

일반논문 (Regular Paper)

방송공학회논문지 제26권 제5호, 2021년 9월 (JBE Vol.26, No.5, September 2021)

<https://doi.org/10.5909/JBE.2021.26.5.599>

ISSN 2287-9137 (Online) ISSN 1226-7953 (Print)

강화학습 기반 비활성 영역 패딩 기술

김 동 신^{a)}, 우딘 쿠틀^{a)}, 오 병 태^{a)†}

Reinforcement Learning based Inactive Region Padding Method

Dongsin Kim^{a)}, Kutub Uddin^{a)}, and Byung Tae Oh^{a)†}

요 약

비활성 영역이란 특정 영상을 표현하기 위해 유효하지 않은 화소 값으로 채워지는 영역을 의미한다. 일반적으로 원본 영상의 형태가 사각형 형태가 아닌 경우 이를 사각형 형태로 변환하는 과정에서 주로 발생하며, 특히 3D 영상을 2D로 표현할 때 자주 발생한다. 이러한 비활성 영역은 압축 효율을 크게 저하시키기 때문에, 활성 영역과 비활성 영역의 경계 부분에 필터링 기술 등을 적용해 해결해 왔다. 하지만 일반적인 필터링 적용 기술은 영상의 특성을 적절하게 반영하지 못할 가능성이 크다. 제안하는 기법에서는 영상의 특성과 압축 과정을 고려한 강화학습을 통한 패딩을 진행하였다. 실험결과 제안한 기법이 기존 기법보다 평균 3.4% 성능이 향상됨을 확인할 수 있다.

Abstract

Inactive region means a region filled with invalid pixel values to represent a specific image. Generally, inactive regions are occurred when the non-rectangular formatted images are converted to the rectangular shaped image, especially when 3D images are represented in 2D format. Because these inactive regions highly degrade the compression efficiency, filtering approaches are often applied to the boundaries between active and inactive regions. However, the image characteristics are not carefully considered during filtering. In the proposed method, inactive regions are padded through reinforcement learning that can consider the compression process and the image characteristics. Experimental results show that the proposed method performs an average of 3.4% better than the conventional padding method.

Keyword: Inactive region padding, Reinforcement learning, Deep learning, Immersive video

a) 한국항공대학교 항공전자정보공학부(Korea Aerospace University)

† Corresponding Author : 오병태(Byung Tae Oh)

E-mail: byungoh@kau.ac.kr

Tel: +82-2-300-0409

ORCID: <https://orcid.org/0000-0003-1437-2422>

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

※ This research was supported in part by the Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Education (NRF-2019R1F1A1063229), and by the GRRC program of Gyeonggi Province [2020-B02, Study on Study on 3D point cloud processing and application technology].

· Manuscript received September 14, 2021; Revised October 26, 2021; Accepted October 26, 2021.

1. 서론

3D 산업이 발전함에 따라 고해상도 영상에 더불어 3D 영상, 그리고 더 나아가 몰입형 영상에 관한 관심이 꾸준히 증가하고 있다. 몰입형 영상은 여러 시점의 영상들을 동시에 제공할 수 있는 영상이며 대표적으로 360 영상, 3DOF+ 영상 등이 있다. 이러한 영상을 제공하기 위해서는 기존 2D 영상과 다른 표현법이 필요하다. Joint Video Exploration Team (JVET)에서 제공하는 360 라이브러리에는 3D 영상을 2D 영상으로 표현하기 위한 다양한 방법이 있으며, 각 포맷 간의 변환 역시 제공한다^[1]. Moving Picture Experts Group (MPEG)에서 제공하는 Test Model for Immersive Video (TMIV)는 여러 시점의 360영상을 한 번에 압축할 수 있는 3DOF+ 기술을 제공한다^[2].

이러한 소프트웨어를 통해 3D 영상을 처리하게 되면 그 과정에서 비활성 영역이 생성된다. 비활성 영역이란 영상 형태를 유지하기 위해 유효하지 않은 화소 값으로 채워지는 영역을 의미한다. 예를 들어 360 라이브러리에서는 그림 1(a) 와 같이 3D 영상을 구 형태의 영상으로 간주하고 이를 6개의 영역으로 분리해 투영시켜 2D 영상 6개를 만드는 Sphere Segmented Projection (SSP)라는 투영 방식이 존재한다. 여기서 구의 상단과 하단의 경우 투영 면이 원 형태이

며, 이를 저장하기 위해 사각형 형태의 영상으로 표현했을 때, 그림 1(b)의 0번과 1번 같이 사각형의 꼭짓점 근처에 유효하지 않은 화소가 존재하게 된다.

