

지도 경험을 활용한 다계층 퍼셉트론의 순차적 학습 방법

(Utilizing Experiences of Supervisor in
Sequential Learning for Multilayer Perceptron)

이재영^{*} 김황수^{††}

(Jae-Young Lee) (Hwang-Soo Kim)

요약 학습 수준의 평가와 수준에 맞는 지식의 제공은 인간의 학습 과정에 많은 영향을 준다. 이것은 학습 순서가 중요하다는 것을 말하고 있으며, 기계 학습에서도 학습 순서를 고려할 필요가 있다. 본 연구는 학습 순서가 학습에 미치는 영향을 알아보기 위해, MLP의 학습에서 지도자의 경험을 이용하여 학습 순서를 제어하는 방법을 제안한다. 지도 경험과 평가를 이용하여 MLP의 상태를 파악하고, 현 상태에서 학습 효율이 좋을 것으로 예상되는 학습 자료를 선택하여 학습을 시킨다. 지도자의 경험을 표현하고 활용하기 위해 CRF(Conditional Random Fields)를 이용하였다. 제안한 방법은 학습 자료를 선택한다는 점에서 능동 학습(Active Learning)과 유사하지만, 학습 순서를 제시하기 위한 자료의 선택이란 점에서 능동 학습과는 차이가 있다. 분류 문제에 대하여 실험해 본 결과, 순서의 제어가 없는 학습의 경우에 비하여 학습 횟수의 측면에서 일반적으로 더 나은 학습 성능을 보여준다.

키워드 : MLP, 학습 순서, 지도 경험, CRF, 분류

Abstract Evaluating the level of achievement and providing the knowledge which is appropriate at the evaluated level have great influence in studying of the human beings. This shows the importance of the order of training and the training order should be considered in machine learning. In this research, to assess the influence of the order of training, we propose a method of controlling the order of training samples utilizing the experience of supervisor in the training of MLP. The supervisor finds out the current state of MLP using teaching experience and student evaluation, and then selects the most instructive sample for MLP in that state. We use CRF to represent and utilize the experience of supervisor. While the proposed method is similar to active learning in selecting samples, it is basically different in that selection is not to reduce the number of samples to be used but to assist the learning progress. The result from classification problem shows that the method is usually effective in terms of time taken in training in contrast to random selection.

Key words : MLP, Training Sequence, Experience, CRF, Classification

1. 서 론

기계 학습 분야에서 많이 사용되는 학습 모델들은 자료 중심의 학습 방법(data-oriented learning method)과 모델 중심의 학습 방법(model-oriented learning method)으로 나눌 수 있다. 자료 중심의 학습 방법을 이용하는 모델들(Decision Tree, SVM, RBFN, Naïve Bayes 등[1-3])은 학습 자료들의 분석을 통해 문제를 해결하며, 일반적으로 모델의 구조가 미리 정해지지 않거나 구조 자체를 정의하지 않고 자료의 분석 결과를 직접적으로 이용한다(Naïve Bayes의 경우). 구조를 가진 모델은 학습 자료가 내포한 문제의 난이도에 따라 그 구조

* 학생회원 : 경북대학교 컴퓨터과학과

yoleeivu@gmail.com

†† 종신회원 : 경북대학교 컴퓨터학부 교수

hsk@knu.ac.kr

논문접수 : 2010년 7월 5일

심사완료 : 2010년 8월 27일

Copyright©2010 한국정보과학회: 개인 목적인 경우, 이 저작물의 전재 또는 일부에 대한 복사본 혹은 디지털 사본의 제작을 허가합니다. 이 때, 사본은 상업적 수단으로 사용할 수 없으며 첫 페이지에 본 문구와 출처를 반드시 명시해야 합니다. 이 외의 목적으로 복제, 배포, 출판, 전송 등 모든 유형의 사용행위를 하는 경우에 대하여는 사전에 허가를 얻고 비용을 지불해야 합니다.

정보과학회논문지: 소프트웨어 및 응용 제37권 제10호(2010.10)

가 달라진다. 학습 자료에 의해 구조가 결정되는 예를 들면, SVM의 경우 학습 자료에서 선택한 대표 자료(support vector)들을 통해 그 구조가 결정되며, RBFN의 경우도 RBF들의 개수와 그 중심들에 따라 그 구조가 결정된다. 이 같은 모델들은 학습 자료에 대해 구조 자체가 종속적이거나 학습 자료에 대한 분석이 구조와 학습 결과에 직접적으로 많은 영향을 주므로, 전체 학습 자료들을 동시에 이용하는 일괄적 학습 방법을 많이 사용한다.

모델 중심의 학습은 자료 중심의 학습과 달리, 학습 자료와 독립적으로 구조가 미리 정의되어 있고 학습 자료들로부터 습득한 지식들을 그 구조에 맞게 수용하는 것을 말한다. 어떻게 학습 자료들에서 지식을 습득하고 표현하는가는 모델의 능력에 달려있다. 이 특성에 의해 순차적 학습 방법을 많이 이용하며, 대표적인 예로서 다계층 패셉트론(MLP)[1,2]를 들 수 있다. MLP의 학습에 많이 사용되는 역전파 방법은 일반적으로 순차적 방법을 의미한다. MLP는 블랙박스와 같아서 저장된 정보에 대해 정확한 해석이 어렵다. 그러므로, 학습 자료에 대한 분석은 MLP의 구조와 학습 결과에 단지 간접적인 영향을 줄 수 있다. MLP는 미리 정의된 입력층, 은닉 층, 출력층의 구조와 각 계층을 구성하는 노드들, 각 계층간의 노드들의 연결관계가 사전에 정의되어 있고, 학습 자료들의 목표 값들에 대한 근사화를 수행하는 것이다. 근사화를 수행한다는 것은 구조의 변형 없이 학습 자료의 정보를 수용하는 것을 의미한다. 이것은 MLP가 자료 중심의 학습 방법을 사용하는 모델들에 비해 인간의 학습과 더 유사하다는 것을 나타낸다.

인간은 각 개인마다 타고난 형질과 개성이 다르므로, 학습이 진행됨에 따라 내부적으로 지식을 받아들이고 해석하는 방식에 차이가 있다. 개인마다의 학습 능력의 차이점으로 인하여, 인간의 학습에서는 지도 경험이 있는 지도자의 존재와 그 역할이 상당히 중요하다. 특히 정확한 학습 수준의 평가와 학습 수준에 따른 적절한 지식의 제공이 중요하다. 이것은 인간의 학습에서 학습의 순서가 중요하다는 것을 나타내며, 모델 중심의 학습을 수행하는 MLP의 학습에서 고려해 볼 사항이다. 본 연구는 학습 순서가 학습에 미치는 영향을 알아보기 위해, MLP의 학습에서 지도자의 경험을 이용하여 학습 순서를 제어하는 방법을 제안한다. 지도 경험과 평가를 이용하여 MLP의 상태를 파악하고, 현 상태에서 학습 효율이 좋을 것으로 예상되는 학습 자료를 선택하여 학습을 시킨다. 지도자의 경험을 표현하고 활용하기 위해 CRF(Conditional Random Fields)[4-9]를 이용하였다. 분류 문제에 대하여 실험해 본 결과, 순서의 제어가 없는 학습의 경우에 비하여 학습 횟수의 측면에서 일반적으로 더 나은 학습 성능을 보여준다.

(Active Learning)[10-12]과 유사하지만, 학습 순서를 제시하기 위한 자료 선택이란 점에서 능동 학습과 차이가 있다. 또한, 최근 발표된 저자들의 논문[13]과는 달리, 본 논문은 지도자가 CRF를 이용하여 경험을 축적하고 이를 자료 선택에 활용한다는 점에 주안점을 두고 있다. 이전의 논문[13]에서는 학습 순서 제어가 학습의 효과를 높이는 것, 즉 학습 횟수를 줄이는 효과보다 학습 과정 동안에 사용되는 학습 자료의 개수를 감소시키는 효과를 더 잘 보여준다. 이것은 학습 과정에서 전체 학습 자료를 효율적으로 활용하지 못한다는 문제점을 나타낸다. 본 논문에서는 학습 자료들의 정보와 지도자의 경험을 함께 이용하여 이 문제점을 보완함으로써, 학습의 효과를 상승시킨다. 지도 경험은 학습 자료들에서 얻을 수 없는 정보이므로 제안한 방법이 [13]에서의 방법보다 더 많은 정보를 활용하여 학습을 진행하는 것이며, 이 경험 정보가 학습의 효율을 상승시키는 역할을 한다. 이것은 순차적 학습에서 지도자 경험의 중요성을 잘 나타낸다.

