

УДК: 004.94

Гибридная нейронная сеть для прогнозирования характеристик покрытия при газопламенном напылении

И. В. Антонов^а, Ю. В. Бруттан^б, М. А. Горелов^с, Ю. С. Яковлев^д

Псковский государственный университет,
Россия, 180000, г. Псков, пл. Ленина, д. 2

E-mail: ^а igorant63@yandex.ru, ^б bruttan@mail.ru, ^с m.gorelov@pskgu.ru, ^д yakovlev.us@pskgu.ru

Получено 03.11.2025.

Принято к публикации 11.11.2025.

Представлена модель гибридной искусственной нейронной сети, основанная на архитектуре, включающей сверточный энкодер изображений (Convolutional Neural Network, CNN) и модуль внимания (Attention-based Multiple Instance Learning, Attention MIL), обеспечивающий агрегирование информативных признаков из последовательности кадров процесса газопламенного напыления. Дополнительные технологические параметры — давление воздуха, давление пропана и расстояние от сопла до поверхности — интегрируются в модель через табличный канал, что позволяет учитывать взаимосвязь между визуальными и числовыми характеристиками технологического режима. Программная реализация выполнена на платформе Streamlit с использованием библиотеки PyTorch и включает интерактивный интерфейс для обучения и визуализации результатов, анализ весов внимания по кадрам, а также режим прогнозирования выходных характеристик — шероховатости поверхности (R_a) и массы нанесенного слоя (m). Проведены экспериментальные исследования на данных реальных технологических процессов, выполнен сравнительный анализ точности различных конфигураций модели. Показано, что гибридная нейронная сеть, объединяющая визуальные и табличные признаки, обеспечивает более высокую точность прогноза по сравнению с моделями, использующими только одну из модальностей. При сравнении вариантов реализации гибридной нейронной сети установлено, что использование механизма внимания при формировании признаков серии изображений процесса газопламенного напыления обеспечивает существенное увеличение точности результатов по сравнению с режимом усреднения признаков без использования механизма внимания. В приложении реализован модуль визуализации внимания, который создает монтаж наиболее значимых кадров и отображает их веса внимания, что позволяет определить, какие кадры оказали наибольшее влияние на прогноз. Реализована возможность экспорта модели в формат ONNX для интеграции в системы технологического контроля. Предложенный подход демонстрирует эффективность слияния визуальной и табличной информации для задач мониторинга технологических процессов. Модель может служить основой для создания системы поддержки принятия решений или системы автоматизированного контроля качества покрытия при газопламенном напылении. Рассмотрены ограничения реализованной модели и перспективы ее дальнейшего развития.

Ключевые слова: газопламенное напыление, прогнозирование, гибридная нейронная сеть, Attention MIL, компьютерное зрение, Streamlit, ONNX, контроль качества покрытия

Статья опубликована в рамках реализации программы развития Псковского государственного университета программы стратегического академического лидерства «Приоритет-2030».

UDC: 004.94

Hybrid neural network for predicting coating characteristics in flame spraying

I. V. Antonov^a, Iu. V. Bruttan^b, M. A. Gorelov^c, Iu. S. Iakovlev^d

Pskov State University,
2 Lenin sq., Pskov, 180000, Russia

E-mail: ^a igorant63@yandex.ru, ^b bruttan@mail.ru, ^c m.gorelov@pskgu.ru, ^d yakovlev.us@pskgu.ru

Received 03.11.2025.

Accepted for publication 11.11.2025.

The paper presents a hybrid artificial neural network model based on an architecture that incorporates a convolutional image encoder (CNN) and an attention module (Attention-based Multiple Instance Learning, Attention MIL). This module aggregates informative features from a sequence of frames capturing the flame spraying process. Additional technological parameters—air pressure, propane pressure, and standoff distance — are integrated into the model via a tabular channel, enabling it to account for the relationship between visual data and numerical process regime characteristics. The software implementation was developed using the Streamlit platform and the PyTorch library. It features an interactive interface for model training and result visualization, analysis of attention weights across frames, and a prediction mode for output characteristics: surface roughness (R_a) and the mass of the deposited coating (m). Experimental studies were conducted on data from real-world technological processes, and a comparative analysis of the accuracy of various model configurations was performed. The results demonstrate that the hybrid neural network, which combines visual and tabular features, achieves higher prediction accuracy compared to models using only a single modality. Furthermore, when comparing different implementations of the hybrid network, it was established that using the attention mechanism to process the series of flame spray images provides a significant increase in accuracy over a simple averaging of features without attention. The application includes an attention visualization module that creates a montage of the most significant frames and displays their attention weights, allowing users to identify which frames had the greatest influence on the prediction. The model's capability for export to the ONNX format for integration into process control systems is also demonstrated. The proposed approach showcases the effectiveness of fusing visual and tabular information for manufacturing process monitoring tasks. The model can serve as a foundation for developing a decision support system or an automated quality control system for coatings produced by flame spraying. The limitations of the implemented model and prospects for its further development are also considered.

Keywords: flame spraying, forecasting, hybrid neural network, Attention MIL, computer vision, Streamlit, ONNX, coating quality control

Citation: *Computer Research and Modeling*, 2026, vol. 18, no. 1, pp. 101–116 (Russian).

The article was published as part of the implementation of the strategic academic leadership program “Priority 2030” at Pskov State University.

1. Введение

Газопламенное напыление является широко распространенным и экономически эффективным технологическим процессом, используемым для создания функциональных покрытий, защиты поверхностей от износа и коррозии, а также для восстановления геометрии деталей. Качество конечного покрытия определяется множеством характеристик, среди которых ключевыми для оценки эксплуатационных свойств часто выступают шероховатость (R_a) и толщина (или масса, m) нанесенного слоя [Елагина и др., 2020; Колубаев, Сизова, 2024]. Процесс напыления отличается высокой стохастичностью и чувствительностью к множеству входных параметров, включая давление воздуха (P_{air}), давление горючего газа (P_{prop}) и расстояние от сопла до заготовки (SOD) [Клименов и др., 2007; Кузнецов и др., 2025]. Незначительные флуктуации в этих параметрах или в условиях окружающей среды могут приводить к существенному изменению морфологии пламени и, как следствие, к вариациям в R_a и m [Горелов и др., 2025]. Существующие методы контроля качества, как правило, являются постфактум контролем: они проводятся в лаборатории на полученных образцах, часто требуют разрушения образца и не позволяют оперативно скорректировать процесс. Это ведет к увеличению производственных издержек и процента брака. В связи с этим разработка методов оперативного мониторинга, способных прогнозировать конечные характеристики покрытия непосредственно в ходе технологического процесса, является актуальной научной и прикладной задачей. Целью настоящей работы являются разработка и валидация гибридной модели глубокого обучения, способной прогнозировать R_a и m покрытия на основе двух модальностей входных данных: 1) серий изображений (кадров) пламени, снятых в процессе напыления; 2) табличных технологических параметров (P_{air} , P_{prop} , SOD). Традиционно для моделирования подобных процессов используются аналитические физико-математические модели [Воронецкий и др., 2011], однако их сложность и необходимость учета множества трудноизмеримых факторов ограничивают их практическое применение. Альтернативой являются методы машинного обучения (МО), такие как регрессионные модели или деревья решений [Pedregosa et al., 2011], которые хорошо зарекомендовали себя в прогнозировании свойств материалов по статичным технологическим параметрам. Однако такие модели полностью игнорируют богатую динамическую информацию, содержащуюся в визуальном потоке данных (например, о форме, стабильности и температуре факела пламени). В то же время методы компьютерного зрения на базе сверточных нейронных сетей (CNN) доказали свою высокую эффективность в смежных областях промышленного мониторинга, таких как контроль сварных швов, мониторинг аддитивного производства (3D-печати) и дефектоскопия [Gui et al., 2023]. Несмотря на это, в доступной литературе наблюдается недостаток исследований, посвященных комплексному анализу процесса газопламенного напыления, который бы одновременно учитывал динамику процесса в виде серий изображений и известные технологические параметры. Обработка серий кадров представляет собой отдельную проблему, поскольку не все кадры в серии могут быть одинаково информативны.

