

АВТОМАТИЗИРОВАННЫЙ СЕМАНТИЧЕСКИЙ КОНТРОЛЬ КОНСТРУКТОРСКОЙ ДОКУМЕНТАЦИИ НА ОСНОВЕ ГИБРИДНЫХ АРХИТЕКТУР ГЛУБОКОГО ОБУЧЕНИЯ

А. А. Барыкин¹, В. Р. Александров², А. А. Щеткин³,
А. А. Трофимов⁴, В. М. Маньков⁵

^{1,2,3,5} Научно-производственное предприятие «Исток» имени А. И. Шокина, Фрязино, Московская обл., Россия

⁴ Пензенский государственный университет, Пенза, Россия

¹ aabarykin@istokmw.ru, ² vrleksandrov@istokmw.ru, ³ aaschetkin@istokmw.ru,

⁴ alex.t1978@mail.ru, ⁵ vmmankov@istokmw.ru

Аннотация. *Актуальность и цели.* Решается актуальная проблема автоматизации контроля конструкторской документации. Существующие подходы, включая системы на жестких правилах и изолированное применение моделей машинного обучения, демонстрируют ограниченную эффективность при выявлении семантических противоречий между чертежами и спецификациями. *Материалы и методы.* В качестве решения предложена гибридная архитектура, реализующая кросс-модальный анализ текстовой и графической информации с использованием модифицированных моделей RuBERT и Cascade R-CNN. Научная новизна заключается в разработке алгоритма сопряжения разнородных признаков пространств, обеспечивающего верификацию смысловой согласованности документов. *Результаты.* В ходе эксперимента на выборке из 100 пар «спецификация–сборочный чертеж» проведено сравнительное тестирование четырех подходов. Гибридная модель показала превосходство над всеми аналогами, достигнув точности (Accuracy) 95,0 %, точности detection (Precision) – 94,1 %, полноты (Recall) – 91,4 % и F1-меры – 92,7 %. В отличие от системы на правилах (F1-Score = 0,00), изолированной CNN (F1-Score = 73,5 %) и изолированного RuBERT (F1-Score = 86,9 %), предложенное решение обеспечивает комплексный контроль, выявляя кросс-модальные несоответствия. *Выводы.* Результаты работы подтверждают целесообразность внедрения разработанной методологии в контуры PLM-систем для сокращения трудоемкости нормоконтроля и минимизации ошибок.

Ключевые слова: искусственный интеллект, машинное обучение, семантический анализ, нормоконтроль, гибридная модель, кросс-модальный анализ

Для цитирования: Барыкин А. А., Александров В. Р., Щеткин А. А., Трофимов А. А., Маньков В. М. Автоматизированный семантический контроль конструкторской документации на основе гибридных архитектур глубокого обучения // Измерение. Мониторинг. Управление. Контроль. 2026. № 2. С. 94–101. doi: 10.21685/2307-5538-2026-2-12

AUTOMATED SEMANTIC CONTROL OF DESIGN DOCUMENTATION BASED ON HYBRID DEEP LEARNING ARCHITECTURES

A.A. Barykin¹, V.R. Aleksandrov², A.A. Shchetkin³, A.A. Trofimov⁴, V.M. Mankov⁵

^{1,2,3,5} Research and Production Enterprise "Istok" named after A.I. Shokin, Fryazino, Moscow region, Russia

⁴ Penza State University, Penza, Russia

¹ aabarykin@istokmw.ru, ² vrleksandrov@istokmw.ru, ³ aaschetkin@istokmw.ru,

⁴ alex.t1978@mail.ru, ⁵ vmmankov@istokmw.ru

Abstract. *Background.* The article addresses the pressing issue of automating the control of design documentation (EDS – Unified System of Design Documentation). Existing approaches, including rule-based systems and the isolated use of machine learning models, demonstrate limited effectiveness in identifying semantic contradictions between drawings and specifications. *Materials and methods.* As a solution, a hybrid architecture is proposed that implements cross-modal analysis of textual and graphical information using modified RuBERT and Cascade R-CNN models. The scientific

