

대조 학습 기반 사전 학습과 생성 모델의 시너지 탐구

최창균*, 김태환*, 박정호*, 이주원*, 남상우*, 박주영°

A Study on Synergy of Contrastive Learning-Based Pre-Training and Generative Model

ChangKyun Choi*, Taehwan Kim*, Jeongho Park*, Juwon Lee*, Sangwoo Nam*, Jooyoung Park°

요약

최근 들어 비지도 학습(unsupervised learning)은 다양한 분야에서 연구되고 적용되며 많은 주목을 받고 있다. 그리고 다양한 비지도 학습 방법 중 최근 긍정적인 샘플(positive samples)과 부정적인 샘플(negative samples)간의 유사성과 비 유사성을 학습하는 대조 학습(contrastive learning)을 이용한 사전 학습(pretraining) 방법이 많은 관심을 받으며 연구되고 있다. 이러한 사전 학습 방법은 컴퓨터 비전 등의 분야에서 지도 학습시 데이터의 부족이나 새로운 데이터가 주어졌을 때 정확도 감소 등의 문제를 해결하기 위해 연구되고 있다. 본 논문에서는 관련 연구에서 우수한 성과를 내며 주요 핵심기술로 부상하고 있는 대조 학습 기반 사전 학습과 생성 모델(generative model)을 결합하는 문제를 탐구한다. 보다 구체적으로, 우리는 고차원 센서 데이터 특징을 저차원 잠재 공간(latent space)에서 보다 더 효과적으로 특성화하는 저차원 잠재 공간 궤적을 생성할 수 있는 결합 절차를 제시한다. 또한 스마트폰 센서를 사용하여 휴먼 모션을 다루는 실험을 수행했는데, 이 실험 결과는 대조 학습 기반 사전 학습과 생성 모델의 의미있는 시너지 효과를 보여준다.

키워드 : 비지도 학습, 대조 학습, 사전 학습, 생성 모델, 스마트폰 센서

Key Words : unsupervised learning, contrastive learning, pretraining, generative model, smartphone sensors

ABSTRACT

In recent years, unsupervised learning has been studied in various fields and has attracted a lot of attention. Among various unsupervised learning methods, the pretraining method using contrastive learning, which learns the similarity and dissimilarity of the positive and negative samples, is being studied with a lot of interest. To overcome the difficulties of supervised learning due to insufficient data and accuracy drop, utilizing contrastive pretraining is an important strategy in computer vision areas. In this paper, we investigate the problem of combining the generative model with contrastive-learning-based pretraining, which has emerged as a major breakthrough resulting in an excellent performance in related studies. More specifically, we present a procedure for the combination which can generate low-dimensional latent trajectories characterizing the high dimensional sensor data features more effectively. We also conducted experiments about human motion using smartphone sensors, which shows a meaningful synergy of contrastive pretraining and generative models.

※ 본 연구는 과학기술정보통신부의 재원으로 한국연구재단(NRF-2020R1F1A1072772)의 지원을 받아 수행되었습니다.

• First Author : Korea University Department of Control and Instrumentation Engineering, ckdrbsckd@korea.ac.kr, 학생회원

° Corresponding Author : Korea University Department of Control and Instrumentation Engineering, Parkj@korea.ac.kr, 정회원

* Korea University Department of Control and Instrumentation Engineering

논문번호 : 202105-099-C-RE, Received April 29, 2021; Revised July 26, 2021; Accepted September 8, 2021

