

강화학습 기반 몰입형 영상 압축 성능 향상 기법

김동신, 오병태

한국항공대학교

dskim20@kau.kr, byungoh@kau.ac.kr

Improving immersive video compression efficiency by reinforcement learning

Dongsin Kim, Byung Tae Oh

Korea Aerospace University

요 약

본 논문에서는 강화학습을 이용하여 몰입형 영상의 압축 효율을 향상시키는 기법을 제안한다. 몰입형 영상이란 3DOF+ 영상 혹은 Point Cloud 영상과 같이 사용자가 직접 체험할 수 있는 영상을 의미한다. 또한 몰입형 영상은 그 특성에 의해 방대한 양의 정보를 가지고 있다. 따라서 이를 압축하기 위한 압축 방법들이 연구되고 있으며, 일반적으로 3D 공간의 영상을 2D 공간으로 사영하는 방식을 사용한다. 하지만 이 과정에서 정보가 존재하지 않는 영역이 생성되며 이는 압축 효율 저하의 원인이 된다. 이러한 문제를 해결하기 위하여 영상의 특성을 반영할 수 있도록 강화학습을 통한 채우기 기법을 제안한다. 실험 결과 제안한 기법이 기존 기법에 비해 좋은 성능을 보임을 확인할 수 있다.

In this paper, we propose a new method for improving compression efficiency of immersive video using reinforcement learning. Immersive video means a video that a user can directly experience, such as 3DOF+ videos and Point Cloud videos. It has a vast amount of information due to their characteristics. Therefore, lots of compression methods for immersive video are being studied, and generally, a method, which projects an 3D image into 2D image, is used. However, in this process, a region where information does not exist is created, and it can decrease the compression efficiency. To solve this problem, we propose the reinforcement learning-based filling method with considering the characteristics of images. Experimental results show that the performance is better than the conventional padding method.

1. 서론

최근 영상의 하드웨어 기술이 발전함에 따라 고해상도 영상에서 더 나아간 몰입형 영상에 대한 관심이 증가하고 있다. 몰입형 영상은 3DOF+ 혹은 Point Cloud 영상과 같이 사용자가 직접 체험할 수 있는 영상을 의미한다. 따라서 몰입형 영상은 일반적으로 3D 정보를 가지고 있으며 이를 표현하기 위해 기존 2D 영상과는 다른 표현법이 연구되고 있다. Joint Video

Exploration Team (JVET)에서 제공하는 360 라이브러리에는 360도 정보를 모두 포함하는 360 영상을 제공하기 위한 다양한 포맷을 형성하는 기법들이 존재한다 [1]. 이렇게 형성된 다양한 시점의 360영상들을 통해 몰입형 영상을 만들 수 있으며 이는 방대한 양의 정보를 가지고 있다. Moving Picture Experts Group (MPEG)에서 제공하는 Test Model for Immersive Video (TMIV)는 여러 시점의 360영상들은 한 번에 압축하는 기법을 제공한다 [2]. 또한 Point Cloud 기술은 3차원 공간을 표현할 수

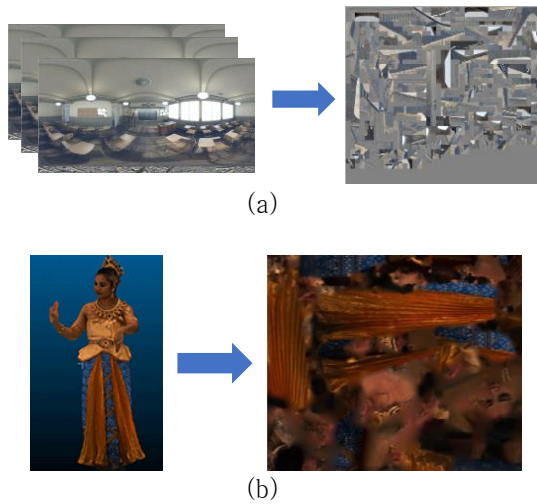


그림 1. 비활성 영역이 존재하는 영상: (a) TMIV 영상 (b) PCC 영상

있는 효율적인 방법 중 하나이며 이것으로 구성된 영상 역시 방대한 양의 정보를 가지고 있다. 이를 압축하기 위해 MPEG에서는 Point Cloud Compression (PCC)를 제공한다 [3].

