

НЕЙРОСЕТЕВОЙ ВИРТУАЛЬНЫЙ АНАЛИЗАТОР ДЛЯ ОЦЕНКИ ПОКАЗАТЕЛЯ КАЧЕСТВА ВЫХОДНОГО ПРОДУКТА С ИСПОЛЬЗОВАНИЕМ ГЕНЕТИЧЕСКОГО АЛГОРИТМА

И.С. Можаровский (ФГБОУ ВО «ВВГУ», ФГБУН ИАПУ ДВО РАН),
С.А. Шевлягина (ФГБУН ИАПУ ДВО РАН)

В промышленности широкое распространение получили нейросетевые виртуальные анализаторы (ВА) для оценки показателей качества выпускаемой продукции в режиме реального времени. При их разработке много времени уходит на поиск наиболее эффективной структуры нейронной сети (НС). Процедура настройки, обучения и тестирования применяется к каждой экспериментальной НС, так как параметры ее архитектуры – число скрытых слоев, число нейронов в каждом слое и функция активации имеют несколько возможных значений. Разработка подходов к поиску соответствующих гиперпараметров сократит время, необходимое для разработки нейросетевых ВА, и облегчит работу исследователей. Представлен подход к поиску оптимальной архитектуры НС при построении ВА с использованием генетического алгоритма. В предложенном подходе представлена модификация оператора скрещивания, позволяющая получить достаточно разнообразный набор гиперпараметров НС, что приводит к улучшению точности разработанного на ее основе ВА. Остановка алгоритма осуществляется автоматически при достижении критерия точности полученного нейросетевого ВА заданному значению. Эффективность предложенного подхода демонстрируется на синтетическом примере и на примере промышленного процесса стабилизации и перегонки бензина для оценки качества фракции 35...70 °C¹.

Ключевые слова: виртуальный анализатор, нейронная сеть, генетический алгоритм, оптимизация, процесс стабилизации и перегонки бензина, оценка показателя качества.

ВВЕДЕНИЕ

В нефтеперерабатывающей промышленности особое внимание уделяется контролю ключевых переменных качества продукта в режиме реального времени для оперативного управления технологическим процессом с минимальными энергетическими и материальными затратами. Поточные анализаторы, используемые для контроля показателей качества производимой продукции очень дороги, сложны в обслуживании и имеют значительную задержку по времени. В связи с этим особую актуальность приобрела разработка виртуальных анализаторов (ВА) для косвенной оценки ключевых показателей качества продукции, которые трудно или дорого измерить, путем создания математических моделей, связывающих ключевые переменные с технологическими параметрами, доступными в любой момент времени [1, 2]. Наиболее популярными методами для построения ВА являются множественная линейная регрессия [3], регрессия главных компонент [4], регрессия опорных векторов [5] и искусственные нейронные сети (ИНС) [6, 7].

В последнее время ИНС получили широкое распространение для создания более мощных и точных ВА. В работах [8–10] показано, что ВА на основе нейронной сети позволяют получать лучшие результаты прогнозирования, чем традиционные подходы, в том числе и для прогнозирования показателей качества выходных продуктов на установках перегонки сырой нефти [11] и стабилизации бензина [12].

Нейронные сети (НС) находят применение для решения различных практических задач: классификации данных, прогнозирования, распознавания звуков и изображений, нелинейного управления, системного анализа

и диагностики, анализа обнаружения неисправностей и т.д. Основной сложностью решения задач с нейронными сетями является определение топологии сети – сколько скрытых слоев и сколько нейронов должно быть в нейронных сетях. Этот вопрос имеет большое значение, поскольку от выбора топологии зависит нахождение эффективного решения. Случайный выбор числа скрытых нейронов может привести к проблемам переобучения или недообучения. Зачастую используются нейронные сети с одним скрытым слоем. Однако во многих практических случаях целесообразнее использовать альтернативные архитектуры ИНС с большим числом скрытых слоев и меньшим числом нейронов. С одной стороны, такая структура сети позволяет решать сложные задачи. С другой – для хорошей прогнозирующей способности сеть должна быть максимально компактной [13]. Кроме того, топология нейронной сети оказывает большое влияние на ее динамику обучения [14]. Большое разнообразие различных типов нейронных сетей и их использования делают невозможным определение универсального решения для выбора подходящей топологии.

