

Пассивный метод параметрической идентификации в адаптивном управлении технологическим процессом с применением нейросетевой технологии

А.Г. Шумихин, Р.Р. Исламов, Д.К. Корнилицин

Пермский национальный исследовательский политехнический университет

Аннотация: Рассмотрен метод параметрической идентификации модели установившихся режимов технологического процесса, использующий искусственные нейронные сети, на вход каждой из которых подаются измеренные значения входных и выходных технологических переменных процесса, а с одного выхода поступает значение соответствующего параметра модели технологического процесса. Оценена эффективность метода путем проведения вычислительных экспериментов на регрессионных моделях с двумя факторами и моделях установившихся режимов технологических процессов действующих производств. Среднее значение относительной ошибки моделей не превышает 0,43 %. Метод параметрической идентификации применим в адаптивном управлении установившимися режимами технологического процесса. Одно из достоинств метода заключается в том, что при заданной форме математического описания для обучения нейронной сети не требуется статистических экспериментальных значений переменных технологического процесса.

Ключевые слова: метод параметрической идентификации, искусственная нейронная сеть, модель установившихся режимов технологического процесса, адаптивное управление.

Введение

Эффективность функционирования адаптивных систем управления напрямую связана с точностью математического описания технологических процессов [1]. Поэтому построение математических моделей (идентификация) технологических процессов является важнейшим этапом разработки управляющих систем, способных адаптировать свои параметры и (или) структуру в зависимости от изменения параметров моделей технологических процессов [2]. Кроме того, идентификацию проводят в исследованиях технологических процессов с целью оптимизации существующей системы управления с точки зрения выбранного критерия качества.

Обобщенная процедура идентификации технологического процесса представлена на рис. 1.

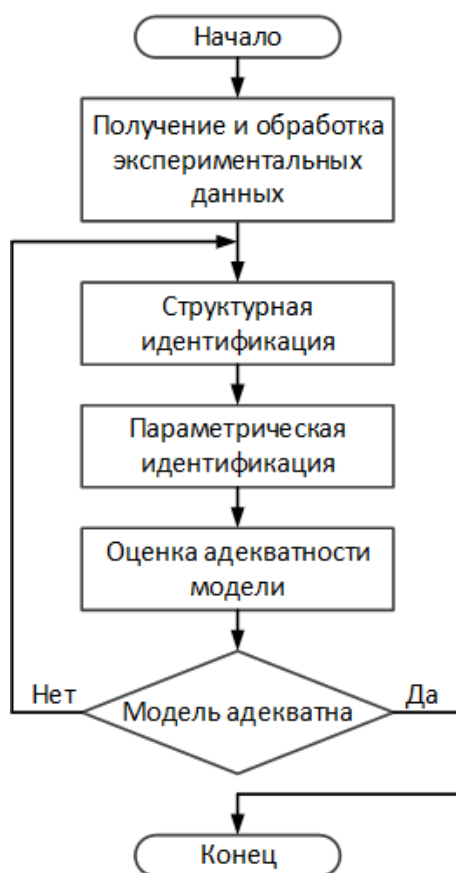


Рис. 1. - Обобщенная процедура идентификации технологического процесса

Процедура предполагает выполнение следующих шагов:

1. Получение и обработка экспериментальных данных. Проводят измерение технологических переменных (переменных технологического процесса) и предварительную обработку их измеренных значений.

2. Структурная идентификация: определяются входные и выходные переменные модели технологического процесса, значимые с точки зрения решаемой задачи управления, устанавливается форма математической зависимости между значимыми входными и выходными переменными, например, в виде уравнения регрессии, дифференциального или разностного уравнения, передаточной функции, искусственной нейронной сети и др.

3. Параметрическая идентификация (параметризация), в которой находятся значения параметров (коэффициентов) выбранной математической

зависимости, связывающей значимые входные и выходные переменные модели технологического процесса.