또한, 몰입형 영상을 제공하기 위한 소프트웨어인 TMIV 는 여러 시점의 360 영상을 압축하는 기술을 제공한다. 이때 압축 과정에서 더욱 효율적인 압축을 위해 여러 시점의 영상 중 대표 영상을 선택한다. 그리고 이 영상을 기준으로 다른 시점의 영상에 대해서 중복되는 부분을 제거하고 중복되지 않는 부분만 잘라내 저장하는 과정이 존재한다. 이때, 중복되지 않는 부분은 패치 단위로 분할되어 패치 크기로 저장된다. 이때 작은 크기의 패치가 큰 크기의 패치 내부에 들어갈 수 있는 공간이 존재한다면 두 패치는 합쳐지게 된다. 따라서 그림 1(c) 와 같이 분할된 패치들이 모두 저장된 영상은 임의의 형태를 가지고 있다. 이러한 과정은 모든 패치를 정확하게 이어 붙일 수 없으므로 일부 영역은 빈 공간이 되며, 유효하지 않은 화소 값으로 채워지게 된다.

이러한 유효하지 않은 화소들로 이루어진 비활성 영역은 전부 하나의 값을 가지기 때문에 압축 과정에서 거의 영향을 끼치지 않는다. 하지만 블록 단위 압축 과정을 고려한다면 유효한 화소들과 유효하지 않은 화소들의 경계 부분에서 문제가 생긴다. 한 블록 내에 유효한 화소들과 유효하지 않은 화소들이 동시에 존재한다면 압축 과정에서의 에러는

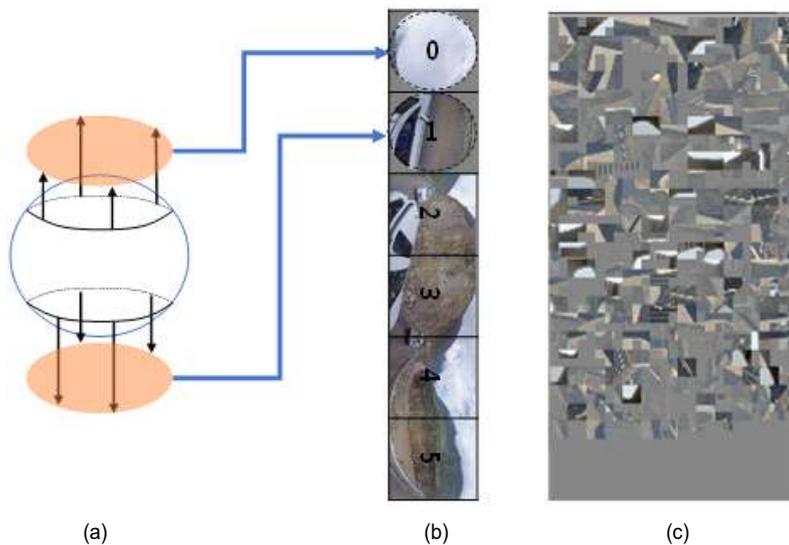


그림 1. 비활성 영역의 예시
Fig. 1. Example of inactive region

유효한 화소들의 값을 변화시킨다. 또한, 급격한 화소 값들의 경계는 압축 과정에서 더욱 세밀하게 분할된 블록의 사용을 유도한다. 따라서 비활성 영역은 압축 성능을 저하의 원인이 된다. 본 논문에서는 이러한 문제점들을 해결하기 위해 강화학습을 통해서 비활성 영역 패딩을 진행하며 이를 통해 압축 성능을 향상시킬 수 있는 기법을 제안한다.

II. 기존 방식

1. 기존 방식의 한계

비활성 영역을 패딩 하기 위해 360 라이브러리에서는 원 중심에서 나가는 방향으로 일정 거리만큼 패딩을 진행하였다^[3]. 이때 활성 영역의 가장자리에 위치하는 화소 값과 비활성 영역의 화소 값 사이를 선형적으로 보간하여 패딩 영역의 화소 값을 생성했다. 이러한 방법은 압축 과정에서 활성 영역의 화소 값이 비활성 영역의 화소 값에 의해 변형되는 것을 쉽게 방지할 수 있다. 하지만 인위적인 경계면의 발생으로 인해 비트량 관점에서 손해를 보게 된다. 또 다른 방법으로는 원 형태의 영상을 표현할 때, 화소의 위치를 반올림하기 때문에 생성되는 오차를 줄이기 위한 방법이다^[4]. 이 방법은 원의 가장자리 부분을 16x16 블록 단위로 분할해 실제 원의 경계면에 더 가깝게 표현하였다. 이 방법의 경우 실제 원의 정보를 더 많이 가지고 있으면서 블록 단위의 경계면을 가지고 있기 때문에 압축 과정에서 큰 손해를 보지 않지만 정해진 형태를 가지기 때문에 그 한계가 명확하다.

