

딥러닝 기술을 위한 시뮬레이션 스펙트럼 데이터 생성 방법

손영재, 진철균, 손성재, 백성준*
전남대학교 ICT 융합시스템공학과

Simulation Data Generation Method of Spectrum Data for Deep Learning Technology

YoungJae Son, Tiejun Chen, SeongJae Son, Sung-June Baek*
Dept. of ICT Convergence System Engineering, Chonnam University

요약 최근 분광법(Spectroscopy)의 적용 분야가 확대됨에 따라 다양한 분석법이 제안되고 있고, 그중에서도 딥러닝 기술을 이용한 신호 처리가 활발히 연구되고 있다. 딥러닝 기술을 이용한 신호 처리는 방대한 양의 데이터가 요구되는데 실제 데이터의 수집은 비용적, 시간적 측면에서 어려움이 존재하기 때문에 다양한 시뮬레이션 데이터 생성 방법이 제시되었다. 일반적으로 사용되는 시뮬레이션 데이터 생성 방법에는 커널 함수와 다항식을 이용하는 방법과 실제 데이터를 이용한 데이터 증강법(Data Augmentation)이 있다. 커널 함수와 다항식을 이용한 방법은 단순 다항식으로 표현되지 않는 실제 분광 신호 처리에 어려움이 존재하고, 데이터 증강법은 이용되는 실제 데이터에 따라 성능이 크게 좌우되는 단점이 있다. 이러한 문제점을 개선하기 위해 본 연구에서는 해닝 윈도우(Hanning window)와 Cubic Spline 보간법 등을 이용하여 가상 분광 스펙트럼 데이터를 생성하는 방법을 제안하였다. 기존 데이터 생성 방법들과의 성능 비교를 위해 배경잡음을 검출하는 딥러닝 모델을 사용하여 원본 데이터와 배경 잡음이 제거된 데이터 간 오차를 비교하였다. 제안된 생성 방법은 커널 함수와 다항식을 이용한 생성 방법 및 데이터 증강법에 비해 각각 29.9%, 86.8%의 성능 향상을 보였으며, 실제 분광 신호 데이터에서도 효과적으로 적용될 수 있음을 확인하였다.

Abstract With the recent expansion of the application of spectroscopy, various methods of analysis have been proposed, among which signal processing using deep learning technology is being actively studied. Signal processing using deep learning technology requires a huge amount of data, and the collection of actual data is a challenge in terms of cost and time. Thus, various simulation data-generation methods have been proposed. Commonly used methods of generating simulation data include using kernel functions and polynomials, as well as data augmentation using real data. Methods using kernel functions and polynomials have a disadvantage of difficulties in the processing of the actual spectroscopic signal, which is not expressed as a simple polynomial. The data augmentation method has the disadvantage of the performance being largely dependent on the actual data used. To remedy this problem, this study proposes a method of generating virtual spectral data using a Hanning window and Cubic Spline interpolation. For performance comparison with existing data-generation methods, a deep learning model that detects background noise was used to compare the error between the original data and the data with background noise removed. The proposed generation method showed performance improvements of 29.9% and 86.8% compared to the generation method using kernel functions and polynomials and the data augmentation method, respectively. It was confirmed that the method can be effectively applied to actual spectroscopic signal data.

Keywords : Spectrum Generation, Deep Learning, Raman Spectrum, Baseline Correction, Signal Process

본 논문은 교육부 및 한국연구재단의 4단계 BK21사업(혁신인재 양성사업)으로 지원된 연구임. (관리번호 5199991714138)

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

email: tozero@jnu.ac.kr

Received July 20, 2022

Accepted October 7, 2022

Revised August 22, 2022

Published October 31, 2022

1. 서론

분광법에서 피크는 물질의 물리·화학적 특성과 같은 고유한 정보를 지니고 있으며, 종류에 따라 가산 잡음, 배경 잡음 등이 존재하므로 관련된 신호 처리가 필수적이다. 최근 분광법은 물질의 화학분석뿐만 아니라 생물학, 의학 등의 정보 분석으로 적용 분야가 확대되고 있어 더욱 정밀한 신호 처리가 요구된다[1-3]. 딥러닝 기술은 이러한 요구를 위해 적합하지만 방대한 데이터가 필요하므로 훈련에 필요한 만큼 이를 수집하기에 어려운 점이 많다. 이 문제를 해결하기 위해 최근에 실제 스펙트럼 데이터가 아닌 시뮬레이션 스펙트럼 데이터를 생성해서 사용하는 방법이 연구되었다.