4. Оценка адекватности полученной модели прямым или косвенным методом. Прямой способ подразумевает определение разности между экспериментальными значениями выходных переменных технологического процесса и его модели, и чем меньше расхождение, тем модель более точно (адекватно) описывает процесс. В косвенном методе сравнивают экспериментальные значения выходных переменных реального процесса и его модели при помощи статистических критериев и, если модель адекватна экспериментальным значениям переменных технологического процесса, то процедура идентификации считается завершённой, иначе следует пересмотреть результаты структурной и параметрической идентификации.

Нейросетевая технология в параметрической идентификации технологического процесса

Существует множество методов параметрической идентификации: метод наименьших квадратов, метод инструментальных переменных и т. д. Такие методы реализуемы только для конкретных классов моделей [3, 4].

В работе [5] рассмотрен метод адаптации для актуализации значений параметров моделей статистики технологических процессов с применением нейросетевой технологии. Метод включает в себя следующие этапы:

1. Осуществление вычислительного эксперимента для формирования значений выходных технологических переменных на статической модели путем генерирования в заданных пределах значений входных технологических переменных и параметров модели.

2. Подготовка обучающих выборок для нейронных сетей, на вход каждой из которых подаются значения входных и выходных переменных, а с выхода поступают значения одного из параметров статической модели (рис. 2).




Рис. 2 - Нейронная сеть для параметризации модели

3. Обучение искусственных нейронных сетей вычислению параметров статической модели по выборкам с заранее выбранным оптимальным числом скрытых слоев и нейронов.

4. Определение при помощи обученных сетей значений параметров статической модели по измеренным входным и выходным переменным технологического процесса.

Такой подход к идентификации благодаря своему быстрдействию применим в системах реального времени.

Применение нейросетевой технологии в параметрической идентификации технологического процесса

С целью оценки эффективности вышеописанного метода проведен ряд вычислительных экспериментов с моделями как со сгенерированными выборками, так и с массивами данных из действующих производств.

Для линейной регрессионной модели

$$y = 13,15 + 4,62 \cdot x_1 + 0,127 \cdot x_2. \quad (1)$$

подготовлен массив данных объемом, равным 1500 элементам. Каждый элемент массива состоит из факторов x_1 и x_2 , значения которых сгенерированы в пределах $[20; 30]$ и $[120; 200]$ соответственно, коэффициентов b_0 , b_1 и b_2 , представляющих собой случайные числа в пределах $\pm 10\%$ от значений параметров модели (1), и вычисленного по ним отклика y . Полученный массив данных разделен на обучающую (первые 1000 элементов) и тестовую (последние 500 элементов) выборку.

На данных выборки обучены три нейронные сети в программной среде Matlab [6, 7]. Входами каждой сети являются факторы x_1 и x_2 и отклик y модели (1), выходом - соответствующий параметр модели (1). По результатам исследования влияния конфигурации сетей прямого распространения и объема выборки на эффективность их функционирования, как и в работе [8], взяты персептроны с одним скрытым слоем из десяти нейронов.

Проведена оценка адекватности трех обученных сетей. По значениям переменных x_1 и x_2 из тестовой выборки, поданным на вход каждой обученной сети (вместе с переменной y), и параметров модели b_0 , b_1 и b_2 , полученным на выходе сетей, вычислены значения отклика модели (1). Результат тестирования трех нейронных сетей представлен на рис. 3.