В статье представлен автоматизированный процесс поиска нейронных сетей с подходящей структурой для разработки ВА на основе генетического алгоритма. Предложенный подход итеративно формирует различные топологии нейронных сетей путем изменения числа нейронов, числа скрытых слоев и функции активации и проверяет, являются ли они приемлемыми в зависимости от заранее определенного критерия на независимом фрагменте данных. Использование полученной архитектуры нейронной сети позволяет построить эффективный по заданным критериям ВА для оценки показателя качества фракции 35...70 °C процесса стабилизации и перегонки бензина.

¹ Работа выполнена в рамках государственного задания ИАПУ ДВО РАН (тема № FFW-2025-0002)

РАЗРАБОТКА НЕЙРОСЕТЕВОГО ВИРТУАЛЬНОГО АНАЛИЗАТОРА С ИСПОЛЬЗОВАНИЕМ ГЕНЕТИЧЕСКОГО АЛГОРИТМА

Для демонстрации метода поиска оптимальной топологии нейронной сети для разработки ВА объекта был выбран генетический алгоритм (ГА) как наиболее распространенный метод оптимизации [15, 16]. Генетический алгоритм основан на концепциях биологической эволюции. Его плюсом является относительно быстрый поиск оптимальной структуры сети благодаря отбору индивидуумов, процедуре скрещивания и мутации.

В качестве основных гиперпараметров архитектуры нейронной сети выбраны: число слоев с ограничением 1...5 ед., число нейронов в каждом слое с ограничением 1...10 ед. и типы функций активации для каждого слоя. В качестве функций активации использовались четыре наиболее часто применяемые с соответствующей кодировкой: «tansig» – 1, «logsig» – 2, «radbas» – 3, «ReLU» – 4. Для разработки нейросетевого ВА классический ГА был модифицирован для поиска оптимальной структуры нейронной сети. Изменения в предлагаемом подходе заключаются в модификации оператора скрещивания, где новые наборы гиперпараметров НС формируются путем усреднения из двух случайно выбранных после селекции архитектур. С целью упрощения структур НС число слоев в новых формируемых наборах гиперпараметров ограничиваются минимальным из , число нейронов будет равняться среднему значению из (p_1, p_2) , а функция активации будет соответствовать функциям активации из p_1 . Мутация нового набора гиперпараметров, то есть изменения числа нейронов и функций активации, осуществлялась с вероятностью 10% ($M = 0,1$) в диапазонах их верхних и нижних границ. Новый набор гиперпараметров будет состоять из: (1) 50% структур НС, оставшихся в результате селекции, (2) 40% новых сформированных структур и (3) 10% структур, полученных в результате мутации. Общее число структур задается на шаге инициализации параметров ГА и в нашем случае равно $pop_size = 100$ ед. Для обучения НС использовался алгоритм Левенберга-Марквардта. Дополнительной отличительной особенностью предложенного алгоритма является критерий остановки. В отличие от существующих, где остановка алгоритма осуществляется при выполнении заранее заданного числа поколений, в нашем случае алгоритм автоматически останавливается при нахождении структуры нейронной сети, дающей требуемую точность разработанному на ее основе ВА на независимом фрагменте данных.

Алгоритм разработки нейросетевого ВА с определением оптимальной структуры нейронной сети на основе ГА

(0) Старт.

(1) Инициализация параметров ГА: число популяций с различными топологиями нейронных сетей (pop_size).

(2) Инициализация параметров нейронной сети: число скрытых слоев, число нейронов в каждом слое, функция активации для каждого скрытого слоя.

(3) Создание начальной популяции с различными топологиями нейронных сетей случайным образом:

(3а) сформировать случайным образом число слоев и нейронов в каждом слое;

(3б) задать функции активации для каждого слоя случайным образом.

(4) Вычислить значения целевой функции средней квадратической ошибки (СКО) для каждой структуры нейронной сети:

$$СКО = \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N},$$

где N – число измерений; $\hat{y}_i$ – показывает прогнозируемое значение; y_i – фактическое значение для измерения i .

