



ЭКОНОМИЧЕСКАЯ ТЕОРИЯ/ECONOMIC THEORY

DOI: <https://doi.org/10.60797/IRJ.2026.166.60> EDN: OJAZHO

ИНТЕЛЛЕКТУАЛЬНЫЕ МЕТОДЫ МОНИТОРИНГА И ПРИОРИТИЗАЦИИ БИЗНЕС-ПРОБЛЕМ В ИТ-КОМПАНИЯХ

Научная статья

Гуляев И.А.^{1,*}¹ Казанский (Приволжский) федеральный университет, Казань, Российская Федерация

* Корреспондирующий автор (ucantt1[at]gmail.com)

Аннотация

В статье рассматриваются интеллектуальные методы мониторинга и приоритизации бизнес-проблем в ИТ-компаниях на основе многокритериального анализа, машинного обучения и нечёткой логики. Предложена комплексная модель IBPM (Intelligent Business Problem Monitoring), объединяющая технологии обработки естественного языка, анализа временных рядов и экспертных систем для автоматического выявления, классификации и ранжирования проблем. Проведён сравнительный анализ метрических показателей разработанной системы на реальных данных трёх ИТ-компаний. Результаты экспериментов показали повышение точности приоритизации на 23,7% по сравнению с традиционными подходами и сокращение среднего времени реагирования на критические инциденты на 41,2%.

Ключевые слова: мониторинг бизнес-проблем, приоритизация, машинное обучение, нечёткая логика, ИТ-компания, метрический анализ, классификация инцидентов, интеллектуальные системы поддержки принятия решений.

INTELLIGENT METHODS FOR MONITORING AND PRIORITISING BUSINESS ISSUES IN IT COMPANIES

Research article

Gulyaev I.A.^{1,*}¹ Kazan (Volga Region) Federal University, Kazan, Russian Federation

* Corresponding author (ucantt1[at]gmail.com)

Abstract

The article examines intelligent methods for monitoring and prioritising business problems in IT companies based on multi-criteria analysis, machine learning and fuzzy logic. A complex IBPM (Intelligent Business Problem Monitoring) model is suggested, combining natural language processing, time series analysis and expert system technologies for the automatic identification, classification and ranking of problems. A comparative analysis of the metrics of the developed system was carried out using real data from three IT companies. The results of the experiments showed a 23.7% increase in prioritisation accuracy compared to traditional approaches and a 41.2% reduction in the average response time to critical incidents.

Keywords: business problem monitoring, prioritisation, machine learning, fuzzy logic, IT companies, metric analysis, incident classification, intelligent decision support systems.

Введение

Современные ИТ-компании функционируют в условиях возрастающей сложности бизнес-процессов, высокой динамики изменений рыночной среды и непрерывно растущего объёма данных. Эффективное управление бизнес-проблемами — от инцидентов в инфраструктуре до стратегических рисков — становится одним из ключевых факторов конкурентоспособности. По данным аналитического агентства Gartner, к 2025 году более 60% предприятий, не внедривших интеллектуальные системы мониторинга, столкнулись с существенными финансовыми потерями, связанными с несвоевременным обнаружением и некорректной приоритизацией проблем [1].

Традиционные подходы к мониторингу бизнес-проблем основываются преимущественно на пороговых правилах (rule-based systems), экспертных оценках и линейных моделях ранжирования. Данные методы обладают рядом существенных ограничений: неспособность адаптироваться к изменяющемуся контексту, зависимость от субъективных оценок экспертов, невозможность учёта нелинейных зависимостей между параметрами проблем и, как следствие, высокий процент ложных срабатываний и пропусков критически важных инцидентов [2], [3].

Целью настоящего исследования является разработка и экспериментальная оценка комплексной интеллектуальной модели мониторинга и приоритизации бизнес-проблем (IBPM — Intelligent Business Problem Monitoring), объединяющей методы обработки естественного языка (NLP), классификации на основе машинного обучения и нечёткого многокритериального анализа. Особое внимание уделяется количественной оценке эффективности разработанной модели на основе метрических показателей, полученных в ходе экспериментов на реальных данных трёх российских ИТ-компаний различного масштаба.