В данной работе предложена гибридная нейросетевая архитектура, которая объединяет предобученный CNN-энкодер, используемый для извлечения признаков из кадров, и многослойный перцептрон, используемый для обработки табличных данных. Задача прогнозирования по серии кадров формализована в рамках парадигмы Multiple Instance Learning (MIL, обучение на множестве объектов) [Carbonneau et al., 2018]. В этой парадигме каждый отдельный эксперимент по газопламенному напылению (идентифицируемый exp_id) рассматривается как «мешок» (bag) изображений, которому присваивается единая метка (R_a , m). Для агрегации признаков из «мешка» кадров используется механизм внимания (Attention) [Vaswani et al., 2017]. Это позволяет модели адаптивно взвешивать вклад каждого кадра, выделяя наиболее информативные моменты процесса (например, фазу стабильного горения или, наоборот, аномалии) и игнорируя «шумные» или нерелевантные изображения.

В рамках исследования была проведена экспериментальная проверка модели на реальных данных. Продемонстрирована возможность анализа весов внимания для интерпретации решений модели, что открывает путь к лучшему пониманию взаимосвязей между визуальными характеристиками пламени и качеством покрытия. Предложенный подход позволяет создать основу для системы поддержки принятия решений, способной в реальном времени давать оператору или автоматизированной системе управления обратную связь о качестве формируемого покрытия.

2. Анализ существующих подходов к проблеме

Процесс газопламенного напыления основан на нагреве и ускорении порошковых частиц потоком раскаленных газов с последующим их осаждением на поверхность заготовки. В результате формируется покрытие с требуемыми физико-механическими свойствами — прочностью сцепления, износостойкостью, плотностью и шероховатостью. Управление этими свойствами требует точного соблюдения технологических режимов, включающих давление воздуха и горючего газа, соотношение компонентов, расстояние от сопла до поверхности (*stand-off distance*, SOD), а также скорость перемещения факела и подаваемого материала [Кузнецов, Гончаренко, 2013; Нагараджа и др., 2020; Кузнецов и др., 2025].

В зарубежной литературе вопросам структуры и свойств покрытий, полученных методом высокоскоростного газопламенного напыления (HVOF), посвящен широкий круг исследований. Показано, что изменение состава порошка, расстояния напыления, отношения «кислород/топливо» и расхода материала позволяет целенаправленно управлять пористостью, фазовым составом, микротвердостью, износостойкостью и коррозионной стойкостью покрытий на основе карбидных и никельсодержащих систем [Abu-Warda et al., 2019; Javed et al., 2021; Rajendran et al., 2022; Anusha et al., 2023; Lingappa et al., 2024]. Обзорные и экспериментальные работы последних лет подчеркивают, что HVOF остается одним из ключевых методов получения износостойких и коррозионностойких покрытий в энергетике, машиностроении и морской технике, а одной из актуальных задач является оптимизация режимов напыления для обеспечения требуемого комплекса эксплуатационных характеристик.

Качество покрытия формируется как результат сложных нелинейных взаимодействий тепловых, аэродинамических и материаловедческих факторов. Теоретическое моделирование таких процессов традиционно базируется на системах дифференциальных уравнений тепломассопереноса и численных методов расчета динамики частиц [Воронцовский и др., 2011]. Однако даже при применении вычислительных моделей, основанных на методах конечных элементов или конечных объемов, точность прогнозов оказывается ограниченной из-за высокой чувствительности к начальному состоянию и неопределенности входных параметров. Кроме того, проведение таких расчетов требует значительных вычислительных ресурсов и не подходит для оперативного анализа в условиях реального производства.

В этой связи в последние годы наблюдается рост интереса к эмпирическим и интеллектуальным методам прогнозирования, использующим экспериментальные данные. Наиболее простые из них — регрессионные модели и нейронные сети прямого распространения (MLP), обучаемые на табличных данных [Kim et al., 2023]. В ряде работ подобные модели используются непосредственно для анализа процессов HVOF-напыления и прогнозирования свойств покрытий [Liu et al., 2019; Liu et al., 2021; Gui et al., 2023; Rannetbauer et al., 2024]. Такие подходы показали удовлетворительные результаты при небольшом числе параметров, но их обобщающая способность ограничена: они не учитывают динамику факела и пространственную неоднородность распределения частиц.

С развитием методов компьютерного зрения возникла возможность анализировать визуальную информацию о факеле напыления [Горелов и др., 2025] и распределении температуры

в зоне взаимодействия. Исследователи отмечают, что интенсивность и форма факела коррелируют с характеристиками получаемого покрытия, а значит, изображения могут использоваться как источник диагностических признаков. Для этой цели применяются сверточные нейронные сети, способные извлекать информативные пространственные признаки из изображений и видеопоследовательностей [Горелов и др., 2025]. Однако такие модели требуют больших объемов размеченных данных и не всегда устойчивы к изменениям условий освещения и фона.

Дополнительной проблемой является многокадровая природа процесса. При газопламенном напылении каждый эксперимент представляет собой серию кадров, характеризующих развитие факела во времени. Классические CNN-архитектуры, рассчитанные на одиночные изображения, не учитывают вариации между кадрами и не могут выявить наиболее значимые фазы процесса. Для решения этой задачи применяются подходы на основе Multiple Instance Learning [Carbonneau et al., 2018], где последовательность кадров рассматривается как «мешок» (bag) экземпляров, а модель учится выделять ключевые кадры, оказывающие наибольшее влияние на выходные характеристики. Внедрение механизма внимания в контексте MIL [Ilse et al., 2018; Vaswani et al., 2017] позволило существенно повысить интерпретируемость моделей: веса внимания показывают вклад каждого кадра в итоговый прогноз.

Современные исследования в области гибридных архитектур демонстрируют эффективность комбинации сверточных сетей для извлечения визуальных признаков и полносвязных слоев для анализа параметрических данных. Такой подход обеспечивает синтез пространственной информации с числовыми технологическими параметрами, создавая более полное представление о состоянии процесса. Подобные модели успешно применяются в смежных областях — неразрушающем контроле, прогнозировании свойств сплавов, анализе структуры сварных швов и др. [Gui et al., 2023].

В контексте газопламенного напыления подобная интеграция особенно важна: визуальные характеристики факела отражают динамику распыления, а технологические параметры задают энергетические и геометрические условия формирования покрытия. Следовательно, комбинированное использование этих двух источников данных позволяет повысить точность прогнозирования характеристик напыленного слоя.