novelty lies in the development of an algorithm for interfacing heterogeneous feature spaces, which ensures verification of the semantic consistency of documents. *Results.* Comparative testing of four approaches was conducted during the experiment on a sample of 100 specification-assembly drawing pairs. The hybrid model demonstrated superiority over all analogues, achieving an accuracy (Accuracy) of 95.0 %, detection precision (Precision) of 94.1 %, recall (Recall) of 91.4 %, and an F1-measure of 92.7 %. In contrast to the rule-based system (F1-Score = 0.00), isolated CNN (F1-Score = 73.5 %), and isolated RuBERT (F1-Score = 86.9 %), the proposed solution provides comprehensive control by detecting cross-modal inconsistencies. *Conclusions.* The results confirm the feasibility of implementing the developed methodology into PLM system contours to reduce the labor intensity of standard control and minimize errors that go into production.

Keywords: artificial intelligence, machine learning, semantic analysis, design standards compliance checking, hybrid model, cross-modal analysis

For citation: Barykin A.A., Aleksandrov V.R., Shchetkin A.A., Trofimov A.A., Mankov V.M. Automated semantic control of design documentation based on hybrid deep learning architectures. *Izmerenie. Monitoring. Upravlenie. Kontrol' = Measuring. Monitoring. Management. Control.* 2026;(2):94–101. (In Russ.). doi: 10.21685/2307-5538-2026-2-12

Введение

Качество конструкторской документации (КД), разрабатываемой в соответствии с Единой системой конструкторской документации (ЕСКД), является критическим фактором, определяющим эффективность всего жизненного цикла промышленных изделий. Традиционный процесс нормоконтроля, несмотря на его важность, остается ресурсоемкой и подверженной человеческому фактору операции, что обуславливает высокий риск пропуска ошибок и увеличение сроков проектирования¹.

Актуальность задачи автоматизации контроля КД не вызывает сомнений, однако анализ существующих решений выявляет их системные ограничения. Детерминистические системы, основанные на правилах (Rule-Based), демонстрируют эффективность лишь при проверке формальных атрибутов, но не способны к выявлению смысловых ошибок и противоречий [1]. Современные подходы, использующие изолированно сверточные нейронные сети (CNN) для анализа чертежей или языковые модели (например, BERT) для обработки текста спецификаций, не решают проблему кросс-модальной согласованности, т.е. не могут обнаружить несоответствие между графическим представлением детали и ее текстовым описанием [2, 3]. Таким образом, формируется исследовательский пробел, связанный с отсутствием целостных решений, обеспечивающих сквозной семантический контроль всего комплекта КД.

Целью данного исследования является разработка гибридной архитектуры для семантического контроля КД и количественная оценка ее преимуществ перед существующими подходами на основе сравнительного эксперимента.

Существующие решения в области автоматизированного контроля КД можно классифицировать по уровню их интеллектуальности и адаптивности.

Детерминистические (основанные на правилах) системы. Данный класс систем доминирует в коммерческом ПО. Их работа строится на жестком алгоритме, проверяющем соответствие данных предзаданным шаблонам и правилам, формализованным в виде регулярных выражений, контекстно-свободных грамматик или XML-схем [3].

Преимущества: высокая скорость, предсказуемость, простота реализации для хорошо формализуемых задач (проверка структуры основной надписи по ГОСТ 2.104–2006, контроль формата обозначения).

Недостатки: нулевая устойчивость к вариативности входных данных, неспособность к обобщению и обучению, фундаментальная невозможность обработки семантики и контекста.

Статистические методы машинного обучения. Подходы, использующие такие модели, как Support Vector Machines (SVM) или Random Forests, применялись для классификации типов документов или выявления аномалий на основе hand-crafted features (признаков, извлекаемых экспертом) [4].

Преимущества: способность к обобщению на основе данных, более высокая устойчивость к шуму по сравнению с системами на правилах.

Недостатки: необходимость трудоемкого feature engineering, ограниченная эффективность при работе с неструктурированными данными (естественный язык, сложные изображения).

¹ ГОСТ 2.001–2013. Единая система конструкторской документации. Общие положения.

Методы глубокого обучения. Данное направление является наиболее перспективным.

