

УДК 004.032.26:658.7

Научная статья

DOI: 10.35330/1991-6639-2025-27-3-29-38

EDN: DHCTWY

Нейросетевая модель оценки надежности контрагентов в системе закупок металлургического предприятия

В. В. Дьячкова, Е. С. Коваленко✉

Донбасский государственный технический университет
294204, Россия, Луганская Народная Республика, г. Алчевск, пр-т Ленина, 16

Аннотация. В статье рассматривается нейросетевая модель оценки надежности контрагентов в системе закупок металлургического предприятия. **Цель исследования** – разработка нейросетевой модели для оценки надежности контрагентов в системе управления закупками металлургического предприятия. **Результаты.** В рамках исследования произведены сбор, анализ и обработка релевантных данных, проведен комплексный анализ параметров, характеризующих поставщиков, включая финансовые, юридические, операционные, организационные и репутационные показатели, построена архитектура модели, выполнены ее обучение и проверка на тестовой выборке, а также осуществлено сравнение с традиционными подходами оценки. Результаты тестирования модели показали высокую точность прогнозирования и подтвердили целесообразность ее применения в условиях информационной неопределенности. Представлены перспективы интеграции модели в корпоративные информационные системы металлургических предприятий.

Ключевые слова: управление закупками, надежность контрагента, металлургия, искусственный интеллект, нейросеть, управление рисками, цифровизация

Поступила 06.05.2025, одобрена после рецензирования 13.05.2025, принята к публикации 19.05.2025

Для цитирования. Дьячкова В. В., Коваленко Е. С. Нейросетевая модель оценки надежности контрагентов в системе закупок металлургического предприятия // Известия Кабардино-Балкарского научного центра РАН. 2025. Т. 27. № 3. С. 29–38. DOI: 10.35330/1991-6639-2025-27-3-29-38

MSC: 68T07; 90B50

Original article

A neural network model for assessing the reliability of counterparties within a metallurgical enterprise's procurement system

V.V. Dyachkova, E.S. Kovalenko✉

Donbass State Technical University
294204, Russia, Lugansk People's Republic, Alchevsk, 16 Lenin avenue

Abstract. The article presents a neural network model for evaluating the reliability of counterparties within a metallurgical enterprise's procurement system. **Aim.** The study aims to develop a neural network model to assess the reliability of counterparties within a metallurgical enterprise's procurement management system. **Results.** The study involved collecting, analyzing and processing relevant data; conducting a comprehensive analysis of parameters characterizing suppliers, including financial, legal, operational, organizational and reputational indicators; constructing the model architecture; training and testing it on a sample; and comparing it with traditional assessment approaches. Testing the model showed that it has high forecasting accuracy and can be used in conditions of information uncertainty.

This paper presents the prospects for integrating the model into the corporate information systems of metallurgical enterprises.

Keywords: procurement management, counterparty reliability, metallurgy, artificial intelligence, neural network, risk management, digitalization

Submitted 06.05.2025,

approved after reviewing 13.05.2025,

accepted for publication 19.05.2025

For citation. Dyachkova V.V., Kovalenko E.S. A neural network model for assessing the reliability of counterparties within a metallurgical enterprise's procurement system. *News of the Kabardino-Balkarian Scientific Center of RAS.* 2025. Vol. 27. No. 3. Pp. 29–38. DOI: 10.35330/1991-6639-2025-27-3-29-38

ВВЕДЕНИЕ

Современные металлургические предприятия функционируют в условиях высокой динамики рынка, жесткой конкуренции и необходимости строгого соблюдения сроков поставок сырья и товарно-материальных ценностей. Отказ или ненадежность контрагента может привести к существенным сбоям в производственном цикле, финансовым потерям и нарушению обязательств перед конечными потребителями [1]. В связи с этим вопросы своевременной и точной оценки надежности контрагентов становятся особенно актуальными.

