

УДК 534.08

DOI: 10.22213/2413-1172-2024-3-79-85

Применение методов машинного обучения для анализа зависимости сигналов виброускорения от усилий затяжки болтовых соединений

Е. М. Сухарев, кандидат технических наук, доцент, Сибирский государственный университет путей сообщения, Новосибирск, Россия

Статья посвящена применению методов машинного обучения для анализа сигналов виброускорения в болтовых соединениях, возникающих при ударном воздействии. Актуальность работы обусловлена необходимостью обеспечения надежности и работоспособности болтовых соединений при нагрузках. Одним из перспективных направлений неразрушающего контроля является анализ характеристик сигналов виброускорения, изменяющихся при различных состояниях конструкций, например, при возрастании момента усилия затяжки. Это позволяет своевременно выявлять возможные дефекты и предотвращать аварийные ситуации, обеспечивая безопасность и долговечность конструкций.

Проанализированы сигналы виброускорения при ударном воздействии на болтовое соединение. После расчета характеристик сигналов сформированы наборы данных, включающие значения моментов затяжки и соответствующие им рассчитанные характеристики сигналов, осуществлена корреляция момента усилий затяжки болтовых соединений и полученной совокупности параметров вибрационных сигналов. Рассчитан частотный спектр сигналов, фрактальная размерность Хигучи, детрендированные флуктуации, спектральная плотность мощности и положение пиков сигнала. Для анализа применялись модели машинного обучения, такие как деревья решений, метод ближайших соседей, метод k -средних и нейросети. Для этих методов осуществлялся поиск оптимального набора параметров, коррелирующих с моментом усилия затяжки.

Основные результаты показывают, что методы машинного обучения эффективны для классификации сигналов и поиска корреляций с параметрами напряженного состояния. Они позволяют обнаруживать связь между набором характеристик сигнала и моментом усилия затяжки, что открывает возможности для более точного и надежного контроля состояния болтовых соединений. Это способствует повышению их эксплуатационной надежности и долговечности, а также снижению вероятности отказов и аварий. Применение таких методов улучшает качество мониторинга и диагностики болтовых соединений.

Ключевые слова: машинное обучение, виброускорение, фрактальная размерность, детрендированные флуктуации, резьбовые соединения.

Введение

Необходимость обеспечения оптимального усилия при затяжке резьбовых элементов является актуальной технической задачей в различных отраслях промышленности, таких как машиностроение, авиастроение и энергетика. Болтовые соединения играют решающую роль в структуре различных инженерных конструкций, воспринимая усилия, возникающие в креплениях. Понимание поведения болтовых соединений при приложении нагрузки необходимо для обеспечения их надежности и работоспособности. Недостаточное или чрезмерное усилие затяжки может привести к ослаблению соединения, образованию люфта, вибрации, чрезмерному или преждевременному износу элементов, деформации, коррозии, заеданию, поломке деталей, разгерметизации, утечке, потере работоспособности системы. В ряде случаев это может привести к повышен-

ному риску аварийности, травматичности, материальному ущербу, снижению надежности, производительности, срока службы, необходимости внепланового ремонта, простоя оборудования. Таким образом, поддержание оптимального усилия затяжки является критическим для обеспечения безопасной, надежной и долговечной службы изделия. Задача получения достоверных данных о величине приложенных усилий во время монтажа и эксплуатации является сложной, что существенно затрудняет оценку состояния конструкций. В простых случаях для этой цели используются динамометрические ключи, в сложных случаях контроль напряжений связан с большими трудностями.

Одним из перспективных направлений неразрушающего контроля является вибродиагностика [1]. Вибросигнал содержит большое количество информации о состоянии объекта. В большинстве случаев вибрация вызывается

при работе механизма в натуральных условиях или лабораторных условиях, моделирующих натурные, однако ее можно возбуждать специальным образом с целью регистрации сигнала и его дальнейшего анализа, при этом воздействие, вызывающее вибрацию, должно быть минимальным. Анализ структуры такого сигнала при различных усилиях затяжки также может служить основанием для поиска корреляционных зависимостей и классификации.

