



Современные тенденции и вопросы диагностики электрооборудования

Выпуск от 16 апреля 2021 года

В выпуске рубрики «Современные тенденции и вопросы диагностики электрооборудования» специалисты ООО «БО-Энерго» подготовили обзор актуальных публикаций, которые касаются инновационных разработок и новых технологий в области мониторинга и диагностики электрооборудования. В данном выпуске даны обзоры статей и докладов на следующие темы:

1. [Классификация состояния подшипников при помощи линейного дискриминантного анализа тока статора](#)
2. [Использование гистограммы частотных сдвигов для диагностического анализа сигналов](#)
3. [Определение дефектов в силовом трансформаторе по СВЧ-сигнала ЧР при помощи свёрточной нейронной сети](#)
4. [Диагностика ветрогенераторов при помощи машинного обучения по данным вибрации](#)
5. [Сравнение характеристик частичных разрядов при переменном и постоянном напряжении](#)
6. [Способ определения минимального числа и расстановки приборов волнового ОМП для определения мест повреждений в электрических сетях сложной структуры](#)
7. [Диагностика силовых трансформаторов при помощи обработки данных концентраций растворённых газов методом общих векторов](#)
8. [Вибрационная диагностика подшипников качения комбинацией методов машинного обучения](#)
9. [Диагностика состояния насосов по данным вибрации при помощи технологий Интернета вещей](#)
10. [Опыт разработки беспроводной системы сбора вибрационных данных](#)
11. [Способ мониторинга состояния машин при помощи разреженных данных вибрации](#)
12. [IoT-система контроля вибрационных характеристик](#)

Подписывайтесь также на наш [Телеграм](#) или [Твиттер](#) или используйте [электронную почту](#) для связи.

Классификация состояния подшипников при помощи линейного дискриминантного анализа тока статора

Источник: С. Р. Mbo'o and K. Hameyer, "Bearing damage diagnosis by means of the linear discriminant analysis of stator current feature," 2015 IEEE 10th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED), Guarda, Portugal, 2015, pp. 296-302, doi: 10.1109/DEMPED.2015.7303705.

<https://ieeexplore.ieee.org/abstract/document/7303705>

На прошедшем в 2015 году IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives группа исследователей из Университета Аахена в Германии предложила способ классификации состояния подшипников (здоровое-дефектное) по набору диагностических свойств, определяемому при помощи линейного дискриминантного анализа.

Исследователи исходили из того, что изменение спектральных характеристик потребляемого тока двигателя, происходящее в результате развития дефекта подшипника, можно описать при помощи набора свойств, определяемого непосредственно из этого спектра. При использовании набора наиболее значимых свойств можно выполнять классификацию состояния подшипника между здоровым и дефектным методами машинного обучения.

Для проверки метода исследователи использовали установку, состоящую из синхронного двигателя с постоянными магнитами, электромагнитного тормоза и регулятора скорости вращения. Установка запускалась с подшипниками без дефектов и с дефектами, и с разными параметрами: скоростью вращения 400 об/мин, 900 об/мин и 1500 об/мин и механическим усилием тормоза 400 Н, 1 кН и 2 кН. Для выделения диагностических свойств из энергетического спектра потребляемого тока выделялись узкие полосы частот, для каждой из которых рассчитывались стандартное отклонение, коэффициент эксцесса (куртозис), коэффициент асимметрии, коэффициент пика, коэффициент прямоугольности.

Для определения наиболее значимых для классификации состояния свойств применялся линейный дискриминантный анализ. В этом методе используется понятие функции-дискриминанта, являющейся линейной комбинацией свойств. Коэффициенты линейной комбинации определяются при обучении модели таким образом, чтобы функция-дискриминант наиболее полно характеризовала режим работы. Пример результата применения линейного дискриминантного анализа показан в таблице ниже.

Loadcase	x_{cr}	x_{cl}	x_{kr}	x_{sh}	x_{sk}	$\Delta_r(x_{std})$
LC1	+	0	0	-	-	-
LC2	0	0	-	-	-	+
LC3	+	0	0	-	-	-
LC4	+	0	0	-	-	-
LC5	+	0	0	-	-	0

Результат применения линейного дискриминантного анализа. Строки таблицы соответствуют режимам работы, столбцы таблицы соответствуют свойствам. Ячейки таблицы показывают значимость свойства для классификации состояния подшипника в заданном режиме работы: высокая (+), средняя (0), низкая (-)

Определённые таким образом свойства использовались в модели Байесовского обучения, которая выполняла классификацию состояния подшипника. В этой модели использовалась априорная гипотеза о начальном бездефектном состоянии подшипника. По значениям комбинации значимых свойств затем рассчитывалась апостериорная гипотеза, описывающая состояние подшипника на основе изменившихся свойств. Результатом выполнения модели было отнесения состояния подшипника к здоровому или дефектному.

Результаты классификации состояния подшипников в разных режимах работы двигателя показаны ниже.

	Faulty group 1					Faulty group 2				
	LC1	LC2	LC3	LC4	LC5	LC1	LC2	LC3	LC4	LC5
Healthy	18 %	36 %	23 %	27 %	64 %	32 %	9 %	18 %	45 %	64 %
Faulty	82 %	64 %	77 %	73 %	36 %	68 %	91 %	82 %	55 %	36 %

Результаты классификации состояния подшипников. Строки таблицы – состояния (здоровое и дефектное), столбцы – режимы работы двигателя. В ячейках таблицы указаны точности классификации заданного состояния в заданном режиме работы

В заключении исследования отмечается, что точность классификации была приемлемой в большинстве случаев. В тех случаях, когда точность классификации была невысокой (60-70%), режим работы машины характеризовался низкой скоростью вращения и низкой нагрузкой. Классификация состояния подшипников в таких случаях сильно затруднена и должна подкрепляться дополнительными методами диагностики.

Использование гистограммы частотных сдвигов для диагностического анализа сигналов

Источник: M. Orkisz and J. Ottewill, "Diagnostic signal analysis using distribution of frequency gaps between spectral peaks," 2015 IEEE 10th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED), Guarda, Portugal, 2015, pp. 253-258, doi: 10.1109/DEMPED.2015.7303698.

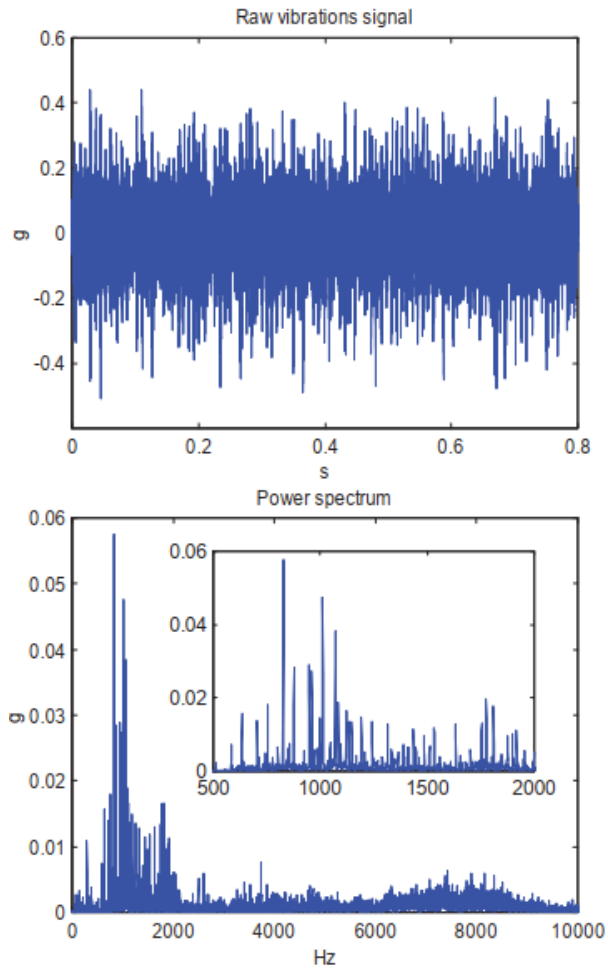
<https://ieeexplore.ieee.org/document/7303698>

Группа сотрудников исследовательского центра ABB в городе Краков, Польша, предложила метод анализа сигналов, основанный на построении гистограммы распределения частотных сдвигов между характерными пиками в спектре сигнала. Метод можно использовать вместо или наряду с анализом спектра сигналов вибрации, акустической эмиссии или потребляемого тока для диагностики состояния оборудования. Работа авторов была представлена на прошедшем в 2015 году IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives.

Суть метода состоит в следующем. В спектре записанного сигнала выделяются характерные гармоники по простому превышению амплитудой гармоники граничного значения, которое задаётся пользователем. Далее выполняется итеративный перебор всех характерных гармоник в порядке возрастания частоты. В каждой итерации для рассматриваемой гармоники рассчитывается разница и условный вес между рассматриваемой гармоникой и всеми остальными гармониками, чья частота меньше рассматриваемой. Условный вес показывает, насколько амплитуда одной гармоники отличается от другой, для его расчёта могут использоваться разные формулы. В самом простом подходе условный вес определяется простой разницей амплитуд гармоник. После расчёта разницы частот и условных весов строится гистограмма распределения весов по частотным сдвигам. При наличии в спектре исходного сигнала характерных пиковых гармоник дефектов, гистограмма частотных сдвигов также будет содержать характерные пики, по характеристикам которых можно выполнять диагностику оборудования.

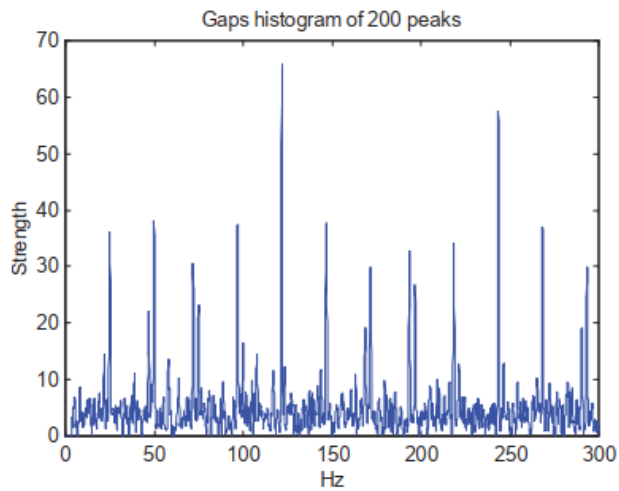
Работа метода была проверена на трёх типах сигналов: вибрации, акустической эмиссии и потребляемого тока. Во всех случаях сигналы записывались на двигателе, имеющем дефектный подшипник.

Осциллограмма и спектр сигнала вибрации показаны ниже.



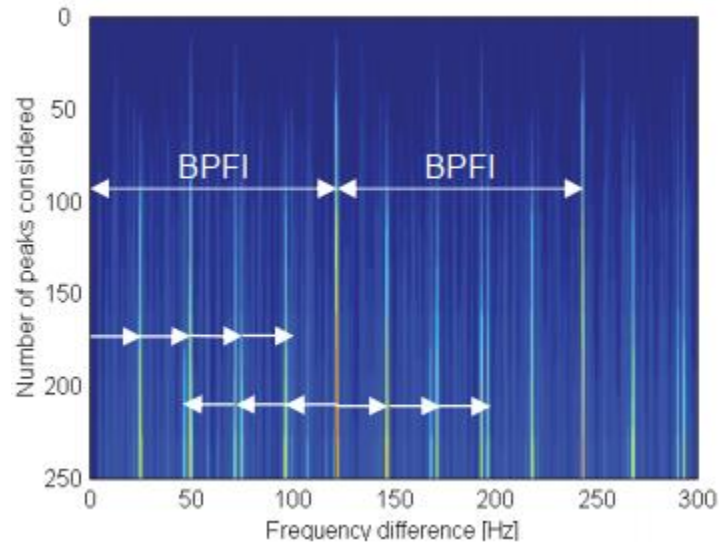
Осциллограмма и спектр вибрации. На спектре дополнительно увеличен участок, содержащий характерные гармоники дефекта

Гистограмма частотных сдвигов, рассчитанная по вибрации, показана ниже.



