

УДК 004.021::519.872.7

¹О.А. Дмитрієва, д-р техн. наук, проф.,²Т.В. Алтухова, асистент,³Є.О. Бабенко, магістрант

Донецький національний технічний університет, м. Покровськ, Україна

¹olga.dmytriyeva@donntu.edu.ua²tetiana.altukhova@donntu.edu.ua³yevheniia.babenko.nniknt@donntu.edu.ua

Розробка комп’ютерної моделі системи діагностики технічного стану електрообладнання на основі кластерного аналізу

В роботі розглянуто можливість використання алгоритмів кластерного аналізу при виконанні діагностики технічного стану електрообладнання на прикладі електродвигунів. Розроблено комп’ютерну модель діагностики, засновану на використанні нейронної мережі Кохонена, нейронної мережі адаптивного резонансу та екстремального машинного навчання з урахуванням основних енергомеханічних параметрів. Дано модель дозволяє виконувати діагностику, виходячи з рівня близькості того чи іншого показника до граничних значень, що характеризують класи можливих станів електродвигунів, серед яких виділяється клас нормальної експлуатації, поточного ремонту, капітального ремонту та повної заміни. Проведений аналіз результатів дослідження дозволив визначити технічний стан електрообладнання при всіх використаних в процесі моделювання алгоритмах. Отримані результати показали, що досліджувані типи електродвигунів ефективно діагностуються за умови безперервного контролю енергомеханічних параметрів, абсолютна середня величина відхилення від емпіричних значень залишалася на рівні 6,5%, проте у випадку максимальної величини відхилення, яка становить понад 10% при діагностиці, існує можливий вплив на якість ремонту і експлуатацію обладнання в подальшому, тому при моделюванні додатково враховувалися крім енергомеханічних параметрів, також несприятливі умови експлуатації на промислових підприємствах і конструктивні особливості. Програмна реалізація комп’ютерної моделі системи діагностики може бути використана для проведення безперебійного контролю електромеханічного обладнання в режимі реального часу з можливістю визначення його залишкового ресурсу на 20-30% ефективніше за існуючі аналоги, що, в свою чергу, дозволить усунути недоліки існуючої системи планово-попереджувальних ремонтів і уникнути значних матеріальних, часових, енергетичних та економічних втрат на підприємствах.

Ключові слова: комп’ютерна модель, діагностика технічного стану, електрообладнання, кластерний аналіз, нейронна мережа Кохонена, нейронна мережа адаптивного резонансу, екстремальне машинне навчання

DOI: 10.31474/1996-1588-2021-1-32-24-31

Вступ

На даний час з розвитком інформаційних технологій актуальним питанням стає їх використання в різних сферах науки і техніки, зокрема і в технічній діагностиці електрообладнання. Через те, що проведення діагностики є дуже складним процесом, використання інтелектуальних методів є перспективним. Такі методи передбачають створення математичних моделей задля розуміння поведінки тієї чи іншої системи з урахуванням виявлення її несправностей та дефектів. Тому математичне моделювання важких процесів діагностики стану є потужним інструментом при розв'язанні інженерних задач в діагностиці технічного стану будь-якої системи, що дозволяє виявляти на ранній стадії дефекти та підвищити

надійність та ефективність роботи самого обладнання.

Найбільш розповсюдженім є кластерний аналіз, який дозволяє поєднати в собі механізм виявлення збоїв роботи ЕМО та методи їх визначення та передбачає застосування теорії обробки сигналу і розпізнавання образів. Його алгоритми використовують для перевірки якості [1], автоматичному контролі [2], в медицині [3], екології [4], в області хвильової енергії [5], фінансового ринку [6] та порушення якості електроенергії [7-8], а також у відомих наукових працях зосереджується увага на вилученні ознак дефектів обладнання [9] або на методах прогнозування механізмів обертання [10], проте в галузі діагностики технічного стану при безперебійному контролі енергомеханічних параметрів електрообладнання мають досить

обмежену сферу. При виконанні аналізу алгоритмів кластерного аналізу було виявлено, що не всі вони можуть використовуватися в технічній діагностиці, однак найбільш ефективними в нашому випадку можна вважати нейронні мережі Кохонена, нейронні мережі адаптивного резонансу та екстремальне машинне навчання [11-17], що дозволяють розпізнавати технічний стан електрообладнання більш ефективно.

Таким чином, метою роботи є розробка і обґрунтування комп’ютерної моделі системи діагностики з використанням алгоритмів кластерного аналізу, яку орієнтовано на діагностику та контроль технічного стану електрообладнання для підвищення його надійності та ефективності функціонування, передбачення незапланованих ремонтів і аварійних ситуацій.