2. 지도 경험을 활용한 MLP의 순차적 학습

인간의 학습에서 지도자의 역할은 학습자에게 지식을 체계적이고 효율적으로 전달함으로써 학습 효과를 높이는 테 있다. 이를 위해 지도자는 학습에 이용할 자료에 대한 정보와 학습 대상(학생)의 상태에 대한 정보를 가져야 하며, 그 상태에 맞는 학습 자료를 활용하여 교육을 진행해야 한다. 이와 같이 학습 과정은 학생들의 개성과 기준의 지식 수준에 맞추어 진행되어야 좋은 학습 결과를 기대할 수 있으므로, 지도자의 다양한 경험을 필요로 한다. 다양한 경험이란, 여러 학생들에 대한 평가를 통해 상태를 파악하는 능력과 현 상태에서 어떤 자료를 이용한 학습이 학습의 효과를 높일 수 있는가에 대한 것을 말한다. MLP의 학습에서는 지도자가 여러 다른 MLP들의 학습에 대한 경험을 가지고 있으며, 자신의 경험을 현재 학습 대상인 MLP의 학습에 활용하는 것이 된다. 따라서, 본 연구 내용은 크게 아래의 두 가지이다.

첫째, 지도자가 MLP의 학습에 대한 경험을 얻는 과정과 그 과정에서 얻어진 경험을 표현하는 방법에 대한 것이다. 경험을 얻기 위하여 여러 MLP들의 학습 과정에 대한 실험과 관찰이 필요하다. 각 MLP들이 어떤 상태에서 어떤 학습 자료에 대해 어떤 학습 효과를 보이는지를 살펴보아야 한다. 하나의 자료를 학습할 때마다 평가를 수행하여 그 학습 자료가 MLP에 미친 영향을 살펴보고 상태를 파악한다. 여기서 평가는 학습 효과를 포함한 MLP의 상태를 파악하는 데 필요한 모든 정보들과 학습 자료의 특징(표 1 참조)들을 얻는 과정을 말한다. 또한, 이 과정에서 얻어진 정보들을 표현하는 방법

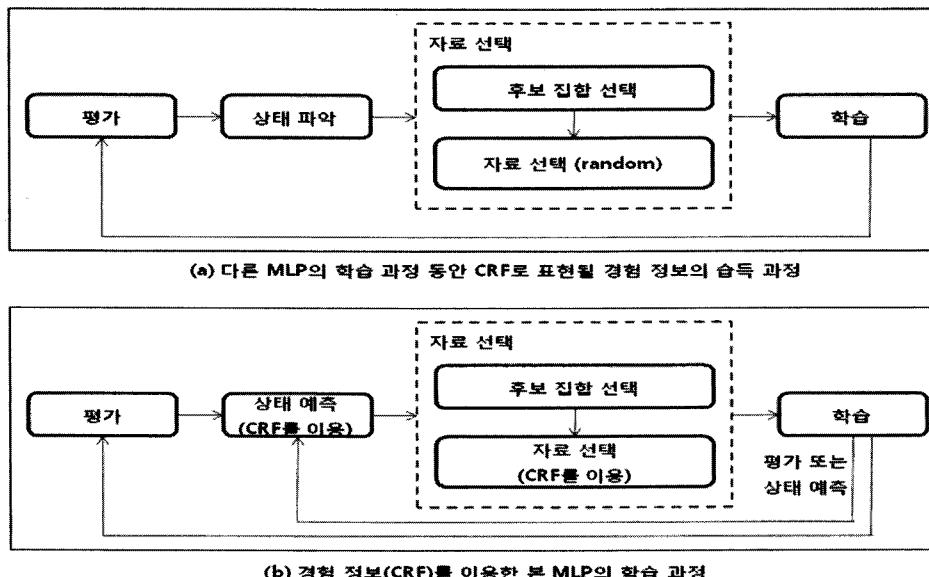


그림 1 MLP의 학습 과정 동안 CRF로 표현할 경험 정보를 얻는 과정과 경험 정보(CRF)를 이용한 MLP의 학습 과정

이 필요하다. 이것은 CRF를 이용하여 표현하고, 향후의 MLP의 학습에서 활용한다. 하나의 MLP의 학습 동안의 경험을 얻는 과정은 그림 1의 (a)와 같다. MLP 상태의 정의를 포함한 세부 내용은 2.1절에서 설명된다.

둘째, 지도자가 MLP의 학습에서 얻은 경험을 활용하는 방법에 대한 것이다. 지도자가 여러 MLP들의 학습 과정에서 실험과 관찰을 통하여 얻어진 경험 정보들을 CRF로 표현하고 저장하였다면, 그 정보를 새로운 MLP의 학습에서 활용할 방법이 필요하다. 경험 정보를 얻는 과정에서는 지도자가 매 학습마다 평가의 과정을 수행하지만, 이 과정에서는 학습 시간을 줄이기 위하여 경험 정보를 활용하여 상태를 예측하며 특정 조건에서 평가를 수행한다. 또한, 학습 자료의 무작위 선택이 아니라 경험 정보를 활용하여 선택한다. 이 과정은 그림 1의 (b)와 같으며, CRF의 경험 정보의 이용 방법을 포함한 세부 내용은 2.2절에서 설명된다.

2.1 CRF를 이용한 지도 경험의 표현

본 연구에서 지도자는 여러 MLP들의 학습 과정에서 발생하는 경험 정보들을 CRF를 이용하여 표현하고 활용한다. CRF는 자연어 처리에서 많이 활용되고 있는 방법으로, 연속된 텍스트 자료들에 대한 POS(Part-of Speech Tagging)[4], NER(Named-Entity Recognition) [5]등의 분야에서 활용되고 있으며, 그 개요는 다음과 같다.

2.1.1 CRF의 개요

관찰 문자(observation symbol)의 집합 X 와 상태

문자(state symbol)의 집합 Y 가 존재할 때, CRF는 입력 시퀀스 $\vec{x} = (x_1, \dots, x_{n+1}), x_i \in X$ 에 대응하는 출력 시퀀스 $\vec{y} = (y_1, \dots, y_{n+1}), y_i \in Y$ 를 확률적으로 예측하는 것이 그 목적이다. HMM[14]과 비슷하지만, \vec{x}, \vec{y} 에 대하여 HMM은 결합 확률 분포 $p(\vec{y}, \vec{x})$ 를 이용하고 CRF는 조건 확률 분포 $p(\vec{y} | \vec{x})$ 를 이용한다. 이 차이점으로 인하여 CRF는 입력 시퀀스 내의 자료들 사이의 의존성을 표현할 수 있으며, 여러 연구들에서 HMM보다 더 나은 결과들을 보여주고 있다. 본 연구에서 이용한 선형-사슬(Linear-Chain) CRF의 경우 다음과 같이 정의된다[4-9].

$$p(\vec{y} | \vec{x}) = \frac{1}{Z_{\vec{x}}} \exp\left(\sum_{i=1}^n \sum_{j=1}^m \lambda_j f_j(y_{i-1}, y_i, \vec{x}, i)\right) \quad (1)$$

여기서 i 는 입력 시퀀스 \vec{x} 내의 위치, j 는 특정 함수의 번호, m 은 사용하는 특정 함수들의 개수,

λ_j 는 j 번째 특정 함수의 가중치, f_j 는 j 번째 특정 함수, $Z_{\vec{x}}$ 는 정규화 인자로

$$\sum_{\vec{y} \in Y} \exp\left(\sum_{i=1}^n \sum_{j=1}^m \lambda_j f_j(y_{i-1}, y_i, \vec{x}, i)\right)$$

을 나타낸다(\vec{Y} 는 모든 가능한 출력 시퀀스의 집합).

특정 함수 $f_j(y_{i-1}, y_i, \vec{x}, i)$ 의 인자 \vec{x} 는 다른 인자 y_{i-1}, y_i, i 와는 다르게 입력 시퀀스내의 위치 i 에 관계 없이 입력 시퀀스내의 자료들이 CRF에 관여함을 나타내며, 이것은 특정 함수를 이용하여 입력 시퀀스 내의

자료들 사이의 의존성을 표현할 수 있다는 것을 의미한다. CRF의 성능은 어떤 특징 함수를 적용하는가에 따라 달라지며, 좋은 특징 함수는 입력 시퀀스와 출력 시퀀스 간의 관계를 잘 나타낼 수 있어야 한다. 이후로는 편의상 선형-사슬 CRF를 CRF로, 특징 함수를 특징으로 간략히 표기한다.

사용할 특징들이 주어졌을 때, λ_j 의 값들을 결정하는 것을 CRF의 학습 과정이라 한다. 이 과정은 입/출력 시퀀스 쌍의 집합 $T = \{(\vec{x}, \vec{y})_1, \dots, (\vec{x}, \vec{y})_N\}$ 이 존재할 때, 그에 대한 로그 유사도 $\bar{L}(T) = \sum_{(\vec{x}, \vec{y}) \in T} \log p(\vec{y} | \vec{x})$ 의 값이 최대가 되는 λ_j 들을 찾는 것이다. 이를 위해 알려진 여러 방법들[4,6-8]이 있으며 본 연구에서는 L-BFGS 방법을 지원하는 Mallet[15] 라이브러리를 이용하였다. 학습된 CRF를 이용하여 임의의 입력시퀀스 \vec{x}' 에 대한 출력시퀀스 \vec{y}' 를 예측하는 과정은 Viterbi 방법[4,6-8,14]을 이용한다.

