

Е.А. Спири́н, В.Р. Куликов, М.В. Сарамуд, Я.Ю. Пикалов

ПРИМЕНЕНИЕ МЕТОДОВ КЛАССИФИКАЦИИ ВРЕМЕННЫХ  
РЯДОВ ПРИ ОПЕРАТИВНОМ КОНТРОЛЕ ХОДА ВЫПОЛНЕНИЯ  
ТЕХНОЛОГИЧЕСКИХ ОПЕРАЦИЙ<sup>1</sup>

**Аннотация.** Работа посвящена практической апробации методов машинного обучения для реализации автоматизированного оперативного контроля выполнения технологической операции. В качестве объекта исследования выбрана технологическая операция затягивания винтового соединения. Для реализации автоматического контроля рассмотрено решение задачи классификации последовательности данных, получаемых в ходе выполнения операций. Особенностью задачи является ограниченный набор данных, используемых в обучении и тестировании нейронных сетей. Выполнен обзор источников и сравнительный анализ эффективности обучения и применения нейронных сетей с рекуррентной и сверточной архитектурами. Экспериментальные исследования выполнены на роботизированном стенде с применением прототипа завинчивающего устройства авторской конструкции. На основе результатов тестирования рассмотренных моделей предложена архитектура нейронной сети, обеспечивающая оптимальное соотношение между точностью и скоростью ее работы.

**Ключевые слова:** автоматизация производства, перспективная контрольно-измерительная техника, нейронные сети, контроль технологического процесса, классификация последовательности.

Е.А. Spirin, V.R. Kulikov, M.V. Saramud, Ya.Yu. Pikalov

APPLICATION OF TIME SERIES CLASSIFICATION METHODS  
IN THE OPERATIONAL CONTROL OF THE PROGRESS  
OF TECHNOLOGICAL OPERATIONS

**Abstract.** The work discusses the practical testing of machine learning methods for the implementation of automated operational control of technological operation. The technological operation of tightening the screw connection was chosen as the object of research. To implement automatic control, the solution of the problem of classifying the sequence of data obtained during the execution of operations is considered. The distinctive feature of the task is a limited set of data used in training and testing neural networks. The authors have performed a review of sources and a comparative analysis of the effectiveness of training and the use of neural networks with recurrent and convolutional architectures. The experimental studies were carried out on a robotic stand using a prototype of a screw-down device of the authors' design. Based on the test results of the considered models, a neural network architecture is proposed that provides an optimal ratio between accuracy and speed of its operation.

**Keywords:** production automation, advanced control and measuring equipment, neural networks, process control, sequence classification.

*Введение*

Постоянное стремление к повышению эффективности предприятий приводит к необходимости поиска новых инструментов и методов управления. Например, для оптимизации процессов управления возможно использование комбинации методов системного

© Спири́н Е.А., Куликов В.Р., Сарамуд М.В., Пикалов Я.Ю., 2023

<sup>1</sup> Работа выполнена при поддержке Министерства науки и высшего образования Российской Федерации (госконтракт № FEFE-2020-0017).

**Спирин Евгений Анатольевич**

кандидат технических наук, научный сотрудник научно-исследовательской лаборатории робототехнических систем, Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева, город Красноярск. Сфера научных интересов: программирование, аналитическая механика, приводные системы и детали машин, вычислительная гидродинамика и теплопередача. Автор более 10 опубликованных научных работ. SPIN-код: 2641-6980, AuthorID: 642040.

Электронный адрес: spirin-evgeniy@yandex.ru

**Куликов Владимир Русланович**

кандидат физико-математических наук, старший научный сотрудник научно-исследовательской лаборатории робототехнических систем, Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева, город Красноярск. Сфера научных интересов: комплексный анализ, алгебраическая геометрия, машинное обучение, искусственный интеллект, теория алгоритмов, техническое зрение. Автор более 30 опубликованных научных работ.