Завдання дослідження полягають у підвищенні надійності та ефективності експлуатації електромеханічного обладнання за рахунок об’єднання трьох алгоритмів кластерного аналізу (нейронні мережі Кохонена, нейронні мережі адаптивного резонансу та екстремальне машинне навчання) за умови безперебійного контролю енергомеханічних параметрів.

Обґрунтування реалізації алгоритмів кластерного аналізу при побудові моделі діагностики

Основна ідея, на якій базується побудова моделі системи діагностики технічного стану електрообладнання, полягає у об’єднанні трьох алгоритмів кластерного аналізу, які дозволяють надійно визначати технічний стан електрообладнання.

При реалізації алгоритму нейронної мережі Кохонена необхідне забезпечення наступних етапів навчання [18]:

1) формування структури мережі з визначенням множини шарів і загальної кількості нейронів у шарі,

2) випадкова ініціалізація вагових коефіцієнтів за умови відповідних обмежень, а саме нормалізація вхідних змінних $w_{ij}^{(0)}$:

$$0.5 - \frac{1}{\sqrt{X}} \leq w_{ij}^{(0)} \leq 0.5 + \frac{1}{\sqrt{X}}, \quad (1)$$

де X - кількість вхідних змінних мережі, тобто множина характеристичних ознак об’єкта дослідження відповідно до технічного стану;

3) подання на входи мережі випадкового навчального прикладу поточного навчання і розрахунок евклідових відстаней від вхідного вектору до центрів всіх кластерів:

$$R_j = \sqrt{\sum_{i=1}^X (\tilde{x}_i - w_{ij}^{(q)})^2}, \quad (2)$$

де \tilde{x}_i - нормалізоване значення вхідної змінної з номером i ;

4) за найменшим зі значень R_j вибирається нейрон-переможець J , у найбільшій мірі близький за значеннями з вхідним вектором, для якого виконується корекція вагових коефіцієнтів:

$$w_{ij}^{(q+1)} = w_{ij}^{(q)} + v \cdot (\tilde{x}_i - w_{ij}^{(q)}), \quad (3)$$

де v - коефіцієнт швидкості навчання,

$w_{ij}^{(q)}, w_{ij}^{(q+1)}$ – поточне і нове значення вагових коефіцієнтів;

5) повторення циклу з 3-го кроку до виконання одного або декількох умов закінчення: по-перше, вичерпання заданої граничної кількості ітерацій навчання; по-друге, не відбувається значної зміни вагових коефіцієнтів в межах заданої точності протягом останньої доби навчання; по-третє, вичерпання заданого граничного фізичного часу навчання.

Реалізація нейронної мережі адаптивного резонансу передбачає стадію ініціалізації та порівняння образів [19]:

1) стадія ініціалізації містить такі етапи:

- встановлюється параметр подібності R_{kp} . Чим вище його значення, тим більше має бути свідченням схожість способу з центром кластера для віднесення до останнього;

- для наявної вибірки даних виконується нормалізація значень змінних в межах $[0, 1]$;

- проводиться нормування елементів кожного вхідного вектору таким чином, щоб сума квадратів цих елементів дорівнювала 1:

$$\hat{x}_i = \frac{\tilde{x}_i}{\sqrt{\sum_{p=1}^X x_p^2}}; \quad (4)$$

- створюється перший і поки єдиний нейрон (кластер) з ваговими коефіцієнтами, чисельне рівними нормованим вхідним значенням першого прикладу (образи):

$$w_{i1} = \hat{x}_i. \quad (5)$$

2) стадія порівняння образів передбачає:

- на вході моделі нейронної мережі подається черговий образ і визначається кількісна міра його подібності з кожним з наявних кластерів:

$$R_j = \sum_{i=1}^X w_{ij} \hat{x}_i; \quad (6)$$

- обирається кластер з номером J з максимальним значенням міри подібності:

$$R_j = \max_{j=1,n} (R_j); \quad (7)$$

- якщо умова $R_j < R_{kp}$ виконується, вважається, що подібність вхідного образу ні з

одним із кластерів не встановлено, тоді створюється новий нейрон з ваговими коефіцієнтами, рівними елементам відповідного нормованого вектору x_i ;

- якщо умова $R_j \geq R_{kp}$ не виконується, вважається, що встановлено найбільшу подібність вхідного образу з кластером J – вагові коефіцієнти відповідного нейрона перераховуються за співвідношенням:

$$w_{ij}^{(q+1)} = (1 - \nu) \cdot w_{ij}^{(q)} + \nu \cdot \hat{x}_i. \quad (8)$$

Потім вже алгоритм продовжує свою роботу саме на стадії порівняння з першого пункту.

