

Можаровский И.С.<sup>1,2</sup>, Шевлягина С.А.<sup>1</sup>

## **АЛГОРИТМ ПОИСКА ПАРАМЕТРОВ НЕЙРОСЕТЕВОГО ВИРТУАЛЬНОГО АНАЛИЗАТОРА ДЛЯ ОЦЕНКИ НАЧАЛА КИПЕНИЯ КЕРОСИНОВОЙ ФРАКЦИИ НА ОСНОВЕ ОПТИМИЗАЦИИ РОЯ ЧАСТИЦ**

<sup>1</sup>Институт автоматизации и процессов управления Дальневосточного отделения Российской академии наук, 690041, Владивосток, Россия

<sup>2</sup>Владивостокский государственный университет, 690014, Владивосток, Россия

*Для мониторинга и оперативного управления качеством выходного продукта в режиме реального времени особую актуальность получили виртуальные анализаторы (ВА). Смена технологического режима функционирования установки, изменение технического состояния производственного оборудования в процессе эксплуатации приводит к необходимости разработки ВА на основе нейронных сетей (НС) – нейросетевых виртуальных анализаторов, позволяющих учитывать текущее состояние технологического процесса. Сложность разработки нейросетевых ВА заключается в определении оптимальных параметров НС. В работе показана разработка нейросетевого виртуального анализатора с использованием оптимизации роя частиц на примере установки перегонки сырой нефти. Предложенный подход позволяет определять оптимальную структуру НС при разработке нейросетевого ВА: количество скрытых слоев, нейронов в каждом слое и функции активации для каждого скрытого слоя. Результаты показывают, что нейросетевой ВА, построенный с помощью предлагаемого подхода, позволяет успешно отслеживать динамику процесса перегонки сырой нефти и достаточно точно оценивать начало кипения керосиновой фракции, которая является важным продуктом и используется в качестве топлива для реактивных и турбовинтовых авиационных двигателей. Кроме того, превосходство предлагаемого подхода иллюстрируется сравнением с другими методами поиска оптимальной структуры НС. Предлагаемый подход позволяет обеспечить более высокий уровень точности прогнозирования, чем другие методы. Результаты работы представляют практическую значимость при разработке систем усовершенствованного управления технологическими процессами.*

**Ключевые слова:** виртуальный анализатор, нейронная сеть, оптимизация роя частиц, параметры, процесс перегонки сырой нефти, начало кипения, керосиновая фракция.

**I.S. Mozharovskii<sup>1,2</sup>, S.A. Shevlyagina<sup>1</sup>**

## **ALGORITHM OF OPTIMIZING NEURAL NETWORK PARAMETERS FOR A SOFT SENSOR DESIGN FOR ESTIMATING THE BOILING POINT**

# OF A KEROSENE FRACTION BASED ON PARTICLE SWARM OPTIMIZATION

<sup>1</sup>Institute of Automation and Control Process FEB RAS, 690041, Vladivostok, Russia

<sup>2</sup>Vladivostok State University, 690014, Vladivostok, Russia

*Soft sensors (SSs) have become especially relevant for monitoring and operational management of output product quality in real time. Changes in the process operating mode of a plant and the technical condition of production equipment during operation necessitate the development of SSs based on neural networks (NNs) that can account for the current state of the process. The complexity of developing neural network SSs lies in determining the optimal NN parameters. This paper presents the development of a neural network SS using particle swarm optimization for a crude oil distillation unit as an example. The proposed approach allows for determining the optimal NN structure when developing a SS based on neural network: the number of hidden layers, neurons in each layer, and activation functions for each hidden layer. The results demonstrate that a SS constructed using the proposed approach can successfully track the dynamics of the crude oil distillation process and accurately estimate the boiling point of the kerosene fraction, which is an important product used as fuel for jet and turboprop aircraft engines. Furthermore, the superiority of the proposed approach is illustrated by comparison with other methods for finding the optimal neural network structure. The proposed approach enables a higher level of forecasting accuracy than other methods. The results of the study are of practical significance for the development of advanced process control systems.*

**Keywords:** soft sensor, neural network, particle swarm optimization, parameters, crude oil distillation process, boiling point, kerosene fraction.

**Введение.** Развитие современных методов управления технологическими процессами влияет на все аспекты мониторинга и управления процессами [1, 2]. В условиях развития новых методов регулирования, применения интеллектуальных датчиков и усовершенствованных систем управления технологическими процессами, промышленные предприятия должны демонстрировать большую эффективность и требуемое качество выпускаемой продукции с минимальными энергетическими и материальными затратами. В результате появляется необходимость в контроле и управлении большого количества технологических параметров на основе соответствующих измерительных устройств и лабораторного контроля качества конечных продуктов, который проводят 1-4 раза в сутки, что не позволяет оперативно отслеживать спецификацию всех производимых продуктов.