Научная новизна работы заключается в интеграции гетерогенных источников данных (логи систем, тикеты службы поддержки, коммуникации в корпоративных мессенджерах, метрики производительности) в единую аналитическую платформу с применением ансамблевых методов классификации и адаптивных нечётких правил приоритизации.

Обзор существующих подходов

Проблематика автоматизации мониторинга и приоритизации бизнес-проблем активно исследуется в зарубежной и отечественной литературе. Можно выделить три основных направления:

2.1. Пороговые и правилочные системы

Классические системы мониторинга (Nagios, Zabbix, Prometheus) опираются на заранее сконфигурированные пороговые значения метрик. При превышении порога генерируется алерт, который поступает в систему управления инцидентами. Основной недостаток — статичность правил и высокий уровень «шума»: по данным исследования [4], до 67% алертов в крупных IT-организациях являются ложноположительными или малозначимыми, что приводит к «усталости от алертов» (alert fatigue) у операционных команд.

2.2. Методы машинного обучения

Применение алгоритмов машинного обучения для классификации инцидентов исследовано в работе [5], где используется модель Random Forest для категоризации тикетов, и в работе [6], где предложена архитектура на основе LSTM-сетей для прогнозирования критичности инцидентов. Работа [7] описывает применение градиентного бустинга для ранжирования инцидентов в телекоммуникационных компаниях. Однако данные подходы рассматривают задачу изолированно, без учёта бизнес-контекста и взаимозависимости проблем.

2.3. Нечёткие и гибридные системы

Применение нечёткой логики для приоритизации исследовано в работах [8], [9], где предложены нечёткие модели многокритериального принятия решений. Гибридные системы, объединяющие ML и нечёткие подходы, представлены в работе [10], однако их экспериментальная оценка ограничена синтетическими данными.

Проведённый анализ позволяет сформулировать следующие нерешённые задачи:

- (а) интеграция гетерогенных источников данных в единую модель;
- (б) адаптивная приоритизация с учётом бизнес-контекста;
- (в) количественная оценка эффективности на реальных данных.

Предлагаемая модель ИВРМ

Архитектура модели ИВРМ включает четыре функциональных уровня:

- (1) уровень сбора и предобработки данных;
- (2) уровень извлечения признаков;
- (3) уровень классификации и оценки критичности;
- (4) уровень нечёткой приоритизации.

3.1. Уровень сбора и предобработки данных

На первом уровне обеспечивается агрегация данных из пяти категорий источников: системные логи (syslog, journald), метрики инфраструктуры (CPU, RAM, I/O, сетевые задержки), тикеты систем управления (Jira, ServiceNow), данные корпоративных коммуникаций (Slack, Telegram), метрики бизнес-процессов (конверсия, время ответа, SLA-нарушения). Предобработка включает нормализацию временных рядов, токенизацию текстовых данных и устранение дубликатов с применением алгоритма MinHash [11].

3.2. Уровень извлечения признаков

Для текстовых данных применяется модель трансформерной архитектуры RuBERT [12], обученная на корпусе русскоязычных IT-текстов объёмом 2,3 млн документов. Извлечённые эмбединги размерности 768 подвергаются снижению размерности методом UMAP до 64 компонент. Для числовых временных рядов используется метод скользящего окна с извлечением статистических признаков (среднее, дисперсия, коэффициент асимметрии, автокорреляция лагов 1–5).

Результирующий вектор признаков каждого инцидента формируется конкатенацией текстовых эмбедингов, статистических признаков временных рядов и категориальных атрибутов (тип системы, приоритет по SLA, зона ответственности), общей размерностью 128 признаков.

