

Горбачов І.О., PhD аспірант
Литвинюк О.М., PhD аспірант
Гнатюк В.О., к.т.н., доцент, завідувач кафедри
Державний університет «Київський авіаційний інститут»

МЕТОД ПРОГНОЗУВАННЯ ЗАВАНТАЖЕННЯ ТА РОЗПОДІЛУ РЕСУРСІВ В ТЕЛЕКОМУНІКАЦІЙНИХ СИСТЕМАХ

Сучасні телекомунікаційні системи характеризуються високою динамічністю трафіку, нерівномірним розподілом навантаження та необхідністю оперативного масштабування ресурсів для забезпечення QoS/QoE. Зростання кількості користувачів, інтенсивне використання мультимедійних сервісів, інтеграція IoT-пристроїв та поява сервісів із жорсткими вимогами до затримки призводять до постійних коливань навантаження на мережеву інфраструктуру.

Аналіз існуючих досліджень [1-4] підкреслює необхідність вирішення наукової задачі щодо прогнозування завантаження та розподілу ресурсів в телекомунікаційних системах.

Метою роботи є розроблення методу прогнозування завантаження та розподілу ресурсів у телекомунікаційних системах на основі нейронних мереж, який забезпечує підвищену точність передбачення майбутнього навантаження, динамічну адаптивність до змін трафіку та можливість ефективного й оптимального управління мережевими ресурсами в умовах інтенсивно змінюваного середовища.

Архітектура запропонованої моделі прогнозування. Попередня обробка даних. Для підвищення точності прогнозування використовується багатоступенева підготовка даних: нормалізація часових рядів методом Min–Max або StandardScaler; виявлення та фільтрація аномалій (раптом виникаючі піки, пропуски даних); формування ковзного вікна фіксованої довжини (Sliding Window) для подачі даних до моделі; збагачення датасета екзогенними ознаками: час доби, день тижня, тип сервісу, події мережі (handover, зміна соти тощо). Такі ознаки дозволяють моделі навчитися складним сезонним і поведінковим залежностям.

Модель нейронної мережі. Запропонована архітектура складається з таких компонентів: компонент ознак (Feature Extraction Layer) із використанням 1D-CNN для виділення локальних часових патернів. Основний прогнозний компонент – двошарова LSTM або GRU модель з 32–128 нейронами, здатна моделювати довготривалі залежності.

Dropout-шари для зменшення перенавчання. Dense-шар для формування кінцевого прогнозу.

Гібрид CNN–LSTM дає змогу одночасно обробляти короткострокові коливання (CNN) і глобальні тренди (LSTM). На практиці така архітектура демонструє кращу стабільність прогнозів у пікові періоди.

Процедура навчання моделі. Навчання здійснюється методом оптимізації Adam із функцією втрат MSE. Гіперпараметри (довжина вікна, кількість нейронів, dropout, швидкість навчання) підбираються шляхом k-fold cross-validation.

Інтеграція прогнозної моделі з механізмом управління ресурсами. Запропонована система складається з трьох взаємодіючих модулів: Модуль моніторингу, який збирає телеметричні метрики (CPU, throughput, RRC-конекції, затримки, Packet Loss, PRB utilization). Модуль прогнозування, де розгорнуто згадану нейронну модель. Модуль управління ресурсами, що виконує дії на основі прогнозу: масштабування інстансів vNF/NF, регулювання ресурсів MEC-вузлів, балансування трафіку між вузлами, забезпечення гарантій QoS для критичних сервісів.

Взаємодія між модулями реалізується через API SDN-контролера та оркестратор NFV, що дозволяє динамічно змінювати конфігурації мережевих компонентів у режимі near-real-time.

Запропонований підхід дозволяє враховувати короткострокові та довгострокові залежності в мережевому трафіку, забезпечуючи високу точність прогнозування та адаптивне управління ресурсами в умовах динамічної зміни навантаження.

Список використаних джерел:

1. Donatti, A., *et al.* (2024). Survey on machine learning-enabled network slicing: Covering the entire life cycle. *IEEE Transactions on Network and Service Management*, 21(1), 994–1011.

2. Uzel, Z. (2023). *Comparative analysis of LSTM, ARIMA, and Facebook's Prophet for traffic forecasting: Advancements, challenges, and limitations* (Bachelor's thesis). Delft University of Technology.

3. Ye, W., Zheng, Y., Bai, H., *et al.* (2025). A neural network for traffic flow prediction with parallel processing of expanded convolutional and radial networks. *Scientific Reports*, 15, Article 38243. <https://doi.org/10.1038/s41598-025-22073-4>

4. Zangooei, M., Saha, N., Golkarifard, M., & Boutaba, R. (2023). Reinforcement learning for radio resource management in RAN slicing: A survey. *IEEE Communications Magazine*, 61(2), 118–124. <https://doi.org/10.1109/MCOM.004.2200532>