Из-за сложности формы временного сигнала его толкование становится затруднительным, поэтому важно обратить особое внимание на обработку сигнала, выделение характерных признаков и удаление нерелевантных признаков, которые дают малосущественную информацию.

С точки зрения машинного обучения анализ сигналов можно рассматривать как анализ временных рядов. Применение методов машинного обучения может помочь выявить потенциальные возможности для улучшения анализа сигналов. Момент усилий затяжки резьбовых соединений влияет на спектральный состав, характеристики демпфирования колебаний [2–4].

Фрактальные характеристики используются для получения классификации сигналов, предсказания поведения различных объектов на воздействия в технических и экономических задачах [5]. Используются различные характеристики фрактальности сигналов: фрактальная размерность, R/S-анализ [6–8], детрендрованные флуктуации [9]. Развивается применение комплексных методов анализа вибросигналов, основанных на машинном обучении [7], применяются модели случайных лесов, ближайших соседей, нейросети [10, 11], изучается связь между спектральными и фрактальными характеристиками и их применение [12–14], метод опорных векторов [15], применение спектральной плотности по Уэлчу для нейросетевого анализа [16], применение машинного обучения для различных конструкций [17–19], в том числе в режиме реальной работы [20–22], нейросети различной архитектуры с мультимодальным объединением при дисбалансе данных [23].

Отмечается, что повышение точности диагностики и одновременно упрощение процедуры можно ожидать при надлежащем выборе признаков сигнала.

Цель представляемой работы – исследование зависимости сигналов виброускорения от усилий затяжки болтовых соединений с использованием методов машинного обучения.

Объект и методы исследования

Изучалась возможность применения различных методов машинного обучения для анализа сигналов виброускорения при ударном воздействии на болтовое соединение. Объект исследования представляет собой болтовое соединение фланца с заглушкой с шестью болтами M20, которые затягивали динамометрическим ключом с различным усилием затяжки. На болт воздействовали ударом стальным шариком массой 9 г, скатывающимся по направляющей трубке с высоты 0,2...0,3 м. Виброускорение головки болта регистрировали акселерометром с тремя осями, изготовленным на базе микросхемы ADXL326. Верхняя частота пропускания составила 1,6 кГц, цена наименьшего разряда – 3 мм/с², а погрешность, связанная с влиянием собственных шумов, не превышала 20 единиц АЦП. Для каждого момента затяжки изучались 500 сигналов. Итоговый сигнал зависит от геометрии соприкосновения, материалов деталей и их состояния.

Для полученных сигналов вычислялись частоты и амплитуды спектрального разложения, фрактальная размерность Хигучи, детрендрованные флуктуации, спектральная плотность мощности, положение пиков сигнала. Все характеристики вычислялись с использованием специально созданной программы на языке Python. Предварительный анализ корреляций между вычисленными характеристиками показал наличие связи между некоторыми из них, что дает дополнительную информацию при дальнейшей оптимизации выбора информативных показателей изучаемых временных рядов.

После расчета характеристик сигналов формировались наборы данных, включающие значения моментов затяжки и соответствующие им рассчитанные характеристики сигналов. Полученный набор данных анализировался с применением методов классификации и регрессии.

Применялись модели, основанные на деревьях решений, методе ближайших соседей, методе k -средних, перцептрона, нейросети прямого распространения (искусственные нейронные сети, в которых сигнал распространяется строго от входного слоя к выходному). Модели деревьев решений служат для создания систем классификации, которые предсказывают или классифицируют будущие наблюдения на основе набора решающих правил. Метод ближайших соседей – классификатор, основанный на оценивании сходства элементов. Объект относится к классу, к которому принадлежат ближайшие

к нему единицы выборки. Метод k -средних – это алгоритм, основанный на итеративной минимизации суммарного квадратичного отклонения точек кластеров от центров этих кластеров.