경험 정보들을 CRF로 표현하는데 있어서 고려해야 할 사항은, MLP의 학습에서 관찰 문자의 집합 X , 상태 문자의 집합 Y , 그리고 사용할 특징들은 무엇인가이다. X 는 MLP의 학습에 사용되는 학습 자료의 집합이고, Y 는 임의의 학습 자료를 학습한 후의 MLP의 상태를 표현하는 것으로 입력 시퀀스내의 값들(학습 자료)에 대응하여 출력 시퀀스에 나타날 수 있는 값들(MLP의 상태)이 된다. 사용할 특징들은 MLP의 학습 과정 동안에 얻을 수 있는 정보들로서 학습의 효과를 높이기 위해 필요한 정보가 된다. 즉, 이전의 학습이 다음의 학습에 영향을 줄 수 있는 정보이다. 이는 학습 순서에 따른 MLP의 상태 변화 또는 학습 순서가 미치는 영향을 나타낼 수 있는 특징을 의미한다. MLP의 상태를 나타내는 Y 는 2.1.2절에, 그리고 CRF에서 사용할 특징들은 2.1.3절에서 설명하고, 2.1.4절에서는 지도자가 MLP들의 학습 과정에서 경험 정보를 얻어 CRF로 표현하는 과정에 대하여 설명한다.

2.1.2 MLP의 상태 표현

MLP의 상태는 임의의 학습 자료를 학습한 후의 상태를 표현하며, 가장 우선적으로 정의되어야 한다. 상태는 크게 내부 정보를 이용하는 방법과 외부 정보를 이용하는 방법으로 나누어 볼 수 있다. 내부 정보란 은닉 층의 구조, 각 노드들 간의 연결관계 및 가중치 등으로, 이들은 그 의미를 정확히 해석하기 어렵고 표현할 수 있는 개수가 너무 많아서 이들을 이용하여 MLP의 상태를 정의하기 어렵다. 반면, 외부 정보란 평가를 통한 분류 정확도, 여러 등의 관찰 가능한 것들로 이들을 이용하여 상태를 정의하는 방법은 어떤 자료들에 대해 어떤 출력을 가지는 가에 대한 간접적인 의미 해석이 가능하

고, 상태의 개수를 조절할 수 있는 장점이 있다. 본 연구에서는 후자의 방법을 이용한다.

상태 정의를 위해 사용하는 정보는 ①MLP의 분류 정확도와 ②지도자와 MLP간의 관점 차이이다. 분류 정확도 ①은 일반적인 MLP의 성능 평가 방법으로 임의의 자료를 학습 후 분류 정확도를 계산하고 이전의 분류 정확도와 비교하여 성능의 변화를 보는 것이고, 지도자와 MLP의 관점 차이 ②는 학습 자료들에 대한 실제 목표 값들의 분포와 MLP가 분류한 목표 값들의 분포간의 거리이며 계산 방법은 다음과 같다.

학습 자료의 집합 X 와 그에 대한 목표 값들의 집합 C 에 대하여,

$$D_c \triangleq \{x | x \in X \text{이며 } x \text{의 실제 목표 값 } c \in C\}$$

$$M_c \triangleq \{x | x \in X \text{이며 현재 MLP가 } x \text{를 분류한 목표 값 } c \in C\}$$

를 각각 정의하자. 지도자와 MLP의 관점 차이 F_{total} 은, 모든 $c \in C$ 에 대하여 D_c 에 속하는 학습 자료들에 대하여 현재 MLP가 분류한 목표 값들의 분포와 M_c 에 속하는 학습 자료들의 실제 목표 값들의 분포 간의 거리의 합으로 볼 수 있으며, Kullback-Leibler 거리[1]를 이용하여 다음과 같이 정의한다. $| \cdot |$ 는 집합의 크기, $abs(\cdot)$ 는 절대값을 나타낸다.

$$F_c = \frac{abs(|D_c| - |M_c|)}{|D_c|} \sum_{c' \in C} \left(\frac{|D_c \cap M_{c'}|}{|D_c|} \log \frac{|D_c \cap M_{c'}|}{|M_{c'}|} - \frac{|D_c \cap M_{c'}|}{|D_c|} \log \frac{|D_c \cap M_{c'}|}{|D_c|} \right) \quad (2)$$

$$F_{total} = \sum_{c \in C} F_c \quad (3)$$

F_{total} 의 값이 작을수록 MLP에 의한 분류가 실제 목표 값들의 분포에 근접했음을 나타내며, $\frac{abs(|D_c| - |M_c|)}{|D_c|}$ 는 실제 목표 값들 자체의 분포를 반영하기 위한 가중치이다.

MLP의 상태는 학습 전/후의 분류 정확도와 F_{total} 의 값의 변화를 이용하여 정의한다. 학습 후 분류 정확도가 증가하고 $1/F_{total}$ 의 값이 증가한다면 UU(UP_UP), 학습 후 분류 정확도가 증가하고 $1/F_{total}$ 의 값이 감소한다면 UD(UP_DOWN)의 상태로 정의하며, 이와 유사하게 DU, DD도 정의한다. 따라서, MLP의 상태 집합은 $Y = \{UU, UD, DU, DD\}$ 가 된다. UU가 가장 좋은 상태를 나타내고, DD가 가장 나쁜 상태를 나타낸다.

2.1.3 CRF에서 사용한 특징들

하나의 자료를 학습한 후 MLP의 상태 변화에 대한 정보를 CRF로 표현하기 위하여, 학습 자료에 대하여 사용할 특징들을 결정해야 한다. 이는 CRF의 성능을 좌우하는 중요한 요소로서 상태 변화를 잘 표현해 줄 수 있는 특징이 필요하다. 학습 전/후의 상태 전이 특징에 더하여, 학습 자료 $x \in X$ 에 대하여 본 실험에서 사

표 1 제안한 방법에서 사용한 특징들

특징	내용
학습 자료의 속성 값들	학습 자료 $x = (a_1, \dots, a_p) \in X$ 의 각 속성 값 a_i 들. 모든 속성 값은 0과 1사이의 실수 값으로 정규화 함 (p 개의 특징)
학습 자료에 대한 MLP의 출력 벡터	학습 자료 $x \in X$ 에 대하여 MLP의 출력 노드에서의 출력 값. 출력의 개수는 목표 값들의 개수 $ C $ 와 같으며, 각 출력은 0과 1사이의 실수 값을 가짐 ($ C $ 개의 특징)
학습 자료의 실제 목표 값 벡터	학습 자료 $x \in X$ 에 대한 실제 목표 값 벡터. MLP의 학습에 사용되며, 목표 값에 해당되는 성분은 1, 나머지는 0의 값을 가짐 ($ C $ 개의 특징)
학습 자료에 대한 MLP의 정확한 분류 유무	학습 자료 $x \in X$ 를 MLP가 정확히 분류하는가 유무. 0 또는 1의 값을 가짐 (1개의 특징)
바로 이전에 사용된 학습 자료의 목표 값 벡터	이전에 학습에 사용된 학습 자료 $x_{prev} \in X$ 의 실제 목표 값 벡터. 바로 이전 MLP의 학습에 사용되었으며, 목표 값에 해당되는 성분은 1, 나머지는 0의 값을 가짐 ($ C $ 개의 특징)
바로 이전 학습 자료와의 코사인 유사도(정규화 된 내적 값)	이전에 학습에 사용된 자료 $x_{prev} \in X$ 와 현재 학습 자료 $x \in X$ 의 유사도. $\frac{\langle x_{prev}, x \rangle}{\ x_{prev}\ \ x\ }$, 0과 1사이의 실수 값 (1개의 특징)
현재 선택된 자료의 학습 전, 전체 자료에 대한 MLP의 분류 정확도	이전 MLP의 분류 정확도 (틀리게 분류한 자료의 수/전체 자료의 수), 0과 1 사이의 실수 값 (1개의 특징)
학습 자료의 실제 목표 값이 $c \in C$ 일 경우, 모든 $c' \in C$ 에 대한 $\frac{ D_c \cap M_{c'} }{ D_c }$ 값들	D_c 에 속하는 학습 자료들에 대하여 현재 MLP가 분류한 목표 값들의 분포. 모든 $c' \in C$ 에 대하여 0과 1사이의 값을 가짐 ($ C $ 개의 특징)
학습 자료의 실제 목표 값이 $c \in C$ 일 경우, 모든 $c' \in C$ 에 대한 $\frac{ D_c \cap M_{c'} }{ M_{c'} }$ 값들	M_c 에 속하는 학습 자료들의 실제 목표 값들의 분포. 모든 $c' \in C$ 에 대하여 0과 1사이의 값을 가짐 ($ C $ 개의 특징)
학습 전/후의 상태 전이	학습 전 상태 y_{i-1} 에서 학습 후 상태 y_i 로의 상태 변화. $y_{i-1}, y_i \in Y = \{UU, UD, DU, DD\}$ (16개의 특징)
	모두 합하여 (학습 자료의 속성들의 개수 + 5 × 학습 자료의 목표 값들의 개수 + 19) 개의 특징을 사용함.

