

무선 네트워크 환경에서의 생성적 적대 신경망 기반 이동성 예측 모델

장보윤*, Syed Muhammad Raza**, 김문성***, 추현승**
*성균관대학교 인공지능학과
**성균관대학교 전자전기컴퓨터공학과
***서울신학대학교 교양학부
boyunj0226@skku.edu*, {s.moh.raza, choo}@skku.edu**, moonseong@stu.ac.kr***

Generative Adversarial Network based Mobility Prediction Model in Wireless Network

Boyun Jang*, Syed Muhammad Raza**, Moonseong Kim***, Hyunseung Choo**
*Dept. of Artificial Intelligence, Sungkyunkwan University
**Dept. of Electrical and Computer Engineering, Sungkyunkwan University
***Dept. of Liberal Art, Seoul Theological University

요 약

초저지연성을 요구하는 5G 네트워크 환경에서 기기의 핸드오버를 능동적으로 조절하는 시스템의 중요성이 대두되고 있으며, 특히 핸드오버 시 기기의 이동성을 예측하는 것은 필수적이다. 딥러닝 모델의 일종인 생성적 적대 신경망은 두 신경망 사이의 경쟁 구도를 이용하여 두 신경망의 성능을 모두 높이는 목적으로 사용된다. 본 논문에서는 주로 데이터 생성 모델로 사용되는 생성적 적대 신경망을 이용하여 무선 네트워크 환경에서 기기의 이동성을 예측하는 시스템을 개발하였다. 이를 통해 실제 모바일 네트워크 환경에 적용되었을 경우 핸드오버 속도를 높이도록 한다.

1. 서론

스마트폰에 대한 수요가 늘어가면서 모바일 네트워크 환경에서 트래픽이 증가하였고, 이에 따라 5G 네트워크가 출현하게 되었다 [1]. 기존의 4G 에서 발전된 형태의 5G 네트워크 환경이 모바일 기기에서 상용화되고 있으며, 8K 비디오 스트리밍 서비스나 자율주행 등의 고성능 서비스에서 특히 5G 의 초저지연성에 대한 요구가 증가하고 있다. 다수의 사용자가 있는 환경에서 기기 간 핸드오버가 자주 발생하는 경우 지연 감소를 위해서는 능동적인 이동성 관리 시스템이 요구되며, 기기의 다음 연결위치, 즉 Point of Attachment (PoA)를 예측하는 것이 필수적이다. [2]

딥러닝을 이용한 예측 모델은 다양한 분야에서 사용되고 있고, 순환 신경망 등 다양한 모델들이 적용되고 있다. 그 중 2014 년 [3]에서 제안된 생성적 적대 신경망(Generative Adversarial Network, 이하 GAN)을 이용한 예측 연구도 진행되었다. 주로 데이터를 생성하는 모델로 쓰이는 GAN 은 두 개의 신경망이 경쟁하면서 발전하는 구조로 되어 있고, 학습의 효율성으로 인해 다양한 분야에서 기존의 딥러닝 모델보다 높은

성능을 보인 바가 있다. 생성 모델이 아닌 예측 모델로 사용되었을 때도 마찬가지로인데, 이로 인해 주식 예측[4]이나 추천 시스템[5]에 사용된 예시가 있다.

본 논문에서는 무선 네트워크 환경에서 기기의 다음 PoA 를 예측하기 위한 모델로 GAN 을 사용하는 방법을 제안한다. 두 개의 신경망 모델을 학습시킨 후 그 중 하나를 예측 모델로 사용하고, 모델을 평가하기 위해 판교에서 수집한 무선 네트워크 데이터를 사용하였다. 그 결과 최대 90%에 근접한 예측 정확도를 달성할 수 있었으며, 해당 모델을 발전시킬 경우 실제 모바일 네트워크 환경에 적용될 경우에도 핸드오버 속도를 높일 것으로 예상된다.

2. 관련연구

초기에 데이터를 생성하는 모델로서 제안된 GAN 은 생성자와 판별자라고 불리는 두 개의 신경망으로 이루어져 있다. 생성자는 임의의 노이즈 벡터 값을 입력 값으로 받아서 가짜 데이터를 생성하고, 판별자는 진짜 데이터를 생성자가 만든 가짜 데이터와 구분한다. 진짜 데이터를 입력 값으로 받았을 경우 판별

자의 출력 값은 1, 가짜 데이터를 받았을 경우 출력 값이 0 이 되도록 판별자는 학습을 진행한다. 생성자의 목적은 진짜와 구분하기 힘든 가짜 데이터를 만드는 것이기 때문에 판별자가 가짜 데이터를 받았을 경우 진짜와 혼동하여 결과 값으로 1 을 만들도록 스스로를 학습시킨다.



