

전력 지연 프로파일 분석을 통한 실내 구조 형태 인식

이 정 용*, 김 성 철^o

Estimation of Room Shape Using Power Delay Profile Analysis

Jung-Yong Lee*, Seong-Cheol Kim^o

요 약

본 논문에서는 전력 지연 프로파일을 통해 실내 구조 형태를 인식하는 새로운 알고리즘을 제안한다. 기존의 경험적 알고리즘에 기반한 방법과는 달리 본 논문에서 제안하는 기법은 축적된 전력 지연 프로파일 데이터를 사용하여 인공신경망을 학습시킨 후, 이를 활용하기 때문에 향상된 성능을 나타낸다.

Key Words : Deep learning, multilayer perceptron, radio propagation, room shape prediction

ABSTRACT

This study proposes a novel algorithm for estimating room shape using radio waves. Unlike the conventional methods, the proposed method exploits accumulated radio channel data to estimate room shape. The simulation results indicated that better performance was obtained when using proposed method.

I. 서 론

최근, 실내에서 다양한 기기의 위치를 추정하는 연구 뿐 아니라, 해당 기기가 존재하는 장소의 형태를 추정하려는 연구 또한 진행되고 있다. 실내 구조의 형

태를 추정하는 것이 가능할 경우 이는 가상현실 구현, 로봇의 이동경로 계산, 전자기기의 전파 커버리지 분석 등의 다양한 상황에 대해 도움을 줄 수 있기에 실내 구조 추정은 주목받고 있다.

최근에는 카메라 등을 활용하여 실내 구조의 형태를 추정하는 기법이 제안되었다¹⁾. 하지만 카메라를 활용하는 기법은 빛의 유무와 장애물 존재에 의해 크게 영향을 받기 때문에 다양한 환경에서 적용이 어렵다. 이와는 별개로, 음파를 활용하여 실내 구조를 추정하는 기법 또한 제안되었다²⁾. 음파는 벽 등 장애물에 의한 영향을 크게 받으며 해당 기법은 경험적 기법에 크게 의존하고 있기 때문에 다양한 환경에서 성능을 보장할 수 없다.

본 논문에서는 전파를 활용하여 실내 구조를 추정하는 기법을 제안한다. 전파를 활용하는 알고리즘은 빛의 유무, 장애물 등에 영향을 비교적 적게 받는 장점이 있다. 본 논문에서 제안하는 기법은 무수히 많은 환경에서의 전력 지연 프로파일을 인공신경망에 학습한 후, 이를 활용하여 임의의 환경에서 얻어진 전력 지연 프로파일을 통해 실내 구조를 추정하는 방식이다. 본 논문에서는 이 기법의 성능을 분석하여 실내 구조 추정의 방향성을 제시한다.

II. 시스템 모델 및 문제 정의

본 논문에서는 6면체 공간의 한 인접한 위치에 송수신기가 존재하는 상황을 가정한다. 송신기에서는 프리엠블신호를 송신하며 송신신호는 채널을 통과한 후 수신기에 도달한다. 수신기는 수신기에 도달한 수신신호와 송신신호로부터 전력 지연 프로파일을 추정한다. 전력지연프로파일은 송신신호의 지연시간에 따른 수신결과를 나타내는 것이다. 변화하는 일반적인 통신시스템에서 전력 지연 프로파일은 least square 등의 알고리즘을 추정할 수 있다. 본 논문에서는 통신 시스템을 특정시키지 않으며, 전력 지연 프로파일은 위와 같은 알고리즘 등을 통해 얻어진 것으로 가정한다. 또한, 모델링의 간결함을 위하여 추정 과정에서 잡음은 존재하지 않는 것으로 가정한다.

* 이 논문은 2018년도 BK21 플러스 사업과 2015년도 정부(미래창조과학부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. NRF-2015R1A2A2A03008195).

• First Author : (ORCID:0000-0001-5247-4804) Department of Electrical and Computer Engineering and Institute of New Media and Communications, Seoul National University, fire3420@maxwell.snu.ac.kr, 학생회원

o Corresponding Author : (ORCID:0000-0002-7896-5625) Department of Electrical and Computer Engineering and Institute of New Media and Communications, Seoul National University, sckim@maxwell.snu.ac.kr, 종신회원

논문번호 : KICS2018-04-080, Received April 12, 2018; Revised April 30, 2018; Accepted May 9, 2018

III. 딥러닝 기반 실내 구조 형태 인식

본 논문에서는 축적된 데이터의 활용을 통한 실내 구조 형태 인식을 위하여 딥러닝 기법을 사용한다. 딥러닝 기법은 분석적 해법이 존재하지 않는 문제를 해결하는 데 있어 기존의 경험적 알고리즘이 인식하지 못하는 특징을 포착할 수 있다는 강점이 있다.

