

Научная статья
DOI: 10.37791/2687-0657-2026-20-3-67-95
EDN: TOCCNQ

ГРНТИ 28.23.25, 06.81.12
БАК 5.2.6
УДК 005.5:004.8

Анализ управленческих подходов и разработка методики интеграции моделей машинного обучения в управление бизнес-процессами

Г. В. Овчинников¹, А. Е. Трубин^{1,2*}, Т. В. Артемова¹, О. П. Култыгин¹

¹Университет «Синергия», Москва, Россия

²Российский экономический университет им. Г. В. Плеханова, Москва, Россия

*niburt@yandex.ru

Аннотация. Ускоренная цифровая трансформация и рост использования технологий искусственного интеллекта в российском бизнесе в условиях конкуренции обострили проблему отсутствия целостных управленческих подходов к интеграции моделей машинного обучения в управление бизнес-процессами. Целью настоящего исследования является анализ современного состояния такой интеграции в условиях конкуренции, выявление ключевых барьеров и предложение методики синхронизации жизненных циклов BPM и ML. В соответствии с поставленной целью решаются задачи синхронизации этапов жизненного цикла бизнес-процессов предприятия с этапами жизненного цикла модели машинного обучения, определяются бизнес-проблемы и осуществляется анализ ситуации, формируется модель машинного обучения, проводится выравнивание целей и области применения ML между бизнес-стратегией и задачами BPM, сравниваются подходы к интеграции ML в BPM за рубежом и в России. В исследовании проработана авторская модель синхронизации жизненных циклов BPM и ML, введены метрики оценки эффективности интеграции (точность прогнозов, прирост производительности, скорость внедрения и др.), проведен системный сравнительный анализ зарубежных и российских подходов (представлен в виде таблицы), а также предложен структурированный пошаговый план (roadmap) внедрения ИИ в бизнес-процессы с указанием этапов, участников, сроков и ресурсов.

Ключевые слова: методика управления, цифровая трансформация, бизнес-процесс, машинное обучение, интеграция ИИ, жизненный цикл BPM, жизненный цикл моделей ML, барьеры внедрения ИИ

Для цитирования: Овчинников Г. В., Трубин А. Е., Артемова Т. В., Култыгин О. П. Анализ управленческих подходов и разработка методики интеграции моделей машинного обучения в управление бизнес-процессами // Современная конкуренция. 2026. Т. 20. №3. С. 67–95. DOI: 10.37791/2687-0657-2026-20-3-67-95.

© Овчинников Г. В.,
Трубин А. Е.,
Артемова Т. В.,
Култыгин О. П.,
2026.

Статья доступна на условиях простой (неисключительной) лицензии, которая является безвозмездной, предоставляется на срок действия исключительного права и действует по всему миру. Данная лицензия предоставляет любому лицу право копировать и распространять материал на любом носителе и в любом формате и создавать производные материалы, видоизменять и преобразовывать материал при условии указания авторов, названия статьи, журнала, его года и номера (в том числе посредством указания DOI).

Research article

DOI: 10.37791/2687-0657-2026-20-3-67-95

Analysis of Management Approaches and Development of a Methods for Integrating Machine Learning Models into Business Process Management

G. Ovchinnikov¹, A. Trubin^{1,2*}, T. Artemova¹, O. Kultygin¹

¹*Synergy University, Moscow, Russia*

²*Plekhanov Russian University of Economics, Moscow, Russia*

**niburt@yandex.ru*

Abstract. Accelerated digital transformation and the growing use of artificial intelligence technologies in Russian businesses in a competitive environment have exacerbated the lack of holistic management approaches to integrating machine learning models into business process management. The purpose of this study is to analyze the current state of such integration in a competitive environment, identify key barriers, and propose a methodology for synchronizing the BPM and ML lifecycles. In accordance with this goal, the following tasks are addressed: synchronizing the stages of the enterprise's business process lifecycle with the stages of the machine learning model lifecycle, identifying business problems and analyzing the situation, developing a machine learning model, aligning the goals and scope of ML application between business strategy and BPM objectives, and comparing approaches to integrating ML into BPM internationally and in Russia. The study developed a proprietary model for synchronizing the BPM and ML lifecycles, introduced metrics for evaluating integration effectiveness (forecast accuracy, productivity gains, implementation speed, etc.), conducted a systematic comparative analysis of international and Russian approaches (presented in a table), and proposed a structured step-by-step roadmap for implementing AI in business processes, specifying stages, participants, deadlines, and resources. This study confirmed that ML integration can increase productivity, reduce costs, and improve the customer experience of enterprises in a competitive environment. However, its adoption is hampered by a number of barriers (poor data quality, skills shortages, resistance to change, security risks, etc.).

Keywords: management methods, digital transformation, business process, machine learning, AI integration, BPM lifecycle, ML model lifecycle, AI implementation barriers

For citation: Ovchinnikov, G., Trubin, A., Artemova, T., & Kultygin, O. (2026). Analysis of Management Approaches and Development of a Methods for Integrating Machine Learning Models into Business Process Management. *Journal of Modern Competition*, 20(3), 67–95. <https://doi.org/10.37791/2687-0657-2026-20-3-67-95>

© Ovchinnikov G.,
Trubin A.,
Artemova T.,
Kultygin O., 2026.

The article is available under a simple (non-exclusive) license, which is royalty-free, provided for the duration of the exclusive right, and is valid worldwide. This license grants any person the right to copy and distribute the material on any medium and in any format, and to create derivative materials, modify, and transform the material, provided that the authors, the article title, the journal, its year, and issue are credited (including by specifying the DOI).

Введение

Управление бизнес-процессами (Business Process Management, BPM) представляет собой дисциплину, нацеленную на повышение конкурентоспособности организации за счет непрерывного совершенствования бизнес-процессов и сквозной оптимизации операций. Классический жизненный цикл BPM включает идентификацию процессов, их моделирование, анализ текущего исполнения, разработку улучшений (редизайн), внедрение изменений и последующий мониторинг. С другой стороны, машинное обучение (ML) – ключевая технология искусственного интеллекта (ИИ), которая позволяет на основе большого объема данных выявлять закономерности, строить прогнозы и принимать решения. Жизненный цикл модели ML охватывает сбор и подготовку данных, инженерии признаков, обучение модели (классификация, регрессия, кластеризация, обучение с подкреплением и др.), оценку качества и развертывание модели в эксплуатацию [22]. Симбиоз использования BPM и ML теоретически открывает новые возможности: процессы становятся более интеллектуальными и адаптивными, решения принимаются на основе данных, а автоматизация выходит за рамки жестко запрограммированных правил¹. Таким образом, интеграция ИИ и BPM может повысить качество принятых решений, эффективность операций и улучшить клиентский опыт.

За последние несколько лет ряд российских компаний существенно нарастили инвестиции в цифровые технологии. Совокупные вложения в цифровизацию бизнеса превысили 4 трлн руб., увеличившись более чем на 80%. Одним из приоритетных направлений стала автоматизация на основе

машинного обучения: уже около четверти крупных предприятий используют технологии ИИ в той или иной форме, и ожидается рост этого показателя до 95% к 2030 г.² Россия входит в топ-10 стран мира по уровню использования ИИ, а средний уровень внедрения ИИ в приоритетных отраслях экономики достиг 31,5%. Тем не менее, несмотря на высокий интерес бизнеса к ML, практическое использование этих моделей остается ограниченным. По данным опроса аналитического центра НАФИ (2019 г.), 80% крупных организаций в РФ автоматизировали отдельные процессы, но лишь 33% внедрили технологии машинного обучения; при этом 93% респондентов прогнозировали дальнейший рост автоматизации³. Наиболее популярные области применения ML – продажи (56% компаний), обслуживание клиентов (44%) и логистика (33%) [11, 18]. Главными барьерами на пути внедрения ИИ были названы необходимость перестройки существующих бизнес-процессов (31% опрошенных), недостаточная подготовка персонала (29%) и низкий уровень цифровизации организаций (27%)⁴. Эти факты свидетельствуют о разрыве между потенциалом ML и готовностью бизнеса к их восприятию. Возникает научный и практический вопрос: как выработать системный управленческий подход, который позволит интегрировать модели ML в BPM с максимальным эффектом для бизнеса?

² Комолов А. Россия вошла в десятку лидеров по внедрению искусственного интеллекта // Российская газета. 13.03.2024. URL: <https://rg.ru/2024/03/13/rossiia-voshla-v-desiatku-liderov-po-vnedreniiu-iskusstvennogo-intellekta.html> (дата обращения: 13.07.2026).

³ Самсонова А. Крупный бизнес не спешит внедрять машинное обучение // ComNews. 27.11.2019. URL: <https://www.comnews.ru/content/203178/2019-11-27/2019-w48/kрупnyy-biznes-ne-speshit-vnedryat-mashinnoe-obuchenie> (дата обращения: 13.07.2026).

⁴ Фокин А. От амбиций до разочарований: как бизнес теряет деньги на ИИ // РБК Тренды. 2025. URL: <https://trends.rbc.ru/trends/industry/68f5e2b79a794728c3b730e1> (дата обращения: 13.07.2026).

¹ Морозова В. (2025). Интеграция BPM и ИИ для оптимизации процессов в реальном времени // BPMS.ru. URL: <https://bpms.ru/post/20250710-convergence-bpm-ai/> (дата обращения: 13.07.2026).

Недостаточная разработанность такого подхода во многом обусловлена тем, что существующие исследования фокусируются либо на технических аспектах ИИ, либо на классических принципах BPM, не предлагая единой междисциплинарной методики [17]. Как отмечается в ряде исследований [21, 22], использование методов предиктивной аналитики и process mining позволяет существенно повысить результативность BPM-практик за счет глубокой обработки данных о ходе исполнения процессов. Однако пока отсутствуют устоявшиеся стандарты и лучшие практики по синхронизации жизненного цикла модели ML с жизненным циклом бизнес-процесса. В литературе [20, 22] отмечается нехватка открытых наборов данных и методов валидации для обучения ML на процессных кейсах, ограниченное использование глубокого обучения в BPM, а также проблемы с прозрачностью и разъяснением решений на базе ИИ. Всё это затрудняет формирование доверия к моделям со стороны менеджмента и тормозит их внедрение.

Таким образом, научная новизна данной работы заключается в разработке комплексного междисциплинарного подхода к интеграции ML и BPM, учитывающего указанные пробелы. В исследовании проанализирован текущий уровень практического внедрения ИИ в бизнес-процессы (в том числе на примерах российских кейсов), выявлены основные проблемы и препятствия и на этой основе предложены решения: авторская модель синхронизации жизненных циклов BPM и ML, система показателей эффективности интеграции в условиях конкуренции, а также практические рекомендации и поэтапный план их реализации. Ниже рассмотрены теоретические основы интеграции BPM и ML, проведен сравнительный анализ зарубежного и российского опыта, выделены ключевые барьеры, а затем представлена методика, направленная на преодоление этих барьеров и достижение эффективной интеграции в условиях конкуренции.

Теоретические основы интеграции моделей ML в BPM

Необходимость междисциплинарной методики

Для эффективного внедрения ИИ в управление процессами требуется синхронизация жизненных циклов BPM и модели ML [6]. Бизнес-процессы должны изначально проектироваться с учетом требований к данным и возможностей аналитических алгоритмов, а модели ML разрабатываться с учетом бизнес-целей, метрик процесса и нормативных ограничений. Иными словами, процессный подход и data science должны быть объединены на каждом этапе.

До сих пор BPM и data science развивались во многом параллельно. Научные исследования либо посвящены вопросам интеграции цифровых инструментов и аналитики процессов в условиях конкуренции, либо фокусируются на классическом реинжиниринге, из-за чего отсутствует единый язык и подход для их объединения [17]. В работах по предиктивному и интеллектуальному BPM подчеркивается важность сочетания методов процессного управления и машинного обучения: например, совместное использование моделирования бизнес-процессов и предиктивной аналитики позволяет не только фиксировать узкие места, но и улучшает процесс прогнозирования отклонений и результаты выполнения процессов. Тем не менее отсутствие междисциплинарной методики проявляется в том, что многие организации внедряют ИИ точно под конкретные задачи, без стратегического охвата всех процессов. Такой фрагментарный подход не обеспечивает полноты эффекта от технологий и зачастую ведет к разочарованию в них. Назрела потребность в научно обоснованной методике, объединяющей инструменты BPM и ML в единый контур управления, то есть позволяющей интегрировать разработку и применение моделей ML непосредственно в цикл управления бизнес-процессами.

