

АВТОМАТИЗАЦИЯ И УПРАВЛЕНИЕ ТЕХНОЛОГИЧЕСКИМИ ПРОЦЕССАМИ И ПРОИЗВОДСТВАМИ

DOI: 10.21821/2309-5180-2025-17-5-756-767

EDN WBVRTH

MODEL OF AN AUTOMATED PRODUCT QUALITY CONTROL SYSTEM BASED ON NEURAL NETWORKS WITH UNSUPERVISED AND SEMI-SUPERVISED LEARNING

V. I. Milushkov

Saint Petersburg State University of Economics,
Saint Petersburg, Russian Federation

This paper addresses the problem of automated visual inspection of welded and hull structures in shipbuilding, where product reliability and operational safety critically depend on the timely and accurate detection of defects. Traditional optical inspection is limited by subjective human assessment and poor scalability, while conventional computer vision techniques suffer from data scarcity and variability of industrial environments. To overcome these limitations, an integrated mathematical framework is proposed that combines unsupervised and semi-supervised learning approaches. The architecture includes: (i) a convolutional autoencoder trained on defect-free reference samples for reconstruction-based anomaly detection; (ii) a two-stage sliding-window algorithm with dual thresholds for distinguishing weak defects from background noise under controlled false alarm rates; and (iii) a semi-supervised classification module that integrates contrastive learning with graph-based pseudo-labeling methods (k -NN and label propagation) to leverage large-scale unlabeled datasets. Joint optimization of reconstruction and discriminative representation aligns normality criteria with stable classification boundaries. Experimental validation confirms that the proposed method reliably detects both prominent and subtle defects, minimizes dependence on manual labeling, and can be seamlessly integrated into industrial quality assurance workflows. The main contribution lies in the development of a unified inspection model that fuses reconstruction-based, contrastive, and graph-driven approaches, demonstrating potential for improving reproducibility, reducing labor intensity, and enhancing the reliability of shipbuilding production.

Keywords: convolutional autoencoder, anomaly detection, sliding window, dual-threshold filtering, contrastive learning, semi-supervised classification, graph-based label propagation, shipbuilding, quality control.

For citation:

Milushkov, Vitaliy I. "Model of an automated product quality control system based on neural networks with unsupervised and semi-supervised learning." *Vestnik Gosudarstvennogo universiteta morskogo i rechnogo flota imeni admirala S. O. Makarova* 17.5 (2025): 756–767. DOI: 10.21821/2309-5180-2025-17-5-756-767.

УДК 004.8

МОДЕЛЬ АВТОМАТИЗИРОВАННОЙ СИСТЕМЫ КОНТРОЛЯ КАЧЕСТВА ИЗДЕЛИЙ НА ОСНОВЕ НЕЙРОСЕТЕЙ С НЕКОНТРОЛИРУЕМЫМ И ЧАСТИЧНО КОНТРОЛИРУЕМЫМ ОБУЧЕНИЕМ

В. И. Милушков

ФГБОУ ВО «Санкт-Петербургский государственный экономический университет»,
Санкт-Петербург, Российская Федерация

В работе рассмотрена задача автоматизации визуального контроля качества сварных и корпусных конструкций в судостроении, когда надежность продукции и безопасность эксплуатации напрямую зависят от своевременного выявления дефектов. Показано, что традиционный оптический контроль основан на субъективной оценке экспертов и плохо масштабируется, а классические методы компьютерного зре-

ния ограничены дефицитом размеченных данных и высокой вариативностью производственных условий. Для преодоления этих ограничений предложена строгая математическая модель, сочетающая механизмы неконтролируемого и частично контролируемого обучения. Архитектура включает три ключевых компонента: сверточный автоэнкодер, обучаемый на бездефектных эталонных образцах и обеспечивающий реконструктивное выявление аномалий; двухэтапную процедуру со скользящим окном и двумя порогами, позволяющую разделять слабовыраженные дефекты и шумы при контролируемом уровне ложных срабатываний; полуконтролируемую классификацию, основанную на контрастном обучении и графовых алгоритмах псевдоразметки (k -NN и распространение меток), что обеспечивает вовлечение масштабных массивов неразмеченных данных. Совместная оптимизация задач реконструкции и дискриминативного представления признаков позволяет согласовать критерии «нормальности» и устойчивой классификации. Экспериментальный анализ подтверждает, что предложенный подход позволяет выявить как ярко выраженные, так и малозаметные дефекты, снижает зависимость от ручной аннотации и легко интегрируется в цикл промышленного контроля качества. Научная новизна исследования заключается в разработке комплексной модели автоматизированного контроля качества промышленных изображений, интегрирующей реконструктивные, контрастивные и графовые методы. Практическая значимость состоит в возможности применения модели в судостроительном производстве для повышения воспроизводимости процедур контроля, снижения трудозатрат и обеспечения надежности выпускаемой продукции.

Ключевые слова: сверточный автоэнкодер, детектирование аномалий, скользящее окно, двухпороговая фильтрация, контрастное обучение, полуконтролируемая классификация, графовое распространение меток, судостроение, контроль качества.

Для цитирования:

Милушков В. И. Модель автоматизированной системы контроля качества изделий на основе нейросетей с неконтролируемым и частично контролируемым обучением / В. И. Милушков // Вестник Государственного университета морского и речного флота имени адмирала С. О. Макарова. — 2025. — Т. 17. — № 5. — С. 756–767. DOI: 10.21821/2309-5180-2025-17-5-756-767. — EDN WBVRTN.

