

УДК 004.37

DOI: [10.26102/2310-6018/2026.58.7.013](https://doi.org/10.26102/2310-6018/2026.58.7.013)

Метод персонификации образовательных траекторий на основе иерархической модели компетенций

Н.С. Качурин✉, А.Г. Кравец, В.С. Андреев

*Волгоградский государственный технический университет, Волгоград,
Российская Федерация*

Резюме. Разрыв между тем, чему учат в вузе, и тем, что ждет от выпускника работодатель, с переходом образования в цифровую среду становится все заметнее. По оценкам World Economic Forum, к 2030 году обновится около 39 % ключевых навыков, поэтому задача своевременного выявления у студентов пробелов в компетенциях приобретает особое значение. Имеющиеся решения в области индивидуализации образовательных маршрутов, как правило, работают на уровне отдельных дисциплин и не позволяют системно сопоставить то, что студентом уже освоено, с тем, что требуется для конкретной профессии, особенно с учетом иерархии связей между навыками. Настоящее исследование посвящено разработке метода, который объединяет разнородные сведения из цифрового профиля обучающегося и формирует рекомендации, ориентированные на выбранную профессиональную роль. В рамках работы предложено: строить компетентностную модель в виде иерархии с тремя уровнями освоения (базовый, средний, продвинутый); собирать оценки по компетенциям из нескольких источников, ослабляя влияние устаревших данных по экспоненциальному закону; проводить многоуровневый гар-анализ, позволяющий количественно оценить дефицит относительно требований роли; применять гибридный алгоритм рекомендаций, в котором контентная и коллаборативная фильтрация дополняются функцией совместимости уровней. Проверка метода выполнена на модельной выборке – 100 профилей студентов, 25 компетенций, 60 учебных активностей и 5 профессиональных ролей IT-отрасли. Полученные показатели подтверждают работоспособность подхода: покрытие дефицитных компетенций (Coverage@5) достигает 0,81, расчетное сокращение суммарного дефицита составляет 46 %, а средний индекс готовности поднимается с 51 % до 76 %. По сравнению с базовыми стратегиями метод демонстрирует статистически значимое преимущество ($p < 0,001$). Переход от бинарной к трехуровневой шкале освоения дает прирост Coverage на 12 процентных пунктов.

Ключевые слова: индивидуальная образовательная траектория, профессиональное развитие, иерархическая модель компетенций, цифровой профиль, рекомендательные системы, гар-анализ.

Для цитирования: Качурин Н.С., Кравец А.Г., Андреев В.С. Метод персонификации образовательных траекторий на основе иерархической модели компетенций. *Моделирование, оптимизация и информационные технологии*. 2026;14(7). URL: <https://moitvvt.ru/ru/journal/article?id=2288> DOI: 10.26102/2310-6018/2026.58.7.013

Method for personalization of educational trajectories based on a hierarchical competency model

N.S. Kachurin✉, A.G. Kravets, V.S. Andreev

Volgograd State Technical University, Volgograd, the Russian Federation

Abstract. As education shifts into the digital environment, the gap between what graduates actually know and what the labor market expects from them keeps widening. According to estimates by the World Economic Forum, about 39% of core skills will need to be updated by 2030, which makes the timely identification of competency gaps among students particularly important. Most existing

approaches to the personalization of learning pathways operate at the level of individual disciplines and do not offer a systematic comparison between the competencies a student has already acquired and those required by a particular professional role, especially when the hierarchical relations between skills are taken into account. The present study develops a method that brings together heterogeneous data from a student's digital profile and produces recommendations aligned with a selected target role. The proposed approach combines: a hierarchical competency model with a three-level proficiency scale (basic, intermediate, advanced); an aggregation mechanism that merges information from several sources while damping outdated records by an exponential rule; a multi-level gap analysis that provides a quantitative estimate of the deficit relative to role requirements; and (iv) a hybrid recommendation algorithm in which content-based and collaborative filtering are combined with a level-compatibility function. The method was tested on a synthetic dataset consisting of 100 student profiles, 25 competencies, 60 educational activities and 5 professional IT roles. The results confirm the viability of the approach: coverage of deficient competencies (Coverage@5) reaches 0.81, the estimated reduction in the aggregate gap is 46 %, and the average readiness index rises from 51 % to 76 %. The comparison with baseline strategies shows a statistically significant advantage of the proposed method ($p < 0.001$). Moving from a binary to a three-level proficiency scale increases Coverage by 12 percentage points.

Keywords: individual educational trajectory, professional development, hierarchical competency model, digital profile, recommendation systems, gap analysis.

For citation: Kachurin N.S., Kravets A.G., Andreev V.S. Method for personalization of educational trajectories based on a hierarchical competency model. *Modeling, Optimization and Information Technology*. 2026;14(7). (In Russ.). URL: <https://moitvvt.ru/ru/journal/article?id=2288> DOI: 10.26102/2310-6018/2026.58.7.013

Введение

Курс на цифровизацию высшего образования закреплён распоряжением Правительства Российской Федерации от 18.10.2023 № 2894-р, которое утверждает стратегическое направление цифровой трансформации этой сферы¹. Проектируя индивидуальные образовательные маршруты, вуз обязан обеспечить достижение планируемых результатов обучения и сформировать у выпускника компетенции, предусмотренные ФГОС ВО по направлению 09.03.01 «Информатика и вычислительная техника»². В этих условиях на первый план выходит разработка таких методов построения траекторий профессионального развития, которые опирались бы на данные цифрового профиля студента и возможности образовательной аналитики [1].

Значительная часть известных подходов к персонификации обучения работает лишь в границах отдельных дисциплин или курсов и не даёт целостной картины соотношения «уже имеется у студента» и «требуется по профессии». К тому же во многих решениях практически не учитываются иерархические связи между областями знаний и компетенциями, из-за чего итоговые рекомендации нередко оказываются разрозненными и плохо согласуются с выбранной профессиональной ролью [2, 3].

В отечественных публикациях также обращается внимание на то, что конкурентоспособность выпускников ИТ-направлений напрямую зависит от того, насколько их компетенции отвечают запросам профессиональной практики [4].

¹ Распоряжение Правительства Российской Федерации от 18.10.2023 № 2894-р «Об утверждении стратегического направления в области цифровой трансформации образования, относящейся к сфере деятельности Министерства просвещения Российской Федерации, и признании утратившим силу распоряжения Правительства РФ от 02.12.2021 № 3427-р». Официальный интернет-портал правовой информации. Номер опубликования: 0001202310270020. Дата опубликования: 27.10.2023 (дата обращения: 13.01.2026).

