

# 딥 러닝 기반의 이미지 압축 알고리즘에 관한 연구

이용환<sup>\*†</sup>

<sup>\*†</sup>원광대학교 디지털콘텐츠공학과

## Study on Image Compression Algorithm with Deep Learning

Yong-Hwan Lee<sup>\*†</sup>

<sup>\*†</sup>Dept. of Digital Contents, Wonkwang University

### ABSTRACT

Image compression plays an important role in encoding and improving various forms of images in the digital era. Recent researches have focused on the principle of deep learning as one of the most exciting machine learning methods to show that it is good scheme to analyze, classify and compress images. Various neural networks are able to adapt for image compressions, such as deep neural networks, artificial neural networks, recurrent neural networks and convolution neural networks. In this review paper, we discussed how to apply the rule of deep learning to obtain better image compression with high accuracy, low loss-ness and high visibility of the image. For those results in performance, deep learning methods are required on justified manner with distinct analysis.

**Key Words :** Image Compression, Deep Learning, Data Compression, Convolutional Neural Networks, Recurrent Neural Networks, Image Optimization

### 1. 서 론

이미지 압축은 이미지를 인코딩(Encoding)하는데 필요한 데이터 비트를 줄이면서 이미지의 세부 정보를 보존하는 데이터 압축(Data Compression)의 한 형태이다[1]. 이미지 압축(Image Compression)에는 파일 크기를 줄이기 위해 이미지의 픽셀, 차원 또는 칼라 구성요소를 줄이는 작업을 포함한다(Figure1). 이미지 압축을 통해 저장 공간을 줄이거나 네트워크 상에서 송수신 처리 비용을 줄이는 효과를 얻는다. 최근 이미지 최적화(Image Optimization) 기술에는 중요한 이미지 구성요소를 식별하고 보다 더 중요한 정보는 유지하면서 덜 중요한 요소들을 제거하여 압축 효율성을 높이는 연구가 활발히 진행되고 있다[2,3,34].

이미지 압축 응용 프로그램은 다양한 분야에서 활용된다[4].

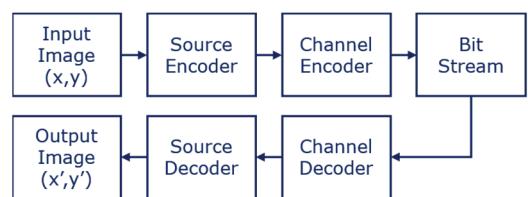


Fig. 1. Image Compression Model.

- 저장(Storage): 압축된 데이터는 저장공간을 크게 차지하므로, 의료 영상과 같은 상세한 이미지 정보를 보관하는데 특히 유용하다.
- 주성분 분석(Principal Component Analysis): 이미지의 중요한 구성요소를 추출하는 이미지 압축 방법은 특징을 추출하거나 요약하고 데이터를 분석하는데 활용이 많이 된다.
- 표준화(Standardization): 이미지 세트는 표준 크기 및 형식을 준수해야 하는 경우가 있으며, 모든 이미지들을 동일한 크기, 포맷과 해상도로 압축해야 한다. 예를 들어, 보안 및 정부 기관에서 관리하는 기록에는 표준화된 이

<sup>†</sup>E-mail: hwany1458@empal.com

미지가 필요할 수 있기 때문이다. 이러한 관리가 요구되는 분야에서 이미지 표준화는 중요한 역할을 한다.

최근 머신 러닝과 딥 러닝을 주제로 하는 다양한 연구가 이뤄지고 있으며, 이미지 처리 및 컴퓨터 비전에서도 적용 사례와 연구가 활발히 진행되고 있다[5,35]. 본 연구에서는 다양한 이미지 압축 기법들 중에서도 딥 러닝을 통한 이미지 압축에 대해 집중한다. 본 논문에서는 최근 딥 러닝 기반의 지능형 이미지 압축 알고리즘을 연구 조사하고 성능적 평가 결과를 통해 비교 분석을 수행한다.