Результаты исследования и их анализ

Для фрактальной размерности Хигучи получена положительная корреляция с величиной момента усилия затяжки, измеренная с помощью динамометрического ключа. При возрастании момента от минимального значения фрактальная размерность также возрастает, затем практически постоянна.




Рис. 1. Зависимость фрактальной размерности сигнала от момента усилия затяжки болта

Fig. 1. Dependence of the fractal dimension of the signal on the bolt tightening torque

Фрактальность сигнала можно объяснить сложностью геометрии соприкасающихся поверхностей, при этом, если момент усилия затяжки увеличивается, уменьшается затухание при отражении от соприкасающихся частей.

При классификации с использованием частот и амплитуд, полученных с помощью дискретного преобразования Фурье, получено, что точность на тестовых данных составила 98 %, а наиболее важными признаками для классификатора на основе дерева решений являются частота первого члена разложения и амплитуда второго. Добавление такого признака, как фрактальная размерность, приводит к увеличению точности данных до 99 %, а при добавлении детрендрованных флуктуаций предсказательные свойства модели еще улучшаются.

При построении дерева классификации для набора данных, содержащих амплитуды и частоты для спектральной плотности мощности по Уэлчу и амплитуды первых пиковых значений исходного сигнала, получена точность классификации для тренировочных данных близкая к 99 %, для тестовых данных – 96 %. Оценка важности признаков показала, что наибольшей

важностью обладает фрактальная размерность – около 0,5. Следующий по важности вклад вносит амплитуда, соответствующая второму члену разложения, – 0,4. Для этого набора данных пиковые значения амплитуд показали низкую корреляцию, поэтому были исключены из построения классификатора.

Таким образом, наиболее важными признаками для увеличения точности данных являются: амплитуда и частота первого члена разложения по Уэлчу, амплитуда второго максимума, частота первого максимума спектрального разложения и фрактальная размерность Хигучи.

Для модели регрессии методом k -ближайших соседей точность предсказаний момента усилия затяжки при $k = 6$, составила 2 Н·м на тестовых данных, и 6 Н·м – на тренировочных данных. На рисунке 2 представлена зависимость предсказанных значений от реальных для тестового набора данных, если в качестве признаков выбирались: первая частота и амплитуда преобразования Фурье, первая частота и амплитуда спектра мощности по Уэлчу и фрактальная размерность Хигучи. Если добавить в качестве признака детрендрованные флуктуации, точность остается примерно на том же уровне. Если в качестве признаков брать только первую частоту и амплитуду спектра Фурье и фрактальную размерность, точность существенно уменьшается.




Рис. 2. Связь тестовых и предсказанных значений момента для модели ближайших соседей

Fig. 2. Relationship between test and predicted torque values for the nearest neighbor model

Для оценки качества кластеризации с использованием метода k средних соседей использовались метрики «индекс силуэта» (silhouette score) и «индекс Дэвиса – Болдина» (Davies-Bouldin index). Для использованных характеристик в наборе данных рассчитанный индекс Дэвиса – Болдина близок к 0,3, а индекс силуэта

порядка 0,79. Если оставить только первую амплитуду разложения спектральной плотности по Уэлчу, то индекс Дэвиса – Болдина становится равным 0,44, а индекс силуэта – 0,69. Если этот единственный признак кластеризации заменить амплитудой первого максимума спектра Фурье, индексы остаются примерно такими же.

Если число кластеров увеличить до 6 (по числу значений моментов усилий затяжки), индекс силуэта уменьшается, а индекс, Дэвиса – Болдина возрастает, то есть кластеризация становится менее качественной. При использовании для кластеризации большего числа характеристик значения указанных индексов кластеризации меняются. Исключение из набора признаков фрактальной размерности Хигучи или величины детрендированных флуктуаций практически не влияет на показатели качества кластеризации. Это говорит о необходимости более тщательного подбора признаков, выделяемых из сигнала и их количества.