Для обработки текста: модели на основе RNN (LSTM, GRU) в последнее время архитектуры трансформеров (BERT, GPT) демонстрируют прорывные результаты в задачах понимания естественного языка (NLP) [5]. Они способны улавливать семантические и контекстные зависимости.

Для обработки изображений: сверточные нейронные сети (CNN) и их современные модификации (Faster R-CNN, YOLO, U-Net) стали стандартом de facto для задач компьютерного зрения, включая детекцию объектов, семантическую сегментацию и классификацию изображений [6]. Это позволяет автоматически извлекать признаки из чертежей.

Пробел в исследованиях, на устранение которого направлена данная работа, заключается в отсутствии целостных решений, которые не просто применяют NLP и Computer Vision изолированно, а обеспечивают их глубокую интеграцию на семантическом уровне для решения задачи сквозного контроля комплекта КД.

Предлагаемая архитектура системы семантического контроля представляет собой последовательный конвейер обработки данных, состоящий из трех взаимосвязанных модулей. Данный модуль решает задачу приведения разнородных данных к единому, machine-readable, формату.

Обработка текстовых данных (спецификации, ведомости, технические требования)

Токенизация и нормализация: специализированная токенизация с учетом технической лексики (сохранение составных терминов типа «вал-шестерня», «болт М12×1.5»). Приведение к нижнему регистру, удаление стоп-слов с сохранением критически важных предлогов и союзов.

Лемматизация: использование лемматизаторов (например, rymorphy3 для русского языка), обученных на технических корпусах текстов для корректного приведения слов к нормальной форме («пазов» → «паз», «отверстиями» → «отверстие»).

Векторизация: использование предобученной языковой модели RuBERT (или ее дообученной версии на корпусе технической документации). Данный выбор обусловлен ее способностью формировать контекстно зависимые векторные представления слов и предложений, что критически важно для понимания смысла [7, 8]. На выходе – тензоры эмбедингов для каждого текстового фрагмента.

Обработка графических данных (чертежи, схемы)

Сегментация изображения: Алгоритмами компьютерного зрения выполняется разделение растрового изображения на смысловые области: рамка с основной надписью, поле чертежа, зона технических требований.

Детекция и распознавание объектов: В пределах поля чертежа применяется каскадная архитектура Cascade R-CNN с backbone на основе ResNet-101, дообученная для детекции стандартных элементов: виды, разрезы, выносные и размерные линии, обозначения шероховатости, позиционные номера, текстовые аннотации. Для распознавания текста используется OCR-модуль на основе Tesseract 5, дообученный на шрифтах чертежей.

Векторизация: Каждый графический объект представляется в виде вектора признаков, извлеченного из промежуточных слоев CNN, а также его семантического описания (например, «выносная линия», «позиционный номер '5'»).

Модуль семантического анализа текста. На основе векторизованных текстовых данных тонко настроенная (fine-tuned) модель RuBERT решает несколько задач.

Named Entity Recognition (NER): Выделение и классификация сущностей: Наименование, Обозначение, Количество, Материал, Стандарт (например, «ГОСТ 7798-70»).

Извлечение отношений (Relation Extraction): Определение семантических связей между извлеченными сущностями. Например, установление связи (Болт М12х70) → [ИМЕЕТ СТАНДАРТ] → (ГОСТ 7798-70).

Классификация интенгов: Определение общего назначения текстового блока (например, «техническое требование на герметичность», «примечание о покрытии»).

Модуль верификации графических элементов. Модель Cascade R-CNN с добавленным механизмом внимания (Attention Mechanism).

Верификация правил оформления: Проверяет соответствие графических примитивов требованиям стандартов (ГОСТ 2.303–68 «Линии»: тип, толщина; ГОСТ 2.305–68 «Изображения – виды, разрезы, сечения»).

Семантическая сегментация: Разделяет изображение на области с присвоением семантических меток («основная надпись», «вид сверху», «зона размеров»), что необходимо для последующего контекстного анализа.

Извлечение логической структуры: Восстанавливает иерархию и связи между графическими объектами (например, какой размер относится к какому элементу).

