

<https://doi.org/10.7236/JIIBC.2018.18.4.55>

JIIBC 2018-4-8

딥 러닝 기반의 잡음 모델링을 이용한 전력선 통신에서의 잡음 제거

De-noising in Power Line Communication Using Noise Modeling Based on Deep Learning

선영규*, 황유민*, 심이삭*, 김진영**

Young-Ghyu Sun*, Yu-Min Hwang*, Issac Sim*, Jin-Young Kim**

요약 본 논문은 전력선 통신에서 딥 러닝 기술 적용시킨 연구의 초기 결과를 보여준다. 본 논문에서는 전력선 통신의 성능을 감소시키는 원인인 잡음을 제거하기 위해 딥 러닝 기술을 적용시켜 효과적인 잡음 제거를 목표로 하고 수신단에서 딥 러닝 모델을 추가하여 잡음을 효과적으로 제거하는 시스템을 제안한다. 딥 러닝 모델을 학습시키기 위해서는 데이터가 필요하므로 기존의 데이터들을 저장하고 있다고 가정하고 제안하는 시스템에 대해 시뮬레이션을 진행하여 부가 백색 가우시안 잡음 채널의 이론적 결과와 비트 에러률을 비교하여 제안하는 시스템 모델이 잡음을 제거하여 통신 성능을 향상시킨 것을 확인한다.

Abstract This paper shows the initial results of a study applying deep learning technology in power line communication. In this paper, we propose a system that effectively removes noise by applying a deep learning technique to eliminate noise, which is a cause of reduced power line communication performance, by adding a deep learning model at the receive part. To train the deep learning model, it is necessary to store the data. Therefore, it is assumed that the existing data is stored, and the proposed system is simulated. we compare the theoretical result of the additive white Gaussian noise channel with the bit error rate and confirm that the proposed system model improves the communication performance by removing the noise.

Key Words : deep learning, de-noising, power line communication system, additive white Gaussian noise channel, multi-layer perceptron

1. 서 론

전력선 통신 기술은 기존의 전력선망을 이용하여 통신이 가능하기 때문에 별도의 통신 선로의 설치가 불필요하고 콘센트를 이용하여 간편하게 접근이 가능하다는

장점을 가지고 있어 어떤 솔루션보다도 가격 경쟁력을 가진다^[1]. 하지만 높은 부하 간섭과 잡음, 제한된 전송 능력, 가변하는 신호 감쇄 및 임피던스 특성, 주파수 선택적 특성이라는 단점^[1]을 가지고 있어 데이터 통신에는 어울리지 않는다는 다양한 실험 결과가 발표되었었다.

*준회원, 광운대학교 전자공학과

**정회원, 광운대학교 전자공학과, 교신저자

접수일자: 2018년 6월 27일, 수정완료: 2018년 7월 27일

게재확정일자: 2018년 8월 10일

Received: 27 June, 2018 / Revised: 27 July, 2018 /

Accepted: 10 August, 2018

**Corresponding Author: jinyoung@kw.ac.kr

Dept of Wireless Communications Engineering, Kwangwoon Univ, Seoul, Korea

최근 4차 산업혁명을 맞이하여 IoT, 인공지능, 빅 데이터 등 기술의 발전으로 인해 전력선통신이 갖는 한계가 극복 가능한 대상되었고 특히 IoT 기술의 응용분야로써 스마트 홈 네트워크, 스마트 그리드 등에 전력선 통신 기술을 적용시키는 연구들이 진행되면서 전력선 통신 기술의 표준화와 상용화를 통해 전력선 통신의 부활이 생각되어진다.

인공지능의 딥 러닝 기술도 전력선 통신 기술과 마찬가지로 이전에 활발히 연구가 진행되었으나 과적합의 문제와 긴 학습시간으로 인해 탁월한 성능을 보임에도 현실에 적용하기에는 실용적이지 않은 것으로 간주되었다^[2]. 그러나 시간이 흘러 하드웨어 기술의 발달과 효율적인 학습 방법에 대한 알고리즘의 개발로 학습시간이 짧아지게 되었고 프리트레이닝, 드랍 아웃 등 과적합 문제를 방지할 수 있는 알고리즘들이 개발되면서 이전에 가지고 있던 문제점들의 해결로 4차 산업혁명의 핵심기술로 자리매김하게 되었다^[2].