용한 특징들을 표 1에 정리하였다.

2.1.4 MLP의 학습 과정에서 경험 정보를 얻는 과정과 경험 정보를 CRF로 표현하는 방법

경험 정보를 CRF로 표현(학습)하기 위하여 (입력시퀀스, 출력시퀀스)의 쌍으로 구성된 자료들이 필요하며, 실제 MLP의 학습 과정에서 2.1.2절과 2.1.3절의 내용에 부합되는 자료들 T 를 구성해야 한다. 이 과정에서 하나의 자료의 학습마다 상태를 파악하고 자료의 특징 값들을 얻기 위하여 MLP의 평가가 이루어진다. T 를 구성하기 위하여 두 가지 사항을 고려해야 한다. 첫째는 MLP가 학습하는 동안 자료를 선택하는 방법이고, 둘째는 학습 동안의 전체 입력시퀀스를 부분 시퀀스로 나누는 방법이다. 부분 시퀀스로 나누는 것은 CRF를 위한 자료들, 즉 입/출력 시퀀스 쌍의 집합 T 를 구성하기 위함이다. 이 두 방법은 다음과 같다.

첫째, 학습 자료를 선택하는 방법은 일반적인 MLP의 역전파 학습처럼 무작위로 학습 자료를 선택하는 것과는 달리, 학습에 사용할 자료들의 집합에서 후보 집합을 만들고 후보 집합에서 자료를 선택한다. 방법은 다음과 같다. 아래의 식 (4)를 이용하여 목표 값 $c^* \in C$ 를 선택하고,

$$c^* = \operatorname{argmax}_{c \in C} F_c \quad (4)$$

실제 목표 값이 c^* 인 학습 자료들의 집합 D_{c^*} 와 현재 MLP가 판단한 목표 값이 c^* 인 학습 자료들의 집합 M_{c^*} 의 차집합 $X_{c^*} = D_{c^*} - M_{c^*}$ 에 속하는 학습 자료들을 후보 집합으로 한다. M_{c^*} 에서 무작위로 하나의 자료를 선택한다. 이것은 지도자가 경험을 쌓기 위한 시행착오의 과정을 나타내며 동시에 다양한 경험을 얻기 위한 것이다. 지도자의 경험 정보가 CRF로 표현되고 난 후의 MLP의 학습에서는, 지도자가 그 경험 정보에 근거하여

학습 자료를 선택하며 그 방법은 2.2절에서 설명된다.

둘째, 학습 동안의 전체 입력시퀀스를 부분 시퀀스로 나누는 이유는, 역전과 학습 동안 사용되는 자료의 시퀀스는 일반적으로 매우 길고, 학습 수준(분류 정확도)에 따라 시퀀스를 구분할 필요가 있기 때문이다. 같은 학습 자료라도 학습 수준에 따라 학습에 미치는 영향이 다르므로, 학습 수준에 따른 학습 효과를 구분하여 보아야 한다. 이를 고려하여, 본 연구에서는 현재 학습 수준이 이전의 가장 좋은 학습 수준보다 높아질 때까지를 하나의 시퀀스로 분할한다(그림 2 참조). 그리고, 생성되는 각 시퀀스가 최소 2 이상의 길이를 가지고도록 보장하며 동시에 이전 시퀀스와의 연관성도 유지하기 위하여, 각 시퀀스의 처음 자료는 이전 시퀀스의 마지막 자료를 사용한다. 단조 증가 형태를 가지는 학습 구간에서는 길이가 2인 시퀀스가 연속적으로 생성될 것이며, 그 외에는 길이가 2 이상인 시퀀스들이 얹어진다.

MLP의 학습 과정에서 T 를 구성하기 위하여 학습, 평가, 상태 파악, 자료 선택의 과정이 반복된다. 또한, 이 과정은 하나의 MLP의 학습에서 경험을 얻는 과정이므로, 다양한 경험을 얻기 위하여 여러 MLP들에 대한 수행이 필요하다. 여러 MLP들의 학습 과정에서 얻어진 입/출력 시퀀스의 집합 T 를 CRF로 표현한다. CRF의 경험 정보는 MLP의 학습 과정에서 자료를 선택하고 상태를 예측하는데 활용된다.

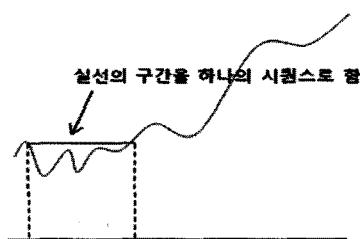


그림 2 학습 곡선에 근거한 시퀀스 분할의 예
(가로축은 학습 횟수, 세로축은 분류 정확도)

2.2 지도 경험을 이용한 MLP의 학습 과정

전체적으로 지도 경험을 얻는 과정과 유사하나 다음과 같은 차이가 있다. 특정한 조건에서 MLP에 대한 평가를 수행한다는 점(2.2.1절 참조), MLP의 현재 상태를 CRF를 이용하여 예측한다는 점, 그리고 학습 자료를 선택할 때 CRF의 정보에 의존한다는 점에서 차이가 있다. 여기서 말하는 평가란, 2.1.3절에서 설명한 특징들의 정보, 즉 학습 자료에 대한 MLP의 출력 벡터, 전체 자료에 대한 MLP의 분류 정확도, 학습 자료의 실제 목표

값이 $c \in C$ 일 경우 모든 $c' \in C$ 에 대한 $\frac{|D_c \cap M_{c'}|}{D_c}$

들, 학습 자료의 실제 목표 값이 $c \in C$ 일 경우 모든 $c' \in C$ 에 대한 $\frac{|D_c \cap M_{c'}|}{|M_{c'}|}$ 값 등을 계산하는 것을 말한다.

2.2.1 학습 자료들에 대한 MLP의 평가를 수행하는 시점 하나의 자료를 학습할 때마다 평가를 수행한다면 많은 시간과 비용이 소비되므로, 본 논문에서는 학습 전/후에 MLP의 분류 결과에 따라 평가를 수행한다. 학습에 사용한 자료를 학습 전에는 틀리게 분류했으나, 학습 후에 맞게 분류한다면 학습의 효과가 있는 것으로 보고, 전체에 대한 평가를 수행한다. 분류 결과가 바뀌지 않는다면 평가를 수행하지 않고 이전 평가 자료를 이용하여 계속 학습 자료를 선택한다.

2.2.2 CRF를 이용한 MLP의 현재 상태 예측

CRF로 MLP의 현재 상태를 예측하는 방법은, 이전에 학습한 자료들의 시퀀스를 이용하여 가장 높은 확률을 가진 상태 시퀀스를 예측하고, 이 시퀀스의 마지막 상태를 현재 상태 $y_{current}$ 로 보는 것이다. 학습 자료의 집합이 X , MLP의 상태를 나타내는 집합이 $Y = \{UU, UD, DU, DD\}$ 일 때, 현재까지의 학습 시퀀스 $\vec{x} = (x_1, \dots, x_{n+1})$, $x_i \in X$ 에 대해 상태 시퀀스 $\vec{y} = (y_1, \dots, y_{n+1})$, $y_i \in Y$ 를 예측하는 것이다. 이전에 학습에 사용한 학습 자료의 시퀀스 \vec{x} 를 알고 있어야 한다. 또한 학습이 진행됨에 따라 학습 시퀀스가 길어지므로, 현재 상태를 예측하기 위해 사용하는 시퀀스는 학습 자료 집합의 크기 $|X|$ 의 20%에 해당하는 길이만큼의 최근 학습 시퀀스로 한다. 그 이전의 학습 시퀀스는 무시한다. 여기서 20%는 그 길이에 제한을 가하는 것과 동시에, 이전의 학습이 현재 상태에 미치는 영향을 충분히 반영할 수 있도록 임의로 선택하였다. 학습 횟수가 $|X|$ 의 20%에 못 미치는 경우에는 현재까지의 학습 시퀀스를 이용하여 상태를 예측한다. 학습 시퀀스 \vec{x} 가 주어졌을 때, 현재 상태 $y_{current}$ 는 Viterbi 방법[4,6-8,14]을 이용하여 다음과 같이 찾는다.

학습 시퀀스 \vec{x} 에 대한 상태 시퀀스 \vec{y} 에 대하여 ($s \in Y$, i 는 시퀀스 내의 위치),

$$\delta_i(s|\vec{x}) = \max_{y_1, y_2, \dots, y_{i-1}} p(y_1, y_2, \dots, y_i = s | \vec{x}) \quad (5)$$

를 정의한다. 이것을 편의상 \vec{x} 를 생략하고 재귀 표현으로 나타내면

$$\delta_{i+1}(s) = \max_{s' \in Y} \delta_i(s') \Psi_{i+1}(\vec{x}, s', s) \quad (6)$$

여기서

$$\Psi_i(\vec{x}, s', s) = \exp(\sum_{j=1}^m \lambda_j f_j(y_{i-1} = s', y_i = s, \vec{x}, i))$$

이다. 이를 이용하여 다음과 같이 $y_{current}$ 를 찾는다.