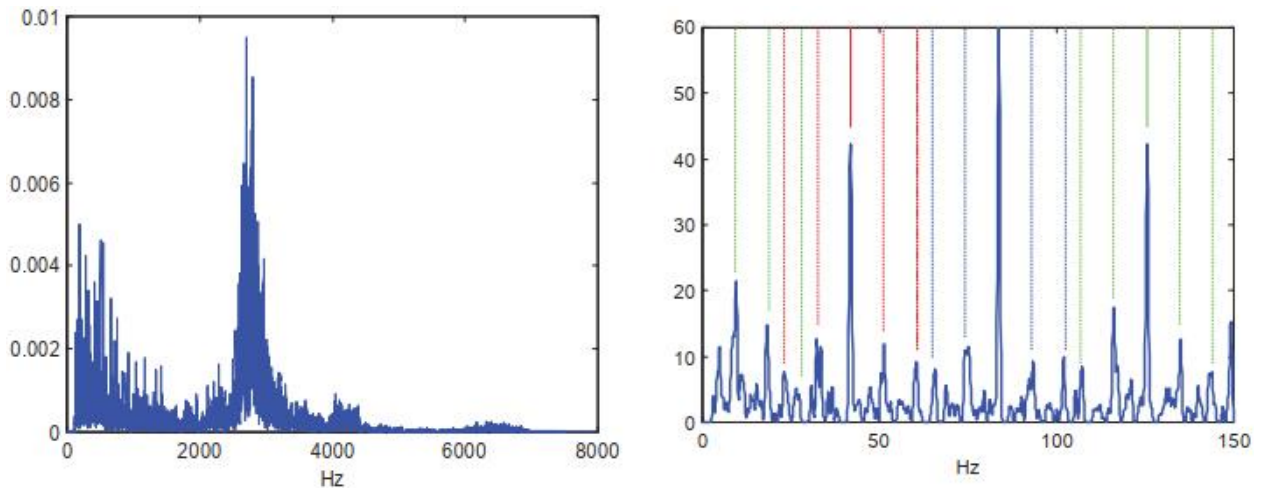
Гистограмма частотных сдвигов сигнала вибрации

Анализ осциллограммы показывает, что она содержит распределения пиков двух типов: первый тип содержит частоты, кратные 121.77 Гц. Второй тип содержит боковые гармоники шагом 24.96 Гц основной частоты вращения. На изображении ниже в явном виде показаны пики обоих типов.




Пики двух типов в гистограмме частотных сдвигов. На положения пиков указывают стрелки

Аналогичные данные были получены при анализе сигналов акустической эмиссии и потребляемого тока. Спектры и гистограммы сигналов показаны ниже.



Спектр (слева) и осциллограмма частотных сдвигов (справа) акустического сигнала. На гистограмме разноцветными линиями показаны боковые гармоники относительно частоты вращения



Спектр (слева) и осциллограмма частотных сдвигов (справа) потребляемого тока

Таким образом, в гистограмме всех трёх сигналов присутствуют характерные пики, указывающие на развивающийся дефект, что позволяет использовать предложенный метод для диагностики.

Как указано в заключении исследования, преимуществами метода являются слабая подверженность зашумлённости спектра и отсутствие необходимости знать заранее характерные частоты характерных гармоник дефекта. Вместе с тем, отмечают исследователи, метод работает хуже на нестационарных сигналах. Также, при большой степени развития дефекта метод не будет давать существенных преимуществ по сравнению с классическим подходом с анализом спектра. Оба метода будут одинаково эффективны.

Определение дефектов в силовом трансформаторе по СВЧ-сигнала ЧР при помощи свёрточной нейронной сети

Источник: T. -D. Do, V. -N. Tuyet-Doan, Y. -S. Cho, J. -H. Sun and Y. -H. Kim, "Convolutional-Neural-Network-Based Partial Discharge Diagnosis for Power Transformer Using UHF Sensor," in IEEE Access, vol. 8, pp. 207377-207388, 2020, doi: 10.1109/ACCESS.2020.3038386.

<https://ieeexplore.ieee.org/document/9261485>

В ноябре 2020 года журнал IEEE Access опубликовал статью группы авторов из Южной Кореи, в которой описывался метод определения типа развивающегося дефекта в силовом трансформаторе по данным, снимаемым СВЧ-датчиком, устанавливаемым в дренажный вентиль трансформатора. Для обработки данных авторы использовали свёрточную нейронную сеть, которая получала PRPD-распределения.

Для сбора данных авторы использовали установку, состоящую из корпуса трансформатора, источника испытательного напряжения, делителя напряжения, искусственной камеры для имитации дефектов, датчика и системы сбора данных. Схема установки показана ниже.





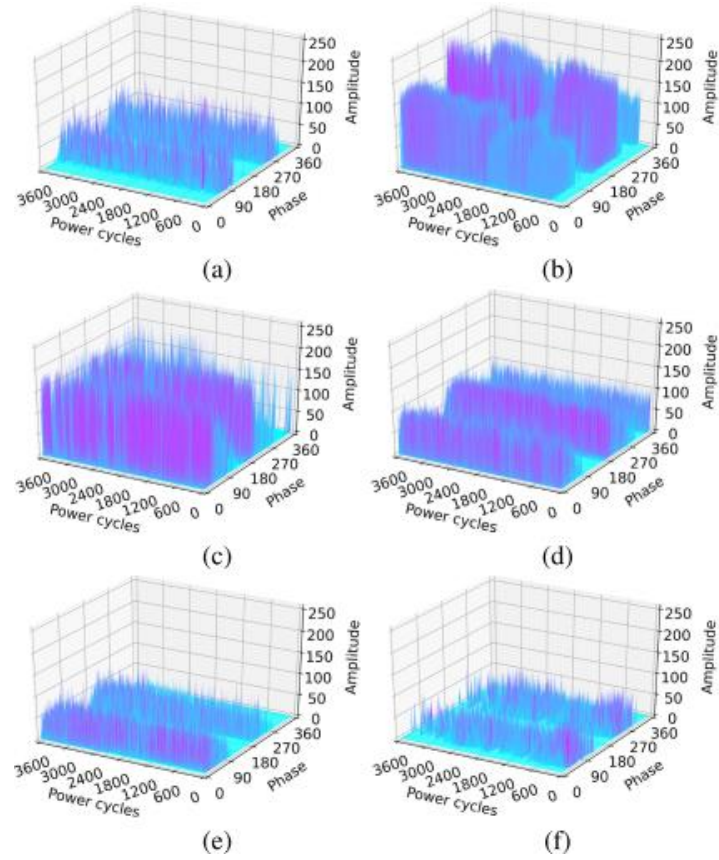
Схема установки

Дефекты создавались внутри отдельной камеры внутри корпуса трансформатора. Имитировались 6 видов дефектов. Изображения камеры со всеми дефектами показано ниже.

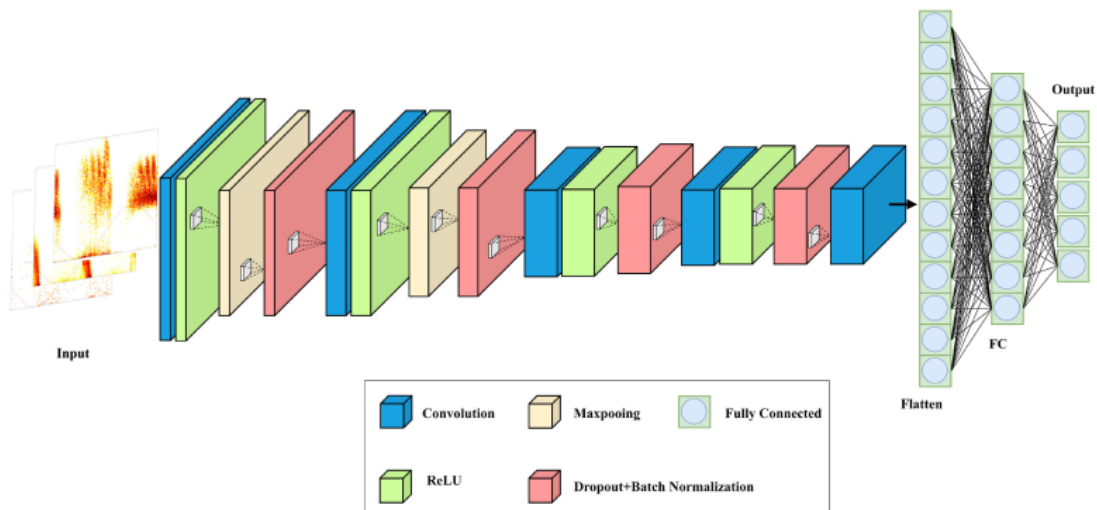


Камера для имитации дефектов

В ходе замеров были записаны PRPD-распределения, характерные для каждого вида дефекта. Эти распределения затем использовались либо напрямую как входы свёрточной нейронной сети, либо опосредованно, после снижения размерности данных до двух. Примеры записанных распределений и схема сети показаны ниже.



Записанные PRPD-распределения шести дефектов



Структура сети

Свёрточная сеть состояла из большого числа слоёв разного типа, выполняющих разные функции преобразования данных, включая: выделение характерных свойств, применение операции свёртки, нормализацию данных. Авторы использовали такой тип нейронной сети из-за её потенциальной возможности обрабатывать сложные распределения данных. Для проверки точности определения дефекта свёрточной сетью авторы сравнили результаты, полученные при помощи иных алгоритмов классификации, включая метод опорных векторов и нейронную сеть прямого распространения. Полученная точность классификации предложенным методом, по информации авторов составила 99,64% и превышала точности классификации другими методами.


Мониторинг состояния редукторов ветрогенераторов при помощи машинного обучения

Источник: Vamsi Inturi, N. Shreyas, Karthick Chetti, G.R. Sabareesh, *Comprehensive fault diagnostics of wind turbine gearbox through adaptive condition monitoring scheme, Applied Acoustics, Volume 174, 2021, 107738, ISSN 0003-682X*

<https://www.sciencedirect.com/science/article/abs/pii/S0003682X20308422>

Исследователи из индийского института науки и технологии Бирла опубликовали статью о результатах исследования применимости различных методов машинного обучения для диагностики состояния редукторов ветрогенераторов по данным вибрации и акустических измерений. Статья была опубликована в издании Applied Acoustics в марте 2021 года.

Исследование основывалось на данных, собранных на имитационной модели редуктора, показанной ниже.



Имитационная модель редуктора ветрогенератора

Данные включали в себя измерения вибрации и акустической эмиссии валов, вращающихся на трёх скоростях: высокой (HSS), средней (ISS) и низкой (LSS). Степень износа редуктора задавалась искусственным высверливанием отверстий в подшипниках и электроэрозионной обработкой зубцов шестерен.

Схема методологии исследования показана ниже.