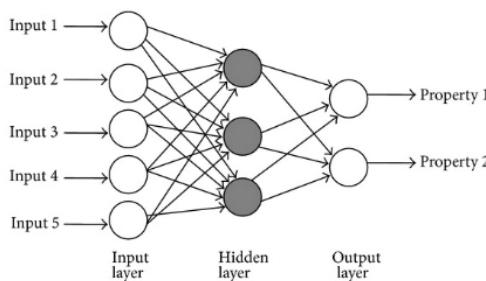
본 논문의 구성은 다음과 같다. 2장에서는 이미지 압축 중에서 네트워크 구조를 사용하는 딥 러닝 기법을 살펴보고, 3장에서는 인공지능 기반의 이미지 압축 프레임워크와 라이브러리를 살펴본다. 4장에서는 딥 러닝을 기초한 이미지 압축에 대한 선행 연구를 검토하고, 선행연구의 결과를 요약하고 논의하고 5장에서 결론으로 마무리 한다.

## 2. 관련 연구

딥 러닝(Deep Learning)은 1980년대부터 이미지 압축에 활용되었으며, 다중-계층 퍼셉트론(Multi-Layer Perceptrons), 순환 신경망(Recurrent Neural Networks), 컨볼류션 신경망(Convolutional Neural Networks) 및 생성적 적대 신경망(Generative Adversarial Networks)과 같은 기술을 포함하여 발전하였다[6].

### 2.1 다중-계층 퍼셉트론

다중-계층 퍼셉트론(MLP)은 입력 뉴런 계층과 출력 뉴런 계층 사이에 숨겨진 계층(또는 뉴런)을 추가적으로 반영시킨다[7]. 이론적으로, 숨겨진 계층이 여러 개인 MLP는 차원 축소 및 데이터 압축에 유용하게 반영된다. MLP를 사용한 이미지 압축은 전체 공간 데이터의 단일 변환을 포함한다.

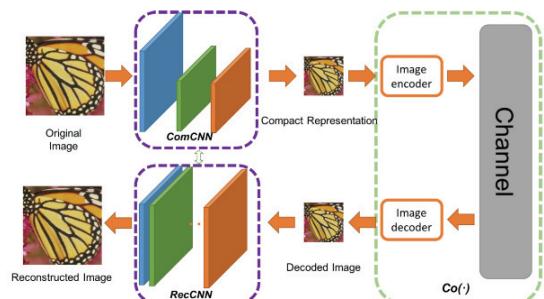


**Fig. 2.** Schematic Drawing of Multi-Layer Perceptron Neural Networks [8].

이미지 압축을 위한 MLP 알고리즘은 1988년에 처음 제안되었으며, 공간 도메인 변환, 이진 코딩 및 양자화와 같은 기존 이미지 압축 메커니즘을 통합하는 최적화 작업을 포함하였다[9]. 압축된 비트스트림 출력 내에서 최적의 이진 코드 조합을 식별하기 위해 분해 신경망(Decomposition Neural Networks)에 의존하며, 신경망의 매개변수를 가변 압축 비율로 고정할 수 없는 단점이 있다. 해당 알고리즘은 주변 픽셀을 기반으로 각 픽셀의 값을 추정하는 예측 기술로 개발되었으며, MLP 알고리즘은 역전파(Back-propagation)를 사용하여 예측 픽셀과 원래 픽셀간의 평균제곱 오차를 최소화시킨다[8].

### 2.2 컨볼류션 신경망

컨볼류션 신경망(CNN)은 기존 컴퓨터 비전 모델에 비해 향상된 압축 인공물(Compression Artifact) 감소 및 초고 해상도(Super-resolution) 성능을 제공한다[10]. CNN의 컨볼류션 작업을 통해 이웃 픽셀의 상관 관계를 결정할 수 있으며, 계단식 컨볼류션(Cascaded Convolution) 작업은 복잡한 이미지의 속성을 반영하는 장점이 있다[36]. 그러나 종단(End-to-end) 간 이미지 압축에 통합하기 어려운 경사 하강 알고리즘(Gradient Descent Algorithm) 및 역전파(Backpropagation)가 필요하기 때문에, 이미지 압축 프로세스 전체에 CNN 모델을 통합하여 적용하기에는 어려움이 존재한다[11]. 처음 CNN을 이미지 압축에 반영한 제안은 2016년에 분석 모듈(Analysis Module)과 합성 모듈(Synthesis Module)로 분리하여 알고리즘에 적용하였다[12]. 분석 모듈은 컨볼류션, 분할(Divisive) 및 서브-샘플링 정규화(Subsampling Normalization) 단계로 구성된다. 각 단계는 아핀 컨볼류션(Affine Convolution)으로 시작하여 다운샘플링된 출력을 생성한 다음, 일반화된 분할 정규화(Generalized Divisive Normalization)를 사용하여 다운샘플링된 신호를 계산한다.