Введение (Introduction)

Качество сварных соединений и прилегающих поверхностей корпусных элементов судостроительных изделий (далее — контролируемые объекты) напрямую определяет безопасность эксплуатации, сроки и стоимость проектов [1]. Несмотря на наличие аппаратных методов неразрушающего контроля (ультразвукового, рентгенографического и др.) [2–4], визуально-оптическая проверка именно этих объектов по-прежнему во многом выполняется вручную и зависит от субъективной оценки экспертов. Переход к автоматизированному анализу затруднен дефицитом размеченных данных по дефектам контролируемых объектов и низкой частотой появления критически важных дефектов, а также вариативностью материалов, условий съемки и производственных режимов, что снижает устойчивость алгоритмов. В результате стандартные методы компьютерного зрения требуют недоступно больших объемов аннотаций и демонстрируют слабую способность к обобщению [1, 5].

В настоящей работе предлагается строгая математическая модель системы визуального контроля, объединяющая методы обнаружения аномалий на основе реконструкции и полуконтролируемой классификации. Базовым компонентом выступает сверточный автоэнкодер (САЭ), обучаемый на бездефектных эталонных образцах. Карта расхождений между входным изображением и его реконструкцией служит источником признаков для выявления потенциальных отклонений. Чтобы повысить чувствительность к слабовыраженным дефектам при контролируемой доле ложных срабатываний, используется *двухэтапная пороговая процедура со скользящим окном*: локальная агрегация сигналов уменьшает влияние шумов и артефактов съемки, а два согласованно калибруемых порога обеспечивают устойчивое принятие решений.

Для автоматической классификации обнаруженных областей применяется *полуконтролируемый контур*: контрастное обучение формирует инвариантные представления дефектов и фоновых структур, а псевдоразметка на k -NN-графе с распространением меток позволяет последовательно вовлекать большие объемы неаннотированных производственных данных. Важной особенностью является совместная оптимизация задач реконструкции и контрастного обучения в едином функционале качества, что согласует критерии «нормальности» и дискриминативности признаков.

Целью данного исследования является разработка модели автоматизированной системы контроля качества продукции, основанной на методах искусственных нейронных сетей, сочетающих механизмы неконтролируемого и частично контролируемого обучения.

Предложенная модель включает три ключевых компонента:

- 1) *единую вычислительную архитектуру*, интегрирующую реконструктивное выявление отклонений и контрастивное обучение в общий функционал потерь;
- 2) *двухпороговую процедуру с применением скользящего окна*, обеспечивающую высокую чувствительность к слабовыраженным дефектам при сохранении низкого уровня ложноположительных срабатываний;
- 3) *графовые алгоритмы псевдоразметки* (метод ближайших соседей и алгоритмы распространения меток), позволяющие эффективно задействовать крупные массивы неразмеченных данных в условиях дефицита экспертных аннотаций.

Научная новизна исследования заключается в разработке комплексной модели автоматизированного контроля качества промышленных изображений, интегрирующей реконструктивные, контрастивные и графовые методы. Предложенная модель обеспечивает надежное выявление дефектов различной сложности, повышает эффективность анализа производственных данных при ограниченном объеме размеченных выборок и ориентирована на интеграцию в контур промышленного контроля качества судостроительного производства. Ее применение позволяет существенно сократить потребность в ручной разметке данных, повысить воспроизводимость и масштабируемость процедур контроля. Модель органично встраивается в регламент принятия решений («исправный» / «подозрительный») и соответствует современным практикам MLOps, включая калибровку порогов, ревизию эталонов и мониторинг дрейфа данных [2], [4].

Теоретическая основа модели базируется на совокупности современных математических и вычислительных подходов. В частности, используются методы оптимизации (стохастический градиентный спуск и его модификации), инструменты линейной алгебры (построение k-NN-графов, итерационные матричные алгоритмы), вероятностно-статистические методы (пороговые правила, доверительные интервалы, модели распределений для псевдоразметки), а также алгоритмы глубокого обучения для сверточных сетей и контрастного обучения. Такое сочетание обеспечивает строгую формализацию процедуры контроля и возможность ее воспроизводимой калибровки в условиях реального производственного процесса.

Методы и материалы (Methods and Materials)

На рис. 1 схематически представлена предлагаемая модель контроля качества: 1 — описание исходных данных и формирование обучающей выборки; 2 — обучение сверточного автоэнкодера на эталонных бездефектных изображениях; 3 — построение карты отклонений по разности «оригинал — реконструкция» и первичный анализ аномалий; 4 — двухэтапное детектирование с пороговой фильтрацией и скользящим окном; 5 — полуконтролируемая классификация на основе контрастных представлений и графового распространения меток; 6 — итоговая интеграция результатов детектирования и классификации для вынесения решения. Дальнейшие этапы формализуют каждый шаг, вводят используемые обозначения и функции потерь, а также описывают условия построения моделей.

Для построения моделей необходимо ввести следующие условия:

1. Наличие набора промышленных изображений высокого (или иного) разрешения, в котором выделено подмножество бездефектных образцов, служащих эталонными.
2. Обучение сверточного автоэнкодера (САЭ) производится исключительно на бездефектных образцах, что обеспечивает возможность выявления отклонений при обработке ранее не встречавшихся образцов.
3. Детектирование дефектов осуществляется посредством анализа «карты разностей», полученной сравнением исходного изображения и его реконструкции, выполненной САЭ [6, 7].
4. Для повышения точности и устойчивости детектирования дефектов используется двухэтапная методика со скользящим окном и двумя порогами (τ_1 и τ_2) [5, 8].

