

이산화 된 로지스틱 혼합 분포를 이용한 비디오 월 컨트롤러의 이상 감지

김성진
(주)리드텍
sjkim@leadtech21.com

Anomaly Detection of Video Wall Controller Using Discretized Logistic Mixture Distribution

Sung-jin Kim
LEADTECH Co., Ltd

요 약

프리징은 컴퓨터 시스템에서 하나의 프로세스나 시스템 전체가 입력에 대한 응답이 중단되고 제어가 불가능한 상태가 되는 현상이다. 비디오 월 컨트롤러의 제어 시스템도 OS에서 동작하는 애플리케이션이므로 프리징이 발생할 수 있지만, 운영자가 멀티 스크린을 실시간으로 모니터링 하고 있더라도 프리징의 발생을 인지하기 어렵고, 프리징을 인지하였을 때는 이미 제어가 불가능한 상태이므로 비디오 월 컨트롤러를 재부팅 하는 것 외에는 대응할 수 있는 방법이 없다. 따라서 본 논문에서는 비디오 월 컨트롤러의 이상 여부를 감지하여 프리징을 방지할 수 있는 모델을 제안한다. 이상 감지 모델은 이산화 된 로지스틱 혼합 분포의 우도 함수를 이용하여 비디오 월 컨트롤러의 이상 여부를 감지한다.

1. 서론

프리징은 컴퓨터 시스템에서 하나의 프로세스나 시스템 전체가 입력에 대한 응답이 중단되고 제어가 불가능한 상태가 되는 현상이다. 프리징의 원인은 다양하다. 장치의 호환성 문제나 파손과 같은 하드웨어적인 결함이나 무한루프에 빠지는 등의 소프트웨어적인 결함일 수도 있고, 프로세스 간 통신에서 경쟁 상태(Race Condition)에 놓이게 되는 경우일 수도 있다. 또한 단순히 시스템 자원의 고갈로 인해 프로그램이 느리게 동작하여 응답이 없는 것처럼 보일 수도 있다. 비디오 월 컨트롤러의 제어 시스템도 OS에서 동작하는 애플리케이션이므로 프리징이 발생할 수 있지만, 운영자가 프리징의 발생을 인지하기 어렵고 설사 프리징을 인지하더라도 비디오 월 컨트롤러는 이미 제어가 불가능한 상태에 있으므로 비디오 월 컨트롤러를 재부팅 하는 것 외에는 달리 대응할 수 있는 방법도 없다. 따라서 본 논문에서는 비디오 월 컨트롤러 의 이상 여부를 감지하여 프리징을 방지할 수 있는 모델을 제안한다. 이상 감지 모델은 이산화 된 로지스틱 혼합 분포(Discretized Logistic Mixture Distribution)의 우도 함수

(Likelihood Function)를 이용하여 비디오 월 컨트롤러의 이상 여부를 감지한다.

2. 관련 연구

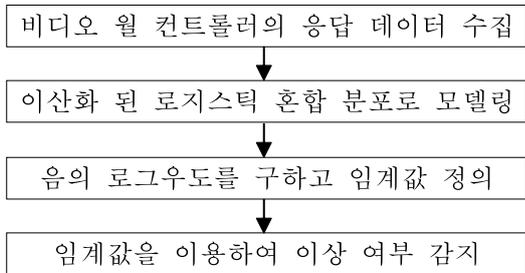
이산화 된 로지스틱 혼합 분포의 우도 함수는 PixelCNN++[1]와 WaveNet[2]에서 이산치(Discrete Value)의 예측을 위해 이용되었다. PixelCNN++의 목표는 이미지의 생성이므로 [0, 255] 범위의 픽셀 값을 예측하면 된다. 픽셀 값의 예측을 위해 소프트맥스 함수를 사용하는 방법도 있지만, 소프트맥스 함수는 훈련 데이터셋에 없는 픽셀 값을 예측할 수 없다는 등의 단점이 있으므로, 이를 해결하기 위해 픽셀 값이 아닌 픽셀 값의 분포를 예측하였다. 분포는 최대우도법(Maximum Likelihood)으로 분포의 파라미터를 추정하여 예측할 수 있다. 데이터의 분포가 복잡하여 정규 분포나 로지스틱 분포와 같은 단순한 분포로 표현할 수 없다면 혼합분포(Mixture Distribution)를 이용한다. 혼합분포는 여러 분포의 선형적 조합이므로 수식 1과 같은 형태를 가진다.

