



DOI 10.28925/2663-4023.2024.26.788

УДК 004.9

**Жебка Вікторія Вікторівна**

доктор технічних наук, професор

завідувач кафедри Технологій цифрового розвитку

Державний університет інформаційно-комунікаційних технологій, Київ, Україна

ORCID ID 0000-0003-4051-1190

v.zhebka@duikt.edu.ua

## ПРОГНОЗУВАННЯ НАВАНТАЖЕННЯ В ГЕТЕРОГЕННИХ ТЕЛЕКОМУНІКАЦІЙНИХ МЕРЕЖАХ НА ОСНОВІ РОЗРОБЛЕНОЇ НЕЙРОННОЇ МОДЕЛІ

**Анотація.** У статті розглядається актуальна наукова проблема прогнозування навантаження в гетерогенних телекомунікаційних мережах на основі використання нейронних мереж. У зв'язку з активним впровадженням технологій 5G, IoT, розумних міст та мобільного хмарного обчислення, виникає необхідність у побудові інтелектуальних моделей, здатних ефективно аналізувати великі обсяги телекомунікаційних даних і прогнозувати навантаження з високою точністю. Одним із ключових викликів у гетерогенних мережах є нерівномірний розподіл трафіку між різними технологіями зв'язку (LTE, Wi-Fi, NB-IoT тощо), що обумовлює потребу в адаптивному управлінні ресурсами мережі. Запропонована в дослідженні модель заснована на багатошаровій перцептронній нейронній мережі (MLP), яка навчається на часових рядах даних про навантаження мережевих компонентів. В якості вхідних параметрів у модель подаються попередні значення навантаження, часові характеристики, тип мережі та рівень QoS. Навчання відбувається з використанням алгоритму зворотного поширення помилки з функцією втрат MSE (середньоквадратична похибка). Результатом роботи мережі є прогнозоване значення навантаження на визначений інтервал часу. У роботі детально представлено алгоритм функціонування моделі, сформульовано математичний опис, цільову функцію та систему обмежень. Модель охоплює структурні особливості гетерогенних мереж, забезпечує адаптивність до змін середовища та може бути масштабована під різні телекомунікаційні платформи. Наведено аналіз сучасних публікацій у галузі прогнозування навантаження в телекомунікаційних системах, зокрема в роботах G. Zhang, M. Chen, Y. Sun, а також українських дослідників, таких як Д.В. Козлов, А.О. Грабовець та Ю.П. Соловей. Результати дослідження можуть бути використані для оптимізації мережевого трафіку, підтримки динамічного балансування навантаження, адаптивного планування ресурсів і запобігання перевантаженням. У перспективі модель може бути інтегрована з системами моніторингу в реальному часі, а також адаптована до мереж 6G та гібридних архітектур зв'язку. Запропоноване рішення сприяє підвищенню ефективності управління телекомунікаційною інфраструктурою в умовах швидко зростаючих цифрових сервісів та інтенсивного використання мереж.

**Ключові слова:** гетерогенна телекомунікаційна мережа, нейронна мережа, прогнозування навантаження, багатошаровий перцептрон, інформаційна технологія.

### ВСТУП

У сучасних телекомунікаційних системах спостерігається стрімке зростання обсягів переданих даних, що обумовлено масовим використанням мобільних пристроїв, сервісів потокового відео, хмарних обчислень і розвитку Інтернету речей. Це призводить до підвищення вимог до якості обслуговування (QoS) і до зростаючої складності управління мережевими ресурсами, особливо в умовах гетерогенності — коли в одній



мережі поєднуються різні технології зв'язку (Wi-Fi, 4G/5G, оптоволокно, супутниковий зв'язок тощо).

Одним з найбільш актуальних викликів у таких мережах є необхідність точного прогнозування навантаження для забезпечення ефективного розподілу ресурсів, уникнення перевантажень та підтримки високої якості обслуговування. Традиційні статистичні або евристичні методи часто не забезпечують достатньої точності в умовах складної динаміки трафіку, змін користувацької поведінки й варіативності параметрів середовища. У цьому контексті штучні нейронні мережі демонструють високу ефективність для задач прогнозування завдяки здатності навчатися на великих обсягах історичних даних і виявляти складні, нелінійні залежності. У даній роботі запропоновано нейронну модель прогнозування навантаження, яка враховує динаміку мережевого трафіку, часові характеристики та параметри якості обслуговування. Побудована модель реалізована у вигляді багатошарової нейронної мережі на мові Python з використанням бібліотек TensorFlow та Keras. Проведено навчання моделі на синтетичних і реальних даних, а також здійснено оцінку її точності.

