

БИЗНЕС- ИНФОРМАТИКА

Научный журнал НИУ ВШЭ

СОДЕРЖАНИЕ

С.В. Бегичева, А.К. Бегичева, Д.М. Назаров

Разработка модели выделения детерминант
успешного импортозамещения программного
обеспечения..... 7

Ю.А. Зеленков, Е.В. Лашкевич

Контрфактуальные объяснения на основе
генерации синтетических данных 24

А.Ю. Варнухов

Скрытая марковская модель: метод построения
модели бизнес-процесса 41

А.В. Куликов, Д.С. Полозов, Н.В. Волков

Оптимизация долгосрочного инвестирования
на основе диверсификации Марковица..... 56

Ю.Ф. Тельнов, В.А. Казаков, А.В. Данилов

Проектирование многоагентной системы
сетевого предприятия 70

*R.N. Alkaied, S.A. Khattab, I.M. Al Shaar,
M.K. Abu Zaid, S.A.I. Al-Bazaiah*

The impact of artificial intelligence on re-purchase
intentions: the mediation approach 87



Издатель:
Национальный
исследовательский университет
«Высшая школа экономики»

Подписной индекс
Объединенного каталога
«Пресса России» – E79128
Выпускается ежеквартально

Журнал включен в Перечень
российских рецензируемых
научных журналов,
в которых должны быть
опубликованы основные научные
результаты диссертаций
на соискание ученых степеней
доктора и кандидата наук

Главный редактор
Е.П. Зараменских

Заместитель главного редактора
Э.А. Бабкин

Компьютерная верстка
О.А. Богданович

Дизайн обложки выполнен
с использованием контента (изображения),
сгенерированного Пользователем
Хрусталева И.И.
(по поручению НИУ ВШЭ),
при помощи Сервиса Kandinsky 3.0
(fusionbrain.ai).

Администратор веб-сайта
И.И. Хрусталева

Адрес редакции:
119049, г. Москва,
ул. Шаболовка, д. 26-28
Тел./факс: +7 (495) 772-9590 *28509
<http://bijournal.hse.ru>
E-mail: bijournal@hse.ru

За точность приведенных сведений
и содержание данных,
не подлежащих открытой публикации,
несут ответственность авторы

**При перепечатке ссылка на журнал
«Бизнес-информатика» обязательна**

Тираж:
русскоязычная версия – 100 экз.,
англоязычная версия – 100 экз.,
онлайн-версии на русском и английском –
свободный доступ

Отпечатано в типографии НИУ ВШЭ
г. Москва, Измайловское шоссе, д. 44, стр. 2

© Национальный
исследовательский университет
«Высшая школа экономики»

О ЖУРНАЛЕ

«**Б**изнес-информатика» – рецензируемый междисциплинарный научный журнал, выпускаемый с 2007 года Национальным исследовательским университетом «Высшая школа экономики» (НИУ ВШЭ). Администрирование журнала осуществляется Высшей школой бизнеса НИУ ВШЭ. Журнал выпускается ежеквартально, на русском и английском языках.

Миссия журнала – развитие бизнес-информатики как новой области информационных технологий и менеджмента. Журнал осуществляет распространение последних разработок технологического и методологического характера, способствует развитию соответствующих компетенций, а также обеспечивает возможности для дискуссий в области применения современных информационно-технологических решений в бизнесе, менеджменте и экономике.

Журнал публикует статьи по следующей тематике: моделирование социальных и экономических систем, цифровая трансформация бизнеса, управление инновациями, информационные системы и цифровые технологии в бизнесе, анализ данных и системы бизнес-интеллекта, математические методы и алгоритмы бизнес-информатики, моделирование и анализ бизнес-процессов, поддержка принятия управленческих решений.

Журнал «Бизнес-информатика» включен в Перечень рецензируемых научных изданий, в которых должны быть опубликованы основные научные результаты диссертаций на соискание ученых степеней кандидата и доктора наук (Перечень ВАК).

Журнал входит в базы Scopus, Web of Science Emerging Sources Citation Index (WoS ESCI), Russian Science Citation Index на платформе Web of Science (RSCI), EBSCO.

Журнал распространяется как в печатном виде, так и в электронной форме.

РЕДАКЦИОННАЯ КОЛЛЕГИЯ

ГЛАВНЫЙ РЕДАКТОР

Зараменских Евгений Петрович

Национальный исследовательский университет
«Высшая школа экономики», Москва, Россия

ЗАМЕСТИТЕЛЬ ГЛАВНОГО РЕДАКТОРА

Бабкин Эдуард Александрович

Национальный исследовательский университет
«Высшая школа экономики», Нижний Новгород, Россия

ЧЛЕНЫ РЕДКОЛЛЕГИИ

Авдошин Сергей Михайлович

Национальный исследовательский университет
«Высшая школа экономики», Москва, Россия

Акопов Андраник Сумбатович

Центральный экономико-математический институт РАН,
Москва, Россия

Алескеров Фуад Тагиевич

Национальный исследовательский университет
«Высшая школа экономики», Москва, Россия

Афанасьев Александр Петрович

Институт проблем передачи информации им. А.А. Харкевича
РАН, Москва, Россия

Афанасьев Антон Александрович

Центральный экономико-математический институт РАН,
Москва, Россия

Баранов Александр Павлович

Главный научно-исследовательский вычислительный центр
Федеральной налоговой службы, Москва, Россия

Бараннин Владимир Борисович

Федеральный исследовательский центр информационных
и вычислительных технологий, Новосибирск, Россия

Беккер Йорг

Университет Мюнстера, Мюнстер, Германия

Вестнер Маркус

Технический университет прикладных наук,
Регенсбург, Германия

Гаврилова Татьяна Альбертовна

Санкт-Петербургский государственный университет,
Санкт-Петербург, Россия

Глотен Эрве

Тулонский университет, Ла-Гард, Франция

Гурвич Владимир Александрович

Ратгерский университет (Университет Нью-Джерси),
Ратгерс, США

Джейкобс Лоренц

Университет Цюриха, Цюрих, Швейцария

Дискин Иосиф Евгеньевич

Всероссийский центр изучения общественного мнения,
Москва, Россия

Зандкуль Курт

Университет Ростока, Росток, Германия

Иванников Александр Дмитриевич

Институт проблем проектирования в микроэлектронике РАН,
Москва, Россия

Исаев Дмитрий Валентинович

Национальный исследовательский университет
«Высшая школа экономики», Москва, Россия

Калягин Валерий Александрович

Национальный исследовательский университет
«Высшая школа экономики», Нижний Новгород, Россия

Кравченко Татьяна Константиновна

Национальный исследовательский университет
«Высшая школа экономики», Москва, Россия

Кузнецов Сергей Олегович

Национальный исследовательский университет
«Высшая школа экономики», Москва, Россия

Лугачев Михаил Иванович

Московский государственный университет
им. М.В. Ломоносова, Москва, Россия

Лин Квей-Жей

Технологический институт Нагои, Нагоя, Япония

Мальцева Светлана Валентиновна

Национальный исследовательский университет
«Высшая школа экономики», Москва, Россия

Мейор Питер

Комиссия ООН по науке и технологиям, Женева,
Швейцария

Миркин Борис Григорьевич

Национальный исследовательский университет
«Высшая школа экономики», Москва, Россия

Назаров Дмитрий Михайлович

Уральский государственный экономический университет,
Екатеринбург, Россия

Пальчунов Дмитрий Евгеньевич

Новосибирский государственный университет, Новосибирск,
Россия

Пардалос Панайот (Панос)

Университет Флориды, Гейнсвилл, США

Пастор Оскар

Политехнический университет Валенсии, Валенсия,
Испания

Посегга Йоахим

Университет Пассау, Пассау, Германия

Самуйлов Константин Евгеньевич

Российский университет дружбы народов, Москва, Россия

Стоянова Ольга Владимировна

Национальный исследовательский университет
«Высшая школа экономики», Санкт-Петербург, Россия

Триболе Жозе

Университет Лиссабона, Лиссабон, Португалия

Ульянов Михаил Васильевич

AVECO, Любляна, Словения

Ускенбаева Раиса Кабиевна

Казахский национальный исследовательский технический
университет им. К.И. Сатпаева, Алматы, Казахстан

Цуканова Ольга Анатольевна

Санкт-Петербургский государственный университет,
Санкт-Петербург, Россия

Чхартишвили Александр Гедеванович

Институт проблем управления им В.А. Трапезникова РАН,
Москва, Россия

ISSN 1998-0663 (print), ISSN 2587-8166 (online)

English version: ISSN 2587-814X (print), ISSN 2587-8158 (online)

BUSINESS INFORMATICS

HSE Scientific Journal

CONTENTS

S.V. Begicheva, A.K. Begicheva, D.M. Nazarov

Constructing a model to identify the determinants
of successful software import substitution 7

Yu.A. Zelenkov, E.V. Lashkevich

Counterfactual explanations based
on synthetic data generation 24

A.Yu. Varnukhov

Hidden Markov model: Method for building
a business process model 41

A.V. Kulikov, D.S. Polozov, N.V. Volkov

Long-term investment optimization based
on Markowitz diversification 56

Yu.F. Telnov, V.A. Kazakov, A.V. Danilov

Designing a multi-agent system
for a network enterprise 70

*R.N. Alkaied, S.A. Khattab, I.M. Al Shaar,
M.K.A. Zaid, S.A.I. Al-Bazaiah*

The impact of artificial intelligence
on re-purchase intentions:
the mediation approach 87

Vol. 18 No. 3 – 2024



Publisher:
HSE University

The journal is published quarterly

The journal is included
into the list of peer reviewed
scientific editions established
by the Supreme Certification
Commission of the Russian Federation

Editor-in-Chief
E. Zaramenskikh

Deputy Editor-in-Chief
E. Babkin

Computer making-up
O. Bogdanovich

The cover design is made
using the content (image)
generated by the User I. Khrustaleva
(on behalf of HSE University),
using the Kandinsky 3.0 Service
(fusionbrain.ai).

Website administration
I. Khrustaleva

Address:
26-28, build. 4, Shablovka Street
Moscow 119049, Russia

Tel./fax: +7 (495) 772-9590 *28509
<http://bijournal.hse.ru>
E-mail: bijournal@hse.ru

Circulation:
English version – 100 copies,
Russian version – 100 copies,
online versions in English and Russian –
open access

Printed in HSE Printing House
44, build. 2, Izmaylovskoye Shosse,
Moscow, Russia

© HSE University

ABOUT THE JOURNAL

Business Informatics is a peer reviewed interdisciplinary academic journal published since 2007 by HSE University, Moscow, Russian Federation. The journal is administered by HSE Graduate School of Business. The journal is issued quarterly, in English and Russian.

The mission of the journal is to develop business informatics as a new field within both information technologies and management. It provides dissemination of latest technical and methodological developments, promotes new competences and provides a framework for discussion in the field of application of modern IT solutions in business, management and economics.

The journal publishes papers in the following areas: modeling of social and economic systems, digital transformation of business, innovation management, information systems and technologies in business, data analysis and business intelligence systems, mathematical methods and algorithms of business informatics, business processes modeling and analysis, decision support in management.

The journal is included into the list of peer reviewed scientific editions established by the Supreme Certification Commission of the Russian Federation.

The journal is included into Scopus, Web of Science Emerging Sources Citation Index (WoS ESCI), Russian Science Citation Index on the Web of Science platform (RSCI), EBSCO.

The journal is distributed both in printed and electronic forms.

