

УДК 004.896:004.032.26
DOI 10.17513/snt.40578

ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ И КВАНТОВЫХ ТЕХНОЛОГИЙ В ТЕХНОЛОГИЧЕСКИХ ПРОЦЕССАХ ПРОЕКТИРОВАНИЯ И ПРОИЗВОДСТВА БЕСПИЛОТНЫХ СИСТЕМ

Тырышкин С.Ю.

*Федеральное государственное бюджетное образовательное учреждение высшего образования
«Алтайский государственный технический университет имени И.И. Ползунова»,
Барнаул, Российская Федерация, e-mail: service.vip-spe@yandex.ru*

Квантовые технологии и инструменты искусственного интеллекта обладают огромным потенциалом для применения во многих отраслях промышленности, обещая повышение эффективности, точности и безопасности, а также расширение возможностей прогнозирования и адаптивного управления сложными процессами. Исследователи полагают, что преимущества этих инновационных технологий могут идеально подойти для создания беспилотных систем. Цель статьи заключается в изучении особенностей и перспектив применения нейросетевых и квантовых технологий в технологических процессах производства беспилотных систем. Методы исследования: анализ и синтез, систематизация данных по сферам применения, моделирование с использованием физически информированных нейронных сетей, применение квантовых алгоритмов для оптимизации проектирования и производства, оценка эффективности и надежности автономных систем. В статье детализированы сферы и потенциал применения нейросетевых и квантовых технологий для производства автономных платформ. Отдельное внимание уделено физически информированным нейронным сетям для идентификации нелинейных моделей систем в процессе проектирования беспилотных аппаратов. Апробация и преимущества предложенной архитектуры проведены на примере параметрической оптимизации лонжерона крыла БПЛА. Проведенный сравнительный анализ показывает, что физически информированные нейронные сети, интегрирующие физические законы в функцию потерь, способны на порядок сократить вычислительное время по сравнению с прямым численным моделированием. Также акцентировано внимание на повышенной сходимости, устойчивости к переобучению и стабильных результатах прогнозирования, которые позволяют получить квантовые алгоритмы в задачах производства и масштабирования беспилотников.

Ключевые слова: нейронные сети, физика, квантовые алгоритмы, вычисления, точность, производство, прогнозирование

Благодарности: Автор благодарит ООО «НИИ Кибернетики Сибири» за техническую и финансовую поддержку при проведении исследований.

THE APPLICATION OF NEURAL NETWORK AND QUANTUM TECHNOLOGIES IN THE TECHNOLOGICAL PROCESSES OF DESIGNING AND MANUFACTURING UNMANNED SYSTEMS

Tyryshkin S.Yu.

*Federal State Budgetary Educational Institution of Higher Education
“Altai State Technical University named after I.I. Polzunov”,
Barnaul, Russian Federation, e-mail: service.vip-spe@yandex.ru*

Quantum technologies and artificial intelligence tools have enormous potential for application in many industries, promising increased efficiency, accuracy, and safety, as well as expanded capabilities for forecasting and adaptive management of complex processes. Researchers believe that the advantages of these innovative technologies may be ideal for the creation of unmanned systems. The purpose of this article is to study the features and prospects of applying neural network and quantum technologies in the technological processes of unmanned system production. Research methods: analysis and synthesis, systematisation of data by area of application, modelling using physically informed neural networks, application of quantum algorithms to optimise design and production, evaluation of the efficiency and reliability of autonomous systems. The article details the areas and potential of neural network and quantum technologies for the production of autonomous platforms. Particular attention is paid to physically informed neural networks for identifying nonlinear system models in the design of unmanned aerial vehicles. The proposed architecture has been tested and its advantages demonstrated using the example of parametric optimisation of the UAV wing spar. A comparative analysis shows that physically informed neural networks, which integrate physical laws into the loss function, can reduce computing time by an order of magnitude compared to direct numerical simulation. Attention is also focused on increased convergence, resistance to overfitting, and stable prediction results, which make it possible to obtain quantum algorithms in the tasks of manufacturing and scaling unmanned aerial vehicles.

Keywords: neural networks, physics, quantum algorithms, computing, accuracy, production, prediction

Acknowledgements: The author thanks the Research Institute of Cybernetics of Siberia LLC for technical and financial support during the research.

Введение

За последнее десятилетие беспилотные системы достигли значительных успехов, в основном благодаря растущему спросу на интеллектуальную автономность, устойчивую адаптивность и контекстно-зависимое принятие решений. Сегодня эти системы находят свое применение в самых различных областях и сферах деятельности, например таких, как автономное вождение, промышленная логистика, космические миссии и точное земледелие. Ключевым требованием для обеспечения производительности, надежности и безопасности беспилотных систем является точная характеристика их базовой динамики. В свою очередь, следует отметить, что достижение этой цели зависит от сочетания различных технологий, в том числе от решения особенно сложной задачи по разработке высоконадежных и безопасных систем искусственного интеллекта [1].