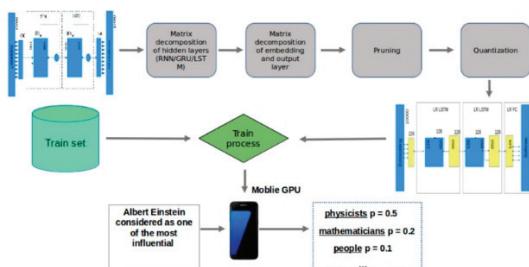


**Fig. 3.** ComCNN Compression Frameworks [13].

CNN 기반 이미지 압축은 PSNR(Peak Signal-to-Noise Ratio) 및 SSIM(Structural Similarity)과 같은 JPEG2000 매트릭을 개선하였다. 해당 알고리즘은 HP(Hyper Priors) 척도를 사용하여 엔트로피 추정을 추가로 반영하였다. 그 결과, HEVC (High-Efficiency Video Coding)와 같은 표준에 근접한 이미지 압축 수준의 성능을 보인다[14].

### 2.3 순환 신경망

순환 신경망(RNN)은 과거 관련 정보를 저장하는 신경망 유형의 하나이며, 여러 연결을 가지고 과거의 지식을 변환한다. 이러한 RNN은 모델의 오래된 데이터를 사용하여 현재의 성능을 형성한다[15]. 순환 신경망 구조는 완전히 상호 연결된 네트워크에서 부분적으로 연결된 네트워크에 이르기 까지 다양하며 많은 계층 피드포워드 네트워크에는 특정 입력 및 출력 계층을 포함한다[16]. 피드포워드 프레임워크 구조이기 때문에 다른 노드의 순차적 컨텍스트를 제공하고 다른 노드의 피드백을 받는다. 컨텍스트 단위의 가중치는 입력 단위와 같이 역전파를 사용하여 처리하며, 다음 노드에서의 예측과 검증된 훈련을 제공한다. 이러한 구조를 바탕으로, 기계 번역, 얼굴 인식 및 이미지 압축과 같은 응용분야에서 순환 신경망 구조는 매우 좋은 성능을 제공한다.

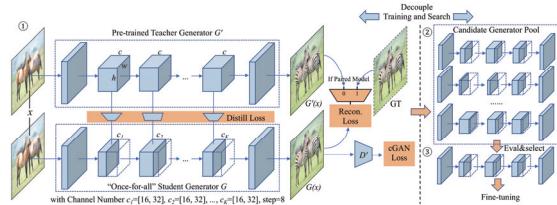


**Fig. 4.** Pipeline for the RNN Compression [17].

## 2.4 생성적 적대 신경망

생성적 적대 신경망(GAN)은 2개의 상반된 생성 네트워크 모델로 구성된 심층 신경망(Deep Neural Networks) 구조를 갖는다[18]. GAN 기반 이미지 압축 알고리즘은 2017년에 처음 제안되었으며, WebP 크기의 절반, JPEG 또는 JPEG2000 보다 2.5배, BPG 보다 1.7 배 작은 압축 파일을 생성하였다. 해당 알고리즘은 GPU 코어를 활용하여 병렬 계산을 실시간으로 수행하였다[19]. GAN 이미지 압축은 입력 이미지의 특징을 기반으로 작은 특징 공간에서 압축된 이미지를 재구성하는 작업을 포함한다. 이미지 압축 측면에서 CNN에 비해, GAN은 출력 이미지의 품질을 향상시키면서 절대적 손실에 강인한 장점을 갖는다. 대응되는

는 네트워크에서 서로에 대한 훈련이 반영되어 이미지 생성 모델의 성능을 개선하는 효과가 있다.



