

**А. В. Каляшина, Ю. Н. Смирнов**

## **ИНФОРМАЦИОННАЯ СИСТЕМА УПРАВЛЕНИЯ ТЕКУЧЕСТЬЮ ПЕРСОНАЛА С ПРИМЕНЕНИЕМ ТЕХНОЛОГИЙ МАШИННОГО ОБУЧЕНИЯ (НА ПРИМЕРЕ ОАО «РЖД»)**

*Ключевые слова: математическая модель, нейронная сеть, машинное обучение, HR-специалист.*

*Данное исследование посвящено актуальной теме – потребности предприятий в технологиях предиктивной аналитики для управления текучестью персонала. Ручной анализ кадровых отчетов требует значительных временных затрат, зависит от опыта HR-специалистов и подвержен риску субъективных ошибок. Интеллектуальные системы на основе моделей глубокого обучения позволяют выполнять прогнозирование индивидуальных и групповых рисков увольнений, выявлять ключевые факторы и формировать рекомендации по retention, повышая точность планирования и оперативность реагирования. Объектом исследования является процесс управления текучестью персонала в ОАО «РЖД». Предмет исследования – методы и алгоритмы машинного обучения, применяемые для предиктивного анализа табличных кадровых данных. Целью исследования – разработка интеллектуальной подсистемы прогнозирования рисков текучести кадров и формирования рекомендаций по их снижению, предназначенной для помощи HR-специалистам и руководителям филиалов. Для достижения поставленной цели проведен анализ деятельности объекта исследования, состава и структуры действующей информационной системы, а также перспектив использовать технологий искусственного интеллекта. Проектируемая подсистема предназначена для поддержки HR-специалистов и руководителей и не заменяет их решения: финальная ответственность полностью остаётся на специалисте. Подсистема должна загружать данные из существующей информационной системы, рассчитывать индивидуальные и групповые риски увольнений с помощью модели TabNet, выделять ключевые факторы риска, генерировать targeted рекомендации и формировать структурированные отчёты. Результаты интегрируются в ЕК-АСУТР и корпоративные дашборды для последующего анализа. В качестве интеллектуального решения использован TabNet – глубокая нейронная сеть, специально разработанная для табличных данных. TabNet использует последовательный механизм внимания (sequential attention), позволяющий на каждом шаге решения динамически выбирать наиболее информативные признаки. Это обеспечивает разреженное использование признаков и повышает обобщающую способность модели. Обучение нейронной сети проводилось на историческом наборе кадровых данных из ЕК-АСУТР ОАО «РЖД» за период 2015-2024 годов, предназначенном для решения задачи бинарной классификации риска увольнения сотрудника в ближайшие 12 месяцев. Проведена оценка эффективности внедрения подсистемы, подтверждающая оптимизацию HR-процессов, сокращение времени анализа (на 70-80%) и повышение точности прогнозов.*

**A. V. Kalyashina, Yu. N. Smirnov**

## **AN INFORMATION SYSTEM FOR MANAGING PERSONNEL TURNOVER USING MACHINE LEARNING TECHNOLOGIES (USING RUSSIAN RAILWAYS AS AN EXAMPLE)**

*Keywords: mathematical model, neural network, machine learning, HR specialist.*

*This study examines a pressing issue: companies' need for predictive analytics technologies to manage employee turnover. Manual analysis of HR reports is time-consuming, relies on the experience of HR specialists, and is susceptible to human error. Intelligent systems based on deep learning models can predict individual and group layoff risks, identify key factors, and generate retention recommendations, improving planning accuracy and response times. This study focuses on employee turnover management at Russian Railways. It also examines machine learning methods and algorithms used for predictive analysis of tabular HR data. The objective of the study is to develop an intelligent subsystem for predicting employee turnover risks and generating recommendations for mitigation, designed to assist HR specialists and branch managers. To achieve this goal, we analyzed the operations of the research facility, the composition and structure of the existing information system, and the prospects for using artificial intelligence technologies. The designed subsystem is intended to support HR specialists and managers and does not replace their decisions: final responsibility remains entirely with the specialist. The subsystem is designed to load data from an existing information system, calculate individual and group layoff risks using the TabNet model, identify key risk factors, generate targeted recommendations, and generate structured reports. The results are integrated into EK-ASUTR and corporate dashboards for subsequent analysis. TabNet, a deep neural network specifically designed for tabular data, is used as the intelligent solution. TabNet uses a sequential attention mechanism, which dynamically selects the most informative features at each decision step. This ensures sparse use of features and increases the generalization ability of the model. The neural network was trained using a historical dataset of HR data from the EK-ASUTR of JSC Russian Railways for the period 2015-2024, designed to solve the problem of binary classification of the risk of employee dismissal within the next 12 months. An assessment of the subsystem's implementation effectiveness was conducted, confirming the optimization of HR processes, a reduction in analysis time (by 70-80%), and an increase in forecast accuracy.*