EDITORIAL BOARD

OR-IN-CHIEF

Evgeny P. Zaramenskikh
HSE University, Moscow, Russia

DEPUTY EDITOR-IN-CHIEF

Eduard A. Babkin
HSE University, Nizhny Novgorod, Russia

EDITORIAL BOARD

Sergey M. Avdoshin
HSE University, Moscow, Russia

Andranik S. Akopov
Central Economics and Mathematics Institute, Russian Academy of Sciences, Moscow, Russia

Fuad T. Aleskerov
HSE University, Moscow, Russia

Alexander P. Afanasyev
Institute for Information Transmission Problems (Kharkevich Institute), Russian Academy of Sciences, Moscow, Russia

Anton A. Afanasyev
Central Economics and Mathematics Institute, Russian Academy of Sciences, Moscow, Russia

Vladimir B. Barakhnin
Federal Research Center of Information and Computational Technologies, Novosibirsk, Russia

Alexander P. Baranov
Federal Tax Service, Moscow, Russia

Jörg Becker
University of Munster, Munster, Germany

Alexander G. Chkhartishvili
V.A. Trapeznikov Institute of Control Sciences, Russian Academy of Sciences, Moscow, Russia

Tatiana A. Gavrilova
Saint-Petersburg University, St. Petersburg, Russia

Hervé Glotin
University of Toulon, La Garde, France

Vladimir A. Gurvich
Rutgers, The State University of New Jersey, Rutgers, USA

Laurence Jacobs
University of Zurich, Zurich, Switzerland

Iosif E. Diskin
Russian Public Opinion Research Center, Moscow, Russia

Dmitry V. Isaev
HSE University, Moscow, Russia

Alexander D. Ivannikov
Institute for Design Problems in Microelectronics, Russian Academy of Sciences, Moscow, Russia

Valery A. Kalyagin
HSE University, Nizhny Novgorod, Russia

Tatiana K. Kravchenko
HSE University, Moscow, Russia

Sergei O. Kuznetsov
HSE University, Moscow, Russia

Kwei-Jay Lin
Nagoya Institute of Technology, Nagoya, Japan

Mikhail I. Lugachev
Lomonosov Moscow State University, Moscow, Russia

Svetlana V. Maltseva
HSE University, Moscow, Russia

Peter Major
UN Commission on Science and Technology for Development, Geneva, Switzerland

Boris G. Mirkin
HSE University, Moscow, Russia

Dmitry M. Nazarov
Ural State University of Economics, Ekaterinburg, Russia

Dmitry E. Palchunov
Novosibirsk State University, Novosibirsk, Russia

Panagote (Panos) M. Pardalos
University of Florida, Gainesville, USA

Óscar Pastor
Polytechnic University of Valencia, Valencia, Spain

Joachim Posegga
University of Passau, Passau, Germany

Konstantin E. Samouylov
Peoples' Friendship University, Moscow, Russia

Kurt Sandkuhl
University of Rostock, Rostock, Germany

Olga Stoyanova
HSE University, St. Petersburg, Russia

José M. Tribolet
Universidade de Lisboa, Lisbon, Portugal

Olga A. Tsukanova
Saint-Petersburg University, St. Petersburg, Russia

Mikhail V. Ulyanov
AVECO, Ljubljana, Slovenia

Raissa K. Uskenbayeva
Kazakh National Technical University after K.I. Satpaev, Almaty, Kazakhstan

Markus Westner
Technical University for Applied Sciences (OTH Regensburg), Regensburg, Germany

DOI: 10.17323/2587-814X.2024.3.7.23

Разработка модели выделения детерминант успешного импортозамещения программного обеспечения

С.В. Бегичева^a 

E-mail: begichevas@mail.ru

А.К. Бегичева^b 

E-mail: abegicheva@hse.ru

Д.М. Назаров^a 

E-mail: slup2005@mail.ru

^a Уральский государственный экономический университет, Екатеринбург, Россия

^b Национальный исследовательский университет «Высшая школа экономики», Москва, Россия

Аннотация

В процессе импортозамещения высшие учебные учреждения сталкиваются с рядом трудностей при переходе от преимущественного использования иностранного программного обеспечения (ПО) к отечественным аналогам, а именно – с отсутствием необходимого пользовательского опыта использования отечественных цифровых решений, необходимостью переноса данных из одних систем в другие и т.п. Сложности переходного периода порождают сопротивление процессу цифровой трансформации. Систематизация исследований по вопросам импортозамещения ПО в вузах выявила три основные темы: проблемы и риски перехода на отечественное ПО, исследование возможности полноценного перехода на отечественное ПО и рекомендации по выбору российских решений. Целью настоящего исследования являлось выявление факторов, влияющих на принятие импортозамещения программных продуктов в вузах. В статье предложена структурная модель выделения детерминант успешного импортозамещения ПО, разработанная на основе подходов теории диффузии инноваций и модели принятия технологий. Модель реализована с использованием программного продукта SmartPLS на данных анкетирования преподавателей и сотрудников Уральского государственного экономического университета. Результаты исследования показывают, что отношение к принятию импортозамещения ПО напрямую зависит от личност-

ных характеристик пользователей и инновационных характеристик ПО. При этом наиболее важными детерминантами, влияющими на положительное отношение к переходу на отечественное ПО, являются вовлеченность и самоэффективность пользователей. Кроме того, положительное отношение к необходимости импортозамещения способствует индивидуальному принятию перехода на российское ПО и признанию импортозамещения как экономической политики страны. Теоретическая ценность исследования состоит в предложении оригинальной модели выделения детерминант успешного импортозамещения программного обеспечения, разграничивающей индивидуальное принятие и общественное признание импортозамещения ПО. Выводы исследования могут быть полезны руководству вузов при планировании и уточнении мероприятий по стратегии импортозамещения.

Ключевые слова: импортозамещение программного обеспечения, технологические инновации, сопротивление инновациям, теоретические модели принятия информационных технологий, теория диффузии инноваций, моделирование структурными уравнениями

Цитирование: Бегичева С.В., Бегичева А.К., Назаров Д.М. Разработка модели выделения детерминант успешного импортозамещения программного обеспечения // Бизнес-информатика. 2024. Т. 18. № 3. С. 7–23. DOI: 10.17323/2587-814X.2024.3.7.23

Введение

В Концепции технологического развития России, принятой 20 мая 2023 г. подчеркивается, что к 2030 году доля отечественной высокотехнологичной продукции, в том числе телекоммуникационной техники и программного обеспечения, в общем объеме потребления должна составить не менее 75%. Решать проблему импортонезависимости следует через расширение разработок собственных технологий для обеспечения долгосрочной конкурентоспособности, а также через подготовку квалифицированных специалистов, владеющих навыками работы с российским ПО.

В 2022 году Министерством науки и высшего образования Российской Федерации в целях организации эффективного перехода образовательных организаций высшего образования на преимущественное использование отечественного программного обеспечения в 2022–2024 гг. были разработаны и утверждены методические рекомендации [1]. На сайте Министерства создан раздел «Импортозамещение ИТ в сфере науки и высшего образования», где расположены реестры аппаратного обеспечения и программных решений для образовательных и научных организаций [2].

Процесс цифровой трансформации вузов запущен, но исследователи отмечают наличие сложно-

стей и барьеров при переводе учебного процесса на отечественное программное обеспечение [3–8]. По мнению Б.А. Бурняшова [3, 4] проблема импортозамещения программных продуктов, используемых при реализации образовательных программ, многомерна и формируется следующей иерархией подпроблем, среди которых – частичное отсутствие российских аналогов ПО, проблемы финансирования перехода вуза на новые программные продукты, отсутствие стимулов у руководителей и преподавателей вузов, необходимость разработки нового методического обеспечения учебного процесса. Исследование [5] дополняет этот список отсутствием необходимых временных и кадровых ресурсов для перевода ИТ-инфраструктуры вуза на российское ПО, а также нежеланием возрастных преподавателей переучиваться, что усугубляется дефицитом молодых преподавателей ИТ-дисциплин. Проблема сопротивления преподавателей вуза замещению зарубежного ПО отечественными разработками отмечена и в работе [6].

Авторы статей [3–9] предлагают рекомендации по нивелированию проблем, связанных с импортозамещением программных продуктов в вузах. Однако, насколько нам известно, в настоящий момент отсутствуют исследования, включающие статистический анализ детерминант принятия необходимости импортозамещения преподавателями и сотрудниками

образовательных организаций для успешного полноценного перехода на российское ПО.

Целью статьи является многомерный статистический анализ факторов, влияющих на принятие необходимости перехода на российское ПО сотрудниками административного и учебно-вспомогательного секторов и профессорско-преподавательским составом вуза в условиях достижения технологического суверенитета.

1. Материалы и методы

1.1. Теоретическая основа исследования

Рассмотрим импортозамещение в сфере образования как «процесс развития и проникновения в широкую практику нововведений» [10], другими словами – как процесс вовлечения преподавателей и сотрудников вуза в принятие технологической инновации. В исследовании [11] авторы указывают, что существует два традиционных подхода к исследованию факторов, влияющих на принятие и внедрение новых технологий в деятельность организаций. Первый подход опирается на теорию *диффузии инноваций* [12–13], второй – на *модель принятия технологий* [14–15].

Теория *диффузии инноваций* объясняет, каким образом новые продукты, технологии, практики, идеи и т.д. распространяются среди потребителей, и определяет инновацию как идею, действие или объект, которые воспринимаются членами социальной системы (организации, поселения, общества и пр.) в качестве новых [12–13]. В рамках этой теории проблема распространения и принятия технологической инновации рассматривается с учетом особенностей внедряемой технологии. В работе [13] Э. Роджерс и Р. Агарвала-Роджерс пояснили, что определенные характеристики инновации могут способствовать или препятствовать ее внедрению различными пользователями, и сформулировали пять ключевых факторов, влияющих на восприятия инновации:

- ◆ относительное преимущество инновации над используемыми ранее технологиями;
- ◆ совместимость инновации с используемыми ранее технологиями;
- ◆ воспринимаемая сложность внедрения и использования инновации;
- ◆ доступность инновации для опробования и тестирования до момента ее развертывания;
- ◆ наблюдаемые результаты использования инноваций коллегами.

Г. Мур и И. Бенбасат [16], опираясь на идеи теории диффузии инноваций, предложили опросник для оценки восприятия пользователями инноваций в сфере ИТ. Ими выявлены наиболее важные предполагаемые факторы, влияющие на решение пользователя принять и использовать ИТ-инновации, а именно:

- ◆ добровольность использования ИТ-инновации;
- ◆ относительное преимущество новой ИТ-инновации;
- ◆ совместимость с существующей практикой;
- ◆ простота использования ИТ-инновации;
- ◆ возможность опробовать ИТ-инновацию до начала внедрения;
- ◆ степень наглядности результатов использования ИТ-инновации.

Таким образом, последователи теории диффузии инноваций Э. Роджерса включают в рассмотрение характеристики внедряемой технологии [17], в то время как сторонники *модели принятия технологий*, разработанной на основе теорий обоснованного действия и запланированного поведения И. Айзена [18], рассматривают проблему внедрения инновации с точки зрения отдельного пользователя. Особое внимание в теории принятия технологий уделяется отношению пользователя к технологии и, в частности, к его намерению внедрить нововведение. Модель принятия технологий была впервые представлена Ф.Д. Дэвисом [14] и позже пересмотрена Ф.Д. Дэвисом, Р.П. Багоцци и П.Р. Уоршоу [15].

Модель принятия технологий учитывает, что фактическое поведение (принятие индивидом технологий) обусловлено поведенческим намерением, которое в свою очередь находится под влиянием субъективных норм и социальных установок. В качестве иллюстрации приведем концептуальную модель принятия информационных технологий, предложенную в статье В. Венкатеша и др. [19] и усовершенствованную в работе [20] (*рис. 1*).

Модель принятия технологий определяет следующие основные факторы, влияющие на восприятие пользователями новых технологий:

- ◆ воспринимаемая полезность – индивидуальная ожидаемая польза от применения нововведения: чем больше воспринимаемая полезность, тем легче пользователь примет инновацию;
- ◆ воспринимаемая простота использования – индивидуальная ожидаемая простота использования нововведения: если технология является




Рис. 1. Концептуальная модель принятия информационных технологий [19, 20].

простой в освоении, то пользователь примет ее быстрее, если же интерфейс технологии сложный и неудобный, то и отношение пользователей к нововведению будет соответственным;

- ♦ внешние переменные, такие как социальное влияние, являются важным фактором, определяющим отношение пользователя к инновации.