Традиционные методы анализа поставщиков, основанные на экспертных оценках, скоринговых картах или статической отчетности, демонстрируют ограниченную эффективность при работе с большими объемами данных и не способны выявлять скрытые риски. Кроме того, они требуют значительных временных и трудовых затрат, а результаты могут носить субъективный характер.

На фоне стремительного развития технологий обработки данных и искусственного интеллекта в промышленной сфере возникает объективная необходимость внедрения интеллектуальных систем оценки контрагентов [2]. Одним из перспективных направлений является использование нейросетевых моделей, способных выявлять сложные зависимости в многомерных выборках и формировать обоснованные прогнозы на основе как структурированных, так и неструктурированных данных.

Проблемы, касающиеся вопросов оценки надежности контрагентов, рассматривались многими российскими и зарубежными учеными и практиками. А. Д. Лузик, Е. В. Пяткова, Е. Д. Тареева, Д. В. Антипов [3] описывают процесс автоматизации оценки потенциальных поставщиков с помощью создания программного обеспечения. Е. М. Казурова [4] описывает порядок оценки поставщиков и получателей лекарственных средств. В. А. Качалов, Л. С. Дворкин, Л. Е. Скрипко [5] предлагают методы проверки поставщиков дополнительно к процедурам, предусмотренным федеральным законом¹. Л. Г. Мишура, Ю. В. Васильева [6] предлагают придерживаться метода рейтинговых оценок и универсальных критериев при оценивании поставщиков. К. Н. Митус, А. А. Митус [7] обобщили существующие методики оценки поставщиков с целью их выбора. Н. С. Херсонский, Л. Г. Большедворская [8] разработали механизм выбора надежного поставщика. С. Ю. Сивандаева [9] рассматривает аудит как механизм оценки поставщиков. С. Н. Кузьминой, В. В. Силаевой, Е. И. Екимовой [10] предложена методика обеспечения качества процесса оценки поставщиков, учитывающая требования международных стандартов на системы менеджмента безопасности пищевой

¹Федеральный закон «О закупках товаров, работ, услуг отдельными видами юридических лиц» от 18.07.2011 № 223-ФЗ. URL: https://www.consultant.ru/document/cons_doc_LAW_116964/ (дата обращения: 13.05.2025 г.)

продукции. К. С. Гордеев, А. А. Жидков, Е. С. Илюшина [11] дают определение понятию поставщика, анализируют сущность процесса поиска, выбора и оценки его надежности. Г. Г. Левкин [12] предлагает методику оценки логистической деятельности поставщиков сырья для промышленного предприятия за счет обеспечения контроля за выполнением транспортно-логистических процессов. Ю. Н. Гулевич, Г. М. Наливайко [13] разработали методику оценки поставщиков на основе системы управления базами данных. Несмотря на большое количество публикаций, посвященных оценке поставщиков, вопросы применения нейросетевых моделей в управлении закупками на металлургических предприятиях еще недостаточно проработаны и являются актуальными.

Целью настоящего исследования является разработка нейросетевой модели для оценки надежности контрагентов в системе управления закупками металлургического предприятия.

МАТЕРИАЛЫ И МЕТОДЫ

Для построения нейросетевой модели оценки надежности контрагентов в закупочной деятельности металлургического предприятия авторами использовались как внутренние, так и внешние источники информации.

Внутренние данные были получены из информационной системы металлургического предприятия ООО «ЮГМК» (г. Алчевск) и включали: реестр контрагентов, допущенных к участию в процедурах закупки; статистику выполнения договорных обязательств за 2022–2024 гг.; сведения о просрочках поставок, отклонениях от объемов, рекламациях; отчетные данные отдела закупок и юридического отдела предприятия.

Внешние данные собирались из общедоступных источников и агрегаторов: данные из Единого государственного реестра юридических лиц (ЕГРЮЛ); финансовая отчетность поставщиков (бухгалтерский баланс, отчет о финансовых результатах, отчет об изменениях капитала, отчет о движении денежных средств, отчет о целевом использовании средств); судебные дела (по базе «Картотека арбитражных дел»); информация из систем Rusprofile, СПАРК, а также новостных и аналитических порталов.

