

ResNet과 Unet을 결합한 딥러닝 모델을 이용한 분광 신호에서 ROI 검출

진철군, 손성재, 박아론, 백성준*
전남대학교 ICT 융합시스템공학과

ROI Detection of Spectral Signal using Deep Learning Model Combining ResNet and Unet

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

요약 본 연구에서는 딥러닝 기술(deep learning technology)을 이용하여 분광 신호의 ROI(region of interest)를 찾는 방법을 제안한다. 제안한 방법은 모의실험 데이터로 학습된 딥러닝 모델을 이용하여 분광 신호의 ROI를 검출하는 방법이다. 분광 신호의 피크는 물질의 물리 화학적인 정보를 포함하고 있으므로 정확한 피크 검출은 분석 시스템의 성능에 영향을 미치는 중요한 과정이다. 지금까지 가장 많이 사용되는 방법은 진폭을 기반으로 피크 검출을 진행하는 것이다. 하지만 이런 방법들은 전처리 과정을 포함하거나 분광 신호에 따라 파라미터를 육안 검사로 선택하여 추정하므로 복잡하고 주관적이다. 이러한 문제점 개선을 위해 딥러닝 모델을 통해 분광 신호의 ROI 검출을 수행하였다. 제안한 방법은 전처리 과정이 없고 파라미터를 설정하지 않아도 되는 장점을 갖는다. 또한 검출한 ROI에 따라 분광 신호에 후처리(post-processing)를 수행하여 피크를 얻을 수 있다. 디폴트 손실 함수에 3만개 테스트 데이터를 적용하여 얻은 손실값을 통해 성능 평가를 수행하였다. 제안된 ResNet과 Unet을 결합한 딥러닝 모델은 일반적인 컨볼루션 신경망(CNN: Convolutional Neural Network), ResNet, 그리고 Unet에 비해 각각 76.5%, 69.8%, 5.9%의 성능 향상을 보였으며, 실제 라만 분광 신호의 ROI 검출에도 효과적으로 적용될 수 있음을 확인하였다.

Abstract This study proposes a method to find the ROI (region of interest) of spectral signals using deep learning technology. The proposed method detects the ROI of spectral signals using a deep learning model trained with simulated data. Since the peak of the spectral signal contains physical and chemical information of the substance, accurate peak detection is an important process affecting the performance of the analyzed system. The widely used method for peak detection is the one based on the amplitude. However, this method is complex and subjective because it involves pre-processing or select and estimate parameters using visual inspection according to spectral signals. To overcome this problem, ROI detection of the spectral signal was performed through a deep learning model. The proposed method has the advantage of requiring no pre-processing and parameter setting. In addition, a peak may be obtained by performing post-processing of the spectral signal according to the detected ROI. Performance evaluation was performed through loss values obtained by applying 30,000 test data to the custom loss function. The proposed deep learning model combining ResNet and Unet showed performance improvements of 76.5%, 69.8%, and 5.9% compared to the general convolutional neural network (CNN), ResNet, and Unet, respectively. It was also confirmed that the proposed method could be effectively applied to measured spectral signals.

Keywords : Peak Detection, Region of Interest, Deep Learning, CNN, Raman Spectroscopy

본 논문은 교육부 및 한국연구재단의 4단계 BK21 사업(혁신인재 양성사업)으로 지원된 연구임 (관리번호 5199991714138)

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

email: tozero@jnu.ac.kr

Received August 10, 2021

Accepted December 6, 2021

Revised September 10, 2021

Published December 31, 2021

1. 서론

분광법(spectroscopy)은 방사선의 파장이나 주파수의 함수로서 물질과 전자기 방사선의 상호작용을 연구하는 학문이다. 분광학은 주로 전자기 스펙트럼에서 물리, 화학 및 기타 과학 분야에서 기초적인 탐색 도구이며, 물질의 화학적 구성, 물리적 구조 및 전자 구조에 대한 정보를 탐지, 식별 및 정량화하는 데 사용될 수 있다. 분광법은 생명과학, 의학, 식품, 의약 및 국방 등 다양한 분야에서 중요하게 응용된다.

물질의 분자 화학적인 조성(compositions)은 분광 신호의 피크(peak)와 연관되며, 피크의 높이 또는 면적에 따라 정량적으로 분석될 수 있다. 하지만 분광 신호 간섭(spectral signal interference)으로 인해 측정된 분광 신호에는 항상 배경 잡음과 가산 잡음이 포함되어 피크 측정이 어려워진다. 따라서 정확한 피크 검출은 분광 신호 분석의 필수적인 단계이며 차후 분석 결과에 많은 영향을 끼칠 수 있다[1-4].

