

컨볼루션 신경망에 기반한 비디오 월 컨트롤러의 블랙 스크린 감지

김성진
(주)리드텍

Detection of Black Screen in Video Wall Controller Using CNN

Sung-jin Kim

LEADTECH Co., Ltd

E-mail : sjkim@leadtech21.com

요 약

최근에 비디오 월 컨트롤러 시장이 빠르게 성장하면서 지금까지는 크게 이슈화 되지 않았던 문제들이 표면화 되고 있는데, 비디오 월 컨트롤러에서 블랙 스크린이 발생하는 현상도 그 중 하나일 것이다. 블랙 스크린은 비디오 월 컨트롤러의 멀티 스크린에 정상적인 영상이 아닌 블랙 스크린이 표출되는 현상이다. 블랙 스크린의 발생을 인지하고 해결하기 위해서는 인간의 개입이 불가피 하지만 운영자가 24시간 멀티 스크린을 모니터링 하는 것은 사실상 불가능하다. 따라서 본 논문에서는 비디오 월 컨트롤러에서 블랙 스크린이 발생하는 것을 자동으로 감지하는 모델을 제안한다. 블랙 스크린 감지 모델은 이미지 분류에 널리 활용되고 있는 컨볼루션 신경망으로 블랙 스크린의 발생 여부를 감지한다.

ABSTRACT

As the video wall controller market is growing rapidly, issues that have not been addressed so far are raised. One of them is a phenomenon in which a black screen is displayed on a multi-screen. Black screen is displayed due to an error in the video being displayed in the video wall controller. Human intervention is inevitable to recognize and solve the black screen. However, it is impossible for the operator to monitor the multi-screen 24 hours a day. In this paper, we propose a model that detects the black screen being displayed on the video wall controller. We propose a CNN based architecture to detect a black screen.

키워드

Convolutional Neural Network, DCGAN, Deep Learning, Image Classification, Video Wall Controller

1. 서 론

불과 몇 년 전만 하더라도 비디오 월 컨트롤러는 대규모의 상황실이나 관제 센터에서 중요한 시설을 모니터링하거나 보안 유지의 목적으로 구축하는 것이 일반적이었다. 하지만 최근에는 제어, 프레젠테이션, 협업, 정보 제공, 감동 부여 등의 다양한 용도로 사용되고 있으며 구축하는 장소도 상황실과 관제 센터뿐 아니라 빌딩의 로비, 회의실, 체험 학습 센터, 텔레비전 스튜디오, 대형 마트, 공

공장 등으로 확대되고 있다. 이와 같이 비디오 월 컨트롤러 시장이 빠르게 성장하면서 지금까지는 크게 이슈화 되지 않았던 문제들도 표면화 되고 있는데 그 중에 하나가 그림 1과 같이 비디오 월 컨트롤러에서 블랙 스크린이 발생하는 현상이다. 비디오 월 컨트롤러를 운용하고 있는 중에 블랙 스크린이 발생하는 빈도는 높지 않다. 하지만 긴급하거나 중요한 상황에서 블랙 스크린이 발생한다면 해당 업무에 지장을 초래할 뿐 아니라 제품의 신뢰도 나아가 회사의 이미지를 실추시킬 수

있는 사안으로 발전할 수도 있으므로 신속하게 인지하고 대처하는 것이 무엇보다 중요하다고 할 수 있다.



그림 1. 블랙 스크린이 발생한 사례

블랙 스크린이 발생하는 원인은 다양하다. 실시간 스트리밍 프로토콜(RTSP)과 관련된 오류 등의 소프트웨어적인 문제일 수도 있고, 디스플레이의 렌더링 오류나 케이블 불량 등의 하드웨어적인 문제일 수도 있다. 또한 단순히 네트워크의 문제일 가능성도 있다. 비디오 월 컨트롤러에서 블랙 스크린이 발생하면 오류가 발생한 영상을 다시 표출한다거나 하드웨어적인 이슈인 경우 비디오 월 컨트롤러를 재부팅 하는 등 인간의 개입이 불가피하다. 한편, 운영자가 24시간 실시간으로 멀티 스크린을 모니터링 하는 것은 사실상 불가능 하므로 블랙 스크린이 발생하더라도 즉시 이 사실을 인지하지 못하고 대처가 늦어지는 경우도 있다. 이에 본 논문에서는 이미지 분류(Image Classification)에 널리 활용되고 있는 컨볼루션 신경망(Convolutional Neural Network)으로 비디오 월 컨트롤러에서 블랙 스크린이 발생하는 것을 자동으로 감지하는 모델을 제안한다.