² Приказ Министерства образования и науки Российской Федерации от 19.09.2017 № 929 «Об утверждении федерального государственного образовательного стандарта высшего образования – бакалавриат по направлению подготовки 09.03.01 Информатика и вычислительная техника» (дата обращения: 13.01.2026).

По прогнозу World Economic Forum³, к 2030 году обновится около 39 % ключевых навыков (годом ранее, в 2023-м, эта величина оценивалась в 44 %). Поскольку нынешние студенты совсем скоро выйдут на рынок труда, описанная динамика лишний раз указывает на то, что вузам нужны более гибкие и более точные инструменты диагностики пробелов в компетенциях и проектирования индивидуальных маршрутов профессионального развития в образовательной среде вуза.

Цель работы – предложить метод персонификации образовательных маршрутов, который позволял бы:

- объединять разнородные данные с учетом иерархии компетенций;
- строить траекторию, согласованную с выбранной профессиональной ролью;
- проходить экспериментальную проверку предложенного подхода.

Обзор существующих решений. В Таблице 1 собран сравнительный обзор работ, в которых рассматриваются те или иные варианты персонификации образовательных маршрутов.

Таблица 1 – Сравнительный анализ существующих подходов к персонификации образовательных траекторий

Table 1 – Comparative analysis of existing approaches to the personalization of educational trajectories

Подход/ Источник	Модель компетенций / данные	Метод (логика) рекомендаций	Ограничения
Качурин Н.С. [3]	Гетерогенные данные: учебные, научные и внеклассные достижения	Интеграция данных → персональные рекомендации; корректировка траектории	Требует формализации компетенций и алгоритмов; нужна валидация
Качурин Н.С. [5]	Учет учебных и научных достижений (разнородные артефакты)	Автоматизация учета/верификации как база для анализа и персонализации	Нет описания рекомендательного алгоритма; фокус на проблеме учета
Подколзин М.М. [6]	Профиль обучающегося и данные обучения в адаптивной системе	Адаптивная персонализация на основе статистических моделей	Высокие требования к данным; сложность интерпретации рекомендаций
Клишин А.П. и др. [1]	Цифровой профиль студента и параметры учебного процесса	Поддержка решений на базе когнитивной модели с применением алгоритмов анализа данных	Ориентация на управление/решения; требуется интеграция с ИОС
Логинова Е.Г., Денисов Н.Л. [7]	Цифровой след и поведенческие паттерны в LMS/ИОС	Process mining для выявления паттернов как основы персонализации	Не формирует траекторию напрямую; нужна связка с компетенциями
Пустовалова Н.В. [8]	Онтологическое/ структурное представление сущностей и связей	Формализация связей для согласованных рекомендаций и анализа	Не дает готового RS- алгоритма; требуется настройка данными и правилами

³ Всемирный экономический форум. *Будущее рабочих мест 2025*. URL: <https://www.weforum.org/publications/the-future-of-jobs-report-2025/> (дата обращения: 13.01.2026).

Из Таблицы 1 следует, что отечественные работы по индивидуализации обучения опираются на разные основания: сведение воедино разнородных сведений о достижениях обучающихся [3, 5], адаптивные схемы обучения [1, 6], анализ цифрового следа и поведенческих паттернов [7], а также формализованное описание учебного процесса и связей между его элементами [8]. Общими слабыми местами остаются два: во-первых, потребность в четко прописанной компетентностной модели и критериях сравнения «требуется – сформировано»; во-вторых, разрыв между процедурой диагностики и собственно механизмом выдачи рекомендаций.

В ряде отечественных публикаций разрабатываются алгоритмические способы построения индивидуальных образовательных маршрутов, в частности, с использованием методов речевого интеллекта, что подтверждает востребованность рекомендательных механизмов, опирающихся на данные об обучающемся [9].

Научная новизна исследования заключается в разработке метода персонификации образовательных траекторий, который объединяет: иерархическую модель компетенций с учетом их структурных взаимосвязей; механизм агрегирования уровней компетенций из разнородных источников цифрового профиля с учетом временного затухания актуальности данных; многоуровневый гар-анализ, учитывающий не только наличие компетенции, но и степень ее сформированности; функцию совместимости уровней освоения компетенций, встроенную в рекомендательный алгоритм. В отличие от существующих подходов, предлагаемый метод обеспечивает согласование рекомендаций одновременно с профессиональной ролью обучающегося, уровнем сформированности компетенций и динамикой их развития.

Материалы и методы

В основе предлагаемого подхода лежит представление о цифровом профиле студента как о динамической модели, отражающей его компетенции, образовательные результаты и поведенческие характеристики и формируемой по данным цифрового следа. Применение цифрового профиля как источника данных для поддержки решений в учебном процессе обсуждается в отечественных работах и делает персонализированные рекомендации обоснованными [1, 7]. Концептуальные вопросы проектирования траектории профессионального развития и требования к ней в условиях вузовской образовательной среды рассматриваются в исследованиях, посвященных методам персонификации маршрутов [3].

Традиционный учебный процесс (Рисунок 1) устроен как относительно линейная последовательность этапов, в которой возможности обратной связи ограничены.

Персонифицированный маршрут профессионального развития (Рисунок 2), в отличие от традиционной схемы, предполагает сбор разнородных данных, формирование цифрового профиля студента, проведение гар-анализа и выдачу индивидуальных рекомендаций в режиме постоянной обратной связи [1, 6].

Профиль строится по данным двух типов [7, 8].

Структурированные данные. К ним относятся академическая успеваемость, итоги контрольных мероприятий, записи в LMS/ЭИОС (электронная информационно-образовательная среда), а также результаты стандартизированных тестирований.

Полуструктурированные и неструктурированные данные. Сюда входят поведенческие признаки, извлекаемые из цифрового следа, сведения об учебных и научных достижениях, а также данные об участии в проектах и внеучебной деятельности. Все это увеличивает полноту профиля и дает возможность точнее фиксировать пробелы в компетенциях [5, 7].

Индивидуальные характеристики обучающегося удобно фиксировать именно через цифровой профиль: он собирает в себе результаты учебной деятельности,

поведенческие сигналы цифрового следа и сведения о желаемых профессиональных ролях. Чтобы сопоставить требования конкретных ролей с содержанием обучения и образовательным контентом, применяются методы структурированного описания предметной области и средства семантического анализа, за счет которых компетенции и учебные активности получают единое описание [1, 8].