TMIV를 통한 다시점의 360영상들과 그에 대응하는 깊이영상들의 압축 과정에는 각 영상들 간의 중복성을 제거한 후 남은 영상들을 패치단위로 분할해 아틀라스에 재배치하는 과정이 존재한다. 이 때 분할된 패치들은 일정한 크기의 블록 단위로 배치되며 각 패치들의 크기는 모두 다르기 때문에 각 패치들 사이에는 빈 공간이 존재할 수 있다. 이러한 빈 공간들은 유효하지 않은 임의의 값들로 채워지게 되며 TMIV에서는 이를 방지하기 위해 더욱 세밀한 블록 분할을 유도한다.

PCC는 3D 공간에 위치한 Point Cloud 영상을 2D 공간으로 사영한 후 압축하는 방식을 사용한다. 또한 압축 효율을 위해 PCC에서는 2D 공간으로 재구성된 영상을 분할해 여러 크기의 패치들로 재구성된 영상을 만들어 압축에 사용한다. 이 때, 각 패치 사이에 빈 공간이 존재하며 PCC에서는 이를 다해상도 Gauss-Seidel 완화 기반 최적화기법을 사용해 채운다 [4].

이러한 유효하지 않은 화소들의 영역인 비활성 영역은 유효한 화소 값들로 이루어진 활성 영역과의 경계에서 급격한 차이를 보이며, 압축 성능을 크게 저하시킨다. TMIV와 PCC에서는 이를 방지하기 위해 위에서 언급한 기법들을 사용하고 있지만 모델 기반 방식이다. 본 논문에서는 강화학습을 통해 영상의 특성을 고려한 화소 값들을 생성해 비활성 영역을 채워 압축 성능을 향상시키는 기법을 제안한다.

2. 제안 알고리즘

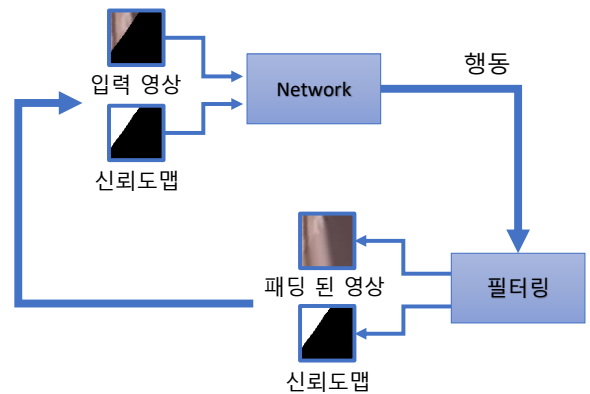


그림 2. 제안 기법 구성도

일반적으로 비활성 영역은 활성 영역과 이루는 급격한 경계에 의해 압축효율을 감소시킨다. 이 문제를 해결하기 위해서는 TMIV에서 사용한 기법인 세밀한 분할과정을 통해 비활성 영역의 크기 자체를 줄이는 방식과 같이 압축 과정에서 해결하는 방식이 있고, PCC에서 사용한 기법인 생성된 비활성 영역을 주변 값들을 통해 채우는 방식과 같이 후처리 기술로 해결하는 방식이 있다. 제안 기법에서는 해당 기법을 보다 자유롭고 범용적으로 적용할 수 있도록 후처리 방식을 사용한다. 또한 비활성 영역은 그에 대응하는 정답이 존재하지 않기 때문에 지도학습을 사용할 수 없다. 반면에 High Efficiency Video Coding (HEVC), Versatile Video Coding (VVC)와 같은 여러 압축 기술들을 사용하여 생성된 영상의 성능을 평가할 수는 있다 [5-6]. 따라서 제안 기법은 보상을 통해 학습하는 강화학습을 사용해 비활성 영역을 예측한다.

