JDCS
디지털콘텐츠학회논문지
Journal of Digital Contents Society
Vol. 25, No. 2, pp. 495-501, Feb. 2024

Fisher의 선형판별함수와 에이다부스트를 응용한 불완전한 데이터 처리 알고리즘

이 종 찬*
*청운대학교 컴퓨터공학과 교수

Algorithm for Handling Incomplete Data with the Application of Fisher's Linear Discriminant Function and Adaboost

Jong Chan Lee*
*Professor, Department of Computer Engineering, ChungWoon University, Incheon 22100, Korea

[요 약]

본 논문은 일부 속성값이 손실된 불완전한 데이터에 대해 손실된 정보를 유추하여 처리함으로써 성능저하를 줄이는데 목적이 있다. 이를 위한 방법으로 앙상블 기법 중에 에이다부스트 알고리즘을 이용하는데, 이 알고리즘의 핵심은 약한 학습기로 결정트리를 만드는 과정과 학습 사건마다 할당된 가중치를 달리하면서 학습 데이터를 샘플링 하는 과정이다. 이 중에서 약한 학습기는 Fisher의 선형분리식을 사용하는 분류기를 불완전한 데이터에 맞게 변형하여 사용하고 절단 과정을 통해 모델을 구성한다.

성능 평가를 위한 실험은 하나의 완전한 결정트리를 사용하는 강한 학습기와 제안 알고리즘의 가중치를 가지는 여러 개의 약한 학습기의 결합된 결과를 가지고 비교하였다. 다시 말해 Fisher의 선형 분류기를 사용하여 학습을 완료한 후 완전한 결정트리를 이용한 결과와, 미리 정한 기준에 따라 학습을 중단하는 과정을 여러 번 반복하여 여러 개의 결정트리를 이용하는 에이다부스트의 결과와 성능을 비교한다. 실험 결과는 실험 데이터마다 차이는 있으나 에이다부스트의 결과가 우수한 것을 확인할 수 있다. 이를 통해 약한 학습기가 가중치의 변화로 여러 모델을 구성하고 이를 학습하여 강한 학습기로 개선됨을 알 수 있다.

[Abstract]

This study aims to mitigate performance degradation by inferring lost information in incomplete data with missing attribute values. To this end, the AdaBoost algorithm - a type of ensemble technique - is employed. This algorithm's core involves creating decision trees as weak learners and varying the weights assigned to each training instance while sampling the training data. Among these, weak learners adapt classifiers using Fisher's linear discriminant function to suit incomplete data and construct the model through a truncation process.

For performance evaluation, experiments compared the results of combining multiple weak learners with weights from the proposed algorithm to the results of a strong learner using a single complete decision tree. That is, the performance between the results obtained using Fisher's linear classifier to complete the training and constructing complete decision trees, and the results from AdaBoost, which involves iteratively repeating the training process, stopping learning based on pre-defined criteria, and utilizing multiple decision trees were compared. Experimental results indicate variations across different datasets but consistently indicate superior performance with AdaBoost. Consequently, it was observed that weak learners improved into strong learners by constructing multiple models with variations in weights and training them.

색인어 : 불완전한 데이터, Fisher의 선형판별함수, 가중치, 에이다부스트, 앙상블
Keyword : Incomplete Data, Fisher's Linear Discriminant Function, Weight, Adaboost, Ensemble

http://dx.doi.org/10.9728/dcs.2024.25.2.495

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-CommercialLicense(http://creativecommons.org/licenses/by-nc/3.0/) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Received 29 December 2023; **Revised** 23 January 2024
Accepted 01 February 2024

***Corresponding Author; Jong Chan Lee**
Tel: ※ 개인정보 표시제한
E-mail: jclee@chungwoon.ac.kr

Ⅰ. 서 론

대부분의 딥러닝 모델에서 네트워크 구조와 초기 상태를 결정하는 문제는 전체 성능에 많은 영향을 주고 있어 이를 위한 많은 연구가 계속되고 있다[1]. 이들 연구에서 여러 분류기를 연합하여 결과를 산출하는 앙상블 기법이 효율적이라는 점에 주목하게 되었다. 앙상블은 배깅(bagging)[2]과 부스팅(boosting)[3]으로 대표되는데, 배깅은 서로 다른 또는 같은 분류기의 학습을 병렬로 결합하고 투표(voting) 기법으로 최종 결과를 결정하는 방법이다[4]. 또한 부스팅은 좋은 성능을 가지는 분류기를 미미한 능력이 있는 많은 수의 약한 분류기(weak classifier)를 직렬로 결합하여 만들 수 있다는 것이다. 이중 가장 일반적인 에이다부스트(adaboost)[5],[6]가 있고, 목적함수의 최저점을 구하기 위해 미분 값을 이용하는 방법을 부스팅에 적용한 Gradient Boosting Machine (GBM)과 GBM에 과적합(overfit)을 방지하기 위한 요소를 추가한 XGBoost(eXtream Gradient Boost) 알고리즘이 있다. 본 논문은 에이다부스트를 이용하는데 이는 학습 데이터를 임의로 샘플링하는 중에 잘못 분류된 사건의 가중치를 증가시켜 약한 분류기가 훈련 사건 집합 안에 분류하기 어려운 사건들에 집중할 수 있도록 하는 과정을 반복적으로 수행한다. 이 특징으로 인해 목적지에 빠르게 수렴한다는 점, 라운드 수를 제외한 별도의 모수가 필요 없다는 점, 약한 분류기에 제약이 없다는 장점을 이용할 수 있다.