I. 서 론

최근 들어, 비지도 학습 분야의 비약적인 발전으로 자연어 처리 및 컴퓨터 비전 등의 다양한 분야에서 이를 이용한 연구가 활발히 진행되고 있다. 그 중, 비지도 학습을 이용한 자가지도 학습(self-supervised learning)으로 사전 학습을 진행함으로써, 일반화 능력을 최대화하고, 적은 데이터로부터 학습 효율을 향상시키는 방법이 좋은 성능을 보이고 있다. 이를 통해 비디오 게임과 같은 분야에서의 응용연구¹⁾가 활발히 이루어지고 있다. 자가지도 학습으로는 큰 틀에서 프리텍스트 테스크(pretext task)를 직접 만들어서 진행되는 방법과 대조 학습을 이용하는 방법으로 나뉘어 있다. 라벨링 되지 않은 데이터로부터 프리텍스트 테스크를 만들어 기존의 지도 학습과 비슷한 방법으로 학습시키는 방법론들²⁻⁴⁾은 만들어진 프리텍스트 테스크에 의해 일반화 능력이 일정부분 제한이 될 수 있다. 최근 들어, 앞서 설명한 프리텍스트 테스크 기반 방법론보다 자가지도 학습에서 긍정적인 샘플과 부정적인 샘플간의 유사성과 비 유사성을 학습시키는 대조 학습을 이용하는 연구⁵⁻¹⁶⁾가 매우 좋은 성능과 차후 연구의 가능성으로 인하여, 주요한 토픽의 하나로 대두되고 있다. 이와 같은 연구 중 다수는 컴퓨터 비전 분야에서 지도 학습시 데이터의 부족이나 새로운 데이터에 대한 정확도 성능 저하 등의 문제를 해결하기 위해서 대조 학습을 적용하고 그 효율성을 제시하고 있다. 또한, 최근 스마트폰을 이용하여 다양한 연구와 응용이 진행됨에 따라 스마트폰 사용자의 동특성을 파악¹⁷⁾하고 이를 활용하는 것은 중요한 문제가 될 수 있다. 이에 따라 웨어러블(wearable) 센서로부터 수집된 모션 데이터를 생성 모델을 통하여 저차원의 잠재 공간상에 표현하고 특징을 파악한다. 하지만 이러한 생성 모델은 데이터 부족이나 편향된 데이터로 인하여 동일한 모션에 대한 잠재 공간상의 궤적 패턴이 상이하게 달라지는 경우가 발생할 수 있다. 이러한 생성 모델의 일반화 능력을 향상시키기 위해 본 논문에서는 관련 연구에서 우수한 성과를 내며 주요 핵심기술로 부상하고 있는 대조 학습 기반 사전 학습과 생성 모델을 결합하는 문제를 고찰한다. 보다 자세하게, 본 논문에서는 수집된 모션 센서 데이터를 학습 데이터와 테스트 데이터로 분리하고 각각 학습 데이터와 테스트 데이터를 이용하여 기존의 생성 모델과 대조 학습 기반 사전 학습된 생성 모델로부터 얻어지는 사용자 모션에 대한 패턴을 분석 및 비교하고 이를 통해 사전 학습과 생성 모델의 시너지에 대해 탐구한다.

본 논문의 구성은 다음과 같다. 1장 서론에서는 본 논문에서 다루고자 하는 주제를 그 필요성과 함께 간단히 기술하고, 2장 본문에서는 본 논문의 실험에서 사용된 데이터와 논문에서 고려하는 방법론들 및 사용된 생성 모델을 설명한다. 그리고 3장 실험에서는 실제 사용자로부터 얻어진 고차원 센서 데이터를 이용한 실험의 결과를 제시하고 분석한다. 마지막으로 4장에서는 결론과 함께 향후 연구 방향을 제시한다.

II. 본 론

본 논문에서는 대조 학습과 생성 모델의 시너지 탐구를 위해 대조 학습으로 사전 학습된 생성 모델과 사전 학습되지 않은 생성 모델을 비교한다. 모델의 비교를 위해 웨어러블 센서 사용자로부터 수집된 데이터를 활용하여 학습된 모델로부터 생성되는 저차원 잠재 공간상의 동특성을 분석한다. 이를 위해 1절에서는 실험에 사용된 데이터의 수집과 전처리에 대해 소개하고, 2절에서는 본 논문에서 적용한 대조 학습 방법과 사전 학습 절차 그리고 3절에서는 생성 모델에 관하여 설명한다.

2.1 데이터

본 절에서는 실험을 위해 웨어러블 센서로부터 수집된 데이터에 대해 소개한다. 본 논문의 실험을 위해 웨어러블 센서로는 스마트폰에 내장된 가속도, 자이로 센서를 활용하였고, 스마트폰과 MATLAB을 연동하여 각 센서로부터 데이터를 수집하였다. 사용자는 좌측 허벅지 부근에 스마트폰을 고정하여 땀걸음 동작을 수행하였고, 웨어러블 센서로부터 약 45초 동안 30Hz 단위로 데이터를 수집하였다. 수집된 데이터는 표 1과 같이 가속도, 자이로 센서 각각 x, y, z축에 해당하는 데이터이고 각 센서의 크기(magnitude) 값을 추가적으로 사용하였다. 이렇게 수집된 데이터는 가속도, 자이로, 가속도 크기, 자이로 크기 순서로 정렬하여 총 8차원 데이터로 구성하였다(즉, $x_t = [a_x, a_y, a_z, \omega_x, \omega_y, \omega_z, a_{mag}, \omega_{mag}]$). 그림 1과 그림 2