1.2. Дизайн исследования

Обзор исследований [12–16] позволил выявить определяющие детерминанты успешного внедрения инновационных продуктов. Для построения модели эти факторы были классифицированы нами и объединены в следующие конструкты: (1) «Личностные характеристики пользователя», (2) «Инновационные характеристики российского ПО». В качестве промежуточной зависимой переменной модели будет выступать конструкт «Отношение к принятию необходимости перехода на российское ПО». Концепт принятия российского ПО будет рассмотрен как симбиоз индивидуального принятия и использования инновации пользователем в учебном процессе и осознания важности импортозамещения ПО для стимулирования национальных экономических интересов. При формировании дизайна исследования нами также учитывались результаты работы [21], посвященной детерминантам успешной цифровой трансформации.

1.3. Переменные исследования

1.3.1. Личностные характеристики пользователя

Конструкт «Личностные характеристики пользователя» включает в себя четыре переменные, которые были выделены на основе анализа исследований [12–16], а именно: (1) «Знания», (2) «Индивидуаль-

ная инновационная восприимчивость», (3) «Самоэффективность» и (4) «Вовлеченность». Ниже поясним выбор этих переменных.

Знания относятся к накопленному опыту, связанному с применением технологии или продукта. Знания позволяют оценить относительное преимущество инноваций по сравнению с используемыми технологиями, воспринимаемую сложность внедрения инновации и совместимость инновации с используемыми технологиями – ключевые факторы принятия инноваций, заявленные Э. Роджерсом [12]. Он утверждал, что чем быстрее пользователь осознает, каким образом использовать новую технологию, тем быстрее она будет внедрена. Следовательно, мы можем утверждать, что знания являются одной из тех основных индивидуальных характеристик, которая важна для начального этапа процесса принятия инновации.

Индивидуальная инновационная восприимчивость проявляется в одобрении пользователем новых технологий. Пользователи с высоким уровнем индивидуальной инновационной восприимчивости склонны принимать и использовать новые технологии раньше, чем это сделают остальные [12]. Индивидуальная инновационная восприимчивость влияет на добровольность применения инноваций на индивидуальном уровне, являющуюся одним из факторов успешного внедрения инноваций, сформулированных Г. Муром и И. Бенбасатом [16]. Согласно модели распространения инноваций Э. Роджерса [12], новаторы и ранние последователи являются личностями с высокой инновационной восприимчивостью и с большой вероятностью будут информировать окружающих о новых технологиях. Можно сказать, что новаторство – это характеристика пионеров в применении новых технологий, на которых впоследствии равняются окружающие.

Самозффективность означает убеждение человека в том, что он способен успешно решить конкретную задачу. В контексте нашего исследования самоэффективность – это субъективная уверенность пользователя в том, что для него российские программные продукты легки в освоении и использовании. Уверенность в самоэффективности при освоении нового программного продукта коррелирует с таким фактором как «простота использования информационных технологий» [16].

Вовлеченность означает интерес к приобретению нового навыка, а также соотносится с восприятием ценности, значимости и важности конкретной технологии. С учетом целей нашего исследования определим вовлеченность как заинтересованность и мотивацию к активному использованию новых программных продуктов. Высокая вовлеченность направлена на получение знаний и навыков, связанных с ИТ-продуктами, и стимулирует принятие и применение новых технологий в работе. Вовлеченный пользователь добровольно примет решение об использовании российского ПО, что согласно исследованию [16] характеризует высокую степень принятия технологии.

1.3.2. Инновационные характеристики российского ПО

Конструкт «Инновационные характеристики российского ПО» состоит из двух переменных: (1) «Относительное преимущество российского ПО» и (2) «Технологическая инновационность российского ПО».

Относительное преимущество является критерием для сравнения инновации и традиционного продукта или технологии [12, 16]. Чем увереннее пользователь осознает относительные преимущества инноваций, тем эффективнее проходит процесс их принятия [12, 16]. Представление о том, что российское программное обеспечение окажется более функциональным, удобным, надежным и превосходящим ранее используемое программное обеспечение, является относительным преимуществом. Чем выше уровень относительного преимущества ПО, тем выше его уровень признания и принятия.

Технологическую инновационность можно интерпретировать как необходимое условие процесса принятия инновационных решений [12]. Новая технология по определению должна быть оригинальной и отличаться от существующих техноло-

гий [12]. Для того, чтобы программное обеспечение считалось новаторским, его технологическая инновационность должна быть достаточно высокой и, кроме того, воспринимаемой потребителем [22].

1.3.3. Отношение к необходимости перехода на российское ПО

Согласно исследованиям Ф.Д. Дэвиса и др. [14], предложившим модель принятия технологий, фактическое принятие (использование) технологий вызвано намерением (желанием) применять их для решения задач. В контексте нашего исследования положительное отношение к необходимости перехода на российское ПО означает намерение его использовать.

Ф.Д. Дэвис и др. [14] указывали, что поведенческие намерения и убеждения влияют на принятие технологий как отдельными пользователями, так и всеми членами организации. В нашем исследовании отношение к необходимости перехода на российское программное обеспечение будет рассмотрено как переменная, опосредующая индивидуальное принятие и признание импортозамещения как экономической политики страны.

1.3.4. Индивидуальное принятие перехода на российское ПО и признание импортозамещения как экономической политики страны

Предполагается, что для того, чтобы конкретная технология была принята, необходимо, чтобы она имела определенную ценность и преимущество по сравнению с традиционными технологиями. Принятие инновации в зависимости от масштаба воздействия, имеет две составляющие: принятие индивидуальной ценности инновации и признание ценности инновации для общества.

Принимая ценность российского ПО на индивидуальном уровне, пользователь готов использовать его для личных целей и интегрировать в образовательный процесс.

Признавая ценность инновации для общества, пользователь считает, что получателем блага при использовании новаторской технологии будет являться широкая общественность. В нашем исследовании признание ценности инновации для общества означает осознание важности импортозамещения ПО для стимулирования национальных экономических интересов России.

Таким образом, в качестве зависимых переменных модели будем рассматривать конструкты «Индивидуальное принятие перехода на российское ПО» и «Признание импортозамещения как экономической политики страны».

1.4. Гипотезы исследования

В рамках исследования мы предполагаем, что индивидуальные характеристики пользователя и инновационные характеристики российского ПО формируют отношение к необходимости перехода на российское ПО, которое в свою очередь влияет на принятие (как индивидуальное, так и признание ценности инновации для общества) российского ПО.

На основании анализа исследований нами выдвигаются следующие гипотезы.

H1: Знание, индивидуальная инновационная восприимчивость, самооффективность и вовлеченность оказывают положительное воздействие на личностные характеристики пользователя, определяющие его отношение к необходимости перехода на российское ПО.

H2: Относительное преимущество российского ПО и технологическое преимущество российского ПО оказывают положительное воздействие на инновационные характеристики ПО, определяющие отношение пользователя к импортозамещению ПО.

H3: Личностные характеристики пользователя и инновационные характеристики ПО оказывают положительное воздействие на отношение пользователя к необходимости перехода на российское ПО.

Как указывалось ранее, положительное отношение к необходимости перехода на российское ПО означает намерение (желание) его использовать. Будем использовать это утверждение при формулировании гипотез H4 и H5.

H4: Желание пользователя использовать российское ПО положительно влияет на индивидуальное принятие.

H5: Желание пользователя использовать российское ПО положительно влияет на признание ценности этой инновации для общества.

На *рисунке 2* приведена концептуальная модель исследования.

1.5. Методология исследования

Для изучения факторов, влияющих на принятие необходимости перехода на российское ПО, нами была составлена анкета. Вопросы конструктов выстроены на основе списка вопросов, которые были предложены в исследовании, посвященном проблемам принятия цифровой трансформации [21]. Анкета состоит из 28 вопросов, относящихся к основным шкалам: личностные характеристики

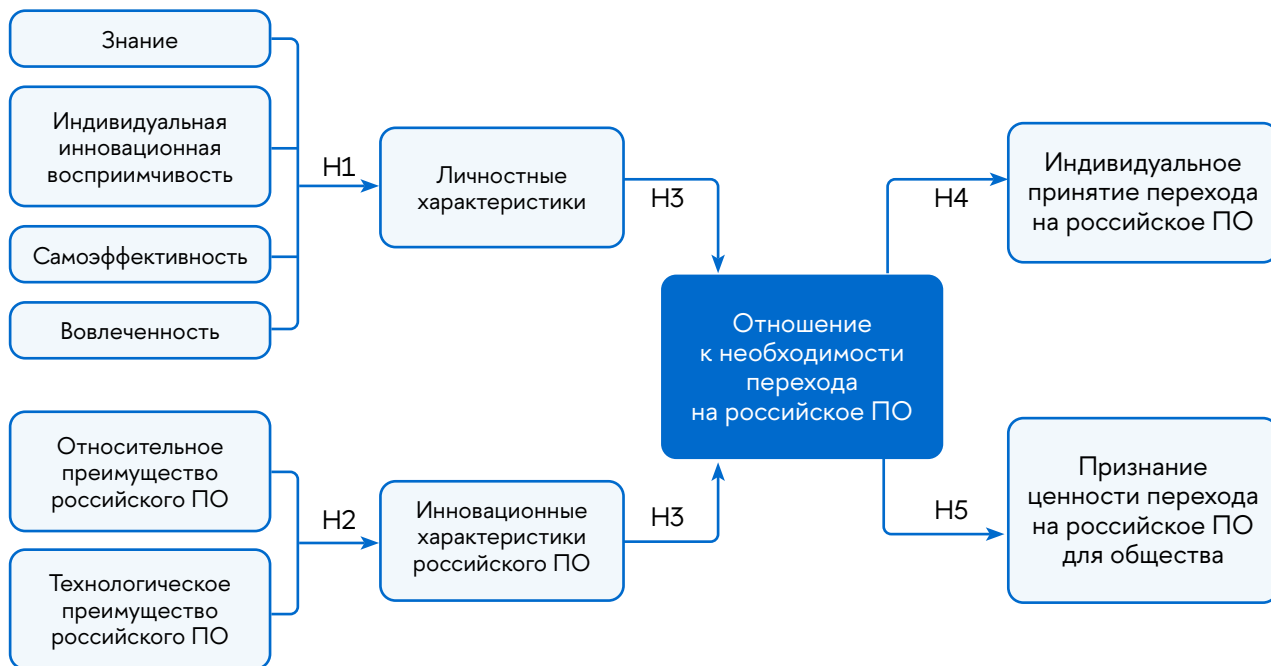


Рис. 2. Концептуальная модель исследования.

пользователя представлены 10 вопросами; 8 вопросов служат для представления инновационных характеристик российского ПО; 4 вопроса затрагивают отношение к необходимости перехода на российское ПО; 3 вопроса нужны для того, чтобы охарактеризовать индивидуальное принятие перехода на российское ПО и 3 вопроса необходимы для оценки признания ценности перехода на российское ПО для общества. В обсуждении вопросов анкеты принимали участие сотрудники социологической лаборатории и кафедры экономической теории и прикладной социологии Уральского государственного экономического университета. Ответы на все вопросы ранжировались по 5-балльной шкале Лайкерта (1 – минимальное значение, 5 – максимальное). Операционализация переменных исследования представлена в *Приложении 1*.

Для подтверждения теоретической модели исследования и построения структурной модели применим метод моделирования структурными уравнениями (structural equation modeling, SEM) на основе анализа частичных наименьших квадратов (partial fewest squares, PLS) с использованием программного продукта SmartPLS [23].

Модель с применением подхода PLS-SEM состоит из двух подмоделей: (1) *иерархическая модель измерений* определяет отношения между латентными переменными (гипотетическими конструктами) и наблюдаемыми переменными, (2) *модель структурных уравнений* определяет наличие причинно-следственных связей между конструктами.

Для тестирования иерархической модели измерений проводится анализ надежности и согласованности шкал. Оценка пригодности модели структурных уравнений подразумевает оценку путей коэффициентов и их значимости.