1.1) 초기화

시작 상태 s_{start} 에서 갈 수 있는 가능한 모든 상태들, 즉 $\forall s \in Y$ 에 대하여

$$\delta_1(s) = \Psi_1(\vec{x}, s_{start}, s)$$

$$\psi_1(s) = s_{start}$$

를 계산한다. $\psi_i(s)$ 는 i 와 s 값들에 대한 자취(이전 상태)를 유지하는 배열을 나타낸다.

1.2) 재귀 호출

현재 상태 s 에서 모든 가능한 다음 상태 s' 에 대하여 즉, $\forall s \in Y, 1 \leq i \leq n$ 에 대하여

$$\delta_i(s) = \max_{s' \in Y} \delta_{i-1}(s') \Psi_i(\vec{x}, s', s)$$

$$\psi_i(s) = \operatorname{argmax}_{s' \in Y} \delta_{i-1}(s') \Psi_i(\vec{x}, s', s)$$

를 계산한다.

계산이 끝난 후, $\operatorname{argmax}_{s' \in Y} \delta_n(s')$ 가 최종 상태, 즉 여기서는 현재 상태의 예측인 $y_{current}$ 가 된다. 상태 시퀀스는 $\psi_n(y_{current})$ 의 값을 이용하여 역으로 자취를 추적하여 알 수 있다.

2.2.3 전체 학습 과정과 학습 자료의 선택 방법

학습 자료의 선택은지도 경험을 얻는 과정에서는 구성된 후보 집합에서 무작위로 선택하나, 경험 정보가 존재할 경우에는 어느 학습 자료가 MLP를 더 나은 상태로 전이시킬 수 있는가를 CRF를 이용하여 예측한다. 전체 학습 과정은 다음과 같으며, 학습 자료의 선택 방법은 4)에서 설명된다.

1) 2.2.2절에서 기술한 방법으로 현재 MLP의 상태 $y_{current}$ 를 예측한다.

학습을 시작하는 시점에서는 이전에 사용한 학습 자료의 시퀀스가 없으므로 상태를 예측할 수 없다. 이 경우는 가장 어려가 큰 자료를 선택하여 학습 후, 평가를 수행하고 1)에서 6)의 과정을 진행한다. 여기서 어려는 학습 자료에 대한 MLP의 출력 벡터와 실제 목표 값 벡터의 차이를 말한다. 예측된 $y_{current}$ 는 4)에서 활용된다.

2) 2.1.4절에서 기술한 방법으로 후보 집합 X_{c^*} 을 만든다. 만약, $X_{c^*} = \emptyset$ 라면 학습을 종료한다.

$X_{c^*} = \emptyset$ 가 의미하는 것은 모든 학습 자료에 대한 학습이 끝났다는 것을 말한다. 이것은 MLP가 모든 학습 자료들을 정확하게 분류한다는 의미이다.

3) X_{c^*} 에 속한 자료들에 대하여 현재 MLP의 어려들을 계산하고, 계산된 어려의 크기에 따라 자료들을 정렬한다. 정렬된 학습 자료들에서 25%간격으로 자료를 선택한다.

X_{c^*} 에 속한 자료들의 수가 많을 경우에 그 모든 자료들에 대하여 아래의 4)의 과정을 수행하는 것은 많은 시간을 필요로 하므로, 어려의 크기에 따라 몇 개의 자료를 선택한다. 어려의 크기는 각 학습 자료에 대한 MLP의 출력의 정확도를 나타내는 것이며, 다

른 자료와의 연관성을 고려하지는 않는다. 즉, 어려의 크기가 큰 자료에 대한 학습이 다른 자료들에게도 학습 효과(어려 감소)를 보장하지는 않는다는 것이다. 오히려 학습 자료의 전체 분포에서 거리가 먼 자료(outlier)일 가능성이 높아 학습에 나쁜 영향을 줄 가능성도 있다. 반면, 작은 어려를 가진 자료는 안정적인 학습을 기대할 수 있으나 학습 효과가 미비한 문제가 있다. 중간 정도의 어려를 가진 자료는 앞선 두 가지 문제점에서는 비교적 자유로우나, 현재 MLP의 전체 어려 공간을 잘 대표하여 전반적인 학습 효과의 증진을 보장하지는 않는다. 중간 어려 값 자체가 편향되어 있을 수도 있다. 따라서 본 연구에서는 어려의 크기에 따라 어려 공간을 잘 대표할 수 있는 자료들을 선택하기 위하여 25% 간격으로 균등하게 분할하여 5개의 자료를 선택한다. 이것은 어려 값의 편향성을 고려한 최소의 선택이라 볼 수 있다.

- 4) 선택된 자료들에 대하여, 1)에서 예측한 상태에서 가장 좋은 다음 상태로 갈 수 있는 자료를 선택한다. 이 과정은 어느 학습 자료가 MLP의 다음 상태를 더 나아지게 할 수 있는가에 대한 예측으로, 현재 상태 $y_{current}$ 에서 갈 수 있는 다음 상태인 y_{next} 에 대한 전이 확률을 고려한다. 3)에서 선택된 5개의 자료들을 $X_s = \{x_{s1}, x_{s2}, x_{s3}, x_{s4}, x_{s5}\}$ 라고 할 때, 학습에 이용할 자료 x_s^* 를 선택하는 식은 다음과 같다.

$$x_s^* = \operatorname{argmax}_{x \in X_s} \sum_{y_{next} \in Y} w(y_{next}) \sum_{j=1}^m \lambda_j f_j(y_{current}, y_{next}, \vec{x}) \quad (7)$$

식 (7)은 현재 상태에만 의존하여 다음 상태를 예측하는 것이므로, 식 (1)의 f_j 의 인자 중에서 시퀀스 내의 위치를 나타내는 i 를 생략하였다. $w(y_{next})$ 는 각 상태의 좋고 나쁨을 반영하는 가중치로써, y_{next} 가 가장 좋은 상태인 UU의 경우엔 2, 가장 나쁜 상태인 DD의 경우에는 -1, 그 외의 경우엔 1의 값을 사용하였다. 이것은 다음 상태가 가장 좋아질 것으로 예상되는 자료를 선택하기 위한 것이다.

- 5) 선택된 자료 x_s^* 를 이용하여 MLP를 학습시키고, 2.2.1절에서 설명하는 조건에 의해 평가를 수행한다.

- 6) 지정된 학습 횟수까지 1)에서 5)의 과정을 반복한다.

2.2.4 능동 학습과의 비교

능동 학습[10-12]은, 학습을 위한 자료들의 분류 또는 구분에 전문가의 많은 노력과 비용이 발생할 경우, 모델이 스스로 학습 자료를 선택하는 능력을 가지는 것이다. 학습에 도움이 되는 자료들을 선택하는 방법에 초점을 맞추고 있으며, 자료 선택의 조건을 제시하는 질의 함수가 학습에 사용될 자료들을 선택하는 핵심적인 역할을 수행한다. 질의 함수를 어떻게 만드느냐에 따라 학습의

성능이 좌우된다. 질의 함수는 Uncertainty Sampling, Query-By-Committee, Estimated Error Reduction 등에 기반하여 다양하게 제안되어 있으으며[11,12], 질의 함수에 의해 선택된 학습 자료들을 전문가가 분류 또는 구분하여 학습에 이용한다. 적은 수의 학습 자료를 이용하여 학습 효과를 높이는 데 목적이 있으며, 다음과 같은 점에서 제안한 방법과 차이를 보인다.

제안하는 방법은 모든 학습 자료들에 대해 학습에 이용되는 순서를 제어함으로써 학습 횟수 측면에서의 효과를 얻는 데 목적이 있다. 이에 따라 일정한 학습 과정 동안 학습 자료의 선택 과정에서 선택되지 않는 자료들이 존재할 수 있으며, 하나의 자료가 반복적으로 계속하여 학습에 이용될 수도 있다. 반면, 능동 학습에서는 학습에 사용될 자료들을 선택한 후 그 자료들을 학습 과정에서 어떤 순서로 이용하는가는 고려하지 않으며, 적은 자료들을 이용하여 학습 결과를 향상시키는데 목적이 있다. 또한, 제안하는 방법은 학습 자료의 목표 값에 근거한 지도자의 평가와 지도자의 경험(학습)에 의한 추정치를 동시에 반영한 선택을 하고, 능동 학습의 질의 함수는 추정되는 정보를 활용하여 학습 자료를 선택한다는 점에서 차이가 있다. 전자는 대부분의 지도 학습 방법처럼 지도자가 이미 모든 학습 자료들에 대한 정확한 지식(목표 값)을 알고 있는 경우를 대상으로 하였고, 후자는 전문가의 검토를 거치지 않은 많은 학습 자료들이 존재할 때, 필요에 의하여 전문가의 검토가 이루어진다. 마지막으로, 제안하는 방법은 지도자의 역할에 그 초점이 맞춰져 있고, 능동 학습은 학습자의 역할에 초점을 맞추고 있다. 이것은 기존의 학습자 중심의 학습에서 지도자 중심의 학습으로의 관점의 전환을 보여준다. 지도자의 역할이 확장됨으로써 모델의 학습에 어떤 영향을 주느냐에 관심을 둔다. 능동 학습은 얼마나 똑똑한 학습자인가에 의미를 두고 있다고 볼 수 있다. 경험과 지식을 갖춘 지도자와 능동적이고 똑똑한 학습자에 대한 관점의 차이이다. 제안된 내용은 학습자가 아닌 지도자의 모델링이라고 할 수 있다.