표 1. 실험에서 사용한 데이터
Table 1. Data from experiments

a_x, a_y, a_z	가속도 센서의 x, y, z축 데이터
a_{mag}	$a_{mag} = \sqrt{a_x^2 + a_y^2 + a_z^2}$
$\omega_x, \omega_y, \omega_z$	자이로 센서의 x, y, z축 데이터
ω_{mag}	$\omega_{mag} = \sqrt{\omega_x^2 + \omega_y^2 + \omega_z^2}$

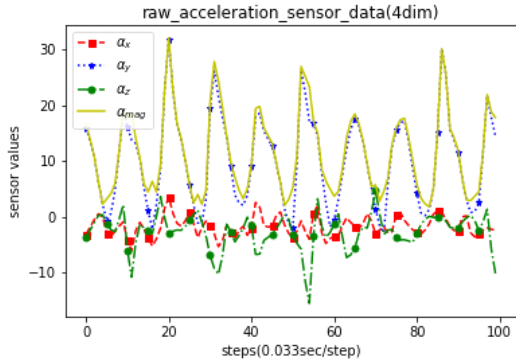


그림 1. 수집된 가속도 센서 데이터 샘플
Fig. 1. Sample from the obtained acceleration sensor data

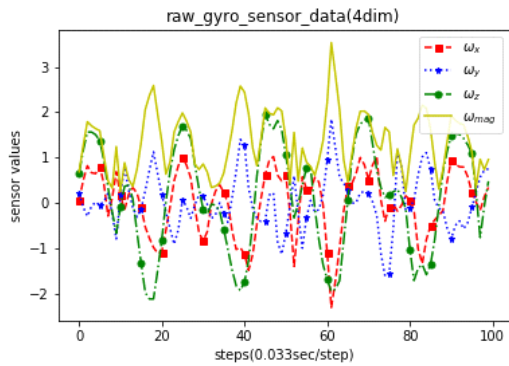


그림 2. 수집된 자이로 센서 데이터 샘플
Fig. 2. Sample from the obtained gyro sensor data

는 각각 가속도 센서와 자이로 센서로부터 얻어지는 데이터를 보여준다. 그리고 단순히 하나의 타임 스텝 정보만을 모델의 입력으로 주기보다는, 그림 3과 같이 변화량 등의 정보를 얻을 수 있도록 과거 두 개의 타임 스텝을 추가적으로 고려하였다. 따라서, 최종입력 데이터의 차원은 8×3 으로 24차원 데이터가 된다 (즉, $X_t = [x_{0:t-2}, x_{1:t-1}, x_{2:t}]$). 이렇게 구성된 데이터를 슬라이딩 윈도우를 이용하여 50개의 타임 스텝을 포함하는 윈도우로 나누어주었다. 이때, 각 윈도우끼리 하나의 타임 스텝 간격을 두어 오버랩(overlap)이 생기도록 구성하였다. 이렇게 구성된 데이터를 마지막으로 min-max 정규화를 통해 [0,1] 범위를 가지도록 하였다.

실험에는 서로 다른 4명의 사용자의 동일한 동작으로부터 수집한 데이터를 사용하였다. 전체 데이터 중 3명의 데이터를 학습 데이터로, 다른 1명의 데이터를 테스트 데이터로 분리하여 실험을 진행하였다.




그림 3. 센서 데이터 처리 과정; 모션의 동특성 분석을 위해 최근 3개의 타임 스텝을 활용하여 데이터 구성
Fig. 3. Sensor data preprocessing; data construction using the recent 3 time steps to analyze the dynamics of motions

2.2 대조 학습

본 논문에서는 1절에서 설명한 센서 데이터 X_t 를 저차원 잠재 공간상의 상태 h_t, z_t 로 표현할 때 일반화 능력을 향상시키기 위해 최근 많은 연구가 진행되고 있는 대조 학습을 이용한 사전 학습 방법을 소개한다. 대조 학습은 유사성과 비 유사성을 고려하여 학습하는 방법론으로 CPC^[5], SwAV^[7], SimCLR^[8], SimCLRv2^[9], Siamese^[10], BYOL^[14], MoCo^[15], MoCov2^[16]등의 기존 연구들에서 우수한 성능을 보여 줌에 따라 최근 다양한 분야에서 주요 방법론으로 대두되고 있다. 이미지 관련 분야에서는 MoCo, BYOL, SimCLR, SwAV등 이미지 변환(augmentation) 기법을 사용하여 대조 학습을 진행하게 된다.

