

다층 퍼셉트론에 의한 갑상선 질환 학습 방법 비교

Training of Hypothyroid Using Multilayer Perceptrons

오 상 훈
목원대학교

Sang-Hoon Oh
Mokwon University

요약

다층퍼셉트론은 학습성능이 우수하여 많은 패턴인식 문제에 응용되고 있다. 그 응용문제 중 하나인 갑상선 질환 진단 문제는 학습이 어려운 문제이다. 이 논문에서는 다층퍼셉트론으로 갑상선 진단 질환을 학습하는 여러 방법을 비교하고, 성능이 좋지 않은 원인을 토대로 성능 향상을 위한 방법을 제시하겠다.

1. 서론

MLP(multi-layer perceptron)는 충분한 중간층 노드가 있으면 임의의 함수를 근사화 시킬 수 있다는 이론적 연구결과[1]를 토대로 많은 응용분야에 적용되고 있다. 그렇지만, 어떤 경우에는 학습이 잘 되지 않는 응용문제가 있으며, 이 경우 MLP에 학습을 잘 시키기 위하여 다양한 방법들이 시도되고 있다. 갑상선 진단 문제[2]가 바로 여기에 해당하며, 이 논문에서는 MLP에 갑상선 진단 문제를 학습시키는 방법에 대하여 다루기로 한다.

MLP의 학습 시 학습속도 혹은 학습성능이 만족스럽지 못한 경우가 발견되었으며, 이를 해결하기 위하여 여러 가지 방법들이 시도되었다. MLP의 구조를 응용문제에 적합하게 변형시키는 방법과 MLP의 학습 기준으로 삼는 오차함수(error function) 혹은 목적함수(objective function)를 새롭게 제시한 방법이 대표적이다. MLP의 구조를 응용문제에 적합하게 제시하는 것은 휴리스틱한 면이 많으므로 여기서는 연구 내용에서 제외하기로 하며, 여러 가지의 오차함수 혹은 목적함수를 MLP의 갑상선 진단 학습에 적용하여, 그 성능을 비교하고자 한다.

MLP의 학습은 보통 MSE(Mean-Squared Error) 함수에 의해 이루어진다[3]. 그렇지만, 이 경우 출력노드의 부적절한 포화 현상에 의해 학습 속도가 상당히 저하되는 현상이 나타난다[4]. 이를 개선하기 위하여 CE(cross-entropy) 오차함수가 제시되었다[5]. 이 CE 오차함수는 MLP의 학습 시 발생하는 출력노드의 부적절한 포화(incorrect saturation) 현상을 제거하여 학습성능이 향상된다. 여기에 학습패턴에 대한 과도한 학습 방지 기능까지 지니도록 제시된 오차함수가 nCE(n-th order extension of Cross-Entropy) 오차함수이다[6]. 또한, MLP의 학습 시 MSE가 감소되는 방향이 인식성능이 향상되는 방향이 아니므로, 이를 개선한 CFM (Classification

Figure of Merit)도 제안되었다[7]. 이 논문에서는 MSE, CE, nCE, CFM을 먼저 간략히 소개하고, 이들을 갑상선 진단 문제 학습에 적용하여 그 결과를 비교하고자 한다.

2. MLP학습을 위한 여러 가지 오차함수

MLP에 임의의 학습패턴

$$\mathbf{x} = [x_1^{(p)}, x_2^{(p)}, \dots, x_M^{(p)}]^T \quad (1)$$

이 주어졌다고 하자. 여기서, $p=1, 2, \dots, P$ 는 학습패턴의 인덱스이다. 이 패턴이 특정 클래스에 속하는 정보는 인식기의 출력 $\mathbf{y} = [y_1, y_2, \dots, y_M]^T$ 에 대한 목표벡터에

$$t_k = \begin{cases} +1 & \text{if } x \in C_k \\ -1 & \text{otherwise} \end{cases} \quad (2)$$

와 같이 주어진다고 가정하자. 여기서, C_k 는 클래스 k의 집합을 나타낸다.

MLP의 학습은 임의의 학습패턴이 입력될 때, MLP의 출력 벡터 \mathbf{y} 와 목표벡터 \mathbf{t} 사이의 오차가 최소화 되도록 하는 것이다. 이 오차는 보통 MSE 함수

$$E_m = \frac{1}{P} \sum_{p=1}^P \frac{1}{2} \sum_{k=1}^M (t_k^{(p)} - y_k^{(p)})^2 \quad (3)$$

를 사용한다[3]. MSE를 최소화시키는 형태로 MLP를 학습 시 출력노드에서 부적절한 포화현상이 발생하기 쉬우며 학습속도가 저하된다[4].

이를 해결하기 위하여 제안된 CE 오차함수는

$$E_{CE} = -\frac{1}{P} \sum_{p=1}^P \sum_{k=1}^M [(1+t_k^{(p)}) \ln(1+y_k^{(p)}) + (1-t_k^{(p)}) \ln(1-y_k^{(p)})] \quad (4)$$

로 주어진다[5]. CE를 최소화 시키는 형태로 MLP를 학습 시키면 출력노드의 부적절한 포화 현상은 감소되지만, 학습패턴에 과도하게 학습되어 MLP의 시험패턴에 대한

일반화 성능이 저하된다[6].

MLP의 학습시 출력노드의 부적절한 포화 현상을 감소시키고, 학습패턴에 대한 과도한 학습을 방지하기 위하여 nCE 오차함수가

$$E_{nCE} = -\frac{1}{P} \sum_{p=1}^P \sum_{k=1}^M \int \frac{t_k^{(p)n+1} (t_k^{(p)} - y_k^{(p)})^n}{2^{n-2} (1 - y_k^{(p)})^2} dy_k^{(p)} \quad (5)$$

와 같이 제안되었다[6].