라만 분광법[5], LIBS(laser-induced breakdown spectroscopy) 분광법[6], Mass 분광법[7], 감마 분광법[8]과 같은 여러 분광 분야에서 피크를 검출하기 위해 다양한 방법이 제안되었다. 일반적으로 대부분 방법은 피크를 검출하기 전에 smoothing과 배경 보정을 포함한 전처리 과정을 수행한다[9,10]. smoothing는 moving average[11], Savitzky-Golay[12] 등 여러 다른 필터를 사용할 수 있으며 고주파 잡음을 제거하기 위한 목적으로 사용된다. 배경 보정은 airPLS[13], arPLS[14]과 같은 다양한 알고리즘을 적용할 수 있고 이는 저주파 잡음을 제거하기 위해 사용된다. 이러한 전처리 과정은 서로 다른 워크플로우에서 다양한 알고리즘을 이용하기 때문에 서로 상이한 결과를 도출한다. CWT(continuous wavelet transform)를 기반한 방법은 smoothing, 배경 보정과 같은 전처리 과정이 필요하지 않은 장점이 있지만 웨이블릿, 척도와 같은 파라미터 수가 많으므로 알고리즘을 조정하기가 어렵다[15,16].

본 연구에서는 분광 신호의 ROI를 검출하는 새로운 방법을 제안하였다. 이 방법은 모의실험 데이터로 학습된 딥러닝 모델을 이용하여 분광 신호의 ROI를 검출하는 방법이다. 실험 결과에 따르면 제안된 방법은 모의실험 데이터와 실제 라만 분광 신호에 효과적으로 적용될 수 있음을 확인할 수 있다. 또한 분광 신호의 피크는 제안한 방법을 통해 검출된 ROI에 따라 분광 신호를 후처리하여 얻어질 수 있다. ROI를 이용한 피크 검출 방법은 이

전의 방법들과 비교하면 여러 단계를 거치는 전처리 과정이 없고 파라미터를 선택하여 추정할 필요가 없다는 장점을 지닌다.

2. 딥러닝 모델

인공지능의 중요한 부분인 딥러닝은 컴퓨터 비전, 신호처리, 패턴인식 등 많은 분야에 성공적으로 적용되어 최고의 결과를 보여주고 있다. 딥러닝 네트워크는 일반적으로 여러 개의 은닉층을 가진 인공신경망으로 간주되어 입력력 사이의 복잡한 비선형 함수를 모델링할 수 있다.




Fig. 1. The structure of CNN.

CNN은 데이터의 특징을 추출하는 부분과 클래스를 분류하는 부분으로 구성되어 있다. 특징 추출 부분은 여러 컨볼루션 레이어로 쌓아 구성되고 클래스 분류 부분은 완전 연결(Fully connected) 레이어로 구성되어 있다. Fig. 1에 일반적인 CNN 구조를 보였다. CNN은 일반적인 인공신경망과 달리 특징 추출을 수동으로 설계하지 않고 신경망의 학습 과정에 포함하여 일괄처리한다. CNN은 공유 파라미터를 이용하여 수용 영역에서만 연산하는 컨볼루션 레이어를 사용하기 때문에 완전 연결인 인공신경망보다 파라미터 수가 적고, 연산이 간단하여 용량이 큰 데이터에 효과적으로 적용될 수 있다. 컨볼루션 레이어는 완전 연결 레이어와 달리 입력 데이터의 공간 정보를 유지할 수 있다[17].




Fig. 2. The structure of ResNet.
 (a) The outline of ResNet
 (b) The detailed structure of ResNet blocks

딥 네트워크는 레이어 수가 많을수록 학습 데이터의 대표적인 특징을 잘 추출할 수 있어 좋은 학습 결과를 얻을 수 있다. 하지만 컨볼루션 신경망의 네트워크가 깊어

지게 되면 vanishing gradient 문제로 인하여 파라미터를 업데이트할 때, gradient 값이 너무 큰 값이나 작은 값으로 포화되어 더는 움직이지 않는다. 이로 인해 학습의 효과가 없어지거나 학습 속도가 아주 느려지는 현상이 일어난다. Fig. 2에 shortcut connection을 이용한 ResNet 구조를 보였다. 그림 중의 (a)와 (b)는 ResNet의 윤곽도와 블록 상세 구조를 나타낸다. ResNet은 shortcut connection을 이용한 잔차 학습 프레임워크를 통해 그 문제를 해결할 수 있다[18]. 몇 개의 레이어를 건너뛰면서 입력과 출력이 연결되기 때문에 forward 나 backward path가 단순해지는 효과를 얻을 수 있다.