**Постановка проблеми.** Однак виникає протиріччя між складністю гетерогенних мережевих середовищ, які потребують адаптивних моделей, здатних до онлайн-обробки, та обмеженою обчислювальною ефективністю багатьох глибинних моделей, що ускладнює їх інтеграцію у реальні телекомунікаційні середовища. Додатковою складністю є необхідність у формуванні релевантних тренувальних наборів даних, які мають бути репрезентативними, але водночас не перевантаженими шумом або нерелевантною інформацією. Таким чином, у даній роботі поставлено завдання розробити нейронну модель прогнозування навантаження у гетерогенній телекомунікаційній мережі, яка б враховувала багатокомпонентну структуру трафіку, часові залежності та ключові показники QoS. Модель має бути адаптивною, здатною до узагальнення на нові умови та демонструвати достатню обчислювальну ефективність для практичного впровадження. Передбачається реалізація моделі з використанням сучасних фреймворків машинного навчання (TensorFlow, Keras), формування навчального датасету, тестування продуктивності моделі та обґрунтування її переваг у порівнянні з традиційними методами.

**Аналіз останніх досліджень і публікацій.** Проблема прогнозування навантаження в телекомунікаційних мережах є актуальною у зв'язку з постійним зростанням кількості підключених пристроїв, зростанням обсягів переданих даних та необхідністю забезпечення стабільної якості обслуговування. У працях [1], [2] розглядаються класичні підходи до моделювання навантаження за допомогою статистичних методів, зокрема авторегресійних моделей і ковзного середнього. Однак ці методи мають обмежену здатність до адаптації в умовах високої варіативності даних, властивої гетерогенним мережам.

У роботах [3] – [6] розглядається використання штучних нейронних мереж для прогнозування навантаження в мобільних і бездротових мережах. Зокрема, в [3, с. 35] запропоновано підхід на основі багатошарового перцептронну, що дозволяє досягти кращої точності порівняно зі стандартними статистичними моделями. У [4] та [5] дослідники використовують рекурентні нейронні мережі (RNN) і їх модифікації — довготривалу короткочасну пам'ять (LSTM), що дозволяє моделі краще враховувати часову залежність даних. У [6, с. 42] висвітлюються методи підвищення стійкості прогнозної моделі до шумів у даних та непередбачуваних коливань трафіку.

Окрему увагу привертають роботи, присвячені гетерогенним мережам нового покоління (4G/5G/6G), у яких одночасно використовуються різні типи каналів зв'язку. У



[7], [8] досліджено методи оптимального розподілу трафіку між різнорідними сегментами мережі, однак питання саме прогнозування навантаження з урахуванням гетерогенності часто розглядається побічно або в обмежених сценаріях. У [9] запропоновано використання гібридної моделі з поєднанням машинного навчання і оптимізаційних методів для керування навантаженням, проте точність прогнозу залежала від попередньої ручної класифікації даних. У роботі [10] запропонували адаптивну просторово-часову графову згорткову нейронну мережу, що поєднує кілька рівнів рецептивних полів для точнішого прогнозування трафіку. Модель демонструє високу здатність до узагальнення, зокрема в умовах складної топології мереж, проте потребує значних обчислювальних ресурсів і спеціалізованих знань для налаштування. У публікації [11] акцент зроблено на методі обчислення стійкості з'єднання в гетерогенних телекомунікаційних мережах. Попри відмінну прикладну цінність, питання прогнозування навантаження тут не розкривається повною мірою, хоча автори підкреслюють необхідність урахування топологічної стійкості при оптимізації ресурсів.

В [12], [14], [15] приділили увагу сумісності обладнання, захисту критичної інфраструктури та підвищенню функціональної стійкості мереж. У [12] аналізується фізична сумісність у гібридних мережах, що є важливою передумовою для ефективного прогнозування, але без конкретних моделей трафіку. У [14] розглянуто важливу тему децентралізації телекомунікаційних мереж під час кіберзагроз, проте методи прогнозування навантаження розглядаються лише як потенційний напрямок. Цікавим є підхід [13], у якому представлено метод функціонування сенсорної мережі за умов перерозподілу запитів між вузлами. Це безпосередньо перегукується з проблемою балансування навантаження, хоча прогнозування використовується як допоміжна функція.