Рисунок 1 – Диаграмма этапов реализации образовательной программы в соответствии с ФГОС ВО
Figure 1 – Diagram of the stages of implementation of the educational program in accordance with the Federal State Educational Standard of Higher Education

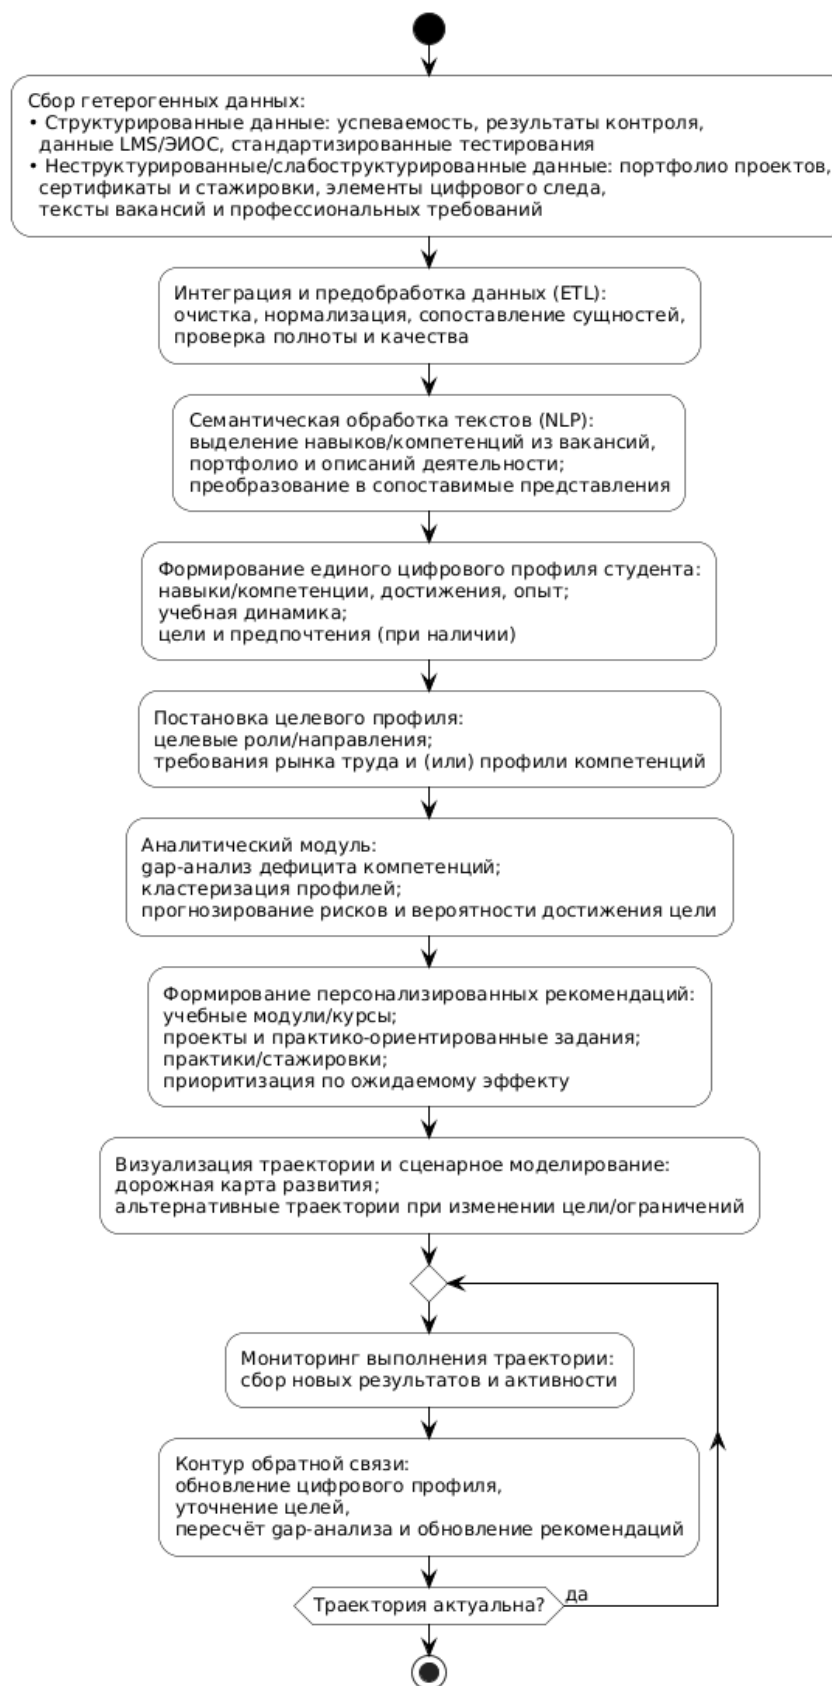


Рисунок 2 – Диаграмма этапов информационно-аналитической поддержки персонализированной траектории профессионального развития студента
Figure 2 – Diagram of the stages of information and analytical support for the personalized trajectory of a student's professional development

Формализация метода персонификации. Иерархическая модель компетенций.

В отличие от плоской схемы, где связи между навыками задаются лишь неявно, в настоящей работе принята иерархическая модель компетенций: она позволяет в явном виде описать домены, блоки и более мелкие уровни декомпозиции. Такой способ повышает прозрачность диагностики и делает рекомендации, получаемые при проектировании индивидуальных маршрутов, более согласованными между собой [3, 8].

$$K = \{D_1, D_2, \dots, D_n\}, \quad (1)$$

где K – множество компетенций; D_j – домены (крупные области компетенций), $j = 1, \dots, n$. Каждый домен декомпозируется на блоки:

$$D_j = \{B_{j,1}, B_{j,2}, \dots, B_{j,m}\}, \quad (2)$$

где $B_{j,l}$ – блок компетенций в домене D_j . Блоки содержат конкретные компетенции с уникальными идентификаторами:

$$B_{j,l} = \{k_{j,l,1}, k_{j,l,2}, \dots, k_{j,l,p}\}. \quad (3)$$

В модели выделяется четыре основных домена:

- 1) профессиональные компетенции – узкоспециализированные навыки, привязанные к конкретной роли;
- 2) опережающие – те, чей рост востребованности прогнозируется на горизонте ближайших лет;
- 3) отраслевые – общие для всей индустрии;
- 4) универсальные компетенции, то есть *soft skills*: метакогнитивные и социальные навыки.

