

비선형 특징추출을 위한 신경망의 학습성능 개선

Improvement on Learning Performance of Neural Networks for Extracting Nonlinear Features

조용현, 윤중환[†], 성주원[†]

Yong-Hyun Cho, Jung-Hwan Yun, Ju-Won Sung

대구가톨릭대학교 컴퓨터정보통신공학부
g9521008@cuth.cataegu.ac.kr

요약

본 논문에서는 새로운 학습알고리즘의 비선형 주요성분분석 신경망을 이용한 데이터의 효율적인 특징추출에 대하여 제안하였다. 제안된 학습알고리즘에서는 모멘트와 동적터널링을 조합하여 이용함으로써 최적해로의 수렴에 따른 발진을 억제하고 빠른 수렴속도로 전역최적해에 수렴되도록 학습시킬 수 있다. 제안된 학습알고리즘을 이용하여 128×128 픽셀의 얼굴영상과 256×128 픽셀의 자동차번호판 영상을 대상으로 시뮬레이션 한 결과, 기율기하강의 학습알고리즘을 이용한 기존 비선형 주요성분분석 신경망보다 우수한 수렴성능과 특징추출성능이 있음을 확인 할 수 있었다.

1. 서론

특징추출은 인식이나 분류와 같은 문제에서 데이터의 사용을 용이하게 하기 위해 속성이나 두르러진 형상을 식별하기 위한 것이다. 이러한 데이터의 특징들을 추출하기 위한 많은 기법들이 제시되어 왔다^[1,2].

주요성분분석(principal component analysis : PCA)은 주어진 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, 주요특징을 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 실시간 처리가 요구되는 응용문제에서는 매우 비효율적이다.

최근 대규모의 병렬계산과 학습, 그리고 일반화 속성을 가지는 신경망은 신호와 영상처리 분야에 많은 관심이 되어 왔다^[3]. 이러한 속성을 가진 신경망에 기반을 둔 여러 가지 PCA 기법들이 변환에 기반을 둔 방법들의 대안으로 이용되고 있다. 지금까지의 대부분 방법들^[4,5]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 추

출하는 데는 어려움이 있다^[1,3]. 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) 학습알고리즘에 기반을 둔 다층신경망(multilayer perceptron:MLP)이 제안되었다^[3]. 그러나 기율기하강(steepest descent)의 속성을 이용하는 역전파 알고리즘은 학습과라미터의 설정에 따라 수렴속도와 견실성 중 하나 이상의 제약을 가지며, 전역최소로의 수렴도 보장되어 있지 않다.

Kramer는 비선형 특징들을 추출하기 위하여 5층으로 구성되는 신경망을 제안하고 이를 여러 분야에 응용하였다^[3]. Tzovaras 등은 영상처리분야에^[5] 응용하였다. 그러나 Kramer의 NLPCA를 위한 신경망은 데이터 내에 존재하는 비선형 속성의 추출을 위해 5층의 신경망을 이용하여 이를 학습시키는데 매우 오랜 시간이 걸린다는 제약이 있다^[4]. 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 학습시킬 수 있도록 입력데이터의 주요특징을 보다 빠르고 정확하게 추출되도록 하였다. 제안된 학습알고리즘을 이용한 신경망을 128×128 픽셀의 얼굴영상과 256×128 픽셀의 자동차 번호판 영상을 대상으로 시뮬레이션한 후 그 타당성을 확인하였으며, 기존의 역전파 알고리즘에 기반을 둔 Kramer의 NLPCA 신경망에 의한 결과와 비교 고찰하였다.

2. 모멘트와 동적터널링을 조합한 NLPCA를 위한 신경망의 효율적인 학습알고리즘

NLPCA는 PCA의 방법과 같은 수단으로 다변량 데이터의 분석을 위한 새로운 기법이다. 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 분포에 닮은 특징공간을 생성함으로써 차원을 축소시키기 위함이다. 그림 1은 NLPCA를 위한 신경망의 구조를 나타낸 것이다.




