

Drivable Area Segmentation을 위한 손실 함수 분석

송지희, 정준, 전우민, 이성진
동서울대학교 신산업특화단

2112008@du.ac.kr, 2212014@du.ac.kr, 2104023@du.ac.kr, sungjinlee@du.ac.kr

Loss Function Analysis for Drivable Area Segmentation

Song Jihui, Jeong Jun, Jun Woomin, Lee Seongjin
DongSeoul Univ.

요약

본 논문은 Segmentation 성능 향상을 위해 BDD100K 데이터셋을 활용하여 다양한 손실 함수의 성능을 분석한다. 특히, Tversky, Dice, BCE 손실 함수를 기반으로 모델의 성능을 비교하여 Tversky($\alpha, \beta = 0.3$)가 가장 높은 IoU를 보여주었다. 실험을 확장하기 위한 Tversky의 가중치를 변경하고 BCE-Dice의 비율을 조절하여 진행한 결과, 여전히 Tversky($\alpha, \beta = 0.3$)가 49.43%로 다른 손실 함수 대비 최소 0.81%, 최대 4.77% 높은 IoU를 기록하였다.

I. 서론

Segmentation은 컴퓨터 비전 분야에서 핵심적인 작업으로, 객체의 영역을 정확하게 분할하는 것이 그 목적이다. 인공지능을 활용한 이미지 인식, 의료 영상 분석, 자율 주행 등 다양한 분야에서 Segmentation은 점차적으로 중요성을 갖고 있다. 이러한 다양한 분야에서 효과적인 Segmentation을 수행하기 위해서는 모델의 학습에 사용되는 손실 함수를 올바르게 선택하는 것이 핵심이다. 기존의 많은 논문들은 Segmentation에 적합한 다양하고 효과적인 손실 함수들을 제시해왔다. 그러나 다양한 환경에서 효과적인 손실 함수를 선택하는 것은 여전히 도전적인 과제로 남아 있다. 이 논문은 다양한 손실 함수를 탐구하고, 각 손실 함수의 성능을 분석함으로써 보다 효과적인 Segmentation 모델을 구축하는 데 기여하고자 한다.

II. 본론

본 논문에서는 ResNet50[1] 기반 FPN[2]을 사용하였으며, 기존 BDD100K[3]의 DAS(Drivable Area Segmentation) 데이터셋 중 70000개의 train을 21000개로, 10000개의 validation을 3000개로 감소시킨 환경을 구축하였다. 이후 Tversky[4], Dice[5], BCE(Binary Cross Entropy)[6], 3개의 손실함수를 기준으로 설정된 환경에서 Epochs값은 50으로 진행하였다.

$$Dice = \frac{2 * |X \cap Y|}{|X| + |Y|}$$

$$Tversky = \frac{TP}{TP + \alpha FN + \beta FP}$$

$$BCE = -(Y * \log X + (1 - Y) * \log(1 - X))$$

그림 1. 손실 함수 수식

Dice 손실 함수는 클래스 간의 정확한 Segmentation을 위한 손실 함수로서 주로 이미지 Segmentation에서 사용되는 함수이다. 클래스 간의 IoU(Intersection over Union) [7]를 개선하며 유사성을 측정하는데 클래스 불균형으로 손실이 높게 나와 다른 클래스를 예측할 수 있다는 단점이 존재한다. Tversky 손실 함수는 이러한 점을 보완하기 위해 FP(False Positives)와 FN(False Negatives)에 가중치를 조절할 수 있는 매개변수를 도입한 함수이다. Tversky 손실 함수의 가중치를 0.5로 설정한다면 Dice 손실 함수와 값이 동일 해진다.[4] BCE은 클래스의 불균형을 해결하기 위해서 만들어졌다.