Модель синхронизации жизненных циклов BPM и ML

Для решения данной методической задачи авторами разработана модель, синхронизирующая этапы жизненного цикла бизнес-процессов с этапами жизненного цикла модели машинного обучения. Эту концепцию иллюстрирует рисунок 1.

Ниже приводятся основные этапы BPM и соответствующие им шаги работы с ML-моделями.

1. Определение бизнес-проблемы и анализ

На данном этапе определяется потенциальная задача для применения ML. Бизнес анализирует стратегические цели и узкие места процесса, формулирует бизнес-проблему и ставит задачу для ML-модели, а также оценивает доступность необходимых данных. Проще говоря, цели BPM и проекты внедрения ИИ должны быть выровнены с самого начала [17]. Это предотвращает ситуации, когда ИИ внедряется «ради внедрения», без привязки к ключевым показателям эффективности процесса. На данном шаге происходит выравнивание целей и области применения ML между бизнес-стратегией и задачами BPM.


2. Моделирование, сбор и подготовка данных

На стадиях проектирования (моделирования) и анализа текущего исполнения бизнес-процесса осуществляется сбор и подготовка данных, необходимых для будущей ML-модели. В то же время команда data science проводит предварительный анализ данных, разведочный анализ (EDA) и инженерию признаков для выявления паттернов в рамках процесса. По сути, требования к данным закладываются при описании процесса, где на выходе каждого шага должно быть определено, какие данные собирать и с какой точностью⁵. В результате к моменту завершения анализа процесса имеются как понимание возможностей для улучшения, так и подготовленный набор данных для обучения модели.

3. Реализация и обучение модели

На этапе разработки улучшений BPM принимается решение о том, как именно интегрировать ML в процесс. Проектируется решение:

⁵ Бузлаев П. Глава Минэкономки: Россия входит в топ-10 стран по внедрению ИИ // Коммерсантъ. 13.03.2024. URL: <https://www.kommersant.ru/doc/6563229> (дата обращения: 13.07.2026).



Источник: составлено авторами на основе анализа [9, 12, 13].

Рис. 1. Модель синхронизации жизненных циклов BPM и ML

Fig. 1. Model for synchronizing BPM and ML life cycles

как встроить результаты модели в последовательность работ, какие шаги автоматизировать или изменить на основе прогнозов модели. Здесь жизненный цикл ML входит в критическую фазу, где проводится обучение и валидация модели на подготовленных данных, и результаты этой модели оцениваются с точки зрения влияния на процесс. Инсайты, полученные от модели ML, влияют на проектирование нового процесса: например, если модель выявляет факторы задержек, процесс можно перепроектировать, чтобы учесть эти факторы. Таким образом, происходит двусторонняя связь, в которой, с одной стороны, процессные требования диктуют критерии качества модели, с другой – результаты экспериментов с моделью помогают сформировать улучшенный дизайн процесса. Практическим примером является кейс ПАО «Газпромнефть»: рекомендации ML по выбору места бурения новой скважины были включены в процесс геологоразведки, изменив последовательность действий геологов.

4. Развертывание и мониторинг процесса

На данном этапе обновленный бизнес-процесс запускается в эксплуатацию вместе с внедрением обученной ML-модели. Происходит развертывание модели в производство (в BPM-системе или ином программном обеспечении, поддерживающем процессе). Это требует интеграции в условиях конкуренции, где модель становится частью информационной системы процесса, бизнес-логика дополняется обращением к ML-сервису или модулю. Важно обеспечить, чтобы сотрудники были подготовлены к работе с результатами модели (например, пользовательские интерфейсы показывали прогнозы, рекомендации). Здесь жизненные циклы сходятся в одной точке: модель ML внедряется непосредственно в бизнес-процесс, изменяя способ его выполнения. После внедрения осуществляется постоянный мониторинг как показателей процесса, так и качества работы ML-модели. Этот завершающий (и на деле непрерывный) этап обеспечивает обратную связь. Измеряются KPI процесса (время цикла, стоимость, качество и т.д.) и метрики модели (точность прогнозов,

процент ошибок). Если процесс не улучшается должным образом или модель теряет точность, это сигнал к пересмотру. Таким образом, жизненный цикл BPM переходит в новую итерацию (возврат к определению проблем) одновременно с итерацией жизненного цикла модели (например, необходимо заново собрать данные и переобучить модель). Такой итеративный контур гарантирует совместное развитие процесса и модели: процессные изменения рожают новые данные для модели, а обученная модель приводит к новым изменениям процесса. Например, в розничной компании после внедрения модели прогнозирования спроса пришлось сократить цикл планирования и регулярно обновлять модель по мере накопления новых данных, т.е. процесс адаптировался под модель, а модель регулярно адаптируется под изменяющийся процесс.

В целом предложенная модель синхронизации жизненных циклов BPM и ML предполагает, что каждый этап управления процессом сопряжен с соответствующими действиями по разработке/поддержке ML-модели. Это предотвращает разрывы, когда модель живет отдельной жизнью без привязки к бизнес-контексту или, наоборот, процесс меняется без учета данных и аналитики. Такой подход позволяет достичь итеративного улучшения: BPM обеспечивает структурированность внедрения и использования модели, а ML привносит адаптивность и интеллектуальную поддержку решений [2, 4, 5].

Метрики оценки эффективности интеграции BPM и ML

Важным элементом предлагаемого подхода является оценка эффективности интеграции в условиях конкуренции ИИ в бизнес-процессы. Для этого необходимо отслеживать набор метрик, отражающих как качество работы ML-модели, так и улучшения самого бизнес-процесса. В таблице 1 представлены ключевые группы показателей, которые рекомендуется использовать для мониторинга результатов интеграции BPM+ML.

Таблица 1. Метрики оценки эффективности интеграции BPM и ML

Table 1. Metrics for evaluating the effectiveness of BPM and ML integration

Метрика <i>Metric</i>	Описание / Пример применения <i>Description / Application example</i>
Количественные / Quantitative	
Время выполнения процесса <i>Process execution time</i>	Сокращение средней длительности одного бизнес-процесса (до/после внедрения ML) <i>Reduction in the average duration of one business process (before/after ML implementation)</i>
Точность модели <i>Model accuracy</i>	Accuracy, Precision, Recall, F1-score – стандартные метрики качества предсказаний ML-модели <i>Accuracy, Precision, Recall, F1-score – standard metrics for the quality of ML model predictions</i>
ROI от внедрения <i>ROI from implementation</i>	Соотношение прироста прибыли или снижения затрат к стоимости проекта интеграции <i>The ratio of profit increase or cost reduction to the cost of the integration project</i>
Уровень автоматизации <i>Level of automation</i>	Доля операций, переведенных в автоматический режим благодаря использованию модели <i>The share of operations transferred to automatic mode due to the use of the model</i>
Снижение количества ошибок <i>Reducing the number of errors</i>	Количество отклонений, сбоев или ошибок в процессе до и после внедрения ML <i>The number of deviations, failures or errors in the process before and after ML implementation</i>
Время реакции на событие <i>Event response time</i>	Время, за которое процесс адаптируется к новому входному событию благодаря предсказанию модели <i>The time it takes for a process to adapt to a new input event thanks to a model prediction</i>
Объем обработанных кейсов <i>Volume of processed cases</i>	Увеличение количества обработанных задач, заявок, клиентов и др. <i>Increase in the number of processed tasks, requests, clients, etc.</i>
Качественные / Qualitative	
Уровень доверия к модели <i>Model confidence level</i>	Восприятие пользователями надежности и обоснованности рекомендаций модели <i>Users' perceptions of the reliability and validity of model recommendations</i>
Прозрачность решений <i>Explainability</i>	Степень объяснимости решений модели (например, XAI-интерфейсы, SHAP-графики) <i>The degree of explainability of model decisions (e.g. XAI interfaces, SHAP graphs)</i>
Удовлетворенность сотрудников <i>Employee satisfaction</i>	Субъективная оценка вовлеченных сотрудников: снижение рутины, повышение удобства <i>Subjective assessment of engaged employees: reducing routine, increasing convenience</i>
Гибкость и адаптивность процесса <i>Flexibility and adaptability of the process</i>	Способность процесса быстро перестраиваться при изменении условий за счет ML <i>The ability of a process to quickly adapt to changing conditions due to ML</i>
Снижение влияния субъективного мнения <i>Reducing the influence of subjective opinion</i>	Снижение роли интуитивных, неконструктивных решений в процессе <i>Reducing the role of intuitive, non-constructive decisions in the process</i>

Источник: составлено авторами на основе анализа [8, 17].

1. Точность прогнозов модели

Доля корректных предсказаний или классификаций, выдаваемых ML-моделью. Эта метрика (ассурасу) напрямую характеризует качество модели ML и ее пригодность для процесса. Например, для модели прогнозирования спроса оценивается средняя ошибка прогноза (%), для модели классификации обращений – точность и полнота классификации и т. д. Без достаточной точности ценность модели для процесса будет невысока, поэтому пороговые значения метрик качества модели необходимо определить на этапе внедрения и контролировать при эксплуатации.

2. Процессные KPI

Показатели эффективности самого бизнес-процесса, которые улучшились (или должны улучшиться) благодаря внедрению ML. Это может быть время цикла процесса, пропускная способность, уровень обслуживания (например, скорость ответа клиенту), качество продукта/услуги, стоимость процесса и др. Желательно еще на старте проекта установить целевые изменения этих KPI. Например, если интегрируется модель для предиктивного обслуживания оборудования, метрикой успеха будет снижение простоев или расходов на ремонт на определенный процент. Прирост производительности и экономический эффект от внедрения ИИ должны быть измеримы количественно (руб., %, пункты уровня обслуживания и т. п.).

3. Скорость и ресурсоемкость внедрения

Показатель, отражающий время разработки и интеграции модели в процесс, а также затраченные ресурсы (финансовые, человеческие) в условиях конкуренции. В идеале проекты по внедрению ML в BPM должны быть относительно короткими (несколько месяцев) и недорогими, чтобы бизнес получил окупаемость. Если внедрение тянется годами, это свидетельствует об организационных проблемах. Поэтому измеряются: время на разработку модели, длительность пилотного проекта до масштабирования, затраты на внедрение. Эти метрики позволяют оценить операцион-

ную эффективность самого проекта интеграции в условиях конкуренции.

4. Уровень автоматизации и охват

Доля задач или решений в процессе, которые теперь выполняются автоматически с помощью ML. Например, можно оценивать процент этапов процесса, где задействован ИИ, или долю решений, принимаемых автоматически (с подсказкой модели). Также сюда относится степень проникновения: сколько бизнес-процессов в организации интегрированы с МО-моделями. Рост этого показателя со временем свидетельствует об успешности масштабирования подхода на компанию в целом.

5. Принятие и удовлетворенность пользователей

Модель может показывать отличные цифры, но если пользователи (сотрудники) не применяют ее рекомендации, фактического улучшения не будет. Поэтому важно измерять уровень использования системы (например, сколько процентов решений реально принимается на основе вывода модели, а сколько вручную), а также собирать обратную связь от сотрудников об удобстве и доверии к инструменту. Высокая степень принятия означает успешную интеграцию в рабочую среду.

6. Возврат инвестиций (ROI)

Интегральный финансовый показатель, сравнивающий выгоды от улучшения процесса с затратами на разработку и поддержку ML-решения. Например, в нефтедобыче пилотная модель ML окупилась многократно за счет обнаружения новых запасов. Расчет ROI по итогам проекта позволяет убедить руководство в ценности подхода на языке бизнеса (рубли, проценты прибыли).

