

Meijer G-함수를 활용한 딥러닝 기반 설명 가능한 패스로스 모델

이현석

세종대학교

hyunsuk@sejong.ac.kr

Explainable Deep Learning-Based Pathloss Model Using Meijer G-Function

Hyun-Suk Lee

Sejong University

요약

딥러닝 기법을 활용하면 무선 측정 데이터로부터 효율적으로 정확한 심층신경망 패스로스 모델을 학습시킬 수 있으나, 심층신경망의 불투명성으로 인해 학습된 패스로스 모델의 특성을 분석하고 이해하기 어려운 문제가 있다. 본 논문에서는 학습된 심층신경망 패스로스 모델을 Meijer G-함수를 기반으로 한 수학적 표현으로 근사하여 설명 가능한 패스로스 모델을 구성하는 기법을 개발하고, 모의실험을 통해 제안 기법을 통해 찾은 모델이 심층신경망 패스로스 모델을 정확하게 근사하는 것을 보인다.

I. 서론

최근 통신 시나리오는 mmWave, 대규모 안테나 기술 등의 등장으로 인해 점점 더 복잡해지고 있다 [1]. 기존의 패스로스 모델링 방식은 무선 측정 데이터의 포스트 프로세싱을 통해, 패스로스의 특성을 조사하고, 이를 기반으로 패스로스 모델을 구성하는 형태로 진행되었다. 하지만 최근에 등장하는 복잡한 시나리오에서는 데이터의 복잡성과 다양성으로 인해 포스트 프로세싱이 어려워지고 높은 비용이 요구되므로 기존의 패스로스 모델링 방식이 사용되기 어려운 문제가 있다 [2]. 이를 해결하기 위해 최근 딥러닝 기술의 비약적인 발전과 함께 데이터로부터 패스로스 모델을 직접적으로 학습하여 전통적인 데이터의 포스트 프로세싱을 수행하지 않고도 정확한 패스로스 모델을 구하는 딥러닝 기법 기반의 효율적인 데이터-드러본 패스로스 모델링이 연구되고 있다 [3].

이 같은 딥러닝 기반의 패스로스 모델링은 일반적으로 심층 신경망(Deep Neural Network, DNN)을 이용한다. DNN을 이용한 패스로스 모델은 DNN이 갖는 높은 학습용량을 바탕으로 복잡한 패스로스 환경을 효과적으로 학습할 수 있게 한다. 하지만 DNN 모델의 경우 학습된 모델 내부의 동작 원리를 설명하기 어려운 한계가 있다 [4]. 이 같은 DNN 모델의 불투명성으로 인해 DNN 모델은 블랙박스 모델로 불린다. 따라서 DNN을 이용하여 학습된 채널 패스로스 모델의 경우 물리적인 송수신단 간 거리, 반송파 주파수 등과 같은 주어진 물리량으로부터 패스로스 출력값을 계산할 수 있으나, 주어진 물리량으로부터 패스로스가 어떻게 정해지는지 내부적인 원리를 설명할 수 없기 때문에 물리량과 패스로스 사이의 관계, 중요도와 같은 패스로스 모델 특성을 분석하고 이해하기 어렵다. 그러므로 이 같은 문제를 해결하기 위하여 DNN 패스로스 모델을 학습한 뒤, 더 나아가 사람이 이해할 수 있고 분석 가능한 형태로 표현할 필요가 있다.

본 논문에서는 위의 문제를 해결하기 위해 Meijer G-함수를 활용하여 DNN 패스로스 모델을 근사하는 이해 가능하고 분석 가능한 수학적 표현을 갖는 설명 가능한 패스로스 모델을 구하는 방법을 제안하고, 실험을 통해 Meijer G-함수 기반 설명 가능한 패스로스 모델이 학습된 DNN 패스로스 모델을 정확히 근사함을 보인다.