5. В задаче полуконтролируемой классификации наряду с аннотированными примерами привлекаются неаннотированные данные, которым при достижении достаточного уровня уверенности присваивается псевдоразметка. Данный механизм реализуется на основе методов контрастного обучения и графового распространения меток [1, 2].

6. Общая функция потерь может включать в себя вклад от задачи реконструкции (САЭ) и вклад от контрастного обучения, что позволяет одновременно усиливать способность модели к обнаружению аномалий и улучшать ее классификацию.

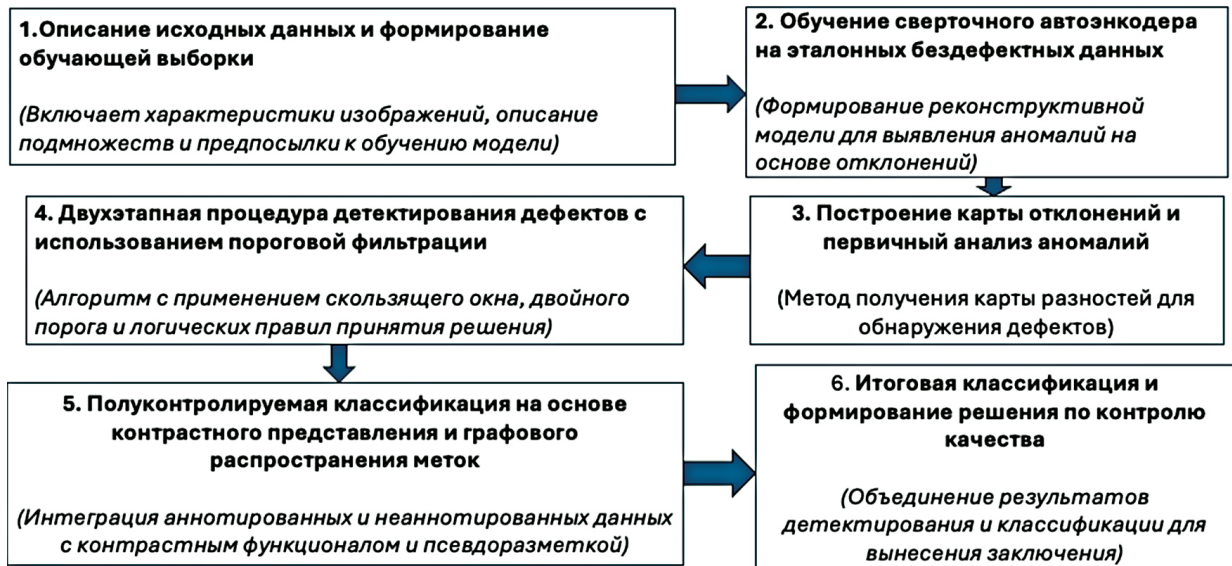


Рис. 1. Архитектура модели визуального контроля качества контролируемых объектов на основе гибридного полуконтролируемого обучения в интеллектуальной системе управления

Исходные данные и обозначения

Множество промышленных изображений. Пусть имеется совокупность M изображений:

$$X = \{x_i\}_{i=1}^M, \quad x_i \in R^{C \times H \times W}.$$

Здесь C — число каналов (например, $C = 1$ для монохромных снимков, либо $C = 3$ для цветных); H и W — высота и ширина изображения.

Подмножество «хороших» образцов для САЭ. Для обучения сверточного автоэнкодера выделяется набор «бездефектных» изображений:

$$X_{go}^{(train)} = \{x_i\}_{i=1}^N, \quad N \leq M.$$

Предполагается, что автоэнкодер будет ориентироваться на статистику данных без аномалий.

Аннотированные и неаннотированные данные для полуконтролируемого обучения

Аннотированный (размеченный) набор из m примеров:

$$D^{ann} = \{(x_i^{ann}, y_i)\}_{i=1}^m, \quad y_i \in \{1, \dots, K\}.$$

Здесь y_i может отражать либо классы дефектов, либо бинарную метку «дефект / отсутствие дефекта» (если $K = 2$).

Неаннотированный набор из n примеров:

$$D^{unann} = \{x_j^{unann}\}_{j=1}^n.$$

Цель — обучить модель классифицировать / детектировать дефекты, используя как аннотированные, так и неаннотированные данные.

Параметры сети

Пусть θ — совокупность параметров, которыми может быть

$\theta = \{\theta_{\text{enc}}, \theta_{\text{dec}}\}$ при обучении автоэнкодера;

θ может расширяться при добавлении проекционной головы, классификатора и других модулей в рамках контрастного обучения.

Сверточный автоэнкодер (САЭ) и дифференциальное отображение

Архитектура и функция потерь

Пусть $\text{Enc}_\theta(x)$ — сверточный кодировщик, отображающий вход x в более компактное векторное (или тензорное) представление, а $\text{Dec}_\theta(\cdot)$ — декодировщик, пытающийся восстановить исходное изображение. Итоговая модель:

$$\hat{x} = \text{Dec}_\theta(\text{Enc}_\theta(x)).$$

Автоэнкодер обучается на «хороших» образцах $X_{\text{go}}^{(\text{train})}$ с целью минимизировать среднеквадратичную (или иную) ошибку реконструкции:

$$L_{AE}(\theta) = \frac{1}{N} \sum_{i=1}^N \|x_i - \hat{x}_i\|^2; \quad \hat{x}_i = \text{Dec}_\theta(\text{Enc}_\theta(x_i)).$$

При качественном обучении автоэнкодер хорошо восстанавливает нормальные структуры без дефектов.