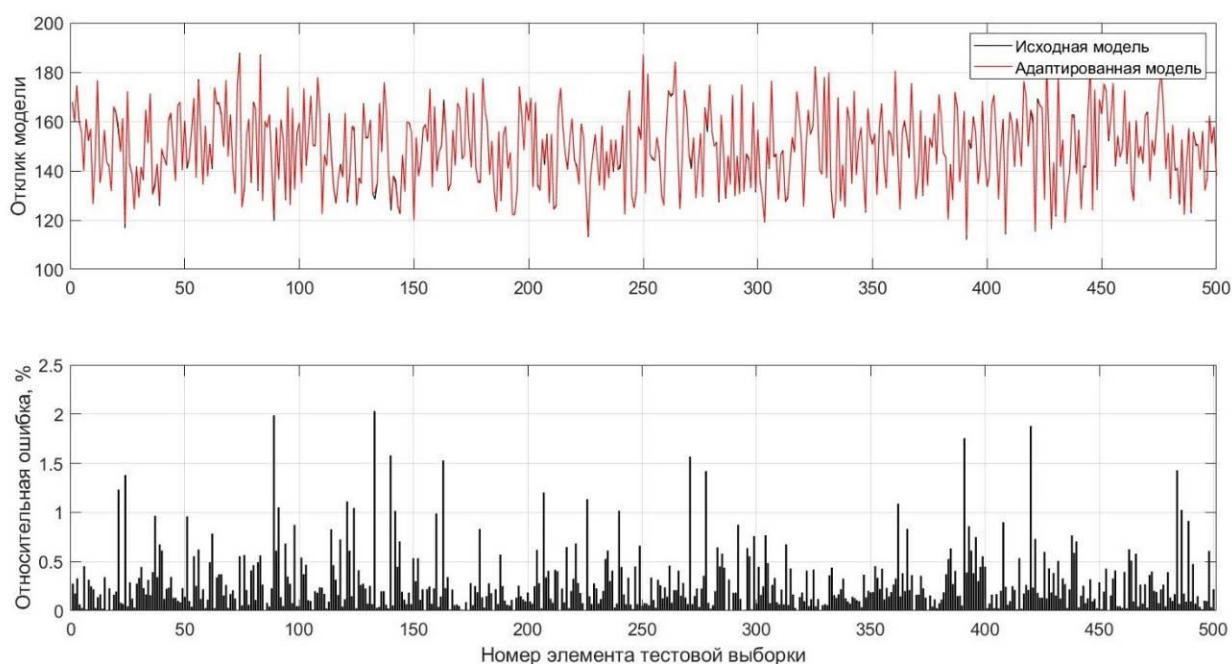


Рис. 3. - Результат вычислений по модели (1) с параметрами после их адаптации в сравнении с исходной моделью из тестовой выборки

Среднее значение относительной ошибки по отклику модели (1), равное 0,28 %, свидетельствует о работоспособности трех обученных сетей. Расчет относительной ошибки по отклику модели y произведен по формуле:

$$\delta = |1 - y_{\text{нс}}/y| \cdot 100 \%, \quad (2)$$

где y - значение отклика, вычисленное по модели (1); $y_{\text{нс}}$ - значение

отклика, вычисленное со значениями параметров модели (1), рассчитанным нейронными сетями.

Аналогичным образом проведен вычислительный эксперимент для билинейной регрессионной модели:

$$y = 18,98 + 5,1 \cdot x_1 + 0,255 \cdot x_2 + 0,0121 \cdot x_1 \cdot x_2. \quad (3)$$

Сгенерированные значения факторов x_1 и x_2 находятся в диапазонах [5,4; 9,0] и [25; 40] соответственно, а коэффициенты b_0 , b_1 , b_2 и b_{12} - в границах $\pm 10\%$ от значений параметров модели (3). На данных выборки обучены четыре искусственные нейронные сети - перцептроны с одним скрытым слоем из десяти нейронов.

На рис. 4 приведены результаты тестирования нейронных сетей, определяющих значение четырех параметров модели (3). Среднее значение относительной ошибки по отклику модели (3) составляет 0,43 %.




Рис. 4. - Результат вычислений по модели (3) с параметрами после их адаптации в сравнении с исходной моделью из тестовой выборки
Для квадратичной регрессионной модели

$$y = 386,1 + 974,1 \cdot x_1 + 12,06 \cdot x_2 + 0,986 \cdot x_1^2 + 0,0057 \cdot x_2^2. \quad (4)$$

сформирован массив данных, в котором значения факторов x_1 и x_2

имеют границы $[0,06; 0,12]$ и $[1,6; 2,6]$ соответственно, а коэффициенты b_0 , b_1 , b_2 , b_{11} и b_{22} - в пределах $\pm 10\%$ от значений параметров модели (4). На сгенерированных данных обучены пять персептронов с одним скрытым слоем из десяти нейронов.