Особый интерес в нефтеперерабатывающей промышленности вызывают виртуальные анализаторы (ВА) для оценки трудноизмеримых показателей качества технологического процесса, которые осуществляют прогноз на основе непрерывно измеряемых значений приборов (термопар, расходомеров, датчиков давления и т.д.) [3-6]. Их можно использовать параллельно с другими датчиками, а также в качестве резервного датчика, когда поточный анализатор неисправен или удален для обслуживания или замены, чтобы поддерживать исправную работу контуров управления и гарантировать требуемую спецификацию выходного продукта. При разработке ВА используются различные подходы моделирования. В большинстве случаев используются методы моделирования на основе данных, так они доступны в режиме реального времени [7-9].

Установки перегонки сырой нефти широко используются в нефтеперерабатывающей промышленности для разделения поступающей сырой нефти на ее составляющие фракции, используя разницу в их температурах кипения. Качество конечных продуктов для такого процесса проверяется лабораторными анализами один раз в день с использованием метода ASTM D86, что требует больших временных затрат, поэтому особый интерес заключается в разработке эффективного виртуального анализатора для оценки свойств продукта с целью постоянного мониторинга и оперативного управления такими процессами в режиме реального времени [10].

В условиях смены технологического режима функционирования установки, а также изменения технического состояния производственного оборудования в процессе эксплуатации со временем снижается и точность разработанного ВА. Для повышения точности прогнозирования и лучшего отражения динамических характеристик особую актуальность приобретают нейросетевые ВА, построенные на базе нейронных сетей (НС) и позволяющие учитывать нелинейные характеристики процесса [11-14]. При достаточной

точности разработанные ВА могут использоваться в контуре обратной связи для автоматического управления и оптимизации технологическим процессом.

При разработке нейросетевого ВА большое количество времени уходит на поиск наиболее эффективной структуры НС для решения заданной задачи. Процедура настройки, обучения, тестирования и сравнения ожидаемой производительности применяется к каждой экспериментальной нейронной сети. Параметры структуры НС – функции активации, количество скрытых слоев, количество нейронов в каждом скрытом слое – имеют несколько возможных значений. При подборе архитектуры во многих случаях используются НС с одним или двумя скрытыми слоями с одинаковым количеством нейронов в каждом слое [15, 16]. Такой подход не гарантирует эффективность подобранной архитектуры нейронной сети. В настоящее время актуальным становится использовать различные эволюционные алгоритмы [17-19] для поиска оптимальной структуры НС, а также современные платформы AutoML. В последних применяются разнообразные методики, такие как нейроэволюция и байесовская оптимизация, каждая из которых имеет свои уникальные преимущества и недостатки. Еще одним популярным методом является метод оптимизации роя частиц, использующий принципы социального взаимодействия и коллективного обучения для поиска оптимальных решений [20, 21]. В контексте поиска оптимальной структуры НС каждая частица в «рое» представляет потенциальную архитектуру, при этом все частицы движутся по пространству возможных решений, адаптируясь и обучаясь на основе личного и коллективного опыта.

В статье представлен подход к повышению точности ВА за счет оптимизации структуры нейронной сети на основе оптимизации роя частиц, который одновременно оптимизирует как количество скрытых слоев, нейронов, а также функции активации нейронной сети прямого распространения. Продемонстрирована эффективность предложенного подхода в сравнении с альтернативными подходами при разработке нейросетевого ВА для оценки начала кипения керосиновой фракции.

## Метод поиска оптимальной структуры НС для разработки ВА.

Процесс оптимизации параметров НС для разработки ВА заключается в итеративном движении частиц-структур ( $nParticles$ ) в пространстве поиска. Каждая частица корректирует свою позицию, ориентируясь как на наилучшее решение, найденное ею самой (локальный оптимум), так и на лучшее решение, обнаруженное всеми частицами в рое –  $gBest$  (глобальный оптимум). Такой механизм обеспечивает эффективный баланс между двумя критически важными аспектами поиска: интенсивным исследованием перспективных областей и широким охватом всего пространства возможных решений. Использование оптимизации роя частиц для поиска параметров НС позволяет не только исключить субъективный ручной подбор, но и существенно повысить шансы нахождения структуры, устойчивой к переобучению и обладающей высокой прогнозирующей способностью для задач промышленной аналитики.