### **Введение**

Цифровизация транспортной отрасли делает автоматизацию процессов управления персоналом ключевым фактором повышения эффективности и устойчивости

человеческого капитала. Рост текучести кадров, дефицит квалифицированных специалистов в удалённых регионах и необходимость оптимизации затрат на подбор и обучение требуют внедрения интеллектуальных систем, способных прогнозировать

риски увольнений и поддерживать принятие управленческих решений [1].

Актуальность выбранной темы определяется потребностью ОАО «РЖД» в технологиях предиктивной аналитики для управления текучестью персонала. Ручной анализ отчётов из Единой корпоративной автоматизированной системы управления трудовыми ресурсами (ЕК-АСУТР) требует значительного времени, зависит от опыта специалистов и подвержен риску субъективных ошибок. Интеллектуальные системы на основе моделей глубокого обучения позволяют выполнять прогнозирование индивидуальных и групповых рисков увольнений, выявлять ключевые факторы и формировать рекомендации по удержанию сотрудников (retention), повышая точность планирования и оперативность реагирования [2].

Объектом исследования является процесс управления текучестью персонала в ОАО «РЖД».

Предмет исследования - методы и алгоритмы машинного обучения, применяемые для предиктивного анализа табличных кадровых данных.

Целью данной работы является разработка интеллектуальной подсистемы прогнозирования рисков текучести кадров и формирования рекомендаций по их снижению, предназначенной для помощи HR-специалистам и руководителям филиалов.

Для достижения поставленной цели решены следующие задачи:

- проанализировать особенности управления текучестью кадров и современные технологии предиктивной аналитики;
- исследовать математические модели и методы обработки табличных данных с применением технологий глубокого обучения;
- разработать архитектуру и программный прототип интеллектуальной информационной (ИИ)-подсистемы с интеграцией в ЕК-АСУТР;
- создать веб-интерфейс для аналитики;
- провести экспериментальную оценку точности работы созданного решения.

Практическая значимость работы заключается в возможности использования разработанной подсистемы как инструмента поддержки принятия управленческих решений. Внедрение подобного решения сокращает время анализа текучести, снижает риск потери ключевых сотрудников и облегчает планирование штата, повышая итоговую эффективность управления человеческим капиталом в холдинге.

### **Структура существующей информационной системы**

Существующая интегрированная интеллектуальная информационная система (ИИИС) представляет собой комплекс взаимосвязанных подсистем, обеспечивающих цифровую поддержку всех основных транспортных, административных, финансовых и HR-процессов. Каждая подсистема включена в единую архитектуру и функционирует на основе отраслевых стандартов, таких как СТО РЖД по информационной безопасности и Стратегия цифровой трансформации до 2025 года. Система развивается на 8

платформах: пассажирские перевозки (автоматизация билетов и расписаний), грузовые перевозки (мониторинг грузов через IoT), логистика (оптимизация маршрутов с ИИ), инфраструктура (компьютерное зрение для путей), тяга (управление локомотивами), транспорт (интеграция с внешними системами), корпоративные функции (включая HR и финансы), а также безопасность и аналитика.

В состав ИИИС входят следующие подсистемы:

Транспортная подсистема;

Логистическая подсистема;

Инфраструктурная подсистема;

Финансово-расчетная подсистема;

Подсистема аналитики и отчетности;

Подсистема обеспечения информационной безопасности.

В ОАО «РЖД» на 2025 год технологии искусственного интеллекта в HR-процессах используются ограниченно [3]. ЕК-АСУТР обеспечивает базовый учёт и аналитику, однако автоматизированного предиктивного анализа рисков увольнений нет. Анализ текучести проводится ретроспективно, что повышает зависимость от ручного труда HR-специалистов и не позволяет оперативно реагировать на риски (например, в регионах с высокой сменностью) [4].

