

УДК 004.8:336.71

Шифр специальности ВАК: 2.3.1

З.Х. Аскеров

Экспериментальная оценка самообучающейся рекомендательной системы для банковского сектора

Актуальность. В банковском секторе персонализированные рекомендации должны быть точными, устойчивыми к изменению поведения клиентов и безопасными с учетом финансовых рисков. Особую значимость имеет проверка таких систем в условиях макроэкономических шоков, когда стандартные модели быстро теряют качество. **Цель исследования.** Оценить эффективность прототипа самообучающейся рекомендательной системы для банковских продуктов, объединяющей обучение с подкреплением, учет макроэкономического контекста и фильтрацию аномальных событий. **Методы.** Применены экспериментальное моделирование, сравнительный анализ с базовыми алгоритмами, кластеризация клиентов методом k-средних, глубокое Q-обучение, лес изоляции для выявления аномалий, а также статистическая оценка метрик P@5, NDCG@5, конверсии, F1-меры и задержки формирования рекомендаций. **Научная новизна.** Предложен комплексный подход к построению банковской рекомендательной системы, в котором адаптивная политика рекомендаций дополнена механизмами учета макроэкономических режимов и предварительного выявления аномалий. **Результаты.** В рамках синтетического эксперимента показано, что разработанный прототип превосходит базовые модели: P@5 составила 0,623, NDCG@5 – 0,712, конверсия в стабильном режиме достигла 82%, а снижение эффективности в кризисном режиме ограничилось 7%. Модуль аномалий обеспечил F1-меру не ниже 0,86, средняя задержка рекомендации составила 23 мс. **Практическая значимость.** Результаты могут быть использованы при проектировании банковских систем персонализации, выборе архитектуры рекомендательных сервисов, оценке их устойчивости и внедрении механизмов риск-контроля в цифровые каналы обслуживания клиентов.

Ключевые слова: рекомендательные системы, глубокое обучение с подкреплением, банковский сектор, персонализация, макроэкономические сценарии, детекция аномалий, метрики качества.

DOI: 10.21293/1818-0442-2026-29-1-160-165

Введение

Экспериментальная проверка персонализированных рекомендательных систем (РС) в банковском секторе критична из-за высокой стоимости ошибок и ограниченных возможностей онлайн-экспериментов. Помимо стандартной задачи ранжирования продуктовых предложений, система должна учитывать риски (мошенничество, кредитные риски), регуляторные ограничения и нестационарность поведения клиентов, усиливающуюся в периоды макроэкономической турбулентности. Поэтому при оценке банковских РС недостаточно измерить только точность: требуется анализ устойчивости к смене режима «рост/кризис», влияние модуля аномалий и измерение задержек формирования рекомендаций в режиме реального времени.

В современных исследованиях банковских рекомендаций активно используются гибридные модели [1, 2]. Отдельно рассматриваются обзоры и промышленные конвейеры персонализации финансовых сервисов [3, 4]. Вместе с тем значительная часть публикаций предполагает стационарность данных и не рассматривает поведение системы при резкой смене макроэкономических условий. Обучение с подкреплением является перспективным инструментом, поскольку позволяет оптимизировать долгосрочные показатели (например, удержание и пожизненная ценность клиента (Life Time Value, LTV)) и корректировать стратегию по мере накопления новых откликов, однако требует корректной постановки среды, функции вознаграждения и протокола оценки [5, 6]. Базо-

вые архитектуры глубокого Q-обучения и дуэльных сетей используются как алгоритмическая основа [7, 8]. В отечественных работах дополнительно рассматриваются общие постановки РС и контекстная персонализация [9, 10]. Гибридные рекомендательные модели для банковских продуктов и выявление подозрительных банковских транзакций представлены в работах [11, 12].

