

다중 모델 출력 융합을 위한 MAP 부스팅 기반 앙상블 기법

서어진 이남윤
포항공과대학교

eojinseo77@postech.ac.kr nylee@postech.ac.kr

MAP Boosting-Based Ensemble Method for Multi-Model Output Integration

Eojin Seo and Namyoon Lee
POSTECH

요약

머신러닝의 분야 중 분류(classification)가 다양한 Safety-Critical 응용 분야에서 쓰이며 고성능 분류기의 필요성이 대두되고 있다. 그러나 단일 모델의 성능 향상에는 막대한 자원이 요구되며 기존의 앙상블(ensemble) 기법은 모델 간 성능 차이나 상관관계가 클 때 성능 향상에 한계가 있다. 본 연구에서는 이러한 문제를 해결하기 위해 이진 분류 문제에 대해 여러 사전학습(pre-trained) 모델의 출력을 통합하여 성능을 향상시키는 최대 사후 확률(Maximum A Posteriori, MAP) 부스팅(boosting) 기반 앙상블 기법을 제안한다. MAP 부스팅의 핵심 아이디어는 각 이진 분류기를 이진 비대칭 채널로 모델링하고, 채널의 통계적 특성을 활용하여 MAP 복호화를 수행하는 데 있다. 실험을 통해 모델 간 독립성을 가정한 근사 MAP(approximate MAP) 부스팅 방식과 MAP 부스팅 방식을 기존 앙상블 기법인 다수결(majority voting) 및 소프트 보팅(soft voting)과 비교하였다. 실험 결과를 통해 각 모델의 분류 성능이 상이하거나 데이터 상관관계가 있는 경우 기존 방법보다 제안한 MAP 부스팅 방법으로 성능이 더욱 향상되었음을 확인했다.

I. 서론

머신러닝의 지도 학습 분야에서 분류(classification)는 입력 데이터를 사전 정의된 범주로 할당하는 핵심적인 작업이다. 특히, 고성능 분류기는 의료 영상 분석을 통한 질병 진단, 자율 주행 차량의 객체 인식, 또는 금융 사기 탐지와 같이 시스템의 안정성과 신뢰성이 필수적인 Safety-Critical 응용 분야에서 중추적인 역할을 한다. 이러한 시스템에서는 정확도 향상이 필수적이지만, 특정 임계점을 초과하는 성능 향상에는 필요한 연산 자원과 학습 데이터셋이 기하급수적으로 증가한다. 따라서 하나의 대형 모델을 단독으로 학습시키기보다, 이미 학습된 여러 사전학습 모델의 출력을 결합하여 보다 효율적으로 성능을 향상시키는 앙상블(ensemble) 기법이 주목받고 있다.

기존에 널리 쓰이는 앙상블 기법으로는 배깅(bagging)과 부스팅(boosting) 기법이 있다. 배깅 기반 앙상블 방법은 각 모델의 출력값을 평균하거나 다수결로 결정하여 모델 간의 개별 성능 차이를 고려하지 못하고, 성능이 낮은 모델이 섞여 있을 경우 전체 성능이 저하될 수 있다 [1]. 또한, 앙상블을 구성하는 모델들이 높은 상관관계를 가질 경우 분산 감소 효과가 제한된다는 한계가 있다 [2]. 부스팅 기법은 서로 다른 가중치를 지닌 데이터셋으로 분류기를 순차적으로 학습시키는 과정을 반복하여 각 모델의 성능에 비례하는 가중치를 부여하는 앙상블 기법이다. 그러나 순차 학습 방법인 부스팅은 이미

학습되어 있는 모델의 결과를 이용하여 추론을 하는 본 논문의 취지와는 다르다.

이에 본 논문에서는 이진 분류 문제를 최대 사후 확률(Maximum A Posteriori, MAP) 복호화 관점에서 해결하는 고성능 앙상블 분류기를 제안한다. 앙상블의 각 모델을 이진 비대칭 채널로 모델링하고, 각 채널의 통계적 특성을 반영하여 MAP 부스팅을 통해 최적의 판정 성능을 달성하고자 한다. 기존의 SignSGD-FV 연구는 그래디언트 전송 환경을 이진 대칭 채널에서의 반복 코드(repetition code) 복호화 문제로 모델링한 알고리즘을 제안한 바 있다 [3]. 이처럼 통신 이론의 접목은 머신러닝 시스템의 다양한 측면에서 최적화의 가능성을 제시한다. 본 논문에서 제안하는 방법은 MAP 부스팅을 통해 통계적 최적 결정을 수행함으로써 기존의 앙상블 방법보다 우수한 성능을 달성한다. 또한 모델 간 독립성을 가정한 근사 MAP(approximate MAP, approxMAP) 부스팅과 실제 상관관계를 고려한 MAP 부스팅을 비교하여 제안 기법의 효용성을 검증하였다.

II. 본론

1. 시스템 모델

본 논문에서는 개와 고양이를 분류하는 이진 분류 문제를 대상으로, 세 개의 서로 다른 모델을 이용하여 입력 데이터 X 에 대한 출력값을 각각 Y_1, Y_2, Y_3 로 정의하였다.

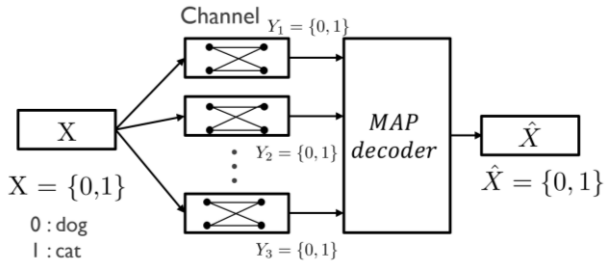


Figure 1. Model structure of MAP decoder for multi-model.