한편, $y_c^{(p)}$ 는 입력패턴이 속하는 클래스에 해당하는 출력노드이고, $y_k^{(p)}$ 는 다른 출력노드라고 하면, CFM은

$$CFM = -\frac{1}{P} \sum_{p=1}^P \sum_{k \neq c} \frac{1}{1 + \exp(-\beta(y_c^{(p)} - y_k^{(p)}))} \quad (6)$$

와 같이 주어지고[7], MLP는 CFM을 최소화시키는 방향으로 학습된다. 이는 MLP의 학습이 직접적으로 인식율을 증가시키는 방향으로 이루어지도록 하는 효과가 있다.

3. 갑상선 진단

UCI 기계학습 데이터저장소[2]의 갑상선진단 데이터베이스 "Ann-Thyroid"는 전체 7,200개의 데이터로 이루어져 있다. 하나의 데이터 벡터는 21개의 측정데이터와 클래스를 나타내는 3개의 데이터로 구성된다. 클래스는 환자의 갑상선 기능부전(hypothyroid) 상태를 나타내는데, 정상(normal), 갑상선 기능항진(hyperfunction), 그리고 기능저하(subnormal functioning)으로 구분된다. 7200개의 데이터 중 임의로 선택된 3600개는 학습에 사용하였으며, 1800개는 validation으로 사용하였고, 나머지 1800개는 시험패턴으로 사용하였다. 한편, 환자의 상태를 나타내는 7200개의 데이터 중 92.6%가 정상이다.

MLP의 구조는 입력노드 21개, 중간층 노드 16개, 출력노드 3개로 하였으며, $[-1 \times 10^{-4}, 1 \times 10^{-4}]$ 에서 초기 가중치를 임의로 설정하여 가중치 변경량을 계산 후 학습률 0.01을 사용하였다.

학습결과 MSE를 사용한 방법은 출력노드의 부적절한 포화 현상으로 인하여 시험 패턴에 대한 성능이 학습 과정 중에 상당히 많이 요동치는 현상을 보인다. 이러한 현상은 출력노드의 부적절한 포화를 감소시키는 작용이 없는 CFM에서도 마찬가지로 나타난다.

CE는 출력노드의 부적절한 포화 현상을 방지하는 학습특성 때문에 MSE와 CFM보다 좋은 성능을 보인다. nCE는 CE의 특성을 개선한 오차함수이므로, 역시 학습패턴 및 시험패턴에 대한 성능이 더 개선되었음을 보여준다.

한편으로, 갑상선 진단 데이터는 한 클래스가 92%를 차지하여 상당히 심각한 불균형을 이루고 있다. 이 이유 때문에 MSE와 CFM을 이용한 학습에서 출력노드의 부적

절한 포화가 심하게 나타나서 학습곡선이 요동치는 현상이 나타난 것이다. 또한, 불균형 데이터는 일반화 성능에도 큰 영향을 미친다. 이러한 불균형 데이터에 대한 학습 방법 역시 새로운 연구 대상이다[8]. 따라서, 갑상선 진단 문제의 학습을 위하여 불균형 데이터 학습 방법을 적용할 필요가 있다.

4. 결론

이 논문에서는 MLP에 갑상선 진단 문제를 학습시키는 방법을 비교하여 보았다. 비교 대상은 MLP의 학습을 위하여 사용되는 MSE, CE, nCE, CFM 함수로 정하였으며, 학습을 시킨 후 시험패턴에 대한 학습곡선으로 특성을 분석하였다. 그 결과, 출력노드의 부적절한 포화 현상을 감소시키는 작용을 하는 CE가 MSE와 CFM보다 좋은 성능을 보였다. 그리고, CE의 특성을 개선한 nCE가 제일 좋은 특성을 보였다. 한편, 갑상선 진단 문제는 불균형 데이터를 이루고 있으므로, 불균형 데이터의 학습 방법을 적용하여 갑상선 진단 문제를 다루어보아야 한다.

■ 참고 문헌 ■

- [1] K. Hornik, M. Stincombe, and H. White, "Multilayer feed-forward networks are universal approximators," *Neural Networks*, Vol. 2, pp. 359-366, 1989.
- [2] A. Frank and A. Asuncion, UCI Machine Learning Repository, <http://archive.ics.uci.edu/ml>, University of California, Irvine, School of Information and Computer Sciences, 2010.
- [3] D. E. Rumelhart and J. L. McClelland, *Parallel Distributed Processing*, MIT Press, Cambridge, MA, 1986.
- [4] Y. Lee, S.-H. Oh, and M. W. Kim, "An analysis of premature saturation in back-propagation learning," *Neural Networks*, Vol. 6, pp. 719-728, 1993.
- [5] A. van Ooyen and B. Nienhuis, "Improving the convergence of the back-propagation algorithm," *Neural Networks*, Vol. 4, pp. 465-471, 1992.
- [6] S.-H. Oh, "Improving the error back-propagation with a modified error function," *IEEE Trans. Neural Networks*, Vol. 8, pp. 799-803, 1997.
- [7] J. B. Hampshire II and A. H. Waibel, "A novel objective function for improved phoneme recognition using time-delay networks," *IEEE Trans. Neural Networks*, Vol. 1, pp. 216-218, 1990.
- [8] S.-H. Oh, "Error back-propagation algorithm for classification of imbalanced data," *Neurocomputing*, Vol. 74, pp. 1058-1061, 2011.