

Таким образом, оценка подобия локальных компонент (2) для режима БНТ (рис. 4, а, в) и режима виткового замыкания (рис. 4, б, г) позволяет отличить их друг от друга и, соответственно, идентифицировать каждый из рассматриваемых наблюдаемых режимов работы трансформатора.

Литература

1. Кочетов И. Д., Лямец Ю. Я., Макашкин Ф. А. Распознающая способность локальных токов при двухстороннем наблюдении линии электропередачи // Электрические станции. 2020. № 6. С. 54–58.

2. Кочетов И. Д., Лямец Ю. Я. Распознавание витковых замыканий в обмотке трансформатора по локальным составляющим наблюдаемых напряжений и токов // Известия РАН. Энергетика. 2022. № 1. С. 57–65.

Дементий Ю.А., Шорников Е.В.
(Чебоксары, ООО «Релематика»)

АКТИВНОЕ ОБУЧЕНИЕ ИНТЕЛЛЕКТУАЛЬНЫХ АЛГОРИТМОВ РЕЛЕЙНОЙ ЗАЩИТЫ И АВТОМАТИКИ. МНОГОМЕРНЫЕ ИНТЕРВАЛЬНЫЕ МОДЕЛИ

Одна из основных задач при построении алгоритма параметрической идентификации – наиболее полное использование имеющейся информации о режиме работы объекта для определения его параметров. Имеющиеся в настоящее время алгоритмы не используют доступную информационную базу в полной мере, что является причиной уменьшения эффективности их работы. Несмотря на то, что существуют различные адаптивные модификации алгоритмов, их результативность не всегда достигает предела, соответствующего используемой информационной базе [1]. Кроме того, методы построения подобных алгоритмов не универсальны и подходят только для одного конкретного типа задач. Это является следствием того, что принципы построения алгоритмов параметрической идентификации зависят от доступной информационной базы и представляют собой лишь

частные решения одной общей задачи – определения неизвестных параметров объекта. В докладе предлагается подход к обучению алгоритмов релейной защиты и автоматики (РЗА), основанный на решении задачи многомерной параметрической идентификации объекта с использованием интервальной оценки параметров объекта.

Пусть имеется имитационная модель объекта (ИМО) $F(\mathbf{x})$, которая отображает вектор параметров объекта в вектор наблюдаемых значений $F(\mathbf{x}) : C \rightarrow A$, где C – множество всех возможных векторов параметров ИМО в объектном пространстве; A – множество всех возможных векторов в наблюдаемом пространстве; \mathbf{x} – вектор параметров ИМО.

Необходимо по наблюдаемым значениям определить возможные значения вектора параметров \mathbf{x} . Результатом работы метода является алгоритм, возвращающий границы интервала оценок верхней и нижней модели объектных параметров.

Алгоритм подразумевает применение наблюдаемых значений в качестве аргументов функции обратной к ИМО (1). В случае, когда одному вектору наблюдаемых значений соответствует один объектный параметр, функция, обратная к ИМО, однозначна, в случае, когда вектору наблюдаемых значений может соответствовать несколько объектных параметров, функция – многозначна. В информационной теории релейной защиты примером такого явления является абсолютная нераспознаваемость [2]. Предлагается метод обучения алгоритмов РЗА, использующий многозначную функцию для генерации прецедентов

$$\mathbf{x} = F^{-1}(\mathbf{v}), \quad (1)$$

где \mathbf{v} – вектор наблюдаемых значений.

Ранее в работах, связанных с параметрической идентификацией, уже использовалась многозначная функция [4–6]. Для представления полученных прецедентов предлагается дискретизировать пространство наблюдаемых значений и разделить его на прямоугольные ячейки, которые представляют собой множества наблюдаемых значений, соответствующих диапазону, заданному шагу дискретизации. Объектные параметры, полученные при помощи ИМО и комбинации наблюдаемых значений, целесообразно записывать в матрицу \mathbf{M} . Информация об объ-

ектных параметрах хранится в матрице под индексами. Значения индексов соответствуют прямоугольным ячейкам наблюдаемых значений.

В таблице приведен пример хранения информации матрицы **M**, который иллюстрирует зависимость одного объектного параметра от двух наблюдаемых значений.