Эти системы должны быть способны ориентироваться в сложных условиях реального мира – будь то автомобиль, движущийся по загруженному городу, или самолет, совершающий посадку в неблагоприятных погодных условиях. Сложность заключается в том, чтобы обеспечить безупречную работу систем автономного вождения в любых условиях, что требует тщательного их тестирования на всех этапах производства с использованием наборов данных, точно отражающих критические сценарии. Именно поэтому в последние годы научно-исследовательские центры, лаборатории и ведущие производители все чаще обращают внима-

ние на квантовые вычисления и, в частности, на квантовый генеративный искусственный интеллект как на технологию, которая имеет все необходимые характеристики для решения этой проблемы. Уже сегодня эксперты считают, что преимущества квантовых подходов могут идеально соответствовать потребностям создания систем автономного вождения и навигации. В отличие от классических, квантовые компьютеры способны обрабатывать огромные объемы данных и генерировать изображения с беспрецедентной детализацией и сложностью [2]. Эта способность открывает новые возможности создания точных симуляций критических тестовых сценариев, что необходимо для развития автономных технологий.

На рис. 1 показаны экспертные прогнозы относительно того, в каких сферах моделирования и производства беспилотных систем нейросетевые и квантовые технологии способны оказать наибольший эффект.

Несмотря на то, что более широкое применение и распространение квантовых компьютеров и интеллектуальных вычислительных методов в производстве может занять еще как минимум десятилетие, научно-экспертному сообществу уже сегодня целесообразно предпринимать шаги для лучшего понимания этих технологий и их потенциальных применений в технологических процессах выпуска беспилотных систем.

Таким образом, отмеченные обстоятельства подтверждают актуальность, теоретическую и практическую значимость темы данной статьи.

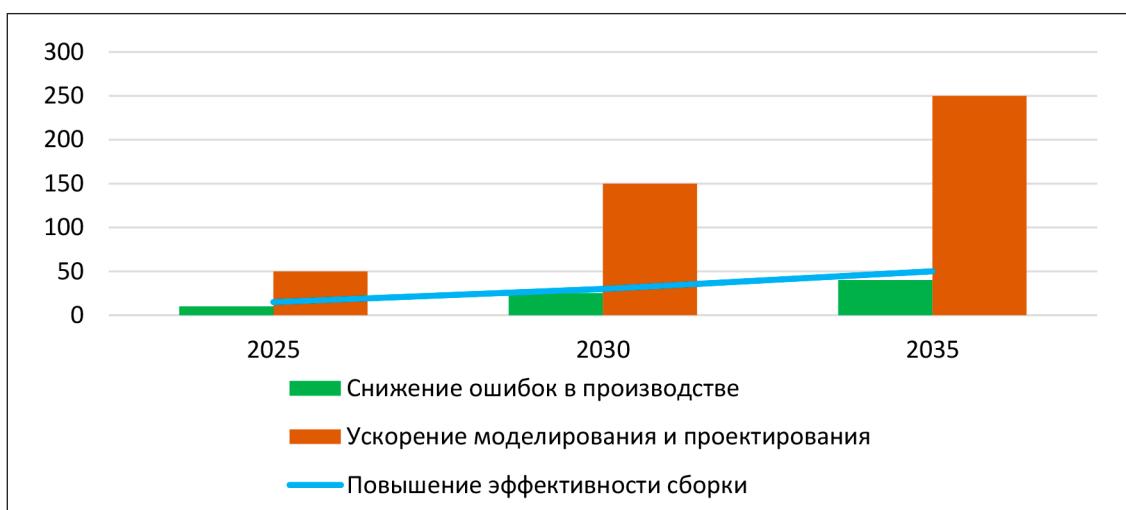


Рис. 1. Прогнозная динамика увеличения эффективности производства беспилотных систем с использованием нейросетевых и квантовых технологий (по сравнению с 2024 г., %)

Примечание: составлено автором с использованием отчетов McKinsey & Company, Boston Consulting Group, DARPA, NVIDIA (The state of AI, Quantum computing's P&L, AI in the Factory, Air Combat Evolution, DARPA, NVIDIA Omniverse, AI in Manufacturing)

Перспективы применения различных архитектур нейронных сетей для повышения точности и эффективности решения кинематических уравнений и управления роботами-манипуляторами в процессе производства сложных технологических систем рассматривают в своих трудах П.А. Замятин, Р.М. Ростовцев, С.А. Солохин, П.Е. Хрустальев [3], Zhang Youchun, Zhang Gonyong [4], Vandana Dabass, S. Sangwan [5].

Возможности квантового генеративного искусственного интеллекта для решения задачи разработки физической модели беспилотника, который позволит оптимизировать входные данные LiDAR и обрабатывать расстояния до препятствий, предупреждая тем самым столкновения и общую адаптивность, изучают М.Ф. Савельев, А.В. Обухов, Н.С. Малахова, Е.Г. Воробьев [6], М.Е. Иванов, Д. Решетников [7], Qifu Wang, Yuteng Guan [8].

Над усовершенствованием алгоритма на основе рекуррентной нейронной сети, который необходим для снижения вычислительных требований, обычно связанных с моделированием динамики беспилотных систем, трудятся Д.А. Сергеев [9], Nihar Patel, Nakul Vasani [10], Chunbo Zhao, Huaran Yan [11]. Особое внимание уделено требованиям к видеопотоку при FPV-управлении беспилотными системами [12].