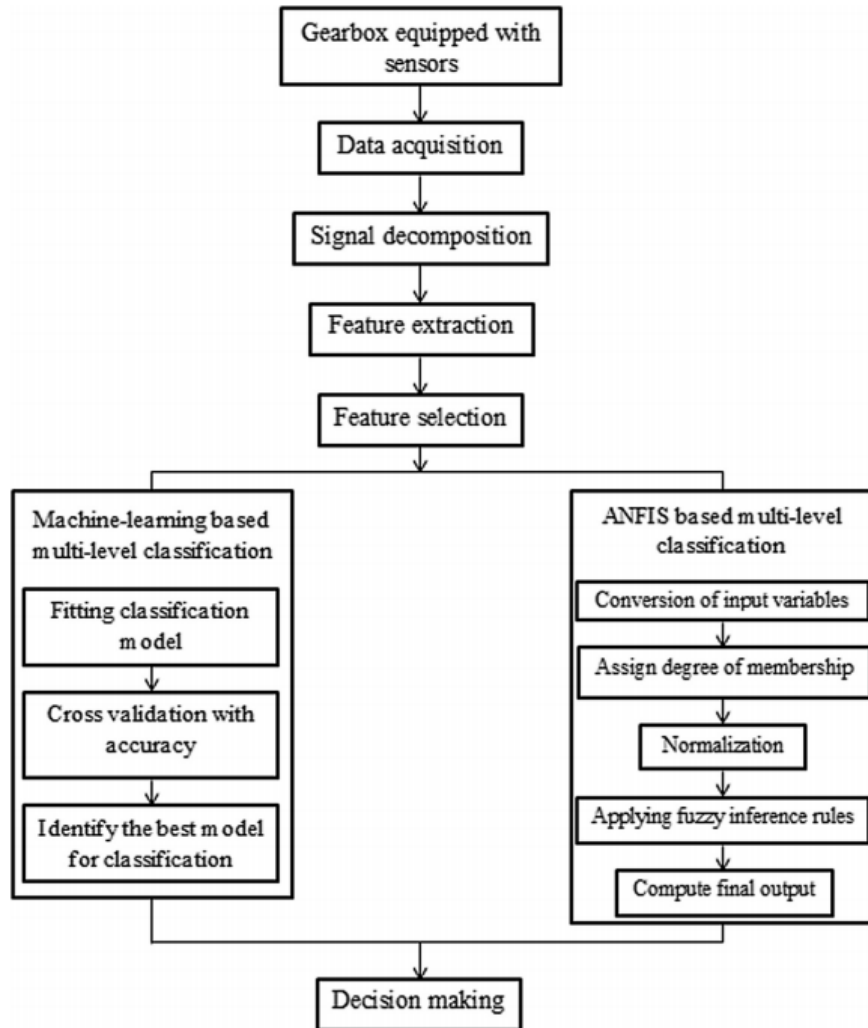
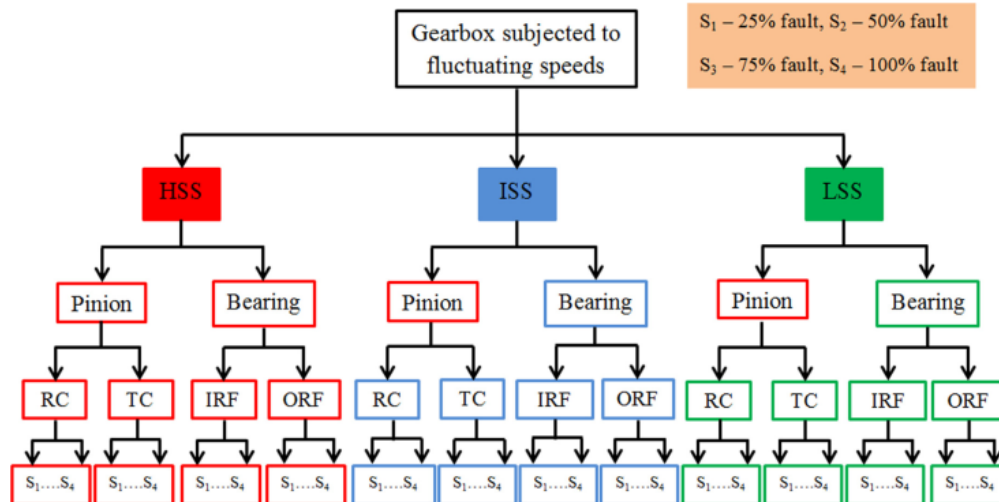


Схема методологии исследования

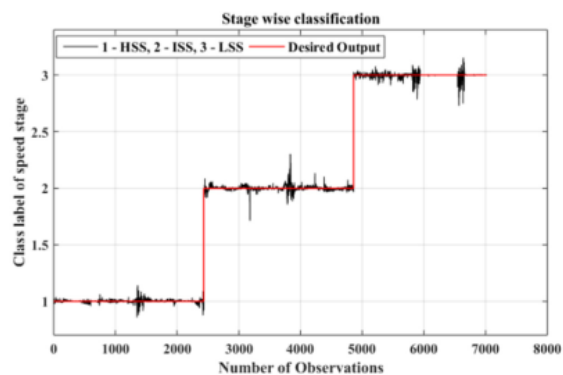
В исследовании по собранным сигналам вибрации и акустической эмиссии рассчитывались коэффициенты четырёхступенчатого вейвлет-преобразования функцией Хаара. Далее выполнялось определение наиболее значащих свойств, для чего строилось дерево принятия решения, структура которого показана ниже.



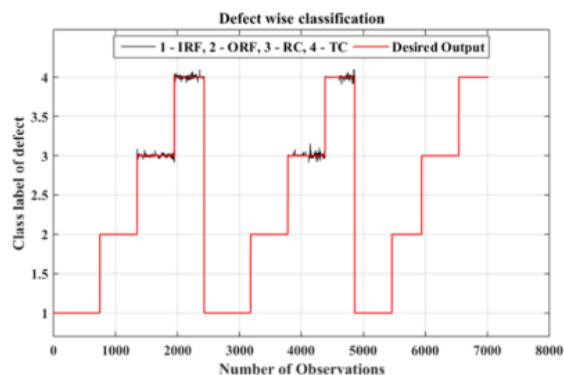
Дерево принятия решения

Набор выделенных свойств затем обрабатывался набором алгоритмов классификации: *k*-ближайших соседей, метода опорных векторов, методом дискриминантного анализа, и специально разработанным исследователями методом нейронно-нечёткой обучающейся системы (ANFIS).

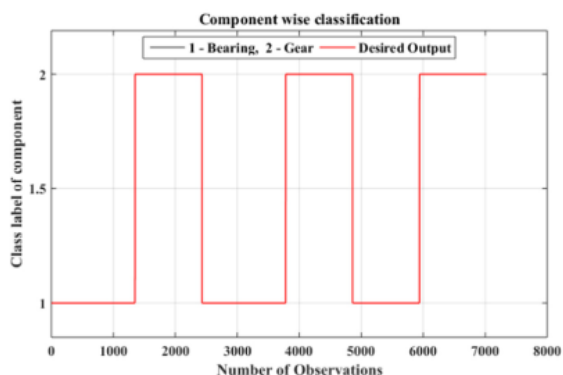
Структура модели ANFIS являлась пятислойной нейронной сетью. Первый слой сети выполнял фаззификацию входных данных. Второй слой выполнял нормализацию данных. Остальные слои выполняли классификацию состояния редуктора. Примеры результатов, получаемых при помощи ANFIS и разного уровня свойств, определяемого уровнем вейвлет-преобразования, показаны ниже.



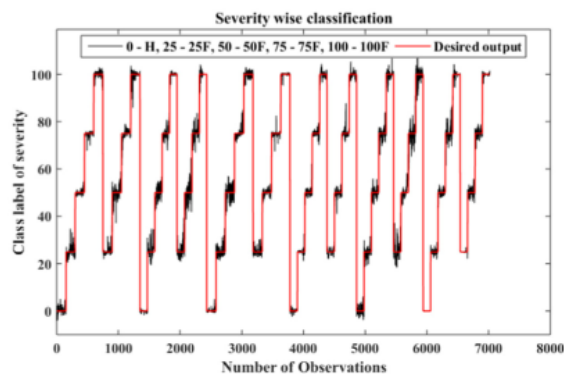
(a) First-level classification



(c) Third-level classification



(b) Second-level classification



(d) Fourth-level classification

Результаты ANFIS. По горизонтальной оси – индекс испытания, по вертикальной – класс состояния редуктора. Красная линия – истинное состояние, чёрная – предсказанное при помощи ANFIS

Согласно представленным авторами результатам, наибольшая точность классификации состояния редуктора была достигнута при помощи метода опорных векторов и составила 82,52%. Точность определения при помощи ANFIS составила 92%.

Диагностика ветрогенераторов при помощи машинного обучения по данным вибрации

Источник: Yu Pang, Limin Jia, Xuejia Zhang, Zhan Liu, Dazi Li, *Design and implementation of automatic fault diagnosis system for wind turbine, Computers & Electrical Engineering, Volume 87, 2020, 106754, ISSN 0045-7906*

<https://www.sciencedirect.com/science/article/abs/pii/S0045790620306091>

Группа исследователей из Китая предложила способ контроля состояния ветрогенераторов по данным вибрации главного редуктора. В способе применяется метод построения набора диагностических свойств, который затем обрабатывается нейронной сетью. Работа авторов была опубликована в издании *Computer and Electrical Engineering* в октябре 2020 года.

Общая схема метода показана ниже.

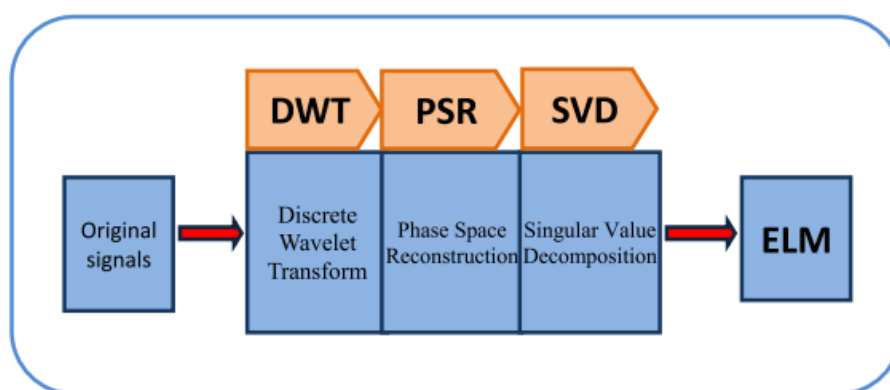



Схема предложенного метода

В методе используются данные виброускорения крышки редуктора. К данным применяется вейвлет-преобразование, результатом которого является набор коэффициентов, соответствующих многоступенчатому применению фильтров нижних и верхних частот. К набору выделенных коэффициентов затем применяется метод реконструкции фазового пространства, который формирует двумерную матрицу, строки которой являются подмножествами вейвлет-коэффициентов с разным сдвигом относительно начала общего множества рассчитанных коэффициентов. К полученной матрице затем применяется метод сингулярного разложения, в котором рассчитывается ковариация разных частей матрицы. Результатом является матрица размером 3×3 , составленная из ковариаций элементов предыдущей матрицы. Физический смысл сингулярного разложения состоит в уменьшении размерности начальной матрицы с сохранением диагностической информации, содержащейся в ней. Далее, по значениям элементов матрицы, рассчитывается набор сингулярных чисел матрицы, которые подаются на вход нейронной сети экстремального машинного обучения, состоящей из одного входного, одного промежуточного и одного выходного слоя. Отличие такой нейронной сети от обычной сети прямого распространения состоит в том, что при обучении в ней рассчитываются только веса нейронных связей между промежуточным и выходным слоями. Это позволяет значительно сократить время обучения за счёт небольшой потери точности. Выходом нейронной сети является отнесение состояния ветрогенератора к бездефектной или одной из дефектных категорий.


Исследователи проверили работу метода на одном из ветрогенераторов энергосистемы Китая. При исследовании моделировались бездефектный режим работы, работа с дефектом электрогенератора и работа с механическим дефектом редуктора.

Пример результатов разложения сигнала виброускорения показан ниже.




Распределения рассчитанных вейвлет-коэффициентов в бездефектном режиме работы. Буква А соответствует фильтру высоких частот, В фильтру низких частот. Число после буквы показывает ступень вейвлет-преобразования

Визуализация значений матрицы фазового пространства показана ниже. На изображении показан результат упрощённого случая приведения распределения вейвлет-коэффициентов к матрице фазового пространства с тремя столбцами. Каждая из строк матрицы фазового пространства использовалась как координаты точки в трёхмерном пространстве.



Визуализация матриц фазового пространства: а) бездефектного режима, б) с дефектом редуктора, с) с дефектом генератора

По полученным затем матрицам ковариаций были рассчитаны наборы трёх сингулярных чисел. Визуализация отличия разных режимов работы ветрогенератора по наборам значений сингулярных чисел показана ниже.



Визуализация режима работы ветрогенератора, координаты которого являются сингулярными числами матрицы ковариаций. Зелёная точка – бездефектный режим, красная – дефект редуктора, синяя – дефект генератора

По данным авторов исследования, точность классификации предложенным методом составила 99,97% на выборке из 300 кейсов.