II. 관련 연구

비디오 월 컨트롤러는 여러 개의 모니터를 연속적으로 배치하여 하나의 큰 스크린으로 표출하는 특수한 형태의 멀티 모니터와 입력 소스의 영상을 멀티 모니터에 표출하기 위한 제어 시스템으로 구성된다. 비디오 월 컨트롤러는 그림 2와 같이 상황실이나 관제 센터, 공항 등에서 대규모의 시스템으로 사용되고 있으며 최근에는 보안에 대한 사회적 관심도가 증가함에 따라 소규모의 시스템에서도 활용되고 있다.



그림 2. 비디오 월 컨트롤러

컨볼루션 신경망은 딥러닝 분야에서 이미지 데이터 분석에 일반적으로 이용되고 있는 심층 신경망이다. 1959년 David Hubel과 Torsten Wiesel[1]은 인간의 시각 피질(visual cortex)에 있는 단순 세포(simple cells)와 복잡 세포(complex cells)가 패턴 인식에 이용 된다고 제시하였으며 두 세포를 활용한 모델을 패턴 인식 작업에 이용하였다. 1980년에 Kunihiko Fukushima[2]는 이들의 연구에서 영감을 얻어 neocognitron 모델을 제안하였는데, 이 모델은 컨볼루션 신경망의 기본이 되는 레이어인 컨볼루션 레이어와 다운샘플링 레이어를 사용하고 있다. Yann LeCun et al. [3]은 계층에 따라 단순한 패턴과 복잡한 패턴을 학습하는 구조의 컨볼루션 신경망이 손으로 쓴 숫자 인식에 성공적으로 이용될 수 있다는 것을 제시하였다. 2012년 Alex Krizhevsky et al. [4]이 제안한 컨볼루션 신경망 기반의 AlexNet이 ImageNet에 있는 이미지에 레이블을 부여하는 작업에서 최첨단의 성능을 과시하며 컨볼루션 신경망의 인지도는 더욱 높아졌고 현재 이미지나 비디오 인식, 추천 시스템, 이미지 분류, 이미지 영역 분할(image segmentation), 의학 영상 분석, 자연 언어 처리, brain-computer 인터페이스, 시계열 데이터 분석 등의 다양한 분야에서 활용되고 있다.

III. 접근 방식 및 모델 아키텍처

블랙 스크린 감지 시스템은 그림 3과 같이 비디오 월 컨트롤러에서 전체 화면의 스크린샷을 수집하는 이미지 수집부, 수집한 이미지 데이터를 사용하여 블랙 스크린을 감지하고 블랙 스크린이 감지 되었을 때 이벤트를 발생시키는 블랙 스크린 감지부 그리고 이벤트가 발생하였을 때 블랙 스크린을 해결하기 위한 이벤트 처리부로 구성된다.




그림 3. 블랙 스크린 감지 시스템의 구성

블랙 스크린 감지 모델은 그림 4와 같이 이미지 데이터 처리에 적합한 구조를 가지고 있는 컨볼루션 신경망을 이용한다. 입력으로 주어지는 이미지의 크기는 64x64이다. feature 추출부는 컨볼루션 레이어와 풀링 레이어로 구성하고 컨볼루션 레이어의 활성화 함수는 ReLU을 사용한다. 분류부는 완전연결 레이어(Fully Connected Layer)를 사용하고 출력 레이어의 활성화 함수는 소프트맥스 함수를 사용하여 정상과 블랙 스크린 발생에 대한 확률을 출력한다. 또한 오

버피팅(overfitting) 방지를 위해 드롭아웃(dropout)을 사용한다.