2. 강화학습 기반 비활성 영역 패딩

기존 필터링 방식의 한계를 극복하기 위한 효과적인 방법으로서 학습 기반 방식을 생각할 수 있다. 현재 널리 사용되고 있는 깊은 신경망을 통한 패딩은 이를 해결할 수 있는 효과적인 방법이다. 하지만 최적의 비활성 영역 화소 값을 알 수 없는 정보이기 때문에 정답이 필요한 지도학습을 통해서 이를 학습하기는 어렵다. 반면에 코덱을 통해 예측된 비활성 영역에 대한 평가는 가능하기 때문에 입력-정답이 아닌 상태-행동-보상이 필요한 강화학습은 이를 학습할 수

있다. 따라서 비활성 영역 패딩을 위해 강화학습을 사용했으며 그 방식은 아래에서 소개한다.

III. 제안 방식

1. 블록 기반 비활성 영역 패딩

High Efficiency Video Coding (HEVC), Versatile Video Coding (VVC)와 같은 표준 코덱들은 모두 블록 기반 압축 방식을 사용한다^[5]. 한 블록 내부에서는 예측된 신호와 원본 신호의 잔차 신호를 구해 이를 압축하고, 압축 과정에서는 다양한 경우에 대한 Rate-distortion (RD) 비용함수를 측정하여 최적의 결과를 선택하여 사용한다. 따라서 블록 내부에 존재하는 경계면은 예측을 어렵게 하고 이는 압축 성능 하락의 원인이 되기 때문에 그 근처에서 더욱 세밀한 블록 분할을 유도한다. 이를 고려하여 본 논문에서는 Coding Tree Unit (CTU) 기반 패딩을 진행한다.

전체 영상을 64x64 블록 단위로 분할한 후 그림 2(a)와 같이 활성 영역과 비활성 영역이 동시에 존재하는 블록에 대하여 패딩을 진행한다. 이때 강화학습을 통해서 비활성 영역의 화소 값을 예측한다. 예측된 비활성 영역은 압축 과정에서 예측 신호를 쉽게 구할 수 있도록 학습되며 이는 보다 큰 블록의 사용을 유도한다. 따라서 블록 기반 비활성 영역 패딩을 통해 화소 값과 비트량 관점에서 모두 이득을 볼 수 있다.

2. 제어점 기반 비활성 영역 패딩

블록 내부에 존재하는 비활성 영역의 화소 값을 강화학습을 통해 예측할 때 모든 위치의 화소 값을 전부 예측하는 것은 굉장히 큰 복잡도를 요구한다. 따라서 이를 완화하기 위해 제어점 기반 예측을 진행한다. 제어점이란 그림 2(b)와 같이 전체 화소 값 중 일부분을 대표하는 화소 값을 선정해 사용하는 것이다. 실험에서는 그림 2(b)와 같이 64x64블록을 작은 서브 블록 단위로 분할한 후 각 서브 블록을 대표하는 값을 제어점으로 사용하였다. 그림 2(c)에서는 생성된 제어점을 시각적으로 보여주며, 제어점을 사용하면 서브

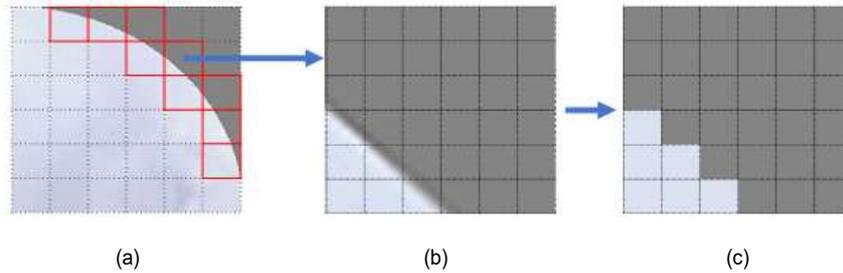


그림 2. 블록 기반 패딩 방법 예시
 Fig. 2. Example of block-based padding method

블록에 대해서 하나의 화소 값을 예측만이 필요하기 때문에 계산 복잡도를 줄일 수 있다. 이때, 제어점은 일정 크기의 블록을 대표하는 값이므로 이를 다시 여러 개의 화소 값으로 변환하는 과정이 필요하다. 해당 변환 과정은 양방향 보간법을 사용하는 등 여러 가지 방법을 사용할 수 있으며, 제안 기법에서는 필터링 기반 변환 기법을 사용하였다. 이렇게 제어점을 사용해 예측을 진행하고 다시 영상으로 변환하는 과정은 계산 복잡도를 줄일 수 있을 뿐만 아니라 한 블록 내부의 화소 값들이 저주파를 가질 수 있도록 해 압축 과정에서 이득을 볼 수 있도록 한다. 본 제안 방식에서는 8x8 크기의 서브 블록을 사용하였다.