Формирование карты отклонений

На этапе применения для произвольного (возможно, дефектного) изображения x строится восстановление $\hat{x} = \text{Dec}_\theta(\text{Enc}_\theta(x))$. Затем вычисляется «карта разностей»:

$$\Delta(x) = \|x - \hat{x}\|,$$

где $\|\cdot\|$ — покомпонентное (по пикселям) абсолютное значение. Предполагается, что наличие дефекта сильно повышает $\Delta(x)$ в соответствующих местах.

Двухэтапная методика выявления дефектов со скользящим окном

Первый этап (грубый отбор дефектных изображений). Для повышения устойчивости к шумам вводится операция «скользящего окна» размера $r \times r$, проходящего по карте $\Delta(x)$. Для каждого положения окна W_k определяется средняя яркость (или сумма) пикселей Δ :

$$A(W_k) = \frac{1}{r^2} \sum_{(u,v) \in W_k} \Delta(x)[u,v].$$

Устанавливается порог τ_1 . Если существует хотя бы одно окно W_k , где $A(W_k) > \tau_1$, то первый этап фиксирует решение «дефект имеется». Если ни в одном положении окна значения не превышают τ_1 , то изображение признается «хорошим», и анализ завершается (второй этап не запускается).

Устанавливаются два порога: τ_1 — порог для грубого отбора изображений с возможными дефектами (используется на первом этапе); τ_2 — более чувствительный порог для уточняющего анализа, применяемый на втором этапе. Если существует хотя бы одно окно w , где $S_w > \tau_1$, то изображение переходит на второй этап анализа. Если по итогам второго этапа хотя бы одно значение S_w превышает порог τ_2 , то изображение классифицируется как дефектное или требующее дальнейшей проверки.

Второй этап (уточнение слабых дефектов и фильтрация шумов). В случае выявления дефекта на первом этапе ($\text{Stage1Decision} = 1$) инициируется второй этап обработки, когда могут применяться другие параметры: меньший порог $\tau_2 \leq \tau_1$, иной размер окна либо когда возможна предварительная фильтрация $\Delta(x)$ для подавления шумов.

Итоговая классификация изображения:

$$\text{Decision}(x) = \text{Stage1Decision}(x) \vee \text{Stage2Decision}(x).$$

Если (Stage2Decision=1), то изображение однозначно считается дефектным либо «подозрительным», требующим дальнейшей проверки.

Гибридный полуконтролируемый метод обучения с контрастной функцией потерь **Формирование мультивидовой партии (mini-batch)**

Пусть на каждом шаге обучения выбираются m аннотированных изображений $\{(x_i^{ann}, y_i)\}_{i=1}^m$ и n неаннотированных изображений $\{x_j^{unann}\}_{j=1}^n$.

Далее для каждого аннотированного примера

$$x_{aug0}^{ann}, x_{aug1}^{ann} \quad (\text{две сильные аугментации}),$$

а для каждого неаннотированного —

$$x_{aug0}^{unann} \quad (\text{сильная аугментация}), x_{waug1}^{unann} \quad (\text{слабая аугментация}).$$

Итого формируется набор $2m + 2n$ аугментированных образцов. Прогнав их через кодировщик Enc_θ , получим векторные представления:

$$Z = \{z_{aug0}^{ann}, z_{aug1}^{ann}, z_{aug0}^{unann}, z_{waug1}^{unann}\}.$$

Механизм псевдоразметки с порогом уверенности

Выполнение инференса (прогнозирования) для неразмеченных образцов. Обозначим $\text{infer}(z)$ — процедуру, которая возвращает

$$y_{\text{prob}}, y_{\text{pred}} = \text{infer}(z_{waug1}^{unann}),$$

где y_{prob} — вектор вероятностей по классам, $y_{\text{pred}} = \arg \max(y_{\text{prob}})$ — способ реализации $\text{infer}(\cdot)$

Графовое распространение меток (Label Propagation) k-NN с подсчетом частот соседей **Другой классификатор** (при условии, если он уже достаточно обучен).

Порог доверия (conf_thresh). Если $\max(y_{\text{prob}}) > \text{conf_thresh}$, то изображение признается «уверенно» классифицированным и его добавляют к текущей выборке как псевдоразмеченное. Пусть I_{idx} — индексный набор таких неаннотированных образцов.

Индексный набор для контрастного обучения. Общее множество «полезных» индексов:

$$I_p = \{1, 2, \dots, 2m\} \cup I_{\text{idx}}.$$

Здесь $\{1, \dots, 2m\}$ соответствуют аннотированным изображениям (по два аугментированных варианта на каждое), I_{idx} — уверенно псевдоразмеченные неаннотированные.

Контрастная функция потерь

Контрастное обучение (на основе InfoNCE и его модификаций) формулируется как задача минимизации следующего функционала [7, 9, 10]:

$$L^{\text{sup}}(\theta) = \sum_{i \in I_p} \frac{-1}{|P(i)|} \sum_{p \in P(i)} \log \frac{\exp\left(\frac{z_i \cdot z_p}{\tau}\right)}{\sum_{a \in A(i)} \exp\left(\frac{z_i \cdot z_a}{\tau}\right)},$$

где $P(i)$ — множество «положительных» индексов для z_i (аугментации того же исходного изображения или того же класса, с учетом аннотации / псевдоаннотации);

$A(i)$ — множество всех индексов в батче, кроме z_i ;

τ — «температурный» параметр (обычно 0,1–0,5).