그림 1. NLPCA를 위한 신경망 구조

그림에서 계층 1과 계층 2로 이루어진 부분 망은 입력데이터를 특징공간으로 사상하는 부호화 망이다. 여기서 특징층 뉴런 수 p 는 입력층 뉴런 수 n 보다 적은 수를 가지게 한다. 또한 그림의 계층 2에서 계층 4까지는 입력데이터의 주요특징들을 출력층으로 사상하는 복호화 망이다. 일반적으로 비선형 사상을 위해 부호화 망과 복호화 망에서의 각 계층 1과 3은 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 신경망에서 각각 $a_i(l)$ 를 계층 l 의 i 번째 뉴런 활성화 함수, $u_i(l)$ 를 계층 l 의 연결강도와 계층 $l-1$ 의 입력값의 곱으로 계산되는 가중된 합, $w_{ij}(l)$ 를 계층 l 의 i 번째 뉴런과 계층 $l-1$ 의 j 번째 뉴런 사이의 연결강도, 그리고 $\theta_i(l)$ 를 계층 l 의 뉴런 i 를 위한 바이어스(bias)라 할 때, $a_i(l)$ 과 $u_i(l)$ 는 각각 다음과 같이 나타낼 수 있다. 즉,

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

$$u_i(l) = \sum_{j=1}^{n_{l-1}} w_{ij}(l) a_j(l-1) + \theta_i(l) \quad (2)$$

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

$$E(w) = \frac{1}{p} \sum_p E_p(w) \quad (3)$$

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

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,

$$w_{ij}(t+1) = w_{ij}(t) + \beta \delta_i(l) a_j(l-1) \quad (4)$$

$$\delta_i(4) = a_i(4) - x_i \quad (5)$$

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

$$a_i(l) = \begin{cases} 1 & \text{if } l=2 \\ f'(u_i(l)) & \text{otherwise} \end{cases} \quad (6)$$

이다. 여기서 β 는 학습율이며, f' 은 비선형 활성화 함수 f 의 미분을 의미한다.

이 기법에서는 식 (4)에서 나타나듯이 연결가중치의 경신에 있어서 단순히 오차에 대한 미분값만을 고려하였으며, 과거의 속성을 반영하는 모멘트 항은 고려되지 않았다. 따라서 최소화 과정에서 발생하는 발진을 없애기 위해 학습알고리즘에 모멘트 항^[6]을 추가하면 모멘트가 가지는 속성을 그대로 얻을 수 있을 것이다. 즉, 식 (4)에 따라 가중치를 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,

$$w_{ij}(t+1) = w_{ij}(t) + \beta \delta_i(l) a_j(l-1) + \alpha \Delta w_{ij}(t-1) \quad (7)$$

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

한편, 동적터널링 알고리즘은 동적최적화와 동적터널링 과정으로 구성된다^[7]. 여기서 동적최적화는 초기상태로부터 국소최소값 중의 한 값을 찾는 과정이며, 동적터널링은 찾은 국소최소값보다 하위유역에 위치한 새로운 초기상태를 찾는 과정이다. 결국 동적터널링은 동적최적화에 의해 국소최소에 빠지는 것을 막아준다. 따라서 NLPCA를 위한 신경망에서 연결가중치 w 에 대한 오차함수 $E(w)$ 을 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 ε 이 추가된 새로운 시작점에서 출발하는 것으로 다음과 같은 미분방정식의 형태로 주어진다.

$$\Delta_p w = -(\partial E_p(w)/\partial w) [1/[(w-w^*)^T(w-w^*)]^\gamma - \xi E_p^*(E_p^\wedge(w))] \quad (8)$$

여기서, ξ 는 터널링페널티(tunneling penalty)이고 γ 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.

$$E_p^*(z) = \begin{cases} z & (z \geq 0) \\ 0 & (z < 0) \end{cases} \quad (9)$$

식 (8)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 하위유역에 존재하는 즉, $E_p(w^{(0)}) \leq E_p(w^*)$ 인 새로운 초기상태 $w^{(0)}$ 를 찾기 위한 것이다. 그러므로 동적터널링에 의한 학습알고리즘의 연결가중치 경

신식은 식 (8)과 같으며, 여기서 계층 4, 계층 3, 계층 2, 그리고 계층 1의 $(\partial E_p(w)/\partial w)$ 는 다음의 식과 같이 정의된다. 즉,

$$\partial E_p(w)/\partial w_{ij}(l) = -\beta\delta_i(l)\alpha_j(l-1) \quad l=4,3,2,1 \quad (10)$$