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

На основании собранных данных была сформирована выборка, включающая сведения по 427 поставщикам, принимавшим участие в закупочных процедурах предприятия. Каждому поставщику сопоставлен набор параметров, охватывающих следующие группы показателей: финансовые, операционные, юридические, репутационные, организационные.

Для осуществления бинарной классификации все контрагенты были разделены на две группы:

- надежные – поставщики, не имевшие нарушений сроков, претензий по качеству и судебных споров с предприятием за последние 12 месяцев;
- ненадежные – поставщики, по которым зафиксированы случаи срывов поставок, нарушение договорных обязательств, судебные разбирательства или частота рекламаций свыше 5 % от объема поставок.

Перед обучением нейросетевой модели был проведен следующий комплекс процедур по очистке и структурированию исходных данных:

- устранены записи с критическим уровнем пропусков (более 30 % отсутствующих значений по основным признакам). Для остальных случаев пропущенные значения заменены на медианные значения внутри соответствующих групп по отрасли или региону, что позволит сохранить баланс данных;

– числовые признаки нормализованы методом Z-преобразования для приведения всех значений к единой шкале со средним значением, близким к нулю, и единичным стандартным отклонением. Это обеспечит корректную работу функции активации в слоях нейросети и повысит сходимость при обучении;

– категориальные признаки (например, форма собственности и регион регистрации контрагента) закодированы методом one-hot-кодирования, что позволило преобразовать категориальные данные в бинарные векторы без потери информации о различиях между классами;

– проведена проверка корреляции между признаками для исключения мультиколлинеарности и повышения устойчивости модели к переобучению. Из выборки были исключены признаки с коэффициентом корреляции $|r| > 0,8$, оставшиеся признаки прошли дополнительную фильтрацию по критерию информационной ценности (information gain).

В итоговом наборе данных было оставлено 15 признаков, которые условно разделены на следующие группы:

– финансовые показатели: годовая выручка, чистая прибыль, рентабельность, коэффициент ликвидности;

– операционные характеристики: средний срок поставки, процент просроченных заказов, количество рекламаций;

– юридические параметры: количество арбитражных дел, открытые исполнительные производства;

– репутационные признаки: публичный рейтинг контрагента, наличие негативных новостей упоминаний;

– организационные: форма собственности, год основания компании, численность персонала, регион регистрации.

Проведенная предобработка данных позволила сформировать датасет из 15 372 позиций, разделенный в пропорции 80/20 на обучающую и тестовую выборки, для обучения нейросетевой модели. Это позволило минимизировать влияние выбросов и повысить достоверность прогнозов.

Авторами проведено более 80 экспериментов для определения оптимальных параметров модели. В качестве инструмента интеллектуального анализа данных и прогнозирования надежности контрагентов была выбрана нейросетевая модель типа многослойного перцептрона (Multilayer Perceptron, MLP). Такой тип архитектуры зарекомендовал себя при решении задач бинарной классификации на табличных данных, особенно в условиях наличия скрытых нелинейных зависимостей между признаками.

Выбор двух скрытых слоев обоснован необходимостью соблюдения баланса между модельной сложностью и способностью к обобщению. Слишком малое число нейронов приводило к недостаточной гибкости модели и заниженной точности. Слишком большое количество – к переобучению на тренировочной выборке, особенно при ограниченном числе наблюдений. При сравнении моделей с различными конфигурациями 16–8, 64–32, 32–16 выявлено, что архитектура 32–16 обеспечила наилучшие показатели по метрикам ROC-AUC и F1-score при приемлемом времени обучения. В скрытых слоях применена функция активации ReLU (Rectified Linear Unit), зарекомендовавшая себя как эффективная и вычислительно простая для глубоких моделей, устойчивая к проблеме затухающего градиента. Для выходного слоя использовалась сигмоида (Sigmoid), так как задача сводилась к бинарной классификации, где требуется получить вероятность принадлежности к одному из классов.

