

이기종 네트워크에서 데이터율 최대화를 위한 지연된 부분 채널 상태 정보를 이용하는 딥러닝 기법

김도현, 이인호, 정해준*

한경국립대학교, *경희대학교

bendohyun@hknu.ac.kr, ihlee@hknu.ac.kr, *haejoonjung@khu.ac.kr

Deep Learning Scheme Using Outdated and Partial Channel State Information for Data Rate Maximization in Heterogeneous Networks

Do-Hyun Kim, In-Ho Lee, Haejoon Jung*

Hankyong National Univ., *Kyung Hee Univ.

요약

본 논문은 지연된 부분 채널 상태 정보를 이용하는 하향링크 이기종 네트워크에서 협력적 다중 포인트 전송을 지원하는 기지국들로부터 사용자들이 달성할 수 있는 총데이터율을 최대화하는 딥러닝 기법을 제안한다. 여기서, 제안하는 기법의 학습 단계에서 딥러닝 기반의 동적 셀 선택의 학습 결과는 송신 전력 할당 학습의 입력으로 이용되어 연합적으로 학습한다. 또한, 제안하는 기법은 실제 지연되는 채널 상태 정보를 이용함과 동시에 피드백 오버헤드를 줄이고 위하여 부분 채널 상태 정보를 이용한다. 시뮬레이션 결과에서 제안하는 기법과 완전 탐색 기법의 데이터율 성능을 비교한다.

I. 서론

최근 딥러닝 기반 무선 통신 자원 할당 기법의 연구가 다양하게 연구되고 있다. 딥러닝 기반 자원 할당은 반복적 수렴 최적화 방식에서 발생하는 복잡도와 계산 시간을 심층신경망(Deep Neural Network, DNN) 기반 학습 방식으로 해결한다. 이러한 딥러닝 기반 자원 할당은 이기종 네트워크(Heterogeneous Network, HetNet)의 협력적 다중 포인트(Coordinated Multi-Point, CoMP) 전송에서 적용될 수 있다[1]. 한편, 실제 무선 통신에서의 제한된 대역폭에서 피드백 오버헤드를 줄이기 위한 부분 채널 상태 정보(Channel State Information, CSI) 피드백과 함께 피드백 지연 시간도 고려될 수 있다[2]. 본 논문에서는 HetNet에서의 CoMP 전송에서 부분 CSI 보고와 피드백 지연 시간을 고려한 딥러닝 기반 동적 셀 선택 및 전력 할당 기법을 제안하고 시뮬레이션을 통해 제안하는 기법과 완전 탐색 기법의 데이터율 성능을 비교한다. 또한, 부분 CSI 보고와 지연 시간에 따른 제안하는 기법의 데이터율 성능 변화를 분석한다.

II. 시스템 모델

본 논문에서는 매크로 기지국(Base Satation, BS)의 통신 반경 안에 $S-1$ 개의 소형 BS들이 배치되고 사용자 U 명이 무작위로 위치한 HetNet 시스템을 고려한다. s 번째 BS와 u 번째 사용자 간 채널 이득은 $g_{s,u} = |f_{s,u}|^2 d_{s,u}^{-\beta}$ 로 표현된다. 여기서, 첫 번째 BS는 매크로 BS이고, $f_{s,u} \sim \mathcal{CN}(0, 1)$ 은 Rayleigh fading이고, $d_{s,u}$ 는 BS와 사용자 간 거리이고, β 는 경로 손실 지수이다. 경로 손실 기반 신호 대 간섭 및 잡음비가 최대인 BS s^{MS} 는 다음과 같다.

$$s^{MS} = \max_{s \in S} (d_{s,u}^{-\beta} E_s^M / \sum_{i \in S \setminus \{i\}} d_{i,u}^{-\beta} E_i^M + WB) = \max_{s \in S} \Theta_{s,u}. \quad (1)$$

이때 E_s^M 와 $\Theta_{s,u}$ 는 기지국의 송신 전력 최댓값과 경로 손실 기반 신호 대 간섭 및 잡음비이다. W 는 백색 가우시안 잡음이고 B 는 전체 대역폭이다. $\psi \geq 10 \log(\Theta_{s^{MS},u} / \Theta_{s,u})$ 를 만족하는 BS만 사용자 u 의 CoMP BS로 설정하고, 이것은 $a_{s,u}^{CoMP} = 1$ 을 의미하며 여기서 ψ 는 주어진 임계