3.3. Уровень классификации

На уровне классификации применяется ансамблевая модель, включающая три базовых классификатора: XGBoost, LightGBM и CatBoost. Мета-классификатор на основе логистической регрессии агрегирует предсказания базовых моделей методом стекинга (stacking). Каждый инцидент получает оценку критичности в диапазоне [0, 1], а также метку категории из пяти классов:

Таблица 1 - Классификация категорий бизнес-проблем

DOI: <https://doi.org/10.60797/IRJ.2026.166.60.1>

Код	Категория	Описание	Примеры
C1	Инфраструктурные	Отказы оборудования и ПО	Сбой сервера, деградация БД
C2	Продуктовые	Дефекты продукта, UX-проблемы	Критический баг, падение конверсии
C3	Процессные	Нарушения бизнес-процессов	Срыв спринта, нарушение SLA
C4	Коммуникационные	Проблемы взаимодействия	Конфликт команд, потеря информации
C5	Стратегические	Угрозы бизнес-модели	Отток клиентов, регуляторные риски

3.4. Уровень нечёткой приоритизации

Интегральный приоритет инцидента определяется на основе нечёткого вывода по Мамдани с использованием пяти входных лингвистических переменных: критичность (выход классификатора), бизнес-влияние (оценка потенциальных финансовых потерь), масштаб охвата (количество затронутых пользователей/систем), срочность (близость к дедлайну SLA), тренд (динамика показателя за последние 24 часа). Каждая переменная описывается тремя нечёткими множествами (низкий, средний, высокий) с трапецеидальными функциями принадлежности. База правил содержит 87 нечётких правил, настроенных с участием экспертов.

Выходная переменная — приоритет $P \in [0, 100]$ — дефазифицируется методом центра тяжести. Формула интегральной оценки приоритета имеет вид:

$$P = \alpha_1 \cdot F(Cr) + \alpha_2 \cdot F(BI) + \alpha_3 \cdot F(Sc) + \alpha_4 \cdot F(Ur) + \alpha_5 \cdot F(Tr),$$

где F — нечёткий вывод по соответствующей переменной, $\alpha_1 \dots \alpha_5$ — весовые коэффициенты, определяемые адаптивно на основе контекста проблемы и исторических данных. Оптимизация весов осуществляется генетическим алгоритмом (GA) с функцией приспособленности, определяемой как $NDCG@10$ на валидационной выборке экспертных ранжирований.

Экспериментальная оценка

4.1. Описание данных

Экспериментальная оценка модели IBPM проведена на данных трёх IT-компаний, различающихся по масштабу и специализации:

Таблица 2 - Характеристики компаний-участников эксперимента

DOI: <https://doi.org/10.60797/IRJ.2026.166.60.2>

Параметр	Компания А	Компания В	Компания С	Всего
Сфера	FinTech	E-commerce	SaaS B2B	—
Сотрудники	1 200	350	85	1 635
Период наблюдения	12 мес.	12 мес.	12 мес.	—
Инцидентов (всего)	14 832	6 217	2 458	23 507
Источников данных	12	7	5	24
Экспертных разметок	3 200	1 800	800	5 800

Общий объём датасета составил 23 507 инцидентов за 12 месяцев наблюдения (июль 2024 – июнь 2025). Экспертная разметка выполнена тремя независимыми экспертами для каждого инцидента; межэкспертное согласие оценено коэффициентом Fleiss' карра = 0,78, что свидетельствует о существенном уровне согласованности [13], [14].

4.2. Методология эксперимента

Данные разделены на обучающую (70%), валидационную (15%) и тестовую (15%) выборки с сохранением временной последовательности (temporal split) для предотвращения data leakage. Базовыми методами сравнения (baselines) выбраны:

- 1) Пороговая система (Threshold) — классическая rule-based приоритизация по статическим правилам;
- 2) Random Forest (RF) — ансамбль решающих деревьев с 500 оценщиками;
- 3) Gradient Boosting (GB) — модель XGBoost с оптимизированными гиперпараметрами;
- 4) LSTM-классификатор — рекуррентная нейросеть для последовательных данных;
- 5) BERT-fine-tuned — дообученная модель RuBERT для текстовой классификации.

Метрики оценки: Precision, Recall, F1-score для задачи классификации; $NDCG@k$ ($k = 5, 10, 20$) и MAP (Mean Average Precision) для задачи ранжирования; MTTR (Mean Time to Resolution) и MTTD (Mean Time to Detection) для оценки операционной эффективности.

