

# 입력 데이터의 무작위도에 따른 오토인코더의 학습 성능에 관한 연구

이주홍, 정다은, 박형곤

이화여자대학교

{egr0419, daeun.jung}@ewhain.net, hyunggon.park@ewha.ac.kr

## Impact of Input Data Randomness on Training Performance of Autoencoder

Joohong Rheey, Daeun Jung and Hyunggon Park

Ewha Womans University

### 요약

본 논문은 입력 데이터의 무작위도가 오토인코더의 학습 성능에 미치는 영향에 대해 분석하고, 입력 데이터의 무작위도에 따라 최적화된 은닉층의 노드 개수를 설정하는 방법에 관한 연구를 진행하였다. 입력 데이터의 무작위도를 의미하는 엔트로피값이 오토인코더의 학습 성능에 영향을 미친다는 사실을 확인하였다. 즉 오토인코더의 은닉층의 노드 개수를 결정할 때 입력 데이터의 무작위도를 계산하여 학습 성능을 예측할 수 있다는 사실을 확인하였다.

### I. 서론

5G/B5G 통신·네트워크를 이용하는 사용자의 폭발적 증가와 새로운 서비스에 따른 비정형 데이터의 대량 발생에 따른 효율적 네트워크 데이터의 처리를 위하여 머신러닝을 활용하는 방안이 제시되고 있다 [1]. 특히 오토인코더는 최소한의 왜곡(Distortion)으로 입력 데이터를 출력 데이터로 변형한다는 점에서 비지도 학습과 딥러닝 아키텍처에서 핵심적인 역할을 하고 있다 [2]. 오토인코더는 비지도 학습 방식 기반의 딥러닝 알고리즘이기 때문에 라벨이 없는 입력 데이터를 활용할 수 있는 장점이 있다. 또한, 데이터 수가 충분하지 않은 경우인 퓨샷 러닝(Few-shot learning)에 효과적이기에 시간에 따라 변화하는 네트워크 흐름에 빠르게 대응할 수 있다. 따라서 데이터 잡음 제거, 이상 탐지, 트래픽 흐름(Traffic flow)의 자동 분류 등에 오토인코더를 활용하고 있다 [3], [4].

오토인코더를 최적으로 사용하기 위해서는 오토인코더의 학습 성능을 결정하는 활성화 함수, 손실함수, 은닉층(Hidden layer)의 구성, 에포크(Epoch), 학습률(Learning rate) 등을 적절히 설정하는 것이 매우 중요하다. 오토인코더의 구성 요소 중 활성화 함수와 손실함수는 입력 데이터의 특성과 사용 목적에 따라 결정할 수 있고 오토인코더에서 은닉층의 노드 개수가 증가할수록 학습 손실(Training loss)이 작아진다는 사실은 알려져 있으나 입력 데이터의 특성에 따라 최적의 은닉층의 노드 개수를 결정하는 방법에 관한 연구는 부족하다 [5]. 은닉층의 노드 개수에 따라 학습량과 학습 손실 간 트레이드 오프(Trade-off)가 발생하므로 입력 데이터에 맞는 최적의 은닉층의 노드 개수를 결정할 필요가 있다.

본 논문에서는 입력 데이터의 무작위도가 오토인코더의 학습 성능에 미치는 영향에 대해 분석하고, 입력 데이터의 무작위도에 따라 적절한 은닉층의 노드 개수를 설정하는 방법에 관한 연구를 진행하였다.

### II. 본론

#### 1. 문제 정의

오토인코더는 고차원의 입력 데이터의 압축된 표현을 찾는 인코더와 압축된 데이터를 활용하여 다시 원래의 입력과 비슷하게 만들어내는 디코더로 구성되어 있다. 오토인코더는 그림1과 같이 입력  $X$ 가 신경망을 통과하여




그림 1 오토인코더의 구조

압축된 잠재 변수(Latent variable)  $Z$ 가 되고,  $Z$ 가 다시 신경망을 통과하여 출력  $\hat{X}$ 이 된다. 목표값을 입력인  $X$ 로 하여 출력값인  $\hat{X}$ 이  $X$ 가 가장 가까운 방향으로 학습시키기 위하여 입력값  $X$ 와 출력값  $\hat{X}$ 의 차이를 손실  $L(X, \hat{X})$ 로 정의하고, 이를 최소화할 수 있도록 잠재 변수  $Z$ 를 학습한다. 본 논문에서는  $L(X, \hat{X})$ 을  $l_1$ -norm을 이용하여 아래와 같이 정의하였다.