Попри наявність низки цікавих рішень, досі залишаються невирішеними такі аспекти:

- створення універсальної нейронної моделі, здатної адаптуватися до змін у топології та протоколах передачі даних у гетерогенних мережах;
- комплексний урахунок показників якості обслуговування (QoS), таких як затримка, пропускна здатність і втрати пакетів у процесі прогнозування навантаження;
- побудова математично обґрунтованої цільової функції і системи обмежень, які формалізують процес навчання моделі.

Саме цим аспектам присвячено дану роботу, у якій запропоновано оригінальну нейронну модель, математично описану як задача оптимізації з цільовою функцією, що мінімізує похибку прогнозу при обмеженнях на параметри QoS і ресурси вузлів мережі. Таким чином, стаття спрямована на вирішення раніше недостатньо досліджених аспектів проблеми прогнозування навантаження в умовах гетерогенності телекомунікаційних систем.

**Мета статті.** Метою цієї роботи є розробка та дослідження нейронної моделі для прогнозування навантаження в гетерогенних телекомунікаційних мережах з урахуванням динамічних параметрів трафіку і показників якості обслуговування, з подальшою інтеграцією результатів прогнозування в систему адаптивного управління мережевими ресурсами.



## РЕЗУЛЬТАТИ ДОСЛІДЖЕННЯ

Модель прогнозування навантаження гетерогенної телекомунікаційної мережі розроблена з використанням штучної нейронної мережі на базі бібліотек TensorFlow та Keras у середовищі Python. Вона орієнтована на аналіз трафіку, який генерується різними сегментами мережі — такими як Wi-Fi, LTE, 5G та супутникові канали — й оцінювання загального рівня завантаженості мережевої інфраструктури з урахуванням часу доби. Змінні, які надходять на вхід моделі, включають числові значення завантаження кожного сегменту в межах від 0 до 1, а також нормалізований показник часу (наприклад, 14:00 як 0.583). Архітектура моделі є класичною для табличних задач регресії: вхідний шар містить п'ять нейронів, що відповідають п'яти параметрам. Далі слідує два приховані шари з по 64 нейрони кожен, активовані функцією ReLU. Завершує модель вихідний шар із одним нейроном, що видає прогнозоване значення загального навантаження. В якості функції втрат використовується середньоквадратична помилка (MSE), що є стандартом для подібних задач. Оптимізатор Adam забезпечує гнучке та ефективне навчання, а додаткова метрика MAE (середня абсолютна похибка) дає змогу оцінити точність у практичних одиницях. Для підготовки моделі до використання з реальними даними було створено умовну навчальну вибірку, де кожен рядок — це окремий часовий знімок навантаження мережі. Після навчання модель здатна отримувати нові вхідні параметри — скажімо, навантаження по кожному каналу в конкретну годину — і повертати прогнозоване значення загального навантаження. Це значення можна інтерпретувати як ймовірність перевантаження мережі або використати для автоматизованого перерозподілу ресурсів (наприклад, відключення менш важливих сервісів або переключення користувачів між мережами). З практичної точки зору модель може бути інтегрована в системи управління мережевою інфраструктурою для прийняття рішень у режимі реального часу, в тому числі в Smart City, IoT-платформах, хмарних дата-центрах, а також в системах, що обслуговують критичну інфраструктуру (енергетика, транспорт). В умовах зростаючої складності мереж і запровадження 5G та 6G-технологій, здатність прогнозувати навантаження стає надзвичайно важливою для забезпечення QoS (якості обслуговування) і SLA (гарантій доступності сервісів).

У перспективі модель може бути модифікована для роботи з часовими рядами — зокрема, шляхом заміни щільних шарів на рекурентні (LSTM, GRU), що дозволить урахувати попередні значення навантаження, створювати довгострокові прогнози й формувати контекст. Також вона може використовуватись як основа для систем адаптивного керування навантаженням у мультиагентних телекомунікаційних середовищах. Математичний опис нейронної мережі для прогнозування навантаження гетерогенної телекомунікаційної мережі подамо як формалізовану регресійну модель із багатьма вхідними змінними. Ця модель відображає класичну структуру багатошарової перцептронної (Multilayer Perceptron, MLP) нейромережі прямого розповсюдження (feedforward), навченої з використанням градієнтного спуску.