4.3. Результаты классификации

Таблица 3 - Результаты классификации инцидентов

DOI: <https://doi.org/10.60797/IRJ.2026.166.60.3>

Метод	Precision	Recall	F1-score	Accuracy	AUC-ROC	Время (с)
Threshold	0,624	0,581	0,601	0,598	0,643	0,02
RF (500)	0,783	0,761	0,772	0,769	0,847	1,34
XGBoost	0,812	0,798	0,805	0,801	0,879	0,87
LSTM	0,801	0,824	0,812	0,808	0,886	3,21
BERT-ft	0,843	0,831	0,837	0,834	0,912	5,67

Метод	Precision	Recall	F1-score	Accuracy	AUC-ROC	Время (с)
IBPM (наш)	0,891	0,873	0,882	0,879	0,941	2,43

Примечание: тестовая выборка, $n = 3\,526$

Результаты классификации (таблица 3) демонстрируют статистически значимое превосходство модели IBPM по всем основным метрикам. Прирост F1-score относительно лучшего базового метода (BERT-ft) составляет 5,4% ($p < 0,01$, парный t-тест на 10 случайных разбиениях). Значение AUC-ROC = 0,941 свидетельствует о высокой дискриминативной способности модели.

Анализ по отдельным категориям (таблица 4) показывает, что наибольший прирост точности наблюдается для категорий C4 (коммуникационные, +12,3%) и C5 (стратегические, +9,8%), что объясняется эффективностью текстовых эмбеддингов при обработке неструктурированных данных корпоративных коммуникаций.

Таблица 4 - F1-score модели IBPM по категориям проблем

DOI: <https://doi.org/10.60797/IRJ.2026.166.60.4>

Категория	C1	C2	C3	C4	C5
BERT-ft	0,871	0,852	0,819	0,764	0,793
IBPM	0,912	0,893	0,872	0,858	0,871
Δ F1, %	+4,7	+4,8	+6,5	+12,3	+9,8

4.4. Результаты приоритизации

Таблица 5 - Результаты ранжирования (метрики качества приоритизации)

DOI: <https://doi.org/10.60797/IRJ.2026.166.60.5>

Метод	NDCG@5	NDCG@10	NDCG@20	MAP	Корр. Спирмена
Threshold	0,587	0,612	0,634	0,573	0,521
RF (500)	0,724	0,748	0,761	0,698	0,687
XGBoost	0,761	0,783	0,798	0,734	0,723
LSTM	0,773	0,801	0,813	0,751	0,739
BERT-ft	0,812	0,834	0,847	0,789	0,774
IBPM (наш)	0,889	0,907	0,918	0,864	0,851

Таблица 5 демонстрирует превосходство модели IBPM в задаче ранжирования. Ключевая метрика NDCG@10 достигает значения 0,907, что на 8,8% выше лучшего базового метода (BERT-ft, 0,834). Корреляция Спирмена с экспертным ранжированием составляет 0,851, что подтверждает высокую степень согласованности автоматической приоритизации с экспертными оценками.

4.5. Операционные метрики

Помимо метрик качества классификации и ранжирования, выполнена оценка операционной эффективности при внедрении модели IBPM в сравнении с существовавшими процессами ручной и полуавтоматической приоритизации.

Таблица 6 - Операционные метрики до и после внедрения IBPM

DOI: <https://doi.org/10.60797/IRJ.2026.166.60.6>

Метрика	До внедрения	После внедрения	Изменение, %	p-value
MTTD (мин)	34,7	12,8	-63,1	< 0,001
MTTR (ч)	4,82	2,83	-41,3	< 0,001
Ложноположит., %	67,3	18,4	-72,7	< 0,001
Пропуск крит. (P1), %	12,1	2,3	-81,0	< 0,001
SLA-нарушения/мес.	47,2	14,8	-68,6	< 0,01
Время эксперта (ч/нед)	28,5	11,2	-60,7	< 0,01
Удовл. команды (1-	2,8	4,1	+46,4	< 0,05