В то же время в существующих на сегодняшний день публикациях освещены отнюдь не все аспекты интеграции квантовых вычислений и нейросетевых технологий в производственные процессы роботизированных платформ. Так, например, нерешенной остается проблема перевода дневных изображений дорог в ночные с сохранением контента, например, положения автомобилей. Эта задача особенно сложна из-за ресурсоемкости классических решений, которые часто дают нестабильные результаты. Отдельного внимания заслуживает вопрос преодоления трудностей, присущих квантовому машинному обучению, таких как проблема «плато Баррена», решение которого, по мнению ученых, будет крайне полезно для более точного проектирования объектов автономной мобильности.

Цель исследования – рассмотреть возможности и особенности применения нейросетевых и квантовых технологий в технологических процессах производства беспилотных систем.

Материалы и методы исследования

Включены анализ и синтез научных публикаций за 2022–2025 гг. в области применения нейросетевых и квантовых технологий в производстве беспилотных систем, систематизация данных международных от-

четов (McKinsey & Company, BCG, DARPA, NVIDIA) о динамике внедрения инновационных технологий. Методы исследования: анализ и синтез, систематизация данных по сферам применения, моделирование с использованием физически информированных нейронных сетей, применение квантовых алгоритмов для оптимизации проектирования и производства, оценка эффективности и надежности автономных систем.

Результаты исследования и их обсуждение

Интеграция квантовых вычислений, технологий искусственного интеллекта в сферу беспилотных систем продвигается стремительными темпами. Эти передовые инновации стали трансформирующей силой в автономных платформах, предоставляя более действенные методы моделирования и испытаний, управления и оптимизации, с которыми классические приемы вычислений часто не справлялись. Междисциплинарные исследования изучают, каким образом квантовые технологии и нейронные сети могут улучшить автономные системы, решая сложные задачи, такие как планирование траектории, координация нескольких агентов, объединение датчиков и оптимизация. Сочетание квантовых вычислений с нейронными сетями улучшает производительность моделей за счет использования свойств квантовой механики, таких как суперпозиция, связанные и квантовый параллелизм [13].

На основе анализа имеющихся на сегодняшний день публикаций и результатов исследований автором в табл. 1 систематизирована информация относительно сфер приложений и возможностей использования рассматриваемых технологий.

Рассмотрим некоторые примеры приложения квантовых технологий и нейронных сетей в технологических процессах производства беспилотных систем.

Инжиниринг и проектирование

Инженерные симуляции имеют существенное значение для производства беспилотных систем. Они необходимы для сокращения затрат на проектирование и тестирование за счет уменьшения необходимости в физических прототипах и лабораториях, например, аэродинамических трубах в автомобильной и аэрокосмической отраслях. Численные моделирования, особенно основанные на методе конечных элементов, имеют решающее значение для симуляции сложных процессов, таких как аэродинамика, рабочая прочность, динамика конструкций, аварийная безопасность и производственные вопросы [14].

Таблица 1

Сфера и возможности применения нейросетевых и квантовых технологий в процессах производства беспилотных систем

Этап производства	Нейросетевые технологии	Квантовые технологии
Проектирование и моделирование	<ul style="list-style-type: none"> оптимизация конструкции: нейросети могут анализировать тысячи вариантов дизайна для повышения аэродинамической эффективности и снижения веса; прогнозирование поведения: симуляция поведения систем в различных условиях (ветер, осадки) для выявления и устранения уязвимостей 	<ul style="list-style-type: none"> создание новых материалов: квантовое моделирование позволяет исследовать новые материалы с улучшенными свойствами (прочность, легкость); оптимизация компоновки: квантовые алгоритмы могут находить наиболее эффективную комплектацию элементов на микроволновом уровне, что улучшает производительность
Разработка систем навигации и управления	<ul style="list-style-type: none"> автономная навигация: нейросети обрабатывают данные с сенсоров (камер, лазеров) для точного распознавания объектов и принятия решений в реальном времени; адаптивное управление: система может самостоятельно подстраивать траекторию полета под меняющиеся условия (например, сильный ветер) 	<ul style="list-style-type: none"> квантовые сенсоры: использование квантовых гироскопов и магнитометров для сверхточной навигации, не зависящей от GPS-сигналов; оптимизация маршрута: квантовые алгоритмы могут мгновенно рассчитывать оптимальные маршруты, учитывая огромное количество переменных (препятствия, погодные условия)
Распознавание и анализ данных	<ul style="list-style-type: none"> компьютерное зрение: мгновенное распознавание объектов, людей, животных, а также анализ местности для картографирования; прогнозирование: анализ данных с датчиков для прогнозирования потенциальных угроз или неисправностей 	<ul style="list-style-type: none"> улучшенная обработка сигналов: квантовые технологии могут обеспечить повышенную чувствительность сенсоров для обнаружения скрытых объектов или сигналов; защита информации: использование квантовой криптографии для защиты каналов связи и предотвращения перехвата данных с беспилотника
Контроль качества и безопасности	<ul style="list-style-type: none"> прогнозирование поломок: нейросети анализируют данные телеметрии и определяют вероятность отказа компонентов; автоматизированное тестирование: моделирование тысяч сценариев в виртуальной среде для проверки надежности системы 	<ul style="list-style-type: none"> квантовые генераторы случайных чисел: обеспечение высокого уровня безопасности связи, что критически важно для защиты от взлома; улучшенный контроль качества: использование квантовых сенсоров для обнаружения микроскопических дефектов в материалах, что повышает надежность аппарата

Примечание: составлена автором.