Электронный адрес: v.r.kulikov@mail.ru

**Сарамуд Михаил Владимирович**

кандидат технических наук, старший научный сотрудник научно-исследовательской лаборатории робототехнических систем, Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева, город Красноярск. Сфера научных интересов: надежность программного обеспечения, робототехника, системный анализ, оптимизация, имитационное моделирование. Автор более 80 опубликованных научных работ. SPIN-код: 3747-8689, AuthorID: 744907.

Электронный адрес: msaramud@gmail.com

**Пикалов Яков Юрьевич**

кандидат технических наук, ведущий научный сотрудник научно-исследовательской лаборатории робототехнических систем, Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева, город Красноярск. Сфера научных интересов: программирование механической обработки, автоматизация технологических процессов машиностроения, робототехника. Автор более 50 опубликованных научных работ. SPIN-код: 1728-3027, AuthorID: 606492.

Электронный адрес: yaibest@mail.ru

подхода с методами машинного обучения [1] либо скользящей шкалы оптимизируемых параметров целевой функции [2].

Внедрение киберфизических систем, основанных на технологиях искусственного интеллекта и промышленного интернета вещей (Industrial Internet of Things – IIoT), дает новые возможности для развития производства и решает задачи повышения производительности и качества, снижения затрат, роста рентабельности и конкурентоспособности производства [3–5].

Применение интеллектуальных инструментов и устройств позволит оперативно контролировать выполнение технологических операций, провести анализ и оптимизацию его параметров на основе собранных данных. Архитектура системы автоматического контроля производственных процессов предполагает централизованную обработку не-

прерывного потока большого объема данных, поступающих с технологического оборудования, при этом одной из задач анализа данных является их классификация.

Данная работа посвящена решению задачи классификации временных рядов, полученных с прототипа технологического устройства, применяемого для автоматизированного завинчивания винтов и контроля технологических параметров выполняемой операции.

**Целью** работы является апробация методов классификации при реализации оперативного контроля выполнения технологических операций.

#### Анализ существующих методов

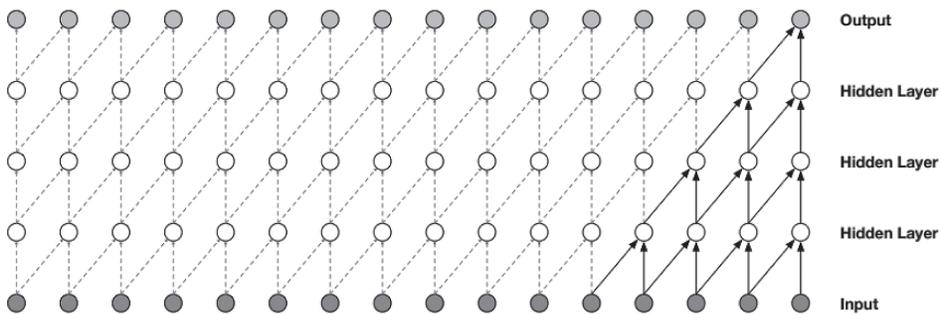
Традиционные подходы к классификации временных рядов основаны на методах частотного анализа, авторегрессионных или марковских моделях. Специалисты по глубокому обучению обычно рассматривают рекуррентные архитектуры как отправную точку по умолчанию для задач моделирования последовательностей.

Среди задач классификации последовательностей можно выделить следующие типы: классификация последовательности (сопоставляется скаляр, определяющий ее тип *sequence classification*); классификация каждого элемента последовательности (вектору последовательности в соответствие ставится вектор классов *sequence to sequence classification*).

В работе [6] предложен метод классификации временных рядов с переменным размером наблюдений, основанный на кодировании формы анализируемого сигнала в виде бинарной последовательности фиксированной длины.

В работе [7] проведена систематическая оценка общих сверточных и рекуррентных архитектур для классификации последовательностей (звук, текст, временные ряды). В результатах показано, что сверточная архитектура превосходит канонические рекуррентные сети, такие как *LSTM*. Результаты показывают, что *TCN* (*temporal convolutional network*) убедительно превосходят базовые рекуррентные архитектуры для широкого спектра задач моделирования последовательностей.