시뮬레이션 스펙트럼 데이터 생성에는 대표적으로 두 가지 방법이 최근에 제안되었다. 첫 번째 방법은 커널 함수를 이용하여 피크를 생성하고, 배경 잡음을 다항식으로 모델링한 다음 이를 더해서 시뮬레이션 스펙트럼을 만드는 것이다[3-5]. 이 방법에서는 로렌츠 커널 함수와 가우시안 커널 함수를 결합하여 구성한 커널 함수를 사용하였고, 배경 잡음은 다항식을 이용하여 생성하였다. 그런데 다항식으로 생성된 배경 잡음은 실제 데이터에서 드러나는 다양한 양상의 배경 잡음을 표현하는 데 어려움이 있다. 두 번째 방법은 데이터 증강법을 이용하는 방법인데, 실제 데이터의 특징(Feature)을 추출하여 이를 다양한 방법으로 변형하여 데이터를 생성하는 것이다 [6]. 적은 양의 실제 데이터를 이용하여 다량의 데이터를 만들 수 있다는 장점이 있지만, 데이터의 다양성이 적어 데이터 과적합(overfitting)이 일어날 수 있으며, 또 실제 데이터에 따라 성능이 크게 좌우된다는 단점을 지니고 있다.

본 연구에서는 이러한 문제점을 극복하고자 해닝 윈도우와 Cubic Spline 보간법을 사용한 시뮬레이션 스펙트럼 데이터 생성법을 제안한다. 해닝 윈도우를 사용하여 피크를 생성하면 기존 커널 함수에 비해 배경 잡음에 영향을 주지 않으므로 피크 생성이 간편해지고, Cubic Spline 보간법을 사용하면 기존의 다항식의 배경 잡음보다 더욱 복잡한 배경 잡음을 표현할 수 있다. 이에 더해 피크를 모델링할 때 실제 스펙트럼 데이터의 피크 분포를 따라가도록 해 실제 데이터와 더욱 가깝도록 시뮬레이션 스펙트럼 데이터가 생성하였다.

본 논문의 구성은 다음과 같다. 2장에서는 기존에 제안된 시뮬레이션 스펙트럼 생성법 두 가지와 본 논문에서 제안한 생성법을 설명한다. 3장에서는 각 방법에 의해 생성된 시뮬레이션 스펙트럼과 실제 스펙트럼에 배경

잡음 처리 기법을 적용하여 오차를 비교하였고, 이를 통해 본 논문에서 제안한 방법의 성능을 평가하였다. 4장에서는 앞선 내용과 결과를 요약하여 본 논문을 마무리한다.

2. 데이터 생성

2.1 커널 함수와 다항식을 이용한 방법

커널 함수와 다항식을 이용한 시뮬레이션 스펙트럼 생성 방법에서는 스펙트럼에서 나타나는 피크를 커널 함수를 이용하여 생성한다. 이 방법에서는 아래의 식과 같이 로렌츠 커널 함수(Lorentz Kernel Function)와 가우시안 커널 함수(Gaussian Kernel Function)를 결합하였고, 이를 무작위로 배치하여 피크 데이터 g 를 생성한다[7].

$$g(x) = \sum_{i=1}^m \frac{2A_i}{\pi} \frac{w_i}{4(x-x_i)^2 + w_i^2} + \sum_{j=1}^n A_j \exp\left(-\frac{(x-x_j)^2}{2\sigma^2}\right) \quad (1)$$


Where n, m denote number of peaks and A denotes peak height and w, σ denote peak width and x_i denotes peak position.

배경 잡음 b 는 아래 식과 같이 n 차 다항식으로 묘사한다.

$$b(x) = a_0x^n + a_1x^{n-1} + \dots + a_{n-2}x + a_{n-1} \quad (2)$$

Where a_n denotes uniformly distributed random variables.

최종 시뮬레이션 스펙트럼은 피크 g 와 배경 잡음 b 를 더한 다음 가우시안 잡음(Gaussian noise)을 첨가하여 Fig. 1과 같이 생성하였다.