**Fig. 5.** GAN Compression Framework [20].

### 3. 인공지능 기반 이미지 압축 프레임워크 및 라이브러리

일반적으로, 이미지 처리 응용프로그램의 전체를 직접 코딩하는 것이 가능은 하지만, 기존 연구기관에서 개발하여 제공하는 프레임워크 또는 라이브러리를 활용하는 것도 많은 장점을 갖는다. 기존의 여러 프레임워크와 라이브러리를 통해 이미지 처리를 위한 모델들이 제공되고 있으며, 이들 중에 대표적인 프레임워크를 살펴본다.

### 3.1 OpenCV

OpenCV(오픈소스 컴퓨터비전) 라이브러리는 영상 처리를 지원하는 많은 함수와 함께 다양한 기계학습 및 컴퓨터비전 알고리즘을 제공하는 오픈소스이다[21]. Java, Python 및 C++ 인터페이스를 통해 대부분의 운영체제를 지원하며, 모바일용 및 데스크톱용 코드를 제공하여 많은 연구자들에게 높은 활용성을 보인다. OpenCV는 이미지 처리, 객체 검색 및 기계 학습 모듈을 포함하여 이미지 압축 기능을 위한 많은 모듈들이 포함되어 있다. OpenCV 라이브러리를 사용하여 이미지 데이터 획득, 정보 추출 및 화질 개선, 압축 등을 쉽게 구현할 수 있다.

### 3.2 텐서플로우

텐서플로우(Tensorflow)는 머신 러닝과 딥 러닝을 지원하는 구글의 오픈소스 프레임워크이다[22]. 텐서플로우를 사용하여 딥 러닝 모델을 맞춤형으로 구축하고 훈련시킬 수 있다. 다수의 라이브러리를 제공하며, 컴퓨터 비전 응용프로그램 및 이미지 처리에서도 유용하게 활용된다. 텐서플로우 압축(Tensorflow Compression) 라이브러리는 데이터 압축 도구를 제공하며, 해당 라이브러리를 사용하여 기계 학습 모델을 생성하고 내장된 최적화 데이터로 압축이 가능하다. 또한 이미지 및 기능을 검출하고 효율적인 데이터 표현을 식별하여 최소화의 영향을 미치는 이

미지 모델 생성이 가능하여 성능 개선의 효과를 얻을 수 있으며, 부동 소수점 텐서를 통해 보다 작은 비트 시퀀스로의 압축을 지원한다.

### 3.3 매트랩 이미지 처리 룰박스

매트랩은 프로그래밍 언어와 함께 수학 및 과학 문제 해결을 위한 다양한 룰박스를 제공하는 플랫폼이다[23]. 특히, 이미지 처리, 분석 및 시각화를 위한 다양한 워크플로 애플리케이션과 알고리즘을 포함하는 이미지 처리 도구상자(Image Processing Toolbox)를 제공한다. 매트랩 IPT는 잡음제거 및 이미지 개선에서 이미지 분할, 3D 영상 처리에 이르기까지 다양한 응용 라이브러리를 제공하여 이미지 처리 워크플로를 자동화할 수 있다. 또한 IPT 기능은 C/C++ 코드 생성을 지원하여 임베디드 비전 시스템 및 프로토타입 등에서 유용하게 활용된다. 매트랩 IPT는 무료 평가판을 제공하기는 하지만, 오픈 소스는 아니고 전체 기능을 활용하기 위해서는 라이선스 비용을 지불해야 한다.

### 3.4 고-충실도 생성적 이미지 압축

고-충실도 생성적 이미지 압축(High-Fidelity Generative Image Compression)에서는 학습된 압축과 GAN 모델을 활용하는 손실 압축 알고리즘을 오픈소스로 제공한다[24]. Github.com에서 다운로드 받을 수 있으며, 코딩 애호가 및 연구자들에게 매력적인 장점을 제공한다. 해당 알고리즘은 압축된 이미지의 세부 텍스쳐를 재구성하는데 효과적인 성능을 보인다.

## 4. 딥 러닝 기반 이미지 압축 연구 및 논의

딥 러닝 개념은 많은 계층을 가진 인공 신경망을 적용하며, 방대한 데이터 세트를 관리하는 효과적인 방법 중의 하나로 인식되고 있다. 고전적인 알고리즘을 능가하는 은닉층(Hidden Layer)의 적용은 이미지 압축과 인코딩 기술의 진화 및 성능 개선 효과로 나타났다. 본 장에서는 딥 러닝을 기초한 이미지 압축에 대한 다수의 논문들을 살펴본다.