3. 필터링 기반 변환 과정

제어점을 다시 영상으로 변환할 때 여러 가지 방법이 사용될 수 있다. 가장 간단한 방법으로는 양방향 선형 보간법이 있다. 이 방법의 경우 계산 복잡도가 낮아 빠르게 계산할

수 있지만, 그 방식이 고정되기 때문에 변환 과정에서 얻을 수 있는 이점을 얻지 못한다. 따라서 변환 과정에서도 이득을 볼 수 있는 방법이 필요하다.

변환 과정에서 이득을 볼 수 있는 방법들 중 한 가지는 Generative Adversarial Network (GAN)를 사용하여 변환하는 것이다^[7]. GAN을 사용한다면 영상 공간에서 음성특성하게 위치한 제어점으로부터 다양한 패턴의 영상을 생성할 수 있다. 하지만 강화학습을 통해 이를 학습하려면 문제가 존재한다. 강화학습은 상태-행동-보상 관계가 명확해야 학습이 가능하다. 따라서 GAN을 강화학습을 통해 학습하기 위해서는 출력 영상의 모든 화소 위치에 대해서 보상이 주어져야 한다. 하지만 일반적으로 전체 영상에 대해 한 개의 RD 값만을 얻을 수 있기 때문에 이를 실제로 학습하기는 어렵다. 따라서 본 논문에서는 제어점을 영상 공간으로 변환할 때 이득을 얻기 위해 필터링 기반 변환 방식을 선택했다.

필터링 기반 변환 방식은 그림 3과 같이 각 제어점을 영

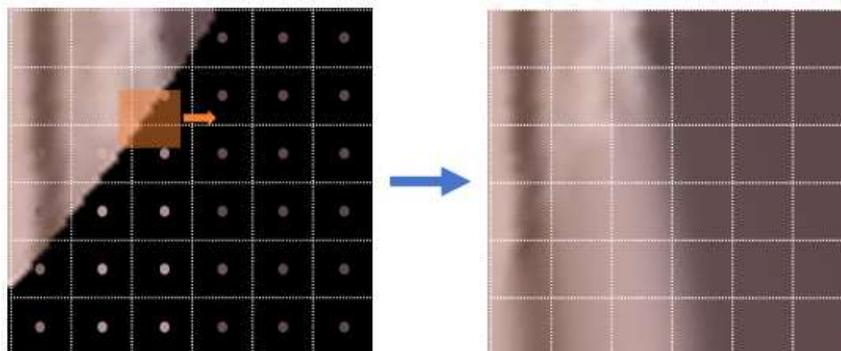


그림 3. 필터링을 통해 제어점을 영상으로 변환하는 과정
 Fig. 3. Image filtering for image completion

상 공간에 위치시킨 후 필터링을 통해서 제어점의 화소 값을 퍼뜨려 전체 영상을 구성하는 방식이다. 필터링 방식은 효율적인 압축이 가능하도록 하는 패턴들을 자체적으로 생성해 낼 수 없다. 하지만 이미 존재하는 활성 영역의 값들을 전과해 각 영상에 맞는 패턴들을 적응적으로 생성해 낼 수 있다. 이러한 적응적인 패턴은 영상의 연속성과 압축 과정을 고려했을 때 충분히 좋은 성능을 낼 수 있다. 따라서 필터링 기반 변환 방식은 제어점을 영상 공간으로 변환할 때 필터의 형태에 따라 전과 방향, 속도 등을 조절해 영상에 적응적인 패턴을 생성할 수 있다. 이를 강화학습을 통해 구현하기 위해서는 몇 가지 문제점을 해결해야 한다.

첫 번째 문제점은 일반적인 필터링을 사용하면 비활성 영역의 화소 값을 적절히 채울 때까지 수많은 반복이 필요하다는 점이다. 필터링의 반복횟수가 많아질수록 그 결과는 평균에 가까워지며 이는 결국 선형 보간법과 비슷한 결과를 끌어낸다. 이를 해결하기 위해서 **Normalized Convolution (N-Conv)** 방식을 사용한다^[8]. N-Conv은 신뢰도에 따라서 특정 화소 값들만을 사용해 필터링을 진행할 수 있게 한다. 따라서 N-Conv을 사용한 필터링은 활성 영역의 화소 값들만을 사용한 전과를 가능하게 하며, 매 반복마다 정규화를 통해 필터링에 사용한 화소 값들을 유지시킴으로써 전과 속도를 빠르게 한다.