Нехай

$x_i$  — навантаження в сегменті Wi-Fi,



$x_2$  – навантаження в сегменті LTE,  
 $x_3$  – навантаження в сегменті 5G,  
 $x_4$  – навантаження в супутниковому сегменті,  
 $x_5$  – час доби, нормалізований у межах  $[0,1]$ .

Вектор вхідних параметрів:

$$x = [x_1, x_2, x_3, x_4, x_5]^T \in \mathbb{R}^5, \quad (1)$$

Модель складається з

1. Вхідного шару  $x \in \mathbb{R}^5$ .
2. Двох прихованих шарів:  
Перший прихований шар:  $h^{(1)} \in \mathbb{R}^{64}$   
Другий прихований шар:  $h^{(2)} \in \mathbb{R}^{64}$
3. Вихідного шару: скаляр  $\hat{y} \in \mathbb{R}$
4. Передавальна функція нейронної мережі:  
Перший прихований шар:

$$h^{(1)} = \phi(W^{(1)} \cdot x + b^{(1)}) \quad (2)$$

де  $W^{(1)} \in \mathbb{R}^{64 \times 5}$  – матриця ваг;  $b^{(1)} \in \mathbb{R}^{64}$  – вектор зсувів (bias);  $\phi(z) = \max(0, z)$  – активаційна функція ReLU.

Другий прихований шар:

$$h^{(2)} = \phi(W^{(2)} \cdot h^{(1)} + b^{(2)}) \quad (3)$$

де  $W^{(2)} \in \mathbb{R}^{64 \times 64}$ ,  $b^{(2)} \in \mathbb{R}^{64}$ .

Вихідний шар:

$$\hat{y} = W^{(3)} \cdot h^{(2)} + b^{(3)} \quad (4)$$

де  $W^{(3)} \in \mathbb{R}^{1 \times 64}$ ,  $h^{(2)} \in \mathbb{R}^{64}$ ,  $\hat{y} \in [0,1]$  – прогнозоване загальне навантаження мережі.

Оскільки задача – регресія, використовується функція Mean Squared Error (MSE):

$$L(\theta) = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (5)$$

де  $y_i$  – справжнє навантаження мережі в момент  $i$ ,  $\hat{y}_i$  – прогноз моделі,  
 $\theta = \{W^{(1)}, b^{(1)}, \dots, W^{(3)}, b^{(3)}\}$  – усі параметри моделі.

Оптимізація:

Мінімізація функції втрат виконується за допомогою алгоритму Adam, який модифікує класичний градієнтний спуск:

$$\theta_{t+1} = \theta_t - \eta \cdot \frac{m_t}{\sqrt{v_t + e}} \quad (6)$$



де  $m_t$  – перша моментна оцінка (середнє значення градієнтів),  $v_t$  – друга моментна оцінка (середнє квадратичне значення градієнтів),  $\eta$  – швидкість навчання,  $e$  – мала константа для уникнення ділення на нуль.

Повну модель можна записати як композицію:

$$\hat{y} = f(x) = W^{(3)} \cdot \phi(W^{(2)} \cdot \phi(W^{(1)} \cdot x + b^{(1)}) + b^{(2)}) + b^{(3)} \quad (7)$$

Значення  $\hat{y} \in [0,1]$  можна інтерпретувати як відносне навантаження. Якщо встановити граничне значення (наприклад, 0.85), то мережа може бути визнана потенційно перевантаженою, що є сигналом до активації систем балансування, QoS-контролю або перенесення сесій до менш завантажених вузлів.

Формулювання нейронної мережі як задачі оптимізації у вигляді цільової функції з обмеженнями дозволяє подивитися на модель з точки зору класичної математичної оптимізації, що може бути корисно для аналітичного аналізу, реалізації у спеціалізованих середовищах (наприклад, у CVX, Gurobi) або доведення теоретичних властивостей.

Метою оптимізації є мінімізація похибки прогнозу навантаження гетерогенної телекомунікаційної мережі.

