

УДК 658.5:004.8

DOI: [10.26102/2310-6018/2026.61.10.002](https://doi.org/10.26102/2310-6018/2026.61.10.002)

Повышение эффективности производственных процессов за счет нейросетевой оптимизации технологических маршрутов

О.А. Гаврилова^{1,2}✉

¹Уфимский университет науки и технологий, Уфа, Российская Федерация

²Уфимский государственный нефтяной технический университет, Уфа,
Российская Федерация

Резюме. В представленной работе предлагается комплексный подход, который включает использование теории графов для построения модели производственных маршрутов; применение методов искусственного интеллекта для оптимизации построенных графовых моделей, в том числе алгоритмов поиска кратчайшего пути с учетом изменяющихся ограничений и эвристических оптимизационных стратегий; разработку специальной архитектуры рекуррентной нейронной сети типа LSTM для решения поставленной в исследовании задачи и адаптированной для работы с последовательностями данных о маршрутах; внедрение системы оценки рисков на основе нейросетевого анализа, которая может быть интегрирована в общую архитектуру оптимизации производственных маршрутов с выполнением ключевой задачи выявления потенциальных проблем и разработки превентивных мер; применение математического моделирования для формализации процесса оптимизации как задачи минимизации целевой функции при заданных ограничениях. В результате исследования разработана адаптивная модель оптимизации технологических маршрутов, создана специализированная программа для оценки научно-технических рисков при внедрении новых или усовершенствованных технологий на предприятии, построена архитектура LSTM-нейронной сети с учетом специфики исследуемых отраслевых производственных процессов, а также произведена валидация модели на реальных производственных данных. Проведенное исследование показало, что применение разработанного подхода позволяет значительно сократить сроки принятия проектных решений, проводить оптимизацию технологических маршрутов с учетом множества необходимых критериев, при этом учитывать их важность для того или иного варианта оптимизации, повысить точность прогнозирования при внедрении результатов на производстве, адаптировать технологические процессы под изменяющиеся производственные условия, а также возможность интегрировать представленное решение в существующие CAM и MES-системы.

Ключевые слова: технологический маршрут, теория графов, нейронные сети, адаптивная комплексная модель, многокритериальная оптимизация, автоматизированные системы, техническая подготовка производства.

Благодарности: Автор благодарит доктора технических наук, профессора, заслуженного деятеля науки Республики Башкортостан Селиванова С.Г. за консультации в области системотехнического проектирования и разработки проблем технологической подготовки и организации производства новой техники, за ценные замечания, полученные в рамках настоящего исследования.

Для цитирования: Гаврилова О.А. Повышение эффективности производственных процессов за счет нейросетевой оптимизации технологических маршрутов. *Моделирование, оптимизация и информационные технологии*. 2026;14(10). URL: <https://moitvvt.ru/ru/journal/article?id=2484> DOI: 10.26102/2310-6018/2026.61.10.002

Enhancing production process efficiency through neural network-based optimization of technological routes

O.A. Gavrilova^{1,2}✉

¹*Ufa University of Science and Technology, Ufa, the Russian Federation*

²*Ufa State Petroleum Technological University, Ufa, the Russian Federation*

Abstract. This paper proposes an integrated approach that includes: the use of graph theory for building a model of technological routes; the use of artificial intelligence methods for optimizing the constructed graph models, including algorithms for finding the shortest path taking into account changing constraints and heuristic optimization strategies; the development of a special LSTM-type recurrent neural network architecture to solve the problem posed in the study, adapted to work with sequences of route data; the implementation of a risk assessment system based on neural network analysis, which can be integrated into the overall architecture of technological route optimization, with the key task of identifying potential problems and developing preventive measures; the use of mathematical modeling to formalize the optimization process as a minimization problem under specified constraints. As a result of the study, an adaptive model for optimizing technological routes was developed, a specialized program was created to assess scientific and technical risks when introducing new or improved technologies at an enterprise, the architecture of the LSTM neural network was built taking into account the specifics of the industry-specific production processes under study, and the model was validated on real production data. The study has shown that the application of the developed approach makes it possible to significantly reduce the time required for making design decisions, optimize technological routes according to multiple necessary criteria while considering their importance for a particular optimization option, increase the accuracy of forecasting when implementing the results in production, and adapt technological processes to changing production conditions. Furthermore, the possibility of integrating the presented solution into existing CAM and MES systems has been demonstrated.

