

УДК 004.8: 629.7.05: 623.67

Соловей О.Л., канд. техн. наук

Київський національний університет будівництва і архітектури, solovey.ol@knuba.edu.ua

## ПІДХІД ДО ІНІЦІАЛІЗАЦІЇ ВАГ НЕЙРОННОЇ МЕРЕЖІ ПРЯМОГО ПОШИРЕННЯ

Архітектура інформаційної технології для управління даними проектів міського будівництва складається з шарів: 1) шар джерел потокових даних; 2) шар прийому потокових даних; 3) шар обробки та збереження потокових даних; 4) шар аналітики потокових даних [1]. Apache Kafka кластер забезпечує обробку потоків даних у реальному часі з низкою затримкою. Висока пропускна здатність для передачі повідомлень від Kafka-продюсера до Kafka-споживача є однією з ключових вимог для інформаційних технологій з управління різнорідними даними проектів міського будівництва. Конфігурація Kafka-кластера забезпечує високу продуктивність за умови відповідності її параметрів потребам системи. Таким чином, актуальним є питання розробки формальних моделей та методів для визначення оптимальної конфігурації Apache Kafka-кластера.

Коли модель глибокого навчання використовується для визначення конфігурації Apache Kafka кластера на основі прогнозування затримки в кластері, вибір початкової матриці ваг має значний вплив на збіжність навчання та кінцеву продуктивність моделі оскільки суттєво впливає на активацію нейронів [2].

Нещодавні дослідження [3] показали, що розуміння причинно-наслідкових зв'язків має велике значення для осіб, які приймають рішення в найрізноманітніших контекстах. Сучасні методи ініціалізації ваг у нейронних мережах включають: 1) метод ініціалізації ваг на основі даних, що ґрунтується на аналізі дискримінантів підкласів (Subclass Discriminant Analysis, SDA), який дозволяє кожному класу представлятися у вигляді набору підкласів, ідентифікованих за допомогою кластеризаційних алгоритмів [4]; 2) метод ZerO-ініціалізації, який повністю усуває випадковість у процесі ініціалізації ваг і задає ваги нулями та одиницями на основі матриці Адамара (Hadamard matrix), що забезпечує ортогональність ініціалізованих ваг. Така ортогональність запобігає «втручанням» нейронів один в одного та дозволяє їм навчатися різноманітним ознакам [5]; 3) метод визначення початкових ваг на основі масштабування, при якому кожен випадковий тензор ваг масштабують безпосередньо за допомогою вивченого скалярного коефіцієнта [6]; 4) метод масштабування ваг під час навчання нейронної мережі, що дозволяє зберегти умови, встановлені на етапі ініціалізації. Ваги, ініціалізовані відповідно до цього підходу, покращують стабільність процесу навчання [7].

З огляду на проведений аналіз робіт [4–7], можна стверджувати, що перелічені методи не враховують причинно-наслідкові впливи під час визначення матриці початкових ваг нейронних мереж.

Аналіз чутливості в баєсівській мережі дозволяє визначити силу причинно-наслідкових впливів шляхом оцінки того, як зміни одного параметра впливають на інший, і кількісно оцінити цю силу. Результати такого аналізу чутливості можуть бути використані для формування матриці ваг у моделях нейронних мереж.

Запропонуємо модель для визначення початкової матриці ваг  $W$  для нейронної мережі прямого поширення.

Нехай  $X$  – це множина з  $n$  дискретних параметрів Apache Kafka кластера. Сила впливу змін станів змінної  $X$  на апостеріорну ймовірність змінної  $Z$  можна визначити після того, як кожна змінна  $X$  та  $Z$  подана у вигляді пари  $(D, P)$ , де:  $D$  - орієнтований ациклічний граф, у якому кожна змінна є вузлом, а ребра відображають причинно-наслідкові зв'язки між

змінними;  $P$  - набір параметрів, що визначає умовні ймовірності для кожної змінної  $x_i \in X$  за умови її батьків  $P_{a_i}$ , тобто:  $P = \{P(X_i = x_i | P_{a_i} = p_{a_i})\}$ .