3. 실험 결과

제안하는 방법의 실험 자료로서 UCI Machine Learning Repository[16]의 Automobile, Connectionist Bench (Sonar, Mines vs. Rocks), Ionosphere, Japanese Vowels, Lymphography, Statlog(Vehicle Silhouettes)을 사용하였다. 아래의 모든 실험 결과는 최대 학습 횟수를 (학습 자료의 수 × 200)로 설정하고, 30번의 시도에 대한 평균값으로 작성되었다. 학습 자료와 테스트 자료는 같은 수의 자료들을 가지도록 무작위로 2세트로 분할하여, 각 시도마다 번갈아 사용하였다. 학습 자료들은 차원 축소,

표 2 사용된 학습 자료의 정보

자료이름	속성개수	목표 값 개수	자료개수
Automobile	26	7	205
Connectionist Bench(Sonar, Mines vs. Rocks)	60	2	208
Ionosphere	34	2	351
Japanese Vowels	13	11	990
Lymphography	18	4	148
Statlog(Vehicle Silhouettes)	18	4	846

특정 출력과 같은 전처리 기법을 적용하지 않고 속성 값 전체를 MLP의 입력으로 사용하였으며, MLP의 학습 성능은 학습 자료와 테스트 자료에 대한 분류 정확도, 즉 (맞게 분류한 자료의 수/전체 자료의 수) × 100 으로 측정하여 평가하였다. MLP의 은닉 층의 노드 수는 자료의 (속성 개수+목표 값의 개수)/2로 설정하였고, 학습율은 0.5로 설정하였다. 표 2는 실험에 사용한 학습 자료의 정보를 보여준다. 참고로 실험은 코어2 듀오 E7400 CPU, 2GB 메모리, 윈도우 XP에서 자바 언어로 작성하여 수행하였다.

제안한 방법이 어떤 효과를 보이는지를 살펴보기 위해 다음의 4가지 선택 방법에 대해 비교해 보았다. 이들은

Exp20 : 20개의 MLP에 대한 학습 과정에서 경험을 얻은 지도자를 통한 학습(제안된 방법),

Exp3 : 3개의 MLP에 대한 학습 과정에서 경험을 얻은 지도자를 통한 학습(제안된 방법),

MaxError : 가장 예상가 큰 자료를 선택하여 학습, 자료의 학습마다 평가를 수행하고, 분류 정확도가 100% 이면 학습을 종료함,

Random : 무작위 선택을 이용한 학습, 주어진 최대 학습 횟수까지 학습함

이다. Exp20, Exp3, MaxError의 경우는 학습 과정 중에 모든 학습 자료를 정확히 구분할 경우, 더 이상 학습을 진행하지 않으므로 최대 학습 횟수보다 대체로 학습이 빨리 종료된다.

표 3은 각 방법에 대한 실험 결과를 보여준다. Exp20, Exp3은 Random과 비교할 때 최종 학습 결과보다 학습 횟수에서 큰 차이를 보이며, MaxError와 비교하여 학습 횟수와 학습 결과에서 더 나은 결과를 보인다. 이 결과들은 제안한 방법을 이용한 학습 자료의 선택이 효율적이라는 것을 보여준다. Exp20과 Exp3은 학습 횟수 측면에서는 그 차이를 발견하기 어렵고, 테스트 자료에 대한 결과에서 차이를 살펴 볼 수 있다. 경험이 많은 지도자를 통한 선택이 좀 더 나은 결과를 보여준다. 테스트 자료에 대한 결과의 차이는, 같은 학습 자료를 이용하더라도 경험에 의해 그 지도 결과가 달라질 수 있으며 많은 경험은 MLP의 과잉 학습(overfitting)을 조절하여 좀 더 일반화(generalization) 된 결과를 가져올

표 3 학습 자료와 각 방법에 따른 학습 후의 정보

자료이름	Exp20			Exp3			MaxError			Random		
	평균 학습 횟수	학습 후 정확도 [%] (30회 평균)		평균 학습 횟수	학습 후 정확도 [%] (30회 평균)		평균 학습 횟수	학습 후 정확도 [%] (30회 평균)		평균 학습 횟수	학습 후 정확도 [%] (30회 평균)	
		학습 자료	테스트 자료									
Automobile	1507	100	63.86	1591	100	62.84	1576	100	63.49	20400	98.04	62.06
Connectionist Bench (Sonar, Mines vs. Rocks)	1112	100	80.19	1095	100	77.69	1500	100	77.66	20800	99.65	79.39
Ionosphere	1656	100	89.29	1898	100	88.93	6788	100	87.60	35000	99.90	89.12
Japanese Vowels	25205	100	89.06	25048	100	88.51	61884	99.69	90.03	99000	94.76	84.80
Lymphography	311	100	84.01	309	100	82.61	343	100	80.94	14800	99.91	84.19
Statlog(Vehicle Silhouettes)	84600	87.64	77.09	84600	85.97	73.92	84600	80.67	72.02	84600	87.47	77.66

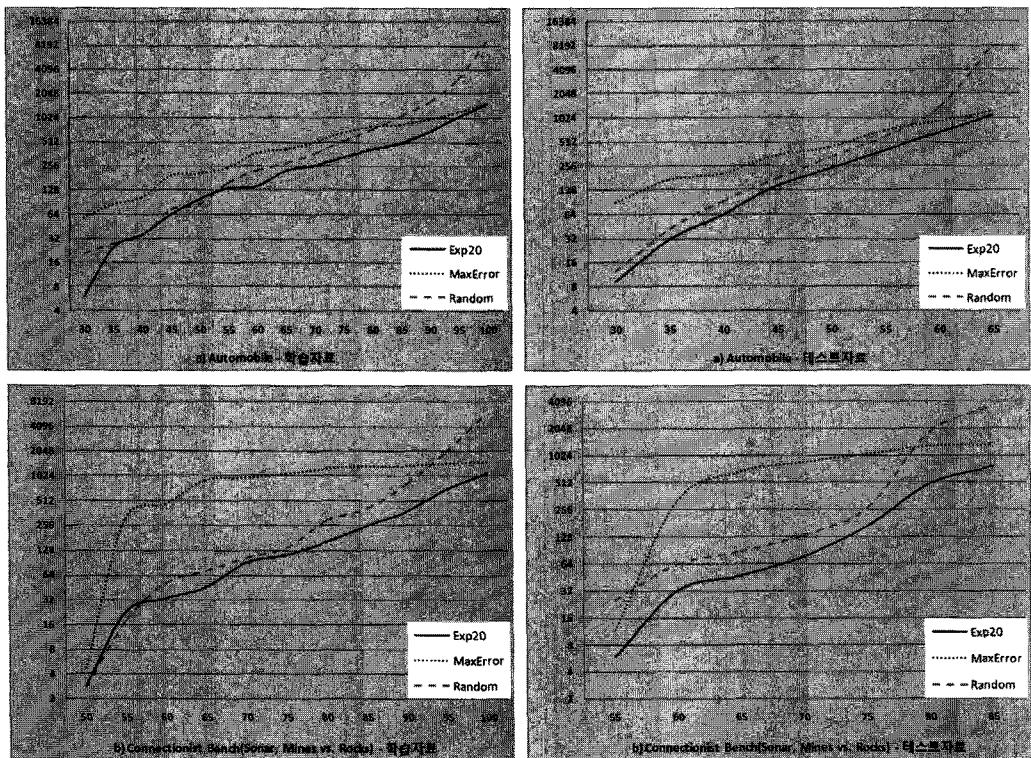


그림 3 분류 정확도에 따른 학습 횟수의 변화

수 있음을 보여준다. Statlog(Vehicle Silhouettes)는 제안한 방법에서 다른 학습 자료들과 달리 최대 학습 횟수까지 학습을 수행했으며, 결과 및 학습 성능 모두 Random의 경우와 유사하여 그 차이를 발견하기 힘들다. 오히려 Exp3의 경우는 학습 능력의 저하를 보여준

다. 이것은 제안한 방법에서 사용한 특징들이 이 학습 자료에게는 적합하지 않은 경우로 생각할 수 있다. 어떤 특징을 사용하느냐가 CRF의 성능에 영향을 준다.

