

# Метод и алгоритм обогащения высокочастотных многомерных сигналов на примере диагностирования технического состояния центробежного насоса и подшипников качения

Ш. Ш. Кодиров

Южно-Уральский государственный университет  
(национальный исследовательский университет)

shahboztjk@mail.ru

А. Л. Шестаков

Южно-Уральский государственный университет  
(национальный исследовательский университет)

shestakoval@susu.ru

**Аннотация.** Данная статья посвящена методам и алгоритмам обогащения высокочастотных многомерных сигналов, которые являются ключевым аспектом анализа данных в области диагностики технического состояния оборудования, где требуется высокая чувствительность к изменениям в сигналах. Высокочастотные сигналы характеризуются быстрыми изменениями во времени и могут содержать большое количество информации, требующей специальных методов обработки для извлечения значимых паттернов. В статье рассматриваются различные подходы к обогащению высокочастотных многомерных сигналов, используемые в современных методах диагностирования технического состояния вращающихся механизмов на базе алгоритмов машинного обучения и глубоких нейронных сетей. В частности, диагностирования технического состояния центробежных насосов и подшипников качения. В данной работе предлагается новый метод и алгоритм обогащения высокочастотных многомерных сигналов на примере диагностирования технического состояния центробежного насоса и подшипников качения с применением алгоритмов машинного обучения. Предлагаемый метод и алгоритм имеют широкий спектр применений, начиная от обработки сигналов в реальном времени до анализа временных рядов высокой частоты. Развитие новых подходов к обогащению высокочастотных многомерных сигналов представляет собой актуальную задачу, которая открывает новые перспективы для исследований в области анализа данных и принятия решений на основе высокочастотных данных.

**Ключевые слова:** обогащения высокочастотных многомерных сигналов; конструирование новых элементов данных; алгоритмы машинного обучения; обнаружение неисправности насоса; обнаружение дефектов подшипника качения

## I. ВВЕДЕНИЕ

В современном мире данные играют ключевую роль в принятии решений, научных исследованиях и развитии бизнеса. Однако часто данные, с которыми приходится работать, могут быть неполными, некачественными и недостаточно структурированными. В таких случаях

методы обогащения данных могут стать незаменимым инструментом для улучшения качества данных и достижения лучших результатов. Обогащение данных (от англ. *Data enrichment*) – это процесс дополнения сырых данных той информацией, которая в исходном виде в них отсутствует, но необходима для качественного анализа. Иными словами это процесс улучшения и дополнения существующих данных путем добавления новой информации или уточнения уже имеющейся.

Использование обогащения данных в области вибродиагностики роторных машин и механизмов, в частности диагностирования технического состояния подшипников качения и центробежных насосов позволяет увеличить точность прогнозов и улучшить качество диагностики. Особенно когда в качестве диагностического признака используются высокочастотные сигналы вибрации, которые быстрыми изменениями во времени могут содержать большое количество полезной информации.

В современных методах и алгоритмах диагностирования технического состояния подшипников качения и центробежных насосов успешно применяются методы обогащения данных [1–34]. В частности, быстрое преобразование Фурье, непрерывное Вейвлет-преобразование, метод эмпирических мод, метод многомерного эмпирического модального разложения и т. п. Объединение этих данных образуют двумерные частотно-временные и амплитудно-частотные изображения, называемые спектрограммы, скалограммы, куртограммы и т. п. Соответственно, с применением таких типов данных создаются модели-классификаторы на базе сверточных нейронных сетей. Однако такой подход весьма трудозатратный и требует больших вычислительных мощностей. Кроме того, модели диагностирования на основе сверточных нейронных сетей имеют низкую производительность за единицу времени, по сравнению с моделями на основе классических алгоритмов машинного обучения. Были попытки по применению такого метода обогащения данных как конструирование новых признаков из статистических характеристик сырых сигналов методом скользящего или непересекающегося окна. Однако, эти попытки не увенчались успехом, так как получаемые

Работа выполнена при финансовой поддержке Российской Федерации в лице Министерства науки и высшего образования Российской Федерации, номер проекта (номер соглашения) № 075-15-2022-1243.