Для выбора оптимального числа кластеров использовался также метод локтя и метод плеча. В первом случае оптимальное число кластеров от 2 до 3, а во втором – значение близкое к 5 или 6, что соответствует количеству уникальных значений момента усилия затяжки.

Для классификации с использованием многослойного перцептрона был опробован классификатор с 10–25 нейронами, использующий для обновления весов модели на основе градиентов, алгоритмы оптимизации Бройдена – Флетчера – Гольдфарба – Шанно, Adam и алгоритм стохастического градиентного спуска. Точность классификации составила 99 % для тренировочных и 93 % для тестовых данных. Скорость обучения варьировалась в пределах 0,01...0,25, число эпох обучения модели – в пределах 50.

Точность классификации оказалась удовлетворительной даже в случае малого набора признаков. При уменьшении скорости обучения точность на тренировочных данных резко уменьшалась до 50...60 %. При уменьшении размера скрытого слоя точность классификации снижалась до значений 70...80 %.

Для нейросети прямого распространения использовались следующие критерии качества модели: средняя абсолютная ошибка (MAE), среднеквадратичная ошибка (MSE), коэффициент детерминации (R -squared). Их значения при разных параметрах набора данных и нейронной сети менялись, однако удавалось достигать значений, которые можно считать удовлетворительными, а именно: MAE = 1,11, MSE = 16, R -squared = 0,98.

На рисунке 3 показана зависимость предсказанных значений момента усилия затяжки от измеренных параметров нейросети: амплитуды первого члена спектральной плотности мощности, второго члена частотного спектра Фурье и фрактальной размерности Хигучи.




Рис. 3. Зависимость предсказанных значений момента усилия затяжки от измеренных параметров нейросети

Fig. 3. Dependence of the predicted values of tightening torque on the measured values for neural network parameters

Если в качестве признака выбрана только фрактальная размерность Хигучи, то показатели качества модели резко снижаются. Увеличение числа анализируемых признаков слабо сказывается на предсказательной способности модели. Это связано с корреляцией признаков, вследствие чего совместное использование коррелируемых признаков не добавляет информативности по сравнению с использованием одного из них.

Таким образом, величина момента усилия затяжки болтовых соединений влияет на характеристики сигнала виброускорения, и для всех исследованных моделей фрактальные характеристики сигнала в сочетании с несколькими спектральными характеристиками могут быть основой классификации и предсказания момента усилий затяжки с применением методов машинного обучения.

Выводы

1. Для всех указанных моделей величина момента усилия затяжки болтовых соединений влияет на характеристики сигнала виброускорения.

2. Для каждой модели возможно выявить наиболее важные признаки, к числу которых всегда относится фрактальная размерность и детрендированные флуктуации, а также некоторые характеристики, извлекаемые из преобра-

зования Фурье и разложения по Уэлчу (различные для различных моделей).

3. Точность предсказания усилий затяжки для этих моделей позволяет говорить о возможности классификации и контроля усилий затяжки с использованием совокупности фрактальных и спектральных характеристик сигнала методами машинного обучения.