Дополнительным аспектом, обеспечивающим практическую применимость, является возможность интерактивного обучения и визуализации модели. Современные программные платформы, такие как библиотека Streamlit (<https://github.com/streamlit>), позволяют создавать приложения, обеспечивающие исследователю удобный интерфейс для настройки параметров обучения, отслеживания метрик и интерпретации результатов. Интеграция таких инструментов с библиотеками PyTorch [Paszke et al., 2019], timm и ONNX делает возможным переход от экспериментальной разработки к прикладным решениям, пригодным для внедрения в промышленные системы контроля качества.

Таким образом, анализ существующих подходов показывает, что

- классические физические и статистические модели недостаточно точны для описания реальных процессов газопламенного напыления;
- применение сверточных сетей для анализа изображений требует дополнения табличными признаками для учета параметров процесса;
- архитектуры нейронных сетей с механизмом внимания (Attention MIL) обеспечивают интерпретируемость и устойчивость моделей при анализе видеопоследовательностей;
- разработка гибридной модели, объединяющей визуальные и параметрические данные, представляет собой перспективное направление для решения задачи прогнозирования характеристик покрытий.

На основании этих положений в работе предложено решение, основанное на гибридной нейронной сети с модулем внимания, реализованной в виде интерактивного программного комплекса для обучения, валидации и прогнозирования параметров покрытия при газопламенном напылении.

3. Постановка задачи

Процесс газопламенного напыления представляет собой сложную многопараметрическую систему, в которой итоговые характеристики покрытия зависят от множества факторов, включая давление воздуха и горючего газа, расстояние от сопла до поверхности, температуру пламени, скорость частиц и особенности взаимодействия распыляемого материала с подложкой. В рамках данной работы задача формулируется как прогнозирование ключевых выходных параметров покрытия — шероховатости поверхности (R_a) и массы (или толщины) нанесенного слоя (m) — на основании сочетания визуальных и технологических данных, регистрируемых в ходе газопламенного напыления.

Каждый эксперимент газопламенного напыления характеризуется совокупностью данных двух типов.

1. Визуальные данные — серия кадров, снятых в процессе формирования покрытия (видеопоследовательность факела напыления). Эти изображения отражают форму, интенсивность и структуру факела, которые тесно связаны с температурно-динамическими характеристиками процесса.

2. Параметрические данные — технологические параметры, задающие режим напыления:

$$X_{tab} = (P_{air}, P_{prop}, SOD),$$

где P_{air} — давление воздуха, P_{prop} — давление пропана, SOD (stand-off distance) — расстояние от сопла до поверхности заготовки.

Пусть видеопоследовательность, соответствующая одному эксперименту, состоит из T кадров:

$$X_{img} = \{I_1, I_2, \dots, I_T\}, \quad I_t \in \mathbb{R}^{H \times W \times 3},$$

где H и W — высота и ширина изображения соответственно.

Для каждого эксперимента известен вектор выходных характеристик:

$$Y = (R_a, m).$$

Таким образом, требуется построить функцию прогнозирования:

$$f: (X_{img}, X_{tab}) \rightarrow Y,$$

которая по визуальной и параметрической информации способна оценить характеристики покрытия.

С практической точки зрения задача сводится к обучению параметризованной модели f_θ , где θ — набор весов нейронной сети, минимизирующей функционал потерь:

$$L(\theta) = \frac{1}{N} \sum_{i=1}^N \ell(f_\theta(X_{img}^{(i)}, X_{tab}^{(i)}), Y^{(i)}),$$

где ℓ — функция ошибки (в работе используется Huber Loss, обеспечивающая устойчивость к выбросам), а N — число экспериментов в обучающей выборке.

Особенностью рассматриваемых данных является наличие последовательности кадров T_i для каждого из экспериментов по газопламенному напылению. Для корректной обработки таких данных применяется подход Multiple Instance Learning, в рамках которого каждый эксперимент рассматривается как «мешок» (bag) экземпляров — изображений $\{I_i\}$. Целевая переменная Y при этом известна только для мешка в целом, а не для отдельных кадров. Эта ситуация требует использования специального механизма агрегации признаков, извлекаемых из отдельных кадров, обеспечивающего дифференцируемое объединение информации по кадрам.

Для этого используется механизм внимания, который предполагает вычисление весов значимости отдельных кадров:

$$\alpha_t = \frac{\exp(g(h_t))}{\sum_{k=1}^T \exp(g(h_k))}, \quad \sum_{t=1}^T \alpha_t = 1,$$

где h_t — вектор признаков, извлеченных CNN-энкодером из кадра I_t , а $g(h_t)$ — параметрическая функция, обучаемая совместно с моделью. Итоговое представление всего мешка вычисляется как взвешенная сумма:

$$H = \sum_{t=1}^T \alpha_t h_t.$$

Вектор H отражает обобщенное представление визуальной информации, наиболее релевантной для прогнозирования свойств покрытия.

Для учета влияния технологических параметров вводится вектор табличных признаков X_{tab} , который объединяется с визуальным представлением H в едином пространстве признаков:

$$Z = \text{concat}(H, X_{tab}).$$

Далее вектор Z подается в серию полносвязных слоев (fusion-блок), на выходе которых формируются прогнозируемые значения шероховатости и массы слоя:

$$(\widehat{R}_a, \widehat{m}) = f_{\theta}(X_{img}, X_{tab}).$$

Таким образом, математическая постановка задачи предусматривает:

- извлечение признаков из последовательностей изображений при помощи сверточного энкодера;
- вычисление весов внимания, определяющих вклад каждого кадра;
- объединение визуальных и табличных признаков;
- прогноз выходных характеристик на основе регрессионного выходного слоя сети.

Данные для обучения формируются из экспериментальных записей, каждая из которых содержит путь к изображениям и значения параметров процесса. В таблицах обучающего датасета для каждого опыта присутствуют поля:

$$\text{exp}_{id}, \quad \text{image}_{path}, \quad P_{air}, \quad P_{prop}, \quad SOD, \quad m, \quad R_a,$$

где exp_{id} — идентификатор эксперимента (серии кадров), image_{path} — относительный путь к изображению кадра, P_{air} — давление воздуха, P_{prop} — давление пропана, SOD — расстояние от сопла до поверхности, m — масса напыленного слоя, R_a — шероховатость поверхности покрытия.

Таким образом, предложенная модель сочетает в себе элементы компьютерного зрения, обучения искусственных нейронных сетей и регрессионного анализа. Решение рассматриваемой