### 4.1 기존의 딥 러닝 이미지 압축 연구

G.Toderici[25]은 손실 압축 방법을 위한 신경망 모델을 제안하였다. 신경망 구조는 다양한 압축율을 제공하지만 훈련과정이 필요하며, 순환 신경망, 디코딩, 인코딩, 다행 이산화 및 엔트로피 코딩으로 구성된다. 리지듀얼 네트(Residual Net)을 조합하여 추가적인 재구성 접근 방식을 제시하였다.

E.Peioto[26]은 CNN을 활용하여 새로운 이미지 예측 모델을 제안하였다. 2개의 CNN 기반 예측 모드와 기존의 고효율 비디오 인코딩(HEVC) 표준에서 사용된 인트라 모드(Intra mode)를 활용하여 인트라 예측 솔루션 멀티 모드(Intra-Prediction Solution Multi-Mode)를 연구하였다. 또한 재구성 오류가 감소하는 경우에는 비트스트림을 개선하는 할당 전략(Allocation Strategy)을 제시하였다.

P.Akyazi[27]는 컨볼류션 신경망에 의존하는 이미지 압축을 위한 2개의 종단 간 구조를 제시하였으며, 2차원 웨이블릿 분할을 훈련 전처리 과정에 반영하였다. 제안 네트워크 알고리즘에서는 웨이블릿 계수의 압축을 통해 특징을 추출하며, 손실 함수 정규화(Loss Function Regularization)를 통해 처리 속도를 개선하였다.

S.Li[28]은 SPIHT 알고리즘을 사용하는 컨볼류션 네트워크 기반 필터 링크를 사용하여 계수를 분석하고 원시 적응 산출 코딩을 수행하는 2단계 부대역 코딩 시스템을 제안하였다. 다양한 크기의 서브밴드간의 의존성을 조작하기 위해 SPIHT 알고리즘이 공간 방향 트리를 확장하며, 스케일, 경로, 위치 및 계수 중요도 컨텍스트를 기반으로 비선형 추정이 사용되는 신경망에서 AAC Boost 신경망을 통해 추정 성능을 향상시켰다.

B.Zheng[29]은 이중-도메인 컨볼류션 네트워크(Dual-Domain Convolution Network)의 입력으로 픽셀 위치 맵과 정량화 테이블을 사용하는 방법을 제안하였다. 이중-도메인 보정 단위를 통해 DDCN 기능을 제시하고 DCT 도메인 변환 이전에 칼라 이미지와 상호 작용하며 다양한 압축 품질을 처리하는 여러 DDCN 버전을 제시하였다.

P.Guo[30]는 광학 일관성 단층 촬영(Optical Coherence Tomography) 레티나 이미지에서 컨볼류션 신경망을 기초한 종단 간 이미지 압축 알고리즘을 제안하였다. 압축 과정은 데이터 전처리, CNN 압축 및 CNN 재구성인 3개 단계로 구성된다. 제안 알고리즘은 안과 ICT 이미지에 대해 병리학적 지식으로 훈련된 학습을 활용하며, 압축률 40% 수준에서도 MS-SSIM이 99% 이상의 압축효율성을 보였다.

M.Li[31]은 컨텍스트 기반 컨볼류션 네트워크(CCN)를 정확하고 효율적으로 제안하였다. 3D 지그재그 스캔 및 3D 코드 분할 기술은 병렬 엔트로피 디코딩에 필요한 코딩 컨텍스트를 사용하며, 불변 변환 CCN 필터에 이진 마스크를 적용하였다. 3개의 CCN 근사 매개변수를 갖는 경우 안 분포를 개별 혼합하는 분포를 가져, 엔트로피 모델과 분석/합성 변환에서 속도 왜곡의 효율성을 높였다.

