



УДК 372.8

DOI: <http://dx.doi.org/10.21686/1818-4243-2026-3-23-35>Е.В. Чумакова, Д.Г. Корнеев, М.С. Гаспарян,
А.А. ПономаревРоссийский экономический университет им. Г.В. Плеханова,
Москва, Россия

Вопросы разработки интеллектуальной системы превентивного мониторинга наступления событий операционных рисков

В рамках управления операционными рисками бизнес-процессы рассматриваются в качестве одного из генераторов рисков событий. Эмпирические данные свидетельствуют, что существенная доля операционных потерь в кредитных организациях связана с человеческим фактором, а именно с профессиональной неподготовленностью сотрудников. В этом контексте, перспективным направлением риск-менеджмента является разработка и внедрение инструментов на основе искусственного интеллекта, предназначенных для автоматизированной оценки уровня критичности операций, что позволяет нивелировать риски, порождаемые персоналом.

Целью работы является разработка интеллектуальной системы превентивного мониторинга наступления критического состояния бизнес-процесса вследствие действий или бездействий персонала для предотвращения события операционного риска. Для этого были проанализированы профессиональные и личностные

критерии оценки персонала, критерии оценки их влияния на бизнес-процесс, а также накопленные статистические показатели. Предложена общая структура системы индикации состояния бизнес-процесса, организованная по модульному принципу. В качестве составных модулей предложено использовать искусственные нейронные сети (ИНС) прямого распространения, описаны основные потоки данных, поступающие на входы ИНС. Проведено сравнение различных моделей ИНС для каждого из модулей системы.

Полученные **результаты** могут быть использованы в различных сферах деятельности, связанных с действиями персонала, для предотвращения негативных последствий наступления критического состояния бизнес-процесса.

Ключевые слова: операционные риски, действия персонала, искусственная нейронная сеть, машинное обучение, ансамбли нейронных сетей, высокоуровневая библиотека Keras.

Ekaterina V. Chumakova, Dmitry G. Korneev, Mikhail S. Gasparian, Andrey A. Ponomarev

Plekhanov Russian University of Economics, Moscow, Russia

Issues of Developing an Intelligent System for Preventive Monitoring of the Occurrence of Operational Risk Events

As part of operational risk management, business processes are considered as one of the generators of risk events. Empirical data show that a significant share of operational losses in credit institutions is associated with the human factor, namely, the professional unpreparedness of employees. In this context, a promising area of risk management is the development and implementation of tools based on artificial intelligence, designed for automated assessment of the criticality level of operations, which allows mitigating the risks generated by personnel.

The aim of the paper is to develop an intelligent system for preventive monitoring of the occurrence of a critical state of a business process due to actions or omissions of personnel to prevent an operational risk event.

To achieve this goal, professional and personal criteria for evaluating personnel, criteria for assessing their impact on the business process,

as well as accumulated statistical indexes were analyzed. The general structure of the business process status indication system is proposed, organized according to the modular principle. It is proposed to use artificial neural networks (ANN) of direct propagation as composite modules. The paper describes the main data flows coming to the ANN inputs and compares different ANN models for each of the system modules.

The results obtained can be used in various areas of activity related to personnel actions to prevent the negative consequences of the critical state of the business process.

Keywords: operational risks, personnel actions, artificial neural network, machine learning, neural network ensembles, high-level Keras library.

Введение

В последнее десятилетие кредитные организации (КО) выделяют в качестве одного из приоритетных направлений деятельности контроль и управление операционными рисками, которые могут привести к финансовым и репутационным потерям. Особый интерес представляют собой методы выявления и оценки уровня операционных рисков и их источников с целью их устранения и минимизации возможных потерь.

Контроль уровня операционных рисков представляет собой весьма нетривиальную задачу, что связано с высокой непредсказуемостью событий, приводящих к операционному риску, а также сложностью классификации источников этих событий. В соответствии с различными принятыми нормативными документами и рекомендациями [1] для снижения уровня операционного риска, КО должны вести информационную базу событий, реализовавшихся операционных рисков, а также использовать программное обеспечение, позволяющее вести мониторинг ключевых индикаторов риска (КИР).

В последнее время КО активно внедряют интеллектуальные информационные системы. Предпринимаются попытки использования ИНС, в том числе для оценки уровня операционного риска и необходимости оперативного реагирования [2, 3].

Хотя использование нейросетевых моделей не обладает явным преимуществом перед традиционными аналитическими, статистическими и оценочными методами [4, 5, 6], (например, ИНС не способны извлекать знания (формировать зависимости или интерпретировать результаты)), нейросети могут эффективно моделировать сложные нелинейные взаимосвязи, ха-

рактерные для операционных рисков. В работах [7, 8] указывается, что использование искусственных нейронных сетей в настоящее время может стать одним из перспективных направлений для определения уровня критичности событий операционного риска.

Источники событий операционного риска многообразны, достаточно сложно четко определить, что именно стало причиной возникновения потерь, тем более что часто имеет место сочетание нескольких событий, что еще более затрудняет моделирование и последующее прогнозирование рискованных ситуаций. В первую очередь это связано с большим разнообразием параметров процессов, которые необходимо учитывать и отслеживать. Причем для каждого из источников возникающих событий характерны свои показатели, которые зачастую не имеют никакого отношения к другим событиям [9, 10].

Государственные органы регулирования также постоянно ведут работу в области надзора за ОР, давая рекомендации для методик управления ими [11]. Так в соответствии с нормативными документами выделяют четыре подгруппы источников возникновения ОР:

- сбои систем и оборудования;
- действия персонала и других связанных с кредитной организацией лиц;
- недостатки процессов;
- внешние причины.

Каждая из подгрупп весьма специфична с точки зрения факторов воздействия на бизнес-процесс, и, следовательно, наиболее целесообразно анализировать и иметь объединенные в комплекс интеллектуальные системы превентивного мониторинга для каждого типа источников рискованных событий в отдельности.

В работе [2] рассмотрены источники ОР, связанные со сбоями систем и оборудова-

ния, и предложено использовать ансамбль ИНС для оценки возникновения ОР. Обученные нейросети, входящие в систему, демонстрировали хорошую точность в 97%. Для построения однородного по структуре комплекса мониторинга ОР очевидно следует сохранить подход к организации систем для оценки возникновения ОР на основе ансамблей ИНС и от остальных типов источников.

Не менее важными для анализа являются источники возникновения событий ОР, связанные с действиями или бездействием персонала [10]. КО тщательнейшим образом подходят к отбору сотрудников и следят за их профессиональной переподготовкой. Эти мероприятия безусловно снижают вероятность реализации ОР, однако, их число всё еще остается на значительном уровне [12, 13]. Очевидно, что КО нуждаются в дополнительных средствах контроля за инцидентами, приводящими к реализации ОР, связанными действиями персонала. В попытке усилить контроль в этой области КО зачастую прибегают к ужесточению дисциплинарного учета, регулярной проверке знаний сотрудников и т.п. [12]. Это безусловно важные факторы, влияющие на события возникновения ОР и обеспечивающие непрерывность бизнес-процессов, но все же далеко не единственные.