Целью подхода PLS-SEM является выделение максимальной доли объясненной общей дисперсии зависимых латентных переменных в модели PLS. Метод PLS позволяет исследовать причинно-следственные связи в условиях выборки малого или среднего размера и при этом не требует допущения о нормальном распределении выборочных данных [24–26].

2. Результаты эмпирического исследования

В исследовании приняло участие 112 преподавателей и сотрудников административного и учеб-

но-вспомогательного секторов Уральского государственного экономического университета. Опрос был проведен с января по февраль 2024 года.

Результаты частотного анализа для изучения социально-демографических характеристик респондентов опроса представлены в *таблице 1*.

Наибольшая доля респондентов (35,7%) принадлежит возрастной группе 36–49 лет. 72,3% респондентов – женщины. Сегмент респондентов из профессорско-преподавательского состава составил более 66% опрошенных.

Как было указано ранее, двухэтапный аналитический подход PLS-SEM состоит из следующих этапов: оценка иерархической модели измерений (на этом этапе оцениваются обоснованность и надежность выбранных показателей) и оценка структурной модели.

Таблица 1.

Социально-демографические характеристики респондентов

Социально-демографические группы		Доля
Возраст	18–35 лет	23,2%
	36–49 лет	35,7%
	50–64 лет	30,4%
	65 лет и старше	10,7%
Пол	Женский	72,3%
	Мужской	27,7%
Должность	Заведующий кафедрой, руководитель института	5,36%
	Преподаватель	66,96%
	Сотрудник административного и учебно-вспомогательного секторов	27,68%
Всего ответов		112

2.1. Оценка иерархической модели измерений

На первом этапе моделирования необходимо провести верификацию структуры диагностического инструментария.

Для проверки надежности были проанализированы факторные нагрузки каждой из включенных в анализ переменных (*таблица 2*).

Таблица 2.

Проверка надежности переменных модели

Переменная	Факторная нагрузка	Конвергентная валидность (average variance extracted, AVE)
Знание		
Я знаю, какими российскими программными продуктами можно заменить иностранное ПО, используемое сейчас при реализации дисциплин	0,853	0,740
Я хорошо осведомлен о плюсах и минусах российского ПО – аналоге зарубежного ПО, используемого сейчас при реализации дисциплин	0,863	
Я могу рассказать другим о возможностях российского ПО – аналоге иностранного ПО, используемого сейчас при реализации дисциплин	0,864	
Индивидуальная инновационная восприимчивость		
Обычно я начинаю использовать инновационные технологии раньше всех	0,844	0,729
Я склонен обновлять устройства по мере появления новых технологий и выхода новых моделей	0,853	
Я склонен информировать окружающих об устройствах, созданных с использованием инновационных технологий	0,864	
Самозффективность		
Я думаю, что мне будет легче обучиться и начать использовать незнакомое ПО, чем другим	0,770	0,773
Я думаю, что смогу овладеть навыками работы с российским ПО за относительно короткое время	0,937	
Я уверен в своих навыках работы с ПО и думаю, что у меня не возникнет сложностей при работе с российским ПО	0,921	
Вовлеченность		
Я открыт к использованию российского ПО – аналогу зарубежного ПО, используемого сейчас при реализации дисциплин	1,000	0,749
Относительное преимущество российского ПО		
Российское ПО, вероятно, имеет более широкие возможности, чем иностранное ПО, используемое сейчас при реализации дисциплин	0,910	0,781
Использование российского ПО будет более комфортным, чем иностранного ПО, используемого сейчас при реализации дисциплин	0,934	
Российское ПО более надежно по сравнению с иностранным ПО, используемым сейчас при реализации дисциплин	0,900	
Обучение навыкам работы с российским ПО более актуально, чем обучение работе с иностранным ПО, используемым сейчас при реализации дисциплин	0,782	
Технологическая инновационность российского ПО		
Я думаю, что российское ПО создано с использованием инновационных технологий	0,874	0,836
Российское ПО является инновационным	0,941	
Российские программные продукты оригинальны, креативны и новы	0,915	
Российские программные продукты заметно отличаются в лучшую сторону от иностранного ПО, используемого сейчас при реализации дисциплин	0,927	
Отношение к необходимости перехода на российское ПО		
Я позитивно отношусь к использованию российского ПО	0,872	0,725
У меня не вызывает затруднений работа с российским ПО	0,822	
Я активно выступаю за использование российского ПО в учебном процессе	0,860	

Переменная	Факторная нагрузка	Конвергентная валидность (average variance extracted, AVE)
Индивидуальное принятие перехода на российское ПО		
Я готов к использованию российского ПО в учебном процессе	0,909	0,729
Если возникнет необходимость, я буду использовать российское ПО в учебном процессе	0,849	
Я продолжу использовать российское ПО в будущем	0,837	
Признание ценности перехода на российское ПО для общества		
Российское ПО должно активно использоваться в нашем обществе	0,958	0,836
Российское ПО должно использоваться организациями различных сфер деятельности	0,968	
Нам необходимо постепенно наращивать использование российского ПО	0,931	

Факторные нагрузки показывают, насколько значительно каждая переменная влияет на фактор. В модели предпочтительны факторные нагрузки более 0,7 [27], факторные нагрузки, имеющие значение более 0,4 считаются приемлемым результатом. Отметим, что факторные нагрузки всех переменных модели превышают рекомендованное значение 0,7.

Другим важным показателем, оценивающим степень репрезентативности переменных в рамках отдельных конструктов, является конвергентная валидность, измеряемая показателем извлеченной средней дисперсии (average variance extracted, AVE). В качестве критерия конвергентной валидности используется значение $AVE > 0,5$, что говорит о том, что дисперсия, объясняемая включенными в

модель факторами, выше, чем ошибка измерения. Это значение было достигнуто во всех конструктах модели (таблица 2).

На следующем этапе была проведена проверка внутренней согласованности переменных, заданных вопросами анкеты, для того чтобы определить, насколько хорошо каждый отдельный вопрос описывает признак-конструкт. Результаты проверки внутренней согласованности переменных приведены в таблице 3. Альфа Кронбаха измеряет степень согласованности переменных, формирующих каждый конструкт. Значение композитной надежности (ρ_c) демонстрирует, в какой степени переменные конструкта являются репрезентативными для своего конструкта. Можно сделать вывод, что вну-

Таблица 3.

Проверка внутренней согласованности модели

Конструкт	Альфа Кронбаха	Кoeffициент надежности (ρ_a)	Композитная надежность (ρ_c)
Знание	0,824	0,825	0,895
Индивидуальная инновационная восприимчивость	0,816	0,825	0,890
Самозффективность	0,853	0,900	0,910
Относительное преимущество российского ПО	0,905	0,911	0,934
Технологическая инновационность российского ПО	0,934	0,935	0,953
Отношение к необходимости перехода на российское ПО	0,810	0,814	0,888
Индивидуальное принятие перехода на российское ПО	0,833	0,848	0,899
Признание ценности перехода на российское ПО для общества	0,934	0,935	0,953

тренняя согласованность подтверждена, поскольку все значения Альфы Кронбаха и композитной надежности (ρ_c) выше 0,8.

Высокий уровень согласованности демонстрирует и тот факт, что для всех конструктов модели значение коэффициента надежности (ρ_a) лежит в границах, заданных Альфой Кронбаха и композитной надежности (ρ_c).

Далее для проверки статистической независимости конструктов модели следовало оценить их дискриминантную валидность. Оценка была проведена с применением критерия НТМТ (heterotrait-monotrait ratio), согласно которому один конструкт отличен от другого конструкта и может быть включен в модель, если значение НТМТ между конструктами превышает пороговое значение, равное 0,9 [27]. Проверка показала достаточную дискри-

минантную валидность конструктов модели: максимальное значение НТМТ составило 0,856.

Таким образом, можно утверждать, что иерархическая модель измерений имеет адекватный уровень конвергентной надежности, внутренней согласованности и дискриминантной валидности.

2.2. Оценка структурной модели

Оценку структурной модели начинаем с анализа значений коэффициента инфляции дисперсии (variance inflation factor, VIF) – метрики для оценки коллинеарности переменных модели. Значение $VIF > 5$ свидетельствует о высокой корреляции между переменными [27]. Максимальное значение VIF модели составило 3,865.

Конфигурация структурной модели представлена на схеме (рис. 3).

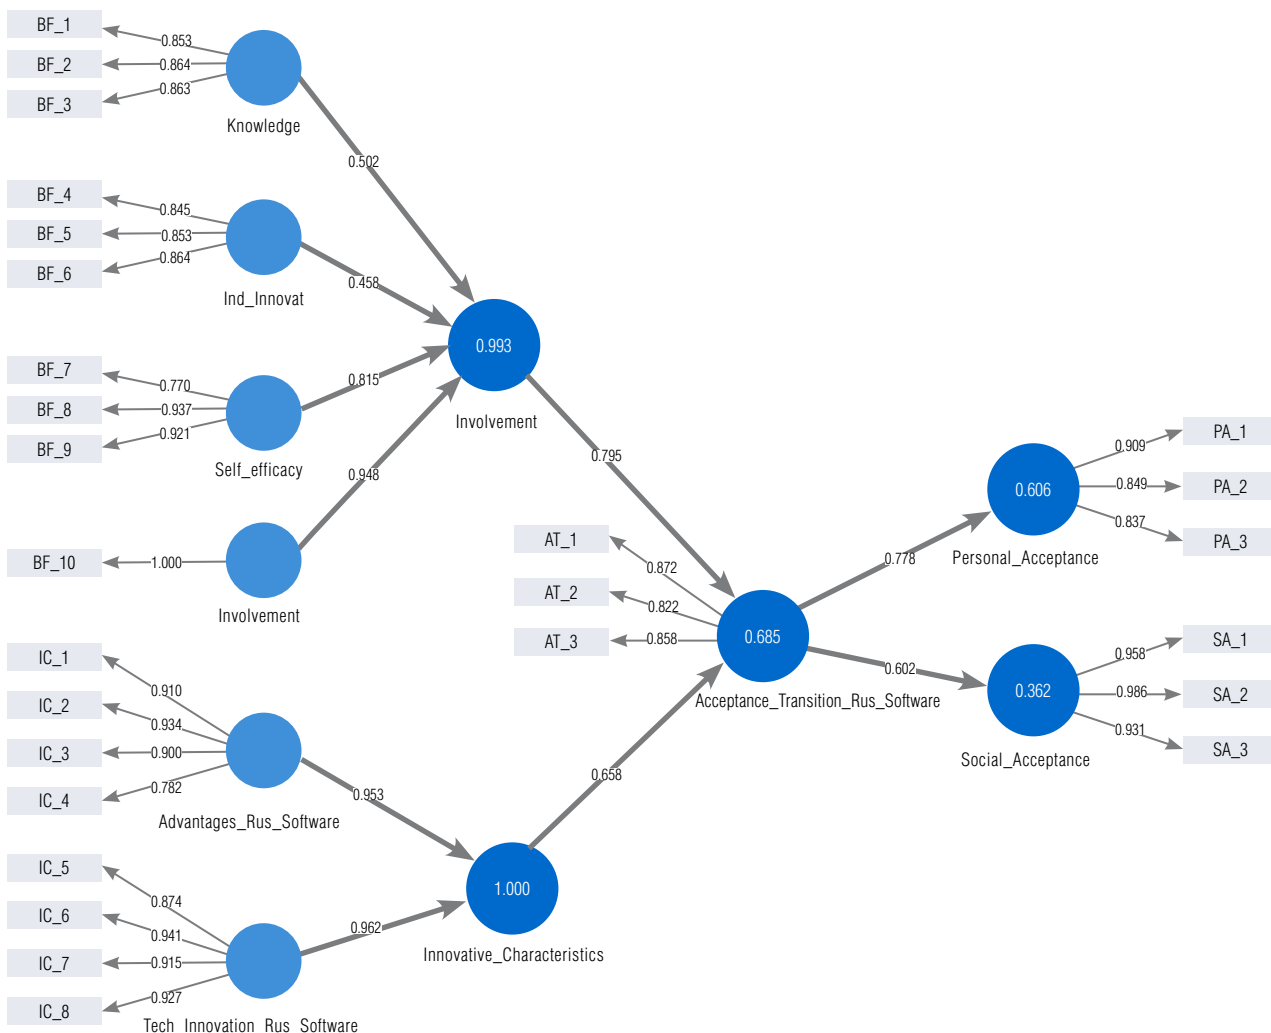


Рис. 3. Конфигурация структурной модели.

