

CNN 잡음감쇠기에서 필터 수의 최적화

이행우*

Optimization of the Number of Filter in CNN Noise Attenuator

Haeng-Woo Lee*

요약

본 논문은 잡음감쇠기에서 CNN(Convolutional Neural Network) 계층의 필터 수가 성능에 미치는 영향을 연구하였다. 이 시스템은 적응필터 대신 신경망 예측필터를 이용하여 심층학습방법으로 잡음을 감쇠한다. 64-뉴런, 16-커널 CNN 필터와 오차 역전파 알고리즘을 이용하여 잡음이 포함된 음성신호로부터 음성을 추정한다. 본 연구에서 필터 수에 대한 잡음감쇠기의 성능을 검증하기 위하여 Keras 라이브러리를 사용한 프로그램을 작성하고 시뮬레이션을 실시하였다. 시뮬레이션 결과, 본 시스템은 필터 수가 16일 때 MSE(Mean Squared Error) 및 MAE(Mean Absolute Error) 값이 가장 작은 것으로 나타났으며 필터가 4개 일 때 성능이 가장 낮은 것을 볼 수 있다. 그리고 필터가 8개 이상이 되면 필터 수에 따라 MSE 및 MAE 값이 크게 차이 나지 않는 것을 보여주었다. 이러한 결과로부터 음성신호의 주요 특징을 표현하기 위해서는 약 8개 이상의 필터를 사용해야 한다는 것을 알 수 있다.

ABSTRACT

This paper studies the effect of the number of filters in the CNN (Convolutional Neural Network) layer on the performance of a noise attenuator. Speech is estimated from a noised speech signal using a 64-neuron, 16-kernel CNN filter and an error back-propagation algorithm. In this study, in order to verify the performance of the noise attenuator with respect to the number of filters, a program using Keras library was written and simulation was performed. As a result of simulation, it can be seen that this system has the smallest MSE (Mean Squared Error) and MAE (Mean Absolute Error) values when the number of filters is 16, and the performance is the lowest when there are 4 filters. And when there are more than 8 filters, it was shown that the MSE and MAE values do not differ significantly depending on the number of filters. From these results, it can be seen that about 8 or more filters must be used to express the characteristics of the speech signal.

키워드

Noise Attenuation, Deep Learning, CNN, Error Back Propagation, MSE, MAE
잡음 감쇠, 심층 학습, 합성곱 신경망, 오차 역전파, 평균 제곱 오차, 평균 절대값 오차

* 교신저자 : 남서울대학교 지능정보통신공학과
• 접수일 : 2021. 07. 14
• 수정완료일 : 2021. 07. 31
• 게재확정일 : 2021. 08. 17

• Received : Jul. 14, 2021, Revised : Jul. 31, 2021, Accepted : Aug. 17, 2021
• Corresponding Author : Haeng-Woo Lee
Intelligent Information Communication Engineering, Namseoul University,
Email : hwlee@nsu.ac.kr

I. 서론

잡음감쇠는 음성에 포함된 잡음을 감쇠시키는 것으로서 지금까지 잡음감쇠기술에 대해 다양한 연구가 이루어졌다. 잡음감쇠방법으로 짧은 구간의 스펙트럼 추정에 기반을 둔 스펙트럼 감산법[1,2]과 위너(Wiener) 필터방법[3,4,5]이 있다. 이 방법들은 입력 음성신호로부터 추정된 잡음의 스펙트럼을 감산하거나 또는 명료한 음성 스펙트럼을 추정하며, 미리 잡음 및 음성신호의 통계적 특성을 알고 있는 경우 유리하다. 다른 방법으로 음성신호의 준주기적 특성을 이용하는 Comb 필터[6] 또는 적응필터[7,8,9]를 이용하는 방법이 있다. Comb 필터방법은 특정 주파수대역을 가진 잡음일 경우 사용되며, 적응필터방법은 잡음의 통계적 특성을 사전에 알고 있지 않아도 필터의 계수를 자동적으로 조정하는 기능을 가진다. 센서가 1개인 단일입력 적응잡음감쇠기는 하나의 마이크로 음성신호가 입력되어 유성음 구간이 나타내는 준주기적 특성을 이용하여 음성신호를 추정한다.