(5) Пока $R^2 < \text{заданного значения}$ выполнять:

(6) ранжирование – сортировку значений целевой функции (1) по возрастанию;

(7) отбор $pop_size/2$ популяций с лучшими архитектурами нейронных сетей на основе целевой функции, то есть дающих минимальные значения целевой функции;

(8) селекцию – выбор из $pop_size/2$ популяций два набора топологий нейронной сети случайным образом;

(9) выполнить комбинированное скрещивание из выбранных структур (p_1, p_2) для получения новой:

(9а) максимальное число слоев определить как ;

(9б) число нейронов в каждом скрытом слое определить как среднее значение нейронов в каждом слое выбранных популяций (p_1, p_2) ;

(9в) функция активации для каждого слоя будет соответствовать функциям активации из p_1 .

(10) Мутация – из сформированных на шаге (9) новых структур НС случайно выбранные подвергаются мутации с заданной вероятностью M :

(10а) случайным образом выбираются скрытые слои для мутации;

(10б) число нейронов в выбранных скрытых слоях изменяется на случайные величины, находящиеся в интервале $[-2, 2]$;

(10в) случайным образом выбранные функции активации заменяются новыми.

(11) Обучение нейронных сетей с полученными архитектурами.

(12) Вычисление целевой функции (1) для нового набора гиперпараметров НС.

(13) Выбор наилучшей топологии нейронной сети на основе целевой функции (1) и построение ВА.

(14) Проверка прогнозирующей способности, полученного нейросетевого ВА на независимом фрагменте данных, который не участвовал в обучении НС, на основе коэффициента детерминации (2) и средней абсолютной ошибки (3):

$$R^2 = \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}, \quad (1)$$

$$CAO = \frac{\sum_{i=1}^N |y_i - \hat{y}_i|}{N}, \quad (2)$$

где $\bar{y}_i$ – усредненное фактическое значение наблюдаемой величины измерения i .

(15) В случае неудовлетворительных результатов, полученных на шаге (14), автоматически осуществляется повтор шагов (6)-(14) до тех пор, пока заданные значения критериев точности не будут достигнуты.

(16) Вывод лучшей архитектуры НС; значений критериев (1)-(3); времени, затраченного на поиск топологии НС, удовлетворяющей заданным критериям.

(17) Конец.

В результате работы алгоритма на выходе формируется оптимизированная архитектура с хорошей прогнозирующей способностью.

Для подтверждения эффективности предложенного подхода приведено его сравнение с подходами автоматизированного машинного обучения (AutoML), позволяющими автоматически создавать модели с хорошим качеством и в кратчайшие сроки; а также хорошо известными оптимизационными подходами: сеточного поиска (grid search), оптимизации роя частиц (particle swarm optimization), случайного поиска (random search), алгоритм имитации отжига (simulated annealing) [17]. Для корректного сравнения оптимизации роя частиц, случайного поиска и алгоритма имитации отжига был реализован предложенный подход к остановке алгоритмов. Разработка алгоритмов осуществлялась с использованием программного обеспечения Matlab R2021b; AutoGluon использовался для построения различных подходов AutoML в Python 3.12.2. Все вычисления осуществлялись на компьютере со следующей конфигурацией: операционная система Windows 10, процессор Intel i7-1165G7 (2,80 ГГц), 16 ГБ ОЗУ.

ДЕМОНСТРАЦИЯ ЭФФЕКТИВНОСТИ ПРЕДЛОЖЕННОГО ПОДХОДА НА СИНТЕТИЧЕСКОМ ПРИМЕРЕ

Продemonстрируем эффективность предложенного алгоритма на синтетическом примере:

$$y_i = \sin(x_i) + 0,1\alpha_i,$$

где α , x – случайные нормально распределённые величины со средним значением 0 и дисперсией 1, $i = 1, 100$.

Полученный набор данных был поделен на два фрагмента данных в соотношении 70% на 30%. Первый фрагмент данных делится на обучающую, валидационную и тестовую выборки в соотношении 70%, 15% и 15%. На втором фрагменте данных осуществляется проверка прогнозирующей способности разработанного ВА на основе найденной структуры НС и проверка выполнения критерия остановки алгоритма. Для проверки последнего задано значение коэффициента детерминации $R^2 > 0,8$. Эта величина определяется экспериментально и зависит от используемых данных. В случае невозможности достижения желаемого значения его необходимо снизить или вернуться на шаг подготовки данных.

В табл. 1 представлены результаты критериев точности ВА, разработанных с использованием различных подходов на независимом фрагменте данных.

Как показано в табл. 1, предложенный подход не уступает по точности и по времени нахождения оптимальной структуры НС для разработки ВА известным подходам. Показана достаточно хорошая точность разработанного ВА на независимом фрагменте данных, что свидетельствует об его эффективности как среди оптимизационных подходов, так и среди современных инструментов AutoML.