II. 딥러닝 기반 패스로스 모델

본 논문에서는 딥러닝 기반 채널 패스로스 모델을 고려한다. 이 같은 패스로스 모델을 위해서는 순방향 신경망 (Feedforward Neural Network) 혹은 컨볼루션 신경망 (Convolutional Neural Network)과 같은 심층 신경망 (DNN)이 사용되며, 신경망의 학습을 위해 무선 측정 데이터 혹은 시뮬레이션을 이용한 데이터셋이 활용된다. 일반적으로 채널 패스로스 모델은 송수신단 3차원 좌표, 송수신단 간 거리, 반송파 주파수 등의 물리적인 입력값들을 기반으로 송수신단 간 패스로스를 출력값으로 예측한다. 따라서 딥러닝 기반 패스로스 모델에서는 입력 feature로 갖고 송수신단 간 패스로스를 출력값으로 갖는 DNN을 구성하고 데이터를 이용하여 학습시켜 패스로스 모델을 구현한다 [2].

딥러닝 기반 패스로스 모델을 구성하는 DNN의 입력 feature와 출력값을 각각 $\mathbf{x} = (x_1, x_2, \dots, x_K)^T \in X$ 및 $y \in Y$ 라 정의한다. 여기서 K 는 입력 feature의 개수를 의미하고 X 및 Y 는 각각 입력 공간, 출력 공간을 의미하며, 일반성을 잃지 않고 입력 공간이 $X = [0, 1]^K$ 과 같음을 가정할 수 있다. 위의 정의를 기반으로 물리적인 실제 무선 환경에서 입력 feature와 채널 패스로스와의 관계를 함수 $H: X \rightarrow Y$ 로 정의한다. 딥러닝 기반 패스로스 모델은 DNN $h: X \rightarrow Y$ 가 앞서 정의한 함수 $H(\mathbf{x})$ 를 근사하도록 (즉, $h(\mathbf{x}) \approx H(\mathbf{x}), \forall \mathbf{x} \in X$) 기계학습 기법을 이용하여 DNN을 학습시킨다.

III. Meijer G-함수를 활용한 설명 가능한 패스로스 모델

딥러닝 기반 패스로스 모델로부터는 DNN의 불투명성으로 인해 각 물리적 입력값들이 패스로스에 미치는 영향, 특성, 중요도 등을 분석하기 어려운 문제가 있다. 이를 해결하기 위해 DNN 모델의 불투명성을 해결할 수 있는 설명 가능한 형태의 패스로스 모델을 구성할 필요가 있고, 본 논문에서는 Meijer G-함수를 이용하여 DNN 패스로스 모델 $h(\mathbf{x})$ 를 이해 가능하고 분석 가능한 수학적 표현으로 나타내는 방법을 연구하였다.

이를 위해, 먼저 이해 가능하고 분석 가능한 수학적 표현들을 포함하는 class $\mathcal{M}$ 을 정의하고, 설명 가능한 패스로스 모델을 구성하기 위해서

DNN 패스로스 모델 $h(\mathbf{x})$ 를 가장 정확히 근사하는 함수 $m \in \mathcal{M}$ 을 찾을 필요가 있다. 함수 $m(\mathbf{x})$ 의 DNN 패스로스 모델 $h(\mathbf{x})$ 에 대한 근사 오차를 Mean Squared Error (MSE)과 입력 feature $\mathbf{x}$ 의 분포 $F(\mathbf{x})$ 를 이용하여 수학적으로 나타내면 아래 수식과 같다.

$$l(m, h) = \|m - h\|_2^2 = \int_{\mathcal{X}} (m(\mathbf{x}) - h(\mathbf{x}))^2 dF(\mathbf{x}) \quad (1)$$

앞서 정의한 근사오차를 이용하여 설명 가능한 패스로스 모델 $m(\mathbf{x})$ 를 찾는 최적화 문제를 아래와 같이 정의할 수 있다.