(a)

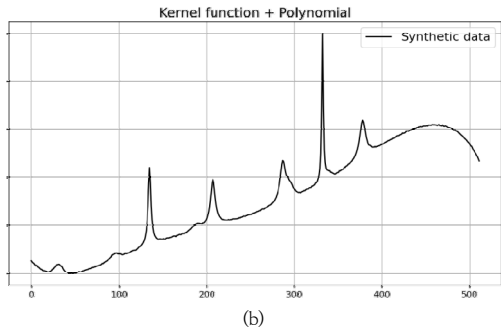


Fig. 1. Simulation data using kernel function and polynomials
(a) Peak and baseline data (b) Synthetic data

2.2 데이터 증강법 (Data Augmentation)

데이터 증강법은 적은 양의 실제 데이터의 특징을 다양한 알고리즘을 적용해 변형하고 다량의 데이터를 생성하는 기법이다. 이 연구에서는 피크 데이터를 생성하기 위해 실제 데이터의 피크를 하나씩 직접 추출 (Cropping) 낸다. 추출한 피크에 다양한 필터를 적용하여 피크의 양 옆 부분을 평평하게 변환하고, 가산 잡음 등을 제거한다. 이 과정을 거쳐 여러 개의 피크를 저장하여 일종의 피크 라이브러리를 만들고, 무작위로 배치하여 피크 데이터를 생성한다.

배경 잡음은 실제 스펙트럼 데이터에 임의의 임계값 (Threshold)을 정하고 임계값보다 큰 값들을 일정한 값으로 변환한다. 이후 가우시안 필터, 이동평균(Moving average) 필터 등을 적용하여 매끄럽게 곡선으로 처리한다. 마지막으로 다양한 양상의 배경 잡음 데이터를 얻기 위하여 다음 식을 적용하였다.

$$B(x) = \sum_{k=1}^n a_k (b_k(x))^k \quad (3)$$

Where n denotes random number between 1 and 10, a_k denotes uniformly distributed random variables between [0, 1], b_k denotes the selected smooth curve

위 식을 거쳐 복잡한 구조를 가진 여러 개의 배경 잡음 B 를 얻을 수 있으며, 실제 데이터의 개수와 양상에 따라 성능에 차이를 보인다[8]. 최종 시뮬레이션 스펙트럼은 앞선 방법과 마찬가지로 생성된 피크와 배경 잡음을 결합한 다음 가우시안 가산 잡음을 첨가하여 Fig. 2와 같이 생성하였다.

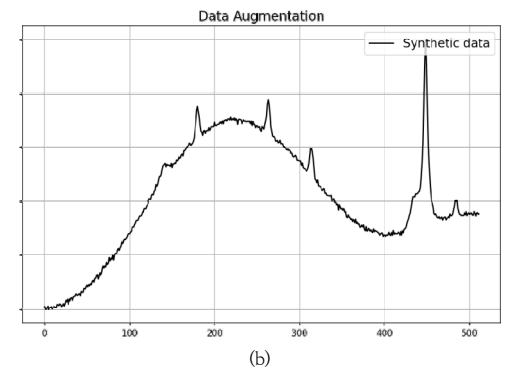
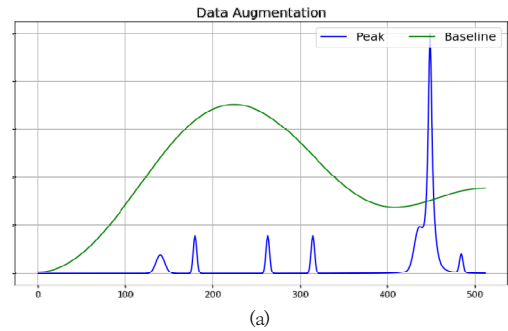


Fig. 2. Simulation data using data augmentation
(a) Peak and baseline data (b) Synthetic data

2.3 제안한 데이터 생성 방법

본 논문에서는 피크를 모델링할 때 해닝 윈도우를 사용하였다. 커널을 이용하는 방법에서는 피크가 전역적으로 모델링되어 성능에 영향을 줄 수 있으므로 이를 피하기 위해 해닝 윈도우를 사용하였다.

피크를 생성할 때 폭과 개수는 무작위로 선택하였는데, 앞의 방법들과 달리 피크의 위치와 높이를 정할 때 실제 데이터에서 나타나는 경향성을 반영하였다. 실제 스펙트럼을 살펴보면 피크의 위치는 전 구간에서 균일하게 분포되어 있지 않고, 일정 구간에 편중되어 존재한다. 이를 묘사하기 위해 피크가 존재하는 영역을 1-3구간을 임의로 선택하였다. 피크의 크기도 실제 데이터의 경향성을 반영하기 위해 큰 피크가 작은 피크의 크기에 일정한 비율을 적용하였다.