이는 그림 4를 통해 확인할 수 있는 바와 같이, 각기 다른 이미지 변환 기법을 적용시킨 이미지를 인코더 모델을 통하여 특성 벡터들(feature vectors)구한 뒤, 코사인 유사도(cosine similarity)나 유클리드 거리(Euclidean distance)등을 사용하여 동일 이미지로부터 얻어진 특성 벡터들의 유사성은 최대화하고, 다른 이미지로부터 얻어진 특성 벡터들의 유사성은 최소화




그림 4. 대조 학습에서 이미지 데이터를 사용하는 상황에서 사용되는 방법론의 그래픽 모델
Fig. 4. A graphic model of contrastive learning for image datasets

한다. 하지만 본 논문에서는 센서 데이터를 활용하기 위해 대조 학습의 여러 가지 방법 중 그림 5와 같이 CPC^[5]를 기반으로 한 사전 학습 방법을 고려하였다. 각각의 실제 시퀀스 센서 데이터를 입력으로하여 인코더와 GRU 모델을 통해 얻어진 긍정적인 샘플과 랜덤하게 섞인 시퀀스 센서 데이터로부터 얻어진 부정적인 샘플을 대조하는 학습을 진행하게 된다. 자세한 대조 학습의 과정은 아래의 학습절차를 통해 진행된다.

[학습절차] CPC기반의 대조 학습을 이용한 사전 학습 방법론

1. Sliding window를 이용하여 센서 데이터 X_t 를 sequence 형태의 데이터로 변환한다.
2. 인코더를 통하여 앞서 변환된 데이터의 상태를 구한 뒤, GRU 모델을 이용해 다음 상태 값을 예측한다.
3. 예측된 다음 상태 값이 긍정적인 샘플이 된다.
4. 3에서 예측된 다음 상태 값의 실제 target을 구하기 위해, 다음 sequence에 해당하는 센서 데이터를 입력으로하여 인코더로부터 target 상태 값을 구한다.
5. 센서 데이터를 시간 축에 대해 무작위로 섞은 뒤 2-3의 과정을 수행하여 부정적인 샘플을 만든다.
6. 5의 과정을 통해 예측된 상태 값은 부정적인 샘플이 된다.
7. 앞서 구한 긍정적인 샘플과 부정적인 샘플에 대하여 InfoNCE 손실 함수(수식 1) 기반으로 인코더와 GRU cell을 사전 학습한다.

$$L_t = -\frac{1}{K} \sum_{k=1}^K \log \left[\frac{\exp(\phi_\theta(x_{t+k})^T z_t)}{\sum_{n \in N_t} \exp(\phi_\theta(n)^T z_t)} \right] \quad (1)$$

여기에서 $\phi_\theta(x_{t+k}), z_t, \phi_\theta(n)$ 의 의미는 다음과 같다.

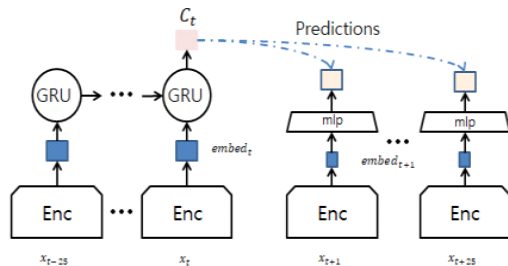


그림 5. 본 논문에서 사용된 모델로써, CPC를 기반으로 한 사전 학습 그래픽 모델
Fig. 5. The graphic model, which was used in this paper, based on CPC method

$\phi_\theta(x_{t+k})$:인코더와 GRU모델을 이용해 구해진 긍정적인 샘플; z_t :인코더와 MLP모델을 이용해 구해진 타겟; $\phi_\theta(n)$:인코더와 GRU모델을 이용해 구해진 부정적인 샘플