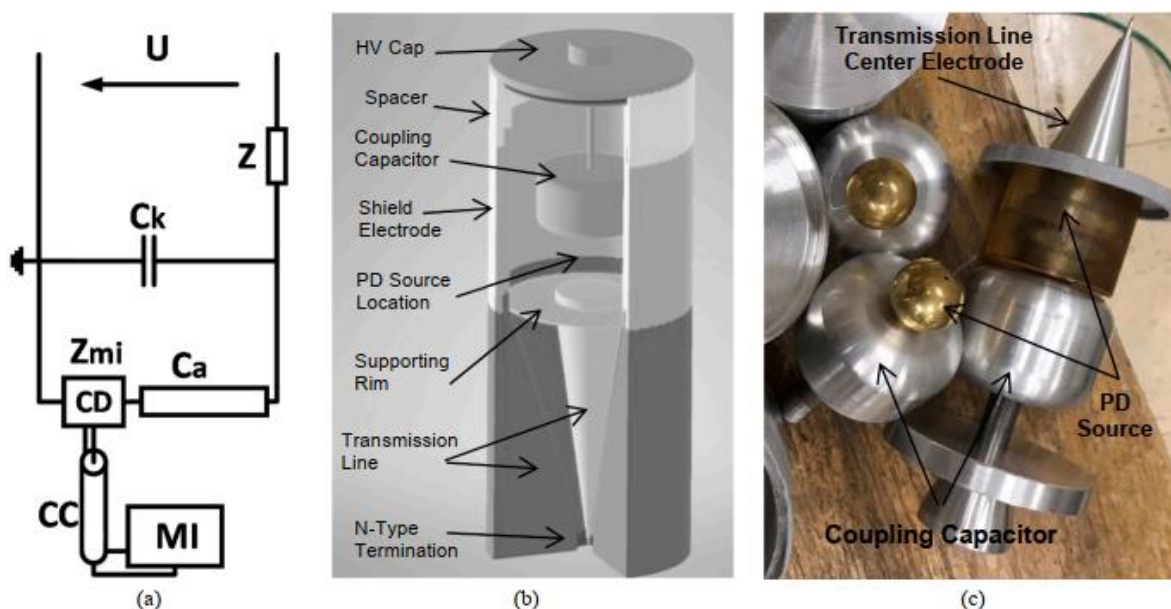
Сравнение характеристик частичных разрядов при переменном и постоянном напряжении

Источник: Mojtaba Rostaghi-Chalaki, Kamran Yousefpour, Joni Klüss, Mehmet Kurum, J. Patrick Donohoe, Chanyeop Park, Classification and comparison of AC and DC partial discharges by pulse waveform analysis, International Journal of Electrical Power & Energy Systems, Volume 125, 2021, 106518, ISSN 0142-0615

<https://www.sciencedirect.com/science/article/abs/pii/S0142061520326685>

В феврале 2021 года в издании International Journal of Electrical Power and Energy Systems была опубликована статья с результатами исследования, проведенного группой авторов из США и Швеции. В исследовании рассматривался вопрос об отличии характеристик ЧР от дефекта одного типа в условиях работы под постоянным или переменным напряжением.

Исследование проводилось на модели дефекта, включенного в измерительную схему согласно МЭК 60270. Изображение испытательной установки показано ниже.

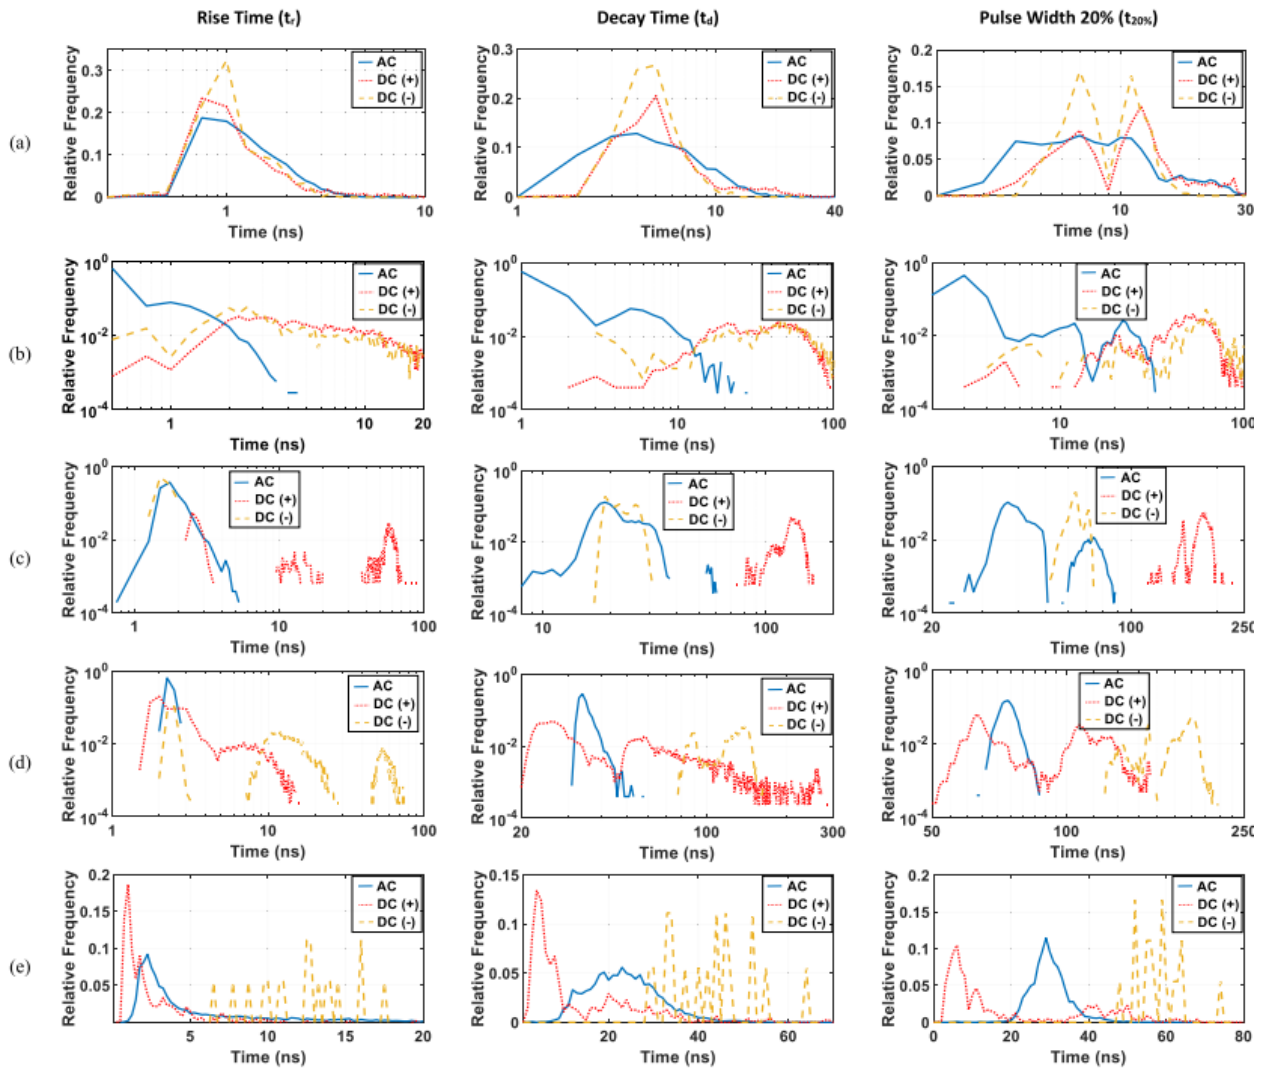


Испытательная установка: а) измерительная схема, состоящая из источника испытательного напряжения (U), фильтра (Z), измерительного конденсатора (C_k), объекта испытаний (C_a), соединительного кабеля (CC), измерительного прибора (MI); б) строение объекта испытаний, в) изображение объекта испытаний

Объект испытаний, выполняющий имитацию дефекта изоляции, представлял собой полый металлический цилиндр, внутрь которого помещались электроды разной формы, имитирующие разные виды дефектов. Для измерения характеристик ЧР использовался прибор Omicron MPD 600. При испытаниях в объекте испытаний имитировались коронный разряд, внутренний разряд в полости (классический ЧР), поверхностный разряд, плавающий электрод. На установку подавалось переменное и постоянное положительное и отрицательное напряжения. Во время испытаний контролировались характеристики индивидуальных импульсов ЧР и характеристики распределений импульсов. К характеристикам индивидуальных импульсов относились: длительность переднего фронта, время затухания импульса, ширину импульса. К характеристикам

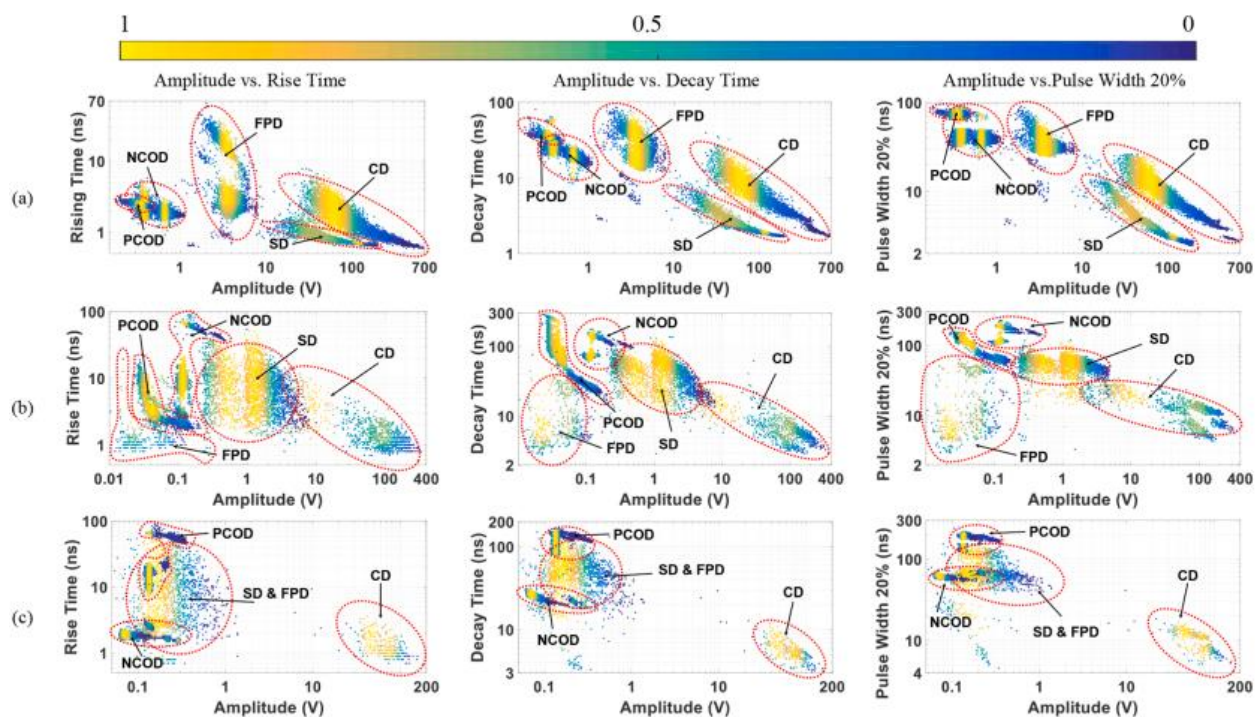
распределений относились картины распределения импульсов по амплитудам и длительностям переднего фронта.

Распределения характеристик индивидуальных импульсов показаны ниже.



Распределения характеристик индивидуальных импульсов. Типы дефектов: а) внутренний разряд, б) поверхностный разряд, в) отрицательный коронный разряд, г) положительный коронный разряд, д) плавающий электрод. Столбцы, слева направо: длительность переднего фронта, время затухания, ширина импульса. На каждом графике горизонтальная ось соответствует значению характеристики, вертикальная – относительной частоте появления значения характеристики, разные цвета линий соответствуют разным типам напряжения

Полученные характеристики распределений показаны ниже.



