



Разработка интеллектуальной системы управления процессом подготовки и перекачки воды в контуре охлаждения аммиачной станции

Е.А. Муравьева^{*} , А.В. Коченков

Филиал ФГБОУ ВО «УГНТУ» г. Стерлитамак, Россия

***Контакты:** e-mail: muraveva_ea@mail.ru

РЕЗЮМЕ: Введение. В современном социально-экономическом и геополитическом развитии России на первый план выходит развитие промышленности. Среди множества отраслей промышленности важнейшая роль принадлежит аммиачным станциям. **Основные закономерности процесса перекачки и подготовки воды.** Процесс состоит из шести стадий, в данной статье рассматривается автоматизация 1 и 2 стадий: по подготовке воды и откачке её насосами Н1 и Н2 из резервуара Р2. Продукция в виде очищенной воды является важнейшим критерием для последующего производства на аммиачной станции, поэтому к качеству готовой продукции предъявляются повышенные требования, в том числе к качеству очистки используемой воды с помощью нанофильтров. Требуемого качества невозможно достичь без управления процессом в автоматизированном режиме. **Разработка нейронной сети.** Для управления значениями частот преобразователей в процессе подготовки и перекачки воды использована искусственная нейронная сеть. Её разработка произведена в среде Matlab в пакете Neural Network Toolbox, для этого определены входные и выходные данные, произведена обработка и подготовка данных, а также выбор типа и архитектуры нейросети. Описана архитектура нейросети Layer Recurrent, процесс её построения и обучения в Matlab. **Тестирование нейронных сетей.** В ходе тестирования сети Layer Recurrent на предмет степени обученности наименьшая погрешность была получена для 30 нейронов в скрытом слое. Близость к заданным значениям свидетельствует о применимости сети для управления параметрами частотных преобразователей. **Разработка модели нейросетевого регулятора в пакете Simulink.** Выполнено моделирование системы управления в пакете Simulink с использованием нейросетевого регулятора с архитектурой Layer Recurrent. Проверка частот частотных преобразователей $\chi_{1_{\text{вых}}}$ и $\chi_{2_{\text{вых}}}$ в Simulink для параметров уровня в резервуарах и в баке $LT_{1_{\text{БК}}}$, $LT_{2_{\text{БК}}}$, $LT_{3_{\text{БК}}}$ показала, что модель объекта работает корректно, таким образом симуляция нейросети показала, что обучение прошло успешно. **Заключение.** В результате проведенного исследования разработана искусственная нейронная сеть для управления процессом подготовки и перекачки воды в среде Matlab и симуляция нейросети в пакете Simulink.

КЛЮЧЕВЫЕ СЛОВА: процесс, аммиачная станция, нанофильтры, разработка, нейронная сеть.

ДЛЯ ЦИТИРОВАНИЯ: Муравьева Е.А., Коченков А.В. Разработка интеллектуальной системы управления процессом подготовки и перекачки воды в контуре охлаждения аммиачной станции // Нанотехнологии в строительстве. – 2021. – Том 13, № 4. – С. 252–258. – DOI: 10.15828/2075-8545-2021-13-4-252-258.

ВВЕДЕНИЕ

Для процесса подготовки и перекачки воды для подпитки ею контура охлаждения аммиачной станции необходимо, чтобы на стадиях подготовки и перекачки воды частотные преобразователи насосов Н1 и Н2 работали без перебоев. Работа частотных преобразователей определяется уровнем жидкости в резервуаре Р2, в секциях 1 и 2, и уровнем жидкости в баке оборотной воды Б1.

Если уровни в секциях 1 и 2 будут высокими, и уровень в баке Б1 будет низким, то необходимо, чтобы значения частот преобразователей были высокими. В случае, если уровни в секциях 1 и 2 будут низкими, и уровень в баке Б1 будет высоким, то необходимо, чтобы значения частот частотных преобразователей были низкими.