В работе [8] описана архитектура генеративной сети *WaveNet*, основанной на последовательности сверточных слоев с причинно-следственными связями (*causal convolutions layers*), что по сути является *TCN*-сетью (см. Рисунок 1). Показано что данная архитектура успешно применяется в генеративных сетях при решении задачи генерации речи на основе текста.



**Рисунок 1.** Сверточные слои с причинно-следственными связями

Источник: [8].

В работе [9] приведена архитектура нейронной сети, содержащей слои сверточной архитектуры и слои сети долгой краткосрочной памяти (*CNN-LSTM network*). При этом

Применение методов классификации временных рядов при оперативном контроле ...

для выделения ключевых признаков последовательности применяются блоки обучения локальным признакам (*local feature learning blocks, LFLB*). Данный подход авторы применили для определения эмоционального характера речи, представленного в виде аудиоследовательности. Каждый блок обучения локальных признаков состоит из одного сверточного слоя, одного слоя пакетной нормализации, одного активационного слоя и слоя подвыборки (*maxpooling*). Для учета влияния долгосрочных зависимостей из последовательности локальных объектов вводится уровень *LSTM*.

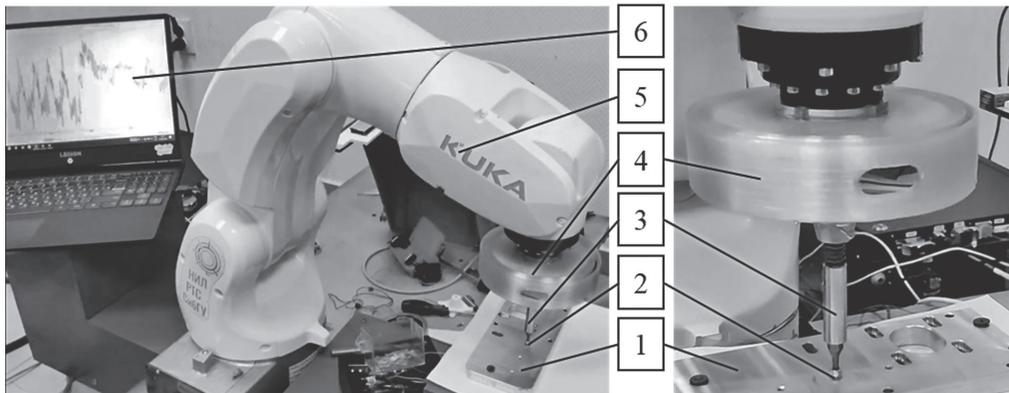
Реализация метода

Технологический процесс, данные с реализации которого используются для анализа, заключается в автоматизированной затяжке винтового соединения. При этом нормально протекающий процесс можно условно разбить на четыре этапа:

- 1) наживление винта, при котором происходит начальный контакт винта и поверхности отверстия и происходит вход витков резьбы во впадины ответной части;
- 2) основной цикл, который характеризуется ускоренным закручиванием 95 % длины винта;
- 3) затяжка винта до заданного крутящего момента, значение которого регламентируется;
- 4) ослабление и извлечение инструмента из зацепления с винтом.

В работе [10] авторы подробно рассматривают ошибки, которые могут случиться на этапе наживления винта (нормальное вкручивание, непопадание в отверстие, перекося винта и др.). Однако завершающую стадию ослабления и извлечения инструмента сложно проконтролировать по изображениям. По этой причине рассматривался заключительный этап завинчивания – достижение заданного крутящего момента затяжки и последующего его снижения с целью нормального извлечения инструмента.

Экспериментальный стенд для анализа процесса роботизированного закручивания винтов представлен на Рисунке 2.



**Рисунок 2.** Прототип специального исполнительного устройства, установленный на работе KUKA KR3 R540

Источник: здесь и далее рисунки и фото являются авторскими.

Стенд состоит из плиты 1 с резьбовыми отверстиями М3, винта 2, подпружиненной биты 3, беспроводного исполнительного устройства 4 с датчиком усилий (см. Рисунок 3), робота-манипулятора 5 KUKA KR3 R540, ноутбука 6 для сбора данных от микроконтроллера.

