

# МЕТОД АДАПТИВНОГО ИМИТАЦИОННОГО МОДЕЛИРОВАНИЯ МНОГОМЕРНЫХ СИГНАЛОВ В ИНФОРМАЦИОННО-УПРАВЛЯЮЩИХ СИСТЕМАХ РЕАЛЬНОГО ВРЕМЕНИ

ARTIFICIAL INTELLIGENCE METHODS  
IN SIMULATION MODELING  
OF MULTIDIMENSIONAL SIGNALS  
IN REAL-TIME INFORMATION  
AND CONTROL SYSTEMS

**I. Rozanov**  
**A. Sotnikov**

*Summary.* The authors reviewed methods of artificial intelligence in the field of simulation modeling, proposed the method for increasing the adequacy of the generic simulation modeling system of multidimensional signals.

The method is based on a hybrid artificial intelligence system, that provides targeted search and clustering of input parameters of the simulation system.

The result of this method are visualized clusters of input parameters of the model, which allow the formation of recommendations for the selection of different ranges of parameters and adjusting the characteristics of a simulation model of multidimensional signals while ensuring its adequacy

*Keywords:* simulation modeling, hybrid systems, artificial intelligence, real-time systems.

**Розанов Иван Александрович**

Ведущий инженер НИЧ НУК ИУ МГТУ им. Н.Э. Баумана

**Сотников Алексей Александрович**

К.т.н

Московский Государственный Технический

Университет им. Н.Э. Баумана

sotnikov@bmstu.ru

*Аннотация.* Авторами рассмотрены технологии искусственного интеллекта и их возможность применения в области имитационного моделирования многомерных сигналов информационно-управляющих систем реального времени, предложен метод увеличения адекватности обобщенной системы имитационного моделирования многомерных сигналов.

Метод основан на гибридной технологии, которая обеспечивает направленный поиск и кластеризацию входных параметров системы моделирования, обеспечивающих её адекватность.

Результатом применения данного метода являются визуализированные кластеры входных параметров модели, которые позволяют формировать рекомендации по выбору различных диапазонов параметров и настройке характеристик имитационной модели многомерных сигналов при одновременном обеспечении ее адекватности.

*Ключевые слова:* имитационное моделирование многомерных сигналов, гибридные системы, искусственный интеллект, системы реального времени.

## Введение

**В** последние десятилетия резкий рывок в технологическом развитии электронной компонентной базы привел к автоматизации и роботизации различных областей промышленности развитых стран, быта семей и отдельно взятых людей. Ключевую роль в этих процессах играют информационно-управляющие системы. Одним из эффективных способов испытания сложных информационно-управляющих систем как на этапах разработки, так и на этапах производства является имитационное моделирование сигналов [1]. Основными задачами систем имитационного моделирования в данном случае являются адекватное воспроизведение входных сигналов информационно-управляющей системы и оценка результатов ее функционирования по выходным сигналам (рисунок 1).

В целом под имитационным моделированием сигналов в данной работе мы понимаем междисциплинарную область системной инженерии, направленную на формирование информационного поля, реализованного с использованием определенных физических явлений под управлением электронно-вычислительных средств и предназначенного для исследования информационно-управляющей системы. В общем случае система имитационного моделирования сигналов представляет собой программно-аппаратный комплекс, реализующий алгоритмы формирования и оценки физических сигналов информационно-управляющей системы для обеспечения ее функционирования в режиме реального времени.

Наиболее важным требованием к имитационной модели является ее адекватность. В общем случае под адек-