Обучение модели производилось с использованием оптимизатора Adam благодаря его способности адаптивно подстраивать скорость обучения. Значение `learning_rate = 0,001` было выбрано как обеспечившее устойчивую сходимость на реальных и искусственных данных.

Dropout-регуляризация с вероятностью 0,2 применялась на скрытых слоях, чтобы уменьшить избыточную зависимость от отдельных нейронов.

Для тестирования и разработки модели использовался Python с библиотеками TensorFlow и Keras, обеспечивающий гибкую настройку параметров сети и визуализацию результатов обучения.

На основании обучающей выборки была проведена оценка качества нейросетевой модели по основным метрикам бинарной классификации. Полученные результаты были сопоставлены с базовыми моделями (логистическая регрессия и дерево решений), что позволило объективно оценить преимущество предлагаемого подхода. Сравнительный анализ качества моделей приведен в табл. 1.

Таблица 1. Сравнительные метрики качества моделей

Table 1. Comparative metrics of model quality

Модель	Accuracy	Precision	Recall	F1-score	ROC-AUC
Логистическая регрессия	0,81	0,77	0,73	0,75	0,83
Дерево решений	0,83	0,79	0,76	0,77	0,85
Нейросетевая модель (MLP)	0,89	0,86	0,84	0,85	0,92

Как видно из таблицы, нейросетевая модель демонстрирует наилучшие значения всех ключевых метрик. Особенно важным является высокий показатель ROC-AUC = 0,92, что указывает на выраженную способность модели различать надежных и ненадежных поставщиков.

Итоговая архитектура модели включает следующие компоненты:

- входной слой: 15 нейронов – по количеству отобранных признаков;
- первый скрытый слой: 32 нейрона с функцией активации ReLU;
- второй скрытый слой: 16 нейронов, также с функцией ReLU;
- выходной слой: 1 нейрон с функцией активации Sigmoid, возвращающий вероятность принадлежности контрагента к классу «надежных».

Гиперпараметры обучения:

- функция потерь – бинарная кросс-энтропия;
- оптимизатор Adam с параметром `learning rate = 0,001`;
- количество эпох обучения – 100;
- размер батча – 32;
- метрики: accuracy, precision, recall, F1-score, ROC-AUC.

Для предотвращения переобучения в процессе обучения применялись:

- dropout-регуляризация (с вероятностью 0,2);
- раннее завершение обучения (early stopping) при отсутствии улучшения на валидационной выборке.

Разработанная модель показала высокие результаты по ключевым метрикам, превысив показатели базовых моделей – логистической регрессии и дерева решений. Это подтверждает целесообразность использования нейросетевых подходов в системе оценки надежности контрагентов металлургического предприятия.

Проведен анализ важности признаков, который показал, что наибольшее влияние на результат классификации оказывают следующие параметры: выручка и рентабельность контрагента, частота просрочек по договорам, рейтинг в открытых источниках, количество судебных дел.

На рисунке 1 представлена диаграмма важности признаков, ранжированных по степени влияния на результат.