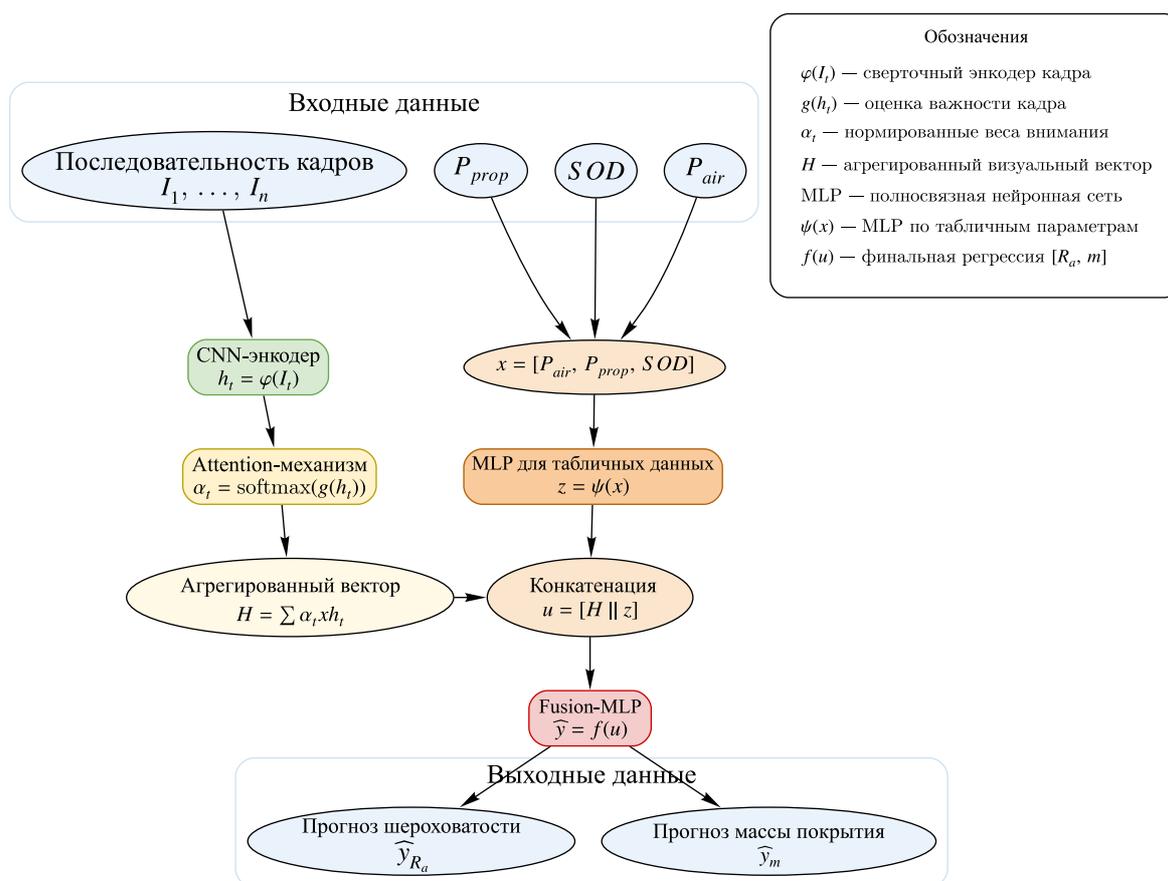


Рис. 1. Функциональная схема гибридной нейронной сети

задачи позволяет автоматизировать прогнозирование параметров качества покрытия и создать основу для интеллектуальных систем адаптивного управления процессом газопламенного напыления.

На рис. 1 представлена функциональная схема рассмотренного выше решения.

4. Архитектура гибридной нейронной сети

Для решения задачи прогнозирования характеристик покрытия при газопламенном напылении разработана программная реализация гибридной нейронной сети, объединяющая возможности сверточных энкодеров изображений, механизм внимания и обработку параметрических данных технологического процесса. Предлагаемая архитектура предназначена для одновременной обработки двух типов информации — визуальной (серии кадров процесса напыления) и табличной (параметры режима), что обеспечивает комплексное представление состояния системы и позволяет повысить точность прогнозов.

Система построена по модульному принципу и включает две взаимосвязанные подсистемы:

- 1) вычислительное ядро (модуль `pipeline_b.py`), реализующее модели, датасеты и процедуры обучения;
- 2) интерактивный управляющий интерфейс (модуль `app.py`), обеспечивающий визуализацию и взаимодействие пользователя с моделью.