Комбинация перечисленных метрик дает всестороннюю оценку: от технической успешности модели до влияния на бизнес-результаты. Внедряя ML-проекты, необходимо изначально определить базовые значения KPI процесса и целевые показатели улучшения, а после интеграции регулярно мониторить ме-

трики модели и процесса. Если, к примеру, точность модели падает ниже установленного порога или прирост эффективности процесса не достигается, это служит триггером к пересмотру подхода (модель переобучить, процесс донстроить или даже признать проект нецелесообразным). Таким образом, метрики связывают воедино BPM и ML на этапе мониторинга, поскольку они отражают синхронно и качество аналитики, и результативность бизнес-деятельности.

Сравнительный анализ зарубежного и российского опыта интеграции ML в BPM

Для более глубокого понимания проблемы рассмотрим, как подходы к интеграции ИИ

в бизнес-процессы в условиях конкуренции реализуются за рубежом и в России.

В таблице 2 обобщены ключевые аспекты (методики, уровень внедрения, барьеры и др.) двух контекстов.

1. Методическая база и исследования

В международной практике теме интеграции ML и BPM в условиях конкуренции уделяется значительное внимание в исследованиях. Зарубежные ученые систематизировали применение ML на всех фазах жизненного цикла BPM, существуют обзоры и фреймворки (например, концепция интеллектуального BPM, предиктивного мониторинга процессов и пр.). Так, Weinzierl et al. [22] провели систематический обзор по ML в BPM, выделив шесть фаз BPM и соответствующие задачи, решаемые ML. Формируется повестка дальнейших

Таблица 2. Сравнение подходов к интеграции ML в BPM за рубежом и в России

Table 2. Comparison of approaches to ML integration in BPM abroad and in Russia

Аспект <i>Aspect</i>	Международная практика <i>International practice</i>	Российская практика <i>Russian practice</i>
Теоретические основы <i>Theoretical foundations</i>	Активные исследования по интеграции BPM+AI, существуют обзоры и модели (предиктивный BPM, iBPM и др.). Формируются стандарты и best practices, единая методика пока в разработке, но есть частичные фреймворки <i>Research into BPM+AI integration is active, with reviews and models (predictive BPM, iBPM, etc.) available. Standards and best practices are being developed; a unified methods is still under development, but partial frameworks exist</i>	Отдельные научные работы и исследования кейсов (процессная аналитика, риски, BPM-системы с ИИ), но целостной методики нет. Внедрение носит междисциплинарный характер, требующий обобщения – данная работа является одним из первых шагов к этому <i>There are some research papers and case studies (process analytics, risks, BPM systems with AI), but no comprehensive methods. Implementation is interdisciplinary in nature, requiring synthesis – this work is one of the first steps toward that end</i>
Уровень внедрения ИИ <i>AI adoption rate</i>	Многие крупные компании внедрили ИИ в нескольких бизнес-процессах; BPM-платформы эволюционируют в интеллектуальные (iBPMS) с AI-инструментами. Появились корпоративные AI-стратегии и центры компетенций <i>Many large companies have implemented AI in several business processes; BPM platforms are evolving into intelligent ones (iBPMS) with AI tools. Corporate AI strategies and centers of excellence have emerged</i>	У ряда ведущих корпораций (банки, нефтегаз, телеком) – успешные пилоты и некоторые промышленные внедрения (скоринг, прогнозирование спроса и т. д.). В среднем по рынку – применение ИИ точечное, часто в режиме эксперимента. Ожидается рост охвата (95% компаний к 2030 г. планируют ИИ-проекты) <i>A number of leading corporations (banks, oil and gas, telecom) have successful pilot projects and some industrial implementations (scoring, demand forecasting, etc.). Overall, AI use is spotty across the market, often in experimental mode. Its reach is expected to grow (95% of companies are planning AI projects by 2030)</i>

Окончание таблицы 2

Основные барьеры <i>Main barriers</i>	Качество данных, организационное изменение и доверие, интеграция с legacy. Большое внимание вопросам этики и соответствия регуляторным требованиям (GDPR и др.). Недостаток кадров решается за счет глобального рынка талантов. По опросам, до 70% проблем – «человеческий фактор» (культура, навыки) <i>Data quality, organizational change and trust, and legacy integration are key. Ethics and regulatory compliance (GDPR, etc.) are emphasized. The global talent market is addressing talent shortages. According to surveys, up to 70% of the problems are due to the "human factor" (culture, skills)</i>	Те же проблемы, усиленные низкой цифровой зрелостью: данные фрагментированы, ИТ-инфраструктура разрознена; острый дефицит data science-специалистов на рынке; сопротивление переменам сильное при низкой аналитической культуре. Финансовые и регуляторные ограничения: соблюдение Закона № 152-ФЗ (персональные данные), отсутствие отечественных облачных AI-сервисов глобального уровня <i>The same problems, exacerbated by low digital maturity: data is fragmented, IT infrastructure is disjointed; there is a severe shortage of data science specialists in the market; resistance to change is strong, coupled with a weak analytical culture. Financial and regulatory constraints include compliance with Federal Law no. 152 (personal data), and the lack of domestic, global-scale cloud AI services</i>
Подходы к интеграции <i>Approaches to integration</i>	Стратегическое выравнивание AI и BPM (связка проектов ИИ с целями процесса) – принцип process first. Поэтапное масштабирование: пилот => rollout. Создание кросс-функциональных команд, обучение персонала data-driven навыкам. Использование облачных и low-code решений для ускорения внедрения. Управление изменениями как часть проектов (коммуникация, обучение пользователей) <i>Strategic alignment of AI and BPM (linking AI projects with process goals) – a process-first approach. Phased scaling: pilot => rollout. Creation of cross-functional teams, staff training in data-driven skills. Use of cloud and low-code solutions to accelerate implementation. Change management as part of projects (communication, user training)</i>	Начала формироваться практика дорожных карт ИИ на уровне компаний: определение приоритетных кейсов, назначение ответственных за ИИ-направление. Часто опора на внешние интеграторы / консультантов при внедрении. Появляются отечественные платформы (например, BPM-системы с встроенной ML-аналитикой) для снижения барьеров внедрения. Государство стимулирует пилотные проекты (песочницы ИИ, гранты). Однако многое держится на энтузиазме отдельных команд, нет системного обмена опытом между организациями <i>The practice of AI roadmaps at the company level has begun to emerge: identifying priority cases and assigning responsibilities for AI. External integrators and consultants are often relied upon for implementation. Domestic platforms (for example, BPM systems with integrated ML analytics) are emerging to reduce implementation barriers. The government is incentivizing pilot projects (AI sandboxes, grants). However, much of this work relies on the enthusiasm of individual teams; there is no systematic exchange of experience between organizations</i>

Источник: составлено авторами на основе анализа [3, 10, 15, 16], а также: AI для бизнеса: специфика модели машинного обучения // BPMSoft. 22.03.2025. URL: <https://bpmsoft.ru/presscenter/ai-ml-modeli/> (дата обращения: 13.07.2026); Бузлаев Г. Глава Минэкономки: Россия входит в топ-10 стран по внедрению ИИ // Коммерсантъ. 13.03.2024. URL: <https://www.kommersant.ru/doc/6563229> (дата обращения: 13.07.2026); Российская промышленность переходит от точечной автоматизации к созданию собственных цифровых экосистем // Новый проспект. 02.12.2025. URL: <https://newprospect.ru/news/rossijskaya-promyshlennost-perexodit-ot-tochnoj-avtomatizacii-k-sozdaniyu-sobstvennyix-cifrovix-ekosistem> (дата обращения: 13.07.2026).

исследований, включающая поиск единой методики сочетания BPM и AI. В России же специализированные исследования по интеграции BPM и ML в условиях конкуренции пока единичны. Большинство научных работ носят либо общий характер (о цифровой трансфор-

мации, процессной аналитике), либо фокусируются на отдельных задачах применения ML. Например, имеются исследования по использованию ML в управлении рисками малого бизнеса, по процессному майнингу и т.п., однако целостной методики для объединения

BPM и ML отечественные авторы еще не предложили [1, 16]. Таким образом, зарубежные подходы опираются на более развитую теоретическую базу, тогда как в России ощущается дефицит системных исследований, что подтверждает новизну и актуальность данной работы.

2. Уровень внедрения и охват

Крупные международные компании уже активно внедряют ИИ в целый ряд бизнес-функций. По данным McKinsey⁶, еще к 2018 г. около половины компаний в мире начали использовать ИИ хотя бы в одном бизнес-процессе, а к 2024 г. AI применялось уже в среднем в трех функциональных областях организации. Популярны кейсы применения ML для оптимизации цепочек поставок, прогнозирования оттока клиентов, интеллектуальной автоматизации back-office и др. Кроме того, BPM-продукты на мировом рынке эволюционируют в сторону iBPMS – интеллектуальных BPM-систем, включающих встроенные ML/AI-модули для анализа и оптимизации процессов. В России интерес к таким технологиям очень высок на уровне флагманов (Сбербанк, Газпромнефть, крупный ретейл и др. уже имеют успешные пилоты). Тем не менее масштабное распространение находится на ранней стадии [19]. По состоянию на конец 2010-х – начало 2020-х гг. лишь около 30% крупных компаний реально внедрили ML-модели в процессы, большинство же ограничивалось испытаниями. Ситуация быстро меняется: госпрограмма «Цифровая экономика» стимулирует внедрение ИИ, к 2030 г. ожидается почти повсеместное применение (95% компаний). Однако пока внедрения носят точечный характер, например одно направление (скоринг клиентов в банке, прогноз добычи на месторождении, система рекомендаций в онлайн-продажах).

До интеграции ИИ во все процессы предприятия в условиях конкуренции дошли единицы организаций, тогда как за рубежом цифровые лидеры уже выстраивают корпоративные AI-платформы, масштабируя решения на множество процессов.

3. Основные барьеры и проблемы

В целом набор препятствий для интеграции ML в BPM в условиях конкуренции схожий везде: проблемы с данными, нехватка кадров, сопротивление изменениям, сложности наследуемых систем и т.д. Разница – в степени выраженности этих барьеров. Для зарубежных компаний одним из главных вызовов стала организационная трансформация: по оценке BCG⁷, около 70% сложностей при внедрении ИИ связаны с людьми и процессами (культура, организационные изменения), а не с технологиями. Так же остро стоят вопросы этики и ответственности ИИ в правовом поле (особенно в ЕС с регуляторными инициативами). В России перечисленные барьеры усугубляются историческим низким уровнем цифровой зрелости многих компаний: данные разрозненные и некачественные (на что указали 27% опрошенных российских компаний), грамотных специалистов по данным недостаточно, сопротивление персонала усиливается недостатком доверия к новым технологиям. Кроме того, финансовый барьер (высокая стоимость решений) в среднем выше для российских фирм, особенно среднего бизнеса, из-за импортозависимости технологий. Сильная сторона России – высокий интерес топ-менеджмента и государства к ИИ, но слабая – разрывы между пилотами и масштабным внедрением. В международной практике тоже отмечают, что локальные успехи не всегда превращаются в системный эффект, однако там чаще имеются корпоративные центры компетенций, планы

⁶ The State of AI in Early 2024: Generative AI's Breakout Year (Global Survey report) // McKinsey & Company. May 2024. URL: <https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai-2024> (дата обращения: 13.07.2026).

⁷ AI Adoption in 2024: 74% of Companies Struggle to Achieve and Scale Value // Boston Consulting Group. 24.10.2024. URL: <https://www.bcg.com/press/24october2024-ai-adoption-in-2024-74-of-companies-struggle-to-achieve-and-scale-value> (дата обращения: 13.07.2026).

масштабирования. В РФ же нередко пилот после завершения «затухает», будучи нераспространенным.