Реалізація ж алгоритму екстремального машинного навчання передбачає використання математичної моделі SLFN [20]:

$$t_{k,s} = \sum_{i=1}^L \beta_{s,i} \cdot G(w_{i0} \cdot x_k + b_{i0}), \quad (9)$$

де $t_{k,s}$ – s-я компонента цільового вектора t_k , відповідного вектору ознак x_k ;

$w_{i0} \in \mathbb{R}^n$ - ваги (weights) i-го нейрона на прихованому шарі;

$b_{i0} \in \mathbb{R}$ - зміщення (bias) i-го нейрона на прихованому шарі;

$\beta_s \in \mathbb{R}^L$ - ваги s-го нейрона на вихідному шарі.

Сутність виконання навчання алгоритму ELM полягає в знаходженні ваг і зміщень для нейронів на прихованому і вихідному шарі.

Матриця ваг вихідного шару β обчислюється як

$$\beta = H^\dagger T \quad (10)$$

де H^\dagger - псевдообернення Мура-Пенроуза матриці H .

$$H^+ = \begin{pmatrix} G(w_{10}x_1+b_{10}) & \dots & G(w_{i0}x_1+b_{i0}) \\ \vdots & & \vdots \\ G(w_{10}x_k+b_{10}) & \dots & G(w_{i0}x_k+b_{i0}) \end{pmatrix} \quad (11)$$

$$\beta = (\beta_1 \ \vdots \ \beta_k)^T, T = \begin{pmatrix} t_1 \\ \vdots \\ t_k \end{pmatrix} \quad (12)$$

Тоді, алгоритм навчання ELM передбачає наступні три етапи:

1) ініціалізація випадковими значеннями w_i і b_i ;

2) побудова матриці (11);

3) визначення ваг на вихідному шарі (10).

Таким чином, розробка моделі буде ґрунтуватися саме на таких стадіях навчання запропонованих алгоритмів кластерного аналізу задля більш ефективного аналізу технічного стану обладнання.

Комп’ютерна модель системи діагностики електрообладнання

Основним чинником при побудові будь-якої моделі діагностики електромеханічного обладнання є визначення параметрів, що впливають на технічний стан, тому здійснено вибір їх множини, яка ґрунтується на таких енергомеханічних параметрах, як навантаження – P, kW ; напруга – U, kB ; струм – I, A ; опір – $R, M\Omega$; температура – $t, {}^\circ C$; швидкість обертання – $n, ob./хв$. Множина цих параметрів прийматиме наступний вигляд:

$$C = \begin{bmatrix} P \\ U \\ I \\ R \\ t \\ n \end{bmatrix} \quad (13)$$

У відповідності до (13) виконано позначення показників режимів стану електродвигунів наступним чином: «0» – нормальні показники параметрів, «+» – підвищенні показники параметрів, «-» – зниження показників параметрів, «Δ» – відсутність характеристичних показань параметрів.

На рисунку 1 представлено дерево відмов електрообладнання на прикладі електродвигунів, за яким виконується класифікація отриманих режимів відносно чотирьох технічних станів, а саме нормальні експлуатація, поточний ремонт, капітальний ремонт і побудова з паді.

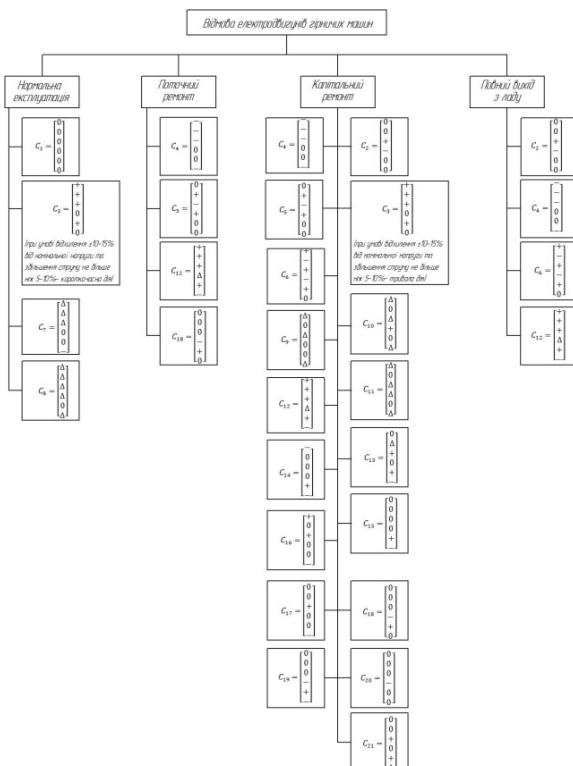


Рисунок 1 – Древо відмов електрообладнання на прикладі електродвигунів

Надалі з урахуванням дерева відмов (рис.1) розробка моделі діагностики технічного стану електромеханічного обладнання виконувалася за допомогою MVP-патерну (рис. 2). У відповідності до рисунку 2 модель складається з п'ятнадцяти класів і має два види взаємозв'язку між ними, а саме асоціація, що базується на об'єднанні класів моделей та класів видів у представниках, і наслідування.