Характеристики распределений, а) при переменном напряжении, б) при постоянном положительном напряжении, в) при постоянном отрицательном напряжении. Разные обведённые области на графиках соответствуют разным типам дефектов. На каждом графике горизонтальная ось соответствует амплитуде, вертикальная – длительности переднего фронта (первый столбец графиков), времени затухания (второй столбец), ширине импульса (третий столбец). Цвет точек в распределениях соответствует нормализованной частоте появления импульсов с заданными характеристиками

После обработки результатов авторы сформулировали основные выводы исследования. Была отмечена низкая корреляция между характеристиками ЧР при постоянном и переменном напряжении, что говорит о необходимости использования отдельных подходов для работы с обоими видами напряжения. Как правило, амплитуда импульсов ЧР была ниже при постоянном напряжении. Формы импульсов ЧР при постоянном напряжении были более многообразны, чем при переменном.

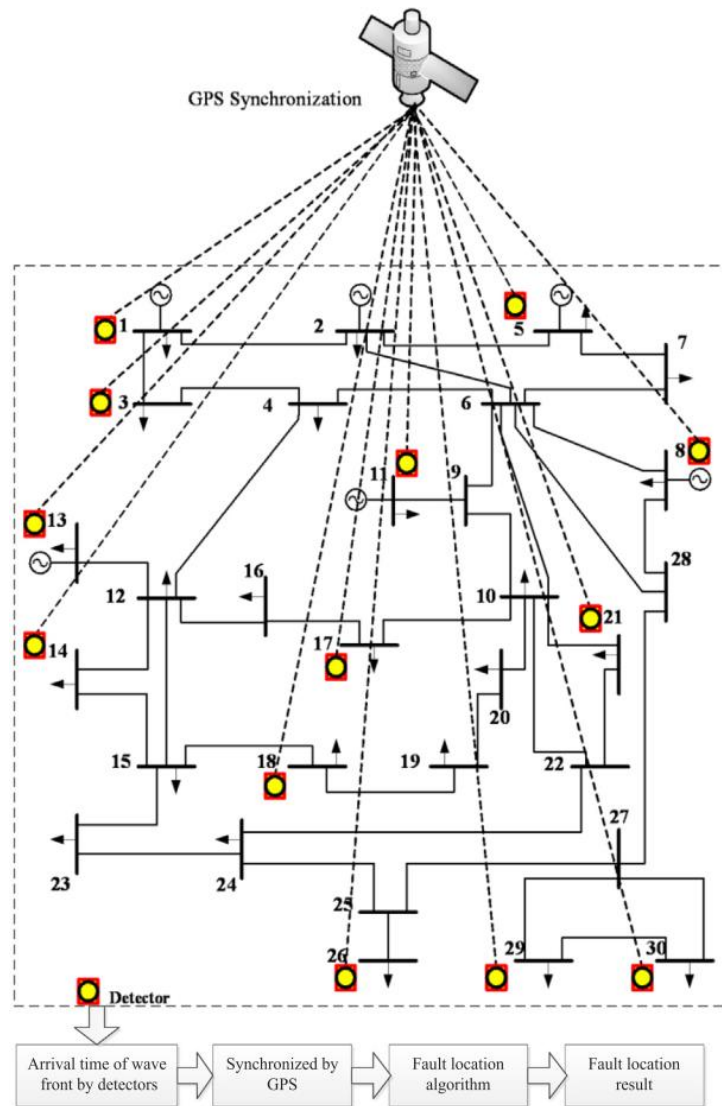
Способ определения минимального числа и расстановки приборов волнового ОМП для определения мест повреждений в электрических сетях сложной структуры

Источник: Moslem Salehi, Ali Akbar Motie Birjandi, Xinzhou Dong, Determining minimum number and placement of fault detectors in transmission network for fault location observability, International Journal of Electrical Power & Energy Systems, Volume 124, 2021, 106386, ISSN 0142-0615

<https://www.sciencedirect.com/science/article/abs/pii/S0142061520314009>

Группа авторов из Ирана и Китая предложила способ определения минимального числа и расстановки приборов волнового определения мест повреждений (ОМП) в сетях сложной структуры. Способ основан на графовом представлении сети и решении задачи численной оптимизации. Работа авторов была опубликована в издании International Journal of Electrical Power & Energy Systems в январе 2021 года.

Авторы рассмотрели задачу, в которой в качестве исходных данных задана сложная структура сети, в некоторых точках которой расставлены приборы волнового ОМП. Пример такой сети показан ниже.

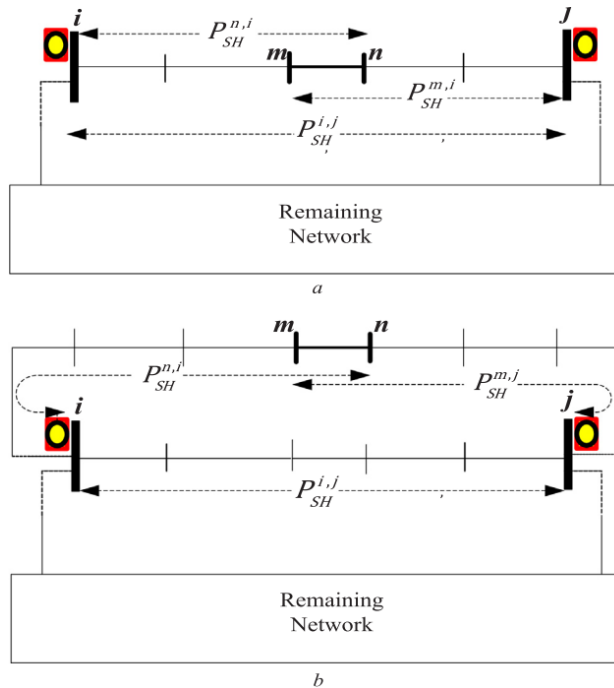


Структура разветвлённой сети с приборами волнового ОМП

Авторы рассмотрели возможные типы расположения участка m - n сети, на котором произошло короткое замыкание, относительно каждой пары i - j приборов ОМП. Таких типов шесть:

1. Участок m - n находится на кратчайшем пути между i и j , кратчайший путь от m к j проходит через n и кратчайший путь от n к i проходит через m .
2. Участок m - n не находится на кратчайшем пути между i и j , но кратчайший путь от m к j проходит через n и кратчайший путь от n к i проходит через m .
3. Участок m - n не находится на кратчайшем пути между i и j , кратчайший путь от m к j проходит через n , но кратчайший путь от n к i не проходит через m .
4. Участок m - n не находится на кратчайшем пути между i и j , кратчайший путь от m к j не проходит через n , но кратчайший путь от n к i проходит через m .
5. Участок m - n не находится на кратчайшем пути между i и j , кратчайший путь от m к j не проходит через n и кратчайший путь от n к i не проходит через m .
6. Конец m участка m - n не соединён ни с какими иными узлами, кроме n . В этом случае участок является тупиковым.

Для иллюстрации схемы типов №№ 1 и 2 показаны ниже.

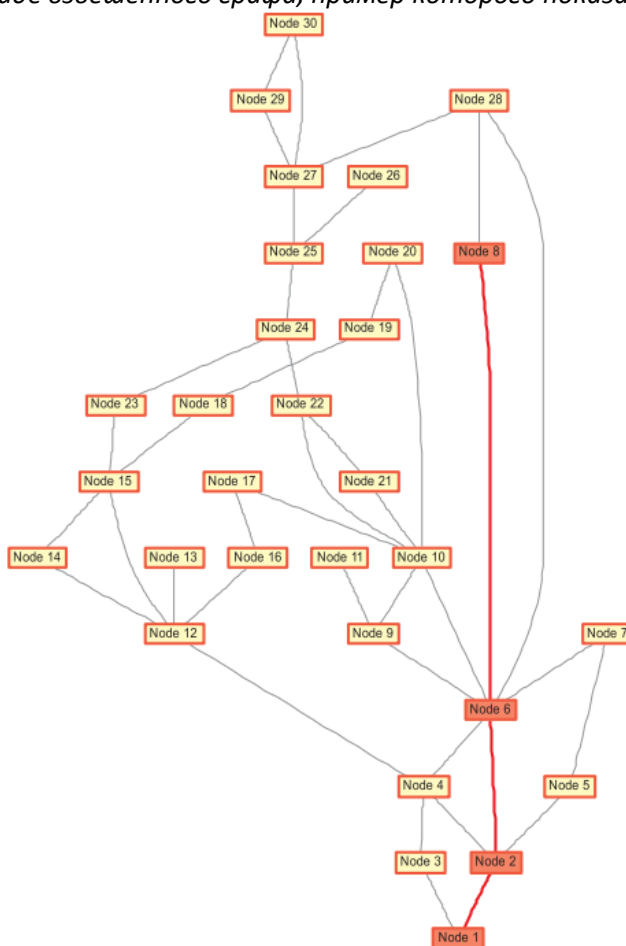


Схемы типов 1 и 2. Показаны концы участка $m-n$, приборы ОМП i и j , кратчайшие пути между приборами ($P_{SH}^{i,j}$), от конца m к прибору j ($P_{SH}^{m,j}$), от конца n к прибору i ($P_{SH}^{n,i}$), остальная сеть (Remaining network)

Для типов 1 и 2 однозначное определение места КЗ на участке $m-n$ по данным меток времени бегущих волн, зарегистрированных приборами i и j , возможно. Для типов № 3-6 однозначное определение невозможно. Это позволило авторам формализовать задачу оптимальной расстановки приборов ОМП следующим образом:

1. На тупиковых подстанциях всегда устанавливать приборы ОМП независимо от расстановки на остальных участках.
2. Для остальных участков сети решить задачу минимизации суммы элементов вектора, каждый элемент которого одному узлу сети (одной подстанции) и равен 0 если прибор ОМП не устанавливается или 1 если устанавливается. Задача оптимизации решается при условии, что все участки сети относятся к типам 1 или 2 после расстановки приборов.

Работа метода была проверена моделированием, в котором структура сети была представлена в виде взвешенного графа, пример которого показан на рисунке ниже.



Графовая структура сети

По информации авторов, результаты симуляции подтвердили применимость метода для решаемой задачи.

Диагностика силовых трансформаторов при помощи обработки данных концентраций растворённых газов методом общих векторов

Источник: Ali Kirkbas, Akif Demircali, Selim Koroglu, Aydin Kizilkaya, Fault diagnosis of oil-immersed power transformers using common vector approach, Electric Power Systems Research, Volume 184, 2020, 106346, ISSN 0378-7796

<https://www.sciencedirect.com/science/article/abs/pii/S0378779620301528>

Группа исследователей из университета Памуккале в Турции предложила способ диагностики состояния силовых трансформаторов по данным концентраций растворённых газов при помощи метода общих векторов, который ориентирован на применение в условиях недостаточности данных. Соответствующая статья была опубликована в издании *Electric Power Systems Research* в июле 2020 года.