Например, компания Bosch исследует подходы к моделированию электрических приводов беспилотных аппаратов на основе квантовых вычислений. AIRBUS изучает использование квантовых или гибридных квантово-классических подходов для вычислительной гидродинамики с целью сокращения затрат, необходимых для анализа поведения воздушного потока вокруг беспилотника.

Особое значение в данной сфере имеют физически информированные нейронные сети, которые вводятся для интеграции физических законов, обычно описываемых обыкновенными дифференциальными уравнениями (ОДУ), в глубокие нейронные сети (ГНС). Этот подход обучает ГНС в режиме контролируемого обучения для отслеживания и контроля заданных физических закономерностей, что позволяет автоматически находить решения ОДУ на основе данных. Основная идея физически информированной нейронной сети заключается в интеграции дифференциального уравнения в функцию потерь, как показано на рис. 2, что повышает надежность сети и облегчает точные аппроксимации даже в сценариях с недостатком данных, что очень часто встречается в технологических процессах производства беспилотных систем.

На рис. 2 условные обозначения:

- сплошные линии → это прямые причинно-следственные зависимости: данные, предсказания или вычисленные величины передаются от одного блока к другому;

- пунктирные линии → это обратные связи или адаптивные корректировки, другими словами, информация идет «назад» в сеть или в модуль коррекции, чтобы обновить веса, параметры или динамику;

- точечные линии → это слабые или вспомогательные связи, которые не участвуют напрямую в вычислительном процессе, но обеспечивают дополнительную проверку или учет информации (например, сравнение предсказаний с измерениями или влияние доверия на функцию потерь).