В качестве основных параметров НС были выбраны: количество слоев, количество нейронов в каждом слое и типы активационных функций. Выбор оптимальной структуры НС осуществлялся на основе максимизации коэффициента детерминации ( $R^2$ ) и минимизации среднеквадратической ошибки (СКО), рассчитанных на основе нейросетевой модели ВА. Алгоритм поиска структуры НС и построение на ее основе ВА описан ниже:

- (1) Старт
- (2) Инициализация начальных параметров НС: задается максимальное количество слоев ( $l_{max}$ ), нейронов ( $n_{max}$ ) и функций активации ( $f_{max}$ )
- (3) Инициализация роя частиц: задается количество итераций ( $Iter_{max}$ ), количество частиц структур в рое ( $nParticles$ ), инерционный вес на итерации ( $\omega$ ), коэффициенты ускорения ( $c_1, c_2$ ), случайные величины, равномерно распределенные в диапазоне  $[0, 1]$  ( $r_1, r_2$ ), случайным образом генерируются начальные значения скорости каждой из частиц ( $v$ ) и устанавливаются соответствующие векторы каждой частицы ( $x$ )

(4) Формирование структур НС для каждой частицы случайным образом в заданном диапазоне  $l=1, \dots, l_{max}$ ,  $n=1, \dots, n_{max}$

(5) Кодировка функций активации в диапазоне  $[1, f_{max}]$ . Случайным образом для каждого скрытого слоя присваивается функция активации из диапазона  $[1, f_{max}]$  в каждой структуре НС

(6) **For**  $t=1$  до  $Iter_{max}$

(7) **For**  $i=1$  до  $nParticles$

(8) Разработка ВА на основе полученной структуры НС

(9) Вычисление значений целевых функций  $R^2$  и СКО для каждой частицы (структуры НС)

(10) Для лучшей найденной частицей структуры по критериям  $R^2$  и СКО присваиваются значения  $pBest_i$

(11) Лучшей найденной структуре НС среди всех частиц системы по критериям  $R^2$  и СКО присваивается значение  $gBest$

(12) Обновление скорости и позиции для текущей частицы:

$$v_i(t+1) = \omega * v_i(t) + c_1 * r_1 * (pBest_i - x_i(t)) + c_2 * r_2 * (gBest - x_i(t))$$

$$x_i(t+1) = x_i(t) + v_i(t+1)$$

(13) **End for**

(14) Вывод промежуточных результатов

(15) **End for**

(16) Вывод оптимальной структуры НС

(17) Построение нейросетевого ВА

(17) Конец

Параметры НС были заданы как  $l_{max}=3$  и  $n_{max}=13$ . В качестве функций активации использовались 4 наиболее часто применяемые с соответствующей кодировкой: «tansig» – 1, «logsig» – 2, «radbas» – 3, «ReLu» – 4. На шаге (3) были заданы следующие параметры:  $\omega=0,7$ ;  $c_1=1,5$ ;  $c_2=1,5$ ; количество частиц в рое задано  $nParticles=50$ ;  $Iter_{max}=10$ . Для обновления текущей архитектуры НС используется шаг (12). По завершению работы вышеописанного алгоритма

находится оптимальная структура параметров нейронной сети для исследуемой выборки данных.

**Демонстрация работы предложенного подхода на примере перегонки бензина.** Предложенный алгоритм оптимизирует структуру НС, используемую при построении ВА для оценки начала кипения (н.к.) керосиновой фракции, получаемой в результате перегонки сырой нефти (рис. 1).