불완전한 데이터는 유비쿼터스 환경에서 서로 다른 기기와 수집 환경의 다양화로 인해 일부 속성 또는 속성값이 결손 된 데이터를 말한다. 이러한 데이터는 전체적인 성능저하와 연결되므로 해결하기 위해 주로 결손 데이터를 예측하여 대체하는 여러 알고리즘이 제안되었다. 본 논문은 불완전한 데이터의 결손을 보상하기 위해 Fisher의 선형 판별 함수(FLDF)와 엔트로피를 이용하는 분류기[7],[8]로 이진 트리 형식의 결정트리를 생성하고, 에이다부스트의 약한 분류기로 이용한다. 이 분류기에 절단(pruning) 작업을 추가하여 약한 분류기로 사용한다. FLDF는 다변량 통계의 방법을 기반으로 최적의 투사면을 찾은 다음, 사건들을 이 투사면에 투사하고, 각 투사점들 사이의 엔트로피를 측정해 최적의 분류면을 찾아가는 방식[7]이다. 이 분류기를 불완전한 데이터에 적용하기 위해 학습 데이터를 원-핫 인코딩(One-hot Encoding)과 각 사건에 중요도를 부여할 수 있도록 확장된 데이터 표현을 이용한다. 실험과정을 통해 제안 에이다부스트의 결과와 하나의 완전 결정트리의 결과와 비교하여 앙상블의 결과가 우수함을 보인다.

일반적인 에이다부스트가 ID3, CART 알고리즘을 이용해 결정트리를 구성하여 약한 분류기로 사용한다. 이에 반해 제안 알고리즘은 SVM 계열의 FLDF로 약한 분류기를 구성할 수 있음을 보였다. CART와 ID3는 속성값과 평행한 방향으로만 분류 평면을 구성하며 결정트리를 완성하는 반면 FLDF는 속성의 기울기와 상관없는 초평면으로 결정트리를 구성한다는 차이가 있다. 앞선 연구에서 FLDF의 결과가 다소 우수함을 확인하였다[7],[8].

2장에서는 본 논문과 관련된 기본적인 앙상블 이론과 FLDF를 사용한 약한 분류기와 데이터 확장기법을 소개한다. 3장에서 본 논문에 도입한 절단 과정과 에이다부스트 과정을 소개한다. 4장의 실험을 통해 제안 방법이 우수함을 비교 결과를 통해 보인다.

Ⅱ. 배 경

2-1 앙상블(Ensemble) 학습

앙상블 학습은 하나의 강한 학습기(strong learner)의 결과 보다는 다수의 약한 학습기(weak learner)의 예측들을 투표함으로써 결합하여 정확한 최종 예측을 얻고자 하는 기법이다. 이에 대한 근거는 큰수의 법칙으로부터 “모든 분류기가 완벽하게 독립적이고 오차에 상관관계가 없다”라는 가정하에 유도될 수 있다[9]-[11]. 실제 데이터의 예로, 동전에서 앞면의 확률이 51%라면 뒷면이 나올 확률은 49%이다. 이 경우 동전을 1,000번 던져 앞면이 다수일 확률은 75%(0.747)이고, 10,000번의 경우 97%(0.978)의 확률이 나온다. 이는 이항분포의 확률질량함수로 계산할 수 있다. 즉 특정 사건이 일어날 확률(pl)의 이항분포에서 n번을 시도할 때 s번 성공할 확률은 식 (1)로 표시된다.

$$\binom{n}{s} pl^{s}(1-pl)^{(n-s)} \tag{1}$$

식 (1)에서 앞면이 나올 확률이 51%인 동전을 1,000번 던져 앞면이 나올 확률을 적용하면 식 (2)와 같다. 식 (2)는 1000번을 던져 뒷면이 나올 확률을 모두 더한 것이므로 이 값이 δ라면 앞면이 나올 확률은 (1-δ)이고 이 값이 0.747이다. 10,000번에 대해서도 이와 비슷하게 산출할 수 있다.