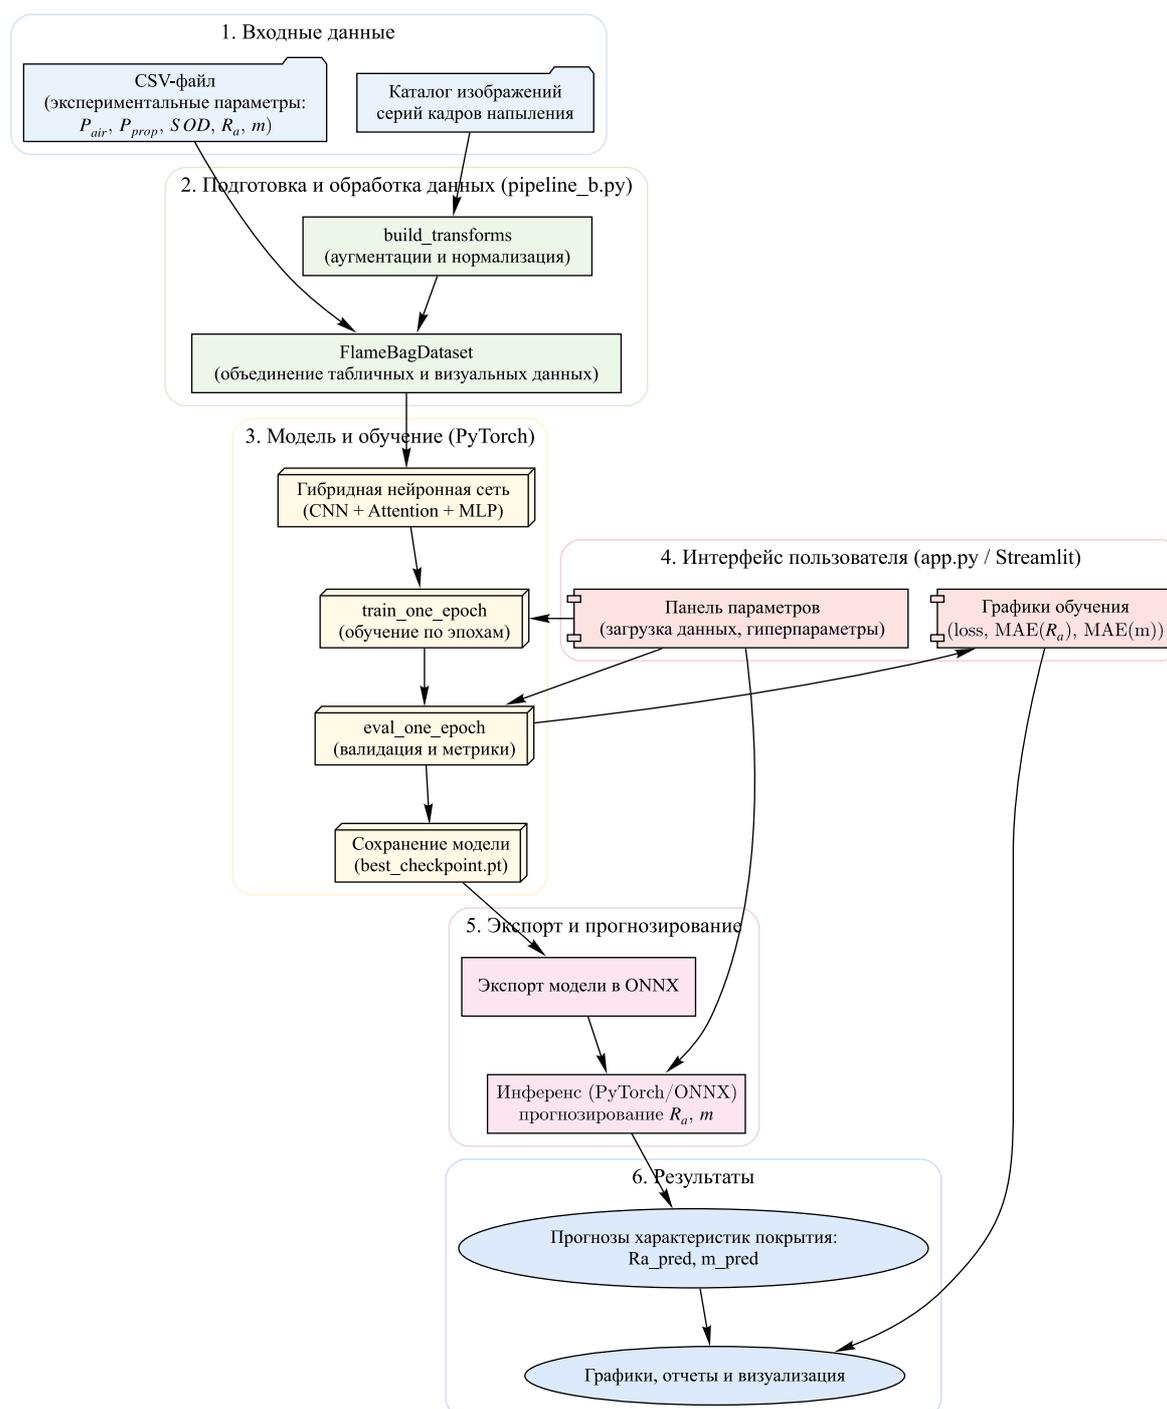


Рис. 2. Общая структура системы

Такое разделение обеспечивает гибкость разработки: вычислительное ядро может использоваться автономно в исследовательских скриптах, а графическая оболочка — служить инструментом для визуального анализа и демонстрации результатов. Общая структура системы представлена на рис. 2.

Приложение реализовано на языке Python 3 с использованием следующих библиотек:

- PyTorch — основная платформа для обучения и инференса нейронных сетей;

- timm — набор предобученных сверточных архитектур;
- Streamlit — инструмент для быстрого создания интерактивных научных приложений;
- Altair, Pandas, NumPy — анализ и визуализация данных;
- scikit-learn — стандартизация признаков и кросс-валидация;
- ONNX Runtime — выполнение экспортированных моделей.

Код приложения полностью модульный и легко расширяемый: возможно добавление новых параметров процесса, альтернативных архитектур CNN или механизмов агрегации (например, LSTM или Transformer).

Программная реализация системы включает в себя несколько функциональных подсистем:

- CNN-энкодер изображений — модуль извлечения признаков из каждого кадра;
- механизм внимания (Attention MIL) — агрегирование признаков по последовательности кадров;
- fusion-блок — объединение визуальных и табличных признаков;
- выходной слой содержит два выхода, формирующих регрессионный прогноз выходных характеристик покрытия: шероховатости и массы напыления.

В качестве энкодера изображений используется модель из библиотеки timm (PyTorch Image Models), что обеспечивает гибкость выбора архитектуры. В библиотеке доступен для использования большой набор предобученных моделей распознавания изображений, включая EfficientNet [Tan, Le, 2019] (tf_efficientnet_b0_ns, b2_ns, b3a), ResNet (resnet18, resnet34), ConvNeXt Tiny и другие модели.

Энкодер создается в конфигурации num_classes=0, global_pool=«avg», то есть применяется для извлечения признаков без классификационного выходного слоя.

Одним из компонентов приложения является модуль визуализации внимания для агрегирования информации по кадрам. Функция make_attention_montage создает монтаж наиболее значимых кадров (топ-кадры по значениям) с наложенными значениями α_i — весов внимания. Визуализация выполняется с помощью библиотеки Pillow: кадры нормализуются, располагаются в сетке, а значения Attention отображаются цветом и подписью. Это позволяет пользователю не только видеть прогноз, но и понимать, какие кадры оказали на него наибольшее влияние, что повышает интерпретируемость результатов. При работе в режиме прогнозирования (демонстрационного инференса) эта визуализация доступна для любого нового эксперимента. Данный режим позволяет инженеру-технологу оценить качество модели, протестировать ее на новых сериях изображений газопламенного напыления и использовать систему в качестве инструмента контроля и диагностики качества покрытия.

Таким образом, предложенная гибридная архитектура нейронной сети сочетает вычислительную эффективность современных CNN-энкодеров с интерпретируемостью и гибкостью MIL-механизмов внимания. Это делает ее перспективной основой для интеллектуальных систем мониторинга и прогнозирования технологических процессов газопламенного напыления покрытий.

После завершения обучения система предоставляет возможность экспорта модели в формат ONNX (Open Neural Network Exchange), что обеспечивает совместимость с другими программными средами и позволяет выполнять инференс на промышленных системах в реальном времени.

5. Экспериментальные исследования

Экспериментальные исследования проводились с целью оценки эффективности предложенной гибридной нейронной сети и реализованной программной системы при решении задачи прогнозирования характеристик покрытий, формируемых методом газопламенного напыления. Особое внимание уделялось влиянию архитектуры модели, параметров обучения и структуры данных на точность предсказаний и устойчивость модели к вариациям технологических условий.

Для обучения и валидации использовались данные, полученные в лабораторных экспериментах по газопламенному напылению. Каждый эксперимент включал от 8 до 16 последовательных кадров, отражающих динамику процесса. Эти кадры образуют *bag* в терминах *Multiple Instance Learning*.

Предварительная обработка табличных данных заключалась в масштабировании с использованием *StandardScaler* из пакета *scikit-learn*. Для обучающей выборки изображений применялись набор аугментаций (*ColorJitter*, *GaussianBlur*) и нормализация (*ImageNet mean/std*).

Для выявления признаков изображений применялась предобученная модель *efficientnet_b3a*, которая была отобрана как показавшая лучшую точность результатов обучения в сравнении с другими моделями из библиотеки *timm*.

Всего в выборке использовались десятки экспериментальных серий, охватывающих диапазоны параметров:

$$\begin{aligned}P_{air} &= 0,15\text{--}0,25 \text{ МПа}, \\P_{prop} &= 0,06\text{--}0,12 \text{ МПа}, \\SOD &= 50\text{--}150 \text{ мм}, \\R_a &= 0,05\text{--}0,3 \text{ мм}, \\m &= 15\text{--}25 \text{ г}.\end{aligned}$$

Обучение выполнялось в интерактивной среде *Streamlit*, что позволяло контролировать процесс в реальном времени и наблюдать за метриками качества. Модель обучалась с использованием *GroupKFold*-кросс-валидации для уменьшения зависимости от случайного разбиения выборки и использования всех данных в обучении.

Для количественной оценки результатов применялась стандартная регрессионная метрика *MAE* (средняя абсолютная ошибка). Как интегральный показатель качества рассматривалась сумма *MAE* по двум прогнозируемым величинам:

$$\text{Score} = \text{MAE}(R_a) + \text{MAE}(m).$$

В ходе экспериментов модель демонстрировала устойчивое снижение функции потерь на обучающей выборке и достижение лучших метрик на валидации после 20–25 эпох.

Для оценки преимуществ гибридного подхода было выполнено сравнение предложенного решения с несколькими альтернативными вариациями используемой модели. Были исследованы следующие альтернативные модели:

- 1) аналогичная гибридная модель, в которой механизм *Attention* заменен на простое усреднение (*Mean Pooling*) векторов признаков изображений;
- 2) модель с механизмом *Attention*, в которой используются только «мешки» изображений без табличных данных;
- 3) модель, которая использует только табличные данные без изображений.

