ResNet-합성곱 오토인코더 기반 신경망을 이용한 스펙트럼 데이터 압축

손성재, 진철군, 박아론, 백성준* 전남대학교 ICT 융합시스템공학과

Spectrum Data Compression Using ResNet-Convolutional AutoEncoder Based Neural Network

SeongJae Son, Tiejun Chen, Aaron Park, Sung-June Baek^{*} Dept. of ICT Convergence System Engineering, Chonnam National University

요 약 본 논문에서는 스펙트럼 저장 시 데이터용량을 줄이기 위해 합성곱 오토인코더(convolutional autoencoder) 구조에 ResNet(Residual Neural Network) 알고리즘을 적용한 스펙트럼 데이터 압축 신경망을 제안한다. 최근 분광법 (spectroscopy)의 적용 분야가 넓어짐에 따라 스펙트럼 데이터베이스가 대용량화되어 효율적인 전송이 어렵고 많은 저장 공간을 필요로 한다. 이러한 대용량의 데이터베이스를 효율적으로 관리하기 위해 데이터 압축을 수행한다. 기존 데이터 압축에 주로 사용되는 PCA(Principal Component Analysis)는 주성분의 개수에 따라 압축률이 결정된다. 주성분 개수가 적을수록 압축률은 높아지지만 정보 손실이 보다 쉽게 발생하기 복원 시 원본 데이터와의 크게 오차가 발생한다. 이러한 한계점을 극복하기 위해 본 논문에서는 제안한 신경망인 CAER(Convolutional AutoEncoder+ResNet)을 통하여 데이터 압축을 수행하였다. 신경망 학습은 실제 스펙트럼 데이터를 묘사하여 생성한 모의실험 데이터를 통해 수행하였다. CAER 신경망의 성능 검증을 위해 라만 스펙트럼의 PCA와 신경망을 통하여 75%, 87.5%, 93.75%의 압축률로 압축과 복원을 수행한 후 각각의 결과를 비교 분석하였다. 원본과 복원 데이터의 오차 비교를 하였을 때 CAER 신경망은 PCA보다 평균 94.2%의 낮은 오차를 보인다. 이 결과를 통해 CAER 신경망이 스펙트럼 데이터 압축에 효과적으로 적용될 수 있음을 확인하였다.

Abstract In this paper, we propose a spectrum compression neural network that applied the ResNet (Residual Neural Network) algorithm to the convolutional autoencoder structure to reduce data capacity requirement in storing the spectrum. Recently, as the field of application of spectroscopy widens, the spectrum database is becoming larger, making efficient transmission difficult and requiring large amount of storage. Therefore, data compression is performed to manage large amounts of data efficiently. In PCA (Principal Component Analysis), which is mainly used for data compression, the compression ratio is determined by the number of principal components. As the number of principal components decreases, the compression rate increases, but at the same time, it is easier for information loss to occur. Hence, errors occur between reconstruction and the raw spectrum. To overcome these limitations, we perform compression through the proposed CAER (Convolutional AutoEncoder+ResNet) network. The training of the network was performed through simulated data describing the real spectrum. To verify the performance of the CAER network, the Raman spectrum was compressed and reconstructed at compression rates of 75%, 87.5%, and 93.75% through the PCA and CAER networks. Comparing the errors between raw and reconstructed data, the CAER network shows an average error of 94.2% lower than that of the PCA. The results obtained confirm that the CAER network can be effectively applied to spectrum compression.

Keywords: Data Compression, PCA, Autoencoder, ResNet, Raman Spectrum

본 논문은 전남대학교 학술연구비지원(과제번호: 2020-3865)에 의하여 수행되었음.

*Corresponding Author: Sung-June Baek(Chonnam Univ.)

email: tozero@jnu.ac.kr

Received August 6, 2021 Accepted December 6, 2021 Revised September 8, 2021 Published December 31, 2021

1. 서론

최근 분광법의 기법 중 적외선 분광법(infrared spectroscopy)과 라만 분광법(Raman spectroscopy)의 사용이 점차 증가하고 있다. 두 분광법의 스펙트럼 데이터는 피크, 배경잡음 그리고 가산잡음으로 구성되어 물질의물리·화학적 특성 및 구조와 같은 고유한 정보를 제공한다. 분광법은 물질의 정보 분석뿐만 아니라 의학, 생물학등 다양한 분야에서 적용 범위를 넓혀가고 있다[1-4]. 이에 따라 스펙트럼 데이터베이스 또한 대용량화 되어 효율적인 전송이 어렵고 많은 저장 공간을 요구한다. 이러한대용량의 데이터베이스를 효율적으로 관리하기 위해 주로차원 축소 기법을 통해 데이터 압축을 수행한다.

