

신경망 탐색을 이용한 최적의 운전자 행위 분류 모델

성재호, 유민우, 김지훈, 한동석*

경북대학교

*dshan@knu.ac.kr

Optimal Driver Behavior Classification Model Using Neural Network Search

Jae Ho Seong, Min Woo Yoo, Ji Hun Kim, Dong Seog Han*

Kyungpook Univ.

요 약

본 논문에서는 최적의 운전자의 행위를 분류하기 위하여 ENAS(efficient neural architecture search)기반의 CNN(convolutional neural network) 모델을 제안한다. 기존 딥러닝 기반 DMS(driver monitoring system)는 CNN을 사용하여 운전자의 상태를 예측하는데 효과적이다. 그러나 CNN 기반의 시스템은 연산량이 많고 임베딩 기기와 같은 제한된 자원 환경에서 적용을 위한 모델 구조 최적화가 요구된다. 본 논문에서는 제안한 ENAS기반의 운전자 행위 분류 모델이 기존 경량화 모델의 분류 성능 보다 향상됨을 보였다.

I. 서 론

운전자의 부주의한 행동은 교통사고의 주요한 원인이다[1]. 따라서 DMS(driver monitoring system)를 통해 운전자의 의도를 예측하고 긴급 상황에서 차량 제어에 개입하여 사고를 방지하는 것이 중요하다. 최근 DMS는 CNN(convolutional neural network)을 주로 사용한다. 예를 들어 CNN을 이용한 얼굴 검출, 헤드 포즈, 시선 추정 등의 알고리즘을 통해 운전자의 상태를 예측하고자 하는 연구가 활발히 진행 중이다[2]. 기존의 CNN 기반의 딥러닝 모델은 운전자의 상태를 예측하는데 매우 효과적이다. 그러나 CNN 기반의 DMS는 계산량이 많고, 차량 내부에 적용을 하기 위한 임베딩 기기는 제한적인 자원 환경을 가진다. 따라서 DMS에 운전자 행위 분류 모델 적용을 위한 경량화 작업이 필요하다. 또한 딥러닝 기반의 분류 모델은 데이터의 종류와 네트워크의 구조에 따라 성능이 변화하므로 최적화 작업에 많은 노력과 시간이 소요된다. 이를 해결하기 위하여 목표 데이터에 모델을 자동으로 최적화할 수 있는 AutoML(automated machine learning) 기법들이 제안되었다. 그 중에서 NAS(neural architecture search) 기법을 사용하면 CNN 네트워크의 구조를 자동으로 설계하고 최적화할 수 있다 [3]. 그리고 NAS 기법 중 ENAS(efficient neural architecture search)는 모델의 가중치를 공유하여 단일 GPU로 짧은 시간안에 CNN 네트워크를 탐색할 수 있다[4].

본 논문에서는 제한된 자원 환경에서 운전자 행위 분류 모델을 적용하기 위하여 ENAS 기반의 CNN 모델을 제안한다. 실험을 통하여 수집한 운전자 행위 데이터셋에 대해 최적의 운전자 행위 분류 모델 탐색하고 제안한 모델의 분류 성능이 기존 딥러닝 기반 경량화 모델보다 성능이 향상됨을 보였다.

II. 본론

2.1 ENAS 모델 생성 과정




그림 1. ENAS 모델 생성 과정. (a) RNN 제어기. (b) CNN의 전체 네트워크 구조. (c) CNN 셀 생성 과정.

ENAS는 그림 1(b)와 같이 전체 CNN을 설계하는 것이 아닌, 작은 모듈 형태의 일반 셀과 축소 셀을 생성하고, 이를 연결하여 전체 CNN을 구성한다. 일반 셀은 같은 차원의 특징 맵을 생성하고, 축소 셀은 특징 맵의 높이와

너비를 반으로 줄인다. 그림 1(a)와 같이 RNN(Recurrent Neural Network) 제어기에서는 CNN 셀을 설계하기 위한 연산과 연산을 수행할 노드의 번호를 선택한다. 그림 1(c)는 CNN 셀 생성 과정을 나타낸다. 예를 들어 모듈이 B개의 노드를 가진다면 노드 1 과 2 는 이전 모듈의 출력 값을 그대로 입력으로 사용한다. 나머지 B-2 개의 노드는 현재 노드의 입력 값으로 제어기에서 선택된 연산과 노드의 번호를 조합한 후 각각의 연산이 적용된 특징 맵을 각 픽셀별로 값을 더한다. 사용된 연산으로는 depth-wise separable convolution 3x3 와 5x5, max pooling, average pooling, identity를 사용하였다. 생성된 CNN 모델은 학습을 시킨 후 검증 정확도를 계산하고 이를 강화학습의 보상으로 사용하여 제어기가 학습된다. 이 과정을 반복하여 제어기에서 최적의 모델을 설계할 수 있다.