4. Подходы к преодолению барьеров

Зарубежные компании выработали ряд лучших практик: это и создание междисциплинарных команд (CoE – центры экспертизы по AI), и внедрение культуры data-driven принятия решений, и модернизация ИТ-ландшафта под AI (микросервисы, облака, API-ориентированные процессы). Особо подчеркивается необходимость встраивать AI-проекты в стратегию BPM, например принцип process first («сначала оптимизируй процесс, потом автоматизируй») получил широкое распространение. Многие иностранные эксперты советуют не гнаться за самыми сложными моделями, а выбирать понятные и надежные решения, удобные для пользователей (концепция Responsible AI) [23]. В России практика только формируется, но уже появляются позитивные примеры, когда крупные игроки на рынке создают собственные AI-платформы и экосистемы (СберAI, Газпром цифровые решения и др.), интегрируя ML в существующие BPM-системы. Развивается рынок отечественных BPM-систем с AI-модулем (некоторые российские платформы BPM заявляют о встроенных ML-механизмах). Государство выпустило ряд методических рекомендаций по внедрению ИИ в деятельность организаций, но в целом системный управленческий подход только начинает вырабатываться. Настоящее исследование как раз закрывает часть этого пробела, предлагая методику и дорожную карту, учитывающие как зарубежный опыт, так и специфически российские условия (нормативные требования, локальные кейсы, ограниченные ресурсы и др.).

Основные проблемы и барьеры интеграции ML в BPM

Несмотря на перечисленные преимущества, массовое внедрение моделей ML в управление бизнес-процессами на практике сдерживает-

ся рядом организационных и технологических барьеров. Рассмотрим ключевые из них (выявленные по результатам анализа литературы и практики), а также причины этих проблем и возможные пути их преодоления (табл. 3).

Качество данных и интеграция источников

Для эффективной работы моделей ML необходимы большие объемы надежных данных, собранных из различных систем (CRM, ERP, датчики IoT и др.). На практике организации сталкиваются с тем, что данные разрознены по подразделениям, хранятся в разных форматах, содержат ошибки и пробелы.

Причина: исторически системы автоматизации внедрялись точечно, без унификации; отсутствуют единый стандарт данных и культура их ведения.

Следствие: модели ML, обученные на неточных или несвязанных данных, выдают некорректные прогнозы, что приводит к неправильной автоматизации процесса и снижению эффективности. Например, компания может принять решение на основе предсказания модели, а затем выясняется, что исходные данные содержали дубли или пропуски, исказившие прогноз.

Решение: необходимо выстроить корпоративное управление данными, интегрировать разрозненные базы в единое хранилище (data warehouse или data lake), реализовать процедуры очистки и верификации данных, наладить постоянный мониторинг их качества⁸. Стандартизация данных и создание «единого источника истины» (single source of truth) являются предварительным условием для успешного использования ML. Кроме того, на этапе

⁸ Бузлаев П. Глава Минэкономики: Россия входит в топ-10 стран по внедрению ИИ // Коммерсантъ. 13.03.2024. URL: <https://www.kommersant.ru/doc/6563229> (дата обращения: 13.07.2026); Петрова В. Искусственный интеллект спотыкается о данные // Коммерсантъ. 14.02.2024. URL: <https://www.kommersant.ru/doc/6509461> (дата обращения: 13.07.2026).

Таблица 3. Основные барьеры интеграции ML в BPM и подходы к их преодолению

Table 3. Main barriers to ML integration in BPM and approaches to overcoming them

Барьер <i>Barrier</i>	Причины и проявления <i>Causes and manifestations</i>	Подходы к преодолению <i>Approaches to overcoming</i>
Низкое качество данных, разрозненность источников <i>Poor data quality, fragmented sources</i>	Данные рассредоточены по системам, содержат ошибки, дубли; отсутствуют единые стандарты и ответственность за качество. Модели обучаются на «грязных» данных, дают неточные результаты, подрывая доверие бизнеса <i>Data is scattered across systems, contains errors and duplicates, and there are no unified standards or accountability for quality. Models are trained on "dirty" data, producing inaccurate results, undermining business trust</i>	- Внедрение корпоративной стратегии управления данными: создание единого хранилища (DWH/Data Lake), интеграция данных из разных источников. <i>Implementation of a corporate data management strategy: creation of a unified data warehouse (DWH/Data Lake), integration of data from various sources.</i> - Очистка и валидация данных, постоянный мониторинг качества. <i>Data cleansing and validation, continuous quality monitoring.</i> - Назначение ответственных за данные (data stewards), регламентация процессов ввода и обновления данных. <i>Assignment of data stewards, regulation of data entry and update processes.</i> - Учет требований к данным при моделировании бизнес-процессов – сбор нужных данных на каждом этапе процесса <i>Consideration of data requirements when modeling business processes – collection of the necessary data at every stage of the process</i>
Недостаток компетенций для разработки и поддержки ML <i>Lack of competencies for the development and support of ML</i>	Не хватает внутренних data science-специалистов; зависимость от подрядчиков. Модели сложно сопровождать: без регулярного обновления их качество падает, проекты умирают после пилота <i>There's a shortage of in-house data science specialists; dependence on contractors. Models are difficult to maintain: without regular updates, their quality deteriorates, and projects die after the pilot</i>	- Формирование кросс-функциональных команд (data scientists + бизнес-эксперты + ИТ) внутри компании, развитие внутренних компетенций ML. <i>Forming cross-functional teams (data scientists + business experts + IT) within the company, developing internal ML competencies.</i> - Использование понятных и поддерживаемых решений: по возможности выбирать более простые, интерпретируемые модели (decision trees, линейные модели) вместо «черных ящиков». <i>Using clear and supportable solutions: Whenever possible, choose simpler, interpretable models (decision trees, linear models) instead of "black boxes".</i> - Применение AutoML и встроенных AI-инструментов в BPM-системах для снижения порога внедрения. <i>Using AutoML and built-in AI tools in BPM systems to reduce the implementation threshold.</i> - Планирование жизненного цикла модели: закладывать ресурсы и регламент для ее периодического переобучения, мониторинга качества, обновления данных <i>Model lifecycle planning: allocate resources and procedures for periodic retraining, quality monitoring, and data updates</i>

Продолжение таблицы 3

Сопротивление сотрудников, недоверие к ИИ <i>Employee resistance, mistrust of AI</i>	Страх автоматизации: опасения потерять работу или влияние. Культурный барьер: предпочтение интуитивных решений данным; невосприимчивость к советам «черного ящика». В результате сотрудники игнорируют рекомендации модели, продолжая работать по-старому <i>Fear of automation: fear of losing one's job or influence. Cultural barrier: preference for intuitive decisions over data; rejection of "black box" advice. As a result, employees ignore the model's recommendations and continue to work as before</i>	▪ Change management: коммуникация целей внедрения (ИИ как помощь, а не замена человеку). <i>Change management: communicating implementation goals (AI as an aid, not a replacement for humans).</i> ▪ Вовлечение сотрудников с начала проекта: совместная работа над пилотом с ключевыми пользователями, поиск champions среди них. <i>Engaging employees from the start of the project: collaborating on a pilot with key users, identifying "champions" among them.</i> ▪ Демонстрация быстрых побед (quick wins) – показывать на практике улучшения работы с помощью ИИ. <i>Demonstrating quick wins: demonstrating operational improvements using AI.</i> ▪ Повышение data literacy: обучение персонала работе с данными, объяснимости моделей. Чем понятнее инструмент, тем выше доверие. <i>Improving data literacy: training staff in data management and model explainability. The more understandable the tool, the greater their trust.</i> ▪ Технические меры: внедрение Explainable AI (объяснение рекомендаций модели), удобный интерфейс, интеграция в привычные рабочие приложения <i>Technical measures: implementing Explainable AI (explanations of model recommendations), a user-friendly interface, and integration into familiar work applications</i>
Риски безопасности и соблюдения норм <i>Safety risks and compliance with standards</i>	Модели используют персональные и чувствительные данные (риск утечек). Возможна дискриминация или ошибки модели, ведущие к юридическим и репутационным проблемам. Неясность регуляторных требований по ИИ (новая область регулирования) <i>Models use personal and sensitive data (risk of leaks). Discrimination or model errors are possible, leading to legal and reputational issues. Unclear regulatory requirements for AI (an emerging area of regulation)</i>	▪ Включение специалистов по рискам и комплаенс в проект команды. <i>Involve risk and compliance specialists in the team's project.</i> ▪ Аудит данных перед использованием: удаление персональных сведений, обеспечение анонимности, получение согласий. <i>Data audit before use: remove personal information, ensure anonymity, obtain consent.</i> ▪ Тестирование модели на отсутствие bias и дискриминации перед внедрением. <i>Test the model for bias and discrimination before implementation.</i> ▪ Human-in-the-loop: установка точек, где решения модели проверяются/одобряются человеком, особенно в критичных процессах (кредитование, медицина и т. д.). <i>Human-in-the-loop: establish points where model decisions are verified/approved by humans, especially in critical processes (lending, medicine, etc.).</i> ▪ Укрепление кибербезопасности: контроль доступа к данным, шифрование, изоляция ML-сервисов, защита API. <i>Strengthen cybersecurity: control data access, encryption, isolation of ML services, API protection.</i> ▪ Отслеживание законодательства и следование отраслевым стандартам по этике ИИ; готовность быстро адаптироваться к новым правилам <i>Monitor legislation and adherence to industry standards on AI ethics; readiness to quickly adapt to new regulations</i>

Окончание таблицы 3

Трудности масштабирования и тиражирования <i>Difficulties in scaling and replication</i>	Пилотный проект сложно распространить на другие подразделения из-за различий в процессах, ИТ-системах, данных. Ограничения legacy-систем, которые не поддерживают интеграцию с ML или требуют больших вложений при модернизации. Процессы негибкие, зарегулированные – не позволяют быстро внести изменения для ИИ <i>The pilot project is difficult to expand to other departments due to differences in processes, IT systems, and data. Legacy systems lack integration with ML or require significant investment in modernization. Inflexible, highly regulated processes prevent rapid implementation of AI-enabled changes</i>	▪ Разработка поэтапного плана масштабирования: начинать с малого (1 филиал, 1 сегмент), затем постепенно добавлять новые элементы. Сопровождать каждый этап измерением KPI и корректировкой подхода. <i>Develop a phased scaling plan: start small (1 branch, 1 segment), then gradually add new elements. Accompany each stage with KPI measurement and approach adjustments</i> ▪ При проектировании новых процессов и ИТ-систем закладывать модульность и открытые API для подключения ML-сервисов. <i>When designing new processes and IT systems, consider modularity and open APIs for connecting ML services.</i> ▪ Использовать облачные решения и контейнеризацию – это облегчает развертывание модели в разных средах без длительной установки инфраструктуры. <i>Use cloud solutions and containerization – this facilitates model deployment in different environments without lengthy infrastructure setup.</i> ▪ Если компания географически или бизнес-направленно диверсифицирована, рассмотреть создание нескольких специализированных моделей вместо одной универсальной, но сложной. Это упростит обучение и повысит точность в зависимости от контекста. <i>If the company is geographically or business-wise diversified, consider creating several specialized models instead of one universal but complex one. This will simplify training and improve accuracy depending on the context.</i> ▪ Создать типовую методику внедрения ИИ для филиалов: шаблоны, чек-листы, команда поддержки. Обмениваться уроками и кейсами внутри организации, чтобы другие подразделения шли по проторенной дорожке <i>Create a standard AI implementation methods for branches: templates, checklists, and a support team. Share lessons and case studies within the organization so that other departments follow the same path</i>
--	--	---

Источник: составлено авторами на основе анализа [7, 10, 14, 15].

моделирования процессов (BPM) следует учитывать требования к данным: на выходе каждого шага процесса определять, какие данные должны собираться и с какой точностью. Таким образом, преодоление данного барьера лежит в плоскости развития практик data management в организации и тесной увязки этих практик с процессным управлением.

Сложность разработки и поддержки моделей

Создание и внедрение сложных моделей машинного обучения – нетривиальная задача для большинства компаний.

Причина: нехватка компетенций, требуется экспертиза в области data science (статистика, программирование, ML-алгоритмы), которая часто отсутствует в штатной структуре предприятия. Даже пригласив внешних разработчиков для пилотного проекта, организация сталкивается со сложностью поддержки модели в рабочем режиме.