기존의 데이터 압축은 주로 PCA를 통해 이루어진다. PCA는 차원 축소의 기법 중 하나로 정보 손실을 최소화하여 고차원의 데이터를 저차원의 데이터로 축소시키는 기법이다. PCA는 입력 데이터의 공분산 행렬 (covariance matrix)에 대해 고유값 분해(eigenvalue decomposition)하여 얻는 고유값과 고유 벡터를 기반으로 주성분을 찾아 차원 축소를 수행한다[5]. 하지만 압축률을 높이기 위해 적은 수의 주성분(principal component)을 통한 압축은 데이터 분포의 유지가 어렵다. 이는 데이터의 정보 손실을 일으키며 복원 시 원본 데이터와의 큰 오차가 발생한다. 또 다른 차원 축소 기법인 Kernel PCA의 경우 압축한 데이터를 복원하기 위해서는 원본 데이터를 가지고 있어야함으로 효율적이지 못하다.

본 연구에서는 이러한 한계점을 극복하기 위해 신경망을 사용하여 스펙트럼 압축을 수행하였다. 신경망은 오토인코더 구조에 입력 데이터로부터 특징 추출에 특화된합성곱층과 신경망을 더 많은 층으로 구성할 수 있도록고안된 ResNet의 알고리즘을 적용하였다. 성능 검증을위해 PCA와 신경망을 통해 데이터 압축과 복원 과정을수행한 후 결과를 비교 분석한다.

본 논문의 구성은 다음과 같다. 2장에서는 실험에 적용한 딥러닝 알고리즘과 제안한 신경망에 대해 설명하고, 실험 결과를 통해 제안한 신경망이 스펙트럼 압축에 효율적임을 확인한다. 3장에서 본론의 요약과 간단한 결론으로 본 논문을 마무리한다.

2. 본론

2.1 데이터 압축

데이터 압축은 데이터를 원본 데이터보다 작은 크기로 변환하여 전송 효율을 높이며 저장 공간과 비용을 줄일 수 있는 기법이다. 데이터의 크기를 압축하는 인코딩 (encoding)과정과 압축된 데이터를 원본 데이터로의 복 원하는 과정인 디코딩(decoding) 과정으로 이루어진다.

데이터 압축 기법 중 PCA를 통한 데이터 압축이 주로 사용된다. 압축률을 높일수록 정보 손실을 일으킬 가능성 이 존재하므로 적절한 압축률을 통한 데이터 압축을 수 행하여야한다.

2.1.1 PCA를 통한 데이터 압축

PCA를 수행하기 위해 입력 데이터 X의 공분산 행렬 Σ 를 구성한다. 공분산 행렬 Σ 를 고유값 분해하여 고유 벡터 행렬 V와 고유값 행렬 Λ 를 내림차순 정렬한다. 입력 데이터를 k개의 점으로 새로운 좌표 공간으로 투영하기 위해 아래의 식을 이용한다[6].

$$Z = V^T X \tag{1}$$

Where, V^T denotes transposed eigenvector matrix, X denotes input data matrix

Z는 주성분을 나타내는 행렬로 첫 번째 z_1 부터 k주 성분 z_k 로 이루어져 있다. V^T 는 고유값 행렬의 전치를 나타내며, X는 입력 데이터의 행렬을 나타낸다. 위와 같은 과정으로 PCA는 입력 데이터의 변수 개수보다 적은 수의 주성분 k를 선택하여 데이터의 압축을 수행한다. 복원은 다음과 같은 식을 이용한다.

$$\hat{X} = ZV$$
 (2)

Where, V denotes eigenvector matrix, Z denotes principal component matrix

 \hat{X} 는 복원된 데이터를 나타내며 주성분 행렬 Z와 고 유벡터 행렬 V의 곱으로 구할 수 있다.