таким способом признаки либо нечувствительны к слабым зарождающимся неисправностям, либо непригодны для отслеживания серьезных неисправностей диагностируемого подшипника или насоса, что снижает точность диагностирования [2-9]. Следовательно, необходимо разработать метод и алгоритм обогащения высокочастотных сигналов для моделей диагностирования технического состояния подшипников качения и центробежных насосов на основе алгоритмов машинного обучения.

## II. МЕТОД ОБОГАЩЕНИЯ СИГНАЛОВ

Как известно, статистические признаки конструируют из сырых сигналов методом скользящего или непересекающегося окна. Однако, в этих методах необходимо указать ширину окна –  $k$ . Традиционно, значение  $k$  задается интуитивно либо, выбирается по усмотрению исследователя, и нет четких критериев для выбора оптимального значения  $k$ . Соответственно, по нашему мнению, по этой причине статистические признаки нечувствительны к слабым зарождающимся дефектам, либо непригодны для отслеживания серьезных неисправностей.

Для решения этой проблемы нами предлагается метод поиска оптимального значения  $k$ , при которой конструированные статистические признаки будут иметь высокую чувствительность к дефектам.

Метод заключается в следующем:

Пусть имеется выборка сигналов в виде массива  $A = [A_1, A_2, \dots, A_N]$  и  $B = [B_1, B_2, \dots, B_N]$ , где  $A_1, B_1$  – первая выборка массива  $A, B$ ;  $A_2, B_2$  – вторая выборка массива  $A, B$ ;  $A_N, B_N$  – последняя выборка массива  $A$  и  $B$ . Частоты дискретизации у сигналов должны быть одинаковы  $f_A = f_B$ .

Тогда методом непересекающегося окна для каждого массива вычислим среднее значение по размеру окна  $k$ , причем процедур будем повторять для последовательных значений  $k$  ( $k=2, 3, 4, \dots, N$ ):

$$A_{mean(k)} = \left[ \frac{1}{k} \sum_{i=1}^k (A_i), \dots, \frac{1}{k} \sum_{i=(n-1) \cdot k + 1}^{n \cdot k} (A_i) \right], \quad (1)$$

$$B_{mean(k)} = \left[ \frac{1}{k} \sum_{i=1}^k (B_i), \dots, \frac{1}{k} \sum_{i=(n-1) \cdot k + 1}^{n \cdot k} (B_i) \right], \quad (2)$$

и рассчитываем коэффициенты корреляции между  $A_{mean(k)}$  и  $B_{mean(k)}$  для ряда последовательных значений  $k$  по формуле (3):

$$F(k) = \frac{\Sigma(A_{mean_i} - \bar{A}) \cdot (B_{mean_i} - \bar{B})}{\sqrt{\Sigma(A_{mean_i} - \bar{A})^2 \cdot \Sigma(B_{mean_i} - \bar{B})^2}} \quad (3)$$

Следовательно, постановка задачи поиска оптимального значения  $k$  будет следующее: необходимо найти такое минимальное значение  $k$ , при котором функция  $F(k)$  по модулю будет иметь максимальное значение:  $|F(k)| \rightarrow \max$ .

Далее, методом непересекающегося окна производится конструирование статистических признаков с оптимальным значением ширины окна –  $k$ . В частности, такие статистические признаки как медиана, мода, сумма, минимальное, максимальное,

среднеквадратическое отклонение, дисперсия и различные квантильные значения выборки сигналов по размеру окна  $k$ . После чего, конструированные признаки объединяются в виде признакового пространства для каждого технического состояния. Следовательно, из совокупности признакового пространства классов технического состояния формируется обучающая выборка. Далее с применением обучающей выборки, на базе алгоритмов машинного обучения разрабатывается модель распознавания или классификатор технического состояния оборудования.