최근 심층학습 모델이 신경망을 기반으로 많은 은닉층을 사용하여 학습할 수 있는 기술이 개발되면서 큰 성과를 내고 있다. 다층 신경망을 학습하는 오차 역전파(error back propagation) 알고리즘을 사용함으로써 많은 층으로 구성된 심층 신경망도 학습이 가능하게 되었다[10,11]. CNN[12]은 현재 가장 많이 사용되는 심층학습 모델로써 음성의 특징을 잘 추정해낼 수 있다. 본 연구에서는 적응잡음감쇠기의 적응필터 대신에 CNN 신경망 필터의 심층학습(deep learning) 알고리즘을 이용하여 잡음을 감쇠시킬 때 CNN 필터의 수가 성능에 미치는 영향을 조사하여 최적의 필터 수를 제안한다.

본문의 내용은 II절에서 적응잡음감쇠기에 대해 알아보고, III절에서는 음성신호의 선형예측을 설명하며, IV절에서는 CNN 신경망 필터의 구조를, V절에서 가중치 계수의 갱신 알고리즘에 대하여 기술한다. 그리고 VI절에서는 필터 수에 대한 시뮬레이션 및 그 결과에 대하여 기술하고, 끝으로 VII절에서 결론을 도출한다.

II. 적응잡음감쇠기

그림 1은 음성신호의 준주기적 특성을 이용하여 적응예측방법으로 1 샘플 이상 지연된 신호들로부터 현재 음

성샘플을 추정하는 단일입력 잡음감쇠기이다. 한 두 피치 지연된 음성신호는 높은 상관관계를 갖지만 백색잡음 성분과는 거의 상관관계가 없다. 즉 음성신호는 잡음과 서로 독립된 관계로서 목표값의 최소 제곱오차가 되도록 수렴해 나간다.




그림 1. 단일입력 잡음감쇠기
Fig. 1 Single input noise attenuator

CNN 필터의 출력은 입력신호에 포함된 음성신호의 특징을 추정하며 이 신호가 입력신호로부터 차감되어 오차가 된다. 이 오차신호는 CNN 필터의 가중치(weight)를 갱신하기 위한 업데이트신호로 사용되며 평균전력은 식 (1)과 같다.

$$E\{e_k^2\} = E\{(s_k - \hat{s}_k)^2 + 2(s_k - \hat{s}_k)n_k + n_k^2\} \quad (1)$$

여기서 $E\{e_k^2\}$ 는 평균값을 나타내며 음성신호와 잡음이 상호 독립적이라고 가정하면

$$E\{e_k^2\} = E\{(s_k - \hat{s}_k)^2 + n_k^2\} \quad (2)$$

임의의 구간에서 잡음에너지는 고정된 값이므로

$$\min(E\{e_k^2\}) = \min(E\{(s_k - \hat{s}_k)^2\}) + E\{n_k^2\} \quad (3)$$

$E\{e_k^2\}$ 를 최소화하는 것은 음성신호의 추정오차 $E\{(s_k - \hat{s}_k)^2\}$ 를 최소화하는 것이며 이때 필터의 출력 \hat{s}_k 는 음성신호를 가장 잘 추정하게 된다. 그러므로 $E\{(s_k - \hat{s}_k)^2\}$ 의 최소화는 $E\{(n_k - e_k)^2\}$ 를 최소화하는 것을 의미하며 오차신호 e_k 는 잡음을 추정하게 된다.

III. 음성신호의 선형예측분석

선형예측(linear prediction) 분석은 음성 분석 및 합성

등 여러 분야에서 사용되는 방법이며, 음성 스펙트럼이 가진 특성을 상대적으로 적은 수의 파라미터로 정확하게 표현할 수 있다.

이산적인 시간 k 에서의 음성 샘플을 s_k 라 하고, 시간 k 에서의 음성 샘플의 예측값을 \hat{s}_k 라고 하면 식 (4)처럼 표현할 수 있다[13].

$$\begin{aligned} \hat{s}_k &= c_1 s_{k-1} + c_2 s_{k-2} + \dots + c_N s_{k-N} \\ &= \sum_{n=1}^N c_n s_{k-n} \end{aligned} \quad (4)$$

따라서 음성신호의 현재 값은 식 (4)로부터 이전 N 개의 과거의 값으로부터 예측될 수 있다. 따라서 실제 입력된 값과 예측된 값의 차이를 나타내는 예측 오차를 e_k 라고 하면 식 (5)로 나타낼 수 있다.

$$e_k = s_k - \hat{s}_k = s_k - \sum_{n=1}^N c_n s_{k-n} \quad (5)$$

여기서 c_n 은 선형예측계수이다. 따라서 e_k 의 제곱 평균값이 최소가 되도록 선형예측계수를 구한다. 본 논문에서는 유성음이 가지고 있는 특유의 저역 주파수 스펙트럼 구조를 이용하여 음성신호를 추정한다.