Таблица 4.

Значения β -коэффициентов и результаты проверка гипотез

Гипотеза	Влияние	β -коэффициент	t -статистика	p -значение	Решение
H1	Индивидуальная инновационная восприимчивость → Личностные характеристики пользователя	-0,004	0,040	0,968	отклоняется
H1	Вовлеченность → Личностные характеристики пользователя	0,720	8,177	0,000	принимается
H1	Знание → Личностные характеристики пользователя	0,113	1,327	0,184	отклоняется
H1	Самозффективность → Личностные характеристики пользователя	0,313	2,531	0,011	принимается
H2	Относительное преимущество российского ПО → Инновационные характеристики российского ПО	0,495	30,845	0,000	принимается
H2	Технологическая инновационность российского ПО → Инновационные характеристики российского ПО	0,549	29,820	0,000	принимается
H3	Личностные характеристики пользователя → Отношение к необходимости перехода на российское ПО	0,625	8,193	0,000	принимается
H3	Инновационные характеристики российского ПО → Отношение к необходимости перехода на российское ПО	0,286	3,617	0,000	принимается
H4	Отношение к необходимости перехода на российское ПО → Индивидуальное принятие перехода на российское ПО	0,778	17,995	0,000	принимается
H5	Отношение к необходимости перехода на российское ПО → Признание ценности перехода на российское ПО для общества	0,602	8,180	0,000	принимается

Адекватность структурной модели оценивается с помощью коэффициентов детерминации R^2 . На рисунке 3 значения коэффициентов R^2 приведены в кругах, обозначающих конструкторы модели.

Анализ взаимосвязей между конструкторами модели включает интерпретацию β -коэффициентов и соответствующих им значений t -статистик.

Результаты анализа структурной модели приведены в таблице 4.

Отметим критерии, необходимые для анализа данных таблицы 4:

- ♦ высокие p -значения ($>0,05$) свидетельствуют о том, что исследовательская гипотеза отклоняется;
- ♦ значения β -коэффициентов демонстрируют тесноту связи между конструкторами.

3. Обсуждение

Итак, анализируя результаты тестирования гипотез были сделаны следующие выводы:

- ♦ отклонена исследовательская гипотеза о влиянии уровня знаний на личностные характеристики,

воздействующие на отношение пользователя к необходимости перехода на российское ПО;

- ♦ отклонена исследовательская гипотеза о влиянии индивидуальной инновационной восприимчивости на личностные характеристики, воздействующие на отношение пользователя к необходимости перехода на российское ПО;
- ♦ подтверждены все остальные исследовательские гипотезы.

Дополняя выводы о результатах тестирования гипотез анализом значений β -коэффициентов можно утверждать, следующее:

- ♦ существует значимое влияние вовлеченности и самоэффективности на личностные характеристики, воздействующие на отношение пользователя к необходимости перехода на российское ПО, при этом значение влияния вовлеченности (0,720) превышает значение влияния самоэффективности (0,313);
- ♦ существует статистически значимое среднее по силе влияние относительного преимущества российского ПО (0,495) и технологической инно-

вационности российского ПО (0,549) на инновационные характеристики российского ПО, воздействующие на отношение пользователя к необходимости перехода на российское ПО;

- ◆ сравнивая силу влияния личностных характеристик пользователя (0,625) и инновационных характеристик российского ПО (0,286) на намерение использовать российское ПО, отметим заметное превышение значения силы влияния личностных характеристик;
- ◆ намерение использовать российское ПО значимо влияет как на индивидуальное принятие перехода на российское ПО (0,778), так и на признание ценности перехода на российское ПО для общества (0,602).

Таким образом, результаты анализа структурной модели позволяют утверждать, что наибольшее влияние на намерение использовать российское ПО, а, следовательно, и на принятие российского ПО оказывают личностные характеристики, а именно вовлеченность и самооффективность. Рассматривая механизмы работы с сопротивлением при внедрении проекта по импортозамещению ПО в вузе, следует воздействовать на эти два фактора мотивации для успешного внедрения российского ПО.

Можно утверждать, что показатели личностных характеристик пользователя и инновационных характеристик российского ПО в совокупности объясняют 68,5% дисперсии показателей отношения к необходимости перехода на российское ПО ($R^2 = 0,685$), тогда как показатели отношения к необходимости перехода на российское ПО объясняют 60,6% дисперсии показателей индивидуального принятия перехода на российское ПО ($R^2 = 0,606$) и 36,2% дисперсии показателей признания ценности перехода на российское ПО для общества ($R^2 = 0,362$).

Заключение

Целью настоящего исследования является выделение значимых факторов, влияющих на принятие российских программных решений в образовательных организациях. Базисом модели исследования послужили концепции теории диффузии инноваций и модели принятия технологий. Для проверки гипотез исследования использовался метод моделирования структурными уравнениями с применением результатов анкетирования преподавателей и сотрудников вуза.

Результаты исследования имеют теоретическую значимость и перспективу дальнейшего практического применения.

Исследование подтвердило выводы модели принятия технологий о влиянии поведенческих намерений использовать информационные технологии на их непосредственное использование. Нами был получен статистически значимый результат, утверждающий, что отношение к необходимости перехода на отечественное ПО выступает в качестве опосредующего фактора между независимыми и зависимыми переменными исследования. Проведенный анализ согласуется также с идеями последователей теории диффузии инноваций: на индивидуальное принятие импортозамещения и признание ценности перехода на отечественное ПО для общества влияют как личностные характеристики пользователя, так и инновационные характеристики российского ПО. При этом положительное отношение к необходимости импортозамещения опосредует влияние на индивидуальное принятие в большей мере, чем на признание ценности перехода на российское ПО для общества. Это свидетельствует о том, что существуют дополнительные неучтенные в модели факторы, влияющие на признание импортозамещения в качестве базового приоритета развития российской экономики.

Результаты исследования имеют практическую значимость. Систематизация факторов, влияющих на успешный переход на отечественное ПО в учреждениях высшего образования в условиях технологического суверенитета, позволит руководству вуза осознанно планировать и уточнять мероприятия по стратегии импортозамещения.

Отметим, что исследование имеет ряд ограничений. Во-первых, оно проведено на относительно небольшой выборке и может иметь ошибку репрезентативности. Во-вторых, на ответы респондентов мог влиять эффект социальной желательности, заключающийся в том, что опрашиваемые могли сознательно или неосознанно выбирать социально одобряемые ответы и преувеличивать или, наоборот, преуменьшать свое согласие с необходимостью импортозамещения.

В последующих исследованиях следует учесть ряд других важных факторов, влияющих на принятие импортозамещения ПО. Нам представляется, что будет интересным провести подобные исследования в организациях различных отраслей российской экономики как в коммерческих компаниях, так и в государственных структурах. ■

Литература

1. Методические рекомендации по переходу образовательных организаций высшего образования на преимущественное использование отечественного программного обеспечения (мессенджеры и ВКС), в том числе отечественного офисного программного обеспечения // Минобрнауки России. Официальный сайт, 2022. [Электронный ресурс]: https://minobrnauki.gov.ru/importozameshcheniye/Метод_рекомендации_отеч_ПО_ВУЗы.pdf (дата обращения 24.05.2024).
2. Импортозамещение ИТ в сфере науки и высшего образования // Минобрнауки России. Официальный сайт, 2022. [Электронный ресурс]: <https://minobrnauki.gov.ru/importozameshcheniye/> (дата обращения 24.05.2024).
3. Бурняшов Б.А. Импортозамещение программного обеспечения учебного процесса российских вузов // Информатика и образование. 2022. Т. 37. № 1. С. 27–36.
4. Бурняшов Б.А. Российские облачные пакеты офисных приложений в учебном процессе вузов // Информатика и образование. 2023. Т. 38. № 2. С. 5–15.
5. Аналитический отчет по определению потенциала импортозамещения программного обеспечения (в системе высшего и среднего профессионального образования). Иннополис: Университет Иннополис, 2022.
6. Пасурин Д.А. Проблемы импортозамещения программного обеспечения в вузе // Цифровые модели и решения. 2023. Т. 2. № 4. С. 63–75.
7. Музалевская А.А. Предпосылки и возможности импортозамещения программного обеспечения при подготовке специалистов в российских вузах / А.А. Музалевская и [др.] // Ученые записки Орловского государственного университета. 2023. № 2(99). С. 275–279.
8. Полонский А.М. Импортозамещение программного обеспечения и организация обучения студентов с использованием отечественного или свободного программного обеспечения // Актуальные проблемы экономики и управления. 2022. № 2(34). С. 65–82.
9. Савватеева Т.П. Проблемы импортозамещения программного обеспечения при обучении студентов-бакалавров проектированию информационных систем // Современные проблемы науки и образования. 2019. № 5.
10. Загвязинский В.И. Теория обучения: современная интерпретация. М.: Издательский центр «Академия», 2001.
11. Калинин Н.С. Феномен принятия информационных технологий: современное состояние и направления дальнейших исследований / Н.С. Калинин и [др.] // Организационная психология. 2022. Т. 12. № 1. С. 128–152.
12. Rogers E.M. Diffusion of innovations. New York: Simon and Schuster, 2010.
13. Роджерс Э., Агарвала-Роджерс Р. Коммуникации в организациях: Пер. с англ. М.: Экономика, 1980.
14. Davis F.D. A Technology Acceptance Model for empirically testing new end-user information systems: theory and results. PhD dissertation. Cambridge: Massachusetts Institute of Technology, 1985.
15. Davis F.D., Bagozzi R.P., Warshaw P.R. User acceptance of computer technology: A comparison of two theoretical models // Management Science. 1989. Vol. 35. No. 8. P. 982–1003.
16. Moore G.C., Benbasat I. Development of an instrument to measure the perceptions of adopting an information technology innovation // Information Systems Research. 1991. Vol. 2. P. 192–222. <https://doi.org/10.1287/isre.2.3.192>
17. Parasuraman A. Technology Readiness Index (TRI): A multiple-item scale to measure readiness to embrace new technologies // Journal of Service Research. 2000. Vol. 2. No. 4. P. 307–320. <https://doi.org/10.1177/109467050024001>
18. Ajzen I. The theory of planned behavior // Organizational Behavior and Human Decision Processes. 1991. Vol. 50. P. 179–211. [https://doi.org/10.1016/0749-5978\(91\)90020-T](https://doi.org/10.1016/0749-5978(91)90020-T)
19. Venkatesh V., Morris M., Davis G., Davis F. User acceptance of information technology: toward a unified view // MIS Quarterly. 2003. Vol. 27. No. 3. P. 425–478. <https://doi.org/10.2307/30036540>
20. Abraham C., Boudreau M., Junglas I., Watson R. Enriching our theoretical repertoire: The role of evolutionary psychology in technology acceptance // European Journal of Information Systems. 2013. Vol. 22. No. 1. P. 56–75. <https://doi.org/10.1057/ejis.2011.25>
21. Oh K., Kho H., Choi Y., Lee S. Determinants for successful digital transformation // Sustainability. 2022. Vol. 14. No. 3. Article 1215. <https://doi.org/10.3390/su14031215>
22. Ram S. A model of innovation resistance // Advances in Consumer Research. 1987. Vol. 14. P. 208–212.
23. SmartPLS 4. The world's most user-friendly statistical software // SmartPLS, 2024. [Электронный ресурс]: <https://www.smartpls.com/> (дата обращения 25.05.2024).
24. Chu Y., Chi M., Wang W. The impact of information technology capabilities of manufacturing enterprises on innovation performance: Evidences from SEM and fsQCA // Sustainability. 2019. Vol. 11. No. 21. Article 5946. <https://doi.org/10.3390/su11215946>
25. Miceli A., Hagen B., Riccardi M.P. Thriving, not just surviving in changing times: How sustainability, agility and digitalization intertwine with organizational resilience // Sustainability. 2021. Vol. 13. No. 4. Article 2052. <https://doi.org/10.3390/su13042052>
26. Zhang J., Long J., von Schaeven A.M.E. How does digital transformation improve organizational resilience? – Findings from PLS-SEM and fsQCA // Sustainability. 2021. Vol. 13. No. 4. Article 11487. <https://doi.org/10.3390/su132011487>
27. Hair J.F., Hult G.T.M., Ringle C., Sarstedt M., Danks N., Ray S. Partial least squares structural equation modeling (PLS-SEM) using R: A workbook. Springer, 2021.