2.2 ENAS 학습 과정

RNN 제어기 학습: 제어기에는 강화학습의 정책(Policy) $\pi(m; \theta)$ 과 보상 $r(m, w)$ 가 있다. m 은 정책에서 선택된 모델이고, θ 는 제어기의 매개변수, w 는 생성된 모듈의 매개변수이다. Adam(Adaptive Moment Estimation)을 사용하여 보상의 기댓값인 $\mathbb{E}_{m \sim \pi(m; \theta)} [r(m, w)]$ 을 최대화하는 방향으로 제어기를 학습한다.

생성된 CNN 모델 학습: 이 단계에서는 CNN의 매개변수 w 를 업데이트한다. w 에 대해 SGD(Stochastic Gradient Descent)를 사용하여 손실함수의 기댓값 $\mathbb{E}_{m \sim \pi(m; \theta)} [\mathcal{L}(m; w)]$ 를 최소화한다. $[\mathcal{L}(m; w)]$ 는 크로스 엔트로피 손실(Cross-entropy loss)를 사용하여 계산한다. 식(1)과 같이 몬테 카를로 추정(Monte Carlo estimate)을 사용하여 w 에 대해 계산한다.

$$\nabla \mathbb{E}_{m \sim \pi(m; \theta)} [\mathcal{L}(m; w)] \approx \frac{1}{M} \sum_{i=1}^M \nabla_w \mathcal{L}(m_i, w) \quad (1)$$

m_i 는 $\pi(m; \theta)$ 에서 생성된 모델이다. $M=1$ 이 작동하므로 단일 모델로 w 에 대한 생성된 모델의 기울기를 계산할 수 있다.

2.3 실험 환경 및 결과

본 장에서는 실험 환경 및 결과에 대해서 설명한다. 운전자 행위 데이터셋은 차량 내부 환경에서 카메라 사용해서 수집하였다. 표 1 과 같이 운전자의 행위는 음식 섭취, 평소 상태, 휴대폰 사용, 흡연으로 분류한다. CPU i7-6700 와 Nvidia Geforce GTX 1080 Ti 그래픽 카드를 사용하여 네트워크를 학습시켰고, 18 시간 이내에 CNN 모델을 탐색하였다. ENAS로 탐색된 일반 셀과 축소 셀은 그림 2 와 같다. 제안한 ENAS 기반 CNN 모델은 운전자 행위 분류 데이터셋에 대해 약 11%의 테스트 오차를 보였다. 이는 표 2 와 같이 기존의 경량화 모델보다 비교적 낮은 파라미터 숫자를 가지며 약 5~8% 더 분류 성능이 높다.

표 1. 운전자 행위 데이터 구성

Class Name	Training data	Test data	Total
Eat	12,580	2,050	14,630
Normal	19,120	1,130	20,250
Phone	12,810	1,400	14,210
Smoke	17,650	1,030	18,680

표 2. 분류 모델 성능 비교

Model	ACC	Params
MobileNetV2	79.37	3.4M
MobileNetV3	83.59	5.4M
ENAS(Proposed Model)	88.48	3.6M




그림 2. ENAS 으로 생성된 일반 셀과 축소 셀

III. 결론

본 논문에서는 최적화된 운전자 분류 모델을 설계하기 위하여 ENAS기반의 CNN 모델을 탐색하고 성능을 확인하였다. ENAS 기반 CNN 모델은 테스트 데이터에 대해서 약 11%의 오차의 성능을 보였다. 결론적으로 ENAS를 사용하여 신경망을 설계하면, 데이터 셋에 최적화된 고성능의 분류 모델을 탐색할 수 있다. 추후 연구에서는 ENAS의 탐색공간과 연산자를 수정하여 성능을 개선할 수 있을 것으로 기대한다.

ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터지원사업의 연구결과로 수행되었음(IITP-2021-2020-0-01808)

참 고 문 헌

- [1] Fountas, Grigorios, et al. "Factors Affecting Perceived and Observed Aggressive Driving Behavior: An Empirical Analysis of Driver fatigue, and Distracted Driving." (2019).
- [2] Vaca-Recalde, Myriam E., Joshué Pérez, and Javier Echanobe. "Driver Monitoring System Based on CNN Models: An Approach for Attention Level Detection." International Conference on Intelligent Data Engineering and Automated Learning. Springer, Cham, 2020.
- [3] Ren, Pengzhen, et al. "A comprehensive survey of neural architecture search: Challenges and solutions." arXiv preprint arXiv:2006.02903 (2020).
- [4] Pham, Hieu, et al. "Efficient neural architecture search via parameters sharing." International Conference on Machine Learning. PMLR, 2018.