В даному випадку MVP-патерн забезпечує зберігання отриманих результатів кластерного аналізу технічного стану електромеханічного обладнання за умови створення файлів з даними із початковим ім'ям та назвою, що характеризують тип проведення аналізу, а також таблиць отриманих результатів. Причому всі новоутворені файли будуть зберігатися у місці розташування програми у форматі «parquet» та матимуть доступ тільки для неї. Враховується також, що отримані результати дослідження даних можуть зберігатися окремо за умови можливості здійснення кожного типу кластерного аналізу самостійно згідно відповідних проміжків часу між ними.

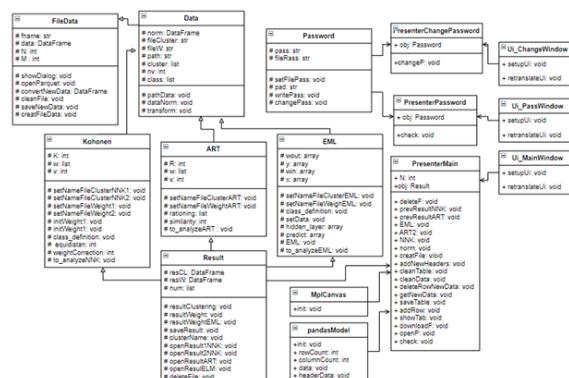


Рисунок 2 – UML діаграма класів в розробленій моделі

На основі UML діаграми класів виконано розробку програмного інтерфейсу запропонованої моделі кластерного аналізу даних для діагностики технічного стану шахтних електродвигунів, загальний вигляд якого представлений на рис. 3.

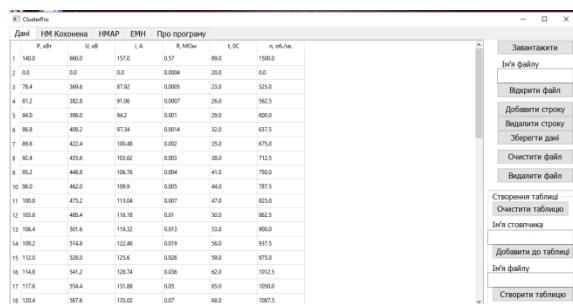


Рисунок 3 – Зовнішній вигляд програмного інтерфейсу запропонованої моделі кластерного аналізу

Даний інтерфейс містить діалогове вікно відкриття файлів; вікно роботи з даними («Дані»); вкладки реалізації алгоритмів кластерного аналізу («НМ Кохонена», «НМАР», «ЕМН») та правила користування програмою («Про програму»). Така програмна реалізація дозволяє здійснювати аналіз за допомогою всіх трьох алгоритмів як разом, так і окремо, отримаючи в результаті залишковий ресурс роботи обладнання та його поточний технічний стан.

Дослідження розробленої моделі кластерного аналізу даних

Дослідження програмної реалізації моделі кластерного аналізу виконувалося на прикладі електродвигунів 7 типів (ЕКВ4-140 – 35 шт., ЕКВ4-160-2 – 23 шт., ЕДКОФВ-51/4 – 38 шт., ЕДКОФВ-315М4 – 26 шт., ВАО62-4-У5 – 28 шт., ВАО2-280S44 – 31 шт., 2ВР250S4 – 19 шт.), емпіричні значення яких представлені на рисунку 4, а отримані результати її реалізації представлені на рис. 5-7.