$$\begin{aligned} &\binom{1000}{1} 0.51^{1}(1-0.51)^{(1000-1)} \\ &\quad \cdots \quad + \quad \cdots \\ &\binom{1000}{499} 0.51^{499}(1-0.51)^{(1000-499)} \end{aligned} \tag{2}$$

앙상블 학습 기법들을 크게 배깅과 부스팅으로 나누는데, 배깅의 경우 학습 데이터에 샘플링을 다르게 하여 여러 개의 학습 집합으로 나눈 다음, 각각의 데이터에 같은 분류기로 학습을 통해 예측하고, 여러 개의 예측 중에 투표를 통해 최종 결과를 얻는 방법이다. 따라서 각 샘플링과 학습은 서로 독립이므로 병렬로 수행할 수 있다. 반면 부스팅은 학습 데이터로 처음 약한 분류기로 학습하여 예측이 틀린 데이터에 대해 다음에 샘플링 될 가중치를 높임으로써 예측이 틀린 데이터를

정확하게 분류할 기회를 부여하는 기법이다. 최종 결과는 학습 결과에 가중치를 반영하는 투표를 통해 결정한다. 따라서 이 방법은 다수의 분류기가 순차적으로 샘플링과 학습을 반복 수행한다.

이때 투표는 하드와 소프트 보팅으로 나눈다. 하드 보팅은 다수결 원칙과 같이 분류기들의 예측값 중에 다수의 분류기가 결정한 예측값을 최종 투표 결과로 정하는 방법이다. 반면 소프트 보팅은 분류기들의 예측값을 확률로 산출하여 가장 높은 확률을 가지는 부류를 결과로 정하는 방법이다. 예를 들어 3개의 분류기가 2개의 부류에 대해 분류기1={0.7, 0.3}, 분류기2={0.2, 0.8}, 분류기3={0.9, 0.1}와 같이 부류를 예측하였다 할 때 부류1 : 부류2는 2 : 1이므로 최종결과는 부류1로 예측한다. 이에 대해 소프트 보팅은 부류1 : 부류2의 확률을 더하면 {0.7+0.2+0.9 : 0.3+0.8+0.1} = {1.8 : 1.2} = {1.8/3, 1.2/3} = {0.6 : 0.4}. 그러므로 부류가 1일 확률이 60%이므로 부류 1의 결과로 정한다.

2-1 약한 학습기(Weak Learner)

1) FLDF를 이용한 분류기

Fisher의 선형분리함수(FLDF)를 이용하는 분류기[7,8]는 노드당 하나의 분류면(hyperplane : P)을 나타내며, 이 분류면을 기준으로 식 (3)과 같이 패턴(X)을 P^L과 P^L로 분류하는 이진 트리 형식의 결정트리를 형성해 나간다.

$$\begin{aligned} P^R &= \{\ X \mid W^T X \geq T\ \} \\ P^L &= \{\ X \mid W^T X < T\ \} \end{aligned} \tag{3}$$

식 (3)에서 분류면은 가중치 벡터(W)와 임계값(T)으로 구성된다. 여기서 가중치 벡터는 식 (4)와 같은 선형분리 함수에 따라 각 패턴들의 투사면($W^T X$)을 결정하고, 각 패턴들을 투사면에 투사한 다음, 투사점들의 분포에 식 (5)와 같은 엔트로피를 적용하여 임계값을 구하게 된다.

$$\frac{W^T BW}{W^T VW} = \frac{W^T\,[\sum_i (\overline{X}_i - \overline{X})(\overline{X}_i - \overline{X})^T]\,W}{W^T\,[\sum_i \sum_j (X_{ij} - \overline{X}_i)(X_{ij} - \overline{X}_i)^T]\,W} \tag{4}$$

$$H(C|\delta^l) \;=\; PL^* H(p_1) + PR^* H(p_2) \tag{5}$$

식 (5)의 함수에서 사용된 수식은 다음과 같다.

$PL^* = n_1/(n_1+n_2)$ $PR^* = n_2/(n_1+n_2)$, $n_1(n_2)$: 왼/오른쪽 영역으로 분류된 패턴의 수

$H(p_i) = -\sum p_{ij} \log_2 p_{ij}$ i=1,2(왼/오른쪽), j=1,...,부류의 수

x_{ij}= 분류된 각 영역에서 부류 j를 가지는 패턴 수

$p_{ij} = x_{ij}/n_i$

이 알고리즘의 학습 과정을 단계별로 보면 다음과 같다[7],[8],[10].