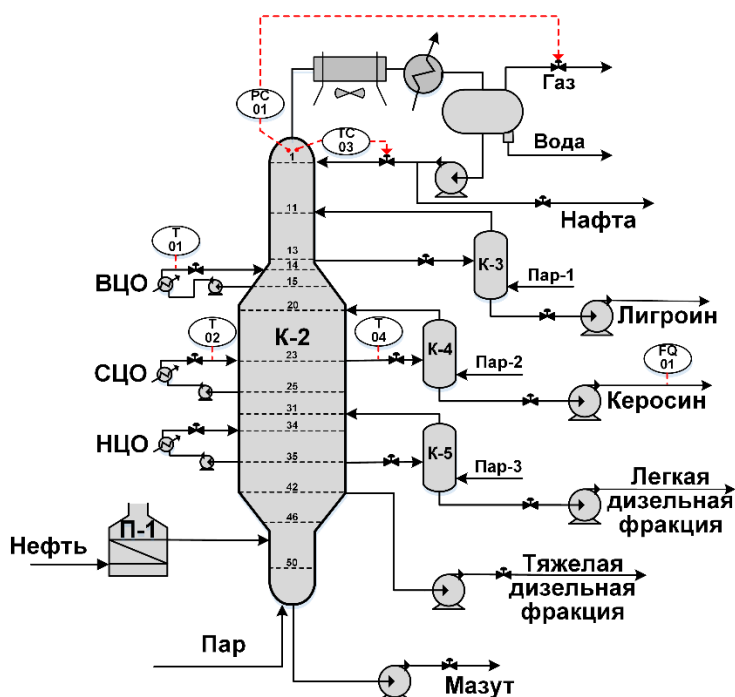


Рис. 1. Технологическая схема перегонки сырой нефти

Сырая нефть через печь (П-1) поступает в ректификационную колонну К-2. В верхней части К-2 имеется три циркуляционных орошения: верхнее циркуляционное орошение (ВЦО), среднее циркуляционное орошения (СЦО) и нижнее циркуляционное орошение (НЦО). Циркуляционные орошения позволяют поддерживать нужную температуру в К-2, а также позволяют достигать эффективного разделения фракций. Верхняя фракция дистиллята, извлеченная из К-2, представляет собой нафту. Мазут выводится из нижней части К-2. Продуктами боковых отпарных колонн являются: лигроин, керосин, легкое дизельное топливо и тяжелое дизельное топливо. Керосин является весьма важным продуктом, который можно использовать для сжигания в

лампах и бытовых обогревателях, а также используется в качестве топлива для реактивных и турбовинтовых авиационных двигателей.

Качество керосина проверяется лабораторными анализами один раз в день по методу ASTM D86. Проверка качества керосина (температура н.к.) с использованием лабораторных анализов является трудоемким процессом. Кроме того, керосин очень нестабилен во время проведения лабораторного анализа, что приводит к плохой повторяемости полученных результатов. В связи с этим разработка надежного виртуального анализатора для оценки начала кипения керосина является необходимой для мониторинга и управления процессом перегонки нефти в реальном времени.

На основе опыта и знаний операторов в качестве переменных-предикторов (входных переменных –  $u$ ) виртуального анализатора были выбраны те, которые связаны с н.к. керосина –  $y$ . В табл. 1 показаны шесть входных переменных, оказывающих влияние на выход (начало кипения керосина), с их рабочими диапазонами.

Таблица 1. Технологические параметры, оказывающие влияние на начало кипения керосиновой фракции

№	Поз.	Описание параметра	Вход / Выход	Диапазон	Среднее значение
1	PC01	Давление К-2, кгс/см <sup>2</sup>	$u_1$	0,55-1,21	0,68
2	TC03	Температура верха К-2, °С	$u_2$	109,9- 118,5	112,27
3	FQ01	Отбор из К-4, т/ч	$u_3$	1,45-55,11	18,28
4	T04	Температура на перетоке в К-4, °С	$u_4$	174,96- 208,41	190,32
5	T01	Температура ВЦО, °С	$u_5$	68,23- 113,79	87,16
6	T02	Температура СЦО, °С	$u_6$	45,5-97,1	71,36
7	-	Начало кипения керосина, °С	$y$	136-150	147



После предварительной обработки общий набор данных составил 538 наблюдений. Из них первые 377 наблюдений были разделены на три выборки: обучающую (70%), валидационную (15%) и тестовую (15%) для оптимизации структуры НС и обучения нейросетевого ВА. Оставшиеся последние 161 наблюдение использовалось для проверки прогнозирующей способности разработанного нейросетевого ВА на независимом фрагменте данных.

В табл. 2 показаны результаты оптимизации параметров НС с использованием предложенного алгоритма на каждой итерации.

Таблица 2. Результаты оптимизации параметров нейронной сети с помощью метода рая частиц на обучающей выборке данных

Итерация	СКО	$R^2$	Слои	Нейроны в слое			Функции активации		
				1	2	3	1	2	3
1	3,2468	0,5340	2	2	13	-	poslin	poslin	-
2	3,1644	0,5459	3	11	12	13	radbas	poslin	tansig
3	3,0176	0,5669	3	13	11	13	logsig	poslin	logsig
4	2,9299	0,5795	3	13	8	13	tansig	radbas	tansig
5	2,9033	0,5833	3	10	12	13	poslin	logsig	tansig
6	2,8671	0,5885	3	11	12	13	radbas	logsig	tansig
7	2,7656	0,6031	3	12	10	4	logsig	radbas	tansig
8	2,4434	0,6493	3	10	13	13	poslin	radbas	tansig
9	2,4434	0,6493	3	13	7	13	poslin	logsig	tansig
10	2,4434	0,6493	3	13	10	13	radbas	radbas	tansig

Можно заметить, что уже на второй итерации было определено оптимальное количество скрытых слоев, равное трем. На последующих итерациях осуществляется поиск оптимального количества скрытых слов и функции активации. Преимуществом данного подхода является возможность поиска функции активации для каждого скрытого слоя отдельно. Для демонстрации эффективности использования оптимизации роя частиц для поиска параметров НС были также использованы следующие подходы: сеточный поиск, случайный поиск и имитация отжига.