기존 다항식을 이용하여 배경 잡음을 모델링 하는 경우 실제 스펙트럼에서 나타나는 다양한 배경 잡음을 적절히 처리하지 못한다는 단점이 존재한다. 이 문제를 해결하기 위해 본 연구에서는 임의의 위치와 크기를 가진 점을 먼저 생성한 다음 이를 Cubic Spline 보간법을 이용하여 매끄럽게 곡선으로 연결하여 배경 잡음을 모델링했다. 이는 다항식으로 모델링 된 그래프와 비슷한 모습

을 보이지만 Cubic Spline 보간법은 점과 점 사이를 연결할 때 3차 다항식을 이용하여 연결하기 때문에 단순 다항식보다 매우 복잡한 형태의 배경 잡음을 모델링할 수 있다. 최종 시뮬레이션 스펙트럼은 생성된 피크와 배경 잡음을 결합한 다음 가우시안 가산 잡음을 첨가하여 Fig. 3과 같이 생성하였다.

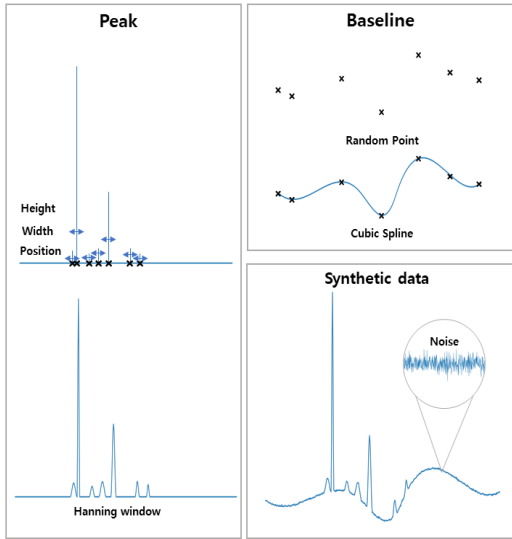


Fig. 3. Simulation data using hanning window and cubic spline

3. 성능 평가

3.1 실험 방법

본 실험에서는 커널 함수와 다항식을 이용한 방법(이하 커널 다항식 방법)의 경우에 두 가지 커널 함수를 이용하여 피크를 5개에서 15개를 생성하여 무작위로 배치

하였다. 배경 잡음은 7차 다항식으로 구성하여 다양한 형태를 표현할 수 있도록 하였다.

데이터 증강법에서는 추출한 피크를 가우시안 필터로 전처리하고 5개에서 15개의 피크를 임의로 배치하였다. 배경 잡음은 실제 데이터에 임의의 임계값을 두고, 가우시안 필터와 이동 평균 필터를 랜덤으로 사용하여 다양한 곡선 데이터를 생성하여 Eq. (3)에 적용하였다.

제한한 방법에서는 해닝 윈도우를 사용하여 실제 데이터의 경향성을 반영하여 5에서 21 사이에 너비를 가지는 피크를 생성하였다. 생성된 피크는 5개에서 15개의 피크를 1-3구간의 영역을 임의로 선택하여 배치하였다. 배경 잡음은 임의의 위치와 크기를 가진 점을 7개 생성하고 Cubic Spline 보간법을 이용해 생성하였다.

기존 데이터 생성 방법 두 가지와 본 논문에서 제시한 데이터 생성 방법으로 각각 80,000개의 데이터를 생성하여 각 70,000개의 학습 데이터 3개를 구성하였다. 각 10,000개의 데이터는 합하여 총 30,000개의 동일한 테스트 데이터를 구성하여 3개의 데이터 세트를 생성하였다. 모든 데이터의 값은 최소-최대 정규화를 거쳐 0과 1 사이의 값으로 변환하였다.

각 데이터 생성 방법의 성능은 동일한 딥러닝 모델과 테스트 데이터를 이용하여, MSE(Mean Square Error)를 통해 비교하였다. 딥러닝 모델은 ResNet 기반의 DRCNN(Deep Residual CNN)을 사용하였다. DRCNN은 스펙트럼의 배경 잡음과 가산 잡음을 검출하기 위한 모델로 Fig. 4와 같이 10개의 합성곱 층과 18개의 Res-Block을 포함한다. 본 실험에서는 피크와 배경 잡음의 성능 비교를 위해 배경 잡음만을 검출하여 진행하였다. 위 모델을 이용하여 0.00001의 학습률과 100회의 epoch으로 3개의 데이터 세트 각각 학습을 진행하였다 [7].