Таблица. Пример хранения информации в матрице **M**

max		Индексы v_2				
Индексы v_1	№	0	1	2	3	
	0	0	0	0	0	
	1	0	10	0	0	
	2	0	0	0	0	
	3	0	0	0	0	

min		Индексы v_2				
Индексы v_1	№	0	1	2	3	
	0	0	0	0	0	
	1	0	5	0	0	
	2	0	0	0	0	
	3	0	0	0	0	

Матрица **M** размером $2 \times 4 \times 4$ составлена путем конкатенации двух двухмерных матриц, являющихся моделями оценок верхней и нижней границ интервала объектных параметров. Первая двухмерная матрица хранит максимальные значения объектных параметров, вторая – их минимальные значения.

В данном примере максимальное значение объектного параметра находится по индексу **M** (0,1,1), а минимальное **M** (1,1,1). Комбинация индексов, представленная в матрице **M**, является ключом для получения информации о наблюдаемых значениях, хранящихся в обучающей выборке, с помощью которой были получены значения объектные параметры.

На рис. 1 изображена визуализация хранения информации в матрице **M**. Наглядное представление матрицы **M** на графике ограничено трехмерным пространством, что соответствует отображению зависимости одного объектного параметра от двух наблюдаемых значений. При этом сам метод не ограничен трехмерным пространством и применим к многомерным пространствам.

Ячейки матрицы **M**, содержащие в себе объектные параметры, представляют собой многомерные прямоугольники. Попадание параметра в ту или иную ячейку обусловлено шагом дис-

кретизации наблюдаемого пространства, его увеличение также повысит точность параметрической идентификации.

В данной работе для формирования обучающей выборки используется ИМО, которая принимает на вход наблюдаемые значения, а на выходе выдает значение объектного параметра. Обучающая выборка представляет собой пары векторов объектных параметров и наблюдаемых значений.

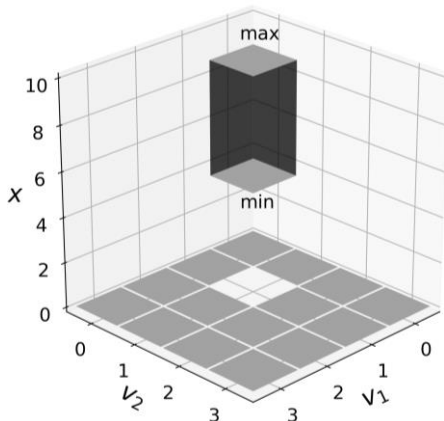


Рис. 1. Визуализация хранения информации в матрице **M**

В работе предлагается стохастическое смещение отдельно полученных точек из наблюдаемого пространства на случайную величину и направление в объектном пространстве. Стохастическое смещение используется в качестве аналога стохастической оптимизации, где в качестве оптимизируемых величин используются значения в ячейках матрицы **M**. Для смещения используется генератор псевдослучайной величины, имеющий нормальное распределение, представленное на рис. 2

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\left(\frac{(x-\mu)^2}{2\sigma^2}\right)}, \quad (2)$$

где μ – математическое ожидание; σ – среднее квадратическое отклонение; σ^2 – дисперсия распределения.

Критерием выбора точек является их информативность [3]. Смещенные точки используются для формирования нового

набора прецедентов, который сравнивается с предыдущим. Объектные параметры, превосходящие экстремальные значения предыдущей выборки, перезаписываются в матрицу \mathbf{M} , остальные исключаются. Во время каждой итерации матрица \mathbf{M} хранит актуальную информацию об информативных точках текущей выборки.