IV. CNN 신경망 필터

본 논문에서 사용한 그림 2의 신경망 필터는 16개의 CNN 필터를 사용하였을 경우의 3층 구조를 보여주고 있다.




그림 2. CNN 필터의 구조
Fig. 2 Structure of CNN filter

첫째 층의 CNN 레이어는 64개 뉴런(neuron)과 16개 특징필터로 이루어져 있으며, 커널(kernel)의 크기는 16 샘플로서 매 샘플 간격으로 커널이 존재한다. 입력신호는 매 샘플마다 64×16개의 데이터로 구성되며, 출력에서 활성화(activation) 함수로 ReLU를 적용한다. CNN 층의 출력은 다음에 있는 Flatten 레이어를 거쳐 1차원으로 평탄화되며 49×16 = 784개 노드로 펼쳐진다. 이 신호들이 784개 뉴런을 가진 Fully-connected Neural Network(:FNN) 층으로 입력되며 출력에서 다시 ReLU 함수를 적용한다. 이어서 마지막 층인 64개 뉴런을 가진 FNN 레이어를 거쳐 1개의 신호로 출력된다. 계산량을 줄이기 위해 배치(batch) 크기는 30으로 설정하였으며 각 레이어의 bias 파라미터는 생략하였다. 이 모델에서 계산해야 할 가중치 파라미터는 CNN 레이어에서 256개 (=16×16), 은닉 레이어에서 50,176개(=784×64), 그리고 출력 레이어에서 64개로서 총 50,496개이다. 가중치의 업데이트 알고리즘은 Adam과 오차 역전파 알고리즘을 이용한다. 본 시스템은 지도학습으로 분류되며 단일입력 데이터로 훈련데이터와 학습 목표값을 준비한다.

V. 가중치 계수의 갱신 알고리즘

다층 퍼셉트론(multi-layer perceptron)은 1개 이상의 은닉층(hidden layer)을 가지는 다층 신경망의 구조를 가진다. 다층 퍼셉트론이 l 개의 입력 뉴런을 가지는 입력층, m 개의 은닉 뉴런을 가지는 은닉층, n 개의 출력 뉴런을 가지는 출력층으로 구성된 경우 입력 뉴런의 값은 l 차원 벡터 $x = [x_1, x_2, \dots, x_i, \dots, x_l]$, 은닉 뉴런의 값은 m 차원 벡터 $a^i = [a_1^i, a_2^i, \dots, a_j^i, \dots, a_m^i]$, 출력 뉴런의 값은 n 차원 벡터 $y = [y_1, y_2, \dots, y_k, \dots, y_n]$ 로 나타낼 수 있다. 그리고 입력층과 은닉층 사이의 가중치를 w_{ij}^1 , 은닉층과 출력층 사이의 가중치를 w_{jk}^2 로 나타내고 바이어스는 생략하도록 한다. 여기서 입력층은 CNN 레이어로서 커널 사이즈 q 와 필터 수 p 로 이루어진다. 또한, j 번째 은닉 뉴런으로 입력되는 가중합을 u_j^h , k 번째 출력 뉴런으로 입력되는 가중합을 u_k^o 라 하고, 은닉 뉴런의 활성화 함수는 ϕ_{relu} 로 표기되는 ReLU 함수를 사용하며 출력 뉴런은 활성화 함수를 사용하지 않는다.