Для обоснования протокола экспериментов использованы публикации по банковским рекомендательным системам и персонализации финансовых сервисов [1, 2]. Обзоры и промышленные подходы к персонализации банковских продуктов учтены по работам [3, 4]. Отечественный гибридный подход рассмотрен отдельно [11]. Классические методы коллаборативной фильтрации и оптимизации ранжирования (матричная факторизация, байесовская персонализированная ранжировка (Bayesian Personalized Ranking, BPR)) использованы по работам [13, 14], а метрики качества ранжирования (CG/DCG/NDCG) – по [15]. Модели выявления подозрительных банковских операций учтены по работе [12]. Лес изоляции и его расширение рассмотрены по работам [16, 17]. Обзорные работы по обнаружению аномалий и финансового мошенничества использованы как обобщающая база [18, 19]. Для дрейфа данных использованы работы об адаптивных окнах и концептуальном дрейфе [20, 21]. Онлайн-обучение и потоковая обработка учтены по работам [22, 23], непрерывное обучение – по обзору [24]. Методы корректировки оценок на данных, собранных иной стратегией, при

рекомендациях на основе обучения с подкреплением приведены по работе [6]. Аналитические отчёты о применении методов машинного обучения в финансовых организациях и устойчивости операционных процессов использованы по источнику [25], а выявление смены режима на финансовых временных рядах – по работе [26].

Цель работы – реализовать прототип самообучающейся рекомендательной системы для банка и провести экспериментальную оценку её эффективности в сравнении с базовыми подходами. Проверяются гипотезы:

- 1) интеграция обучения с подкреплением повышает качество ранжирования продуктов относительно классических методов;
- 2) учёт аномалий повышает устойчивость и безопасность рекомендаций;
- 3) включение макроэкономических сценариев и механизма адаптации уменьшает просадку качества в кризисном режиме.

Задачи эксперимента:

- 1) реализовать модули сегментации, выявления аномалий и обучения с подкреплением в едином прототипе;
- 2) подготовить обучающий и тестовый наборы с отдельным кризисным интервалом;
- 3) определить метрики качества рекомендаций и выявления аномалий;
- 4) сравнить решение с базовыми моделями;
- 5) оценить устойчивость к смене режима и быстрое действие.

Формально задача экспериментальной проверки задаётся кортежем $Z = \langle C, P, T, E, S, A, G, f_{\text{аном}}, \pi, M \rangle$, где C – множество клиентов, P – каталог банковских продуктов, T – история транзакций, E – макроэкономический сценарий, S – пространство состояний клиента, A – множество допустимых действий рекомендательного агента, G – процедура генерации синтети-

ческих данных, $f_{\text{аном}}$ – функция оценки аномальности, π – рекомендательная политика, M – набор метрик качества. Требуется найти политику π^* , максимизирующую качество ранжирования и конверсию при ограничении уровня риска и времени формирования рекомендации.

Метод решения и допущения

Реализация прототипа. Система реализована в виде модульного программного комплекса на языке Python. Рекомендательный агент обучается с использованием нейросетевой реализации алгоритма глубокого Q-обучения (DQN); для повышения стабильности применяются буфер воспроизведения опыта и целевая сеть. Модуль выявления аномалий реализует лес изоляции [16, 17] для потоковой фильтрации и дополнительный блок контроля частоты операций (частотные аномалии). Схема взаимодействия компонентов прототипа приведена на рис. 1.

Эксперименты проведены на синтетическом наборе данных, имитирующем поведение розничных клиентов. Он включает 5 000 профилей клиентов и более 100 000 транзакций за период 2020–2025 гг. Процедура генерации включала формирование пяти типов клиентов, моделирование транзакций по категориям расходов с учётом сезонности, создание вкладов и инвестиционных позиций, задание макроэкономических режимов и внедрение контрольных аномальных событий. В тестовом периоде моделируется смена режима: после стабильного интервала вводится кризисный шок (изменение ставки, рост волатильности, перераспределение спроса на продукты), что приводит к изменению паттернов поведения клиентов. Обучение агента выполняется на данных до кризиса; в тесте проверяется способность сохранять качество при изменении условий за счёт встроенного механизма адаптации. Блок-схема обнаружения дрейфа и переключения режима адаптации показана на рис. 2.