Unet은 네트워크 구조가 U자 형태로 생긴 것으로 이름이 명명되었고 Fig. 3(a)에서 보듯이 수축 경로(contracting path)와 팽창 경로(expansive path)로 구성되어 있다[19]. Fig. 3(b)는 모델의 블록 세부 구조이다. 수축 경로는 일반적인 딥러닝 구조에서 보이는 바와 같이 데이터로부터 컨텍스트를 포착할 수 있도록 하는 부분이다. Unet의 메인 아이디어는 팽창 경로에서 특징맵을 업샘플링하고 이를 수축 경로에서 포착한 특징맵의 컨텍스트와 결합하여 더 정확한 로컬라이제이션을 하는 것이다. Unet의 장점은 수축 경로에서 축약된 정보를 팽창 경로에 순차 연결해서 사용하여 데이터 크기를 줄였다가 다시 키우면 사라진 픽셀 정보를 스킵커넥션을 통해 얻을 수 있다는 점이다.




Fig. 3. The structure of Unet.
 (a) The outline of Unet (b) The detailed structure of Unet blocks

본 연구에서는 ResNet과 Unet 두 모델의 기본 아이디어를 이용하여 ResNet+Unet 모델을 제안하였다. Fig. 4에 제안한 ResNet+Unet 모델의 전체 구조를 보였다. 그림의 (a)와 (b)에서 보듯이 ResNet 모델의 shortcut connection 기법과 Unet 모델의 스킵커넥션 기법을 이용한 U자형 구조이다.

3. 실험 방법

실험에 이용한 모의실험 데이터는 가우시안 백색 잡음과 피크를 혼합하고 배경 잡음을 더하여 구성하였다. 실제 분광 신호를 한껏 시뮬레이션하기 위해 피크는 8개에서 16개까지 해닝 윈도우(hanning window)를 이용하여 폭을 5에서 31로 설정하고 무작위로 생성하였다. 배경 잡음은 최대 7차 다항식을 묘사할 수 있도록 데이터 길이 범위 내에 랜덤하게 생성한 7개 점을 cubic spline 보간법을 이용하여 매끄러운 곡선으로 피팅하였다. 모의 실험 데이터는 다양한 형태로 구성하기 위해 생성된 피크를 좌우로, 배경 잡음은 상하좌우로 반전하여 랜덤하게 조합하고, 상대 강도(relative intensity) 차이에 의한 편차를 최소화하기 위해 데이터의 최소값을 0, 최대값을 1로 변환하는 최소-최대 정규화 방법(Min-Max normalization)을 적용하였다. Fig. 5(a)~(f)에 각각

1~6차 배경 잡음을 포함하고 길이가 512인 모의실험 데이터 6개를 보였다.

본 연구의 모든 딥러닝 모델의 학습에 사용된 손실 함수와 최적화 기법은 예비 실험을 통해 결정하였다. 손실 함수는 일반적인 sigmoid와 binary cross entropy를 순차적으로 사용하는 것보다 수치적으로 안정적인 sigmoid layer와 binary cross entropy를 하나의 클래스로 결합한 함수를 사용하고, 최적화 기법으로 Adam(Adaptive Moment Estimation) 알고리즘을 사용하였다. 딥러닝 모델 학습의 주요 파라미터인 학습률은 $5e-4$, batch size는 500, 최대 학습 epoch은 1300으로 설정하고, 학습률의 1/8에 도달하면 학습을 중단하는 조기 종료(early stopping) 기법을 사용하였다.

본 연구에서는 모델들의 성능을 평가하기 위해 Eq. (1)와 같은 Loss인 $Loss_{roi}$ 를 사용하였다. 예측한 ROI의 폭을 P 라고 하고, 실제 ROI(ground truth)의 폭을 G 라고 하면 $Loss_{roi}$ 는 다음과 같다. 이때 $Loss_{roi}$ 는 실제 ROI와 예측된 ROI가 얼마만큼 다른지를 나타내는 지표가 된다.

$$Loss_{roi} = \begin{cases} 0, & P \cup G - P \cap G \leq 0.2G \\ P \cup G - P \cap G, & otherwise \end{cases} \quad (1)$$




Fig. 4. The structure of ResNet+Unet.