$$L(X, \hat{X}) = \sum_{i=1}^n |X_i - \hat{X}_i| \quad (1)$$

본 논문에서는 입력 데이터의 무작위도를 정량화하기 위하여 엔트로피(Entropy)를 이용하였다. 엔트로피가 클수록 무작위도가 크고, 정보량이 많음을 의미한다. 입력 데이터의 분포가  $p(x)$ 로 주어진 경우, 엔트로피는 식 (2)와 같이 정의된다.

$$H(x) = - \int p(x) \ln p(x) dx \quad (2)$$

#### 2. 실험 설정

본 논문에서는 입력 데이터가 평균  $m$ , 표준편차  $\sigma$ 의 가우시안 분포를 갖는다고 가정하였다. 즉,  $X \sim N(m, \sigma)$ 이다. 가우시안 분포에 대한 엔트로피는 식 (3)과 같이 주어지고

$$H(x) = \frac{1}{2} \{1 + \ln(2\pi\sigma^2)\} \quad (3)$$

$m$ 과  $\sigma$ 를 변화시켜 입력 데이터의 무작위도를 다르게 하였다. 식 (3)에서는  $\sigma$ 가 증가할수록 정보 엔트로피값이 증가하고, 증가율은 줄어드는 로그 형태를 띠게 된다.

일정한 가우시안 분포를 가지는 50만 개의 데이터를 생성한 후 오토인코더의 입력으로 사용하기 위해, 수를 100개씩 나누어 길이가 100인 5,000개의 데이터  $X$ 를 오토인코더의 입력으로 사용하였다. 본 논문에서는 오토인코더의 입력을 제외한 다른 파라미터는 고정하였다. 활성화 함수는 LeakyReLU, 학습률은 0.01, 에포크는 100으로 설정하였다. 이러한 조건 설정은 실험을 통해 오토인코더 학습 과정에서 과적합(Overfitting)이 일어나지 않고, 에포크가 증가할수록 학습 손실이 줄어드는 방향으로 안정적으로 학습하는 값으로 선택하였다.

### 3. 실험 결과

#### 1) 평균에 의한 오토인코더 학습 성능의 변화




그림 2. 평균을 변화시켰을 때 은닉층의 개수에 따른 학습 손실 변화

본 실험에서는  $\sigma=1$ 로 고정하고,  $m \in \{5, 10, 15, 20\}$ 로 설정하였다. 활성화 함수 LeakyReLU는 입력이 음수일 때는 작은 값으로 축소시키는 특성이 있기 때문에,  $m \leq 0$ 인 경우는 제외하고 실험하였다. 그림 2에서 볼 수 있듯이  $m \in \{5, 10, 15, 20\}$ 인 모든 경우에서  $\sigma$ 에 관계없이 학습 성능이 거의 동일하며 은닉층에 따른 손실 감소량이 거의 동일한 것을 관찰할 수 있다. 따라서 무작위도에 영향을 미치지 못하는 평균값은 오토인코더의 학습 성능에 영향을 미치지 않는 것을 확인할 수 있다.

#### 2) 표준편차에 의한 오토인코더 학습 성능의 변화

본 실험은  $m=10$ 으로 고정하고  $\sigma \in \{1.0, 1.8, 2.6, 3.4, 4.2, 5.0, 5.8, 6.6, 7.4, 8.2, 9.0\}$ 로,  $\sigma$ 를 1부터 0.8씩 증가시키며 실험하였다. 그림 3에서 볼 수 있듯이  $\sigma$ 가 커질수록 오토인코더의 학습 성능이 저하되는 결과를 볼 수 있다. 이는  $\sigma$ 가 클수록 엔트로피가 커지기 때문에, 엔트로피가 커질수록 학습 성능이 저하됨을 확인할 수 있다. 또한,  $\sigma$ 가 클수록 은닉층의 수에 따라 학습 성능 개선율이 높아지는 것을 확인할 수 있다. 그림 4는  $\sigma$ 에 대하여 학습 성능이 식 (3)에 나타난 엔트로피와 동일한 로그 형태로 나타남을 알 수 있다. 따라서 입력 데이터의 무작위도가 오토인코더의 학습 성능에 영향을 미치는 것을 확인할 수 있다.