Следствие: модели быстро устаревают без регулярного переобучения, деградирует точность, и в итоге проект ИИ сворачивается из-за невозможности его масштабировать и сопровождать. Кроме того, зависимость от внешних подрядчиков усиливает риски (vendor lock-in).

Решение: развивать внутренние компетенции и кросс-функциональные команды. В идеале в компании должна сформироваться группа специалистов (аналитиков данных, инженеров ML), взаимодействующих с бизнес-экспертами⁹. Также следует отдавать предпочтение более простым и интерпретируемым решениям там, где это возможно – избыточно сложные модели трудно поддерживать силами бизнеса. Еще один подход – использование инструментов AutoML и встроенных средств ML в современных BPM-системах, снижающих требования к квалификации персонала (концепция democratizing AI). В любом случае руководство должно понимать: внедрение ИИ – это не разовый ИТ-проект, а постоянный процесс, требующий ресурсов на поддержание модели (обновление данных, корректировка параметров и т. д.)¹⁰. Эти ресурсы (бюджет на инфраструктуру, время специалистов) нужно закладывать еще на этапе планирования внедрения цифровых инструментов.

Сопrotивление изменениям и организационная культура

Любое внедрение ИИ-технологий затрагивает сотрудников и их устоявшиеся обязанности, что неизбежно вызывает сопротивление переменам.

Причина: люди опасаются, что автоматизация и ML сделают их роль менее значимой или вовсе сократят рабочие места; кроме того, существует недоверие к «черным ящикам», решениям, предлагаемым алгоритмом. В корпоративной культуре многих компаний решения,

основанные на личном опыте и интуиции, ценятся выше, чем «сухой» аналитический вывод системы.

Следствие: даже после технически успешного внедрения модели ML она может игнорироваться персоналом, рекомендации ИИ не будут применяться на практике. К примеру, сотрудники отдела продаж могут продолжать формировать заказ товара «по привычке», несмотря на прогнозные подсказки системы, считая, что они «лучше знают клиентов». Такое поведение сведет на нет пользу от интеграции ML в условиях конкуренции.

Решение: фокус на управлении изменениями (change management) – изменении мышления и обучении. Компания должна прозрачно донести до коллектива цели внедрения ИИ (не для сокращения людей, а для устранения рутины и помощи в принятии решений). Важно вовлекать сотрудников в процесс с самого начала: пилотные проекты делать вместе с «лидерами мнений» от бизнеса, показывать быстрые победы (quick wins) от использования ML. Также нужно инвестировать в повышение data literacy, обучать персонал основам работы с данными, интерпретации результатов моделей. Чем более понятным и дружелюбным будет инструмент ML для конечных пользователей, тем выше его принятие. Например, если модель рекомендует решение, интерфейс должен сопровождать его объяснимыми причинами (feature importance, визуализация трендов и т. д.), чтобы устранить эффект «магии». Культивирование доверия к данным и моделям будет длительным процессом, но без него интеграция ИИ обречена тормозиться на уровне человеческого фактора¹¹. В успешных кейсах отмечается, что активное участие бизнес-экспертов в проекте (совместно с дата-специалистами) значительно повышает принятие результатов, например в проекте process mining банка ВТБ специалисты подразделений совместно с ИТ

⁹ AI Adoption in 2024: 74% of Companies Struggle to Achieve and Scale Value // Boston Consulting Group. 24.10.2024. URL: <https://www.bcg.com/press/24october2024-ai-adoption-in-2024-74-of-companies-struggle-to-achieve-and-scale-value> (дата обращения: 13.07.2026).

¹⁰ Кол С. ИИ в западных корпорациях: период отрезвления (сентябрь 2025) // Хабр. 25.09.2025. URL: <https://habr.com/ru/articles/950756/> (дата обращения: 13.07.2026).

¹¹ Там же.

прорабатывали отчеты, и персонал увидел ценность инсайтов¹².

Безопасность, этичность и нормативное соответствие

Использование ML в процессах неизбежно затрагивает вопросы информационной безопасности и этики.

Причина: модели обучаются на данных, в том числе персональных, финансовых и других конфиденциальных; кроме того, алгоритмы могут неявно содержать bias (предвзятость), унаследованный из данных. В российском законодательстве в последние годы появляются требования к обращению с персональными данными, к недискриминационному характеру алгоритмов (например, недопустимо, чтобы модель отказывала клиенту на основе пола, расы, религии и пр.). Отдельное направление – регулирование ИИ: разрабатываются национальные стандарты и этические кодексы, но четких правил пока мало.

Следствие: компании сталкиваются с неопределенностью, как встроить модель ML в процесс с соблюдением всех норм. Возможны риски утечки данных при интеграции разных систем в условиях конкуренции, риск нарушения закона о данных, а также репутационные риски, если модель примет «неэтичное» решение.

Решение: включать блок risk management and compliance в методику интеграции. Перед запуском модели проводить аудит данных на предмет чувствительности и законности использования, обезличивать персональные данные, получать необходимые согласия от субъектов. Проводить тестирование модели на наличие скрытой дискриминации (например, проверять, не занижает ли кредитный скоринг оценки определенной группе клиен-

тов). В процессе эксплуатации мониторить решения ИИ, внедрить процедуру контроля человеком в критических точках (human in the loop). Также крайне важно обеспечить кибербезопасность, поскольку модели ИИ и связанные с ними новые сервисы не должны создавать уязвимости в ИТ-инфраструктуре. Для этого рекомендуется изолировать контуры данных, шифровать хранилища, ограничивать доступ по принципу необходимости. Особое внимание к безопасности требуется в облачных решениях ИИ (где хранится модель и данные). Нормативный контроль также усиливается, регуляторы финансового сектора уже требуют от банков учитывать риски ИИ-моделей в системе комплаенса (ИИ для обнаружения подозрительных транзакций должен быть сертифицирован и контролируем)¹³. В целом этическая и юридическая экспертизы должны сопровождать проект интеграции ML наравне с технической. Это повышает доверие со стороны стейкхолдеров и снижает вероятность проблем постфактум.

Масштабируемость и гибкость внедрения

Даже успешно реализовав один-два пилотных проекта по интеграции ИИ в процессы, компания в условиях конкуренции часто испытывает сложности с распространением решений на всю организацию.

Причина: многообразие процессов и систем, различный уровень их зрелости, наследуемые легаси-системы. То, что хорошо сработало в одном подразделении, может потребовать серьезной доработки для другого. Кроме того, для масштабирования может потребоваться модернизация ИТ-инфраструктуры (серверы, хранилища, лицензии ПО), что ведет к новым затратам.

¹² Давыдова Ю. 74% компаний проваливают внедрение ИИ. Вот 5 шагов, чтобы попасть в успешные 26% // VC.ru. 31.07.2025. URL: <https://vc.ru/ai/2131024-74-protsent-kompanij-ne-mogut-vnedrit-ii> (дата обращения: 13.07.2026).

¹³ Бузлаев П. Глава Минэкономики: Россия входит в топ-10 стран по внедрению ИИ // Коммерсантъ. 13.03.2024. URL: <https://www.kommersant.ru/doc/6563229> (дата обращения: 13.07.2026).

Следствие: проекты ИИ остаются локальными успехами, не влияющими существенно на общую эффективность бизнеса. Например, модель ML внедрена в онлайн-продажах, но не используется офлайн-розницей компании из-за разных платформ и стандартов данных, и в итоге эффект ограничен. Еще один аспект – жесткость процессов: некоторые бизнес-процессы слишком негибкие, зарегулированные и не позволяют быстро внести изменения, необходимые для работы модели.

Решение: применять поэтапный подход к масштабированию (см. рекомендации о пилотах в следующем разделе) и архитектурные принципы, облегчающие интеграцию. В частности, все новые процессы стоит проектировать модульными, с открытыми API для подключения сервисов ML. При выборе платформы BPM ориентироваться на интеллектуальные BPMS (iBPMS), уже включающие инструменты ИИ. Использовать облачные платформы machine learning, чтобы ускорять развертывание моделей в разных филиалах без разворачивания инфраструктуры с нуля. Также важно учитывать специфику подразделений: возможно, вместо одной громоздкой модели целесообразно создавать несколько более простых, но адаптированных под контекст (например, отдельные модели прогноза спроса для разных регионов). Отмечено, что AI-решения сложно подогнать под существующие процессы без их пересмотра – это требует гибкости и от ИТ-подразделения, и от бизнес-направлений. Организациям, особенно с диверсифицированной структурой, рекомендуется разработать типовую методику внедрения ИИ в филиалах: шаблон проекта, чек-лист необходимых условий, команду поддержки. Тогда масштабирование пойдет быстрее и с меньшими издержками.

Рекомендации по выработке управленческой методики интеграции ИИ

Исходя из проведенного анализа, можно выделить ряд направлений, следование ко-

торым поможет организациям эффективно встроить модели машинного обучения в систему управления бизнес-процессами. Эти рекомендации охватывают стратегический, организационный и технический уровни, формируя основу комплексной методики (рис. 2).

Синхронизация стратегии BPM и ИИ

Цели внедрения ИИ должны быть непосредственно связаны с бизнес-целями и задачами процессного управления организации. Важно, чтобы проекты по ML исходили из приоритетов BPM, например улучшения определенных показателей процессов (времени цикла, качества продукта, стоимости процесса и т.п.). Стратегия компании в области ИИ должна рассматриваться не отдельно, а как часть общей цифровой стратегии и стратегии процессных улучшений. Такой стратегический альянс позволит избежать разрозненных инициатив (когда ИИ внедряется «ради внедрения») и сконцентрировать усилия на тех точках, где ML реально приносит максимальную отдачу. Кроме того, увязка с KPI бизнеса поможет обосновать инвестиции в ML языком, понятным руководству (ROI, срок окупаемости) и получить поддержку топ-менеджмента, что само по себе является критичным фактором успеха проекта. Зарубежные эксперты подчеркивают, что прежде чем автоматизировать процесс с помощью AI, необходимо оптимизировать и выстроить сам процесс (принцип process first). То есть ИИ должен усиливать хорошо организованные процессы, а не пытаться компенсировать их хаотичность.

Практическое применение данного подхода – создание дорожной карты AI-программ, привязанной к процессной архитектуре организации. На стратегических сессиях с участием руководства и владельцев ключевых процессов следует определить, какие процессы являются кандидатами для обогащения ИИ (где наибольший эффект и достаточно данных). Например, если узким местом в компании является длительный цикл

обработки заявок клиентов, приоритетным AI-проектом может стать модель для интеллектуального распределения и поддержки этих заявок. Результатом стратегического этапа должно стать четкое понимание того, какие бизнес-цели (цифрами) мы улучшим с помощью ML и какие процессы для этого трансформируем.


Управление данными как бизнес

Как было продемонстрировано выше, данные – это основа обучения любой модели ML, поэтому data management должен стать неотъемлемой частью BPM-методики. Практические шаги включают создание единого хранилища (DWH или data lake), куда стекаются данные от всех ключевых бизнес-процессов; внедрение ролей, ответственных за качество данных (data stewards) в бизнес-подразделе-

ниях; регламентацию процессов ввода, очистки и обновления данных. При описании бизнес-процессов следует явно указывать, какие данные генерируются на каждом шаге и где они сохраняются. Инструменты процессного моделирования (например, нотация BPMN) могут дополняться элементами, отражающими информационные объекты и их связь с шагами процесса¹⁴.

Кроме организационных мер, стоит внедрять технические решения: ETL-конвейеры для регулярного сбора и интеграции данных, системы контроля качества (data quality dashboards), мастер-данные (MDM). Перед применением модели ML важно предусмо-

¹⁴ Бузлаев П. Глава Минэкономики: Россия входит в топ-10 стран по внедрению ИИ // Коммерсантъ. 13.03.2024. URL: <https://www.kommersant.ru/doc/6563229> (дата обращения: 13.07.2026).



