

기계학습 기반 이동통신 네트워크 인식 및 처리량 예측 모델 분석

김연희, 노현민
전북대학교 전자공학부

{1209dusgml, hmnoh}@jbnu.ac.kr

Analysis of ML-Based Network Classification and Throughput Prediction Model

Yeonhee Kim, Hyunmin Noh
Division of Electronic Engineering, Jeonbuk National University

요약

본 논문은 4G 와 5G 가 공존하는 이동통신 환경에서 네트워크 인식, 핸드오버 탐지, 그리고 처리량 예측을 위한 접근 방식을 제안한다. 네트워크 인식 부문에서는 GBM, XGBoost, LightGBM 을 비교하여 XGBoost 가 가장 우수한 성능을 보임을 확인하였다. 핸드오버 탐지 부문에서는 A3 및 A2A4 조건을 조합한 새로운 기준을 설계하였다. 처리량 예측 부문에서는 시계열 특성을 반영한 LSTM 과 RNN 모델을 비교하여 LSTM 의 우수성을 검증하였다.

I. 서론

최근 5G 보급 지역으로 인해 4G 와 5G 가 공존하는 Non-Standalone (NSA) 환경이 일반화되었으며, 이에 따라 이동 중 빈번한 핸드오버(Handover)가 발생하고 있다. 또한, 고주파수 대역을 사용하고 스몰 셀 기반으로 구축되는 5G 특성상 네트워크 밀집도가 높아 핸드오버 빈도를 더욱 증가시킬 수 있으며, 이는 사용자 QoE 저하를 초래할 수 있다[3]. 이러한 문제를 해결하기 위해, 본 연구에서는 단말이 네트워크 상태를 인식하여 4G 와 5G 환경을 구분하고, 해당 네트워크에 맞는 핸드오버 조건을 적용하여 핸드오버 발생을 탐지하며, 인식된 네트워크 상태 정보를 기반으로 다운링크 처리량의 시계열 추세를 예측하여 네트워크 자원을 효율적으로 관리하고 사용자 QoE 을 향상시키는 것을 목표로 한다.

II. 본론

본 논문에서는 먼저, 단말 네트워크 식별을 위한 각 기계학습 모델의 성능을 비교했으며, 새로운 핸드오버 기법을 설계했다. 마지막으로 단말의 신호정보를 이용한 기계학습 기반 처리량 예측 모델의 성능을 측정하였다.

II-1. 네트워크 탐지

먼저, 모바일 단말이 연결된 네트워크를 식별하기 위해 [1,2]의 10 개 특성(DL_bitrate, UL_bitrate, NRxRSRP, RSRP, RSSI, NRxRSRQ, Speed, SNR, RSRQ, CQI)에 대한 데이터셋을 활용하여 GBM, XGBoost, LightGBM 의 성능을 평가하였다. GBM 은 약한 학습기를 순차적으로 결합하는 양상을 기법이다. XGBoost 는 정규화와 병렬 처리 등을 통해 GBM 을 개선한 모델이며, LightGBM 은 히스토그램 기반 학습과 리프 중심 분할 방식을 적용하여 학습 속도와 메모리 효율성을 높인 모델이다. 각 모델의 성능은 표 1 과 같다. GBM 은 낮은 F1-score 에도 정밀도와 재현율의 균형을 유지했고, XGBoost 는 정밀도와 재현율 모두 95.2%로, 가장 우수한 성능을 기록했다. LightGBM 은 XGBoost 보다 성능은 낮았으나, 효율성 측면에서 실용적인 대안이다.

모델	정확도	정밀도	재현율	F1-score
GBM	0.905	0.896	0.880	0.888
XGBoost	0.959	0.952	0.952	0.952
LightGBM	0.942	0.932	0.932	0.932

표 1. GBM, XGBoost, LightGBM 성능 비교

II-2. RAT 기반 핸드오버 기법 설계

핸드오버는 동일 RAT 내 전환인 수평 핸드오버와, 다른 RAT 간 전환인 수직 핸드오버로 구분된다. 본 연구에서는 LTE 및 5G 네트워크에서 수평 핸드오버로, 3GPP TS 36.331 과 38.331 에 정의된 Event A3(RSRP 기반)와 Event A2/A4(RSRQ 기반) 측정 이벤트를 동시에 만족할 때만 핸드오버를 트리거하는 알고리즘을 제안한다. 이는 기존 단일 조건 기반 핸드오버에서 발생할 수 있는 과도한 핸드오버를 완화하고, 핸드오버 결정의 신뢰성을 높여 안정적인 무선 연결과 사용자 QoE 를 제공할 수 있다.