(a) The outline of ResNet+Unet (b) The detailed structure of ResNet+Unet blocks




Fig. 5. Example of simulation spectra. a~f image are spectra of 1 to 6 order respectively.

Fig. 6은 $Loss_{roi}$ 를 쉽게 이해하기 위한 설명도이다. 실선이 실제 ROI, 점선이 예측한 ROI로 가정하면 $Loss_{roi}$ 는 실제 ROI와 예측한 ROI 차이의 영역을 나타낸다. 가산 잡음을 감안하여 예측한 ROI 양쪽 영역의 오차가 각각 피크 폭의 10% 이내일 경우 잘 검출된 것으로 간주될 수 있다.




Fig. 6. The explanatory diagram of $Loss_{roi}$

실험에서는 총 18만 개의 모의실험 데이터를 학습, 검증과 테스트 데이터로 나누었으며, 데이터의 개수는 각각 12만 개, 3만 개, 3만 개이다. 본 논문에서 제안한 ResNet+Unet 딥러닝 모델의 성능을 비교하기 위해 CNN, ResNet, Unet을 추가하여 모두 4가지 딥러닝 모델을 학습과 검증 데이터를 이용하여 학습하였다. 학습된 모델로 테스트 데이터의 ROI를 예측하고 평가 메커니즘으로서의 $Loss_{roi}$ 를 사용하여 모델들의 성능을 평가하였다.

4. 실험 결과

4.1 모의실험 데이터

본 논문에서 제안한 ResNet+Unet 모델과 CNN, ResNet, Unet 딥러닝 모델의 성능을 비교한 실험 결과를 Table 1에 요약하고 Fig. 7에 나타내었다. Table 1과 Fig. 7을 보면 제안한 방법의 오차가 다른 방법들보다 상대적으로 낮다.

Table 1. Loss value of models.

	Deep learning Models			
	CNN	ResNet	Unet	ResNet+Unet
Loss	0.0136	0.0106	0.0034	0.0032




Fig. 7. Bar chart of loss value of CNN, Resnet, Unet and ResNet+Unet.




Fig. 8. The results of an example of simulated experimental data by CNN, ResNet, Unet and ResNet+Unet.

CNN, ResNet, Unet과 ResNet+Unet 4가지 모델은

모의실험 데이터에 적용되어 얻은 결과 중의 제일 좋은 결과가 거의 일치하기 때문에 예측되는 결과의 차이점을 볼 수 없고 서로 비교할 수 없다. 그래서 Fig. 8과 같이 안 좋은 결과 중에 하나를 선택하여 4가지 모델로 예측한 결과들의 차이를 보였다. 그림을 보면 CNN, ResNet과 Unet는 샘플 간격 300에서 400 사이의 작은 피크의 ROI를 정확하게 검출하지 않았고 ResNet+Unet는 제대로 그 작은 피크의 ROI를 검출했다. 그러므로 ResNet+Unet 모델은 작은 피크의 ROI를 검출할 수 있다고 판단할 수 있다.

Fig. 9(a)~(f)에 1~6차 배경 잡음을 포함한 모의실험 데이터에 제안한 딥러닝 모델로 예측한 ROI를 나타내었다. 그림에서 다양한 형태의 배경 잡음에서 예측한 ROI가 실제 ROI와 거의 일치한 것을 확인할 수 있고 분광 신호에 효과적으로 적용할 수 있음을 기대할 수 있다.




Fig. 9. The results of ROI of simulation spectra by proposed method.

4.2 라만 분광 신호

실제 라만 분광 신호를 이용한 실험에서는 6가지 화학 물질 2-Methyl-1, 3-dinitrobenzene (2,6-DNT), Ammonium dinitramide (ADN), Ammonium nitrate (AN), Ammonium perchlorate (AP), Octahydro-1,3,5,7-tetranitro- 1,3,5,7-tetrazocine (HMX), Acetonitrile(ACN)을 측정할 라만 분광 신호를

사용했다. 라만 분광 신호를 측정할 때 레이저 가열로 인한 영향을 방지하기 때문에 레이저 파워를 1.0mW 이하로 유지하도록 하였다. Rayleigh 라인을 라만 산란으로부터 제거하기 위해 측정 과정에서 홀로그래픽 노치 필터를 이용하였다. 라만 분광 신호는 5초간 축적하였고, 50x 대물렌즈를 이용하여 레이저의 초점을 맞췄다.