딥러닝 기법은 다층의 은닉계층을 중첩하여 인공신경망을 모방한다. 다층의 은닉계층을 구성하는 방법 중, 본 논문에서는 다중계층퍼셉트론 기법을 사용한다. 다중계층퍼셉트론의 구조를 갖는 인공신경망은 1개의 입력 계층, K 개의 은닉 계층, 1개의 출력 계층을 갖는다. 또한, 각 계층은 다수의 뉴런들로 이루어져 있으며, 각 계층의 뉴런을 통과한 출력 값은 다음 계층의 입력 값으로 사용된다. 이 때 각 출력 값은 활성화함수를 거친 후 다음 계층으로 전이 된다. 본 논문에서는 이와 같은 인공신경망에 전력 지연 프로파일 데이터를 학습시킴으로써 실내 구조 형태 추정기를 개발한다.

인공신경망에 입력되는 전력 지연 프로파일이 $\vec{s} = (s_1, s_2, \dots, s_j)$ 라 할 때, 출력 값은 실내 구조를 구성하는 꼭짓점으로 설정한다. 이 때, j 는 입력 파라미터의 총 길이를 나타낸다. 본 논문에서는 6면체 실내 구조를 가정하였기 때문에 출력 값은 $\vec{v} = (v_1, v_2, \dots, v_8)$ 이며 이 때 v_b ($b = 1, 2, \dots, 8$)는 각 꼭짓점의 3차원 좌표 벡터를 나타낸다. 이와 같이 정의된 입출력 데이터 관계를 수식으로 나타내면 다음과 같다.

$$\begin{aligned} \vec{v} &= f(\vec{s}, \vec{w}) \\ &= f^{(K)}(f^{(K-1)}(\dots(f^{(1)}(\vec{s}))\dots)), \end{aligned} \quad (1)$$

여기서 f 는 각 뉴런에 적용되는 활성화함수를 나타내며 \vec{w} 는 인공신경망을 구성하고 있는 가중치를 나타낸다. 이와 같은 입출력 데이터 관계를 구성하기 위하여 각 은닉계층에서는 다음과 같이 출력을 계산한다.

$$q_h^k = f^{(k)}\left(\sum_{i=1}^{N_{k-1}} w_{hi}^{(k)} q_i^{(k-1)}\right), \quad (2)$$

여기서 q_h^k 는 k 번째 은닉계층의 h 번째 뉴런에서 출력되는 값이며, $w_{hi}^{(k)}$ 는 $k-1$ 번째 계층의 i 번째 뉴런과 k 번째 은닉계층의 h 번째 뉴런 사이의 가중치이다. 이와 같이 구성된 인공신경망은 역전파 방법을 통해

예측오차를 최소화 시키는 가중치를 학습한다.

IV. 모의실험 결과

이 장에서는 인공신경망을 통하여 실내 구조 형태를 인식하는 기법의 성능을 분석한다. 인공신경망의 적절한 학습을 위해서는 다수의 데이터가 필요한데, 본 논문에서는 이를 효과적으로 얻기 위하여 [3]에서 그 정확성이 입증된 3D ray tracing 기법을 활용하였다.

4.1 Ray tracing 기법

본 논문에서 사용하는 ray tracing 기법은 송신기의 이미지를 각 벽에 대하여 만든 후, 이를 수신기와 연결하는 방식을 통해 가상의 경로를 계산하는 방식이다. 계산된 2차원 상의 경로는 건물의 높이 정보를 반영하여 3차원으로 확장된다. 3차원 상에서 계산된 각 전파경로는 반사, 회절, 전파(propagation) 과정을 거치며, 이에 의한 전력손실을 각 경로마다 계산한다. 그림1은 이에 대한 간략한 예시를 나타낸다. 본 논문에서는 학습과 검증에 사용하는 실내 구조의 가로 세로 크기를 5 ~ 22 m로 변화시켰다. 임의의 실내 구조 크기가 가로 길이 L_1 세로 길이 L_2 일 때 송수신기의 위치는 각 벽면에서 1m만큼 떨어진 곳을 제외한, $(L_1 - 2) \text{ m} * (L_2 - 2) \text{ m}$ 의 공간에 1 m 간격으로 변화시켜가며 위치하였다. 또한 모든 환경에서 수신기의 높이는 1.5m로 설정하였다.