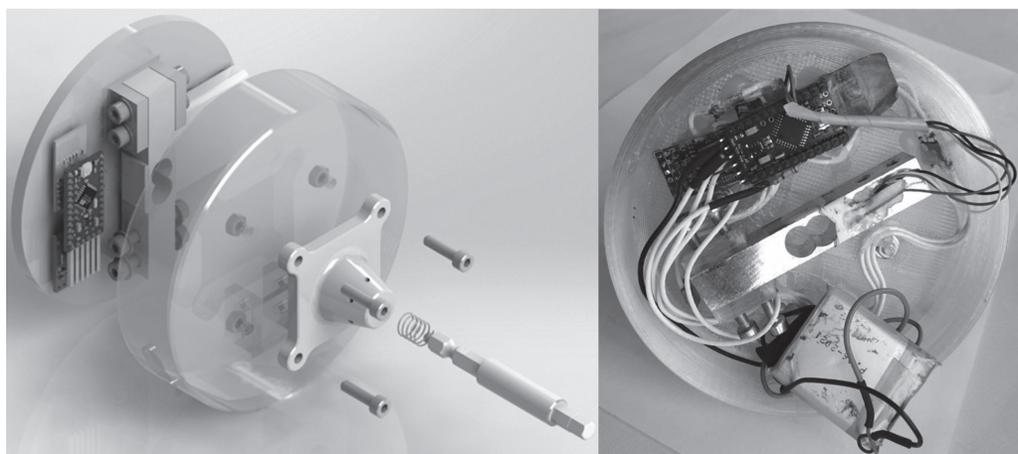


Рисунок 3. Беспроводное исполнительное устройство

Целью решаемой задачи классификации является определение зон затяжки и ослабления. Решаемая задача характеризуется сравнительно малым объемом данных обучающей выборки. Для обучения используются 8 временных рядов, полученных в результате выполнения технологической операции в номинальном режиме. Каждая последовательность содержит 400 значений с датчика нагрузки (датчик воспринимает как крутящий момент затяжки, так и осевое усилие на инструменте).

На Рисунке 4 приведен пример разметки ряда, содержащего значения, соответствующие классам затяжки ( $T$ ), ослабления ( $L$ ) и прочие ( $O$ ).

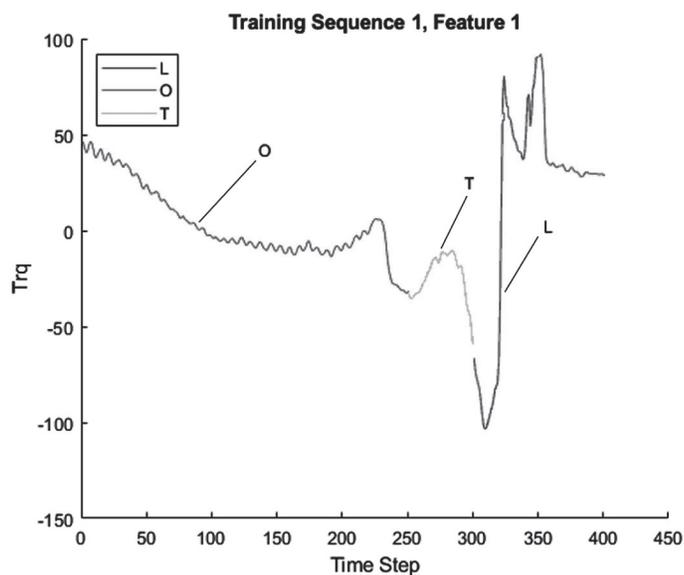
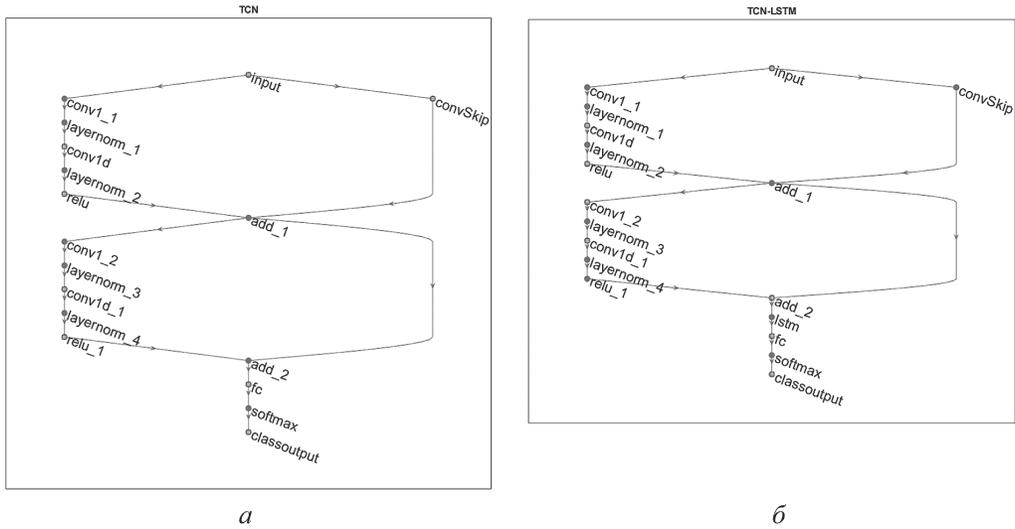


