

교사학습과 비교사 학습의 접목에 의한 학습패턴의 생성*

Generation of Exemplar Patterns for Training Through the Merge of Supervised and Unsupervised Learning

오상훈

목원대학교 정보통신전파공학부

Oh Sang-Hoon

Div. of Information Communication Eng.,
Mokwon University

요약

시간/경제적 문제 혹은 수집 대상의 제한으로 충분한 수의 학습패턴을 모을 수 없는 경우에 인간의 두뇌를 모방한 교사학습 및 비교사학습 모델을 이용하여 새로운 학습패턴을 생성한 후 이를 이용하여 학습한 경우 성능이 향상됨을 시뮬레이션을 통하여 확인하였다.

Abstract

In the case that we do not have enough number of training patterns because of limitation such as time consuming, economic problem, and so on, we generate a new patterns using the brain-style information processing algorithm, that is, supervised and unsupervised learning methods. The proposed method is verified through the simulation of handwritten digits.

I. 서론

뇌 정보처리 방식의 공학적 응용을 다루는 뇌공학에서 현재 활용 및 개발 중인 학습 알고리즘은 크게 교사 학습(supervised learning)과 비교사 학습(unsupervised learning)으로 대별되며, 그 각각이 뇌의 이해를 기반으로 한다. 대표적인 예로, 가장 널리 활용되는 교사학습 모델인 퍼셉트론(Perceptron)은 Albus와 Marr의 이론적 고찰과 Masao Ito의 실험적 고찰에 의해 소뇌의 작용과 비슷하다는 것이 알려졌다[1,2]. 또한, 최근에 각광을 받고 있는 비교사 학습 모델인 ICA(Independent Component Analysis)에 의해 Bell과 Sejnowski는 시각 피질의 V1 layer에 존재하는 simple cell의 특성을 재현하였

으며[3], Apo Hyvarinen은 topographic ICA 방법에 의해 simple feature들의 self organizing 특성도 보였다[4,5]. 이수영 교수팀은 음성신호를 대상으로 ICA 학습을 실시하여 추출된 특징이 귀의 달팽이관 에서 추출되는 청각특징과 유사함을 보였다[6].

이제까지 교사학습과 비교사 학습은 주로 각각의 고유한 영역 내에서 연구가 수행되었다. 그렇지만, 이와 같은 교사학습과 비교사 학습의 접목은 그 각각이 나타낼 수 없었던 많은 효과를 얻을 수 있을 것이다 [7,8]. 본 연구는 이 중 패턴인식, 음성인식, 의료진단 (medical diagnosis) 등에 활용이 가능한 "비교사 학습과 교사학습의 접목에 의한 학습패턴 생성 알고리즘"을 개발 하고자 한다.

이와 관련된 연구는 크게 세 가지 형태로 진행되어 왔다. 그 첫 번째는 현재의 학습패턴에 단지 random noise를 더하는 형태로 학습패턴을 변형시키는 방법

* 이 논문은 학술진흥재단의 지원에 의하여 연구되었음 (KRF-2003-003-D00245)

이다[9,10,11]. 두 번째는 이 보다 조금 더 진전된 형태로써 수집된 학습 패턴을 부분적 요소가 없는 missing 패턴과 모든 요소가 제대로 갖추어진 complete 패턴으로 분류하여, missing 패턴의 복원을 시도하는 방법이다[12,13]. 마지막 세 번째 방법은 학습패턴의 prototype을 설정한 후, RDT(random deformation technique)를 적용하여 특정 class에 속하는 패턴들을 생성시키는 방법이다[14]. 그렇지만, 이 방법은 RDT의 적용 결과 생성된 패턴이 특정 class에 속하는 지 여부를 사람의 눈으로 판단하므로, 결국 사람이 일일이 개입하는 방식이다.

이와 달리, 본 연구에서는 기본 패턴을 근거로 학습 패턴 자체를 자동으로 생성시키는 알고리즘을 개발하고자 하는 것으로써, 이상의 방법과는 확연히 차이가 있다. 즉, 비교사 학습에 의해 패턴들의 특성을 분석해내고, 그 특성을 반영시켜 기본 패턴들의 변형을 만들어 내하고자 한다. 이렇게 생성된 변형패턴들은 교사학습모델에 입력시켜 특정 class에 속하는 지를 판정하도록 하고자 한다.