Рис. 1. Схема контура взаимодействия компонентов прототипа самообучающейся рекомендательной системы (формирование рекомендаций и накопление откликов)




Рис. 2. Блок-схема алгоритма мониторинга дрейфа и адаптации рекомендательной политики

В блок-схеме использована общепринятая нотация: прямоугольники обозначают вычислительные операции, ромбы – условия ветвления, терминаторы – начало и завершение процедуры.

Синтетический набор данных используется как воспроизводимый экспериментальный стенд. Он не заменяет проверку на обезличенных реальных банковских логах, поэтому далее количественные результаты трактуются как первичная оценка алгоритмов, а не как доказательство промышленного превосходства разработанной системы.

Метрики качества рекомендаций. Для оценки ранжирования используются метрики точности в первых K позиций ($P@K$) и нормированной дисконтированной кумулятивной прибыли ($NDCG@K$) как стандартные метрики ранжирования рекомендаций. $P@K$ рассчитывается по формуле (1), $DCG@K$ – по формуле (2), $NDCG@K$ – по формуле (3). Для оценки модуля выявления аномалий используются точность, полнота и F1-мера; F1 рассчитывается по формуле (4). Дополнительно фиксируется бизнес-метрика конверсии (доля успешных рекомендаций) и относительная просадка качества в кризисном режиме. Метрики $DCG/NDCG$ применяются в соответствии с классической постановкой оценки ранжирования [15].

Базовые модели для сравнения. Рассмотрены следующие базовые подходы: 1) статическая система на правилах, сопоставляющая сегментам клиентов фиксированные предложения; 2) коллаборативная фильтрация (матричная факторизация) без учёта макроконтекста; 3) контентная модель, ранжирующая

продукты по сходству признаков; 4) агент обучения с подкреплением без учёта аномалий и макроадаптации (исследование исключения компонент) для оценки вклада соответствующих модулей. Для коллаборативной фильтрации используются стандартные постановки матричной факторизации и BPR [13, 14].

Формулы (1)–(4), на которые даны ссылки в описании метрик, приведены ниже.

$$P@K = \frac{1}{K} \sum_{i=1}^K rel_i, \quad (1)$$

$$DCG@K = \sum_{i=1}^K \frac{2^{rel_i} - 1}{\log_2(i+1)}, \quad (2)$$

$$NDCG@K = \frac{DCG@K}{IDCG@K}, \quad (3)$$

$$F1 = \frac{2PR}{P+R}. \quad (4)$$

Таблица 1

Набор данных и сценарии экспериментов	
Показатель	Значение
Число клиентов	5 000 профилей
Объем транзакций	100 000+ записей
Период	2020–2025 гг.
Сценарии	Рост (стабильный режим) и кризис (макрошок в тесте)

Результаты

Сегментация клиентов. На признаковом описании поведения методом k -средних выделено 5 устойчивых кластеров клиентов. Кластеры интерпретируются как «консервативные вкладчики», «активные инвесторы», «зарплатные клиенты», «кредито-ориентированные» и «высокочастотные транзакционные клиенты». В экспериментах принадлежность к кластеру добавляется в состояние агента и повышает персонализацию стратегии.

Обучение агента и выбор архитектуры. Сравнились три варианта алгоритма глубокого Q-обучения: базовая архитектура DQN, дуэльная архитектура DQN и дуэльная архитектура DQN с параметрическим шумом [27] для исследования. По итоговой средней награде и скорости сходимости лучшим оказался вариант с параметрическим шумом, достигающий стабилизации на уровне около 160 условных единиц награды к 500–600-му эпизоду обучения.

Качество рекомендаций и сравнение с базовыми моделями. Итоговые показатели качества приведены в табл. 2. На синтетическом тестовом наборе предложенная система демонстрирует $P@5 = 0,623$ и $NDCG@5 = 0,712$, что соответствует приросту 27 и 33% относительно коллаборативной фильтрации. Конверсия в стабильном режиме достигает 82%. Сравнение с базовыми моделями представлено в табл. 2.

