

УДК 303.732

DOI: 10.22213/2410-9304-2026-2-64-70

## Результаты сравнительного анализа моделей 1D-CNN и GRU в задаче прогнозирования показателей швейных производств на основе эксплуатационных параметров оборудования

Д. С. Пономарев, кандидат технических наук, ИжГТУ имени М. Т. Калашникова, Ижевск, Россия  
Научно-исследовательский институт Федеральной службы исполнения наказаний, Москва, Россия

*В современных производственных системах повышение эффективности управления технологическими процессами во многом связано с использованием методов интеллектуального анализа данных и машинного обучения. Одной из важных задач управления производственными предприятиями является прогнозирование объемов выпуска продукции на основе параметров эксплуатации оборудования и характеристик производственной нагрузки. Традиционные методы прогнозирования не всегда позволяют учитывать сложные нелинейные зависимости между параметрами функционирования оборудования и итоговыми производственными показателями, что ограничивает их применение в условиях динамично изменяющихся производственных процессов. В работе рассматривается задача прогнозирования объемов выпуска продукции швейных производственных участков на основе временных рядов эксплуатационных параметров оборудования. Исследование выполнено на основе данных швейных производств, функционирующих в исправительных учреждениях Приволжского федерального округа. Набор данных охватывает период с 2014 по 2022 год и включает 1129 наблюдений с месячным шагом временного ряда. В качестве входных признаков использовались показатели, характеризующие состояние и режим эксплуатации оборудования, включая коэффициенты загрузки и использования оборудования, время простоев, коэффициент отказов, среднее время восстановления оборудования, объем заказов, обеспеченность материалами и показатели кадровой загрузки производственного участка. Для решения задачи многократного прогнозирования были реализованы две архитектуры глубокого обучения: одномерная сверточная нейронная сеть (1D-CNN) и рекуррентная нейронная сеть типа GRU. Оценка точности прогнозирования проводилась с использованием метрик RMSE, MAE и MAPE. В результате экспериментального исследования было установлено, что обе модели позволяют достаточно эффективно прогнозировать динамику производственных показателей. Помимо этого, было выявлено, что модель GRU в целом может быть более точной в поставленной задаче прогнозирования. Полученные результаты подтверждают перспективность применения нейросетевых методов для анализа и прогнозирования производственных процессов на основе эксплуатационных параметров оборудования.*

**Ключевые слова:** прогнозирование производственных показателей, нейронные сети, временные ряды, 1D-CNN, GRU, производственные процессы, машинное обучение, анализ временных рядов, промышленная аналитика.

### Введение

На сегодняшний день в условиях цифровой трансформации промышленности наблюдается значительный рост методов интеллектуального анализа данных и машинного обучения. Одной из ключевых задач управления производственными предприятиями является прогнозирование производственных показателей, которое позволяет повысить эффективность планирования загрузки оборудования, распределения трудовых ресурсов и обеспечения производственного процесса материальными ресурсами. Швейные производства в данном вопросе не являются исключением. Они представляют собой сложные производственные системы, в которых итоговые показатели выпуска продукции формируются под воздействием множества факторов. К числу наиболее значимых факторов можно отнести: загрузку оборудования, время простоев, частоту отказов техники, обеспеченность материалами,

а также фактическую доступность операторов, которые обслуживают технологические линии. Таким образом, в совокупности данные параметры формируют динамическую систему, характеризующую функционирование производственного участка во времени.

В последние годы для решения задач прогнозирования производственных процессов активно применяются методы искусственного интеллекта и нейронные сети. В отличие от классических статистических моделей, данные подходы позволяют исследователям выявлять сложные нелинейные зависимости между переменными, а также учитывать непосредственно саму временную структуру данных. Также особо эффективными при анализе временных рядов могут явиться архитектуры глубокого обучения, которые позволяют автоматизировано извлекать признаки из многомерных последовательностей наблюдений.