1. 학습 패턴들을 루트노드에 입력한다.
2. 현재의 노드에서 식 (4), (5)을 이용해 W와 T를 구하고 결정트리의 현재 층에 저장한다
3. 식 (3)의 분류면에 의해 현재 노드의 학습 데이터가 왼쪽(오른쪽) 패턴으로 분류된다.
4. 임의의 노드에서 완전한 분류가 이루어지지 않았으면(부류 수가 2개 이상이면), 분류가 완전히 이루어지지 않은 왼쪽(오른쪽)에 하위 노드를 만든다. 이 노드에 분류되지 않은 패턴들을 입력한 후 2번 과정을 반복한다.

2) 데이터 확장 기법[7],[11]

표 1의 훈련 데이터의 예는 3개의 속성과 1개의 부류(Class)로 구성된다. V1과 V3는 {1, 2}를 가지는 2개, V2는 {1, 2, 3}로 구성된 3개, 그리고 부류는 2개의 카디너리티를 가지고 있다. 표 2는 추가로 수집된 데이터이며 일부 속성값이 손실되었다. 이러한 불완전한 데이터의 경우 이를 처리하기 위한 별도의 데이터 구조와 처리를 위한 알고리즘이 필요하다.

표 1. 학습 데이터의 예
Table 1. The example of learning data

V1	V2	V3	Class
1	3	1	2
2	2	2	1
1	1	2	2

표 2. 손실 데이터의 예
Table 2. The example of missing data

V1	V2	V3	Class
2	?	1	1

(a) V2가 손실됨
(a) V2 is missed

V1	V2	V3	Class
1	2	1	?

(b) 부류가 손실됨
(b) Class is missed

표 3은 표 1과 표 2가 결합하는 예를 보인다. 우선 표 1의 무손실 데이터는 원-핫 인코딩으로 변환한다. 즉, 해당 엔트리에 {0, 1} 중 하나를 채워 넣는다. 반면 표 2의 손실된 엔트리는 0에서 1사이([0, 1])의 확률적 값으로 채워 넣는다. 여기에 가중치(weight, W) 개념을 더하여 각 레코드를 재정의한다. 가중치 값은 각 사건이 얼마나 중요한지를 나타내는 척도이다. 표 3에서 첫 사건의 가중치가 5라면 이 인스턴스는 5개의 사건과 같은 중요도를 가진다고 할 수 있다. 따라서 에이다부스트 알고리즘에서 다음 학습 데이터를 표본 추출할 때 알고리즘에 의해 가중치의 변환을 반영할 수 있게 한다.

표 3. 학습과 손실 데이터로부터 확장된 데이터의 결과.
Table 3. The result of extended data from learning and missing data.

E	W	V1		V2			V3		Class	
		1	2	1	2	3	1	2	1	2
1	5	1	0	0	0	1	1	0	0	1
2	1	0	1	0	1	0	0	1	1	0
3	1	1	0	1	0	0	0	1	0	1
4	1	0	1	1/3	1/3	1/3	1	0	1	0
5	1	1	0	0	1	0	1	0	1/2	1/2

Ⅲ. 불완전한 데이터를 처리하기 위한 에이다부스트

3-1 약한 학습기를 위한 절단(pruning)

딥러닝과 같은 반복적 학습모델과는 다르게 점증적 학습모델은 필요에 따라 확장되므로 학습구조를 미리 결정할 필요는 없으나 데이터에 포함된 잡음(noise)으로 인해 노드의 수가 좌우될 수 있어 이에 대한 대책이 필요하다. 본 논문의 FLDF 분류기도 임의의 노드에서 특정 부류만 남아 있을 때까지 알고리즘이 반복됨으로 시간 및 메모리 낭비의 원인이 되며 성능저하의 원인이 되기도 한다. 더구나 무작위보다 약간 나은(>0.5) 성능을 요구하는 에이다부스트의 약한 분류기 정책에 따라 학습을 완료하지 않고 중단하는 알고리즘이 고안되어야 한다. 본 논문에서는 이에 대해 다음과 같은 간단한 알고리즘으로 절단(pruning) 작업을 사용하였다. 즉 임의의 노드에서 미리 정한 기준값(Prun_Rate)과 N(·)를 비교하여 다음 조건을 만족하면 학습을 종료하는 것이다.

IF(N(·) > Prun_Rate)
  Terminate the learning procedure.

여기서 N(·)는 학습이 이루어 짐에 따라 임의 노드에서 데이터에 포함된 잡음의 비율을 의미하며 식 (6)과 같이 두 가지를 사용할 수 있다. 식 (6)의 (a)는 임의 노드에서 최빈수를 가지는 부류와 기타 부류를 가지는 패턴의 비율을 의미하고, (b)는 전체 패턴 중에 최빈수의 비율을 의미하는 것이다. 실제 실험에서 둘 간의 결과 격차는 미미한 것으로 나타났다.

$$\text{(a) } N_i(X) = \frac{(\#TE - \#MCE)}{\#MCE} \times 100 \qquad (6)$$

$$\text{(b) } N_i(X) = \frac{\#MCE}{\#TE} \times 100$$

#TE : 노드 i에서 패턴의 총수($\sum W_j$, j=1, ⋯, #TE).