В данной статье производится исследование метода для управления процессами подготовки и перекачки воды, происходящими на 1 и 2 стадиях, ка-

чественное управление которыми необходимо для плавной подачи воды для очистки на нанофильтры, именно использование нейронной сети для создания регулятора подачи защищает нанофильтры от выхода из строя, обеспечивая тем самым систему их противоаварийной защиты.

Целью исследования является разработка искусственной нейронной сети для управления процессом подготовки и перекачки воды в среде Matlab R2017b и симуляция нейросети в Simulink.

Для поддержания стабильности технологического процесса подготовки и перекачки воды необходимо управлять непосредственно параметрами частотных преобразователей насосов. На основании проведенных исследований была разработана нейронная сеть, которая применяется для регулирования параметров насосов путем использования частотных преобразователей Ч1 и Ч2 [8].

При использовании системы управления на основе ПИД-регуляторов существует проблема отсутствия компенсации возмущения и учета взаимного влияния технологических параметров, что приводит к нестабильности при управлении объектом [5].

1. Основные закономерности процесса перекачки и подготовки воды

Технология перекачки и подготовки воды основана на сборе ливневых стоков в резервуар Р1 с последующей перекачкой насосами на фильтрующие колонны. Процесс перекачки и подготовки воды включает основные стадии [7]:

- 1) подготовка воды (сбор ливневых стоков, отстой и грубая фильтрация) из резервуара Р1 в резервуар Р2;
- 2) откачка воды насосами Н1 и Н2 из резервуара Р2;
- 3) очистка воды на нанофильтрах поз. Ф01 и Ф02 от мелких механических примесей;
- 4) очистка воды методом ионного обмена в фильтрующей колонне поз. Ф03;
- 5) очистка воды на фильтрующей колонне обезжелезивания поз. Ф04;

6) очистка от аммиака путем фильтрации на аммиачном фильтре поз. Ф05, что способствует улучшению концентрации рН очищенной воды.

В качестве конечных продуктов производственного процесса перекачки и подготовки воды получают очищенную воду для подпитки контура охлаждения аммиачной станции.

Во время промывки загрязненная вода сливается в канализацию.

Процесс перекачки и подготовки воды предназначен для очистки воды и подпитки ею контура охлаждения аммиачной станции. В данной статье рассматривается автоматизация 1 и 2 стадий процесса.

Процесс перекачки и подготовки воды включает в себя [4]:

- резервуары (Р1, Р2) — предназначены для сбора, мелкой фильтрации и последующей откачки на фильтрующие колонны;
- насосы (Н1, Н2) — осуществляют перекачку воды из резервуара Р2 в фильтрующие колонны;
- скиммеры (Н3, Н4) — осуществляют сбор нефтяной пленки из резервуара Р2;
- фильтрующие колонны (Ф01 — Ф05) (5 штук) — осуществляют полную очистку воды.

2. Разработка нейронной сети

Для управления значениями частот преобразователей в процессе подготовки и перекачки воды необходимо внедрить искусственную нейронную сеть.

Разработка ИНС (искусственной нейронной сети) производится в среде Matlab R2017b в пакете Matlab Neural Network Toolbox [7].

Процесс подготовки и перекачки воды для построения нейросетевой модели можно условно разделить на 5 основных этапов.

На первом этапе проведен анализ и отбор входных данных, которые существенным образом влияют на управляемый процесс.

На втором этапе осуществляется определение и сбор входных данных, и выбираются способы получения выходных значений.




Рис. 1. Функциональная схема автоматизации процесса подготовки и перекачки воды

Третий этап заключается в выборе архитектуры ИНС.

На четвертом этапе производится обучение сети.

На пятом этапе проверяется эффективность созданной нейронной сети [2–5].