Keywords: technological route, graph theory, neural networks, adaptive integrated model, multi-criteria optimization, automated systems, technical preparation of production.

Acknowledgements: The author thanks S.G. Selivanov, Doctor of Engineering Sciences, Professor, Honored Scientist of the Republic of Bashkortostan, for consultations on systems engineering design and on the development of issues of technological preparation and organization of production of new equipment, and for valuable comments received during this study.

For citation: Gavrilova O.A. Enhancing production process efficiency through neural network-based optimization of technological routes. *Modeling, Optimization and Information Technology*. 2026;14(10). (In Russ.). URL: <https://moitvvt.ru/ru/journal/article?id=2484> DOI: 10.26102/2310-6018/2026.61.10.002

Введение

Разработка технологических процессов изготовления деталей для сложных технических изделий в наукоемких отраслях промышленности относится к направлению технической подготовки производства. На современном этапе развития науки и техники, в условиях комплексной автоматизации и цифровизации, специалисты инженерно-технического профиля применяют системы сквозного проектирования в своей работе: CAD, CAM, CAE и PLM-системы, что в свою очередь, требует системного подхода к автоматизации работ в рамках технической подготовки производства, которая не только охватывает конструкторскую, технологическую и организационную подготовку, но и включает в себя аспекты, связанные с модернизацией производственных систем через внедрение инновационных технологий, интеллектуальных систем поддержки и принятия решений и цифровую трансформацию отраслей в целом.

Разработка технологии изготовления деталей – это всегда сложная кросс-дисциплинарная задача. Эксперт-разработчик должен комплексно подходить к выбору методов и режимов обработки материала, обеспечивая при этом требуемую конфигурацию детали, качество поверхностного слоя строго в соответствии с характеристиками, заданными конструктором. Более того, он также должен учитывать выполнение специализированных технологических процессов в рамках основного плана обработки, например, нанесение упрочняющих или защитных покрытий, термическую обработку и т. д. При этом особенно важно найти оптимальные значения ключевых производственных показателей [1], таких как себестоимость и время изготовления детали, коэффициент использования материала и фондоемкость, параллельно внедряя в технологический маршрут новые и перспективные методы обработки и прогрессивное оборудование. Выполнить все вышеназванные задачи, достичь требуемой точности и заданного качества изделия позволяет применение комплексного научного подхода к проектированию и планированию обработки деталей с учетом оптимизации производственных параметров. В последние годы для повышения эффективности такой оптимизации применяются методы машинного обучения, прежде всего, нейросетевые модели. Ввиду возможности анализировать значительные объемы данных, прогнозировать результаты в конкретных заданных условиях и адаптироваться к изменяющимся обстоятельствам такие модели существенно ускоряют процесс принятия проектно-технологических решений и сокращают сроки технической подготовки производства [2, 3]. Классические же подходы к моделированию сложных производственных процессов, например, такие как структурное и сетевое проектирование, симплекс-метод, применение элементов теории игр, линейное программирование и т. п., часто сталкиваются с рядом ограничений, которые обусловлены дефицитом априорных данных, сложностью формализации отдельных параметров и нелинейным развитием производственных процессов [2, 4]. Перспективным решением в такой ситуации выступает сочетание нейросетевых методов с математической теорией графов, где последняя служит базовой моделью для описания дискретных детерминированных процессов, каким и является технологический маршрут изготовления детали. Далее рассмотрен вариант реализации предложенного подхода на одном из машиностроительных предприятий.

Научная проблема исследования заключается в существовании теоретико-методологического противоречия между высокой нелинейностью, динамичностью и многокритериальностью современных дискретных производственных процессов в авиадвигателестроении и ограниченными возможностями классических детерминированных методов их оптимизации в условиях дефицита априорных данных.

Целью настоящего исследования является повышение эффективности технической подготовки производства за счет разработки адаптивной комплексной модели нейросетевой оптимизации технологических маршрутов.

Для достижения цели были решены следующие задачи: формализация технологических маршрутов с использованием аппарата теории графов; разработка специализированной архитектуры рекуррентной нейронной сети (LSTM), адаптированной под задачи анализа последовательностей маршрутных данных с учетом технологической наследственности; создание подсистемы нейросетевой оценки научно-технических рисков при проектировании инновационных техпроцессов; а также валидация разработанного подхода на реальном массиве производственных данных авиадвигателестроительного предприятия.