2.3 생성 모델

본 절에서는 앞서 대조 학습 방법론과의 시너지를 탐구하기 위해 사용된 생성 모델을 소개한다. 실험에 사용된 생성 모델로는 최근 심층 강화 학습(deep reinforcement learning) 방법론 중 Dreamer^[18-19]에서 제시한 표현 모델(representation model), 전이 모델(transition predictor), 이미지 모델(image predictor), 보상 모델(reward predictor), 할인 모델(discount predictor) 중에서, 표현 모델과 전이 모델 그리고 이미지 모델을 사용하고, 이 모델들을 이용해 대조 학습과 생성 모델의 시너지에 관한 탐구를 수행한다. 그림 6은 앞서 소개한 Dreamer v1^[18] 모델을 나타내고, 여기에 추가적으로 이산 월드 모델(discrete world model)을 사용하는 형태로 확장된 것이 Dreamer v2^[19]이다. 본 논문에서는 이러한 Dreamer v2의 표현 모델과 전이 모델 그리고 이미지 모델의 학습절차의 과정을 사용하여, 각각 긍정적인 샘플로부터 얻어지는 유사성과 부정적인 샘플로부터 얻어지는 비유사성을 고려하는 대조 학습 기반의 사전 학습을 진행한다.




그림 6. Dreamer v1[18]에서의 표현 모델, 전이 모델, 이미지 모델에 센서 데이터를 사용할 경우
Fig. 6. Representation model and image predictor using sensor datasets in Dreamer v1[18]

III. 실험

본 논문에서는 2장에서 설명한 스마트폰의 센서로부터 가공된 데이터 X_t 를 생성 모델을 통해 저차원 잠재 공간에 표현하는 실험을 진행하였다. 실험 결과는 사전 학습의 효과를 비교하기 위해, 대조 학습 기반의 사전 학습을 진행한 생성 모델로부터 얻어지는

결과와 사전 학습 없이 학습한 생성 모델로부터 얻어지는 결과를 비교하였다.

우선 생성 모델로부터 얻어지는 저차원 잠재 공간상의 상태 h_t 에 관하여 실험하였다. 여기서 h_t 는 (50,2)의 크기를 가진 시계열 상태 벡터로 그림 7과 그림 8처럼 2차원으로 표현할 수 있다. 그림 7은 사전 학습의 효과를 비교하기 위해, 사전 학습을 하지 않고 학습된 생성 모델로부터 얻어진 결과이다. 좌측의 학습 데이터로부터 얻어진 저차원 잠재 공간상태 h_t 와 우측의 테스트 데이터로부터 얻어진 h_t 는 다른 유저로부터 얻어진 센서 데이터이지만, 동일한 궤적을 동작을 표현하였기 때문에 유사한 패턴을 보이기를 기대하였지만 다른 패턴을 보이고 있다.

하지만, 대조 학습 기반 사전 학습이 진행된 생성 모델로부터 얻어지는 결과는 그림 8과 같이 학습 데이터로부터 얻어진 h_t 와 테스트 데이터로부터 얻어진 h_t 는 유사한 패턴으로 진행되는 것을 확인할 수 있다. 또한, 실험에 사용된 궤적을 동작 데이터의 경우 일정한 동작이 반복적으로 발생하는 주기성을 가지고 있는데, 실험의 결과를 통해 잠재 공간상에 표현된 궤적이 반복적인 패턴을 보이는 것을 보아 사용자의 동특

성이 의미있게 표현되었다고 볼 수 있다. 추가적으로 사전 학습된 생성 모델에서 학습 데이터로부터 얻어진 h_t 와 테스트 데이터로부터 얻어진 h_t 간의 Kendall T 상관계수 값은 0.274로, 사전 학습되지 않은 생성 모델에서 학습 데이터로부터 얻어진 h_t 와 테스트 데이터로부터 얻어진 h_t 간의 Kendall T 상관계수 값인 0.21보다 높은 값을 보이므로 사전 학습된 모델이 새로운 데이터에 대하여 기존 모델보다 일반화 능력이 우수하다고 볼 수 있다.

이산 잠재 공간상에서 Z_t 는 (50,9,9)의 크기를 가진 시계열 상태 확률 벡터로 아래의 그림 9과 그림 10처럼 3차원 그래프로 표현하였다. 여기서 각 그래프의 x축은 시간, y축은 이산 잠재 공간의 인덱스, z축은 Z_t 의 로짓(logit) 값이다. 그림 9에서 사전 학습되지 않은 생성 모델로부터 얻어지는 학습 데이터에 대한 Z_t 의 형태와 테스트 데이터로부터 얻어지는 Z_t 의 형태를 보면, 동일한 동작 데이터이지만 매우 다른 형태의 그래프를 볼 수 있다. 하지만, 그림 10을 보면 대조 학습을 기반으로 사전 학습된 생성 모델로부터 얻어지는 학습 데이터에 대한 Z_t 의 형태와 테스트 데이터로