2.1.2 딥러닝 알고리즘 기반 데이터 압축

오토인코더는 데이터의 특성이나 구성을 분석하거나 추출에 사용하는 비지도 학습(unsupervised learning) 신경망 중 하나이다. 오토인코더는 Fig. 1과 같이 인코 더(encoder)와 디코더(decoder)로 구성되어있다.

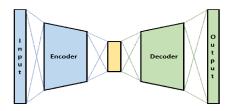


Fig. 1. Structure of autoencoder

인코더는 입력데이터를 잘 표현할 수 있는 특징을 추출하여 압축을 수행한다. 압축한 특징들을 디코더를 통해 입력 데이터와 동일하도록 복원한다. 이렇게 복원된 데이터가 입력 데이터와 비슷할수록 압축 성능이 뛰어나다고 판단할 수 있다.

본 논문에서는 오토인코더 구조에 합성곱 신경망 (CNN: Convolutional Neural Network)과 ResNet의 알고리즘을 적용한 신경망(neural network)을 제안한다. 제안한 신경망의 성능 비교를 위해 오토인코더 구조의 다층퍼셉트론(MLP: Multi-Layer Perceptron)과 합성곱 신경망을 정의하였다.

Fig. 2는 다층퍼셉트론을 통한 압축과 복원 과정이다.

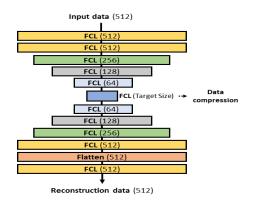


Fig. 2. Compression and reconstruction process based on MLP

다층퍼셉트론은 완전연결층(FCL: Fully Connected Layer)으로 구성된 신경망을 의미한다. 완전연결층은 한층의 모든 노드가 이웃한 층의 노드와 모두 연결된 상태의 층을 말하며 1차원 데이터 분류에 주로 사용된다[7].

실험에 사용한 다층퍼셉트론은 완전연결층을 통해 신호의 길이가 512인 데이터의 길이를 줄여간다. 중앙의 완전연결층을 통해 지정한 압축 사이즈로 압축을 수행한다. 복원은 압축과정을 역순으로 수행하여 Flatten층으로 데이터 평탄화 후 복원 데이터를 출력한다.

Fig. 3은 합성곱 신경망을 이용한 압축과 복원 과정이다. 합성곱층은 이미지 인식과 음성 인식, 신호처리 분야에서 에서 주로 사용되며 합성곱층의 필터(Filter)와 입력 데이터간의 합성곱 연산을 통해 데이터의 특징 추출에 특화되어있다[8].

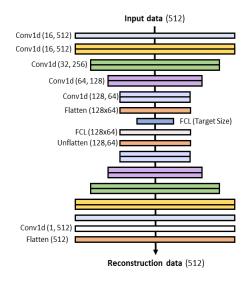


Fig. 3. Compression and reconstruction process based on CNN

실험에 사용한 합성곱 신경망은 1차원 데이터 특징 추출에 특화된 1차원 합성곱층(Conv1d: Convolution layer 1d)으로 구성하였다. 첫 합성곱층을 통해 입력 데이터의 채널(channel) 수를 확장시킨다. 이후 합성곱층을 통해 채널 수를 순차적으로 늘려가며 입력 데이터의 특징 추출을 수행하는 동시에 신호의 길이를 줄여나간다.

Fig. 4는 제안한 CAER 신경망의 압축과 복원 과정이다. CAER 신경망은 앞선 합성곱 신경망 구조에 ResNet의 알고리즘을 적용하였다. 또한 계산량 감소를 위해 average pooling을 수행하는 합성곱층을 Mid Block에추가하여 신경망을 정의하였다.

ResNet은 기울기 소실(gradient vanishing) 문제를 피하며 더 깊은 신경망을 구성하기 위해 고안된 구조이다[9]. 신경망은 예측 값과 실제 값의 오차를 계산하여 역전파(back propagation)를 통해 신경망의 출력 층부터입력 층 순으로 가중치를 수정하며 학습을 진행한다. 이때 가중치에 대해 미분의 연쇄 법칙(chain rule)을 이용하여 계산한 기울기 벡터(gradient vector)를 통해 각층(layer)의 가중치를 수정한다[10]. 하지만 신경망의 깊