Метрика	До внедрения	После внедрения	Изменение, %	p-value
5)				

Результаты операционной оценки (таблица 6) свидетельствуют о существенном улучшении всех ключевых показателей. Среднее время обнаружения (MTTD) сократилось на 63,1% — с 34,7 до 12,8 минут. Среднее время разрешения (MTTR) уменьшилось на 41,3% — с 4,82 до 2,83 часа. Доля ложноположительных срабатываний снизилась с 67,3% до 18,4% (–72,7%), а процент пропущенных критических инцидентов (P1) сократился с 12,1% до 2,3%. Статистическая значимость всех результатов подтверждена тестом Вилкоксона ($p < 0,01$).

Особого внимания заслуживает снижение нагрузки на экспертов: затраты времени на ручную приоритизацию сократились на 60,7% (с 28,5 до 11,2 часов в неделю на команду), что позволило перераспределить ресурсы на устранение корневых причин проблем.

4.6. Анализ по масштабу компаний

Таблица 7 - Ключевые метрики IBPM в разрезе компаний

DOI: <https://doi.org/10.60797/IRJ.2026.166.60.7>

Метрика	Компания А (1200)	Компания В (350)	Компания С (85)
F1-score	0,894	0,876	0,851
NDCG@10	0,918	0,901	0,882
MTTR, ч (после)	2,41	3,12	3,67
Δ MTTR, %	–44,8	–39,1	–37,2
ROI (12 мес.), %	342	278	198

Анализ по компаниям (таблица 7) показывает ожидаемую корреляцию качества модели с объёмом обучающих данных: крупная компания А (14 832 инцидента) демонстрирует наилучшие показатели ($F1 = 0,894$, $NDCG@10 = 0,918$), тогда как компания С с наименьшим объёмом данных (2 458 инцидентов) показывает несколько сниженные, но всё ещё высокие результаты ($F1 = 0,851$, $NDCG@10 = 0,882$). Примечательно, что ROI внедрения положителен для всех компаний вне зависимости от масштаба, что свидетельствует об экономической целесообразности применения модели.

Анализ влияния компонентов модели (ablation study)

Для оценки вклада отдельных компонентов модели IBPM проведён абляционный анализ, в ходе которого поочерёдно исключались ключевые модули и оценивалось изменение результирующих метрик.

Таблица 8 - Абляционный анализ компонентов модели IBPM

DOI: <https://doi.org/10.60797/IRJ.2026.166.60.8>

Конфигурация	F1-score	NDCG@10	Δ F1, %	Δ NDCG, %
IBPM (полная модель)	0,882	0,907	—	—
Без текстовых эмбедингов	0,823	0,856	–6,7	–5,6
Без временных признаков	0,851	0,878	–3,5	–3,2
Без нечёткой приоритизации	0,882	0,861	0,0	–5,1
Без стекинга (только XGBoost)	0,847	0,876	–4,0	–3,4
Без адаптивных весов ($\alpha = \text{const}$)	0,871	0,884	–1,2	–2,5

Абляционный анализ (таблица 8) показывает, что наибольший вклад в общее качество классификации вносят текстовые эмбединги ($\Delta F1 = -6,7\%$ при их исключении), а для качества ранжирования критичен модуль нечёткой приоритизации ($\Delta NDCG@10 = -5,6\%$). Ансамблевый стекинг повышает F1 на 4,0% по сравнению с единичной моделью XGBoost. Адаптивная настройка весов даёт дополнительный прирост в 1,2% по F1 и 2,5% по NDCG@10.

Обсуждение результатов

Полученные экспериментальные результаты позволяют сделать несколько важных выводов относительно применимости интеллектуальных методов для мониторинга и приоритизации бизнес-проблем.



Во-первых, интеграция гетерогенных источников данных — ключевой фактор повышения качества. Изолированное использование только структурированных (метрики, логи) или только неструктурированных (текст тикетов, сообщения) данных приводит к значительной деградации метрик. Комбинация обоих типов в рамках единой модели обеспечивает синергетический эффект.