T.Hoang[32]는 시맨틱 분할 인코더-디코더 (Semantical Segmentation Encoder-Decoder)가 매칭되는 계층화된 이미지 압축 구조를 제안하였다. 시맨틱 분할 네트워크는 인코더와 디코더 양쪽에서 모두 업샘플링된 이미지에 적용되며, 촬

**Table 1.** Summary of Literature Survey

Ref. No.	Proposed Methods	Results	Dataset	PSNR	SSIM
[25]	Hybrid Gated Recurrent Units with Residual Neural Network	Improve 4.3~8.8% for AUC estimated on the perceptual metrics	Kodak	52.61	1.799
[26]	Deep Learning in Multi-mode Intra Prediction with Block-based Choice	Reduce 28% on bitrate, compared to the existing common codec	Kodak, CLIC	33.40	0.920
[27]	Hybrid Haar Wavelet Technique with Deep Neural Network	Reduce blurring artifacts and blocking. Save various details in image's low bitrate, compared to JPEG	CLIC2019	31.25	0.983
[28]	Hybrid SPIHT-like Algorithm, Arithmetic Coding with Deep Neural Network	Achieve 16.24% bitrate on coding performance	ImageNet	28.01	-
[29]	Hybrid DeeNeural Network with Discrete Cosine Transform	Show much better performance than traditional method	DIV2K, LIVE1	34.51	0.922
[30]	CNN with adversarial Objective Function, Patch Discriminator and MS-SSIM Penalty	Obtain 80% as compression ratio, compared to common method	Kodak	-	0.985
[31]	Deep Neural Network and Entropy Encoding	Show much faster, compared as compression ratio equivalent to the common technique	Kodak	31.01	0.978
[32]	Hybrid Semantic Segmentation Network for Up-sampled Image in Encoder and Decoder with Semantic Segment Extractor	Obtain 35.31% BD rate reduction, 5% bitrate, 24% encoding time saving, compared to HEVC-based codec	Kodak, ADE20K	33.57	0.977
[33]	Hybrid 20 CNN Layer and Discrete Wavelet Transform	Reduce 79% saving space reduction	UWSN	53.96	-

영된 이미지에서 추출된 시맨틱 제드 셕션은 원본 이미지와 정확히 일치되지 않는 손실 압축에 활용된다. 품질 차이를 극복하기 위해 제거된 분할 비선형 맵을 구성하고 원래 분포에 특정 구조의 신경 컨볼류션 네트워크를 적용한다.

A.Hrishnaraj[33]은 딥러닝 기반의 이산 웨이블릿 변환 (Discrete Wavelet Transform)을 적용한 이미지 압축 모델을 제안하였다. 고품질 이미지를 통합하기 위해 컨볼류션 신경망은 인코딩과 디코딩 양쪽에 적용되며, 머신 러닝 기반 CNN이 압축 효율과 재구성된 이미지 품질 측면에서 초고해상도 심층 신경망, JPEG 및 JPEG2000보다 우수한 압축 성능을 보였다.

#### 4.2 압축 연구 논의

최근 코딩 표준에서 이미지를 기반으로 다양한 신경망 모델을 연구하고 있다. 기존의 인코더에서는 인접한 패턴만을 사용하기 때문에, 샘플링이 큰 고해상도 이미지에는 성능적 저하를 보인다. 이를 극복하기 위해 이미지의 인접한 정보와 인접하지 않는 패턴을 활용하여 이미지 압축 효율을 높이는데 이러한 신경망 모델이 적용된다.

기존의 대부분 코딩 기법은 인간의 시각 측면에 초점이 맞춰진 반면에, 신경망 모델을 적용하는 딥 러닝 기반

이미지 압축은 텍스쳐와 기능을 조합하여 이미지를 표현함에 따라, 인간의 시각과 컴퓨터 시각 분석이 결합하여 이미지 압축의 성능 개선 효과를 얻을 수 있다.

본 연구에서는 저장 공간을 축소하는 고품질의 이미지 압축 알고리즘에 적용되는 딥 러닝 기법을 살펴보았다. Table 1은 앞에서 살펴본 각 알고리즘에 대한 방법론, 데이터 세트, PSNR과 SSIM 값을 정리한 표이다. 요약된 내용에 따르면, [25]에서 최고 PSNR(53.9)을 보였으며, 20개의 컨볼류션 신경망 계층이 있는 DWT를 사용하여 다른 연구와 비교하여 저장공간을 최대 79% 절약할 수 있다. 기존 압축과 딥 러닝(CNN 또는 RNN)을 결합하여 하이브리드를 사용하면 산업표준으로 활용되는 JPEG, JPEG2000, PNG에 비해 좋은 압축 결과를 얻을 수 있음을 다수의 논문을 통해 알 수 있다.