В данной работе предпринята попытка создания системы мониторинга событий ОР не только с точки зрения влияния на них профессиональных качеств персонала, но и неспецифических надпрофессиональных навыков (Soft Skills). Следует отметить, что традиционные аналитические, статистические и оценочные методики обычно не включают анализ личностных характеристик персонала и не позволяют в полной мере учитывать сложные зависимости таких слабо формализуемых параметров.

Целью проводимых исследований является организация системы мониторинга действий персонала в бизнес-процессах для выявления операционных рисков с использованием современных методов искусственного интеллекта, в частности, ансамбля ИНС.

Для достижения поставленной цели необходимо решить следующие задачи:

1. проанализировать данные, которые могут характеризовать влияние профессиональных и неспецифических надпрофессиональных навыков сотрудников на устойчивость бизнес-процесса;

2. предложить обобщенную структуру системы мониторинга событий бизнес-процесса, вызываемых действиями или бездействием персонала на основе ансамбля ИНС;

3. определить наборы целевых параметров и их количественную оценку для использования в обучающей (генеральной) выборке;

4. провести исследование точности и интерпретируемости решений, сгенерированных различными архитектурами ИНС, и выполнить сравнительный анализ полученных результатов.

В соответствии с поставленной целью и решаемыми задачами, структура работы включает введение, основную часть, заключение и список используемой литературы.

Во введении сформулирована цель исследования, приведено описание предметной области, а также приводится обоснование актуальности и значимости исследуемой проблемы.

Результаты исследования представлены в основной части статьи. Так, раздел «методы» связан с анализом порядка пяти десятков параметров, связанных с такими факторами как профессионализм сотрудников, личностные качества и лояльность к компании,

их технологическая дисциплинированность, загруженность и условия труда, а также тип события и статистика его реализации для КО с целью выявления степени их влияния на оценку состояния бизнес-процессов КО и отбора части из них для исследования. Также, в данном разделе дается обоснование использования ансамбля ИНС для оценки уровня угрозы штатному функционированию бизнес-процесса и приводится подробное описание этапов исследования. Раздел «результаты» включает описание общей структуры системы индикации критичности реализованного события на основе ансамбля ИНС, а также моделей ИНС для оценки профессиональной компетентности, надпрофессиональных навыков и критичности события ОР. В данном разделе также представлены итоговые показатели эффективности различных архитектур нейросетей, и делается вывод о возможности применения данных моделей и предлагаемого подхода в целом для оценки и превентивного мониторинга наступления событий операционных рисков. В разделе «дискуссия» приводятся общие оценки эффективности использования глубоких нейронных сетей, и делается вывод о возможности практического использования предложенных подходов к организации подобного рода систем оценки наступления событий операционных рисков.

В заключении подводятся итоги проведенного исследования и делается вывод о возможности совершенствования системы риск-менеджмента КО на базе разработанной методики.

1. Методы

1.1. Методическая основа проведенного исследования

В рамках исследования проводилось изучение влияния персонала и его действий вну-

три бизнес-процесса, а также способов их оценки с точки зрения возможного возникновения событий ОР.

На возникновение самого события ОР, а также реализации ОР влияет множество факторов, таких как профессионализм сотрудников, личностные качества и лояльность к компании, их технологическая дисциплинированность, загруженность и условия труда, а также тип события и статистика его реализации для КО [14, 15, 16]. При этом далеко не все события приводят к реализации ОР, и, тем более, к ощутимым финансовым потерям, уровень которых является разным для каждой КО. Для КО важно получать превентивный сигнал о критичности текущего состояния бизнес-процесса для того, чтобы не допустить или минимизировать возможные потери.

Таким образом, в ходе анализа произведено изучение степени влияния широкого спектра параметров, характеризующих кадровый состав, на возможность оценки реализации ОР. Рассматривались не только критерии, которые как правило собираются КО, но и которые потенциально могут быть рекомендованы к хранению. В силу этого изначально исследовалось порядка пяти десятков параметров. Некоторые из них были исключены из дальнейшего рассмотрения из-за неоднозначного влияния на оценку состояния бизнес-процесса (результат) и, как следствие, возможное получение противоречивых обучающих наборов для ИНС. В конечном счете, к исследованию был принят набор из 26 показателей, учитываемых при оценке зависимости непрерывности бизнес-процесса от воздействия персонала.

Однако, использование единственной модели ИНС накладывает дополнительные повышенные требования:

- на экспертов, которым необходимо одновременно

учитывать большое число разносторонних параметров, что может привести к снижению объективности оценки;

- на объем обучающей выборки из-за большого числа настраиваемых параметров ИНС как на этапе исследования, так и тем более на последующих этапах внедрения и эксплуатации.

При более детальном изучении 26 выделенных параметров были отмечены три основных направления оценивания влияния персонала на бизнес-процесс:

- профессиональных навыков;
- надпрофессиональных навыков;
- текущих показателей критичности события ОР.

Таким образом, все параметры могут быть разбиты на три группы. Каждая из совокупностей может быть использована для решения подзадач с использованием собственной ИНС, объединенных определенным образом в общую систему (ансамбль) для совместного принятия решения.

Так в различных работах [18, 19] предлагаются системы диагностики и управления, построенные на основе ансамбля ИНС, решающих разнородные задачи. В целом отмечается, что подобный подход к организации систем диагностики и управления, приводит к упрощению процесса обучения ИНС, улучшению наблюдаемости за состоянием процессов в целом, а также отмечается повышение точности функционирования систем. Также отмечается, что при использовании ансамбля ИНС результаты становятся более стабильными, ошибки обобщения меньше, т.е. модели, основанные на ансамблях ИНС, в большей степени обладают свойством обобщения.

Для оценки уровня угрозы штатному функционированию бизнес-процесса со стороны персонала предложено исполь-

зовать стандартную методику RAG (red-amber-green): красный (высокий риск), желтый (средний), зеленый (низкий) [20]. Аналогичный статус присваивался в случае оценки профессиональной и надпрофессиональной компетентности каждого сотрудника. Общая компетентность сотрудников в бизнес-процессе складывается из профессиональных и надпрофессиональных навыков каждого работника. При этом базовым требованием является то, что каждый специалист уже обладает минимально необходимыми компетенциями для своей должности.

В ходе проведения исследования для обучения каждой ИНС были сформированы три генеральных совокупности:

- профессиональные навыки и soft skills сотрудников оценивались по 2688 записям для каждой оценки с итоговым отношением к одной из трех зон: зеленой, желтой или красной;
- для показателей определения критичности влияния кадров на бизнес-процесс с итоговой оценкой (зеленая, желтая и красная зоны) 18700 записей.