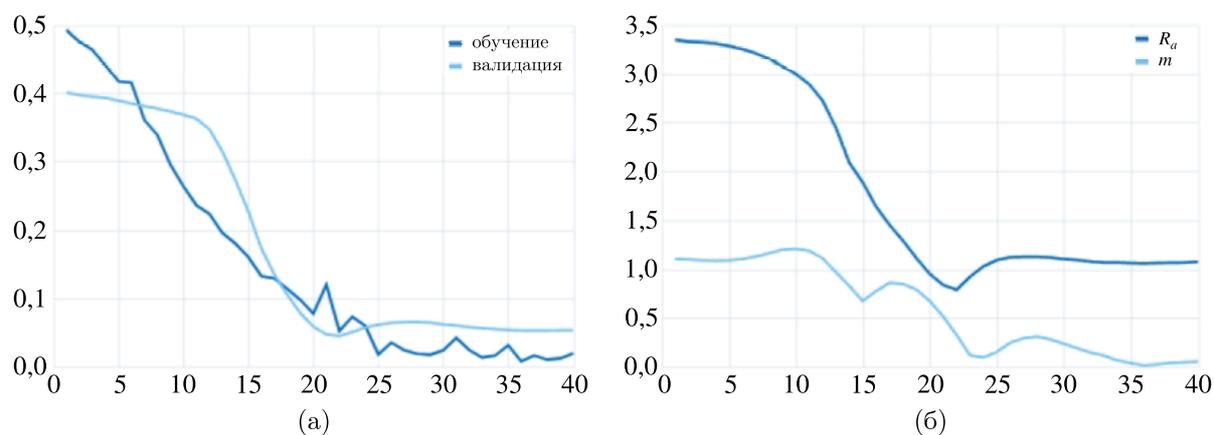


Рис. 3. Графики функции потерь при обучении и валидации (а); оценки MAE для шероховатости и массы при обучении основной гибридной модели (б)

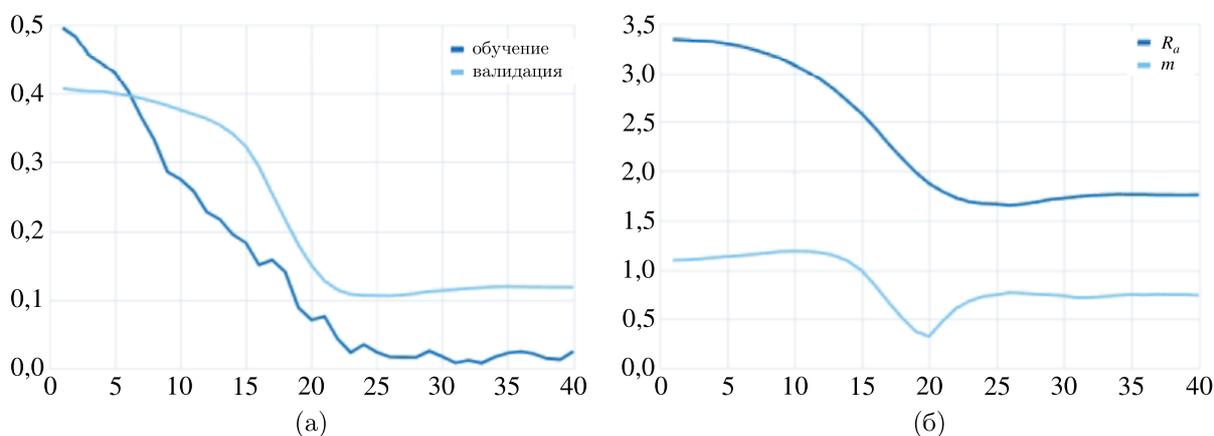


Рис. 4. Графики функции потерь при обучении и валидации (а); оценки MAE для шероховатости и массы при обучении гибридной модели без механизма внимания (б)

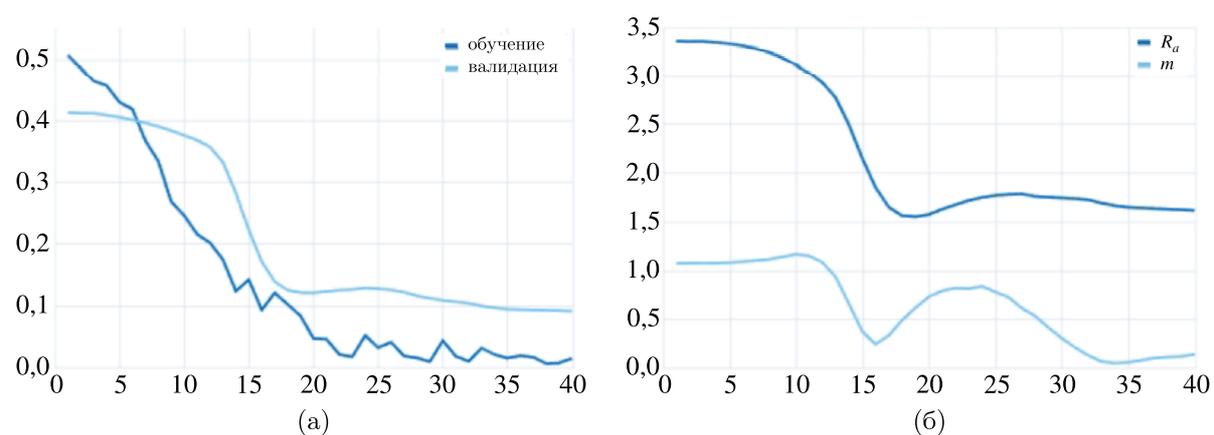


Рис. 5. Графики функции потерь при обучении и валидации (а); оценки MAE для шероховатости и массы при обучении модели с механизмом внимания без табличных данных (б)

На рис. 3–6 представлены графики обучения рассмотренных моделей. Слева на рисунках расположены графики функции потерь при обучении и валидации, справа — оценки MAE для

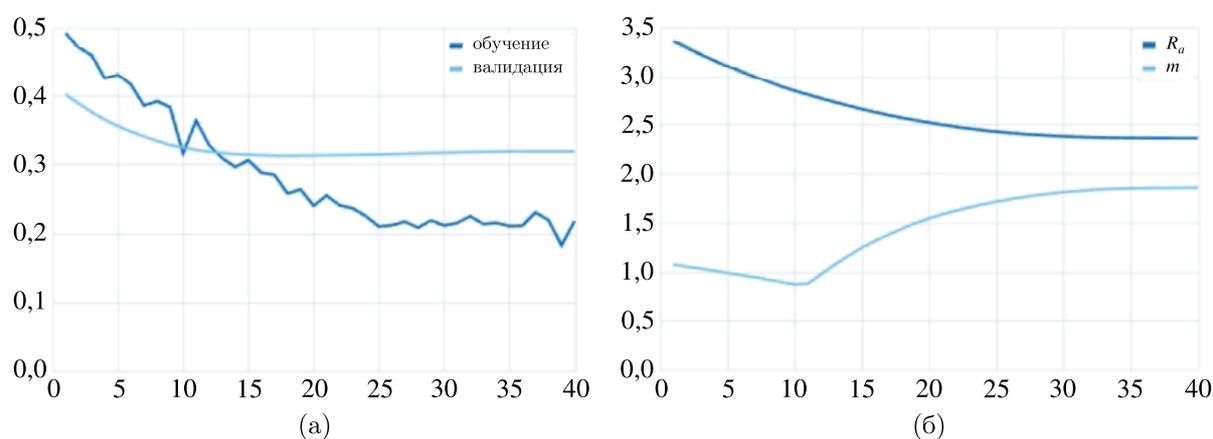


Рис. 6. Графики функции потерь при обучении и валидации (а); оценки MAE для шероховатости и массы при обучении модели только на табличных данных (б)

шероховатости и массы. Для массы оценка MAE формируется в граммах, для шероховатости — в сотых долях миллиметра.