Отсутствие систем автоматического прогнозирования исключает «второе мнение» на основе данных, усложняет планирование retention и не позволяет автоматически выделять сотрудников в группы риска. Сравнение динамики текучести по филиалам проводится визуально, без количественных моделей [5].

В рамках стратегии цифровой трансформации предполагается внедрение ИИ-систем машинного обучения, интегрированных с ЕК-АСУТР и обученных на исторических данных компании. Пилотные проекты в транспортной отрасли показывают снижение текучести на 15-25%, повышение точности прогнозов до 88-92% и сокращение времени анализа с дней до минут [2],[6].

Анализ деятельности ОАО «РЖД» показал, что действующий процесс управления текучестью персонала имеет серьёзные ограничения: специалисты HR-служб вручную анализируют отчёты из ЕК-АСУТР, выявляют группы риска и формируют рекомендации. Такой подход увеличивает нагрузку на персонал, удлиняет время планирования штата и создаёт риск несвоевременного реагирования на угрозы увольнений квалифицированных сотрудников. Использование технологий машинного обучения позволяет автоматизировать часть аналитических операций и повысить качество принятия решений [7].

### **Структура проектируемой подсистемы «Управление текучестью персонала»**

Проектируемая подсистема «Управление текучестью персонала» предназначена для поддержки HR-специалистов и руководителей филиалов и не заменяет их решения: финальная ответственность полностью остаётся на специалисте. Подсистема должна загружать данные из ЕК-АСУТР, рассчитывать индивидуальные и групповые риски увольнений с помощью интеллектуальной модели TabNet [8], выделять



- стандартизация процессов: система генерирует единообразные отчёты и рекомендации, что повышает качество документации и сравнимость данных по филиалам.

- формирование обучающей базы: накопление размеченных случаев (прогноз + фактическое увольнение) создаёт ресурс для дообучения модели и обучения новых HR-специалистов.

### Разработка подсистемы «Управление текучестью персонала»

Подсистема «Управление текучестью персонала» разрабатывается как специализированный модуль, предназначенный для интеграции с существующей Единой корпоративной автоматизированной системой управления трудовыми ресурсами (ЕК-АСУТР) ОАО «РЖД» [11]. Основная цель подсистемы – автоматизация процессов анализа, прогнозирования и управления текучестью кадров, что позволит снизить уровень оборота персонала, оптимизировать затраты на массовый подбор и обучение, а также повысить эффективность использования человеческого капитала в условиях регионального дефицита квалифицированных специалистов (машинистов, инженеров, путевых рабочих).

Подзадачи для решения:

Автоматизированный сбор и предобработка данных о сотрудниках из ЕК-АСУТР (личные дела, табели учета рабочего времени, данные об увольнениях, результаты опросов мотивации, графики смен).

Анализ текущей структуры и динамики текучести кадров по различным срезам: филиалы (16 железных дорог), специальности, возрастные группы, регионы, причины увольнений.

Прогнозирование индивидуальных и групповых рисков увольнений на горизонте 3-12 месяцев с учетом факторов (стаж, зарплата, условия труда, мотивация).

Сегментация сотрудников по уровням риска и формирование targeted рекомендаций по retention (программы обучения, корректировка графиков, мотивационные меры).

Визуализация результатов анализа в интерактивных дашбордах для руководителей HR-служб и филиалов, с возможностью экспорта отчетов.

Практическая значимость подсистемы заключается в снижении прямых затрат на найм, сохранении ключевых компетенций, повышении лояльности персонала и соответствии стратегическим документам РЖД, включая Программу развития человеческого капитала до 2025 года и Стратегию цифровой трансформации до 2030 года [2], [12]. Внедрение позволит перейти от реактивного (анализ после увольнений) к proactive управлению текучестью, интегрируя данные ЕК-АСУТР с аналитическими инструментами.

Организационно-логическая сущность решения задачи описывает последовательность выполнения операций в процессе прогнозирования укомплектованности персонала. Для визуализации используется нотация BPMN 2.0, позволяющая наглядно представить текущий процесс и оптимизированный процесс после внедрения интеллектуальной подсистемы [13].