## III. ЭКСПЕРИМЕНТАЛЬНОЕ ИССЛЕДОВАНИЕ НА РЕАЛЬНЫХ ДАННЫХ

### A. Экспериментальный набор данных о различных технических состояниях центробежного насоса

В качестве экспериментального набора данных о различных технических состояниях центробежного насоса, был использован экспериментальный набор данных с работы [12]. Набор данных состоит из сигналов вибрации и акустической эмиссии для 5-ти технических состояний центробежного насоса, в частности: DF (defect free) – исправное состояние насоса; BI (broken impeller) – неисправное состояние насоса с поломкой рабочего колеса насоса; CI (clogged impeller) – неисправное состояние насоса с засоренным рабочим колесом; IR (bearing with inner race defect) – неисправное состояние насоса с дефектом внутреннего кольца подшипника; OR (bearing with outer race defect) – неисправное состояние насоса с дефектом наружного кольца подшипника. План эксперимента, экспериментальный стенд и технические характеристики оборудования подробно рассмотрены в работах авторов [12–15].

### B. Экспериментальный набор данных о различных технических состояниях подшипника качения

Экспериментальный набор данных о различных технических состояниях подшипника качения был получен от авторов работы [25]. Экспериментальные данные содержат три сигнала акселерометра для пяти состояний подшипника. В частности, исправное состояние подшипника (Normal), состояние подшипника с дефектом внутреннего кольца (Inner), состояние подшипника с дефектом шарика (Ball), состояние подшипника с дефектом наружного кольца (Outer), и состояние подшипника с комбинированным дефектом (Comb.). Экспериментальный стенд и план эксперимента более подробно рассмотрен в работе авторов [25].

### C. Обогащения данных

Предлагаемый метод и алгоритм обогащения сигналов был воспроизведен с использованием выше рассмотренных наборов данных. В частности, по выражениям (1) и (2) были рассчитаны средние значения сигналов по размеру окна  $k$ , и по выражению (3) были рассчитаны коэффициенты корреляции для этих сигналов. Результаты вычисления представлены в виде графиков функции корреляции от размера окна  $k$  на рис. 1 (для первого набора) и на рис. 2 (для второго набора). Далее, были найдены оптимальные значения размера окна  $k$  для сигналов этих наборов, после чего из сырых сигналов были конструированы различные

статистические признаки для всех технических состояний.

#### D. Модели обнаружения неисправностей

В качестве метрики оценки качества работы моделей обнаружения неисправностей, были использованы такие метрики как точность – «precision», аккуратность – «accuracy», полнота – «recall» и f-мера «f1 score», которые описываются выражениями (4–7):

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN}, \quad (4)$$

$$precision = \frac{TP}{TP+FP}, \quad (5)$$

$$recall = \frac{TP}{TP+FN}, \quad (6)$$

$$f1\ score = \frac{2 \cdot (precision \cdot recall)}{precision + recall}, \quad (7)$$

где  $TP$  – (true positive) количество верно обнаруженных исправных состояний,  $TN$  – (true negative) количество верно обнаруженных неисправных состояний,  $FP$  – (false positive) количество неверно обнаруженных исправных состояний и  $FN$  – (false negative) количество неверно обнаруженных неисправных состояний.

Модели обнаружения неисправностей были разработаны на различных алгоритмах машинного обучения, среди которых наилучшие результаты работы показали ансамблевые алгоритмы, в частности алгоритм экстремального градиентного бустинга (eXtreme Gradient Boosting Classifier) и алгоритм с экстремально рандомизированными деревьями (Extremely Randomized Trees Classifier).