Algorithm 1 DETECTHANDOVER

```
1: procedure DETECTHANDOVER(RSRP_c, RSRQ_c, RSRP_n, RSRQ_n, RAT)
2:   if RAT == LTE then
3:     a3_offset ← 3
4:     a2_threshold ← 30
5:     a4_offset ← 1
6:   else if RAT == 5G then
7:     a3_offset ← 2
8:     a2_threshold ← 28
9:     a4_offset ← 0.5
10:  end if
11:  rsrpDiff ← RSRP_n - RSRP_c
12:  a3 ← (rsrpDiff > a3_offset)
13:  a2 ← (RSRQ_c < a2_threshold)
14:  a4 ← (RSRQ_n > RSRQ_c + a4_offset)
15:  rsrqCond ← a2 ∧ a4
16:  return a3 ∧ rsrqCond
17: end procedure
```

$RSRQ_{current}$ 와 $RSRP_{current}$ 는 현재 셀의 RSRQ, RSRP 을, $RSRQ_{neighbor}$ 와 $RSRP_{neighbor}$ 는 이웃 셀의 RSRQ, RSRP 을

의미한다. DetectHandover 알고리즘은 $RSRQ_{current}$, $RSRP_{current}$, $RSRQ_{neighbor}$, $RSRP_{neighbor}$, RAT 을 입력으로 받아, 현재 단말의 네트워크에 따라 임계값을 다르게 설정한다. LTE의 경우, $A3_{offset}$ 을 3으로, $A2_{threshold}$ 을 30으로, $A4_{offset}$ 을 1로 설정하였다. 5G에서는 전파 특성과 스몰 셀 환경의 특성을 고려하여 LTE 보다 더 낮은 값으로 $A3_{offset}$ 을 2로, $A2_{threshold}$ 을 28로, $A4_{offset}$ 을 0.5로 설정하였다. 이웃 셀의 RSRP가 현재 셀보다 $A3_{offset}$ 이상 높은 경우를 확인(a3Condition), 현재 셀의 RSRQ가 $A2_{threshold}$ 미만이며(a2Condition), 이웃 셀과의 RSRQ 차이가 $A4_{offset}$ 이상인지 평가한다(a4Condition). 세 가지 조건이 모두 만족할 때 핸드오버가 필요한 것으로 판단한다. 각 임계값은 임의로 설정하였으며, 추가 연구를 통해 성능 검증 및 최적화를 수행할 예정이다.

II-3. 처리량 예측

본 연구에서는 이동통신 환경에서 다운링크 처리량 예측을 위해 RNN과 LSTM 모델을 설계하고, 두 모델의 예측 성능을 비교하였다. RNN은 순차 데이터를 처리하지만 장기 의존성 학습에 한계가 있으며, LSTM은 게이트 메커니즘과 셀 상태를 통해 이를 보완한다. 입력 변수로는 UL_bitrate, NRxRSRP, RSRP, RSSI, NRxRSRQ, Speed, SNR, RSRQ, CQI, 원-핫 인코딩된 NetworkMode를 사용하였고, DL_bitrate를 예측하였다. 학습 데이터는 그림 1과 같이 DL_bitrate와 UL_bitrate 대부분의 값이 0 근처에 밀집되고 오른쪽으로 치우친 분포를 보이고 있다. 원활한 학습을 위해 전처리 과정을 통해 비대칭적인 분포를 보정하고 모델 학습의 안정성을 확보하기 위해 로그 변환을 적용 후, Z-점수 기반의 이상치 제거를 수행하여 예측 정확도를 향상시켰다. NRxRSRQ 변수는 높은 값 영역에서 비정상적으로 큰 값이 관측되어 극단적인 이상치를 제거하였다. 모델은 2개의 순환 신경망 층과 Bi-RNN 또는 Bi-LSTM 층을 포함한 동일한 구조를 가지며, 각 층은 68개의 유닛을 가진다. 각 모델 표 2의 하이퍼파라미터로 [1,2]에서 제공하는 데이터셋을 이용하여 학습되었으며, 성능은 표 3와 같다. LSTM 모델은 RNN 보다 낮은 RMSE와 MAE, 높은 R^2 값을 기록하여 더 우수한 예측 성능을 보였다. 그림 2는 실제값과 예측값의 관계를 나타낸 산점도로, 초록색 점은 RNN의 예측 결과, 빨간색 점은 LSTM의 예측 결과, 점선은 이상적인 예측선을 의미한다. 대부분의 데이터는 이상적인 예측선 근처에 분포하지만, 낮은 DL Bitrate 구간에서는 다소 큰 오차가 관찰되었다.