### Нейросетевая модель решения задачи и технологий ИИ

Решение задачи автоматического анализа текучести кадров основано на методах глубокого обучения, специально адаптированных для табличных данных, позволяющих извлекать сложные нелинейные зависимости между признаками без ручного проектирования признаков. Для прогнозирования рисков увольнений и интерпретации факторов используется архитектура TabNet, где последовательный механизм внимания обеспечивает динамический выбор наиболее информативных признаков на каждом шаге принятия решения. Это позволяет модели имитировать поведение деревьев решений, но с преимуществами нейронных сетей – высокой точностью и встроенной интерпретируемостью [14].

TabNet – глубокая нейронная сеть, специально разработанная для табличных данных. TabNet использует последовательный механизм внимания (sequential attention), позволяющий на каждом шаге решения динамически выбирать наиболее информативные признаки. Это обеспечивает разреженное использование признаков и повышает обобщающую способность модели [15].

Процесс принятия решения в TabNet состоит из  $N$  шагов. На каждом шаге  $d$  вычисляется маска внимания  $M_d$ , определяющая, какие признаки будут использованы:

$$M_d = \text{sparsemax} \left( W_d \cdot \text{ReLU}(BN(a_d)) \right),$$

где  $a_d$  – выход предыдущего attention-блока;  $BN$  – пакетная нормализация (Batch Normalization);  $W_d$  – обучаемые веса;  $\text{sparsemax}$  – функция активации, обеспечивающая разреженность (многие элементы маски равны нулю).

Затем выбранные признаки обрабатываются в блоке принятия решения с использованием Gated Linear Unit (GLU):

$$h_d = \text{GLU}(FC(M_d \odot f(x))),$$

где  $f(x)$  – предварительно преобразованные признаки (с общими shared-слоями);  $\odot$  – поэлементное умножение (Hadamard product);  $FC$  – полносвязный слой.

Итоговый прогноз формируется агрегацией вкладов всех шагов:

$$\hat{y} = \sigma \left( \sum_{d=1}^N h_d \right),$$

где  $\sigma$  – сигмоида для бинарной классификации (риск увольнения: 0/1) или линейный выход для регрессии вероятности.

Для обеспечения разреженности и предотвращения переобучения добавляется регуляризационный член потери:

$$L_{\text{sparse}} = -\lambda_{\text{sparse}} \sum_{d=1}^N (N - d + 1) \sum_{i=1}^F M_d[i] \log(M_d[i] + \epsilon),$$

где  $\lambda_{\text{sparse}}$  – коэффициент регуляризации разреженности;  $F$  – общее количество признаков; коэффициент  $(N - d + 1)$  усиливает штраф для ранних шагов.

Обучение модели осуществляется методом обратного распространения ошибки с минимизацией комбинированной функции потерь (кросс-энтропия + разреженность):

$$L = L_{\text{CE}} + L_{\text{sparse}},$$

где кросс-энтропия для бинарной классификации:

$$L_{CE} = -\frac{1}{m} \sum_{i=1}^m [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)]$$

Оптимизация выполняется алгоритмом AdamW с адаптивной скоростью обучения и weight decay для регуляризации весов сети.

Особенностью TabNet является встроенная интерпретируемость: глобальная важность признака вычисляется как сумма масок по всем шагам и примерам:

$$\text{Global Importance}[j] = \frac{1}{m \cdot N} \sum_{i=1}^m \sum_{d=1}^N M_d^{(i)}[j]$$

а локальная – для каждого конкретного сотрудника, что позволяет объяснить, почему модель присвоила высокий риск увольнения (например, комбинация «низкая зарплата + сменный график + удалённый регион»).

Технологическая реализация подсистемы основана на использовании фреймворка PyTorch и библиотеки pytorch-tabnet, обеспечивающих эффективное распараллеливание вычислений на GPU и гибкость в настройке архитектуры. Предобработка данных включает нормализацию числовых признаков к диапазону [0, 1] или стандартизацию, кодирование категориальных переменных через встроенные эмбединги TabNet и обработку пропусков (mean/mode imputation). Для борьбы с дисбалансом классов (увольнения составляют менее 10%) применяется взвешивание потери или техника oversampling.

Математическая основа работы включает операции последовательного внимания для формирования разреженных масок признаков, Gated Linear Units (GLU) для нелинейной обработки выбранных признаков и регуляризацию разреженности для предотвращения переобучения. Вероятностный вывод осуществляется с помощью сигмоиды на агрегированном выходе всех шагов, а обучение модели выполняется методом обратного распространения ошибки с минимизацией комбинированной функции потерь (кросс-энтропия + разреженность) и оптимизатором AdamW.