Модель уровней сформированности. Важным расширением модели стало введение уровней сформированности компетенций, благодаря чему удастся уйти от грубой бинарной фиксации «сформировано / не сформировано» и перейти к более тонкой диагностике, точнее описывающей образовательные результаты. Многоуровневые модели оценки хорошо ложатся на задачи мониторинга качества подготовки и управления индивидуальными маршрутами студентов [2, 10]. В работе вместо бинарной шкалы предложена трехуровневая:

$$L(k) \in \{0, B, I, A\} \equiv \{0, 1, 2, 3\}, \quad (4)$$

здесь 0 означает, что компетенция не сформирована; B (Basic, базовый, 1) – владение основными понятиями; I (Intermediate, средний, 2) – умение применять компетенцию в типовых ситуациях; A (Advanced, продвинутый, 3) – способность справляться с нестандартными задачами. Дескрипторы уровней описаны в Таблице 2.

Таблица 2 – Структура дескрипторов уровней сформированности компетенций
Table 2 – Structure of descriptors for competency development levels

Уровень	Знания	Умения	Навыки
Basic – Базовый (B)	Знает основные понятия и методы	Применяет по образцу	Выполняет типовые задачи
Средний – Intermediate (I)	Понимает взаимосвязи методов	Выбирает и адаптирует методы	Решает нестандартные задачи
Продвинутый – Advanced (A)	Владеет передовыми концепциями	Разрабатывает новые подходы	Создаёт инновационные решения

Модель цифрового профиля студента. Обозначим через U множество студентов, через K – множество компетенций, через R – множество профессиональных ролей. Цифровой профиль отдельного студента $u \in U$ описывается кортежем:

$$P(u) = \langle P_{skills}(u), P_{ach}(u), P_{dyn}(u), P_{goal}(u) \rangle, \quad (5)$$

где $P_{skills}(u)$ – множество пар (компетенция, уровень); $P_{ach}(u)$ – подтвержденные достижения; $P_{dyn}(u)$ – динамика освоения; $P_{goal}(u)$ – целевая роль и предпочтения.

Механизм агрегирования компетенций. Сведения об одной и той же компетенции могут приходить из разных источников: это и итоги освоения дисциплин, и практико-ориентированные задания, и проектная деятельность, и, наконец, данные цифрового следа. Обращение к совокупности агрегированных признаков профиля и поведенческих паттернов студента делает выдаваемые впоследствии рекомендации более обоснованными [1, 7]. Агрегированный уровень компетенции k_i для студента u :

$$L_{u,i} = [\sum_s \in S w_s \cdot d(t_s) \cdot f_s(u, k_i)], \quad (6)$$

где w_s – вес источника s (Таблица 3); $d(t_s)$ – коэффициент давности; $f_s(u, k_i)$ – функция извлечения уровня из источника s . Коэффициент давности определяется экспоненциальным затуханием:

$$d(t_s) = \exp(-\lambda \cdot \Delta t_s), \quad (7)$$

где Δt_s – время с момента получения данных (в месяцах); λ – параметр скорости затухания (в эксперименте $\lambda = 0,1$). Обоснование выбора весов источников представлено в Таблице 3.

Таблица 3 – Веса источников данных для агрегирования компетенций

Table 3 – Weights of data sources for competency aggregation

Источник данных	Вес w_s	Обоснование выбора веса
ЭИОС (академическая успеваемость)	0,30	Формальная верификация знаний [3]
Портфолио проектов	0,35	Демонстрация практических навыков [6]
Внешние сертификаты	0,20	Независимая оценка компетенций [7]
Стажировки и практики	0,15	Реальный профессиональный опыт [2]

Модель профессиональной роли. Для любой роли $r \in R$ строится матрица требований к компетенциям, описывающая целевой профиль выпускника – какие компетенции нужны и на каком уровне они должны быть сформированы. Такой способ задания целевых ориентиров согласуется с логикой проектирования индивидуальных маршрутов профессионального развития и позволяет привязать рекомендации к реальным требованиям ролей [4].

$$Q(r) = \{(k_i, L_{r,i})\}, \quad (8)$$

где $L_{r,i} \in \{\leftarrow, B, I, A\}$ – требуемый уровень компетенции k_i для роли r . Значение $\leftarrow$ означает, что компетенция не требуется. Общая структура матрицы требований и обозначения представлены в Таблице 4.

Таблица 4 – Общая структура матрицы требований для профессиональных ролей
Table 4 – General structure of the requirements matrix for professional roles

Компетенция	Роль 1	Роль 2	Роль 3	Роль 4
Профессиональная k ₁	П/С/Б/–	П/С/Б/–	П/С/Б/–	П/С/Б/–
Профессиональная k ₂	П/С/Б/–	П/С/Б/–	П/С/Б/–	П/С/Б/–
Отраслевая k ₃	П/С/Б/–	П/С/Б/–	П/С/Б/–	П/С/Б/–
Универсальная k ₄	П/С/Б/–	П/С/Б/–	П/С/Б/–	П/С/Б/–

Принятые в Таблице 4 обозначения расшифровываются так: П (Advanced, А) – ключевая компетенция, от сотрудника ожидается экспертное владение; С (Intermediate, I) – важная, но не ключевая компетенция, достаточно уверенного применения; Б (Basic, B) – вспомогательная компетенция, где хватает базового понимания; знак «–» ставится, если компетенция для этой роли не требуется вовсе.

Чтобы показать, что метод применим в разных отраслях, ниже приведены два примера заполнения такой матрицы – для IT-сферы (Таблица 5) и для инженерно-технической области (Таблица 6).

Таблица 5 – Пример матрицы требований для IT-ролей
Table 5 – Example of a requirements matrix for IT roles

Компетенция	Data Scientist	ML Engineer	Backend Dev	Аналитик
Машинное обучение (k ₁)	П	П	Б	С
Статистический анализ (k ₂)	П	С	–	П
Программирование Python (k ₃)	С	П	П	Б
Визуализация данных (k ₄)	С	Б	Б	П
Деловая коммуникация (k ₅)	С	Б	Б	П

Таблица 6 – Пример матрицы требований для инженерных ролей
Table 6 – Example of a requirements matrix for engineering roles

Компетенция	Конструктор	Технолог	Инженер КК	Руководитель проекта
CAD-проектирование (k ₁)	П	С	Б	Б
Технология обработки (k ₂)	С	П	С	Б
Метрология и контроль (k ₃)	Б	С	П	Б
Управление проектами (k ₄)	Б	Б	Б	П
Техническая документация (k ₅)	С	С	С	С

Из Таблиц 5 и 6 видно, что матрица требований хорошо отражает специфику каждой роли: в ней явно расставлены ключевые компетенции (уровень П), поддерживающие (уровень С) и базовые – те, без которых не обойтись даже начинающему специалисту (уровень Б).