이때 MAP은 다음과 같은 확률식으로 표현된다.

$$\hat{X}_{MAP} = \operatorname{argmax}_{x \in \{0,1\}} P(X = x | Y_1 = y_1, Y_2 = y_2, Y_3 = y_3). \quad (1)$$

MAP 부스팅은 모델 간의 상관관계를 고려하여 각 모델 출력 간의 조건부 결합 확률(joint conditional probability)을 계산하고, 이를 이용해 테스트 데이터의 사후확률을 비교하여 더 높은 확률을 갖는 레이블을 선택한다. MAP 부스팅은 분류 오차를 최소화할 수 있으나, 각 모델 결과의 모든 경우의 수를 기억해야 하기 때문에 분류기 레이블 수 또는 모델의 개수가 증가하였을 때 연산 자원의 부담이 커진다.

이러한 상황에서 성능은 sub-optimal 하지만 계산량을 줄인 approxMAP 부스팅을 제안한다. 모델 간 독립성을 가정한 approxMAP은 다음과 같은 확률식으로 표현된다.

$$\hat{X}_{MAP} = \frac{1}{2} - \frac{1}{2} \cdot \operatorname{sign} \left(\log \left(\frac{\prod_{i=1}^N P(Y_i = y_i | X = 0) P(X = 0)}{\prod_{i=1}^N P(Y_i = y_i | X = 1) P(X = 1)} \right) \right). \quad (2)$$

2. 시뮬레이션 결과

1) 실험 1 : 고성능 모델 앙상블

본 실험에서는 사전 학습된 높은 성능의 모델들을 대상으로 각 모델의 정확도와 다수결 기법(majority voting, MV), 소프트 보팅(soft voting, SV), approxMAP 및 MAP 부스팅 방법의 성능을 측정하였다. 성능 측정 지표로는 5000 개의 테스트 데이터셋에 대해 분류 정확도를 측정하였다. 대상으로 한 모델은 ResNet18, ResNet50, DenseNet121 이다.

Model	ResNet18	ResNet50	DenseNet121
Accuracy(%)	95.30	96.68	97.24
MV	97.56		
SV	97.50		
approxMAP	97.56		
MAP	98.80		

Table 1. Simulation results for experiment 1.

제안한 approxMAP 부스팅은 개별 모델 중 가장 성능이 좋은 DenseNet121 보다 0.33%, SV 기법보다 약 0.06% 성능이 향상되었으며, MV 와는 성능이 동일했다. MAP 부스팅은 approxMAP 부스팅보다 1.27% 추가 성능 향상으로 비교군 중 가장 높은 성능을 보였다.

2) 실험 2 : 다양한 성능 모델 앙상블

간단한 합성곱 신경망(CNN) 모델(simpleCNN), 복잡한 CNN 모델(deepCNN), ResNet18 모델을 사용하였다.

Model	simpleCNN	deepCNN	ResNet18
Accuracy(%)	76.68	82.80	95.30
MV	89.28		
SV	91.88		
approxMAP	93.36		
MAP	95.30		

Table 2. Simulation results for experiment 2.

제안한 approxMAP 부스팅은 MV 보다 약 4.57%, SV 보다 약 1.61% 성능이 향상되었으나 개별 모델 중 가장 성능이 좋은 ResNet18 보다 약 2.04% 성능이 감소하였다. 그러나 MAP 부스팅은 approxMAP 보다 약 2.08%의 추가적인 성능 향상을 보이며 비교군 중 가장 뛰어난 성능을 보였다. 본 실험에서와 같이 모델 간 성능 차이가 큰 경우 기존 앙상블 방법으로는 개별 모델의 성능을 뛰어넘지 못했으나, 제안한 MAP 부스팅 기법으로는 이러한 문제를 해결했음을 확인할 수 있었다.

III. 결론

본 논문에서는 여러 사전학습 모델의 출력을 통신이론 관점에서 해석하고, MAP 부스팅 기반 앙상블 기법을 제안하였다. 본 방법은 추가적인 학습 과정 없이 기존 모델의 출력을 확률적으로 융합하여 효율적인 성능 향상을 달성하였다. 또한 모델 간 성능 차이가 상이하거나 상관관계가 있는 경우 기존 배경 방식이 가지는 성능 상한을 극복함을 실험적으로 확인하였다. 제안한 기법은 이진 분류 상황에서 머신러닝 앙상블 문제를 통신 이론의 관점에서 접근하는 새로운 방향을 제시한다.

ACKNOWLEDGMENT

a grant of Korean ARPA-H Project through the Korea Health Industry Development Institute (KHIDI), funded by the Ministry of Health & Welfare, Republic of Korea (Grant number: RS-2025-25454431).

참 고 문 헌

- [1] Y. Freund and R. E. Schapire, "A decision-theoretic generalization of on-line learning and an application to boosting," *Journal of Computer and System Sciences*, vol. 55, no. 1, Aug. 1997.
- [2] L. K. Kuncheva and C. J. Whitaker, "Measures of diversity in classifier ensembles and their relationship with the ensemble accuracy," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 33, no. 2, Apr. 2003.
- [3] C. Park, H. V. Poor, and N. Lee, "SignSGD with Federated Voting," *IEEE Journal of Selected Topics in Signal Processing*, vol. 18, no. 5, pp. 1178-1192, May 2024.