В таблице 1 представлены результаты точности обучения исследованных моделей.

Таблица 1. Показатели моделей

№ п/п	Тип модели	Используемые признаки	Механизм агрегации	Сумма MAE	Ошибка %
1	CNN + Tab + Attention	Изображения + параметры	Внимание	1,041	3,0
2	CNN-avg + Tab	Изображения + параметры	Усреднение	2,198	6,3
3	CNN + Attention	Только изображения	Внимание	1,701	4,9
4	Tab	Только параметры	—	3,681	10,5

Полученные результаты подтверждают, что введение механизма внимания и объединение визуальных и технологических признаков приводят к значительному снижению ошибок прогнозирования и повышению стабильности модели.

Наиболее показательное сравнение вариантов 1 и 2. Обе модели являются гибридными, но замена простого усреднения (AvgPool) на механизм внимания (Attention) приводит к самому значительному скачку точности. Это подтверждает гипотезу о том, что не все кадры в процессе одинаково информативны, и способность модели адаптивно взвешивать их вклад является ключом к более точному прогнозу. Анализ результатов показывает, что модель научилась присваивать наибольшие веса (например, $\alpha = 0,25$) кадрам, на которых факел пламени имеет четкую, стабильную морфологию, характерную для установившегося режима горения. Кадры с нечетким изображением или снятые в переходных режимах получают меньшие веса.

Худший результат варианта 4 показывает, что одних лишь табличных данных недостаточно для точного прогноза результатов напыления. Наиболее точный результат позволяет получить только совместное использование визуальных и табличных данных.

Производительность предложенной гибридной нейронной сети оценивалась на аппаратной базе, включающей компьютер с процессором AMD Ryzen 9 (3,8 ГГц, оперативная память — 128 Гб) и видеоадаптера NVIDIA GeForce 4060 Ti, 16 Гб. Время вычисления прогноза параметров напыления с использованием обученной модели составляло в среднем около 100 миллисекунд, что позволяет обновлять прогноз параметров несколько раз в секунду в составе системы автоматизированного контроля качества покрытия в реальном времени.

6. Заключение

В настоящей работе рассмотрена задача прогнозирования ключевых характеристик качества покрытия при газопламенном напылении на основе мультимодальных данных.

Для решения поставленной задачи была разработана и обучена гибридная нейросетевая архитектура, способная эффективно объединять статические технологические параметры и динамическую визуальную информацию (серии кадров пламени). Экспериментально подтверждено, что гибридный подход обеспечивает более высокую точность прогнозирования по сравнению с моделями, использующими только одну модальность (только таблицы или только изображения). Подтверждена эффективность парадигмы Multiple Instance Learning (MIL) с механизмом внимания (Attention). Модель, использующая Attention, показала себя существенно лучше, чем модель с простым усреднением (AvgPool), что доказывает важность адаптивного взвешивания информативности кадров в процессе обучения.

Практическая значимость исследования состоит в создании задела для разработки промышленных систем неразрушающего контроля качества «на лету». Разработанный программный прототип и возможность экспорта модели в формат ONNX демонстрируют возможность интеграции модели в существующие системы управления технологическим процессом на производстве.

Несмотря на положительные результаты, необходимо признать ограничения работы. Модель обучалась на конкретном наборе данных, ограниченном определенным диапазоном материалов, конфигураций оборудования и режимов напыления. Ее обобщающая способность на принципиально иные условия требует дополнительной проверки.

Текущее исследование ограничено объемом и разнообразием доступного набора данных. Дальнейшая работа должна быть направлена на расширение датасета (включение разных материалов и более широких диапазонов параметров). Ключевым направлением развития является оптимизация модели для работы в реальном времени. Конечной целью является создание замкнутой системы управления, в которой прогнозы модели будут использоваться не только для мониторинга, но и для автоматической корректировки технологических параметров с целью достижения заданных показателей в режиме реального времени.

Список литературы (References)

- Воронецкий А. В., Колпаков В. И., Филimonov Л. А., Ходыкин А. А.* Математическое моделирование процесса формирования покрытий при сверхзвуковом газопламенном напылении // Вестник Московского государственного технического университета им. Н. Э. Баумана. Сер. Машиностроение. — 2011. — № 3 (84). — С. 30–37.
- Voroneckij A. V., Kolpakov V. I., Filimonov L. A., Hodykin A. A.* Matematicheskoe modelirovanie processa formirovanija pokrytij pri sverhzvukovom gazoplazmennom napylenii [Mathematical modeling of the coating formation process during supersonic flame spraying] // Vestnik Moskovskogo gosudarstvennogo tehničeskogo universiteta im. N. E. Baumana. Ser. Mashinostroenie. — 2011. — No. 3 (84). — P. 30–37 (in Russian).
- Горелов М. А., Бруттан Ю. В., Никифоров И. П., Антонов И. В., Яковлев Ю. С.* Комплексный анализ пламени газопламенного напыления с использованием методов компьютерного зрения и статистического моделирования // Научно-технический вестник Поволжья. — 2025. — № 11. — С. 82–86.
- Gorelov M. A., Bruttan Ju. V., Nikiforov I. P., Antonov I. V., Iakovlev Ju. S.* Kompleksnyj analiz plameni gazoplazmennogo napylenija s ispol'zovaniem metodov komp'juternogo zrenija i statističeskogo modelirovanija [Comprehensive analysis of the gas-flame spray plume using computer vision and statistical modeling] // Nauchno-tehničeskij vestnik Povolzh'ja. — 2025. — No. 11. — P. 82–86 (in Russian).
- Елагина О. Ю., Прыгаев А. К., Волков И. В.* Эксплуатационные характеристики покрытий, полученных методом высокоскоростного газопламенного напыления // Перспективные материалы. — 2020. — № 5. — С. 81–88.
- Elagina O. Ju., Prygaev A. K., Volkov I. V.* Ekspluatacionnye harakteristiki pokrytij, poluchennyh metodom vysokoskorostnogo gazoplazmennogo napylenija [Operational characteristics of coatings obtained by high-speed flame spraying] // Perspektivnye materialy. — 2020. — No. 5. — P. 81–88 (in Russian).

