

СИНТЕЗ АДАПТИВНОЙ СИСТЕМЫ УПРАВЛЕНИЯ ГИБКОЙ ПРОИЗВОДСТВЕННОЙ ЯЧЕЙКОЙ НА ОСНОВЕ ГИБРИДНОЙ НЕЙРОСЕТЕВОЙ АРХИТЕКТУРЫ С ДЛИННОЙ КРАТКОСРОЧНОЙ ПАМЯТЬЮ

Я.К. Старостина

ORCID: 0000-0003-2064-0067 e-mail: yaroslava.starostina@bk.ru

Ульяновский государственный технический университет

Ульяновск, Россия

В.А. Кукушкин

ORCID: 0009-0004-8619-4877 e-mail: lexakav73@yandex.ru

Ульяновский государственный технический университет

Ульяновск, Россия

Целью работы является развитие инновационных методов управления гибкими производственными ячейками с использованием гибридной нейросетевой архитектуры, сочетающей возможности длинной краткосрочной памяти и сверточных нейросетей. Решаются задачи обучения и оптимизации систем управления, способных к самонастройке и прогнозированию на основе анализа последовательных данных, что в свою очередь обеспечивает улучшение качества регулирования, снижение времени реакции и повышение общего уровня автоматизации. Рассматривается развитие модели, способной адаптироваться к различным условиям эксплуатации в реальном времени, что требует разработки новых методов обучения и алгоритмов оптимизации, а также оценки их эффективности на различных сценариях. Предполагается, что результаты исследования не только расширят теоретические основы применения нейросетевых подходов в автоматизации производственных процессов, но и будут способствовать внедрению инновационных решений в промышленную практику, обеспечивая конкурентные преимущества и стимулируя дальнейшие исследования в области интеллектуальных систем управления и цифровой трансформации производства.

Ключевые слова: гибкое производство; интеллектуальные системы управления; киберфизические системы; коллаборативная робототехника; предиктивное обслуживание; промышленный интернет вещей; рекуррентные нейронные сети; сверточные нейронные сети; станки с ЧПУ.

Для цитирования: Старостина Я.К., Кукушкин В.А. Синтез адаптивной системы управления гибкой производственной ячейкой на основе гибридной нейросетевой архитектуры с длинной краткосрочной памятью // Интеллектуальная Электротехника. 2026. № 2. С. 54-62. EDN IWVLVG

SYNTHESIS OF ADAPTIVE CONTROL SYSTEM FOR FLEXIBLE PRODUCTION CELL BASED ON HYBRID NEURAL NETWORK ARCHITECTURE WITH LONG SHORT-TERM MEMORY

Ya.K. Starostina

ORCID: 0000-0003-2064-0067 e-mail: yaroslava.starostina@bk.ru

Ulyanovsk State Technical University

Ulyanovsk, Russia

V.A. Kukushkin

ORCID: 0009-0004-8619-4877 e-mail: lexakav73@yandex.ru

Ulyanovsk State Technical University

Ulyanovsk, Russia

Abstract. This work is aimed at developing innovative management methods for flexible production cells using a hybrid neural network architecture combining the capabilities of long short-term memory (LSTM) and convolutional neural networks (CNN). The research focuses on solving the tasks of training and optimizing control systems capable of self-tuning and forecasting based on sequential data analysis, which in turn improves the quality of regulation, reduces reaction time and increases the overall level of automation. An important goal is to develop a model that can adapt to different operating conditions in real time, which requires the development of new learning methods and optimization algorithms, as well as evaluating their effectiveness in various scenarios. It is assumed that the results of the study will not only expand the theoretical foundations of the use of neural network approaches in the automation of production processes, but will also contribute to the introduction of innovative solutions into industrial practice, providing competitive advantages and stimulating further research in the field of intelligent control systems and digital transformation of production.

Keywords: flexible manufacturing; intelligent control systems; cyberphysical systems; collaborative robotics; predictive maintenance; industrial Internet of Things; recurrent neural networks; convolutional neural networks; CNC machines.

