

УДК 519.86:621.311

**ЗАСТОСУВАННЯ ГРАФОВИХ НЕЙРОННИХ МЕРЕЖ
ДЛЯ АНАЛІЗУ ТА ПРОГНОЗУВАННЯ СТАНУ
ЕНЕРГЕТИЧНИХ МЕРЕЖ**

Левченко Н.С.

e-mail: nikita.levchenko@gmail.com

Науковий керівник – канд. техн. наук, доц. Єсілевський В.С.

Харківський національний університет радіоелектроніки,

кафедра прикладної математики

м. Харків, Україна

Modern energy systems are complex infrastructure networks that generate large amounts of operational data. Traditional analysis methods are often insufficient to account for spatial dependencies between network elements. This paper considers an approach using graph neural networks for modelling and analysing energy infrastructure. The power supply system is represented as a graph, where nodes correspond to substations and edges correspond to transmission lines. A graph convolutional neural network is used to account for spatial relationships between network elements and predict system states. The proposed model allows identifying critical nodes and detecting potential overloads in the network. Such approaches contribute to improving the reliability and efficiency of energy infrastructure.

Сучасні енергетичні системи характеризуються складною структурою взаємозв'язаних елементів, що включають генератори електроенергії, підстанції та лінії електропередач. Аналіз та прогнозування стану таких систем є важливою задачею забезпечення стабільності енергетичної інфраструктури. Особливу актуальність ці задачі набувають в умовах зростання навантаження на енергомережі, інтеграції відновлюваних джерел енергії та необхідності підвищення їх надійності.

Традиційні методи аналізу часто не враховують складні взаємозв'язки між елементами мережі, що обмежує їх ефективність. У зв'язку з цим актуальним є використання методів машинного навчання, зокрема графових нейронних мереж, які дозволяють моделювати структуру складних систем та враховувати їх топологічні особливості.

Енергетичну мережу можливо представити у вигляді графа:

$$G = (V, E), \quad (1)$$

де V – множина вузлів графа, що відповідають підстанціям, генераторам, трансформаторам, тощо; E – множина ребер, які відповідають лініям передач.

Кожному вузлу $v_i \in V$ відповідає вектор характеристик

$$x_i = (p_i, u_i, l_i), \quad (2)$$

де p_i – потужність навантаження; u_i – рівень напруги; l_i – інші параметри функціонування вузла.

Топологія мережі задається матрицею суміжності

$$A = (a_{ij}). \quad (3)$$

де $a_{ij} = 1$, якщо вузли пов'язані, та $a_{ij} = 0$ – інакше. Матриця суміжності визначає структуру взаємодії між елементами системи та дозволяє враховувати вплив сусідніх вузлів при аналізі стану мережі.

Врахування часової динаміки для задачі прогнозування. Енергоспоживання має яскраво виражений часовий характер: добові коливання (день/ніч), тижневі цикли (будні/вихідні), сезонні зміни. Тому для якісного прогнозування необхідно враховувати не лише поточний стан мережі, а й історію змін. Таким чином, поєднання просторової (графової) та часової інформації є ключовим для побудови ефективних моделей прогнозування.

Для моделювання просторових залежностей між елементами мережі використовується графова нейронна мережа (GNN). Базовим елементом є графовий згортковий шар (Graph Convolutional Layer), запропонований у роботі Kipf & Welling. Правило поширення сигналу у графовому згортковому шарі має вигляд:

$$H^{(l+1)} = \sigma \left(D^{-\frac{1}{2}} \tilde{A} D^{-\frac{1}{2}} H^{(l)} W^{(l)} \right), \quad (4)$$

де $H^{(l)}$ – матриця представлень вузлів на l -му шарі; $W^{(l)}$ – матриця ваг моделі (навчальні параметри); σ – нелінійна функція активації; $\tilde{A} = A + I$ – матриця суміжності з доданими петлями; $\tilde{D}$ – діагональна матриця степенів для $\tilde{A}$ $\left(\tilde{D}_{ii} = \sum_j A_{ij} \right)$.

Цей шар виконує агрегацію інформації від сусідніх вузлів з урахуванням топології мережі, що дозволяє моделі «зрозуміти» просторову структуру. Таким чином, кожен вузол оновлює своє представлення на основі інформації від сусідніх вузлів, що дозволяє враховувати локальну структуру мережі. При багатошаровій архітектурі модель здатна враховувати залежності між віддаленими елементами системи.

Нормалізована матриця суміжності має вигляд:

$$\tilde{A} = A + I, \quad (5)$$

де I – одинична матриця.

Метою задачі є прогнозування стану вузлів енергетичної системи

$$\tilde{Y} = f_{\theta}(X, A), \quad (6)$$

де A – матриця суміжності мережі; X – матриця ознак вузлів; θ – параметри нейронної мережі. Модель f_{θ} реалізує відображення з простору ознак вузлів у простір прогнозованих значень, враховуючи як властивості самих вузлів, так і структуру зв'язків між ними.

Вибір функції втрат визначає критерій якості моделі. Використання середньоквадратичної похибки дозволяє ефективно оцінювати точність

прогнозу у задачах регресії. Оскільки прогнозування навантаження є задачею регресії, як функцію втрат обрано середньоквадратичну похибку (MSE):

$$L_{MSE} = \frac{1}{n} \sum_{i=1}^n (p_i^{t+1} - \hat{p}^{(t+1)})^2, \quad (7)$$

де p_i^{t+1} – фактичне значення навантаження; $\hat{p}^{(t+1)}$ – прогноз моделі.

Навчання моделі здійснюється шляхом мінімізації функції витрат:

$$\hat{\theta} = \underset{\theta}{\operatorname{argmin}} \sum_{i=1}^n L(y_i, y_i). \quad (8)$$

Окрім задачі прогнозування, важливим аспектом є аналіз критичних станів мережі. На основі отриманих представлень вузлів можливо виявляти потенційно вразливі елементи системи, що можуть призвести до перевантажень або аварійних ситуацій. Це дозволяє використовувати модель не лише для прогнозування, але й для моніторингу стану інфраструктури.

Запропонований підхід дозволяє враховувати топологію енергетичної мережі та складні просторові залежності між її елементами. Використання графових нейронних мереж забезпечує підвищення точності прогнозування у порівнянні з традиційними методами.

Отримані прогнозні значення навантаження можуть бути використані для розв'язання задач оптимізації режимів роботи енергомережі. Зокрема, на основі прогнозу можна завчасно перерозподіляти навантаження між генераторами, зменшувати втрати електроенергії при передачі та підвищувати ефективність функціонування системи в цілому.

Таким чином, застосування графових нейронних мереж дозволяє формалізувати задачу аналізу та прогнозування енергетичних мереж як задачу машинного навчання на графах. Запропонований підхід поєднує методи теорії графів, машинного навчання та математичного моделювання, що робить його перспективним напрямом для дослідження сучасних енергетичних систем.

Список використаних джерел:

1. Wu Z., Pan S., Chen F., Long G., Zhang C., Yu P. S. A comprehensive survey on graph neural networks. *IEEE Transactions on Neural Networks and Learning Systems*. 2020. Vol. 32, No. 1. P. 4–24.
2. Kipf T. N., Welling M. Semi-Supervised Classification with Graph Convolutional Networks. *Proceedings of the International Conference on Learning Representations (ICLR)*. 2017.
3. 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. P. 57–81.