$$p(x) = a_1 \times p_1(x) + a_2 \times p_2(x) + \dots + a_n \times p_n(x) \quad (1)$$

파라미터를 늘릴수록 복잡한 데이터 분포를 표현할 수 있다. 혼합 분포를 이용하는 경우에 추정할 파라미터는 a_i , μ_i 그리고 s_i 이며 PixelCNN++에서는 마지막 레이어에서 이 파라미터를 추정하고 있다.

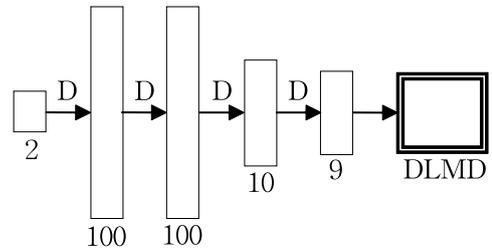
3. 접근 방식 및 모델 아키텍처

본 논문에서는 음의 로그우도(Negative Log-Likelihood, NLL)를 이용하여 이상 여부를 감지한다. 먼저, 비디오 월 컨트롤러에서 수집한 응답 데이터를 이산화 된 로지스틱 혼합 분포로 모델링하고 샘플 데이터를 생성한다. 다음으로, 샘플에 대한 음의 로그우도를 구한다. 마지막으로, 음의 로그우도의 평균과 표준편차를 이용하여 이상 감지의 임계값(threshold)을 정의하고 임계값을 초과하는 음의 로그우도를 가지는 데이터를 비정상적으로 판단한다. 이 과정을 순서도로 나타내면 그림 1과 같다.



(그림 1) 이상 감지의 순서도

비디오 월 컨트롤러의 응답 데이터는 동일한 네트워크에서 실행되는 클라이언트 프로그램에서 비디오 월 컨트롤러에 패킷을 송신하고 응답 데이터가 수신되는 횟수를 1초 단위로 측정한다. 이 데이터는 포아송 분포(Poisson Distribution)로 모델링할 수도 있지만 본 논문에서는 성능이 더 우수한 이산화 된 로지스틱 혼합 분포를 이용한다. 비디오 월 컨트롤러의 응답 데이터는 이산형 데이터이지만 로지스틱 분포는 한계치가 없는 연속형 데이터이므로 로지스틱 분포를 이산화하고 유연한 분포의 처리를 위해 혼합 분포를 이용한다. 혼합 분포의 혼합 비율은 카테고리 확률 분포로 결정한다. 로지스틱 혼합 분포의 예측을 위해 추정할 파라미터는 3가지인데, 로지스틱 분포의 파라미터인 위치(location)와 척도(scale) 그리고 혼합 분포의 혼합 비율이다. 이 파라미터는 그림 2와 같이 딥 신경망으로 추정한다. 척도는 양수여야 하므로 소프트플러스 함수로 변환하여 사용한다.



D: Dense Layer

DLMD: Discretized Logistic Mixture Distribution

(그림 2) 모델 아키텍처

훈련 완료 후 이산화 된 로지스틱 혼합 분포로 샘플을 생성하고 샘플에 대해 음의 로그우도를 계산한 후 이상 감지의 임계값을 수식 2와 같이 구한다.

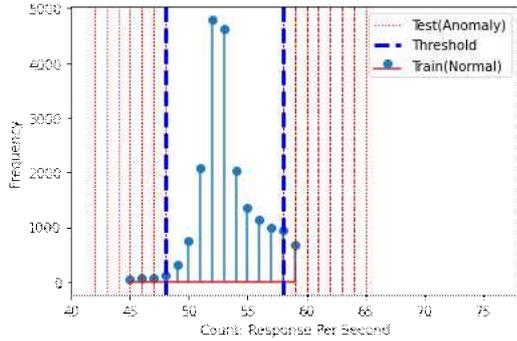
$$\text{임계값} = \text{NLL의 평균} + 2 \times \text{NLL의 표준편차} \quad (2)$$

테스트 데이터셋에 대해 이 임계값을 초과하는 음의 로그우도를 가지는 데이터를 비정상적으로 판단한다.

