

에너지 효율 향상을 위한 딥러닝 기반 전력 제어 연구

김지형, 조예지*, 김정현*
한국전자통신연구원, *세종대학교

savant21@etri.re.kr

A Study on deep learning-based power control for improving energy efficiency

Kim Jihyung, Yeji Cho*, Kim Junghyun*
ETRI, *Sejong Univ.

요 약

본 논문은 이동통신 시스템에서 간섭 완화 및 에너지 효율 향상을 위한 새로운 딥러닝 기반 전력 제어 할당 방식을 제안한다. 실험을 통해 제안 기법이 간섭을 고려하지 않은 단순한 최대 전력 할당 기법과 전통적인 전력 제어 기법 중 하나인 WMMSE 기법의 성능을 현저하게 개선시킴을 확인하였다.

I. 서 론

6G 이동통신의 도래로 인해 수많은 무선 장치들이 연결된 밀집된 무선 통신 환경에서는 빈번한 간섭 발생이 예상되며 이를 완화하기 위한 자원 관리의 향상이 요구된다. 이에 따라 무선 장치들의 채널 조건과 상대적 위치를 고려한 최적의 전력 분배를 결정하는 것은 중요한 이슈 중 하나이다. 본 논문에서는 이러한 문제를 해결하기 위해 딥러닝 기술을 이용한 새로운 전력 제어 기법을 제안한다.

II. 본론

가중 최소 평균 제곱 오차(WMMSE) 알고리즘은 가중 합을 최대화를 목표로 하며, 각 송신기와 수신기 간의 간섭을 최소화하는 방향으로 동작함으로써 기본적인 성능 기준값 중 하나로 활용된다. 그러나 이 알고리즘은 반복적인 최적화 과정을 통해 계산 복잡도가 높아지고, 대규모 네트워크에서 실시간 적용이 어렵다는 한계를 가지고 있다. 또한 새로운 환경에 대한 적응력이 낮아 각 네트워크 환경에 맞춰 재설정이 필요하다[1].

이러한 문제를 해결하기 위해 본 논문에서는 그래프 신경망을 활용한 전력 제어 방식을 제안한다. 기본적으로 그래프 신경망은 각 정점이 이웃 정점의 특성을 집계하고, 중앙 정점이 집계된 특성을 각 계층의 자체 특성과 결합하는 다층 구조를 가지고 있다[2]. 그림 1에서 보듯이 집계 및 결합 작업을 수행하여 각 정점의 표현을 반복적으로 업데이트한다. 정점 x 의 n 번째 계층의 업데이트는 다음과 같이 표현될 수 있다.

$$\alpha_x^n = \Pi^n(\beta_y^{n-1}), \beta_x^n = \varphi^n(\beta_x^{n-1}, \alpha_x^n) \quad (1)$$

여기서 α_x^n 은 정점 x 가 n 번째 계층에서 이웃 정점 y 로부터 집계한 특징이고, β_x^n 는 n 번째 계층에서 정점 x 의 특




그림 1. 그래프 신경망 개념도

징 벡터이다. Π^n 과 φ^n 은 각각 그래프 신경망에서의 집계 함수와 결합 함수이다.

이에 대해 전력 제어를 위해 W_{max} 로 표시되는 각 정점의 최대 허용 전송 전력과 η_{min} 으로 표시되는 최소 스펙트럼 효율성에 대한 조건을 유지하면서 스펙트럼 효율성을 최대화하는 것으로 변환한다. 편의를 위해 여기서는 η_{min} 을 0으로 설정한다. 이에 따라 단일 목적 최적화 함수는 다음과 같이 표현될 수 있다.

$$\max_w \sum_{x=1}^X \eta_x(w, \Theta) \quad (2)$$

여기서 x 번째 정점의 파워 w_x 는 $0 \leq w_x \leq W_{max}$, $\forall w_x \in W$ 이고, 전송 파워 벡터 W 는 학습 파라미터이다. $\eta_x \geq \eta_{min}$, $\forall x \in X$ 이며 X 는 정점의 집합을 나타낸다. Θ 는 채널 정보 행렬이다. 또한, 스펙트럼 효율성은 다음과 같이 표현될 수 있다.