그림 7. 사전 학습하지 않은 모델로부터 얻어진 h_t 좌측: 학습 데이터로부터 얻어진 h_t , 우측: 테스트 데이터로부터 얻어진 h_t

Fig. 7. h_t from unpretrained model left: h_t from train datasets, right: h_t from test datasets




그림 8. 사전 학습한 모델로부터 얻어진 h_t 좌측: 학습 데이터로부터 얻어진 h_t , 우측: 테스트 데이터로부터 얻어진 h_t

Fig. 8. h_t from pretrained model left: h_t from train datasets, right: h_t from test datasets





그림 9. 사전 학습하지 않은 모델로부터 얻어진 Z_t 위: 학습 데이터로부터 얻어진 Z_t , 아래: 테스트 데이터로부터 얻어진 Z_t

Fig. 9. Z_t from unpretrained model top: Z_t from train datasets, bottom: Z_t from test datasets

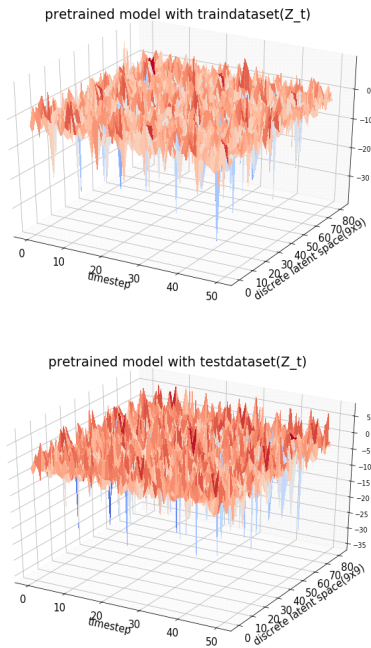


그림 10. 사전 학습한 모델로부터 얻어진 Z_t 위: 학습 데이터로부터 얻어진 Z_t , 아래: 테스트 데이터로부터 얻어진 Z_t
 Fig. 10. Z_t from pretrained model top: Z_t from train datasets, bottom: Z_t from test datasets

부터 얻어지는 Z_t 의 형태는 비슷한 패턴이 보이는 것을 확인할 수 있다. 이러한 결과의 정량적인 비교를 위해, 이산 잠재 공간상에서 Z_t 의 로짓 값을 이용하여 카테고리컬로 재표현한 뒤, 이를 시간에 따라 2차원 그래프로 표현하면 x축은 시간, y축은 0과 8사이의 값을 가진 9개의 그래프로 표현한다. 다음과 같은 그래프들을 FastDTW^[20]방법과 Cross-correlation 방법을 사용하여 사전 학습된 생성 모델과 사전 학습되지 않은 모델의 성능을 비교하면 다음의 표 2, 3과 같다. FastDTW의 경우, 0에 가까운 값일수록 유사성이 높은 것으로 볼 수 있다. 그 예로 표 2에서 동일한 학습 데이터셋A으로부터 얻어진 Z_t 간의 FastDTW값은 0인 것을 확인할 수 있다. 표 2를 통해 볼 수 있듯이,

표 2. FastDTW로 얻어진 유사도 값
 Table 2. Similarity value by FastDTW

(pretrain / not pretrain)	trainsetA	trainsetB	testset
trainsetA	0/0	49/67	48/58
trainsetB	49/67	0/0	43/69
testset	48/58	43/69	0/0

표 3. Cross-correlation로 얻어진 유사도 값
 Table 3. Similarity value by Cross-correlation

(pretrain / not pretrain)	trainsetA	trainsetB	testset
trainsetA	1/1	0.107/0.01	0.125/0.09
trainsetB	0.107/0.01	1/1	0.216/0.019
testset	0.125/0.09	0.216/0.019	1/1

사전 학습된 모델로부터 얻어진 Z_t 간의 FastDTW값은 사전 학습되지 않은 모델로부터 얻어진 Z_t 간의 FastDTW값보다 0에 가까운 것을 볼 수 있다(즉, 사전 학습된 생성 모델로부터 얻어진 Z_t 의 FastDTW[trainsetB, testset]=43 < 사전 학습되지 않은 생성 모델로부터 얻어진 Z_t 의 FastDTW[trainsetB, testset]=69). 반대로 Cross-correlation의 경우, 1에 가까운 값일수록 유사성이 높다고 볼 수 있다. 그 예로 표3에서 동일한 학습 데이터셋A으로부터 얻어진 Z_t 간의 교차 상관관계값은 1인 것을 확인할 수 있다.