따라서 은닉 뉴런과 출력 뉴런의 출력값은 식 (6)과

(7)로 나타낼 수 있다.

$$a_j^1 = \phi(u_j^1) = \phi_{relu}\left(\sum_{i=1}^l w_{ij}^1 x_i\right) \quad (6)$$

$$y_k = u_k^o = \sum_{j=1}^m w_{jk}^2 a_j^1 \quad (7)$$

모든 가중치를 하나의 파라미터 θ 로 나타내면 입력 x 가 주어졌을 때 k 번째 출력 뉴런의 값은 함수 $f_k(x, \theta)$ 로 표현된다.

$$f_k(x, \theta) = y_k = \sum_{j=1}^m w_{jk}^2 \phi_{relu}\left(\sum_{i=1}^l w_{ij}^1 x_i\right) \quad (8)$$

오차 역전과 학습알고리즘[14,15,16]은 다층 퍼셉트론을 학습하는 알고리즘으로 다층 퍼셉트론의 지도학습은 학습목표값이 주어지고 다층 퍼셉트론에 의해 출력되는 값의 차이인 오차함수를 정의한다. 학습데이터와 목표값이 입력력의 순서쌍 (x_i, t_i) 로 주어졌을 때 학습 데이터 전체 X 에 대한 오차는 다음 식과 같이 평균제곱오차(mean square error)로 정의할 수 있다.

$$E(X, \theta) = \frac{1}{2N} \sum_{i=1}^N \|t_i - f(x_i, \theta)\|^2 \quad (9)$$

위 식에서 오차함수 $E(X, \theta)$ 는 데이터 집합 X 와 파라미터 θ 가 주어지면 하나의 값으로 정해지는데 X 는 외부에서 입력되는 값이고 최적화해야할 대상은 θ 이므로 $E(\theta)$ 로 나타낼 수 있다. 오차 역전과 학습알고리즘은 오차함수 $E(\theta)$ 를 최소화하기 위한 파라미터를 찾기 위해 경사하강법(gradient descent method)을 사용한다. 경사하강법은 반복적인 탐색으로 비용함수의 값을 최소화하는 파라미터를 찾는 알고리즘이며 식 (10)으로 표현된다.

$$\theta(t+1) = \theta(t) + \Delta\theta(t) = \theta(t) - \eta \frac{\partial E(\theta)}{\partial \theta} \quad (10)$$

여기서 η 는 학습속도를 제어하는 학습률(learning rate)이다. 다층 퍼셉트론에서 오차 역전과 학습은 각 가중치마다 하나의 데이터를 사용하여 업데이트하는 확률(stochastic) 경사하강법을 적용하며 하나의 데이터에 대한 오차함수 $E(x, \theta)$ 를 사용한다.

$$E(x, \theta) = \frac{1}{2}(t_k - y_k)^2 = \frac{1}{2}\left(t_k - \sum_{j=1}^m w_{jk}^2 a_j^1\right)^2 \quad (11)$$

여기서 은닉층과 출력층 사이의 가중치 w_{jk}^2 와 입력층과 은닉층 사이의 가중치 w_{ij}^1 는 학습을 통해 수정해 나가야 하는 파라미터이다. 오차함수를 출력층 가중치로 편미분하면

$$\frac{\partial E}{\partial w_{jk}^2} = \frac{\partial E}{\partial u_k^o} \frac{\partial u_k^o}{\partial w_{jk}^2} = -(t_k - y_k) a_j^1 = \delta_k a_j^1 \quad (12)$$

여기서 δ_k 는 출력 뉴런이 오차에 미치는 영향이다. 또한 오차함수를 입력층 가중치로 편미분하면

$$\frac{\partial E}{\partial w_{ij}^1} = \frac{\partial E}{\partial u_j^h} \frac{\partial u_j^h}{\partial w_{ij}^1} = \phi'_h(u_j^h) \sum_{k=1}^m w_{jk}^2 \delta_k x_i = \delta_j x_i \quad (13)$$

결과적으로 입력층과 은닉층 사이의 가중치는 은닉층과 출력층 사이의 가중치와 각각의 출력 뉴런이 오차에 미치는 영향인 δ_k 를 곱하여 합한 값에 좌우된다는 것을 알 수 있다. 이와 같이 출력 뉴런의 오차가 역으로 은닉 뉴런에 전파되어 은닉 뉴런의 파라미터 조정에 영향을 미치기 때문에 오차 역전과 학습알고리즘이라 하며, 각 가중치의 업데이트는 다음 식과 같이 이루어진다.

$$w_{jk}^2(t+1) = w_{jk}^2(t) + \eta(t_k - y_k) a_j^1 \quad (14)$$

$$w_{ij}^1(t+1) = w_{ij}^1(t) - \eta \phi'_h(u_j^h) \sum_{k=1}^m w_{jk}^2 \delta_k x_i \quad (15)$$