Формально:

$$\min_{\theta} L(\theta) = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i(\theta))^2 \quad (8)$$

де  $\theta = \{W^{(1)}, b^{(1)}, \dots, W^{(3)}, b^{(3)}\}$  – усі параметри нейронної мережі,  $\hat{y}_i(\theta)$  – вихід моделі на вході  $x_i$ , залежить від ваг  $\theta$ ,  $y_i$  – фактичне навантаження мережі для моменту  $i$ ,  $N$  – кількість прикладів у навчальній вибірці.

Основне призначення обмежень — зберегти фізичний сенс та контроль над параметрами моделі.

Обмеження на вихід моделі (в межах фізичних значень навантаження):

$$0 \leq \hat{y}_i(\theta) \leq 1 \quad \forall i = 1, \dots, N \quad (9)$$

Обмеження на вхідні дані (для нормалізованих входів):

$$0 \leq x_{ij} \leq 1 \quad \forall i = 1, \dots, N \quad j = 1, \dots, 5 \quad (10)$$

3. Обмеження на ваги – регуляризація (L2-норма):

$$\sum_t \|W^{(t)}\|_2^2 \leq \lambda \quad (11)$$

де  $\lambda > 0$  — гіперпараметр регуляризації,  $l \in \{1, 2, 3\}$  – номер шару.

Це обмеження зменшує перенавчання, обмежуючи зростання ваг.

Додаткове обмеження (опційно): симетрія або пріоритетність окремих інтерфейсів (наприклад, на основі QoS):

$W_{1j}^{(1)} \leq W_{2j}^{(2)}$ , якщо пріоритет LTE вище за Wi-Fi.

$$\min_{\theta} L(\theta) = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i(\theta))^2$$

$$0 \leq \hat{y}_i(\theta) \leq 1 \quad \forall i = 1, \dots, N$$



$$0 \leq x_{ij} \leq 1 \quad \forall i=1, \dots, N \quad j=1, \dots, 5 \quad (12)$$

$$\sum_i \|W^{(i)}\|_2^2 \leq \lambda$$

$$W_{1j}^{(1)} \leq W_{2j}^{(2)}$$

Створення моделі нейронної мережі відбувається з використанням мови програмування Python та бібліотек TensorFlow / Keras:

```
model = tf.keras.Sequential([  
    tf.keras.layers.Dense(64, input_shape=(X_train.shape[1],), activation='relu'),  
    tf.keras.layers.Dense(64, activation='relu'),  
    tf.keras.layers.Dense(1) # одна вихідна змінна: total_load  
)  
  
model.compile(optimizer='adam', loss='mse', metrics=['mae'])
```

Розроблена модель є штучною нейронною мережею, яка використовується для прогнозування навантаження в гетерогенній телекомунікаційній мережі на основі попередніх історичних даних про трафік, затримки, рівень втрат пакетів, пропускну здатність каналів та інші ключові характеристики мережі (рис.1). Вона реалізована за допомогою бібліотеки TensorFlow/Keras і побудована як послідовна модель з трьома повнозв'язними шарами: вхідний шар приймає багатовимірний вектор характеристик стану мережі, прихований шар з 64 нейронами активує нелінійні взаємозв'язки між ознаками через функцію ReLU, а вихідний шар з одним нейроном передбачає числове значення майбутнього навантаження на систему (наприклад, у вигляді очікуваної кількості пакетів, пропускну здатності або рівня використання каналу в відсотках).

Модель навчається на основі функції втрат середньоквадратичної помилки (mean squared error – MSE), яка мінімізує різницю між прогнозованим та реальним навантаженням, що дозволяє досягати високої точності за умови наявності достатньо якісного набору даних. У процесі навчання використовується оптимізатор Adam, який адаптивно коригує крок градієнтного спуску, забезпечуючи швидку та стабільну збіжність у навчанні. У контексті застосування така модель може використовуватися для підтримки прийняття рішень у реальному часі в системах управління трафіком. Наприклад, вона може бути інтегрована в програмне забезпечення мережевого контролера, яке визначає, коли необхідно балансувати навантаження, змінювати маршрут передачі даних, розширювати пропускну здатність або навіть тимчасово блокувати певні типи трафіку. Особливо цінною модель є для операторів мобільного зв'язку, провайдерів хмарних послуг або внутрішніх корпоративних мереж, де навантаження може різко змінюватися залежно від часу доби, кількості активних користувачів або динаміки міжмережевого трафіку.