Многоуровневый гар-анализ. Ядром всего метода служит гар-анализ, позволяющий в числовом выражении оценить, насколько профиль студента не дотягивает до требований выбранной роли. Диагностика дефицита по цифровому профилю и последующая выдача рекомендаций дают возможность опираться на данные при принятии решений в учебном процессе и управлять качеством подготовки [1, 10]. Дефицит по одной компетенции выражается так:

$$g_{u,r,i} = \max(0, L_{r,i} - L_{u,i}), \quad (9)$$

где $g_{u,r,i}$ – дефицит компетенции k_i для студента u относительно роли r ; $L_{r,i}$ – требуемый уровень; $L_{u,i}$ – текущий уровень студента. Интегральная оценка дефицита с учетом иерархии:

$$G(u, r) = \sum_j w_j \cdot \sum_i \alpha_i \cdot g_{u,r,i}, \quad (10)$$

где w_j – вес домена D_j ; α_i – вес критичности компетенции k_i (определяется экспертно или на основе частотного анализа вакансий). Нормированный показатель готовности (Readiness Index) к роли:

$$R(u, r) = \frac{1 - G(u, r)}{G_{\max}(r)}, \quad (11)$$

где $G_{\max}(r) = \sum_j w_j \cdot \sum_i \alpha_i \cdot 3$ – максимально возможный дефицит (при $L_{u,i} = 0$ для всех компетенций). Показатель $R(u, r) \in [0; 1]$ показывает, насколько профиль конкретного студента приближен к требованиям выбранной роли.

Гибридный рекомендательный алгоритм. Модель образовательных активностей. Пусть $A = \{a_1, a_2, \dots, a_k\}$ – набор доступных студенту учебных активностей: от дисциплин учебного плана до онлайн-курсов, проектных заданий и стажировок. Каждая активность описывается матрицей вклада в компетенции:

$$\Delta(a) = \{(k_i, \delta_{a,i}, L_{\text{target}})\}, \quad (12)$$

где $\delta_{a,i}$ – ожидаемый прирост уровня компетенции k_i после выполнения активности a ; L_{target} – целевой уровень после выполнения активности.

Контентная составляющая (контентная фильтрация). Контентная фильтрация оценивает, насколько та или иная активность полезна для закрытия имеющихся пробелов, – то есть сопоставляет вклад активности в компетенции с выявленным у студента дефицитом. Такой способ отбора хорошо известен в области рекомендательных систем и неплохо работает там, где есть описания контента и заранее заданные целевые признаки [2].

$$S_{\text{content}}(u, r, a) = \sum_i g_{u,r,i} \cdot \delta_{a,i} \cdot \alpha_i \cdot \theta(L_{u,i}, L_{\text{target}}), \quad (13)$$

где θ – функция совместимости уровней (level compatibility function):

$$\theta(L_{\text{curr}}, L_{\text{target}}) = \exp(-\gamma \cdot |L_{\text{target}} - (L_{\text{curr}} + 1)|), \quad (14)$$

где γ – параметр чувствительности (в эксперименте принято $\gamma = 1,0$). Функция θ построена так, что максимальный балл получают активности, соответствующие следующему по порядку уровню освоения, тем самым задается принцип постепенного наращивания компетенций.

Коллаборативная составляющая (коллаборативная фильтрация). Если в системе уже накоплена история прохождения активностей, имеет смысл подключить коллаборативную фильтрацию, которая переносит опыт похожих студентов на текущего пользователя. Такой учет поведенческих паттернов и цифрового следа повышает релевантность итоговых рекомендаций и делает модель более устойчивой к тому, что часть данных может отсутствовать [2, 7].

$$S_{\text{collab}}(u, a) = \sum_v \in N(u) \text{sim}(u, v) \cdot \text{outcome}(v, a), \quad (15)$$

где $N(u)$ – множество k ближайших соседей студента u ; $\text{sim}(u, v)$ – косинусная мера сходства профилей; $\text{outcome}(v, a) \in [0; 1]$ – результат прохождения активности a студентом v .

Интегральная скоринговая функция. Итоговая оценка складывается из двух составляющих – контентной и коллаборативной, – а их вклад регулируется настраиваемыми весами; благодаря этому удается держать баланс между точным соответствием целевым компетенциям и реальными траекториями, по которым идут живые студенты. Гибридные схемы такого рода обсуждаются как в отечественных обзорах, так и в прикладных работах по адаптивному обучению [2, 6].

$$S_{core}(u, r, a) = \lambda_1 \cdot S_{content} + \lambda_2 \cdot S_{collab} + \lambda_3 \cdot S_{rules} + \lambda_4 \cdot S_{pref}, \quad (16)$$

где $\lambda_1 + \lambda_2 + \lambda_3 + \lambda_4 = 1$; S_{rules} – бонусы/штрафы на основе правил; S_{pref} – учет предпочтений студента. Обоснование выбора весов: $\lambda_1 = 0,5$ (приоритет устранения дефицита), $\lambda_2 = 0,25$ (учет коллективного опыта), $\lambda_3 = 0,15$ (бизнес-правила), $\lambda_4 = 0,1$ (персональные предпочтения).

Алгоритм формирования траектории. По значениям скоринга выстраивается итоговая траектория $T(u, r)$. Подробная схема работы алгоритма приведена на Рисунке 3.

Работа алгоритма (Рисунок 3) разбита на следующие этапы: получение и проверка данных студента; извлечение признаков и их нормализация; параллельная обработка академических показателей, данных об активности и интересах; настройка модели с контролем точности (порог ассигасу $\geq 85\%$); подготовка рекомендаций по курсам и карьерным направлениям; ранжирование результатов по релевантности и фильтрация с учетом предпочтений; проверка уверенности в рекомендации (порог confidence $\geq 70\%$); наконец, сбор обратной связи и обновление профиля по ее итогам.

Экспериментальная валидация. *Параметры эксперимента.* Для проверки предложенного метода написана программа на Python с веб-интерфейсом на Flask, которая воспроизводит полный цикл построения индивидуального маршрута. В состав программы входят: иерархическая модель компетенций (4 домена, 25 компетенций); матрица требований для пяти профессиональных ролей IT-отрасли; база из 60 учебных активностей с описанным вкладом каждой из них в компетенции; программная реализация формул (6)–(16), используемых для gap-анализа и формирования рекомендаций.