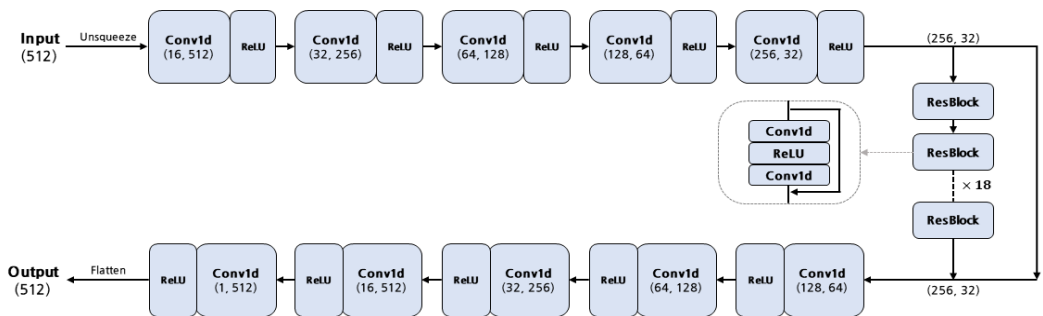


Fig. 4. The structure of DRCNN

3.2 실험 결과

기존에 일반적으로 사용되고 있는 두 가지 데이터 생성 방법과 본 논문에서 제안한 데이터 생성 방법을 여러 환경에 의해 생성된 테스트 데이터에서의 오차를 비교하여 Table 1에 나타내었다. 제안한 데이터 생성 방법이 가장 오차가 낮으며, 커널 함수와 다항식을 이용한 방법, 데이터 증강법 순으로 오차가 낮음을 확인할 수 있다.

Table 1. MSE Loss of model using each data generation method

Simulation Data Method	MSE Loss
Kernel function + Polynomial	0.000184
Data Augmentation	0.000974
Hanning window + Cubic Spline	0.000129

각 데이터 간의 정확한 성능 검증을 위하여 오차가 큰 상위 10%와 30%의 평균을 Table 2에 나타내었다. 두 오차 모두 제안한 방법이 상대적으로 낮으며, 이는 제안한 방법의 데이터가 기존 두 가지 생성 방법의 데이터를 훨씬 잘 포용할 수 있다는 것으로 해석할 수 있다.

Table 2. Top MSE Loss of model using each data generation method

Simulation Data Method	MSE Loss	
	Top 10%	Top 30%
Kernel function + Polynomial	0.000824	0.000504
Data Augmentation	0.005277	0.002754
Hanning window + Cubic Spline	0.000579	0.000327

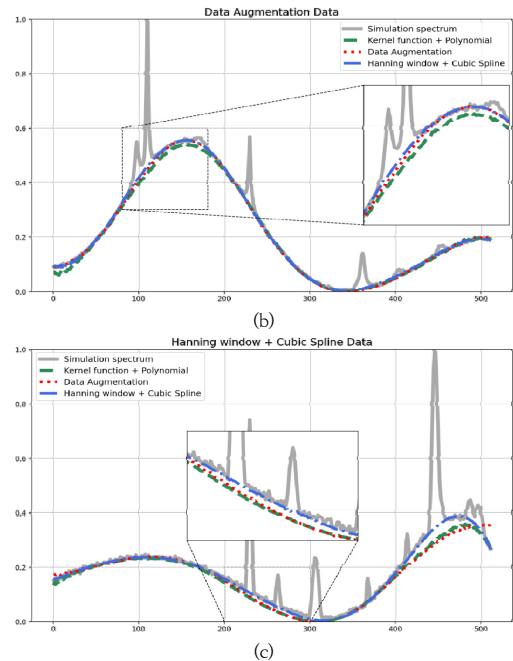
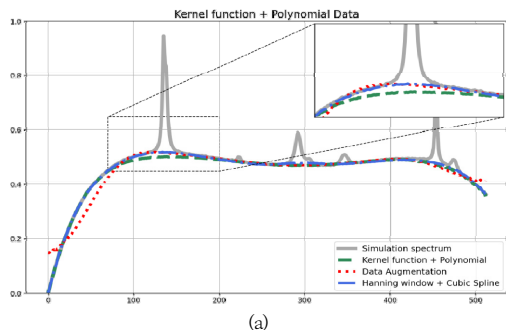