$$\arg \min_{m \in \mathcal{M}} l(m, h) \quad (2)$$

Meijer G-함수는 파라미터 $a_i, b_j \in \mathbb{R}, \forall i = 1, \dots, p, j = 1, \dots, q$ 및 $m, n, p, q \in \mathbb{N}$ 으로 특징되는 함수로써, 정의는 아래와 같다.

$$G_{p,q}^{m,n} \left(\begin{matrix} a_1, \dots, a_p \\ b_1, \dots, b_q \end{matrix} \middle| x \right) = \frac{1}{2\pi i} \int_{\mathcal{L}} \frac{\prod_{j=1}^m \Gamma(b_j - s) \prod_{j=1}^n \Gamma(1 - a_j + s)}{\prod_{j=m+1}^q \Gamma(1 - b_j + s) \prod_{j=n+1}^p \Gamma(a_j - s)} x^s ds$$

위의 정의에서 $\Gamma(\cdot)$ 은 Gamma 함수를 의미한다. Meijer G-함수는 주어진 파라미터에 따라 지수함수, 삼각함수, 초기하함수 등 알려진 많은 함수를 표현할 수 있다. 아래에서 Meijer G-함수를 이용하여 설명 가능한 패스로스 모델 $m(\mathbf{x})$ 를 파라미터 θ 로 표현되는 함수 $M_\theta(\mathbf{x})$ 로 정의한다. Kolmogorov superposition 정리에 따르면 어떤 다변수 함수도 표현할 수 있고, 이를 활용하여 다변수 함수인 패스로스 모델을 단변수 함수인 Meijer G-함수로 아래와 같이 표현한다.

$$M_\theta(\mathbf{x}) = \sum_{i=0}^r G_{p,q}^{m,n} \left(\theta_i^{\text{out}} \middle| \sum_{j=1}^K G_{p,q}^{m,n}(\theta_{ij}^{\text{in}} | x_j) \right)$$


위의 식에서 파라미터 $\theta = (\theta^{\text{out}}, \theta^{\text{in}})$, $\theta^{\text{out}} = (\theta_0^{\text{out}}, \dots, \theta_r^{\text{out}})$, 그리고 $\theta^{\text{in}} = \{(\theta_{i1}^{\text{in}}, \dots, \theta_{iK}^{\text{in}})\}_{i \in \{0, \dots, r\}}$ 를 의미하고 각 파라미터 θ 들은 $a_1, \dots, a_p$ 및 $b_1, \dots, b_q$ 로 구성된다. 마지막으로 (m, n, p, q, r) 은 $M_\theta(\mathbf{x})$ 를 표현하는 초파라미터이다. 따라서 수식 (2)의 문제는 DNN 패스로스 모델을 근사하는 M_θ 를 찾는 파라미터 최적화 문제로 변형된다. 파라미터 θ 의 공간이 Θ 일 때, Meijer G-함수 기반 수학적 표현 class는 $\mathcal{M} = \{M_\theta : \theta \in \Theta\}$ 로 정의되고, 주어진 공간 Θ 에 따라 polynomial, algebraic, closed-form 등 폭넓은 수학적 표현 class를 표현한다. 따라서 분석 목적에 따라 적절한 파라미터 공간을 선택할 필요가 있다 [5]. Meijer G-함수 기반 설명 가능한 패스로스 모델을 구하기 위해 M_θ 를 이용하여 수식 (2)의 문제를 아래와 같은 파라미터 최적화 문제로 다시 정의한다.

$$\arg \min_{\theta \in \Theta} l(M_\theta, h) \quad (3)$$

위 문제를 해결하기 위해서 근사오차를 최소화하는 최적 파라미터 θ^* 를 구해야 한다. Meijer G-함수의 또 다른 장점은 파라미터에 대한 그래디언트를 수치적으로 구할 수 있다는 점이고, 이를 이용하면 일반적인 그래디언트 최적화 기법들을 활용하여 수식 (3)의 문제의 최적 파라미터를 효율적으로 구할 수 있다는 것이 알려져 있다 [5]. 구체적으로, 임의의 입력 feature를 생성하고 생성된 입력값들을 기반으로 경사하강법 (gradient descent algorithm)을 이용하여 근사오차를 최소화하는 파라미터 θ^* 를 구하여 Meijer G-함수 기반 설명 가능한 패스로스 모델 M_θ 를 얻는다. 패스로스 모델 M_θ 는 수학적 표현으로 Taylor 급수 등을 이용하여 feature 중요도 및 상관도 등을 쉽게 분석할 수 있는 장점이 있다 [5].