- Клименов В. А., Ковалевская Ж. Г., Зайцев К. В., Толмачев А. И.* Исследование адгезии покрытий, полученных высокоскоростным газопламенным напылением // Известия Томского политехнического университета. — 2007. — Т. 310, № 3. — С. 57–61.
Klimenov V. A., Kovalevskaja Zh. G., Zajcev K. V., Tolmachev A. I. Issledovanie adgezii pokrytij, poluchennyh vysokoskorostnym gazoplammennym napyleniem [Investigation of the adhesion of coatings obtained by high-speed flame spraying] // Izvestiya Tomskogo politekhnicheskogo universiteta. — 2007. — Vol. 310, No. 3. — P. 57–61 (in Russian).
- Колубаев А. В., Сизова О. В.* Структура и свойства покрытий, полученных способом газотермического напыления // Известия вузов. Черная металлургия. — 2024. — Т. 67, № 6. — С. 710–715.
Kolubaev A. V., Sizova O. V. Struktura i svojstva pokrytij, poluchennyh sposobom gazotermicheskogo napylenija [Structure and properties of coatings obtained by gas thermal spraying] // Izvestija vuzov. Chernaja metallurgija. — 2024. — Vol. 67, No. 6. — P. 710–715 (in Russian).
- Кузнецов Ю. А., Гончаренко В. В.* Технологии высокоскоростного напыления // Техника и оборудование для села. — 2013. — № 8. — С. 40–45.
Kuznecov Ju. A., Goncharenko V. V. Tehnologii vysokoskorostnogo napylenija [High-speed spraying technology] // Tehnika i oborudovanie dlja sela. — 2013. — No. 8. — P. 40–45 (in Russian).
- Кузнецов Ю. А., Добычин А. В., Яковлев Д. Д., Грибакин А. А., Пичев В. С., Кравченко И. Н.* Исследование структуры и свойств покрытий, полученных методом сверхзвукового газопламенного напыления // Проблемы машиностроения и надежности машин. — 2025. — № 5. — С. 83–92.
Kuznecov Ju. A., Dobychin A. V., Jakovlev D. D., Gribakin A. A., Pichev V. S., Kravchenko I. N. Issledovanie struktury i svojstv pokrytij, poluchennyh metodom sverhzvukovogo gazoplammennogo napylenija [Investigation of the structure and properties of coatings obtained by supersonic flame spraying] // Problemy mashinostroenija i nadezhnosti mashin. — 2025. — No. 5. — P. 83–92 (in Russian).
- Назараджа Ч. Р., Кумар Б. С. А., Реданна Х. Н., Рамеш М. Р., Коппад П. Г.* Микроструктура, микротвердость и характеристики окисления Ni3Ti и Ni3Ti + (CR3C2 + 20NiCr) покрытий, полученных методом высокоскоростного газопламенного напыления // Физика металлов и металловедение. — 2020. — Т. 121, № 2. — С. 179–189.
Nagaradzha Ch. R., Kumar B. S. A., Redappa H. N., Ramesh M. R., Koppad P. G. Mikrostruktura, mikrotverdost' i harakteristiki okislenija Ni3Ti i Ni3Ti + (CR3C2 + 20NiCr) pokrytij, poluchennyh metodom vysokoskorostnogo gazoplammennogo napylenija [Microstructure, microhardness, and oxidation characteristics of Ni3Ti and Ni3Ti + (CR3C2 + 20NiCr) coatings obtained by high-speed flame deposition] // Fizika metallov i metallovedenie. — 2020. — Vol. 121, No. 2. — P. 179–189 (in Russian).
- Abu-Warda N., López A. J., López M. D., Utrilla M. V.* High temperature corrosion and wear behavior of HVOF-sprayed coating of Al₂O₃-NiAl on AISI 304 stainless steel // Surface and Coatings Technology. — 2019. — Vol. 359. — P. 35–46.
- Anusha K., Routara B. C., Guha S.* A review on High-Velocity Oxy-Fuel (HVOF) coating technique // Journal of The Institution of Engineers (India). Ser. D. — 2023. — Vol. 104. — P. 831–848.
- Carbonneau M. A., Cheplygina V., Granger E., Gagnon G.* Multiple instance learning: A survey of problem characteristics and applications // Pattern Recognition. — 2018. — Vol. 77. — P. 329–353.
- Gui L., Wang B., Cai R., Yu Z., Liu M., Zhu Q., Xie Y., Liu S., Killinger A.* Prediction of in-flight particle properties and mechanical performances of HVOF-sprayed NiCr-Cr₃C₂ coatings based on a hierarchical neural network // Materials. — 2023. — Vol. 16, No. 18. — P. 6279.
- Ilse M., Tomczak J. M., Welling M.* Attention-based deep multiple instance learning // Proceedings of the 35th International Conference on Machine Learning (ICML). — PMLR, 2018. — Vol. 80. — P. 2127–2136.
- Javed M. A., Ang A. S. M., Bhadra C. M., Piola R., Neil W. C., Berndt C. C., Leigh M., Howse H., Wade S. A.* Corrosion and mechanical performance of HVOF WC-based coatings with alloyed nickel binder for use in marine hydraulic applications // Surface and Coatings Technology. — 2021. — Vol. 418. — P. 127239.
- Kim I. S., Lee M. G., Jeon Y.* Review on machine learning based welding quality improvement // Int. J. Precis. Eng. Manuf.-Smart Technol. — 2023. — Vol. 1. — P. 219–226.
- Lingappa R., Mamatha T. G., Prabhuswamy M. S., Singh V., Bansal A.* High-velocity oxy-fuel and high-velocity air fuel sprayed WC-Co-Cr coatings on solution-treated 21-4N steel for slurry and

- corrosion resistance // *Journal of Electrochemical Science and Engineering*. — 2024. — Vol. 14, No. 4. — P. 499–522.
- Liu M., Wang L., Zhang H.* Prediction and analysis of high velocity oxy-fuel (HVOF) sprayed coating using artificial neural network // *Surface and Coatings Technology*. — 2019. — Vol. 378. — P. 124988.
- Liu M., Yu Z., Wu H., Liao H., Zhu Q., Deng S.* Implementation of artificial neural networks for forecasting the HVOF spray process and HVOF sprayed coatings // *Journal of Thermal Spray Technology*. — 2021. — Vol. 30, No. 5. — P. 1329–1343.
- Paszke A., Gross S., Massa F., Lerer A., Bradbury J., Chanan G., Killeen T., Lin Z., Gimelshein N., Antiga L., Desmaison A., Kopf A., Yang E., DeVito Z., Raison M., Tejani A., Chilamkurthy S., Steiner B., Fang L., Bai J., Chintala S.* PyTorch: An imperative style, high-performance deep learning library // *NIPS'19: Proceedings of the 33rd International Conference on Neural Information Processing Systems*. — Vancouver, Canada: NeurIPS, 2019. — No. 721. — P. 8026–8037.
- Pedregosa F., Varoquaux G., Gramfort A., Michel V., Thirion B., Grisel O., Blondel M., Prettenhofer P., Weiss R., Dubourg V., Vanderplas J., Passos A., Cournapeau D., Brucher M., Perrot M., Duchesnay É.* Scikit-learn: Machine learning in Python // *Journal of Machine Learning Research*. — 2011. — Vol. 12. — P. 2825–2830.
- Rajendran P.R., Duraisamy T., Chidambaram Seshadri R., Mohankumar A., Ranganathan S., Balachandran G., Murugan K., Renjith L.* Optimisation of HVOF spray process parameters to achieve minimum porosity and maximum hardness in WC-10Ni-5Cr coatings // *Coatings*. — 2022. — Vol. 12, No. 3. — P. 339.
- Rannetbauer W., Hambrock C., Hubmer S., Ramlau R.* Enhancing predictive quality in HVOF coating technology: a comparative analysis of machine learning techniques // *Procedia Computer Science, 5th International Conference on Industry 4.0 and Smart Manufacturing (ISM 2023)*. — Elsevier, 2024. — Vol. 232. — P. 1377–1387.
- Tan M., Le Q. V.* EfficientNet: rethinking model scaling for convolutional neural networks // *Proc. of ICML*. — 2019. — P. 6105–6114.
- Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A. N., Kaiser L., Polosukhin I.* Attention is all you need // *Advances in Neural Information Processing Systems 30 (NIPS 2017)*. — 2017. — P. 5998–6008.