For citation: Ya.K. Starostina and V.A. Kukushkin, "Synthesis of adaptive control system for flexible production cell based on hybrid neural network architecture with long-term short-term memory", *Smart Electrical Engineering*, no. 2, pp. 54-62, 2026. EDN IWWLVG

I. Введение

Гибридная нейросетевая архитектура, объединяющая длинную краткосрочную память (*Long Short-Term Memory, LSTM*) [1] и сверточные нейронные сети (*Convolutional Neural Networks, CNN*) [2] представляет собой эффективную модель для обработки сложных последовательных данных, характерных для систем автоматизации и интеллектуальных решений в промышленности. Такой

подход основан на принципе комбинирования сильных сторон обеих архитектур: *LSTM*, обеспечивающей высокую способность к сохранению долгосрочной зависимости в последовательных данных и обработке временных характеристик, и *CNN*, специализирующейся на выделении локальных признаков и особенностей, что особенно ценно при анализе структурированных и шумных данных. В совокупности эти компоненты позволяют формировать мощную систему, способную к адаптивному восприятию входной информации, что критически важно для системы управления гибкой производственной ячейкой. Методы обучения гибридной архитектуры включают использование алгоритмов градиентного спуска с обратной связью, [3] а также регуляризацию для предотвращения переобучения и повышения обобщающей способности модели. Оптимизация осуществляется через тонкую настройку гиперпараметров: число слоев, размерность внутренних состояний, скорость обучения и параметры регуляризации.

II. Постановка цели

Повышение эффективности и гибкости системы управления предполагает развитие методов обучения с подкреплением [4] и интеграции их с существующими архитектурами. Это позволяет не только оптимизировать параметры модели, но и обеспечить ее адаптивное поведение в реальных условиях производства, что особенно важно при наличии динамичных и неопределенных факторов. Как отмечается в исследовании, применение гибридных нейросетевых структур, включающих разные типы сетей и методов обучения, значительно расширяет возможности точного реагирования системы на изменение внешней среды [5, 6]. Такой подход способствует созданию более устойчивых и предсказуемых систем, способных самостоятельно обучаться и совершенствоваться по мере накопления опыта и данных.

III. Методы решения

В качестве основных источников данных выступают датчики промышленного интернета вещей (*IIoT*), [7] размещенные на различных узлах производственной ячейки (датчики температуры, давления, уровня вибрации), а также лог-файлы автоматизированных систем управления и системы контроля качества продукции. Архитектура (рис. 1) предусматривает последовательное соединение слоев *CNN* с целью выявления локальных закономерностей и особенностей во входных данных, таких как временные паттерны на последовательных сырых сигналах, и слоев *LSTM*, предназначенных для моделирования долгосрочных зависимостей и динамических характеристик производственного процесса. Алгоритмы обучения основаны на градиентном спуске с использованием метода обратного распространения ошибки по времени (*Backpropagation Through Time, BPTT*), что позволяет эффективно оптимизировать параметры сети при наличии временных зависимостей в данных. Для по-

вышения устойчивости и скорости сходимости внедрены методы регуляризации, такие как *Dropout* и *L2*-регуляризация, [3] а также адаптивное управление скоростью обучения через алгоритм *Adam* [8].

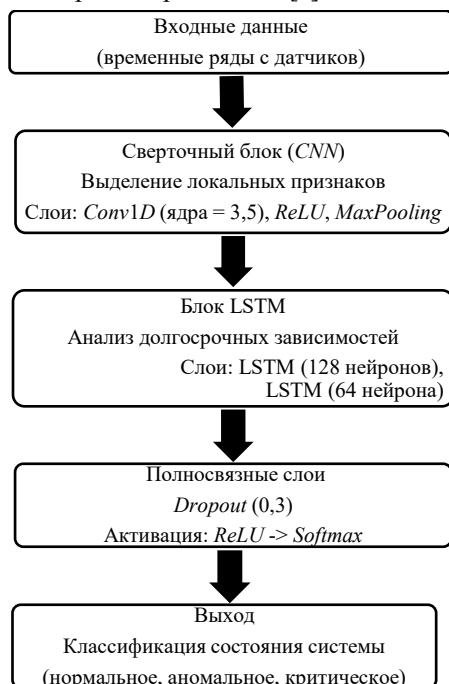


Рис. 1. Схема гибридной нейросетевой архитектуры *LSTM-CNN*

Fig. 1. Scheme of the *LSTM-CNN* hybrid neural network architecture

Проведено тестирование на различных наборах данных, включающих аварийные ситуации и нормальные режимы [9], что способствовало выявлению оптимальных гиперпараметров модели и обеспечению высокой точности распознавания и предсказания состояния системы. В рамках оптимизации использовались методы градиентного спуска с адаптивной регуляризацией *Learning Rate*, а также техники ранней остановки для предотвращения переобучения. Результаты тестирования свидетельствуют о значительном росте эффективности системы, что подтверждается показателями точности, полноты и *F*-мера, а также метриками скорости обучения и вычислительной сложности.