Экспертную оценку проводили три специалиста из РЭУ им. Г.В. Плеханова, обладающие практическим опытом работы в КО.

В рамках исследования эффективности обучения были протестированы архитектуры нейронных сетей (DNN) с 2–3 скрытыми слоями, доказавшие свою эффективность в аналогичных задачах анализа последствий системных отказов [2]. Полученные результаты подтвердили высокую точность таких моделей при оценке уровня критичности возникающих событий операционных рисков бизнес-процессов. Стандартизированная структура нейросетевых решений обеспечивает их совместимость в качестве готового компонента для систем интеллектуального анализа

операционных рисков. Для моделирования применялся технологический стек на базе языка программирования Python с использованием библиотеки глубокого обучения Keras.

1.2. Этапы исследования

Первоначальный этап работы включал изучение традиционных показателей оценки сотрудников [21] и идентификацию факторов, которые могут способствовать появлению и реализации операционных рисков. Изучалась степень их воздействия на бизнес-процессы и применяемые методики измерения. В перечень анализируемых параметров вошли:

- демографические и профессиональные характеристики (возраст, опыт работы, уровень образования);
- показатели квалификации (дополнительное обучение, средний балл диплома);
- дисциплинарные аспекты и история ошибок;
- финансовое состояние сотрудника (кредитная нагрузка, иждивенцы);
- медицинские показатели.

Отдельно оценивались soft skills, включая лояльность, управленческие компетенции, коммуникативные способности и когнитивные характеристики [22]. При этом было принято во внимание участие в процессе нескольких сотрудников, что требует учета воздействия каждого из участников на событие ОР.

На следующем этапе все показатели были разделены на три группы как потенциальные входные параметры для трех ИНС: показатели профессиональной компетентности, показатели soft skills и показатели, характеризующие реализацию риска. В рамках исследования была использована трехуровневая система индикации, где красный цвет обозначает критический уровень, требующий немедленного вмешательства, желтый — средний уровень, а зеленый — допусти-

мые значения. Данная шкала применялась для качественного анализа таких параметров, как коммуникативные навыки, лояльность сотрудников и эффективность их мышления.

При анализе входных данных для нейросетевой модели исходили из следующих базовых предположений: во-первых, все принимаемые на работу сотрудники априори соответствуют установленным профессиональным стандартам и квалификационным требованиям; во-вторых, в компании действует система постоянного мониторинга и развития профессиональных компетенций персонала, включающая обязательные программы дополнительного обучения, периодические тренинги и объективную оценку усвоения учебного материала [23]. После исключения показателей с неоднозначным влиянием, которые могли привести к противоречивым результатам обучения, для нейросетевых моделей были определены конкретные архитектуры. Для нейросетевой модели оценки компетентности было выделено 10 входных нейронов, для ИНС, которая будет использоваться при оценке soft skills сотрудника – 10 входных нейронов и для ИНС оценки уровня критичности события ОР – 8 нейронов входного слоя. Все указанные ИНС имеют 3 выходных нейрона.

Следующим шагом стало создание обучающих наборов данных, где каждому показателю присваивалась экспертная оценка, отражающая потенциальную вероятность реализации событий операционного риска. Эти данные в дальнейшем использовались для последующего обучения каждой из ИНС.

Исходя из результатов предшествующих этапов работы, было предложено обучить три нейросетевые модели с различной архитектурой, включающей 2–3 скрытых слоя.

Конкретно, для оценки профессиональной компетентности персонала выбрана архитектура 10-m-3, для анализа soft skills – 10-m-3, а для определения критичности операционных рисков – 8-m-3. Количество нейронов в скрытых слоях (m) устанавливалось в соответствии с общепринятыми рекомендациями и принимало значения 15, 20 и 25. Обучение всех архитектурных решений проводилось на протяжении 200 эпох.

При построении нейросетевых моделей для оценки операционных рисков были использованы методики из исследования [2]. Для всех моделей применялся оптимизатор Adam, реализованный в библиотеке Keras. В ходе экспериментов сравнивалась эффективность различных функций активации в скрытых слоях – сигмоидальной (sigmoid) и гиперболического тангенса (tanh), тогда как на выходном слое всех моделей использовалась функция активации softmax. В качестве критерия оптимизации выбрана среднеквадратичная ошибка (MSE). Обучение нейросетевых моделей проводилось на подготовленных выборках данных: модели оценки компетентности персонала и soft skills обучались на 2688 примерах каждая, а модель оцен-

ки критичности операционных рисков – на расширенной выборке из 18700 примеров. Все данные были разделены на обучающую (80% от общего объема – 2150 и 14960 наборов соответственно), валидационную и тестовую выборки (по 10% каждая).

2. Результаты

2.1. Функциональная схема системы

Анализ причинно-следственных связей в возникновении операционных рисков, связанных с действиями (или бездействием) сотрудников в процессе выполнения рабочих задач, позволил распределить все факторы в три отдельные группы. Каждая из этих групп параметров дает возможность оценить вероятность наступления риск-событий по различным аспектам профессиональной деятельности. Очевидно, что для получения общей многосторонней оценки необходимо построение системы, учитывающей все рассмотренные аспекты.

Для этого была предложена общая структура системы превентивной индикации состояния бизнес-процесса при реализации событий ОР, представляющая собой ансамбль ИНС. В целом, структура имеет гибридную архитектуру (рис. 1), т.е. в её составе име-




Рис. 1. Общая структура системы оповещения критичности реализованного события

Fig. 1. The general structure of the alert system for indicating the criticality of a realized event

ются три модуля ИНС, решающих разнородные задачи, объединенных между собой алгоритмическими модулями, предназначенными для предварительной подготовки данных, а также обработки полученных результатов на выходе ИНС.

Модуль предварительной обработки данных представляет собой совокупность алгоритмов, выполняющих преобразование сохраненных БД исторических показателей бизнес-процесса, данных о сотрудниках, а также текущих данных по бизнес-процессу, к виду подходящему для передачи на вход ИНС. При этом формируется 20 параметров по каждому из работников, участвующих в бизнес-процессе, и 6 параметров, характеризующих сам процесс.

Система включает в себя две ИНС, выполняющие вспомогательные подзадачи, а именно ИНС оценивают уровень профессиональных компетенций и уровень надпрофессиональных навыков каждого отдельного сотрудника, задействованного в бизнес-процессе. Обе оценки выполняются на основании 10 показателей каждая.