II. 비교사 및 교사 학습 모델

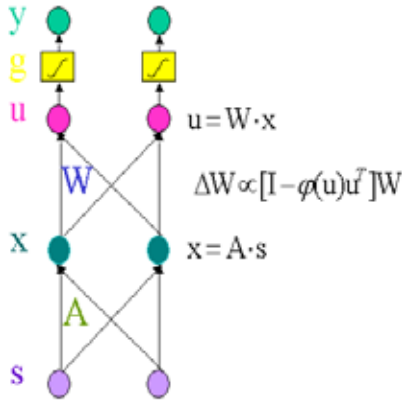
1. 독립성분석을 이용한 패턴 생성

비교사 학습과 교사학습의 접목에 의한 학습패턴 생성 알고리즘 개발 목적을 달성하기 위하여, 비교사 학습 모델은 최근에 개발된 ICA 알고리즘을 기반으로 한다. ICA란 그림 1과 같이 상호 독립적인 신호원들(s)이 섞여서 측정된 신호들(x)로부터, 상호 독립적이라는 것 이외에는 신호원들에 대한 정보가 전혀 없다는 가정 하에, 신호원을 다시 복원해 내는 학습 방법이다. 즉, ICA가 주어진 데이터에서 변환을 거친 뒤의 출력(u)이 지닌 정보량 혹은 엔트로피가 최대가 되도록 학습을 수행하며, 그 결과 얻어지는 변환 벡터들은 독립성분에 대한 정보를 지니게 된다[16,17]. 특히, 입력신호와 분리해내고자 하는 신호의 수가 같지 않을 경우에도 이 방법을 적용하여 데이터 내부에


존재하는 구조를 파악할 수 있다[18]. ICA는 또 다른 측면에서 projection pursuit learning으로도 해석할 수 있으며[19], 이는 데이터가 지닌 특성을 잘 반영하는 projection 방향을 찾아내는 것으로 해석할 수 있다. 따라서, 데이터의 특성을 잘 반영하는 여러 개의 projection 방향을 ICA로 찾아내는 알고리즘을 개발한 후, 이를 기반으로 여러 가지로 변형된 학습패턴을 생성하는 알고리즘을 고안한다.

2. MLP를 이용한 과도변형패턴 제거

그 다음에 변형된 패턴 중 과도하게 변형된 것을 학습패턴의 대상에서 제외시키는 방법은 교사 학습 모델 중 가장 뛰어나다고 평가받는 MLP를 기반으로 고안한다. MLP는 그림 2와 같은 구조를 가지며, 학습에 의해 패턴을 분류하는 기능을 수행하는 데, 이때 학습에 의해 얻어진 MLP의 출력(y)은 입력패턴이 특정 class에 속할 확률을 나타낸다[20]. 또한 MLP의 각 계층은 패턴의 분류에 필요한 정보는 유지시키면서, 패턴의 분류에 필요치 않은 정보는 제거시키는 기능도 수행한다. MLP의 동작을 이러한 정보처리 관점에서 조명하여, Shannon's entropy의 일반화된 형태인 Renyi's entropy를 MLP의 학습에 도입하여 학습을 개선시킬 수도 있다[21]. 또한 학습 목적에 따라 중간층 뉴런들이 가지는 정보량을 조절하는 방법도 있다[22]. 본 연구에서는 MLP의 학습에 의한 패턴 분류기능 및 class 확률 표현 특성을 이용하여, 비교사 학습 방법에 의해 생성된 패턴 중 그 변형 정도가 과도하여 특정 class에 속하지 않는 패턴들은 제외시키는 기능을 수행토록 구조 설정 및 학습을 구현한다.



▶▶ 그림 1. ICA network 및 학습방법



▶▶ 그림 2. 다층퍼셉트론 구조

III. 학습패턴 생성

주어진 패턴들을 이용하여 ICA 알고리즘을 적용하여 얻어진 basis vectors를 이용하여 패턴들을 생성시키는 과정을 정리하면 다음과 같다. 주어진 학습패턴 x 는 PCA 분석을 수행하여

$$z = Vx \tag{1}$$

를 얻어낸다. 여기서 V 는 eigenvectors로 이루어진 행렬이다. 그 다음 z 에서 eigenvalues가 작은 성분

은 제거하여 차원이 축소된 vectors를 \hat{z} 이라 두자. 이 \hat{z} 에 대해 ICA를 적용시켜

$$u = W\hat{z} \tag{2}$$

를 얻게된다. 한편, u 는 그 요소들이 독립이 되도록 ICA 학습이 이루어졌으므로 u 의 확률밀도함수(p.d.f.: probability density function)는

$$p(u) = \prod_i p(u_i) \tag{3}$$


이다. 따라서, 학습에 의해 u 를 얻어낸 다음, $p(u_i)$ 에 따라 u 들을 발생시켜 역의 과정을 거쳐 x 를 만들어 낸다. 이것이 ICA를 이용하여 학습패턴을 생성하는 과정이다.