После того как модели обнаружения неисправностей были обучены, была произведена процедура тестирования обученных моделей. В результате тестирования, были получены итоговые оценки работы моделей, которые представлены в виде матрицы невязок на рис. 3 и 4. Как видно из представленных результатов тестирования, разработанные модели с применением статистических признаков имеют 100 %-ю точность обнаружения неисправностей. Такая высокая точность работы моделей была достигнута благодаря предлагаемому методу и алгоритму обогащения сигналов, позволяющие конструировать статистические признаки, имеющие высокую чувствительность к различным техническим состояниям.




Рис. 1. Графики функции корреляции сигналов различных состояний центробежного насоса в зависимости от размера окна «k»




Рис. 2. Графики функции корреляции сигналов различных состояний подшипника качения в зависимости от размера окна k.

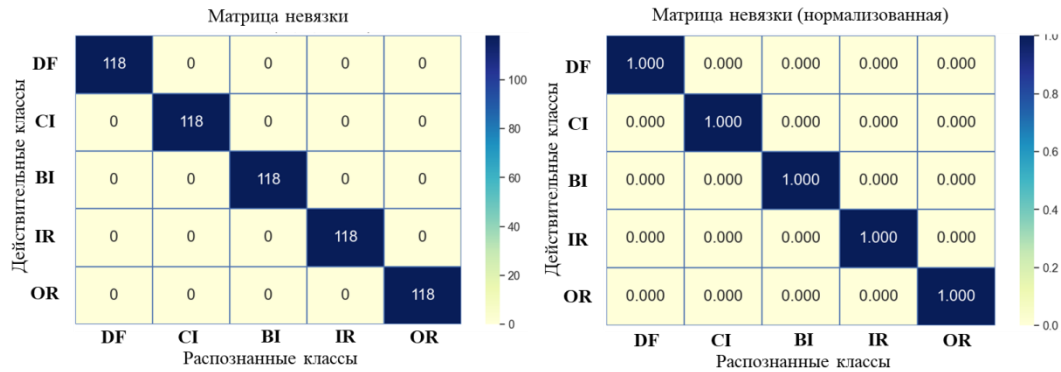


Рис. 3. Результаты тестирования модели обнаружения неисправности центробежного насоса

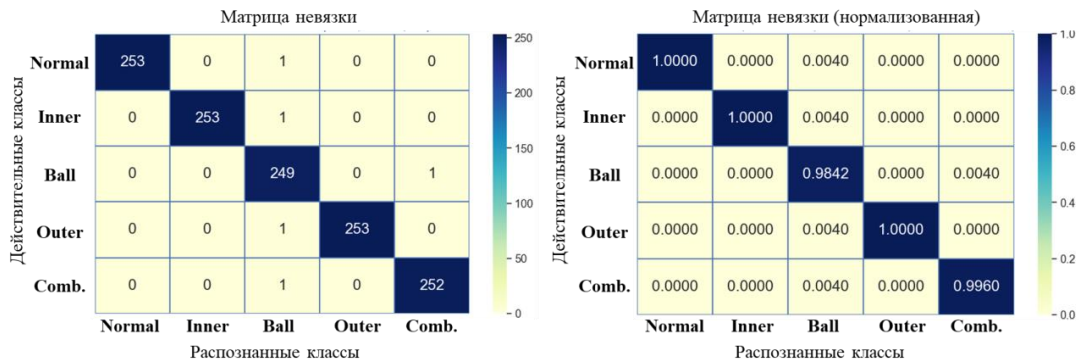


Рис. 4. Результаты тестирования модели обнаружения неисправности подшипника качения

#### IV. ЗАКЛЮЧЕНИЕ

Предлагаемый метод и алгоритм обогащения высокочастотных сигналов позволяют конструировать статистические признаки, имеющие высокую чувствительность к дефектам или неисправностям диагностируемого оборудования, в частности центробежного насоса и подшипников качения. Подтверждением этого могут служить результаты экспериментального тестирования, где разработанные модели обнаружения неисправностей с применением статистических признаков демонстрировали 100%-ю точность обнаружения. Кроме того, предлагаемый метод и алгоритм прост с точки зрения реализации и воспроизведения, и не требуют больших вычислительных мощностей. Предлагаемый метод и алгоритм обогащения высокочастотных сигналов также могут применяться в решение большинство задач, связанных с обнаружением неисправностей или дефектов вращающихся механизмов, такие как электрические двигатели, коробки передач, турбины, генераторы и роторные машины.