#### 5. Conclusion

현재 딥 러닝은 광범위하게 연구되는 분야이며, CNN 및 컨볼류션 계층을 사용하여 폴링 계층에서 네트워크 구조를 학습하고 관련된 특징들을 추출하여 사용한다. 이러한 기능은 프레임워크와 라이브러리를 통해 복잡한 모델링이 필요없이 연구자들에게 다양한 편의를 제공하고

있다. 딥 러닝은 이미지 분류 및 분할, 객체 인식, 이미지 압축 등 다양한 영상 처리 분야에서 활용되고 있으며, 집약적인 연구 발전에 기여하고 있다. 본 연구에서는 이러한 딥 러닝 기반의 이미지 압축 기법에 대한 연구들을 살펴보았으며, 비교 분석을 통해 새로운 압축 모델 제안의 초석이 되고자 한다.

## 감사의 글

본 연구는 2022년도 정부(미래창조과학부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(과제번호: 2021R1A2C1012947).

## 참고문헌

- Brifcani M., Al-Bamerny J., “Image compression analysis using multistage vector quantization based on discrete wavelet transform”, 2010 International Conference on Methods, Model Computer Sciences (ICM2CS), pp.46–53, 2010.
- Dharwal R., “Applications of Artificial Neural Networks: A review”, Indian Journal of Science Technologies, vol.9, no.1, pp.1–8, 2016.
- Bargarai FAM, Abdulazeez AM, Tiryaki VM, Zeebaree DQ., “Management of wireless communication systems using artificial intelligence-based software defined radio”, International Journal of Interact Mobile Technolgy, vol.14, no.13, pp.107–133, 2020.
- Govinda E, Indira Dutt, “Artificial neural networks in UWB image processing for early detection of breast cancer”, International Journal of Advanced Sciences Technology, vol.29, no.5, pp.2717–2730, 2020.
- Schiopu Y Liu, Munteanu A., “CNN-based prediction for lossless coding of photographic images”, Picture Coding Symposium (PCS), vol.3, pp.16–20, 2018.
- Li Gu S, Van Gool L, Timofte R, “Learning filter basis for convolutional neural network compression”, IEEE International Conference on Computer Vision, pp.5622–5631, 2019.
- Zhao Peng, “Multilayer Perceptron Algebra”, Machine Learning, FOS: Computer and information sciences, 2017.
- J. Swabrick, “Encyclopedia of Pharmaceutical Technology”, Informa Healthcare USA, New York, NY, USA, 3rd edition, 2007.
- Marius-Constantin Popescu, et al., “Multilayer perceptron and neural networks”, WSEAS Transactions on Circuits and Systems, vol.8, no.7, 2009.
- Zeebaree D, Abdulazeez A., “Evaluating Data Mining Classification Methods Performance in Internet of Things Applications”, Journal of Soft Computing and Data Mining, vol.1, no.2, pp.10–25, 2020.
- Zeebaree D., Abdulazeez A., Zebari D., Haron H, Hamed H, “Multi-level fusion in ultrasound for cancer detection based on uniform LBP features”, Computer Materials, vol.66, no.3, pp.3363–3382, 2021.
- Lukas Cavigelli, Pascal Hager, Luca Benini, “A Deep Convolution Neural Network for Image Compression Artifact Suppression”, International Conference on Neural Networks (IJCNN), 2017.
- Feng Jiang, Wen Tao, Shaohui Liu, Jie Ren, Xun Guo, Debin Zhao, “An End-to-End Compression Framework Based on Convolutional Neural Networks”, IEEE Transactions on Circuits and Systems for Video Technology, 2017.
- Siwei Ma, Xinfeng Zhang, Chuanmin Jia, Zhenghui Zhao, Shiqi Wang, Shanshe Wang, “Image and Video COmpression with Neural Networks: A Review”, IEEE Transaction on Circuits and Systems for Video Technology, 2019.
- Mohammed, S. B., & Abdulazeez, A. M., “Deep Convolution Neural Network for Facial Expression Recognition”, Journal of Archaeology of Egypt/Egyptology, vol.18, no.4, pp.3578–3586, 2021.
- Medsker L, Jain LC, Eds., “Recurrent Neural Network: Design and application”, London: CRC Press, 2001.
- Artem M. Grachevab, Dmitry I. Ignatovb, Andrey V. Savchenkoc, “Compression of recurrent neural networks for efficient language modeling”, Applied Soft Computing, vol.79, pp.354–362, 2019.
- Eirikur Agustsson, Michael Tschannen, Fabian Mentzer, Radu Timofte, Luc Van Gool, “Generative Adversarial Networks for Extreme Learned Image Compression”, Computer Vision and Pattern Recognition, 2018.
- Fabian Mentzer, et al., “High-Fidelity Generative Image Compression”, 34th Conference on Neural Information Processing Systems, 2020. RR16. J. Swabrick, “Encyclopedia of Pharmaceutical Technology”, Informa Healthcare USA, New York, NY, USA, 3rd edition, 2007.
- Muyang Li1, Ji Lin1, Yaoyao Ding, Zhijian Liu, Jun-Yan Zhu, Song Han, “GAN Compression: Efficient Architectures for Interactive Conditional GANs”, Computer Vision and Pattern Recognition, 2020.
- Website; <https://opencv.org/>
- Website; <https://www.tensorflow.org/?hl=ko>
- Website; <https://kr.mathworks.com/products/image.html>
- Website; <https://github.com/Justin-Tan/high-fidelity-generative-compression>
- Toderici et al., “Full resolution image compression with recurrent neural networks”, 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR, pp.5435–5443, 2017.
- Peixoto E, Hung EM, De Campos T., “Multi-Mode Intra