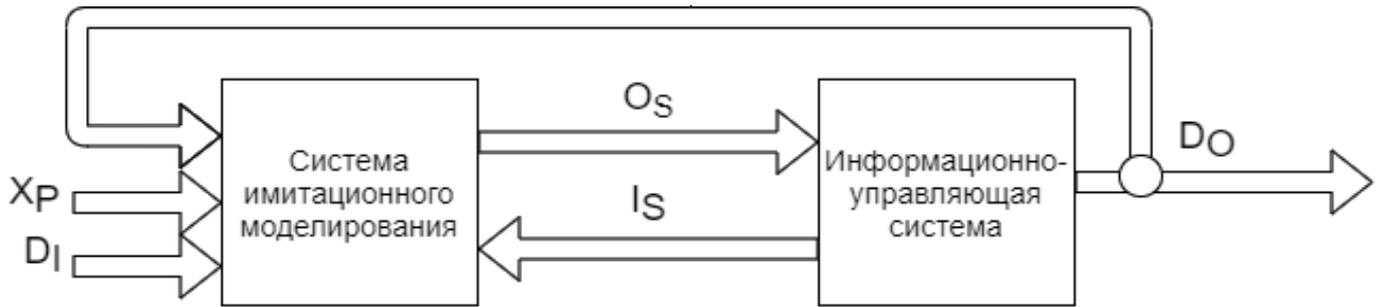


Рис. 1. Схема использования имитационного моделирования при полунатурных испытаниях:  $X_p$  — вектор входных параметров системы имитационного моделирования;  $D_I$  — вектор входных параметров объекта моделирования (параметры имитированных сигналов);  $D_O$  — вектор выходных параметров объекта моделирования;  $O_S$  — Вектор выходных сигналов системы имитационного моделирования;  $I_S$  — Вектор входных сигналов системы имитационного моделирования.

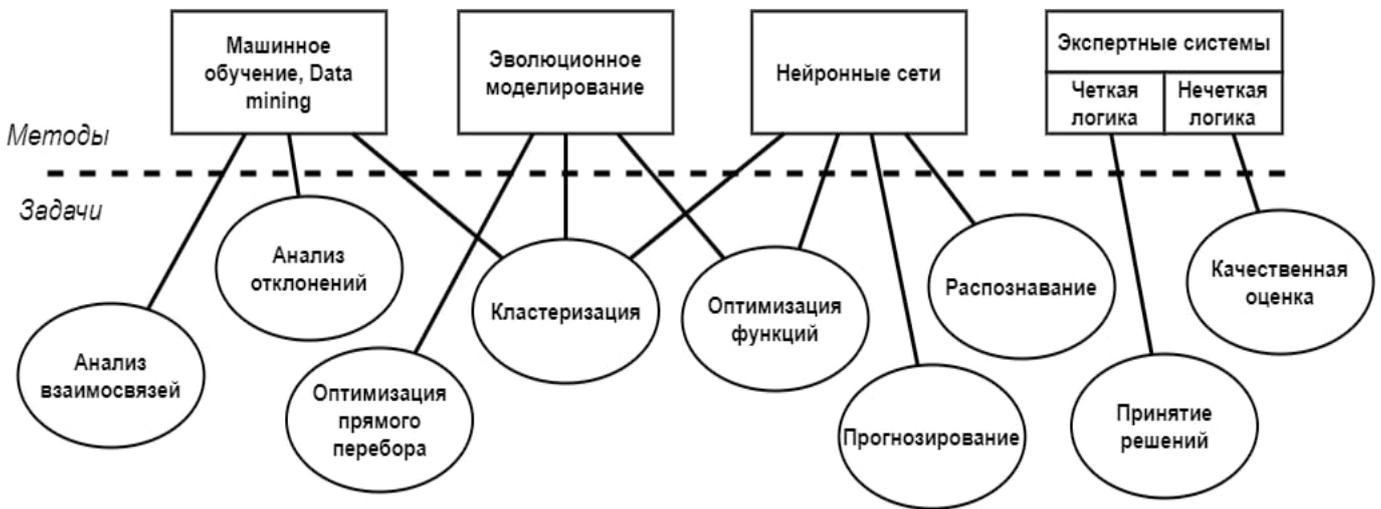


Рис. 2. Схема соответствия методов и задач искусственного интеллекта

ватностью понимают степень соответствия модели тому реальному явлению или объекту, для описания которого она строится с учетом целей исследования. Валидация имитационной модели на предмет ее адекватности представляет собой сложный процесс [2], как с точки зрения формального описания, так и, в общем случае, с точки зрения ресурсоемкости. В рамках проведения валидации модели необходимо оценить ее характеристики (точность, чувствительность, устойчивость, масштабируемость, производительность). Проверяемые характеристики модели зависят от вектора ее входных параметров и управляются им. Размерность вектора входных параметров в общем случае может быть большой, что является предпосылкой для использования в настройке модели методов и автоматизированных средств поиска оптимальной конфигурации системы имитационного моделирования. В некоторых случаях наиболее эффективным является аналитическое решение поставленной