4. 실험 및 결과

비디오 월 컨트롤러에서 수집한 응답 데이터를 훈련 데이터셋과 검증(validation) 그리고 테스트 데이터셋으로 분리하고 배치의 크기를 128로 설정한 후 미니 배치 SGD(Mini-batch Stochastic Gradient Descent)로 훈련 하였다. 모든 파라미터는 랜덤으로 초기화하였고 활성화 함수는 ReLU를 사용하였다. 최적화 알고리즘은 Adam optimizer(Kingma & Ba[3], 2014)를 사용하였고 학습률(Learning Rate)은 0.0002, β_1 은 0.5를 설정하였다. 모델의 훈련 완료 후 테스트 데이터셋에 대해 이상 여부를 예측한 결과는 그림 3과 같다. 임계값을 초과하는 음의 로그우도를 가지는 데이터의 응답 횟수는 정상적인 값의 범위를 벗어나고 있는 것을 알 수 있다.

다음으로, 이산화 된 로지스틱 혼합 분포를 다른 모델과 비교하기 위해 동일한 데이터셋을 포아송(Poisson)과 영과잉(Zero-Inflated) 포아송으로 모델링하고 각 모델의 음의 로그우도를 계산하여 표 1에 나타내었다. 이산화 된 로지스틱 혼합 분포의 성능이 가장 우수하다는 것을 알 수 있다.



(그림 3) 테스트 데이터셋에 대한 이상 감지

<표 1> 각 모델의 음의 로그우도 비교

모델	음의 로그우도
이산화 된 로지스틱 혼합	2.35
포와송	2.96
영과잉 포아송	2.98

5. 결론

본 논문에서는 비디오 월 컨트롤러의 이상 여부를 감지하여 프리징이 발생하는 것을 방지할 수 있는 모델을 제안하였다. 비디오 월 컨트롤러에서 수집한 응답 데이터를 이산화 된 로지스틱 혼합 분포로 모델링한 후 샘플을 생성하고, 샘플에 대해 음의 로그우도를 계산한 후 이상 감지를 판단하기 위한 임계값을 정의하였다. 테스트 데이터셋에 대한 이상 감지 실험을 통해 음의 로그우도가 이상 감지 판단의 적절한 기준이 될 수 있다는 것을 확인할 수 있었다. 본 논문에서 제안한 방법으로 비디오 월 컨트롤러의 이상 여부를 감지하고 자동으로 조치를 취하는 시스템을 고안하거나 운영자가 적절한 대처를 한다면 프리징이 발생하지 않는 논스톱 비디오 월 컨트롤러의 실현도 꿈같은 일은 아닐 것이다.

참고문헌

[1] Tim Salimans, Andrej Karpathy, Xi Chen, Diederik P. Kingma, “PixelCNN++: Improving the PixelCNN with Discretized Logistic Mixture Likelihood and Other Modifications”, 2017, <http://arxiv.org/abs/1701.05517>.

[2] Aaron van den Oord, Yazhe Li, Igor Babuschkin, Karen Simonyan, Oriol Vinyals, Koray Kavukcuoglu, George van den Driessche,

Edward Lockhart, Luis C. Cobo, Florian Stimberg, Norman Casagrande, Dominik Grewe, Seb Noury, Sander Dieleman, Erich Elsen, Nal Kalchbrenner, Heiga Zen, Alex Graves, Helen King, Tom Walters, Dan Belov, Demis Hassabis, “Parallel WaveNet: Fast High-Fidelity Speech Synthesis”, 2017, <http://arxiv.org/abs/1711.10433>.

[3] Diederik P. Kingma, Jimmy Ba, “Adam: A Method for Stochastic Optimization”, 2014, <http://arxiv.org/abs/1412.6980>.