#### БЛАГОДАРНОСТЬ

Авторы выражают благодарность доктору Анилу Кумару и доктору Раджешу Кумару, а также Синицину Владимиру Владимировичу за предоставленные экспериментальные данные для данного исследования.

#### СПИСОК ЛИТЕРАТУРЫ

- [1] Istomin D.A., Stolbov V.Yu., Platon D.N. Expert system for assessment of technical condition of electric centrifugal pump assemblies based on productive presentation of knowledge and fuzzy logic. Bulletin of the South Ural State University. Ser. Computer Technologies, Automatic Control, Radio Electronics. 2020, vol. 20, no. 1, pp. 133-143. (in Russ.), DOI: 10.14529/ctcr200113
- [2] Hasan M.J., Rai A., Ahmad Z., Kim J.M. A fault diagnosis framework for centrifugal pumps by scalogram-based imaging and deep learning. IEEE Access, 2021, vol. 9, pp. 58052-58066, DOI: 10.1109/ACCESS.2021.3072854
- [3] Ahmad S., Ahmad Z., Kim J.M. A centrifugal pump fault diagnosis framework based on supervised contrastive learning. Sensors (Basel, Switzerland), 2022, vol. 22, no. 17(6448), DOI: 10.3390/s22176448
- [4] ALTobi Saud M.A., Bevan G., Wallace P., Harrison D., Ramachandran K.P. Fault diagnosis of a centrifugal pump using MLP-GABP and SVM with CWT. Engineering Science and Technology, an International Journal, 2019, vol. 22, no. 3, pp. 854-861, DOI: 10.1016/j.jestech.2019.01.005
- [5] Ahmad Z., Nguyen T.-K., Ahmad S., Nguyen C.D., Kim J.-M. Multistage centrifugal pump fault diagnosis using informative ratio principal component analysis. Sensors, 2022, vol. 22, no. 179, DOI: 10.3390/s22010179
- [6] Azadeh A., Saberi M., Ebrahimpour V., Nourmohammadzadeh A., Saberi Z. A flexible algorithm for fault diagnosis in a centrifugal pump with corrupted data and noise based on ANN and support vector machine with hyper-parameters optimization. Applied Soft Computing Journal, 2013, vol. 13, no. 3, pp. 1478-1485, DOI: 10.1016/j.asoc.2012.06.020
- [7] Daraz A., Gu F., Ball A.D. Impeller wear diagnosis in centrifugal pumps under different flow rate based on acoustic signal analysis. Performance Engineering and Maintenance Engineering, Springer, Cham. 2022, vol. 117, pp. 385-401, DOI: 10.1007/978-3-030-99075-6\_32
- [8] Daraz A., Alabied S., Smith A., Gu F., Ball A.D. Detection and diagnosis of centrifugal pump bearing faults based on the envelope analysis of airborne sound signals. 24th International Conference on Automation and Computing (ICAC), Newcastle Upon Tyne, UK. 2018, pp. 1-6, DOI: 10.23919/ICAC.2018.8749053
- [9] Azizi R., Attaran B., Hajnayeb A., Ghanbarzadeh A., Changizian M. Improving accuracy of cavitation severity detection in centrifugal pumps using a hybrid feature selection technique. Measurement, 2017, vol. 108, pp. 9-17, DOI: 10.1016/j.measurement.2017.05.020