Рисунок 4. Пример разметки данных

В результате оптимизации гиперпараметров  $TCN$  по критериям точности классификации и производительности оптимальное количество блоков локальных признаков стало

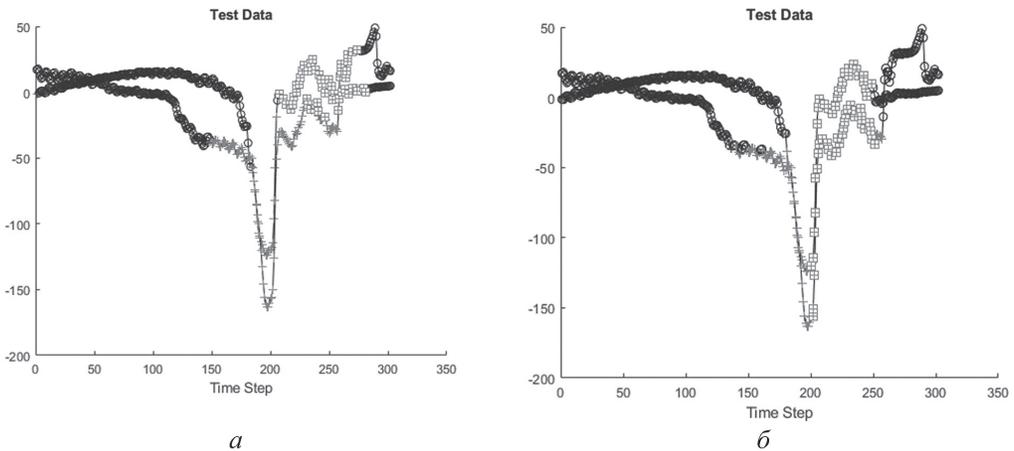
равным двум. В качестве эксперимента была рассмотрена архитектура *TCN* с дополнительным слоем *LSTM* (см. Рисунок 5).



**Рисунок 5.** Архитектура нейронных сетей: *a* – *TCN* с двумя блоками локальных признаков; *б* – *TCN-LSTM* с одним блоком локальных признаков и одним слоем *LSTM*

Результаты экспериментов

Обученные нейронные сети использовались для классификации тестовых последовательностей (не используемых в обучении), результаты которой приведены на Рисунке 6.



**Рисунок 6.** Результаты применения алгоритмов на тестовых рядах:  
*a* – *LSTM*; *б* – *TCN* (+ – затяжка; ⊠ – ослабление; ○ – остальное)

На Рисунке 6 приведены графики результатов классификации простой *LSTM*-модели и модели *TCN* применительно к двум тестовым последовательностям. Графики демонстрируют качественные различия в работе моделей: несмотря на незначительную по-

грешность в определении зоны ослабления, границы перехода состояния технологического процесса определены верно.