Вследствие применения контрастной функции потерь происходит сближение векторов признаков, относящихся к одному классу (положительные пары), в пространстве эмбедингов, тогда

как векторы признаков различных классов (отрицательные пары) демонстрируют дивергентное поведение, увеличивая межклассовое расстояние.

Графовое распространение меток (Label Propagation)

Формирование (конструирование) графа на основе k -ближайших соседей (k -NN-графа)

Пусть имеются опорный (support) набор $S = \{z_i\}_{i=1}^{L_s}$ с известными метками y_i и запросный (query) набор $Q = \{z_j\}_{j=L_s+1}^{L_s+L_q}$.

Объединим все векторы в единый массив: $Z = \{z_1, \dots, z_T\}, |T| = L_s + L_q$.

Строится k -ближайший соседний граф, задаваемый матрицей $A \in R^{T \times T}$:

$$A_{ij} = \begin{cases} \text{sim}(z_i, z_j), & z_j \in KNN(z_i) \text{ и } i \neq j, \\ 0 & \text{в противном случае.} \end{cases}$$

где $\text{sim}(\cdot, \cdot)$ может быть скалярным произведением $z_i^\top z_j$ (при нормированных векторах это эквивалент косинусного сходства) с добавкой $\gamma > 1$ для усиления связи.

Для обеспечения симметризации и нормировки матрицы весов применяется приведенная последовательность операций:

$$W = \frac{1}{2}(A + A^\top), \quad D = \text{diag}(W 1_T), \quad W \leftarrow D^{-1/2} W D^{-1/2},$$

где D — диагональная матрица степеней вершин.

Итеративная процедура распространения меток (Label Propagation)

Определим матрицу меток $Y \in R^{T \times K}$:

$$Y_{ik} = \begin{cases} 1, & \text{если } i \leq L_s \text{ и } y_i = k; \\ 0 & \text{в противном случае.} \end{cases}$$

Зададим $\alpha \in (0, 1)$. Изначально $P^*(0) = Y$. Итеративно

$$P^*(\text{iter} + 1) = \alpha W P^*(\text{iter}) + (1 - \alpha) Y.$$

При $\text{iter} \rightarrow \infty$ находим

$$P = (I - \alpha W)^{-1} (1 - \alpha) Y.$$

Каждая строка P есть распределение вероятностей для соответствующего вектора. Последние L_q строк относятся к неаннотированным образцам (запросному набору Q).

Таким образом, получаем $y_{\text{prob}}, y_{\text{pred}} = \arg \max_k P_{\cdot, k}$ для неаннотированных векторов, что и используется при псевдоразметке.

Итоговое обучение и интеграция в общую модель

Обучение САЭ:

$$\min_{\theta} L_{\text{AE}}(\theta), \quad L_{\text{AE}}(\theta) = \frac{1}{N} \sum_{i=1}^N \|x_i - \text{Dec}_{\theta}(\text{Enc}_{\theta}(x_i))\|^2.$$

Модель усваивает структуру «бездефектных» данных. Для каждого изображения x строится реконструкция автоэнкодера, после чего вычисляется разностная карта $\Delta(x) = \|x - \text{Dec}_{\theta}(\text{Enc}_{\theta}(x))\|$. На ее основе применяется двухэтапная процедура со скользящим окном $r \times r$ и порогами τ_1, τ_2 , что позволяет принять итоговое бинарное решение $\text{Decision}(x)$ о принадлежности объекта к классу «исправный» или «дефектный».

Классификация дефектов выполняется в полуконтролируемой постановке и опирается на контрастный функционал потерь совместно с механизмами псевдоразметки. Для этого формируются мультимодовые партии, включающие m аннотированных и n неаннотированных изображений. К ним применяются сильные и слабые аугментации, после чего для неаннотированных образцов

выполняется псевдоразметка на основе k -NN или графового распространения меток (Label Propagation) при условии превышения доверительного порога $conf_thresh$. Контрастная функция L^{sup} оптимизируется по индексам из множества $I_p = \{1, \dots, 2m\} \cup I_{idx}$, а параметры модели θ (кодировщика, проектора и / или классификатора) обновляются для улучшения эмбедингового пространства.

Совместная минимизация функционала потерь

Рассматривается вариант, при котором результирующая функция потерь представляет собой совокупность двух составляющих: ошибки реконструкции и критерия контрастного обучения:

$$L_{total}(\theta) = \lambda_{AE} L_{AE}(\theta) + \lambda_{CTR} L^{sup}(\theta),$$

где $\lambda_{AE}, \lambda_{CTR} > 0$.

Это позволяет одновременно повышать способность модели к обнаружению аномалий (благодаря автоэнкодеру) и улучшать классификацию благодаря контрастному обучению.



Рис. 2. Модель визуального контроля качества контролируемых объектов на основе гибридного полуконтролируемого обучения в интеллектуальной системе управления

Как показано на рис. 2, предложенный конвейер состоит из шести взаимосвязанных модулей:

- 1) подготовка данных и разбиение на эталонные аннотированные и неаннотированные подмножества;
- 2) обучение сверточного автоэнкодера на бездефектных снимках с минимизацией L_{AE} ;
- 3) построение карты отклонений $\Delta(x) = |x - \hat{x}|$ для первичного выявления аномалий;
- 4) двухэтапное детектирование по средним значениям в скользящем окне $r \times r$ с порогами τ_1 и τ_2 ;
- 5) полуконтролируемая классификация на основе контрастной функции L^{sup} и распространения меток на графе;
- 6) интеграция результатов с итоговой функцией $L_{total} = \lambda_{AE} L_{AE} + \lambda_{CTR} L^{sup}$.