- [10] Adamkowski A., Henke A., Lewandowski M. Resonance of torsional vibrations of centrifugal pump shafts due to cavitation erosion of pump impellers. *Engineering Failure Analysis*, 2016, vol. 70, pp. 56-72, DOI: 10.1016/J.ENGFAILANAL.2016.07.011
- [11] Sakthivel N.R., Nair B.B., Sugumaran V., Saravanmurugan S. Comparison of dimensionality reduction techniques for the fault diagnosis of mono block centrifugal pump using vibration signals. *Engineering Science and Technology, an International Journal*, 2014, vol. 17, no. 1, pp. 30-38, DOI: 10.1016/j.jestch.2014.02.005
- [12] Anil K., Hesheng T., Govind V., Jiawei X. Noise subtraction and marginal enhanced square envelope spectrum (MESES) for the identification of bearing defects in centrifugal and axial pump. *Mechanical Systems and Signal Processing*, 2022, vol. 165, no. 108366, DOI: 10.1016/j.ymsp.2021.108366
- [13] Anil K., Gandhi C.P., Yuqing Z., Rajesh K., Jiawei X. Improved deep convolutional neural network (CNN) for the identification of defects in the centrifugal pump using acoustic images. *Applied Acoustics*, 2020, vol. 167, no. 107399, DOI: 10.1016/j.apacoust.2020.107399
- [14] Anil K., Rajesh K. Oscillatory behavior-based wavelet decomposition for the monitoring of bearing condition in centrifugal pumps. *Proceedings of the Institution of Mechanical Engineers, Part J: Journal of Engineering Tribology*, 2018, vol. 232, no. 6, pp. 757-772, DOI: 10.1177/1350650117727976
- [15] Anil K., Rajesh K. Time-frequency analysis and support vector machine in automatic detection of defect from vibration signal of centrifugal pump. *Measurement*, 2017, vol. 108, pp. 119-133, DOI: 10.1016/j.measurement.2017.04.041
- [16] Rauber T.W., da Silva Loca A.L., Boldt F.D.A., Rodrigues A.L., Varejão F.M. An experimental methodology to evaluate machine learning methods for fault diagnosis based on vibration signals. *Expert Syst. Appl.* 2021, vol. 167, no. 114022, DOI: 10.1016/j.eswa.2020.114022
- [17] Wang Y., Yang M., Li Y., Xu Z., Wang J., Fang X. A Multi-Input and Multi-Task Convolutional Neural Network for Fault Diagnosis Based on Bearing Vibration Signal. *IEEE Sens. J.* 2021, vol. 21, pp. 10946-10956, DOI: 10.1109/JSEN.2021.3061595
- [18] Fan H., Xue C., Zhang X., Cao X., Gao S., Shao S. Vibration Images-Driven Fault Diagnosis Based on CNN and Transfer Learning of Rolling Bearing under Strong Noise. *Shock Vib.* 2021, vol. 2021, pp. 1-16, DOI: 10.1155/2021/6616592
- [19] Qian W., Li S. A novel class imbalance-robust network for bearing fault diagnosis utilizing raw vibration signals. *Meas. J. Int. Meas. Confed.* 2020, vol. 156, no. 107567, DOI: 10.1016/j.measurement.2020.107567
- [20] Zhao B., Yuan Q., Zhang H. An improved scheme for vibration-based rolling bearing fault diagnosis using feature integration and adaboost tree-based ensemble classifier. *Appl. Sci.* 2020, vol. 10, no. 1802, DOI: 10.3390/app10051802
- [21] Chen H.-Y., Lee C.-H. Vibration Signals Analysis by Explainable Artificial Intelligence (XAI) Approach: Application on Bearing Faults Diagnosis. *IEEE Access*, 2020, vol. 8, pp. 134246-134256, DOI: 10.1109/ACCESS.2020.3006491