Значения выхода системы (y), а также результаты функционирования нейросетевых ВА ($\hat{y}$), разработанных на основе структур НС, полученных различными оптимизационными подходами, на независимом фрагменте данных для синтетического примера (4) изображены рис. 1.

Как показано на рис. 1 предложенный подход показывает большую точность предсказания, что делает его перспективным для использования в решении промышленных задач.

Таблица 1. Критерии точности ВА, полученных различными подходами, на независимом фрагменте данных для синтетического примера

Подход	СКО		R ²		CAO			
AutoGluon								
LightGBMXT_BAG_L1	0,0128		0,8257		0,0931			
LightGBM_BAG_L1	0,0133		0,8181		0,0959			
ExtraTrees_BAG_L1	0,0119		0,8380		0,0864			
NeuralNetFastAI_BAG_L2	0,0174		0,7621		0,1144			
Оптимизационные подходы для разработки нейросетевых ВА								
Подход	Время подбора структуры НС, с	СКО	R ²	CAO	Число нейронов в слое, ед. Функция активации в слое			
Случайный поиск	0,52	0,0114	0,8439	0,0868	4 Logsig»			
Оптимизация роя частиц	27,85	0,0142	0,8054	0,0969	6 ReLU			
Алгоритм имитации отжига	90,49	0,0118	0,8382	0,0922	5 ReLU	5 ReLU	5 ReLU	5 ReLU
Сеточный поиск	159,17	0,0083	0,8864	0,0792	1 ReLU	5 ReLU	10 ReLU	5 ReLU
Предложенный подход	48,06	0,0069	0,9052	0,0668	7 ReLU		8 Logsig	

ДЕМОНСТРАЦИЯ ЭФФЕКТИВНОСТИ ПРЕДЛОЖЕННОГО ПОДХОДА НА ПРИМЕРЕ БЛОКА СТАБИЛИЗАЦИИ И ПЕРЕГОНКИ БЕНЗИНА




Рис. 1. Функционирование разработанных нейросетевых ВА на независимом фрагменте данных. Структура НС получена: а) оптимизацией роя частиц б) случайным поиском в) алгоритмом имитации отжига г) предложенным подходом на основе ГА




Рис. 2. Схема стабилизации бензиновой фракции

Также эффективность предложенного подхода для нахождения оптимальной архитектуры нейронной сети при разработке ВА для оценки ключевого показателя качества выходного продукта продемонстрирована на процессе стабилизации и перегонки бензина (рис. 2).

Исследуемый процесс предназначен для стабилизации бензиновой фракции (фракции, выкипающей до 140 °С) с получением рефлюкса, углеводородного газа и дальнейшего разделения стабильной фракции 140 °С на фракцию 35...70 °С и фракцию 70...140 °С. Получаемая фракция 35...70 °С используется в качестве сырья процесса изомеризации. В связи с этим требуется оперативная оценка содержания суммы углеводородов C₇ во фракции 35...70 °С (дистиллят колонны К-2), так как превышение данного показателя приводит к преждевременному старению катализатора.

В табл. 2 представлены технологические параметры, используемые для построения нейросетевого ВА для оценки концентрации суммы углеводородов C₇ во фракции

Таблица 2. Технологические параметры для построения виртуальных анализаторов

№	Переменные	Описание	Ед. измерения	Позиция
1	x_1	Температура низа колонны К-2	°С	TC2
2	x_2	Температура верха колонны К-2	°С	TC1
3	x_3	Давление верха колонны К-2	МПа	PC2
4	x_4	Расход фракции 35...70 °С колонны К-2	м ³ /ч	FC3
5	x_5	Расход углеводородного газа колонны К-1	т/ч	FC2
6	x_6	Расход фракции 70...140 °С колонны К-2	м ³ /ч	FC4
7	y	Сумма углеводородов C ₇ во фракции 35...70 °С	% мас.	-

Таблица 3. Критерии точности ВА, полученных различными подходами, на независимом фрагменте данных для оценки концентрации суммы углеводов C_7 во фракции 35...70 °С

