

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

요 약

본 논문은 4G와 5G가 공존하는 이동통신 환경에서 네트워크 인식, 핸드오버 탐지, 그리고 처리량 예측을 위한 접근 방식을 제안한다. 네트워크 인식 부문에서는 GBM, XGBoost, LightGBM을 비교하여 XGBoost가 가장 우수한 성능을 보임을 확인하였다. 핸드오버 탐지 부문에서는 A3 및 A2/A4 조건을 조합한 새로운 기준을 설계하였다. 처리량 예측 부문에서는 시계열 특성을 반영한 LSTM과 RNN 모델을 비교하여 LSTM의 우수성을 검증하였다.

I. 서 론

최근 5G 보급 지연으로 인해 4G와 5G가 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 4G와 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 QoE를 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 10개 특성(DL_bitrate, UL_bitrate, NRxRSRP, RSRP, RSSI, NRxRSRQ, Speed, SNR, RSRQ, CQI)에 대한 데이터셋을 활용하여 GBM, XGBoost, LightGBM의 성능을 평가하였다. GBM은 약한 학습기를 순차적으로 결합하는 앙상블 기법이다. XGBoost는 정규화와 병렬 처리 등을 통해 GBM을 개선한 모델이며, LightGBM은 히스토그램 기반 학습과 리프 중심 분할 방식을 적용하여 학습 속도와 메모리 효율성을 높인 모델이다. 각 모델의 성능은 표 1과 같다. GBM은 낮은 F1-score에도 정밀도와 재현율의 균형을 유지했고, XGBoost는 정밀도와 재현율 모두 95.2%로, 가장 우수한 성능을 기록했다. LightGBM은 XGBoost보다 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 36.331과 38.331에 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 QoE를 제공할 수 있다.

Algorithm 1 DETECTHANDOVER

```

1: procedure DETECTHANDOVER(RSRPc, RSRQc, RSRPn, RSRQn, 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 ← RSRPn - RSRPc
12:  a3 ← (rsrpDiff > a3.offset)
13:  a2 ← (RSRQc < a2.threshold)
14:  a4 ← (RSRQn > RSRQc + a4.offset)
15:  rsrqCond ← a2 ∧ a4
16:  return a3 ∧ rsrqCond
17: end procedure

```

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

의미한다. DetectHandover 알고리즘은 $RSRQ_{current}$, $RSRP_{current}$, $RSRQ_{neighbor}$, $RSRP_{neighbor}$, RAT 을 입력으로 받아, 현재 단말의 네트워크에 따라 임계값을 다르게 설정한다. LTE 의 경우, $A3_{offset}$ 을 3 으로, $A2_{threshold}$ 을 30 으로, $A4_{offset}$ 을 1 로 설정하였다. 5G 에서는 전파 특성과 스몰 셀 환경의 특성을 고려하여 LTE 보다 더 낮은 값으로 $A3_{offset}$ 을 2 로, $A2_{threshold}$ 을 28 로, $A4_{offset}$ 을 0.5 로 설정하였다. 이웃 셀의 RSRP 가 현재 셀보다 $A3_{offset}$ 이상 높은 경우를 확인(a3Condition), 현재 셀의 RSRQ 가 $A2_{threshold}$ 미만이며(a2Condition), 이웃 셀과의 RSRQ 차이가 $A4_{offset}$ 이상인지 평가한다(a4Condition). 세가지 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 RNN 과 LSTM 모델을 설계하고, 두 모델의 예측 성능을 비교하였다. RNN 은 순차 데이터를 처리하지만 장기 의존성 학습에 한계가 있으며, LSTM 은 게이트 메커니즘과 셀 상태를 통해 이를 보완한다. 입력 변수로는 UL_bitrate, NRxRSRP, RSRP, RSSI, NRxRSRQ, Speed, SNR, RSRQ, CQI, 원-핫 인코딩된 NetworkMode 를 사용하였고, DL_bitrate 를 예측하였다. 학습 데이터는 그림 1 과 같이 DL_bitrate 와 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 2 개의 순환 신경망 층과 Bi-RNN 또는 Bi-LSTM 층을 포함한 동일한 구조를 가지며, 각 층은 68 개의 유닛을 가진다. 각 모델 표 2 의 하이퍼파라미터로 [1,2]에서 제공하는 데이터셋을 이용하여 학습되었으며, 성능은 표 3 와 같다. LSTM 모델은 RNN 보다 낮은 RMSE 와 MAE, 높은 R^2 값을 기록하여 더 우수한 예측 성능을 보였다. 그림 2 는 실제값과 예측값의 관계를 나타낸 산점도로, 초록색 점은 RNN 의 예측 결과, 빨간색 점은 LSTM 의 예측 결과, 점선은 이상적인 예측선을 의미한다. 대부분의 데이터는 이상적 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. RNN 과 LSTM 성능 비교

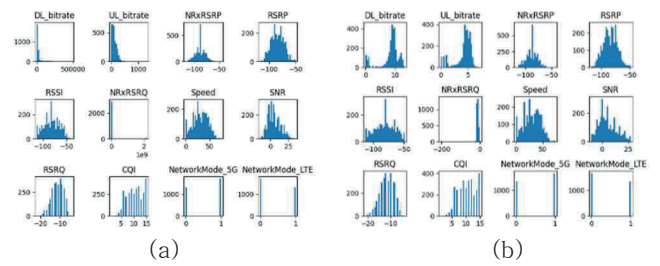


그림 1. (a) 전처리 전, (b) 전처리 후 데이터 분포




그림 2. RNN 과 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 XGBoost 가 가장 우수한 분류 성능을 보였으며, 핸드오버 탐지에서는 RSRP 와 RSRQ 조건을 모두 만족해야 트리거되는 새로운 수평 핸드오버 알고리즘을 제안하였다. 처리량 예측에서는 시계열 특성을 반영한 RNN 과 LSTM 모델을 비교하여 LSTM 이 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 2025 년도 과학기술정보통신부의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No. 2021-0-00484, 노드 간 메시지 전달과 합의를 위한 최적 경로 네트워크 프로토콜 기술개발)

참 고 문 헌

- [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