이다. 여기서도 $\delta_i(l)$ 은 각각 식 (5)와 (6)로 주어진다. 따라서 식 (8)와 (10)이 조합된 동적터널링과 모멘트에 기초한 제안된 NLPCA 신경망의 학습알고리즘에서 각 층의 연결가중치 경신식은 다음과 같다. 즉,

$$w_{ij}(t+1) = w_{ij}(t) + \beta\delta_i(l)\alpha_j(l-1)[1/[(w-w^*)^T(w-w^*)] - \xi E_p^*(E_p^*(w))] + \alpha\Delta w_{ij}(t-1) \quad l = 4,3,2,1 \quad (11)$$

이다. 결국 제안된 NLPCA 신경망의 학습알고리즘은 먼저 모멘트 항을 이용한 식 (7)의 경신식으로 학습을 수행하다 오차의 변화가 일어나지 않거나 그 변화량이 설정치 이하이면 국소최소값에 수렴된 것으로 가정하고 다음의 동적터널링과 모멘트를 조합한 식 (11)의 경신식으로 학습을 수행한다. 이 과정의 반복수행으로 신경망을 학습하면 빠른 시간 내에 학습이 가능하여 효과적으로 데이터의 비선형 주요성분분석이 가능하다.

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

$$PSNR = 20 * \log_{10}(255/RMSE) \quad (12)$$

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 5층의 전향신경망을 구성하였다. 이 신경망에서 각 뉴런간의 초기 연결가중치는 랜덤시드(random seed)의 변화에 의해서 각각 -0.5에서 +0.5사이 임의의 값으로 설정하였다. 학습은 전체 반복회수가 20,000회 이상이거나 전체 오차함수 값이 설정치 이하일 때 종료되도록 하였다.

제안된 학습알고리즘의 5층 전향신경망을 128×128 픽셀의 얼굴영상과 256×128 픽셀의 자동차 번호판 영상을 대상으로 시뮬레이션한 후 그 타당성을 확인하였으며, 기존의 기율기하강에 기초한 NLPCA를 위한 학습알고리즘의 5층 전향신경망 결과들과 비교하였다.

3.1 얼굴영상

데이터의 주요특징추출을 위해 128×128 픽셀의 얼굴영상을 이용하였다. 실험에 이용된 영상은 한 개의 학습표본으로 64개 픽셀을 가지는 전체 256개의 표본을 연속으로 정렬하였다. 실험에서 전체 신경망의 입력뉴런과 출력뉴런수는 각각 64개로 하였으며, 종료를 위한 전체 오차함수의 설정치는 10^{-3} 으로 하였다.

표 1은 특징층의 뉴런수를 40 개로 고정하고 은닉층 뉴런수에 따라 학습시킨 결과, 주어진 종료조건이 만족될 때의 반복회수와 CPU 시간과 PSNR의 값을 나타낸 것이다.

주어진 조건에 수렴하는 동안 제안된 알고리즘에서는 국소최소해로의 수렴은 발생되지 않아 모멘트의 속성만 이용되었다. 또한 기존 알고리즘이나 제안된 알고리즘 사이의 PSNR값을 비교해보면 거의 유사한 값을 가진다. 하지만 반복회수와 수렴시간

면에서는 각각 제안된 알고리즘은 기존의 알고리즘보다 평균적으로 약 8.3 배정도와 약 6.2 배정도 개선되었음을 알 수 있어 그 우수한 성능을 확인할 수 있다.

표 1. 은닉층 뉴런수의 변화에 따른 결과

| 알고리즘 뉴런수 | 기존 알고리즘 | | | 제안된 알고리즘 | | |
|-------------|---------|-------|-----------|-----------------|-------|-----------|
| | N_c | C_c | PSNR | $N_c(N_m, N_a)$ | C_c | PSNR |
| 70 | 8052 | 3442 | 78.130943 | 850(850.0) | 489 | 78.129539 |
| 75 | 6643 | 3055 | 78.130890 | 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 2는 은닉층 뉴런수를 110 개로 고정하고 특징층 뉴런수의 변화 따라 학습시킨 결과, 주어진 학습 종료조건이 만족될 때의 반복회수와 CPU 시간과 PSNR의 값을 나타낸 것이다. 여기서도 제안된 알고리즘이 기존의 알고리즘보다 반복회수와 수렴시간에서 평균적으로 약 7.2 배 및 약 5.5 배정도 개선됨을 알 수 있다. 그리고 기존 알고리즘에서 특징층 뉴런수가 10 개, 20 개인 경우는 주어진 조건에 수렴되지 않아 학습 반복수가 20000까지 되었다. 이런 경우에 제안된 알고리즘에서는 주어진 조건으로 수렴한다는 것을 알 수가 있었다. 특히 표에서 뉴런수가 10 개인 경우 동적터널링 과정이 수행되었다. 이는 영상데이터 내의 비선형성이 많고 적응에 따라서나 특징층의 뉴런수에 따라서 국소최소해가 존재하며, 그에 따라 동적터널링이 수행될 수도 있고 안될 수도 있다는 것을 확인할 수 있다. 표에서 기존 알고리즘과 제안된 알고리즘을 비교하여 볼 때 PSNR값에서는 특징층 뉴런수가 10 개와 20 개일 때 제안된 알고리즘이 기존의 알고리즘보다 우수하며, 나머지의 뉴런수에 대해서는 거의 유사한 값을 가짐을 알 수 있다.