#MCE : #TE 중에서 빈도가 가장 많은(num[1]) 부류의 패턴 수($\sum_{k}^{num[j]} W_k$, j=1,⋯, #MCE).

3-2 에이다부스트(Adaboost)

배깅은 학습 데이터 집합에 대해 중복을 허용하면서 각각 다른 학습 데이터로 샘플링 한 후, 이 데이터들을 학습하여 여러 개의 결정트리를 병렬로 구성한 다음, 테스트 데이터를 이들 결정트리에 입력하여 각 결정트리의 결과들을 투표하여 다수결로 가설에 대한 부류를 결정한다. 반면 부스팅은 약한 학습기 여러 개를 결합하여 강한 학습기를 만드는 앙상블 기법인데 이중 가장 널리 사용하는 것이 “adaptive+ boosting”을 결합한 에이다부스트[12]-[14]이다. 이는 이전 예측기를 보완하는 새로운 예측기를 만들기 위해 이전 모델에서 오류를 발생시킨 훈련 샘플의 가중치를 높이는 것이다. 즉, 새로 만드는 예측기 모델은 학습하기 어려운 샘플에 점점 더 맞춰 나가는 것이다.

이를 설명하는 것이 그림 1에 나타난다. 우선 데이터를 학습과 테스트 집합으로 분리한 후, 임의로 정한 학습 집합에 FLDF 알고리즘에 절단을 적용한 모델로 학습한다. 이때 오류를 고려한 가중치(a_i)에 따라 샘플링하여 새로운 학습 집합을 구성하고 모델을 통해 새로운 가설($h_i(x)$)을 세우는 과정을 정해진 수(m)만큼 반복한다. 그리고 테스트 사건을 m 개의 모델에 입력하고 여기에 가중치의 영향을 더하여 최종 결과를 산출한다.

본 논문에서 사용한 에이다부스트의 구체적인 설명은 다음과 같다.

우선, $(x_1,y_1),...,(x_n,y_n)$, $x_i \in X$, $y_i \in Y = \{-1,+1\}$에 대해 다음과 같이 정의한다.

- n : 학습 데이터 개수
- m : 분류기 개수(number of classifiers)
- $h_j(x)$: 모델(model) 또는 분류기(classifier)
- $I(A)$: 지표함수(Indicator function)
  $IF(A = True)\ Return\ (1)$
  $ELSE\ Return\ (0)$
- L_j : 에러 함수(weighted error function)

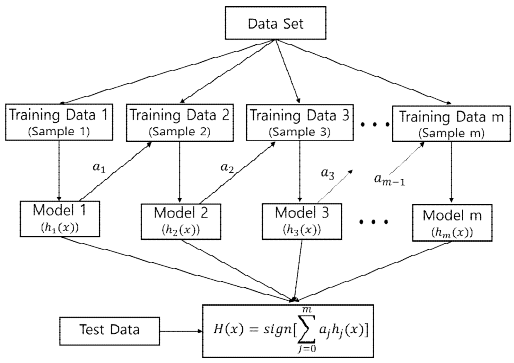

그림 1. 에이다부스트의 학습 과정
Fig. 1. The learning procesure of Adaboost

정의된 기호로 부터 알고리즘은 단계별로 다음과 같이 전개된다.

초기화 과정 :

1. Set initial weight $W_i = 1/n,\ i = 1,...n$

학습 과정 :

2. For j=1 to m

Step 1 : Find $h_j(x)$ that minimizes L_j.

$$L_j = \frac{\sum_{i=1}^{n} W_i\, I(y_i \neq h_j(x))}{\sum_{i=1}^{n} W_i} \tag{7}$$

Step 2 : Define the weight of a classifier.

$$a_j = \log\frac{(1-L_j)}{L_j} \tag{8}$$

Step 3 : Update weight

$$W_{t+1}(i) = \frac{W_t(i)}{Z_t} \times \begin{cases} e^{-a_j t}, \text{if}\,(h_t(x) = y_i) \\ e^{a_j t}\ \ , \text{if}\,(h_t(x) \neq y_i) \end{cases} = \frac{W_t(i)\exp\{a_j y_i h_t(x_i)\}}{Z_t} \tag{9}$$

Endfor

출력 과정 :

3. Final boosted model

$$H(x) = sign[\sum_{i=1}^{m} a_j h_j(x)] \tag{10}$$

식 (7)은 L_j = 틀린수/전체로 틀린 비율을 의미한다. 식 (8) 은 분류기의 가중치를 결정하는 것으로 다음으로 설명된다.