Модуль обработки-интерпретации результатов вычисляет агрегированные показатели для этих величин по всем сотрудникам бизнес-процесса на текущий момент. Эти два агрегированных показателя поступают на вход третьей ИНС для принятия окончательного решения по уровню критичности реализовавшегося события. Решение формируется не только на основе ранее полученных оценок (2 параметра), но и учитывает статистические показатели реализовавшегося события, а также общие показатели кадрового состава, занятого в бизнес-процессе (6 параметров). Архитектура сети включает выходной слой с тремя нейронами, что позволяет отнести событие операционного риска к одному из трех це-

левых классов с низким, средним или высоким риском.

2.2. Модель ИНС для оценки профессиональной компетентности

Банковский сектор придерживается строгих стандартов в управлении профессиональными компетенциями персонала. Прием на работу осуществляется исключительно среди кандидатов с профильным образованием, после чего для сотрудников организуется система непрерывного обучения, включающая регулярные тренинги и программы профессионального развития. Тем не менее, как показывает практика, даже безупречная профессиональная подготовка не исключает возможность возникновения операционных рисков в ходе выполнения рабочих задач. Подобная ситуация обусловлена комплексом причин: полученные сотрудниками в ходе обучения новые теоретические знания требуют практического опыта их применения, эффективность работы зависит от личной мотивации специалиста, а также может ограничиваться внешними организационными обстоятельствами и производственными факторами.

При оценке профессиональной компетентности персонала была предпринята попытка учесть широкий набор характеристик, выходящий за рамки традиционных критериев образования. Среди параметров, которые можно отнести в группу показателей, прямо или косвенно демонстрирующих уровень профессиональных компетенций, изначально рассматривались даже такие как физическое состояние сотрудников, их материальная обеспеченность, семейный статус и т.п. Однако из дальнейшего рассмотрения они были исключены ввиду их неоднозначного влияния на рабочий процесс в различных обстоятельствах и не могут быть оце-

нены экспертами без противоречий. Так, например, с одной стороны сотрудник, имеющий детей, может чаще отсутствовать на рабочем месте по семейным обстоятельствам (снижение производительности), а с другой стороны, он может быть более заинтересован в сохранении рабочего места и продвижении по карьерной лестнице (повышение технологической дисциплины). При этом говорить о том, что несемейный сотрудник менее заинтересован в профессиональном росте неправильно.

Таким образом, для разрабатываемой ИНС в качестве входных параметров были отобраны следующие атрибуты, характеризующие сотрудника по трем основным направлениям:

А. Квалификация и профессиональный опыт (параметры: уровень образования (соответствует требованиям, превышает требования); средний балл документа об образовании; наличие документов о дополнительном профессиональном образовании/переподготовке/повышении квалификации и др. (при условии их необязательности); общий стаж работы в профессиональной области, соответствующей специфике бизнес-процесса; общий стаж выполнения конкретного функционала в рамках данного бизнес-процесса).

В. Трудовая дисциплина и мотивация (параметры: наличие благодарностей и иных форм поощрения; наличие дисциплинарных взысканий; наличие регистрируемых нарушений технологической дисциплины).

С. Карьерная динамика и стабильность (параметры: частота смены места работы (индикатор ротации, чаще одного раза в год); факт повышения в должности за последние пять лет).

Следовательно, архитектура нейросетевой модели анализа влияния профессиональных

компетенций участников бизнес-процессов на уровень операционных рисков представлена 10 входными параметрами (нейронами) и 3 выходными значениями, кодирующими степень риска: 1 (зеленый) — допустимый уровень, 2 (желтый) — повышенный риск, 3 (красный) — критический уровень опасности. Объем экспертных данных, использованных для обучения модели, составил 2688 наборов показателей, комплексно характеризующих профессиональные качества персонала и их связь с возможными риск-ситуациями.

2.3. Модель ИНС для оценки надпрофессиональных навыков (soft skills)

Поведение сотрудников в условиях кризисной ситуации определяется комплексом факторов, включающим как профессиональную подготовку, так и индивидуально-психологические особенности. Эти личностные характеристики могут играть двоякую роль: способствовать эффективному решению проблем или, напротив, усугублять ситуацию, создавая дополнительные угрозы для стабильности бизнес-процессов. В результате анализа выявлены следующие надпрофессиональные качества, которые оказывают наибольшее влияние на выполнение должностных обязанностей и, соответственно, могут служить входными параметрами ИНС:

1. коммуникативные навыки;
2. лояльность к компании;
3. управленческие навыки;
4. стрессоустойчивость;
5. эффективное мышление — скорость принятия решения / выполнения задач;
6. креативность;
7. ответственность / обязательность;
8. умение работать в команде;
9. адаптивность / гибкость;
10. обучаемость.

Оценка перечисленных показателей в большей степени носит достаточно субъективный характер. Однако, следует отметить, что в последнее время разрабатывается множество различных тестов и других подходов, позволяющих оценить уровень этих показателей. Также возможна дополнительная корректировка показателей с учетом исторической статистики действий сотрудника внутри компании, но это уже выходит за рамки данного исследования.

Все параметры для ИНС оценки soft skills сотрудника приняты как категориальные, для параметров стрессоустойчивость, креативность, ответственность/обязательность и умение работать в команде определялись значениями «да» (устойчив) или «нет» (не устойчив). Для остальных параметров определялось уровнем: низкий (1), средний (2) и высокий (3).

На выходе ИНС получаем уровень положительного влияния сотрудника на текущее состояние бизнес-процесса, который был оценен экспертами исходя из ранее принятой шкалы: 1 (зеленый) — допустимый уровень, 2 (желтый) — повышенный риск, 3 (красный) — критический уровень опасности.

В итоге, архитектура обобщенной модели ИНС для оценки влияния надпрофессиональных навыков на бизнес-процессы с точки зрения операционных рисков имеет архитектуру с входным слоем из 10 нейронов, соответствующих ключевым показателям soft skills, и выходным слоем из 3 нейронов, отражающих уровень влияния по описанной ранее трехуровневой шкале. Для обучения модели экспертами была сформирована генеральная выборка объемом 2688 наборов данных, каждый из которых содержит оценку взаимосвязи конкретных надпрофессиональных компетенций с

вероятностью возникновения риск-событий.

В целом по системе для бизнес-процесса (рис. 1) предварительно оценивается влияние профессиональных (по 10 показателям) и надпрофессиональных (по 10 показателям) навыков каждого из сотрудников с помощью отдельных ИНС.

2.4. Модель ИНС для оценки критичности события ОР

Окончательно решение формируется ИНС оценки критичности события ОР, которая учитывает статистические показатели реализовавшегося события, а также общие показатели кадрового состава, занятого в бизнес-процессе, включая полученные от других ИНС оценки навыков сотрудников.