Устойчивость в кризисном режиме. При переходе в кризис доля успешных рекомендаций снижается с 82 до 78% (просадка 7% относительно базового уровня), тогда как система на правилах теряет до 31% эффективности. Для коллаборативной фильтрации

характерна просадка порядка 15–20%. Результаты по режимам представлены в табл. 3.

Эффективность выявления аномалий. Модуль аномалий обеспечивает высокий уровень качества на встроенных аномалиях: средняя F1-мера не ниже 0,86, а для типовых мошеннических паттернов (серии переводов и нетипичные суммы) достигает 0,90–0,95 (табл. 4). Включение фильтра аномалий повышает стабильность обучения агента и улучшает P@5 примерно на 0,05 относительно варианта без фильтра (см. табл. 2).

Производительность. Среднее время формирования рекомендации в прототипе составляет 23 мс, 95-й перцентиль – 45 мс (табл. 5). Пропускная способность потоковой обработки транзакций в тесте составляет порядка 8 000 транзакций/с, что соответствует требованиям онлайн-каналов банка.

Таблица 2
Сравнение качества рекомендаций
с базовыми моделями

Модель	P@5	NDCG@5	Конверсия (рост)
Предложенная система (обучение с подкреплением + аномалии + макро)	0,623	0,712	0,82
Обучение с подкреплением без аномалий и макроадаптации	0,550	0,630	0,74
Коллаборативная фильтрация (матричная факторизация/BPR)	0,489	0,534	0,65
Система на правилах	0,400	0,530	0,60
Контентная модель	0,467	0,512	0,62

Таблица 3
Устойчивость моделей при смене макрорежима

Модель	Конверсия (рост)	Конверсия (кризис)	Просадка, %
Предложенная система	0,82	0,78	7
Обучение с подкреплением без макроадаптации	0,74	0,63	15
Коллаборативная фильтрация	0,65	0,52	20
Система на правилах	0,60	0,41	31

Таблица 4
Качество выявления аномалий на тестовых вставках

Тип аномалии	Точность	Полнота	F1
Мошеннические транзакции (встроенные)	0,93	0,92	0,92
Всплески активности (частотные аномалии)	0,95	0,94	0,94
Поведенческие выбросы (смена паттерна)	0,86	0,85	0,86

Таблица 5
Показатели производительности прототипа

Показатель	Значение
Средняя задержка рекомендации	23 мс
95-й перцентиль задержки	45 мс
Пропускная способность потока	≈ 8 000 транзакций/с

Анализ полученных результатов

Полученные результаты показывают, что каждый модуль действительно влияет на итоговое качество системы. Обучение с подкреплением повышает точность ранжирования по сравнению с коллабора-

тивной фильтрацией и системами на правилах, поскольку учитывает состояние клиента и ориентируется не только на разовый отклик, но и на долгосрочный эффект рекомендаций. Модуль выявления аномалий снижает влияние выбросов на обучение и уменьшает риск появления нерелевантных предложений в периоды подозрительной активности. Механизм макроадаптации, в свою очередь, позволяет избежать резкого снижения качества в кризисных условиях, что особенно важно для практического применения системы на волатильном рынке.

Существенным ограничением исследования является использование синтетического набора данных. При его формировании заданы поведенческие типы клиентов, макроэкономические режимы и контрольные аномалии; поэтому нельзя полностью исключить зависимость высоких значений метрик от структуры генератора, заложенных корреляций и параметров стресс-сценария. Валидация на реальных банковских данных в данной работе не проводилась из-за требований конфиденциальности и банковской тайны. Следующим этапом должна стать проверка на обезличенных логах откликов, ретроспективный back-testing и A/B-тестирование с соблюдением требований безопасности и комплаенса.

Выводы

В работе разработан и на синтетическом экспериментальном стенде проверен прототип самообучающейся рекомендательной системы для банковской сферы, который объединяет обучение с подкреплением, выявление аномалий и учет макроэкономических сценариев.

В рамках проведенного синтетического эксперимента система превосходит базовые подходы: значение P@5 составило 0,623, NDCG@5 – 0,712, а конверсия в стабильном режиме достигала 82%. Устойчивость в кризисных условиях также подтвердилась: снижение эффективности не превысило 7%.