На рис. 5 отражены результаты тестирования сетей, каждая из которых вычисляет значение одного из пяти параметров модели (4). Среднее значение относительной ошибки по отклику модели (4) равно $0,37\%$.




Рис. 5. - Результат вычислений по модели (4) с параметрами после их адаптации в сравнении с исходной моделью из тестовой выборки

Для квадратичной регрессионной модели с эффектом парного взаимодействия:

$$y = 116,3 + 0,45 \cdot x_1 + 9,6 \cdot x_2 + 0,08 \cdot x_1 \cdot x_2 + 0,0008 \cdot x_1^2 + 0,66 \cdot x_2^2. \quad (5)$$

сгенерирована выборка, в которой значения факторов x_1 и x_2 находятся в диапазонах $[0; 25]$ и $[0,10; 0,42]$ соответственно, а коэффициенты b_0 , b_1 , b_2 , b_{12} , b_{11} и b_{22} - в пределах $\pm 10\%$ от значений параметров модели (5). На данных выборки обучены шесть персептронов с одним скрытым слоем и десятью нейронами.

На рис. 6 изображены результаты тестирования нейронных сетей, определяющих значение шести параметров модели (5). Среднее значение относительной ошибки по отклику модели (5) - 0,11 %.




Рис. 6. - Результат вычислений по модели (5) с параметрами после их адаптации в сравнении с исходной моделью из тестовой выборки

В качестве первого примера с реального действующего производства рассмотрена регрессионная модель, построенная методом наименьших квадратов по историческим данным с производства формалина. Модель описывает зависимость температуры T_p в реакторе синтеза формальдегида от расходов метанола F_m и воздуха F_v , поступающих в реактор [9]. Исторические данные представляют собой массив из 1400 значений температуры и двух расходов, измеренных во время различных установившихся (статических) режимов работы реактора. С целью повышения точности (по коэффициенту корреляции) и адекватности (по критерию Фишера) модели проведена предварительная обработка исторических данных путем подавления шумов (флуктуаций температуры и расходов) методом скользящего среднего, описываемым формулой:

$$x_c = \frac{1}{n} \cdot \sum_{i=1}^n x_i, \quad (6)$$

где x_c - усредненное значение технологической переменной x ; x_i - значение технологической переменной x , измеренное на i -м цикле функционирования системы управления; n - период усреднения (количество циклов функционирования системы управления).

В результате вычислительного эксперимента установлено, что повышение периода усреднения n с 50 до 183 циклов приводит к возрастанию коэффициента корреляции R с 50 до 52 %. Поэтому в качестве оптимального значения периода усреднения взято 50 циклов, которое увеличивает коэффициент корреляции с 29 до 50 % [10].

Полученная регрессионная модель имеет вид:

$$T_p = 525 + 65,5 \cdot F_M + 0,02 \cdot F_B - 0,01 \cdot F_M \cdot F_B - 4,6 \cdot F_M^2 + 4 \cdot 10^{-6} \cdot F_B^2. \quad (7)$$

Сформирован массив данных из 1400 элементов. Все элементы массива состоят из значений расходов метанола и воздуха, сгенерированных в регламентированных пределах, коэффициентов b_0 , b_1 , b_2 , b_{12} , b_{11} и b_{22} , представляющих собой случайные числа в пределах ± 10 % от значений параметров модели (7), и вычисленного по ним температуры. Подготовленный массив данных разделен на обучающую (первые 900 элементов) и тестовую (последние 500 элементов) выборки.

Обучены и протестированы шесть сетей по подготовленному массиву данных. Входами каждой сети являются расходы метанола и воздуха и температура, выходом - соответствующий параметр регрессионной модели (7). В качестве нейронных сетей использованы перцептроны с одним скрытым слоем из десяти нейронов. По результатам тестирования среднее значение относительной ошибки по температуре равно 0,21 %.