При реализации методов классификации в реальных условиях производства критичными являются характеристики, обеспечивающие производительность выполнения контроля и скорость переналадки. Для сравнительного анализа моделей их характеристики приведены в Таблице.

Таблица

**Сравнительные характеристики архитектур нейросетевых моделей**

Тип	Продолжительность обучения	Точность классификации, %	Продолжительность вычислений на тестовых рядах, с/ряд
<i>LSTM</i>	8 мин 38 с	76...78	0,065
<i>TCN</i> (2 блока <i>LFLB</i> )	1 мин 11 с	89...93	0,05
<i>TCN_LSTM</i> (1 блок <i>LFLB</i> )	35 с	85...88	0,01

#### Выводы

Несмотря на то, что *LSTM* показывает неплохую точность классификации, качественная картина, как видно из Рисунка 6, является неудовлетворительной. Добавление дополнительного слоя *LSTM* не приводит к улучшению качества классификации. В сравнении с *LSTM* архитектура *TCN* позволяет решать задачу классификации эффективнее, при этом замена одного из блоков определения локальных признаков на слой *LSTM* дает преимущество в скорости обучения и реализации.

#### Заключение

Применение методов глубокого обучения для классификации временных рядов при реализации оперативного контроля выполнения технологических операций является эффективным. В условиях централизованной обработки потока данных, получаемого с технологического оборудования, предпочтительной является реализация модели классификации на основе *TCN-LSTM*-архитектуры, обеспечивающей баланс между точностью и скоростью работы.

#### Литература

1. Золкин А.А., Тормозов В.С., Буштрук Т.Н., Арнаутов Е.А. Системный подход в моделировании эффективности кадрового потенциала сотрудников ИТ-предприятия // Вестник Российского нового университета. Серия: Сложные системы: модели, анализ, управление. 2023. № 1. С. 1–9. EDN LCMWQ. DOI: 10.18137/rnUV9187.23.01.p.3
2. Вечерская С.Е. Применение скользящей шкалы приоритетов в задачах оптимизации управления // Вестник Российского нового университета. Серия: Сложные системы: модели, анализ, управление. 2022. № 4. С. 32–38. EDN ZGVB0E. DOI 10.18137/RNU.V9187.22.04.P.32
3. Temelkova M. Similarities and Differences Between the Technological Paradigms “Production System”, “Cyber-physical System” and “Cyber-physical Production System” // 2022 International Conference on Communications, Information, Electronic and Energy Systems (CIEES). Veliko Tarnovo, Bulgaria, November 24–26, 2022. Pp. 1–7. DOI: 10.1109/CIEES55704.2022.9990698
4. Смышляева А.А., Резникова К.М., Савченко Д.В. Современные технологии в Индустрии 4.0 – киберфизические системы // Отходы и ресурсы. 2020. Т. 7. № 3. DOI: 10.15862/02INOR320

5. Al-Ali A.R., Gupta R., Nabulsi A.A. Cyber physical systems' role in manufacturing technologies // 6<sup>th</sup> International Conference on Nano and Materials Science: ICNMS 2018 : AIP Conference Proceedings. Vol. 1957. No. 1. Article no. 050007. DOI: 10.1063/1.5034337
6. Kudo M., Toyama J., Shimbo M. Multidimensional curve classification using passing-through regions // Pattern Recognition Letters. 1999. Vol. 20. No. 11–13. Pp. 1103–1111. DOI: 10.1016/S0167-8655(99)00077-X
7. Bai S., Kolter J. Z., Koltun V. An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling // arXiv. Cornell University. Preprint, submitted April 19, 2018. URL: <https://arxiv.org/abs/1803.01271> (дата обращения: 20.10.2023).
8. Oord A. van den, Dieleman S., Zen H., Simonyan K., Vinyals O., Graves A., Kalchbrenner N., Senior A., Kavukcuoglu K. WaveNet: A Generative Model for Raw Audio // Preprint, submitted September 12, 2016. URL: <https://arxiv.org/abs/1609.03499> (дата обращения: 20.10.2023).
9. Zhao J., Mao X., Chen L. Speech emotion recognition using deep 1D & 2D CNN LSTM networks // Biomedical Signal Processing and Control. 2019. Vol. 47. Pp. 312–323. DOI: 10.1016/j.bspc.2018.08.035
10. Matsuno T., Huang J., Fukuda T. Fault detection algorithm for external thread fastening by robotic manipulator using linear support vector machine classifier // 2013 IEEE International Conference on Robotics and Automation. Karlsruhe, Germany, May 06–10, 2013. Pp. 3443-3450. DOI: 10.1109/ICRA.2013.6631058