Подход	СКО		R ²		САО				
Множественная линейная регрессия	0,1492		0,0006		0,2439				
Множественная линейная регрессия + bias update	0,1146		0,2327		0,2123				
AutoGluon									
LightGBMXT_BAG_L1	0,1196		0,1987		0,1697				
LightGBM_BAG_L1	0,1139		0,2369		0,1797				
ExtraTrees_BAG_L1	0,1038		0,3045		0,2168				
NeuralNetFastAI_BAG_L2	0,1144		0,2337		0,2478				
Оптимизационные подходы для разработки нейросетевых ВА									
Подход	Время подбора структуры НС, с	СКО	R2	САО	Число нейронов в слое, ед. Функция активации в слое				
Случайный поиск	САО	0,0520	0,6519	0,1609	3 Logsig				
Сеточный поиск	0,1609	0,0561	0,6241	0,1742	10 Logsig	10 Logsig	5 Logsig	5 Logsig	10 Logsig
Оптимизация роя частиц	0,1742	0,0524	0,6487	0,1486	7 Tansig				
Алгоритм имитации отжига	0,1486	0,0514	0,6555	0,1673	6 Logsig			6 Logsig	
Предложенный подход	0,1673	0,0473	0,6832	0,1336	7 Logsig		9 Logsig	2 Logsig	




Рис. 3. Функционирование разработанных нейросетевых ВА для оценки концентрации C_7 во фракции 35...70 °С на независимом фрагменте данных. Структура НС получена: а) оптимизацией роя частиц б) случайным поиском в) алгоритмом имитации отжига г) предложенным подходом на основе ГА

35...70 °С. Отбор входных переменных осуществлялся на основе экспертной оценки операторов-технологов. Для интеграции разрабатываемых ВА в систему усовершенствованного управления были выбраны те, на основе которых осуществляется поддержание необходимого технологического режима. Для формирования набора данных использовались технологические параметры (входы-предикторы), полученные с датчиков установки и данные лабораторных анализов выходного продукта — концентрация суммы углеводов C_7 во фракции 35...70 °С. Входные переменные (x_1 – x_6) были сопоставлены со временем отбора проб для лабораторного контроля (y) и усреднены за последний час.

Из промышленного набора данных были удалены выбросы, после чего к оставшимся 652 наблюдениям была применена минимакс нормализация. Весь набор данных был разделен на две части в соотношении 70% на 30%. Первая часть случайным образом делилась на обучающую, валидационную и тестовую выборки в соотношении 70%, 15% и 15% для поиска оптимальной структуры и обучения нейронной сети. Вторая часть использовалась как независимый фрагмент данных для проверки прогнозирующей способности разработанного ВА на основе найденной структуры НС и остановки алгоритма. Таким образом, для нахождения топологии НС и ее обучения использовались первые 456 наблюдений, последние 196 наблюдений использовались как независимый фрагмент данных.

Для остановки алгоритма изначально было задано значение коэффициента детерминации $R^2 > 0,8$. Однако данное значение не было достигнуто и было снижено до $R^2 > 0,6$. Это может свидетельствовать о наличии нелинейности в технологическом процессе и/или не измеряемых возмущений, что усложняет процесс построения ВА. В табл. 3 показаны результаты вычислений критериев точности разработанных ВА для оценки концентрации суммы углеводов C_7 во фракции 35...70 °С с помощью различных подходов

включая промышленные подходы: метод множественной линейной регрессии без и с обновлением свободного коэффициента (bias update).

Как показано в табл. 3, для исследуемого промышленного процесса перспективным является разработка нейросетевых ВА, так как они позволяют повысить точность прогноза до 21% по САО, снизив среднюю ошибку прогноза до 0,1336 % мас. Для нахождения структуры НС, дающей точность прогноза по $R^2 > 0,6$, предложенным подходом уходит больше времени в сравнении другими с оптимизационными подходами. Несмотря на это, прогнозирующая способность разработанного ВА выше на 5% по (R^2) и 10% по САО в сравнении с оптимизацией роя частиц.

Значения лабораторного контроля (y) и результаты работы нейросетевых ВА ($\hat{y}$), разработанных на основе найденной структуры НС, для оценки концентрации суммы углеводородов C_7 во фракции 35...70 °С на независимом фрагменте данных показаны рис. 3.

Как показано на рис. 3, несмотря на высокую прогнозирующую точность разработанных нейросетевых ВА, не все модели позволяют корректно оценить изменения показателя качества. Нейросетевые ВА с найденной структурой НС с помощью оптимизации роя частиц (рис. 3а) и методом случайного поиска (рис. 3б) могут хорошо прогнозировать периодические всплески концентрации C_7 , но не всегда четко отражают ее изменения в диапазоне 0...0,7 % мас.

