

СТАТЬИ

УДК 621.6:004.032.26

РАЗРАБОТКА И АВТОМАТИЗАЦИЯ МЕТОДИКИ ДИАГНОСТИКИ НЕИСПРАВНОСТЕЙ УСТАНОВОК ЭЛЕКТРОЦЕНТРОБЕЖНЫХ НАСОСОВ С ИСПОЛЬЗОВАНИЕМ НЕЙРОСЕТЕВЫХ АЛГОРИТМОВ

¹Большунов А.В., ²Волков П.В., ³Мостакалов К.А.

¹ФГАОУ «Национальный исследовательский Томский политехнический университет»,
Томск, e-mail: avb5@tpu.ru;

²АО «ТомскНИПИнефть», Томск, e-mail: VolkovPV@nipineft.tomsk.ru;

³ФГАОУ «Национальный исследовательский Томский политехнический университет»,
Томск, e-mail: mostokalov93@mail.ru

В работе описан подход методом машинного обучения для автоматического обнаружения и диагностики неисправностей погружного электрического насоса. Данный вид диагностики позволит автоматизировать процесс обнаружения неисправностей и предотвратить преждевременный выход оборудования из работы. Также алгоритм позволит удешевить процесс работы, так как программа самообучаема и нет необходимости в высококвалифицированных рабочих. Несколько тысяч показаний значения вибрации были получены от распределенных по вертикали акселерометров вдоль ряда двигателей, насосов и протекторов. Промежуточные характеристики извлекаются из необработанных сигналов вибрации, исходящих от группы акселерометров. Каждый образец был проработан экспертом, чтобы обеспечить максимальный класс обработки результатов и учет ошибок приборов (неисправность датчика, истирание, дисбаланс или смещение). Программная структура используется для сравнения нескольких классификаторов архитектуры. Чтобы повысить эффективность классификации, вариации различных версий архитектуры классификатора строятся с использованием функции объединения шаблонов решений. Надежность системы по отношению к появлению новых неисправностей подтверждается методологией систематического анализа. Проанализированы различные подходы и методы решения, проведены эксперименты в ошибочных и экстремальных ситуациях. Изучены особенности поведения алгоритма в различных условиях.

Ключевые слова: диагностика неисправностей, электрический погружной насос, классификация, критерии эффективности, шаблоны решений

DEVELOPMENT AND AUTOMATION OF THE METHODOLOGY FOR DIAGNOSING FAULTS IN ELECTRIC CENTRIFUGAL PUMP INSTALLATIONS USING NEURAL NETWORK ALGORITHMS

¹Bolshynov A.V., ²Volkov P.V., ³Mostokalov K.A.

¹National Research Tomsk Polytechnic University, Tomsk, e-mail: avb5@tpu.ru;

²TomskNIPIneft, Tomsk, e-mail: VolkovPV@nipineft.tomsk.ru;

³National Research Tomsk Polytechnic University, Tomsk, e-mail: mostokalov93@mail.ru

A machine learning approach to perform automatic detection and diagnosis of faults of electrical submersible pump systems is presented. This type of diagnostics will allow to automate the process of detecting malfunctions and prevent premature equipment out of work. Also, the algorithm allows to reduce the cost of the work process, since the program is self-learning and there is no need for highly skilled workers. Several thousand vibration patterns were acquired from vertically distributed accelerometers along the string of motors, pumps and protectors. Intermediate features are extracted from the raw vibration signals originating from the set of accelerometers. Each pattern was labelled by a human expert to provide ground truth with respect to the different operation classes (normal, sensor fault, rubbing, unbalance or misalignment). A software framework is used to compare several classifier architectures in a bias aware performance evaluation. In order to boost the classification performance, an ensemble of different versions of a classifier architecture is constructed using the Decision Templates fusion function. The robustness of the system with respect to the emergence of new faults (i.e., untreated faults so far) is corroborated by a systematic analysis methodology. Various approaches and solution methods are analyzed, experiments in erroneous and extreme situations are carried out. The features of the behavior of the algorithm in various conditions are studied.