Для оценки операционных рисков в качестве выходных параметров искусственной нейронной сети (ИНС) было предложено использовать следующие 8 атрибутов, каждый из которых имеет четкую числовую интерпретацию:

1. *Критичность инцидента.* Данный параметр представляет собой числовую переменную, оценивающую степень влияния произошедшего инцидента (события) на возможность возникновения операционного риска бизнес-процесса. Шкала оценки имеет три значения (уровня критичности риск-события): 1 (низкий, «зеленый», означает, что событие оказывает минимальное влияние и редко приводит к существенным потерям); 2 (средний, «желтый», означает, что событие оказывает умеренное влияние на возможность возникновения операционного риска) и 3 (высокий, «красный», означает, что событие оказывает значительное влияние на бизнес-процесс, с высокой вероятностью приводя к крупным прямым или косвенным потерям). Чем выше уровень критичности, тем выше веро-

ятность реализации операционного риска и размер потенциального ущерба.

2. *Уровень прямых потерь.* Параметр количественно оценивает масштаб прямых финансовых потерь, вызванных инцидентом определенного типа за фиксированный период наблюдений. Нормированное значение параметра, численно описывающее статистические показатели прямых потерь, вычисляется по формуле:

$$\frac{\sum P_i - P_{\min}}{k} \cdot \frac{P_{\max} - P_{\min}}{P_{\max} - P_{\min}},$$

где:

P_i — размер потери в денежном эквиваленте для i -го случая события данного типа;

k — количество случаев возникновения риск-события определенного типа;

$P_{\min}$ — минимальный порог значимости потерь, устанавливаемый внутренними регламентами КО;

$P_{\max}$ — максимальный зарегистрированный размер потери для данного типа события либо расчетный максимум при наихудшем сценарии.

Таким образом, значение параметра представляет собой число в диапазоне $[0, 1]$, где 0 соответствует потерям на уровне порога $P_{\min}$, а 1 — максимально возможным потерям ($P_{\max}$).

3. *Потенциал косвенных потерь.* Данный параметр является бинарным признаком (0 или 1), который указывает на способность инцидента определенного типа повлечь косвенные убытки (например, репутационный ущерб, штрафы со стороны регулятора, упущенную выгоду). Значение «1» присваивается, если в течение периода сбора статистики был хотя бы один инцидент, повлекший за собой косвенные потери. В противном случае атрибут принимает значение «0».

4. *Агрегированная компетентность сотрудников от-*

ветственных за текущий (оцениваемый) бизнес-процесс, получается на этапе предварительной обработки результатов, полученных ИНС в форме низкая (красная — 1), средняя (желтая — 2), высокая (зеленая — 3) компетентность.

5. *Текущая кадровая нагрузка по бизнес-процессу* — показатель того, насколько активно увольнялись работники в определенный промежуток времени. Определяется как процентное соотношение должностных позиций, на которых произошла смена сотрудника к общему числу должностных позиций, задействованных в бизнес-процессе, за оцениваемый период (значение от 0 до 1).

6. *Трудовая нормированная нагрузка на одного сотрудника* — изменяется от 0 (совсем не занят) до 3 (выполняет работу за троих), в норме составляет единицу, может превышать в случае отсутствия сотрудников по различным причинам (вакансия, больничный, отпуск и пр.).

7. *Агрегированный Soft Skills* ответственных за текущий (оцениваемый) бизнес-процесс, получается на этапе предварительной обработки результатов, полученных ИНС в форме низкий (красный — 1), средний (желтый — 2), высокий (зеленый — 3) положительный эффект.

8. *Средний возраст*, который нормирован относительно возраста выхода на пенсию.

Таким образом, предложенная модель искусственной нейронной сети (ИНС), предназначенная для классификации событий операционного риска по степени критичности, реализована на основе многослойного перцептрона. Базовая конфигурация сети включает входной слой, состоящий из восьми нейронов (что соответствует количеству анализируемых входных параметров). Выходной слой состоит из трех нейронов для обеспечения классификации событий

операционного риска по трем целевым категориям: «низкий риск», «средний риск» и «высокий риск».

2.5. Процесс обучения и оптимизация топологии ИНС

Для определения оптимальной архитектуры ИНС был проведен обширный цикл вычислительных экспериментов. В рамках исследования методом перебора анализировались различные конфигурации сетей прямого распространения (feed-forward networks). Основное внимание уделялось подбору глубины модели (количества скрытых слоев) и ее ширины (количества нейронов в каждом из этих слоев) с целью минимизации функции потерь и повышения качества результатов предсказания значений выходных параметров. Все итоговые показатели эффективности разных архитектур систематизированы в нижеприведенной таблице 1.

Полученные результаты соответствуют следующим параметрам обучения нейросетевой модели: обучение проводилось в течение 200 эпох, при этом дальнейшее увеличение количества эпох не улучшало точность предсказаний. В экспериментах использовался оптимизатор Adam с размером пакета batch_size=32 — любые отклонения от данного значения (как в сторону увеличения, так и уменьшения) приводили к снижению точности работы модели. Следует отметить, что в ходе обучения не было выявлено признаков переобучения сети, что свидетельствует о стабильности выбранной конфигурации и достоверности полученных результатов.

Как видно из данных обучения (табл. 1), наивысшую точность демонстрируют модели с двумя скрытыми уровнями, при этом число нейронов в каждом из них в $2,5 \div 3$ раза больше, чем во входном слое. В частности, для оценки критичности событий лучшие резуль-

Таблица 1 / Table 1

Результаты обучения ИНС различных архитектур
Results of training ANN of different architectures

Подзадача	Модели DNN		Функция активации							
			sigmoid				tanh			
			Acc.	Valid.	Test	mse	Acc.	Valid.	Test	mse
Компетентность сотрудника	2 скрытых слоя	10-15-15-3	96,66	92,21	92,53	0,05	98,15	93,0	94,02	0,03
		10-20-20-3	98,34	93,75	92,54	0,04	99,4	93,47	94,4	0,03
		10-25-25-3	99,35	94,37	93,66	0,03	99,86	94,33	95,9	0,023
	3 скрытых слоя	10-15-15-15-3	95,86	91,78	92,91	0,04	98,7	94,07	96,64	0,022
		10-20-20-20-3	98,23	93,49	92,16	0,036	98,74	95,7	94,4	0,032
		10-25-25-25-3	98,88	94,59	94,03	0,032	99,22	95,71	94,49	0,038
Soft skills сотрудника	2 скрытых слоя	10-15-15-3	96,77	95,68	94,58	0,033	96,92	95,15	94,83	0,035
		10-20-20-3	99,29	97,61	97,13	0,014	97,92	96,78	96,15	0,027
		10-25-25-3	99,21	97,32	96,02	0,029	97,79	96,42	95,83	0,030
	3 скрытых слоя	10-15-15-15-3	96,83	95,45	95,14	0,038	98,13	96,28	95,17	0,027
		10-20-20-20-3	97,22	96,51	96,11	0,029	98,35	96,67	95,73	0,038
		10-25-25-25-3	97,96	97,11	96,29	0,036	98,27	96,02	95,45	0,043
Критичность реализовавшегося события	2 скрытых слоя	8-15-15-3	96,81	96,22	96,54	0,06	98,43	94,2	95,13	0,042
		8-20-20-3	98,72	97,74	97,54	0,023	99,7	95,24	94,93	0,039
		8-25-25-3	99,12	98,84	97,99	0,008	97,24	95,74	95,88	0,015
	3 скрытых слоя	8-15-15-15-3	97,08	95,88	95,61	0,045	99,03	96,23	96,58	0,032
		8-20-20-20-3	97,67	97,32	96,56	0,04	98,87	97,26	97,03	0,037
		8-25-25-25-3	98,12	97,58	97,49	0,032	98,35	96,62	95,92	0,017

таты показала конфигурация 8-25-25-3 с активацией sigmoid.