VI. 모의실험 결과

제한한 잡음감쇠기의 성능을 검증하기 위해 Keras 심층학습 라이브러리를 이용하여 시뮬레이션 프로그램을 작성하였다. 음성과 백색잡음이 혼합된 입력신호는 8kHz로 샘플링되며, 입력데이터는 500,000 샘플(62.5 sec)로 구성되었다. 내부적으로 $64 \times 499,935$ 샘플의 입력배열과 499,935 샘플의 목표값으로 이루어져 있다. 시스템의 성능을 평가하기 위한 척도는 목표값인 입력신호와 음성에

측값 간의 오차에 대한 평균제곱오차 MSE와 평균절대값 오차 MAE를 사용하였다.

그림 3에서 배치 수에 따라 필터 수별 평균제곱오차를 보여주고 있다. 5개의 필터 수(4, 8, 12, 16, 20)에 대한 MSE 곡선을 보면 배치 연산에 따라 초기 1,500배치 이전까지는 가파르게 감소하다가 이후에는 속도가 급격히 둔화되어 서서히 감소한다. 그리고 5개의 필터 수 중 16개일 때 MSE가 가장 작은 것을 볼 수 있다.




그림 3. 필터 수별 평균제곱오차의 비교
Fig. 3 Comparison of MSE for numbers of filter

그림 4에서는 배치 수에 따라 필터 수별 평균절대값오차를 보여주고 있다. 5개의 필터 수(4, 8, 12, 16, 20)에 대한 MAE 곡선도 MSE 곡선과 마찬가지로 배치 연산에 따라 초기 1,500배치 이전까지는 가파르게 감소하다가 이후에는 속도가 급격히 둔화되어 서서히 감소한다. 아울러 5개의 필터 수 중 16개일 때 MAE가 가장 작은 것을 볼 수 있다.

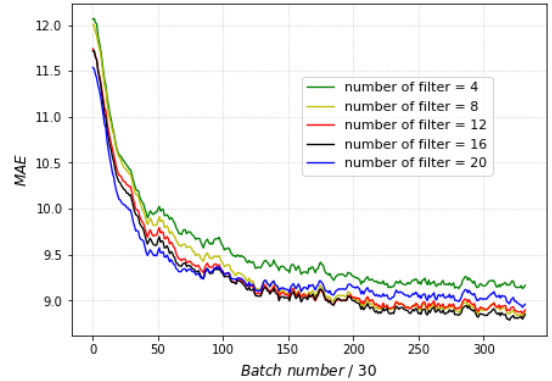


그림 4. 필터 수별 평균절대값오차의 비교
Fig. 4 Comparison of MAE for numbers of filter

또한 그림 5와 6은 필터 수에 따라 평균제곱오차 및 평균절대값오차를 보여주고 있다. 그림 5에서는 5개의 필터 수에 대한 MSE 곡선을 보여주는 바, 필터가 4개일 때 MSE가 가장 크고 나머지의 경우는 큰 차이 없이 비슷한 크기를 나타낸다. 그 중에서 필터 수가 16개일 때 MSE가 가장 작은 것을 알 수 있다.




그림 5. 필터 수에 대한 평균제곱오차 곡선
Fig. 5 MSE curve to numbers of filter

그림 6에서는 5개의 필터 수에 대한 MAE 곡선을 보여주는 바, MSE 곡선과 마찬가지로 필터가 4개일 때 MAE가 가장 크고 나머지의 경우는 큰 차이 없이 비슷한 크기를 나타낸다. 그 중에서 필터 수가 16개일 때 MAE가 가장 작은 것을 알 수 있다.




그림 6. 필터 수에 대한 평균절대값오차 곡선
Fig. 6 MAE curve to numbers of filter

VII. 결 론

본 논문은 CNN 심층학습 기술을 이용한 잡음감쇠기에서 필터 수가 성능에 미치는 영향을 살펴보았다. 잡음감쇠기는 64-뉴런, 16-커널 size CNN 필터와 오차 역전파 알고리즘을 이용하여 구현하였다. Keras 라이브러리를 사용하여 모델을 코딩하였으며 필터 수에 따라 MSE 및 MAE 값이 어떻게 변화하는지 관찰하였다.