전력선 통신의 성능을 저하시키는 주요한 원인으로서는 잡음문제가 있다. 전력선 통신 상황에서 발생하는 잡음은 크게 주기성 잡음과 비주기성 잡음으로 분류할 수 있고 주기성 잡음은 규칙성이 존재하므로 다양한 모델링을 통해 제거할 수 있는 방법들이 존재하지만 비주기성 잡음은 불규칙하게 발생하기 때문에 하나의 모델로 모델링할 수 없어 통신성능을 저하시킨다. 이러한 문제를 해결하기 위해 본 논문에서는 딥 러닝 기술을 이용해 잡음을 모델링하고 모델링한 잡음을 통해 통신 신호의 잡음을 제거하여 통신 성능 향상시키는 시스템 모델을 제안한다.

본 논문의 구성은 다음과 같다. II장에서는 전력선통신의 기존 시스템 모델에 대해 살펴보고 III장에서는 딥 러닝 기술에 대해 설명한다. IV장에서는 전력선 통신 신호의 잡음 모델링에 대해 알아본 후 V장에서 딥 러닝 기술을 이용하여 잡음을 제거하는 시스템 모델을 제안한다. VI장에서는 제안한 시스템의 시뮬레이션 결과를 확인하고 장에서 결론을 통해 마무리 짓는다.

II. 전력선 통신의 기존 시스템 모델

국내에서 사용되는 전력은 60Hz의 교류 신호로 가진 기기는 전력변환기를 통해 직류로 바꿔 사용하며 전력선 통신에서의 정보신호는 고주파와저출력의 신호이므로 가전기기 작동에 어떠한 영향도 미치지 않는다. 전력선

통신의 정보신호를 송신할 때는 전력을 보내기 위해 이용되는 60Hz의 주파수에 고주파 신호를 실어 전송하고 수신할 때는 고주파 필터를 이용해 정보신호를 분리한다. 이러한 부분을 구현하기 위해 커패시터와 인덕터를 이용하는 라인 커플러가 사용된다. 라인 커플러는 송신 시에는 고주파의 정보신호가 커패시터를 통과하여 전력선에 실리게 되며 인덕터 쪽으로는 누출되지 않고 수신시에는 고주파의 정보신호만 커패시터를 통과하는 구조로 이루어져있다. 이후의 과정은 일반적인 디지털통신 시스템과 같이 모델을 통해 변복조를 하여 데이터를 얻는 과정이다. 전력선통신의 기존 시스템 모델은 그림1^[1]과 같이 표현된다.

III. 딥 러닝

딥 러닝 기술은 컴퓨터 비전^[3], 자연어 처리^[4], 음성 인식^[5] 등 많은 분야에서 상당한 성능향상을 보여준다. 포괄적인 딥 러닝 기술은^[6]에 설명이 되어있다.

1. 다층 퍼셉트론

그림2^[7]는 다층 퍼셉트론(Multi-layer perceptron)의 구조이다. 일반적으로 신경망(neural network) 구조에서 은닉 층(hidden layer)이 하나인 구조를 인공신경망(artificial neural network)이라 하고 은닉 층이 2개 이상의 경우 다층 퍼셉트론 또는 딥 뉴럴 네트워크(deep neural network)라 한다. 딥 뉴럴 네트워크에서 은닉 층의 수를 증가시키면 표현이나 인식 능력을 향상시킬 수 있고 뉴럴 네트워크의 각 계층은 여러 개의 뉴런으로 구성되며, 각 뉴런은 그림2와 같이 이전 계층의 뉴런들의 가중치 합에 비선형 함수인 출력을 가진다.




그림 1. 전력선 통신의 기존 시스템 모델.
Fig. 1. The existing system model of power line communication.




그림 2. 다층 퍼셉트론의 구조.
 Fig. 2. Structure of multi-layer perceptron.

비선형함수는 활성화함수라고 부르며 다양한 비선형 함수들이 이용되며 뉴럴 네트워크의 학습과정에서의 문제점을 해결하기 위해 주로 Relu 함수를 사용한다.

2. 손실함수

뉴럴 네트워크의 학습과정에서 최소화시키려는 값을 말하고 목적함수라고도 한다. MSE(Mean Square Error), crossentropy 등이 있으며 손실함수는 가중치를 정의역으로 가지는 함수이다. 손실함수가 최솟값을 가지는 가중치의 값이 해당 뉴럴 네트워크의 최적의 가중치이며 다양한 최적화 알고리즘이 사용하여 손실함수의 최솟값을 구할 수 있다. 본 논문에서는 아담 최적화알고리즘(Adam optimizer)^[8]을 사용하여 최적의 가중치를 구한다.