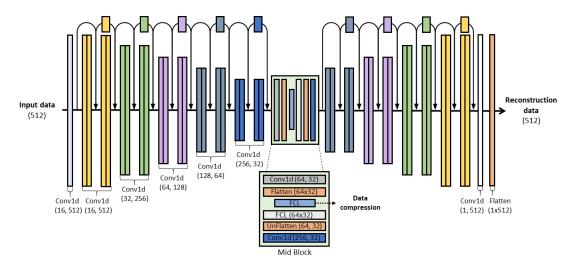


Fig. 4. Compression and reconstruction process based on CAER(Convolutional AutoEncoder + ResNet) neural network

이가 깊어질 경우 역전파를 통해 전달되는 기울기 벡터의 값이 0이 되어 학습이 제대로 진행되지 않는 기울기소실 문제가 발생한다. ResNet은 이러한 문제를 Fig. 5와 같은 shortcut을 통해 해결하였다. Shortcut은 일정 개수의 층을 건너 출력에 더해줄 수 있도록 한다. 이러한 구조는 신경망 학습이 더 쉽게 이루어지며 역전파시 기울기가 쉽게 전달되도록 한다. 다만 Shortcut 통과한 데이터와 그렇지 않은 데이터의 사이즈가 동일하지 않을 경우, shortcut 경로에 합성곱층을 추가하여 데이터 사이즈를 일치시켜주어야 한다.

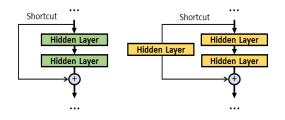


Fig. 5. Shortcut method in ResNet

CAER 신경망은 shortcut을 적용하여 많은 합성곱층으로 구성이 가능하도록 하였다. 앞선 합성곱 신경망과유사하게 압축, 복원을 수행하지만 더 많은 층으로 입력데이터의 특징을 추출한다. 계산량 감소를 위해 Mid Block 내의 average pooling 합성곱층을 이용하여 압축 전 채널 수를 줄여주었다. 또한 Mid Block의 마지막하나의 합성곱층을 통해 Mid Block 이전의 채널 수로확장시켜 복원 과정의 계산량을 줄여주었다.

2.2 실험 방법

본 연구에서는 PCA와 3가지 신경망의 압축 성능을 비교를 위해 신호의 길이가 512인 입력 데이터에 대하여 각각 75%(128/512), 87.5%(64/512), 93.75%(32/512)의 압축률로 압축과 복원을 수행하였다. 신경망은 잡음과 피크를 포함한 모의실험 데이터로 학습하였다.

원본 데이터와 복원 데이터를 MSE(Mean Square Error) 와 피어슨 상관 계수(Pearson correlation coefficient)를 통해 성능을 비교하였다.

2.1.1 데이터 구성과 학습 방법

학습 데이터셋의 다양성을 위해 Fig. 6 (a)와 같은 좌우 반전한 라만 스펙트럼과 Fig. 6 (b)의 모의실험 데이터로 구성하였다.

모의실험 데이터는 일반적인 스펙트럼 데이터의 피크와 배경잡음을 참고하여 묘사하였다. 모의실험 데이터는 너비가 5에서 31인 피크를 8개에서 16개를 포함하도록 랜덤하게 생성하였다. 배경잡음은 전체 데이터의 구간 내에 무작위로 생성된 위치와 크기를 가진 7개의 점을 cubic spline 보간법으로 매끄럽게 곡선으로 연결하여 최대 7차 다항식을 묘사하고, 상하좌우로 반전하여 다양한 형태를 표현할 수 있도록 하였다. 생성한 피크와 배경잡음의 비를 0.9 이상으로 설정하여 배경잡음이 모의실험 데이터에 미치는 영향을 최소화하였다.

총 45,000개의 데이터를 생성하여 신경망 학습, 검증, 테스트 데이터로 사용하였다. 모든 데이터에 대해 최솟값을 0, 최댓값을 1, 나머지 다른 값들은 0에서 1 사이의

값으로 변환하는 최소-최대 정규화 방법(min-max normalization)을 적용하였다.

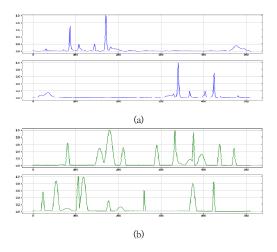


Fig. 6. Examples of training data

(a) Raman spectrum (b) Simulation data

학습은 0.0005의 학습률로 최대 3,000회의 epoch로 진행하였으며, validation loss가 최소가 되는 epoch와 loss 값을 저장하여 이 후 75회의 epoch동안 최소 loss 값을 갱신하지 못할 경우 마치도록 하였다.