Fig. 5. Results of each data generation method for the generated data

(a) Kernel function and polynomial data (b) Data augmentation data (c) Hanning window and cubic spline data

세 방법으로 생성한 데이터를 임의로 하나씩 선정하여 각 모델에 적용하여 Fig. 5로 나타내었다. Fig. 5 (a)는 커널 함수와 다항식을 이용한 데이터를 각 데이터 생성 방법으로 분석한 그림이다. 확대 부분을 보면 커널 함수가 전역적으로 모델링되어 피크를 정확히 구분해 내지 못한 것을 확인할 수 있다. 데이터 증강법은 피크를 잘 구분하지만, 배경 잡음의 시작 부분과 끝부분에서 오차가 크게 발생하는 것을 볼 수 있다. 반면에 제안한 방법에서는 비교적 큰 오차 없이 해석된 것을 볼 수 있다.

Fig. 5 (b)는 데이터 증강법의 데이터를 각 데이터 생성 방법으로 분석한 그림이다. 커널 다항식 방법은 시작 부분에서 오차가 발생하고, 위와 마찬가지로 확대 부분에서 피크가 전역적으로 영향을 줘 피크 구역의 배경 잡음에서 오차가 발생하였다. 데이터 증강법과 제안한 방법에서는 큰 오차가 없었다.

Fig. 5 (c)는 제안한 방법의 데이터를 각 데이터 생성 방법으로 분석한 그림이다. 확대 부분을 보면 기존의 두 방법 모두 전체적으로 배경 잡음을 잘 검출하지 못하였다. 이는 Cubic Spline 보간법이 기존 방법의 배경 잡음에 비해 더욱 풍부한 구조를 지닌 곡선을 생성한다고 볼 수 있다.

실제 데이터에 적용을 위해 공개 데이터 사이트 RRUFF에서 실제 라만 스펙트럼 데이터를 수집하였고, Fluorellestadite, Beryl 데이터를 사용하여 실험을 진행하였다[9]. 실제 데이터에 각 방법을 이용해 배경 잡음을 검출한 결과를 Fig. 6-7에 나타내었다.

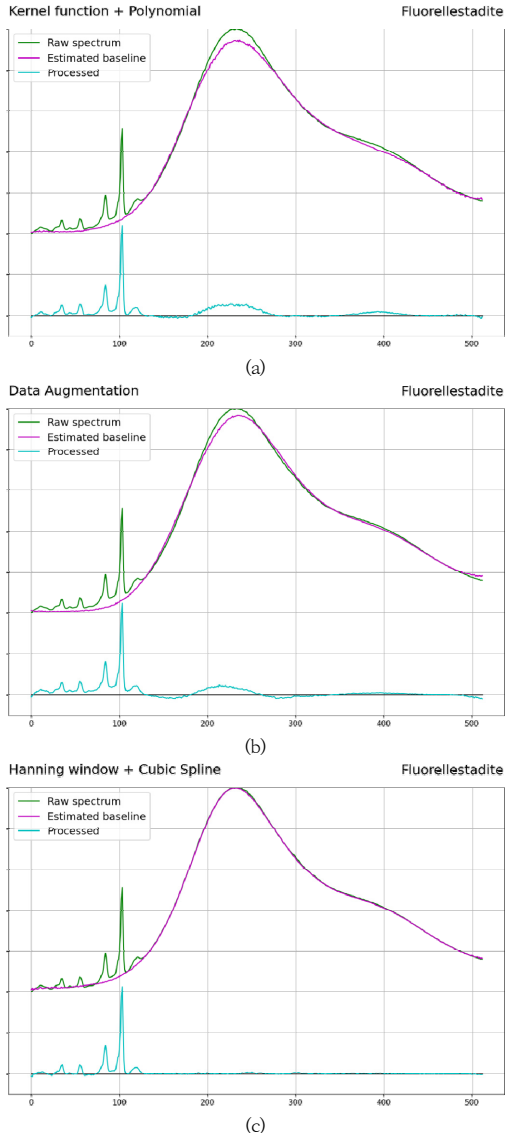


Fig. 6. The results of baseline of Raman spectrum by each data generation method (Fluorellestadite) (a) Kernel function and polynomial (b) Data augmentation (c) Hanning window and cubic spline