Отметим, что процесс стабилизации бензина является сложным, а промышленные данные зачастую имеют сильную зашумленность, в связи с этим построение ВА является трудоемкой задачей. Несмотря на это, предложенный подход позволил найти оптимальную архитектуру модели нейронной сети для описанного объекта исследования.

ЗАКЛЮЧЕНИЕ

Разработанный автоматизированный подход на основе ГА позволяет упростить процесс поиска оптимальной архитектуры нейронной сети при разработке ВА. Предложенный подход не только позволяет сэкономить время и труд разработчика для создания моделей, но и получить ВА с хорошей прогнозирующей способностью, о чем свидетельствуют полученные результаты на независимом фрагменте промышленных данных. Показано, что предложенный подход может применяться и для сложных технологических объектов, например, для ректификационных процессов.

Список литературы

1. Черешко А.А. Виртуальные анализаторы качества на основе цифровых моделей // Автоматизация в промышленности. 2022. №. 7. С. 33–38.
2. Бахматдзе Н.Н. Виртуальные анализаторы (идентификационный подход) // Автоматика и телемеханика. 2004. №. 11. С. 3–24.
3. Souza F.A.A., Araújo R., Mendes J. Review of soft sensor methods for regression applications // Chemometrics and Intelligent Laboratory Systems. 2016. Vol. 152. P. 69–79.
4. Ge Z., Huang B., Song Z. Mixture semisupervised principal component regression model and soft sensor application // AIChE Journal. 2014. Vol. 60. Iss. 2. P. 533–545.
5. Kaneko H., Funatsu K. Application of online support vector regression for soft sensors // AIChE Journal. 2014. Vol. 60. Iss. 2. P. 600–612.
6. Wang G., Jia Q.S., Zhou M., Bi J., Qiao J., Abusorrah A. Artificial neural networks for water quality soft-sensing in wastewater treatment: a review // Artificial Intelligence Review. 2022. Vol. 55. Iss. 1. P. 565–587.
7. Yuan X., Huang L., Ye L., Wang Y., Wang K., Yang C., Gui W., Shen F. Quality prediction modeling for industrial processes using multiscale attention-based convolutional neural network // IEEE transactions on cybernetics. 2024. Vol. 54. Iss. 5. P. 2696–2707.
8. 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.
9. Jiang Q., Wang Z., Yan S., Cao Z. Data-driven soft sensing for batch processes using neural network-based deep quality-relevant representation learning // IEEE Transactions on Artificial Intelligence. 2022. Vol. 4. Iss. 4. P. 602–611.
10. Yu Z., Zhang Z., Jiang Q., Yan X. Neural network-based hybrid modeling approach incorporating Bayesian optimization with industrial soft sensor application // Knowledge-Based Systems. 2024. Vol. 301. P. 112341.
11. 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.
12. 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.
13. Rozycki P., Kolbusz J., Wilamowski B.M. Dedicated deep neural network architectures and methods for their training // In Proceedings of the IEEE 19th International Conference on Intelligent Engineering Systems (INES). 2015. P. 73–78.
14. Emmert-Streib F. Influence of the neural network topology on the learning dynamics // Neurocomputing. 2006. Vol. 69. P. 1179–1182.
15. Coello C.A.C. Evolutionary algorithms for solving multi-objective problems. NY: Springer, 2007. 810 p.
16. Rooker T. Review of genetic algorithms in search, optimization, and machine learning // AI Magazine. 1991. Vol. 12. Iss. 1. P. 102–102.
17. Yang L., Shami A. On hyperparameter optimization of machine learning algorithms: theory and practice // Neurocomputing. 2020. Vol. 415. P. 295–316.

Можаровский Игорь Сергеевич – канд. техн. наук, доцент кафедры информационных технологий и систем ФГБОУ ВО "Владивостокский государственный университет", младший научный сотрудник, ФГБУН Институт автоматизации и процессов управления ДВО РАН, **Шевлягина Светлана Александровна** – канд. техн. наук, старший научный сотрудник, ФГБУН Институт автоматизации и процессов управления ДВО РАН.
E-mail: studvvsu@gmail.com shevlyagina_sa@iacp.dvo.ru