Приложение 1.

Операционализация переменных исследования

Переменная	Наим.	Вопросы
Конструкт 1. Личностные характеристики пользователя		
Знание	BF_1	Я знаю, какими российскими программными продуктами можно заменить иностранное ПО, используемое сейчас при реализации дисциплин
	BF_2	Я хорошо осведомлен о плюсах и минусах российского ПО – аналоге зарубежного ПО, используемого сейчас при реализации дисциплин
	BF_3	Я могу рассказать другим о возможностях российского ПО – аналоге иностранного ПО, используемого сейчас при реализации дисциплин
Индивидуальная инновационная восприимчивость	BF_5	Обычно я начинаю использовать инновационные технологии раньше всех
	BF_6	Я склонен обновлять устройства по мере появления новых технологий и выхода новых моделей
	BF_7	Я склонен информировать окружающих об устройствах, созданных с использованием инновационных технологий
Самозффективность	BF_8	Я думаю, что мне будет легче обучиться и начать использовать незнакомое ранее ПО, чем другим
	BF_9	Я думаю, что смогу овладеть навыками работы с российским ПО за относительно короткое время
	BF_10	Я уверен в своих навыках работы с ПО и, думаю, что у меня не возникнет сложностей при работе с российским ПО
Вовлеченность	BF_11	Я открыт к использованию российского ПО – аналогу зарубежного ПО, используемого сейчас при реализации дисциплин
Конструкт 2. Инновационные характеристики российского ПО		
Относительное преимущество российского ПО	IC_1	Российское ПО, вероятно, имеет более широкие возможности, чем иностранное ПО, используемое сейчас при реализации дисциплин
	IC_2	Использование российского ПО будет более комфортным, чем иностранного ПО, используемого сейчас при реализации дисциплин
	IC_3	Российское ПО более надежно по сравнению с иностранным ПО, используемым сейчас при реализации дисциплин
	IC_4	Обучение навыкам работы с российским ПО более актуально, чем обучение работе с иностранным ПО, используемым сейчас при реализации дисциплин
Технологическая инновационность российского ПО	IC_5	Я думаю, что российское ПО создано с использованием инновационных технологий
	IC_6	Российское ПО является инновационным
	IC_7	Российские программные продукты оригинальны, креативны и новы
	IC_8	Российские программные продукты заметно отличаются в лучшую сторону от иностранного ПО, используемого сейчас при реализации дисциплин
Конструкт 3. Отношение к необходимости перехода на российское ПО		
Отношение к необходимости перехода на российское ПО	AT_1	Я позитивно отношусь к использованию российского ПО
	AT_2	У меня не вызывает затруднений работа с российским ПО
	AT_3	Я активно выступаю за использование российского ПО в учебном процессе
Конструкт 4. Индивидуальное принятие перехода на российское ПО		
Индивидуальное принятие	PA_1	Я готов к использованию российского ПО в учебном процессе
	PA_2	Если возникнет необходимость, я буду использовать российское ПО в учебном процессе
	PA_3	Я продолжу использовать российское ПО в будущем
Конструкт 5. Признание ценности перехода на российское ПО для общества		
Признание ценности перехода на российское ПО для общества	SA_1	Российское ПО должно активно использоваться в нашем обществе
	SA_2	Российское ПО должно использоваться организациями различных сфер деятельности
	SA_3	Нам необходимо постепенно наращивать использование российского ПО

Об авторах

Бегичева Светлана Викторовна

к.э.н.;

доцент, кафедра бизнес-информатики, Уральский государственный экономический университет, Россия, 620144, г. Екатеринбург, ул. 8 Марта, д. 62;

E-mail: begichevas@mail.ru

ORCID: 0000-0002-0551-1622

Бегичева Антонина Константиновна

преподаватель, аспирант, департамент программной инженерии, факультет компьютерных наук, Национальный исследовательский университет «Высшая школа экономики», Россия, 109028, г. Москва, Покровский б-р, д. 11;

стажер-исследователь, научно-учебная лаборатория процессно-ориентированных информационных систем (ПОИС), факультет компьютерных наук, Национальный исследовательский университет «Высшая школа экономики», Россия, 109028, г. Москва, Покровский б-р, д. 11;

E-mail: abegicheva@hse.ru

ORCID: 0000-0001-6657-1760

Назаров Дмитрий Михайлович

д.э.н.;

заведующий кафедрой бизнес-информатики, Уральский государственный экономический университет, Россия, 620144, г. Екатеринбург, ул. 8 Марта, д. 62;

E-mail: slup2005@mail.ru

ORCID: 0000-0002-5847-9718

Constructing a model to identify the determinants of successful software import substitution

Svetlana V. Begicheva^a

E-mail: begichevas@mail.ru

Antonina K. Begicheva^b

E-mail: abegicheva@hse.ru

Dmitry M. Nazarov^a

E-mail: slup2005@mail.ru

^a Ural State University of Economics, Yekaterinburg, Russia

^b HSE University, Moscow, Russia

Abstract

In the process of import substitution, higher educational institutions face several challenges in transitioning from the predominant use of foreign software to domestic alternatives. These challenges include a lack of user experience with domestic digital solutions, difficulty in transferring data between systems and other issues. The difficulties associated with the transition period create resistance to the digital transformation process. Research on import substitution in universities has identified three main themes: the challenges and risks associated with switching to domestic software, exploring the feasibility of a complete transition to Russian software and providing recommendations for selecting Russian solutions. This study aims to identify the factors that influence the adoption of import substitution software products in higher education. The article proposes a structural model to identify the factors that contribute to successful software import substitution. The model is based on the theories of innovation diffusion and technology adoption, and it was developed using SmartPLS software. The model is based on data collected from a survey of professors and staff at the Ural State University of Economics. The results of the study indicate that the attitude towards adopting import substitution software depends on several factors, including the personal characteristics and innovative features of the software. The most significant determinants of a positive attitude towards transitioning to domestic software include user involvement and self-efficacy. In addition, a positive perception of the need for import substitution can influence individual acceptance of transitioning to Russian software and recognizing import substitution as an economic policy of the country. The theoretical significance of the study lies in its proposal of an original model for identifying the determinants of successful software import substitution that differentiates between individual acceptance and public recognition of software import substitution. The findings of the study could be useful to university management in planning and implementing measures for an import substitution strategy.

Keywords: software import substitution, technological innovations, resistance to innovations, theoretical approaches to technology acceptance, diffusion of innovations theory, structural equation modeling

Citation: Begicheva S.V., Begicheva A.K., Nazarov D.M. (2024) Constructing a model to identify the determinants of successful software import substitution. *Business Informatics*, vol. 18, no. 3, pp. 7–23. DOI: 10.17323/2587-814X.2024.3.7.23

References

1. Ministry of Education and Science of Russia (2022) *Methodological recommendations for the transition of educational organizations of higher education to the primary use of domestic software (messaging and video conferencing), including domestic office software*. Available at: https://minobrnauki.gov.ru/importozameshcheniye/Метод_рекомендации_отеч_ПО_ВУЗы.pdf (accessed 24 May 2024) (in Russian).
2. Ministry of Education and Science of Russia (2022) *Import substitution of IT in the field of science and higher education*. Available at: <https://minobrnauki.gov.ru/importozameshcheniye/> (accessed 24 May 2024) (in Russian).
3. Burnyashov B.A. (2022) Import substitution of the software used in the educational process in Russian universities. *Informatics and Education*, vol. 37, no. 1, pp. 27–36 (in Russian).
4. Burnyashov B.A. (2023) Russian cloud office application packages in the educational process of universities. *Informatics and Education*, vol. 38, no. 2, pp. 5–15 (in Russian).
5. Innopolis University (2022) *Analytical report on determining the potential for import substitution of software (in the system of higher and secondary vocational education)*. Innopolis: Innopolis University (in Russian).
6. Pasurin D.A. (2023) Problems of software import substitution in universities. *Digital models and solutions*, vol. 2, no. 4, pp. 63–75 (in Russian).
7. Muzalevskaya A.A., Gajdamakina I.V. (2023) Prerequisites and opportunities for import substitution of software in the training of specialists in Russian universities. *Scientific Notes of Orel State University*, no. 2(99), pp. 275–279 (in Russian).
8. Polonskij A.M. (2022) Import substitution of software and organization of student education using domestic or free software. *Aktual'nye problemy ekonomiki i upravleniya (Actual problems of economics and management)*, no. 2(34), pp. 65–82 (in Russian).
9. Savvateeva T.P. (2019) Problems of software import substitution for teaching of bachelor students to information systems design. *Modern problems of science and education*, no. 5 (in Russian).
10. Zagvyazinskij V.I. (2001) *Learning Theory: A modern interpretation*. Moscow: Academia (in Russian).

11. Kalinichenko N.S., Velichkovskij B.B. (2022) The technology acceptance phenomenon: current state and future research. *Organizational Psychology*, vol. 12, no. 1, pp. 128–152 (in Russian).
12. Rogers E.M. (2010) *Diffusion of innovations*. New York: Simon and Schuster.
13. Rogers E.M., Agarwala-Rogers R. (1980) *Communication in organizations*. Moscow: Economy (in Russian).
14. Davis F.D. (1985) *A Technology Acceptance Model for empirically testing new end-user information systems: theory and results*. PhD dissertation. Cambridge: Massachusetts Institute of Technology.
15. Davis F.D., Bagozzi R.P., Warshaw P.R. (1989) User acceptance of computer technology: A comparison of two theoretical models. *Management Science*, vol. 35, no. 8, pp. 982–1003.
16. Moore G.C., Benbasat I. (1991) Development of an instrument to measure the perceptions of adopting an information technology innovation. *Information Systems Research*, vol. 2, pp. 192–222. <https://doi.org/10.1287/isre.2.3.192>
17. Parasuraman A. (2000) Technology Readiness Index (TRI): A multiple-item scale to measure readiness to embrace new technologies. *Journal of Service Research*, vol. 2, no. 4, pp. 307–320. <https://doi.org/10.1177/109467050024001>
18. Ajzen I. (1991) The theory of planned behavior. *Organizational Behavior and Human Decision Processes*, vol. 50, pp. 179–211. [https://doi.org/10.1016/0749-5978\(91\)90020-T](https://doi.org/10.1016/0749-5978(91)90020-T)
19. Venkatesh V., Morris M., Davis G., Davis F. (2003) User acceptance of information technology: Toward a unified view. *MIS Quarterly*, vol. 27, no. 3, pp. 425–478. <https://doi.org/10.2307/30036540>
20. Abraham C., Boudreau M., Junglas I., Watson R. (2013) Enriching our theoretical repertoire: The role of evolutionary psychology in technology acceptance. *European Journal of Information Systems*, vol. 22, no. 1, pp. 56–75. <https://doi.org/10.1057/ejis.2011.25>
21. Oh K., Kho H., Choi Y., Lee S. (2022) Determinants for successful digital transformation. *Sustainability*, vol. 14, no. 3, 1215.
22. Ram S. (1987) A model of innovation resistance. *Advances in Consumer Research*, vol. 14, pp. 208–212. <https://doi.org/10.3390/su14031215>
23. SmartPLS (2024) *SmartPLS 4. The world's most user-friendly statistical software*. Available at: <https://www.smartpls.com/> (accessed 25 May 2024).
24. Chu Y., Chi M., Wang W. (2019) The impact of information technology capabilities of manufacturing enterprises on innovation performance: Evidences from SEM and fsQCA. *Sustainability*, vol. 11, no. 21, 5946. <https://doi.org/10.3390/su11215946>
25. Miceli A., Hagen B., Riccardi M.P. (2021) Thriving, not just surviving in changing times: How sustainability, agility and digitalization intertwine with organizational resilience. *Sustainability*, vol. 13, no. 4, 2052. <https://doi.org/10.3390/su13042052>
26. Zhang J., Long J., von Schaeuwen A.M.E. (2021) How does digital transformation improve organizational resilience? – Findings from PLS-SEM and fsQCA. *Sustainability*, vol. 13, no. 4, 11487. <https://doi.org/10.3390/su132011487>
27. Hair J.F., Hult G.T.M., Ringle C., Sarstedt M., Danks N., Ray S. (2021) *Partial least squares structural equation modeling (PLS-SEM) using R: A workbook*. Springer.