Keywords: Fault diagnosis, electrical submersible pump, classification, performance criteria, decision templates

В современных условиях добыча нефти является дорогостоящим видом деятельности, предполагающей использование сложного и дорогого оборудования. Основная подсистема, которая помогает поднять сырую нефть и газ на поверхность, известна как электрический погружной насос. Такие подсистемы работают на большой глубине,

поэтому имеют трудный доступ, и в связи с этим невозможно наблюдать работу процесса в реальном времени. Кроме того, производственные перерывы и простои выходят очень дорого, что усиливает необходимость надежной работы оборудования после запуска в эксплуатацию. Для того чтобы избежать затрат, связанных с подня-

тием и заменой неисправного оборудования, которое находится в эксплуатации, оно тщательно проверяется в специальной тестовой среде [1; 2] до начала работы. Такие тесты направлены на выявление потенциальных неисправностей оборудования.

Большая часть потенциальных неисправностей связана с механическими проблемами и обнаруживается в виде появления вибраций по сравнению с исправным состоянием. Шаблоны вибрации могут быть измерены акселерометрами, а затем преобразованы в более описательный набор функций, помогающих распознавать различные режимы работы. Подсистемы насоса испытываются в искусственной среде при различных условиях работы, при этом шаблоны вибрации регистрируются датчиками акселерометра. Два датчика акселерометра расположены ортогонально (ось X и ось Y) в нескольких равномерно распределенных точках вдоль шести основных компонентов оборудования. Такое распределение выборки дает в общей сложности $6 \times 3 \times 2 = 36$ одновременно полученных сигналов вибрации во временной области. После сбора сигналы поступают в частотную область с помощью обычного преобразования Фурье, где может выполняться оценка сигналов; пример сигналов представлен на рис. 1. После анализа данных оборудование может быть диагностировано как исправное или неисправное. Эта работа фокусируется на трех типах неисправностей насоса: перекося вала, дисбаланс лопасти насоса и механическое трение. Кроме того, она рассматривает неисправные датчики акселерометра, генерирующие аномальное поведение вибрации как дефект. Учитывая предыдущие неисправности и исправное

рабочее состояние, для описания работы насоса используются пять взаимоисключающих категорий: смещение, дисбаланс, трение, датчик, нормальное состояние.

Цель исследования: визуально проверить спектры вибрации и решить, следует ли отбраковывать оборудование – задача не из легких. Кроме того, эти знания не передаются и не усваиваются другими инженерами без многолетнего обучения и практики. Экспертная система, представленная в этой работе, автоматически и систематически выполняет такие задачи и позволяет выполнять работу неспециалистам [3; 4].

График показывает соответствующее преобразование в частотную область с помощью преобразования Фурье. Что еще более важно, человек может сохранить некоторый тип корпоративных знаний. Поскольку имеющиеся знания о диагностике неисправностей электрических погружных насосов по-прежнему неполны, ожидается, что в будущем будут обнаружены новые типы дефектов, которые будут включены в набор обучающих данных при накоплении значительного числа примеров. Действительно, факт, наблюдаемый в ходе всего этого исследовательского проекта, заключается в том, что эксперт в конечном итоге указал на схему, в которой подозревается неисправность, но без достаточной уверенности, чтобы отклонить оборудование как неисправное или охарактеризовать новую неисправность. В результате технология должна быть способна адаптироваться к обнаружению новых дефектов. Потенциально технология, разработанная в этой работе, должна иметь такое поведение, но было важно официально показать эту функцию [5].