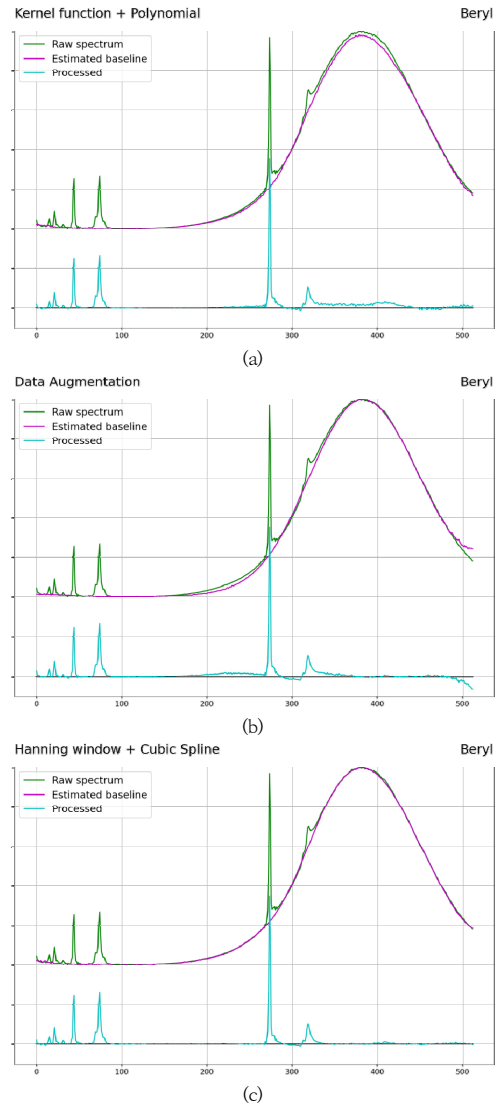


Fig. 7. The results of baseline of Raman spectrum by each data generation method (Beryl) (a) Kernel function and polynomial (b) Data augmentation (c) Hanning window and cubic spline

Fig. 6-(a), 7-(a)는 커널 다항식, Fig. 6-(b), 7-(b)는 데이터 증강법, Fig. 6-(c), 7-(c)는 본 논문에서 제안한 방법의 데이터를 이용해 실제 배경 잡음을 검출한 결과이다. 이 그림들을 보면 본 논문에서 제안한 방법이 기존 두 방법보다 비교적 배경 잡음을 잘 검출하는 것을 확인할 수 있다. 이 결과는 제안한 방법이 기존 방법에 비해 실제 분광 신호 처리에 효과적임을 보여주며, 딥러닝 기반 모델들에 적용하면 기존 데이터 생성 방법에 비해 성능을 개선할 수 있고, 더욱 효율적인 모델을 만들 수 있을 것으로 기대할 수 있다.

4. 결론

본 논문은 딥러닝 기술 적용을 위한 새로운 스펙트럼 데이터 생성 방법을 제안하였다. 제안한 데이터 생성 방법은 해닝 윈도우와 Cubic Spline 보간법, 가우시안 잡음을 적용하여 피크, 배경 잡음과 가산 잡음을 나타내었으며, 실제 라만 스펙트럼의 피크 양상을 파악하여 유사하게 피크를 배치하였다.

실험에서는 기존에 제안된 커널 다항식 방법과 데이터 증강법의 데이터를 각각 구성하여 학습 데이터셋을 구성하고, 각 방법으로 생성된 테스트 데이터를 합하여 테스트 셋트를 구성하였다. 각 방법의 성능은 배경 잡음을 검출하는 DRCNN 딥러닝 모델을 사용해 MSE를 통해 비교하였다. 제안한 생성 방법은 커널 다항식 방법에 비해 29.9%로 오차가 감소하였고, 데이터 증강법에 비해 86.8%로 낮은 오차를 보였다.

각 방법을 실제 라만 스펙트럼 데이터에 적용했을 경우 제안된 방법이 시각적으로도 더욱 정확한 배경 잡음 검출을 할 수 있음을 확인하였다. 이 실험 결과를 통해 제안된 방법이 딥러닝을 이용한 스펙트럼 신호 처리에 유용하게 사용될 수 있을 것으로 판단된다. 이를 바탕으로 스펙트럼 데이터의 잡음 제거, 데이터 압축, ROI 검출 등에 관한 연구를 진행할 계획이다.