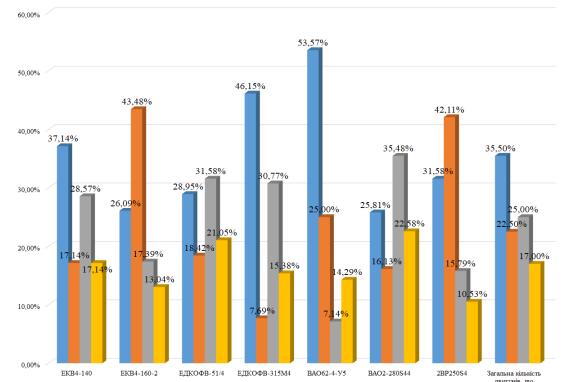


Рисунок 4 – Емпіричні значення станів об'єктів контролю

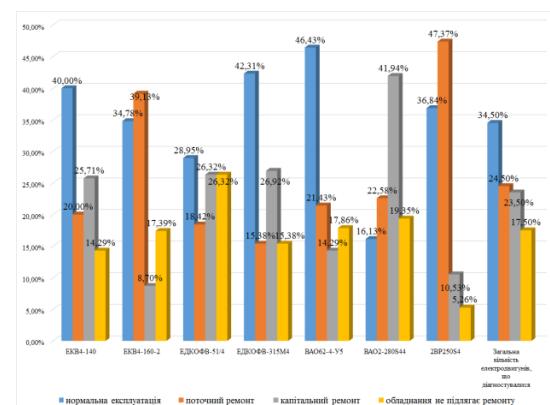


Рисунок 5 – Результати процесу діагностики електродвигунів: кластерний аналіз на основі мережі Кохонена

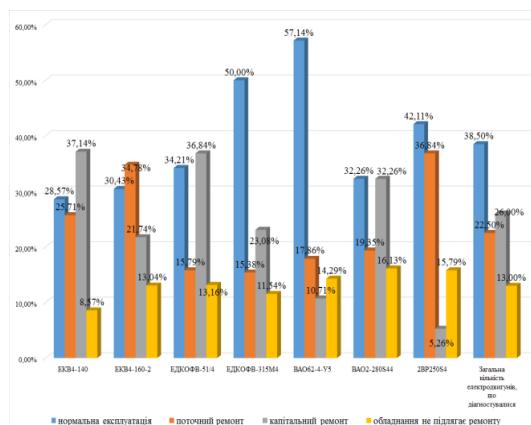


Рисунок 6 – Результати процесу діагностики електродвигунів: кластерний аналіз на основі адаптивного резонансу

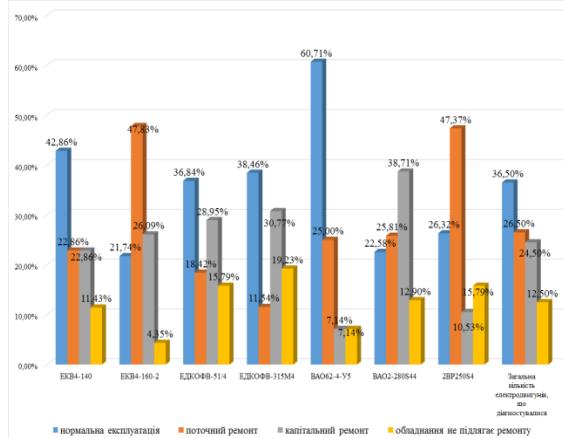


Рисунок 7 – Результати процесу діагностики електродвигунів: кластерний аналіз на основі екстремального машинного навчання

Отримані результати виконання діагностики були порівняні з еталонними значеннями (рис. 4) та виконано визначення їх розходжень (рис. 8-10).

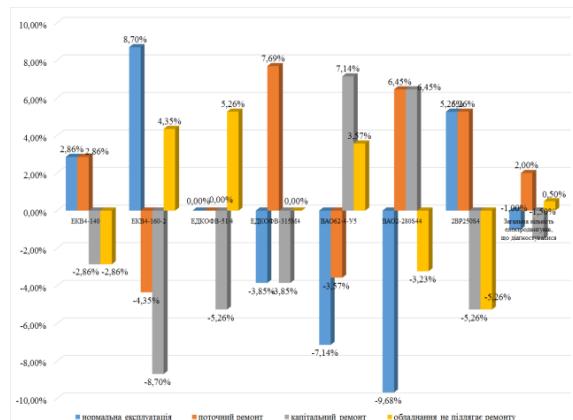


Рисунок 8 – Відхилення отриманих результатів кластерного аналізу на основі мережі Кохонена від емпіричних значень

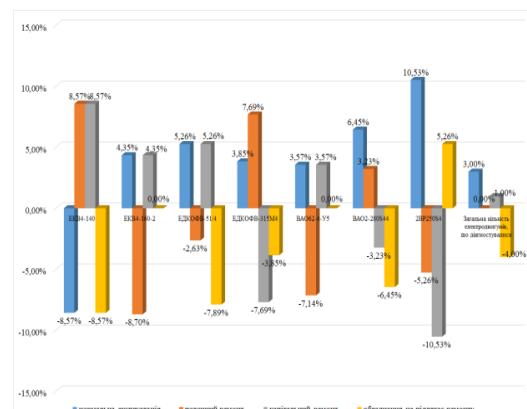


Рисунок 9 – Відхилення отриманих результатів кластерного аналізу на основі адаптивного резонансу