HEVC, VVC와 같은 압축 기술들은 효율적인 압축을 위해 그 과정이 블록 단위로 이루어진다. 이를 고려하여 제안 기법은 블록 단위로 비활성 영역 채우기를 진행한다. 또한 비활성 영역에는 유효한 값이 존재하지 않기 때문에 활성 영역의 값을 사용해 비활성 영역의 값을 생성하는 방식을 사용한다. 이 때, 강화학습을 통해 화소 값 전체를 예측하면 action 공간이 너무 커져 좋은 결과를 얻을 수 없다. 따라서 제안 기법은 계산 복잡도를 낮추기 위해 제어 점 기반 방식을 사용한다. 제어점이란 일정한 범위의 화소 값들을 대표하는 값이다. 예를 들어 128x128 크기의 영상이 존재할 때 하나의 제어점이 8x8 공간을 대표하도록 설정한다면 이 영상은 16x16 크기의 제어점들로 나타낼 수 있다. 이러한 제어점들은 계산 복잡도를 낮출 수 있으며 영상의 전반적인 정보를 가지고 있다. 또한 제어점들은 원본 영상보다 작기 때문에 이를 다시 영상 공간으로 변환하는

과정이 필요하다. 제안 기법에서는 제어점을 영상을 변환할 때, 영상 공간에서 활성 영역의 값과 제어점의 값을 비활성 영역으로 전파하는 방식을 사용한다. 이 때 효율적인 전파를 위해서 필터링 방식을 사용하며 일반적인 필터링 기법을 사용하면 유효하지 않은 비활성 영역의 값을 포함해 계산하기 때문에 신뢰도를 기반으로 원하는 값들만을 사용해 필터링할 수 있는 normalized convolution 기법을 사용한다 [7]. 또한 영상의 필터링을 통해 유효한 값들을 전파할 때 그 방향과 속도를 조절해 영상의 특성이 반영된 결과를 얻어 압축 성능을 높이기 위해 스티어링 필터 (Steering filter)를 사용한다 [8].

강화 학습을 통해서 제어점의 화소 값과 필터의 모양을 예측하기 위해서는 먼저 action을 정의해야 한다. 제어점의 화소 값과 스티어링 필터의 파라미터들은 action을 통해 한 번에 예측할 수 없는 범위의 값을 가진다. 따라서 일정한 크기의 오프셋 값을 통해 이를 조절하는 방식을 사용한다. 제안 기법에서는 해당 action을 사용해 영상을 반복적으로 개선한다. 여기서 각 단계의 출력 영상은 다음 단계의 입력 state로 사용되며 신뢰도 맵 역시 이에 포함된다. 보상의 경우 입력 영상과 출력 영상에 대한 압축을 진행한 후 얻을 수 있는 Rate-Distortion(R-D) cost의 차이를 사용한다 [9]. 강화학습을 위한 모델로는 A3C [10]를 사용하였다.

3. 실험

시스템을 학습하기 위해 MPEG에서 제공하는 데이터셋을 사용하였다. 360+ 영상의 경우 훈련 데이터셋으로 5개의 비디오에서 추출한 1900장의 영상을 사용했으며, 검증 데이터셋으로 3개의 비디오에서 추출한 1000장의 영상을 사용했다. PCC의 경우 3개의 비디오에서 추출한 1500장의 영상을 훈련에 사용했으며 검증 데이터셋으로 3개의 데이터셋에서 추출한 300장의 영상을 사용하였다. 필터링 반복 횟수의 경우 충분한 반복을 위해 30번 반복하였다.

제안 기법을 평가하기 위해 PCC의 경우 압축 과정에서 적용된 기술을 비교군으로 사용하였다. 3DOF+ 영상의 경우 압축 과정에서 별도의 후처리 과정이 없기 때문에 양방향 선형 보간법을 사용한 결과를 비교군으로 사용하였다. 표 1, 2는 채우기 기법이 적용되지 않은 원본 영상들 과의 Bjøntegaard delta bit-rate (BDBR) [11]을 측정된 결과를 보여주며, 제안하는 기법을 통해 성능 향상을 얻을 수 있음을 알 수 있다. 여기서 3DOF+의 경우 성능 향상의 정도가 낮은 것을 확인할 수 있는데, 이는 TMIV에서 세밀한 블록 분할 기법을 통해 비활성 영역의 크기를 줄이는 방식을 사용했기 때문에 강화학습을 통해 성능을 개선할

표 1. Point Cloud 데이터셋 BDBR 성능 비교

실험영상	기존 방식	제안 방식
	BDBR	
Boxer	-5.7%	-10.0%
Longdress	-5.8%	-10.0%
Loot	-5.2%	-9.6%
Average	-5.6%	-9.9%

표 2. 3DOF+ 데이터셋 BDBR 성능 비교

실험영상	기존 방식	제안 방식
	BDBR	
InterdigitalHijack	-1.2%	-1.5%
IntelFrog	-1.0%	-1.1%
PoznanFencing	-1.2%	-1.5%
Average	-1.1%	-1.3%

비활성 영역의 양이 전체 영상에 비해서 작기 때문이다.