IF $L_j = 0$(오류가 없는) $a_j = \log\frac{1}{0} = \infty$
(그림 2의 (a) 로그 그래프에서 + ∞ 쪽에 해당)

ELSEIF $L_j = 0.5$(헛갈리는) $a_j = \frac{1-0.5}{0.5} = \log 1 = 0$

ELSE $L_j = 1$(전부 틀리는) $a_j = \log\frac{0}{1} = -\infty$
(그림 2의 (a)에서 [0,1] 구간에 해당)

식 (9)는 그림 2 (b)의 exp 그래프에서 식 (11)의 성질을 확인할 수 있다.

$$IF(a > 0)\ \ e^a > 1 \qquad ELSEIF(a < 0)\ \ e^a < 1 \tag{11}$$

다시 말해 가중치(a)가 0보다 크면 가중치 변화량(e^a)을 1보다 크게 한다. 반면에 0보다 작으면 가중치 변화량(e^a)을 1보다 작게 한다. 여기서 z_t는 가중치를 [0,1] 구간으로 만들기 위한 정규화 요소이다. 식 (10)은 최종 판정을 위해 가중치를 고려하는 각 분류기의 결과를 하나로 합치는 것을 의미한다.

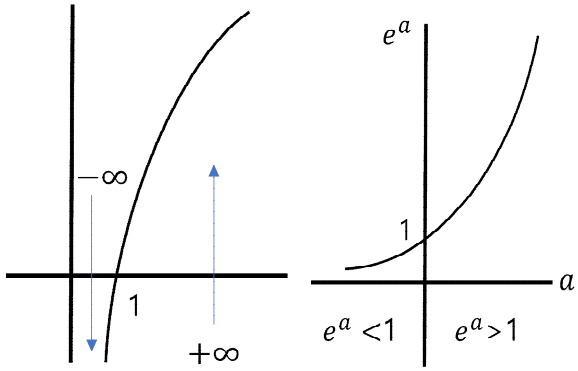

(a) weight (b) weight update

그림 2. 가중치와 가중치 변화율

Fig. 2. Weights and weight update rates

Ⅳ. 구 현

실험에 사용된 데이터는 UCI 기계 저장소[15]에서 “Balance Scale Weight & Distance Database (BSO)”와 “Car Evaluation Database(Car)”를, 그리고 “Sleep stage scoring data set(Sleep)”를 사용하였다. BSO는 625개 사건 (3 변수, 3 부류)을, Car는 1728개 사건(6 변수, 4 부류)을 가진다. 그리고 Sleep은 799개 사건(11 변수, 6 부류)을 가진다. 각 데이터에는 10-겹 교차 검증 방법을 적용하여 결과를 산출하였다. 즉, 전체 데이터 집합을 임의로 10개 블록으로 나누고 교대로 9개는 실험에 하나는 테스트로 사용한 후, 실험 결과의 평균을 산출한다. 이 결과가 표 4에 나타나 있다. 실험은 12개로 고정된 약한 분류기 상에서 손실률(Prun_Rate)을 각 변수당 5%, 15%, 30%, 45%씩 증가하면서 실행하였다. 3.1절에서 식 (6)에 소개되었던 두 절단 방법을 사용한 결과에는 커다란 차이가 나지 않는 것을 확인했으며 표 4의 실험은 식 (6)에서 (a) 식을 사용한 결과이다.

제안 시스템의 결과를 비교하기 위해 2.2절에서 소개한 데이터 확장기법으로 손실 데이터를 형식을 변경한 후 FLDF을 이 데이터에 맞게 변형한 분류기로 학습한 결과와 같은 데이터로 실험하여 비교하였다. 즉 이 분류기는 완전한 결정트리 하나로만 산출한 결과(표 4에서 흰색)이고, 제안 결과는 약한 분류기로 분류한 여러 개의 결정트리와 가중치로 에이다부스트 알고리즘으로 산출한 결과(표 4에서 음영색)이다. 실험한 전체 데이터에서 에이다부스트의 결과가 우수한 것으로 나타났고 이를 명확하게 표시하고자 각 손실률 별로 결과의 평균값을 그래프로 비교한 것이 그림 3에 나타나 있다. 여기서 “Uniform”이 하나의 분류기로 결정트리로 산출한 결과이고, “Adaboost”가 약한 분류기 여러 개가 연합하여 산출한 결과이다. 결과들에서 보듯이 에이다부스트의 결과가 우수한 것을 확인할 수 있으며 이는 앙상블 기법을 사용한 결과로 생각할 수 있다. 다시 말해 앙상블의 이론에서 말하는 바와 같이 하나의 완벽한 결정트리(강한 분류기)보다는 다수개의 미미한 성

능을 가지는 결정트리(약한 분류기)를 결합하여 투표를 한 결과가 성능면에서 앞선다는 것을 확인하는 결과라 할 수 있다.