Материалы и методы

В данной публикации представлена интеллектуальная модель для оптимизации технологического маршрута изготовления деталей, которую можно применять в общем машиностроении, нефтяном машиностроении, авиадвигателестроении, приборостроении и других отраслях, в которых разрабатываются дискретные детерминированные процессы. Методология исследования основывается на реализации нескольких этапов.

На подготовительном этапе осуществляется сбор и обработка производственных данных (техкарты, параметры операций, оборудования, время, стоимость и другие), производится нормализация и кодирование категориальных признаков. Этап моделирования включает построение ориентированного графа технологического маршрута с определением вершин (операций) и связей между ними, параллельно разрабатывается архитектура LSTM-нейронной сети с определенным количеством слоев и нейронов, что необходимо для выбора наилучшего в заданных условиях маршрута из всего множества маршрутов, полученных с помощью графовой модели. Далее следует процесс обучения, который реализуется через минимизацию значения целевой функции, и проводится валидация параметров с последующей корректировкой архитектуры сети при необходимости. Затем осуществляется оптимизация техмаршрута путем генерации и оценки альтернативных вариантов с учетом выбранных критериев. Внедрение результатов предполагает корректировку маршрутных карт и мониторинг эффективности на основе сравнения показателей до и после оптимизации. Рассмотрим более подробно предложенный подход.

Для оптимизации технологического маршрута обработки детали в заданных производственных условиях целесообразно применять рекуррентные нейронные сети [1, 5] либо их модифицированные версии – LSTM-сети (рекуррентные сети с «длительной кратковременной памятью»). LSTM-модели открывают широкие возможности для преодоления проблемы большого расхождения градиентов между начальными и конечными слоями данных при обучении нейросети с использованием метода обратного распространения ошибки, то есть обновление весов нейронной сети производится на основе частных производных от функции потерь, что важно при решении рассматриваемой в статье производственной задачи. Так как технологический маршрут – это последовательность операций, а результат выполнения каждой технологической операции всегда зависит от предыдущих (такое явление называется технологической наследственностью и влияет на эксплуатационные характеристики детали), критически важно учитывать кумулятивное воздействие параметров оптимизации на всем протяжении маршрута. Несмотря на то, что базовая топология маршрутов моделируется с помощью направленных графов, в качестве ядра оптимизационного алгоритма были выбраны рекуррентные сети типа LSTM, а не графовые нейронные сети (GNN). Это обусловлено тем, что технологический маршрут представляет собой строго хронологическую, направленную последовательность дискретных этапов, где критически важно учитывать кумулятивное влияние феномена технологической наследственности (влияние параметров предшествующих операций на финишные характеристики детали). В то время как GNN ориентированы на выявление пространственных или структурных связей в произвольных сетевых топологиях, LSTM-архитектура наиболее адекватно отражает динамику направленного сквозного процесса обработки деталей.

Технологический маршрут, который был оптимизирован в настоящем исследовании с помощью вышеуказанного комплексного подхода – сочетания теории графов с методами искусственного интеллекта – представлен на Рисунке 1 в его базовом

варианте, а многовариантный граф, который был разработан для оптимизации технологических маршрутов детали типа «шестерня» маслоагрегата авиационного двигателя, разработанных на основе базового варианта, представлен на Рисунке 2.