(그림 1) GAN 의 구조 및 학습 과정

딥러닝 기반의 예측 모델로 RNN (Recurrent Neural Network) 기반의 모델들이 많이 사용되며 LSTM (Long Short-Term Memory)과 GRU (Gated Recurrent Unit) 이 대표적이다. 하지만 RNN 만을 이용할 경우 전체적인 데이터 분포를 학습하기에 한계가 발생한다. 따라서 생성자의 데이터 분포 학습 능력을 이용하는 GAN 을 예측 모델로 사용한 연구들이 있으며, 그 중 [4]에서는 주식 시장 예측에 LSTM 을 기반으로 한 GAN 을 이용했다.

3. 학습 데이터

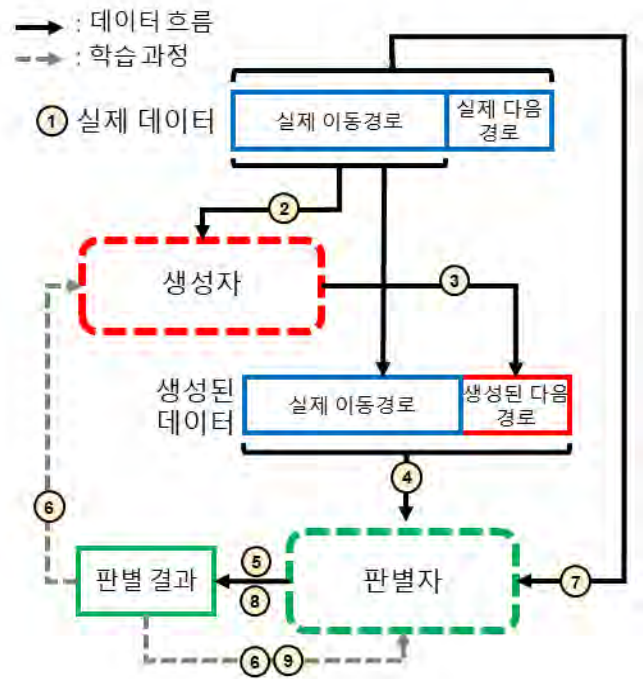
본 논문에서 사용된 데이터는 성균관대학교 판교연구센터에서 2 개월간 수집되었다. 총 12 개의 Access Point (AP)가 있는 무선 네트워크 환경에서 기기의 핸드오버 기록을 모은 데이터인데, 핸드오버가 발생했을 때 해당되는 기기의 MAC (Media Access Control Address) 주소, 이동하기 전의 AP 번호 및 이동한 후의 AP 번호에 대한 정보가 담겨 있다. 기기가 일정 횟수만큼 핸드오버를 했을 경우 그 다음에 이동하게 될 AP 번호를 예측하는 모델을 만드는 것이 목표이기 때문에 기기에 따라 AP 번호를 연결시켰고, 필요한 길이만큼 잘라서 사용했다 [6].

예를 들어 MAC 주소가 0123.0456.0789 인 기기가 있고, 그 기기가 핸드오버가 일어났을 때 AP 번호 1 에서 3으로, 3 에서 2로, 2에서 5로, 5에서 3으로 이동했을 경우, 이 모든 AP 번호들의 이동 경로를 합치면 {1, 3, 2, 5, 3}이 된다. 기기마다 이러한 AP 이동 경로의 길이는 다른데, 실제 모델을 학습시킬 때는 일정한 길이만큼 학습이 진행되어야 하므로 이동 경로를 잘라서 사용했다. 이동 경로가 {1, 2, 3, 4, 3, 2, 1}이고 AP 주소 5 개로 잘라서 이용한다고 하면 이 이동

경로는 {1, 2, 3, 4, 3}, {2, 3, 4, 3, 2}, {3, 4, 3, 2, 1} 총 3 개의 이동 경로로 쪼개져서 사용된다.

4. GAN 기반 예측 모델

예측 모델은 GAN 과 같은 구조를 가진다. 생성자는 다음 경로를 생성하고, 판별자는 실제 다음 경로와 생성된 다음 경로를 구별해 낸다. 생성자와 판별자는 서로 경쟁을 하면서 학습을 진행한다. 하지만 본 논문에서의 목적은 단순히 다음 경로를 생성하는 것이 아니라 이동 경로 정보를 토대로 다음 경로를 예측하는 것이기 때문에 데이터를 수정해서 사용했다. 앞서 AP 주소 5 개를 자른 이동 경로들 중 {1, 2, 3, 4, 3}을 학습에 사용한다고 가정하자. 기존의 경로들을 토대로 다음 위치를 예측하고자 하기 때문에 학습 및 검증 데이터로 사용될 때는 {1, 2, 3, 4}가 이동 경로로 사용되고, {3}은 다음 경로로 사용된다 (그림 2 의 ①).