Источник: составлено авторами на основе анализа [8, 10, 13], а также: Российская промышленность переходит от точечной автоматизации к созданию собственных цифровых экосистем // Новый проспект. 02.12.2025. URL: <https://newprospect.ru/news/rossijskaya-promyshlennost-perexodit-ot-tochechnoj-avtomatizaczii-k-sozdaniyu-sobstvennyix-czifrovyx-ekosistem> (дата обращения: 13.07.2026).

Рис. 2. Этапы внедрения технологий искусственного интеллекта в процессы организации

Fig. 2. Stages of implementing artificial intelligence technologies into organizational processes

треть автоматизированные процедуры проверки входных данных, как например, бизнес-правила на минимальные объемы, допустимые диапазоны значений, фильтрацию выбросов. В кейсе «Абрау-Дюрсо», чтобы модель прогнозирования спроса давала эффект, компании пришлось наладить оперативный обмен данными между отделами и внедрить метрики качества прогноза на каждом цикле планирования. Таким образом, интеграция ML должна сопровождаться построением надежной информационной основы, и только тогда результаты ИИ станут воспроизводимыми и заслуживающими доверия.

Кросс-функциональные команды и развитие компетенций

Успешность проектов по интеграции ИИ и BPM в условиях конкуренции существенно зависит от человеческого фактора – наличия в команде разнообразных компетенций. Рекомендуется формировать кросс-функциональные команды, включающие представителей ИТ / данных, бизнес-владельцев процессов и аналитиков. Такая команда с самого начала учитывает различные требования и ограничения: ИТ-специалисты обеспечивают техническую реализуемость, бизнес-эксперты – соответствие решаемой проблемы реальным потребностям процесса, аналитики – правильность применения методов ML. Подобное сотрудничество предотвращает разрыв между моделью и ее пользователями. В реальных кейсах отмечено, что проекты, где бизнес-эксперты активно вовлечены, проходят успешнее. Например, при внедрении ML-модели в процесс геологоразведки в ПАО «Газпромнефть» команда включала геологов, ИТ-аналитиков и маркетологов, совместно они сумели правильно интерпретировать результаты нейросети и встроить их в практику принятия решений.

Кроме того, необходимо развивать компетенции персонала по всей организации:

организовывать обучение ключевых сотрудников основам работы с ИИ, проводить семинары, на которых демонстрируются возможности ML для улучшения процессов, делиться успешными кейсами. В корпоративную культуру полезно внедрять принципы data-driven мышления, поощрять принятие решений на основе данных, экспериментирование и анализ. Например, можно запустить внутренние конкурсы идей применения ML в процессах, тем самым вовлекая сотрудников в инновации. Хороший пример – хакатоны или программы AI Ambassadors в западных компаниях, где сотрудники соревнуются в предложениях по автоматизации своих процессов. Развитая культура и компетенции уменьшают сопротивление изменениям (как обсуждалось ранее) и создают кадровый фундамент для долгосрочной поддержки AI-инициатив.

Выбор моделей и их сопровождение

При интеграции ML в условиях конкуренции важно правильно подобрать тип модели под каждую задачу процесса и обеспечить ее жизненный цикл сопровождения. Для простых предсказательных задач может быть достаточно классической алгоритмики (дерево решений для скоринга, линейная регрессия для тренда спроса), в более сложных случаях требуется применение современных методов (градиентные бустинги, нейронные сети, методы без учителя для кластеризации клиентов и т. д.). Не стоит гнаться за модными технологиями без необходимости, критерием должна быть интегрируемость и достаточность модели. Например, если процесс требует прозрачности, предпочтение лучше отдать интерпретируемым моделям, даже если они немного менее точны.

Перед внедрением в реальный процесс модель ML должна пройти строгие испытания на исторических данных (бэк-тест), в режиме имитации на тестовом участке процесса. Желательно привлечь независимых экспер-

тов для верификации модели, например университетских специалистов или консультантов в предметной области. После развертывания необходимо организовать постоянный мониторинг качества модели в рабочем процессе. Для этого определяются метрики (точность прогноза, процент ошибок и т.д.) и допустимые пороги. Если метрики ухудшаются (например, данные со временем «плывут»), модель следует переобучить. Этот цикл retrain должен быть вписан в регламент процесса, например «пересмотр модели раз в квартал» или при падении точности ниже $N\%$. Также нужно отслеживать появление новых факторов и по мере необходимости дополнять модель. Для критичных процессов рекомендуется внедрять методы XAI (eXplainable AI) и генерировать объяснения решений модели, чтобы аудируемость процесса сохранялась. Все эти меры позволяют модели ML оставаться эффективной и полезной составляющей бизнес-процесса в долгосрочном горизонте, а не разовым экспериментом.

Управление рисками и нормативное соответствие

Включение ИИ в процессы требует обновления системы корпоративного риск-менеджмента и контроля соответствия нормам. На этапе планирования внедрения необходимо проводить оценку рисков применения модели от финансовых (возможные ошибки прогноза и их стоимость для бизнеса) до репутационных и юридических. Стоит разработать план действий на случай, если модель даст сбой или допустит ошибку, например резервные процедуры ручного контроля, возможность отката к прошлой версии процесса. Необходимо назначить ответственных за управление рисками ИИ (например, ввести должность AI Compliance Officer или распределить обязанности между ИБ и юридическим отделом). Также, надо убедиться, что процесс с внедренным ML удовлетворяет всем действующим нормам. В сфере персональных данных необходимо соблюсти

требования Закона № 152-ФЗ (об обезличивании, согласиях и хранении данных), в финансовой сфере – при необходимости согласовать использование ИИ с надзорными органами. Если отрасль высокорегулируемая (медицина, финансы), возможно, потребуется сертификация решения.

Важно также документировать работу модели, хранить логи решений и историю изменения параметров, что поможет при разборе инцидентов и для обучения персонала. Интеграция ML часто означает открытие дополнительных точек входа (API, доступы к данным). Следует обновить модель угроз и реализовать защитные меры (межсетевые экраны, шифрование, контроль доступа). Например, в банковском процессе кредитного скоринга на базе ML особое внимание нужно уделить тому, чтобы внешние данные, используемые моделью, не стали каналом атаки, и чтобы злоумышленник не смог манипулировать моделью (адверсариальные атаки на ИИ). Таким образом, внедрение ИИ сопровождается созданием системы контроля, которая страхует бизнес от новых рисков. Это повышает устойчивость процесса и доверие со стороны регуляторов и клиентов.

Пилотные проекты и поэтапное масштабирование

Наконец, ключевым управленческим подходом является постепенное внедрение ИИ с помощью пилотных проектов. Не следует пытаться охватить все процессы сразу, поскольку велика вероятность неудачи из-за сложности и неопределенности. Рекомендуется выбрать 1–2 процесса, где пересечение BPM и ML наиболее перспективно (например, узкое место, влияющее на прибыль, и при этом где есть качественные данные для ML). Реализовать пилотный проект в ограниченном масштабе – одном филиале, одном продукте или сегменте клиентов, чтобы оценить эффект и отработать методику. При этом важно изначально сформулировать критерии успеха

пилота (KPI улучшения процесса, точность модели, экономия средств и пр.) и измерять их. Если пилот дал положительный результат, можно переходить к тиражированию и постепенно подключать новые подразделения или расширять функциональность модели. Каждый шаг масштабирования – это новый этап проекта, со своими контролируемыми метриками. Такой интерактивный подход позволяет учесть уроки предыдущего шага и скорректировать методику. Более того, поэтапность облегчает управление изменениями, персонал привыкает к ИИ постепенно, обучается на пилотных проектах, что снижает сопротивление. Важно также фиксировать и документировать все аспекты пилота – от технических настроек до реакций пользователей, чтобы иметь шаблон для дальнейшего внедрения. Постепенное масштабирование способствует и оптимальному инвестированию, ресурсы вкладываются по мере доказательства ROI, а не авансом «вслепую». Многие компании, добившиеся успеха в цифровой трансформации, следовали принципу Start small, think big, move fast («Начинай с малого, имей большую цель и двигайся быстро, наращивая достижения»). Этот принцип применим и к интеграции ML в BPM.

Данный подход подтвердил эффективность на практике. Так, пилотный проект Газпромнефти по внедрению ML-модели для поиска нефти в трудных участках сначала был опробован на одном месторождении, и он выявил приток около 70 баррелей в сутки нефти из новой скважины. После этого, доказав ценность (модель позволила обнаружить суммарно около 100 тыс. тонн дополнительных запасов, окупившись многократно), решение было масштабировано на другие геологоразведочные процессы и даже применено в смежной области (маркетинг на АЗС). Этот кейс демонстрирует, что аккуратно выбранный пилот + масштабирование приводит к трансформационному эффекту. Другой пример – банк ВТБ начал с пилота по process mining в кредитном процессе, до-

бился оптимизации и затем распространил подход на все ключевые процессы банка. Такие истории успеха следует использовать как обоснование пошагового подхода для руководства компаний.

Следование указанным рекомендациям поможет выработать комплексную управленческую методику интеграции искусственного интеллекта в бизнес-процессы в условиях конкуренции. Она включает в себя и увязку с бизнес-целями, и подготовку данных, и работу с людьми, и техническое сопровождение, обеспечивая тем самым устойчивое внедрение инноваций.

Семь этапов внедрения AI в бизнес-процессы

Для практического применения вышеописанных рекомендаций авторы предлагают пошаговый план внедрения ИИ в бизнес-процессы – своеобразную roadmap, которая указывает основные этапы, ответственных участников, примерные сроки и необходимые ресурсы. Ниже представлен такой план по этапам.

Этап 1. Стратегическое обоснование (0–3 мес.)

Формирование видения и целей

На данном этапе иницируется проект на уровне руководства.

Участники: топ-менеджмент, владельцы ключевых бизнес-процессов, руководитель цифровой трансформации / ИТ.

Задачи: определить бизнес-цели внедрения ИИ (какие KPI процессов планируется улучшить), выбрать приоритетные процессы для пилотных внедрений, согласовать проект с общей стратегией компании.

Ресурсы: время руководства на стратегические сессии; возможно привлечение внешних экспертов для оценки потенциала AI.

Результат: утвержденный перечень AI-инициатив, связанных с BPM, и поддержка сверху.

Этап 2. Подготовка данных и инфраструктуры (1–6 мес.)

Создание базиса для ML

Участники: ИТ-департамент, специалисты по данным (DBA, data engineers), бизнес-аналитики.

Задачи: провести аудит текущих данных по выбранным процессам; интегрировать необходимые источники данных (настроить выгрузки из информационных систем, объединить данные в data lake / хранилище); очистить и привести данные к единому формату; обеспечить доступность инфраструктуры для моделирования (серверы, облачные сервисы, ПО для разработки моделей). Параллельно решаются вопросы безопасности – согласование использования данных, анонимность.

Ресурсы: выделенные серверные мощности или облачные кредиты, лицензии на аналитическое ПО, трудозатраты ИТ-специалистов.

Результат: готовый датасет для пилотной модели, развернутая технологическая среда (песочница) для экспериментов с ML.

Этап 3. Формирование команды и обучение (1–4 мес.)

Организация кросс-функциональной команды проекта

Участники: назначенный менеджер проекта, аналитик данных / дата-сайентист, бизнес-эксперт процесса, представитель ИБ / рисков, ИТ-архитектор.

Задачи: утвердить состав рабочей группы, распределить роли (например, бизнес-эксперт отвечает за описание процесса и постановку задач, дата-сайентист – за модель, ИТ – за интеграцию, риск-менеджер – за соответствие требованиям); провести для членов команды вводные тренинги по основам BPM и ML (в зависимости от их профиля, чтобы все говорили на одном языке); установить регламент взаимодействия (скрам-митинги, отчетность).

Ресурсы: время сотрудников (частичная или полная занятость в проекте), бюджет на обучение (тренинги, семинары).

Результат: сплоченная междисциплинарная команда, готовая реализовывать пилот.

Этап 4. Разработка пилотного решения (3–9 мес.)