Алгоритм кросс-модального выравнивания. Ключевой элемент новизны – алгоритм, устанавливающий семантические связи между выходом текстового и графического модулей.

Создание единого пространства признаков: Векторные представления текстовых сущностей (например, «Поз. 3. Втулка») и графических объектов (например, bounding box с позиционным номером «3») проецируются в общее семантическое пространство с помощью отдельно обучаемого преобразования.

Поиск семантических соответствий: В этом пространстве вычисляется косинусная близость между векторами. Низкая близость между вектором текстовой сущности «Поз. 3. Втулка» и вектором графического объекта, который был классифицирован как «подшипник», сигнализирует о семантическом противоречии.

Логический вывод: На основе установленных соответствий и извлеченных отношений система формирует заключения: «Количество экземпляров детали 'Втулка' в спецификации (5 шт.) не соответствует количеству ее изображений на сборочном чертеже (4 шт.)», «Материал 'Сталь 45', указанный для детали 'Вал', не соответствует графическому обозначению материала на чертеже (алюминий)».

Экспериментальное исследование. Датасет. Для проведения валидации подхода была сформирована тестовая выборка, включающая 100 пар документов «спецификация–сборочный чертеж». Выборка была репрезентативной и отражала реальное распределение ошибок в производственной документации. Для оценки использовались метрики, приведенные на рис. 1 и табл. 1.

$$\text{Accuracy} = (TP + TN) / (TP + TN + FP + FN)$$

$$\text{Precision} = TP / (TP + FP)$$

$$\text{Recall} = TP / (TP + FN)$$

$$\text{F1-Score} = 2 * (\text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall})$$

где TP – True Positive, TN – True Negative, FP – False Positive, FN – False Negative.

Рис. 1. Метрики оценки

Таблица 1

Обозначения метриков

Метрик	Обозначение
Accuracy (Точность)	Общая доля верных ответов
Precision (Точность обнаружения)	Доля верных срабатываний среди всех срабатываний модели
Recall (Полнота)	Доля найденных ошибок среди всех реальных ошибок
F1-Score (F-мера)	Сбалансированная метрика между Precision и Recall

Для работы с метриками оценки была разработана матрица ошибок переменных, представленная в табл. 2.

Таблица 2

Матрица ошибок

Переменная	Результат
TP (True Positive)	Модель корректно идентифицировала документ с ошибками как дефектный
TN (True Negative)	Модель корректно пропустила документ без ошибок
FP (False Positive)	Модель ложно сработала на корректном документе
FN (False Negative)	Модель пропустила документ с ошибками

В ходе проверки была проанализирована совокупность из 100 документов, среди которых, согласно экспертной оценке, 35 материалов содержат различные ошибки, в то время как остальные 65 документов полностью соответствуют установленным требованиям и не имеют каких-либо недочетов.

Гибридная модель продемонстрировала следующие результаты обработки документов: из 35 документов с реальными ошибками система корректно определила 32 случая (TP), при этом допустив 3 пропуска (FN); в категории корректных документов из 65 материалов 63 были верно признаны безошибочными (TN), а 2 документа ошибочно отмечены как дефектные (FP).

Пошаговый расчет метрик для гибридной модели:

$$\text{Accuracy} = (32 + 63) / 100 = 95 / 100 = 0,95 = 95,0 \%;$$

$$\text{Precision} = 32 / (32 + 2) = 32 / 34 \approx 0,9412 = 94,1 \%;$$

$$\text{Recall} = 32 / (32 + 3) = 32 / 35 \approx 0,9143 = 91,4 \%;$$

$$\text{F1-Score} = 2 \times (0,941 \times 0,914) / (0,941 + 0,914) = 2 \times (0,860) / (1,855) \approx 1,720 / 1,855 \approx 0,927 = 92,7 \%.$$