2.1. Определение входных и выходных данных

Для решения задачи с помощью нейронной сети необходимо собрать данные для обучения. Выходные параметры — значения частот преобразователей частоты $\dot{Q}_{1\text{вых}}$, $\dot{Q}_{2\text{вых}}$ — изменяются в зависимости от входных параметров $LT1_{\text{вх}}$, $LT2_{\text{вх}}$, $LT3_{\text{вх}}$ по приведенным ниже зависимостям. Выходные данные рассчитали по формулам:

$$\dot{Q}_{1\text{вых}} = (LT1_{\text{вх}} / (LT3_{\text{вх}} / LT1_{\text{вх}})) \cdot 2; \quad (1)$$

$$\dot{Q}_{2\text{вых}} = (LT2_{\text{вх}} / (LT3_{\text{вх}} / LT2_{\text{вх}})) \cdot 2, \quad (2)$$

где $LT1_{\text{вх}}$ — уровень воды в секции 1 резервуара P2;

$LT2_{\text{вх}}$ — уровень воды в секции 2 резервуара P2;

$LT3_{\text{вх}}$ — уровень воды в баке оборотной воды Б1;

$\dot{Q}_{1\text{вых}}$ — мощность первого насоса;

$\dot{Q}_{2\text{вых}}$ — мощность второго насоса.

В случае, если уровни в секциях 1 и 2 будут высокими, и уровень в баке Б1 будет низким, то необходимо, чтобы значения частот частотных преобразователей были высокими. В том случае, если уровни в секциях 1 и 2 будут низкими, и уровень в баке Б1 будет высоким, то необходимо, чтобы значения частот частотных преобразователей были низкими [10].

Далее подготовим данные для обучения нейронной сети.

На вход нейронной сети будут подаваться 3 значения:

1. Уровень воды в секции 1 $LT1_{\text{вх}}$ резервуара P2 (0÷100) %.

2. Уровень воды в секции 2 $LT2_{\text{вх}}$ резервуара P2 (0÷100) %.

3. Уровень воды в баке оборотной воды $LT3_{\text{вх}}$ Б1 (0÷100) %.

На выходе нейронная сеть должна рассчитать:

1. Количество оборотов двигателя насоса $\dot{Q}1$ (0÷2000) об/сек.

2. Количество оборотов двигателя насоса $\dot{Q}2$ (0÷2000) об/сек.

2.2. Обработка и подготовка данных

Используя формулы (1–2), создадим таблицу с обучающим набором данных. Она состоит из 1044 примеров.

Таблица 1

Обучающий набор данных

№	Входы			Выходы	
	$LT1_{\text{вх}}$, %	$LT2_{\text{вх}}$, %	$LT3_{\text{вх}}$, %	$\dot{Q}_{1\text{вых}}$, об/сек	$\dot{Q}_{2\text{вых}}$, об/сек
1	1	1	5	0	0
2	1	1	10	0	0
3	1	1	15	0	0
4	1	1	20	0	0
5	1	1	25	0	0
6	1	1	30	0	0
...	...	...	...	...	...
1039	100	100	75	266	266
1040	100	100	80	250	250
1041	100	100	85	235	235
1042	100	100	90	222	222
1043	100	100	95	210	210
1044	100	100	100	200	200

2.3. Выбор типа и архитектуры нейросети

В ходе анализа решено было выбрать Layer Recurrent neural networks (рекуррентные нейронные сети). Критерии для выбора были следующими: высокая точность выходных значений за счет обратных связей выбранной архитектуры, нелинейное строение выбранной архитектуры нейросети, большое количество источников по ней.

Однозначной методики выбора количества скрытых слоев и нейронов в них нет, и вопрос о том, насколько успешным является тот или иной выбор, зачастую решается на основании экспериментальных результатов обучения и тестирования ИНС [9].

Необходимо выбрать количество нейронов в скрытом слое. Выбор правильного количества является очень важным этапом [2]. Слишком малое количество — и сеть не сможет обучиться. Слишком большое повлечет за собой увеличение времени обучения сети до фактически нереального значения. Не существует простого способа для определения необходимого числа элементов в скрытом слое сети. В данном случае экспериментально установлено необходимое число нейронов в скрытом слое для наименьшей погрешности нейросети Layer Recurrent — 30 [14].