IV. 전력선 통신 신호의 잡음

전력선 통신의 잡음 채널은 다른 통신 채널들과 다르게 부가 백색 가우시안 잡음(AWGN : Additive White Gaussian Noise) 모델로 묘사할 수 없다^[9]. 그래서 전력선 통신의 잡음은 크게 주기성 잡음과 비주기성 잡음으로 나눌 수 있으며 비주기성 잡음으로 인해 하나의 모델로 묘사하기가 어렵다. 그래서 주기성 잡음에 대해 모델링을 하고 전력선 통신선로에서 주기성 잡음의 예로 충동적인 잡음(impulsive noise)가 있다.

본 논문에서는 수신 신호의 잡음 채널이 배경소음(background noise)와 충동적인 잡음만이 존재한다고 가정하므로 수신 신호는 다음과 같이 표현할 수 있다.

$$y(t) = x(t) + n(t). \quad (1)$$

$$n(t) = n_b(t) + n_i(t). \quad (2)$$

여기서 $x(t)$ 는 송신신호, $y(t)$ 는 수신신호, $n(t)$ 는 잡음신호, $n_b(t)$ 는 배경소음, $n_i(t)$ 는 충동적인 잡음이다.

V. 제안하는 시스템 모델

제안하는 시스템 모델은 그림3과 같다. 수신 단에서 전력선에서 정보신호만을 추출하는 라인커플러와 복조기 사이에 데이터를 저장할 수 있는 메모리 부분과 덤핑 모델이 추가된다. 제안하는 시스템 모델은 그림4와 같이 잡음을 모델링하는 모드와 그림5와 같이 모델링된 잡음을 이용하여 잡음을 제거하여 복조를 진행하여 데이터를 수신하는 모드가 있다. 먼저 잡음을 모델링하는 모드에서는 송신 단에서 파일럿(pilot) 신호를 송신하고 수신 단에서 파일럿 신호에 잡음이 추가된 신호를 수신하고 수신된 신호가 학습된 덤핑 모델의 입력으로 들어가서 출력으로 예측된 잡음이 나와 메모리에 저장되어진다. 데이터를 수신하는 모드에서는 데이터를 가지고 있는 신호를 송신하면 수신 단에서는 잡음이 추가된 신호를 수신하게 되고 수신된 신호를 복조하기 전에 메모리에 저장되어 있던 예측한 잡음 신호를 수신된 신호에서 뺄으로써 잡음을 제거하여 복조를 한다. 만약 학습된 덤핑 모델을 통해 잡음 신호가 정확히 잡음을 모델링하였다면 복조를 통해 나온 데이터는 손실이 존재하지 않을 것이다.




그림 3. 제안하는 시스템 모델.
 Fig. 3. The proposed system model.




그림 4. 잡음을 모델링하는 모드.
 Fig. 4. Noise modeling mode.




그림 5. 모델링된 잡음을 이용하여 잡음 제거 모드.
Fig. 5. Noise elimination mode using the modeling noise.




그림 6. 입력과 타겟 데이터를 얻는 과정.
Fig. 6. The process of obtaining input and target data.

1. 딥 러닝 모델 학습

딥 러닝 모델을 학습하기 위해서는 입력 데이터와 타겟 데이터의 데이터 셋이 있어야 한다. 본 논문에서는 입력 데이터로 파일럿 신호에 잡음이 추가된 신호를 타겟 데이터로 잡음 신호를 사용한다. 타겟 데이터로 사용되는 잡음 신호는 파일럿 신호를 송신하여 수신하고 수신단에서 파일럿 신호를 발생시켜 수신한 신호에서 빼면 구할 수 있다. 그림6은 이러한 과정을 나타낸다. 앞의 과정을 통해 입력 데이터와 타겟 데이터를 저장하여 데이터 셋을 만들어 딥 러닝 모델을 데이터 셋에 대해 반복적으로 학습시키면 잡음이 섞인 파일럿 신호에 대한 입력을 통해 예측한 잡음 신호를 출력이 나온다. 데이터 셋을 저장하고 있다는 가정 하에 제안하는 시스템 모델을 사용한다.