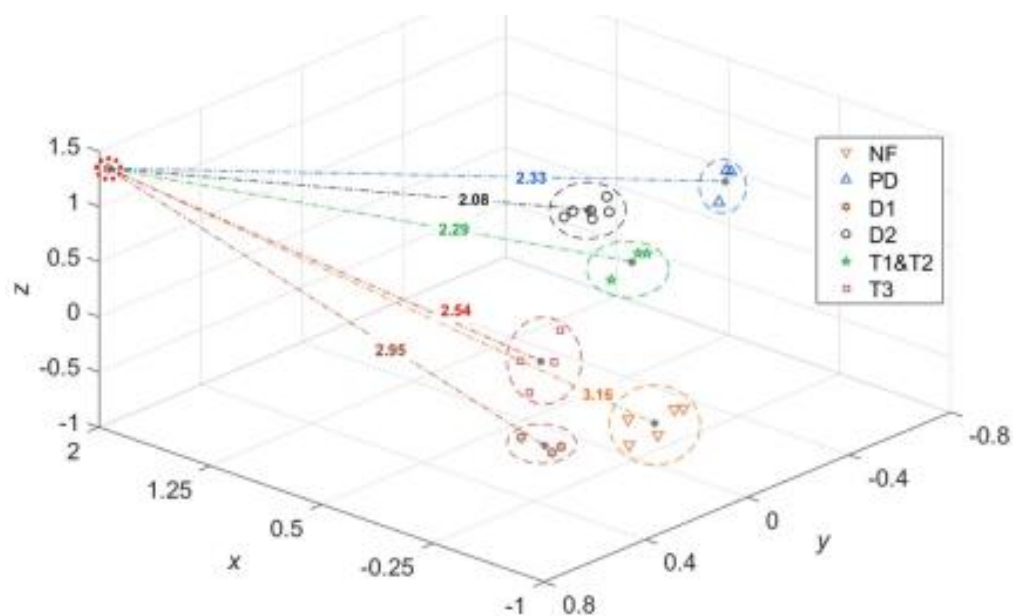
Суть метода общих векторов состоит в том, что каждый набор свойств, определяющих принадлежность к какому-либо классу (дефекту трансформатора), можно представить в виде произведения нескольких векторов, среди которых будут общий вектор и разностный вектор. Общий вектор содержит компоненты диагностических свойств, которые присущи рассматриваемому классу состояния, и являются общими для всех членов данного класса. Разностный вектор содержит компоненты, которые могут меняться произвольно, и не содержат значимой информации для принятия решения о принадлежности к классу. Применительно к диагностике трансформаторов, общий вектор может содержать отношения ключевых газов, по которым делается вывод о наличии определённого дефекта, а разностный вектор – информацию о несвязанных с дефектом колебаниях концентраций газов из-за колебаний нагрузки или температуры окружающей среды.

Применение метода общих векторов начинается с определения среднего вектора, равного среднему арифметическому всех векторов диагностических свойств, соответствующих одному состоянию трансформатора в тренировочном наборе данных. Затем для этого вектора определяется ковариационная матрица, составленная из попарных ковариаций элементов векторов диагностических свойств и среднего вектора. У ковариационной матрицы затем рассчитывается набор собственных значений. Из набора собственных значений затем выбирается часть значений выше определённой границы. Выбранные значения определяют многомерную плоскость в пространстве собственных значений. Остальные элементы, не превышающие выбранную границу, определяют другую многомерную плоскость, перпендикулярную первой плоскости. Эти плоскости называют разностной и общей. Разностную и общую плоскости определяют для всех классов состояний трансформатора в обучающей выборке.

Далее, для определения принадлежности трансформатора к выбранному классу состояния, к набору свойств текущего состояния трансформатора применяется аналогичная операция по выбору части собственных значений ковариационной матрицы, не превышающих определённую границу. Набор значений определяет многомерный вектор в пространстве, в котором заданы наборы разностных и общих плоскостей. Для каждой из общих плоскостей рассчитывается расстояние между вектором текущего состояния и его проекцией на общую плоскость. Среди всех рассчитанных расстояний выбирается наименьшее, т.е. выбирается та общая плоскость, к которой ближе всего находится вектор текущего состояния. Состояние, которому соответствует выбранная общая плоскость, будет соответствовать текущему состоянию трансформатора.

Для выбора наборов свойств, к которым применяется метод, авторы предложили использовать четыре набора: непосредственно концентрации, статистические свойства (стандартное отклонение, коэффициент перекоса, фактор запаса и т.д.), отношения ключевых газов и коэффициенты 5-уровневого вейвлет-преобразования. Свойства в каждом наборе прошли нормализацию и были объединены в один вектор свойств.

Для проверки метода авторы использовали набор данных из 1073 записей с 44 разных трансформаторов одного из энергопредприятий Турции. Примеры результатов применения метода показаны ниже.



Пример результатов применения метода. Группы точек разного цвета определяют общий плоскости разных состояний трансформатора. Пунктиром показаны расстояния между вектором текущего состояния и каждой из плоскостей

По информации авторов, точность диагностики составила 96%. Наряду с предложенным методом, авторы также проверили точность диагностики другими методами: методом ключевых газов, методом треугольника Дюваля и методом опорных векторов. Их точности диагностики составили соответственно 60%, 65% и 92%.

Вибрационная диагностика подшипников качения комбинацией методов машинного обучения

Источник: Jalali, S.K., Ghandi, H. & Motamedi, M. *Intelligent Condition Monitoring of Ball Bearings Faults by Combination of Genetic Algorithm and Support Vector Machines. J Nondestruct Eval* 39, 25 (2020)

<https://link.springer.com/article/10.1007%2Fs10921-020-0665-7>

Группа авторов из Ирана предложила способ диагностики подшипников качения по данным вибрации, в котором используется комбинация генетического алгоритма и нейронной сети для выделения диагностических свойств и метода опорных векторов для определения состояния подшипника. Работа была опубликована в феврале 2020 года в издании *Journal of Nondestructive Evaluation*.

Суть метода состояла в следующем. По записанным данным вибрации рассчитывался набор свойств частотного и временного представления. Временными свойствами были среднее значение, стандартное отклонение, действующее значение, коэффициент эксцесса и т.п. Частотные свойства были аналогичными, но рассчитывались по спектру вибрации. Далее, при помощи генетического алгоритма, из набора свойств выбиралось случайное подмножество свойств. Выбранное подмножество подавалось на вход нейронной сети, которая выполняла классификацию состояний. Специально разработанная функция затем определяла «качество» классификации в рамках тренировочного набора данных. Функция учитывала количество свойств в выбранном подмножестве и оценку точности классификации состояния, выполненную нейронной сетью. Значения функции, близкие к нулю, соответствовали малой ошибке классификации и малому набору выбранных свойств. Чем выше была ошибка классификации или чем больше свойств было выбрано для классификации, тем выше была пенализация, т.е. тем выше было значение функции. Степень пенализации за ошибку классификации и за избыточное число используемых свойств в функции задавалась при помощи весовых коэффициентов. Генетический алгоритм выполнял последовательные выборки наборов свойств, для каждого из которых рассчитывалось значение функции качества. Работа алгоритма завершалась, когда для какого-либо набора свойств было найдено низкое значение функции качества, которое не снижалось при использовании других наборов свойств. Таким образом, результатом применения генетического алгоритма и нейронной сети на тренировочном наборе данных был набор свойств, наилучшим образом подходящий для диагностики. При тестировании метода, когда информация о состоянии подшипника отсутствовала, этот набор свойств обрабатывался алгоритмом опорных векторов, который классифицировал состояние подшипника на основе общих характеристик наборов свойств, присущих каждому отдельному дефекту.

Работа метода была проверена на тестовом стенде, в котором подшипники качения работали при разной скорости вращения вала и с разными дефектами. Диапазон скоростей состоял из 1800, 3900 и 6600 об/мин, диапазон дефектов состоял из дефекта внешнего кольца (ORF), дефекта внутреннего кольца (IRF), дефекта тела качения (BRF) и дефекта, связанного с неплотным креплением корпуса подшипника (HBM). Пример матрицы результатов классификации, выполненной при помощи предложенного метода, показана ниже.

RPM	Classification tag	Non-fault	ORF	BRF	IRF	HBM
1800	Non-fault	24	1	0	4	6
	ORF	3	27	3	0	2
	BRF	0	3	29	1	2
	IRF	2	1	0	30	2
	HBM	1	1	2	3	28
3900	Non-fault	22	1	2	5	0
	ORF	4	20	1	4	5
	BRF	1	2	27	2	3
	IRF	2	1	3	25	4
	HBM	2	3	5	4	21
6600	Non-fault	23	4	3	4	1
	ORF	7	21	2	3	3
	BRF	4	4	19	2	6
	IRF	3	1	2	24	5
	HBM	0	3	6	2	24

Матрица результатов классификации бездефектного состояния и разных типов дефектов при разных скоростях вращения

По информации, предоставленной авторами статьи, точность диагностики подшипника, в целом, зависела от скорости вращения и весовых коэффициентов в функции оценки качества. Наилучшая точность, достигнутая при тестировании, составила 93,33%.

Диагностика состояния насосов по данным вибрации при помощи технологий Интернета вещей

Источник: Qinhua Hu, Elene F. Ohata, Francisco H.S. Silva, Geraldo L.B. Ramalho, Tao Han, Pedro P. Rebouças Filho, A new online approach for classification of pumps vibration patterns based on intelligent IoT system, Measurement, Volume 151, 2020, 107138, ISSN 0263-2241

<https://www.sciencedirect.com/science/article/abs/pii/S0263224119310048>

Группа исследователей из Дуньгуаньского технологического университета в Китае и Федерального университета Сеара в Бразилии опубликовала статью о собственном опыте разработки платформы вибродиагностики, в которой используются машинное обучение и технологии Интернета вещей. Статья была опубликована в издании Measurement в феврале 2020 года.

Платформа была реализована на тестовой установке, работающей в лаборатории кампуса университета Сеара. Установка состояла из центробежного водяного насоса, набора вентилей для регулирования напора воды через насос и набора датчиков вибрации, установленных на корпусе насоса. Использовались трёхосевые датчики MMA7361, выполненные на платформе Arduino. Датчики были оснащены беспроводным передатчиком для отправки сигналов на удалённый сервер. Изображение тестовой установки показано ниже.



Тестовая установка

Информация передавалась на сервер системы. Основными элементами сервера являлись вычислительная платформа LINDA (Lapisco Image Interface for Development of Applications) и база данных, реализованная на PostgreSQL. LINDA выполняла все расчёты и работала по технологии веб-сервера. PostgreSQL выполняла хранение всех данных. Общая схема системы показана ниже.

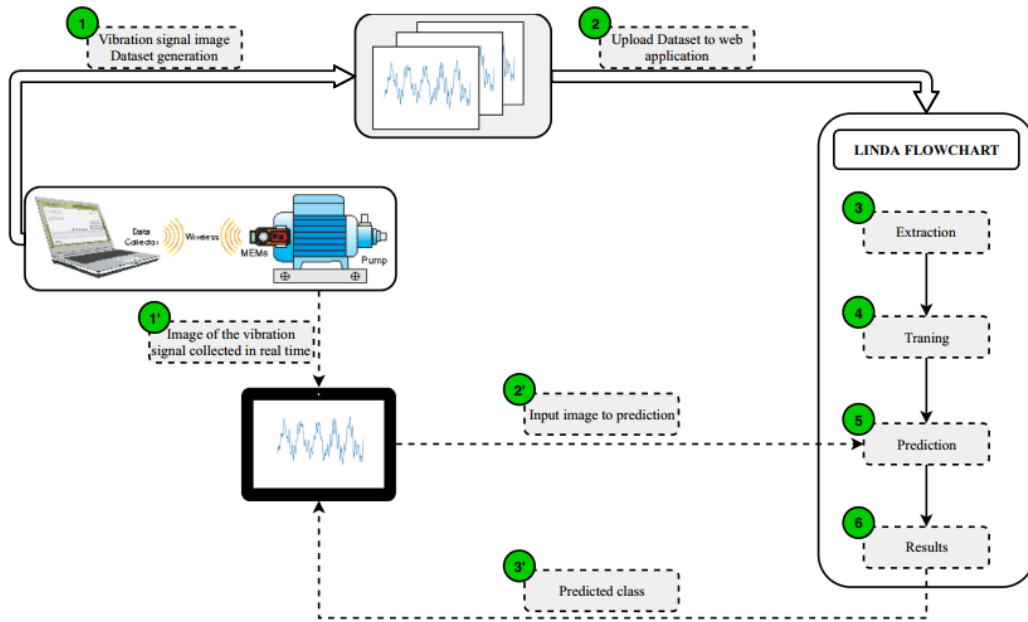
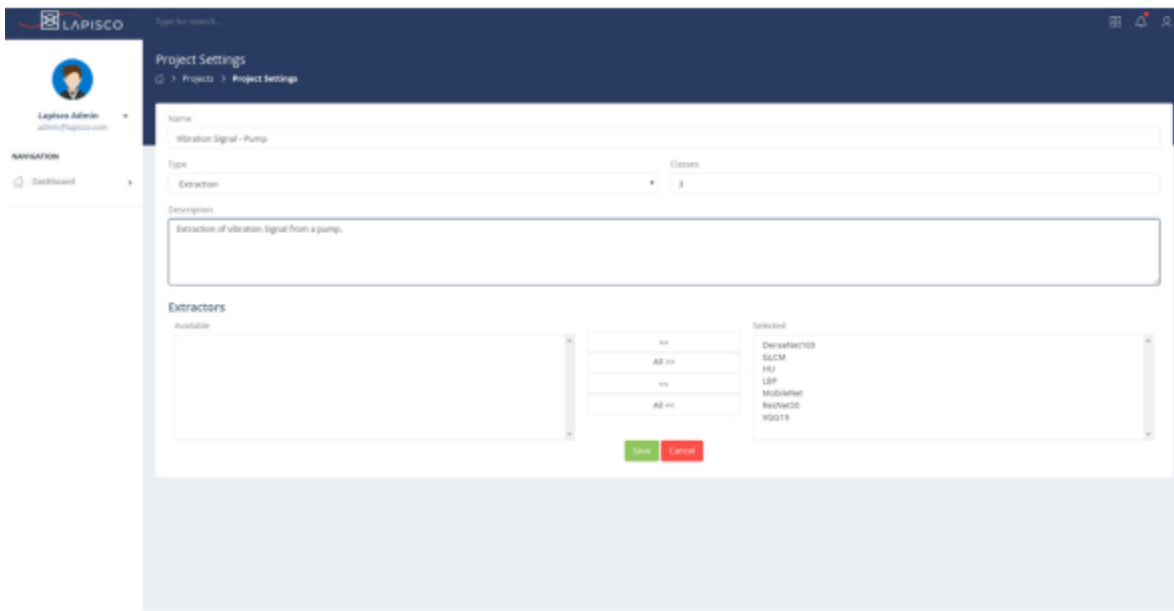