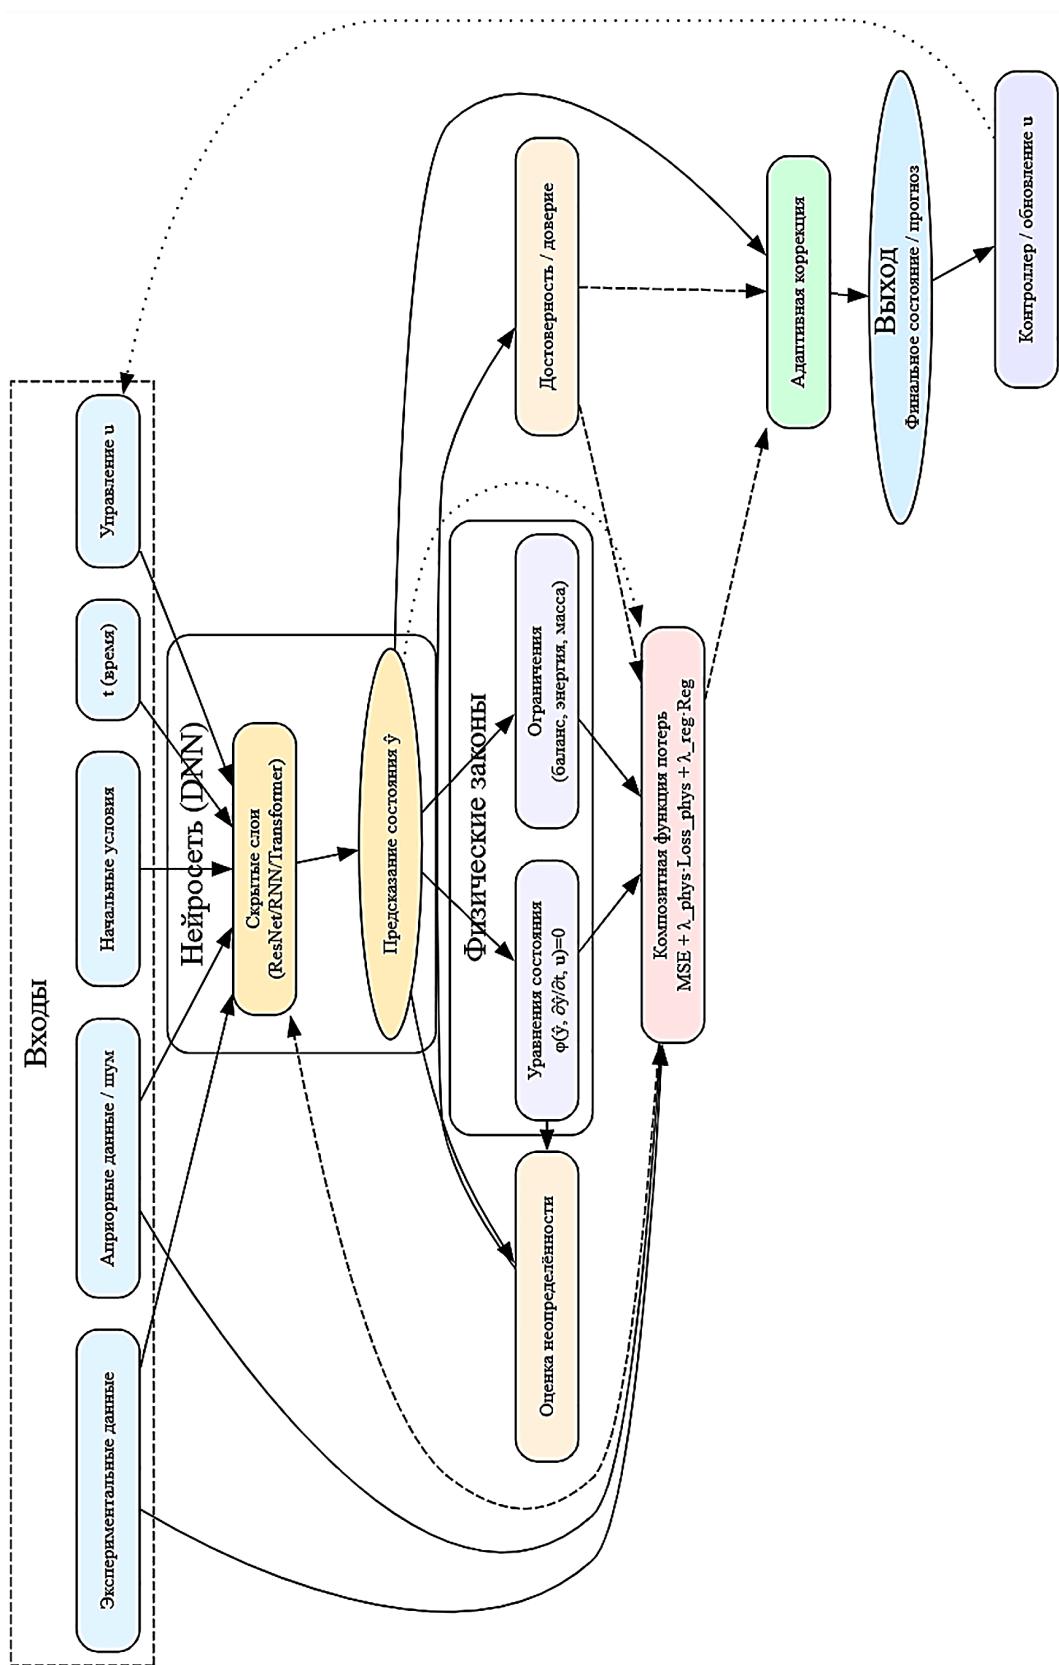


Рис. 2. Архитектура физически информированной нейронной сети
Примечание: составлен автором по результатам данного исследования

Параметризованные и нелинейные уравнения в частных производных имеют следующий общий вид:

$$\partial_t \hat{y} + N[\hat{y}; \lambda] = 0 \quad t \in [0, T],$$

где $\hat{y}(t, x)$ представляет собой скрытое (неявное) решение или состояние динамической системы, а $N[\cdot]$ обозначает нелинейный дифференциальный оператор, параметризованный λ . Определим $l(t, x)$ как выражение в левой части уравнения, то есть:

$$l : \partial_t \hat{y} + N[\hat{y}].$$

После этого продолжается моделирование $\hat{y}(t, x)$ с помощью глубокой нейронной сети. В данном контексте \hat{y} служит выходом многослойной нейронной сети, обозначенной $l_w(t)$, где $\hat{y} = l_w(t)$, пусть l_w является функцией отображения, обученной глубокой сетью с аддитивными весами w . Таким образом, ожидается, что нейронная сеть обучится решению заданного ОДУ как функции непрерывного времени t .

Используя автоматическое дифференцирование и правило цепочки, можно вывести нейронную сеть, представляющую $\hat{y}(t, x)$. Предполагая автономную систему, нейронная сеть $\hat{y}(t)$ обучается, тем самым оптимизируются ее общие параметры с параметрами $\hat{y}(t, x)$ и $l(t, x)$. Цель – минимизировать функцию затрат среднеквадратичной ошибки (MSE).

$$MSE = MSE_{\hat{y}} + \gamma MSE_l,$$

$$MSE_{\hat{y}} = \frac{1}{N_{\hat{y}}} \sum_{i=1}^{N_{\hat{y}}} \frac{1}{N_t} \sum_{i=1}^{N_{\hat{y}}} \left| \hat{y}_i(t^j) - \hat{y}_{i,ref}^j \right|^2,$$

$$MSE_l = \frac{1}{N_{\hat{y}}} \sum_{i=1}^{N_{\hat{y}}} \frac{1}{N_l} \sum_{i=1}^{N_{\hat{y}}} \left| l(\hat{y}_i(t^k)) \right|^2,$$

где $0 \leq \gamma \leq 1$ – гиперпараметр, который должен отражать степень уверенности в физических ограничениях системы, N_t – общее количество выборок обучающих данных, N_l – количество точек коллокации, а $N_{\hat{y}}$ – количество выходов, генерируемых нейронной сетью. Для каждого выхода i обозначаем прогноз сети как $\hat{y}_i(\cdot)$. Имея пару данных $(t^j, \hat{y}_{i,ref}^j)$, где j индексирует пару, а $\hat{y}_{i,ref}^j$ является желаемым выходом, можно сравнить ее с прогнозом сети $\hat{y}_i(\cdot)$.

Рассмотрим на конкретном примере преимущества использования архитектуры физически информированной нейронной сети для проектирования и производства БПЛА. Для этого проведем сравнительный анализ трех подходов: прямое численное моделирование, суррогатное моделирование на основе

данных (Data-Driven Surrogate), физически информированная нейронная сеть (PINN).

Итак, задача заключается в параметрической оптимизации лонжерона крыла БПЛА.

Объект: лонжерон крыла БПЛА.