Библиографические ссылки

1. Неразрушающий контроль : справочник : в 8 т. / под общ. ред. В. В. Клюева. Т. 7 : в 2 кн. Кн. 2 : Вибродиагностика / Ф. Я. Балицкий, А. В. Барков, Н. А. Баркова [и др.]. – 2-е изд., испр. М. : Машиностроение, 2006. 829 с.
2. Куц М. С. Экспериментальное исследование влияния усилия затяжки болтов на резонансные частоты консольно закрепленной балки // Известия высших учебных заведений. Машиностроение. 2018. № 9 (702). С. 37–43 DOI: 10.18698/0536-1044-2018-9-37-43
3. Brons M., Thomsen J.J., Sah S.M., Tcherniak D., Fidlin A. (2020) Estimating bolt tension from vibrations: Transient features, nonlinearity, and signal processing. *Mechanical Systems and Signal Processing*, 150, Article 107224. DOI: 10.1016/j.ymsp.2020.107224
4. Lei Li, Zhong Luo, Fayong Wu, Fengxia He, Kai Sun (2023) Frequency spectrum analysis of the rotor system with bolted joint: Numerical and experimental verification. *Applied Mathematical Modelling*, vol. 118, pp. 745-761. DOI: 10.1016/j.apm.2023.02.003
5. Gowrisankar A., Banerjee S. (2023) Framework of fractals in data analysis: theory and interpretation. *European Physical Journal Special Topics*, vol. 232, pp. 965-967. DOI: 10.1140/epjs/s11734-023-00890-w
6. Golmankhaneh A.K., Welch K., Tunç C. (2023) Classical mechanics on fractal curves. *European Physical Journal Special Topics*, vol. 232, pp. 991-999. DOI: 10.1140/epjs/s11734-023-00775-y
7. Yang X., Xiang Y., Jiang B. (2022) On multi-fault detection of rolling bearing through probabilistic principal component analysis denoising and Higuchi fractal dimension transformation. *Journal of Vibration and Control*, no. 28(9-10), pp. 1214-1226. DOI: 10.1177/1077546321989527
8. Wanliss J. (2023) Fractal Methods in Nonequilibrium Systems. *Fractal Analysis - Applications and Updates*. Intech Open, Jul. 13, 2023. DOI: 10.5772/intechopen.1002058
9. Setty V.A., Sharma A.S. (2015) Characterizing detrended fluctuation analysis of multifractional Brownian motion. *Physica A: Statistical Mechanics and its Applications*, vol. 419, pp. 698-706. DOI: 10.1016/j.physa.2014.10.016
10. Shi C.-T. (2018) Signal Pattern Recognition Based on Fractal Features and Machine Learning. *Applied Science*, 8, p. 1327. DOI: 10.3390/app8081327
11. Xue R., Liu J., Tang H. (2020) Two-Dimensional Jamming Recognition Algorithm Based on the Sevcik Fractal Dimension and Energy Concentration Property for UAV Frequency Hopping Systems. *Information*, no. 11, p. 520. DOI: 10.3390/info11110520
12. Agathiyani A., Nur Aisyah Abdul Fataf, Gowrisankar A. (2023) Explicit relation between Fourier transform and fractal dimension of fractal interpolation functions. *The European Physical Journal Special Topics*, 232:7, pp. 1077-1091. DOI: 10.1140/epjs/s11734-023-00779-8
13. Medina R., Sánchez R.-V., Cabrera D., Cerrada M., Estupiñan E., Ao W., Vásquez R.E. (2024) Scale-Fractal Detrended Fluctuation Analysis for Fault Diagnosis of a Centrifugal Pump and a Reciprocating Compressor. *Sensors*, 24, p. 461. DOI: 10.3390/s24020461
14. Li J.-M., Wei H.-J., Wei L.-D., Zhou D.-P., Qiu Y. (2020) Extraction of Frictional Vibration Features with Multifractal Detrended Fluctuation Analysis and Friction State Recognition. *Symmetry*, no. 12, p. 272. DOI: 10.3390/sym12020272
15. Salim Lahmiri, Chakib Tadj, Christian Gargour, Stelios Bekiros (2022) Optimal tuning of support vector machines and k-NN algorithm by using Bayesian optimization for newborn cry signal diagnosis based on audio signal processing features, *Chaos, Solitons & Fractals*, vol. 167, p. 112972. DOI: 10.1016/j.chaos.2022.112972
16. Jin Z., Han Q., Zhang K., Zhang Y. (2020) An intelligent fault diagnosis method of rolling bearings based on Welch power spectrum transformation with radial basis function neural network. *Journal of Vibration and Control*, no. 26(9-10), pp. 629-642. DOI: 10.1177/1077546319889859
17. Wang L., Zhang C., Zhu J., Xu F. (2022) Fault Diagnosis of Motor Vibration Signals by Fusion of Spatiotemporal Features. *Machines*, vol. 10, p. 246. <https://doi.org/10.3390/machines10040246>
18. Altaf M., Akram T., Khan M.A., Iqbal M., Ch M.M.I., Hsu C.-H. (2022) A New Statistical Features Based Approach for Bearing Fault Diagnosis Using Vibration Signals. *Sensors*, vol. 22. DOI: 10.3390/s22052012
19. Joshuva A., Sugumaran V. (2018) A machine learning approach for condition monitoring of wind turbine blade using autoregressive moving average (ARMA) features through vibration signals: a comparative study. *Progress in Industrial Ecology: An International Journal*, vol. 12, no. 14, pp. 14-34. DOI: 1504/PIE.2018.10016959
20. Gana M., Achour H., Belaid K., Chelli Z., Laghrouche M., Chaouchi A. (2022) Non-invasive intelligent monitoring system for fault detection in induction motor based on lead-free-piezoelectric sensor using ANN. *Measurement Science and Technology*, vol. 33. DOI: 10.1088/1361-6501/ac4b8f
21. Wang Haiya, Zhongqing Yu., Guo Lu. (2020) Real-time Online Fault Diagnosis of Rolling Bearings Based on KNN Algorithm. *Journal of Physics: Conference Series*, 1486, 032019. DOI: 10.1088/1742-6596/1486/3/032019
22. Zou F., Zhang H., Sang S. (2021) Bearing fault diagnosis based on combined multi-scale weighted entropy morphological filtering and bi-LSTM. *Applied*