СМЕЖНЫЙ ЦЕХ		УЧАСТКА №	ОПЕРАЦИИ №	КОД ОПЕРАЦИИ	НАИМЕНОВАНИЕ ОПЕРАЦИИ	ОБОРУДОВАНИЕ		РАБОЧЕГО ЦЕНТРА №	ПРИМЕЧАНИЕ
№	КОД					ТИП	МОДЕЛЬ		
1	2	3	4	5	6	7	8	9	10
		03	40000		ЗАГОТОВКА-ШТАМПОВКА Ц.2А И ОБРАБОТКА ТЕРМИЧЕСКАЯ В Ц.4А				
		03	40005	4233	ТОКАРНАЯ С ЧПУ	ТПО	SPT16NC	305	
		03	40010	4233	ТОКАРНАЯ С ЧПУ	ТПО	SPT16NC	305	
		03	40015	4233	ТОКАРНАЯ С ЧПУ	ТС	TS66L	309	
		03	40020	4233	ТОКАРНАЯ С ЧПУ	ТС	TS66L	309	
		04	40025	4143	ЦЕНТРОШЛИФОВАЛЬНАЯ	ШС	ZSM5100	414	
		01	40030	0125	ПРОМЫВКА	ММ	T272	135	
		04	40035	4135	РЕЗЬБОШЛИФОВАЛЬНАЯ	ШР	N31	450	
		01	40040	0125	ПРОМЫВКА	ММ	T272	135	
		04	40045	4151	ЗУБОШЛИФОВАЛЬНАЯ	ШЗО	KLINGELNBERG G30	438	
		04	40050	4151	ЗУБОШЛИФОВАЛЬНАЯ	ШЗО	KLINGELNBERG G30	438	
			40055	0125	ПРОМЫВКА	ММ	T272	135	
		04	40060	0200	КОНТРОЛЬ	ОТ	К.СТОЛ	447	
		04	40070	0108	СЛЕСАРНАЯ	ОТ	БЕРСТАК	412	
		04	40075	0125	ПРОМЫВКА	ММ	T272	135	
		04	40080	4110	ТОКАРНАЯ	ТВ	16K20M	401	
		04	40085	4260	ФРЕЗЕРНАЯ	ФУ	6H81	416	
		04	40090	0108	СЛЕСАРНАЯ	ОТ	БЕРСТАК	412	
		04	40095	0200	КОНТРОЛЬ	ОТ	К.СТОЛ	447	
		01	40100	0125	ПРОМЫВКА	ММ	T272	135	
9А	009	01	41000		МЕДНЕНИЕ ЭЛЕКТРОХИМИЧЕСКОЕ				
4А	041	02	42000		ЦИАНИРОВАНИЕ				
		04	43105	4143	ЦЕНТРОШЛИФОВАЛЬНАЯ	ШС	ZSM5100	414	

Рисунок 1 – Фрагмент технологического маршрута обработки детали типа «шестерня»
маслоагрегата авиационного двигателя

Figure 1 – A fragment of the technological route for processing a gear-type part of an aircraft engine
oil unit

В качестве входных данных для каждой i -й технологической операции рассматривались: время операции T_i (мин); ее себестоимость C_i (руб); ее фондоемкость F_i (руб./мин); коэффициент использования материала на каждой операции K_{im} (безразмерная величина, лежащая в интервале $[0;1]$); возможность применения нового метода обработки или оборудования на данной технологической операции (балльная оценка $M_i \in \{0,1\}$, где 0 – новые методы / оборудование применить невозможно, 1 – новые методы / оборудование применить возможно); параметры качества поверхностного слоя детали (шероховатость, качество точности); тип операции (рассматривается в качестве закодированного категориального признака: токарная, термическая, фрезерная и т. п.); тип оборудования (в качестве закодированного категориального признака); инструмент (в качестве закодированного категориального признака). В качестве выходных данных рассматривался, в первую очередь, оптимизированный порядок технологических операций; замены методов обработки или технологического оборудования (вектор M_i); а также прогнозируемые значения целевых показателей, таких как общее время выполнения технологического процесса T_{total} , общая себестоимость C_{total} , средний коэффициент использования материала K_{im} , полученная в итоге шероховатость Ra_{final} . Архитектура такой LSTM-сети состоит из трех слоев с общим количеством нейронов от 64 до 256, включает в себя «dropout-слой» со

значениями вероятностей в диапазоне $p = 0,2 \dots 0,3$ для сохранения стабильности выходных данных во время обучения, а также из полносвязных слоев, необходимых для окончательного преобразования используемых признаков. Общий вид такой сети показан на Рисунке 3.




