

모터 동작음 기반 불량 검출 시스템을 위한 불균형 데이터 처리 방안 연구

이영화, *최건영, **박구만

서울과학기술대학교 나노 IT 융합대학원 정보통신미디어공학전공,

*에스엠알 오토모티브 모듈 코리아,**서울과학기술대학교 전자 IT 미디어공학과

younghwaya@seoultech.ac.kr,

* geonyoung.choi@smr-automotive.com ,**gmpark@seoultech.ac.kr

Processing Method of Unbalanced Data for a Fault Detection System Based Motor Gear Sound

Younghwa Lee, * Geonyoung Choi, **Gooman Park

Dept. of Information Technology and Media Engineering, The graduate School of Nano IT Design Fusion, Seoul National University of Science * SMR Automotive Moules Korea Ltd.

**Dept. of Electronic IT Media Engineering, Seoul National University of Science and Technology

요 약

자동차 부품의 결함은 시스템 전체의 성능 저하 및 인적 물적 손실이 발생할 수 있으므로 생산라인에서의 불량 검출은 매우 중요하다. 따라서 정확하고 균일한 결과의 불량 검출을 위해 딥러닝 기반의 고장 진단 시스템이 다양하게 연구되고 있다. 하지만 제조현장에서는 정상 샘플보다 비정상 샘플의 발생 빈도가 현저히 낮다. 이는 학습 데이터의 클래스 불균형 문제로 이어지게 되고, 이러한 불균형 문제는 고장을 판별하는 분류 모델의 성능에 영향을 끼치게 된다. 이에 본 연구에서는 모터의 동작음으로부터 불량 모터를 판별하는 불량 검출 시스템 설계를 위한 데이터 불균형 해결 방법을 제안한다. 자동차 사이드 미러 모터의 동작음을 학습 및 테스트를 위한 데이터 셋으로 사용하였으며 손실함수 계산 시 학습 데이터 셋의 클래스별 샘플 수 가 반영되는 label-distribution-aware margin(LDAM) loss 와 Inception, ResNet, DenseNet 신경망 모델의 비교 분석을 통해 불균형 데이터를 처리할 수 있는 가능성을 보여주었다.

1. 서론

모터 기어박스는 자동차의 여러 부분에 쓰이는 부품으로, 특히 사이드 미러에서 미러의 기울기 및 미러 윈 폴딩 매커니즘을 수행하는 중요한 부분이다. 모터 기어 박스와 같은 작은 모터의 결함은 차량 유지 보수의 물질적 비용과 신뢰성

저하로 생산자에게 돌아오기 때문에 생산라인에서의 불량 검출은 매우 중요하다. 최근 들어 인공지능의 발전에 따라 딥러닝 기반의 불량 진단 기술이 다양하게 연구되고 있으며, 다양한 방법으로 산업 전반에 응용되고 있다. 하지만 제조 공정의 특성상 정상 샘플보다 비정상 샘플의 취득이 어려워 학습 데이터에 불균형이 존재한다. 데이터 불균형의 가장 큰 문제는 분류 예측 시 모델 학습에 부정적인 영향을 준다는 것이다. 기계학습 알고리즘들은

각각의 클래스 비율이 비슷하다는 상황을 가정하고 학습하기 때문에, 클래스가 불균형한 데이터셋의 경우 다수의 클래스에 편향되어 학습한다[1]. 그 결과 전체적인 정확도는 높게 나타나지만 실제 원하는 항목에 대한 분류 정확도가 떨어지는 클래스 불균형 현상이 발생하게 된다. 이러한 학습 데이터의 불균형 문제를 해결하기 위해 데이터 샘플링[2], 또는 데이터 증강[3] 등과 같은 연구와 시도가 진행됐다. 데이터 샘플링은 크게 언더 샘플링(Under sampling)과 오버 샘플링(Over sampling)으로 구분할 수 있으며, 각각의 샘플링 기법들은 상황에 따라 다양하게 적용하고 있다[4,5].

본 연구에서는 샘플의 절대적인 볼륨을 조정하는 샘플링 기법이 아닌 학습 데이터 셋의 클래스별 샘플 수가 반영되는 손실함수인 label-distribution-aware margin(LDAM) loss[6]을 사용하여 데이터 불균형 문제로 인해 발생하는 소수 클래스에 대한 낮은 분류 성능을 개선하였다. 또한 Inception[7], ResNet[8], DensNnet[9] 신경망 모델을 비교 분석하였다.

2. LDAM loss

LDAM 손실함수는 클래스에 대해서 분류 경계까지의 마진(margin)이 클래스 별 샘플 수의 1/4 승에 비례하며, cross entropy 손실함수와 결합시킨 형태로 나타난다. 즉 학습 데이터 셋의 클래스별 샘플 수를 손실함수에 반영하고 클래스의 분류 경계면을 조절한다. 따라서 학습 시 클래스 불균형 상황에서 분류 성능을 향상시킨다. 본 논문에서는 LDAM 손실 함수를 사용하여 데이터 불균형 상황에서 불량 검출 시스템을 개선하고자 한다. 또한 categorical cross entropy loss 와 focal 손실 함수[10]로 학습한 모델과 성능을 비교 분석한다.

3. 모델

Inception 은 이미지에서 여러 차원의 피처를 추출하는 방식으로 컨볼루션 레이어의 채널상관성과 공간상관성을 따로 처리할 수 있는 구조를 지닌다. 1x1 컨볼루션으로 차원을 줄이고, 3x3, 5x5 컨볼루션을 뒤이어 실행한다.