Intelligence, vol. 51, pp. 6647-6664. DOI: 10.1007/s10489-021-02229-1

23. Qiu S., Cui X., Ping Z., Shan N., Li Z., Bao X., Xu X. (2023) Deep Learning Techniques in Intelligent Fault Diagnosis and Prognosis for Industrial Systems: A Review. *Sensors*, no. 23, p. 1305. <https://doi.org/10.3390/s23031305>

References

1. Balitsky F.Ya., Barkov A.V., Barkova N.A. (2006) *Vibrodiagnostika* [Vibration diagnostics]. Moscow: Mashinostroenie Publithing, 829 p. (in Russ.).

2. Kuts M.S. (2018) [Experimental study of the influence of bolt tightening force on the resonant frequencies of a cantilevered beam]. *Izvestija vysshih uchebnyh zavedenij. Mashinostroenie*, no. 9 (702) (in Russ.). DOI: 10.18698/0536-1044-2018-9-37-43

3. Brøns M., Thomsen J. J., Sah S. M., Tcherniak D., Fidlín A. (2020) Estimating bolt tension from vibrations: Transient features, nonlinearity, and signal processing. *Mechanical Systems and Signal Processing*, 150, Article 107224. DOI: 10.1016/j.ymssp.2020.107224

4. Lei Li, Zhong Luo, Fayong Wu, Fengxia He, Kai Sun (2023) Frequency spectrum analysis of the rotor system with bolted joint: Numerical and experimental verification. *Applied Mathematical Modelling*, vol. 118, pp. 745-761. DOI: 10.1016/j.apm.2023.02.003

5. Gowrisankar A., Banerjee S. (2023) Framework of fractals in data analysis: theory and interpretation. *European Physical Journal Special Topics*, vol. 232, pp. 965-967. DOI: 10.1140/epjs/s11734-023-00890-w