만약 $p(u_i)$ 를 정확히 알고 있다면 생성해내는 패턴들 역시 정확한 학습패턴일 것이다. 그렇지만 현실적으로 이를 제대로 알아내는 것은 힘들므로 이 논문에서는 $p(u_i)$ 가 Gaussian 분포를 지니도록 한다.

생성된 패턴들 중 과도한 변형 패턴의 제거는 MLP를 이용한다. 먼저, MSE를 이용한 MLP의 학습은 incorrect saturation을 유발하는 성질을 이용한다. 즉, MLP의 학습 시 목표값과 다른 포화영역에 출력값이 위치하게 되는 경우, 이는 다른 패턴들과 달리 학습이 아주 힘든 패턴이거나 혹은 잘못된 패턴으로 볼 수 있으므로 제거시킨다[20]. 기존의 학습패턴들과 새롭게 생성되었지만 MSE를 이용한 MLP의 학습에서 제거되지 않은 패턴들을 모아서, 일반화 성능을 검사하게 된다. 즉, 이 단계에서는 nCE를 이용한 MLP 학습[20]을 실시하여 주어진 학습패턴들을 대상으로 한 일반화 성능을 조사한다.


IV. 시뮬레이션

제안한 패턴생성 방법의 효용성을 확인하기 위하여 충분한 학습패턴 및 시험패턴을 확보하는 있는 CEDAR 데이터베이스를 사용하였다. 이 데이터베이스에 있는 18468개의 패턴으로 제안한 방법에 따라 학습패턴을 생성한 후, MLP의 MSE(mean squared error)에 따른 학습 시 incorrect saturation이 발생하는 패턴들을 제외 시킨 다음, 다음 MLP를 nCE 오차함수[20]를 최소화 시키는 방법으로 학습시켜 일반화 성능이 향상되는 지 확인하였다. 이때, PCA에 의한 차원 축소 후 얻어지는 벡터는 필기체 숫자의 eigenvalue를 조사하여 70 차원이 되도록 하였다.



▶▶ 그림 3. PCA에 의한 학습패턴 생성


패턴 생성은 PCA 출력단에 잡음을 첨가하는 방법과 이 논문에서 제안한 것과 같이 ICA의 출력단에 잡음을 첨가한 방법을 실시하여 보았다. 그 결과 PCA 출력단에 잡음을 첨가한 경우는 그림 3에서 보는 방화 같이 생성된 패턴이 기존 패턴에 잡음이 섞인 형태로 보인다. 그림 3에서 첫 열은 입력패턴, 2번째 열은 가우시안 잡음의 표준편차가 0인 경우 생성된 패턴, 3번째 부터는 차례로 가우시안 잡음의 표준편차가 0.1씩 증가하면서 생성된 패턴들이다.



▶▶ 그림 4. 제안한 방법에 의해 생성된 패턴

이와 반면에, ICA 출력단에 잡음을 더한 경우는 그림 4에서 보는 바와 생성된 패턴이 기존 패턴의 모양을 많이 유지하고 있음을 알 수 있다. 여기서 첫 열은 입력패턴, 2번째 열 부터는 가우시안 잡음의 표준편차가 0부터 0.1씩 증가하면서 생성된 패턴들이다.

이와 반면에, 본 논문에서 제안한 바와 같이 ICA 출력단에 잡음을 더한 경우는 그림 4에서 보는 것처럼 생성된 패턴이 기존 패턴의 모양을 많이 유지하고 있는 상태에서 패턴이 흐리게 변형되는 형태임을 볼 수 있다. 새로운 패턴 생성 효과를 확연히 보일 수 없는 이유는 앞 절에서 설명한 바와 같이 현실적으로 $p(u_i)$ 를 제대로 알아내는 것은 힘들므로 이 논문에서는 가우시안(Gaussian) 분포를 지니도록 하였기 때문이다. 여기서 첫 열은 입력패턴, 2번째 열 부터는 가우시안 잡음의 표준편차가 0부터 0.1씩 증가하면서 생성된 패턴들이다.



