였다. 그림에서 제안된 알고리즘의 반복수가 300회 정도부터 오차값은 거의 일정하게 유지되며, 기존의 알고리즘보다 빠른 수렴속성이 있음을 알 수가 있다.



(그림 5) 반복수에 따른 오차값의 변화

(그림 6)은 얼굴의 원영상과 2가지 알고리즘의 NLPCA로 복원된 영상을 나타낸다. 여기서도 (a)는 원 얼굴영상이며, (b)와 (c)는 각각 주어진 학습 종료조건을 만족할 때 40개의 주요특징을 추출한 후 이들을 이용하여 복원한 영상이다. 여기서 (그림 2)에서 복원된 영상들과는 달리 기존의 알고리즘과 제안된 알고리즘에 의해 복원된 영상인 (b)와 (c) 사이의 차이가 상대적으로 많지 않음을 알 수 있다. 이는 실험에 이용한 얼굴영상의 경우 앞의 간암영상에 비해 영상데이터 상호간의 비선형성이 적기 때문으로 추측된다. 여기에서도 간암영상에서처럼 원래의 영상과 복원된 영상을 정량적으로 비교하기 위한 이용된 정합도 계산식은  $100 - \frac{1}{128 \times 128} \sum_{i=1}^{128 \times 128} |x_i - y_i|$ 이다. 그림에서 기존 NLPCA와 제안된 NLPCA에 의해 복원된 영상의 정합도는 각각 93.1과 93.2로 거의 유사한 특징추출 속성이 있음을 확인할 수 있다. 하지만, 간암영상과 얼굴영상에서 기존기법과 제안된 기법에 의해서 복원된 영상의 특징추출 결과를 비교하면 얼굴영상보다는 간암영상의 실험결과에서 더욱 더 큰 차이를 나타내어 상대적으로 규모가 큰 영상일수록 그 특징추출 성능이 우수함을 알 수 있다.



(a) 원영상 (b) 기존 NLPCA (c) 제안된 NLPCA  
(그림 6) 2 가지 학습알고리즘에 따른 복원된 128×128 픽셀의 얼굴영상들

#### 4. 결 론

본 논문에서는 새로운 학습알고리즘의 비선형 주요성분분석 신경망을 이용한 데이터의 효율적인 특징추출에 대하여 제안하였다. 제안된 학습알고리즘에서는 최적해로의 수렴에 따른 진동을 억제하여 빠른 수렴속도의 최적화가 가능하도록 하기 위해 모멘트를 이용하였고, 국소최적해를 만났을 때 이를 벗어난 전역최적해로의 수렴을 위한 새로운 연결가중치의 설정을 위하여 동적터널링을 이용함으로써 빠른 수렴속도로 전역최적해에 수렴되도록 학습시킬 수 있다.

제안된 학습알고리즘을 이용한 신경망을 256×256 픽셀의 간암영상과 128×128 픽셀의 얼굴영상들을 대상으로 시뮬레이션 한 결과, 기울기하강의 학습알고리즘을 이용한 기존 비선형 주요성분분석 신경망보다 우수한 수렴성과 특징추출성능이 있음을 확인할 수 있었다. 또한 규모가 큰 영상일수록 상대적으로 우수한 수렴특성이 있음을 알 수 있었다.

향후 좀더 빠른 최적화 기법을 이용한 학습알고리즘에 대한 연구가 계속 진행되어야 하며, 영상인식 등과 같은 다양한 분야의 적용에 대한 연구도 남아 있다.

### 참 고 문 헌

- [1] S. Y. Kung, "Digital Neural Networks," Prentice Hall, Int., Inc., Englewood Cliffs, New Jersey, pp.269-310, 1993.
- [2] J. Hertz, A. Krogh, and R. G. Palmer, "Introduction to the Theory of Neural Computation," Santa Fe Institute, Lecture Notes, Vol.1, pp.197-250, 1995.
- [3] S. Haykin, "Neural Networks : A Comprehensive Foundation," Prentice-Hall, 2ed., London, pp.392-442, 1999.
- [4] M. Arozullah and A. Namphol, "A Data Compression System Using Neural Network Based Architecture," International Joint Conference on Neural Networks, San Diego, Vol.1, pp.531-536, June 1990.
- [5] J. A. Freeman and D. M. Skapura, "Neural Networks : Algorithms, Applications, and Programming Techniques," Addison Wesley, London, pp.89-125, 1991.
- [6] Mark A. Kramer, "Nonlinear Principal Component Analysis Using Autoassociative Neural Networks," AIChE Journal, Vol.37, No.2, pp.233-243, Feb. 1991.
- [7] E. C. Malthouse, "Limitations of Nonlinear PCA as Performed with Generic Neural Networks," IEEE Transactions on Neural Networks, Vol.9, No.1, pp.165-173, Jan. 1998.
- [8] D. Tzovaras and M. G. Strintzis, "Use of Nonlinear Principal Component Analysis and Vector Quantization for Image Coding," IEEE Transactions on Image Processing, Vol.7, No.8, pp.1218-1223, Aug. 1998.
- [9] F. D. Frate and G. Schiavon, "Nonlinear Principal Component Analysis for the Radiometric Inversion of Atmospheric Profiles by Using Neural Networks," IEEE Transactions on Geoscience and Remote Sensing, Vol.37, No.5, pp.2335-2342, Sep. 1999.
- [10] N. Qian, "On the momentum term in gradient descent learning algorithms," Elsevier Science Ltd., Neural Networks, pp. 145-151, Dec. 1999.
- [11] Y. Yao, "Dynamic Tunneling Algorithm for Global Optimization," IEEE Trans. On Systems, Man, and Cybernetics, Vol.19, No.5, pp.1222-1230, Sept/Oct. 1989.



### 조 용 현

e-mail : yhcho@cuth.cataegu.ac.kr

1979년 경북대학교 공과대학 전자공학과 (공학사)

1981년 경북대학교 대학원 전자공학과 (공학석사)

1993년 경북대학교 대학원 전자공학과 (공학박사)

1983년~1984년 삼성전자(주) 사원

1984년~1987년 한국전자통신연구소 연구원

1987년~1997년 영남전문대학 전자과 부교수

1997년~현재 대구가톨릭대학교 컴퓨터정보통신공학부 부교수

관심분야 : 신경망, 병렬분산처리, 신호처리, 영상인식, 교환기 등



### 윤 중 환

e-mail : jhyun21@intizen.com

1999년 경일대학교 컴퓨터공학과 졸업 (학사)

2001년 대구가톨릭대학교 대학원 전산통계학과 졸업(석사)

2001년~현재 (주)나라비전 근무

관심분야 : 뉴럴 네트워크 및 퍼지 이론, 이미지 프로세싱



### 박 용 수

e-mail : timpark@chollian.net

1979년 경북대학교 전자공학과 졸업(학사)

1981년 경북대학교 대학원 전자공학과 졸업(석사)

1985년~1992년 LG반도체(주) 근무

1993년~1994년 반도체 엔지니어링(주) 근무

1999년~2000년 포항직업전문학교 교사

1999년~2001년 대구가톨릭 대학교 박사과정 수료

2001년~현재 대구기능대학 및 포항1대학 시간강사

관심분야 : Neural Network, Fuzzy system, 진화 연산, 이미지 프로세싱