Рисунок 2 – Пример многовариантного направленного графа для моделирования технологических маршрутов детали типа «шестерня» маслоагрегата авиационного двигателя
Figure 2 – An example of a multivariate directed graph for modeling technological routes of a gear-type part of an aircraft engine oil unit




Рисунок 3 – Упрощенная архитектура LSTM-нейронной сети для решения задачи оптимизации технологических маршрутов
Figure 3 – Simplified architecture of the LSTM neural network for solving the problem of optimizing technological routes

Для построения нейросетевой модели, требуемой для решения задачи оптимизации технологического маршрута, необходимо для каждой операции i описать

входной вектор X_i для того, чтобы LSTM-нейронная сеть могла вычислить скрытое состояние h_i и определить это значение в ячейку памяти c_i . Если обозначить векторы «забывания», входа и выхода – f_i , i_i , o_i , соответственно; сигмоидальную функцию активации буквой σ , а функцию активации гиперболического тангенса – $\tanh$, матрицы, содержащие весовые коэффициенты – w_f , w_i , w_c , w_o ; а смещения, происходящие в процессе работы сети – b_f , b_i , b_c , b_o , а знаком « $\times$ » – поэлементное умножение, то можно записать следующие выражения:

$$f_i = \sigma(w_f \cdot [h_{i-1}, X_i] + b_f), \quad (1)$$

$$i_i = \sigma(w_i \cdot [h_{i-1}, X_i] + b_i), \quad (2)$$

$$\tilde{c}_i = \tanh(w_c \cdot [h_{i-1}, X_i] + b_c), \quad (3)$$

$$c_i = f_i \times c_{i-1} + i_i \times \tilde{c}_i, \quad (4)$$

$$o_i = \sigma(w_o \cdot [h_{i-1}, X_i] + b_o), \quad (5)$$

$$h_i = o_i \times \tanh(c_i). \quad (6)$$

Целевая функция J будет стремиться к минимуму взвешенной суммы критериев оптимизации и, с учетом ограничений, может быть записана следующим образом:

$$J = w_1 \cdot \frac{T_{total}}{T_{base}} + w_2 \cdot \frac{C_{total}}{C_{base}} - w_3 \cdot \overline{K_{im}} + w_4 \cdot \frac{Ra_{final}}{Ra_{target}} + \mu \cdot D(\theta), \quad (7)$$

где T_{total} – общее время прохождения технологического маршрута после оптимизации; C_{total} – общая себестоимость технологического маршрута; $\overline{K_{im}}$ – среднее значение коэффициента использования материала; Ra_{final} – итоговая шероховатость или шероховатость поверхностей готовой годной детали, которая получена в ходе выполнения технологического маршрута, причем $Ra_{final} \leq Ra_{target}$; $w_1 \dots w_4$ – весовые коэффициенты, обозначающие «значимость» критериев оптимизации, причем $\sum_1^n w_i = 1$; μ – коэффициент регуляризации; $D(\theta)$ – регуляризационный член. В качестве ограничений выступает сама последовательность технологического маршрута, которая всегда разделена на этапы черновой обработки, при необходимости – термической обработки, чистовой и финишной обработки. Также производится контроль качества такой, что для любой i -й операции, являющейся ответственной, существует такой контроль j , где $j > i$. Требования к качеству: $Ra_{final} \leq Ra_{target}$, а также можно задать ограничения по твердости поверхностного слоя изготавливаемой детали при необходимости. Дополнительно в качестве ограничений учитывается совместимость используемого технологического оборудования и методов обработки поверхностей, предлагаемых на конкретной i -й технологической операции:

$$M'_i = 1 \Rightarrow \text{оборудование } E'_i \text{ поддерживает метод } M'_i. \quad (8)$$

Для описания функции потерь при обучении в данном исследовании использована комбинация среднеквадратичной ошибки и так называемых «штрафных функций» за нарушение ограничений:

$$L = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 + \alpha \cdot \max(0, Ra_{final} - Ra_{target}) + \beta \cdot \sum_k I(\text{наруш.огр.}k), \quad (9)$$

где y_i – целевое значение; $\hat{y}_i$ – предсказание нейросети; α и β – «штрафные» коэффициенты, I – индикаторная функция.