На рис. 2 представлены структуры нейронных сетей, полученные различными методами.




Рис. 2. Структуры НС, полученные с использованием: (а) сеточным поиском; (б) случайным поиском; (в) имитацией отжига; (г) оптимизацией роя частиц

На рис. 2 показано, что структура НС варьируется в зависимости от алгоритма оптимизации ее параметров. Максимальное количество скрытых слоев достигается при использовании оптимизации роя частиц с количеством нейронов 13, 10 и 13 с функциями активации «radbas» для первых двух скрытых слоев и «tansig» для последнего скрытого слоя.

Оценка прогнозирующей способности нейросетевых ВА осуществлялась на фрагменте данных, который не входил в обучение НС в сравнении с нейросетевыми ВА. В дополнение к критериям  $R^2$  и СКО были рассчитаны значения средней абсолютной ошибки (САО). Вычисленные значения критериев точности нейросетевых ВА показаны в табл. 3.

Таблица 3. Вычисленные значения критериев точности нейросетевых ВА на независимом фрагменте данных

№	Метод оптимизации НС	$R^2$	СКО	САО
1	Сеточный поиск	0,2946	6,0416	2,0453
2	Случайный поиск	0,2148	6,7253	2,1787
3	Имитация отжига	0,3128	5,8864	2,0206
4	Оптимизация роя частиц	0,4610	4,6167	1,6443

Результаты, представленные в табл. 3, подтверждают эффективность использования оптимизации роя частиц для нахождения оптимальной структуры НС при разработке ВА. Точность нейросетевого ВА с поиском

структуры НС оптимизацией роя частиц увеличивается на 47% по  $R^2$  и на 21% по СКО. Средняя абсолютная ошибка нейросетевого ВА составила  $1,6^{\circ}\text{C}$ .

Результаты функционирования нейросетевых ВА ( $\hat{y}$ ), разработанных на основе структур НС, полученных различными оптимизационными подходами, на независимом фрагменте данных представлены на рис. 3.