그림 3. 표준편차를 변화시켰을 때 은닉층의 개수에 따른 학습 손실 변화

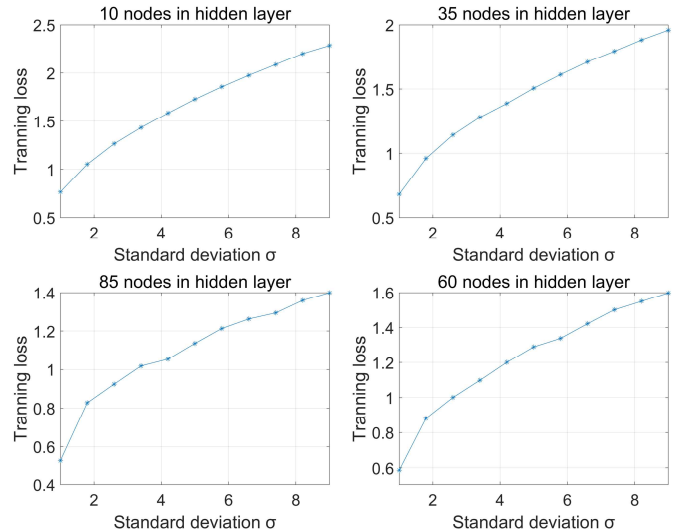


그림 4. 은닉층의 노드 개수를 동일하게 설정했을 때 표준편차에 따른 학습 손실 변화 (왼쪽 위부터 시계방향으로 노드 개수 10, 35, 60, 85개)

### III. 결론

본 논문에서는 입력 데이터의 무작위도가 오토인코더의 학습 성능에 미치는 영향에 대해 분석하고, 입력 데이터의 무작위도에 따라 적절한 은닉층의 노드 개수를 설정하는 방법에 관한 연구를 진행하였다. 이를 통해 입력 데이터의 무작위도를 의미하는 지표로 볼 수 있는 엔트로피값이 오토인코더의 학습 성능에 영향을 준다는 사실을 확인하였다. 즉 오토인코더의 은닉층의 노드 개수를 결정할 때 입력 데이터의 무작위도를 계산하여 학습 성능을 예측할 수 있다.

### ACKNOWLEDGMENT

이 논문은 2021년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원(No.2021-0-00739분산/협력 AI 기반 5G+ 네트워크 데이터 분석 기능 및 제어 기술 개발, No. 2019-0-00024, 네트워크 자동화를 위한 개방형 네트워크 데이터 분석 기반 지도형 애자일 머신러닝 기술 개발)과 2021년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. NRF-2020R1A2B5B01002528).

### 참고 문헌

- [1] C. Wang, M. D. Renzo, S. Stanczak, S. Wang and E. G. Larsson, "Artificial Intelligence Enabled Wireless Networking for 5G and Beyond: Recent Advances and Future Challenges," *IEEE Wireless Communications*, vol. 27, no. 1, pp. 16-23, February 2020.
- [2] P. Baldi, "Autoencoders, Unsupervised Learning, and Deep Architectures," *ICML Workshop on Unsupervised and Transfer Learning*, Proc. of Machine Learning Research, 2012.
- [3] J. Höchst, L. Baumgärtner, M. Hollick and B. Freisleben, "Unsupervised Traffic Flow Classification Using a Neural Autoencoder," *IEEE Conf. on Local Computer Networks (LCN)*, 2017, pp. 523-526.
- [4] H. Choi, M. Kim, G. Lee, et al., "Unsupervised learning approach for network intrusion detection system using autoencoder," *J. Supercomput* 73, pp. 5597 - 5621, 2019.
- [5] Bahadur, Nitish, and Randy Paffenroth. "Dimension estimation using autoencoders." *arXiv preprint arXiv:1909.10702*, 2019.