Для сегментации сотрудников по группам риска и генерации рекомендаций применяется постобработка результатов TabNet, включая кластеризацию

(k-means) на основе вероятностей и важности признаков. Встроенная интерпретируемость модели (глобальная и локальная важность признаков) позволяет сохранять прозрачность прогнозов, что особенно важно при работе с персональными данными и принятии управленческих решений.

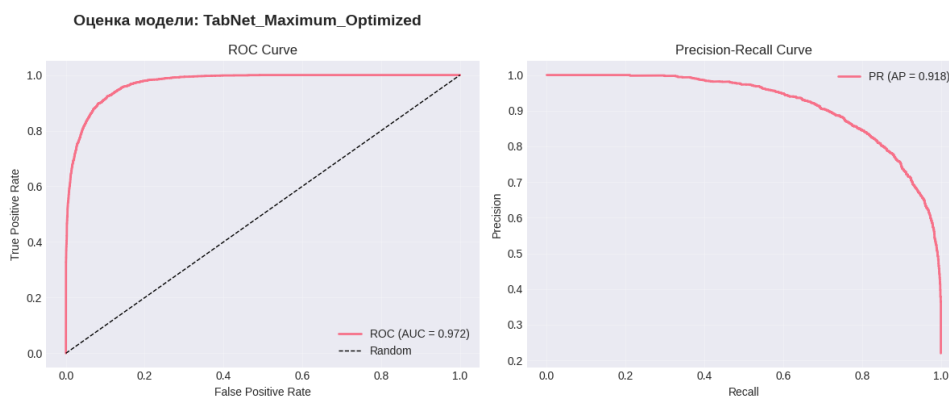
Обучение нейронной сети проводилось на историческом наборе кадровых данных из ЕК-АСУТР ОАО «РЖД» за период 2015-2024 годов, предназначенном для решения задачи бинарной классификации риска увольнения сотрудника в ближайшие 12 месяцев. В качестве базовой архитектуры была выбрана модель TabNet с предобученными эмбедингами, что позволило эффективно использовать сложные взаимодействия признаков и сократить время сходимости модели на табличных данных большого объёма.

Обучение проводилось в течение 325 эпох с использованием графического ускорителя. Для повышения вычислительной эффективности применялось обучение со смешанной точностью (Mixed Precision Training), что позволило сократить время обучения и снизить потребление видеопамяти. Дополнительно использовалось ограничение нормы градиента и Early Stopping по метрике AUC на валидационной выборке (patience=10).

В качестве основной метрики качества классификации использовалась площадь под ROC-кривой (AUC-ROC), вычисляемая для бинарной задачи риска увольнения. Данная метрика устойчива к дисбалансу классов и широко применяется в задачах предиктивной аналитики персонала. Дополнительно анализировались значения функции потерь, Precision-Recall AUC и F1-мера на валидационной выборке.

На рисунке 2 представлена ROC-кривая модели с AUC = 0.972. Кривая значительно превосходит диагональ случайного классификатора, подтверждая эффективность выбранной архитектуры TabNet.

На том же рисунке справа показана Precision-Recall кривая с AP = 0.918, демонстрирующая хороший баланс между точностью и полнотой, особенно важный в условиях несбалансированной выборки (класс увольнений менее представлен).



**Рис. 2 - ROC-кривая и Precision-Recall кривая модели TabNet\_Maximum\_Optimized**  
**Fig. 2 - ROC curve and Precision-Recall curve of the TabNet\_Maximum\_Optimized model**

На рисунке 3 приведена матрица ошибок (Confusion Matrix) на тестовом наборе. Модель правильно классифицировала 8972 случая «Останется» (True Negative) и 2116 случаев «Уволится» (True Positive). Ложноотрицательных ошибок (пропущенные увольнения) - 522, ложноположительных (ошибочно предсказанные увольнения) - 390. Соотношение ошибок приемлемо для задачи прогнозирования текучести и позволяет руководителям HR сосредоточиться на реальных группах риска без значительного перерасхода ресурсов на ложные сигналы.