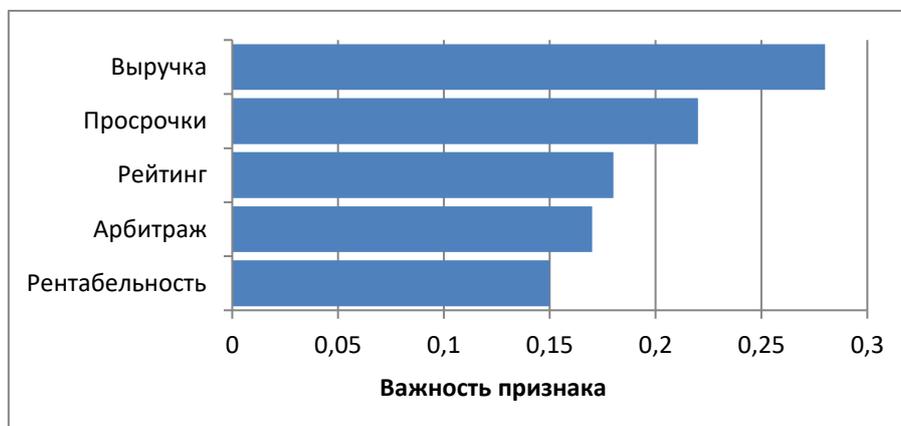


Рис. 1. Диаграмма важности признаков

Fig. 1. Feature importance diagram

Дополнительно была построена ROC-кривая (рис. 2), демонстрирующая высокую чувствительность и специфичность модели.

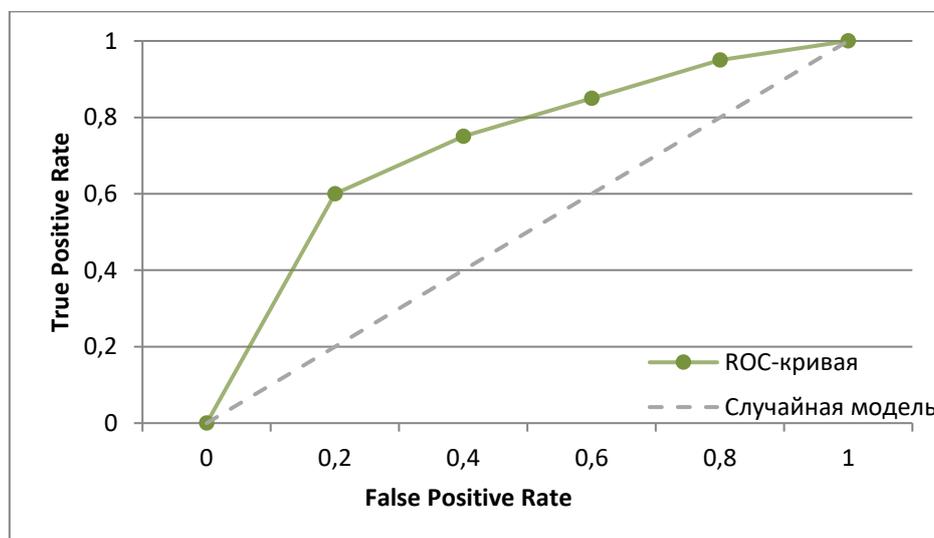


Рис. 2. ROC-кривая нейросетевой модели

Fig. 2. ROC curve of the neural network model

Разработанная модель может быть интегрирована в существующие ERP-системы металлургического предприятия в качестве модуля предварительной фильтрации поставщиков. Это позволит:

- оперативно исключать рискованных контрагентов еще на этапе подачи заявки;
- повысить прозрачность и обоснованность закупочных решений;
- снизить вероятность срывов поставок и непредвиденных финансовых потерь [14].

Предложенная архитектура многослойного перцептрона (MLP) продемонстрировала высокие значения точности классификации, а также показатели полноты, точности и ROC-AUC, существенно превосходящие результаты базовых моделей. Это свидетельствует о высокой эффективности применения нейросетевого подхода для задач предиктивной оценки контрагентов.

Важным преимуществом модели является возможность ее интеграции в корпоративные информационные системы, что позволяет автоматизировать процесс предварительной фильтрации поставщиков и существенно сократить риски, связанные с выбором ненадежных партнеров. Практическое применение модели способствует повышению прозрачности закупочных процедур, снижению издержек и укреплению устойчивости логистической цепи.

Тем не менее стоит отметить, что эффективность модели во многом зависит от качества исходных данных. Поэтому ее применение целесообразно в условиях налаженного документооборота, доступа к внешним аналитическим ресурсам и возможности актуализации информации о контрагентах.