ResNet 은 딥러닝 모델의 깊이를 깊게 설계하면 발생하는 문제인 오버피팅, 그레디언트 소멸, 연산량 증가 등의 개선을 위해 이전 레이어의 결과를 다시 사용하는 잔차연결(residual connection)을 사용한다. ResNet 은 여러 연결로 이루어진 잔차 블록과 컨볼루션 블록으로 이루어져 있다.

DenseNet 은 모든 이전 레이어의 아웃풋 정보를 이후

레이어의 인풋으로 사용한다. 특징 맵끼리 concatenate 시켜주고 이렇게 이어 붙인 연결 덩이를 하나의 블록으로 만들어서 컨볼루션, 풀링 레이어를 순차적으로 거친 후 마지막에 리니어 레이어 후 결과를 뽑아낸다.

4. 데이터 셋

불량 검출 시스템의 학습 및 평가 데이터 셋은 사이드 미러의 모터 동작음을 방음시설이 완비된 녹음실에서 직접 녹취하여 사용하였다. 동작음 데이터의 길이는 7 초이며, 표본주파수 44.1Khz 의 웨이브 파일이다. 정상 샘플 250 세트, 불량 샘플은 유형별로 fault1 146 세트, fault2 42 세트, fault3 26 세트의 샘플이 존재하며 클래스별로 데이터 불균형이 존재함을 알 수 있다. 또한 본 연구에서 사용된 학습 데이터는 멜 스펙트로그램(mel-spectrogram)으로 변환하여 사용하였다.

5. 실험결과 및 분석

LDAM 손실함수를 사용하여 Inception, ResNet, DenseNet 신경망 모델의 비교 분석해 보았다. 또한 LDAM 손실함수의 성능 비교를 위하여 categorical cross entropy loss 와 focal 손실 함수로 학습한 모델과 성능을 비교하였다. 5 번의 실험결과를 평균한 결과이며, 평가 지표는 정확도를 기준으로 산출하였다.

	Inception			ResNet			DenseNet		
	CE	FC	LDAM	CE	FC	LDAM	CE	FC	LDAM
Normal	75.6	76.8	79.6	77.6	79.1	81.2	76.2	83.7	93.7
Fault 1	72.8	76.8	77.3	72.9	77.8	78.2	72.5	80.2	84.6
Fault 2	62.9	73.2	75.6	69.7	72.2	74.9	62.4	77.3	82.5
Fault 3	55.1	57.2	56.8	53.1	65.8	65.3	51.5	66.2	70.1

<표 1> 신경망에 따른 손실함수의 클래스별 분류 정확도

표 1 은 각각의 신경망에 따른 손실 함수의 클래스별 정확도를 나타내었다. 표 1 에서 보는 바와 같이 LDAM 손실함수를 사용한 DenseNet 신경망 분류모델이 소수 클래스인 Fault3에서 높은 분류 정확도를 보여주었다.

4. 결론

본 연구에서는 클래스 불균형 문제 상황에서의 모터 동작음 기반 불량 검출 시스템의 균형잡힌 검출을 위한 방안에 대하여

살펴보았다. categorical cross entropy loss 와 focal 손실 함수, LDAM 손실 함수를 사용한 Inception, ResNet, DenseNet 신경망 모델을 비교 분석하였다.

실험 결과 LDAM 손실 함수를 사용한 DenseNet 신경망이 샘플 수가 부족한 클래스에 대한 분류 성능에 우수한 결과를 나타냄을 확인하였다. 이번 연구를 바탕으로 전혀 새로운 유형의 불량이 나타날 가능성을 대비하는 것이 향후 과제가 될 것이다. 따라서 향후 이어지는 연구에서는 불량 샘플의 은닉벡터 특징을 추론하고 유형별 불량 샘플의 은닉벡터가 정상 샘플의 은닉벡터와 멀어지도록 학습시키는 방식을 통한 자기지도학습의 불량 검출 시스템을 연구할 예정이다.

참고문헌

- [1] R. O'Brien and H. Ishwaran, "A random forests quantile classifier for class imbalanced data," *Pattern Recognition*, Vol.90, pp.232-249, 2019.
- [2] A. More, "Survey of resampling techniques for improving classification performance in unbalanced datasets," *arXiv preprint arXiv:1608.06048*, Aug. 2016.
- [3] S. C. Wong, A. Gatt, S. Victor and M. D. McDonnell, "Understanding data augmentation for classification: when to warp?," *2016 International Conference on DICTA*, pp. 1-6, Nov. 2016.
- [4] J. Prusa, T. M. Khoshgoftaar, D. J. Dittman and A. Napolitano, "Using Random Undersampling to Alleviate Class Imbalance on Tweet Sentiment Data," *2015 IEEE International Conference on Information Reuse and Integration*, pp. 197-202, Aug., 2015.
- [5] W. Jindaluang, V. Chouvatut and S. Kantabutra, "Under-sampling by algorithm with performance guaranteed for class-imbalance problems," *2014 International Computer Science and Engineering Conference (ICSEC)*, pp. 215-221, Jul. 2014.
- [6] G. Lemaitre, F. Nogueira and C. K. Aridas, "Imbalanced-learn: A python toolbox to tackle the curse of imbalanced datasets in machine learning," *The Journal of Machine Learning Research*, Vol. 18, No. 1, pp. 559-563, Jan. 2017.
- [7] C. Szeged, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, "Going deeper with convolutions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 1-9.
- [8] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770-778.
- [9] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp.
- [10] T. Y. Lin, P. Goyal, R. Girshick, K. He & P. Dollár (2017, Oct). Focal Loss for Dense Object Detection. In *Proceedings of the IEEE International Conference on Computer Vision* (pp. 2980-2988).