Анализ графиков демонстрирует устойчивую сходимость модели и отсутствие выраженного переобучения, что подтверждает корректный выбор архитектуры TabNet, функции потерь и стратегии обучения.

В ходе обучения осуществлялось сохранение модели с наилучшим значением метрики AUC-ROC на валидационной выборке. Полученная модель в дальнейшем используется для тестирования и интеграции в состав интеллектуальной подсистемы поддержки принятия управленческих решений по управлению текучестью персонала в ОАО «РЖД».

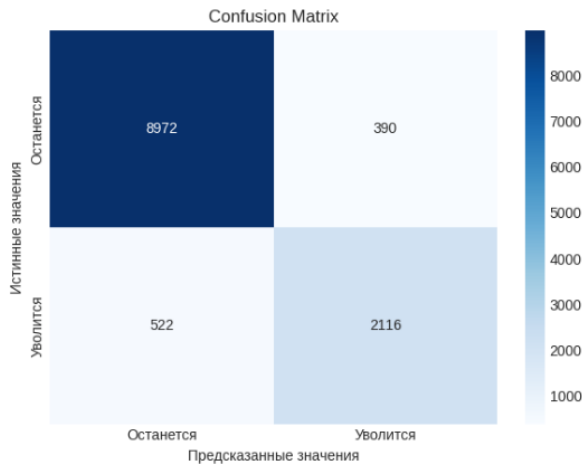


Рис. 3 - Матрица ошибок модели TabNet Maximum\_Optimized

Fig. 3 - Model error matrix TabNet Maximum\_Optimized

### Заключение

В результате исследования решены следующие задачи: определен состав задач подсистем ИС и проанализированы информационные потоки, что послужило основой для постановки задачи разработки интеллектуальной подсистемы управления текучестью персонала; обоснованы и исследованы математические модели и методы глубокого обучения, включая применение архитектуры TabNet для прогнозирования рисков увольнений и интерпретации факторов; разработана организационно-логическая сущность решения задачи в нотации IDEFO, демонстрирующая оптимизацию процесса анализа текучести; разработана информационно-логическая модель базы данных и выполнен выбор технологического стека: PyTorch и pytorch-tabnet для разработки моделей и

React/TypeScript для фронтенд-части системы; проведена оценка эффективности внедрения подсистемы, подтверждающая оптимизацию HR-процессов, сокращение времени анализа (на 70–80%) и повышение точности прогнозов.

### Литература

1. Федеральный закон «О персональных данных» от 27.07.2006 № 152-ФЗ // Федеральный закон "О персональных данных" от 27.07.2006 N 152-ФЗ (последняя редакция) \ КонсультантПлюс.
2. Стандарт ОАО «РЖД» 1.18.002-2009 Управление информационной безопасностью// СТО РЖД 1.18.002-2009 Управление информационной безопасностью. Общие положения / 1 18 002 2009.
3. И.Н. Калиновская *Управление в социальных и экономических системах*, 31, 28-30 (2022).
4. А.Ф. Денисов, Д.С. Кардаш, *Экономика и управление*, 6 (152), 26-37 (2018).
5. М. Г. Нуриев, Е. С. Белашова, К. А. Барабаш *Программные системы и вычислительные методы*, 1, 1-12. (2023) – DOI 10.7256/2454-0714.2023.1.39547. – EDN SNAYLQ.
6. Ю.Н. Смирнов, А.И. Абдуллин, А.В. Каляшина, *Научно-технический вестник Поволжья*. 6, 106-109.(2023) – EDN JAZFDJ.
7. А. Р. М. Худхейр, Е. В. Заргарян, Ю. А. Заргарян *Известия ЮФУ. Технические науки*, 227, 3, 211-222 (2022) – DOI 10.18522/2311-3103-2022-3-211-222.
8. М.А. Рукомин, *Вестник науки*, 89, 8, 348-354. (2025).
9. В.И. Симашев, М.Г. Нуриев, *Международный научно-исследовательский журнал*, 154, 4, 123-124 (2025)- DOI: 10.60797/IRJ.2025.154.89.
10. Н. В. Власова, В. А. Оленцевич, *Современные технологии. Системный анализ. Моделирование*, 77, 1, 127-135. (2023) – DOI 10.26731/1813-9108.2023.1(77).127-135.
11. М. Г. Нуриев, М. Г. Лаптева, В. А. Космынин *Международный научно-исследовательский журнал*, 158, 8. (2025) – DOI 10.60797/IRJ.2025.158.44.
12. А. А. Васильев, Э. В. Фурего, А. А. Любченко, С. В. Ерошенко, *Путь и путевое хозяйство*, 10, 2-5 (2024).
13. А.В.Каляшина, *Вестник Технологического университета*, 27, 12, 147-152 (2024) 10.55421/1998-7072\_2024\_27\_12\_147.
14. А.В. Каляшина, Ю.Н. Смирнов *Научно-технический вестник Поволжья*, 11, 119-122 (2023) – EDN LXULQC.
15. А. Хамитов, Е. Ю. Белова, *Информационные технологии. Проблемы и решения*, 25, 4, 27-33. (2023).