Для решения задачи оптимизации маршрутной технологии потребовалось собрать данные существующего производства. В представленном исследовании – это

авиадвигателестроительное производство и производство энергоустановок, разрабатываемых на основе газотурбинных двигателей. В качестве исходных данных были собраны ретроспективные данные по технологическим маршрутам и технологическим процессам для производства маслоагрегатов авиационных двигателей, так как на примере изготовления деталей данных узлов проводилось представленное исследование. Потребовались данные по применяемому технологическому оборудованию, его параметрам, технологической оснастке, режущим, мерительным и контрольным инструментам, а также данные нормирования технологических операций и их себестоимость по базовому и альтернативным вариантам, то есть данные, указанные в технологических картах на каждую операцию технологического процесса изготовления деталей [3, 6]. Предобработка включала в себя нормализацию всех числовых признаков и *one-hot*-кодирование категориальных параметров, то есть преобразования выбранных категориальных признаков в формат, с которым может работать нейросетевой алгоритм, когда каждая из категорий кодируется бинарным признаком 0 или 1. Обучение самой LSTM-нейронной сети производилось на исторических данных, с учетом которых осуществлялась настройка гиперпараметров сети, таких как количество слоев, количество нейронов в слое, скорость обучения и т. п. Оптимизация технологического маршрута включала генерацию различных вариантов последовательностей операций, с учетом оценки каждой такой последовательности согласно значению целевой функции J , описанной выше.

Для обучения, тестирования и валидации разработанной LSTM-модели был сформирован массив ретроспективных производственных данных, включающий информацию по 350 уникальным технологическим маршрутам изготовления деталей типа «шестерня» маслоагрегатов авиационных двигателей. Суммарный объем выборки составил более 8 400 технологических операций. База данных была разделена в классической пропорции: 70 % – обучающая выборка, 15 % – тестовая, 15 % – валидационная выборка.

Оптимальным считался вариант с минимальным значением целевой функции [7, 8]. Однако, при решении реальной производственной задачи следует учитывать, что все параметры оптимизации не могут достичь идеальных целевых значений, а значит, какие-то параметры будут улучшаться, какие-то останутся неизменными, а какие-то неизбежно ухудшаться. Поэтому при решении задачи оптимизации технологических маршрутов эксперту следует выбирать только те варианты при соответствующем значении целевой функции, при которых ряд параметров улучшается, а ряд – не ухудшается, и такие варианты технологических маршрутов будут оптимальными по Парето, или наиболее рациональными в конкретных заданных производственных условиях. При валидации работы алгоритма машинного обучения производилась проверка на соответствие установленным ограничениям, а также симуляция самого технологического процесса, на основании чего корректировались маршрутные карты производственных процессов и производился мониторинг производственных показателей при внедрении полученных в результате исследования оптимальных вариантов технологических маршрутов. Представленные в статье методологический подход к оптимизации технологических маршрутов, математическая модель и нейросетевой алгоритм были реализованы на языке *Python* с использованием библиотек *TensorFlow* и *Keras*. Для оценки достоверности результатов выбора оптимального варианта технологического процесса из множества решений был также проведен анализ данных, полученных в результате проведенной оптимизации технологических маршрутов с оценкой научно-технических рисков. Теоретически каждый из полученных в ходе оптимизации вариантов может быть использован в производстве, однако технологические процессы, приближенные к желательному глобальному оптимуму,

являются наиболее предпочтительными. Для этого был проведен производственный эксперимент, в результате которого было установлено, что выбирать наиболее рациональный вариант маршрута необходимо из области «гребня» графика распределения (Рисунок 4), так как в этой области полученные варианты наиболее близки к глобальному оптимуму значения целевой функции (7).




Рисунок 4 – Распределение полученных в результате исследования вариантов технологических маршрутов относительно глобального оптимума

Figure 4 – Distribution of technological route options obtained as a result of the study relative to the global optimum

Рисунок 5 – Интерфейс специализированной программы оценки научно-технических рисков при внедрении инновационных технологий¹

Figure 5 – Interface of the specialized software for assessing scientific and technical risks in the implementation of innovative technologies¹

Для автоматизации расчета рисков проектных технологических маршрутов автором предлагается использовать вероятностное моделирование рисков в инновационных проектах, для этого была разработана специализированная программа (Рисунок 5), также с элементами нейросетевого анализа, которая предназначена для предварительной оценки рисков при внедрении инновационных технологий в виде техпроцессов или маршрутов, которая также позволяет решать задачи большой размерности, когда использование традиционных детерминированных методов затруднительно или невозможно.

¹ Гаврилова О.А. Оптимизация научно-технических рисков при разработке инновационных технологий: заявл. 03.02.2026; опубл. 13.02.2026. Свидетельство о государственной регистрации программы для ЭВМ № 2026614341 Российская Федерация.