2.1.2 CAER 신경망 구성

CAER 신경망은 Table 1과 같이 구성하였다. 입력 데 이터의 채널 수를 첫 합성곱층를 통해 16개로 확장시킨

Table 1. Structure of CAER neural network

	Layer type	Output shape	# of Layers
	Conv1d×1	16×512	1
	Conv1d×2	16×512	6
		32×256	6
Encoding		64×128	5
Layer		128×128	4
		256×64	3
	Conv1d×1	32×64	1
	Flatten×1	2048	1
Mid	FCL×1	Target Size	1
Layer	FCL×1	2048	1
	Unflatten×1	32×64	1
	Conv1d×1	256×64	1
Decoding Layer	Conv1d×2	128×128	4
		64×128	5
		32×256	6
		16×512	6
	Conv1d×1	1×512	1
	Flatten×1	512	1

다. 인코더에 해당하는 합성곱층을 통해 채널 수를 16부터 256까지 순차적으로 늘리며 512의 신호 길이를 256, 128, 128, 64순으로 줄인다. 256개의 채널을 mid Block의 합성곱층에서 32개로 감소시킨다. 다음 완전연결층을 통해 지정한 압축률로 압축을 수행한다. 복원을위해 Mid block의 합성곱층으로 채널 수를 256개로 확장시킨 후 디코더의 합성곱층으로 채널 수를 다시 순차적으로 줄이며 신호의 길이는 늘려 복원을 수행한다.

2.3 실험 결과

원본 데이터와 복원 데이터의 오차 비교를 위해 MSE 를 적용하였으며, 두 데이터의 유사도(similarity)를 비교 위해 피어슨 상관 계수를 이용하였다.

$$r = \frac{\sum_{i}^{n} (x_{i} - \overline{x})(y_{i} - \overline{y})}{\sqrt{\sum_{i}^{n} (x_{i} - \overline{x})^{2}} \sqrt{\sum_{i}^{n} (y_{i} - \overline{y})^{2}}}$$
 (3)

Where, x_i , y_i denote sample values indexed with i, \overline{x} , \overline{y} denote means of x, y, n denotes sample size

피어슨 상관계수는 두 샘플의 공분산을 각 샘플의 표준 편차의 곱으로 나누어 구할 수 있다. 상관계수 r은 +1과 -1사이의 값을 가진다. 1은 양의 선형 상관관계, -1은 음의 선형 상관관계를 나타내며 0은 두 데이터의 선형 상관관계가 없음을 나타낸다[11].

Table 2와 Tabel 3은 각각 모의실험 데이터를 적용하여 압축 후 복원을 수행한 데이터와 원본 데이터간의 MSE와 피어슨 상관 계수를 출력한 표이다.

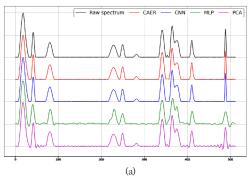
Table 2. MSE between simulation data and reconstruction data.

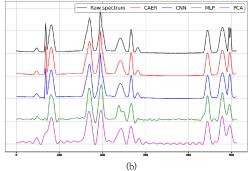
	Compression rate (%)		
	75	87.5	93.75
PCA	0.3227	1.7319	6.1154
MLP (Multi-Layer Perceptron)	1.4336	1.4860	3.8483
CNN (Convolutional Neural Network)	0.0026	0.0342	0.7083
CAER	0.0014	0.0024	0.0480

Table 3. Pearson correlation between simulation data and reconstruction data

	Compression rate (%)		
	75	87.5	93.75
PCA	0.9907	0.9502	0.8166
MLP	0.9596	0.9579	0.8884
CNN	0.9999	0.9990	0.9806
CAER	0.9999	0.9999	0.9983

합성곱층 기반 신경망이 모든 압축률에서 압축 성능이 PCA에 비해 우수한 것을 확인하였다. PCA를 기준으로





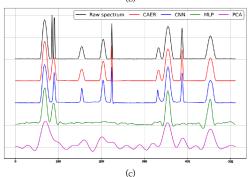


Fig. 7. Worst performance results by compression rate of simulation data
(a) 75% (128/512) (b) 87.5% (64/512) (c) 93.75% (32/512)

하여 합성곱 신경망과 CAER 신경망의 압축률별 오차 감소율을 계산한 후 평균하였을 때, 합성곱 신경망은 평균 95.2%, CAER 신경망은 평균 99.5%의 오차 감소를 보였다. CAER 신경망은 합성곱 신경망보다 평균 77.4%의 낮은 오차를 보인다.