▶▶ 그림 5. 제안한 패턴 생성 후 일반화 성능 조사결과

그림 5는 그림 4와 같이 생성된 패턴들에 대하여 MSE를 이용한 MLP의 학습으로 과도 변형 패턴들을 제거한 후, nCE를 이용한 MLP의 학습으로 시험 패턴에 대한 오인식률을 조사한 그래프이다. 이 그림에서 x축은 패턴 생성 시 발생시키는 가우시안 잡음의 표준편차가 72번째 eigenvalue의 몇 배인지를 나타낸다. 학습패턴이 18468개, 9234개, 그리고 4617개인 경우에 각각 제안한 알고리즘을 적용시켜 얻은 결과이며, MLP의 초기 가중치를 10번 다르게 적용시켜 얻은 결과의 평균치를 그림으로 그렸다. 또한, 수치의 명확한 값을 알아보기 쉽도록 표1에 오인식률을 적어두었다. 먼저, 그림 5의 x축이 0인 경우는 패턴 미생성에 해당하는 경우로써, 오인식률이 각각 4.60%(학습패턴 수 18468개), 5.38%(학습패턴 수 9234개), 7.17%(학습패턴 수 4617개)이다. 한편, 패턴 생성 시 얻어진 시험패턴에 대한 오인식률의 평균값들 중, 학습 패턴이 18468개인 경우는 가우시안 잡음의 표준편차가 6배(n_sig=6)일 때 가장 좋은 결과인 오인식률 3.87%임을 표1에서 볼 수 있으며 이는 패턴 미생성인 경우보다 15.9%의 성능 향상이 있음을 나타낸다. 학습 패턴수 9234개인 경우는 n_sig가 7일 때 11.9%의 성능향상이 있으며, 학습 패턴 수 4617인 경우도 비슷한 성능 향상이 있다. 그렇지만, 비록 패턴 생성을 하더라도 기본적으로 학습패턴을 많이 가진 경우 보다 좋은 성능을 얻을 수 없음을 알 수 있다. 이는 앞에서 이야기 한 바와 같이 $p(u_i)$ 를 정확히 알고 있지 못하여 Gaussian 분포를 지닌다는 가정 하에 패턴 생성을 하였기 때문이다. 만약, $p(u_i)$ 를 정확히 안다면 훨씬 더 좋은 결과를 얻을 수 있을 것이다.

한편, 제안한 방법의 성능을 검증하기 위하여 입력 패턴에 임의의 잡음을 더하는 형태로 패턴을 생성한 경우 MLP를 이용한 일반화 성능도 조사하여 보았다. 학습 대상 및 패턴 생성을 위한 잡음의 표준편차 및 MLP의 학습방법은 그림 5의 경우와 동일하도록 하여 시뮬레이션 결과를 그림 6에 그렸다. 입력잡음에

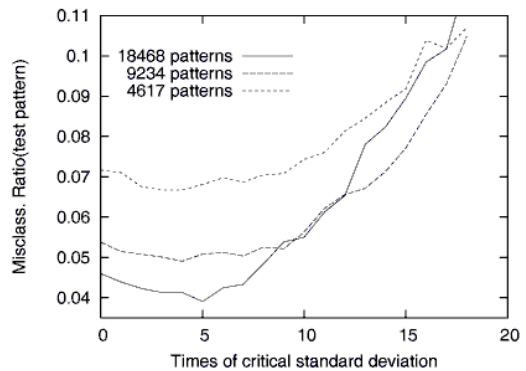
의해 얻어질 수 있는 향상된 오인식률은 표1에 정리된 바와 같이 3.91%(학습패턴 수 18468개), 4.91%(학습패턴 수 9234개), 6.67%(학습패턴 수 4617개)이다. 이는 표 1의 제안한 패턴생성 방법 결과보다 성능이 나쁨을 알 수 있다. 또한, 그림 6에서 보는 바와 같이 패턴 생성 잡음을 크게 할수록 오인식률이 아주 급격하게 나빠짐도 확인된다.

[표 1] 패턴 생성에 의해 얻어진 최고 성능의 시험패턴 오인식률

학습패턴수	18468	9234	4617
패턴미생성	4.60%	5.38%	7.17%
제안한 패턴생성	3.87% (n_sig=6)	4.74% (n_sig=7)	6.31% (n_sig=10)
입력잡음 패턴생성	3.91% (n_sig=5)	4.91% (n_sig=4)	6.67% (n_sig=3,4)

V. 결론

이 논문에서는 비교사학습인 ICA를 이용하여 패턴의 숨겨진 구조를 분석한 후 이를 바탕으로 새로운 학습패턴들을 생성시키고, 이 생성된 패턴들은 MSE를 최소화 시키는 MLP의 학습 후, incorrect saturation을 일으키는 패턴을 제외시키고 나서, 다시 nCE를 최소화시키는 MLP의 학습으로 일반화 성능이 향상됨을 확인하였다. 이 방법은 충분한 수의 학습패턴을 수집하기 힘든 상황에 적용하여 시스템의 성능을 향상시킬 수 있다.