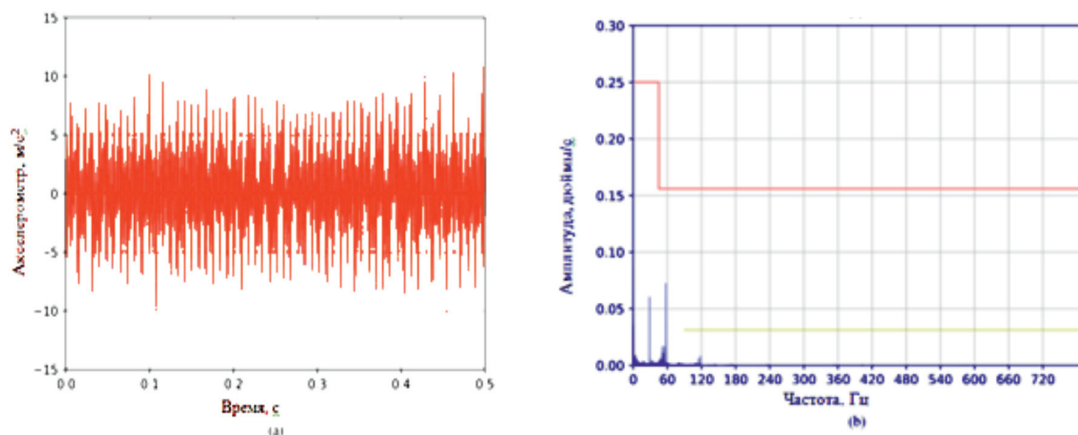


Рис. 1. Пример данных, полученных акселерометром. Верхний график показывает необработанный сигнал вибрации во временной области, нижний показывает соответствующее преобразование в частотную область с помощью преобразования Фурье

Дорогие электрические погружные насосные системы должны быть проверены перед началом эксплуатации. Это необходимо, чтобы избежать ненужных затрат, так как подводная коррекция на море невозможна. Эта работа предлагает подход машинного обучения для решения важной проблемы машиностроения.

Шаблоны решений

Шаблоны принятия решений [6; 7] – это метод определения окончательной классификации для ансамбля классификатора с одной меткой. Для заданного числа L классификаторов D_i , $i = 1..L$ для шаблона x , принадлежащего ровно одному из классов w_i , общего количества классов $\{w_j | j = 1, \dots, c\}$, непрерывный выходной сигнал $d_{i,j}$ каждого из этих классификаторов для каждого из c возможных классов организован в профиле принятия решений (DP).

$$DP(x) = \begin{pmatrix} d_{1,1}(x) & d_{1,j}(x) & d_{1,c}(x) \\ d_{i,1}(x) & d_{i,j}(x) & d_{i,c}(x) \\ d_{L,1}(x) & d_{L,j}(x) & d_{L,c}(x) \end{pmatrix}. \quad (1)$$

В идеале эти оценки являются вероятностями, основанными на условных распределениях истинного класса. Предполагаемые вероятности, нечеткие заданные степени членства или расстояния также возможны в качестве оценки. Следовательно, запись $d_{i,j}(x)$ в DP – это оценка i -го классификатора из общего количества L различных классификаторов для j -го класса в общей сложности C классов. Рассмотрим тот же обучающий набор, состоящий из n выборок, который используется для обучения классификаторов D_i , используемых для определения уравнения DP (1) для выборки x , теперь разделенной для каждого класса с n_j выборками, $\sum_{j=1}^c n_j = n$ как $\{x_{i,k} | k = 1, \dots, n_j\}, j = 1, \dots, C$.

Тогда DT класса w вычисляется как

$$DT_i = \frac{1}{n_j} \sum_{k=1}^{n_j} DP(x_{j,k}). \quad (2)$$

Возможные комбинации для классификаторов должны были быть ограничены, чтобы обеспечить разумное время выполнения, в основном в зависимости от сложности каждой архитектуры классификатора. Сложность системы оценки с R подходов, K и \tilde{K} складки этапа тестирования и настройки, а L версий классификатора в ансамбле – $O(R \times K \times \tilde{K} \times L)$. Тем не менее эта сложность должна быть умножена на внутреннюю сложность конкретного класси-