Обучение сети будет производиться по модифицированному алгоритму обратного распространения ошибки: trainFcn = 'trainbr'.

Задаем максимальное количество эпох (epochs) обучения, которое определяет число эпох (интервал

времени), по прошествии которых обучение будет прекращено: $\text{epochs} = 1000$.

Выберем количество эпох между показами, равное двадцати пяти: $\text{show} = 25$.

Задаем критерий окончания обучения – значение отклонения, при котором обучение будет считаться законченным: $\text{goal} = 0$.

2.4. Описание архитектуры нейросети Layer Recurrent

Нейронные сети Layer Recurrent – это вид сетей, где связи между элементами образуют направленную последовательность. Благодаря этому появляется возможность обрабатывать данные во времени или последовательные пространственные цепочки данных. Обучение рекуррентных нейронных сетей осуществляется методом обратного распространения ошибки, что дает возможность обучения весовых коэффициентов при многократном обучении сети, что в свою очередь повышает эффективность обучения ИНС [13].

2.5. Построение и обучение нейронной сети в Matlab

Реализуем и обучим в Matlab нейронную сеть архитектуры Layer Recurrent. Для этого используем инструмент `nntool`. Входные данные нейронной сети назовем `input`, а выходные – `output`. Выберем нейросеть Layer Recurrent. Загруженные данные отображаются в рабочем окне «Workspace».

Вход во вкладку «Обучение нейронной сети» осуществляется с помощью команды `nntool` [7]. На вход нейронной сети поступает сигнал x , который состоит из следующих параметров: уровень воды в резервуаре Р2 секции 1 $LT_{1\text{вх}}$, уровень в резервуаре Р2 секции 2 $LT_{2\text{вх}}$, уровень в баке оборотной воды Б1 $LT_{3\text{вх}}$. Сумматор «+» умножает каждый вход b_i на вес w_i и суммирует взвешенные входы. Затем значение проходит через функцию активации соответствующего слоя и рассчитываются выходы: мощности частотных преобразователей $\mathcal{P}_{1\text{вых}}$, $\mathcal{P}_{2\text{вых}}$.

С помощью команды `NNTool` будет реализован вход во вкладку «Обучение нейронной сети». В рабочем окне `Input Data` (входные данные) вводятся входные значения «Input». В рабочем окне `Target Data` (целевые данные) вводятся выходные значения «Output».

2.6. Нейронная сеть архитектуры Layer Recurrent

Проанализируем следующую нейросеть Layer Recurrent. Было выбрано 30 нейронов в скрытом слое.

По окончании процесса обучения НС появляется окно завершения процесса обучения, на котором




Рис. 2. Обучение нейронной сети

отображается количество проведенных итераций – 1000, затраченное время на обучение – 00:01:07 ч, величина средней квадратичной ошибки – 0,18887, величина градиента – 0,27445, величина регуляризации – 0,01 и частота отклонений полученных значений от заданной ошибки – 0.

Изменение реального значения от истинного можем наблюдать на графике обучения нейросети Layer Recurrent в окне завершения обучения (рис. 3). Из графика обучения нейросети Layer Recurrent можем увидеть, что значение среднеквадратичной ошибки 0,18887 было достигнуто за 1000 эпох, которая является меньше заданной – 0,315.




Рис. 3. Средняя квадратичная ошибка

Далее видно, как изменялся градиент и коэффициент обучения в процессе обучения нейронной сети (рис. 4). Изменение градиента функционала ошибки обучения по весам нейронной сети Layer Recurrent показывает график `gradient` (рис. 4). Веса нейросети рассматриваются как аргументы нейронной сети Layer Recurrent, где происходит постепенное движение во все более низкие точки в плоскости графика с целью поиска минимума. На графике `gradient` при обучении нейронной сети Layer Recurrent можно наблюдать резкие переходы для поиска лучшего значения для корректировки значений обучающей




Рис. 4. Графики обучения сети

выборки. Значение градиента (рис. 4) для нейросети Layer Recurrent, равное 0,27445, показывает сумму всех корректировок для переменных, которые максимально превышали норму ошибки.