- [22] Li H., Zhang Q., Qin X., Yuantao S. Raw vibration signal pattern recognition with automatic hyper-parameter-optimized convolutional neural network for bearing fault diagnosis. *Proc. Inst. Mech. Eng. Part C J. Mech. Eng. Sci.* 2020, vol. 234, pp. 343-360, DOI: 10.1177/0954406219875756
- [23] Xin Y., Li S., Wang J., An Z., Zhang W. Intelligent fault diagnosis method for rotating machinery based on vibration signal analysis and hybrid multi-object deep CNN. *IET Sci. Meas. Technol.* 2020, vol. 14, pp. 407-415, DOI: 10.1049/iet-smt.2018.5672
- [24] Pham M.T., Kim J.M., Kim C.H. Accurate bearing fault diagnosis under variable shaft speed using convolutional neural networks and vibration spectrogram. *Appl. Sci.* 2020, vol. 10, no. 6385, DOI: 10.3390/app10186385
- [25] Sinitsin V., Ibryaeva O., Sakovskaya V., Ereemeeva V. Intelligent bearing fault diagnosis method combining mixed input and hybrid CNN-MLP model. *Mechanical Systems and Signal Processing*, 2022, vol. 180, no. 109454, DOI: 10.1016/j.ymsp.2022.109454
- [26] Saufi S.R., Ahmad Z.A.B., Leong M.S., Lim M.H. Low-Speed Bearing Fault Diagnosis Based on ArSSAE Model Using Acoustic Emission and Vibration Signals. *IEEE Access*, 2019, vol. 7, pp. 46885-46897, DOI: 10.1109/ACCESS.2019.2909756
- [27] He M., He D. A new hybrid deep signal processing approach for bearing fault diagnosis using vibration signals. *Neurocomputing*, 2020, vol. 396, pp. 542-555, DOI: 10.1016/j.neucom.2018.12.088
- [28] Huang S., Zheng J., Pan H., Tong J. Order-statistic filtering Fourier decomposition and its application to rolling bearing fault diagnosis. *Journal of Vibration and Control*, 2022, vol. 28(13-14), pp. 1605-1620, DOI: 10.1177/1077546321997598
- [29] Attoui I., Oudjani B., Boutasseta N., Fergani N., Bouakkaz M.S., Bouraiou A. Novel predictive features using a wrapper model for rolling bearing fault diagnosis based on vibration signal analysis. *Int. J. Adv. Manuf. Technol.* 2020, vol. 106, pp. 3409-3435, DOI: 10.1007/s00170-019-04729-4
- [30] Klausen A., Robbersmyr K.G. Cross-correlation of whitened vibration signals for low-speed bearing diagnostics. *Mech. Syst. Signal Process.* 2019, vol. 118, pp. 226-244, DOI: 10.1016/j.ymsp.2018.08.048
- [31] Dybała J. Diagnosing of rolling-element bearings using amplitude level-based decomposition of machine vibration signal. *Meas. J. Int. Meas. Confed.* 2018, vol. 126, pp. 143-155, DOI: 10.1016/j.measurement.2018.05.031
- [32] You L., Fan W., Li Z., Liang Y., Fang M., Wang J. A Fault Diagnosis Model for Rotating Machinery Using VWC and MSFLA-SVM Based on Vibration Signal Analysis. *Shock Vib.* 2019, vol. 2019, pp. 1-16, DOI: 10.1155/2019/1908485
- [33] Shao K., Fu W., Tan J., Wang K. Coordinated approach fusing time-shift multiscale dispersion entropy and vibrational Harris hawks optimization-based SVM for fault diagnosis of rolling bearing. *Meas. J. Int. Meas. Confed.* 2021, vol. 173, no. 108580, DOI: 10.1016/j.measurement.2020.108580
- [34] Jiao J., Yue J., Pei D., Hu Z. Application of Feature Fusion Using Coaxial Vibration Signal for Diagnosis of Rolling Element Bearings. *Shock Vib.* 2020, vol. 2020, no. 8831723, DOI: 10.1155/2020/8831723