하이퍼파라미터	값
timestep	10
Dropout rate	0.2
Optimizer	Adam
Learning rate	0.0001
Loss function	MSE
Batch size	128

표 2. 모델의 하이퍼파라미터

	LSTM	RNN
RMSE	0.911	0.943
MAE	0.609	0.640
R^2	0.915	0.908

표 3. RNN과 LSTM 성능 비교

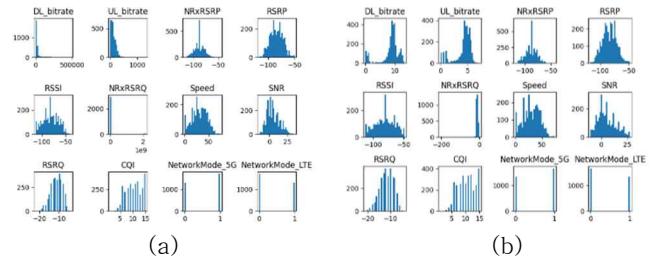


그림 1. (a) 전처리 전, (b) 전처리 후 데이터 분포

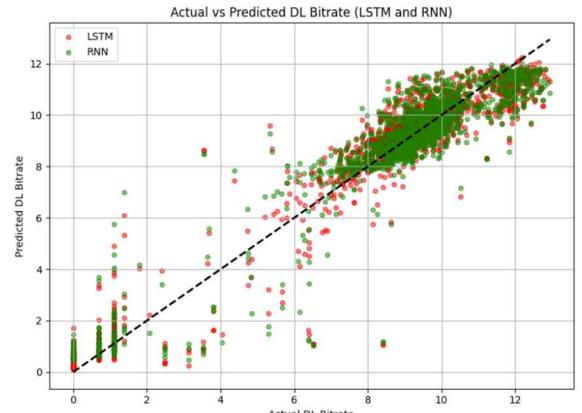


그림 2. RNN과 LSTM 모델의 예측 비교

III. 결론

본 논문은 상용 5G 네트워크 데이터를 기반으로 네트워크 인식, 핸드오버 탐지, 처리량 예측을 다루었다. 네트워크 인식에서는 GBM 계열 중 XGBoost가 가장 우수한 분류 성능을 보였으며, 핸드오버 탐지에서는 RSRP와 RSRQ 조건을 모두 만족해야 트리거되는 새로운 수평 핸드오버 알고리즘을 제안하였다. 처리량 예측에서는 시계열 특성을 반영한 RNN과 LSTM 모델을 비교하여 LSTM이 우수함을 확인하였다. 본 연구는 이동통신 환경에서 딥러닝 기반 네트워크 인식 및 처리량 예측 가능성을 실험으로 검증하였으며, 향후 정교한 모델 설계와 실시간 데이터 적용을 통한 성능 향상을 기대할 수 있다.

ACKNOWLEDGMENT

이 논문은 2025년도 과학기술정보통신부의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No. 2021-0-00484, 노드 간 메시지 전달과 합의를 위한 최적 경로 네트워크 프로토콜 기술개발)

참고 문헌

- [1] Hyeonji Lee, Yoohwa Kang, Minju Gwak and Donghyeok An, "Bi-LSTM model with time distribution for bandwidth prediction in mobile networks," ETRI Journal Volume 46, Issue 2, pp. 205-217, August 2023.
- [2] UCC MISL 5G dataset, <https://github.com/uccmisl/5Gdataset>
- [3] Muhammad Tayyab, Xavier Gelabert, Riku Jäntti and T. Melodia, "A Survey on Handover Management: From LTE to NR," IEEE, pp. 118907-118930, August 2019