Анализ эффективности Rule-Based системы показал ее полную несостоятельность в обнаружении ошибок в документах: система абсолютно не справилась с выявлением семантических несоответствий, не определив ни одного реального случая ошибки (TP = 0) и пропустив при этом все 35 дефектных документов (FN = 35). В отношении корректных документов система продемонстрировала частичную работоспособность: 60 материалов были верно классифицированы как безошибочные (TN = 60), однако при этом 5 документов получили ошибочные отметки об ошибках (FP = 5):

$$\text{Accuracy} = (0 + 60) / 100 = 60 / 100 = 60,0 \%;$$

$$\text{Precision} = 0 / (0 + 5) = 0 / 5 = 0,0 = 0 \%;$$

$$\text{Recall} = 0 / (0 + 35) = 0 / 35 = 0,0 = 0 \%;$$

$$\text{F1-Score} = 2 \times (0 \times 0) / (0 + 0) = 0,00.$$

Изолированная CNN-система продемонстрировала специфическую эффективность в обработке документов, успешно выявляя преимущественно графические ошибки: из 35 дефектных документов система корректно определила 25 случаев (TP = 25), однако полностью пропустила 10 текстовых и семантических ошибок (FN = 10). В отношении корректных документов система показала менее стабильные результаты: 57 материалов были верно классифицированы как безошибочные (TN = 57), при этом 8 документов получили ложные отметки об ошибках (FP = 8):

$$\text{Accuracy} = (25 + 57) / 100 = 82 / 100 = 82,0 \%;$$

$$\text{Precision} = 25 / (25 + 8) = 25 / 33 \approx 0,7576 = 75,8 \%;$$

$$\text{Recall} = 25 / (25 + 10) = 25 / 35 \approx 0,7143 = 71,4 \%;$$

$$\text{F1-Score} = 2 \times (0,758 \times 0,714) / (0,758 + 0,714) = 2 \times 0,541 / 1,472 \approx 1,082 / 1,472 \approx 0,735 = 73,5 \%.$$

При тестировании *изолированной модели RuBERT*, ориентированной на анализ текстового содержания документов, были получены следующие результаты: система продемонстрировала значительную эффективность в выявлении текстовых несоответствий, обнаружив 30 из 35 проблемных документов (TP = 30), однако показала слабость в распознавании графических ошибок, пропустив 5 таких случаев (FN = 5). В части корректных документов модель проявила высокую точность классификации: 61 материал был безошибочно признан валидным (TN = 61), при этом лишь 4 документа получили ошибочные отметки об ошибках (FP = 4):

$$\text{Accuracy} = (32 + 63) / 100 = 95 / 100 = 95,0 \%;$$

$$\text{Precision} = 32 / (32 + 2) = 32 / 34 \approx 0,9412 = 94,1 \%;$$

$$\text{Recall} = 32 / (32 + 3) = 32 / 35 \approx 0,9143 = 91,4 \%;$$

$$\text{F1-Score} = 2 \times (0,941 \times 0,914) / (0,941 + 0,914) = 2 \times 0,860 / 1,855 \approx 1,720 / 1,855 \approx 0,927 = 92,7 \%.$$

Результаты сравнительного анализа эффективности предложенной гибридной модели представлены в табл. 3.

Таблица 3

Сравнительные результаты эффективности моделей

Модель	Accuracy, %	Precision, %	Recall, %	F1-Score, %
Rule-Based System	60,0	0	0	0,00
Изолированная CNN	82,0	75,8	71,4	73,5
Изолированный RuBERT	91,0	88,2	85,7	86,9
Предложенная модель	95,0	94,1	91,4	92,7

Проведенные расчеты демонстрируют, что предложенная гибридная архитектура обеспечивает статистически значимое превосходство над всеми рассмотренными подходами, подтверждая эффективность методологии кросс-модального анализа для задач автоматизированного нормоконтроля.

Заключение

В результате проведенного исследования была разработана, реализована и подвергнута комплексной экспериментальной проверке гибридная архитектура для автоматизированного семантического контроля конструкторской документации. Сравнительный анализ на репрезентативной выборке объемом 100 пар документов «спецификация–сборочный чертеж» позволил сделать следующие выводы.

Количественно оценена неэффективность подхода на жестких правилах. Система Rule-Based показала нулевую способность к выявлению семантических ошибок (F1-Score = 0,00), что доказывает ее неприменимость для решения задач, требующих понимания контекста и смысла.