Fig. 7은 PCA와 신경망을 통하여 모의실험 데이터 압축 후 복원한 결과이다. 압축 신경망은 가장 성능이 떨어지는 결과에서도 오차가 크게 발생하지 않아야 실제 데이터 압축에 적용이 가능하다. 이를 확인하기 위해 CAER 신경망의 피어슨 상관 계수가 가장 낮은 복원 데이터를 기준으로 출력하였다.

PCA와 다층퍼셉트론은 압축률이 높아질수록 정보 손실로 인해 복원되는 피크의 수가 감소하며 복원된 피크에서도 큰 오차가 발생한다. 반면 합성곱 신경망과 CAER 신경망의 경우 오차는 발생하지만 원본 데이터와 유사하게 복원이 가능하다.

Table 4와 Tabel 5는 실제 라만 스펙트럼을 적용하여 압축 후 복원을 수행한 데이터와 원본 데이터간의 MSE와 피어슨 상관 계수를 출력한 표이다.

라만 스펙트럼은 총 7가지 화학물질 1,2-dichloroethane (1,2-DCA), 2,6-dinitrotoluene(2,6-DNT), Acetone, Ammonium dinitramide(ADN), Ammonium Perchlorate(AP), Benzene, Octahydro-1,3,5,7-tetranitro-1,3,5,7-tetrazocine(HMX)을 측정하여 사용하였다. 레이저 전력을 $1.0m\ W$ 이하로 유지하여 측정하였으며 측정 과정에서 홀로그래픽 노치 필터를 사용하여 Rayleigh 라인을 제거하였다.

Table 4. MSE between Raman spectrum and reconstruction data

	Compression rate (%)		
	75	87.5	93.75
PCA	0.3494	1.0704	1.9095
MLP	0.8449	0.8731	1.6143
CNN	0.0373	0.0889	0.3373
CAER	0.0191	0.0458	0.1485

Table 5. Pearson correlation between Raman spectrum and reconstruction data

	Compression rate (%)		
	75	87.5	93.75
PCA	0.9517	0.8501	0.7222
MLP	0.8892	0.8824	0.7713
CNN	0.9963	0.9899	0.9603
CAER	0.9974	0.9943	0.9817

라만 스펙트럼에 적용한 경우 모의실험 데이터의 결과에 비해 전체적으로 오차가 증가하고 유사도는 감소하였다. PCA의 오차에 비해 합성곱 신경망은 평균 87.8%, CAER 신경망은 평균 94.2%만큼 오차가 감소하였다. 또한 CAER 신경망은 합성곱 신경망에 보다 평균 66.4% 낮은 오차로 복원이 가능하다.

Fig. 8은 PCA와 신경망을 통해 라만 스펙트럼을 압축 후 복원 했을 때 CAER 신경망의 피어슨 상관 계수가 가장 낮은 복원 데이터이다.

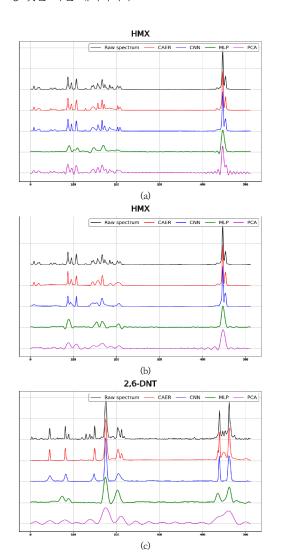


Fig. 8. Worst performance results by compression rate of Raman spectrum
(a) 75% (128/512) (b) 87.5% (64/512) (c) 93.75% (32/512)

모의실험 데이터와 라만 스펙트럼에 대해 CAER 신경 망이 모든 압축률에서 가장 뛰어난 압축 성능을 보인다. 그 다음으로 우수한 압축 성능을 보이는 합성곱 신경망과 CAER 신경망의 자세한 비교를 위해 Fig. 9를 출력하였다.