모의실험 결과, 본 시스템은 CNN 필터 수가 16일 때 MSE 및 MAE 값이 가장 작은 것으로 나타났는데 필터가 4개로 적을 때 성능이 가장 낮은 것을 확인할 수 있다. 그리고 필터가 8개 이상이 되면 필터 수에 따라 MSE 및 MAE 값이 크게 차이나지 않는 것을 보여주었다. 이러한 결과로부터 음성신호의 주요 특징을 표현하기 위해서는 약 8개 이상의 필터를 사용해야 한다는 것을 알 수 있다.

감사의 글

이 논문은 2021년도 남서울대학교 학술연구비 지원에 의해 연구되었음.

References

- [1] S. F. Boll, "Suppression of acoustic noise in speech using spectral subtraction," *IEEE Trans. Acoust., Speech, Signal Processing*, vol. ASSP-29, Apr. 1979, pp. 113-120.
- [2] A. Schaub and P. Schaub, "Spectral sharpening for speech enhancement/noise reduction," In *Proc. of Int. Conf. on Acoust., Speech, Signal Processing*, vol. 2, May 1991, pp. 993-996.
- [3] J. Lim and A. V. Oppenheim, "All-pole modeling of degraded speech," *IEEE Trans. Acoust., Speech, Signal Processing*, vol. ASSP-26, June 1978, pp. 197-210.
- [4] J. Hansen and M. Clements, "Constrained iterative speech enhancement with to speech recognition," *IEEE Trans. Acoust., Speech, Signal Processing*, vol. ASSP-39, no. 4, Apr. 1989, pp. 21-27.
- [5] J. Choi, "Noise Reduction Algorithm in Speech by Wiener Filter," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 8, Sept. 2013, pp. 1293-1298.
- [6] J. Lim, A. V. Oppenheim, and L. D. Braid, "Evaluation of an adaptive comb filtering method for enhancing speech degraded by white noise addition," *IEEE Trans. Acoust., Speech, Signal Processing*, vol. ASSP-26, no. 4, Apr. 1991, pp. 354-358.
- [7] S. F. Boll and D. C. Pulsipher, "Suppression of acoustic noise in speech using two microphone adaptive noise cancellation," *IEEE Trans. Acoust., Speech, Signal Processing*, vol. ASSP-28, no. 6, Dec. 1989, pp. 752-753.
- [8] W. A. Harrison, J. Lim and E. Singer, "A new application of adaptive noise cancellation," *IEEE Trans. Acoust., Speech, Signal Processing*, vol. ASSP-34, Feb. 1986, pp. 21-27.
- [9] O. Kwon, "Study on Efficient Adaptive Controller for Attenuation of Engine Noises in a Car," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 9, Sept. 2014, pp. 983-989.

- [10] J. Schmidhuber, "Deep learning in neural networks: An overview," *Neural Networks*, vol. 61, 2015, pp. 85-117.
- [11] J. Choi, "Speech and Noise Recognition System by Neural Network," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 5, no. 4, Aug. 2010, pp. 357-362.
- [12] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner "Gradient-Based Learning Applied to Document Recognition," *Proceedings of the IEEE*, vol. 86, no. 11, Nov. 1998, pp. 2278-2324.
- [13] P. B. Patil, "Multilayered network for LPC based speech recognition," *IEEE Transactions on Consumer Electronics*, vol. 44, no. 2, 1998, pp. 435-438.
- [14] D. Rumelhart, G. Hinton, and R. Williams, "Learning representations by back-propagating errors," *Cognitive modeling*, vol. 5, 1988, pp. 3.
- [15] M. Jang and J. Kong, "Association Analysis of Convolution Layer, Kernel and Accuracy in CNN," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 14, no. 6, Dec. 2019, pp. 1153-1160.
- [16] J. Jo, "Performance Comparison Analysis of AI Supervised Learning Methods of Tensorflow and Scikit-Learn in the Writing Digit Data," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 14, no. 4, Aug. 2019, pp. 701-706.

저자 소개



이행우(Haeng-Woo Lee)

1985년 광운대학교 전자공학과 (공학사)

1987년 서강대학교 대학원 전자공학과 (공학석사)

2001년 전북대학교 대학원 전자공학과 (공학박사)

1987년~1998년 한국전자통신연구원 선임연구원

2001년~현재 남서울대학교 지능정보통신공학과 교수

※ 관심분야 : 반도체 설계, 심층학습 알고리즘, 음향잡음감쇠