표 4. 실험 결과
Table 4. Experiment results

	5	15	30	45
V1	89.559	87.145	86.414	89.001
	91.652	90.952	91.379	88.207
V2	88.028	89.069	88.222	84.402
	90.543	91.340	89.331	89.515
V3	88.380	88.537	87.577	84.237
	93.600	93.164	89.968	88.604
V4	91.570	88.066	86.718	81.883
	92.767	92.881	89.465	86.560
AVG	89.384	88.204	87.233	84.881
	92.141	92.084	90.036	88.221

(a) Balance Scale Weight & Distance Database

	5	15	30	45
V1	88.446	87.429	86.124	85.334
	93.794	93.765	92.009	91.237
V2	88.723	86.705	88.729	87.711
	93.641	92.961	92.655	91.691
V3	88.918	88.695	89.085	88.107
	93.513	93.794	92.845	92.369
V4	88.441	86.556	88.344	86.109
	93.494	93.167	91.512	89.437
V5	87.443	87.407	87.504	87.179
	93.091	93.177	92.203	88.987
V6	87.610	85.565	86.396	83.035
	93.116	92.047	90.344	87.958
AVG	88.263	87.059	87.697	86.246
	93.441	93.152	91.928	90.280

(b) Car Evaluation Database

	5	15	30	45
V1	85.953	84.428	86.059	86.783
	89.020	88.381	87.577	87.602
V2	86.535	86.410	86.589	85.277
	90.117	89.601	90.213	90.000
V3	86.520	87.290	86.330	84.497
	89.000	90.429	90.078	87.218
V4	87.628	85.308	84.736	83.912
	90.025	87.270	87.206	87.905
V5	86.163	88.029	86.327	85.885
	90.494	89.312	89.169	90.062
V6	88.804	85.417	85.652	83.876
	90.482	89.520	89.620	89.839
V7	89.114	86.628	85.916	85.814
	88.251	88.652	89.286	89.831
V8	85.852	86.033	86.487	85.883
	89.950	89.591	89.781	88.903
V9	86.448	88.098	85.149	86.569
	90.141	91.551	90.909	91.425
V10	85.822	86.359	84.929	84.061
	89.158	89.926	87.453	87.125
V11	84.813	87.078	85.971	82.850
	87.665	89.911	90.339	88.628
AVG	86.696	86.462	85.831	85.037
	89.482	89.468	89.239	88.958

(c) Sleep stage scoring data set

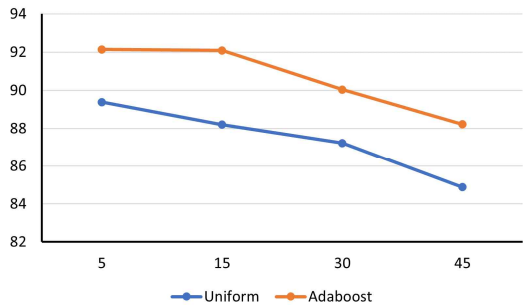

(a) BSO

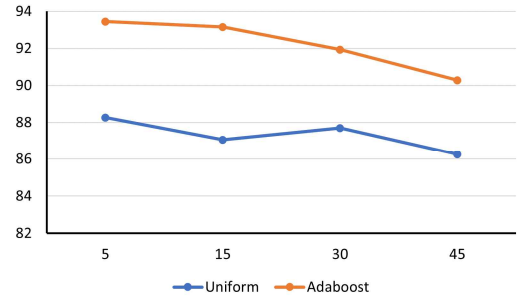

(b) Car

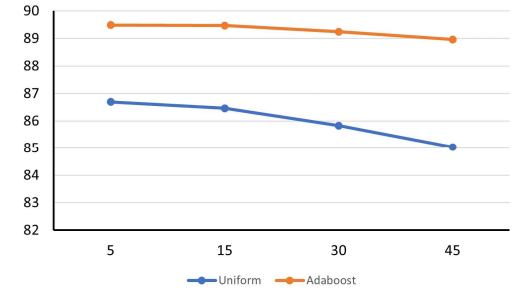

(c) Sleep

그림 3. 표 4의 결과의 비교
Fig. 3. Comparison of results in Table 4

V. 결 론

지금까지 본 논문은 앙상블 기법 중에 에이다부스트를 이용하는 과정을 살펴보았다. 여기서 약한 분류기로 FLDF에 절단 알고리즘을 적용해 사용하였고 실험 과정에서 강한 학습기인 단일 결정트리의 결과보다는 우수한 결과를 보임을 확인하였다.