Изменение переменной регуляризации при обучении нейронной сети Layer Recurrent можно наблюдать на графике Mu (рис. 4). Изменение параметра регуляризации происходит с помощью выбранного нами метода — Левенберга-Маркарта. Для корректировки значений обучающей выборки нейронной сети Layer Recurrent и переобучения нейронной сети используется диапазон числовых значений — это называется регуляризация. На рис. 4 можно видеть, что данное число принимает значение 10^{-3} , и можно сделать вывод, что величина значения невелика, поэтому им можно пренебречь.

Частоту отклонений полученных значений от заданной ошибки показывает Validation checks (рис. 4). На рис. 4 видно, что в диапазоне с 0 по 1000 эпоху обучения частота отклонений не меняется и равняется 0.

Проведя анализ графика Validation checks, можно сделать вывод, что в процессе обучения нейронной сети Layer Recurrent для наименьшей ошибки лучше остановить обучение нейронной сети Layer Recurrent на 1000 эпохе. Так как после 1000 эпохи больше не возникают отклонения, то целесообразно остановить обучение нейросети.

Итоговое значение 0, которое наблюдаем на графике Validation checks, показывает, что частота отклонений нейросети Layer Recurrent при достижении 1000 эпохи достигает минимального значения.

3. Тестирование нейронных сетей

Для тестирования нейронных сетей на предмет степени их обученности подадим на вход 3 значения в главном окне Matlab [15–16].

3.1 Тестирование нейронной сети архитектуры Layer Recurrent

Введем новую переменную $xx = [100; 100; 100]$ $LT1_{\text{вх}} = 100$, $LT2_{\text{вх}} = 100$, $LT3_{\text{вх}} = 100$. Ввели новую переменную xx для проверки выходных значений (частот частотных преобразователей) [6].

Далее проведем симуляцию и выводим выходные значения.

1. Для 30 нейронов в скрытом слое.

Для проверки нейронной сети возьмем проверочные данные (табл. 2).

Таблица 2

Проверочные данные для выходных значений (для 30 нейронов)

Вход			Выход	
$LT1_{\text{вх}}, \%$	$LT2_{\text{вх}}, \%$	$LT3_{\text{вх}}, \%$	$\mathcal{C}_1, \text{об/сек}$	$\mathcal{C}_2, \text{об/сек}$
100	100	100	200	200

Результаты проверки: получили выводные значения частот частотных преобразователей $\mathcal{C}_{1\text{вых}}, \mathcal{C}_{2\text{вых}}$:

$\mathcal{C}_{1\text{вых}} = 199,75$;

$\mathcal{C}_{2\text{вых}} = 199,74$.

В ходе тестирования сети Layer Recurrent наименьшая погрешность была получена для 30 нейронов в скрытом слое [4]. Исходные данные — 200;200. Близость к заданным значениям (199,75;199,74) свидетельствует о применимости сети. В дальнейшем ее можно использовать для управления параметрами частотных преобразователей.

4. Разработка модели нейросетевого регулятора в пакете Simulink

На рис. 5 показан общий вид нейросети Layer Recurrent, где блок Custom Neural Network (пользовательская нейронная сеть) обозначает непосредственно искусственную нейронную сеть. В блок Constant вводим входные значения $LT1_{\text{вх}}, LT2_{\text{вх}}, LT3_{\text{вх}}$, а блок $y1$ отображает выходные значения $\mathcal{C}_{1\text{вых}}$ и $\mathcal{C}_{2\text{вых}}$.