Создание и внедрение ML-модели в выбранный процесс в ограниченном масштабе

Участники: проектная команда (из этапа 3) – особенно активны дата-сайентист и бизнес-эксперт, разработчики ПО для интеграции модели.

Задачи: детально описать текущий процесс («как есть») и обозначить точки внедрения ИИ; разработать прототип ML-модели: провести анализ данных, выбрать алгоритм, обучить модель; провести внутреннее тестирование модели (офлайн на исторических данных, затем в тестовом режиме онлайн); одновременно модифицировать бизнес-процесс под интеграцию модели (например, обновить инструкции для сотрудников, добавить шаг в информационной системе, где вывод модели вливается в процесс); обучить ограниченный круг пользователей работе с новым инструментом.

Ресурсы: рабочее время команды, мощности для обучения модели (GPU/облако при необходимости), тестовая среда BPM-системы для отладки интеграции, возможно, услуги внешних консультантов по ML.

Результат: действующий прототип: обновленный процесс + ML-модель, запущенные в пилотном контуре (на ограниченной области применения).

Этап 5. Тестирование и оценка пилота (6–12 мес.)

Проверка результата на практике

Участники: проектная команда, пользователи пилотного проекта, кураторы от руководства.

Задачи: эксплуатировать процесс с интегрированным ИИ в течение оговоренного пилотного периода (например, 1–3 месяца); собирать метрики: показатели процесса (как изменились по сравнению с базовыми значениями), метрики работы модели (точность, число

сбоев), отзывы пользователей; регулярно информировать руководство о промежуточных результатах; по завершении периода провести финальную оценку – достигнуты ли KPI успеха, где есть отклонения.

Ресурсы: средства мониторинга (дашборды KPI, системы логирования решений модели), время аналитиков для обработки собранных данных, поддержка пользователей (helpdesk) для оперативного решения возникающих проблем.

Результат: отчет о результатах пилота, включающий количественные показатели (например, сокращение времени процесса на 20%, рост точности прогноза до 90% и т.п.), качественные выводы (реакция сотрудников, удобство, выявленные проблемы).

Этап 6. Коррекция и масштабирование (9–18 мес.)

Усовершенствование решения и расширение его охвата

Участники: всё та же команда (может немного трансформироваться под масштабирование), дополнительные команды в новых подразделениях при тиражировании.

Задачи: на основе уроков пилота доработать модель (например, дополняются данные, корректируются алгоритмы) и процессы (внеести изменения, которые обнаружились в ходе пилота, возможно, упростить какие-то шаги, добавить новые роли и т.д.); подготовить план распространения решения на другие подходящие процессы/филиалы; провести обучение более широкого круга сотрудников, которым предстоит работать с ИИ; осуществить поэтапное тиражирование либо по организационным единицам (одно подразделение за другим), либо по функционалу (подключение новых функций модели).

Ресурсы: дополнительный бюджет на внедрение в новых подразделениях (может потребоваться закупка оборудования, расширение лицензий BPM-системы, наем или переподготовка сотрудников); время ИТ-служб для развёртывания решения в новых условиях.

Результат: улучшенная версия AI-решения и план-график его внедрения в масштабах организации; несколько первых успехов тиражирования (например, модель внедрена уже в трех филиалах из 10, дает экономию N рублей).

Этап 7. Закрепление и continuous improvement (постоянно)

Встраивание ИИ в повседневную деятельность компании

Участники: владельцы процессов, центр экспертизы по ИИ (если создан), ИТ-отдел (саппорт), HR (для обучения новых сотрудников).

Задачи: перевести интегрированные с ИИ процессы на режим постоянной эксплуатации с регулярным мониторингом; назначить ответственных за сопровождение модели в каждом существенном процессе (например, роль процессного аналитика + специалиста по данным для мониторинга качества модели); включить показатели эффективности ИИ-моделей в систему KPI подразделений; продолжать расширять применение ИИ на новые процессы по мере готовности (данный этап переходит в новую волну проекта, фактически возвращаясь к этапу 1 для выбора следующих кандидатов).

Ресурсы: постоянное финансирование для поддержки инфраструктуры данных и моделей; программы внутреннего обучения новых сотрудников работе с интеллектуальными системами; обновление регламентов и политик компании с учетом AI (например, политика безопасности с учетом ИИ-рисков, этический кодекс ИИ).

Результат: функционирующая экосистема BPM+AI в организации – бизнес-процессы, обогащенные моделями ML, действуют устойчиво, принесенный эффект закреплен и растет, компания обладает внутренней способностью поддерживать и развивать эти решения.

Данная дорожная карта, разумеется, может варьироваться в деталях в зависимости от масштаба организации и специфики от-

расли, однако базовая логика «сперва стратегия – потом данные – команда – пилот – масштабирование – постоянное улучшение» универсальна. Она отражает как собственно рекомендации авторов, так и мировой опыт успешных внедрений AI в бизнес (многие компании проходили эти этапы итерационно). Важно подчеркнуть, что на каждом этапе критична межфункциональная координация: совместная работа ИТ, бизнеса и аналитиков, а также поддержка руководства. Только при этих условиях дорожная карта не останется на бумаге, а воплотится в реальные изменения.

Заключение

Настоящее исследование отвечает на вызовы цифровой трансформации, формируя управленческую основу для системной интеграции в условиях конкуренции моделей машинного обучения в управление бизнес процессами. Проанализированы существующие практики и барьеры, с которыми сталкиваются российские компании при внедрении ИИ технологий, а также предложены инструменты и подходы, обеспечивающие переход от фрагментарных пилотных проектов к комплексной цифровизации процессов.

В рамках работы были достигнуты следующие новые ключевые результаты, отраженные в аннотации и подтвержденные в ходе анализа:

1. Предложена интеграция ML в BPM, представленная через разработанную авторскую модель синхронизации жизненных циклов BPM и ML, отражающую логическое и функциональное соответствие между этапами проектирования процессов и этапами построения моделей. Это позволяет выстроить управляемый контур «процесс – данные – модель – решение – улучшение» с непрерывной обратной связью.

2. Новизна результатов исследования заключается в выявлении ключевых барьеров внедрения ML в процессы: от проблем с каче-

ством и доступностью данных до организационного сопротивления и дефицита компетенций. Они систематизированы в таблице и связаны с предлагаемыми мерами преодоления, включая формирование data governance, внедрение explainable AI и институционализацию AI-инициатив внутри компании.

3. Введены новые метрики оценки эффективности интеграции в условиях конкуренции, как количественные (снижение времени выполнения, точность прогнозов, ROI), так и качественные (доверие к модели, прозрачность решений, адаптивность процессов). Эти новые метрики служат критериями для контроля и оценки зрелости внедрения ИИ.

4. Проведен сравнительный анализ новых зарубежных и российских подходов, что позволило выявить особенности локального контекста и интегрировать лучшие международные практики в предложенную методику. В частности, сделан акцент на институциональной роли государства, кадровых барьерах и необходимости развития зрелой стратегии внедрения AI, что является новым в исследовании.

5. Сформулирован новый, междисциплинарный подход, объединяющий знания из областей BPM, data science и организационного управления. Он представлен в виде пошаговой дорожной карты внедрения, охватывающей все этапы от аудита процессов и постановки целей до масштабирования решений и непрерывного мониторинга.

Таким образом, основным вкладом, научной новизной настоящей работы стало формирование основ системной методики интеграции ML в управление бизнес процессами в условиях конкуренции, адаптированной под условия российской экономики и учитывающей как технологические, так и управленческие аспекты.

Полученные новые результаты могут быть использованы как основа для последующих прикладных исследований (например, эмпирической валидации модели BPM+ML на реальных кейсах), а также как практический

инструмент в проектах цифровой трансформации. Стратегическое соединение BPM и ИИ позволяет компаниям выйти за рамки локальных автоматизаций и перейти к построению

по-настоящему интеллектуальных, адаптивных и ориентированных на данные процессов – ключевому условию устойчивого развития в условиях цифровой экономики.

Список литературы

1. Адаменко П.А., Цибульникова В.Ю., Нужина И.П. Применение машинного обучения и искусственного интеллекта при управлении предпринимательскими рисками в малом бизнесе // Журнал прикладных исследований. 2023. № 10. С. 66–72. DOI: 10.47576/2949-1878_2023_10_66.
2. Алексеева Т.В., Гумеров Э.А., Култыгин О.П. и др. Разработка архитектуры интеллектуальной системы управления граничными вычислениями для IoT систем промышленного предприятия // Информационные системы и технологии. 2023. № 6 (140). С. 29–40. EDN: HBWVET.
3. Зубанова А.Е., Култыгин О.П., Люблинская Н.Н. и др. Применение нейронных сетей для анализа текстовой информации о состоянии рынка // Информационные системы и технологии. 2023. № 1 (125). С. 53–64. EDN: BXKWLE.
4. Кириллова Е.А., Лазарев А.И., Култыгин О.П. Нейросетевая модель для поддержки принятия решений по управлению кооперативными связями в инновационных экосистемах // Прикладная информатика. 2022. Т. 17. № 2. С. 79–92. DOI: 10.37791/2687-0649-2022-17-2-79-92.
5. Кондратенко Н.А., Филимонова Е.В., Машегов П.Н. и др. Построение математической модели системы поддержки принятия решений в области ценообразования для электронной коммерции // Прикладная информатика. 2022. Т. 17. № 6. С. 5–17. DOI: 10.37791/2687-0649-2022-17-6-5-17.
6. Култыгин О.П. Оценка экономической эффективности проектов по созданию информационных систем // Прикладная информатика. 2021. Т. 16. № 5. С. 117–125. DOI: 10.37791/2687-0649-2021-16-5-117-125.
7. Култыгин О.П., Люблинская Н.Н., Токмакова Е.Н., Трубин А.Е. Проблемы и перспективы развития рынка криптовалют // Вестник Российского экономического университета имени Г.В. Плеханова. 2024. Т. 21. № 4. С. 135–147. DOI: 10.21686/2413-2829-2024-4-135-147.
8. Мелихова Л.А., Рюмшин А.В., Думм Д.В. Возможности оптимизации бизнес-процессов в организациях IT-сферы и маркетинга на основе использования искусственной нейросети // Экономика, предпринимательство и право. 2025. Т. 15. № 4. С. 2431–2442. DOI: 10.18334/err.15.4.122941.
9. Научно-практические аспекты цифровой трансформации экономики: монография / А.Ю. Анисимов, А.Е. Трубин, А.Н. Алексахин [и др.]; под общ. ред. А.Н. Алексахина, А.Ю. Анисимова, А.Е. Трубина. М.: Русайнс, 2023. 214 с. EDN: GDJVCQ.
10. Пантелеева Т.А. Интеграция инструментов искусственного интеллекта в систему стратегического менеджмента агробизнеса // Продовольственная политика и безопасность. 2021. Т. 8. № 2. С. 145–166. DOI: 10.18334/ppib.8.2.111548.
11. Сахаров А.Г., Трубин А.Е., Култыгин О.П., Анисимов А.Ю. Методические аспекты управления запасами в логистике в современных условиях // Вестник Северо-Кавказского федерального университета. 2025. № 3 (108). С. 148–161. DOI: 10.37493/2307-907X.2025.3.14.
12. Сковорцова Н.А., Захаров А.В., Булатов И.И. Цифровая трансформация бизнес-процессов на основе технологий искусственного интеллекта (российский и международный опыт) // Экономика, предпринимательство и право. 2025. Т. 15. № 1. С. 131–152. DOI: 10.18334/err.15.1.122526.
13. Трансфер технологий в инновационной экономике: учебник для вузов / А.Ю. Анисимов, О.А. Пятаева, А.Т. Волков [и др.]. М.: Издательство Юрайт, 2024. 251 с. EDN: FJGAXY.