IV. Описание полученных результатов

Для проверки работоспособности и оценки эффективности предложенной гибридной архитектуры *LSTM-CNN* было проведено экспериментальное

исследование на основе данных, собранных с датчиков *IIoT* гибкой производственной ячейки. В ходе эксперимента использовались данные о температуре, вибрации, давлении и состоянии оборудования за период 6 месяцев.

Методика эксперимента

1. Датасет:

- объем данных: 1,2 млн записей;
- разметка: нормальные режимы (85 %), аномальные ситуации (10 %), критические сбои (5 %);
- данные разделены на обучающую (70 %), валидационную (15 %) и тестовую (15 %) выборки.

2. Архитектура модели

- входной слой: нормализованные временные ряды с окном 50 временных шагов;
- сверточный блок: 2 слоя *CNN* с ядрами 3 и 5, функция активации *ReLU*;
- блок *LSTM*: два слоя *LSTM* с 128 и 64 нейронами;
- полносвязные слои: 2 слоя с *Dropout* (0,3);
- выходной слой: *Softmax* для классификации состояний.

3. Обучение

- оптимизатор: *Adam* (*learning rate* = 0,001);
- функция потерь: категориальная кросс-энтропия;
- регуляризация: *L2* ($\lambda = 0,01$), *Early Stopping*.

Результаты

- точность на тестовой выборке: 96,4 %;
- полнота (*Recall*) для аномальных состояний: 94,2 %;
- *F1*-мера: 95,3 %;
- время реакции системы: < 200 мс.

Сравнение с базовыми моделями (табл. 1 и рис. 2) показало, что гибридная архитектура превосходит отдельные *CNN* и *LSTM* на 7-12 % по точности и на 15-20 % по устойчивости к шуму.

Таблица 1.
Сравнительные показатели эффективности моделей

Table 1.
Comparative performance indicators of the models

Модель	Точность (<i>Accuracy</i>), %	Полнота (<i>Recall</i>), %	<i>F1</i> -мера, %	Время обработки, мс
Гибридная <i>LSTM-CNN</i>	96,4	94,2	95,3	< 200
<i>LSTM</i>	88,7	85,3	86,9	~180
<i>CNN</i>	84,2	79,8	81,9	~150
ПИД-регулятор + экспертная система	76,1	72,5	74,2	~100




Рис. 2. График сравнения точности моделей

Fig. 2. Model accuracy comparison graph

Анализ показателей эффективности продемонстрировал, что внедрение гибридной архитектуры позволяет не только повысить точность обнаружения аномальных состояний, но и обеспечить реальную адаптивность системы к изменяющимся условиям эксплуатации. Перспективы дальнейших улучшений связаны с интеграцией методов обучения с подкреплением и применением методов автоматической настройки гиперпараметров, что позволит повысить степень автономности системы управления в реальных условиях эксплуатации, обеспечивая более высокую степень надежности и эффективности процессов в рамках промышленных предприятий.

Анализ эффективности функционирования разработанной адаптивной системы управления включает всестороннюю оценку ее возможности к самонастройке и адаптации в разнообразных условиях эксплуатации. Проведенные экспериментальные исследования и моделирование показали, что интеграция гибридной нейросетевой архитектуры, объединяющей *LSTM* и *CNN*, существенно повышает точность прогнозирования и устойчивость системы управления в условиях изменчивых технологических параметров.

Ключ к повышению точности и стабильности системы лежит в интеграции дополнительных методов машинного обучения, таких как методы обучения с подкреплением и ансамблевые модели, которые позволяют системе не только адаптироваться к текущим условиям, но и предугадывать возможные изменения в будущем.