Рис. 5. Общий вид нейросети в Simulink

На рис. 6 показана общая архитектура Layer Recurrent. С блока Input (Ввод) сигналы LT_{1_BX} , LT_{2_BX} , LT_{3_BX} поступают для анализа в блок Process Input 1 (Ввод процесса), далее входной сигнал идет на скрытый слой Layer 1. Слой Layer 2 принимает выходной сигнал Layer 1 и рассчитывает выходы $\chi_{1_ВЫХ}$ и $\chi_{2_ВЫХ}$.




Рис. 6. Общая архитектура Layer Recurrent

На рис. 7 показан скрытый слой нейросети Layer 1, где сумматор «+» умножает каждый вход b_i на вес w_i и суммирует взвешенные входы.




Рис. 7. Скрытый слой нейросети Layer 1

На рис. 8 показан выходной слой нейросети Layer 2, значение из слоя Layer 1 проходит через функцию активации соответствующего выходного слоя Layer 2, и рассчитываются выходы $\chi_{1_ВЫХ}$ и $\chi_{2_ВЫХ}$.




Рис. 8. Выходной слой нейросети

Проведем проверку частот частотных преобразователей $\chi_{1_ВЫХ}$ и $\chi_{2_ВЫХ}$ в Simulink для LT_{1_BX} , LT_{2_BX} , LT_{3_BX} [100;100;100], затем изменяем входные значения на [4;4;100] (рис. 9). Рис. 9 отображает значения $\chi_{1_ВЫХ}$ и $\chi_{2_ВЫХ}$ для входных значений LT_{1_BX} , LT_{2_BX} , LT_{3_BX} .

ЗАКЛЮЧЕНИЕ

В статье обоснована целесообразность разработки интеллектуальной системы управления параметрами частотных преобразователей насосов, реализуемой с использованием нейронной сети Layer Recurrent. Представлена модель для управления параметрами частотных преобразователей с учетом множественных взаимосвязей между параметрами технологического процесса и управляющими сигналами.

В результате обучения получена нейронная сеть, которая формирует выходные сигналы с минимальной погрешностью. Исходные данные частот частотных преобразователей были выбраны равными по 200 об/сек. Близость результата тестирования к заданным значениям (199,75;199,74) свидетельствует о применимости сети для управления параметрами частотных преобразователей.

Выполнено моделирование системы управления в пакете Simulink с использованием нейросетевого




Рис. 9. Выходной слой нейросети $\chi_{1_ВЫХ}$ и $\chi_{2_ВЫХ}$

регулятора с использованием архитектуры Layer Recurrent. Проверка частот частотных преобразователей $\chi_{1_{\text{ВЫХ}}}$ и $\chi_{2_{\text{ВЫХ}}}$ в Simulink для параметров уровня в резервуарах и в баке $LT_{1_{\text{ВХ}}}$, $LT_{2_{\text{ВХ}}}$, $LT_{3_{\text{ВХ}}}$ [100;100;100] показала, что модель объекта работает правильно, то есть симуляция нейросети показывает, что обучение прошло успешно. Затем изменили

входные значения на [4;4;100], это делается для проверки нейросети на правильный переход с одних значений на другие.

Разработана, обучена и протестирована искусственная нейронная сеть для управления процессом перекачки и подготовки воды, учитывающая взаимное влияние параметров.