Модуль выявления аномалий обеспечил F1 не ниже 0,86, что повысило устойчивость обучения и снизило риск формирования небезопасных или нерелевантных рекомендаций. Время отклика системы составляет несколько десятков миллисекунд, поэтому ее можно использовать в интерактивных цифровых каналах банка.

Литература

1. Gigli A. Recommender systems for banking and financial services / A. Gigli, F. Lillo, D. Regoli // Poster Track of the 11th ACM Conference on Recommender Systems (RecSys 2017). – Como, Italy: CEUR-WS.org, 2017. – P. 315–316.
2. Oyeboode O. A hybrid recommendation system for the financial service sector / O. Oyeboode, R. Orji // Journal of Banking and Financial Technology. – 2020. – Vol. 4. – P. 17–32.
3. Sharaf M. A survey on recommendation systems for financial services / M. Sharaf, E.E.D. Hemdan, A. El-Sayed, N.A. El-Bahnasawy // Multimedia Tools and Applications. – 2022. – Vol. 81, No. 12. – P. 13617–13642.
4. Vaquero-Patricio C. Recommenders in Banking: An End-to-End Personalization Pipeline within ING / C. Vaquero-Patricio, N. van Ommeren, S. Gil-Begue // Proceedings of the 15th ACM Conference on Recommender Systems (RecSys