그림 3은 MLP의 분류 정확도에 따른 학습 횟수의 변화를 보여준다. 세로 축은 학습 횟수를 나타내며 기준이

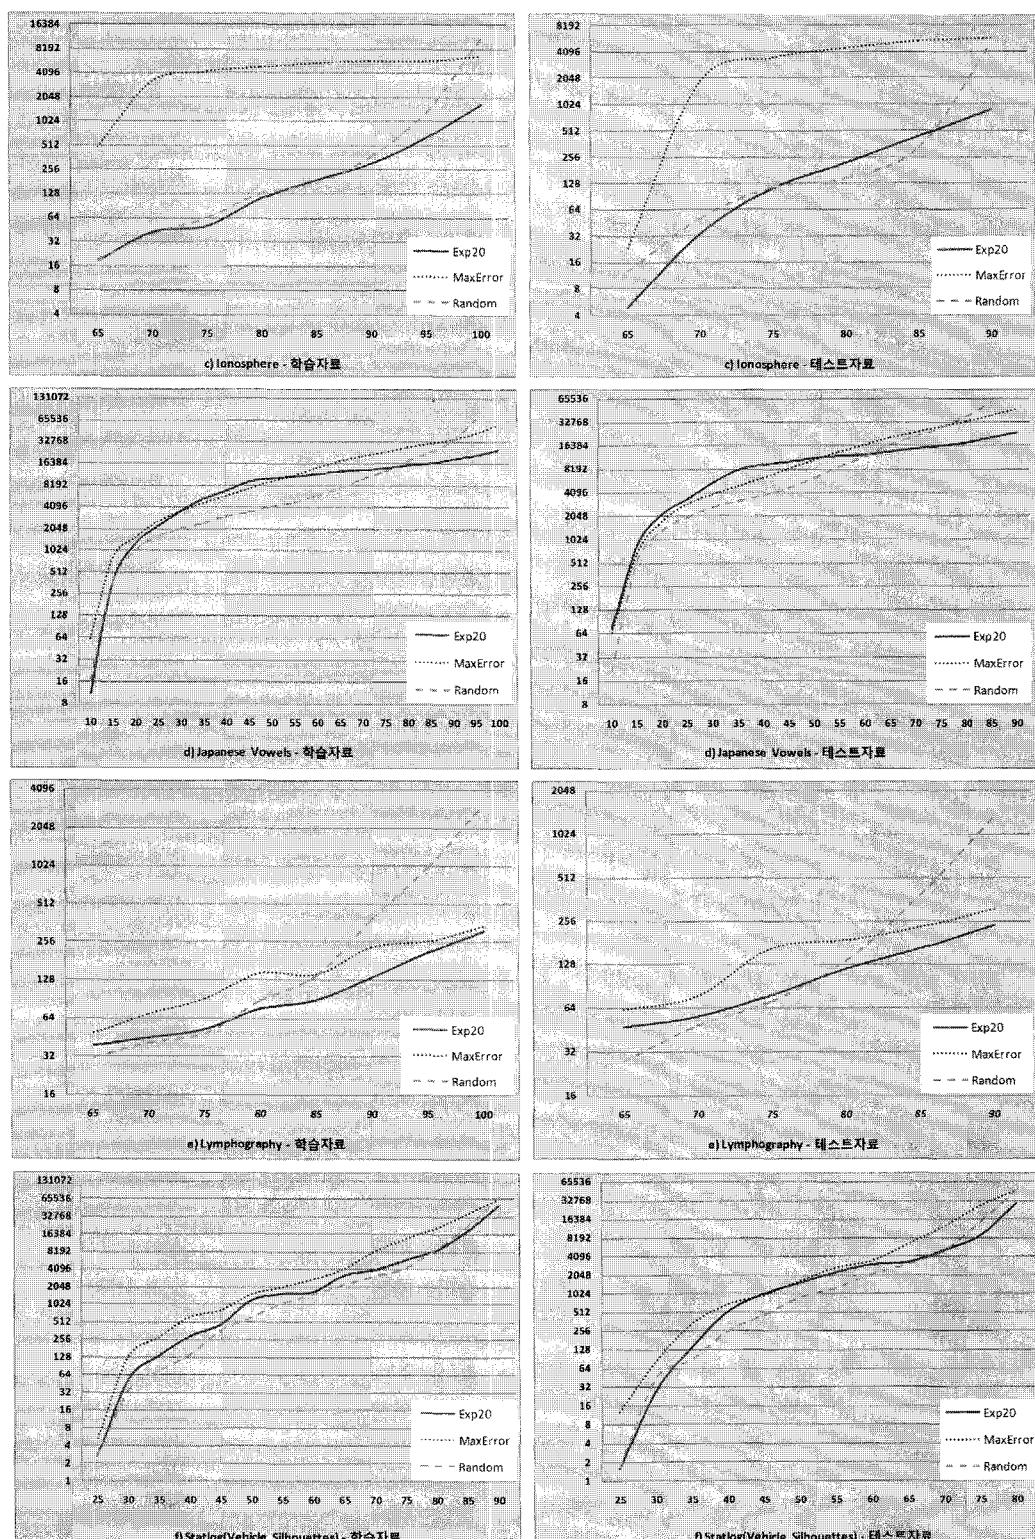


그림 3 분류 정확도에 따른 학습 횟수의 변화 (계속)

2인 로그 간격으로 되어 있다. 가로 축은 분류 정확도 (%)이다. 5%의 간격으로 분류 정확도를 분할한 후, Exp20, MaxError, Random의 방법을 이용하여 각 정확도 구간에 최초 도달할 때까지의 평균 학습 횟수를 비교해 보았다. 이것은 각 목표 정확도에 따라 필요로 하는 학습 횟수를 측정한 것으로서 학습 방법의 효율성과 성능을 잘 나타낸다. 실제 수행하는 학습 횟수는 정해져 있지만, 그럼에서는 학습 자료와 테스트 자료의 학습 횟수가 다르게 표시될 수 있다. 이것은 학습 과정에서 학습 자료의 분류 정확도는 증가하나, 테스트 자료의 분류 정확도는 더 이상 증가하지 않는 경우에 나타난다. 전반적으로 Exp20이 Random보다 빠른 학습 속도를 보이고 있다. Statlog(Vehicle Silhouettes)와 Japanese Vowels의 경우는 다른 곡선들과는 다르게 낮은 정확도에서 Random에 비해 더 많은 학습 횟수를 보이고 있으나 높은 정확도로 갈수록 필요로 하는 학습 횟수가 줄어든다. Statlog(Vehicle Silhouettes)의 경우는 사용된 특징들이 학습 효과 증진에 명확한 역할을 수행하지 못하는 것으로 볼 수 있다. Japanese Vowels의 경우는 표 3에서 나타난 최종 분류 정확도의 차이를 볼 때, 초기에 행해진 학습에 의해 최종적으로 더 나은 결과를 가져왔으므로 경험을 이용한 학습은 이후의 학습에 주는 영향을 고려하여 학습을 진행하는 것으로 볼 수 있다.

MaxError는 다른 선택 방법들에 비하여 학습 초기에 필요로 하는 학습 횟수가 상당히 많다. 특히, Connectionist Bench(Sonar, Mines vs. Rocks), Ionosphere의 경우에서 명확히 나타난다. 이 결과들은 에러가 가장 큰 자료를 선택하는 방법이 가질 수 있는 문제점을 잘 나타낸다. 2.2.3절의 3)의 과정에서 설명한 것처럼, 에러가 가장 크다는 것은 학습 효과가 가장 클 수 있다는 긍정적인 면 보다는 부정적인 측면이 더 많다는 것이다. 학습 자료의 분포를 잘 반영하여 전체적인 성능 향상을 가져오는 것보다, 학습 자료의 실제 분포에서 거리가 먼 자료(outlier)이거나 노이즈의 영향을 받아 왜곡된 자료일 가능성이 높다는 것이다. 이 자료는 오히려 학습에 나쁜 영향을 줄 수 있다. 따라서, 초기에 필요로 하는 학습 횟수가 많은 것은 학습 모델이 학습 자료의 분포를 예측하는데 많은 시행착오의 과정을 거친다는 사실을 나타낸다. 곡선의 기울기에서 시행착오 이후의 학습은 빠르게 진행되는 것을 알 수 있다.

표 4는 각 방법들의 1회 학습에 필요로 하는 평균 학습 수행 시간을 보여주며, 수행 시간은 20회 시도에 대한 평균으로 측정하였다. ()안의 내용은 표 3의 평균 학습 횟수와 측정한 값을 곱하여 나온 결과로, 실제 수행 시간의 예측이다. Random*은 Random과 선택 방법은 같으나, 자료의 학습마다 분류 정확도를 측정한다.