Результаты и обсуждение

Преимуществами представленного в статье комплексного подхода являются высокая степень адаптивности к заданным условиям, гибкость, которые выражаются в возможности включения в существующие базовые модели новых прогрессивных методов обработки [9, 10], а соответственно, и новых технологических маршрутов, созданных на их основе. Предложенная модель учитывает изменения в технологическом оборудовании, материалах, требованиях к качеству обработки, использованию ресурсов, и одновременно осуществляет оценку влияния изменений на себестоимость и качество изделия. Дополнительно проведенная технико-экономическая оценка результатов оптимизации показала, что внедрение предложенного подхода позволяет сократить сроки выполнения работ по технической подготовке производства на 20 %, общее время производственного цикла до 15 %, уменьшить межоперационное время на 12 %, снизить себестоимость изготовления детали до 18 %, а фондоемкость до 14 %, а также повысить коэффициент использования материалов с 0,72 до 0,81. Стоит также отметить, что применение нейросетевых оптимизационных моделей не только возможно, но и необходимо при разработке проектов комплексной автоматизации, цифровизации и цифровой трансформации производственных процессов и предприятий в рамках автоматизированных систем технической подготовки производства, в качестве универсального инструмента интеграции между САМ-планированием и исполнительным уровнем MES-систем, так как предложенная модель при применении интеллектуального подхода может быть построена автоматически на основе операционных карт САМ-системы, используемой на предприятии, вследствие чего вершины и ребра модели сформируются из технологических переходов с сохранением всех атрибутов; предложенная модель служит основой цифрового двойника технологического процесса, ведь симуляция технологических маршрутов позволяет предсказывать время цикла, себестоимость, и в целом находить наилучший маршрут еще до запуска детали в производство, за счет того, что фактические данные выполненных маршрутов уточняют веса ребер графа, формируя базу знаний для моделей машинного обучения и прогнозирования оптимального маршрута.

Заключение

В данной публикации предлагается новый подход к оптимизации проектно-технологических решений, который может быть реализован на предприятиях авиа-, приборо- и машиностроительного профиля, а также и в других отраслях, где рассматриваются дискретные детерминированные процессы. Применяя описанный подход, можно сократить не только сроки принятия проектно-технологических решений, но и повлиять на длительность производственного цикла в целом, сокращать потери, внедрять новые технологии и методы обработки в производство.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Шайхулова А.Ф., Гаврилова О.А. Системотехнические основы методов интеллектуализации инновационной подготовки производства в машиностроении. *Автоматизация. Современные технологии*. 2022;76(1):30–34. <https://doi.org/10.36652/0869-4931-2022-76-1-30-34>
Shaykhulova A.F., Gavrilova O.A. System-technical bases of intellectualization methods for innovative production preparation in machine building. *Avtomatizatsiya. Sovremennye tekhnologii*. 2022;76(1):30–34. (In Russ.). <https://doi.org/10.36652/0869-4931-2022-76-1-30-34>