표 2. 특징층 뉴런수의 변화에 따른 결과

| 알고리즘 뉴런수 | 기존 알고리즘 | | | 제안된 알고리즘 | | |
|-------------|---------|-------|-----------|-----------------|-------|-----------|
| | N_c | C_c | PSNR | $N_c(N_m, N_a)$ | C_c | 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 | 78.130890 |
| 40 | 5803 | 3837 | 78.131180 | 799(799.0) | 717 | 78.132416 |

그림 3은 얼굴의 원영상과 2가지 알고리즘의 NLPCA로 복원된 영상을 나타낸다. 그림 3(a)는 원 얼굴영상이며, (b)와 (c)는 각각 주어진 학습 종료조건을 만족할 때 40 개의 주요특징을 추출한 후 이들을 이용하여 복원한 영상이다.



(a) 원영상 (b) 기존 NLPCA (c) 제안된 NLPCA

그림 3. 2 가지 학습알고리즘에 따른 복원된 128×128 픽셀의 얼굴영상들

기존의 알고리즘과 제안된 알고리즘에 의해 복원된 영상인 (b)

와 (c) 사이의 차이가 상대적으로 많지 않음을 알 수 있다. 이는 영상데이터 상호간의 비선형성이 적기 때문으로 추측된다.

3.3 자동차 번호판

다음 실험에서는 얼굴영상에 비해 규모가 큰 256×128 픽셀의 자동차 번호판을 이용하여 실험하였다. 앞의 실험과 마찬가지로 64 픽셀을 한 개의 학습표본으로 하는 전체 512 개의 표본을 가지도록 연속으로 정렬하였으며 입력뉴런과 출력뉴런수는 각각 64 개로 하고 허용오차함수의 설정치를 10^{-3} 으로 하였다.

표 3에서도 표 1과 마찬가지로 특징층 뉴런수를 40 개로 고정하고 은닉층 뉴런수에 따라 학습시킨 결과, 주어진 조건에 수렴하는 동안 제안된 알고리즘에서는 표 1처럼 국소최소해로의 수렴은 발생되지 않아 모멘트의 속성만 이용되었다. PSNR값을 비교해보면 제안된 알고리즘을 이용한 신경망의 PSNR값이 높다는 것을 알 수 있다. 그리고 반복회수와 수렴시간 면에서도 앞의 실험에서와 마찬가지로 제안된 알고리즘은 기존의 알고리즘보다 평균적으로 약 6.5 배정도과 약 5 배정도 개선되었음을 알 수 있어 그 우수한 성능을 확인할 수 있다.

표 3. 은닉층 뉴런수의 변화에 따른 결과

| 뉴런수 | 기존 알고리즘 | | | 제안된 알고리즘 | | |
|-----|---------|-------|-----------|-----------------|-------|-----------|
| | N_c | C_t | PSNR | $N_c(N_m, N_d)$ | C_t | PSNR |
| 70 | 3208 | 2896 | 78.130870 | 366(366.0) | 423 | 78.136803 |
| 75 | 2453 | 2244 | 78.131699 | 429(429.0) | 536 | 78.135033 |
| 80 | 2943 | 2874 | 78.131195 | 377(377.0) | 499 | 78.135361 |
| 85 | 2587 | 2684 | 78.131844 | 434(434.0) | 605 | 78.134277 |
| 90 | 2645 | 2889 | 78.131966 | 395(395.0) | 589 | 78.135826 |
| 95 | 2610 | 3013 | 78.130981 | 362(362.0) | 572 | 78.134041 |
| 100 | 2696 | 3977 | 78.131149 | 436(436.0) | 813 | 78.136581 |
| 110 | 2281 | 3031 | 78.131454 | 401(401.0) | 728 | 78.137756 |
| 120 | 2410 | 3497 | 78.131500 | 372(372.0) | 731 | 78.137428 |

