

비디오 월 컨트롤러의 블랙 스크린 감지를 위한 데이터셋 생성

김성진
(주)리드텍

Generation of Dataset for Detection of Black Screen in Video Wall Controller

Sung-jin Kim

LEADTECH Co., Ltd

E-mail : sjkim@leadtech21.com

요 약

데이터 증강은 데이터셋의 양이 충분하지 않을 때 소량의 데이터를 활용하여 데이터의 양을 늘리는 기법이다. 인터넷의 보급으로 인해 손쉽게 얻을 수 있는 데이터는 많아졌지만 의학과 같이 데이터의 수집이 곤란한 분야도 여전히 남아 있다. 블랙 스크린 감지 모델에서 사용하는 비디오 월 컨트롤러에서 블랙 스크린이 발생한 이미지도 수집하기 어려운 데이터인데, 이는 비디오 월 컨트롤러를 운용하고 있는 중에 블랙 스크린이 발생하는 빈도가 낮기 때문이다. 따라서 본 논문에서는 비디오 월 컨트롤러에서 수집한 소량의 블랙 스크린 이미지를 활용하여 DCGAN을 훈련한 후 DCGAN의 생성자로 대량의 데이터셋을 생성하는 모델을 제안한다.

ABSTRACT

Data augmentation are techniques used to increase the amount of data by using small amount of existing data. With the spread of the Internet, we can easily obtain data. However, there are still certain industries, like medicine, where it is difficult to obtain data. The same is true for image data in which a black screen is displayed on video wall controller. Because it is rare that a black screen is displayed during operation, it is not easy to obtain an image with a black screen. We propose a DCGAN based architecture that generate dataset using a small amount of black screen image.

키워드

Convolutional Neural Network, Data Augmentation, DCGAN, Deep Learning, Video Wall Controller

1. 서 론

데이터 증강(Data Augmentation)은 데이터셋의 양이 충분하지 않을 때, 기존의 데이터에 수정을 가한 복사본을 추가하거나 기존의 데이터를 바탕으로 새로운 데이터를 생성하여 데이터의 양을 늘리는 기법이다. 레이블이 있는 데이터의 부족은 머신 러닝의 연구나 애플리케이션 개발의 주요한 걸림돌 중 하나이다. 인터넷의 보급으로 레이블이 없는 데이터는 쉽게 얻을 수 있게 되었지만 데이터

에 레이블을 부여하는 작업은 비용과 시간이 들뿐 아니라 데이터의 수집 자체가 곤란한 분야도 있다. 따라서 소량의 레이블이 있는 데이터를 활용하여 알고리즘의 성능을 향상시키는 것이 점점 중요해지고 있다.

블랙 스크린 감지 모델의 훈련에 사용하는 비디오 월 컨트롤러에서 블랙 스크린이 발생한 이미지도 수집하기 어려운 데이터이다. 블랙 스크린은 그림 1과 같이 비디오 월 컨트롤러의 멀티 스크린에 정상적인 영상이 아닌 블랙 스크린이 표출되는 현

상이다. 비디오 월 컨트롤러를 운영하고 있는 중에 블랙 스크린이 발생하는 빈도가 낮기 때문에 블랙 스크린이 발생한 이미지 데이터를 얻기가 쉽지 않다. 이에 본 논문에서는 비디오 월 컨트롤러에서 실제로 수집한 소량의 블랙 스크린 이미지를 활용하여 대량의 데이터셋을 생성하는 모델을 제안한다.



그림 1. 블랙 스크린이 발생한 사례

II. 관련 연구

2016년에 Alec Radford et al. [1]은 비지도 학습(Unsupervised Learning)을 위한 컨볼루션 신경망(Convolutional Neural Network) 기반의 DCGAN(Deep Convolutional Generative Adversarial Network)을 제안하였다. DCGAN은 GAN[2]의 여러 모델 가운데 가장 중요한 혁신 중의 하나로 주목 받았는데 컨볼루션 신경망을 GAN에 성공적으로 적용한 것은 DCGAN이 처음이기 때문이었다. 컨볼루션 신경망을 이용하면 GAN의 취약점으로 거론되는 훈련이 불안정해 진다거나 기울기 값이 소멸되는 등의 문제를 악화시킬 수 있다. 실제로 이러한 문제들로 인해 몇몇 연구자들은 LAPGAN(Laplacian Generative Adversarial Network)[3]과 같은 다른 접근 방법을 시도하기도 하였다. LAPGAN은 복잡하고 계산적으로 비효율적이었지만 오리지널 GAN에 비해 4배 정도 향상된 품질의 이미지를 생성하였다. LAPGAN은 GAN과 컨볼루션 신경망이 결합할 때의 잠재력을 제시한 모델이라고 할 수 있다.

GAN 훈련의 불안정성을 개선하기 위해 Radford et al. 이 사용한 기법 중의 하나는 배치 정규화(Batch Normalization)이다. 배치 정규화는 각 레이어의 입력을 정규화 하여 GAN 훈련을 안정화시킨다. 배치 정규화는 2015년 Sergey Ioffe와 Christian Szegedy[4]가 제안하였는데, 신경망의 입력을 정규화 하듯이 신경망에 있는 각 레이어의 입력을 미니 배치 단위로 정규화 하는 방법이다. 배치 정규화는 딥 신경망의 훈련을 불안정하게 만드는 covariate shift 문제를 방지할 수 있다.