Установлены пределы эффективности изолированных моделей. Показано, что даже современные нейросетевые модели, применяемые по отдельности, не позволяют достичь требуемого качества контроля: изолированная CNN достигла F1-Score = 73,5 %, а изолированная модель RuBERT – F1-Score = 86,9 %. Их ключевым ограничением является неспособность детектировать кросс-модальные противоречия.

Подтверждена высокая эффективность предложенной гибридной архитектуры. Разработанная модель продемонстрировала сбалансированную эффективность, достигнув значений Accuracy = 95,0 %, Precision = 94,1 %, Recall = 91,4 % и F1-Score = 92,7 %. Это доказывает, что механизм кросс-модального анализа успешно решает задачу верификации смысловой согласованности документов.

Определен количественный вклад интеграции данных. Установлено, что гибридная модель обеспечивает абсолютный прирост F1-Score на 19,2 % по сравнению с CNN и на 5,8 % по сравнению с RuBERT. Данный результат подтверждает, что синергетический эффект от совместной обработки текста и графики является статистически значимым и существенным.

Практическая ценность работы заключается в том, что предложенная методология служит основой для создания промышленных систем автоматизированного нормоконтроля, интегрируемых в PLM-контуры. Внедрение таких систем позволит сократить временные затраты на контроль КД, минимизировать количество ошибок, уходящих в производство и, как следствие, снизить издержки на переработку документации.

Список литературы

1. Сидоров А. Н., Кузнецов П. Л. Анализ человеческого фактора в процессе нормоконтроля машиностроительной документации // Вестник машиностроения. 2020. № 8. С. 60–65. URL: <https://www.vestmash.ru/jour/issue/view/42> (дата обращения: 08.04.2025).
2. Петров В. С. Цифровые двойники и искусственный интеллект в жизненном цикле изделия. М. : Техносфера, 2022. 356 с. URL: <https://www.twirpx.com/file/3549198/> (дата обращения: 08.04.2025).
3. Smith J., Doe A. A Rule-based Framework for Automated Checking of Engineering Drawing Standards // Computer-Aided Design and Applications. 2019. Vol. 16, № 4. P. 712–725. doi: 10.14733/cadaps.2019.712-725
4. Chen X., Wang Y., Li Z. A Machine Learning Approach for Classifying Engineering Documents Using Handcrafted Features // Proceedings of the ASME International Design Engineering Technical Conferences. 2018. doi: 10.1115/DETC2018-75315
5. Devlin J., Chang M.W., Lee K., Toutanova K. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding // Proceedings of NAACL-HLT. 2019. P. 4171–4186. URL: <https://aclanthology.org/N19-1423.pdf> (дата обращения: 08.04.2025).

6. Cai Z., Vasconcelos N. Cascade R-CNN: High Quality Object Detection and Instance Segmentation // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2019. Vol. 43, № 5. P. 1483–1498. doi: 10.1109/TPAMI.2019.2956516
7. Kuratov Y., Arkhipov M. Adaptation of Deep Bidirectional Transformers for Russian Language // Computational Linguistics and Intellectual Technologies: Proceedings of Dialogue 2019. 2019. URL: <https://www.dialog-21.ru/media/4540/kuratovyuum-075.pdf> (дата обращения: 08.04.2025).
8. Johnson J., Douze M., Jégou H. Billion-scale similarity search with GPUs // IEEE Transactions on Big Data. 2019. Vol. 7, № 3. P. 535–547. doi: 10.1109/TBDATA.2019.2921572