Таким образом, результаты проведенного исследования подтверждают целесообразность и практическое применение нейросетевых моделей в сфере управления закупками, особенно в условиях неполноты, динамичности и сложности доступной информации. Разработанная нейросетевая модель, построенная на основе многослойного перцептрона, предназначена для классификации поставщиков по степени надежности на основании совокупности признаков и может быть использована в качестве инструмента предварительной фильтрации поставщиков, а также интегрирована в корпоративные информационные системы в целях автоматизации принятия решений в сфере закупок.

В дальнейшем планируется расширение обучающей выборки, включение временных рядов, отражающих поведение контрагентов во времени, а также адаптация модели для других отраслей промышленности. Кроме того, перспективным направлением является построение гибридной экспертно-нейросетевой системы, объединяющей количественные оценки и экспертные знания в едином контуре для принятия решений.

СПИСОК ЛИТЕРАТУРЫ

1. Дьячкова В. В., Коваленко Е. С. Особенности закупочной деятельности промышленного предприятия в условиях цифровизации экономики // 65 лет ДонГТИ. Наука и практика. Актуальные вопросы и инновации: Сборник тезисов докладов юбилейной Международной научно-технической конференции, Алчевск, 13–14 октября 2022 года. Часть 2. Алчевск: Донбасский государственный технический институт, 2022. С. 94–95. EDN: KSWVGH
2. Дьячкова В. В., Коваленко Е. С. Современные цифровые инструменты в управлении закупками промышленного предприятия // Направления повышения эффективности управленческой деятельности органов государственной власти и местного самоуправления: Сборник материалов V Международной научно-практической конференции, Алчевск, 15 декабря 2022 года. Алчевск: Луганский государственный университет имени Владимира Даля, 2023. С. 387–390. EDN: KPRAQC
3. Лузик А. Д., Пяткова Е. В., Тареева Е. Д., Антипов Д. В. Создание автоматизированной системы оценки потенциальных поставщиков // От качества инструментов к инструментам качества: Сборник докладов Всероссийской научно-технической конференции, Тула, 19–20 октября 2023 года. Тула: Тульский государственный университет, 2023. С. 376–380. EDN: GBPLKC

4. Казурова Е. М. Оценка поставщиков и получателей лекарственных средств аптечного склада // Вестник фармации. 2024. № 1(103). С. 26–30. DOI 10.52540/2074-9457.2024.1.26. EDN: PUSBJW
5. Качалов В. А., Дворкин Л. С., Скрипко Л. Е. О проведении оценки и повторной оценки внешних поставщиков // Методы менеджмента качества. 2020. № 3. С. 48–53. EDN: NRYLOY
6. Мишура Л. Г., Васильева Ю. В. Оценка поставщика с учетом требований ГОСТ Р ИСО 9001 // Экономика. Право. Инновации. 2020. № 2. С. 4–9. EDN: ASYOOD
7. Митус К. Н., Митус А. А. Трехпараметрическая методика оценки поставщика // Вектор экономики. 2020. № 4(46). С. 75. EDN: EWZQLS
8. Херсонский Н. С., Большедворская Л. Г. Методы выбора и оценки поставщиков с учетом категорирования параметров продукции и комплектующих // Crede Experto: транспорт, общество, образование, язык. 2023. № 4. С. 6–19. DOI: 10.51955/2312-1327_2023_4_6. EDN: VKMOFY
9. Сивандаева С. Ю. Аудит – как механизм оценки поставщиков // Моя профессиональная карьера. 2022. Т. 1. № 32. С. 19–21. EDN: IBGGVF
10. Кузьмина С. Н., Силаева В. В., Екимова Е. И. Методика обеспечения качества процесса оценки поставщиков на предприятиях пищевой промышленности // Качество. Инновации. Образование. 2022. № 4(180). С. 3–11. DOI: 10.31145/1999-513X-2022-4-03-11. EDN: DJMEUY
11. Гордеев К. С., Жидков А. А., Илюшина Е. С. и др. Методы поиска, выбора и оценки надежности поставщика // Современные научные исследования и инновации. 2021. № 3(119). С. 23. EDN: TGYGKD
12. Левкин Г. Г. Методика оценки логистической деятельности поставщиков промышленного предприятия // Логистика. 2024. № 6(211). С. 14–16. EDN: KOQRDE
13. Гулевич Ю. Н., Наливайко Г. М. Перспективы применения ИТ для выбора и оценки поставщиков материалов и комплектующих изделий // Доклады Белорусского государственного университета информатики и радиоэлектроники. 2021. Т. 19. № 5. С. 61–69. DOI: 10.35596/1729-7648-2021-19-5-61-69. EDN: BEWIRM
14. Дьячкова В. В., Коваленко Е. С. Организация тендерной деятельности промышленного предприятия в условиях цифровизации экономики // Инновации и информационные технологии в условиях цифровизации экономики: Сборник тезисов докладов международной научно-практической конференции, Алчевск, 27–28 апреля 2023 года. Алчевск: Донбасский государственный технический университет, 2023. С. 141–143. EDN: FWOLES