▶▶ 그림 6. 입력 잡음 패턴 생성 후 일반화 성능 조사 결과

■ 참고문헌 ■

- [1] M. Tatsuno, "Computational Neuroscience-Methods in Neuronal modeling," Educational Lecture, BSI Retreat, Oiso, Japan, Sept. 18-20, 2000.
- [2] J. Albus, "A theory of cerebellar function," *Mathematical Biosciences*, vol. 10, pp. 25-61, 1971.
- [3] A. J. Bell and T. J. Sejnowski, "The independent components of natural scenes are edge filters," *Vision Research*, vol. 37, pp. 3327-3338, 1997.
- [4] A. Hyvarinen, P. O. Hoyer, and M. Inki, "Topographic independent component analysis," *Neural Computation*, vol. 13, no. 7, pp. 1527-1558, 2001.
- [5] A. Hyvarinen, P. O. Hoyer, and J. Hurri, "Extensions of ICA as models of natural images and visual processing," *Proceedings of ICA2003*, April 1-4, 2003, Nara, Japan.
- [6] J. H. Lee and S.-Y. Lee, "On the efficient speech feature extraction based on independent component analysis," *Neural Processing Letters*, accepted for publication.
- [7] U.-M. Bae and S.-Y. Lee, "A complementary approach to blind signal separation for real-world speech recognition," *Advances in Neural Information Processing Systems 13*, Nov. 2000.
- [8] I. V. Tetko and A. E. P. Villa, "Efficient partition of learning data sets for neural network training," *Neural Networks*, vol. 10, pp. 1361-1374, 1997.
- [9] C. Wang and J. C. Principe, "Training neural networks with additive noise in the desired signal," *IEEE Trans. Neural Networks*, vol. 10, pp. 1511-1517, 1999.
- [10] L. Holmstrom and P. Koistinen, "Using additive noise in back-propagation training," *IEEE Trans. Neural Networks*, vol. 3, pp. , 1992.
- [11] K. Matsuoka, "Noise injection into inputs in back-propagation learning," *IEEE Trans. Systems, Man, and Cybernetics*, vol. 22, no. 3, 1992.
- [12] S.-Y. Yoon and S.-Y. Lee, "Training algorithm with incomplete data for feed-forward neural networks," *Neural Processing Letters*, vol. 10, pp. 171-179, 1999.
- [13] Z. Ghahramani and M. Jordan, "Supervised learning from incomplete data via an EM approach," *Advances in Neural Information Processing Systems 6*, pp. 120-127, Nov. 1994.
- [14] B. Kamgar-Parsi, B. Kamgar-Parsi, J. E. Dayhoff, and A. K. Jain, "Improving classification boundaries by exemplar generation for visual pattern discrimination," *Proc. IJCNN2001*, vol. 4, pp. 2969-2974.
- [15] B. A. Olshausen and D. J. Field, "Emergence of simple-cell receptive field properties by learning a sparse code for natural images," *Nature*, vol. 381, pp. 607-609, 13 June, 1996.
- [16] T.-W. Lee, et al., "A unifying information-theoretic framework for independent component analysis," *Computers & Mathematics with Applications*, vol. 31, no. 11, pp. 1-21, March 2000.
- [17] S.-H. Oh, A. Cichocki, S. Choi, S.-I. Amari, and S.-Y. Lee., "Comparison of ICA/BSS algorithms in noisy environment," *Proc. ICONIP*, vol. 2, pp. 1192-1197, Nov. 2000.
- [18] M. Girolami, A. Cichocki, and S.-I. Amari, "A common neural-network model for unsupervised exploratory data analysis and independent component analysis," *IEEE Trans. Neural Networks*, vol. 9, no. 6, Nov. 1998.
- [19] J. Karhunen, et al., "A class of neural networks for independent component analysis," *IEEE Trans. Neural Networks*, vol. 8, pp. 486-504, 1997.
- [20] S.-H. Oh, "Improving the error back-propagation algorithm with a modified error function," *IEEE Trans. Neural Networks*, vol. 8, pp. 799-803, 1997.
- [21] J. C. Principe, et al., "Learning from examples with information theoretic criteria," *VLSI Signal Proc. Systems, special issue on neural networks*, accepted for publication.
- [22] R. Kamimura and S. Nakanishi, "Hidden information maximization for feature detection and rule discovery," *Network: Computation in Neural Systems*, vol. 6, pp. 577-602, 1995.