두 번째 문제점은 강화학습을 통한 필터 예측의 어려움이다. 필터의 각 계수는 연속적인 값을 갖기 때문에 강화학습의 행동을 정의하기 어렵다. 일반적으로 강화학습에서는 이를 해결하기 위해 일정 범위의 불연속적인 오프셋 값을 행동으로 사용하며 이를 통해 연속 공간을 간접적으로 표현한다. 하지만 필터 계수의 범위는 너무 방대하므로 실제로 이를 학습하기는 어렵다. 따라서 다 변량 가우시안 필터의 변수들을 독립적으로 만든 필터인 스티어링 커널 (steering kernel)을 사용한다^[9]. 이러한 방식을 사용할 경우 필터의 계수들은 각 변수를 통해서 결정되고 각 변수는 불연속적인 오프셋 값을 통해서 조절할 수 있다. 아래 수식 1은 스티어링 커널을 결정하기 위한 식을 보여주며 변수 $w(i, j, k, l)$ 은 영상의 (i, j) 위치에 존재하는 커널의 (k, l) 위치에 해당하는 값을 의미한다. 또한, 변수 $X_{(i, j)}$ 와 $X_{(k, l)}$ 은 좌푯값이다. 그리고 변수 γ 는 회전 (rotation), θ 는 스케일 (scaling), σ 는 축의 늘어짐 (elongation)을 담당한다. h

는 전역 평활화 계수이고 μ 는 데이터들의 지역적인 밀도를 결정하며, 사전에 정해진 값을 사용한다. 이를 통해 다양한 형태의 필터를 예측할 수 있으며, 다양한 형태의 필터 예측은 곧 학습을 통해 전과 방향을 결정할 수 있다는 것을 의미한다.

$$\begin{aligned}
 w(i, j, k, l) &= e^{-\frac{1}{2}(x_{(i, j)} - x_{(k, l)})^T H^{-2}(x_{(i, j)} - x_{(k, l)})} \\
 H &= h\mu C^{-\frac{1}{2}} \\
 C &= \gamma U \Lambda U^T \\
 U &= \begin{bmatrix} \cos\theta & \sin\theta \\ -\sin\theta & \cos\theta \end{bmatrix} \\
 \Lambda &= \begin{bmatrix} \sigma & 0 \\ 0 & \sigma^{-1} \end{bmatrix}
 \end{aligned} \tag{1}$$

마지막으로 블록 단위 압축 과정을 고려하면 주변 블록의 화소 값이 현재 블록의 압축률에 영향을 미친다는 것이다. 압축 과정에는 주변 블록의 정보를 사용하여 현재 블록을 예측하는 과정이 존재한다. 만약 현재 블록을 주변 블록들과 독립으로 가정하고 각각 패딩을 한다면 압축 과정에서 최적의 결과를 얻기는 힘들 것이다. 따라서 현재 블록을 처리하는 과정에서 주변 블록을 고려하기 위해 블록 단위 필터링을 진행한다. 블록 단위 필터링이란 양방향 선형 필터링과 비슷하게 을 통해 필터의 모양이 결정된다. 하지만 양방향 선형 필터링과 달리 블록 단위로 동일한 변숫값을 가진다. 따라서 필터링을 진행할 때 블록 간의 경계에서 주변 블록의 값을 변수를 통해 적응적으로 가져올 수 있다. 이를 통해 현재 블록을 처리할 때 주변 블록의 정보를 사용하는 것을 의미한다. 따라서 압축 과정에서 더 많은 이득을 얻을 수 있다.

4. 네트워크 구조도

강화학습을 통해 제어점 기반 블록 단위 스티어링 필터링 방식을 학습하기 위해서는 우선 상태-행동-보상 쌍이 정의되어야 한다. 상태의 경우 현재 블록의 정보를 그대로 포함하고 있는 현재 블록과 각 화소 값들의 신뢰도를 나타내는 신뢰도맵으로 구성된다. 신뢰도 맵의 경우 활성 영역과 비활성 영역을 구분한 이진 영상을 시작 영상으로 하며 각