REFERENCES

1. Dyachkova V.V., Kovalenko E.S. Features of procurement activities of an industrial enterprise in the context of digitalization of the economy. *65 let DonGTI. Nauka i praktika. Aktual'nyye voprosy i innovatsii* [65 years of DonSTI. Science and practice. Current issues and innovations]: *Sbornik tezisov dokladov yubileynoy Mezhdunarodnoy nauchno-tekhnicheskoy konferentsii*, Alchevsk, October 13–14, 2022. Part 2. Alchevsk: Donbasskiy gosudarstvennyy tekhnicheskii institut, 2022. Pp. 94–95. EDN: KSWVGH. (In Russian)
2. Dyachkova V.V., Kovalenko E.S. Modern digital tools in procurement management of an industrial enterprise. *Napravleniya povysheniya effektivnosti upravlencheskoy deyatel'nosti organov gosudarstvennoy vlasti i mestnogo samoupravleniya* [Directions for improving the efficiency of managerial activities of public authorities and local self-government]: *Sbornik materialov V Mezhdunarodnoy nauchno-prakticheskoy konferentsii*, Alchevsk, 15 dekabrya 2022 goda, Alchevsk,

December 15, 2022. Alchevsk: Luganskiy gosudarstvennyy universitet imeni Vladimira Dalya, 2023. Pp. 387–390. EDN: KPRAQC. (In Russian)

3. Luzik A.D., Pyatkova E.V., Tareeva E.D., Antipov D.V. Creation of an automated system for evaluating potential suppliers. *Ot kachestva instrumentov k instrumentam kachestva* [From the quality of tools to quality tools]: *Sbornik dokladov Vserossiyskoy nauchno-tekhnicheskoy konferentsii*, Tula, October 19–20, 2023. Tula: Tul'skiy gosudarstvennyy universitet, 2023. Pp. 376–380. EDN: GBPLKC. (In Russian)

4. Kazurova E.M. Evaluation of suppliers and recipients of medicines in a pharmacy warehouse. *Bulletin of Pharmacy*. 2024. No. 1(103). Pp. 26–30. DOI: 10.52540/2074-9457.2024.1.26. EDN: PUSBJW. (In Russian)

5. Kachalov V.A., Dvorkin L.S., Skripko L.E. On the assessment and re-assessment of external suppliers. *Quality Management Methods*. 2020. No. 3. Pp. 48–53. EDN: NRYLOY. (In Russian)

6. Mishura L.G., Vasilyeva Yu.V. Supplier assessment taking into account the requirements of GOST R ISO 9001. *Economics. Law. Innovations*. 2020. No. 2. Pp. 4–9. EDN: ASYOOD. (In Russian)

7. Mitus K.N., Mitus A.A. Three-parameter method for supplier evaluation. *Vector of Economics*. 2020. No. 4(46). P. 75. EDN: EWZQLS. (In Russian)

8. Khersonsky N.S., Bolshedvorskaya L.G. Methods for selecting and evaluating suppliers taking into account the categorization of product and component parameters. *Crede Experto: Transport, Society, Education, Language*. 2023. No. 4. Pp. 6–19. DOI: 10.51955/2312-1327_2023_4_6. EDN: VKMOFY. (In Russian)