References

- [1] H. Chen, W. Xu, N. Broderick, J. Han, "An adaptive denoising method for Raman spectroscopy based on lifting wavelet transform", *Journal of Raman Spectroscopy*, Vol.49, pp.1529-1539, June 2018. DOI: <https://doi.org/10.1002/jrs.5399>
- [2] S. Son, T. Chen, A. Park, S. Baek, "Spectrum Data Compression using ResNet-Convolutional AutoEncoder based Neural Network", *Journal of the Korea Academia-Industrial cooperation Society*, Vol.22, No.12 pp.135-143, 2021. DOI: <https://doi.org/10.5762/KAIS.2021.22.12.135>
- [3] K. Kong, C. Kendall, N. Stone, I. Notingher, "Raman spectroscopy for medical diagnostics From in-vitro biofluid assays to in-vivo cancer detection", *Advanced Drug Delivery Reviews*, Vol.89, pp.121-134, March 2015. DOI: <https://doi.org/10.1016/j.addr.2015.03.009>
- [4] Y. Hu, T. Jiang, A. Shen, W. Li, X. Wang, J. Hu, "A background elimination method based on wavelet transform for Raman spectra", *Chemometrics and Intelligent Laboratory Systems*, Vol.85, pp.94-101,

2007.

DOI: <https://doi.org/10.1016/j.chemolab.2006.05.004>

- [5] Z. Zhang, S. Chen, Y. Liang, Z. Liu, Q. Zhang, L. Ding, F. Ye, H. Zhou, "An intelligent background-correction algorithm for highly fluorescent samples in Raman spectroscopy", *Journal of Raman Spectroscopy*, Vol.41, pp.659-669, October 2009. DOI: <https://doi.org/10.1002/jrs.2500>
- [6] W. Li, C. Chen, M. Zhang, H. Li, Q. Du, "Data Augmentation for Hyperspectral Image Classification With Deep CNN", *IEEE Geoscience and Remote Sensing Letters*, Vol.16, No.4, pp.593-597, April 2019. DOI: <https://doi.org/10.1109/LGRS.2018.2878773>
- [7] B. Kung, C. Huang, P. Hu, S. Lo, C. Lee, C. Yao, C. Kuan, "Baseline Correction and Denoising of Raman Spectra by Deep Residual CNN", *2020 Conference on Lasers and Electro-Optics (CLEO), OSA Technical Digest*, Washington, DC, USA pp.10-15, May 2020. DOI: https://doi.org/10.1364/CLEO_AT.2020.JTu2G.28
- [8] Y. Liu, "Adversarial nets for baseline correction in spectra processing", *Chemometrics and Intelligent Laboratory Systems*, Vol.213, Article.104317, April 2021. DOI: <https://doi.org/10.1016/j.chemolab.2021.104317>
- [9] B. Lafuente, R. T. Downs, H. Yang, N. Stone, "The power of databases: The RRUFF project", *De Gruyter*, 2015 [cited 2015 November 13], Available From: <https://rruff.info> (accessed Apr. 27, 2022)

손 영 재(YoungJae Son)

[준회원]



- 2022년 2월 : 홍익대학교 재료공학과 (공학사)
- 2022년 3월 ~ 현재 : 전남대학교 ICT융합시스템공학과 (석사과정)

<관심분야>

딥러닝, 패턴인식, 디지털 신호처리

진 철 군(Tiejun Chen)

[준회원]



- 2020년 2월 : 전남대학교 전자컴퓨터공학부 (공학사)
- 2021년 8월 : 전남대학교 ICT융합시스템공학과 (공학석사)
- 2021년 9월 ~ 현재 : 전남대학교 ICT융합시스템공학과 (박사과정)

<관심분야>

디지털 신호처리, 패턴인식, 딥러닝 및 기계 학습

손 성 재(SeongJae Son)

[준회원]



- 2020년 2월 : 전남대학교 신소재공학부 (공학사)
- 2022년 2월 : 전남대학교 ICT융합시스템공학과 (공학석사)

<관심분야>

딥러닝, 패턴인식, 디지털 신호처리

백 성 준(Sung-June Baek)

[정회원]



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

<관심분야>

딥러닝, 패턴인식, 디지털 신호처리