задачи. Тем не менее зачастую «прямое» решение задачи связано с использованием слишком сложных вычислений и требует применения эвристических методов, либо предполагается динамическое изменение конфигурации системы имитационного моделирования в процессе функционирования с использованием обратных связей и адаптивной подстройкой параметров. Кроме того, есть задачи, решение которых не может быть записано в виде алгоритма и требует разветвленного подхода к принятию решений, подобного тому, что использует человеческий разум.

В данной статье авторами проведен анализ различных методов искусственного интеллекта, определена степень их соответствия требованиям применения в области имитационного моделирования сигналов, предложен метод увеличения адекватности обобщенной системы моделирования.

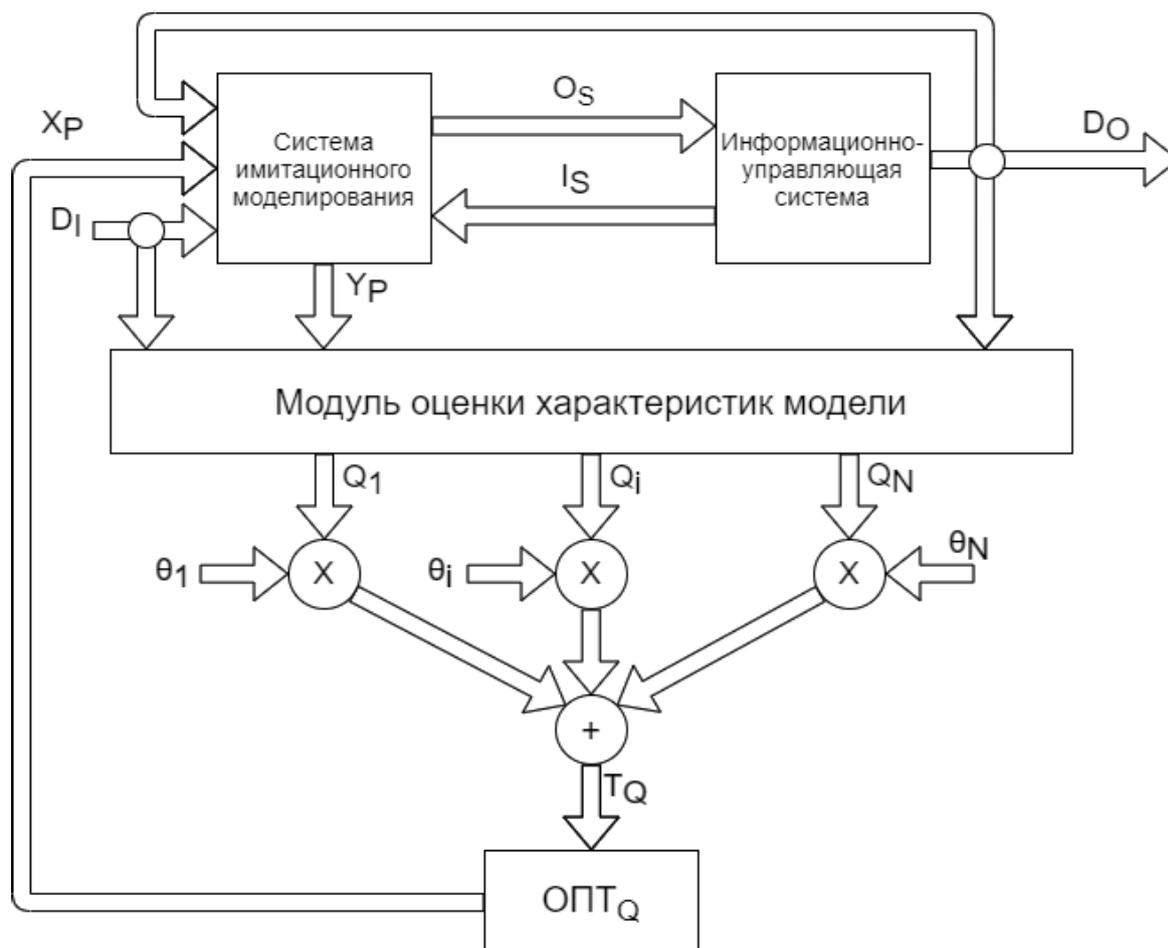


Рис. 3. Функциональная схема системы адаптивного управления параметрами:  $X_{p0}$  — вектор начальных параметров системы имитационного моделирования;  $Y_p$  — вектор выходных параметров системы имитационного моделирования;  $Q_i$  — вектор характеристики системы моделирования;  $\theta_i$  — вектор весовых коэффициентов характеристик системы моделирования;  $T_q$  — функция адекватности (качества) системы моделирования.

### Имитационное моделирование сигналов с применением технологии искусственного интеллекта

Искусственный интеллект — это область информационных технологий, направленная на создание компьютерных систем, имитирующих работу человеческого интеллекта при решении задач [3]. На данный момент наибольшее развитие получили такие методы искусственного интеллекта как нейронные сети, эволюционное моделирование, экспертные системы. Большое количество научных работ [4–7] посвящено применению данных методов для решения различных задач (рисунок 2).

Такие методы ИИ как нейросети и генетические алгоритмы позволяют организовать «направленный» поиск, что существенно сокращает ресурсоемкость

перебора входных параметров системы имитационного моделирования в процессе поиска оптимальных значений и обеспечения адекватности. На рисунке 3 представлена функциональная схема взаимодействия системы имитационного моделирования и информационно-управляющей системы с системой адаптивного управления параметрами модели.

Результатом работы такой функциональной схемы станет множество векторов входных параметров системы имитационного моделирования  $U_p$ , которые удовлетворяют выражению

$$\forall X_p \in U_p: T_q < T_{qmax},$$

где  $T_{qmax}$  — наибольшее значение функции  $T_q$ , при котором системы моделирования является адекватной [8].