## References

1. Zolkina A.L., Tormozov V.S., Bushtruk T.N., Arnautov E.A. (2023) A systematic approach to modeling the effectiveness of the personnel potential of employees of an IT enterprise. *Bulletin of the Russian New University. Series: Social systems: models, analysis, management*. No. 1. Pp. 1–9. DOI: 10.18137/RNU.V9187.23.01.P.3 (In Russian).
2. Vecherskaya S.E. (2022) Application of a sliding scale of priorities in the management optimization problems. *Bulletin of the Russian New University. Series: Social systems: models, analysis, management*. No. 4. Pp. 32-38. DOI: 10.18137/rNu.v9187.22.04. Page 32 (In Russian).
3. Temelkova M. (2022) Similarities and differences between technological paradigms “Production System”, “Cyberphysical System” and “Cyberphysical Production System”. In: International Conference on Communication, Information, Electronic and Energy Systems (CIEES). Veliko Tarnovo, Bulgaria, November 24–26, 2022. Pp. 1–7. DOI: 10.1109/CIEES55704.2022.9990698
4. Smyshlyaeva A., Reznikova K., Savchenko D. (2020) Modern technologies in industry 4.0 – cyberphysical systems. *Russian Journal of Resources, Conservation and Recycling*. Vol. 7. No. 3. DOI: 10.15862/02INOR320 (In Russian).
5. Al-Ali A.R., Gupta R., Nabulsi A.A. (2018) Cyberphysical systems' role in manufacturing technologies. In: 6<sup>th</sup> International Conference on Nano and Materials Science: ICNMS 2018 : AIP Conference Proceedings. Vol. 1957. No. 1. Article no. 050007. DOI: . 10.1063/1.5034337
6. Kudo M., Toyama J., Shimbo M. (1999) Classification of multidimensional curves using through areas. *Pattern Recognition Letters*. Vol. 20. No. 11–13. Pp. 1103–1111. DOI: 10.1016/S0167-8655(99)00077-X
7. Bai S., Kolter J.Z., Koltun V. (2018) Empirical evaluation of universal convolutional and recurrent networks for sequence modeling. *arXiv. Cornell University*. arXiv:1803.01271. Preprint, submitted April 19, 2018. URL: <https://arxiv.org/abs/1803.01271> (accessed 20.10.2023).

8. Oord A. van den, Dieleman S., Zen H., Simonyan K., Vinyals O., Graves A., Kalchbrenner N., Senior A., Kavukcuoglu K. (2016) WaveNet: Generative model for raw Audio. *arXiv. Cornell University*. Preprint, presented September 12, 2016. URL: <https://arxiv.org/abs/1609.03499>
9. Zhao J., Mao H., Chen L. (2019) Speech emotion recognition using deep 1D and 2D CNN LSTM networks. *Biomedical Signal Processing and Control*. Vol. 47. Pp. 312–323. DOI: 10.1016/j.bspc.2018.08.035
10. Matsuno T., Huang J., Fukuda T. (2013) Fault detection algorithm for fixing external threads with a robotic manipulator using a machine classifier of linear support vectors. *2013 IEEE International Conference on Robotics and Automation*. Karlsruhe, Germany, May 06–10, 2013. Pp. 3443-3450. DOI: 10.1109/ICRA.2013.6631058