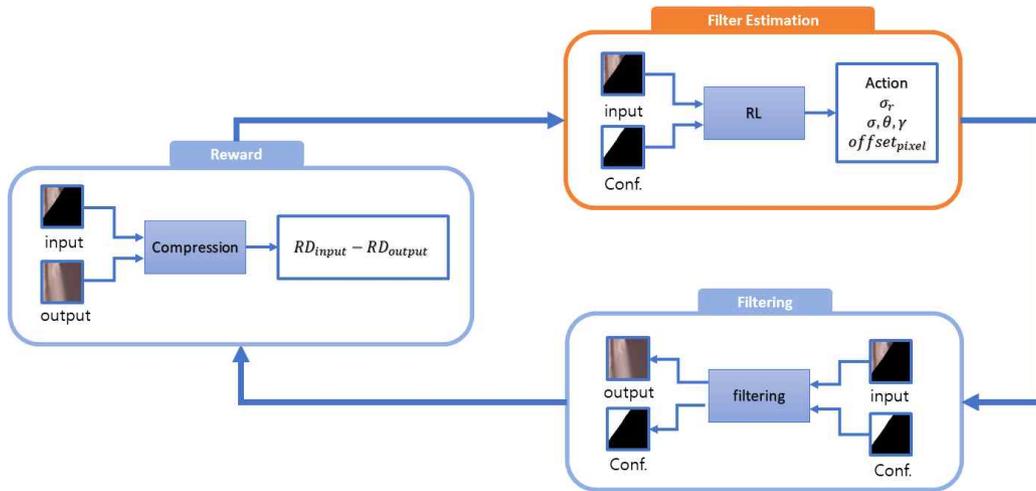


그림 4. 전체 시스템 구조도
Fig. 4. Overall system structure

표 1. 비활성 영역 패딩을 위한 행동
Table 1. Actions for inactive region padding

Action	offset				
γ	50%	83%	100%	120%	200%
σ_{rn}	67%	91%	100%	110%	150%
θ	-45	-15	0	15	45
pixel offset	-10	-2	0	2	10

반복에서 N-Conv이 적용될 때 갱신된다. 행동의 경우 제어점의 값 조절, 스티어링 커널의 변숫값 조절, 블록 단위 필터링을 위한 변숫값 조절을 위한 오프셋 값으로 한다. 표 1은 네트워크에서 사용한 행동들을 보여준다. 행동이 결정된 후에는 해당 행동을 수행한다. 먼저 제어점에 대한 오프셋 값을 더해 새로운 제어점을 생성하고 필터 생성을 위한 변수들을 행동에 따라 갱신한다. 그 후 해당 제어점을 활성 영역이 존재하는 영상의 특정 위치에 위치시킨다. 그 후 각 위치에서 변수들에 따른 필터를 생성해 N-Conv을 사용해 필터링한다. 마지막으로 보상의 경우 각 반복마다 계산하며, 입력 영상과 필터링 후 영상을 각각 압축하여 나오는 RD를 사용한다. 이때 각 반복마다 좋아지는 정도를 보상으로 하기 위해 해당 RD 값의 차이를 보상으로 사용한다. 그림 4는 이 과정을 시각적으로 보여준다.

IV. 실험결과 및 분석

1. 실험 세부사항

제안하는 방법을 구현하기 위해 A2C 모델을 사용하였다^[10]. 또한, 필터 반복의 경우 충분한 반복을 통해 완전한 결과물을 얻기 위해 총 30번 반복하였다. 학습 데이터의 경우 Youtube에서 제공하는 4K 영상 20개를 사용하였으며, 각 영상에서 10프레임당 한 장씩 총 20장을 추출해 사용하였다. 테스트의 경우 MPEG에서 제공하는 4K 영상 2개, 6K 영상 2개, 8K 영상 2개를 사용하였다.

2. 정량적 비교

제안 기술을 평가하기 위해서 JVET에서 제공하는 360 라이브러리의 패딩 기법이 적용된 영상들과 각 지표별로 비교를 진행하였다. 위에서 언급한 데이터셋을 해상도 별로 평가를 진행하였다. 강화학습을 통한 비활성 영역 패딩 기법만의 성능을 측정하기 위해 강화학습이 적용된 CTU들만 사용해 Bjontegaard delta bit-rate (BDBR)을 계산하였으며 표 2에서 BDBR이라 표기된 부분이 이에 해당한다^[11]. 또한 Spherical PSNR (S-PSNR)는 2D 영상을 다시 구로 투영한 후 오차를 계산하는 방식이며 Weighted Spherical

표 2. 객관적 지표들을 통한 정량적 품질 비교
 Table 2. Quantitative performance comparisons

Dataset	BDBR	Codec		End-to-End	
		WS-PSNR	S-PSNR	WS-PSNR	S-PSNR
4K					
DrivingCity	-11.04%	-1.44%	-1.33%	-3.25%	-3.18%
DrivinInCountry	-8.75%	-1.14%	-1.05%	-2.59%	-2.51%
PoleVault	-8.37%	-1.09%	-1.02%	-2.47%	-2.41%
AerialCity	-9.89%	-1.29%	-1.19%	-2.93%	-2.84%
6K					
Balboa	-8.48%	-1.00%	-0.92%	-2.26%	-2.19%
Landing	-10.01%	-1.50%	-1.39%	-3.42%	-3.31%
8K					
Harbor	-9.08%	-0.97%	-0.91%	-2.21%	-2.15%
Trolley	-9.33%	-1.10%	-1.02%	-2.51%	-2.43%
Average	-9.37%	-1.19%	-1.10%	-2.70%	-2.63%