이후 다양한 성능 비교를 하기 위해 BCE-Dice 손실함수의 각 비율을 변환하면서 진행하였다. BCE-Dice 손실 함수는 Dice 손실 함수와 BCE 손실 함수를 결합한 것으로 Dice 손실 함수는 두 집합 간의 유사성을 측정하는데 사용되며, BCE 손실 함수는 이진 분류 작업에서 주로 사용되어 두 확률 분포 간의 차이를 최소화한다. BCE-Dice 손실 함수는 위의 두 함수를 조합하여 이진 분류와 Segmentation 작업에서 두 가지 측면을 모두 고려하여 픽셀 단위의 확률 예측과 Segmentation 결과의 정확성을 측정한다. 기준점을 잡기 위해 처음은 각 함수의 비율을 1:1로 설정하여 진행한 후 수정했다. 수정 기준은 BCE 손실 함수 보다 Dice 손실 함수를 사용했을 때의 성능이 더 높아 각각 0.43:1과 0.25:1의 비율로 설정하였다. 초기에 설정한 0.3에서 0.2로 수정하였고, 그 결과 Dice 손실 함수와는 동일한 IoU 값이 나타나 기존의 설정한 $\alpha, \beta (= 0.3)$ 보다는 낮은 수치가 도출되었다. 위와 같이 값 또는 비율을 임의로 변경하여 실행하였다. 결과들을 전반적으로 보아 Tversky 손실 함수의 성능이 상위권을 차지하였고, 그 아래로는 Dice 손실 함수와 BCE 손실 함수의 비율을 수정하며 진행한 결과값들이 Dice 손실 함수의 비율이 높은 순으로 표가 이루어졌다.

III. 결론

| 손실 함수의 종류 | IoU |
|-----------------------------------|--------|
| Tversky ($\alpha, \beta = 0.3$) | 49.34% |
| Dice | 48.53% |
| Tversky ($\alpha, \beta = 0.2$) | 48.53% |

| | |
|-------------------|--------|
| BCE-Dice (0.25:1) | 46.88% |
| BCE | 46.87% |
| BCE-Dice (0.43:1) | 45.97% |
| BCE-Dice (1:1) | 44.57% |

표 1. 손실 함수의 종류, 비율 별 결과값

본 논문에서는 다양한 손실 함수들 중 Tversky 손실 함수($\alpha, \beta = 0.3$)가 BDD100K-DAS 데이터셋을 사용한 Segmentation에서 가장 높은 IoU 값인 9.34%를 나타냈다. 이는 Dice 손실 함수와 비교했을 때 약 0.81% 높은 결과이며, BCE 손실 함수과는 약 2.47%의 차이를 보여준다.

또한, BCE-Dice 손실 함수의 다양한 비율 변화를 통해, Dice 손실 함수의 비율이 높을수록 성능이 향상된다는 사실을 확인할 수 있었다. BCE-Dice(0.25:1)의 경우 Dice 손실 함수와는 1.65%, BCE-Dice(1:1)와는 3.96%의 성능 차이가 나타났다. 이러한 결과는 Dice 손실 함수가 BDD100K-DAS 작업에 있어서 중요한 역할을 하며, Dice 손실 함수의 비율의 조절을 통해 성능을 최적화할 수 있다는 점을 파악할 수 있다. 따라서 다양한 손실 함수의 조합과 데이터셋에 맞는 함수의 율에 따라 효과적인 손실 함수 선택을 가능케 하는 관점을 제시한다.

ACKNOWLEDGMENT

이 논문은 2023년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(2023 신산업분야 특화 선도전문대학 지원사업)

참 고 문 헌

- [1] K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image Recognition.", *arXiv preprint arXiv:1512.03385*, 2015
- [2] T. Lin, P. Dollár, R. Girshic, K. He, B. Hariharan and S. Belongie, "Feature Pyramid Networks for Object Detection.", *arXiv preprint arXiv:1612.03144*, 2016
- [3] F. Yu, H. Chen, X. Wang, W. Xian, Y. Chen, F. Liu, V. Madhavan and T. Darrell, "BDD100K : A Diverse Driving Dataset for Heterogeneous Multitask Learning", *arXiv preprint arXiv:1805.04687*, 2018
- [4] S. Salehi, D. Erdogmus and A. Gholipour, "Tversky loss function for image segmentation using 3D fully convolutional deep networks", *arXiv preprint arXiv:1706.05721*, 2017
- [5] Y. Zhang, S. Liu, C. Li and J. Wang, "Rethinking the Dice Loss for Deep Learning Lesion Segmentation in Medical Images", In *Journal of Shanghai Jiaotong University* 96–102, 2021
- [6] U. Ruby and V. Yendapalli, "Binary cross entropy with deep learning technique for Image classification", In *International Journal of Advanced Trends in Computer Science and Engineering*, 2020
- [7] H.Rezatofighi, N.Tsoi, J.Gwak, A.Sadeghian,I.Reid and S.Savarese, "Generalized Intersection over Union : A Metric and A Loss for Bounding Box Regression", *arXiv preprint arXiv:1902.09630*,2019