На рисунке 2 приведен график зависимости обучения для лучшей из моделей ИНС определения критичности реализовавшегося события.

Как следует из данных таблицы 1, исследуемые модели продемонстрировали высокую точность на уровне 96–98%. Дальнейшее повышение эффективности работы сети, по всей видимости, возможно лишь за счет увеличения объема обучающей выборки.




Рис. 2. Кривая обучения в ИНС прямого распространения с архитектурой 8-25-25-3 для определения критичности реализовавшегося события

Fig. 2. Learning curve of ANN direct distribution with the 8-25-25-3 architecture for determining the criticality of a realized event

Функционирование обученного ансамбля ИНС было проверено на 100 реальных риск-ситуациях в КО. Результаты, полученные с использованием предложенного подхода, в 94% случаев совпали с реальным статусом инцидентов, что позволяет говорить о возможности применения ансамбля ИНС в качестве инструмента автоматизированного прогнозирования риск-инцидентов. Несмотря на то, что в комплексе ансамбль ИНС показал процент точности ре-

шений чуть ниже, чем каждая из ИНС в отдельности (94% против 97% в среднем), система показала свою работоспособность и может быть использована как вспомогательный инструмент для минимизации возможных финансовых потерь КО. Повысить точность прогнозирования можно обучением ИНС на реальных данных конкретной КО.

3. Дискуссия

Результаты исследования свидетельствуют о перспективности внедрения ансамблей нейронных сетей в системы выявления операционных рисков, возникающих вследствие действий персонала. Тестирование показало, что ИНС-модели обеспечивают высокую точность (96–98%) при классификации степени критичности событий ОР. Предложенный механизм упреждающей оценки рисков на базе нейросетевых ансамблей обладает гибкостью для адаптации к специфике конкретной кредитной орга-

низации. Для более полной оценки эффективности метода необходимо его тестирование в рамках действующей риск-менеджмент системы конкретной кредитной организации.

Принятая в работе трехуровневая градация риска (красный, желтый и зеленый), является достаточно грубой для всего разнообразия возникающих ситуаций в реальной КО и может быть не достаточной, так как является индикатором срочности реагирования и применения экстренных мер. Несмотря на это, использование ИНС не делают данное ограничение критическим для реализации подобного подхода.

В данной работе, также как и в работе [2], посвященной превентивной индикации возникновения событий операционного риска, связанного использованием ИТ-технологий, наибольшую эффективность продемонстрировали глубокие нейронные сети (DNN) с одинаковым соотношением числа входных нейронов к числу нейронов в скрытом слое, а также одинаковым числе скрытых слоев. Отличие имела только одна ИНС определения компетентности персонала в используемой функции активации. Полученная тенденция позволяет надеяться на эффективность использования подхода к организации систем оценки реализации ОР и от других источников.

Среди перспективных направлений научной работы следует отметить исследование

методов построения ансамбля нейронных сетей с целью оценки уровня критичности событий операционного риска, связанного с несовершенством или ошибочными внутренними процессами КО.

Заключение

В работе предложена организация системы оценки критичности состояния бизнес-процесса применительно к возможной реализации событий ОР, связанных с деятельностью персонала КО (неумышленные ошибки, намеренные действия или бездействие), т.е. получения упреждающего сигнала для проведения процедур с целью предотвращения или минимизации потенциальных финансовых и репутационных потерь. Для построения системы использовались методы искусственного интеллекта, а именно методы построения ансамбля нейронных сетей, в силу превосходства над другими методами по точности прогнозирования. Для увеличения обобщающей способности и повышения стабильности применялись модели, основанные на ансамбле ИНС.

Данный подход дает возможность создания прогностических систем для операционных рисков, базирующихся на стандартизированных нейромодулях, что позволяет проводить комплексный анализ всех потенциальных источников риска в кредитной организации.

Согласно проведенному ис-

следованию [24], посвященному анализу использования методов для оценки рисков в различных компаниях, в последние годы растет число публикаций в области риск-менеджмента, в том числе связанного с деятельностью персонала [25]. При этом самым популярным подходом оказалось использование глубоких ИНС, другие типы ИНС использовались в качестве решения реже и в равной степени с другими методами, т.е. в целом следует отметить значительный интерес и перспективность использования ИНС для моделирования риск-процессов.

В исследованиях [24, 25] отмечается, что при ограниченном объеме данных модели ИНС могут эффективно регуляризовать прошлые данные для изучения и лучше улавливать нелинейные закономерности, что значительно улучшает систему финансового раннего оповещения благодаря улучшенным показателям производительности.

Следовательно, описанная в данной работе методика, основанная на применении ансамбля нейронных сетей для анализа событий операционных рисков, обладает значительным потенциалом для совершенствования системы риск-менеджмента кредитной организации. Обеспечивая высокую точность и интерпретируемость прогнозов, данный подход является актуальным и способствует снижению рисков и оптимизации бизнес-процессов даже в условиях сложных и неопределенных данных.

Литература

1. Банк России № 3624-У от 15.04.2015 Указание Банка России «О требованиях к системе управления рисками и капиталом кредитной организации и банковской группы» [Электрон. ресурс] // Банк России. Режим доступа: https://cbr.ru/faq_ufr/dbrnfaq/doc/?number=3624-U.
2. Чумакова Е.В., Корнеев Д.Г., Гаспарян М.С., Махов И.С. Оценка уровня критичности операционного риска банка на основе нейросетевых технологий // Прикладная информатика. 2023. Т. 18. № 2(104). С. 103–115.

3. Chumakova E.V., Korneev D.G., Gasparian M.S., Ponomarev A.A., Makhov I.S. Building a neural network to assess the level of operational risks of a credit institution // Journal of Theoretical and Applied Information Technologies. 2023. Т. 101. № 11. С. 4205–4213.
4. Казимагомедов А.А. Банковское дело: организация деятельности центрального банка и коммерческого банка, небанковских организаций. М.: ИНФРА-М, 2017. 502 с.
5. Tavana M., Abtahi A. R., Di Caprio D., Poortarigh M. An Artificial Neural Network

and Bayesian Network Model for Liquidity Risk Assessment in Banking // *Neurocomputing*. 2017. Т. 275. С. 2525–2554.