Одним из перспективных направлений в данной области является использование сверточных нейронных сетей для анализа временных рядов. Одномерные сверточные сети (1D-CNN) [1, 2] позволяют выявлять локальные закономерности во временных данных и эффективно извлекать устойчивые паттерны изменения производственных показателей [3, 4]. Другим широко применяемым подходом являются рекуррентные нейронные сети, в частности архитектура GRU (Gated Recurrent Unit) [5, 6]. Ее особенностью является наличие механизма запоминания временных зависимостей и способность учитывать влияние предыдущих состояний системы на текущие значения прогнозируемых показателей [7, 8].

Несмотря на широкое применение данных методов, в частности и для задач анализа временных рядов, вопросы прогнозирования производственных показателей с использованием параметров эксплуатации оборудования остаются недостаточно изученными. Особенно это касается производственных участков, в которых существенное влияние на динамику выпуска оказывают эксплуатационные характеристики оборудования. В связи с этим представляет интерес проведение исследования эффективности различных архитектур искусственных нейронных сетей (далее – ИНС) при прогнозировании производственных показателей на основе совокупности технических и эксплуатационных параметров [9, 10].

Таким образом, целью настоящей работы является разработка и сравнительный анализ моделей ИНС на основе архитектур 1D-CNN и GRU для

решения задачи многократного прогнозирования объемов выпуска продукции швейных производственных участков. Исследование выполнено на основе набора данных, сформированного по производственным показателям швейных производств, функционирующих в учреждениях Приволжского федерального округа. Рассматривались производства пенитенциарной системы, это было обосновано: наличием организованной стабильной системой сбора и учета данных (утвержденной нормативно-правовыми документами); постоянством организованных производств; долговременным и стабильным производством однотипной продукции; стабильным наличием заказчиков и закупки сырья. Период наблюдений охватывает интервал с 2014 по 2022 год, при месячном шаге временного ряда. Общий объем выборки составляет 1129 наблюдения. Оценка точности моделей осуществляется с использованием метрик RMSE, MAE и MAPE [11], широко применяемых в задачах прогнозирования временных рядов.

#### Описание данных и постановка задачи исследования

В качестве входных переменных были использованы десять производственных параметров, характеризующих состояние оборудования, режим его эксплуатации, обеспеченность производства материальными ресурсами и кадровую нагрузку на технологические линии. Прогнозируемой величиной является фактический объем выпуска продукции. Общий перечень используемых признаков приведен в табл. 1 [12].

Таблица 1. Входные параметры моделей ИНС

Table 1. Input parameters of neural network models

№	Показатель	Обозначение	Описание
1	Количество активных швейных машин	$M_{act}$	Число машин, задействованных в производственном процессе
2	Коэффициент загрузки оборудования	$K_{load}$	Доля времени, в течение которого оборудование выполняет производственные операции
3	Коэффициент использования оборудования	$K_{util}$	Отношение фактической производительности оборудования к номинальной
4	Время простоев оборудования	$T_{down}$	Суммарная продолжительность простоев за период
5	Коэффициент отказов оборудования	$K_{fail}$	Доля оборудования, вышедшего из строя в течение периода
6	Среднее время восстановления оборудования	MTTR	Средняя продолжительность восстановления работоспособности оборудования после отказа
7	Объем заказов	$Q_{ord}$	Количество изделий, запланированных к производству
8	Обеспеченность тканью	$K_{fabric}$	Отношение фактического объема материала к потребности производства
9	Коэффициент выхода на работу	$K_{att}$	Доля работников, присутствующих на производстве
10	Коэффициент операторской нагрузки	$K_{op}$	Соотношение числа активных машин и числа операторов

В качестве целевой переменной выступал фактический объем выпуска продукции швейного участка –  $Q_{\text{fact}}$ . Формально задачу прогнозирования можно представить следующим образом. Пусть имеется временной ряд наблюдений производственной системы (1):

$$X_t = (M_{\text{act}}, K_{\text{load}}, K_{\text{util}}, T_{\text{down}}, K_{\text{fail}}, MTTR, Q_{\text{ord}}, K_{\text{fabric}}, K_{\text{att}}, K_{\text{op}}), \quad (1)$$

где  $t$  – номер временного периода. Требуется построить модель, позволяющую по последовательности предыдущих наблюдений параметров швейных производств определить значение целевой переменной на будущих временных интервалах:  $Q_{\text{fact}}(t+h)$ , где  $h$  – горизонт прогнозирования.