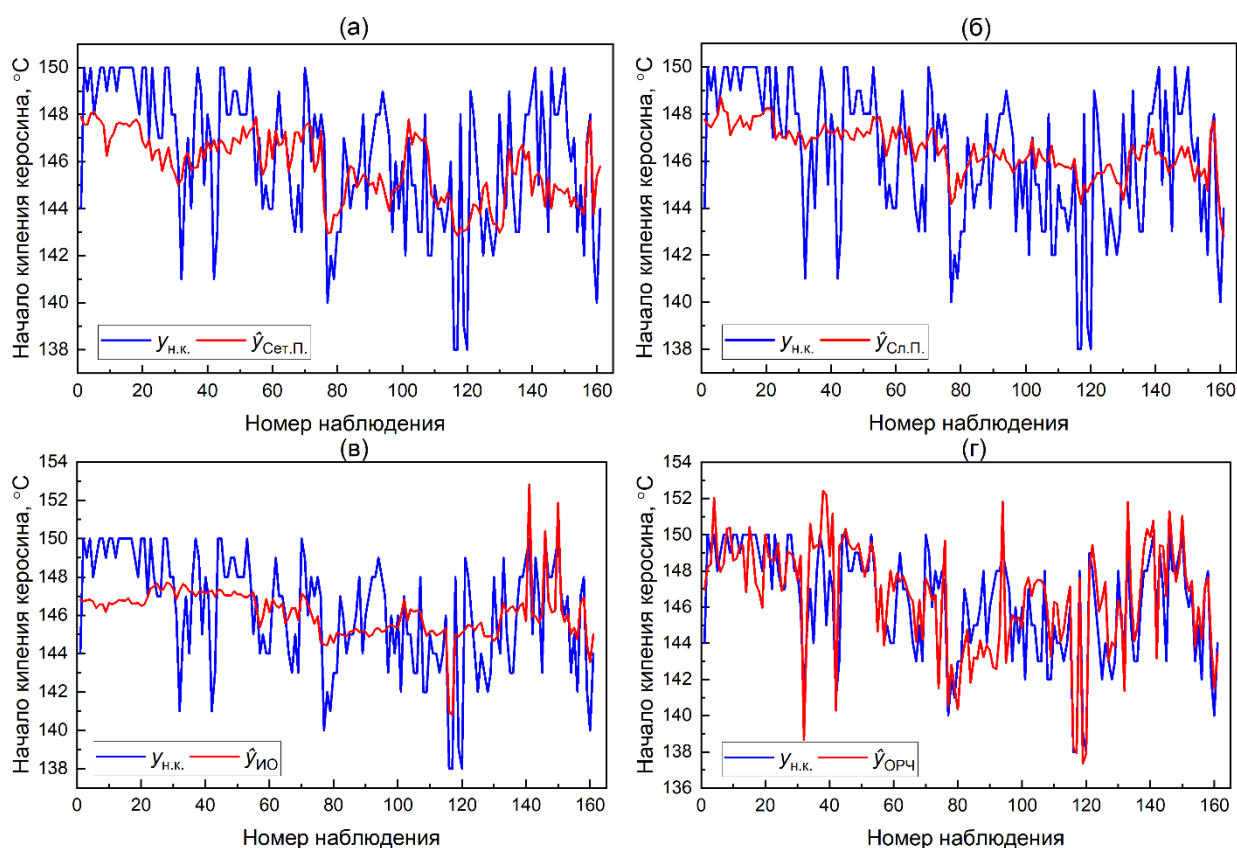


Рис. 3. Результаты оценки начала кипения керосиновой фракции с помощью ВА, разработанного на основе НС со структурой полученной: (а) сеточным поиском; (б) случайным поиском; (в) имитацией отжига; (г) оптимизацией роя частиц

Рис. 3 подтверждает высокую прогнозирующую точность ВА со структурой НС, полученной оптимизацией роя частиц. В остальных случаях нейросетевые ВА не всегда дают точную оценку температуры начала кипения керосиновой фракции особенно в диапазонах приближенных к верхним и нижним границам. Следует отметить, что такие методы, как сеточный поиск, случайный поиск и имитация отжига могут повысить точность ВА, если использовать их для тонкой настройки предварительно определенных структур нейронных сетей.

**Заключение.** Использование нейронных сетей для разработки виртуальных анализаторов является актуальным подходом для прогнозирования ключевых характеристик товарного продукта сложных технологических процессов. Точность разработанной модели во многом зависит от оптимальной архитектуры и параметров НС. В данной работе представлен подход разработки нейросетевых ВА для прогнозирования начала кипения керосиновой фракции установки первичной перегонки сырой нефти на основе оптимизации роя частиц. Предложенный подход позволяет определить оптимальную структуру нейросетевого ВА (количество скрытых слоев, количество нейронов в каждом слое и функцию активации для каждого скрытого слоя) и демонстрирует эффективность по сравнению с другими алгоритмами оптимизации.

**Благодарности.** Работа выполнена в рамках гос. задания Минобрнауки (FWFW-2025-0002).

## **Литература**

1. *Lee M., Yu Y., Cheon Y., Baek S., Kim Y., Kim K., Jung H., Lim D., Byun H., Lee C., Jeong J.* Machine learning-based prediction of controlled variables of APC systems using time-series data in the petrochemical industry // *Processes*. 2023. Vol. 11. Iss. 7. P. 2091.
2. *Raven D.B., Chikkula Y., Patel K.M., Al Ghazal A.H., Salloum H.S., Bakhurji A.S., Patwardhan R.S.* Machine learning & conventional approaches to process control & optimization: Industrial applications & perspectives // *Computers & Chemical Engineering*. 2024. Vol. 189. P. 108789.
3. *Мусаев А.А.* Виртуальные анализаторы: концепция построения и применения в задачах управления непрерывными технологическими процессами // *Автоматизация в промышленности*. 2003. Т. 8. С. 28-14.
4. *Улазевич В.Ю., Туманов А.В.* Идентификация виртуальных анализаторов качества нефтепродуктов с использованием выборок коррелирующих показателей // *Вестник Пермского национального*

исследовательского политехнического университета. Химическая технология и биотехнология. 2021. №. 1. С. 82-92.

5. *Ferreira J., Pedemonte M., Torres A.I.* Development of a machine learning-based soft sensor for an oil refinery's distillation column // *Computers & Chemical Engineering*. 2022. T. 161. С. 107756.

6. *Shevlyagina S.* Simulation of the physical temperature probes for soft sensor design under feed composition changes for naphtha plant // *Chemical Engineering Science*. 2024. Vol. 296. P. 120222.

7. *Shang C., Yang F., Huang D., Lyu W.* Data-driven soft sensor development based on deep learning technique // *Journal of Process Control*. 2014. Vol. 24. Iss. 3. P. 223-233.

8. *Yan W., Tang D., Lin Y.* A data-driven soft sensor modeling method based on deep learning and its application // *IEEE Transactions on Industrial Electronics*. 2016. Vol. 64. Iss. 5. P. 4237-4245.

9. *Mozharovskii I., Shevlyagina S.* A hybrid approach to soft sensor development for distillation-in-series plant under input data low variability // *Measurement Science and Technology*. 2024. Vol. 35. Iss. 7. P. 076211.

10. *Sun K., Huang S.H., Jang S.S., Wong D.S.H.* Development of soft sensor with neural network and nonlinear variable selection for crude distillation unit process // *Computer Aided Chemical Engineering*. 2016. Vol. 38. P. 337-342.