6. Wang Yongqiao, Shouyang Wang, Kin Keung Lai. A New Fuzzy Support Vector Machine to Evaluate Credit Risk // *IEEE Transactions on Fuzzy Systems*. 2005. Т. 820. № 13. С. 31.

7. Yong Hu, Jie Su. Research on Credit Risk Evaluation of Commercial Banks Based on Artificial Neural Network Model // *Procedia Computer Science*. 2022. Т. 199. С. 1168–1176.

8. Van Liebergen B. Machine learning: A revolution in risk management and compliance? // *Journal of Financial Transformation*. 2017. Т. 45. С. 60–67.

9. Anna Chernobai, Ali Ozdagli, Jianlin Wang. Business complexity and risk management: Evidence from operational risk events in U.S. bank holding companies [Электрон. ресурс] // *Journal of Monetary Economics*. 2021. Т. 117. С. 418–440. Режим доступа: <https://www.sciencedirect.com/science/article/pii/S0304393220300209>.

10. Mainelli, Michael, and Mark Yeandle. Best execution compliance: New techniques for managing compliance risk // *The Journal of Risk Finance*. 2006. № 7. С. 301–312.

11. International Convergence of Capital Measurement and Capital Standards: A Revised Framework. Basel Committee on Banking Supervision [Электрон. ресурс]. Режим доступа: <https://www.bis.org/publ/bcbs118.pdf>.

12. Hasan, Atik and Anika, Noshin and Kendezi, Anshela and Mahdavian, Azin and Sakib, Sadman and Nnange, Metuge. The Effect of Knowledge Management and Human Resource Management on Organizations' Success [Электрон. ресурс]. 2023. Dortmund, Germany: Fachhochschule Dortmund. Режим доступа: <https://www.researchgate.net/publication/371292735>.

13. Peng Jinqian., Bao Liyuan. Construction of enterprise business management analysis framework based on big data technology. *Heliyon* [Электрон. ресурс]. 2023. № 9(6). Режим доступа: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10293672/>.

14. Bodyanskiy Y.V., Tyshchenko A.K., Deineko A.A. An evolving radial basis neural network with adaptive learning of its parameters and architecture // *Automatic Control and Computer Sciences*. 2015. Т. 49. С. 255–260.

15. Белалов Р.М. Тестирование как метод контроля и оценки сформированности компетенций // *Вестник «Сознание»*. 2021. № 1. С. 13.

16. Елькина К.В., Пак Г.Ю., Мамонтова Е.О. Теоретические аспекты системы кадрового обе-

спечения предприятия // *Политика, экономика и социальная сфера*. 2020. № 7. С. 48.

17. Кричевский М.Л., Дмитриева С.В., Мартынова Ю.А. Нейросетевая оценка компетенций персонала // *Экономика труда*. 2018. Т. 5. № 4. С. 1101–1118.

18. Sewell M. Ensemble Learning. Department of Computer Science. University College London [Электрон. ресурс]. 2008. Режим доступа: <http://machine-learning.martinsewell.com/ensembles/ensemble-learning.pdf>.

19. Cha Zhang, Yunqian Ma. Ensemble Machine Learning. Methods and Applications. NY: Springer New York, 2012.

20. Simon Ashby Fundamentals of Operational Risk Management: Understanding and Implementing Effective Tools, Policies and Frameworks. London: Kogan Page, 2022.

21. Haijun Wang, Kunyuan Mao, Wanting Wu, Haohan Luo Fintech inputs, non-performing loans risk reduction and bank performance improvement [Электрон. ресурс] // *International Review of Financial Analysis*. 2023. Т. 90. С. 102849. Режим доступа: <https://www.sciencedirect.com/science/article/pii/S1057521923003654>.

22. Hsin Huang, Gwo-Jen Hwang, Morris Siu-Yung Jong. Technological solutions for promoting employees' knowledge levels and practical skills: An SVVR-based blended learning approach for professional training [Электрон. ресурс] // *Computers & Education*. 2022. Т. 189. С. 104593. Режим доступа: <https://www.sciencedirect.com/science/article/pii/S0360131522001646>.

23. Романадзе Е.К., Семина А.П. Обзор методов оценки персонала в современных организациях // *Московский экономический журнал*. 2019. № 1. С. 7.

24. Valentin Lennart Heß, Bruno Dam'asio. Machine learning in banking risk management: Mapping a decade of evolution [Электрон. ресурс] // *International Journal of Information Management Data Insights*. 2025. Т. 5. № 1. С. 100324. Режим доступа: <https://www.sciencedirect.com/science/article/pii/S2667096825000060>.

25. Novikov V.V., Litvinov A.E., Bajina T.P., Yakunkina O.V. Express risk assessment at engineering enterprises using neural networks // *Proceedings of the International Scientific Conference on Biotechnology and Food Technology (BFT-2023)*. (Saint Petersburg, September 19–21, 2023). Saint Petersburg: 2023, E3S Web of Conferences 460(30).