VI. 시뮬레이션 및 결과

데이터 셋은 컴퓨터를 이용하여 랜덤하게 발생시킨 10만개의 데이터를 사용하고 딥러닝 모델은 490개의 뉴런으로 이루어진 1개의 은닉 층을 가지는 모델을 사용하였다. 딥 러닝 모델에서 최적의 은닉 층의 개수와 은닉 층을 구성하는 뉴런의 개수를 명확히 구하는 방법은 없고 경험적으로 구하는 방법 밖에 없어 여러 번을 시뮬레이션을 통해 최적의 모델을 구하였다. 변복조 방식으로는

BPSK(Binary Phase Shift Keying)와 QPSK(Quadrature Phase Shift Keying)에 대해 시뮬레이션을 진행하였다. 그림7은 딥 러닝 모델의 학습 정확도를 나타낸다. 데이터 셋을 반복적으로 학습시키면 점점 정확도가 증가하고 약 98%에 수렴하는 것을 확인할 수 있다. 그림8은 잡음을 모델링한 그림이다. 위의 그림은 타겟 신호이고 아래의 그림은 학습된 딥러닝 모델을 통해 예측된 잡음 신호이다. 파형으로 비교해보았을 때 잡음이 잘 예측되었다는 것을 확인할 수 있다.




그림 7. 딥러닝 모델의 학습 정확도.
Fig. 7. train accuracy of deep learning model.




그림 8. 타겟 잡음과 모델링한 잡음.
Fig. 8. Target noise and modeling noise.




그림 9. BPSK 변복조 방식에 대한 시뮬레이션 결과.
Fig. 9. Simulation result for BPSK.




그림 10. QPSK 변복조 방식에 대한 시뮬레이션 결과.
 Fig. 10. Simulation result for QPSK.

그림9는 BPSK 변복조 방식에 대해 제안한 시스템 모델을 적용시켜 시뮬레이션을 진행하여 얻은 BER(Bit Error Rate) 그래프이다. 이론적인 BER 그래프와 비교해 봤을 때 잡음대비 신호의 세기가 작을 경우 잡음이 많이 제거되어 제안한 시스템 모델의 성능이 좋다는 것을 확인할 수 있다. 잡음대비 신호의 세기가 큰 경우는 오히려 성능이 좋지 않은 것을 확인할 수 있다. 이러한 현상이 발생한 이유는 딥러닝 모델의 학습 정확도가 100%가 아니기 때문에 잡음 예측에서 에러가 발생할 수 있으며 잡음대비 신호의 세기가 큰 경우에는 잡음의 세기가 작으므로 값을 예측하기 어려워 예측한 잡음이 오히려 에러를 발생하는 원인이 된 것으로 생각된다.

그림10은 QPSK 변복조 방식에 대해 제안한 시스템 모델을 적용시켜 시뮬레이션을 진행하여 얻은 BER 그래프이다. BPSK의 경우와 같은 성능을 보이는 것을 확인할 수 있다.

Ⅶ. 결 론

본 논문은 전력선 통신에서 딥 러닝 기술을 이용하여 잡음을 모델링하고 모델링된 잡음을 이용하여 신호에 추가된 잡음을 제거하여 통신 성능을 향상시키는 시스템 모델을 제안하였다. 또한, 제안한 시스템 모델을 적용시켜 변복조방식에 따라 시뮬레이션을 진행해보고 통신 성능을 확인하였다. 성능은 기존의 잡음이 있을 때의 이론적인 결과보다 좋게 나왔다. 다만, 잡음대비 신호의 세기가 큰 경우 예측한 잡음이 통신성능을 감소시키는 원인이 되었고 이러한 문제를 없애기 위해서 보다 많은 데이

터를 수집하고 딥 러닝 모델을 변경하여 학습 정확도를 100%로 한다면 해결할 수 있을 것으로 생각된다. 만약 학습 정확도를 100%로 만든다면 잡음대비 신호의 세기가 작은 경우에서도 성능이 더욱 좋아질 것이다. 제안한 시스템 모델은 전력선 통신뿐만 아니라 일반적인 통신시스템에서도 적용이 가능하여 전력선 통신이외의 통신시스템에서도 통신성능을 향상시키는 방법이 될 수 있다. 제안하는 시스템 모델을 이용하기 위해서는 데이터의 확보가 필수적이므로 앞으로의 연구는 데이터의 확보 방법과 학습 정확도를 100%로 만드는 방법에 대해 연구하는 방향으로 진행될 것이다.