Направление потоков данных и расчетных величин (см. стрелки и формулы в блоках на рис. 2) отражает переход от реконструкции и анализа аномалий к уточняющей классификации и финальному решению, обеспечивая одновременное повышение чувствительности к дефектам и устойчивости классификации.

Обсуждение (Discussion)

Предложенная модель объединяет реконструктивное детектирование аномалий и полуконтролируемую классификацию в едином конвейере для задач промышленного контроля качества,

характерных для судостроения. Обучение сверточного САЭ только на эталонных данных делает модель чувствительной к отклонениям структуры изображения; разностная карта $\Delta(x) = |x - \hat{x}|$ служит универсальным индикатором дефекта независимо от его морфологии. Двухэтапная процедура со скользящим окном $r \times r$ и порогами τ_1 / τ_2 помогает разделить задачи «грубой фильтрации» и «уточнения», снижая ложные срабатывания при сохранении чувствительности к слабовыраженным дефектам (тонкие трещины, пористость, локальные включения).

Интеграция контрастного обучения (L^{sup}) с механизмом псевдоразметки по k -NN/Label Propagation позволяет использовать масштабные неаннотированные массивы без линейного роста затрат на ручную разметку. Сближение эмбедингов одного класса и разведение межклассовых расстояний стабилизирует последующую классификацию, а доверительный порог `conf_thresh` ограничивает влияние ошибочных псевдометок. Совместная оптимизация $L_{\text{total}}(\theta) = \lambda_{\text{AE}} \cdot L_{\text{AE}} + \lambda_{\text{CTR}} \cdot L^{\text{sup}}$ обеспечивает баланс между способностью «видеть» аномалии и устойчивостью финального решения [6, 8, 10].

С практической точки зрения для судостроительных производств важны три свойства предложенного подхода [2], [3]:

1. *Воспроизводимость и масштабируемость.* САЭ обучается на небольшом, тщательно сформированном эталонном наборе; дальнейшее расширение охвата достигается за счет неразмеченных данных и графового распространения меток, что хорошо согласуется с вариативными условиями съемки и редкостью критичных дефектов.

2. *Устойчивость к шумам.* Усреднение по окну и разнесение порогов снижают чувствительность к локальным артефактам съемки (блики, шум датчика) без ухудшения обнаружения протяженных или малоконтрастных дефектов [5, 11].

3. *Интеграция в цикл контроля.* Бинарное решение $\text{Decision}(x)$ обеспечивает возможность интеграции в технологический регламент: «исправный» → пропуск; «подозрительный / дефектный» → маршрутизация на экспертную проверку или повторную съемку.

Вместе с тем имеются следующие ограничения и аспекты, требующие дальнейшей доработки:

Подбор порогов и размера окна. Значения τ_1 , τ_2 и r зависят от класса контролируемых объектов, оптики и разрешения. Недонастройка приводит либо к росту ложных тревог, либо к пропуску слабых дефектов. Практически оправдана калибровка по доверительным кривым (ROC/PR) на небольшом валидационном подмножестве.

Смещение «эталона». Если в «бездефектном» наборе присутствуют систематические артефакты, САЭ начнет их реконструировать, что снизит контраст $\Delta(x)$. Это требует периодической санитарной очистки эталонного пула и мониторинга распределений ошибок реконструкции.

Зависимость псевдоразметки от топологии графа. Количество ближайших соседей k , метрика сходства и параметр α в Label Propagation влияют на стабильность y_{prob} . Чрезмерно плотные графы могут усиливать «эффект эха» (распространение неверной метки), слишком разреженные — приводить к фрагментации классов.

Вариативность аугментаций. Дисбаланс между «сильными» и «слабыми» аугментациями в мультимодовой выборке способен ухудшить консистентность эмбедингов, поэтому полезен отбор аугментаций, инвариантных к реальным технологическим вариациям (изменение освещения, небольшие сдвиги/повороты, зернистость).

Вычислительная стоимость. Построение k -NN-графа на больших пулах и итерации распространения меток требуют оптимизаций (пакетная обработка, приближенный NN-поиск, периодическая, а не непрерывная перепривязка псевдометок) [12].

Методологически важно планировать абляционные исследования: (i) только САЭ; (ii) САЭ + двухпороговая фильтрация; (iii) добавление контрастного обучения; (iv) добавление графовой псевдоразметки. Это позволит количественно оценить вклад каждого компонента и подобрать $\lambda_{\text{AE}} / \lambda_{\text{CTR}}$. Для внедрения на площадке целесообразно вести MLOps-практики: контроль дрейфа данных, периодическую перекалибровку порогов, «черные списки» кадров с нетипичными артефактами, версификацию эталонного пула [13–16].

Заключение (Conclusion)

В работе предложена модель автоматизированной системы контроля качества контролируемых объектов для судостроительного производства, основанная на сочетании механизмов неконтролируемого и частично контролируемого обучения. Архитектура объединяет сверточный автоэнкодер для реконструктивного выявления аномалий, двухэтапную процедуру детектирования со скользящим окном и порогами различной чувствительности, а также полуконтролируемую классификацию с применением контрастного обучения и графовых алгоритмов псевдоразметки.

Проведенный анализ показывает, что предложенный подход имеет ряд существенных преимуществ:

- обеспечивает надежное выявление как ярко выраженных, так и слабых дефектов при контролируемом уровне ложных срабатываний;
- позволяет эффективно задействовать масштабные массивы неразмеченных данных, снижая зависимость от дефицитной экспертной аннотации;
- может быть интегрирован в производственные процессы поддержки принятия решений и соответствует современным практикам управления жизненным циклом моделей машинного обучения (MLOps).