Fig. 9는 Fig. 8 (c)에서 합성곱 신경망과 CAER 신경 망의 압축 후 복원 결과이다. 합성곱 신경망은 피크의 높이에 관계없이 오차를 보이거나 복원이 제대로 이루어지지 않았다. 반면 CAER 신경망은 주로 높이 0.2 이하의 피크에서 주로 오차가 발생한다. 이는 라만 스펙트럼에 더욱 유사한 모의실험 데이터를 구현하여 신경망 학습에 적용할 경우 신경망의 압축 성능이 더욱 향상될 것으로보인다.

압축과 복원에 많은 시간이 요구될 경우 실제 스펙트럼 압축에 적용하기 어려우므로 압축과 복원까지의 소요시간을 비교하였다. Table 6은 각 기법의 압축률별 압축과 복원까지의 소요시간을 나타낸 표이다. 120,000개의모의실험 데이터에 대해 압축과 복원을 수행하였으며, 압축률별로 5회씩 측정하여 소요 시간을 평균 내었다.

Table 6. Time require for compression and reconstruction by compression ratio

	Compression rate (%)	Time (sec.)
PCA	75	0.6231
	87.5	0.6033
	93.75	0.5596
MLP	75	0.8127
	97.5	1.0677
	93.75	1.0647
CNN	75	1.0389
	87.5	1.0705
	93.75	1.0450
CAER	75	5.5648
	87.5	5.6383
	93.75	5.6098

CAER 신경망이 가장 많은 시간이 소요되지만, 데이터의 개수와 압축 성능을 고려하였을 때 길지 않은 시간이라고 판단되므로 스펙트럼 데이터 압축에 무리 없이적용 가능할 것으로 보인다.

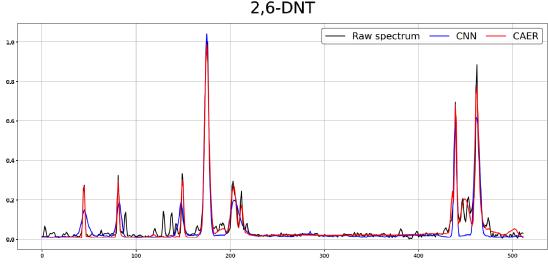


Fig. 9. 2.6 DNT Raman spectrum compression and reconstruction result of CNN and CAER (93.75% compression rate)

3. 결론

본 논문은 합성곱 오토인코더 구조 기반 스펙트럼 데이터 압축 신경망을 제안하였다. 제안한 신경망은 합성곱 층과 ResNet의 알고리즘을 오토인코더의 구조에 적용하였으며 기존 데이터 압축에 주로 사용되는 PCA와 비교 분석하였다. 또한 오토인코더 구조의 다층퍼셉트론과 합성곱 신경망을 구성하여 제안한 신경망의 성능 비교에 활용하였다.

신경망 학습은 라만 스펙트럼을 묘사한 모의실험데이 터를 이용하여 수행하였다. 학습한 신경망을 통해 데이터 의 압축과 복원 과정을 수행하여 MSE와 피어슨 상관 계 수를 통해 압축 성능을 비교하였다.

모의실험 데이터에서 PCA와 다층퍼셉트론은 압축률이 높아질수록 오차가 비약적으로 증가하는 반면 합성곱 신경망과 제안한 신경망은 큰 오차 없이 복원이 가능하다. 제안한 신경망은 PCA에 비해 평균 99.5%로 오차가 감소하며, 합성곱 신경망보다 77.4% 낮은 오차를 보여준다.

라만 스펙트럼을 적용했을 경우 제안한 신경망은 PCA에 비해 94.2% 합성곱 신경망에 비해 66.4% 낮은 오차를 보인다. 실험 결과를 통해 제안한 신경망은 스펙트럼 데이터 압축에 유용하게 적용될 것으로 판단된다. 연구 결과를 바탕으로 압축 효율을 더욱 높이기 위해 스펙트럼의 잡음을 제거하며 압축을 수행하는 신경망에 관한 연구를 진행 중이다.