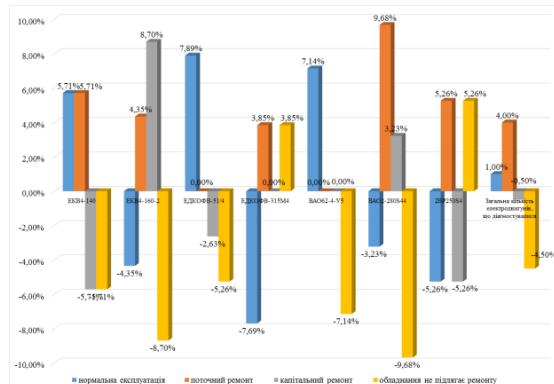


Рисунок 10 – Відхилення отриманих результатів кластерного аналізу від емпіричних значень на основі екстремального машинного навчання

Висновки

В результаті проведеного дослідження виконано розробку комп’ютерної моделі системи діагностики технічного стану електрообладнання із застосуванням алгоритмів кластерного аналізу (нейронні мережі Кохонена, нейронні мережі адаптивного резонансу та екстремального машинного навчання).

З реалізації даної моделі видно, що отримані результати дозволяють ефективно визначати технічний стан електрообладнання за умови використання запропонованих алгоритмів при здійсненні безперервного контролю енергомеханічних параметрів, так як показала досить надійні результати діагностики технічного стану електродвигунів в порівнянні з емпіричними даними в межах 10%, при цьому визначено, що абсолютна середня відхилення складали не більш 6,5%.

Отримана модель дозволяє виконувати прогнозування залишкового ресурсу електрообладнання на 20-30% ефективніше за існуючі аналоги.

Наукова новизна полягає у розробці комп’ютерної моделі системи діагностики технічного стану електрообладнання із застосуванням алгоритмів кластерного аналізу, спрямованих на підвищення надійності його експлуатації за рахунок безперервного контролю енергомеханічних показників.

Практична значимість полягає в уdosконаленні існуючої системи планово-попереджувальних ремонтів при формуванні графіків ремонтів для забезпечення ефективної

організації технічного обслуговування за фактичним станом з можливістю прогнозування залишкового ресурсу електрообладнання та надійну і ефективну роботу обладнання на підприємствах. Створено комп’ютерну модель системи діагностики електрообладнання та отримано її програмну реалізацію для розв’язання складної задачі визначення технічного стану на основі кластерного аналізу.