СПИСОК ЛИТЕРАТУРЫ

1. Muravyova E., Popkov V. Development and Research of a Dynamic Flow Laboratory Bench Model. In: *Advances in Intelligent Systems Research 7th Scientific Conference on Information Technologies for Intelligent Decision-Making Support (ITIDS)*. 2019. P. 1–6.
2. Muravyova E., Gabitov R. Economic Features to Optimize the Catalyst Calcinations Process. In: *International scientific multi-conference on industrial engineering and modern technologies (FAREASTCON)*. 2018. P. 1–8.
3. Muravyova E., Sharipov M., Gabitov R. SCADA-System Based on Multidimensional Precise Logic Controller for the Control of a Cement Kiln. In: *International scientific multi-conference on industrial engineering and modern technologies (FAREASTCON)*. 2018. P. 1–9.
4. Muravyova E., Bondarev A. Method for Increasing the Speed and Reducing the Error of Multidimensional Precise Logic Controller. In: *International scientific multi-conference on industrial engineering and modern technologies (FAREASTCON)*. 2018. P. 1–11.
5. Muravyova E., Sharipov M. Method of optimal parameters control in three-phase separator using fuzzy controller. In: *Proceedings of the International conference actual issues of mechanical engineering (AIME)*. 2018. P. 1–8.
6. Muravyova E., Fedorov S., Bondarev A. Control Systems with Pulse Width Modulation in Matrix Converters. In: *International conference on mechanical engineering, automation and control systems (MEACS)*. 2017. P. 1–7.
7. Muravyova E., Bondarev A., Sharipov M., Galiaskarova G., Kubryak A. Power consumption analysis of pump station control systems based on fuzzy controllers with discrete terms in iThink software. In: *International conference on mechanical engineering, automation and control systems (MEACS)*. 2017. P. 1–8.
8. Muravyova E., Azanov A., Enikeeva E. Modeling power consumption by pump station control systems based on fuzzy controllers with discrete terms. In: *Proceedings of the international conference: aviamechanical engineering and transport (AVENT)*. 2018; p. 1–6.
9. Muravyova E., Sharipov M., Radakina D. Method of fuzzy controller adaptation. In: *Proceedings of the international conference actual issues of mechanical engineering (AIME)*. 2017. P. 1–7.
10. Muravyova E., Bondarev A. Fuzzification Concept Using the Any-time Algorithm on the basis of Precise Term Sets. In: *International conference on industrial engineering, applications and manufacturing (ICIEAM)*. 2017. P. 1–9.
11. Muravyova E., Sharipov M. Two Fuzzy Controller Synthesis Methods with the Double Base of Rules: Reference Points and Training Using. In: *International conference on industrial engineering, applications and manufacturing (ICIEAM)*. 2017. P. 1–7.
12. Muravyova E., Kayashev A., Sharipov M., Emekeev A., Sagdatullin A. Verbally Defined Processes Controlled by Fuzzy Controllers with Input/Output Parameters Represented by Set of Precise Terms. In: *International conference on mechanical engineering, automation and control systems (MEACS)*. 2014. P. 1–8.
13. Yoshiko H., Shunji U., Taiko K. Evaluation of artificial neural network classifiers in small sample size situations. In: *Pros. Int. It. Conf. Neural Networks*. 2019. P. 1–6.
14. Wasserman F. *Brain-computer equipment*. Transl. from Eng. Moscow: Mir; 1992.
15. Hrycej T. *Neurocontrol: Towards An Industrial Control Methodology*. John Wiley & Sons. 2018. 380 p.
16. Istvan Szite, Andras Lorincz. *Simple algorithm for recurrent neural networks that can learn sequence completion (JCNN)*. 2019. P. 1–6.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Муравьева Елена Александровна, доктор технических наук, профессор, зав. кафедрой «Автоматизированные технологические и информационные системы» филиала ФГБОУ ВО «УГНТУ», г. Стерлитамак, Россия, ORCID: <https://orcid.org/0000-0002-7118-5570>, e-mail: muraveva_ea@mail.ru

Коченков Александр Вячеславович, студент кафедры «Автоматизированные технологические и информационные системы» филиала ФГБОУ ВО «УГНТУ», г. Стерлитамак, Россия, ORCID: <https://orcid.org/0000-0002-5346-6491>, e-mail: ko4enkov.alex@yandex.ru

Авторы заявляют об отсутствии конфликта интересов.

Статья поступила в редакцию: 30.06.2021.

Статья поступила в редакцию после рецензирования: 19.07.2021.

Статья принята к публикации: 22.07.2021.