- 2021). – Amsterdam, Netherlands: ACM, 2021. – P. 587–589. DOI: 10.1145/3460231.3474612.
5. Afsar M.M. Reinforcement learning based recommender systems: A survey / M.M. Afsar, T. Crump, B. Far // ACM Computing Surveys. – 2021. – Vol. 54, No. 3. – Article 42. – P. 1–38.
6. Chen M. Top-K off-policy correction for a REINFORCE recommender system / M. Chen, A. Beutel, P. Covington, S. Jain, F. Belletti, E. Chi // Proceedings of the 12th ACM International Conference on Web Search and Data Mining (WSDM 2019). – Melbourne, VIC, Australia: ACM, 2019. – P. 456–464. DOI: 10.1145/3289600.3290999.
7. Mnih V. Human-level control through deep reinforcement learning / V. Mnih, K. Kavukcuoglu, D. Silver et al. // Nature. – 2015. – Vol. 518, No. 7540. – P. 529–533.
8. Wang Z. Dueling Network Architectures for Deep Reinforcement Learning / Z. Wang, T. Schaul, M. Hessel et al. // Proceedings of the 33rd International Conference on Machine Learning (ICML 2016). – New York, NY, USA: PMLR, 2016. – P. 1995–2003.
9. Кутянин А.Р. Рекомендательные системы: обзор основных постановок и результатов / А.Р. Кутянин // Интеллектуальные системы. Теория и приложения. – 2017. – Т. 21, № 4. – С. 18–30.
10. Меньшикова Н.В. Обзор рекомендательных систем и возможностей учета контекста при формировании индивидуальных рекомендаций / Н.В. Меньшикова, И.В. Портнов, И.Е. Николаев // Academy. – 2016. – № 6 (9). – С. 20–22.
11. Павлов Д.А. Универсальная рекомендательная система банковских продуктов на основе гибридного подхода / Д.А. Павлов, О.С. Косюга // Научные труды КубГТУ. – 2022. – № 1. – С. 88–97.
12. Аркадьева О.Г. Модели машинного обучения как инструмент обнаружения подозрительных банковских транзакций / О.Г. Аркадьева, А.В. Петров // Вестник Сургутского государственного университета. – 2025. – Т. 13, № 3. – С. 8–21. DOI 10.35266/2949-3455-2025-3-1.
13. Koren Y. Matrix factorization techniques for recommender systems / Y. Koren, R. Bell, C. Volinsky // IEEE Computer. – 2009. – Vol. 42, No. 8. – P. 30–37.
14. Rendle S. BPR: Bayesian Personalized Ranking from Implicit Feedback / S. Rendle, C. Freudenthaler, Z. Gantner, L. Schmidt-Thieme // Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence (UAI 2009). – Montreal, QC, Canada: AUAI Press, 2009. – P. 452–461.
15. Järvelin K. Cumulated gain-based evaluation of IR techniques / K. Järvelin, J. Kekäläinen // ACM Transactions on Information Systems. – 2002. – Vol. 20, No. 4. – P. 422–446.
16. Liu F.T. Isolation Forest / F.T. Liu, K.M. Ting, Z.-H. Zhou // Proceedings of the 8th IEEE International Conference on Data Mining (ICDM 2008). – Pisa, Italy: IEEE, 2008. – P. 413–422. DOI: 10.1109/ICDM.2008.17.
17. Hariri S. Extended Isolation Forest / S. Hariri, M. Carrasco Kind, R.J. Brunner // IEEE Transactions on Knowledge and Data Engineering. – 2021. – Vol. 33, No. 4. – P. 1479–1489.
18. Pang G. Deep learning for anomaly detection: A review / G. Pang, C. Shen, L. Cao, A. van den Hengel // ACM Computing Surveys. – 2021. – Vol. 54, No. 2. – P. 1–38.
19. Hilal W. Financial fraud: A review of anomaly detection techniques and recent advances / W. Hilal, S.A. Gadsden, J. Yawney // Expert Systems with Applications. – 2022. – Vol. 193. – Article 116429.
20. Bifet A. Learning from time-changing data with adaptive windowing / A. Bifet, R. Gavaldà // Proceedings of the 7th SIAM International Conference on Data Mining (SDM 2007). – Minneapolis, MN, USA: SIAM, 2007. – P. 443–448. DOI: 10.1137/1.9781611972771.42.
21. Lu J. Learning under concept drift: A review / J. Lu, A. Liu, F. Dong, J. Gama, G. Zhang // IEEE Transactions on Knowledge and Data Engineering. – 2019. – Vol. 31, № 12. – P. 2346–2363.
22. Hoi S.C.H. Online learning: A comprehensive survey / S.C.H. Hoi, D. Sahoo, J. Lu, P. Zhao // Neurocomputing. – 2021. – Vol. 459. – P. 249–289.
23. Raab C. Reactive and self-adjusting sliding windows for efficient event stream processing with general delay distributions / C. Raab, B. Ziebart, M. Kellermeier, S. Schelter // Neurocomputing. – 2020. – Vol. 416. – P. 340–351.
24. De Lange M. A continual learning survey: Defying forgetting in classification tasks / M. De Lange, R. Aljundi, M. Masana et al. // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2022. – Vol. 44, No. 7. – P. 3366–3385.
25. Bank of England; Financial Conduct Authority. Machine learning in UK financial services: report. – October 2022. – URL: <https://www.bankofengland.co.uk/report/2022/machine-learning-in-uk-financial-services> (дата обращения: 26.02.2026).
26. Nystrup P. Detecting change points in finance: A mid-2020 review / P. Nystrup, E. Lindström, T. Christiansen, H. Madsen, A. Engsø // Expert Systems with Applications. – 2022. – Vol. 77, No. 1. – P. 5–47.
27. Fortunato M. Noisy Networks for Exploration / M. Fortunato, M.G. Azar, B. Piot et al. // Proceedings of the International Conference on Learning Representations (ICLR 2018). – Vancouver, BC, Canada: OpenReview.net, 2018. – 13 p. – URL: <https://openreview.net/forum?id=rywHCPkAW> (дата обращения: 26.02.2026).

Аскеров Заур Ханахмедович

Аспирант Института интеллектуальных кибернетических систем Национального исследовательского ядерного университета «МИФИ» (НИЯУ МИФИ)
Каширское шоссе, 31, г. Москва, Россия, 115409
Тел.: +7-977-297-79-45
Эл. почта: xerailost@gmail.com

Поступила в редакцию: 12.03.2026.

Принята к публикации: 26.05.2026.

Askerov Z.K.