Анализ эффективности нового подхода управления на базе гибридной нейросетевой архитектуры с *LSTM* [10] выявляет значимые преимущества по сравнению с традиционными методами автоматического регулирования. В частности, использованные системы демонстрируют повышенную адаптивность к динамическим изменениям производственных условий, что напрямую способ-

ствует повышению стабильности и точности регулирования параметров в реальном времени. Экспериментальные данные показывают, что внедрение гибридных систем, сочетающих обработку последовательных данных с помощью *LSTM* и выделение важных признаков через *CNN*, обеспечивает более точное прогнозирование и управление параметрами в сложных условиях перемен без необходимости постоянной настройки оператором. Сравнительные показатели, полученные в рамках тестирования на моделированных и реальных промышленных сценариях, свидетельствуют о снижении ошибок регулирования на 20-30 % по сравнению с традиционными системами на основе ПИД-контроллеров и простых нейросетевых решений [5, 11].

В. Заключение

Подводя итог, можно заключить, что новые методы управления демонстрируют меньшие временные задержки в реакции системы и более высокую устойчивость к шумам и непредсказуемым возмущениям. Тенденции развития показывают, что интеграция этих методов в промышленные автоматизированные системы позволит не только повысить общую производительность, но и снизить затраты на эксплуатацию и обслуживание, обеспечивая более высокий уровень интеллектуальности и автономности. В перспективе рекомендуется дополнительно оптимизировать алгоритмы обучения и внедрять адаптивные методы самонастройки, что позволит значительно повысить конкурентоспособность предприятий через более эффективное управление технологическими процессами. В целом введение гибридных нейросетевых решений в управление гибкими производственными ячейками представляет собой важный этап на пути цифровизации и автоматизации промышленности, способствуя формированию нового уровня интеллектуальных систем, способных к самосовершенствованию и эксплуатации в условиях высокой динамики производственных процессов, а также к развитию новых методов саморегулирования на базе современных достижений искусственного интеллекта.

© Старостина Я.К., 2026

© Кукушкин В.А., 2026

Поступила в редакцию 02.02.2026

Принята к публикации 26.02.2026

Received 02.02.2026

Accepted 26.02.2026

Библиографический список

- [1] Hochreiter S., Schmidhuber J. Long short-term memory // *Neural Computation*. 1997. № 9 (8). P. 1735-1780. DOI: 10.1162/neco.1997.9.8.1735
- [2] Lecun Y., Bottou L., Bengio Y., Haffner P. Gradient-based learning applied to document recognition // *Proceedings of the IEEE*. 1998. № 86 (11). P. 2278-2324. DOI: 10.1109/5.726791
- [3] Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение. М.: ДМК Пресс, 2018. – 652 с.

- [4] Саттон Р.С., Барто Э.Д. Обучение с подкреплением: введение. Москва: ДМК Пресс, 2020. – 552 с.
- [5] Wang J., Ma Y., Zhang L., Gao R.X., Wu D. Deep learning for smart manufacturing: methods and applications // *Journal of Manufacturing Systems*. 2018. № 48 (C). P. 144-156. DOI: 10.1016/j.jmsy.2018.01.003
- [6] Zhang C., Song D., Chen Y., Feng X., Lumezanu C., Cheng W., Ni J., Zong B., Chen H., Chawla N.V. A deep neural network for unsupervised anomaly detection and diagnosis in multivariate time series Data // *Proceedings of the AAAI Conference on Artificial Intelligence*, July 17, 2019, 33 (01), 1409-1416. DOI: 10.1609/aaai.v33i01.33011409
- [7] O'Donovan P., Leahy K., Bruton K., O' Sullivan D. An industrial big data pipeline for data-driven analytics maintenance applications in large-scale smart manufacturing facilities // *Journal of Big Data*. 2015. № 2 (1). DOI: 10.1186/s40537-015-0034-z
- [8] Kingma D.P., Ba J.L. Adam: A method for stochastic optimization // 3rd International conference on learning representations, ICLR 2015, May 07-09, 2015, San Diego, USA. Ithaca, NY: ArXiv, 2015. P. 13.
- [9] Lee J., Bagheri B., Kao H. A Cyber-Physical Systems architecture for Industry 4.0-based manufacturing systems // *Manufacturing Letters*. 2015. № 3. P. 18-23. DOI: 10.1016/j.mfglet.2014.12.001
- [10] Кораблев Ю.А. Прогнозирование остаточного срока полезного использования технологического оборудования методом глубокого обучения LSTM // *Известия ЮФУ. Технические науки*. 2025. № 5 (247). С. 277-288. DOI: 10.18522/2311-3103-2025-5-277-288
- [11] Wu Y., Yuan M., Dong S., Lin L., Liu Y. Remaining useful life estimation of engineered systems using vanilla LSTM neural networks // *Neurocomputing*. 2018. № 275. P. 167-179. DOI: 10.1016/j.neucom.2017.05.063