IV. 모의실험

모의실험을 통해 Meijer G-함수 기반의 설명 가능한 패스로스 모델 (MGF)이 딥러닝 기법을 통해 학습된 DNN 패스로스 모델을 효과적으로 근사하는지 살펴본다. 이를 위해 임의의 거리를 생성하고 WINNER II 패스로스 모델에서 거리를 임의로 생성된 거리에 따른 패스로스에 평균 0 표준편차 0.1을 갖는 가우시안 잡음을 추가하여 1000개의 샘플을 갖는 패스로스 데이터셋을 생성하였고, 해당 데이터셋을 이용하여 100개의 unit으로 이루어진 2개의 hidden layer들로 구성된 DNN 패스로스 모델을 학습시켰다. 이후 학습된 DNN 패스로스 모델을 Meijer G-함수를 이용하여 설명 가능한 패스로스 모델로 근사하였다.



(a) 정규화된 패스로스

(b) 복원된 패스로스

그림 1. 패스로스 모델들의 비교

그림 1은 원래의 패스로스 모델 WINNER II와, DNN 패스로스 모델, Meijer G-함수 기반 패스로스 모델을 보여준다. WINNER II 모델로부터 생성된 데이터셋을 정규화시켜 DNN을 학습시켰으므로 그림 1(a)에서는 정규화된 패스로스 모델을 보여주고, 그림 1(b)에서는 복원된 패스로스 모델을 보여준다. 두 그림 모두 DNN 모델이 효과적으로 WINNER II 모델을 학습한 것을 보여주며, Meijer G-함수 기반의 설명 가능한 모델 또한 DNN 모델을 효과적으로 근사하고 있는 것을 볼 수 있다. 위 결과를 통해 제안 기법이 DNN 패스로스 모델을 정확히 근사하는 Meijer G-함수를 기반으로 하는 설명 가능한 패스로스 모델을 찾는다는 것을 알 수 있다.

V. 결론

본 논문에서는 학습된 DNN 패스로스 모델을 Meijer G-함수를 기반으로 한 수학적 표현으로 근사하여 설명 가능한 패스로스 모델을 구성하는 기법을 개발했고, 모의실험을 통해 제안 기법을 통해 찾은 설명 가능한 모델이 DNN 패스로스 모델을 정확하게 근사하는 것을 보였다.

참고 문헌

- [1] W. H. Chin, Z. Fan, and R. Haines, "Emerging technologies and research challenges for 5G wireless networks," *IEEE Wireless Commun.*, vol. 21, no. 2, pp. 106–112, Apr. 2014.
- [2] J. Huang, C. Wang, L. Bai, J. Sun, Y. Yang, J. Li, O. Tirkkonen, and M. Zhou, "A big data enabled channel model for 5G wireless communication systems," *IEEE Trans. Big Data*, vol. 6, no. 2, pp. 211–222, June 2020.
- [3] J. Thrane, D. Zibar, and H. L. Christiansen, "Model-aided deep learning method for path loss prediction in mobile communication systems at 2.6 GHz," *IEEE Access*, vol. 8, pp. 7925–7936, 2020.
- [4] W. Guo, "Explainable artificial intelligence for 6G: Improving trust between human and machine," *IEEE Commun. Mag.*, vol. 58, no. 6, pp. 39–45, June 2020.
- [5] A. M. Alaa and M. van der Schaar, "Demystifying black-box models with symbolic metamodels," in *Advances in Neural Information Processing Systems*, 2019.