2. Пучков А.Ю., Дли М.И., Лобанева Е.И. Применение глубоких нейронных сетей в моделях сложных технологических объектов. *Известия СПбГТИ(ТУ)*. 2020;(52):104–110. <https://doi.org/10.36807/1998-9849-2020-52-78-104-110>
Puchkov A.Yu., Dli M.I., Lobaneva E.I. Application of deep neural networks in models of complex technological objects. *Bulletin of SPbSIT(TU)*. 2020;(52):104–110. (In Russ.). <https://doi.org/10.36807/1998-9849-2020-52-78-104-110>
3. Шайхулова А.Ф., Селиванов С.Г. Постановка задачи цифровой трансформации производства индустрии 4.0. *XXI век: итоги прошлого и проблемы настоящего плюс*. 2021;10(2):92–95.
Shaykhulova A.F., Selivanov S.G. Digital transformation strategy development for industry 4.0. *XXI Century: Resumes of the Past and Challenges of the Present Plus*. 2021;10(2):92–95. (In Russ.).
4. Городнова Н.В. Применение искусственного интеллекта в бизнес-сфере: современное состояние и перспективы. *Вопросы инновационной экономики*. 2021;11(4):1473–1492. <https://doi.org/10.18334/vinec.11.4.112249>
Gorodnova N.V. Application of artificial intelligence in the business sphere: current state and prospects. *Russian Journal of Innovation Economics*. 2021;11(4):1473–1492. (In Russ.). <https://doi.org/10.18334/vinec.11.4.112249>
5. Махалина О.М., Махалин В.Н. Искусственный интеллект: драйвер экономического развития или генератор проблем и угроз? *BENEFICIUM*. 2024;(1):14–21. [https://doi.org/10.34680/BENEFICIUM.2024.1\(50\).14-21](https://doi.org/10.34680/BENEFICIUM.2024.1(50).14-21)
Makhalina O.M., Makhalin V.N. Artificial intelligence: a driver of economic development or a generator of problems and threats? *BENEFICIUM*. 2024;(1):14–21. (In Russ.). [https://doi.org/10.34680/BENEFICIUM.2024.1\(50\).14-21](https://doi.org/10.34680/BENEFICIUM.2024.1(50).14-21)
6. Тырышкин С.Ю. Нейросетевая оптимизация в автоматизированных системах управления высокоразмерными технологическими процессами. *Доклады ТУСУР*. 2025;28(2):153–159.
Tyryshkin S.Yu. Neural network optimization in automated control systems for complex technological processes and production. *Proceedings of the TUSUR University*. 2025;28(2):153–159. (In Russ.).
7. Соловьёв Д.В., Бондаренко И.Б. Параметрическая оптимизация сложных технологических процессов оптического производства с использованием технологий искусственных нейронных сетей. *Научно-технический вестник Санкт-Петербургского государственного университета информационных технологий, механики и оптики*. 2010;(6):121.
Soloviev D., Bondarenko I. Parametrical optimization of difficult technological processes of optical manufacture with technologies of artificial neural networks. *Nauchno-tekhnicheskii vestnik Sankt-Peterburgskogo gosudarstvennogo universiteta informatsionnykh tekhnologii, mekhaniki i optiki*. 2010;(6):121. (In Russ.).
8. Климова Т.Ю., Хаймович И.Н., Тарасов В.А., Кураков С.В. Оптимизация процессов технического обслуживания производственного оборудования с помощью нейросети. *Известия Тульского государственного университета. Технические науки*. 2025;(5):140–149.
Klimova T.Y., Khaimovich I.N., Tarasov V.A., Kurakov S.V. Preventing equipment failures in digital factory 4.0 using a neural network model. *News of the Tula State University. Technical Sciences*. 2025;(5):140–149. (In Russ.).
9. Анисимов А.А., Сороковнин М.Е., Тарарыкин С.В. Нейросетевая идентификация и настройка мехатронных систем с регуляторами состояния. *Мехатроника, автоматизация, управление*. 2025;26(2):65–76. <https://doi.org/10.17587/mau.26.65-76>

- Anisimov A.A., Sorokovnin M.E., Tararykin S.V. Neural Network Identification and Tuning of Mechatronic Systems with State Controllers. *Mekhatronika, Avtomatizatsiya, Upravlenie*. 2025;26(2):65–76. (In Russ.). <https://doi.org/10.17587/mau.26.65-76>
10. Хонин К.А., Ермолаев Р.А. Совершенствование технологического процесса в условиях автоматизированного производства. *Молодой ученый*. 2018;(25):151–155.

ИНФОРМАЦИЯ ОБ АВТОРЕ / INFORMATION ABOUT THE AUTHOR

Гаврилова Оксана Александровна, кандидат технических наук, доцент, доцент кафедры технологии машиностроения Уфимского института науки и технологий; доцент кафедры цифровых технологий в разработке и эксплуатации нефтяных и газовых месторождений Уфимского государственного нефтяного технического университета, Уфа, Российская Федерация.
e-mail: oks9036@yandex.ru
ORCID [0000-0002-9667-7977](https://orcid.org/0000-0002-9667-7977)

Oksana A. Gavrilova, Candidate of Engineering Sciences, Docent, Associate Professor at the Department of Mechanical Engineering Technology of the Ufa Institute of Science and Technology; Associate Professor at the Department of Digital Technologies in Development and Operation of Oil and Gas Fields of the Ufa State Petroleum Technical University, Ufa, the Russian Federation.

Статья поступила в редакцию 13.07.2026; одобрена после рецензирования 23.09.2026; принята к публикации 05.10.2026.

The article was submitted 13.07.2026; approved after reviewing 23.09.2026; accepted for publication 05.10.2026.