그림 1. 실내 공간에서의 광선추적 기법 예시. 명료한 그림을 위하여 많은 광선 중 일부만이 도시됨.
Fig. 1. Some of the paths traced in an indoor building

4.2 실내 구조 형태 인식

본 논문에서는 인공신경망에 입력되는 전력 지연 프로파일의 차원을 일정하게 유지하기 위하여, 최대

도달 시각을 200 ns로 설정하였다. 만약 전파 채널의 최대도달시각이 200 ns보다 작을 경우, 최대 도달시각과 200 ns 사이의 전력 지연 프로파일에 -2000 dBm에 해당하는 경로들을 삽입하여 차원을 일치시켰다. 표 1은 전파채널 및 시스템을 모의실험하기 위한 파라미터와 인공신경망의 하이퍼 파라미터가 적시되어 있다. 본 논문에서는 인공신경망의 학습 및 검증을 위하여 총 324개의 환경에서 50505개의 전력 지연 프로파일을 얻은 후 이를 사용하였다. 이 때 데이터의 70%는 학습, 15%는 검증, 15%는 성능평가에 활용되었다. 그림 2는 본 알고리즘에서 제시하는 방법의 성능을 나타내고 있다. 비교 대상으로는 전력 지연 프로파일에서 얻어지는 평균 지연시간을 통하여 얻어진 실내 구조를 사용하였다. 이 기법은 실내의 벽면들이 송수신기로부터 평균 지연시간에 해당하는 거리만큼 위치해있는 것으로 예상하고 실내 구조를 추정하는 것이다. 누적분포함수는 인공신경망을 통해 얻는 실내구조의 형태 추정이 전력 지연 프로파일의 통계적 특성을 활용한 추정보다 매우 정확한 것을 나타내고 있다. 특히 데이터의 80%가 2 m 미만의 오차를 갖는 것으

로 나타난 것을 볼 때, 성능평가에 활용된 실내 구조의 크기가 최대 22 m인 것을 감안한다면 제안 기법이 매우 뛰어난 성능을 갖는다고 할 수 있다.

V. 결 론

본 논문에서는 실내 구조의 형태를 딥러닝을 통한 전력 지연 프로파일 분석을 이용하여 추정하는 기법을 제안하였다. 다양한 환경에서 3D ray tracing 기법을 통하여 전력 지연 프로파일을 얻은 후, 이를 인공신경망에 학습시킴으로써 추정기를 제작하였다. 이렇게 제작된 추정기는 임의의 환경에서 실내 구조를 추정하는 것에 사용되었으며, 이에 대한 성능평가가 수행되었다. 제안된 기법은 실내 구조의 형태를 매우 정확하게 예측하였다.

References

[1] C. H. Han and K. B. Sim, "Real-time mapping of mobile robot on stereo vision," *J. KICS*, vol. 20, no. 1, pp. 60-65, Feb. 2010.

[2] I. Dokmanic, R. Parhizkar, A. Walther, Y. M. Lu, and M. Vetterli, "Acoustic echoes reveal room shape," in *Proc. Natl. Acad. Sci.*, vol. 110, no. 30, pp. 12186-12191, Jun. 2013.

[3] J.-H. Jung, J. Lee, J.-H. Lee, Y.-H. Kim, and S.-C. Kim, "Ray-tracing aided modeling of user-shadowing effects in indoor wireless channels," *IEEE Trans. Ant. Propag.*, vol. 62, no. 6, pp. 3412-3416, Jun. 2014.

표 1. 시스템 파라미터
Table 1. System Parameters.

Parameters	Values
Center frequency	5 GHz
Transmit power	20 dBm
Number of hidden layers	3
Number of neurons for each hidden layer	50, 50, 20
Activation function	Sigmoid function

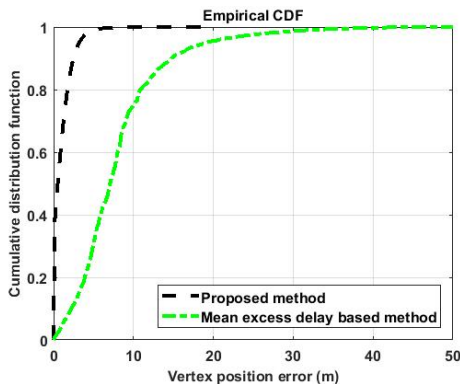


그림 2. 실내 구조 형태 인식 기법의 성능에 대한 누적분포함수
Fig. 2. Cumulative distribution function of room shape prediction performance.