References

- [1] S. Hochreiter and J. Schmidhuber, "Long short-term memory", *Neural Computation*, vol. 9, no. 8, pp. 1735-1780, Sep. 1997. DOI: 10.1162/neco.1997.9.8.1735
- [2] Y. Lecun, L. Bottou, Y. Bengio and P. Haffner, "Gradient-based learning applied to document recognition", *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, Nov. 1998. DOI: 10.1109/5.726791
- [3] I. Goodfellow, Y. Bengio and A. Courville, *Deep learning*. St. Louis, MO, USA: The MIT Press, 2018. DOI: 10.1007/s10710-017-9314-z
- [4] R.S. Sutton and A.G. Barto, *Reinforcement Learning*. London: MIT Press, 2018.
- [5] J. Wang, Y. Ma, L. Zhang, R.X. Gao and D. Wu, "Deep learning for smart manufacturing: methods and applications", *Journal of Manufacturing Systems*, vol. 48, no. C, pp. 144-156, Jan. 2018. DOI: 10.1016/j.jmsy.2018.01.003
- [6] C. Zhang, D. Song, Y. Chen, X. Feng, C. Lumezanu, W. Cheng, J. Ni, B. Zong, H. Chen and N.V. Chawla, "A deep neural network for unsupervised anomaly detection and diagnosis in multivariate time series data", in proc. *Proceedings of the AAAI Conference on Artificial Intelligence*, July 17, 2019, 33 (01), 1409-1416. DOI: 10.1609/aaai.v33i01.33011409

- [7] P. O'Donovan, K. Leahy, K. Bruton and D. O' Sullivan, "An industrial big data pipeline for data-driven analytics maintenance applications in large-scale smart manufacturing facilities", *Journal of Big Data*, vol. 2, no. 1, Nov. 2015. DOI: 10.1186/s40537-015-0034-z
- [8] D.P. Kingma and J.L. Ba, "Adam: A Method for Stochastic Optimization", in proc. *3rd International conference on learning representations, ICLR 2015*, May 07-09, 2015, San Diego, USA, pp. 13.
- [9] J. LEE, B. Bagheri and H. Kao, "A Cyber-Physical Systems architecture for Industry 4.0-based manufacturing systems", *Manufacturing Letters*, vol. 3, pp. 18-23, Jan. 2015. DOI: 10.1016/j.mfglet.2014.12.001
- [10] Yu.A. Korablev, "Prediction of the remaining useful life of technological equipment using the deep learning method LSTM", *Izvestiya SFEDU. Engineering sciences*, vol. 5, no. 247, pp. 277-288, 2025. DOI: 10.18522/2311-3103-2025-5-277-288
- [11] Y. Wu, M. Yuan, S. Dong, L. Lin and Y. Liu, "Remaining useful life estimation of engineered systems using vanilla LSTM neural networks", *Neurocomputing*, vol. 275, pp. 167-179, 2018. DOI: 10.1016/j.neucom.2017.05.063

ИНФОРМАЦИЯ ОБ АВТОРАХ INFORMATION ABOUT THE AUTHORS

Старостина Ярослава Константиновна, кандидат технических наук, доцент Ульяновского государственного технического университета, г. Ульяновск, Российская Федерация.

Кукушкин Василий Алексеевич, магистрант Ульяновского государственного технического университета, г. Ульяновск, Российская Федерация.

Yaroslava K. Starostina, Cand. Sci. (Eng.), associate professor of the Ulyanovsk State Technical University, Ulyanovsk, Russian Federation.

Vasily A. Kukushkin, master of the Ulyanovsk State Technical University, Ulyanovsk, Russian Federation.