11. *Rani A., Singh V., Gupta J.R.P.* Development of soft sensor for neural network based control of distillation column // *ISA transactions*. 2013. Vol. 52. Iss. 3. P. 438-449.

12. *Тугашова Л.Г.* Виртуальные анализаторы показателей качества процесса ректификации // *Электротехнические и информационные комплексы и системы*. 2013. Т. 9. №. 3. С. 97-103.

13. *Zheng J., Ma L., Wu Y., Ye L., Shen F.* Nonlinear dynamic soft sensor development with a supervised hybrid CNN-LSTM network for industrial processes // *ACS omega*. 2022. Vol. 7. Iss. 19. P. 16653-16664.

14. *Alencar G.M.R.D., Fernandes F.M.L., Moura Duarte R., Melo P.F.D., Cardoso A.A., Gomes H.P., Villanueva J.M.M.* A soft sensor for flow estimation and uncertainty analysis based on artificial intelligence: A case study of water supply systems // *Automation*. 2024. Vol. 5. Iss. 2. P. 106-127.
15. *Sartori M.A., Antsaklis P.J.* A simple method to derive bounds on the size and to train multilayer neural networks // *IEEE transactions on neural networks*. 1991. Vol. 2. Iss. 4. P. 467-471.
16. *Rachmatullah M.I.C., Santoso J., Surendro K.* Determining the number of hidden layer and hidden neuron of neural network for wind speed prediction // *PeerJ Computer Science*. 2021. Vol. 7. P. e724.
17. *Chiroma H., Noor A.S.M., Abdulkareem S., Abubakar A.I., Hermawan A., Qin H., Hamza M.F., Herawan T.* Neural networks optimization through genetic algorithm searches: a review // *Applied Mathematics & Information Sciences*. 2017. Vol. 11. Iss. 6. P. 1543-1564.
18. *Cicek Z.I.E., Ozturk Z.K.* Optimizing the artificial neural network parameters using a biased random key genetic algorithm for time series forecasting // *Applied Soft Computing*. 2021. Vol. 102. P. 107091.
19. *Gallareta J.G., González-Menorca C., Muñoz P., Vasic M.V.* Advancements in Soft Sensor Technologies for Quality Control in Process Manufacturing: A Review // *IEEE Sensors Journal*. 2025.
20. *Казакова Е.М.* Применение метода роя частиц в задачах оптимизации // *Известия Кабардино-Балкарского научного центра РАН*. 2022. №. 5 (109). С. 48-57.
21. *Clerc M., Kennedy J.* The particle swarm-explosion, stability, and convergence in a multidimensional complex space // *IEEE transactions on Evolutionary Computation*. 2002. Vol. 6. №. 1. P. 58-73.

## References

1. *Lee M., Yu Y., Cheon Y., Baek S., Kim Y., Kim K., Jung H., Lim D., Byun H., Lee C., Jeong J.* Machine learning-based prediction of controlled variables of APC

- systems using time-series data in the petrochemical industry. *Processes*, 2023, vol. 11, no. 7, p. 2091.
2. *Raven D.B., Chikkula Y., Patel K.M., Al Ghazal A.H., Salloum H.S., Bakhurji A.S., Patwardhan R.S.* Machine learning & conventional approaches to process control & optimization: Industrial applications & perspectives. *Computers & Chemical Engineering*, 2024, vol. 189, p. 108789.
  3. *Musaev A.A.* Virtual'nye analizatory: koncepciya postroeniya i primeneniya v zadachah upravleniya nepreryvnymi tekhnologicheskimi processami. *Avtomatizatsiya v promyshlennosti*, 2003, vol. 8, pp. 28-14. (in Russian).
  4. *Ulahevich V.YU., Tumanov A.V.* Identifikatsiya virtual'nyh analizatorov kachestva nefteproduktov s ispol'zovaniem vyborok korreliiruyushchih pokazatelej. *Vestnik Permskogo nacional'nogo issledovatel'skogo politekhnicheskogo universiteta. Himicheskaya tekhnologiya i biotekhnologiya*, 2021, no. 1, pp. 82-92. (in Russian).
  5. *Ferreira J., Pedemonte M., Torres A.I.* Development of a machine learning-based soft sensor for an oil refinery's distillation column. *Computers & Chemical Engineering*, 2022, vol. 161, p. 107756.
  6. *Shevlyagina S.* Simulation of the physical temperature probes for soft sensor design under feed composition changes for naphtha plant. *Chemical Engineering Science*, 2024, vol. 296, p. 120222.
  7. *Shang C., Yang F., Huang D., Lyu W.* Data-driven soft sensor development based on deep learning technique. *Journal of Process Control*, 2014, vol. 24, no. 3, pp. 223-233.
  8. *Yan W., Tang D., Lin Y.* A data-driven soft sensor modeling method based on deep learning and its application. *IEEE Transactions on Industrial Electronics*, 2016, vol. 64, no. 5, pp. 4237-4245.
  9. *Mozharovskii I., Shevlyagina S.* A hybrid approach to soft sensor development for distillation-in-series plant under input data low variability. *Measurement Science and Technology*, 2024, vol. 35, no. 7, p. 076211.