6. Golmankhaneh A.K., Welch K., Tunç C. (2023) Classical mechanics on fractal curves. *European Physical Journal Special Topics*, vol. 232, pp. 991-999. DOI: 10.1140/epjs/s11734-023-00775-y

7. Yang X., Xiang Y., Jiang B. (2022) On multi-fault detection of rolling bearing through probabilistic principal component analysis denoising and Higuchi fractal dimension transformation. *Journal of Vibration and Control*, no. 28(9-10), pp. 1214-1226. DOI: 10.1177/1077546321989527

8. Wanliss J. (2023) Fractal Methods in Nonequilibrium Systems. *Fractal Analysis, Applications and Updates*. Intech Open, Jul. 13, 2023. DOI: 10.5772/intechopen.1002058

9. Setty V.A, Sharma A.S. (2015) Characterizing detrended fluctuation analysis of multifractional Brownian motion. *Physica A: Statistical Mechanics and its Applications*, vol. 419, pp. 698-706. DOI: 10.1016/j.physa.2014.10.016

10. Shi C.-T. (2018) Signal Pattern Recognition Based on Fractal Features and Machine Learning. *Applied Science*, 8, p. 1327. DOI: 10.3390/app8081327

11. Xue R., Liu J., Tang H. (2020) Two-Dimensional Jamming Recognition Algorithm Based on the Sevcik Fractal Dimension and Energy Concentration Property for UAV Frequency Hopping Systems. *Information*, no. 11, p. 520. DOI: 10.3390/info11110520

12. Agathiyani A., Nur Aisyah Abdul Fataf, Gowrisankar A. (2023) Explicit relation between Fourier transform and fractal dimension of fractal interpolation functions. *The European Physical Journal Special Topics*,

232:7, pp. 1077-1091. DOI: 10.1140/epjs/s11734-023-00779-8

13. Medina R., Sánchez R.-V., Cabrera D., Cerrada M., Estupiñan E., Ao W., Vásquez R.E. (2024) Scale-Fractal Detrended Fluctuation Analysis for Fault Diagnosis of a Centrifugal Pump and a Reciprocating Compressor. *Sensors*, 24, p. 461. DOI: 10.3390/s24020461

14. Li J.-M., Wei H.-J., Wei L.-D., Zhou, D.-P., Qiu Y. (2020) Extraction of Frictional Vibration Features with Multifractal Detrended Fluctuation Analysis and Friction State Recognition. *Symmetry*, no. 12, p. 272. DOI: 10.3390/sym12020272

15. Salim Lahmiri, Chakib Tadj, Christian Gargour, Stelios Bekiros. (2022) Optimal tuning of support vector machines and k-NN algorithm by using Bayesian optimization for newborn cry signal diagnosis based on audio signal processing features. *Chaos, Solitons & Fractals*, vol. 167, p. 112972. DOI: 10.1016/j.chaos.2022.112972

16. Jin Z., Han Q., Zhang K., Zhang Y. (2020) An intelligent fault diagnosis method of rolling bearings based on Welch power spectrum transformation with radial basis function neural network. *Journal of Vibration and Control*, no. 26(9-10), pp. 629-642. DOI: 10.1177/1077546319889859

17. Wang L., Zhang C., Zhu J., Xu, F. (2022) Fault Diagnosis of Motor Vibration Signals by Fusion of Spatiotemporal Features. *Machines*, vol. 10, p. 246. <https://doi.org/10.3390/machines10040246>

18. Altaf M., Akram T., Khan M.A., Iqbal M., Ch M.M.I., Hsu C.-H. (2022) A New Statistical Features Based Approach for Bearing Fault Diagnosis Using Vibration Signals. *Sensors*, vol. 22. DOI: 10.3390/s22052012

19. Joshuva A., Sugumaran V. (2018) A machine learning approach for condition monitoring of wind turbine blade using autoregressive moving average (ARMA) features through vibration signals: a comparative study. *Progress in Industrial Ecology: An International Journal*, vol. 12, no. 14, pp. 14-34. DOI: 1504/PIE.2018.10016959