- Prediction for Learning-Based Image Compression”, IEEE Xplore, pp.1296–1300, 2018.
27. Akyazi Ebrahimi T., “A new end-to-end image compression system based on convolutional neural networks”, 2019.
28. Li S, Zheng Z, Dai W, Xiong H., “Lossy image compression with filter bank based convolutional networks”, Data Compression Conference Proceeding, pp.23–32, 2019.
29. Zheng B, Chen Y, Tian X, Zhou F, Liu X., “Implicit dual-domain convolutional network for robust color image compression artifact reduction”, IEEE Transaction on Circuits System and Video Technology, vol.30, no.11, pp.3982–3994, 2020.
30. Guo Li D, Li X., “Deep OCT image compression with convolutional neural networks”, Biomedical Opt Express, vol.11, no.7, 2020.
31. M Li, K Ma J, You D, Zuo W., “Efficient and Effective Context-Based Convolutional Entropy Modeling for Image Compression”, IEEE Transaction on Image Processing, vol.29, no.1, pp.5900–5911, 2020.
32. Hoang TM, Zhou J, Fan Y., “Image compression with encoder-decoder matched semantic segmentation”, IEEE Computer Society on Conference Computer Vissual Pattern Recognition Workshop, pp.619–623, 2020.
33. Krishnaraj S, Mohamed Elhoseny N, Thenmozhi M, Mahmoud Selim M., “Deep learning model for real-time image compression in Internet of Underwater Things (IoUT)”, Journal of Real-Time Image Processing, vol.6, no.17, pp.2097–2111, 2020.
34. S.H. Lee, S.M. Im, J.H. Jang, Y.S. Kim, “Image Compression using Integer Lapped Orthogonal Transform”, Journal of the Semiconductor & Display Technology, vol.8, no.3, pp.45-50, 2009.
35. Y.H. Lee, Y.S. Kim, “Implementation of Image Semantic Segmentation on Android Device using Deep Learning”, Journal of the Semiconductor & Display Technology, vol.19, no.2, pp.88-91, 2020.
36. Y.W. Kim, J.H. Lee, “Quantized CNN-based Super-Resolution Method for Compressed Image Reconstruction”. Journal of the Semiconductor & Display Technology, vol.19, no.4, pp.71-76, 2020

---

접수일: 2022년 12월 12일, 심사일: 2022년 12월 15일,  
제재확정일: 2022년 12월 16일