라만 분광 신호에 제안한 딥러닝 방법을 적용하여 ROI를 예측한 결과를 Fig. 10에 나타내었다. 그림에서 피크는 검출한 ROI에 선형 보간법(linear interpolation)을 이용하여 라만 분광 신호를 간단히 후처리 결과이다. 그림에서 보듯이 모든 라만 분광 신호는 피크의 높이와 위치가 매우 자연스럽게 바람직하다. 따라서 6가지 화학 물질의 라만 분광 신호의 ROI 검출 결과로부터 실제 분광 신호에 대해 제안한 방법의 적합성과 유효성을 확인할 수 있다.




Fig. 10. The results of ROI of Raman spectra by proposed method and post processed results of Raman by linear interpolation.

5. 결론

본 논문에서 제안된 방법은 딥러닝 기술을 통해 분광 신호의 피크 영역으로서의 ROI를 검출하는 방법이다. 본 연구에서는 주로 일반적인 CNN, ResNet, Unet과 ResNet, Unet 두 모델의 기본 아이디어를 이용한 ResNet+Unet 4가지 모델을 적용하여 실험하였다. 테스트

트 데이터를 이용한 실험 결과에 따르면 ResNet과 Unet을 결합한 딥러닝 모델 성능은 일반적인 CNN, ResNet과 Unet보다 각각 76.5%, 69.8%, 5.9%를 향상되었다. 그리고 ResNet+Unet 모델은 실제 라만 분광 신호의 ROI 검출 결과에 따라 실제 분광 신호에 효과적으로 적용될 수 있음을 확인하였다. 또한, 분광 신호의 피크는 제안된 방법을 통해 검출한 ROI에 따라 분광 신호를 후처리하면 얻어질 수 있다.

이전의 연구에서 제안된 피크 검출 방법들은 일반적으로 smoothing, 배경 보정과 같은 전처리 과정이 있거나 알고리즘의 파라미터를 선택하여 추정해야 한다. 본 연구에서 제안된 방법으로 검출한 ROI를 통해 피크를 얻으면 이전 방법들에 필수적이었던 전처리와 파라미터 설정이 없어지므로, 사용자의 개입 없이 피크를 추출하는 데 보다 더 유용하게 사용될 수 있을 것으로 판단된다.