В рамках исследования рассматривается задача многократного прогнозирования, при которой модель должна оценивать значения целевой переменной на нескольких будущих временных шагах.

#### Статистический анализ многомерного временного ряда и сопоставление с регрессионной моделью

Перед проведением экспериментального исследования был выполнен статистический анализ многомерного временного ряда, включающего целевую переменную  $Q_{\text{fact}}$  и совокупность входных параметров, характеризующих состояние и режим эксплуатации технологического оборудования.

Проведение данного этапа обусловлено тем, что при исследовании процессов швейных производств пенитенциарной системы важную роль играют автокорреляционные зависимости уровней временного ряда, а также характер взаимосвязи между эксплуатационными параметрами швейного оборудования и результирующими показателями непосредственно самого выпуска продукции.

Для выявления временных зависимостей была построена автокорреляционная функция исследуемого временного ряда. Результаты расчета коэффициентов автокорреляции приведены в табл. 2.

Таблица 2. Коэффициенты автокорреляции временного ряда

Table 2. Autocorrelation coefficients of a time series

Порядок временного сдвига	Коэффициент автокорреляции
1	0,71
2	0,58
3	0,42
4	0,29

Как видно из табл. 2, наибольшая зависимость наблюдается между соседними наблюдениями временного ряда. Коэффициент автокорреляции первого порядка составляет 0,71, что свидетельствует о выраженной инерционности производственного процесса. С увеличением временного сдвига величина автокорреляции постепенно уменьшается. Но при этом статистически значимые значения сохраняются до третьего порядка. Это указывает на наличие устойчивых временных зависимостей в динамике производственных показателей.

Для формальной проверки наличия автокорреляции была использована статистика Дарбина – Уотсона (далее – DW). Полученное значение показателя составило  $DW = 1,34$ , что указывает на наличие умеренной положительной автокорреляции уровней исследуемого временного ряда. Дополнительно была проведена проверка с использованием критерия Льюнга – Бокса, результаты которой позволили подтвердить статистическую значимость автокорреляционной структуры временного ряда ( $p = 0,012$ ).

Для сопоставления результатов ИНС с классическими статистическими методами была построена множественная регрессионная модель временного ряда. В качестве зависимой переменной рассматривался показатель  $Q_{\text{fact}}$ , а в качестве объясняющих переменных – ключевые эксплуатационные параметры оборудования: коэффициент загрузки оборудования  $K_{\text{load}}$ , время простоев  $T_{\text{down}}$ , объем заказов  $Q_{\text{ord}}$ , обеспеченность производства материалами  $K_{\text{fabric}}$  и коэффициент выхода персонала на работу  $K_{\text{att}}$ .

Регрессионная зависимость имеет следующий вид:

$$Q_t = \beta_0 + \beta_1 K_{\text{load}} + \beta_2 T_{\text{down}} + \beta_3 Q_{\text{ord}} + \beta_4 K_{\text{fabric}} + \beta_5 K_{\text{att}} + \varepsilon_t, \quad (2)$$

где  $Q_t$  – объем выпуска продукции в момент времени  $t$ ;  $\beta_i$  – параметры регрессионной модели;  $\varepsilon_t$  – случайная составляющая модели.

По результатам оценки параметров модели коэффициент детерминации составил  $R^2 = 0,64$ , а скорректированный коэффициент детерминации – 0,61. Значение статистики Фишера составило 18,7 при уровне значимости  $p < 0,001$ , что свидетельствует о статистической значимости полученной регрессионной зависимости.

Для оценки точности прогнозирования было проведено сопоставление результатов регрессионной модели и нейросетевых архитектур. Результаты расчета основных показателей точности приведены в табл. 3.