그동안 에이다부스트는 여러 분야에서 다양한 문제에 적용하여 성능 개선을 위해 이용되어왔다. 그러나 학습 데이터의 수가 충분하지 못하거나, 학습 데이터에 많은 노이즈나 손실이 있는 경우 등에서 불완전한 결과가 산출될 수 있음을 많은 연구자들이 지적하였다. 이에 대해 약한 학습기가 또 다른 약한 학습기로 정보를 전이하는 과정에서 알고리즘적인 보완이 뒤따라야 할 것으로 본다. 그리고 차기 연구로는 요즘 여러 응용 분야에서 주목을 받고 있는 GBM과 XGBoost를 불완전

한 데이터 처리 문제에 이용하는 방안에 대해 고려하고 있다. 물론 정통 딥러닝보다는 관심의 정도가 약하더라도 결과를 서로 비교할 수 있을 정도로 우수하므로 연구할 만한 충분한 가치가 있을 것으로 본다.

감사의 글

본 논문은 청운대학교의 2023학년도 학술연구조성비(학술 2023-47)에서 지원을 받았음.

참고문헌

[1] M. Kantardzic, *Data Mining: Concepts, Models, Methods, and Algorithms*, Hoboken, NJ: Wiley-IEEE Press, 2002.

[2] L. Breiman, "Bagging Predictors," *Machine Learning*, Vol. 24, No. 2, pp. 123-140, August 1996. https://doi.org/10.1007/bf00058655

[3] Y. Freund and R. E. Schapire, "Experiments with a New Boosting Algorithm," in *Proceedings of the 13th International Conference on Machine Learning (ICML '96)*, Bari, Italy, pp. 148-156, July 1996.

[4] T. G. Dietterich, "An Experimental Comparison of Three Methods for Constructing Ensembles of Decision Trees: Bagging, Boosting, and Randomization," *Machine Learning*, Vol. 40, No. 2, pp. 139-157, August 2000. https://doi.org/10.1023/a:1007607513941

[5] N. Cristianini and J. Shawe-Taylor, *An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods*, Cambridge, UK: Cambridge University Press, 2000.

[6] X. Li, L. Wang, and E. Sung, "A Study of AdaBoost with SVM Based Weak Learners," in *Proceedings of 2005 IEEE International Joint Conference on Neural Networks*, Montreal, Canada, pp. 196-201, July-August 2005. https://doi.org/10.1109/IJCNN.2005.1555829

[7] J. C. Lee, D.-H. Seo, C.-H. Song, and W. D. Lee, "FLDF Based Decision Tree Using Extended Data Expression," in *Proceedings of 2007 International Conference on Machine Learning and Cybernetics*, Hong Kong, pp. 3478-3483, August 2007. https://doi.org/10.1109/ICMLC.2007.4370749

[8] J. C. Lee, "Application Examples Applying Extended Data Expression Technique to Classification Problems," *Journal of the Korea Convergence Society*, Vol. 9, No. 12, pp. 9-15, December 2018. https://doi.org/10.15207/JKCS.2018.9.12.009

[9] R. Polikar, L. Udpa, S. S. Udpa, and V. Honavar, "Learn++: An Incremental Learning Algorithm for Supervised Neural Network," *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, Vol. 31, No. 4, pp. 497-508, November 2001. https://doi.org/10.1109/5326.983933

[10] J. C. Lee, "Algorithm to Handling Incomplete Data from Decision Tree Using SVM," *Journal of Knowledge Information Technology and Systems,* Vol. 17, No. 6, pp. 1145-1153, December 2022. https://doi.org/10.34163/JKITS.2022.17.6.006

[11] A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras & Tensorflow*, 2nd ed. Sebastopol, CA: O'Reilly, 2019.

[12] H. Schwenk and Y. Bengio, "Boosting Neural Networks," *Neural Computation*, Vol. 12, No. 8, pp. 1869-1887, August 2000. https://doi.org/10.1162/089976600300015178

[13] T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System," in *Proceedings of the 22nd ACM Sigkdd International Conference on Knowledge Discovery and Data Mining (KDD '16)*, San Francisco: CA, pp. 785-794, August 2016. https://doi.org/10.1145/2939672.2939785

[14] R. J. A. Little and D. B. Rubin, *Statistical Analysis with Missing Data*, 2nd ed. Hoboken, NJ: John Wiley & Sons, 2002.

[15] UCI Machine Learning Repository. Datasets [Internet]. Available: https://archive.ics.uci.edu/datasets

이종찬(Jong Chan Lee)

1988년 : 충남대학교 계산통계학과 (학사)

1990년 : 충남대학교 전산학과 대학원 (석사)

1996년 : 충남대학교 전산학과 대학원 (박사)

1996년～현 재: 청운대학교 컴퓨터공학과 교수

※관심분야 : 딥러닝, 패턴분류, 최적화문제, 데이터압축