References

1. Bank of Russia No. 3624-U dated 15.04.2015 Bank of Russia Instruction «On the Requirements for the Risk and Capital Management System of a Credit Institution and a Banking Group» [Internet]. Bank Rossii = Bank of Russia. Available from: https://cbr.ru/faq_ufr/dbrnfaq/doc/?number=3624-U. (In Russ.)
2. Chumakova Ye.V., Korneyev D.G., Gasparian M.S., Makhov I.S. Assessing the Level of Criticality of a Bank's Operational Risk Based on Neural Network Technologies. *Prikladnaya informatika = Applied Informatics*. 2023; 18; 2(104): 103–115. (In Russ.)
3. Chumakova E.V., Korneev D.G., Gasparian M.S., Ponomarev A.A., Makhov I.S. Building a neural network to assess the level of operational risks of a credit institution // *Journal of Theoretical and Applied Information Technologies*. 2023. T. 101. № 11. С. 4205–4213.
4. Kazimagomedov A.A. Bankovskoye delo: organizatsiya deyatelnosti tsentral'nogo banka i kommercheskogo banka, nebankovskikh organizatsiy = Banking: organization of activities of the central bank and commercial bank, non-banking organizations. M.: INFRA-M; 2017. 502 p. (In Russ.)
5. Tavana M., Abtahi A. R., Di Caprio D., Poortarigh M. An Artificial Neural Network and Bayesian Network Model for Liquidity Risk Assessment in Banking. *Neurocomputing*. 2017; 275: 2525–2554.
6. Wang Yongqiao, Shouyang Wang, Kin Keung Lai. A New Fuzzy Support Vector Machine to Evaluate Credit Risk. *IEEE Transactions on Fuzzy Systems*. 2005; 820; 13: 31.
7. Yong Hu, Jie Su. Research on Credit Risk Evaluation of Commercial Banks Based on Artificial Neural Network Model. *Procedia Computer Science*. 2022; 199: 1168–1176.
8. Van Liebergen B. Machine learning: A revolution in risk management and compliance? *Journal of Financial Transformation*. 2017; 45: 60–67.
9. Anna Chernobai, Ali Ozdagli, Jianlin Wang. Business complexity and risk management: Evidence from operational risk events in U.S. bank holding companies [Internet]. *Journal of Monetary Economics*. 2021; 117: 418–440. Available from: <https://www.sciencedirect.com/science/article/pii/S0304393220300209>.
10. Mainelli, Michael, and Mark Yeandle. Best execution compliance: New techniques for managing compliance risk. *The Journal of Risk Finance*. 2006; 7: 301–312.
11. International Convergence of Capital Measurement and Capital Standards: A Revised Framework. Basel Committee on Banking Supervision [Internet]. Available from: <https://www.bis.org/publ/bcbs118.pdf>.
12. Hasan, Atik and Anika, Noshin and Kendezi, Anshela and Mahdavian, Azin and Sakib, Sadman and Nnange, Metuge. The Effect of Knowledge Management and Human Resource Management on Organizations' Success [Internet]. 2023. Dortmund, Germany: Fachhochschule Dortmund. Available from: <https://www.researchgate.net/publication/371292735>.
13. Peng Jinqian., Bao Liyuan. Construction of enterprise business management analysis framework based on big data technology. *Heliyon* [Internet]. 2023; 9(6). Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10293672/>.
14. Bodyanskiy Y.V., Tyshchenko A.K., Deineko A.A. An evolving radial basis neural network with adaptive learning of its parameters and architecture. *Automatic Control and Computer Sciences*. 2015; 49: 255–260.
15. Belalov R.M. Testing as a Method of Monitoring and Assessing the Development of Competencies. *Vestnik «Soznaniye» = Educational Bulletin "CONSCIOUSNESS"*. 2021; 1: 13.
16. Yel'kina K.V., Pak G.YU., Mamontova Ye.O. Theoretical Aspects of the Enterprise Personnel Management System. *Politika, ekonomika i sotsial'naya sfera = Politics, Economics and Social Sphere*. 2020; 7: 48. (In Russ.)
17. Krichevskiy M.L., Dmitriyeva S.V., Martynova YU.A. Neural Network Assessment of Personnel Competencies. *Ekonomika truda = Labor Economics*. 2018; 5; 4: 1101–1118. (In Russ.)
18. Sewell M. Ensemble Learning. Department of Computer Science. University College London [Internet]. 2008. Available from: <http://machine-learning.martinsewell.com/ensembles/ensemble-learning.pdf>.
19. Cha Zhang, Yunqian Ma. Ensemble Machine Learning. Methods and Applications. NY: Springer New York; 2012.
20. Simon Ashby Fundamentals of Operational Risk Management: Understanding and Implementing Effective Tools, Policies and Frameworks. London: Kogan Page; 2022.
21. Haijun Wang, Kunyuan Mao, Wanting Wu, Haohan Luo Fintech inputs, non-performing loans risk reduction and bank performance improvement [Internet]. *International Review of Financial Analysis*. 2023; 90: 102849. Available from: <https://www.sciencedirect.com/science/article/pii/S1057521923003654>.
22. Hsin Huang, Gwo-Jen Hwang, Morris Siu-Yung Jong. Technological solutions for promoting employees' knowledge levels and practical skills: An SVVR-based blended learning approach for professional training [Internet]. *Computers & Education*. 2022; 189: 104593 Available from: <https://www.sciencedirect.com/science/article/pii/S0360131522001646>.
23. Romanadze Ye.K., Semina A.P. Review of personnel assessment methods in modern organizations. *Moskovskiy ekonomicheskii zhurnal = Moscow Economic Journal*. 2019; 1: 7. (In Russ.)
24. Valentin Lennart Heß, Bruno Dam'asio. Machine learning in banking risk management: Mapping a decade of evolution [Internet]. *International Journal of Information Management Data Insights*. 2025; 5; 1: 100324. Available from:

<https://www.sciencedirect.com/science/article/pii/S2667096825000060>.

25. Novikov V.V., Litvinov A.E., Bajina T.P., Yakunkina O.V. Express risk assessment at engineering enterprises using neural networks. Proceedings

of the International Scientific Conference on Biotechnology and Food Technology (BFT-2023). (Saint Petersburg, September 19–21, 2023). Saint Petersburg: 2023, E3S Web of Conferences 460(30). (In Russ.)

Сведения об авторах

Екатерина Витальевна Чумакова

К.ф.-м.н., доцент, доцент кафедры прикладной информатики и информационной безопасности
Российский экономический университет
им. Г.В. Плеханова,
Москва, Россия
Эл. почта: catarinach@yandex.ru

Дмитрий Геннадьевич Корнеев

К.э.н., доцент, доцент кафедры прикладной информатики и информационной безопасности
Российский экономический университет
им. Г.В. Плеханова,
Москва, Россия
Эл. почта: Korneev.DG@rea.ru

Михаил Самуилович Гаспарян

К.э.н., доцент, доцент кафедры прикладной информатики и информационной безопасности
Российский экономический университет
им. Г.В. Плеханова,
Москва, Россия
Эл. почта: Gasparian.MS@rea.ru

Андрей Александрович Пономарев

Старший преподаватель кафедры прикладной информатики и информационной безопасности
Российский экономический университет
им. Г.В. Плеханова, Москва, Россия
Эл. почта: ponomarev.AA@rea.ru

Information about the authors

Ekaterina V. Chumakova

Cand. Sci. (Physics and Mathematics), Associate Professor, Associate Professor of the Department of Applied Informatics and Information Security
Plekhanov Russian University of Economics,
Moscow, Russia
E-mail: catarinach@yandex.ru

Dmitry G. Korneev

Cand. Sci. (Economics), Associate Professor, Associate Professor of the Department of Applied Informatics and Information Security
Plekhanov Russian University of Economics,
Moscow, Russia
E-mail: Korneev.DG@rea.ru

Mikhail S. Gasparian

Cand. Sci. (Economics), Associate Professor, Associate Professor of the Department of Applied Informatics and Information Security
Plekhanov Russian University of Economics,
Moscow, Russia
E-mail: Gasparian.MS@rea.ru

Andrey A. Ponomarev

Senior Lecturer at the Department of Applied Informatics and Information Security
Plekhanov Russian University of Economics,
Moscow, Russia
E-mail: ponomarev.AA@rea.ru