14. Трубин А.Е., Ожередов В.А., Морозов А.А. и др. Построение и анализ модели машинного обучения для краткосрочного прогнозирования рынка биткоина на основе рекуррентных нейронных сетей // Прикладная информатика. 2022. Т. 17. №3. С. 45–54. DOI: 10.37791/2687-0649-2022-17-3-45-54.
15. Фроликов А.В., Трубин А.Е., Алексахин А.Н., Нечаев А.М. Перспективы и риски применения технологии искусственного интеллекта в корпоративном управлении // Вестник Российского экономического университета имени Г.В. Плеханова. 2025. Т. 22. № 1 (139). С. 198–208. DOI: 10.21686/2413-2829-2025-1-198-208.
16. Функциональное программирование на императивных и функциональных языках: учебник / А.Н. Алексахин, Е.И. Алехин, А.В. Андреев [и др.]. М.: КноРус, 2025. 240 с. EDN: XGVOBZ.
17. Шаврин А.В. Применение методов искусственного интеллекта в управлении рисками предприятий малого бизнеса // Молодой ученый. 2025. № 48 (599). С. 117–120. EDN: AXNIXE.
18. Шакиров Т.Р., Трубин А.Е., Култыгин О.П. Оптимизация логистических процессов в условиях глобализации рыночной экономики // Вестник Академии знаний. 2024. № 2 (61). С. 768–774. EDN: AOSQSE.
19. Fountaine, T., McCarthy, B., & Saleh, T. (2019). Building the AI-Powered Organization. *Harvard Business Review*, 97(4), 62–73. URL: <https://hbr.org/2019/07/building-the-ai-powered-organization> (дата обращения: 14.07.2026).
20. Khan, A., Le, H., Do, K. et al. (2021). DeepProcess: Supporting Business Process Execution Using a MANN-Based Recommender System (pp. 19–33). In: Hacid, H., Kao, O., Mecella, M. et al. (eds.) *Service-Oriented Computing (ICSOC 2021). Lecture Notes in Computer Science*, vol. 13121. Springer Publ. https://doi.org/10.1007/978-3-030-91431-8_2
21. Van der Aalst, W. (2016). *Process Mining: Data Science in Action*. 2nd edition. Springer Publ. <https://doi.org/10.1007/978-3-662-49851-4>
22. Weinzierl, S., Zilker, S., Dunzer, S., & Matzner, M. (2024). Machine Learning in Business Process Management: A Systematic Literature Review. *Expert Systems with Applications*, 253, 124181. <https://doi.org/10.1016/j.eswa.2024.124181>
23. Xu, F., Uszkoreit, H., Du, Y. et al. (2019). Explainable AI: A Brief Survey on History, Research Areas, Approaches and Challenges (pp. 563–574). In: Tang, J., Kan, M.-Y., Zhao, D. et al. (eds.) *Natural Language Processing and Chinese Computing (NLPCC 2019). Lecture Notes in Computer Science*, vol. 11839. Springer Publ. https://doi.org/10.1007/978-3-030-32236-6_51

Сведения об авторах

Овчинников Глеб Владиславович, ORCID 0009-0009-2569-1200, аспирант, кафедра цифровой экономики, Университет «Синергия», Москва, Россия, ovchi1331@gmail.com

Трубин Александр Евгеньевич, ORCID 0000-0002-7189-5679, SPIN 5097-5521, канд. экон. наук, доцент, заведующий кафедрой цифровой экономики, Университет «Синергия»; доцент кафедры информатики, Российский экономический университет им. Г. В. Плеханова, Москва, Россия, niburt@yandex.ru

Артемова Татьяна Викторовна, ORCID 0009-0004-5326-1623, SPIN 6649-3939, преподаватель, кафедра цифровой экономики, Университет «Синергия», Москва, Россия, tatyana.artemova.94@mail.ru

Култыгин Олег Петрович, ORCID 0000-0002-6519-1982, SPIN 7982-6994, канд. экон. наук, доцент, доцент кафедры цифровой экономики, Университет «Синергия», Москва, Россия, OKultygin@synergy.ru

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Статья поступила 16.01.2026, рассмотрена 18.02.2026, принята 22.03.2026

References

1. Adamenko, P. A., Tsubulnikova, V. Yu., & Nuzhina, I. P. (2023). Application of Machine Learning and Artificial Intelligence in Managing Business Risks in Small Business. *Journal of Applied Research*, 10, 66–72. https://doi.org/10.47576/2949-1878_2023_10_66
2. Alekseeva, T. V., Gumerov, E. A., Kultygin, O. P. et al. (2023). Development of the Architecture of an Intelligent Edge Computing Management System for IoT Systems of an Industrial Enterprise. *Information Systems and Technologies*, 6, 29–40. <https://elibrary.ru/hbwvet>
3. Zubanova, A. E., Kultygin, O. P., Lyublinskaya, N. N. et al. (2023). The Use of Neural Networks for the Analysis of Textual Information about the State of the Market. *Information Systems and Technologies*, 1, 53–64. <https://elibrary.ru/bxkwle>
4. Kirillova, E. A., Lazarev, A. I., & Kultygin, O. P. (2022). Neural Network Model for Supporting Decision-Making on Managing Cooperative Relations in Innovation Ecosystems. *Journal of Applied Informatics*, 17(2), 79–92. <https://doi.org/10.37791/2687-0649-2022-17-2-79-92>
5. Kondratenko, N. A., Filimonova, E. V., Mashegov, P. N. et al. (2022). Building the Mathematical Model of the Decision Support System in the Field Ofpricing for E-Commerce. *Journal of Applied Informatics*, 17(6), 5–17. <https://doi.org/10.37791/2687-0649-2022-17-6-5-17>
6. Kultygin, O. P. (2021). Economic Efficiency Assessment of Projects for the Information Systems Creation. *Journal of Applied Informatics*, 16(5), 117–125. <https://doi.org/10.37791/2687-0649-2021-16-5-117-125>
7. Kultygin, O. P., Lyublinskaya, N. N., Tokmakova, E. N., & Trubin, A. E. (2024). Challenges and Prospects of Crypto-Currency Market Development. *Vestnik of the Plekhanov Russian University of Economics*, 21(4), 135–147. <https://doi.org/10.21686/2413-2829-2024-4-135-147>
8. Melikhova, L. A., Ryumshin, A. V., & Dumm, D. V. (2025). Possibilities of Business Process Optimization in It and Marketing Organizations Based on an Artificial Neural Network. *Journal of Economics, Entrepreneurship and Law*, 15(4), 2431–2442. <https://doi.org/10.18334/epp.15.4.122941>
9. Anisimov, A. Yu., Trubin, A. E., Aleksakhin, A. N. et al. (2023). *Nauchno-prakticheskie aspekty cifrovoy transformacii ekonomiki: monografiya* [Scientific and Practical Aspects of the Digital Transformation of the Economy: Monograph]. *Rusains* Publ. <https://elibrary.ru/gdjvcq>
10. Panteleeva, T. A. (2021). Integration of Artificial Intelligence Tools into Agribusiness Strategic Management System. *Food Policy and Security*, 8(2), 145–166. <https://doi.org/10.18334/ppib.8.2.111548>
11. Sakharov, A. G., Trubin, A. E., Kultygin, O. P., & Anisimov, A. Yu. (2025). Methodological Aspects of Inventory Management in Logistics under Modern Conditions. *Newsletter of North-Caucasus Federal University*, 3, 148–161. <https://doi.org/10.37493/2307-907X.2025.3.14>
12. Skvortsova, N. A., Zakharov, A. V., & Bulatov, I. I. (2025). Digital Transformation of Business Processes Based on Artificial Intelligence Technologies: Russian and International Experience. *Journal of Economics, Entrepreneurship and Law*, 15(1), 131–152. <https://doi.org/10.18334/epp.15.1.122526>
13. Anisimov, A. Yu., Pyataeva, O. A., Volkov, A. T. et al. (2024). *Transfer tekhnologii v innovacionnoy ekonomike: uchebnik dlya vuzov* [Transfer of Technologies in the Innovative Economy: A Textbook for Universities]. *Yurayt* Publ. <https://elibrary.ru/fjgaxy>
14. Trubin, A. E., Ozheredov, V. A., Morozov, A. A. et al. (2022). Building and Analyzing a Machine Learning Model for Short-Term Bitcoin Market Forecasting Based on Recurrent Neural Networks. *Journal of Applied Informatics*, 17(3), 45–54. <https://doi.org/10.37791/2687-0649-2022-17-3-45-54>
15. Frolikov, A. V., Trubin, A. E., Aleksakhin, A. N., & Nechaev, A. M. (2025). Prospects and Risks of Using AI Technology in Corporate Management. *Vestnik of the Plekhanov Russian University of Economics*, 22(1), 198–208. <https://doi.org/10.21686/2413-2829-2025-1-198-208>
16. Aleksakhin, A. N., Alekhin, E. I., Andreev, A. V. et al. (2025). *Funkcional'noe programmirovaniye na imperativnykh i funkcional'nykh yazykakh: uchebnik* [Functional Programming in Imperative and Functional Languages: A Textbook]. *KnoRus* Publ. <https://elibrary.ru/xgvobz>

17. Shavrin, A. V. (2025). *Primenenie metodov iskusstvennogo intellekta v upravlenii riskami predpriyatiy malogo biznesa* [Application of Artificial Intelligence Methods in Risk Management of Small Businesses]. *Molodoy ucheniy*, 48, 117–120. <https://elibrary.ru/axnixe>
18. Shakerov, T. R., Trubin, A. E., & Kultygin, O. P. (2024). Logistic Process Optimization in a Globalized Market Economy. *Bulletin of the Academy of Knowledge*, 2, 768–774. <https://elibrary.ru/aosqse>
19. Fountaine, T., McCarthy, B., & Saleh, T. (2019). Building the AI-Powered Organization. *Harvard Business Review*, 97(4), 62–73. Available at: <https://hbr.org/2019/07/building-the-ai-powered-organization> (accessed 14.07.2026).
20. Khan, A., Le, H., Do, K. et al. (2021). DeepProcess: Supporting Business Process Execution Using a MANN-Based Recommender System (pp. 19–33). In: Hacid, H., Kao, O., Mecella, M. et al. (eds.) *Service-Oriented Computing (ICSOC 2021). Lecture Notes in Computer Science*, vol. 13121. Springer Publ. https://doi.org/10.1007/978-3-030-91431-8_2
21. Van der Aalst, W. (2016). *Process Mining: Data Science in Action*. 2nd edition. Springer Publ. <https://doi.org/10.1007/978-3-662-49851-4>
22. Weinzierl, S., Zilker, S., Dunzer, S., & Matzner, M. (2024). Machine Learning in Business Process Management: A Systematic Literature Review. *Expert Systems with Applications*, 253, 124181. <https://doi.org/10.1016/j.eswa.2024.124181>
23. Xu, F., Uszkoreit, H., Du, Y. et al. (2019). Explainable AI: A Brief Survey on History, Research Areas, Approaches and Challenges (pp. 563–574). In: Tang, J., Kan, M.-Y., Zhao, D. et al. (eds.) *Natural Language Processing and Chinese Computing (NLPCC 2019). Lecture Notes in Computer Science*, vol. 11839. Springer Publ. https://doi.org/10.1007/978-3-030-32236-6_51

About the authors

Gleb V. Ovchinnikov, ORCID 0009-0009-2569-1200, Postgraduate, Digital Economy Department, Synergy University, Moscow, Russia, ovchi1331@gmail.com

Alexander E. Trubin, ORCID 0000-0002-7189-5679, SPIN 5097-5521, Cand. Sci. (Econ.), Associate Professor, Head of Digital Economy Department, Synergy University; Associate Professor at Computer Science Department, Plekhanov Russian University of Economics, Moscow, Russia, niburt@yandex.ru

Tatyana V. Artemova, ORCID 0009-0004-5326-1623, SPIN 6649-3939, Lecturer, Digital Economy Department, Synergy University, Moscow, Russia, tatyana.artemova.94@mail.ru

Oleg P. Kultygin, ORCID 0000-0002-6519-1982, SPIN 7982-6994, Cand. Sci. (Econ.), Associate Professor at Digital Economy Department, Synergy University, Moscow, Russia, OKultygin@synergy.ru

Conflict of interest

The authors declare no conflict of interest.

Received 16.01.2026, reviewed 18.02.2026, accepted 22.03.2026