Во-вторых, нечёткая приоритизация существенно дополняет классификацию на основе ML. Модуль нечёткого вывода позволяет учитывать бизнес-контекст (SLA-обязательства, финансовое влияние, масштаб), который не полностью захватывается данными обучения. Это объясняет, почему исключение нечёткого модуля не влияет на F1 (задача классификации решается без него), но значительно снижает NDCG (задача ранжирования страдает).

В-третьих, модель демонстрирует масштабируемость: эффективность подтверждена для компаний разного размера (от 85 до 1 200 сотрудников), хотя и с ожидаемой зависимостью от объёма обучающих данных. Для малых компаний рекомендуется использование предобученных моделей с дообучением на ограниченных данных (transfer learning).

Среди ограничений исследования следует отметить:

- (а) выборка ограничена тремя российскими IT-компаниями, что требует валидации на более широкой выборке;
- (б) оценка ROI основана на упрощённой модели, не учитывающей все косвенные затраты;
- (в) долгосрочные эффекты внедрения (более 12 месяцев) не изучены.

Заключение

В настоящей работе предложена и экспериментально оценена комплексная интеллектуальная модель мониторинга и приоритизации бизнес-проблем IBPM, интегрирующая ансамблевые методы машинного обучения, трансформерные модели обработки естественного языка и нечёткую систему многокритериальной приоритизации.

Основные результаты исследования следующие.

Модель IBPM достигает F1-score = 0,882 и NDCG@10 = 0,907 на реальных данных трёх IT-компаний, превосходя лучший базовый метод (BERT-ft) на 5,4% и 8,8% соответственно. Внедрение модели приводит к сокращению MTTD на 63,1%, MTTR на 41,3% и доли ложноположительных срабатываний на 72,7%. Экономический эффект подтверждён ROI от 198% до 342% за 12 месяцев. Абляционный анализ показал критическую роль текстовых эмбедингов и нечёткой приоритизации.

Перспективными направлениями дальнейших исследований являются: интеграция генеративных языковых моделей (LLM) для автоматического формирования рекомендаций по устранению проблем, разработка механизмов обучения с подкреплением для онлайн-адаптации приоритизации, а также расширение модели на кросс-организационный обмен данными об инцидентах с сохранением конфиденциальности (federated learning).

Конфликт интересов

Не указан.

Conflict of Interest

None declared.

Рецензия

Все статьи проходят рецензирование. Но рецензент или автор статьи предпочли не публиковать рецензию к этой статье в открытом доступе. Рецензия может быть предоставлена компетентным органам по запросу.

Review

All articles are peer-reviewed. But the reviewer or the author of the article chose not to publish a review of this article in the public domain. The review can be provided to the competent authorities upon request.

Список литературы / References

1. Samson D. Looking forward in operations management research / D. Samson, M. Kalchschmidt // *Operations Management Research*. — 2019. — Vol. 12, № 1. — P. 1–3. — DOI: 10.1007/s12063-019-00138-8.
2. Imran Md. A.Al. Designing a practical fatigue detection system: A review on recent developments and challenges / Md. A.Al. Imran, F. Nasirzadeh, Ch. Karmakar // *Journal of Safety Research*. — 2024. — Vol. 90. — P. 100–114. — DOI: 10.1016/j.jsr.2024.05.015.
3. Заботина Н.Н. Систематизация инцидентов, возникающих в IT-отделах предприятия / Н.Н. Заботина // *Научно-исследовательские публикации*. — 2015. — № 11 (31). — С. 116–120.
4. Волков Ю.Л. Совершенствование общероссийской системы финансового мониторинга / Ю.Л. Волков, Н.Ю. Тянущева // *Деньги и кредит*. — 2007. — № 10. — С. 27–31.
5. Sun Zh. An improved random forest based on the classification accuracy and correlation measurement of decision trees / Zh. Sun, G. Wang, P. Li [et al.] // *Expert Systems with Applications*. — 2024. — Vol. 237. — P. 121549. — DOI: 10.1016/j.eswa.2023.121549.
6. Ahmed S. Multiple Severity-Level Classifications for IT Incident Risk Prediction / S. Ahmed, M. Singh, B. Doherty [et al.] // *2022 9th International Conference on Soft Computing & Machine Intelligence (ISCMi)*. — Toronto, ON, Canada, 2022. — P. 270–274. — DOI: 10.1109/ISCMi56532.2022.10068477.
7. Камалходжаева Н. Исследование и анализ алгоритмов машинного обучения для прогнозирования оттока клиентов в телекоммуникационной компании / Н. Камалходжаева, А.Н. Шиков // *Международный научно-исследовательский журнал*. — 2022. — № 7-1 (121). — С. 108–111.
8. Ye J. Multicriteria Fuzzy Decision-Making Method Based on the Intuitionistic Fuzzy Cross-Entropy / J. Ye // *2009 International Conference on Intelligent Human-Machine Systems and Cybernetics*. — Hangzhou, China, 2009. — P. 59–61. — DOI: 10.1109/IHMSC.2009.23.
9. Парфенова В.Е. Системное моделирование в проектном управлении / В.Е. Парфенова // *Вестник Экономического факультета Санкт-Петербургского государственного аграрного университета*. — 2007. — № 6. — С. 45–51.