Список літератури

1. V. Piuri, F. Scotti, M. Roveri. Computational Intelligence in Industrial Quality Control. Proceedings of the IEEE 2005 International Workshop on Intelligent Signal Processing, Faro, Portugal, September 1–3, 2005. P. 4–9.
2. X. Y. Wang, Y. M. Ding. Adaptive Real-time Predictive Compensation Control for 6-DOF Serial Arc Welding Manipulator. Chinese Journal of Mechanical Engineering, 2010, 23(3): P. 361–366.
3. Q. K. Al-Shayea. Artificial neural networks in medical diagnosis. International Journal of Computer Science Issues, 2011, 8(2): P. 150–154.
4. R. D. Labati, A. Genovese, E. Mun~oz, et al. Computational intelligence for industrial and environmental applications. Proceedings of the IEEE 8th International Conference on Intelligent Systems, Sofia, Bulgaria, September 4–6, 2016. P 8–14.
5. L. Cuadra, S. Salcedo-Sanz, J. C. Nieto-Borge, et al. Computational intelligence in wave energy: Comprehensive review and case study. Renewable and Sustainable Energy Reviews, 2016, 58. P 1223–1246.
6. R. C. Cavalcante, R. C. Brasileiro, V. L. F. Souza, et al. Computational Intelligence and Financial Markets: A Survey and Future Directions. Expert Systems with Applications, 2016, 55. P. 194–211.
7. O. P. Mahela, A. G. Shaik, N. Gupta. A critical review of detection and classification of power quality events. Renewable and Sustainable Energy Reviews, 2015, 41: 495–505.
8. S. Khokhar, A. A. B. Mohd Zin, A. S. B. Mokhtar, et al. A comprehensive overview on signal processing and artificial intelligence techniques applications in classification of power quality disturbances. Renewable and Sustainable Energy Reviews, 2015, 51. P. 1650–1663.
9. P. Henriquez, J. B. Alonso, M. A. Ferrer, et al. Review of Automatic Fault Diagnosis Systems Using Audio and Vibration Signals. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2014, 44(5): P.642–652.
10. M. S. Kan, A. C. C. Tan, J. Mathew. A review on prognostic techniques for non-stationary and non-linear rotating systems. Mechanical Systems and Signal Processing, 2015, 62–63: P. 1–20.
11. Шолле Франсуа, Глубокое обучение на Python. Серия «Библиотека программиста» СПб.: Питер, 2018. 400 с.
12. Гудфеллоу Я., Бенджио И., Курвиль А. Глубокое обучение / пер. с англ. А. А. Слинкина. 2-е изд., испр. Москва: ДМК Пресс, 2018. 652 с.
13. Шпаргалка по разновидностям нейронных сетей. Часть первая. Элементарные конфигурации: веб-сайт. URL: <https://tproger.ru/translations/neural-network-zoo-1/>
14. A Novel CNN-Based Framework for Classification of Signal Quality and Sleep Position from a Capacitive ECG Measurement / Koshiro Kido, Toshiyo Tamura, Naoaki Ono, Masaki Sekine , Shigehiko Kanaya: Sensors 2019, 19(7), 1731. URL:<https://doi.org/10.3390/s19071731>
15. Chih-Chung Hsu, Chia-Wen Lin. CNN-Based Joint Clustering and Representation Learning with Feature Drift Compensation for Large-Scale Image Data. IEEE Transactions on Multimedia, 2017.
16. Zhi-Xin Yang, Xian-Bo Wang, Jian-Hua Zhong. Representational Learning for Fault Diagnosis of Wind Turbine Equipment: A Multi-Layered Extreme Learning Machines Approach. Energies. 2016, 9(6), P. 379. URL: <https://doi.org/10.3390/en9060379>
17. Yu Wei1, Minqiang Xu, Yongbo Li, Wenhua Huang. Gearbox fault diagnosis based on local mean decomposition, permutation entropy and extreme learning machine. Journal of Vibroengineering. 2016, vol. 18, issue 3, P. 1459–1473. URL:<https://doi.org/10.21595/jve.2016.16567>
18. Дударов С. П. Модели самоорганізовуючихся штучних нейронних мереж для ідентифікації стационарних промислових джерел забруднення повітря. Математичне моделювання, Т.29, №1, 2017 г. С. 33–44
19. Нейронні мережі адаптивного резонанса: веб-сайт. URL: <https://neuronus.com/theory/nn/956-nejronnye-seti-adaptivnogo-rezonansa.html>

20. Horata P, Chiewchanwattana S, Sunat K. Robust extreme learning machine. *Neurocomputing*, V.102, 15 February 2013, P. 31–44

