

УДК 004.942:519.876

Прогнозування електроспоживання на базі нейронної мережі

Живогляд О.С., ORCID [0000-0002-2194-6191](https://orcid.org/0000-0002-2194-6191)e-mail olegzhivo123@gmail.com

Національний технічний університет України

«Київський політехнічний інститут імені Ігоря Сікорського» www.kpi.uaКафедра промислової електроніки www.kaf-pe.kpi.ua

Київ, Україна

Реферат — в статті розглянуто задачу прогнозування дискретних значень потужності споживання електричної енергії, яка вирішується з використанням одного з методів штучних нейронних мереж - обмеженої машини Больцмана. В цьому методі прогнозування здійснюється шляхом підлаштування вагових функцій шарів нейронної мережі таким чином, щоб мінімізувати відстань між реальними та розрахованими значеннями. У кожній фазі навчання мережі за допомогою відповідних математичних функцій розраховуються і змінюються коефіцієнти ваг з урахуванням їх поточних значень. В результаті після навчання система здатна ефективно прогнозувати часові залежності потужності споживання електричної енергії, що є важливим при розробці системи керування електроспоживанням промислових та побутових об'єктів.

Ключові слова — нейронна мережа; обмежена машина Больцмана; контрастна дивергенція.

I. ВСТУП

Задача енергоефективного керування споживанням та генерацією електричної енергії є надзвичайно актуальною як для великих електротехнічних комплексів, так і для локальних об'єктів типу MicroGrid або SmartHouse [1]. Під час розробки систем керування виникає необхідність прогнозування значень потужності споживання електричної енергії. Часова залежність електроспоживання на заданому інтервалі (найчастіше – протягом доби) може бути представлена у вигляді дискретного числового ряду. На підставі формування бази даних добових залежностей споживання для різних умов (робочі/вихідні дні, різні пори року, тощо) виявляється можливим провести її подальшу обробку з метою прогнозування електроспоживання у різні моменти часу поточної доби [1].

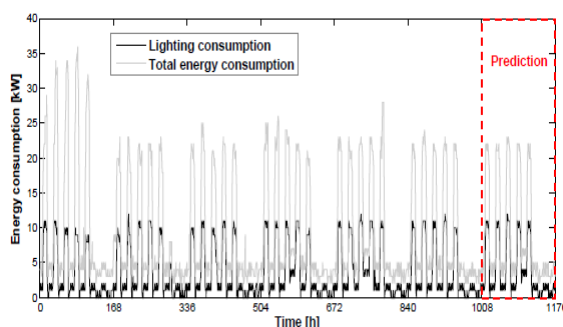


Рис. 1 Графік споживання електричної енергії датського офісу з передбаченням штучних нейронних мереж

Оскільки обсяг бази даних графіків споживання повинен бути досить значним, щоб прогнозування було достовірним, то для обробки цих графіків доцільно застосувати сучасні математичні підходи, зокрема, штучні нейронні мережі (НМ) [1]. Розробці та дослідженню методів прогнозування на базі нейронних мереж присвячено значну кількість сучасних досліджень [1]. Застосування НМ дозволяє підвищити ефективність роботи системи керування електроспоживанням для достатньо складних за структурою промислових та побутових електротехнічних об'єктів, наприклад, MicroGrid [***]. Приклад подібного графіку та результати прогнозування можна спостерігати на рис.1 [1].

Таким чином, задача розробки методу прогнозування дискретного числового ряду споживання електричної енергії на базі застосування штучних нейронних мереж є актуальною.

II. ОБМЕЖЕНА МАШИНА БОЛЬЦМАНА

Для вирішення поставленої задачі серед математичних методів опису штучних нейронних мереж доцільно розглянути структуру так званої «обмеженої машини Больцмана» (ОМБ) [2]. ОМБ являє собою стохастичну штучну нейронну мережу, навчання якої здійснюється «без вчителя» за алгоритмом зворотного розповсюдження помилки [2]. Як і інші НМ, ОМБ складається з видимих і прихованих бінарних шарів нейронів (рис.2). Видимий шар представляє дані, в той час як прихований забезпечує навчання.




Рис.2 Структура НМ: видимі та приховані шари нейронів і зв'язки між ними

Порівняно з іншими структурами нейронних мереж, обмежена машина Больцмана уможливує ефективніший алгоритми тренування, ніж доступний для загального класу нейронних мереж, зокрема, алгоритм «контрастна дивергенція» [3].

Метод стохастичного машинного навчання успішно застосовується для моделювання часових рядів, які характеризуються значним ступенем нестационарності та фактично не можуть бути апроксимовані аналітичними залежностями. Саме цим умовам відповідає типовий графік потужності споживання електричної енергії. Тому застосування ОМБ для прогнозування часового ряду електроспоживання є виправданим.

В процесі навчання штучної нейронної мережі змінюються вагові коефіцієнти нейронів різних шарів. Відповідно змінюється і зважена сума значень вихідних сигналів нейронів, яка надалі надходить на блок активації. В залежності від функції, закладеної у блок активації, формується вихідний сигнал. Отже, результатом кожної фази навчання є зміна вагових коефіцієнтів та параметрів функції активації.