Таблица 3. Сравнение точности моделей прогнозирования

Table 3. Comparison of Forecasting Model Accuracy

Модель	RMSE	MAE	MAPE
Регрессионная модель	521,3	401,7	12,4 %
1D-CNN	412,6	318,4	8,92 %
GRU	356,8	274,1	7,43 %

Как следует из табл. 3, регрессионная модель характеризуется более высокой величиной ошибок прогнозирования по сравнению с архитектурами ИНС. Средняя относительная ошибка прогнозирования для регрессионной модели составляет 12,4 %, тогда как для модели 1D-CNN этот показатель снижается до 8,92 %, а для модели GRU – до 7,43 %.

Дополнительно был выполнен анализ случайной составляющей регрессионной модели. Для проверки гипотезы о постоянстве дисперсии ошибок был применен тест Бреуша – Пагана (в некоторых публикациях Бройша – Пагана [13] (Breusch-Pagantest, далее – BP)). Полученное значение статистики составило  $BP = 4,27$  при уровне значимости  $p = 0,37$ , что не позволяет отвергнуть гипотезу о гомоскедастичности ошибок модели.

На рис. 1 представлено распределение ошибок регрессионной модели относительно прогнозируемых значений производственного показателя.



Рис 1. Распределение ошибок регрессионной модели (график остатков)

Fig. 1. Distribution of regression model errors (residuals plot)

Из рис. 1 можно отметить, что разброс ошибок не демонстрирует систематического увеличения или уменьшения в зависимости от величины прогнозируемого значения. Таким образом, дисперсия ошибок модели может считаться статистически постоянной.

Таким образом, в результате проведенного статистического анализа многомерного временного ряда было установлено, что динамика вы-

пуска швейной продукции может быть выражена автокорреляционной структурой и сложными взаимосвязями между эксплуатационными параметрами швейного оборудования и результирующими производственными показателями.

### Методика проведения

#### экспериментального исследования

Перед обучением моделей исходные данные были приведены к форме временных последовательностей фиксированной длины. Для каждого временного шага формировалось окно наблюдений, включающее значения входных параметров за несколько предыдущих периодов. Каждое обучающее наблюдение представляло собой матрицу входных признаков (3):

$$X = (x_{t-k+1}, x_{t-k+2}, \dots, x_t), \quad (3)$$

где  $k$  – длина временного окна,  $x_t$  – вектор производственных параметров в момент времени  $t$ . Целевой переменной для каждого окна наблюдений являлось значение фактического объема выпуска продукции на будущих временных интервалах.

Одномерные сверточные нейронные сети широко применяются для анализа временных рядов благодаря способности эффективно выявлять локальные закономерности и повторяющиеся паттерны в последовательных данных [14, 15]. Для поставленной задачи в общем виде структура модели 1D-CNN может быть представлена следующим образом: входная последовательность → сверточный слой → слой подвыборки → полносвязный слой → выходной слой.

Что же касается GRU, то здесь основным преимуществом является возможность эффективно моделировать долгосрочные зависимости во временных рядах при сравнительно небольшом количестве параметров [16]. Структура модели GRU представлена как: входная последовательность → рекуррентный слой GRU → полносвязный слой → выходной слой.

Практическая часть состояла из этапов preprocessing данных, определения обучающей и тестовой выборки, непосредственно самого процесса обучения моделей, а также проведения сравнительного анализа полученных результатов для моделей 1D-CNN и GRU. Временной ряд был проверен на наличие пропущенных значений и аномалий; выявленные пропуски были заполнены методом интерполяции. Масштабирование осуществлялось с использованием линейного преобразования, приводящего признаки к единому диапазону. Далее была выполнена трансформация временного ряда в набор обучающих последовательностей фиксированной длины. Для этого использовался метод скользящего окна. Каждая последовательность включала значения входных

признаков за несколько предыдущих временных периодов и соответствующее значение целевой переменной, которое должно быть спрогнозировано моделью.