References

1. Piuri, V., Scotti, F., Roveri, M. (2005), “Computational Intelligence in Industrial Quality Control”, *Proceedings of the IEEE 2005 International Workshop on Intelligent Signal Processing*, Faro, Portugal, P. 4–9.
2. Wang, X. Y., Ding, Y. M. (2010), “Adaptive Real-time Predictive Compensation Control for 6-DOF Serial Arc Welding Manipulator”, *Chinese Journal of Mechanical Engineering*, 23(3), P. 361–366.
3. Al-Shayea, Q. K. (2011), “Artificial neural networks in medical diagnosis”, *International Journal of Computer Science Issues*, 8(2), P. 150–154.
4. Labati, R. D., Genovese, A., Munoz, E., et al (2016), “Computational intelligence for industrial and environmental applications”, *Proceedings of the IEEE 8th International Conference on Intelligent Systems*, Sofia, Bulgaria, P. 8–14.
5. Cuadra, L., Salcedo-Sanz, S., Nieto-Borge, J. C., et al (2016), “Computational intelligence in wave energy: Comprehensive review and case study”, *Renewable and Sustainable Energy Reviews*, 58, P. 1223–1246.
6. Cavalcante, R. C., Brasileiro, R. C., Souza, V. L. F., et al (2016), “Computational Intelligence and Financial Markets: A Survey and Future Directions”, *Expert Systems with Applications*, 55, P. 194–211.
7. Mahela, O. P., Shaik, A. G., Gupta, N. (2015), “A critical review of detection and classification of power quality events”, *Renewable and Sustainable Energy Reviews*, 41, P. 495–505.
8. Khokhar, S., Mohd Zin, A. A. B., Mokhtar, A. S. B., et al (2015), “A comprehensive overview on signal processing and artificial intelligence techniques applications in classification of power quality disturbances”, *Renewable and Sustainable Energy Reviews*, 51, P. 1650–1663.
9. Henriquez, P., Alonso, J. B., Ferrer, M. A., et al (2014), “Review of Automatic Fault Diagnosis Systems Using Audio and Vibration Signals”, *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 44(5), P. 642–652.
10. Kan, M. S., Tan, A. C. C., Mathew, J. (2015), “A review on prognostic techniques for non-stationary and non-linear rotating systems”, *Mechanical Systems and Signal Processing*, 62–63, P. 1–20.
11. Chollet François (2018), “Deep Learning in Python”, Peter, 400 p.
12. Goodfellow, J., Benjio, I., Courville, A. (2018), “Deep learning”, DMK Press, Moscow, 652 p.
13. “Cheat sheet on the types of neural networks. Part one. Elementary configurations.”, available at: <https://tproger.ru/translations/neural-network-zoo-1/>
14. Koshiro Kido, Toshiyo Tamura, Naoaki Ono, Masaki Sekine , Shigehiko Kanaya (2019), “A Novel CNN-Based Framework for Classification of Signal Quality and Sleep Position from a Capacitive ECG Measurement” [Sensors], 19(7), P. 1731. available at:<https://doi.org/10.3390/s19071731>
15. Chih-Chung Hsu, Chia-Wen Lin (2017), “CNN-Based Joint Clustering and Representation Learning with Feature Drift Compensation for Large-Scale Image Data”, *IEEE Transactions on Multimedia*.
16. Zhi-Xin Yang, Xian-Bo Wang, Jian-Hua Zhong (2016), “Representational Learning for Fault Diagnosis of Wind Turbine Equipment: A Multi-Layered Extreme Learning Machines Approach”, *Energies*, 9(6), P. 379. available at: <https://doi.org/10.3390/en9060379>
17. Yu Wei1, Minqiang Xu, Yongbo Li, Wenhua Huang (2016), “Gearbox fault diagnosis based on local mean decomposition, permutation entropy and extreme learning machine”, *Journal of Vibroengineering*, vol. 18, issue 3, P.1459-1473. available at: <https://doi.org/10.21595/jve.2016.16567>
18. Dudarov S. (2017), “Models of self-organizing artificial neural networks for identification of stationary industrial sources of air pollution” [Моделі самоорганізації штучних нейронних мереж для ідентифікації промислових джерел забруднення повітря], *Matem. Modeling*, vol.29, No 1, P. 33–44
19. “Neural networks of adaptive resonance”, available at: <https://neuronus.com/theory/nn/956-nejronnye-seti-adaptivnogo-rezonansa.html>
20. Horata P, Chiewchanwattana S, Sunat K. (2013), “Robust extreme learning machine”, *Neurocomputing*, Volume 102, P. 31–44

Надійшла до редакції 11.03.2021

¹O. DMITRIEVA, ²T. ALTUKHOVA, ³E. BABENKO

Donetsk National Technical University, Pokrovsk, Ukraine

¹olga.dmytriyeva@donntu.edu.ua

²tetiana.altukhova@donntu.edu.ua

³yevheniia.babenko.nniknt@donntu.edu.ua

DEVELOPMENT OF A COMPUTER MODEL OF THE SYSTEM FOR DIAGNOSING THE TECHNICAL CONDITION OF ELECTRICAL EQUIPMENT BASED ON CLUSTER ANALYSIS

The paper considers the possibility of using cluster analysis algorithms when performing diagnostics of the technical condition of electrical equipment on the example of electric motors. A computer model of diagnostics based on the use of the Kohonen neural network, adaptive resonance neural network and extreme machine learning, taking into account the basic energy-mechanical parameters, has been developed. This model allows you to perform diagnostics based on the level of proximity of an indicator to the limit values that characterize the classes of possible states of electric motors, among which were the classes of normal operation, maintenance, overhaul and complete replacement. The analysis of the research results allowed to determine the technical condition of electrical equipment with all the algorithms used in the modeling process. The obtained results showed that the studied types of electric motors are effectively diagnosed under the condition of continuous control of energy-mechanical parameters, the absolute average deviation from empirical values remained at 6.5%, but in case of maximum deviation of more than 10% at diagnosis, there is a possible effect. on the quality of repair and operation of equipment in the future, so the modeling was additionally taken into account in addition to energy-mechanical parameters, as well as adverse operating conditions at industrial enterprises and design features. Software implementation of a computer model of the diagnostic system can be used for uninterrupted monitoring of electromechanical equipment in real time with the ability to determine its residual life 20-30% more efficiently than existing counterparts, which, in turn, will eliminate the shortcomings of the existing system. preventive repairs and avoid significant material, time, energy and economic losses in enterprises.

Keywords: *computer model, diagnostics of the technical condition of materials, cluster analysis, Kohonen neural network, adaptive resonance neural network, extreme machine learning*