Проведена оценка адекватности шести обученных сетей по новому массиву данных из 1400 значений расходов метанола и воздуха и

температуры в реакторе синтеза формальдегида. По значениям расходов и температуры, поданным на вход каждой сети, и параметров модели b_0 , b_1 , b_2 , b_{12} , b_{11} и b_{22} , полученными на выходе сетей, вычислены значения температуры согласно модели (7). Результат параметрической идентификации технологического процесса шестью нейронными сетями приведен на рис. 7. Среднее значение относительной ошибки по температуре равно 0,04 %.




Рис.7. - Результат параметрической идентификации технологического процесса нейронными сетями

Во втором примере взята эмпирическая модель газовой топки:

$$t_{dg} = 0,43 + 2920 \cdot \beta / \alpha, \quad (8)$$

где t_{dg} - температура дымовых газов в подрешетном пространстве, °C; β - коэффициент потери тепла в топке; α вычисляется по формуле:

$$\alpha = L / (9,4 \cdot R), \quad (9)$$

где α - коэффициент избытка воздуха; L - расход вторичного воздуха, м³/с; R - расход топливного газа, м³/с.

Подготовлен массив данных, включающий в себя сгенерированные значения коэффициента β в пределах [0,7; 1,0] и расходов L и R в допустимых границах, а также значения температуры t_{dg} , вычисленные согласно модели

(8) по сгенерированным значениям β , L и R . Полученный массив данных разделен на обучающую и тестовую выборки.

Выполнено обучение и тестирование сети по подготовленному массиву данных. Входами сети являются расходы вторичного воздуха и топливного газа и температура дымовых газов, выходом - коэффициент потери тепла в топке. В качестве нейронной сети использован персептрон с одним скрытым слоем из десяти нейронов. По результатам тестирования среднее значение относительной ошибки по температуре равно 0,35 %.

Проведена оценка адекватности обученной сети по новому массиву данных, описывающему другие режимы процесса топки. Результат параметрической идентификации нейронной сетью приведен на рис. 8. Среднее значение относительной ошибки по температуре - 0,43 %.

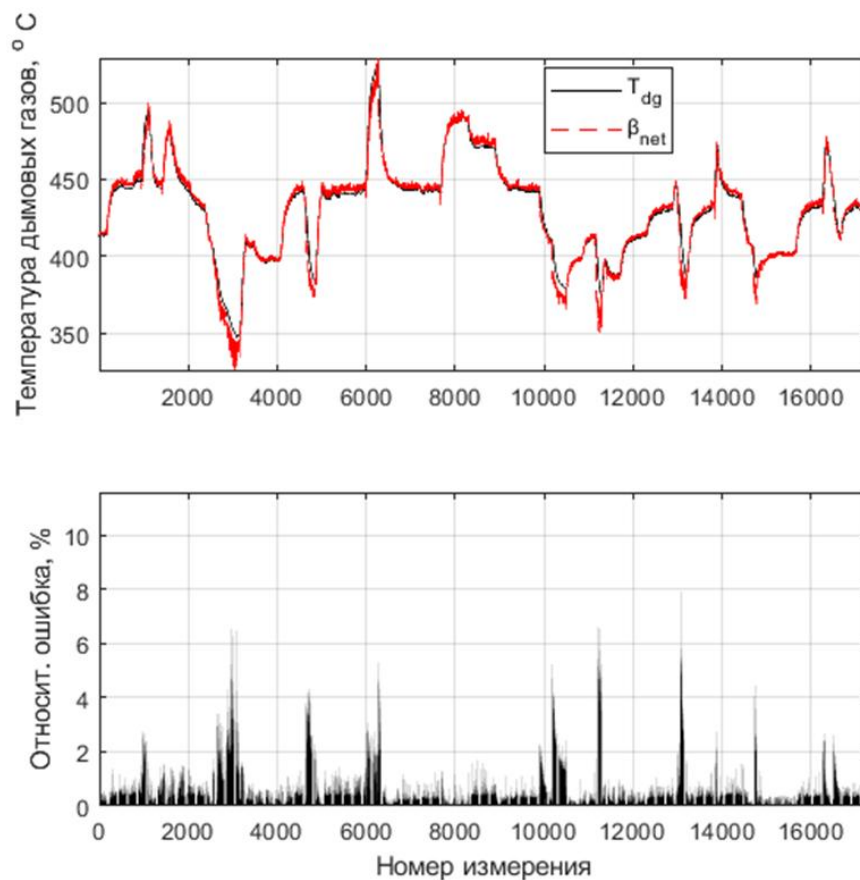


Рис. 8. - Результат параметрической идентификации технологического процесса нейронной сетью