Для оценки обобщающей способности моделей исходный временной ряд был разделен на обучающую и тестовую части (по правилу Парето в соотношении 80 и 20 %). При этом разделение осуществлялось с учетом хронологического порядка наблюдений.

Процесс обучения осуществлялся на основе минимизации функции ошибки, характеризующей отклонение прогнозируемых значений от фактических наблюдений. После завершения процедуры обучения выполнялось прогнозирование значений целевой переменной на тестовой части выборки. Полученные прогнозные значения сопоставлялись с фактическими наблюдениями производственных показателей, после чего для каждой из рассматриваемых моделей вычислялись значения указанных метрик точности.

#### Результаты экспериментального исследования для GRU и 1D-CNN

Результаты сравнения моделей были представлены ранее, в табл. 3, из которой видно, что обе модели имеют достаточно высокую точность прогнозирования показателей швейного производства. Можно отметить, что модель на основе GRU имеет более низкие значения всех рассматриваемых метрик ошибки по сравнению с 1D-CNN. Снижение значения RMSE для модели GRU может свидетельствовать о более высокой точности воспроизведения динамики производственного показателя. Подобную ситуацию можно отметить и для MAE.

Для наглядной оценки качества прогнозирования на рис. 2 представлено сопоставление фактических значений объема выпуска продукции и прогнозов, полученных с использованием модели GRU (проверка проводилась на независимой выборке, которая ранее не использовалась для обучения моделей).




Рис. 2. Сравнение фактических и прогнозируемых значений выпуска продукции

Fig 2. Comparison of actual and forecasted output values

Исходя из представленного графика на рис. 2 можно сказать, что модель GRU достаточно точно воспроизводит общую динамику изменения производственного показателя и корректно отражает периоды роста и снижения объемов выпуска продукции.

Небольшие отклонения наблюдаются преимущественно в отдельных периодах резкого изменения производственной нагрузки, что может быть связано с влиянием факторов, не учтенных в модели.

#### Заключение

В результате разработки и проведения сравнительного анализа моделей ИНС на основе архитектур 1D-CNN и GRU было получено следующее: для модели 1D-CNN отмечено значение среднеквадратической ошибки RMSE на уровне 412,6, а средняя абсолютная ошибка MAE составила 318,4; средняя абсолютная процентная ошибка MAPE – 8,92 %. Для модели GRU можно отметить более высокую точность прогнозирования: значение RMSE составило 356,8, MAE – 274,1, а MAPE – 7,43 %.

Установлено, что использование рекуррентной архитектуры GRU позволяет снизить среднеквадратическую ошибку прогнозирования на 13,5 % по сравнению со сверточной моделью 1D-CNN. Средняя абсолютная ошибка уменьшилась на 13,9 %, а относительная ошибка прогнозирования снизилась с 8,92 до 7,43 %, что соответствует улучшению точности примерно на 1,5 процентных пункта. Таким образом, архитектура GRU, которая обладает механизмом запоминания предыдущих состояний системы, позволяет более эффективно учитывать накопительные эффекты эксплуатации швейного оборудования, изменения производственной нагрузки и инерционность производственного процесса.

#### Библиографические ссылки

1. Detection of Corona Faults in Switchgear by Using 1D-CNN, LSTM, and 1D-CNN-LSTM Methods / Ya. A. Mohammed Alsumaidae, Ch. T. Yaw, S. P. Koh [et al.] // Sensors. 2023. Vol. 23, No. 6. P. 3108. DOI 10.3390/s23063108. EDN UTWEVL.
2. Deep Learning-Based Channel Estimation With 1D CNN for OFDM Systems Under High-Speed Railway Environments / A. Siriwanitpong, K. Sanada, H. Hatano [et al.] // IEEE Access. 2025. Vol. 13. P. 13128-13142. DOI 10.1109/access.2025.3531009. EDN YBNUIB.
3. Towards Automatic Depression Detection: A BiLSTM/1D CNN-Based Model / L. Lin, X. Chen, Y. Shen, L. Zhang // Applied Sciences (Switzerland). 2020. Vol. 10, No. 23. – P. 8701. DOI 10.3390/app10238701. EDN BZRNL.