표 4도 표 2에서처럼 은닉층 뉴런수를 110 개로 고정하고 특징층 뉴런수의 변화 따라 학습시킨 결과, 표 2에서와 마찬가지로 주어진 학습 종료조건이 만족될 때의 반복회수와 CPU 시간과 PSNR의 값을 나타낸 것이다. 여기서도 제안된 알고리즘이 기존의 알고리즘보다 반복회수와 수렴시간에서 평균적으로 약 5 배 및 약 3.7 배정도 개선됨을 알 수 있다. 여기서는 표 2와 달리 동적터널링이 수행되지 않았으며 모멘트의 성질만 이용되었다. 그 이유는 실험 데이터가 가지는 속성면에 있어 얼굴영상보다 비선형성이 적다는 것을 알 수 있고 학습의 진행과정에서 국소 최소해에 수렴하는 경우가 발생하지 않았다는 것을 알 수 있다.

표 4. 특징층 뉴런수의 변화에 따른 결과

| 뉴런수 | 기존 알고리즘 | | | 제안된 알고리즘 | | |
|-----|---------|-------|-----------|-----------------|-------|-----------|
| | N_c | C_t | PSNR | $N_c(N_m, N_d)$ | C_t | PSNR |
| 10 | 13097 | 12736 | 74.651917 | 5286(5286.0) | 6773 | 78.130867 |
| 20 | 9284 | 10023 | 76.562996 | 1901(1901.0) | 2741 | 78.131767 |
| 30 | 3751 | 4514 | 78.131355 | 542(542.0) | 884 | 78.131050 |
| 40 | 2281 | 3031 | 78.131454 | 401(401.0) | 728 | 78.137756 |

그림 4은 자동차 번호판의 원영상과 2가지 알고리즘의 NLPCA로 복원된 영상을 나타낸다. 그림 4(a)는 원 얼굴영상이며, (b)와 (c)는 각각 주어진 학습 종료조건을 만족할 때 40 개의 주요특징을 추출한 후 이들을 이용하여 복원한 영상이다.

여기서는 그림 3과는 달리 기존의 알고리즘에 의해 복원된 영상(b)이 제안된 알고리즘을 이용하여 복원된 영상(c)보다 잡음이 많다는 것을 알 수 있고 데이터 내의 특징들이 잘 추출되지 못하였다.



(a) 원영상 (b) 기존 NLPCA (c) 제안된 NLPCA

그림 4. 2 가지 학습알고리즘에 따른 복원된 256×128 픽셀의 자동차 번호판들

4. 결론 및 향후과제

본 논문에서는 새로운 학습알고리즘의 비선형 주요성분분석 신경망을 이용한 데이터의 효율적인 특징추출에 대하여 제안하였다. 제안된 학습알고리즘에서는 모멘트와 동적터널링을 조합함으로써 최적해로의 수렴에 따른 발진을 억제하여 빠른 수렴속도로 전역최적해에 수렴되도록 학습시킬 수 있다.

제안된 학습알고리즘을 이용한 신경망을 128×128 픽셀의 얼굴영상과 256×128 픽셀의 자동차 번호판을 대상으로 시뮬레이션 한 결과, 기울기하강의 학습알고리즘을 이용한 기존 비선형 주요성분분석 신경망보다 우수한 수렴성능과 특징추출성능이 있음을 확인할 수 있었다.

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

5. 참고문헌

- [1] K. I. Diamantaras and S. Y. Kung, 'Principal Component Neural Networks : Theory and Applications, Adaptive and Learning Systems for Signal Processing, Communication, and Control,' John Wiley & Sons, Inc., New York, 1996.
- [2] S. Haykin, 'Neural Networks : A Comprehensive Foundation,' Prentice-Hall, 2ed., London, 1999.
- [3] Mark A. Kramer, "Nonlinear Principal Component Analysis Using Autoassociative Neural Networks," AIChE Journal, Vol.37, No.2, pp.233-243, Feb. 1991.
- [4] 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.
- [5] 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.
- [6] N. Qian, "On the momentum term in gradient descent learning algorithms," Elsevier Science Ltd., Neural Networks , pp.145-151, Dec. 1999.
- [7] 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.