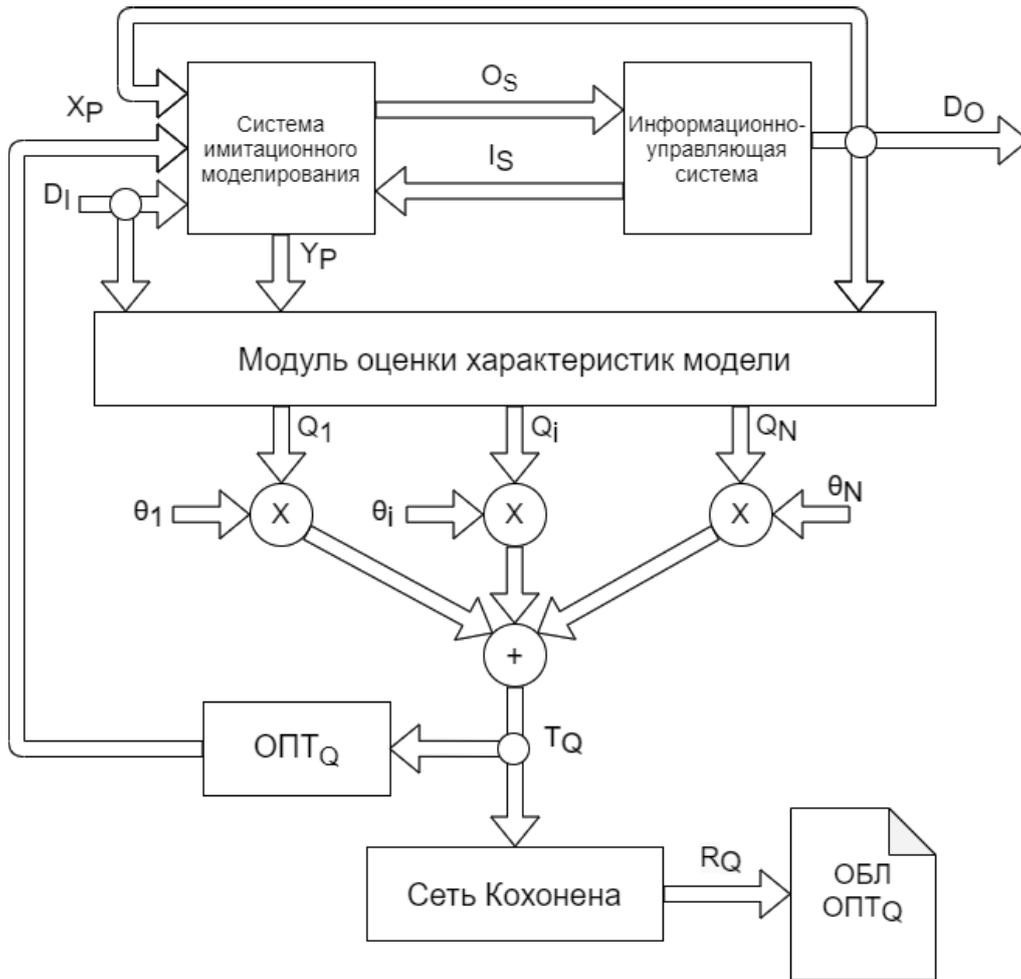


Рис. 4.— Структурная схема гибридной системы адаптивного имитационного моделирования:  
 $R_Q$  — вектор кластеризованных областей оптимальных параметров модели;

**Кластеризация параметров имитационной модели сигналов**

Сами по себе найденные значения вектора параметров представляют интерес с точки зрения адекватности модели, однако с инженерной точки зрения полезнее интервальные допущения, что ставит перед нами задачу кластеризации (рисунок 4).

Главной частью этой схемы является модуль оценки характеристик модели, в качестве которой авторы предлагают использовать нейронную сеть. Такая нейросеть в общем виде задается функцией активации, функцией ошибки и правилом пересчета весовых коэффициентов. Состояние каждого нейрона задается формулой

$$S = \sum_{i=1}^N Q_i \theta_i, \tag{1}$$

где  $\theta_i$  — весовые коэффициенты.

Функция активации  $f$ , как правило, подбирается в соответствии с конкретной предметной областью [9], и в общем виде значение аксона равно

$$Y = f(S),$$

а функция ошибки вычисляет вектор качества (адекватности) системной модели:

$$T(Q) = \frac{1}{2} \sum_{i=1}^p (y_i - d_i)^2,$$

где  $y_i$  — значение  $i$ -го выхода нейросети,  $d_i$  — целевое значение  $i$ -го выхода,  $p$  — число нейронов в выходном слое. Обучение такой адаптивной системы моделирования можно обеспечить, например, при помощи градиентного спуска:

$$\Delta w_{ij} = -\eta \cdot \frac{\partial E}{\partial w_{ij}},$$

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial y_i} \cdot \frac{dy_i}{dS_j} \cdot \frac{\partial S_j}{\partial w_{ij}},$$

где  $\eta$  — параметр, определяющий скорость обучения;  $y_i$  — значение выхода  $i$ -го нейрона,  $S_j$  — взвешенная сумма входных сигналов, определяемая по формуле (1).

Выработанные нейронной сетью оптимальные многомерные входные параметры имитационной модели размерностью  $p$  и многомерность вектора выходных параметров объекта моделирования обуславливают высокую сложность интерпретации результатов до и после кластеризации. Таким образом, важным фактором при выборе алгоритма кластеризации является возможность качественной визуализации, интерпретируемой человеком. Этим свойством обладают кластеризаторы в виде сетей Кохонена, которые также обеспечивают устойчивость к зашумленным данным [10]; позволяют обнаружить скрытые закономерности в больших массивах данных.