그림 3과 4는 제안 기법이 적용된 영상을 보여준다. 해당 영상의 비활성 영역에 채워진 값들을 보면 기존 활성 영역의 특성이 반영된 것을 확인할 수 있다. 이는 제안 필터링 기법이 영상의 특성을 효율적으로 전파할 수 있음을 보여준다.

4. 결론

본 논문에서는 강화학습을 통해 비활성 영역을 채우는 기법에 대해서 제안하였다. 제안하는 방법은 블록 단위로 적용되며 각각의 블록에서 제어점 기반 필터링 방식을 사용해 활성 영역의 값을 비활성 영역으로 전파한다. 또한 스티어링 필터와 normalized convolution을 이용해 필터링 과정에서 효율적으로 전파 방향과 속도를 제어하였다. 실험 결과를 통해 제안하는 기법이 기존 기법에 비해 좋은 성능을 보임을 확인할 수 있다. 추후 연구에서는 압축 과정에서 사용되는 기술들을 고려하는 등 제안 법의 한계를 극복하는 방향으로 연구를 진행할 예정이다.




그림 3. 제안 기술이 적용된 PCC 영상의 예: (a) 기존 기법 (b) 제안 기법




그림 4. 제안 기술이 적용된 TMIV 영상의 예: (a) 기존 기법 (b) 제안 기법

[2] B. Salahieh, B. Kroon, J. Jung, M. Domański (Eds.), "Test model 2 for Immersive Video," ISO/IEC JTC1/SC29/WG11, N18577, July 2019.

[3] Cui, Li, et al. "Point-cloud compression: Moving picture experts group's new standard in 2020." IEEE Consumer Electronics Magazine 8.4 (2019): 17-21.

[4] Graziosi, D., et al. "An overview of ongoing point cloud compression standardization activities: video-based (V-PCC) and geometry-based (G-PCC)." APSIPA Transactions on Signal and Information Processing 9 (2020).

[5] High Efficiency Video Coding, Standard ISO/IEC 23008-2, ISO/IEC JTC 1, Apr. 2013.

[6] Versatile Video Coding, Standard ISO/IEC 23090-3, ISO/IEC JTC 1, Jul. 2020.

[7] Eldesokey, Abdelrahman, Michael Felsberg, and Fahad Shahbaz Khan. "Confidence propagation through cnns for guided sparse depth regression." IEEE transactions on pattern analysis and machine intelligence 42.10: 2423-2436, 2019.

[8] Takeda, Hiroyuki, Sina Farsiu, and Peyman Milanfar. "Kernel regression for image processing and reconstruction." IEEE Transactions on image processing 16.2: 349-366, 2007

[9] Sullivan, Gary J., and Thomas Wiegand. "Rate-distortion optimization for video compression." IEEE signal processing magazine 15.6 (1998): 74-90

[10] Mnih, Volodymyr, et al. "Asynchronous methods for deep reinforcement learning." International conference on machine learning. PMLR, 2016

[11] Bjøntegaard, G. "Calculation of average PSNR differences between RD-curves." VCEG-M33, 2001

감사의 글

본 연구는 2020 년도 정부(교육부)의 재원으로 한국연구재단 기초연구사업(NRF-2019R1F1A1063229)과 경기도 지역협력 연구센터 사업 (GRR) (2017-B02, 3 차원 공간 데이터 처리 및 응용기술 연구)의 지원을 받아 수행되었음.

참조문헌

[1] Y. Ye, E. Alshina, and J. Boyce, "Algorithm descriptions of projection format conversion and video quality metrics in 360Lib (Version 5)," Joint Video Exploration Team of ITU-T SG16 WP3 and ISO/IEC JTC1/SC29/WG11, JVET-H1004, Oct. 2017.