값이다. 반대로 이 조건을 만족 못하는 BS는 사용자 u 의 CoMP BS에서 배제되고, 이것은 $a_{s,u}^{CoMP} = 0$ 을 의미한다. 실제 환경의 CSI 피드백 지연을 고려해 $g_{s,u}$ 는 지연된 채널 이득이고 현재의 채널 이득은 다음과 같다.

$$\ddot{g}_{s,u} = |\ell f_{s,u} + p_{s,u} \sqrt{(1-\ell^2)}|^2 d_{s,u}^{-\beta}. \quad (2)$$

여기서, ℓ 은 $g_{s,u}$ 와 $\ddot{g}_{s,u}$ 의 지연 관계 계수이자 0차 Bessel 함수인 $J_0(2\pi f_d \tau)$ 이고, f_d 는 최대 도플러 주파수이고, τ 는 피드백 지연 시간이다. 그리고 $p_{s,u} \sim \mathcal{CN}(0, 1)$ 은 $f_{s,u}$ 와 독립인 가우시안 분포를 따른다. $0 \leq \ell \leq 1$ 이고 ℓ 이 증가할수록 피드백 지연 시간이 늘어남을 의미한다. 사용자는 임계값 Φ 를 이용하여 다음의 조건을 충족하면 CSI를 보고한다.

$$\Phi \leq 10 \log(g_{s,u} / g_{s^{MG},u}). \quad (3)$$

따라서 s 와 u 에 대한 현재의 데이터율은 다음과 같다.

$$DR_{s,u} = \frac{a_{s,u} \cdot B}{\sum_{j \in U, s, j} a_{s,j}} \times \log_2(1 + \ddot{g}_{s,u} \ell_{s,u} / \sum_{i \in S \setminus \{i\}} \ddot{g}_{s,u} \ell_{i,u} + WB). \quad (4)$$

여기서, $a_{s,u}$ 는 사용자 할당 계수로 u 가 동적 셀 선택 후 s 에게 접속될 경우 $a_{s,u} = 1$ 이고, 그렇지 않을 경우 $a_{s,u} = 0$ 이다. 여기서 $\sum_{s \in S} a_{s,u} = 1$ 에 의해 사용자 한 명에 대해 단일 BS가 할당된다. $e_{s,u}$ 는 s 와 u 사이의 전력 할당 계수이다.

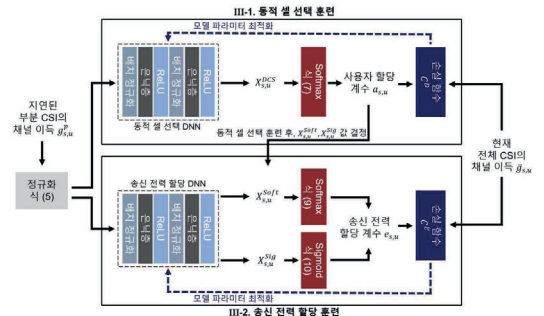


그림 1. 제안된 딥러닝 동적 셀 선택 기법과 송신 전력 할당 기법

III-1. 딥러닝 동적 셀 선택 기법

본 논문에서는 딥러닝을 기반으로 각각의 사용자에게 대하여 CoMP BS들 중 최적의 데이터율을 보이는 BS를 선정한다. 사용되는 신경망은 그림 1의 점선 블록 내 512 노드를 가지는 은닉층 2개와 층마다 배치 정규화와 rectified linear unit(ReLU)을 활성화 함수로 배치한 DNN이다. DNN의 입력은 다음의 L2 정규화 과정을 거친 지연된 부분 CSI 채널 이득이다.

$$\tilde{g}_{s,u}^p = \frac{10 \log_{10}(1 + g_{s,u}^p a_{s,u}^{CoMP})}{\sum_{s \in S} \sum_{u \in U} (10 \log_{10}(1 + g_{s,u}^p a_{s,u}^{CoMP}))^2}. \quad (5)$$

여기서, $g_{s,u}^p$ 는 보고된 부분 CSI 채널 이득이다. DNN의 출력은 $S \times U$ 행렬로 변환되고 이는 다음과 같이 조정된다.