About the authors

Svetlana V. Begicheva

Cand. Sci. (Econ.);

Associate Professor, Department of Business Informatics, Ural State University of Economics, 62, 8 Marta Str., Yekaterinburg 620144, Russia;

E-mail: begichevas@mail.ru

ORCID: 0000-0002-0551-1622

Antonina K. Begicheva

Lecturer, Postgraduate Student, School of Software Engineering, Faculty of Computer Science, HSE University, 11, Pokrovsky Blvd., Moscow 109028, Russia;

Research Assistant, Laboratory of Process-Aware Information Systems (PAIS Lab), Faculty of Computer Science, HSE University, 11, Pokrovsky Blvd., Moscow 109028, Russia;

E-mail: abegicheva@hse.ru

ORCID: 0000-0001-6657-1760

Dmitry M. Nazarov

Dr. Sci. (Econ.);

Head of Department of Business Informatics, Ural State University of Economics, 62, 8 Marta Str., Yekaterinburg 620144, Russia;

E-mail: slup2005@mail.ru

ORCID: 0000-0002-5847-9718

DOI: 10.17323/2587-814X.2024.3.24.40

Контрфактуальные объяснения на основе генерации синтетических данных

Ю.А. Зеленков 

E-mail: yzelenkov@hse.ru

Е.В. Лашкевич 

E-mail: evlashkevich@hse.ru

Высшая школа бизнеса, Национальный исследовательский университет «Высшая школа экономики», Москва, Россия

Аннотация

Контрфактуальное объяснение – это генерация для заданного экземпляра множества объектов, которые принадлежат к противоположному классу, но находятся в пространстве признаков максимально близко к объясняемому фактуалу. Известные алгоритмы, решающие эту задачу, как правило, основаны на сложных моделях, требующих большого объема обучающих данных и значительных вычислительных затрат. В данной статье предлагается метод, который включает два этапа. На первом этапе на основе простых статистических моделей (гауссовская копула, последовательная модель на основе условных распределений, байесовская сеть и др.) генерируется синтетическое множество потенциальных контрфактуалов, на втором – производится отбор объектов, удовлетворяющих ограничениям правдоподобия, близости, разнообразия и т.д. Такая организация позволяет сделать процесс прозрачным, управляемым и повторно использовать модели генерации. Эксперименты на трех свободно распространяемых наборах данных показали, что предложенный метод позволяет добиться результатов, как минимум, сравнимых с известными алгоритмами контрфактуальных объяснений, а в ряде случаев их превосходит, особенно на малых наборах данных. Наиболее эффективной моделью генерации при этом является байесовская сеть.

Ключевые слова: контрфактуальные объяснения, генерация синтетических данных, моделирование мультимодальных распределений, байесовская сеть, кредитный скоринг

Цитирование: Зеленков Ю.А., Лашкевич Е.В. Контрфактуальные объяснения на основе генерации синтетических данных // Бизнес-информатика. 2024. Т. 18. № 3. С. 24–40.

DOI: 10.17323/2587-814X.2024.3.24.40

Введение

В последние годы стремительно растет интерес к интерпретируемому искусственному интеллекту (explainable AI, XAI), что продиктовано расширяющимся использованием алгоритмов машинного обучения в различных областях человеческой деятельности [1, 2]. Более того, многие национальные и международные регуляторы требуют обеспечить прозрачность решений, основанных на алгоритмах. В частности, Общий регламент ЕС по защите данных (GDPR) предусматривает право граждан запрашивать «содержательную информацию о задействованной логике, а также о значении и предполагаемых последствиях» автоматизированных решений¹, а кредитное законодательство США требует предоставлять потребителям обоснования неблагоприятных решений [3]. Центральный банк РФ также следует рекомендациям ОЭСР по использованию AI², согласно которым модели должны быть прозрачны и интерпретируемы для ограничения модельных рисков и обеспечения возможности независимой внешней, внутренней и регуляторной проверки.

Методы XAI можно разделить на две группы [4]. Первая включает модели, для которых интерпретируемость (interpretability) является базовым свойством (например, дерево решений или линейная регрессия). Ко второй группе относятся методы, рассматривающие модель как черный ящик. В отличие от моделей первой группы, они не обладают свойствами, которые обеспечивают осмысленную интерпретацию, поэтому необходимо предпринимать дополнительные действия для объяснения логики принятия решения постфактум (explainability). Во второй группе, в свою очередь, можно выделить методы объяснения модели, объяснения локального результата и инспекции черного ящика [5].

В данной работе рассматриваются методы контрфактуального объяснения [5–8]. Контрфактуальное объяснение (counterfactual explanation, CE) позволяет для заданного экземпляра найти множество объектов, которые принадлежат к противоположному классу, но находятся в пространстве признаков максимально близко к объясняемо-

му экземпляру. В качестве примера в литературе обычно приводится заемщик, которому было отказано в кредите на основании решения алгоритма, используемого в банке. Задачей CE является генерация для данного заемщика такого профиля, чтобы его заявка была одобрена (например, уменьшение суммы запрашиваемого кредита). Очевидным ограничением при этом является реализуемость предлагаемых изменений, поэтому обязательным параметром, минимизируемым в задачах такого рода, является расстояние между образцом и контрфактуалом. Из данного примера следует, что, согласно приведенной выше классификации, CE относится к группе локальных методов объяснения постфактум, поскольку объясняет решение обученной модели, трактуемой как черный ящик, для конкретного образца.

Следует отметить, что в русском языке нет устоявшегося соответствия английскому термину “counterfactual”. В Большой российской энциклопедии (БРЭ)³ можно встретить как «контрфактуальный», так и «контрфактический». Мы выбрали первый вариант, поскольку он использован в переводе книги [9]⁴, впервые, насколько нам известно, представившем эту концепцию на русском языке. Кроме того, на наш взгляд, при использовании такой формы прослеживается связь с моделью потенциального результата Д. Рубина, которая противопоставляет действительно происшедшее событие (factual) и его альтернативу (counterfactual).

В философии контрфактуал определяется как условное утверждение, антецедент (предшествующее событие, помогающее понять настоящее) которого ложен, а консеквент (следствие) описывает, каким был бы мир, если бы антецедент имел место (ответ на вопрос «что-если»). Согласно БРЭ, контрфактуальное мышление – вид мышления, характеризующийся склонностью человека представлять возможные иные варианты уже произошедших событий, т.е. размышление вопреки фактам.

В то время как большинство методов XAI направлены на получение ответов на вопрос «почему» [4], контрфактуальные утверждения служат средством интерпретации, указывая на то, какие

¹ General Data Protection Regulation (<https://gdpr-info.eu>)

² Recommendation of the Council on Artificial Intelligence (<https://legalinstruments.oecd.org/en/instruments/OECD-LEGAL-0449>)

³ <https://bigenc.ru>

⁴ Мишра П. Объяснимые модели искусственного интеллекта на Python. ДМК Пресс, 2022.

изменения потребуются для достижения желаемой цели (предсказание), а не помогают понять, почему текущая ситуация имеет определенный прогнозируемый результат [8]. Поэтому многие авторы [5], констатируют что SE соответствует третьему уровню моделей причинности Перла [10], которые должны отвечать на вопросы, предполагающие ретроспективные рассуждения, например, «какова вероятность события y при x , если в действительности наблюдаются x' и y' ». При этом SE также не накладывает ограничений на сложность модели и не требует раскрытия информации о модели [3].

Очевидно, что методы SE являются мощным инструментом поддержки принятия решений в различных областях, например, в финансах [11, 12] и медицине [13]. К настоящему времени уже известно несколько десятков алгоритмов SE (см. обзоры [5, 6, 8] и др.). Большинство из них основаны на оптимизации некоторой целевой функции, и эта задача решается каждый раз, когда необходимо вычислить множество контрфактуалов для заданного образца. Это накладывает ограничения на производительность и масштабируемость SE [6]. Возможной альтернативой является использование методов, которые позволяют моделировать совместное распределение признаков изучаемых объектов. В этом случае однократно обученная модель может генерировать контрфактуалы для различных образцов без значительных вычислительных затрат.

Отметим, что в такой постановке задачу можно рассматривать как генерацию синтетических табличных данных [14, 15]. Для создания таких моделей используются как статистические методы – копулы, байесовские сети, так и методы машинного обучения – вариационные автоэнкодеры, генеративные состязательные сети и т.д. [16]. Некоторые исследователи также адаптируют для этой цели методы оверсэмплинга, которые разработаны для генерации объектов минорного класса в случае несбалансированных данных [17].

Учитывая эти обстоятельства, в данной статье предлагается подход к SE, основанный на принципах генерации синтетических данных, который включает два этапа. На первом этапе генерируется множество потенциальных контрфактуалов, на втором – производится отбор тех из них, которые удовлетворяют ограничениям реализуемости, близости, стоимости и т.д. Такая организация позволяет сделать процесс SE прозрачным, управляемым, повторно использовать модели генерации и,

тем самым, значительно сократить вычислительные затраты.

Оставшаяся часть работы организована следующим образом. После обзора литературы, в разделе 2 представлен предлагаемый метод. В разделах 3 и 4 представлены результаты эксперимента по сравнению предложенного метода с другими известными методами SE. В заключении обсуждаются ограничения предложенного метода, а также дальнейшие направления исследований.

1. Обзор литературы

1.1. Генерация контрфактуалов

SE базируется на нескольких неявных предположениях [3]:

- ◆ рекомендуемое изменение значений признаков однозначно реализуется в реальном мире;
- ◆ распределение значений признаков может быть восстановлено из доступных обучающих данных;
- ◆ предлагаемые изменения имеют отношение только к принимаемому решению и не затрагивают другие области;
- ◆ модель устойчива во времени, монотонна и ограничена бинарными исходами.

Как уже отмечалось выше, SE является активно развивающейся областью исследований. Сам термин «контрфактуальное объяснение» применительно к AI-системам впервые использован в [18], однако работы, использующие аналогичный подход, стали появляться с середины 2010 годов [5].

Дадим формальные определения. Рассмотрим классификатор $h: \mathcal{X} \rightarrow \mathcal{Y}$ обученный на наборе данных $\mathcal{D} = \{(x_1, y_1), \dots, (x_n, y_n)\}$, $x_i \in \mathcal{X}$, $y_i \in \mathcal{Y}$, $\mathcal{X} \subset \mathbb{R}^m$ – пространство признаков, \mathcal{Y} – пространство меток классов. Обычно полагается $\mathcal{Y} = \{0, 1\}$ но все предлагаемые определения легко обобщаются и на случай многоклассовой классификации. Каждый экземпляр x_i – это вектор m пар признаков, $x_i = \{(a_j, v_{ij})\}_{j=1}^m$, где a_j – это признак (атрибут), а v_{ij} – его значение из домена a_j . Атрибуты могут быть как категориальными, порядковыми, так и непрерывными.

Определение 1. Если классификатор h присваивает метку $y = h(x)$ экземпляру x , контрфактуальным объяснением x является экземпляр x^* такой, что метка x^* отлична от y , т.е. $h(x^*) \neq y$, при этом различие между x и x^* минимально. Концепция мини-

мального различия здесь не уточняется, поскольку она зависит от контекста решаемой задачи и будет рассмотрена позднее.