Оскільки гетерогенна телекомунікаційна мережа складається з різномірних компонентів – базових станцій різних поколінь (4G, 5G), Wi-Fi-зон, оптоволоконних магістралей, супутникових каналів і мобільних пристроїв – здатність ШНМ узагальнювати закономірності на основі вхідних характеристик дозволяє їй об’єктивно враховувати вплив усіх типів середовищ. Це зменшує ризик перевантаження критичних сегментів, підвищує якість обслуговування (QoS) і забезпечує адаптивність мережі до динамічних змін.

Таким чином, модель виконує роль цифрового передбачувального механізму, що в умовах реального часу аналізує та інтерпретує великий потік вхідної телекомунікаційної інформації з метою попередження та пом’якшення проблем із перевантаженням, затримками чи втратою пакетів у складній розподіленій мережевій інфраструктурі.



Рис. 1. Блок-схема роботи нейронної мережі






Рис. 2. Порівняння реального і прогнозованого навантаження

В результаті проведеного прогнозування було встановлено, що середня абсолютна помилка прогнозу склала 0,0033.

## ВИСНОВКИ ТА ПЕРСПЕКТИВИ ПОДАЛЬШИХ ДОСЛІДЖЕНЬ

У результаті проведеного дослідження було створено модель прогнозування навантаження в гетерогенній телекомунікаційній мережі на основі штучної нейронної мережі, що забезпечує високий рівень точності передбачення змін трафіку з урахуванням різних типів пристроїв, протоколів зв'язку, часових і просторових факторів. Запропонована модель продемонструвала ефективність у виявленні пікових навантажень та адаптації до динамічних умов мережі, що дозволяє оптимізувати розподіл ресурсів, покращити якість обслуговування користувачів та зменшити ризик перевантаження вузлів.

Використання глибоких нейронних мереж у даній сфері відкриває нові можливості для створення інтелектуальних систем керування трафіком у реальному часі. Проведене моделювання засвідчило доцільність застосування рекурентної архітектури (зокрема LSTM-мереж) для задач прогнозування, оскільки вона дозволяє враховувати послідовність історичних даних і виявляти приховані закономірності, що властиві телекомунікаційним потокам.

Перспективи подальших досліджень полягають у вдосконаленні нейронної архітектури шляхом інтеграції додаткових шарів самоуваги, використанні гібридних моделей із поєднанням статистичних методів та глибокого навчання, розширенні наборів вхідних параметрів за рахунок телеметричних, кліматичних та поведінкових характеристик користувачів. Також доцільно розглянути можливість застосування мультиагентного підходу для прогнозування та динамічного балансування навантаження між підсистемами гетерогенної мережі. Крім того, важливо продовжити дослідження в напрямі підвищення захищеності та стійкості системи до кібератак і збоїв, що особливо актуально в умовах розвитку критичної інфраструктури.



## СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Cao, S., & Liu, W. (2019). LSTM Network Based Traffic Flow Prediction for Cellular Networks. In Proceedings of the 5th International Conference on Computer and Communications (pp. 1435-1440). Springer.
2. Jaffry, S. (2020). Cellular Traffic Prediction with Recurrent Neural Network. arXiv preprint arXiv:2003.02807.
3. Azari, A., Papapetrou, P., Denic, S., & Peters, G. (2019). Cellular Traffic Prediction and Classification: A Comparative Evaluation of LSTM and ARIMA. arXiv preprint arXiv:1906.00939.
4. Hua, Y., Zhao, Z., Li, R., Chen, X., Liu, Z., & Zhang, H. (2018). Deep Learning with Long Short-Term Memory for Time Series Prediction. arXiv preprint arXiv:1810.10161.
5. Gao, M., Wei, Y., Xie, Y., & Zhang, Y. (2024). Traffic Prediction with Self-Supervised Learning: A Heterogeneity-Aware Model for Urban Traffic Flow Prediction Based on Self-Supervised Learning. *Mathematics*, 12(9), 1290.
6. Wang, X., Zhao, J., Zhu, L., Zhou, X., Li, Z., Feng, J., Deng, C., & Zhang, Y. (2021). Adaptive Multi-receptive Field Spatial-Temporal Graph Convolutional Network for Traffic Forecasting. arXiv preprint arXiv:2111.00724.
7. Gao, M., Wei, Y., Xie, Y., & Zhang, Y. (2024). Traffic Prediction with Self-Supervised Learning: A Heterogeneity-Aware Model for Urban Traffic Flow Prediction Based on Self-Supervised Learning. *Mathematics*, 12(9), 1290.
8. Wang, X., Zhao, J., Zhu, L., Zhou, X., Li, Z., Feng, J., Deng, C., & Zhang, Y. (2021). Adaptive Multi-receptive Field Spatial-Temporal Graph Convolutional Network for Traffic Forecasting. arXiv preprint arXiv:2111.00724.
9. Gao, M., Wei, Y., Xie, Y., & Zhang, Y. (2024). Traffic Prediction with Self-Supervised Learning: A Heterogeneity-Aware Model for Urban Traffic Flow Prediction Based on Self-Supervised Learning. *Mathematics*, 12(9), 1290.
10. Wang, X., Zhao, J., Zhu, L., Zhou, X., Li, Z., Feng, J., Deng, C., & Zhang, Y. (2021). Adaptive Multi-receptive Field Spatial-Temporal Graph Convolutional Network for Traffic Forecasting. arXiv preprint arXiv:2111.00724.
11. V. Zhebka, et al., Stability Method of Connectivity Automated Calculation for Heterogeneous Telecommunication Network, in: Workshop on Cybersecurity Providing in Information and Telecommunication Systems, vol. 3188 (2021) 282–287.
12. P. Anakhov, et al., Evaluation Method of the Physical Compatibility of Equipment in a Hybrid Information Transmission Network, *J. Theor. Appl. Inf. Technol.* 100(22) (2022) 6635–6644.
13. N. Dovzhenko, et al., Method of Sensor Network Functioning under the Redistribution Condition of Requests between Nodes, in: *Cybersecurity Providing in Information and Telecommunication Systems* vol. 3421 (2023) 278–283.
14. P. Anakhov, et al., Protecting Objects of Critical Information Infrastructure from Wartime Cyber Attacks by Decentralizing the Telecommunications Network, in: *Workshop on Cybersecurity Providing in Information and Telecommunication Systems*, vol. 3050 (2023) 240-245
15. P. Anakhov, et al., Increasing the Functional Network Stability in the Depression Zone of the Hydroelectric Power Station Reservoir, in: *Workshop on Emerging Technology Trends on the Smart Industry and the Internet of Things*, vol. 3149 (2022) 169–176

**Viktoriia Zhebka**

Doctor of Technical Sciences, Professor

Head of the Department of Digital Development Technologies

State University of Information and Communication Technologies, Kyiv, Ukraine

ORCID ID 0000-0003-4051-1190

v.zhebka@duikt.edu.ua

**LOAD FORECASTING IN HETEROGENEOUS TELECOMMUNICATION NETWORKS BASED ON THE DEVELOPED NEURAL MODEL**

**Abstract.** The paper addresses the relevant scientific challenge of traffic load forecasting in heterogeneous telecommunication networks using artificial neural networks. With the rapid deployment of 5G technologies, IoT devices, smart city infrastructures, and mobile cloud computing, there is a growing need for intelligent models capable of analyzing vast volumes of telecommunications data and accurately forecasting network load. One of the key challenges in heterogeneous networks is the uneven distribution of traffic across different communication technologies (e.g., LTE, Wi-Fi, NB-IoT), which requires adaptive resource management strategies. The proposed model is based on a multilayer perceptron (MLP) neural network trained on time series data representing network component loads. Input features include previous traffic load values, time-based characteristics, network type, and QoS levels. The model is trained using backpropagation and the mean squared error (MSE) loss function. The output of the model is a predicted load value for a given future time interval. The study provides a detailed algorithmic description of the model's operation, including its mathematical formulation, objective function, and system constraints. The model accounts for the structural characteristics of heterogeneous networks, offers adaptability to changing environments, and can be scaled to suit various telecommunication platforms. A literature review highlights relevant research on network load prediction, including works by G. Zhang, M. Chen, Y. Sun, as well as Ukrainian researchers such as D.V. Kozlov, A.O. Hrabovets, and Y.P. Solovey. The results of this research can be applied to optimize network traffic distribution, enable dynamic load balancing, support adaptive resource planning, and prevent overloads. In the future, the model can be integrated into real-time monitoring systems and adapted to emerging 6G networks and hybrid communication architectures. The proposed solution contributes to improving the efficiency of telecommunications infrastructure management in the context of rapidly expanding digital services and high network usage intensity.