В эксперимент вошли пять профессиональных ролей IT-отрасли: Data Scientist, ML Engineer, Backend Developer, аналитик данных и DevOps-инженер. Для каждой из них экспертным путем была составлена матрица требований по 25 компетенциям, распределенным между четырьмя доменами: профессиональным (10 компетенций), опережающим (5), отраслевым (5) и универсальным (5). База из 60 учебных активностей включает 20 дисциплин учебного плана, 18 онлайн-курсов, 12 проектных заданий и 10 стажировок и практик. Матрица вклада $\Delta(a)$ заполнялась экспертами на основе рабочих программ дисциплин и описаний курсов.

Модельная выборка из 100 студенческих профилей строилась так: исходные уровни компетенций $L(k)$ разыгрывались случайно по дискретному равномерному закону $U\{0, 3\}$; чтобы профиль выглядел правдоподобно, компетенции целевого домена с вероятностью 0,6 получали надбавку в +1 уровень. Давность подтверждения Δt задавалась равномерно в диапазоне от 0 до 24 месяцев. Целевая роль для каждого профиля также выбиралась случайным образом – из пяти имеющихся.

Так как в эксперименте использовались только синтетические данные и реальной истории прохождения активностей не было, коллаборативная составляющая S_{collab} (15) при выдаче рекомендаций не задействовалась ($\lambda_2 = 0$). Веса оставшихся компонентов были пропорционально перераспределены: $\lambda_1 = 0,67$, $\lambda_3 = 0,20$, $\lambda_4 = 0,13$. Проверку коллаборативной фильтрации планируется провести позднее – уже на реальных данных ЭИОС, в ходе апробации метода.




Рисунок 3 – Диаграмма активности гибридного рекомендательного алгоритма
Figure 3 – Activity diagram of the hybrid recommendation algorithm

Для оценки качества рекомендаций применялись две метрики: Coverage@k (какая доля дефицитных компетенций попадает в рекомендации) и расчетное сокращение суммарного дефицита (Gap Reduction), получаемое по итогам моделирования прохождения рекомендованных активностей. Чтобы показать выигрыш от предложенного подхода, проведено сравнение с двумя базовыми стратегиями (baseline): случайным подбором активностей (Random) и чисто контентной фильтрацией без функции совместимости уровней θ (Content-only).

Таблица 7 – Параметры эксперимента
Table 7 – Experiment Parameters

Параметр	Значение
Количество профилей студентов	100
Количество компетенций в модели	25
Количество образовательных активностей	60
Количество профессиональных ролей	5
Уровни сформированности	4 (0, B, I, A)
Топ-К рекомендаций	5
Коэффициент затухания λ (7)	0,1
Параметр чувствительности γ (14)	1,0
Веса гибридного алгоритма (16)	$\lambda_1 = 0,5, \lambda_2 = 0,25, \lambda_3 = 0,15, \lambda_4 = 0,1$

Результаты

Эксперимент был поставлен на 100 синтетических профилях студентов, различавшихся по начальному уровню сформированности компетенций. Для каждого профиля случайным образом выбиралась целевая роль, выполнялся гар-анализ и строились индивидуальные рекомендации. Сводные итоги сведены в Таблице 8.

Таблица 8 – Сводные результаты экспериментальной валидации
Table 8 – Summary results of experimental validation

Метрика	Значение	Описание
Coverage@5	$0,81 \pm 0,10$	Покрытие дефицитных компетенций рекомендациями топ-5
Gap Reduction	$46 \% \pm 7 \%$	Ожидаемое снижение интегрального дефицита
Readiness Index (до)	51 %	Средний индекс готовности R(u,r) до рекомендаций
Readiness Index (после)	76 %	После прохождения рекомендованных активностей
Улучшение (3-уровн. vs бинарн.)	+12 %	Преимущество трёхуровневой модели
Условия гар-анализа	100 %	Корректность математических условий

Из Таблицы 8 видно, что метод работает корректно: условия гар-анализа (9)–(11) выполняются во всех 100 % случаев. Значение Coverage = 0,81 означает, что рекомендации из топ-5 покрывают 81 % компетенций, по которым у студента есть

пробел. Расчетное снижение суммарного дефицита равно 46 %, а средний индекс готовности вырастает с 51 % до 76 % после прохождения рекомендованных активностей.

Сопоставление трехуровневой шкалы сформированности (4) с бинарной «сформировано / не сформировано» дало прирост Coverage в 12 процентных пунктов. Этот результат говорит о том, что детализированное описание уровней освоения имеет ощутимый практический эффект при формировании персонализированных рекомендаций.

Чтобы оценить эффективность гибридного алгоритма, в качестве ориентиров были взяты два базовых варианта (baseline): случайный подбор активностей и чисто контентная фильтрация без функции совместимости уровней θ . Итоги сравнения сведены в Таблице 9.

Таблица 9 – Сравнение с базовыми стратегиями рекомендаций

Table 9 – Comparison with baseline recommendation strategies

Стратегия	Coverage@5	Gap Reduction	R(u,r) после
Random (случайный выбор)	0,43 ± 0,15	19 % ± 9 %	59 %
Content-only (без θ)	0,68 ± 0,12	34 % ± 8 %	68 %
Предложенный метод	0,81 ± 0,10	46 % ± 7 %	76 %

Из Таблицы 9 следует, что разрыв по Coverage между предложенным методом и случайным выбором составил 0,38 (0,81 против 0,43), а относительно стратегии Content-only – 0,13 (0,81 против 0,68). По критерию Уилкоксона оба различия статистически значимы ($p < 0,001$, $n = 100$). Проверка по критерию Уилкоксона на синтетических данных используется только для относительного сравнения моделей и не рассматривается как подтверждение статистического эффекта в реальных данных. Показатель Gap Reduction вырос с 19 % при случайном выборе и 34 % при стратегии Content-only до 46 %, что указывает на самостоятельный вклад функции совместимости уровней θ и многоуровневого гар-анализа в итоговое качество рекомендаций.

Отдельно была проверена чувствительность результата к ключевым параметрам. При изменении параметра γ (14) в диапазоне от 0,5 до 2,0 значение Coverage держится в пределах 0,77–0,83; оптимум достигается при $\gamma = 1,0$, где удается найти приемлемый компромисс между точностью и полнотой рекомендаций. Варьирование коэффициента затухания λ (7) в интервале от 0,05 до 0,2 влияет на результат умеренно – Coverage меняется лишь в диапазоне 0,79–0,82, что говорит об устойчивости метода к выбору этого параметра.

Функция совместимости уровней θ (14) выводит вперед те активности, которые соответствуют текущему уровню подготовки студента; тем самым в работе алгоритма фактически реализуется принцип последовательного наращивания компетенций, и это положительно сказывается на качестве итоговых рекомендаций.