4. Jana, G. Ch. A 1D-CNN-Spectrogram Based Approach for Seizure Detection from EEG Signal / G. Ch. Jana, R. Sharma, A. Agrawal // *Procedia Computer Science*. 2020. Vol. 167. P. 403-412. DOI 10.1016/j.procs.2020.03.248. EDN YQOJQN.
5. Predicting Energy Consumption Using LSTM, Multi-Layer GRU and Drop-GRU Neural Networks / S. Mahjoub, L. Chrifi-Alaoui, B. Marhic, L. Delahoche // *Sensors*. 2022. Vol. 22, no. 11. P. 4062. DOI 10.3390/s22114062. EDN YPYEY.
6. Cornelius Stephanus Alfredo. Time Series Forecasting of Significant Wave Height using GRU, CNN-GRU, and LSTM / Cornelius Stephanus Alfredo, D. A. Adytia // *Jurnal RESTI (RekayasaSistem dan TeknologiInformasi)*. 2022. Vol. 6, no. 5. P. 776-781. DOI 10.29207/resti.v6i5.4160. EDN MWLDGO.
7. Chaudhari, S. Integration of GRU Features with Q-Learning based VARMA for Protocol DDoS Attack Analysis / S. Chaudhari, M. Solanki // *International Journal of Communication Networks and Distributed Systems*. 2025. Vol. 1, no. 1. DOI 10.1504/ijcnds.2025.10067549. EDN OZYSFY.
8. A Short-Term Power Load Forecasting Method Using CNN-GRU with an Attention Mechanism / Q. Hua, Z. Fan, W. Mu [et al.] // *Energies*. 2025. Vol. 18, no. 1. P. 106. DOI 10.3390/en18010106. EDN OPDKDU.
9. Zhang, K. Using neural network to automatic manufacture product label in enterprise under IoT environments / K. Zhang, Ch. Dong // *Computer Science and Information Systems*. 2023. Vol. 20, No. 2. P. 701-722. DOI 10.2298/csis220703019z. EDN AMFSRB.
10. Polling in the frequency domain: A new MAC protocol for industrial wireless network for factory automation / J. Lin, W. Liang, H. Yu, Y. Xiao // *International Journal of Ad Hoc and Ubiquitous Computing*. 2015. Vol. 20, No. 4. P. 211-222. DOI 10.1504/IJAHUC.2015.073434. EDN WRFNOD.
11. Chicco, D. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation / D. Chicco, M. J. Warrens, G. Jurman // *PeerJ. Computer Science*. 2021. Vol. 7. P. 1-24. DOI 10.7717/PEERJ-CS.623. EDN VSUBGE.
12. Пономарев Д. С., Горохов М. М., Пономарев С. Б., Разумова И. В. Производственная и трудовая деятельность как фактор медико-социальной адаптации осужденных : отчет о НИР / федеральное казенное учреждение «Научно-исследовательский институт Федеральной службы исполнения наказаний», 2022. С. 5-40.
13. Проверка надежности модели зависимости ВВП России от экспорта методом тестирования случайных остатков / А. А. Мухин, И. А. Мухина, Е. В. Марковина [и др.] // *Вестник Алтайской академии экономики и права*. 2022. № 4-2. С. 215–223. DOI 10.17513/vaael.2160. EDN OQDHJW..
14. Predicting the Wear Amount of Tire Tread Using 1D-CNN / H. Park, Ju. Seo, K. Kim, T. Kim // *Sensors*. 2024. Vol. 24, No. 21. P. 6901. DOI 10.3390/s24216901. EDN LDSLQN.
15. Pal, P. Meta-learning Based Cardiopathy Detection from PPG Signals Using GAN and 1D CNN / P. Pal, M. Mahadevappa // *Circuits, Systems, and Signal Processing*. 2024. DOI 10.1007/s00034-024-02941-6. EDN WGJZWB.
16. GRU-INC: An inception-attention based approach using GRU for human activity recognition / T. R. Mim, M. Amatullah, S. Afreen [et al.] // *Expert Systems with Applications*. 2023. Vol. 216. P. 119419. DOI 10.1016/j.eswa.2022.119419. EDN YGNKXC.