Заключение

Результаты вычислительных экспериментов свидетельствуют о применимости рассмотренного метода параметрической идентификации для управления установившимися (статическими) режимами на основе регрессионных моделей технологических процессов. Основное достоинство подхода заключается в том, что для автоматической адаптации значений параметров моделей не требуется проведение активных экспериментов на процессе или накопление больших массивов экспериментальных данных, поскольку адаптация осуществляется по результатам текущих измерений технологических переменных средствами системы управления.

На рис. 9 представлена структура рассмотренного пассивного метода параметрической идентификации в адаптивных системах. Метод применим в адаптивных системах управления, представленных, например, в [11].



Рис. 1 - Структура системы идентификации: \vec{x} и y - входные и выходная технологические переменные; \vec{x}_c и y_c - усредненные переменные \vec{x} и y ; $\vec{\mu}$ - управляющие воздействия; \vec{b} - параметры модели технологического процесса (ТП); y_m - переменная y , вычисленная по модели ТП; θ - критерий качества параметрической идентификации; ИНС - искусственная нейронная сеть.

Значения параметров адаптивной (настраиваемой) регрессионной модели объекта управления (технологического процесса) актуализируются искусственными нейронными сетями. На вход нейронных сетей подаются усредненные величины технологических переменных \vec{x}_c и y_c , по которым каждая нейронная сеть определяет и выдает на выходе значение соответствующего коэффициента b адаптивной регрессионной модели. Значения технологических переменных \vec{x} и y могут усредняться, например, по рекуррентной формуле скользящего среднего:

$$x_c[i \cdot T] = x_c[(i - 1) \cdot T] + \{x[i \cdot T] - x_c[(i - 1) \cdot T]\} / n, \quad i \geq n \quad (10)$$

где $x[i \cdot T]$ - значение технологической переменной x , измеренное на i -м цикле функционирования системы управления; $x_c[i \cdot T]$ и $x_c[(i - 1) \cdot T]$ - усредненные значения технологической переменной x на i -м и $(i - 1)$ -м циклах соответственно; T - период дискретизации (продолжительность цикла); n - период усреднения (количество циклов).

Процесс адаптации модели активируется в зависимости от критерия качества параметрической идентификации θ : например, если усредненное значение выходной технологической переменной y_c отличается от выхода регрессионной модели y_m более чем на 5 %, то запускается процесс параметризации модели. Организованный таким образом идентификатор может быть использован в задачах оптимизации функционирования объекта управления.

Литература

1. Жмурко Д.Ю. Понятие, сущность и классификация адаптивного управления системами с организационной сложностью // Политематический сетевой электронный научный журнал Кубанского государственного аграрного университета, 2013, № 90. URL: ej.kubagro.ru/2013/06/pdf/66.pdf (дата обращения: 23.10.2023).

2. Цыпкин Я.З. Информационная теория идентификации. М.: Наука. Физматлит, 1995. 336 с.

3. Алпатов Д.А. Методы параметрической идентификации линейных объектов // Международный студенческий научный вестник, 2021, № 6. URL: s.eduherald.ru/pdf/2021/6/20724.pdf (дата обращения: 11.11.2023).

4. Сумин Д.Л., Мартыненко Д.В. Методы идентификации объектов управления // Научно-образовательный журнал для студентов и преподавателей «StudNet». 2022. № 7. С. 7386-7402.

5. Власов С.А., Шумихин А.Г. Автоматизация настройки в компьютерных тренажерах математических моделей технологических объектов с применением технологии искусственных нейронных сетей // Вестник Пермского национального исследовательского политехнического университета. Химическая технология и биотехнология. 2020. № 2. С. 102-112.