$$X_{s,u}^{DCS} = \begin{cases} -\infty & \text{if } g_{s,u}^p a_{s,u}^{CoMP} = 0, \\ D_{s,u}^{DCS} & \text{if } g_{s,u}^p a_{s,u}^{CoMP} \neq 0. \end{cases} \quad (6)$$

이때 $D_{s,u}^{DCS}$ 는 DNN의 출력이고 $X_{s,u}^{DCS}$ 는 softmax 함수의 입력이 된다.

$$a_{s,u} = X_{s,u}^{DCS} / \sum_{i \in S} X_{i,u}^{DCS}, \quad \forall u \in U. \quad (7)$$

softmax로 얻어진 $a_{s,u}$ 는 $\sum_{s \in S} a_{s,u} = 1$ 를 만족하고, CoMP 송신하지 않거나 부분 CSI 보고가 되지 않으면 $a_{s,u} = 0$ 이 된다. 얻어진 $a_{s,u}$ 로 훈련하는 손실 함수 C^D 는 데이터율을 최대화하도록 다음과 같이 정리된다.

$$C^D = - \sum_{s \in S} \sum_{u \in U} DR_{s,u} + \lambda^D \sum_{u \in U} \tanh \left(ReLU \left(\frac{DR_T - \sum_{i \in S} DR_{i,u}}{DR_T} \right) \right). \quad (8)$$

여기서 DR_T 는 서비스 품질 $\sum_{s \in S} DR_{s,u} \geq DR_T$ 의 최소 데이터율이고, λ^D 는 데이터율 최대화와 서비스 품질의 중요도를 결정하는 계수이고, $ReLU$ 함수는 u 의 데이터율이 DR_T 를 넘지 않는다면 C^D 의 값을 증가시킨다. 그림 1과 같이 C^D 의 $DR_{s,u}$ 에서의 채널 이득은 현재 데이터율을 구하기 위해 현재의 전체 CSI의 채널 이득 $\tilde{g}_{s,u}$ 를 사용한다. 훈련 복잡도를 낮추기 위해 $e_{s,u}$ 는 각 s 의 송신 전력 최댓값 E_s^M 의 $1/U$ 배로 고정된다. Adam 알고리즘으로 DNN의 weight와 bias 훈련 후 u 에 대한 s 의 가장 큰 $a_{s,u}$ 가 1이 되고, 나머지 s 는 0이 된다. 이진화된 $a_{s,u}$ 은 그림 1처럼 전력 할당 학습의 입력이 된다. 또한 훈련에서는 모든 b 와 u 가 CoMP 전송한다고 가정하여(즉, $\psi = \infty$) 식 (5), (6)의 모든 $a_{s,u}^{CoMP}$ 가 1로 고정된다. 동적 셀 선택 훈련 신경망은 입력 $g_{s,u}^p$ 의 임계값 ψ 와 지연 관계 계수 ℓ 에 따라 구별되어 훈련된다.

III-2. 딥러닝 송신 전력 할당 기법

동적 셀 선택 훈련 이후 III-1에서 제시한 DNN과 구조는 같으나 독립적인 두 DNN에 $\tilde{g}_{s,u}^p$ 가 각각 입력된다. 두 DNN의 출력인 $D_{s,u}^{Soft}$ 와 $D_{s,u}^{Sig}$ 은 동적 셀 선택 훈련에서 $a_{s,u} = 1$ 인 경우 $X_{s,u}^{Soft} = D_{s,u}^{Soft}$, $X_{s,u}^{Sig} = D_{s,u}^{Sig}$ 가 되고, $a_{s,u} = 0$ 인 경우 $X_{s,u}^{Soft} = -\infty$, $X_{s,u}^{Sig} = -\infty$ 가 된다. $X_{s,u}^{Soft}$ 과 $X_{s,u}^{Sig}$ 은 softmax와 sigmoid 함수의 입력이며 동적 셀 선택으로 사용자가 BS에 접속하면 각 $X_{s,u}$ 은 $D_{s,u}$ 가 되고, 그렇지 않으면 각 원소 당 softmax와 sigmoid의 함수값은 0이 된다.