## References

1. Detection of Corona Faults in Switchgear by Using 1D-CNN, LSTM, and 1D-CNN-LSTM Methods / Ya. A. Mohammed Alsumaidae, Ch. T. Yaw, S. P. Koh [et al.] // *Sensors*. 2023. Vol. 23, No. 6. P. 3108. DOI 10.3390/s23063108. EDN UTWEVL.
2. Deep Learning-Based Channel Estimation With 1D CNN for OFDM Systems Under High-Speed Railway Environments / A. Siriwanitpong, K. Sanada, H. Hatano [et al.] // *IEEE Access*. 2025. Vol. 13. P. 13128-13142. DOI 10.1109/access.2025.3531009. EDN YBNUIB.
3. Towards Automatic Depression Detection: A BiLSTM/1D CNN-Based Model / L. Lin, X. Chen, Y. Shen, L. Zhang // *Applied Sciences (Switzerland)*. 2020. Vol. 10, No. 23. P. 8701. DOI 10.3390/app10238701. EDN BZRNL.
4. Jana, G. Ch. A 1D-CNN-Spectrogram Based Approach for Seizure Detection from EEG Signal / G. Ch. Jana, R. Sharma, A. Agrawal // *Procedia Computer Science*. 2020. Vol. 167. P. 403-412. DOI 10.1016/j.procs.2020.03.248. EDN YQOJQN.
5. Predicting Energy Consumption Using LSTM, Multi-Layer GRU and Drop-GRU Neural Networks / S. Mahjoub, L. Chrifi-Alaoui, B. Marhic, L. Delahoche // *Sensors*. 2022. Vol. 22, No. 11. P. 4062. DOI 10.3390/s22114062. EDN YPYEY.
6. Cornelius Stephanus Alfredo. Time Series Forecasting of Significant Wave Height using GRU, CNN-GRU, and LSTM / Cornelius Stephanus Alfredo, D. A. Adytia // *Jurnal RESTI (RekayasaSistem dan TeknologiInformasi)*. 2022. Vol. 6, No. 5. P. 776-781. DOI 10.29207/resti.v6i5.4160. EDN MWLDGO.
7. Chaudhari, S. Integration of GRU Features with Q-Learning based VARMA for Protocol DDoS Attack Analysis / S. Chaudhari, M. Solanki // *International Journal of Communication Networks and Distributed Systems*. 2025. Vol. 1, No. 1. DOI 10.1504/ijcnds.2025.10067549. EDN OZYSFY.
8. A Short-Term Power Load Forecasting Method Using CNN-GRU with an Attention Mechanism / Q. Hua, Z. Fan, W. Mu [et al.] // *Energies*. 2025. Vol. 18, No. 1. P. 106. DOI 10.3390/en18010106. EDN OPDKDU.
9. Zhang, K. Using neural network to automatic manufacture product label in enterprise under IoT environments / K. Zhang, Ch. Dong // *Computer Science and Information Systems*. 2023. Vol. 20, No. 2. P. 701-722. DOI 10.2298/csis220703019z. EDN AMFSRB.

10. Polling in the frequency domain: A new MAC protocol for industrial wireless network for factory automation / J. Lin, W. Liang, H. Yu, Y. Xiao // International Journal of Ad Hoc and Ubiquitous Computing. 2015. Vol. 20, No. 4. P. 211-222. DOI 10.1504/IJAHUC.2015.073434. – EDN WRFNOD.

11. Chicco, D. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation / D. Chicco, M. J. Warrens, G. Jurman // PeerJ. Computer Science. 2021. Vol. 7. P. 1-24. DOI 10.7717/PEERJ-CS.623. EDN VSUBGE.