Experimental evaluation of a self-learning recommender system for the banking sector

Relevance. In the banking sector, personalized recommendations must remain accurate, robust, and safe under changing customer behavior and financial risks. It is particularly important to test such systems under macroeconomic stress, when conventional models may lose performance. **Purpose.** The study evaluates a prototype self-learning recommender system for banking products that combines reinforcement learning, macroeconomic context, and anomaly filtering. **Methods.** The work uses experimental simulation, comparative analysis with baseline algorithms, k-means customer clustering, deep Q-learning, isolation forest anomaly detection, and statistical assessment of P@5, NDCG@5, conversion, F1-score, and recommendation latency. **Novelty.** The study proposes an integrated approach, in which an adaptive recommendation policy is combined with macroeconomic regimes awareness and preliminary anomaly detection for banking use cases. **Results.** In the synthetic benchmark, the prototype outperformed baseline models: P@5 reached 0,623, NDCG@5 reached 0,712, conversion in the stable regime was 82%, and the performance drop under crisis conditions was limited to 7%. The anomaly detection module achieved an F1-score of at least 0,86, while

the average recommendation latency was 23 ms. **Practical significance.** The results can support the design of banking personalization systems, selection of recommender architectures, robustness assessment, and implementation of risk-control mechanisms in digital customer service channels.

Keywords: recommender systems, deep reinforcement learning, banking sector, personalization, macroeconomic scenarios, anomaly detection, quality metrics.