$$\eta_x(W, \Theta) = \log_2(1 + \frac{w_x \theta_{x,x}}{\sum_{y=1, y \neq x}^X w_y \theta_{y,x} + \sigma^2}) \quad (3)$$

여기서 σ^2 은 잡음 전력이다. x 와 y 가 동일한 경우 채널 정보를 사용하고, x 와 y 가 다른 경우 직접적인 채널에 대




그림 2. 제안 기법에서 k 번째 계층의 i 번째 정점에 대한 업데이트 구조

한 정보 대신 위치 정보를 활용할 수 있다.

제안 모델은 (1)과 (2)를 기반으로 에지 컨볼루션을 적용하여 집계 및 결합 연산을 동시에 수행하며, 집계 단계에서 각 정점은 자체 및 이웃의 이전 특성을 함께 고려하여 현재 특성을 업데이트한다. 정점 특성은 타겟 링크의 채널 정보를 반영하고 에지 특성은 간접 링크의 거리를 고려한다. 이때, 집계 함수로는 다층 퍼셉트론(MLP) 구조를 사용하고 결합 함수로는 Max 함수를 사용한다. 이를 그림으로 표현하면 그림 2 와 같다. 그림에서 V 는 전체 노드 개수, d 는 노드 간 거리, X 는 정점의 값을 나타낸다.

제안한 방식은 기존 방식들과 달리 중심 정점의 특징에서 자체 특징까지 빼서 각 이웃에 대한 로컬 이웃 정보를 얻음으로써 각 정점이 이웃 정점의 간접 정보를 정밀하게 반영하여 간접 관리의 효율성을 향상시킬 수 있다. 또한 계층에 따라 가변적인 MLP 구조를 구성하고 계층마다 순차적으로 한 번씩만 학습함으로써 반복 횟수가 줄어들고 학습 시간을 단축시킬 수 있다. 제안 모델을 구성하는 각 계층의 뉴런 구조는 각각 [5, 32, 16, 16], [33, 32, 16, 16], [33, 32, 16, 1]로 설정된다. 마지막 계층에는 활성화 함수로 시그모이드(Sigmoid)가 사용되며, 신경망 가중치 업데이트에는 ADAM 알고리즘이 적용된다.

그림 3 은 전력 제어 방식에 따른 평균 전송 전력의 CDF 를 보이고 있다. 그림에서 Max Power 는 간섭을 고려하지 않고 최대 전력으로 전송한 방식이다. 제안한 방식은 평균 스펙트럼 효율을 유지하면서 Max Power 와 WMMSE 의 성능보다 각각 약 8 과 5 dBm 의 전력 감소를 얻을 수 있다.

III. 결론

본 논문에서는 전력 감소를 위해 에지 컨볼루션 기반의 전력 제어 방식을 제안했다. 타겟링크 채널 정보와 간접링크 거리 정보를 에지 컨볼루션에 결합함으로써 기존방식 대비 상대적으로 빠른 학습을 통해 새로운 환경에 적응할 수 있으며 전력 소모를 줄임으로써 에너지 효율성을 향상시킬 수 있다.

ACKNOWLEDGMENT

이 논문은 2024 년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임(No. 2022-0-00436, 지능형 재구성 표면 중계기 표준기술개발).




그림 3. Max Power, WMMSE 및 제안 기법의 평균 전송 전력에 대한 CDF

참고 문헌

- [1] Q. Shi, et al., "An Iteratively Weighted MMSE Approach to Distributed Sum-Utility Maximization for a MIMO Interfering Broadcast Channel," IEEE Trans. on Signal Processing, vol. 59, no. 9, pp. 4331-4340, Sep. 2011.
- [2] F. Scarselli, M. Gori, A. C. Tsoi, M. Hagenbuchner, and G. Monfardini, "The Graph Neural Network Model," IEEE Transactions on Neural Networks, vol. 20, no. 1, pp. 61- 80, Jan. 2009.