표 3을 통해 볼 수 있듯이, 사전 학습된 모델로부터 얻어진 Z_t 간의 교차 상관관계수 값은 사전 학습되지 않은 모델로부터 얻어진 Z_t 간의 교차 상관관계수 값보다 더 높은 값을 보이는 것을 확인할 수 있다(즉, 사전 학습된 생성 모델로부터 얻어진 Z_t 간의 교차 상관관계수 [trainsetB, testset]=0.216 > 사전 학습되지 않은 생성 모델로부터 얻어진 Z_t 간의 교차 상관관계수 [trainsetB, testset]=0.019). 이러한 결과들을 통해, 사전 학습된 생성 모델로부터 얻어지는 동일한 동작의 Z_t 간의 유사도는 사전 학습되지 않은 생성 모델로부터 얻어지는 Z_t 간의 유사도보다 높은 것을 볼 수 있다.

위의 실험 결과들을 통해 대조 학습 기반의 사전 학습이 생성 모델에 어느 정도 영향을 미치는지 확인할 수 있다. 대조 학습을 기반으로 사전 학습된 생성 모델로부터 얻어지는 저차원 은닉 공간상의 궤적 그림 8은 기존의 사전 학습 없이 학습된 생성 모델로부터 얻어지는 저차원 은닉 공간상의 궤적 그림 7과는 다르게, 새로운 데이터가 추가되어도 데이터의 유사성과 비 유사성을 비교하여 일반화를 더욱 잘하는 모습을 볼 수 있다. 아울러 Z_t 의 경우에도 그림 9보다 사전 학습된 모델로부터 얻어진 그림 10에서 더욱더 유의미한 정보가 포함될 수 있음을 확인하였다.

IV. 결론

본 논문에서는 유사성과 비 유사성을 고려하는 대조 학습 기반의 사전 학습 방법을 통해, 일반적인 생성 모델 보다 일반화 능력 등에 있어 더 효율적인 생성 모델을 구현하는 방법에 대해 고찰을 수행하였다. 일반적인 생성 모델은 학습 데이터 부족이나 데이터의 노이즈와 같은 실질적인 문제점을 가진 다수의 공학적 응용문제를 해결할 때, 상황에 따라 현실에서는 높은 비용과 시간을 초래할 수 있음을 고려하면, 더욱더 높은 일반화 능력을 가지는 생성 모델을 구현하는 연구 방향은 매우 의미 있다고 볼 수 있다. 이후 비디오나 이미지 데이터를 사용한 대조 학습 기반의 사전 학습된 생성 모델에 관한 연구를 통하여, 더욱더 강인하고 일관된 생성 모델을 구현하는 연구가 필요하다고 생각된다. 본 논문에서 고찰한 내용과 추가 연구 방향은 향후에 심층 강화 학습 등과 결합하여 보다 더 효율적인 강화 학습 전략을 탐구하는 방향으로 발전할 수 있다.

References

[1] M. G. Azar, B. Piot, B. A. Pires, J. B. Grill, F. Althé, and R. Munos, "World discovery models," *arXiv preprint arXiv:1902.07685*, 2019.

[2] S. Gidaris, P. Singh, and N. Komodakis, "Unsupervised representation learning by predicting image rotations," *arXiv preprint arXiv:1803.07728*, 2018.

[3] M. Norouzi and P. Favaro, "Unsupervised learning of visual representations by solving jigsaw puzzles," in *Eur. Conf. Comput. Vision*, pp. 69-84, Springer, Cham, Oct. 2016.

[4] A. Kolesnikov, X. Zhai, and L. Beyer, "Revisiting self-supervised visual representation learning," in *Proc. IEEE/CVF Conf. CVPR*, pp. 1920-1929, 2019.

[5] A. V. D. Oord, Y. Li, and O. Vinyals, "Representation learning with contrastive predictive coding," *arXiv preprint arXiv:1807.03748*, 2018.

[6] M. Rivière, A. Joulin, P. E. Mazaré, and E. Dupoux, "Unsupervised pretraining transfers well across languages," in *ICASSP 2020-2020*, pp. 7414-7418, May 2020.

[7] M. Caron, I. Misra, J. Mairal, P. Goyal, P. Bojanowski, and A. Joulin, "Unsupervised learning of visual features by contrasting cluster assignments," *arXiv preprint arXiv:2006.09882*, 2020.