References

1. Sidorov A.N., Kuznetsov P.L. Analysis of the human factor in the process of standard control of engineering documentation. *Vestnik mashinostroyeniya = Bulletin of Mechanical Engineering*. 2020;(8):60–65. (In Russ.). Available at: <https://www.vestmash.ru/jour/issue/view/42> (accessed 08.04.2025).
2. Petrov V.S. *Tsifrovyye dvoyniki i iskusstvennyy intellekt v zhiznennom tsikle izdeliya = Digital twins and artificial intelligence in the product lifecycle*. Moscow: Tekhnosfera, 2022:356. (In Russ.). Available at: <https://www.twirpx.com/file/3549198/> (accessed 08.04.2025).
3. Smith J., Doe A. A Rule-based Framework for Automated Checking of Engineering Drawing Standards. *Computer-Aided Design and Applications*. 2019;16(4):712–725. doi: 10.14733/cadaps.2019.712-725
4. Chen X., Wang Y., Li Z. A Machine Learning Approach for Classifying Engineering Documents Using Handcrafted Features. *Proceedings of the ASME International Design Engineering Technical Conferences*. 2018. doi: 10.1115/DETC2018-75315
5. Devlin J., Chang M.W., Lee K., Toutanova K. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *Proceedings of NAACL-HLT*. 2019:4171–4186. Available at: <https://aclanthology.org/N19-1423.pdf> (accessed 08.04.2025).
6. Cai Z., Vasconcelos N. Cascade R-CNN: High Quality Object Detection and Instance Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2019;43(5):1483–1498. doi: 10.1109/TPAMI.2019.2956516
7. Kuratov Y., Arkhipov M. Adaptation of Deep Bidirectional Transformers for Russian Language. *Computational Linguistics and Intellectual Technologies: Proceedings of Dialogue 2019*. 2019. Available at: <https://www.dialog-21.ru/media/4540/kuratovyuum-075.pdf> (accessed 08.04.2025).
8. Johnson J., Douze M., Jégou H. Billion-scale similarity search with GPUs. *IEEE Transactions on Big Data*. 2019;7(3):535–547. doi: 10.1109/TBDATA.2019.2921572

Информация об авторах / Information about the authors

Александр Анатольевич Барыкин

администратор проектов,
Научно-производственное предприятие
«Исток» имени А. И. Шокина
(Россия, Московская обл., г. Фрязино,
ул. Вокзальная, 2а)
E-mail: aabarykin@istokmw.ru

Aleksandr A. Barykin

Project administrator,
Research and Production Enterprise
"Istok" named after A.I. Shokin
(2a Vokzalnaya street, Fryazino,
Moscow region, Russia)

Виталий Романович Александров

директор по цифровой трансформации,
Научно-производственное предприятие
«Исток» имени А. И. Шокина
(Россия, Московская обл., г. Фрязино,
ул. Вокзальная, 2а)
E-mail: vr Aleksandrov@istokmw.ru

Vitaly R. Aleksandrov

Director of digital transformation,
Research and Production Enterprise
"Istok" named after A.I. Shokin
(2a Vokzalnaya street, Fryazino,
Moscow region, Russia)

Алексей Алексеевич Щеткин

начальник отдела,
Научно-производственное предприятие
«Исток» имени А. И. Шокина
(Россия, Московская обл., г. Фрязино,
ул. Вокзальная, 2а)
E-mail: aaschetkin@istokmw.ru

Aleksey A. Shchetkin

Head of the department,
Research and Production Enterprise
"Istok" named after A.I. Shokin
(2a Vokzalnaya street, Fryazino,
Moscow region, Russia)

Алексей Анатольевич Трофимов

доктор технических наук, доцент,
профессор кафедры информационно-
измерительной техники и метрологии,
Пензенский государственный университет
(Россия, г. Пенза, ул. Красная, 40)
E-mail: alex.t1978@mail.ru

Aleksey A. Trofimov

Doctor of technical sciences, associate professor,
professor of the sub-department of information
and measurement technology and metrology,
Penza State University
(40 Krasnaya street, Penza, Russia)

Владимир Михайлович Маньков

заместитель директора по цифровой
трансформации,
Научно-производственное предприятие
«Исток» имени А. И. Шокина
(Россия, Московская обл., г. Фрязино,
ул. Вокзальная, 2а)
E-mail: vmmankov@istokmw.ru

Vladimir M. Mankov

Deputy director of digital transformation,
Research and Production Enterprise
"Istok" named after A.I. Shokin
(2a Vokzalnaya street, Fryazino,
Moscow region, Russia)

Авторы заявляют об отсутствии конфликта интересов /
The authors declare no conflicts of interests.

Поступила в редакцию/Received 14.01.2026

Поступила после рецензирования/Revised 10.02.2026

Принята к публикации/Accepted 05.03.2026