Параметр: толщина стенки лонжерона h .

Цель: минимизация массы $m(h)$ при соблюдении ограничений по рабочей прочности.

Ограничение: максимальные эквивалентные напряжения (по Мизесу) σ_{max} при расчетной аэродинамической нагрузке F_{load} не должны превышать допустимого значения $[\sigma] = 250$ МПа.

Сценарий: для построения функции отклика $\sigma_{max}(h)$ и нахождения оптимального h^* требуется выполнить 100 оценочных расчетов (итераций) в диапазоне $h \in [2,0 \text{ мм}, 12,0 \text{ мм}]$.

Подход 1: прямое численное моделирование (МКЭ)

Данный подход является традиционным и базовым для верификации. Он заключается в решении уравнений теории упругости методом конечных элементов (МКЭ) для каждой итерации h_i ($i = 1 \dots 100$).

Методология: для каждого значения h_i выполняется полный цикл: регенерация геометрии, дискретизация (построение сетки), решение системы линейных алгебраических уравнений (СЛАУ) $KU=F$ и постобработка для нахождения σ_{max} .

Вычислительная оценка:

– средняя вычислительная трудоемкость одного полного расчета (включая регенерацию сетки и решение) на доступном вычислительном кластере:

$$T_{fem} = 45 \text{ мин};$$

– суммарные вычислительные затраты на оптимизационный цикл:

$$T_{total} = N_{eval} \times T_{fem} = 100 \times 45 \text{ мин} = \\ = 4500 \text{ мин} = 75 \text{ ч.}$$

Ограничение: подход вычислительно затратен и плохо масштабируется при увеличении числа параметров.

Подход 2: Суррогатное моделирование на основе данных (Data-Driven Surrogate)

Этот подход предполагает использование «чистой» нейронной сети (например, MLP – многослойный перцептрон) для аппроксимации функции отклика $\sigma_{max} \approx f(h; w)$, где w – веса сети.

Методология: требуется двухэтапный процесс.

1. Этап «Offline» (генерация данных): создание представительной обучающей выборки. Для адекватной аппроксимации нелинейной физики требуется N_{data} точек, сгенерированных Подходом 1. Для обеспечения робастности предположим $N_{data} = 2000$.

2. Этап «Online» (обучение и предсказание): обучение сети на выборке

$$\{h_j, \sigma_{max}\}_{j=1}^{N_{data}}$$

и последующее (предсказание) для 100 ис-
комых вариантов h_j .

Вычислительная оценка:

– затраты на генерацию данных:

$$T_{data} = N_{data} \times T_{fem} = 2000 \times 45 \text{ мин} = 1500 \text{ ч};$$

– затраты на обучение сети:

$$T_{data} \approx 1 \text{ ч (на GPU);}$$

– затраты на предсказание:

$$T_{infer} < 1 \text{ с.}$$

Ограничение:

суммарные затраты $T_{total} \approx 1501 \text{ ч}$. Под-
ход неэффективен для новых R&D задач,
где отсутствует априорная база данных
(data-scarce scenarios).

Подход 3: Физически информированная
нейронная сеть (PINN)

Данный подход, описанный в статье,
решает проблему дефицита данных, инте-
грируя физические законы (УЧП) непосред-
ственно в функцию потерь.

Методология: сеть $u_{NN}(x, y, z, h, w)$ аппрок-
симирует само поле перемещений u в за-
висимости не только от координат (x, y, z) ,
но и от параметра h .

Функция потерь $Loss = Loss_{data} + Loss_{phys}$:

$Loss_{data}$: минимизирует ошибку на край-
не малом наборе N_u «якорных» точек (ре-
зультатов МКЭ-симуляций), $N_u \ll N_{data}$.

$Loss_{phys}$: минимизирует остаток УЧП те-
ории упругости $l(u_{NN}) = \nabla \cdot \sigma(u_{NN}) + F$ на
 N_l точках коллокации, распределенных по
области Ω и ее границам. УЧП выступает
в роли регуляризатора.

Вычислительная оценка:

– затраты на генерацию данных: пусть
 $N_u = 10$ опорных симуляций (на 10% меньше
данных, чем в Подходе 1, и на 99,5% меньше,
чем в Подходе 2). $T_{data} = 10 \times 45 \text{ мин} = 7,5 \text{ ч}$;

– затраты на обучение сети: T_{train_pinn} . Об-
учение PINN – это нетривиальная задача
оптимизации невыпуклой функции потерь,
требующая тонкой настройки гиперпараме-
тров (включая u). Оценим ее в 5 ч;

– затраты на предсказание: $T_{infer} < 1 \text{ с.}$

Ограничение:

суммарные затраты $T_{total} \approx 12,5 \text{ ч}$. Слож-
ность процесса обучения и чувствитель-
ность к гиперпараметрам (спектральное сме-
щение, балансировка $Loss$).

Сравнительная характеристика полу-
ченных результатов представлена в табл. 2.