표 4 학습에 소요되는 시간 [ms]

자료이름	Exp20	MaxError	Random	Random*
Automobile	25.42 (38307)	25.26 (39809)	0.25 (5100)	12.46 (254184)
Connectionist Bench (Sonar, Mines vs. Rocks)	17.24 (19170)	16.41 (24615)	0.16 (3328)	8.29 (172432)
Ionosphere	10.77 (17835)	10.12 (68694)	0.06 (2100)	5.07 (177450)
Japanese Vowels	30.30 (763711)	33.50 (2073114)	0.07 (6930)	16.52 (1635480)
Lymphography	6.12 (1903)	5.75 (1972)	0.08 (1184)	2.90 (42920)
Statlog(Vehicle Silhouettes)	10.92 (923832)	10.88 (920448)	0.03 (2538)	5.29 (447534)

측정 시간은 컴퓨터의 상태와 세부 구현 방법에 따라 조금의 차이를 보일 수 있으나, 전체적인 경향을 보는 것은 가능하다. 이 결과에서는 학습 자료를 선택하는 데 발생하는 추가 시간과 그 원인에 대하여 추측이 가능하다. 1회 학습에서 Exp20과 MaxError는 수행 시간이 서로 유사하나 Random에 비하여 많은 차이를 보이며, Random*의 경우에 비해 약 2배의 시간을 필요로 한다. 이것은 분류 정확도를 계산하는데 많은 시간이 소요된다는 사실을 나타내며, Exp20과 MaxError 두 방법 모두 분류 정확도 측정에 소요되는 시간과 유사한 시간을 필요로 하는 다른 추가적인 연산을 수행한다는 것을 의미한다. 추가적인 연산은 MaxError의 경우는 가장 큰 에러를 선택하기 위해 학습 자료들에 대해 에러를 계산하고 자료를 선택하는 것이고, Exp의 경우는 CRF를 이용한 상태 예측과 자료의 선택이다. 분류 정확도 계산과 추가적으로 수행되는 연산은 모두 학습 자료들에 대한 MLP 또는 CRF의 반응을 보는 것이므로 결국 학습 수행 시간은 학습 자료들의 활용 횟수에 비례한다. 따라서, 학습 자료를 선택하는 방법들의 수행 시간은 선택을 위한 학습 자료의 활용 횟수에 의존적이라고 볼 수 있다.

제안한 방법은 표 3의 결과로 볼 때 학습 횟수와 학습 결과에서는 효과가 있으나, 표 4의 ()안의 실제 수행 시간에 대한 예측 값을 볼 때 Random에 비하여 실제 수행 시간 측면에서는 비효율적이다. 실제 구현에서 수행 시간의 차이를 줄일 수는 있으나, 근본적으로 선택을 하는 방법이 학습 자료의 분석에 근거한다면 수행 시간은 더 걸릴 것으로 예측된다. 이것은 Random*의 결과를 볼 때, 분류 정확도 계산에 필요한 시간이 학습에 필요한 시간보다 많이 소요된다는 점에서 추측할 수 있다.

4. 결론 및 향후 연구

지금까지 지도자의 경험을 활용하여, MLP의 순차적 학습에서 학습 순서 제어의 방법과 그 효과에 대하여

고찰하였다. 이것은 실제 교사와 학생간의 교육과 유사하게, 지도자가 학습 성과를 향상시키기 위하여 학습 자료를 MLP의 상태에 따라 적절하게 선택해주는 역할을 수행한다. 지도자는 자신의 경험 정보를 활용하여 MLP의 현재 상태를 파악하고, 그 상태에 적합한 학습 자료를 선택해 준다. 무작위 선택에 의한 학습보다 제안한 방법이 필요로 하는 학습 횟수가 더 적다는 실험 결과를 볼 때, 경험 정보를 활용한 선택이 효과적임을 알 수 있으며, 학습 순서가 학습 결과에 영향을 준다는 사실도 알 수 있다. 또한, 지도자의 경험의 차이가 학습 대상의 학습 결과에도 영향을 주는 것으로 나타난다. 이 결과들은 기계 학습에서도 지도자의 역할이 중요하다는 것을 보여주며, 순차적 학습이 가능한 다른 학습 모델들에도 적용하고 실험해 볼 필요가 있다.

순차적 학습에서 가장 최적화 된 학습 시퀀스를 찾는 일은 매우 어려운 문제이다. 이것은 학습 자료의 수가 많아질수록 고려해야 할 학습 시퀀스의 개수가 너무 많아서 계산이 거의 불가능하다. 또한, 여러 MLP들의 초기 상태가 서로 다른 동적인 환경에서 최적화된 학습 시퀀스를 찾는 것은 더 어려운 문제이다. 따라서 본 연구에서 지도자의 경험은 동적 환경에서 학습 시퀀스 공간에서의 근사화 과정을 수행한다고 볼 수 있다. 경험이 많을수록 학습 시퀀스에 대한 더 나은 근사화 능력을 가진다고 볼 수 있다.

현재 제안한 방법은 여러 MLP를 학습시키는 동안 지도자가 점진적으로 자신의 경험 정보를 정리하고 받아들여 자신의 경험을 향상시키는 것이 아니라, 여러 MLP의 교육에서 나오는 정보들을 특정 시점에서 정리하고 표현하는 일괄적인 방식이다. 이것은 향후 개선되어야 할 사항으로 하나의 MLP를 교육할 때 마다 점진적으로 자신의 경험을 향상시킬 수 있어야 한다. 또한, 학습 자료마다 가지는 특성이 다르기 때문에, CRF에 사용할 특징들을 각 문제에 맞게 잘 정의하고 찾아내는 방법에 대한 연구가 필요하다. 이것은 Statlog(Vehicle Silhouettes)의 실험 결과를 볼 때, 학습 결과에 직접적인 영향을 줄 수 있는 사항이다.

본 연구는 학습자(학습 대상) 중심에서 지도자 중심으로 학습에 대한 관점의 전환을 시도하였다. 이것은 자신의 경험을 통해 지도 능력을 향상시켜가는 지도자 모델에 대한 연구와 지도자 모델을 통해 학습한 학습자들이 어떤 결과를 보이는지를 지도자의 경험 정도와 관련시킨 연구의 필요성을 보여준다.

참 고 문 헌

- [1] Simon Haykin, Neural Networks:A Comprehensive Foundation, 2nd Ed., Prentice Hall, 1999.
- [2] David MacKay, Information Theory, Inference and Learning Algorithms, Cambridge University Press, 2003.
- [3] Corinna Cortes and Vladimir Vapnik, "Support Vector Networks," *Machine Learning*, vol.20, pp.273-297, 1995.
- [4] J. Lafferty, A. McCallum and F. Pereira, "Conditional random fields: Probabilistic models for segmenting and labeling sequence data," *Proc. 18th International Conf. on Machine Learning*, Morgan Kaufmann, San Francisco, CA, pp.282-289, 2001.
- [5] Burr Settles, "Biomedical Named Entity Recognition using Conditional Random Fields and Rich Feature Sets," International Joint workshop on Natural Language Processing in Biomedicine and its Applications (NLPBA/BioNLP), pp.107-110, 2004.
- [6] Charles Sutton and Andrew McCallum, "An Introduction to Conditional Random Fields for Relational Learning : Introduction to Statistical Relational Learning," MIT Press, Chap. 4, pp.93-127, November 2007.
- [7] R. Klinger and K. Tomanek, "Classical probabilistic models and conditional random fields," *Technische Universität at Dortmund, Electronic Publication*, 2007.
- [8] Rahul Gupta, "Conditional random Fields," Technical report, IIT Bombay, 2006.
- [9] Fei Sha and Fernando Pereira, "Shallow parsing with Conditional Random Fields," *Proceedings of the 2003 Conference of the North American Chapter of the Association for Computational Linguistics on Human Language Technology (NAACL '03)*, pp.134-141, 2003.
- [10] Mingkun Li and Ishwar K.Sethi, "Confidence-Based Active Learning," *IEEE Transaction on Pattern Analysis and Machine Intelligence*, vol.28, no.8, pp.1251-1261, Aug. 2006.
- [11] Burr Settles, "Active Learning Literature Survey," Computer Sciences Technical Report 1648, University of Wisconsin-Madison. 2009.
- [12] Fredrik Olsson, "A literature survey of active machine learning in the context of natural language processing," SICS Technical Report T2009:06. Swedish Institute of Computer Science, Kista, Sweden. 2009.
- [13] J.-Y. Lee, H.-S. Kim, "Effect of Training Sequence Control in On-line Learning for Multilayer Perceptron," *Journal of KIISE : Software and Applications*, vol.37, no.7, pp.491-502, Jul. 2010. (in Korean)
- [14] L.R. Rabiner, "A tutorial on hidden Markov models and selected applications in speech recognition," *Proceedings of the IEEE*, vol.77, no.2, pp.257-286, 1989.
- [15] Andrew McCallum, "MALLET: A Machine Learning for Language Toolkit," <http://mallet.cs.umass.edu>, 2002.
- [16] UCI Machine Learning Repository, <http://archive.ics.uci.edu/ml/>

이재영

정보과학회논문지 : 소프트웨어 및 응용
제 37 권 제 7 호 참조

김황수

정보과학회논문지 : 소프트웨어 및 응용
제 37 권 제 7 호 참조