СПИСОК ЛИТЕРАТУРЫ

1. Милушков В. И. Интеграция гибридного полуконтролируемого и контрастного обучения для автоматической классификации дефектов в производственных данных: повышение точности контроля качества продукции / В. И. Милушков, Н. Н. Лиманский, В. Е. Марлей // Перспективы науки. — 2024. — № 6(177). — С. 81–86. — EDN FBGA FM.
2. Стебаков И. Н. Интеллектуальная диагностика неисправностей роторных систем / И. Н. Стебаков, А. В. Корнаев, Е. П. Корнаева // Энерго- и ресурсосбережение — XXI век : Материалы XIX международной научно-практической конференции, Орёл, 10–12 ноября 2021 года / Под редакцией А. Н. Качанова, Ю. С. Степанова. — Орёл: Орловский государственный университет имени И. С. Тургенева, 2021. — С. 100–105. — EDN HBWIFY.
3. Щетинин Е. Ю. Автоматическое обнаружение аномалий в электрокардиограммах методами генеративного машинного обучения / Е. Ю. Щетинин // Вестник компьютерных и информационных технологий. — 2022. — Т. 19. — № 6(216). — С. 51–59. DOI: 10.14489/vkit.2022.06.pp.051-059. — EDN ERIQNA.
4. Бирюлин К. Г. Методы обучения нейронных сетей / К. Г. Бирюлин // Современное профессиональное образование: опыт, проблемы, перспективы : Материалы VIII Международной научно-практической конференции. В 2-х ч., Ростов-на-Дону, 22 марта 2021 года. Том Часть 1. — Ростов-на-Дону: Южный университет (ИУБиП) «Издательство ВВМ», 2021. — С. 53–56. — EDN CYSHGL.
5. Мухачев П. А. Современные методы машинного обучения для анализа технического состояния космических аппаратов по данным телеметрической информации / П. А. Мухачев, Т. Р. Садретдинов, Д. А. Прицыкин [и др.] // Автоматика и телемеханика. — 2021. — № 8. — С. 3–38. DOI: 10.31857/S0005231021080018. — EDN QNLLZZ.
6. Милушков В. И. Применение методов автоматического обнаружения аномалий в автоматизированном промышленном контроле изображений: возможности и перспективы / В. И. Милушков // Актуальные решения проблем водного транспорта : сборник материалов III Международной научно-практической конференции., Астрахань, 29–31 мая 2024 года. — Астрахань: Волжский государственный университет водного транспорта, 2024. — С. 85–88. — EDN XLELVP.
7. Милушков В. И. Обзор применения методов полуавтоматического и неуправляемого обучения для повышения эффективности автоматического промышленного контроля изображений / В. И. Милушков // 74-я Международная студенческая научно-техническая конференция : Материалы, Астрахань, 08–13 апреля 2024 года. — Астрахань: Астраханский государственный технический университет, 2024. — С. 597–598. — EDN NYEBIR.
8. Цыба Е. Н. Опыт применения автоэнкодеров при решении задач обнаружения аномалий во временных рядах измерительной информации / Е. Н. Цыба, О. А. Волкова, Н. А. Вострухов // Альманах современной метрологии. — 2024. — № 2(38). — С. 150–160. — EDN KITLEM.

9. He K. Momentum Contrast for Unsupervised Visual Representation Learning / K. He, H. Fan, Y. Wu, S. Xie, R. Girshick // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) 2020.
10. He K. Deep Residual Learning for Image Recognition / K. He, X. Zhang, S. Ren, J. Sun // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR) 2016.
11. Hinton G. E. A Fast Learning Algorithm for Deep Belief Nets / G. E. Hinton, S. Osindero, Y-W. Teh // Neural Computation. — 2006. — Vol. 18. — Is. 7. — Pp. 1527–1554. DOI: 10.1162/neco.2006.18.7.1527.
12. Hu G. Unsupervised fabric defect detection based on a deep convolutional generative adversarial network / G. Hu, J. Huang, Q. Wang, J. Li, Z. Xu, X. Huang // Textile Research Journal. — 2020. — Vol. 90. — Is. 3–4. — Pp. 247–270. DOI: 10.1177/0040517519862880.
13. Tan Y. An Encoder-Decoder Based Approach for Anomaly Detection with Application in Additive Manufacturing / Y. Tan, B. Jin, A. Nettekoven, Y. Chen, Y. Yue, U. Topcu, A. Sangiovanni-Vincentelli // 2019 18th IEEE International Conference On Machine Learning And Applications (ICMLA) — 2019. — C. 1008–1015. DOI: 10.1109/ICMLA.2019.00171.
14. Oh S. Automatic Detection of Welding Defects Using Faster R-CNN / S. Oh, M. Jung, C. Lim, S. Shin // Applied Sciences. — 2020. — Vol. 10. — Is. 23. DOI: 10.3390/app10238629.
15. Wan Y. Semi-Supervised Defect Detection Method with Data-Expanding Strategy for PCB Quality Inspection / Y. Wan, L. Gao, X. Li, Y. Gao // Sensors. — 2022. — Vol. 22. — Is. 20. DOI: 10.3390/s22207971.
16. Wang X. A new method for deep learning detection of defects in X-ray images of pressure vessel welds / X. Wang, F. He, X. Huang // Scientific Reports. — 2024. — Vol. 14. — Is. 1. — Pp. 6312.