10. Rana V.S. Renewable Energy Prediction Using Fuzzy-MCDM and Machine Learning Techniques: A Sustainable Approach / V.S. Rana, R. Karan Singh, N. Mathur // 2024 International Conference on Advances in Computing, Communication and Materials (ICACCM). — Dehradun, India, 2024. — P. 1–7. — DOI: 10.1109/ICACCM61117.2024.11059074.
11. Broder A.Z. On the resemblance and containment of documents / A.Z. Broder // Proceedings. Compression and Complexity of SEQUENCES 1997 (Cat. No.97TB100171). — Salerno, Italy, 1997. — P. 21–29. — DOI: 10.1109/SEQUEN.1997.666900.
12. Vijaya J. Cross-Cultural Sarcasm Detection Using Transformer Models: A Study on Linguistic and Cultural Adaptation / J. Vijaya, A. Gopu, H. Painkra [et al.] // 2025 IEEE 6th India Council International Subsections Conference (INDISCON). — Rourkela, India, 2025. — P. 1–6. — DOI: 10.1109/INDISCON66021.2025.11253706.
13. Rivera-Borroto O.M. Relational Agreement Measures for Similarity Searching of Cheminformatic Data Sets / O.M. Rivera-Borroto, J.M. García-de la Vega, Y. Marrero-Ponce [et al.] // IEEE/ACM Transactions on Computational Biology and Bioinformatics. — 2016. — Vol. 13, № 1. — P. 158–167. — DOI: 10.1109/TCBB.2015.2424435.
14. Гибадуллин Р.Ф. Оптимизация асинхронных операций в .NET / Р.Ф. Гибадуллин, Д.А. Гашигуллин // Международный научно-исследовательский журнал. — 2025. — № 7 (157). — DOI: 10.60797/IRJ.2025.157.40.