References

- [1] D. A. Long, Raman Spectroscopy. In The characterization of chemical purity: Organic Compounds, p.173, Butterworth, 1971, pp. 149-161 DOI: http://dx.doi.org/10.1016/B978-0-408-70145-7.50015-6
- [2] D. L. Pavia, G. M. Lampman, G. S. Kriz, J. R. Vyvyan, Introduction to Spectroscopy 5th Edition, p. 786, CENGAGE Learning, 2014, pp. 14-87
- [3] D. J. Gardiner, Introduction to Raman Scattering. In Practical Raman Spectroscopy, p.157, Springer, 1989, pp.1-12
 DOI: https://dx.doi.org/10.1007/978-3-642-74040-4_1
- [4] D. W. Shipp, F. Sinjab, I. Notingher, "Raman spectroscopy: techniques and applications in the life sciences", Advanced in Optics and Photonics, Vol.9, No.2, pp.315-428, 2017. DOI: http://dx.doi.org/10.1364/AOP.9.000315
- [5] H. Abdi, L. J. Williams, "Principal component analysis", Wiley Interdisciplinary Reviews: Computational Statistics, Vol.2, No.4, pp. 433-459, 2010. DOI: http://dx.doi.org/10.1002/wics.101
- [6] S. K. Kim, D. Y. Ko, J. k. Park, A. R. Park, S. J. Baek, "A Hierarchical Cluster Tree Based Fast Searching Algorithm for Raman Spectroscopic Identification", *Journal of the Korea Academia-Industrial cooperation Society*, Vol.20, No. 3, pp.562-569, 2019. DOI: http://doi.org/10.5762/KAIS.2019.20.3.562
- [7] M. W. Gardner, S.R. Dorling, "Artificial neural networks(the multilayer perceptron)-a review of applications in the atmospheric sciences", *Atmospheric environment*, Vol.32, No.14-15, pp.2627-2636, 1998. DOI: http://dx.doi.org/10.1016/S1352-2310(97)00447-0

- [8] S. Albawi, T. Mohammaed, S. Al-Zawi. "Understanding of a convolutional neural network", 2017 International Conference on Education and Technology (ICET), IEEE, Antalya, Turkey, pp.1-6, August 2017. DOI: http://dx.doi.org/10.1109/ICEngTechnol.2017.8308186
- [9] K. He, X. Zhang, S. Ren, J. Sun, "Deep residual learning for image recognition", 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, Las Vegas, USA, pp.770-778, June 2016. DOI: http://dx.doi.org/10.1109/CVPR.2016.90
- [10] Y. LeCun, Y. Bengio, G. Hinton, "Deep learning", Nature, Vol. 521, No. 7553, pp.436-444, 2015. DOI: http://dx.doi.org/10.1038/nature14539
- [11] J. Benesty, J. Chen, Y. Huang, I. Cohen, Pearson Correlation Coefficient. In Noise Reduction in Speech Processing, p.229, Springer, 2009, pp. 37-40 DOI: http://dx.doi.org/10.1007/978-3-642-00296-0_5

박 아 론(Aaron Park)

[정회원]



- 2006년 2월 : 전남대학교 전자컴 퓨터정보통신공학부(공학학사)
- 2008년 2월 : 전남대학교 전자공 학과(공학석사)
- 2012년 2월 : 전남대학교 전자공 학과(공학박사)

〈관심분야〉 디지털 신호처리, 패턴인식, 바이오 응용 패턴 인식, 특징 추출/선택

손 성 재(SeongJae Son)

[준회원]



- 2020년 2월 : 전남대학교 신소재 공학부 (공학학사)
- 2020년 3월 ~ 현재 : 전남대학교 ICT융합시스템공학과 (석사과정)

〈관심분야〉 딥러닝, 패턴인식, 디지털 신호처리

백 성 준(Sung-June Baek)

딥러닝, 패턴인식, 디지털 신호처리

[정회원]



〈관심분야〉

- 1989년 2월 : 서울대학교 전자공 학과(공학사)
- 1992년 2월 : 서울대학교 전자공 학과(공학석사)
- 1999년 2월 : 서울대학교 전자공 학과(공학박사)
- 2002년 3월 ~ 현재 : 전남대학교
- ICT융합시스템공학과 교수

진 철 군(Tiejun Chen)

[준회원]



- 2020년 2월 : 전남대학교 전자컴 퓨터공학부(공학사)
- 2020년 3월 ~ 현재 : 전남대학교 ICT융합시스템공학과(석사과정)

〈관심분야〉 디지털 신호처리, 패턴인식, 딥러닝 및 기계 학습