REFERENCES

1. Milushkov, V. I., N. N. Limanskiy and V. E. Marley. “Integrating hybrid semi-supervised and contrastive learning for automatic defect classification in manufacturing data: Improving product quality control accuracy.” *Science Prospects* 6(177) (2024): 81–86.
2. Stebakov, I. N., A. V. Kornaev and E. P. Kornaeva. “Intelligent diagnostics of rotary systems failures.” *Energo — i resursoberezhenie — XXI vek: Materialy XIX mezhdunarodnoy nauchno-prakticheskoy konferencii, Oryol, 10–12 noyabrya 2021 goda / Pod redakciey A. N. Kachanova, YU.S. Stepanova*. Orel: Orlovskiy gosudarstvennyy universitet imeni I. S. Turgeneva, 2021: 100–105.
3. Schetinin, E. Yu. “On automatic detection of anomalies in electrocardiograms with generative machine learning.” *Vestnik Komp'yuternykh i informatsionnykh Tekhnologii* 19.6(216) (2022): 51–59. DOI: 10.14489/vkit.2022.06.pp.051-059.
4. Biryulin, K. G. “Neural network training methods.” *Sovremennoe professional'noe obrazovanie: opyt, problemy, perspektivy: Materialy VIII Mezhdunarodnoy nauchno-prakticheskoy konferentsii. V 2-kh chastyakh, Rostov-na-Donu, 22 marta 2021 goda. Tom Chast' I*. Rostov-na-Donu: Yuzhnyy universitet (IUBiP) “Izdatel'stvo VVM”, 2021: 53–56.
5. Mukhachev, P. A., T. R. Sadretdinov et al. “Modern machine learning methods for telemetry-based spacecraft health monitoring.” *Avtomatika i Telemekhanika* 8 (2021): 3–38. DOI: 10.31857/S0005231021080018.
6. Milushkov, V. I. “Application of automatic anomaly detection methods in automated industrial image inspection: opportunities and perspectives.” *Aktual'nye resheniya problem vodnogo transporta: sbornik materialov III Mezhdunarodnoy nauchno-prakticheskoy konferentsii., Astrakhan', 29–31 maya 2024 goda*. Astrakhan': Volzhskiy gosudarstvennyy universitet vodnogo transporta, 2024: 85–88.
7. Milushkov, V. I. “Obzor primeneniya metodov poluavtomaticheskogo i neupravlyаемого obucheniya dlya povysheniya effektivnosti avtomaticheskogo promyshlennogo kontrolya izobrazheniy.” *74-ya Mezhdunarodnaya studentcheskaya nauchno-tekhnicheskaya konferentsiya: Materialy, Astrakhan', 08–13 aprelya 2024 goda*. Astrakhan': Astrakhanskiy gosudarstvennyy tekhnicheskii universitet, 2024: 597–598.
8. Tsyba, E. N., O. A. Volkova and N. A. Vostrukhov. “Experience of using autoencoders in solving problems of detecting anomalies in time series of measurement information.” *AI'Manac of Modern Metrology* 2(38) (2024): 150–160.
9. He, K., R. Girshick, et al. “Momentum Contrast for Unsupervised Visual Representation Learning.” *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)2020*.
10. He, K., X. Zhang, S. Ren and J. Sun. “Deep Residual Learning for Image Recognition.” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)2016*.
11. Hinton, G. E., S. Osindero and Y-W. Teh. “A Fast Learning Algorithm for Deep Belief Nets.” *Neural Computation* 18.7 (2006): 1527–1554. DOI: 10.1162/neco.2006.18.7.1527.
12. Hu, G., X. Huang, et al. “Unsupervised fabric defect detection based on a deep convolutional generative adversarial network.” *Textile Research Journal* 90.3–4 (2020): 247–270. DOI: 10.1177/0040517519862880.

13. Tan, Y., A. Sangiovanni-Vincentelli, et al. “An Encoder-Decoder Based Approach for Anomaly Detection with Application in Additive Manufacturing.” *2019 18th IEEE International Conference On Machine Learning And Applications (ICMLA)* — 2019: 1008–1015. DOI: 10.1109/ICMLA.2019.00171.

14. Oh, S., M. Jung, C. Lim and S. Shin. “Automatic Detection of Welding Defects Using Faster R-CNN.” *Applied Sciences* 10.23 (2020). DOI: 10.3390/app10238629.

15. Wan, Y., L. Gao, X. Li and Y. Gao. “Semi-Supervised Defect Detection Method with Data-Expanding Strategy for PCB Quality Inspection.” *Sensors* 22.20 (2022). DOI: 10.3390/s22207971.

16. Wang, X., F. He and X. Huang. “A new method for deep learning detection of defects in X-ray images of pressure vessel welds.” *Scientific Reports* 14.1 (2024): 6312.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Милушков Виталий Игоревич — ассистент
ФГБОУ ВО «Санкт-Петербургский
государственный экономический университет»
191023, Российская Федерация, г. Санкт-Петербург,
наб. канала Грибоедова, 30–32
e-mail: vitaliy@milushkoff.ru

INFORMATION ABOUT THE AUTHORS

Milushkov, Vitaliy I. — Assistant Lecturer
Saint Petersburg State
University of Economics
30–32 Griboedov Canal Emb., St. Petersburg, 191023,
Russian Federation
e-mail: vitaliy@milushkoff.ru

*Статья поступила в редакцию: 04 августа 2025 г.
Received: Aug. 4, 2025.*