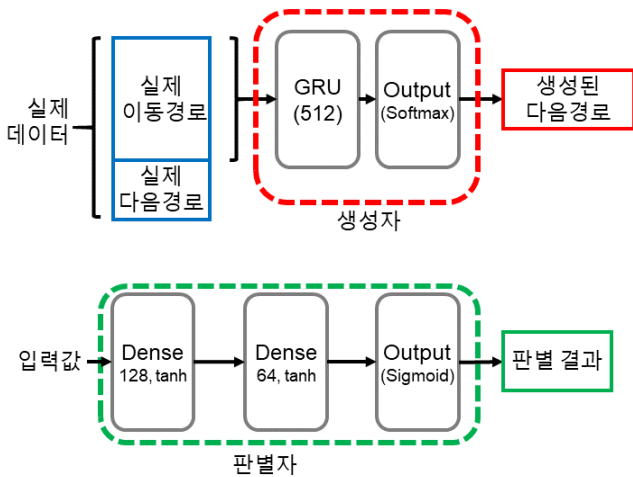


(그림 2) GAN 기반의 이동성 예측 모델

생성자는 이동 경로 {1, 2, 3, 4}를 입력 값으로 받아서 다음 경로 α 를 생성하며, α 와 {1, 2, 3, 4}가 합쳐진 {1, 2, 3, 4, α }는 생성된 데이터가 된다 (그림 2 의 ②, ③). 판별자는 생성된 데이터를 입력으로 받아서 결과를 내는데 (그림 2 의 ④, ⑤), 판별자는 생성된 데이터에 대해 0 이라는 결과를, 생성자는 1 이라는 결과를 낼 수 있도록 학습이 진행된다 (그림 2 의 ⑥). 그 다음 실제 이동 경로인 {1, 2, 3, 4, 3}이 판별자의 입력 값으로 들어가서 결과를 내게 되는데 (그림 2 의 ⑦),

⑧), 판별자는 이에 대한 결과가 1 이 될 수 있도록 학습을 진행한다 (그림 2 의 ⑨).

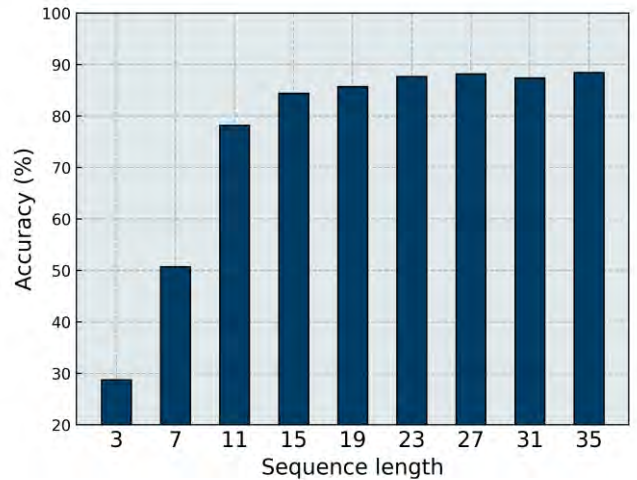
생성자와 판별자는 각각 하나의 신경망 구조로 되어 있는데, 생성자에는 GRU 구조가 사용되며 판별자에는 여러 층의 Fully Connected Layer 가 사용된다. 생성자의 경우 기존 이동 경로 정보를 토대로 다음 경로를 생성, 즉 예측해야 하는 상황이며, 이를 위해 기존에 예측 모델로 많이 사용되는 RNN 기반의 구조가 사용된다. 또한 이미 GAN 자체의 학습 과정이 복잡하기 때문에 학습의 효율성을 위해 생성자는 비교적 구조가 단순한 GRU 를 이용한다. 반대로 판별자는 다음 위치를 예측하기보다는 실제 이동 경로와 생성된 이동 경로를 구분하는 역할을 수행한다. [7]에 따르면 시계열 데이터를 판별하는 모델로는 RNN 기반의 구조보다는 오히려 여러 층의 Fully Connected Layer 를 사용하는 것이 효율적이다. 따라서 판별자는 RNN 기반의 구조가 아닌 2~3 개의 Fully Connected Layer 로 이루어진 단순한 구조의 신경망을 사용한다. (그림 3)



(그림 3) 생성자와 판별자의 신경망 구조

사용되는 활성화 함수로 Softmax 를 사용했다. 판별자는 각각 128 개와 64 개의 node 로 구성된 Fully Connected Layer 2 개를 사용했으며 각 계층의 활성화 함수로 tanh 를 사용했다. Output 에서는 Sigmoid 함수를 활성화 함수로 사용했다.