Зв'язки між нейронами різних шарів забезпечують проходження сигналу від входу до виходу. У з'єднанні виходу i -го нейрону із входом j -го перший вважається попередником другого, а другий - наступником першого. З'єднанню цих двох нейронів призначається вага w_{ij} [2].

Вагова функція ОМБ має наступний вигляд:

$$E(v, h) = -\sum_{i=1}^m \sum_{j=1}^n v_i h_j w_{ij} - \sum_{i=1}^m v_i a_i - \sum_{j=1}^n h_j b_j,$$

де i – номер нейрону видимого шару, j – номер нейрону прихованого шару, w_{ij} – вага з'єднання; v_i і h_j – стан i -го видимого і j -го прихованого нейрону; a_i і b_j – вагові коефіцієнти упереджень видимих і прихованих шарів.

Вираз $\sum_{i=1}^m \sum_{j=1}^n v_i h_j w_{ij}$ визначає загальну енергію зв'язку між нейронами різних шарів, $\sum_{i=1}^m v_i a_i$ – енергію видимого шару, $\sum_{j=1}^n h_j b_j$ – енергію прихованого шару [2].

Спільна ймовірність стану прихованого і видимого шарів визначається виразом:

$$P(v, h) = \frac{\exp(-E(v, h))}{Z} = \frac{1}{Z} \exp\left(-\sum_{i=1}^m \sum_{j=1}^n v_i h_j w_{ij} - \sum_{i=1}^m v_i a_i - \sum_{j=1}^n h_j b_j\right),$$

де $Z = \sum_{v, h} \exp(-E(v, h))$ – це сума ваг по всім можливим парам видимих і прихованих з'єднань.

Ймовірність стану видимого шару визначається шляхом додавання ймовірностей станів прихованого шару:

$$p(v) = \sum_h P(v; h)$$

Після перетворень отримаємо:

$$p(v) = \frac{1}{Z} \sum_h \exp\left(-\sum_{i=1}^m \sum_{j=1}^n v_i h_j w_{ij} - \sum_{i=1}^m v_i a_i - \sum_{j=1}^n h_j b_j\right).$$

Для будь-якого прихованого нейрона j умовна ймовірність стану визначається як:

$$p(h_j|v) = \text{sig}(b_j + \sum_i v_i w_{ij}).$$

Для будь-якого видимого нейрона i умовна ймовірність стану визначається як:

$$p(v_i|h) = \text{sig}(a_i + \sum_j h_j w_{ij}).$$

де $\text{sig}(*)$ – сигмоподібна функція активації, що визначається виразом [3]:

$$\sigma(u) = \frac{A(T)}{1 + \exp(-\frac{u}{T})}.$$

Нормувальна константа $A(T)$ вводиться для умови нормалізації розподілу ймовірності:

$$\int_0^1 \sigma(u) du = 1.$$

Параметр T визначає впорядкованість нейронної мережі. Якщо T спрямувати до 0, стохастичний нейрон перейде в звичайний нейрон з передавальною функцією Хевісайда (пороговою функцією), при будь-якому іншому значенні параметра T нейрон активується з ймовірністю $P(u)$ [3].

Алгоритмом, що застосовується для тренування ОМБ, тобто для оптимізації вектора вагових коефіцієнтів, є алгоритм «контрастна дивергенція» (CD – Contrast Divergence) [4]. Цей алгоритм здійснює вибірку за Гіббсом, що використовується у процедурі градієнтного спуску для обчислення уточнених вагових коефіцієнтів.

При оптимізованих значеннях ваг мінімізується відстань Кульбака-Лейблера (D_{KL}) [1] між розподілом вхідних даних і наближенням моделі:

$$CD_n \propto D_{KL}(p_0(x) || p_\infty(x)) - D_{KL}(p_n(x) || p_\infty(x))$$

де $p_n(x)$ є розподілом ланцюга Маркова, що виконується для n кроків [1]. Навчання може бути виконано за допомогою одного кроку вибірки Гіббса. На цьому кроці виконуються операції: 1) оновлення ваг всіх прихованих нейронів, 2) оновлення ваг всіх видимих нейронів. Це відбувається згідно виразів:

$$w_{ij}^{\tau+1} = w_{ij}^\tau + \alpha((h_j v_i)_{p(h|v; W)} - (h_j v_i)_n)$$

$$((h_j v_i)_{p(h|v; W)})_0 = \frac{1}{N} \sum_{k=1}^N v_i^{(k)} P(h_j^{(k)} = 1 | v^{(k)}; W)$$

$$(h_j v_i)_n = \frac{1}{N} \sum_{k=1}^N v_i^{(k)(n)} P(h_j^{(k)(n)} = 1 | v^{(k)(n)}; W)$$

де τ -ітерація, α – зміна коефіцієнтів ваг, N – загальна кількість вхідних екземплярів, верхній індекс (n) –



кількість станів, отриманих після n ітерацій вибірки Гіббса з ланцюга Маркова, починаючи з P_0 [5].