PSNR (WS-PSNR)은 해당 방식에 더불어 구의 위치를 기준으로 가중치를 두어 오차를 계산하는 방식이다^[12-13]. 두 방식 모두 전체 영상에 관한 결과이다. 또한, Codec의 경우 SSP 형식에서만 측정된 결과이고 End-to-End의 경우 ERP 형식에서부터 오차를 계산한 결과이다. 표 2를 보면 강화학습이 적용된 블록에 대해서 측정된 결과인 BDBR 지표의

성능이 기존보다 좋은 것을 볼 수 있다. 이는 각 CTU들을 독립적으로 보았을 때 제안 기법을 통한 비활성 영역 패딩 기술이 좋은 성능을 내는 것을 의미한다. 또한, 압축 과정 중에는 더 높은 압축 효율을 위해 현재 CTU를 주변 CTU 정보를 사용해 예측하는 것과 같이 주변 정보를 사용하는 과정이 존재한다. BDBR 지표를 제외한 나머지 지표들은

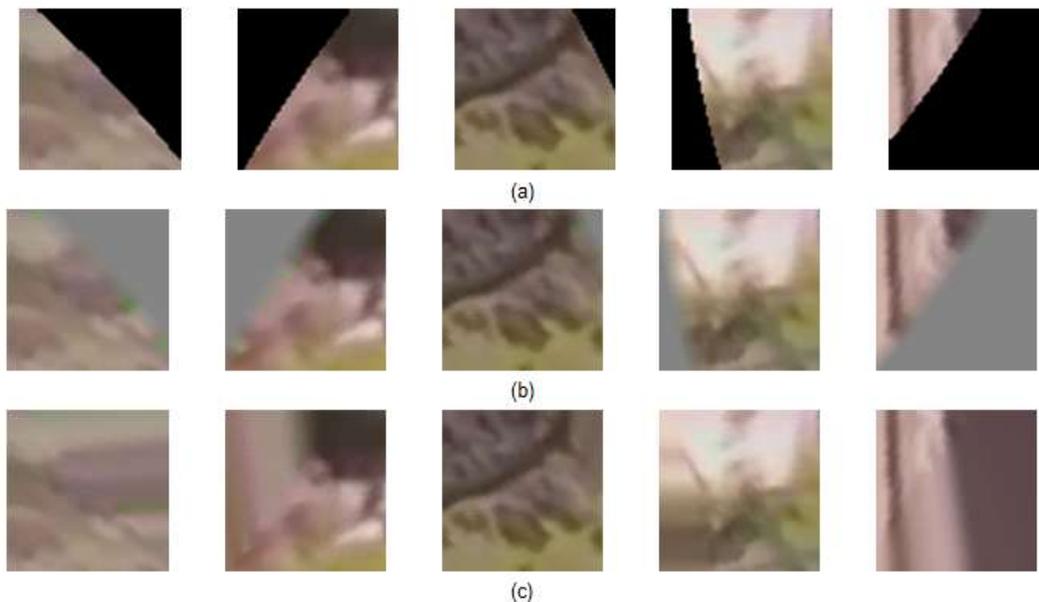


그림 5. 패딩 된 블록의 시각적인 비교 : (a) 입력 블록, (b) 기존 방법으로 패딩 된 블록, (c) 제안 방법으로 패딩 된 블록
 Fig. 5. Visual comparisons for padded blocks : (a) input blocks, (b) traditional padded blocks, (c) proposed padded blocks

이러한 과정이 모두 반영된 지표들이며, 해당 부분 역시 제안 기법이 기존에 비해 좋은 성능을 내는 것을 확인할 수 있다. 이는 제안 기법이 예측을 용이하게 하여 압축률을 향상시켰으며, 활성 영역의 화소 값들을 잘 보존하여 2D영상에서 다시 3D 영상으로 변환했을 때 생기는 에러 역시 많이 줄어들었음을 의미한다.

3. 정성적 비교

제안 기술의 시각적 비교를 위해서 그림 5와 같이 비교를 진행하였다. 몇 개의 데이터셋에서 영상을 뽑아 각 블록을 확대해 비교하였으며, 대부분은 제안 기술이 영상의 특성을 반영한 패딩을 진행해 기존 패딩 기술에 비해 좋은 성능을 냄을 확인할 수 있다. 예를 들어 그림 5(b)와 같은 기존 패딩 방식은 블록 단위 압축 과정을 고려한다면 활성 영역과 비활성 영역 경계에서 더욱 세밀한 블록의 사용을 유도하며, 이는 압축 효율을 저하시킨다. 반면에 그림 5(c)의 가장 오른쪽 영상의 경우 기존 블록에 존재하는 패턴의 방향이 비활성 영역에서도 그대로 유지되는 것을 볼 수 있다. 이러한 경우 전체 영상의 일정 부분 이상이 같은 패턴을 가지고 있으며, 이는 압축 과정에서 보다 큰 블록의 사용을 유도해 압축 효율을 향상시킬 수 있다. 다른 영상들 역시 마찬가지로 활성 영역의 특성을 반영함과 동시에 예측을 보다 쉽게 할 수 있도록 비활성 영역의 화소 값들이 예측된 것을 확인할 수 있다.