References

- [1] J. H. Kim and H. B. Lee, "Market trends and prospects for power line communication," in *Proc. Information and Communication Equipment*, pp. 573-578, Aug, 2008.
- [2] D. K. Kang, "Deep learning based machine learning technology trends," *ITFIND-Weekly Technology Trends*, vol. 1742, pp. 12-24, Apr. 2016.
- [3] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in *Proc. Adv. Neural Inf. Process. Syst.*, pp. 1097 - 1105, 2012.
DOI : <https://doi.org/10.1145/3065386>
- [4] K. Cho, "Learning Phrase Representations Using RNN Encoder-Decoder for Statistical Machine Translation," 2014 [Online]. Available: <http://arxiv.org/abs/1406.1078>
DOI : <https://doi.org/10.3115/v1/d14-1179>
- [5] C. Weng, D. Yu, S. Watanabe, and B.H. F. Juang, "Recurrent deep neural networks for robust speech recognition," in *Proc. ICASSP*, Florence, Italy, pp. 5532 - 5536, May 2014.
DOI : <https://doi.org/10.1109/icassp.2014.6854661>
- [6] J. Schmidhuber, "Deep learning in neural networks: An overview," *Neural Netw.*, vol. 61, pp. 85 - 117, Jan. 2015.
DOI : <https://doi.org/10.1016/j.neunet.2014.09.003>
- [7] H. Ye, G. Y. Li, and B. H. Juang "Power of deep

learning for channel estimation and signal detection in OFDM systems," *IEEE Wireless Communications Letters*, vol. 7, pp. 114 - 117, Feb. 2018.

DOI : <https://doi.org/10.1109/lwc.2017.2757490>

- [8] D. P. Kingma, and J. L. Ba "Adam : a method for stochastic optimization," in *Proc. ICLR 2015*, pp. 1 - 15, San Diego ,May. 2015.

DOI:<https://doi.org/10.1002/9780470061602.eqf13013>

- [9] L. D. Bert, P. Caldera, D. Schwingshack, and A. M. Tonello "On noise modeling for power line communications," in *Proc. 2011 IEEE international Symposium on Power Line Communications and Its Applications*, pp. 283 - 288, Udine, Italy, May 2011.

DOI : <https://doi.org/10.1109/isplc.2011.5764408>

- [10] D. H. Na, and D. H. Ryu, "Development of time information broadcasting system using power line communication," *The Journal of The Institute of Internet, Broadcasting and Communication(JIIBC)*, vol. 12, no. 1, pp. 217 - 223, Feb. 2012.

DOI : <https://doi.org/10.7236/jiwit.2012.12.1.217>

- [11] H. S. Cho, "Direct-band spread system for neural network with interference signal control," *Measurement of Intrusion Prevention System," Journal of the Korea Academia-Industrial cooperation Society(JKAIS)*, vol. 14, no. 3, pp. 1372 - 1377, Mar. 2013.

DOI : <https://doi.org/10.5762/kais.2013.14.3.1372>

저자 소개

선 영 규(준회원)



- 2018년 2월 : 광운대학교 전자융합공학 학사 졸업
- 2018년 3월 ~ 현재 : 광운대학교 전과공학과 석박사통합과정
- <관심분야> 인공지능, 무선 에너지 하베스팅, 디지털통신, 전력선 통신

황 유 민(준회원)



- 2012년 2월 : 광운대학교 전과공학과 학사 졸업
- 2012년 3월 ~ 현재 : 광운대학교 전과공학과 석·박사통합과정
- <관심분야> 디지털 통신, 무선에너지 하베스팅, 무선 측위 시스템, 인공지능, 전력선 통신

심 이 삭(준회원)



- 2016년 2월 : 광운대학교 전자융합공학과 졸업
- 2016년 3월 ~ 현재 : 광운대학교 전과공학과 석박사통합과정
- <관심분야> 전력선 통신, 무선 에너지 하베스팅, Backscatter, 인공지능

김 진 영(정회원)



- 1998년 2월 : 서울대학교 전자공학과 공학박사
- 2001년 2월 : SK텔레콤 네트워크 연구소 책임연구원
- 2001년 3월 ~ 현재 : 광운대학교 전자융합공학과 교수
- <관심분야> 차세대이동통신, 가시광통신, 전력선통신, 인공지능

※ 본 연구는 한국연구재단 이공학 개인기초연구지원사업(NRF-2016R1D1A1B03933872)의 일환으로 수행되었음.