[8] T. Chen, S. Kornblith, M. Norouzi, and G. Hinton, "A simple framework for contrastive learning of visual representations," *arXiv preprint arXiv:2002.05709*, 2020.

[9] T. Chen, S. Kornblith, K. Swersky, M. Norouzi, and G. Hinton, "Big self-supervised models are strong semi-supervised learners," *arXiv preprint arXiv:2006.10029*, 2020.

[10] X. Chen and K. He, "Exploring simple siamese representation learning," *arXiv preprint arXiv:2011.10566*, 2020.

[11] C. Doersch, A. Gupta, and A. Zisserman, "CrossTransformers: Spatially-aware few-shot transfer," *arXiv preprint arXiv:2007.11498*, 2020.

[12] M. Ye, X. Zhang, P. C. Yuen, and S. F. Chang, "Unsupervised embedding learning via invariant and spreading instance feature," in *Proc. IEEE/CVF Conf. CVPR*, pp. 6210-6219, 2019.

[13] P. Bachman, R. D. Hjelm, and W. Buchwalter, "Learning representations by maximizing mutual information across views," *arXiv preprint arXiv:1906.00910*, 2019.

[14] J. B. Grill, F. Strub, F. Althé, C. Tallec, P. H. Richemond, E. Buchatskaya, and M. Valko, "Bootstrap your own latent: A new approach to self-supervised learning," *arXiv preprint arXiv:2006.07733*, 2020.

[15] K. He, H. Fan, Y. Wu, S. Xie, and R. Girshick, "Momentum contrast for unsupervised visual representation learning," in *Proc. IEEE/CVF Conf. CVPR*, pp. 9729-9738, 2020.

[16] X. Chen, H. Fan, R. Girshick, and K. He, "Improved baselines with momentum contrastive learning," *arXiv preprint arXiv:2003.04297*, 2020.

[17] K. Seong, T. Kim, S. Heo, J. Kim, J. Park, and J. Park, "Investigations on the ma-

chine-learning-based identification of dynamic motion characteristics utilizing wearable sensors," *J. Korean Soc. Control Robot Syst.*, pp. 456-457, 2016.

- [18] D. Hafner, T. Lillicrap, J. Ba, and M. Norouzi, "Dream to control: Learning behaviors by latent imagination," *arXiv preprint arXiv:1912.01603*, 2019.
- [19] D. Hafner, T. Lillicrap, M. Norouzi, and J. Ba, "Mastering atari with discrete world models," *arXiv preprint arXiv:2010.02193*, 2020.
- [20] S. Salvador and P. Chan, "FastDTW: Toward accurate dynamic time warping in linear time and space," *Comput. Sci.*, 2004.

최 창 균 (ChangKyun Choi)



2019년 : 고려대학교 제어계측 공학과 졸업
2019년~현재 : 고려대학교 제어 계측공학과 석사과정
<관심분야> 강화학습, 기계학습 응용, 딥러닝

김 태 환 (Tachwan Kim)



2015년 : 고려대학교 제어계측 공학과 졸업
2017년 : 고려대학교 제어계측 공학과 석사
2019년~현재 : 고려대학교 제어 계측공학과 박사과정
<관심분야> 강화학습, 기계학습 응용, 딥러닝

박 정 호 (Jeongho Park)



2016년 : 고려대학교 제어계측 공학과 졸업
2018년 : 고려대학교 제어계측 공학과 석사
2019년~현재 : 고려대학교 제어 계측공학과 박사과정
<관심분야> 강화학습, 기계학습 응용, 딥러닝

이 주 원 (Juwon Lee)



2018년 : 고려대학교 제어계측 공학과 졸업
2018년~현재 : 고려대학교 제어 계측공학과 석사통합과정
<관심분야> 강화학습, 기계학습 응용, 딥러닝

남 상 우 (Sangwoo Nam)



2019년 : 고려대학교 제어계측 공학과 졸업
2021년 : 고려대학교 제어계측 공학과 석사
<관심분야> 강화학습, 기계학습 응용, 딥러닝

박 주 영 (Jooyoung Park)



1983년 : 서울대학교 전기공학과 졸업
1992년 : University of Texas at Austin 전자 컴퓨터공학과 PhD
1993년~현재 : 고려대학교 제어 계측공학과 교수

<관심분야> 강화학습, 기계학습 응용, 딥러닝