

CNN기반의 워터마킹 프로세서 설계 최적화 방법

강지원 · 이재은 · 서영호 · 김동욱*

광운대학교

CNN-based watermarking processor design optimization method

Ji-Won Kang · Jae-Eun Lee · Young-Ho Seo · Dong-Wook Kim*

Kwangwoon University

E-mail : jwkang@kw.ac.kr / jelee@kw.ac.kr / yhseo@kw.ac.kr / dwkim@kw.ac.kr

요 약

본 논문에서는 초 고해상도 디지털 이미지 및 비디오의 지적 재산권 보호를 위한 딥러닝 기술 기반 워터마킹 프로세서의 하드웨어 구조를 제안한다. 하드웨어에서 딥 러닝 기반 워터마킹 알고리즘을 구현하기 위한 최적화 방법론을 제안한다.

ABSTRACT

In this paper, we propose a hardware structure of a watermarking processor based on deep learning technology to protect the intellectual property rights of ultra-high resolution digital images and videos. We propose an optimization methodology to implement a deep learning-based watermarking algorithm in hardware.

키워드

watermarking, deep learning, accelerator, hardware optimization

I. 서 론

최근 영상 콘텐츠 수요의 증가로 영상 콘텐츠들의 지적재산권 문제가 발생하고 있다. 고부가가치의 콘텐츠인 영상 콘텐츠의 활성화를 위해서는 지적재산권 보호가 매우 중요하는데, 그 방법으로 디지털 워터마킹이 가장 활발하게 연구가 되고 있다 [1]. 기존에는 결정론적 알고리즘 기반의 워터마킹 방법이 많이 연구되어 왔지만, 최근에는 딥 러닝 기반의 워터마킹 방법에 대한 연구가 많이 진행되고 있다. 또한 이를 통하여 우수한 성능을 보이고 있다 [2,3]. 하지만 딥 러닝 연산은 연산량과 메모리 사용량이 매우 커 실시간 구현을 위해서는 하드웨어 가속기가 필수적이다.

따라서, 최근 개발한 딥 러닝 기반 워터마킹 [4]를 최적화하고 이를 하드웨어로 구현하고자 한다. 이를 위한 최적화 방법론을 제안하고 이로부터의 이득을 보인다.

II. 워터마킹 시스템

본 논문에서는 호스트 영상을 전 처리하는 전처리 네트워크, 삽입하는 삽입 네트워크 두 가지 네트워크에 대하여 설계를 진행한다. 호스트 영상의 전처리 네트워크는 호스트 영상을 보존하며 워터마크를 삽입하기 좋은 특징을 출력하고, 업 스케일링으로 인하여 호스트 영상과 해상도가 같아진 워터마크와 전처리 네트워크를 통하여 나온 호스트 영상을 이용하여 삽입 네트워크를 수행하여 워터마킹된 영상을 출력한다.

Table 1에 설계한 디지털 워터마킹 네트워크의 구조를 나타낸다. 일반적인 CNN의 구조를 가지며 컨볼루션 연산, 배치 정규화, 활성화 함수의 구성을 가진다.

III. 제안하는 최적화 방법

하드웨어 성능 향상을 위해 계산량과 메모리 접근 횟수를 최소화하기 위한 딥 러닝 최적화를

* corresponding author

Table 1. Network structure to be implemented

Network	Kernel size	number of kernels	stride	Batch Normalization	Activation function
Pre-processing Network	3×3	64	1	X	X
WM Embedding Network	3×3	64	1	○	ReLU
	3×3	64	1	○	ReLU
	3×3	64	1	○	ReLU
	3×3	64	1	○	ReLU
	3×3	1	1	X	tanh

제안한다.

컨볼루션 연산은 식 1과 같이 정의된다. 이 때 I는 input feature map (IFM)이고, W는 가중치 그리고 B는 바이어스이다.

$$O_C = \sum_{i,j}^{AB} I_{i,j} * W_{i,j} + B \quad (1)$$

배치 정규화의 식은 아래 식 2에서 나타내었다. μ 는 데이터 평균, σ 는 표준편차이다. γ 와 β 는 훈련된 매개변수이다.

$$O_B = \frac{O_C - \mu}{\sigma} * \gamma + \beta \quad (2)$$

배치 정규화에는 많은 수의 매개변수가 필요하기 때문에 많은 수의 메모리 접근과 높은 분할 계산 비용을 가져온다. 따라서 배치 정규화와 컨볼루션 연산을 결합하여 재구성하고 이를 이용하여 컨볼루션 연산과 같은 형태로 산술분석을 진행하였다. 이를 통하여 유일한 컨볼루션 블록으로 계산됨을 알 수 있다.

IV. 실험 결과

앞서 보였던 3장에서의 최적화 방법을 2장에서 보인 네트워크에 적용하였다. 최적화 후 2비트 가산기(2-bit Adder)의 계산량은 약 30%로 줄어들고, 분배기(Divider)는 쓰이지 않게 된 것을 확인할 수 있었다.

또한, 메모리 접근 횟수를 최소화하기 위하여 반복하여 사용되는 가중치는 외부메모리에서 가져오지 않고 공유 내부 메모리에 저장하여 재사용하여 메모리 접근 횟수를 줄였다. 또한 이미지의 각 행에 대한 input feature map (IFM)을 재사용하여 재사용율을 높이고 메모리 접근을 줄였다. 메모리 접근량은 알고리즘 최적화 전후에는 21×10^6 배 감소하고, 메모리 최적화 전후로는 $2,492 \times 10^6$ 감소를 확인했다.

V. 결론

본 논문에서는 딥 러닝을 기반으로 하는 워터마킹 시스템의 하드웨어 가속기 설계 최적화 방법을 제안한다. 본 논문의 워터마킹 네트워크는 딥 러닝 분야에서 많이 사용되는 CNN을 기반으로 하기 때문에 딥 러닝의 하드웨어 가속기 설계에 도움이 될 것이라 사료된다.

Acknowledgement

This research was supported by Basic Science Research Program through the National Research Foundation of Korea(NRF) funded by the Ministry of Education(NRF-2019R1F1A1054552)

References

- [1] I. J. Cox, et al., "Digital watermarking and steganography," Morgan Kaufmann Publisher, 2008.
- [2] J. Zhu, R. Kaplan, J. Johnson, and L. Fei-Fei, "HiDDeN: hiding data with deep networks," arXiv:1807.09937, July, 2018.
- [3] M. Ahmadi, A. Norouzi, S. M. Reza Soroushmehr, N. Karimi, K. Najarian, S. Samavi, and A. Emami, "ReDMark: framework for residual diffusion watermarking on deep networks," arXiv:1810.07248, Dec. 2018.
- [4] J.-E. Lee, Young-Ho Seo, and Dong-Wook Kim, "Convolutional Neural Network-Based Digital Image Watermarking Adaptive to the Resolution of Image and Watermark," Applied Science, 2020, 10, 6854. doi.org/10.3390/app10196854