6. Маршаков Д.В., Цветкова О.Л., Айдинян А.Р. Нейросетевая идентификация динамики манипулятора // Инженерный вестник Дона, 2011, № 3. URL: ivdon.ru/ru/magazine/archive/n3y2011/504 (дата обращения: 16.12.2023).

7. Шумихин А.Г., Бояршинова А.С. Параметрическая идентификация систем управления с обратной связью на основе нейросетевого моделирования процессов их функционирования // Инженерный вестник Дона, 2017, № 2. URL: ivdon.ru/ru/magazine/archive/N2y2017/4124 (дата обращения: 20.12.2023).

8. Yergök D., Güven C.T., Aci M. Artificial Neural Network Model Design for Daily Demand Prediction in Mass Meal Production // International Conference on Advanced Technologies. Computer Engineering and Science. 2018. pp. 583-586.

9. Муховикова Н.К. Получение формальдегида окислительным дегидрированием метанола // Кузбасский государственный технический университет: материалы всероссийской научно-практической конференции

молодых ученых «Россия Молодая», 2019 URL: science.kuzstu.ru/wp-content/Events/Conference/RM/2019/RM19/pages/Articles/70207.pdf (дата обращения: 24.12.2023).

10. Smith S.W. The Scientist and Engineer's Guide to Digital Signal Processing. California Technical Publishing, 2001. 611 p.

11. Ротач В.Я. Теория автоматического управления: учебник для вузов. 5-е изд. М.: Издательский дом МЭИ, 2008. 396 с.

References

1. Zhmurko D.Yu. Politematicheskii setevoy elektronnyy nauchnyy zhurnal Kubanskogo gosudarstvennogo agrarnogo universiteta, 2013, № 90. URL: ej.kubagro.ru/2013/06/pdf/66.pdf (accessed 23/10/2023).

2. Tsypkin Ya.Z. Informatsionnaya teoriya identifikatsii [Information theory of identification]. Moskva, Nauka. Fizmatlit, 1995. 336 p.

3. Alpatov D.A. Mezhdunarodnyj studencheskiy nauchnyy vestnik, 2021, № 6. URL: s.eduherald.ru/pdf/2021/6/20724.pdf (accessed 11/11/2023).

4. Sumin D.L., Martynenko D.V. Nauchno-obrazovatel'nyy zhurnal dlya studentov i преподаvateley «StudNet». 2022. № 7. pp. 7386-7402.

5. Vlasov S.A., Shumikhin A.G. Vestnik Permskogo natsional'nogo issledovatel'skogo politekhnicheskogo universiteta. Khimicheskaya tekhnologiya i biotekhnologiya. 2020. № 2. pp. 102-112.

6. Marshakov D.V., Tsvetkova O.L., Aydiyanyan A.R. Inzhenernyj vestnik Dona, 2011, № 3. URL: ivdon.ru/ru/magazine/archive/n3y2011/504 (accessed 16/12/2023).

7. Shumikhin A.G., Boyarshinova A.S. Inzhenernyj vestnik Dona, 2017, № 2. URL: ivdon.ru/ru/magazine/archive/N2y2017/4124 (accessed 20/12/2023).

8. Yergök D., Güven C.T., Aci M. International Conference on Advanced Technologies. Computer Engineering and Science. 2018. pp. 583-586.



9. Mukhovichova N.K. Kuzbasskiy gosudarstvennyy tekhnicheskiy universitet: materialy vserossiyskoy nauchno-prakticheskoy konferentsii molodykh uchenykh «Rossiya Molodaya», 2019. URL: science.kuzstu.ru/wp-content/Events/Conference/RM/2019/RM19/pages/Articles/70207.pdf (accessed 24/12/2023).

10. Smith S.W. The Scientist and Engineer's Guide to Digital Signal Processing. California Technical Publishing, 2001. 611 p.

11. Rotach V.Ya. Teoriya avtomaticheskogo upravleniya [Automatic control theory]. Moskva, Izdatel'skiy dom Moskovskogo energeticheskogo instituta, 2008. 396 p.

Дата поступления: 20.05.2024

Дата публикации: 30.08.2024