

УДК 004

## ГРАФОВІ НЕЙРОННІ МЕРЕЖІ У ЗАДАЧАХ ПРОГНОЗУВАННЯ ПАРАМЕТРІВ ТЕХНОЛОГІЧНИХ ПРОЦЕСІВ

*Авсітідійський М. М.*

*Харківський національний університет радіоелектроніки, Харків*

У сучасних технологічних процесах – від виробництва й транспорту до енергетики та авіації – ключовим завданням є своєчасне прогнозування параметрів, що характеризують стан обладнання. Системи технічного обслуговування за станом (Condition-Based Maintenance) вимагають точного передбачення таких величин, як залишковий ресурс роботи вузлів, рівень зношення компонентів або ймовірність відмови у найближчому майбутньому.

Сенсорні дані у таких задачах мають складну природу: вони є багатовимірними, корельованими, нелінійними та змінюються у часі. У зв'язку з цим традиційні методи регресійного аналізу часто демонструють низьку ефективність, оскільки не здатні повноцінно врахувати часову структуру даних та нелінійні залежності між параметрами. Тому на зміну класичним статистичним моделям приходять методи глибинного навчання, зокрема рекурентні нейронні мережі (LSTM, GRU) та сучасні графові моделі (Graph Neural Networks, GNN).

Рекурентні нейронні мережі (RNN) стали фундаментом сучасних методів прогнозування часових сигналів. Їхні найпопулярніші модифікації – LSTM (Long Short-Term Memory) та GRU (Gated Recurrent Unit) – спеціально розроблені для подолання проблеми зникання градієнта та здатні запам'ятовувати залежності на довгих часових проміжках.

LSTM використовує три «входи»: вхідний, вихідний та вхід забування, що дозволяють моделі контролювати, які дані запам'ятовувати, а які вилучати зі стану мережі. Завдяки цьому LSTM ефективно моделює довгі послідовності, згладжує шум у сенсорних вимірюваннях, адаптивно зберігає релевантну інформацію про стан системи.

GRU — спрощена версія LSTM, яка має лише два гейти (update та reset). За рахунок меншої кількості параметрів GRU тренується швидше, менш схильна до перенавчання, часто показує результати, близькі до LSTM.

Рекурентні моделі, такі як LSTM і GRU, добре працюють із послідовними даними, однак мають низку обмежень: вони бачать процес лише як лінійну часову послідовність і не враховують структурну подібність між станами, можуть уповільнюватися на довгих серіях та є чутливими до шуму, що характерно для промислових сенсорних даних. Через це зростає інтерес до графових моделей, які дозволяють представити технологічний процес у вигляді мережі взаємопов'язаних станів і враховувати як часові, так і структурні залежності.

Графові нейронні мережі (GNN), натомість, моделюють технологічний процес як граф, де кожна вершина відповідає окремому стану системи (наприклад, циклу роботи двигуна), а ребра відображають зв'язки між подібними або сусідніми станами [1]. У Graph Attention Networks (GAT) інформація від сусідніх вершин агрегується з вагами, що визначаються механізмом уваги. Для кожної вершини  $h'_v = \sigma(\sum_{u \in N(v)} \alpha_{vu} W h_u)$ , де  $h_u$  — ознаки сусідньої вершини,  $W$  — матриця перетворення, а коефіцієнти уваги  $\alpha_{vu} = \text{softmax}(a(Wh_v, Wh_u))$ , визначають важливість кожного сусіда. Такий підхід дозволяє моделі вибірково підсилювати найінформативніші зв'язки, враховувати структурну подібність між станами та будувати більш гнучку модель деградації, ніж традиційні послідовні методи [2].

У дослідженні було порівняно ефективність рекурентних моделей (LSTM, GRU) та графової мережі GAT на реальних промислових даних NASA C-MAPSS [3]. Рекурентні архітектури продемонстрували високу точність: покращена конфігурація LSTM досягла похибок MAE на рівні 7–9 циклів та RMSE – 10–12, тоді як GRU забезпечила близькі результати з незначним відставанням. Водночас графова нейронна мережа GAT, побудована на основі комбінованого графа подібності та часових зв'язків, показала цілком конкурентні результати, досягнувши MAE – 13–16 циклів та

RMSE – 17–19 циклів, що підтверджує її здатність ефективно вловлювати закономірності деградації. Важливо, що GAT не поступилася рекурентним моделям у стабільності навчання: на поданих графіках Loss-функцій добре видно рівномірну та монотонну збіжність GNN без різких стрибків або розходжень, що свідчить про стійкість графового підходу навіть за відсутності глибокої оптимізації гіперпараметрів. Урахування не лише часових, а й структурних зв'язків між циклами роботи двигуна дозволило GAT будувати більш гнучке представлення станів, у деяких сценаріях демонструючи поведінку, близьку до LSTM, а за ускладнення структури даних (багаторежимні підмножини FD002–FD004) потенційно може і перевершувати рекурентні мережі. Отримані результати доводять, що графові нейронні мережі є не гіршою, а часто більш універсальною альтернативою традиційним RNN-моделям у задачах прогнозування параметрів технологічних процесів.

### **Література:**

1. Zhou J., Cui G., Hu S., Zhang Z., Yang C., Liu Z., Wang L., Li C., Sun M. Graph neural networks: A review of methods and applications // *AI Open*. 2020. Vol. 1. С. 1–26.
2. Klinke N., Buchkremer S., Elend L., Kalaidov M., von Tschammer T. AI-based performance prediction and its application on the design and simulation of cooling plates for battery electric vehicles // *Future Automotive Production Conference (FAPC)*. Wolfsburg, Germany, 17–18 May 2022. С. 1–10.
3. NASA Turbofan Jet Engine Data Set. URL: <https://www.kaggle.com/datasets/behrad3d/nasa-cmaps> (дата звернення: 19.09.2025).