фикатора, который совершенно различен. Структура оценки производительности изображена в алгоритме (рис. 2). Используются следующие символы: C – классификатор, V – общий набор данных из n шаблонов, T – Тренировочный набор, v – тестовый набор, P – набор гиперпараметров P – кандидатов, P^* – лучший набор гиперпараметров, R – количество подходов, K – число сгибов внешней петли CV для оценки общей эффективности, PM – $R \times K$ матрица производительности, \tilde{K} – количество сгибов внутренней петли CV для настройки.

```

Function  $PM \leftarrow ModelPerformance(D, R, K)$ 
  Input:  $n$  labelled patterns  $\mathcal{D}$  from  $c$  classes,  $R$ 
           number of rounds, number of folds  $K$  (outer
           loop),  $\tilde{K}$  (inner loop)
  Output: For each round  $r \leftarrow 1, \dots, R$  make  $K$ 
           stratified folds. One fold is fixed as test,
           remaining folds are train and tune.
           Calculate performance criterion for each
           combination of round and fold and put
           into  $R \times K$  performance matrix  $PM$ 
  for  $r = 1$  to  $R$  do // all rounds
    // generate  $K$  stratified folds
     $f_{r,k}, k = 1, \dots, K;$ 
    for  $k = 1$  to  $K$  do // all folds
      // training set of  $k$ -th fold of  $r$ -th round
       $\mathcal{T} \leftarrow \{f_{r,1} \cup \dots \cup f_{r,K}\} \setminus f_{r,k};$ 
      // test set of  $k$ -th fold of  $r$ -th round
       $\mathcal{V} \leftarrow f_{r,k};$ 
       $P^* \leftarrow Tuning(\mathcal{T}, \tilde{K});$ 
       $C \leftarrow trainclassifier(\mathcal{T}, P^*);$ 
       $crit \leftarrow testclassifier(C, \mathcal{V});$ 
       $PM(r,k) \leftarrow crit$ 
    end
  end
  end

```

Рис. 2. Алгоритм оценки производительности

Экспериментальные результаты и обсуждение

Эксперименты разделены на две части. Первая часть – это сравнительное исследование всех архитектур классификаторов, оценка каждого типа классификатора с использованием и без использования функций объединения информации ансамбля. Цель состоит в том, чтобы получить подсказку о том, что использование ансамблей полезно в отношении показателей производительности. Классификатор, который достиг наивысшего балла, сохраняется для второй части экспериментов. В этой части анализируется влияние удаления определенной ошибки из классов или рассмотрения ошибки как нормального класса. Цель этого эксперимента – оценить эффективность системы классификации для более реалистичных ситуаций. Во время опе-

рации классификации неисправностей вполне вероятно, что возникают новые ситуации. Например, сломанные подшипники качения проявляют себя в измененной схеме вибрации. От системы диагностики ожидается, что она все еще способна распознавать обнаруженные неисправности с определенной степенью надежности. Это означает, что производительность классификатора не должна значительно ухудшаться, когда он обучается с учетом новых классов неисправностей.

Сравнение автономных классификаторов и ансамблей

Цель этого экспериментального этапа – определить, какой классификатор работает лучше всего для данной базы данных о состоянии машины. Эксперименты проводились с общим количеством $n = 4570$ примеров для $R = 10$ подходов на каждом этапе с использованием оценки эффективности перекрестной проверки $K = 10$ раз. Количество различных версий, использованных в процессе расфасовки, было установлено на $L = 10$ классификаторов. Блокпост выбранного критерия эффективности для каждого из классификаторов является очень выразительным непараметрическим инструментом графического представления, принятым в данном исследовании.

На рис. 3 показаны результаты F-замеров для каждого метода с ансамблями пакетирования и без них для каждой из трех функций объединения информации ансамбля. Анализируя результаты, можно увидеть, что радиочастотный классификатор, использующий DT в качестве функции объединения информации ансамбля, достиг наилучшей производительности среди всех классификаторов, поскольку он имеет наивысшую среднюю производительность и высокие значения других статистических данных. Кроме того, DTs превзошли другие функции объединения информации ансамбля для всех классификато-

ров, кроме SVM, где результаты большинства были немного лучше. Следовательно, классификаторы с ансамблями и без них попарно сравниваются, рассматривая DT как функцию объединения информации ансамбля.