그림 4. 모델 아키텍처

블랙 스크린 감지 모델의 훈련에 사용하는 이미지 데이터는 정상적인 이미지와 블랙 스크린이 발생한 이미지이다. 정상적인 이미지는 비디오 월 컨트롤러의 운용 중에 수집한다. 운용 중에 블랙 스크린이 발생하는 빈도가 낮기 때문에 블랙 스크린이 발생한 이미지는 3가지 단계로 수집한다. 먼저, 멀티 스크린에 표출중인 영상에서 오류가 발생하도록 비디오 월 컨트롤러를 제어하여 블랙 스크린을 인위적으로 표출한 후 이미지 데이터를 수집한다. 다음으로, 인위적으로 수집한 소량의 이미지 데이터로 DCGAN(Deep Convolutional Generative Adversarial Network)[5]을 훈련한다. 마지막으로, DCGAN의 생성자(generator)로 나머지 데이터셋을 생성한다.

IV. 실험 및 결과

실험에 사용한 비디오 월 컨트롤러는 3단 5열의 UHD(3840x2160) 모니터로 구성된 시스템이며 전체 해상도는 19200x6480이다. 정상적인 이미지 데이터와 블랙 스크린이 발생한 이미지 데이터를 훈련 데이터셋과 검증(validation) 데이터셋으로 분리하고 배치의 크기를 16으로 설정한 후 미니 배치 SGD(Mini-batch Stochastic Gradient Descent)로 훈련 하였다. 모든 파라미터는 랜덤으로 초기화하였고 RMSprop optimizer를 사용하였다. 50 epoch 후의 모델의 정확도(accuracy)는 표 1과 같다. 단순한 구조의 컨볼루션 신경망을 이용했음에도 불구하고 블랙 스크린 감지 작업에 있어 나쁘지 않은 결과를 보여주고 있다.

표 1. 모델의 정확도

데이터셋	정확도(%)
훈련	99.948
검증	99.920
테스트	96.900

V. 결 론

본 논문에서는 비디오 월 컨트롤러에서 블랙 스크린이 발생하였을 때 이를 자동으로 감지하기 위한 컨볼루션 신경망 기반의 모델을 제안하였다. 데이터셋의 수집이 곤란한 환경에서 생성 모델(Generative Model)의 일종인 DCGAN으로 데이터셋을 생성하여 블랙 스크린 감지 모델을 훈련하였고, 실험을 통해 블랙 스크린의 발생 여부를 감지하는 작업에서 좋은 결과를 얻을 수 있다는 것을 확인할 수 있었다. 하지만 실제 제품에 적용하기 위해서는 정확도를 더 높여야 하므로 준지도학습(Semi-Supervised Learning)과 GAN[6]을 접목한 Semi-supervised GAN(SGAN)[7]을 이용하거나 파라미터를 튜닝하며 모델의 성능을 개선해 나갈 것이다. 또한 본 논문에서는 단일 해상도에서만 실험을 진행하였지만 비디오 월 컨트롤러는 다양한 해상도로 사용되고 있기 때문에 여러 해상도에서 실험을 진행하여 해상도에 대한 의존성의 존재 여부도 검증할 계획이다.

References

- [1] D. H. Hubel and T. N. Wiesel, "Receptive fields of single neurones in the cat's striate cortex", *The Journal of Physiology*, 124 (3), pp. 574-591, Oct. 1959.
- [2] Fukushima, Kunihiko, "Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position", *Biological Cybernetics*, 36 (4), pp. 193-202, Apr. 1980.
- [3] Yann LeCun et al., "Gradient-Based Learning Applied to Document Recognition," *Proceedings of the IEEE* 86, no. 11, pp. 2278-2324, Dec. 1998.
- [4] Alex Krizhevsky et al., "ImageNet Classification with Deep Convolutional Neural Networks," *Advances in neural information processing systems* 25, 1097-1105, pp. 1097-1105, Dec. 2012.
- [5] Alec Radford, Luke Metz, and Soumith Chintala, "Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks," 2016, <http://arxiv.org/abs/1511.06434>.
- [6] Ian J. Goodfellow et al., "Generative Adversarial Networks," 2014, <http://arxiv.org/abs/1406.2661>.
- [7] Maayan Frid-Adar et al., "Synthetic Data Augmentation Using GAN for Improved Liver Lesion Classification", 2018, <https://arxiv.org/abs/1801.02385>.