Сравнительный анализ показывает,
что в задачах параметрической оптимиза-
ции, характеризующихся дефицитом дан-
ных, физически информированные нейрон-
ные сети (PINN) демонстрируют значитель-
ное (в представленном примере – в 6 раз)
преимущество в вычислительных затра-
тах по сравнению с традиционными ме-
тодами прямого численного моделирова-
ния (75 ч vs 12,5 ч). В отличие от «чи-
стых» суррогатных моделей, требующих
для обучения очень больших объемов апри-
орных данных (1501 ч), PINN эффектив-
но используют информацию, заложенную
в самих дифференциальных уравнениях
(УЧП), которые выступают в роли мощно-
го физического регуляризатора. Это позво-
ляет находить достоверные решения даже
при минимальном объеме эмпирических
или численных данных (N_u), что полностью
соответствует целям сокращения затрат
на проектирование и производство БПЛА.

Таблица 2

Сводная таблица сравнительного анализа

Параметр	Подход 1: прямой МКЭ	Подход 2: суррогат (Data-Driven)	Подход 3: PINN
Основной принцип	Численное решение УЧП	Аппроксимация данных	Гибрид: аппроксимация + регуляризация УЧП
Потребность в данных (N_{data})	0 (для предсказания)	$N_{data} \sim 2000 +$ (для обучения)	$N_u \sim 10$ (для калибровки)
«Знание» физики	Явное (встроено в решатель)	Неявное (только из данных)	Явное (встроено в $Loss_{phys}$)
Время «Offline» (подготовка)	0	1500 ч (сбор данных) + 1 ч (обучение)	7,5 ч (сбор данных) + 5 ч (обучение)
Время «Online» (расчет 100 вариантов)	75 ч	< 1 с	< 1 с
Общее время выполнения	75 ч	~1501 ч	12,5 ч

Таблица 3

Применение квантовых алгоритмов для решения задач оптимизации технических процессов в ходе производства беспилотных систем

Алгоритм	Математическая задача	Техническое применение в производстве беспилотных систем
Квантовый отжиг	Комбинаторная оптимизация	Оптимизация роботизированных сборочных линий: расчет идеальной последовательности операций для минимизации времени сборки. Проектирование печатных плат: размещение компонентов для максимальной эффективности и минимизация наводок
Алгоритм Гровера	Неструктурированный поиск данных	Базы данных материалов: мгновенный поиск компонентов, соответствующих заданным техническим требованиям (прочность, вес, электропроводимость). Тестирование программного обеспечения: быстрый поиск уязвимостей или ошибок в коде полетного контроллера
Квантовое моделирование	Моделирование многочастичных систем	Материаловедение: моделирование новых сплавов и композитов для корпусов с целью предсказания их прочности, усталости и теплопроводности на атомном уровне. Моделирование батарей: расчет химических реакций для разработки более эффективных и легких аккумуляторов
Гибридные квантово-классические алгоритмы	Оптимизация с ограничениями	Оптимизация маршрутов и логистики: расчет идеальных маршрутов поставок с учетом тысяч переменных, таких как пробки, вес груза и срочность. Управление производством: оптимизация графика смен и использования оборудования для максимизации выпуска продукции
Квантовые сенсоры (на основе кубитов)	Сверхточное измерение	Неразрушающий контроль: выявление микроскопических дефектов в материалах, сварных швах и электронике путем измерения магнитных и гравитационных аномалий. Калибровка: сверточная калибровка гироскопов и акселерометров перед установкой.

Примечание: составлена автором на основе полученных данных в ходе исследования

Производство и масштабирование

Технологические процессы производства беспилотных систем часто включают большое количество переменных и ограничений, которые необходимо учитывать. Классические алгоритмы, такие как имитационный отжиг, позволяют найти только локальные оптимумы и предоставить не-оптимальное решение [15]. Квантовые подходы к оптимизации, такие как квантовый отжиг, адиабатические или гибридные алгоритмы (например, квантовый алгоритм приближенной оптимизации), обещают решить проблемы с большими пространствами параметров, предоставить более качественные решения и сократить время их поиска (табл. 3) [16].

Заключение

Активно развивающиеся на сегодняшний день технологии искусственного интеллекта и квантовые вычисления заключают в себе большой потенциал повышения эффективности и точности технологических процессов производства беспилотных систем.

В рамках статьи описаны возможности использования метода машинного обучения на основе физических знаний, а именно нейронных сетей на основе физических знаний, для идентификации нелинейных моделей систем в процессе проектирования автономных платформ, особенно в случаях, когда реальные данные ввода-вывода ограничены. Показан потенциал физически информированных нейронных сетей в замене сложной нелинейной динамики более простыми и вычислительно эффективными аппроксимациями.

Проведенный сравнительный анализ вычислительной эффективности для задачи параметрической оптимизации лонжерона крыла БПЛА продемонстрировал значительное преимущество физически информированных нейронных сетей. Общие временные затраты на решение задачи (включая подготовку и расчет 100 вариантов) для PINN составили 12,5 ч, в то время как для традиционного прямого моделирования методом конечных элементов (МКЭ) потребовалось ~75 ч. Это 6-кратное ускорение достигается за счет замены многократ-

ных полных расчетов однократным обучением быстрой суррогатной модели.

Также в ходе исследования акцентировано внимание на повышенной сходимости, устойчивости к переобучению и стабильных результатах прогнозирования, которые могут быть достигнуты с помощью квантовых алгоритмов в процессе производства беспилотных систем и его масштабирования. Это представляет собой ценный шаг вперед в области высокоточной оценки и оптимизации динамических параметров в сложных системах, требующих точного моделирования в реальном времени.