DOI: 10.21293/1818-0442-2026-29-1-160-165

References

- Gigli A., Lillo F., Regoli D. Recommender systems for banking and financial services. Poster Track of the 11th ACM Conference on Recommender Systems (RecSys 2017). Como, Italy, CEUR-WS.org, 2017, pp. 315–316.
- Oyebode O., Orji R. A hybrid recommendation system for the financial service sector. *Journal of Banking and Financial Technology*, 2020, vol. 4, pp. 17–32.
- Sharaf M., Hemdan E.E.D., El-Sayed A., El-Bahnasawy N.A. A survey on recommendation systems for financial services. *Multimedia Tools and Applications*, 2022, vol. 81, no. 12, pp. 13617–13642.
- Vaquero-Patricio C., van Ommeren N., Gil-Begue S. Recommenders in Banking: An End-to-End Personalization Pipeline within ING. Proceedings of the 15th ACM Conference on Recommender Systems (RecSys 2021). Amsterdam, Netherlands, ACM, 2021, pp. 587–589. DOI 10.1145/3460231.3474612.
- Afsar M.M., Crump T., Far B. Reinforcement learning based recommender systems: A survey. *ACM Computing Surveys*, 2021, vol. 54, no. 3, article 42, pp. 1–38.
- Chen M., Beutel A., Covington P., Jain S., Belletti F., Chi E. Top-K off-policy correction for a REINFORCE recommender system. Proceedings of the 12th ACM International Conference on Web Search and Data Mining (WSDM 2019). Melbourne, VIC, Australia, ACM, 2019, pp. 456–464. DOI: 10.1145/3289600.3290999.
- Mnih V., Kavukcuoglu K., Silver D. et al. Human-level control through deep reinforcement learning. *Nature*, 2015, vol. 518, no. 7540, pp. 529–533.
- Wang Z., Schaul T., Hessel M. et al. Dueling Network Architectures for Deep Reinforcement Learning. Proceedings of the 33rd International Conference on Machine Learning (ICML 2016). New York, NY, USA, PMLR, 2016, pp. 1995–2003.
- Kutanin A.R. [Recommender systems: survey of main problem statements and results]. *Intelligent systems. Theory and Applications*, 2017, vol. 21, no. 4, pp. 18–30 (in Russ.).
- Menshikova N.V., Portnov I.V., Nikolaev I.E. [Review of recommender systems and opportunities for context accounting in individual recommendations]. *Academy*, 2016, no. 6 (9), pp. 20–22 (in Russ.).
- Pavlov D.A., Kosyuga O.S. [A universal recommender system for banking products based on a hybrid approach]. *Scientific Papers of Kuban State Technological University*, 2022, no. 1, pp. 88–97 (in Russ.).
- Arkadyeva O.G., Petrov A.V. [Machine learning models as a tool for detecting suspicious bank operations]. *Vestnik Surgutskogo gosudarstvennogo universiteta*, 2025, vol. 13, no. 3, pp. 8–21. DOI: 10.35266/2949-3455-2025-3-1 (in Russ.).
- Koren Y., Bell R., Volinsky C. Matrix factorization techniques for recommender systems. *IEEE Computer*, 2009, vol. 42, no. 8, pp. 30–37.
- Rendle S., Freudenthaler C., Gantner Z., Schmidt-Thieme L. BPR: Bayesian Personalized Ranking from Implicit Feedback. Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence (UAI 2009). Montreal, QC, Canada, AUAI Press, 2009, pp. 452–461.
- Järvelin K., Kekäläinen J. Cumulated gain-based evaluation of IR techniques. *ACM Transactions on Information Systems*, 2002, vol. 20, no. 4, pp. 422–446.
- Liu F.T., Ting K.M., Zhou Z.-H. Isolation Forest. Proceedings of the 8th IEEE International Conference on Data Mining (ICDM 2008). Pisa, Italy, IEEE, 2008, pp. 413–422. DOI: 10.1109/ICDM.2008.17.
- Hariri S., Carrasco Kind M., Brunner R.J. Extended Isolation Forest. *IEEE Transactions on Knowledge and Data Engineering*, 2021, vol. 33, no. 4, pp. 1479–1489.
- Pang G., Shen C., Cao L., van den Hengel A. Deep learning for anomaly detection: A review. *ACM Computing Surveys*, 2021, vol. 54, no. 2, article 38, pp. 1–38.
- Hilal W., Gadsden S.A., Yawney J. Financial fraud: A review of anomaly detection techniques and recent advances. *Expert Systems with Applications*, 2022, vol. 193, article 116429.
- Bifet A., Gavaldà R. Learning from time-changing data with adaptive windowing. Proceedings of the 7th SIAM International Conference on Data Mining (SDM 2007). Minneapolis, MN, USA, SIAM, 2007, pp. 443–448. DOI: 10.1137/1.9781611972771.42.
- Lu J., Liu A., Dong F., Gama J., Zhang G. Learning under concept drift: A review. *IEEE Transactions on Knowledge and Data Engineering*, 2019, vol. 31, no. 12, pp. 2346–2363.
- Hoi S.C.H., Sahoo D., Lu J., Zhao P. Online learning: A comprehensive survey. *Neurocomputing*, 2021, vol. 459, pp. 249–289.
- Raab C., Ziebart B., Kellermeier M., Schelter S. Reactive and self-adjusting sliding windows for efficient event stream processing with general delay distributions. *Neurocomputing*, 2020, vol. 416, pp. 340–351.
- De Lange M., Aljundi R., Masana M. et al. A continual learning survey: Defying forgetting in classification tasks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, vol. 44, no. 7, pp. 3366–3385.
- Bank of England; Financial Conduct Authority. Machine learning in UK financial services. Report, October 2022. Available at: <https://www.bankofengland.co.uk/report/2022/machine-learning-in-uk-financial-services> (accessed: 26 February 2026).
- Nystrup P., Lindström E., Christiansen T., Madsen H., Engso A. Detecting change points in finance: A mid-2020 review. *Expert Systems with Applications*, 2022, vol. 77, no. 1, pp. 5–47.
- Fortunato M., Azar M.G., Piot B. et al. Noisy Networks for Exploration. Proceedings of the International Conference on Learning Representations (ICLR 2018). Vancouver, BC, Canada, OpenReview.net, 2018, 13 p. Available at: <https://openreview.net/forum?id=rywHCPkAW> (accessed: 26 February 2026).

Zaur Kh. Askerov

Postgraduate Student, Institute of Intelligent Cybernetic Systems, National Research Nuclear University MEPhI (Moscow Engineering Physics Institute)
31, Kashirskoe Hwy, Moscow, 115409, Russia
Phone: +7-977-297-79-45
Email: xerailost@gmail.com

Received: 12.03.2026.

Accepted: 26.05.2026.