$$\varepsilon_{s,u}^{Soft} = e^{X_{s,u}^{Soft}} / \sum_{j \in U} e^{X_{s,j}^{Soft}}, \quad \forall s \in S. \quad (9)$$

$$\varepsilon_{s,u}^{Sig} = 1 / (1 + e^{-X_{s,u}^{Sig}}), \quad \forall s \in S, \forall u \in U. \quad (10)$$

여기서 $\varepsilon_{s,u}^{Soft}$ 와 $\varepsilon_{s,u}^{Sig}$ 는 각 원소의 softmax와 sigmoid 함수값이고 이를 통해 전력 할당 계수를 송신 전력 최댓값 E_s^M 과 함께 다음과 같이 유도한다.

$$e_{s,u} = \max(\varepsilon_{s,u}^{Soft} \varepsilon_{s,u}^{Sig} E_s^M, e_{\min}). \quad (11)$$

여기서 e_{\min} 은 최소 송신 전력이고 동적 셀 선택이 되지 않은 경우 $e_{s,u}$ 는 0이 된다. 또한 $\sum_{u \in U} e_{s,u} \leq E_s^M$ 을 식 (9)–(11)을 통해 만족한다. 동적 셀 선택 기법으로 얻은 고정된 $a_{s,u}$ 를 이용해 손실함수 C^E 를 식 (8)과 같이 정리한다. 데이터율을 최대화하는 $e_{s,u}$ 를 Adam 알고리즘으로 DNN의 weight와 bias의 훈련을 통해 구해진다. 송신 전력 할당 훈련 신경망 역시 입력 $g_{s,u}^p$ 의 임계값 ψ 와 지연 관계 계수 ℓ 에 따라 구별되어 훈련된다. 그림 1의 훈련이 끝나면 테스트 샘플로 모델을 평가한다.




그림 2. 임계값 Φ, ψ 와 지연 관계 계수 ℓ 에 따른 데이터율 결과

IV. 시뮬레이션 결과 및 결론

본 실험은 임계값 Φ, ψ 그리고 지연 관계 계수 ℓ 에 따라 변하는 CoMP BS와 부분 CSI 피드백 비율의 변화와 데이터율의 상관관계를 확인하고 그 성능을 평가한다. 실험에선 반경 500m 내에 매크로 BS 1개, 소형 BS 3개의 위치를 고정했다. 사용자 수는 10이고, 테스트 샘플은 10,000개, β 는 3.0이다. 잡음 전력은 -174 dBm/Hz, 주파수 대역폭은 5 MHz, 최소 데이터율은 1 Mbps, 매크로 BS 최대 전력은 30 dBm, 소형 BS 최대 전력은 27 dBm 그리고 최소 송신 전력은 0 dBm이다. 그림 2의 모든 기법에서 피드백 지연 시간이 다르다면 ψ 가 증가할수록 같은 Φ 를 가지는 신경망의 데이터율 성능 편차가 증가한다. Prop. DNN-PA는 제안된 기법으로 Φ 와 ℓ 에 따른 데이터율을 보여준다. $\psi = \infty$ 일 때, Prop. DNN-PA ($\Phi = -13$)은 식 (1)의 경로 손실 기반 신호 대 간섭 및 잡음비가 s^{MS} 의 5% 이상의 크기를 갖는 채널이 보고되고, 63%의 전체 CSI에 대한 부분 CSI 피드백률을 가진다. 피드백률이 낮을수록 데이터율의 최대치가 낮고 $\psi = \infty$ 일 때 데이터율과 유사한 데이터율을 제공하는 ψ 값이 상대적으로 낮다. Exhaustive search는 완전 탐색 기법을 의미하고, ψ 가 높아질수록 제안된 기법은 완전 탐색 기법과 유사한 데이터율 성능을 보인다.

ACKNOWLEDGMENT

This research was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIT) (Grant number: RS-2022-NR069055).

참고 문헌

- [1] D. Kim, H. Jung, and I.-H. Lee, "Deep Learning-Based Spectral and Energy Efficiency Optimization for CoMP in HetNets," In 2023 IEEE Globecom Workshops, pp. 1970–1975, Dec. 2023.
- [2] D. Kim, H. Jung, and I.-H. Lee, "Deep Learning-Based Power Control Scheme With Partial Channel Information in Overlay Device-to-Device Communication Systems," in IEEE Access, vol. 9, pp. 122125–122137, Sep. 2021.