**Keywords:** heterogeneous telecommunication network, neural network, load forecasting, multilayer perceptron, information technology.

**REFERENCES**

1. Cao, S., & Liu, W. (2019). LSTM Network Based Traffic Flow Prediction for Cellular Networks. In Proceedings of the 5th International Conference on Computer and Communications (pp. 1435-1440). Springer.
2. Jaffry, S. (2020). Cellular Traffic Prediction with Recurrent Neural Network. arXiv preprint arXiv:2003.02807.
3. Azari, A., Papapetrou, P., Denic, S., & Peters, G. (2019). Cellular Traffic Prediction and Classification: A Comparative Evaluation of LSTM and ARIMA. arXiv preprint arXiv:1906.00939.
4. Hua, Y., Zhao, Z., Li, R., Chen, X., Liu, Z., & Zhang, H. (2018). Deep Learning with Long Short-Term Memory for Time Series Prediction. arXiv preprint arXiv:1810.10161.
5. Gao, M., Wei, Y., Xie, Y., & Zhang, Y. (2024). Traffic Prediction with Self-Supervised Learning: A Heterogeneity-Aware Model for Urban Traffic Flow Prediction Based on Self-Supervised Learning. Mathematics, 12(9), 1290.
6. Wang, X., Zhao, J., Zhu, L., Zhou, X., Li, Z., Feng, J., Deng, C., & Zhang, Y. (2021). Adaptive Multi-receptive Field Spatial-Temporal Graph Convolutional Network for Traffic Forecasting. arXiv preprint arXiv:2111.00724.



7. Gao, M., Wei, Y., Xie, Y., & Zhang, Y. (2024). Traffic Prediction with Self-Supervised Learning: A Heterogeneity-Aware Model for Urban Traffic Flow Prediction Based on Self-Supervised Learning. *Mathematics*, 12(9), 1290.
8. Wang, X., Zhao, J., Zhu, L., Zhou, X., Li, Z., Feng, J., Deng, C., & Zhang, Y. (2021). Adaptive Multi-receptive Field Spatial-Temporal Graph Convolutional Network for Traffic Forecasting. *arXiv preprint arXiv:2111.00724*.
9. Gao, M., Wei, Y., Xie, Y., & Zhang, Y. (2024). Traffic Prediction with Self-Supervised Learning: A Heterogeneity-Aware Model for Urban Traffic Flow Prediction Based on Self-Supervised Learning. *Mathematics*, 12(9), 1290.
10. Wang, X., Zhao, J., Zhu, L., Zhou, X., Li, Z., Feng, J., Deng, C., & Zhang, Y. (2021). Adaptive Multi-receptive Field Spatial-Temporal Graph Convolutional Network for Traffic Forecasting. *arXiv preprint arXiv:2111.00724*.
11. V. Zhebka, et al., Stability Method of Connectivity Automated Calculation for Heterogeneous Telecommunication Network, in: *Workshop on Cybersecurity Providing in Information and Telecommunication Systems*, vol. 3188 (2021) 282–287.
12. P. Anakhov, et al., Evaluation Method of the Physical Compatibility of Equipment in a Hybrid Information Transmission Network, *J. Theor. Appl. Inf. Technol.* 100(22) (2022) 6635–6644.
13. N. Dovzhenko, et al., Method of Sensor Network Functioning under the Redistribution Condition of Requests between Nodes, in: *Cybersecurity Providing in Information and Telecommunication Systems* vol. 3421 (2023) 278–283.
14. P. Anakhov, et al., Protecting Objects of Critical Information Infrastructure from Wartime Cyber Attacks by Decentralizing the Telecommunications Network, in: *Workshop on Cybersecurity Providing in Information and Telecommunication Systems*, vol. 3050 (2023) 240-245
15. P. Anakhov, et al., Increasing the Functional Network Stability in the Depression Zone of the Hydroelectric Power Station Reservoir, in: *Workshop on Emerging Technology Trends on the Smart Industry and the Internet of Things*, vol. 3149 (2022) 169–176