9. Sivandaeva S.Yu. Audit as a mechanism for supplier evaluation. *My Professional Career*. 2022. Vol. 1. No. 32. Pp. 19–21. EDN: IBGGVF. (In Russian)

10. Kuzmina S.N., Silaeva V.V., Ekimova E.I. Methodology for ensuring the quality of the supplier evaluation process at food industry enterprises. *Quality. Innovations. Education*. 2022. No. 4(180). Pp. 3–11. DOI: 10.31145/1999-513X-2022-4-03-11. EDN: DJMEUY. (In Russian)

11. Gordeev K.S., Zhidkov A.A., Ilyushina E.S. et al. Methods for searching, selecting, and assessing supplier reliability. *Modern Scientific Research and Innovations*. 2021. No. 3(119). P. 23. EDN: TGYGKD. (In Russian)

12. Levkin G.G. Methodology for evaluating the logistics activities of suppliers of an industrial enterprise. *Logistics*. 2024. No. 6(211). Pp. 14–16. EDN: KOQRDE. (In Russian)

13. Gulevich Yu.N., Nalivaiko G.M. Prospects for the use of IT in the selection and evaluation of suppliers of materials and components. *Reports of the Belarusian State University of Informatics and Radioelectronics*. 2021. Vol. 19. No. 5. Pp. 61–69. DOI: 10.35596/1729-7648-2021-19-5-61-69. EDN: BEWIRM. (In Russian)

14. Dyachkova V.V., Kovalenko E.S. Organization of tender activities of an industrial enterprise in the context of digitalization of the economy. *Innovatsii i informatsionnyye tekhnologii v usloviyakh tsifrovizatsii ekonomiki* [Innovations and information technologies in the context of digitalization of the economy]: *Sbornik tezisev dokladov mezhdunarodnoy nauchno-prakticheskoy konferentsii, Alchevsk, 27–28 aprelya 2023 goda*. Alchevsk: Donbasskiy gosudarstvennyy tekhnicheskii universitet, 2023. Pp. 141–143. EDN: FWOLES. (In Russian)

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации. Авторы заявляют об отсутствии конфликта интересов.

Contribution of the authors: the authors contributed equally to this article. The authors declare no conflicts of interests.

Финансирование. Исследование проведено без спонсорской поддержки.

Funding. The study was performed with no external funding.

Информация об авторах

Дьячкова Виктория Викторовна, канд. экон. наук, доцент кафедры информационных технологий, Донбасский государственный технический университет;

294204, Россия, Луганская Народная Республика, г. Алчевск, пр-т Ленина, 16;

dyachkova.vika@gmail.com, ORCID: <https://orcid.org/0009-0003-9771-616X>, SPIN-код: 5620-0952

Коваленко Екатерина Сергеевна, ст. преподаватель кафедры информационных технологий, Донбасский государственный технический университет;

294204, Россия, Луганская Народная Республика, г. Алчевск, пр-т Ленина, 16;

kathris92@gmail.com, ORCID: <https://orcid.org/0009-0009-8931-7138>, SPIN-код: 9202-9286

Information about the authors

Victoria V. Dyachkova, Candidate of Economic Sciences, Associate Professor of the Department of Information Technology, Donbass State Technical University;

294204, Russia, Lugansk People's Republic, Alchevsk, 16 Lenin avenue;

dyachkova.vika@gmail.com, ORCID: <https://orcid.org/0009-0003-9771-616X>, SPIN-code: 5620-0952

Ekaterina S. Kovalenko, Senior Lecturer of the Department of Information Technology, Donbass State Technical University;

294204, Russia, Lugansk People's Republic, Alchevsk, 16 Lenin avenue;

kathris92@gmail.com, ORCID: <https://orcid.org/0009-0009-8931-7138>, SPIN-code: 9202-9286