10. *Sun K., Huang S.H., Jang S.S., Wong D.S.H.* Development of soft sensor with neural network and nonlinear variable selection for crude distillation unit process. *Computer Aided Chemical Engineering*, 2016, vol. 38, pp. 337-342.
11. *Rani A., Singh V., Gupta J.R.P.* Development of soft sensor for neural network based control of distillation column. *ISA transactions*, 2013, vol. 52, no. 3, pp. 438-449.
12. *Tugashova L.G.* Virtual'nye analizatory pokazatelej kachestva processa rektifikacii. *Elektrotekhnicheskie i informacionnye komplekсы i sistemy*, 2013, vol. 9, no. 3, pp. 97-103. (in Russian).
13. *Zheng J., Ma L., Wu Y., Ye L., Shen F.* Nonlinear dynamic soft sensor development with a supervised hybrid CNN-LSTM network for industrial processes. *ACS omega*, 2022, vol. 7, no. 19, pp. 16653-16664.
14. *Alencar G.M.R.D., Fernandes F.M.L., Moura Duarte R., Melo P.F.D., Cardoso A.A., Gomes H.P., Villanueva J.M.M.* A soft sensor for flow estimation and uncertainty analysis based on artificial intelligence: A case study of water supply systems. *Automation*, 2024, vol. 5, no. 2, pp. 106-127.
15. *Sartori M.A., Antsaklis P.J.* A simple method to derive bounds on the size and to train multilayer neural networks. *IEEE transactions on neural networks*, 1991, vol. 2, no. 4, pp. 467-471.
16. *Rachmatullah M.I.C., Santoso J., Surendro K.* Determining the number of hidden layer and hidden neuron of neural network for wind speed prediction. *PeerJ Comput-er Science*, 2021, vol. 7, p. e724.
17. *Chiroma H., Noor A.S.M., Abdulkareem S., Abubakar A.I., Hermawan A., Qin H., Hamza M.F., Herawan T.* Neural networks optimization through genetic algorithm searches: a review. *Applied Mathematics & Information Sciences*, 2017, vol. 11, no. 6, pp. 1543-1564.
18. *Cicek Z.I.E., Ozturk Z.K.* Optimizing the artificial neural network parameters using a biased random key genetic algorithm for time series forecasting. *Applied Soft Computing*, 2021, vol. 102, p. 107091.



19. *Gallareta J.G., González-Menorca C., Muñoz P., Vasic M.V.* Advancements in Soft Sensor Technologies for Quality Control in Process Manufacturing: A Review. *IEEE Sensors Journal*, 2025.
20. *Kazakova E.M.* Primenenie metoda roya chastic v zadachakh optimizacii // *Izvestiya Kabardino-Balkarskogo nauchnogo centra RAN*. 2022. №. 5 (109). S. 48-57. (in Russian).
21. *Clerc M., Kennedy J.* The particle swarm-explosion, stability, and convergence in a multidimensional complex space // *IEEE transactions on Evolutionary Computation*. 2002. Vol. 6. №. 1. P. 58-73.

### **Сведения об авторах**

**Можаровский Игорь Сергеевич**, канд. техн. наук, научный сотрудник лаборатории информационно-аналитических и управляющих систем и технологий (№ 65) Института автоматизации и процессов управления ДВО РАН, доцент кафедры информационных технологий и систем Владивостокского государственного университета; **Igor S. Mozharovskii**, Ph. D. (Eng.), researcher, Laboratory of Information-Analytical and Control Systems and Technologies (No. 65), Institute of Automation and Control Processes FEB RAS, Associate Professor, Department of Information Technologies and Systems, Vladivostok State University, studvvsu@gmail.com.

**Шевлягина Светлана Александровна**, канд. техн. наук, доцент, старший научный сотрудник лаборатории информационно-аналитических и управляющих систем и технологий (№65), Институт автоматизации и процессов управления ДВО РАН, доцент, Дальневосточный федеральный университет; **Svetlana A. Shevlyagina**, Ph. D. (Eng.), Associate Professor, senior researcher, Laboratory of Information-Analytical and Control Systems and Technologies (No. 65), Institute of Automation and Control Processes FEB RAS, shevlyagina\_sa@iacp.dvo.ru.