이동 경로의 AP 개수에 따른 예측 정확도를 비교하기 위해 그림 4 와 같이 다양한 이동 경로 내 AP 개수 (Sequence length)에 따라 예측 정확도 (Accuracy, %)를 측정하는 실험을 진행했다. 여기서의 예측 정확도란 주어진 기존 Sequence 가 있을 때 다음 AP 를 정확히 예측하는 비율을 의미한다. 이 때 각 Sequence length 마다 10 번씩 실험을 했고 이들의 평균값을 이용했다. Sequence length 가 증가할수록 일정 수치까지는 예측 정확도가 증가하는 것을 확인할 수 있으나, Sequence length 가 23 이상으로 올라갈 때는 예측 정확도에 거의 변화가 생기지 않는 것을 볼 수 있으며 주로 87%에서 88% 정도의 예측 정확도를 달성했다는 것을 확인할 수 있다. 또한 Sequence length 가 35 일 때, 즉 가장 많은 기존 AP 정보가 있을 때 예측 정확도를 88.43%까지 달성할 수 있었다.



(그림 4) 이동 경로의 길이에 따른 예측 정확도

5. 실험 및 결과

관교연구센터에는 총 12 개의 AP 가 있으므로, 수집된 데이터를 통해 이동 경로 데이터를 전처리한 후 각 AP 번호에 따라 12 차원의 One-Hot Vector 를 부여했다. 이는 모델이 학습을 할 때 AP 번호 자체의 크기에 따라 학습에 차이를 보이지 않도록 하기 위함이다. 전체 학습 횟수, 즉 Epoch 는 4,000 번, 학습률은 0.001, 손실 함수로 Binary Cross Entropy 를 이용했으며, Optimizer 로는 Adam Optimizer 를 이용했다. 전체 데이터 중 70%를 학습 데이터로 사용했으며, 30%를 실험 데이터로 사용했다. 모델 구조 상으로 생성자는 512 개의 node 로 구성된 GRU 를 사용하였으며, Output 에

6. 결론

본 논문에서는 모바일 네트워크 환경에서 핸드오버 발생 시 기기의 이동성 예측을 위해 기존에 생성 모델로 사용되던 딥러닝 모델인 GAN 을 이용했다. 기존의 GAN 모델에서 데이터 입력력 방식에 변화를 주어 예측 모델로 사용될 수 있도록 했고, 이를 실제 무선 네트워크 데이터에 적용해 본 결과 90%에 가까운 예측 정확도를 달성할 수 있었다. 이는 기존에 LSTM 을 통해 진행한 예측[6]의 예측 정확도와 거의 근접한 결과이며, PoA 예측 모델로서 GAN 을 이용한 첫 번째 시도임에도 상당히 높은 성과를 보였다. 모델의 파라

미터나 학습 방식에 변화를 줄 경우 더 높은 예측 정확도를 달성할 수 있을 것으로 예상되며, 데이터의 전처리 방식 변화를 통해 예측 정확도 외에도 모델 자체의 효율성 및 안정성을 높이는 연구를 진행할 예정이다. 또한 해당 모델은 네트워크 환경 외에도 다양한 분야에 예측 모델로 활용될 수 있을 것으로 전망된다.

ACKNOWLEDGEMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 글로벌핵심인재양성지원사업(IITP-2019-0-01579), 2020 년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원(No.2019-0-00421, 인공지능대학원지원(성균관대학교))과 2020 년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(NRF-2020R1A2C2008447).

참고문헌

- [1] 방승찬, 홍승은, 송종태, 김일규, 박애순, 이문식, 장성철, "5G 이동통신 기술 방향," 한국통신학회지, 2013. 11, pp.25-36
- [2] Ozturk, Metin, et al. "A novel deep learning driven, low-cost mobility prediction approach for 5G cellular networks: The case of the Control/Data Separation Architecture (CDSA)." *Neurocomputing* 358 (2019): 479-489.
- [3] Goodfellow, Ian, et al. "Generative adversarial nets." *Advances in neural information processing systems*. 2014.
- [4] Zhang, Kang, et al. "Stock market prediction based on generative adversarial network." *Procedia computer science* 147 (2019): 400-406.
- [5] Bharadhwaj, Homanga, Homin Park, and Brian Y. Lim. "RecGAN: recurrent generative adversarial networks for recommendation systems." *Proceedings of the 12th ACM Conference on Recommender Systems*. 2018.
- [6] Yang, Huigyu, et al. "Next Point-of-Attachment Selection Based on Long Short Term Memory Model in Wireless Networks." 2020 14th International Conference on Ubiquitous Information Management and Communication (IMCOM). IEEE, 2020.
- [7] Fawaz, Hassan Ismail, et al. "Deep learning for time series classification: a review." *Data Mining and Knowledge Discovery* 33.4 (2019): 917-963.