20. Gana M., Achour H., Belaid K., Chelli Z., Laghrouche M., Chaouchi A. (2022) Non-invasive intelligent monitoring system for fault detection in induction motor based on lead-free-piezoelectric sensor using ANN. *Measurement Science and Technology*, vol. 33. DOI: 10.1088/1361-6501/ac4b8f

21. Wang Haiya, Zhongqing Yu., Guo Lu. (2020) Real-time Online Fault Diagnosis of Rolling Bearings Based on KNN Algorithm. *Journal of Physics: Conference Series*, 1486, 032019. DOI: 10.1088/1742-6596/1486/3/032019

22. Zou F., Zhang H., Sang S. (2021) Bearing fault diagnosis based on combined multi-scale weighted entropy morphological filtering and bi-LSTM. *Applied Intelligence*, vol. 51, pp. 6647-6664. DOI: 10.1007/s10489-021-02229-1

23. Qiu S., Cui X., Ping Z., Shan N., Li Z., Bao X., Xu X. (2023) Deep Learning Techniques in Intelligent Fault Diagnosis and Prognosis for Industrial Systems: A Review. *Sensors*, no. 23, p. 1305. <https://doi.org/10.3390/s23031305>

Application of Machine Learning Methods to Analyze the Dependence of Vibration Acceleration Signals on the Tightening Forces of Bolted Connections

E.M. Sukharev, PhD in Engineering, Associate Professor, Siberian Transport University, Novosibirsk, Russia

The article is devoted to the application of machine learning methods for the analysis of vibration acceleration signals in bolted joints that occur under impact. The relevance of the work is due to the need to ensure the reliability and operability of bolted joints under loads. One of the promising areas of non-destructive testing is the analysis of the characteristics of vibration acceleration signals that change with changes in the state of structures, for example, with an increase in the tightening torque. This allows for the timely detection of possible defects and the prevention of emergency situations, ensuring the safety and durability of structures.

The vibration acceleration signals under impact action on a bolted joint were analyzed. After calculating the signal characteristics, data sets were formed, including the values of tightening torques and the corresponding calculated signal characteristics, a search for a correlation between the tightening torque of bolted joints and the obtained set of vibration signal parameters was carried out. The frequency spectrum of signals, the Higuchi fractal dimension, detrended fluctuations, spectral power density and position of signal peaks were calculated. Machine learning models such as decision trees, the nearest neighbor method, the k-means method and neural networks were used for the analysis. For these methods, an optimal set of parameters correlating with the tightening torque was searched for.

The main results show that machine learning methods are effective in classifying signals and finding correlations with stress state parameters. They allow us to detect the relationship between a set of signal characteristics and tightening torque, which opens up opportunities for more accurate and reliable monitoring of the condition of bolted connections. This should help to increase their operational reliability and durability, as well as reduce the likelihood of failures and accidents. The use of such methods can improve the quality of monitoring and diagnostics of bolted connections.

Keywords: machine learning, vibration acceleration, fractal dimension, detrended fluctuations, threaded connections.

Получено 03.04.2024

Образец цитирования

Сухарев Е. М. Применение методов машинного обучения для анализа зависимости сигналов виброускорения от усилий затяжки болтовых соединений // Вестник ИжГТУ имени М. Т. Калашникова. 2024. Т. 27, № 3. С. 79–85. DOI: 10.22213/2413-1172-2024-3-79-85

For Citation

Sukharev E.M. (2024) [Application of Machine Learning Methods to Analyze the Dependence of Vibration Acceleration Signals on the Tightening Forces of Bolted Connections]. *Vestnik IzhGTU imeni M.T. Kalashnikova*, 2024, vol. 27, no. 3, pp. 79-85 (in Russ.). DOI: 10.22213/2413-1172-2024-3-79-85