Надежность системы

В этом подразделе описывается поведение классификатора RF^{DT} с учетом появления новых неисправностей. Графики для трех сценариев, сгруппированных для каждого класса неисправностей, показаны на рис. 4. Соответствующие числовые значения представлены в табл. 1. Для неисправности акселерометра средняя производительность снижается при удалении и замене по сравнению с первоначальной диагностикой неисправности [8]. Результаты процедуры понижения Холма показаны в табл. 2. Входными параметрами процедуры понижения Холма являются $m = 3$ случая (оригинал, удаление и замена), следовательно, $q = \frac{m \cdot (m - 1)}{2} = 3$. Соответственно для

уровня значимости $\alpha = 0,05$ и $q = 3$ динамический порог уравнения рассчитывается как $\left\{ \frac{\alpha}{q+1-1}, \frac{\alpha}{q+1-2}, \alpha \right\} = \left\{ \frac{1}{60}, \frac{1}{40}, \frac{1}{20} \right\}$.

Значения p в табл. 2 значительно превышают этот динамический порог после упорядочения в порядке возрастания. Следовательно, это указывает на то, что система способна обрабатывать новые неисправности в случае, если она должна быть переобучена, чтобы справиться с дополнительными схемами неисправностей. Этот факт важен с практической точки зрения, потому что новый тип ошибки может быть воспринят экспертом со временем. В этом случае система должна иметь возможность обрабатывать новый сбой, не снижая производительность со старыми шаблонами [9].




Рис. 3. Блок-схема результирующих макро-F-мер для каждой модели классификатора. Верхний индекс обозначает объединение информации ансамбля

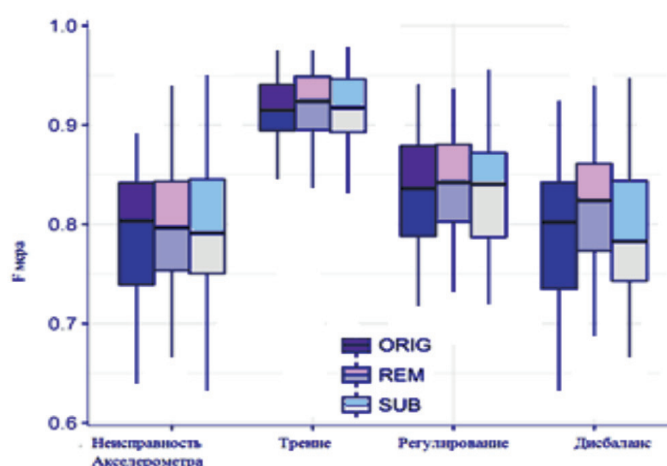


Рис. 4. Сценарии появления новых неисправностей

Таблица 1

Числовые значения для классов неисправностей

Статистика	ORIG1	REM1	SUB1	ORIG2	REM2	SUB2	ORIG3	REM3	SUB3	ORIG4	REM4	SUB4
Минимум	0,6568	0,6277	0,8214	0,8280	0,8322	0,7166	0,7236	0,7183	0,6228	0,6748	0,6621	0,6568
1 подход	0,7625	0,7596	0,9051	0,9059	0,9036	0,7974	0,8122	0,7964	0,7439	0,7826	0,7520	0,7625
Медиана	0,8059	0,8005	0,9260	0,9350	0,9284	0,8461	0,8523	0,8505	0,8118	0,8340	0,7924	0,8059
3 подход	0,8533	0,8554	0,9521	0,9606	0,9576	0,8895	0,8910	0,8825	0,8525	0,8714	0,8540	0,8533
Максимум	0,9597	0,9707	0,9951	0,9922	0,9989	0,9522	0,9482	0,9674	0,9358	0,9509	0,9589	0,9597

Таблица 2

Результаты процедуры понижения Холма

Часть	ORIG vs REM	ORIG vs SUB	REM vs SUB
Неисправность акселерометра	0,716884	0,828107	0,989886
Трение	0,422648	0,726995	0,701717
Регулирование	0,555105	0,913041	0,649139
Дисбаланс	0,136501	0,99292	0,086956