V. 결론

본 논문에서는 강화학습을 사용해 제어점 기반 블록 단위 필터링 기법을 사용해 비활성 영역을 패딩 하는 방법을 제안한다. 더욱 효율적인 예측을 위해 모든 화소에 대한 예측이 아닌 특정 범위를 대표하는 제어점을 사용하여 화소 값을 예측하였으며, 예측된 제어점을 다시 영상으로 변환하면서 이득을 얻기 위해 블록 단위 스티어링 필터링 기법을 사용하였다. 각 기법들은 몇 개의 변수들을 통해 조작이 가능하도록 설계되었으며, 필터링 과정에서 블록 단위 처

리를 함으로써 주변 블록들의 영향력을 조절해 압축 성능을 올릴 수 있었다. 성능 비교표를 보면 제안 기술이 기존 기술보다 우수한 성능을 보임을 알 수 있으며 시각적 결과 역시 제안 기술이 영상의 특성을 반영한 결과물을 생성한다는 것을 보여준다.

참 고 문 헌 (References)

- [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.
- [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] Y.-H. Lee, H.-C. Lin, J.-L. Lin, S.-K. Chang, C.-C. Ju, "EE4: ERP/EA P-based segmented sphere projection with different padding sizes," Joint Video Exploration Team of ITU-T SG16 WP3 and ISO/IEC JTC1/SC29/WG11, JVET-G0097, Jul. 2017.
- [4] A. Abbas, "AHG8: An Update on RSP Projection," Joint Video Exploration Team of ITU-T SG16 WP3 and ISO/IEC JTC1/SC29/WG11, JVET-H0056, Oct. 2017.
- [5] G. Sullivan, J. Ohm, W. Han, and T. Wiegand, "Overview of the High Efficiency Video Coding (HEVC) Standard," IEEE Transactions on Circuits and Systems for Video Technology, Vol.22, No.12, pp.1649-1668, December 2012.
- [6] J. Lee, J. Park, H. Choi, J. Byeon, and D. Sim, "Overview of VVC," Broadcasting and Media Magazine, Vol.24, No.4, pp.10-25, October 2019.
- [7] Goodfellow, Ian, et al. "Generative adversarial nets." Advances in neural information processing systems 27, 2014.
- [8] 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.
- [9] Takeda, Hiroyuki, Sina Farsiu, and Peyman Milanfar. "Kernel regression for image processing and reconstruction." IEEE Transactions on image processing 16.2: 349-366, 2007.
- [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.
- [12] M. Yu, H. Lakshman, and B. Girod, "A framework to evaluate omnidirectional video coding schemes," in IEEE International Symposium on Mixed and Augmented Reality, pp. 31 - 36, 2015.
- [13] Y. Sun, A. Lu, and L. Yu, "AHG8: WS-PSNR for 360 video objective quality evaluation," in Joint Video Exploration Team of ITU-T SG16 WP3 and ISO/IEC JTC1/SC29/WG11, JVET-D0040, Chengdu, 2016.

저 자 소 개



김 동 신

- 2020년 2월 : 한국항공대학교 전자및항공전자공학 학사
- 2020년 3월 ~ 현재 : 한국항공대학교 항공전자정보공학과 석사과정
- ORCID : <https://orcid.org/0000-0002-0301-3275>
- 주관심분야 : 영상처리, 비디오압축, 강화학습



Kutub Uddin

- 2017년 7월 : Univ. of Chittagong, Dept. of Computer Science and Engineering
- 2020년 8월 : 한국항공대학교 항공전자정보공학과 석사
- 2020년 9월 ~ 현재 : 한국항공대학교 항공전자정보공학과 박사과정
- ORCID : <https://orcid.org/0000-0003-4365-682X>
- 주관심분야 : 비디오 압축, 머신러닝, 영상 포렌식



오 병 태

- 2003년 8월 : 연세대학교 전기전자공학부 학사
- 2009년 8월 : Univ. of Southern California (USC), Dept. of Electrical Eng. 석사 및 박사
- 2009년 ~ 2013년 : 삼성종합기술원 전문연구원
- 2013년 ~ 현재 : 한국항공대학교 항공전자정보공학부 부교수
- ORCID : <http://orcid.org/0000-0003-1437-2422>
- 주관심분야 : 영상처리, 비디오압축, 영상 포렌식, 3차원영상