### References

1. Federal Law "On Personal Data" dated July 27, 2006 No. 152-FZ // Federal Law "On Personal Data" dated July 27, 2006 No. 152-FZ (latest revision) \ ConsultantPlus
2. Standard of JSC Russian Railways 1.18.002-2009 Information Security Management// STO RZD 1.18.002-2009 Information Security Management. General Provisions / 1 18 002 2009
3. I.N. Kalinovskaya *Management in Social and Economic Systems*, 31, 28-30 (2022)
4. A.F. Denisov, D.S. Kardash, *Economics and Management*, 6 (152), 26-37 (2018)
5. M. G. Nuriev, E. S. Belashova, K. A. Barabash *Software systems and computational methods*, 1, 1-12. (2023) – DOI 10.7256/2454-0714.2023.1.39547. – EDN SNAYLQ.
6. Yu.N. Smirnov, A.I. Abdullin, A.V. Kalyashina, *Scientific and Technical Herald of the Volga Region*. 6, 106-109.(2023) – EDN JAZFDJ

7. A. R. M. Khudkhair, E. V. Zargaryan, Yu. A. Zargaryan *Bulletin of SFedU. Technical sciences*, 227, 3, 211-222 (2022) - DOI 10.18522/2311-3103-2022-3-211-222.
- 8 M.A. Rukomin, *Bulletin of Science*, 89, 8, 348-354. (2025)
9. V.I. Simashev, M.G. Nureyev, *International Research Journal*, 154, 4, 123-124 (2025) - DOI: 10.60797/IRJ.2025.154.89.
10. N. V. Vlasova, V. A. Olentsevich, *Modern Technologies. Systems Analysis. Modeling*, 77, 1, 127-135. (2023) – DOI 10.26731/1813-9108.2023.1(77).127-135
11. M. G. Nureyev, M. G. Lapteva, V. A. Kosmynin *International Research Journal*, 158, 8. (2025) – DOI 10.60797/IRJ.2025.158.44.
12. A. A. Vasiliev, E. V. Furego, A. A. Lyubchenko, S. V. Eroshenko, *The Road and the Road Economy*, 10, 2-5 (2024)
13. A.V. Kalyashina., *Herald of Technological University*. I, 27, 12, 147-152 (2024) 10.55421/1998-7072\_2024\_27\_12\_147
14. A.V. Kalyashina, Yu.N. Smirnov *Scientific and Technical Bulletin of the Volga Region*, 11, 119-122 (2023) – EDN LXULQC
15. A. Khamitov, E. Yu. Belova, *Information Technologies. Problems and Solutions*, 25, 4, 27–33. (2023)

---

© **А. В. Каляшина** – канд. техн. наук, доцент кафедры Лазерных и аддитивных технологий, Казанский национальный исследовательский технический университет им. А.Н. Туполева, Казань, Россия, anna\_vik@mail.ru; **Ю. Н. Смирнов** – кандидат физико-математических наук, доцент, заведующий кафедрой «Цифровые системы и модели», Казанский государственный энергетический университет, mmite@mail.ru.

© **A. V. Kalyashina** – PhD (Technical Sci.), Associate Professor of the Department of Laser and Additive Technologies, Kazan National Research Technical University named after A. N. Tupolev, Kazan, Russia, anna\_vik@mail.ru; **Yu. N. Smirnov** – PhD (Technical Sci.), Associate Professor of the Department of Digital Systems and Models, Kazan State Power Engineering University, mmite@mail.ru.

Дата поступления рукописи в редакцию – 29.03.26.

Дата принятия рукописи в печать – 23.04.26.