Выводы

В этой статье исследовалось использование ансамблей для совмещения в пакеты с шаблонами решений вместе с различными архитектурами классификатора, чтобы определить наиболее подходящую модель для предлагаемой системы диагностики погружных насосов. Выбранная архитектура классификатора RF^{DT} была исследована для особых ситуаций возникновения неисправностей, чтобы выполнить стресс-тест надежности системы диагностики. Сначала определенная ошибка была удалена из базы данных. Затем образцы ошибки были включены в нормальный класс. В обоих сценариях диагностические показатели системы не претерпели существенных изменений, о чем свидетельствуют результаты процедуры Холма по проверке гипотезы о том,

что классификаторы имеют сходные показатели производительности. Сейчас эксперты, способные качественно и безошибочно контролировать всю процедуру тестирования насоса, которая выполняется на заводе-изготовителе, встречаются очень редко. Результаты показали, что система может работать систематически исправно. Надлежащее обнаружение неисправностей позволяет избежать высоких затрат на ремонт (в пределах от 50 миллионов рублей), чтобы поднять на поверхность систему ЭЦН из подводных спутниковых скважин.

В будущей работе следует более тщательно изучить причины изменения производительности классификаторов и рассмотреть дополнительные классы неисправностей. Кроме того, данные от одного и того же моторного насоса собирались несколько раз, однако любые зависимости между датчика-

ми в этой работе игнорировались. Анализ, учитывающий корреляции между различными вибрационными сигналами, можно представить в качестве будущей работы, когда станут доступны данные от большего числа насосов. Методы глубокого обучения показали невероятную эффективность в различных областях исследований. Таким образом, некоторые одномерные методы свертки, такие как [10; 11], должны быть исследованы, чтобы попытаться заменить элементы ручной работы, разработанные для этой проблемы.

Список литературы

1. Toliyat H.A., Nandi S., Choi S., Meshgin-Kelk H. *Electric Machines: Modeling, Condition Monitoring, and Fault Diagnosis*. CRC Press, 2016. 170 p.
2. Sharma R., Pandey N. A neural network model for electric submersible pump surveillance. 2016 International Conference on Communication and Signal Processing (ICCSPP). IEEE. 2016. С. 2083–2088.
3. Семенкин Е.С. Метод обобщенного адаптивного поиска для синтеза систем управления сложными объектами. М.: МАКС Пресс, 2012. 320 с.
4. Большунов А.В., Мостакалов К.А. Методика диагностики фактического состояния и неисправностей установок электроцентробежных насосов (УЭЦН) в реальном времени с использованием промысловых, электротехнических и геологических параметров // *Успехи современного естествознания*. 2016. № 10. С. 15–17.
5. Еникеев Р.М., Гарифулин А.Р. Интеллектуализация работы мехфонда // *Производственно-технический нефтегазовый журнал*. 2020. № 2. С. 39–44.
6. Трупова В.А. Система дифференциальных уравнений в пространстве одномерных касательных элементов второго порядка // *Вестник ИргТУ*. 2010. № 6. С. 295–298.
7. Большунов А.В., Волков П.В., Зятиков П.Н. Экспериментальное исследование аэромеханического метода для предотвращения гидратообразования при подготовке и транспортировке природного газа и конденсата // *Успехи современного естествознания*. 2018. № 9. С. 52–56.
8. Dmitriev V.V., Gandzha T.V., Dolganov I.M., Aksenova N.V. An algorithm to improve the speed and accuracy of analysis of chemical process systems operation. *Petroleum and Coal*. 2017. vol. 59. I. 3. P. 429–441.
9. Maystrenko A.V., Svetlakov A.A., Gandzha T.V., Dmitriev V.V., Aksenova N.V. Application of numerical signal differentiation methods to determine stationarity of A process. *Petroleum and Coal*. 2017. vol. 59. I. 3. P. 311–318.
10. Marius S., Pana I., Minescu M., Ichim A. Centrifugal Pump Monitoring and Determination of Pump Characteristic Curves Using Experimental and Analytical Solutions. *Processes*. 2018. T. 6. № 2. P. 18.
11. Капустин Н.М. Автоматизация производственных процессов в машиностроении (учеб. для вузов). М.: Высш. шк., 2011. 415 с.