Схема системы

Для диагностики насоса исследователи реализовали несколько методов для выделения диагностических свойств и классификации состояния. Исследователи проверили следующие методы выделения свойств: метод матрицы корреляций Грея, метод моментов изображения Ху, метод локальных бинарных паттернов, свёрточная нейронная сеть. Для классификации состояния насоса были проверены методы байесовского обучения, k-ближайших соседей, многослойного перцептрона, случайного леса и метод опорных векторов. Результаты применения всех методов визуализировались в LINDA, для чего были созданы отдельные формы конфигурирования и учёта результатов методов. Пример формы конфигурирования методов классификации в LINDA показан ниже.




Форма конфигурирования

Пример представления результатов классификации показан ниже.

Accuracy Statistics

Accuracy

DenseNet169 draw



Результаты классификации

В результатах исследования авторы указывают, что наилучшая точность диагностики была достигнута комбинацией выделения диагностических свойств методом моментов X_u и классификацией методом k -ближайших соседей. Точность диагностики в этом случае достигала 99,67%. В дальнейшей работе авторы планируют сосредоточиться на повышении быстродействия метода и расширении возможностей работы с платформой с мобильных устройств.

Опыт разработки беспроводной системы сбора вибрационных данных

Источник: Soto-Ocampo, C.R.; Mera, J.M.; Cano-Moreno, J.D.; Garcia-Bernardo, J.L. *Low-Cost, High-Frequency, Data Acquisition System for Condition Monitoring of Rotating Machinery through Vibration Analysis-Case Study. Sensors* 2020, 20, 3493.

<https://www.mdpi.com/1424-8220/20/12/3493>

Группа авторов из политехнического университета Мадрида разработала прототип системы сбора вибрационных данных, построенной на основе одноплатного компьютера Raspberry Pi, способной записывать высокочастотные данные по четырём каналам. Статья авторов была опубликована в издании *Sensors* в июне 2020 года.

Основными требованиями, предъявленными к системе перед разработкой, были компактность, дешевизна и способность вести запись с частотой до 50 кГц по трём каналам. Для этих целей был выбран одноплатный компьютер модели Raspberry Pi 3 B+ с модулем АЦП на основе микросхемы ADS8326. Установка была дополнена аналоговым мультиплексором MAX4518CPD со скоростью переключения каналов до 250 нс и регулятором напряжения NCP1541. Электрическая схема устройства показана ниже.

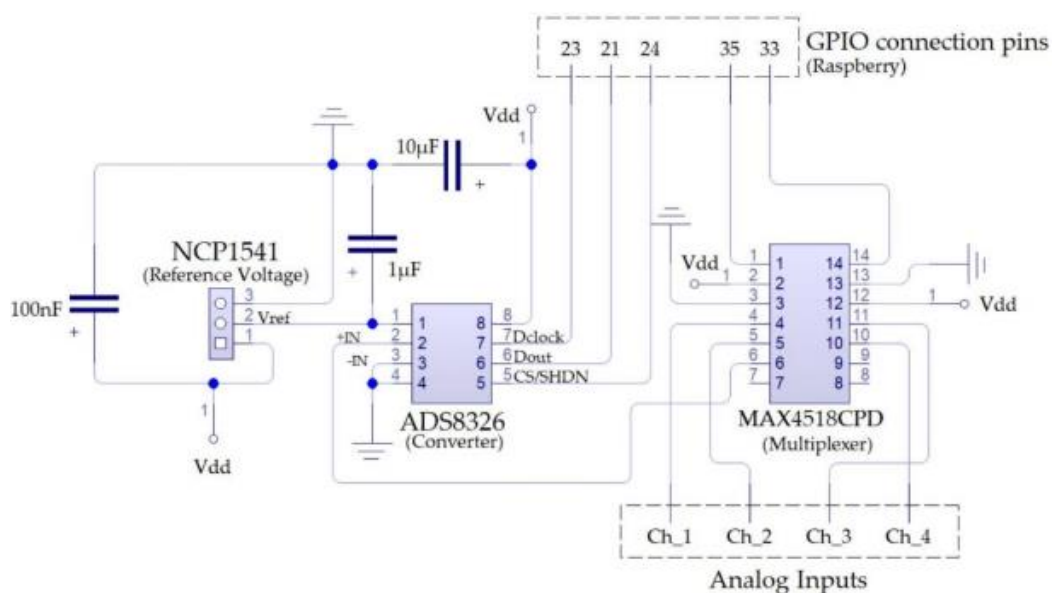


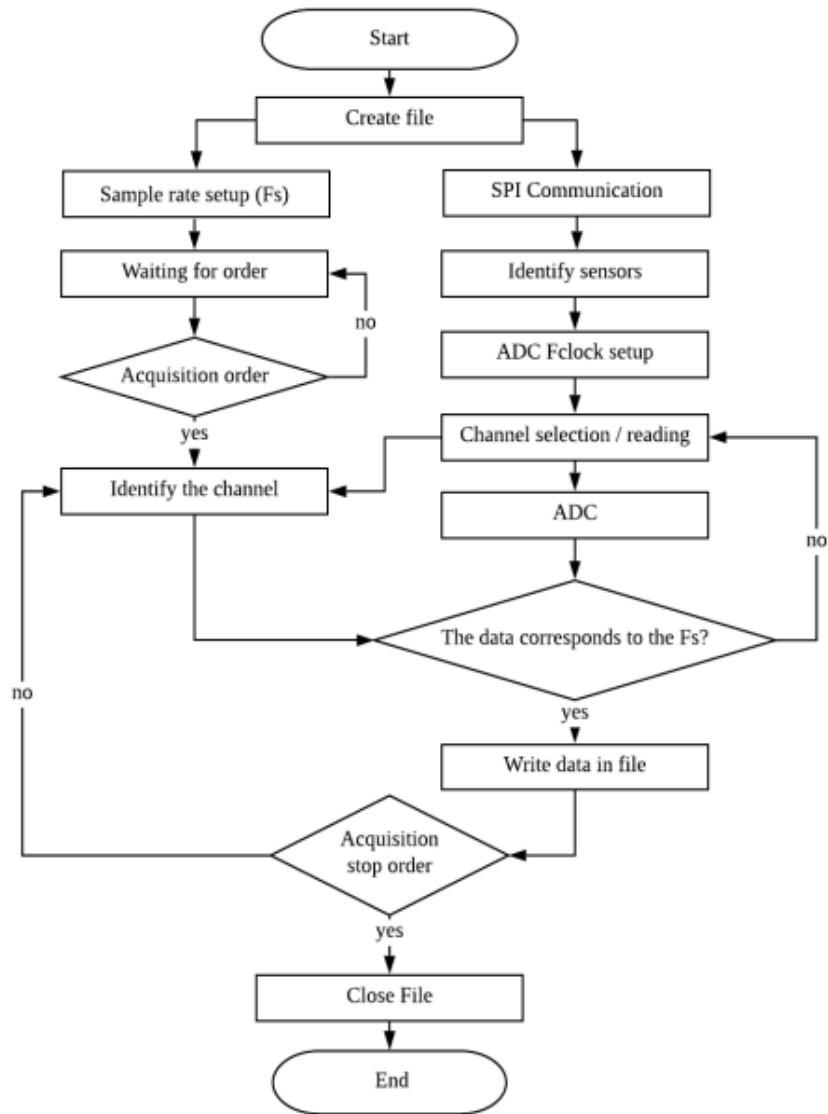
Схема устройства

В качестве первичных чувствительных элементов вибрации использовались компактные акселерометры 805M1-0020, обладающие равномерным усилением в диапазоне частот 0,4 Гц – 10 кГц и чувствительностью 100 мВ/г. Акселерометры показаны на изображении ниже.



Акселерометры 805M1-0020

Для управления устройством была разработана программа, запускаемая на Raspberry. Программа была написана на C++ при помощи библиотеки VCM 2835 управления чипами Broadcom. Схема основного алгоритма программы показана ниже.



Основной алгоритм программы

Выполнение программы начинается с создания пустого текстового файла в памяти Raspberry. После этого инициализируется двухпоточный процесс, в одном потоке которого выполняется инициализация настроек опроса и идентификация текущего измерительного канала, а в другом выполняется настройка частоты опроса и её синхронизация с генератором тактовых импульсов. После выполнения процессов в обоих потоках выполняется запись полученных данных в файл. После этого программа завершает запись в текущий файл данных и дожидается начала записи следующего файла данных.

Для сбора всех компонентов устройства использовалась плата, показанная ниже. Плата имела разъёмы USB 2.0 для подключения акселерометров и беспроводной передатчик для отправки результатов измерений.



Плата для сбора компонентов устройства

Общий вид полученного устройства со схемой передачи информации показан ниже.



Схема передачи информации

Работа системы была опробована на тестовой установке, состоящей из синхронного двигателя с контролируемой скоростью вращения и механическим моментом. Вал двигателя был закреплён в двухрядных подшипниках качения. Установка запускалась с разными дефектами подшипников. Схема установки с расположением подшипников и местами установки акселерометров показана ниже.