III. 접근 방식 및 모델 아키텍처

블랙 스크린 감지 모델은 이미지 분류 알고리즘

을 이용하여 블랙 스크린의 발생 여부를 감지하므로 훈련에 필요한 데이터는 비디오 월 컨트롤러가 정상적으로 운용 중일 때의 이미지 데이터와 블랙 스크린이 발생하였을 때의 이미지 데이터이다. 정상적인 이미지 데이터는 비디오 월 컨트롤러를 운용하며 수집한다. 일반적인 상황에서는 블랙 스크린이 발생한 이미지 데이터를 얻기가 어려우므로 블랙 스크린이 발생한 이미지 데이터는 인위적으로 블랙 스크린을 발생시켜 수집한다. 인위적으로 얻을 수 있는 데이터의 개수에는 한계가 있으므로 소량의 데이터를 수집하여 DCGAN을 훈련하고 부족한 데이터셋은 DCGAN의 생성자로 생성한다. 이 과정을 순서대로 나타내면 그림 2와 같다.




그림 2. 블랙 스크린 데이터셋 수집의 순서도

DCGAN의 판별자(discriminator)는 블랙 스크린이 발생한 이미지가 실제로 수집한 이미지인지 생성자가 만들어낸 합성 이미지인지를 구분하도록 훈련되며 아키텍처는 그림 3과 같다.




그림 3. 판별자의 아키텍처

DCGAN의 생성자(generator)는 판별자가 구분하기 힘든 수준의 블랙 스크린이 발생한 이미지를 생성하도록 훈련되며 아키텍처는 그림 4와 같다.




그림 4. 생성자의 아키텍처

IV. 실험 및 결과

실험에 사용한 비디오 월 컨트롤러는 그림 5와 같이 3단 5열의 UHD(3840x2160) 모니터로 구성된 시스템이다. 블랙 스크린이 발생한 이미지 데이터는 특정 모니터에 표출중인 영상에서 오류가 발생하도록 비디오 월 컨트롤러를 제어하여 블랙 스크린을 인위적으로 표출한 후 그림 6과 같은 이미지

데이터를 수집하였다.



그림 5. 비디오 월 컨트롤러의 모니터 구성



그림 6. 블랙 스크린이 발생한 이미지

인위적으로 블랙 스크린을 표출하여 이미지 데이터를 수집하는 방법으로 모든 데이터를 얻기에는 비용이나 시간적인 면에서 한계가 있으므로 소량의 이미지 데이터만 수집하였다. 비디오 월 컨트롤러에서 수집한 이미지 데이터를 64x64 크기로 리사이징하고 [-1, 1]의 범위로 스케일링 하였다. 그 외의 이미지 전처리는 수행하지 않았다. DCGAN은 배치의 크기를 256으로 설정하고 미니 배치 SGD (Mini-batch Stochastic Gradient Descent)로 훈련 하였다. 모든 파라미터는 랜덤으로 초기화 하였다. 활성화 함수는 LeakyReLU을 사용하였고 파라미터는 0.2를 설정하였다. 최적화 알고리즘은 Adam optimizer (Kingma & Ba[5], 2014)를 사용하였고 학습률(Learning Rate)은 0.0002, β_1 은 0.5를 설정하였다. 20 epoch와 200 epoch 후에 DCGAN의 생성자가 생성한 샘플 이미지를 그림 7과 그림 8에 나타내었다.




그림 7. 20 epoch 후의 샘플 이미지



그림 8. 200 epoch 후의 샘플 이미지

그림 7은 어렵듯한 형태이긴 하지만 블랙 영역을 생성하고 있으며 그림 8은 블랙 영역이 더 또렷해지고 사각형에 가까운 모양을 띄고 있다. 블랙 스크린이 발생한 이미지는 사각형 모양의 영역이 블랙으로 표시된 이미지인데 DCGAN은 이러한 특

징을 학습하여 훈련 데이터셋과 유사한 이미지를 생성하고 있는 것을 알 수 있다.

V. 결 론

본 논문에서는 블랙 스크린 감지 모델에서 사용하는 데이터셋 수집을 위한 모델을 제안하였다. 비디오 월 컨트롤러에서 수집한 소량의 블랙 스크린이 발생한 이미지로 DCGAN을 훈련하였고 DCGAN의 생성자가 생성한 샘플 이미지를 통해 소량의 이미지 데이터만으로도 블랙 스크린 감지 모델의 훈련에 필요한 데이터셋을 수집할 수 있다는 것을 확인할 수 있었다. 다만 샘플 이미지에서 아쉬웠던 점은 사각형 모양이 아닌 블랙 영역이 생성되거나 블랙 영역이 아예 없는 이미지가 드물게 생성되었다는 것인데, 아키텍처의 개선이나 파라미터의 튜닝 그리고 데이터셋의 개수를 조정해 가며 개선할 계획이다. 아울러 본 논문에서 이용한 DCGAN 대신 attention의 개념을 도입한 Self-Attention GAN (SAGAN)[6]을 이용하는 모델을 구현한 후 본 논문의 결과와 비교 분석하고 비디오 월 컨트롤러에서 처리하고 있는 다른 데이터에 대해서도 본 논문에서 제안한 방법을 활용해 나갈 것이다.

References

- [1] Alec Radford, Luke Metz, and Soumith Chintala, "Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks," 2016, <http://arxiv.org/abs/1511.06434>.
- [2] Ian J. Goodfellow et al., "Generative Adversarial Networks," 2014, <http://arxiv.org/abs/1406.2661>.
- [3] Emily Denton et al., "Deep Generative Image Models using a Laplacian Pyramid of Adversarial Networks", 2015, <http://arxiv.org/abs/1506.05751>.
- [4] Sergey Ioffe and Christian Szegedy, "Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift," 2015, <http://arxiv.org/abs/1502.03167>.
- [5] Diederik P. Kingma, Jimmy Ba, "Adam: A Method for Stochastic Optimization", 2014, <http://arxiv.org/abs/1412.6980>.
- [6] Han Zhang et al, "Self-Attention Generative Adversarial Networks," 2018, <http://arxiv.org/abs/1805.08318>.