References

- [1] J. Park, S. Baek, "Local Region Spectral Analysis for Performance Enhancement of Dementia Classification", *Journal of the Korea Academia-Industrial Cooperation Society*, Vol.12, No.11, pp.5150-5155, Nov. 2011.
DOI: <https://doi.org/10.5762/KAIS.2011.12.11.5150>
- [2] A. Park, S. Baek, "A screening of Alzheimer's disease using basis synthesis by singular value decomposition from Raman spectra of platelet", *Journal of the Korea Academia-Industrial Cooperation Society*, Vol.14, No.5, pp.2393-2399, May. 2013.
DOI: <https://doi.org/10.5762/KAIS.2013.14.5.2393>
- [3] G. Yang, J. Dai, X. Liu, M. Chen, X. Wu, "Multiple Constrained Reweighted Penalized Least Squares for Spectral Baseline Correction", *Applied Spectroscopy*, Vol.74, No.12, pp.1443-1451, Dec. 2019.
DOI: <https://doi.org/10.1177/0003702819885002>
- [4] G. Yang, J. Dai, X. Liu, M. Chen and X. Wu, "Spectral feature extraction based on continuous wavelet transform and image segmentation for peak detection", *Analytical Methods*, No.2, pp. 169-178, Nov. 2020.
DOI: <https://doi.org/10.1039/C9AY02052G>
- [5] Z. Cai and J. Wu, "An Automatic Peak Detection Algorithm for Raman Spectroscopy Based on Wavelet Transform", *2011 International Conference on Optical Instruments and Technology: Optoelectronic Imaging and Processing Technology*, SPIE, Beijing, China, Nov. 2011.
DOI: <https://doi.org/10.1117/12.904862>
- [6] P. Chen, D. Tian, S. Qiao and G. Yang, "An Automatic Peak Detection Method for LIBS Spectrum Based on Continuous Wavelet Transform", *Spectroscopy and Spectral Analysis*, Vol. 34, No.7, pp. 1969-1972, May. 2014.
DOI: [https://doi.org/10.3964/j.issn.1000-0593\(2014\)07-1969-04](https://doi.org/10.3964/j.issn.1000-0593(2014)07-1969-04)
- [7] N. Nguyen, H. Huang, S. Orintara and A. Vo, "Gaborlocal: Peak Detection in Mass Spectrum by Gabor Filters and Gaussian Local Maxima", *Proceedings of the CSB 2008 Conference*, Computational Systems Bioinformatics, CA, USA, pp. 85-96, Aug. 2008.
DOI: https://doi.org/10.1142/9781848162648_0008
- [8] D. Yuan, P. Guss and T. Ashenfelter, "Wavelet Approach for Operational Gamma Spectral Peak Detection", *Nuclear Technology*, Vol.177, No.2, pp.273-284, May. 2011.
DOI: <https://doi.org/10.13182/NT12-A13371>
- [9] W. Yu, B. Wu, N. Lin, K. Stone, K. Williams and H. Zhao, "Detecting and aligning peaks in mass spectrometry data with applications to MALDI", *Computational Biology and Chemistry*, Vol.30, No.1, pp.27-38, Feb. 2006.
DOI: <https://doi.org/10.1016/j.compbiolchem.2005.10.006>
- [10] D. Mantini, F. Petrucci, D. Pieragostino, P. D. Boccio, M. D. Nicola, C. D. Ilio, G. Federici, P. Sacchetta, S. Comani and A. Urbani, "LIMPIC: A Computational Method for the Separation of Protein MALDI-TOF-MS Signals from Noise", *BMC Bioinformatics*, Vol.8, pp.101-117, Mar. 2007.
DOI: <https://doi.org/10.1186/1471-2105-8-101>
- [11] J. N. "A Study in Analysis of Stationary Time Series", *Journal of the Royal Statistical Society*, Vol.102, No.2, pp.295-298, 1939.
DOI: <https://doi.org/10.2307/2980009>
- [12] A. Savitzky and M. J. E. Golay, "Smoothing and Differentiation of Data by Simplified Least Squares Procedures", *Analytical Chemistry*, Vol.36, No.8, pp.1627-1639, Jul. 1964.
DOI: <https://doi.org/10.1021/ac60214a047>
- [13] Z. Zhang, S. Chen and Y. Liang, "Baseline correction using adaptive iteratively reweighted penalized least squares", *Analyst*, Vol.135, No.5, pp.1138-1146, Feb. 2010.
DOI: <https://doi.org/10.1039/B922045C>
- [14] S. Baek, A. Park, Y. Ahn and J. Choo, "Baseline Correction using Asymmetrically Reweighted Penalized Least Squares Smoothing", *Analyst*, Vol.140, No.1, pp.250-257, Sept. 2014.
DOI: <https://doi.org/10.1039/C4AN01061B>
- [15] P. Du, W. A. Kibbe and S. M. Lin, "Improved Peak Detection in Mass Spectrum by Incorporating Continuous Wavelet Transform-based Pattern Matching", *Bioinformatics*, Vol.22, No.17, pp.2059-2065, Sept. 2006.
DOI: <https://doi.org/10.1093/bioinformatics/btl355>
- [16] E. Lange, C. Gropl, K. Reinert, O. Kohlbacher and A. Hildebrandt, "High-accuracy Peak Picking of

Proteomics Data using Wavelet Techniques", *Pacific Symposium on Biocomputing*, PSB, pp.243-254, Jan. 2006.

DOI: https://doi.org/10.1142/9789812701626_0023

- [17] K. O'Shea and R. Nash, "An Introduction to Convolutional Neural Networks", *ArXiv*, arXiv:1511.08458, Nov. 2015.
- [18] K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image Recognition", *2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, IEEE, NV, USA, pp.770-778, Jun. 2016.
DOI: <https://doi.org/10.1109/CVPR.2016.90>
- [19] O. Ronneberger, P. Fischer and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation", *Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015*, MICCAI, Munich, Germany, pp.234-241, Oct. 2015.
DOI: https://doi.org/10.1007/978-3-319-24574-4_28

진 철 군(Tiejun Chen)

[준회원]



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

<관심분야>

디지털 신호처리, 패턴인식, 딥러닝 및 기계 학습

박 아 론(Aaron Park)

[정회원]



- 2006년 2월 : 전남대학교 전자컴퓨터정보통신공학부(공학학사)
- 2008년 2월 : 전남대학교 전자공학과(공학석사)
- 2012년 2월 : 전남대학교 전자공학과(공학박사)

<관심분야>

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

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

손 성 재(SeongJae Son)

[준회원]



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

<관심분야>

딥러닝, 디지털 신호처리, 패턴인식