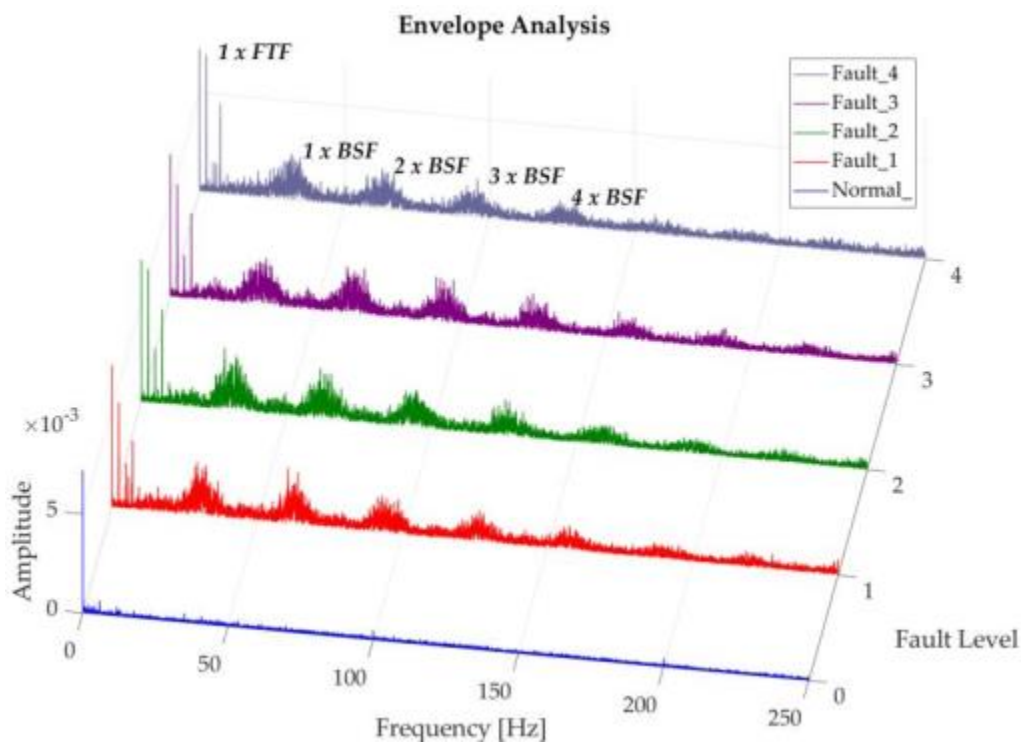


Схема установки с подшипниками и акселерометрами

Пример результатов измерения вибрации показан ниже. В этом случае установка запускалась с разным уровнем дефекта тел качения одного из подшипников при частоте вращения вала 350 об/мин.



Один из результатов измерения. Горизонтальные оси: частота спектра вибрации и степень развития дефекта, вертикальная ось – амплитуда гармоник

Авторы указывают, что результаты первичных испытаний системы признаны успешными. Дальнейшая разработка будет направлена на применение дополнительных методов анализа вибрации (использование иных диагностических признаков или машинного обучения).


Способ мониторинга состояния машин при помощи разреженных данных вибрации

Источник: Rani, M.; Dhok, S.; Deshmukh, R. A Machine Condition Monitoring Framework Using Compressed Signal Processing. *Sensors* 2020, 20, 319

<https://www.mdpi.com/1424-8220/20/1/319>

Исследователи из индийского национального технологического института имени М. Висвесварая предложили способ мониторинга состояния машин при помощи разреженных данных вибрации. Основным преимуществом такого метода является необходимость пересылками меньшего набора данных по коммуникационным каналам без уменьшения качества диагностирования машины. Статья авторов была опубликована в издании *Sensors* в январе 2020 года.

Разрежение данных можно выполнять разными методами. Авторы предложили использовать метод случайного демодулятора, суть которого схематично показана на изображении ниже.



Разрежение данных случайным демодулятором

В этом методе исходный сигнал сначала рандомизируется умножением на псевдослучайную последовательность чисел (например, ± 1). Эта операция расширяет диапазон гармоник в спектре сигнала. Рандомизированный сигнал затем проходит через интегратор, который выполняет интегрирование (накопление) порций сигнала в течение определённых промежутков времени. Последовательность накопленных таким образом значений можно использовать как сигнал, соответствующий исходному, но с более низкой частотой следования точек.

Для проверки гипотезы о диагностической значимости разреженного сигнала исследователи использовали схему, показанную ниже.


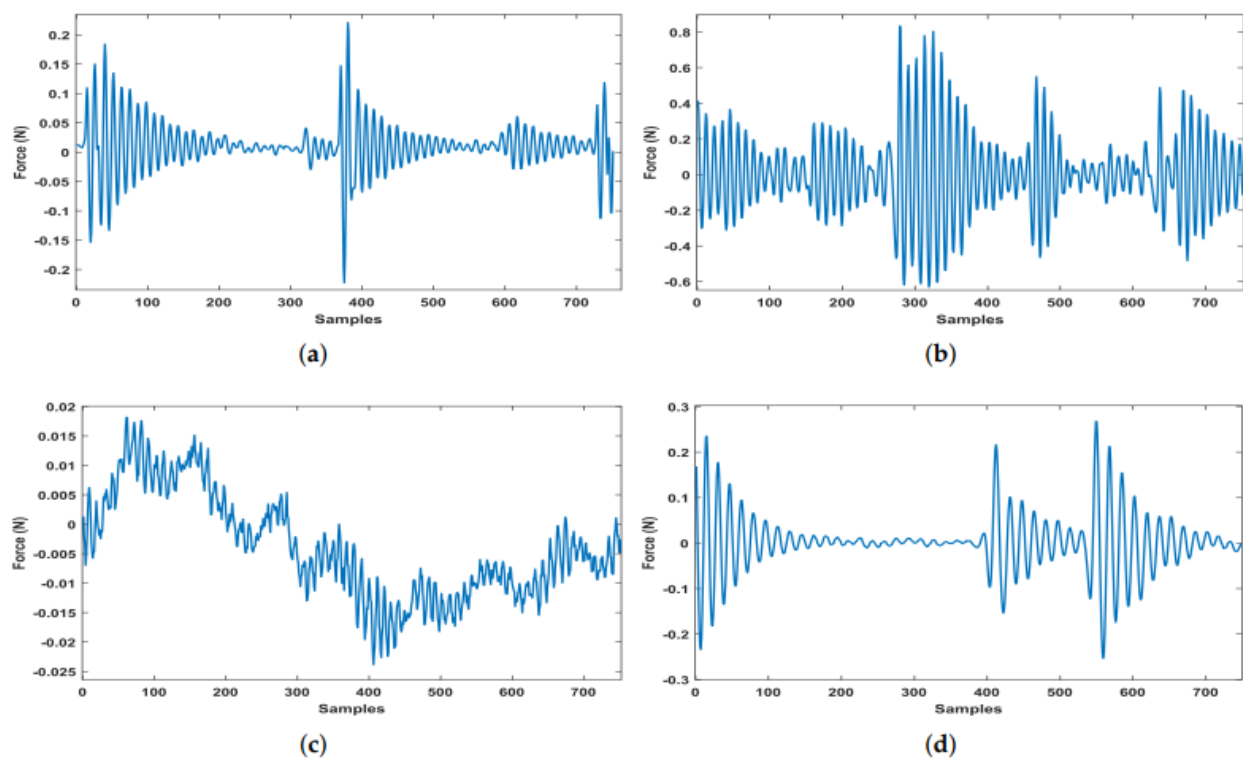


Схема проверки

В схеме сначала выполнялось разрежение сигнала (этап I), затем по разреженному сигналу рассчитывался набор диагностических свойств (этап II), который затем подавался в алгоритм классификации (этап III), результатом выполнения которого было отнесение сигнала к одному из классов состояний, соответствующих типам дефектов. Для сравнения, аналогичная схема с выделением свойств и классификацией была применена к оригинальному несжатому сигналу.

Выделение частотных свойств выполнялось одинаково в обоих случаях. Спектр сигнала разделялся на 8 сегментов. Набором свойств, используемых при классификации, являлись нормализованные энергии каждого сегмента. Для классификации применялись несколько методов машинного обучения: метод опорных векторов с линейной и степенной функцией-классификатором, обычный и взвешенный метод k -ближайших соседей.

Метод был опробован на имевшемся в распоряжении исследователей наборе данных вибрации, который включал в себя наборы сигналов вибрации вращающихся машин с разными дефектами. Примеры использованных сигналов показаны ниже.



Примеры сигналов, использованных при тестировании: а) с дефектом, приводящим к осевым биениям, б) с загрязнённым смазочным маслом, в) с новым, бездефектным подшипником, д) с дефектом, приводящим к радиальным биениям

Точность классификации типа дефекта при использовании разрежения сигнала составляла, в зависимости от степени разрежения и алгоритма классификации, от 83% до 97,9%, и не отличалась от точности, достигаемой при использовании сигнала без разрежения. Однако число выборок разреженного сигнала было в несколько раз меньше, чем у оригинального сигнала.

Однако авторы исследования признают, что использование разрежения накладывает более высокие требования к вычислительным мощностям оборудования. В дальнейшей работе авторы планируют сфокусироваться на переносе части вычислительных функций на аппаратный уровень системы.

IoT-система контроля вибрационных характеристик

Источник: G. Bucci, F. Ciancetta, E. Fiorucci, A. Fioravanti, A. Prudenzi and S. Mari, "An IoT condition monitoring system for resilience based on spectral analysis of vibration," 2020 IEEE International Workshop on Metrology for Industry 4.0 & IoT, Roma, Italy, 2020, pp. 38-43, doi: 10.1109/MetroInd4.0IoT48571.2020.9138177.

<https://ieeexplore.ieee.org/abstract/document/9138177>

Группа авторов из университета Л'Акуила в Италии разработала систему контроля спектральных характеристик вибрации, использующую технологии Интернета вещей. Соответствующий доклад был представлен на прошедшем в июне 2020 года Workshop on Metrology for Industry 4.0 and IoT.

Основным элементом системы является модуль сбора данных вибрации, показанный на изображении ниже.



Модуль сбора данных вибрации

Модуль состоит из двух устройств: STEVAL-IDP005V1 (слева на изображении) для сбора данных вибрации и Particle Photon (справа на изображении) для передачи данных. В качестве чувствительных элементов в STEVAL-IDP005V1 используются 3D-гироскоп и акселерометр. STEVAL-IDP005V1 и Particle Photon соединяются при помощи последовательного интерфейса. Для дальнейшей передачи информации в Particle Photon используется Wi-Fi-чип Broadcom BCM43362.

Схема обработки данных, реализуемой на модуле, показана ниже.

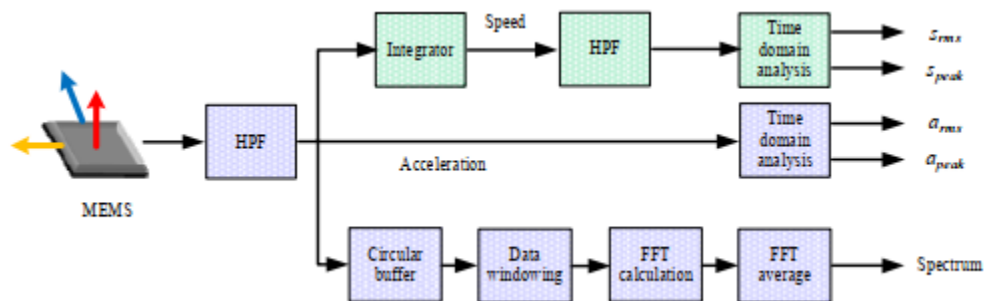



Схема обработки данных

Данные виброускорения сначала обрабатываются фильтром верхних частот. Затем модуль сохраняет среднее и пиковое значения виброускорения в текущем замере. К данным ускорения также применяется интегрирование для получения скорости, к которой затем снова применяется

фильтр верхних частот. Среднее и пиковое значение скорости также сохраняются. Помимо этого, в модуле сохраняются средние значения выделенных окон спектра виброускорения. Каждое окно соответствует полосе частот шириной 51,5 кГц и состоит из 32 точек.

Совокупность модулей передаёт накопленную информацию по промышленному Wi-Fi в специально разработанную Web-платформу. Общая архитектура системы показана ниже.



Сетевая архитектура системы

Пользовательский интерфейс Web-платформы показан ниже.



Интерфейс Web-платформы

Помимо представления осциллограмм вибрации, авторы также реализовали трёхмерное представление результатов расчёта спектральных характеристик. Для каждой тройки окон в спектре вибрации по трём осям формировалась точка в трёхмерном пространстве по значениям максимальных амплитуд в окнах. Оси трёхмерного пространства соответствовали амплитудам по каждой из трёх осей датчика. Таким образом, анализируя распределения множества точек всех окон в выбранном замере, можно делать вывод о преобладании вибрации по одной из осей. Трёхмерное представление вибрации показано справа сверху на изображении интерфейса Web-платформы.

Испытания системы показали, что общее время обработки данных одного замера вибрации, не превышает 4,5 с. Авторы также подчёркивают, что стоимость одного модуля вибрации не превышает 150\$.