Сети Кохонена легко встроить в исходную систему моделирования, подключить дополнительные слои Кохонена к выходам первичного модуля искусственного интеллекта.

Для создания такой нейросети необходимо осуществить выбор количества кластеров  $K$ , который можно осуществить разными способами, указанными в литературе [11].

На стадии инициализации всем весовым коэффициентам присваиваются небольшие случайные значения  $w_{ij}^0, i = 1, 2, \dots, m$ .

На выходы сети подаются последовательно в случайном порядке образы  $y$  объектов входного слоя и для каждого из них выбирается «нейрон-победитель» с минимальным расстоянием:

$$\sum_{i=1}^m (y_i - w_{ij}^t).$$

Далее определяется подмножество ближайшего окружения «нейрона-победителя», радиус которого  $R$  уменьшается с каждой итерацией  $t$ .

Пересчитываются веса  $w_j^t$  выделенных узлов с учетом их расстояний до нейрона-победителя и близости к вектору  $y$ .

Последние 3 шага повторяются, пока выходные значения не будут стабилизированы с заданной точностью [12].

## Заключение

В результате проведенного анализа различных методов и технологий искусственного интеллекта авторами предложен метод адаптивного имитационного моделирования с гибридным искусственным интеллектом, обеспечивающий выполнение требования адекватности модели. Результатом применения предложенного метода являются кластеры значений параметров модели, позволяющие формировать рекомендации по настройке характеристик имитационной модели многомерных сигналов при одновременном обеспечении ее адекватности.

Данное исследование выполнено за счет гранта Российского научного фонда № 22–11–00049, <https://rscf.ru/project/22-11-00049/> от 12.05.2022.

## ЛИТЕРАТУРА

1. Строгалев В.П., Толкачева И.О. Имитационное моделирование (3-е издание), 2017.
2. Пепеляев В.А., Черный Ю.М. О современных подходах к оценке достоверности имитационных моделей//Режим доступа: <http://www.gpss.ru>, 2003.
3. Zeigler B., Muzy A., Yilmaz L. Artificial Intelligence in Modeling and Simulation//Computational Complexity/ ed. R.A. Meyers. — New York, NY: Springer New York, 2012. — P. 204–227.
4. Leondes C.T. Fuzzy Logic and Expert Systems Applications. — Elsevier, 1998. — 437 p.
5. Cook D.F., Ragsdale C.T., Major R.L. Combining a neural network with a genetic algorithm for process parameter optimization//Engineering applications of artificial intelligence, 2000, T. 13, N4, С. 391–396.
6. Bäck T., Schwefel H.-P. An Overview of Evolutionary Algorithms for Parameter Optimization//Evolutionary Computation, 1993, T. 1, N1, С. 1–23.
7. Better M., Glover F., Laguna M. Advances in analytics: Integrating dynamic data mining with simulation optimization//IBM journal of research and development, 2007, T. 51, Advances in analytics, N3.4, С. 477–487.
8. Королев М.Р., Лобейко В.И., Старусев А.В. Оценка адекватности комплексной модели сложной технической системы//Известия Волгоградского государственного технического университета, 2012, N4, С. 12–15.
9. Рудой Г.И. Выбор функции активации при прогнозировании нейронными сетями//Машинное обучение и анализ данных, 2011, T. 1, N1, С. 16–39.

10. Манжула В.Г., Федяшов Д.С. Нейронные сети Кохонена и нечеткие нейронные сети в интеллектуальном анализе данных//Фундаментальные исследования, 2011, N4, С. 108–114.
11. Елизаров С.И., Куприянов М.С. Проблема определения количества кластеров при использовании методов разбиения//Известия высших учебных заведений. Приборостроение, 2009, Т. 52, N12, С. 3–8.
12. Э.Ш.В.К. Мاستицкий С. Классификация, регрессия и другие алгоритмы Data Mining с использованием R.

---

© Розанов Иван Александрович, Сотников Алексей Александрович ( sotnikov@bmstu.ru ).

Журнал «Современная наука: актуальные проблемы теории и практики»



Московский Государственный Технический Университет им. Н.Э. Баумана