12. Ponomarev D.S., Gorokhov M.M., Ponomarev S.B., Razumova I.V. [Industrial and labor activity as a factor in the medical and social adaptation of convicts], Research Report / Federal State Institution “Research Institute of the Federal Penitentiary Service”, 2022. Pp. 5-40 (in Russ.).

13. Mukhin A.A., Mukhina I.A., Markovina E.V. [et al.] [Testing the reliability of the model of dependence of

Russia's GDP on exports using the random residuals testing method]. Bulletin of the Altai Academy of Economics and Law. 2022. No. 4-2. Pp. 215-223 (in Russ.). DOI 10.17513/vaael.2160. EDN OQDHJW.

14. Predicting the Wear Amount of Tire Tread Using 1D-CNN / H. Park, Ju. Seo, K. Kim, T. Kim // Sensors. 2024. Vol. 24, No. 21. P. 6901. DOI 10.3390/s24216901. EDN LDSLQN.

15. Pal, P. Meta-learning Based Cardiopathy Detection from PPG Signals Using GAN and 1D CNN / P. Pal, M. Mahadevappa // Circuits, Systems, and Signal Processing. 2024. DOI 10.1007/s00034-024-02941-6. EDN WGJZWB.

16. GRU-INC: An inception-attention based approach using GRU for human activity recognition / T. R. Mim, M. Amatullah, S. Afreen [et al.] // Expert Systems with Applications. 2023. Vol. 216. P. 119419. DOI 10.1016/j.eswa.2022.119419. EDN YGNKXC.

\* \* \*

### Results of a Comparative Analysis of 1D-CNN and GRU Models in the Task of Predicting Production Indicators of Garment Production Based on Equipment Operating Parameters

D.S. Ponomarev, PhD in Engineering, KalashnikovIzhevsk State Technical University; Research Institute of the Federal Penitentiary Service, Izhevsk, Russia

*In modern manufacturing systems, improving the efficiency of process control is largely dependent on the use of data mining and machine learning. One of the key management tasks for manufacturing enterprises is forecasting output volumes based on equipment operating parameters and production load characteristics. Traditional forecasting methods do not always account for complex nonlinear relationships between equipment operating parameters and final production indicators, limiting their application in dynamically changing production processes.*

*This paper examines the problem of forecasting output volumes in sewing production units based on time series of equipment operating parameters. The study is based on production data from sewing units operating in correctional facilities in the Volga Federal District. The dataset covers the period from 2014 to 2022 and includes 1129 observations with a monthly time series increment. The input features included indicators characterizing the equipment condition and operating mode, including equipment load factors, downtime, failure rate, mean time to repair, order volume, material availability, and production area staffing levels.*

*To solve the iterative forecasting problem, two deep learning architectures were implemented: a one-dimensional convolutional neural network (1D-CNN) and a GRU-type recurrent neural network. Forecasting accuracy was assessed using the RMSE, MAE, and MAPE metrics. The experimental results showed that both models are capable of effective forecasting production indicator dynamics, but the GRU model provides higher forecasting accuracy. The obtained results confirm the potential of using neural network methods for analyzing and forecasting production processes based on equipment operating parameters.*

**Keywords:** production performance forecasting, neural networks, time series, 1D-CNN, GRU, production processes, machine learning, time series analysis, industrial analytics.

Получено: 19.03.26

#### Образец цитирования

Пономарев Д. С. Результаты сравнительного анализа моделей 1D-CNN и GRU в задаче прогнозирования показателей швейных производств на основе эксплуатационных параметров оборудования // Интеллектуальные системы в производстве. 2026. Т. 24, № 2. С. 64–70. DOI: 10.22213/2410-9304-2026-2-64-70.

#### For Citation

Ponomarev D.S. [Results of a Comparative Analysis of 1D-CNN and GRU Models in the Task of Predicting Production Indicators of Garment Production Based on Equipment Operating Parameters]. *Intellectual'nyesistemy v proizvodstve*. 2026, vol. 24, no. 2, pp. 64-70 (in Russ.). DOI: 10.22213/2410-9304-2026-2-64-70.