Список литературы

1. Левченко Н.В., Замятин П.А. Применение положений унитарной квантовой теории в интересах подогрэли беспилотных авиационных систем // Славянский форум. 2024. № 1 (43). С. 337–346. EDN: PVGLV.
2. M.D. Owahedur Rahman, Muhammad Bilal Yaseen, Anum Shafiq, Sadashiv Chaturvedi. Quantum-Driven Optimization in UAV-Assisted RIS Networks: A Comprehensive Framework for Maximizing Quantum-Enhanced Signal Reconfiguration Efficiency // International Journal of Communication Systems. 2025. Vol. 38. Is. 14. P. e70224. DOI: 10.1002/dac.70224.
3. Замятин П.А., Ростовцев Р.М., Солохин С.А., Хрусталев П.Е. Использование квантовых технологий для решения навигационных задач робототехнических комплексов, включая беспилотные авиационные системы // Славянский форум. 2024. № 3 (45). С. 182–200. EDN: HPITEU.
4. Youchun Zh. Design of Multimodal Neural Network Control System for Mechanically Driven Reconfigurable Robot // Computational Intelligence and Neuroscience. 2022. Vol. 2022. P. 2447263. DOI: 10.1155/2022/2447263. EDN: KFSYMO.
5. Vandana Dabass, Suman Sangwan. Optimization Algorithm-Based Deep Quantum Neural Network for Task Allocation in Multi-Robot Systems // International Journal of Adaptive Control and Signal Processing. 2025. Vol. 39. Is. 8. P. 1696–1711. DOI: 10.1002/acs.4015.
6. Саельев М.Ф., Обухов А.В., Малахова Н.С., Воробьев Е.Г. Метод решения задачи безопасного движения транспорта и пешеходов на основе квантовых и нейрокомпьютерных систем // Интеллектуальные технологии на транспорте. 2024. № 4 (40). С. 43–49. DOI: 10.20295/2413-2527-2024-440-43-49. EDN: DEEAVT.
7. Иванов М.Е., Решетников Д.В. Нейросетевая коррекция навигационных систем высокоточных беспилотных летательных аппаратов на основе обучения нейросети без учителя // Инновационное приборостроение. 2025. Т. 4. № 1. С. 68–73. DOI: 10.31799/2949-0693-2025-1-68-73. EDN: UPDLCI.
8. Qifu Wang, Yuteng Guan Neural Network-Based Adaptive Dynamic Surface Course Tracking Control of an Unmanned Surface Vehicle With Signal Input Quantization // International Journal of Adaptive Control and Signal Processing. 2025. Vol. 39. P. 20–27. DOI: 10.1002/acs.4017.
9. Сергеев Д.А., Родионов Д.Г., Поляков П.А. и др. Интеллектуальная система мониторинга и адаптации маршрута беспилотных летательных аппаратов на основе нейросетевого анализа объектов риска // Программные системы и вычислительные методы. 2025. № 1. С. 55–70. DOI: 10.7256/2454-0714.2025.1.73255. EDN: UZVYID.
10. Patel N., Vasani N., Gupta R. et al. Convolutional neural network and unmanned aerial vehicle-based public safety framework for human life protection // International Journal of Communication Systems. 2025. Т. 38. № 1. e5545. DOI: 10.1002/dac.5545. EDN: ETIXOI.
11. Zhao Ch., Yan H., Gao D. et al. Adaptive Neural Network Iterative Sliding Mode Course Tracking Control for Unmanned Surface Vessels // Journal of Mathematics. 2022. Vol. 2022. P. 1417704. DOI: 10.1155/2022/1417704. EDN: YUASUN.
12. Березкин А.А., Вивчарь Р.М., Киричек Р.В. Подход к обоснованию требований к качеству видеопотока при FPV-управлении беспилотными системами // Труды учебных заведений связи. 2024. Т. 10. № 4. С. 7–15. DOI: 10.31854/1813-324X-2024-10-4-7-15. EDN: JQQCXK.
13. Амосов О.С., Амосова С.Г. Интеллектуальные технологии совместной навигации и функционирования подвижных объектов в разных физических средах // Информационные технологии. 2025. Т. 31. № 1. С. 24–34. DOI: 10.17587/it.31.24-34. EDN: ZOUENC.
14. Özgören A.C., Uzol O. A Data-Driven Approach for the Prediction of Reynolds Number Effects on Wind Turbine Airfoil Aerodynamic Polars // Wind Energy. 2025. Vol. 28. Is. 3. DOI: 10.1002/we.2964. EDN: ZXGPHH.
15. Fan B., Li Yu., Zhang R., Fu Q. Review on the Technological Development and Application of UAV Systems // Chinese Journal of Electronics. 2020. Vol. 29. Is 2. P. 199–207. DOI: 10.1049/cje.2019.12.006. EDN: EKVCCK.
16. Тырышкин С.Ю. Алгоритмы квантовой оптимизации в исследовании операций: методы, приложения и перспективы развития // Международный журнал гуманитарных и естественных наук. 2024. № 11–3 (98). С. 243–247. DOI: 10.24412/2500-1000-2024-11-3-243-247. EDN: HUVQMR.

Конфликт интересов: Автор заявляет об отсутствии конфликта интересов.

Conflict of interest: The author declares that there is no conflict of interest.