ВИСНОВКИ

Математичний апарат штучної нейронної мережі зі структурою обмеженої машини Больцмана є ефективним методом для прогнозування графіку потужності електричного споживання, оскільки дозволяє мінімізувати відстань між реальними та розрахованими значеннями часових рядів. Після навчання такої системи на сформованій базі даних графіків добового електроспоживання вона буде здатна здійснювати прогнозування в межах заданої похибки.

Застосування запропонованого підходу є ефективним при розробці системи керування електроспоживанням як великих, так і малих промислових та побутових об'єктів, зокрема MicroGrid.

УДК 004.942:519.876

Прогнозирование электропотребления сети на базе нейронной сети

Живогляд О. С., ORCID [0000-0002-2194-6191](https://orcid.org/0000-0002-2194-6191)

e-mail olegzhivo123@gmail.com

Национальный технический университет Украины

«Киевский политехнический институт имени Игоря Сикорского» www.kpi.ua

Кафедра промышленной электроники www.kaf-pe.kpi.ua

Киев, Украина

Реферат — в статье рассмотрена задача прогнозирования дискретных значений мощности потребления электрической энергии которая решается с использованием одного из методов искусственных нейронных сетей - ограниченной машины Больцмана. В этом методе прогнозирования осуществляется путем подстройки весовых функций слоев нейронной сети таким образом, чтобы минимизировать расстояние между реальными и расчетными значениями. В каждой фазе обучения сети с помощью соответствующих математических функций рассчитываются и изменяются коэффициенты весов с учетом их текущих значений. В результате после обучения система способна эффективно прогнозировать временные зависимости мощности потребления электрической энергии, является важным при разработке системы управления электропотреблением промышленных и бытовых объектов.

Ключевые слова — нейронная сеть; ограниченная машина Больцмана; контрастная дивергенция.

ПЕРЕЛІК ПОСИЛАНЬ

- [1] E. Mocanu, *Machine learning applied to smart grids*. Eindhoven: Technische Universiteit Eindhoven, 2017.
- [2] Geoffrey Hinton and C. Ruslan Salakhutdinov, "Reducing the dimensionality of data with neural networks," *Science (80-.)*, vol. 28, no. 5786, pp. 502–504, 2006.
- [3] "Restricted Boltzmann Machine," 2012. [Online]. Available: https://en.wikipedia.org/wiki/Restricted_Boltzmann_machine.
- [4] A. Oppermann, "Deep Learning meets Physics: Restricted Boltzmann Machines Part 1," *Toward. Data Sci.*, 2018, URL: <https://towardsdatascience.com/deep-learning-meets-physics-restricted-boltzmann-machines-part-i-6df5c4918c15>
- [5] M. G. Simões *et al.*, "A comparison of smart grid technologies and progresses in Europe and the US," *IEEE Trans. Ind. Appl.*, vol. 48, no. 4, pp. 1154–1162, 2012.



Prediction of electrical consumption network based on a neural network

O. S. Zhyvogliad, ORCID [0000-0002-2194-6191](https://orcid.org/0000-0002-2194-6191)

e-mail olegzhivo123@gmail.com

National Technical University of Ukraine

«Igor Sikorsky Kyiv Polytechnic Institute» www.kpi.ua

Department of Industrial Electronics www.kaf-pe.kpi.ua

Kyiv, Ukraine

Abstract — in this article is considered a problem of predicting discrete values of power consumption of electric energy. Since the volume of the consumption charts database must be sufficiently large to allow prediction to be reliable, it is advisable to apply modern mathematical approaches to processing these graphs, in particular, artificial neural networks. So it is solved by using one of the methods of artificial neural networks - the restricted Boltzmann machine. Restricted Boltzmann machine is a stochastic artificial neural network, the training of which is carried out "without a teacher" according to the algorithm of the reverse error propagation. Compared to other structures of neural networks, a restricted Boltzmann machine enables more efficient training algorithms than is possible for a general class of neural networks, in particular, the "contrast divergence" algorithm. This algorithm performs Gibbs sampling, which is used in the gradient descent procedure to calculate the refined weighting coefficients. In this method forecasting is carried out by adjusting the weight functions of the layers of the neural network in such a way so if optimized weighting is used, we minimize the Kulbock-Leibler distance between the distribution of input data and model approximation. In each phase of network training, weighting coefficients are calculated and modified based on their current mathematical values using the appropriate mathematical functions such as, one step of the Gibbs sample (updating the weights of all hidden and visible neurons). Accordingly, the weighed sum of the values of the output signals of the neurons, which goes on to the activation block, also changes. Depending on the function embedded in the activation block, an output signal is generated. Consequently, the result of each phase of the training is the change in the weighting factors and parameters of the activation function. As a result, after training, the system is able to effectively predict the time dependencies of the power consumption of electrical energy, which is important when developing a power management system for industrial and household objects. After studying such a system on the current database of graphs of daily electricity consumption, it will be able to make predictions within the specified error. Application of the proposed approach is effective in developing a system for managing the consumption of both large and small industrial and domestic objects, in particular Micro Grid.

Keywords — neural network; restricted Boltzmann machine; contrast divergence.