Прототип реализован на Python 3.12 с применением веб-фреймворка Flask и библиотек NumPy и Pandas – последние две используются для численных расчетов. Веб-интерфейс написан на HTML5, CSS3 и JavaScript и выполняет следующие функции: визуализирует иерархическую модель компетенций; обеспечивает интерактивный ввод профиля студента; позволяет выбрать целевую профессиональную роль; отображает результаты гар-анализа в наглядной форме; показывает список рекомендованных учебных активностей с присвоенной оценкой Score; наконец, дает возможность запустить экспериментальную проверку с разными настройками параметров (Рисунки 4–6).

Метод персонификации траектории профессионального развития студента
на основе анализа гетерогенных данных | Экспериментальная программа валидации метода

Гетерогенные данные | Профиль студента | Эксперимент | Модель компетенций | Математический аппарат

Источники гетерогенных данных
Структура данных цифрового профиля студента

Полуструктурированные данные

Данные с частичной формализацией

- Сертификаты
Внешние сертификации и курсы $w = 0.75$
- Соревнования и олимпиады
Участие в хакатонах, олимпиадах $w = 0.9$
- Практика и стажировки
Производственная практика $w = 0.95$
- Проектная деятельность
Участие в учебных и научных проектах $w = 0.85$

Демонстрация агрегирования
Формула (6): $L = \sum w \cdot d(u, k_i)$

Выберите компетенцию для демонстрации:
ПК-1: Алгоритмизация и структуры данных

Источники данных: Уровень: Давность:

Сертификаты	2 (l)	9	×
Сертификаты	2 (l)	10	×
Сертификаты	2 (l)	8	×

+ Добавить источник данных

Рассчитать агрегированный уровень

Рисунок 4 – Интерфейс экспериментальной программы: иерархическая модель компетенций и профиль студента

Figure 4 – Interface of the experimental software: hierarchical competency model and student profile

Метод персонификации траектории профессионального развития студента
на основе анализа гетерогенных данных | Экспериментальная программа валидации метода

Гетерогенные данные | Профиль студента | Эксперимент | Модель компетенций | Математический аппарат

Экспериментальная валидация метода
Параметры эксперимента (Таблица 7)

Количество профилей:	Топ-K рекомендаций:	Компетенций в модели:	Образовательных активностей:
100	5	25	60
Источников данных:	Профессиональных ролей:	Коэффициент затухания λ :	Параметр γ :
12	5	0.1	1.0

Запустить эксперимент с гетерогенными данными

0.52
Coverage@5

58%
Gap Reduction

+775%
Улучшение (3-уровн.)

100%
Условия gap-анализа

Рисунок 5 – Интерфейс экспериментальной программы: результаты gap-анализа

Figure 5 – Interface of the experimental software: results of gap analysis

Сводные результаты (Таблица 8)
Метрики качества рекомендаций

Метрика	Значение	Std	Описание
Coverage@5	0.52	± 0.102	Покрытие дефицитных компетенций
Gap Reduction	58%	$\pm 7\%$	Снижение интегрального дефицита
Readiness (до)	48%	—	Индекс готовности до рекомендаций
Readiness (после)	78%	—	Индекс готовности после рекомендаций
Среднее источников	12	—	Источников данных на студента
Улучшение (3-уровн.)	+775%	—	Преимущество трёхуровневой модели
Условия gap-анализа	100%	—	Корректность математических условий

Рисунок 6 – Интерфейс экспериментальной программы: рекомендованные образовательные активности

Figure 6 – Interface of the experimental software: recommended educational activities

У предложенного метода есть ряд преимуществ перед тем, что предлагается в существующих подходах (Таблица 1).

Иерархическое представление компетенций дает гибкость в настройке под разные профессиональные сферы. Это удалось показать на примерах как IT-ролей (Таблица 5), так и инженерных специальностей (Таблица 6).

Введение трехуровневой шкалы позволяет учитывать не только факт наличия компетенции, но и степень ее практического освоения, а это напрямую влияет на точность диагностики и качество рекомендаций. Прирост Coverage в 12 процентных пунктов (Таблица 8) подтверждает, что такая детализация не является избыточной.

Гибридная архитектура алгоритма позволяет совмещать контентную и коллаборативную составляющие, за счет чего качество рекомендаций остается приемлемым даже при ограниченном объеме исторических данных.

Ограничения исследования

Следует отметить несколько ограничений работы. Во-первых, веса источников (Таблица 3) и параметры алгоритма нуждаются в настройке под конкретную предметную область. Во-вторых, метод пока не учитывает ни временные возможности самого студента, ни реальную доступность активностей как образовательных ресурсов. В-третьих, проверка проведена на синтетических данных; коллаборативная составляющая (15) не оценивалась, поскольку реальной истории прохождения активностей не было. Апробация метода на данных ЭИОС намечена как следующий шаг исследования.

Экспериментальная проверка выполнена на синтетической выборке, сформированной по заданным правилам генерации компетенций. Такая выборка позволяет проверить внутреннюю согласованность математической модели и корректность работы алгоритма, однако не воспроизводит в полной мере реальные зависимости между компетенциями, влияние предшествующего обучения и особенности поведения обучающихся. Поэтому полученные количественные показатели следует рассматривать как результаты модельного эксперимента, а не как оценку эффективности метода в реальной образовательной среде.

Заключение

В работе изложен метод персонификации образовательных маршрутов, состоящий из следующих компонентов: иерархической модели компетенций с трехуровневой шкалой сформированности (Таблица 2); механизма агрегирования компетенций из нескольких источников с обоснованием весов (Таблица 3); универсальной матрицы требований к профессиональным ролям с примерами для IT и инженерной сферы (Таблицы 4–6); многоуровневого гар-анализа с численной оценкой дефицита; а также гибридного рекомендательного алгоритма, параметры которого выбраны с обоснованием (Рисунок 3).

Экспериментальная проверка (Таблицы 7–9) подтвердила работоспособность метода: Coverage = 0,81, сокращение суммарного дефицита – 46 %, прирост качества от перехода к трехуровневой шкале – 12 процентных пунктов. Сравнение с базовыми стратегиями (Таблица 9) показало статистически значимое ($p < 0,001$) преимущество предложенного подхода.