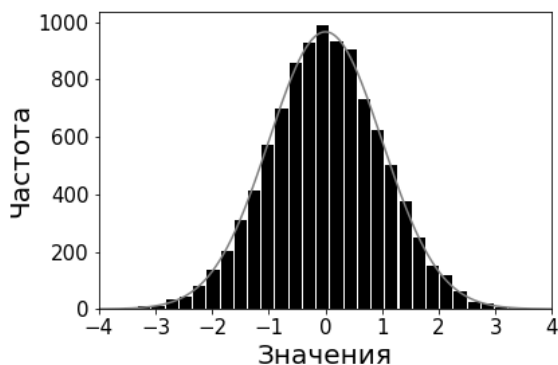


Рис. 2. Нормальное распределение

Для обеспечения эффективности алгоритма предлагается ввести матрицу, имеющую ту же размерность, что и матрица \mathbf{M} , значения которой представляют собой счетчики. Сравнение значений объектных параметров между итерациями происходит согласно индексу в матрице \mathbf{M} . При перезаписи значение в ячейке счетчика обнуляется, иначе увеличивается на единицу при каждой итерации сравнения в ячейке. Критерием остановки алгоритма предлагается считать безуспешные перезаписи в каждой ячейке.

Эффективность работы алгоритма проверена путем моделирования возможных режимов работы наблюдаемого объекта. В качестве примера работы активного обучения интеллектуальных алгоритмов выбран абстрактный объект.

В ходе эксперимента были проделаны следующие шаги:

- составлена имитационная модель абстрактного объекта;
- с помощью двух наблюдаемых значений и ИМО была получена обучающая выборка;

проведена дискретизация осей наблюдаемых значений;
получены прямоугольные ячейки наблюдаемых значений;
шаг дискретизации наблюдаемых значений позволил разделить каждую ось наблюдаемых значений на 100 ячеек;
алгоритм определил размер матрицы \mathbf{M} как $2 \times 100 \times 100$;
пустая матрица \mathbf{M} приняла первый набор объектных параметров в соответствующие индексы положения в матрице;
во время каждой итерации алгоритм генерирует новые точки, сравнивая их с предыдущими. По результату сравнения происходит перезапись значений объектных параметров матрицы \mathbf{M} .

Алгоритм завершил работу по критерию остановки, который гарантирует получение границ интервала объектных параметров, стремящихся к истинным значениям. Результат работы алгоритма показан на рис. 3. Визуализация соответствует значениям матрицы \mathbf{M} .




Рис. 3. Пример работы алгоритма активного обучения моделей оценок верхней и нижней границ интервала

Таким образом, предлагаемый метод позволяет построить интервалы оценок объектных параметров наблюдаемого объекта; предлагаемый метод обучения алгоритмов РЗА является

универсальным инструментом построения РЗА для объекта с любым набором параметров; предлагаемый метод позволяет реализовать защиту, основанную на оценке интервала объектных параметров на любой современной платформе РЗА.

Литература

1. *Мартынов М. В.* Исследование и разработка обучаемых модулей микропроцессорных защит линий электропередачи: диссертация ... кандидата технических наук: 05.14.02 / Мартынов М.В.; Чебоксары, Чуваш. гос. ун-т им. И.Н. Ульянова, 2014.

2. Об информационной теории релейной защиты / Ю. Я. Лямец [и др.] // Известия Академии электротехнических наук РФ. 2009. С. 32–44.

3. *Дементий Ю. А.* Активное обучение классификатора режимов работы объекта с использованием имитационной модели // Современные тенденции развития цифровых систем релейной защиты и автоматики: материалы науч.-техн. конф. молодых специалистов форума «РЕЛАВЭКСПО-2021». Чебоксары: Издво Чуваш. ун-та, 2021. С. 157–162.

4. *Дементий Ю. А., Шорников Е. В.* Машинное обучение для интервальной оценки параметров объекта // Современные тенденции развития цифровых систем релейной защиты и автоматики: материалы науч.-техн. конф. молодых специалистов форума «РЕЛАВЭКСПО – 2021». Чебоксары: Изд-во Чуваш. ун-та, 2021. С. 153–157.

5. *Дементий Ю. А., Шорников Е. В.* Применение активного обучения для построения моделей параметрической идентификации // Динамика нелинейных дискретных электротехнических и электронных систем: материалы XIV Всерос. науч.-техн. конф. Чебоксары: Изд-во Чуваш. ун-та, 2021. С. 446–450.

6. *Дементий Ю. А., Шорников Е. В.* Регуляризация в задаче обучения интеллектуальных алгоритмов параметрической идентификации // Динамика нелинейных дискретных электротехнических и электронных систем: материалы XIV Всерос. науч.-техн. конф. Чебоксары: Изд-во Чуваш. ун-та, 2021. С. 450–454.