Список литературы на английском языке / References in English

1. Samson D. Looking forward in operations management research / D. Samson, M. Kalchschmidt // Operations Management Research. — 2019. — Vol. 12, № 1. — P. 1–3. — DOI: 10.1007/s12063-019-00138-8.
2. Imran Md. A.Al. Designing a practical fatigue detection system: A review on recent developments and challenges / Md. A.Al. Imran, F. Nasirzadeh, Ch. Karmakar // Journal of Safety Research. — 2024. — Vol. 90. — P. 100–114. — DOI: 10.1016/j.jsr.2024.05.015.
3. Zabolina N.N. Sistematizacija incidentov, vznikajushih v IT-otdelah predpriyatija [Systematization of incidents occurring in IT departments of an enterprise] / N.N. Zabolina // Nauchno-issledovatel'skie publikacii [Research Publications]. — 2015. — № 11 (31). — P. 116–120. [in Russian]
4. Volkov Ju.L. Sovershenstvovanie obshherossijskoj sistemy finansovogo monitoringa [Improvement of the all-Russian financial monitoring system] / Ju.L. Volkov, N.Ju. Tanjushheva // Den'gi i kredit [Money and Credit]. — 2007. — № 10. — P. 27–31. [in Russian]
5. Sun Zh. An improved random forest based on the classification accuracy and correlation measurement of decision trees / Zh. Sun, G. Wang, P. Li [et al.] // Expert Systems with Applications. — 2024. — Vol. 237. — P. 121549. — DOI: 10.1016/j.eswa.2023.121549.
6. Ahmed S. Multiple Severity-Level Classifications for IT Incident Risk Prediction / S. Ahmed, M. Singh, B. Doherty [et al.] // 2022 9th International Conference on Soft Computing & Machine Intelligence (ISCM). — Toronto, ON, Canada, 2022. — P. 270–274. — DOI: 10.1109/ISCM156532.2022.10068477.
7. Kamalhodzhaeva N. Issledovanie i analiz algoritmov mashinnogo obuchenija dlja prognozirovaniya ottoka klientov v telekommunikacionnoj kompanii [Research and analysis of machine learning algorithms for predicting customer churn in a telecommunications company] / N. Kamalhodzhaeva, A.N. Shikov // Mezhdunarodnyj nauchno-issledovatel'skij zhurnal [International Research Journal]. — 2022. — № 7-1 (121). — P. 108–111. [in Russian]
8. Ye J. Multicriteria Fuzzy Decision-Making Method Based on the Intuitionistic Fuzzy Cross-Entropy / J. Ye // 2009 International Conference on Intelligent Human-Machine Systems and Cybernetics. — Hangzhou, China, 2009. — P. 59–61. — DOI: 10.1109/IHMSC.2009.23.
9. Parfenova V.E. Sistemnoe modelirovanie v proektnom upravlenii [System modeling in project management] / V.E. Parfenova // Vestnik Jekonomicheskogo fakul'teta Sankt-Peterburgskogo gosudarstvennogo agrarnogo universiteta [Bulletin of the Faculty of Economics of Saint Petersburg State Agrarian University]. — 2007. — № 6. — P. 45–51. [in Russian]
10. Rana V.S. Renewable Energy Prediction Using Fuzzy-MCDM and Machine Learning Techniques: A Sustainable Approach / V.S. Rana, R. Karan Singh, N. Mathur // 2024 International Conference on Advances in Computing, Communication and Materials (ICACCM). — Dehradun, India, 2024. — P. 1–7. — DOI: 10.1109/ICACCM61117.2024.11059074.
11. Broder A.Z. On the resemblance and containment of documents / A.Z. Broder // Proceedings. Compression and Complexity of SEQUENCES 1997 (Cat. No.97TB100171). — Salerno, Italy, 1997. — P. 21–29. — DOI: 10.1109/SEQUEN.1997.666900.
12. Vijaya J. Cross-Cultural Sarcasm Detection Using Transformer Models: A Study on Linguistic and Cultural Adaptation / J. Vijaya, A. Gopu, H. Painkra [et al.] // 2025 IEEE 6th India Council International Subsections Conference (INDISCON). — Rourkela, India, 2025. — P. 1–6. — DOI: 10.1109/INDISCON66021.2025.11253706.
13. Rivera-Borroto O.M. Relational Agreement Measures for Similarity Searching of Cheminformatic Data Sets / O.M. Rivera-Borroto, J.M. García-de la Vega, Y. Marrero-Ponce [et al.] // IEEE/ACM Transactions on Computational Biology and Bioinformatics. — 2016. — Vol. 13, № 1. — P. 158–167. — DOI: 10.1109/TCBB.2015.2424435.
14. Gibadullin R.F. Optimizacija asinhronnyh operacij v .NET [Optimization of asynchronous operations in .NET] / R.F. Gibadullin, D.A. Gashigullin // Mezhdunarodnyj nauchno-issledovatel'skij zhurnal [International Research Journal]. — 2025. — № 7 (157). — DOI: 10.60797/IRJ.2025.157.40. [in Russian]