Апостеріорна ймовірність  $P(Z|X)(p)$  для вузла  $Z$ , що базується на змінах параметрів вузлів-батьків  $X$ , виражається як відношення двох лінійних функцій від параметра  $p$ :

$$P(Z|X)(p) = \frac{a \cdot p + b}{c \cdot p + d} \quad (1)$$

де  $a, c$  - кутові коефіцієнти в лінійному рівнянні;

$b, d$  - зсув по осі  $OY$ ;

$p$  - ймовірність того, що параметри мережі  $X$  набудуть певного стану з множини  $S$ .

Частинна похідна від функції (1) за параметром  $p$  визначає чутливість:

$$Dr = \frac{\partial P(Z|X)(p)}{\partial p} = \frac{ad - bc}{(c \cdot p + d)^2} \quad (2)$$

Сила впливу  $I_{ij}$  від зміни значень вузла-батька ( $i$ ) на апостеріорну ймовірність вузла-нащадка ( $j$ ) визначається як добуток ширини інтервалу зміни параметра ( $W_i$ ) на абсолютне значення похідної (2):

$$I_{ij} = W_i \cdot Dr_i, \quad (3)$$

де  $W_i = P(Z|X)(p = 1) - (Z|X)(p = 0) = \frac{a+b}{c+d} - \frac{b}{d}$

Нехай матриця суміжності  $A_{m \times m}$  орієнтований ациклічний граф басівської мережі визначається за правилом;  $a_{ij} = 1$ , якщо вузол  $i$  з'єднаний з вузлом  $j$ , і  $a_{ij} = 0$  - в інших випадках;  $m$  — загальна кількість вузлів у мережі. Тоді відповідна початкова матриця ваг  $W$  для нейронної мережі прямого поширення встановлюється за правилом:

$$w_{ij} = \begin{cases} 0, & \text{where } a_{ij} = 0 \\ I_{ij}, & \text{where } a_{ij} <> 0 \end{cases} \quad (3)$$

де  $I_{ij}$  визначає силу впливу (3).

Таким чином, використання запропонованої моделі (4) для визначення початкової матриці ваг  $W$  дає змогу врахувати силу впливу між вузлами мережі прямого поширення, між якими є причинно-наслідковий зв'язок в орієнтованому ациклічному графі басівської мережі.

### Список посилань

1. Соловей, О. (2025). Процес підтримки прийняття рішення для налаштування Apache Kafka-продюсера. *Управління розвитком складних систем*, (61), 170-179.
2. M.V. Narkhede, P.P. Bartakke, and M. S. Sutaone. A review on weight initialization strategies for neural networks. *Artificial intelligence review*, 2022, vol. 55, iss. 1, pp.291-322. doi: 10.1007/s10462-021-10033-z.
3. JE Brand, X. Zhou, Y. Xie. Recent developments in causal inference and machine learning. *Annual Review of Sociology*, 2023, vol. 49, iss. 1, pp. 81-110. Doi: 10.1146/annurev-soc-030420-015345.
4. K. Chumachenko, A. Iosifidis, and M. Gabbouj. Feedforward neural networks initialization based on discriminant learning. *Neural Networks*, 2022, vol. 146, pp.220-229. Doi: 10.1016/j.neunet.2021.11.020.
5. J. Zhao, F. Schäfer, and A. Anandkumar, 2021. Zero initialization: Initializing neural networks with only zeros and ones, Published in *Transactions on Machine Learning Research*, 2021, *arXiv preprint arXiv:2110.12661*.
6. Y. Pan, C. Wang, Z. Wu, Q. Wang, M. Zhang, and Z. Xu. IDInit: A Universal and Stable Initialization Method for Neural Network Training, 2025, *arXiv preprint arXiv:2503.04626*.
7. Y. Pan, Z. Su, A. Liu, W. Jingquan, N. Li, and Z. Xu. A unified weight initialization paradigm for tensorial convolutional neural networks. In *International conference on machine learning*, 2022, vol 162, pp. 17238-17257.
8. T. Most, J. Will. Sensitivity analysis using the Metamodel of Optimal Prognosis. *arXiv preprint arXiv:2408.03590*. doi: <https://doi.org/10.48550/arXiv.2408.03590>.