Перспективы развития. интеграция механизмов интерпретируемого объяснения выдаваемых рекомендаций; расширение анализа неструктурированных данных портфолио за счет методов обработки естественного языка и автоматизированного извлечения признаков из текстовых и проектных артефактов.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Клишин А.П., Власов Д.В., Лысков А.А. Поддержка принятия решений в учебном процессе вуза на основе когнитивной модели обучения с использованием нейронной сети. *Вестник НГУ. Серия: Информационные технологии*. 2024;22(4):33–48. <https://doi.org/10.25205/1818-7900-2024-22-4-33-48>
Klishin A.P., Vlasov D.V., Lyskov A.A. Decision Support in the Educational Process of the University based on a Cognitive Learning Model using a Neural Network. *Vestnik NSU. Series: Information Technologies*. 2024;22(4):33–48. (In Russ.). <https://doi.org/10.25205/1818-7900-2024-22-4-33-48>
2. Архипова З.В., Сорокин А.В. Анализ подходов к созданию рекомендательных систем в сфере предоставления образовательных услуг. *System analysis & Mathematical modeling*. 2024;6(2):133–145. [https://doi.org/10.17150/2713-1734.2024.6\(2\).133-145](https://doi.org/10.17150/2713-1734.2024.6(2).133-145)
Arkhipova Z.V., Sorokin A.V. Analysis of approaches to the development of recommendation systems in the field of education. *System analysis & Mathematical modeling*. 2024;6(2):133–145. (In Russ.). [https://doi.org/10.17150/2713-1734.2024.6\(2\).133-145](https://doi.org/10.17150/2713-1734.2024.6(2).133-145)
3. Качурин Н.С. Концепция метода персонификации траектории профессионального развития обучающихся в образовательной среде вуза. *Волгоградский государственный технический университет*. 2024;136–137.
4. Худжина М.В., Каракозов С.Д. Дидактическая модель обеспечения конкурентоспособности выпускника вуза на региональном рынке труда (на примере подготовки выпускников ИТ-направлений). *Преподаватель XXI век*. 2023;(3):20–33. <https://doi.org/10.31862/2073-9613-2023-3-20-33>
Khudzhina M.V., Karakozov S.D. Ensuring Competitive Advantages of University Graduates in the Regional Labor Market: A Didactic Model (On the Example of Training IT Graduates). *Prepodavatel XXI vek*. 2023;(3):20–33. (In Russ.). <https://doi.org/10.31862/2073-9613-2023-3-20-33>
5. Качурин Н.С. Исследование и анализ проблем в области учета научных и учебных достижений студентов. В сборнике: *Волжский – территория развития: Материалы XXIX Межвузовской научно-практической конференции студентов и молодых ученых, посвященной 70-летию города Волжского, 13–23 мая 2024 года, Волжский, Россия*. Волгоград: Волгоградский государственный технический университет; 2024. С. 36.
6. Подколзин М.М. Интеллектуальная система адаптивного обучения на основе нейронных сетей для персонализации образовательных траекторий студентов российских вузов. *Информатика и образование*. 2024;39(6):65–81. <https://doi.org/10.32517/0234-0453-2024-39-6-65-81>
Podkolzin M.M. Intelligent adaptive learning system based on neural networks for personalization of educational trajectories of Russian university students. *Informatics and Education*. 2024;39(6):65–81. (In Russ.). <https://doi.org/10.32517/0234-0453-2024-39-6-65-81>
7. Логинова Е.Г., Денисов Н.Л. Использование алгоритмов Process Mining для выявления паттернов поведения студентов. *Вестник Астраханского государственного технического университета. Серия: Управление, вычислительная техника и информатика*. 2024;(3):75–84. <https://doi.org/10.24143/2072-9502-2024-3-75-84>
Loginova E.G., Denisov N.L. Using Process Mining algorithms to identify patterns of student behavior. *Vestnik of Astrakhan State Technical University. Series: Management,*

- Computer Science and Informatics*. 2024;(3):75–84. (In Russ.). <https://doi.org/10.24143/2072-9502-2024-3-75-84>
8. Пустовалова Н.В. Онтологическая модель процесса взаимодействия образовательного контента и обучаемого в архитектуре интеллектуальных обучающих систем. *Вестник Астраханского государственного технического университета. Серия: Управление, вычислительная техника и информатика*. 2021;(4):113–125. <https://doi.org/10.24143/2072-9502-2021-4-113-125>
Pustovalova N.V. Ontological model of interaction between educational content and learner in intelligent tutorial system architecture. *Vestnik of Astrakhan State Technical University. Series: Management, Computer Science and Informatics*. 2021;(4):113–125. (In Russ.). <https://doi.org/10.24143/2072-9502-2021-4-113-125>
 9. Частикова В.А., Псеуш А.Г. Применение алгоритмов роевого интеллекта в процессе построения индивидуальных образовательных траекторий. *Вестник АГУ*. 2022;2(301). <https://doi.org/10.53598/2410-3225-2022-2-301-84-90>
Chastikova V.A., Pseush A.G. Application of swarm intelligence algorithms in the process of building individual educational trajectories. *Bulletin of the Adyghe State University*. 2022;2(301). (In Russ.). <https://doi.org/10.53598/2410-3225-2022-2-301-84-90>
 10. Закиева Р.Р. Модель управления качеством образования, основанная на непрерывной объективной оценке профессионального развития студента технического университета. *Современные наукоемкие технологии*. 2023;(2):144–148. <https://doi.org/10.24143/2072-9502-2023-2-144-148>
Zakieva R.R. Model of educational quality management based on continuous objective assessment of professional development of a technical university student. *Modern High Technologies*. 2023;(2):144–148. (In Russ.). <https://doi.org/10.24143/2072-9502-2023-2-144-148>

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Качурин Никита Станиславович, магистрант Волгоградский государственный технический университет, Волгоград, Российская Федерация. **Nikita S. Kachurin**, Master's Degree student, Volgograd State Technical University, Volgograd, the Russian Federation.
e-mail: ka4urin.nik@yandex.ru

Кравец Алла Григорьевна, доктор технических наук, профессор, Волгоградский государственный технический университет, Волгоград, Российская Федерация. **Alla G. Kravets**, Doctor of Engineering Sciences, Professor, Volgograd State Technical University, Volgograd, the Russian Federation.
e-mail: allagkravets@yandex.ru
ORCID: [0000-0003-1675-8652](https://orcid.org/0000-0003-1675-8652)

Андреев Виктор Сергеевич, магистрант, Волгоградский государственный технический университет, Волгоград, Российская Федерация. **Victor S. Andreev**, Master's Degree student, Volgograd State Technical University, Volgograd, the Russian Federation.
e-mail: viktormoonwell123@yandex.ru

Статья поступила в редакцию 29.04.2026; одобрена после рецензирования 06.07.2026; принята к публикации 17.07.2026.

The article was submitted 29.04.2026; approved after reviewing 06.07.2026; accepted for publication 17.07.2026.