Определение 2. Контрфактуальная модель (counterfactual explainer) – это функция f_k , которая для набора данных \mathcal{D} , классификатора h и экземпляра x возвращает набор $C = f_k(h, \mathcal{D}, x)$ из $l \leq k$ допустимых контрфактуальных примеров $C = \{x_1^*, \dots, x_l^*\}$, где k – количество необходимых контрфактуалов.

Характеристики, которые позволяют оценить качество алгоритма генерации контрфактуалов:

1. Валидность (validity) измеряется отношением числа контрфактуалов, которые имеют требуемую метку класса, к общему числу сгенерированных объектов [11]:

$$V = |C_v| / |C|,$$

где C_v – множество валидных контрфактуалов, сгенерированных моделью f_k ;

C – множество примеров, сгенерированных f_k , $C_v \subset C$.

Валидность сгенерированного примера определяется при помощи предиктивной модели h , для валидного примера должно выполняться условие $h(x^*) \neq h(x)$. Как следует из определения, максимальное значение валидности $V = 1$, значения меньше 1 сигнализируют о недостаточной эффективности модели.

2. Близость (proximity) – расстояние контрфактуала от объекта, для которого генерируется объяснение. Близость множества контрфактуалов оценивается через среднее значение на этом множестве [19]:

$$P = \frac{1}{|C_v|} \sum_{x^* \in C_v} \text{dist}(x^*, x).$$

Для измерения расстояния $\text{dist}(x^*, x)$ чаще всего используются L_0 , L_1 , L_2 и L_∞ – нормы, $L_k = \left(\sum_i |x_i - x_i^*|^k\right)^{1/k}$ и их взвешенные комбинации. Чем меньше значение P , тем ближе найденные объекты к объясняемому фактуалу.

3. Разреженность (sparsity) – это оценка того, сколько признаков нужно изменить, чтобы перейти в класс контрфактуалов. Желательно, чтобы контрфактуалы имели как можно меньше изменений в своих характеристиках. Это свойство позволяет получить более эффективные, понятные человеку и интерпретируемые контрфактуализации [18].

$$S = \frac{1}{|C_v|} \sum_{x^* \in C_v} K(x^*).$$

$K(x^*)$ – количество атрибутов контрфактуала x^* , значение которых изменяется по сравнению с фактуалом x . Таким образом, предпочтительнее модели с меньшим значением S .

4. Разнообразие (diversity). Поиск ближайших точек в соответствии с функцией расстояния может привести к очень похожим контрфактуальным кандидатам с небольшими различиями между ними. Разнообразие подразумевает, что процесс генерации контрфактуалов дает различающиеся объяснения для одного и того же экземпляра данных. Это приводит к тому, что объяснения становятся более интерпретируемыми и более понятными для пользователя. Авторы [19] в качестве меры разнообразия предлагают использовать среднее расстояние между всеми парами валидных контрфактуалов:

$$D = \frac{1}{|C_v|^2} \sum_{i=1}^{k-1} \sum_{j=i+1}^k \text{dist}(x_i^*, x_j^*),$$

где $\text{dist}(x_i^*, x_j^*)$ – мера расстояния между двумя контрфактуалами x_i^* и x_j^* . Чем выше разнообразие, тем эффективнее алгоритм SE.

5. Правдоподобность (plausibility). Это свойство подчеркивает, что генерируемые контрфактуалы должны быть легитимными, а процесс поиска должен обеспечивать логически обоснованные результаты. Это означает, в частности, что найденный контрфактуал никогда не должен изменять неизменяемые характеристики, такие как пол или раса. В литературе выделяются три категории правдоподобия [20]:

- ♦ согласованность с доменом, которая ограничивает диапазон допустимых значений признаков контрфактуала;
- ♦ согласованность распределения требует, чтобы вероятности конкретных значений признаков контрфактуала соответствовали (эмпирическому) распределению данных. Это свойство может быть измерено [6] как среднее расстояние до k ближайших соседей, например, локальный коэффициент выбросов (local outlier factor, LOF) [21], а также с помощью ядерных функций (kernel density estimation, KDE). В последнем случае оценивается плотность распределения каждого признака на основе KDE, а затем вычисляется вероятность принадлежности соответствующего атрибута контрфак-

туала этому распределению. Данный подход имеет очевидные ограничения – рассматривается каждый признак отдельно, и он применим только к непрерывным атрибутам. Способ на основе ближайших соседей таких ограничений не имеет;

- ◆ согласованность с прототипом выбирает контрфактуальные экземпляры, которые либо непосредственно присутствуют в наборе данных, либо близки к объясняемому объекту данных. Отметим, что данное свойство близко к определению близости (proximity), представленному выше.

В данной работе мы будем использовать изменение правдоподобности на основе значения LOF, т.е.

$$U = \frac{1}{|C_v|} \sum_{x^* \in C_v} LOF(x^*).$$

Отметим, что значения LOF трудно интерпретировать ввиду локальности метода. Значения около 1, говорит, что точка внутренняя, чем выше значение, тем больше вероятность того, что она является выбросом. Таким образом, с точки зрения оценки алгоритма SE предпочтительными являются значения, близкие к 1.

6. Осуществимость (actionability / feasibility). Поиск наиболее близкого контрфактуала для экземпляра данных не обязательно приводит к осуществимому изменению характеристик. Возможность изменения конкретной переменной описывается одной из трех категорий:

- ◆ изменение признака может быть осуществимо (actionable) и, соответственно, признак изме-

няем (mutable), например, данные бухгалтерского баланса;

- ◆ признак изменяем, но изменение не осуществимо (например, кредитный рейтинг);
- ◆ признак неизменяем (например, место рождения).

Отметим, что пользователь не может изменить значения переменных двух последних категорий, однако эти значения могут меняться в результате воздействия на их предков в причинно-следственной модели [20]. Некоторые авторы полагают, что удовлетворение требования осуществимости автоматически гарантирует правдоподобность контрфактуальной рекомендации [22], однако, несмотря на некоторое пересечение, это разные концепции [20]. Осуществимость ограничивает набор действий теми, что можно выполнить, правдоподобие требует, чтобы результирующий контрфактуал был реалистичным.

Авторы обзорных статей [5–8] используют различные таксономии методов SE. Здесь предлагается классификация на основе архитектуры используемых моделей (рис. 1).

Первая группа методов основана на решении задачи оптимизации, в которой часть перечисленных выше свойств рассматривается как целевая функция, а оставшиеся свойства – как ограничения. Например, в [18] в качестве цели используется расстояние $dist(x^*, x)$ с ограничением на метку контрфактуала $h(x^*) = y^*$. Данная задача может быть преобразована в проблему, описываемую дифференцируемой функций без ограничений:

$$x^* \in \arg \min_{x^*} \max_{\lambda} \lambda(h(x^*) - y^*)^2 + dist(x^*, x).$$

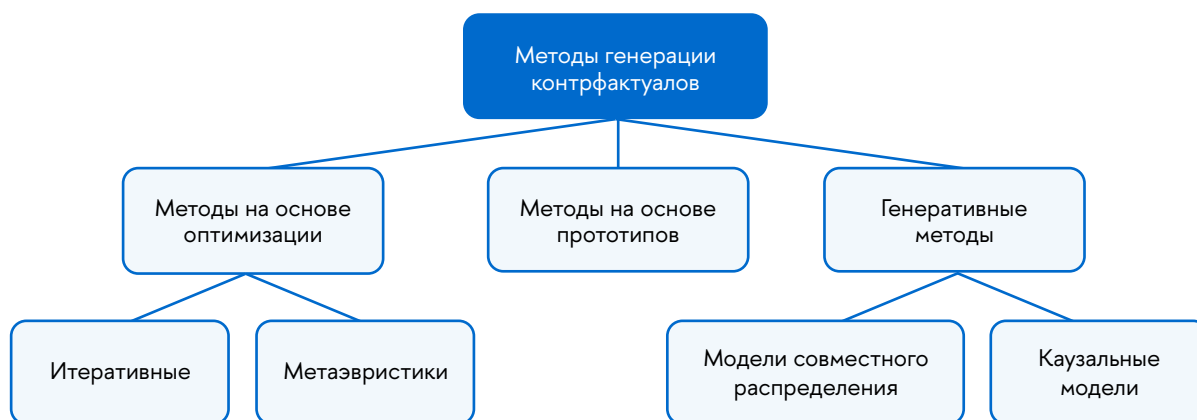


Рис. 1. Классификация алгоритмов генерации контрфактуалов.

Член $\lambda(h(x^*) - y^*)^2$ обеспечивает соответствие метки контрфактуала желаемому классу.

Подобный подход может быть расширен так, чтобы включать ограничения осуществимости (actionability), разреженности (sparsity), согласованности распределения (data manifold closeness) и др., например [6]:

$$x^* \in \arg \min_{x^* \in \mathcal{A}} \max_{\lambda} \lambda (h(x^*) - y^*)^2 + \text{dist}(x^*, x) + g(x^* - x) + l(x^*; \mathcal{X}).$$

Условие $x^* \in \mathcal{A}$ ограничивает список изменяемых атрибутов x^* теми, изменение которых может быть осуществимо, $g(x^* - x)$ — функция штрафа за различие между оригинальным экземпляром и контрфактуалом (например, L_0 , L_1 норма), $l(x^*; \mathcal{X})$ — функция штрафа за отклонение от многообразия данных.

Авторы методов SE, основанных на оптимизации, фокусируются прежде всего на определении целевой функции, включающей различные метрики для перечисленных выше свойств, а затем на выборе алгоритма нахождения оптимума. Как правило, при этом невозможно гарантировать выпуклость целевой функции. Часто используются итерационные методы различных порядков, также широкое распространение получили метаэвристики (например, генетические алгоритмы). Однако, такой подход требует решения задачи оптимизации при генерации контрфактуалов для каждого нового экземпляра данных. Поэтому в [6] авторам таких работ рекомендуется приводить время вычислений как одну из характеристик алгоритма.

Вторая группа методов основана на поиске в \mathcal{D} прототипов, которые будут использованы для генерации контрфактуалов [23]. Концептуально этот подход близок к методу рассуждения на основе прецедентов (Case Based Reasoning, CBR) [24], который включает четыре шага: (1) *retrieve* — извлечение кейса, имеющего отношение к решаемой проблеме, (2) *reuse* — сопоставление найденного решения с проблемой, (3) *revise* — тестирование решения и при необходимости его пересмотр, (4) *retain* — сохранение успешно адаптированного решения.

В частности, в [25] предложен алгоритм, согласно которому набор данных \mathcal{D} рассматривается как множество пар (x, x^*) , где (x, x^*) — наиболее близкие объекты, для которых $h(x^*) \neq h(x)$. Для заданного фактуала z находятся ближайший экземпляр x , принадлежащий к тому же классу, $h(z) = h(x)$. Значения атрибутов контрфак-

туала z^* инициализируются значениями из z , затем изменяются те атрибуты, которые различаются в x и x^* , пока не будет найден такой z^* , что $h(z^*) = h(x^*)$. Если данное условие не достигнуто, то используется следующая пара (x, x^*) . Идея заключается в том, что z^* должен отличаться от z так же, как x^* отличается от x .

Третья группа методов SE (генеративные модели) основана на моделировании процесса генерации данных. В данной группе можно выделить два типа моделей: моделирование совместного распределения и каузальные модели.

Модель совместного распределения $P(X)$ обучается на основе наблюдений \mathcal{D} и затем используется для поиска контрфактуалов. В качестве такой модели в SE чаще всего используются вариационные автоэнкодеры (variational autoencoder, VAE), которые состоят из двух частей — энкодера, отображающего распределение признаков $P(X)$ в пространстве \mathbb{R}^m в распределение латентных переменных $P(Z)$ в пространстве меньшей размерности $Z \subset \mathbb{R}^k$ ($k < m$), и декодера, генерирующего значение x' , соответствующее точке z' в $P(Z)$. Подход на основе VAE открывает интересную перспективу — проводить поиск контрфактуалов в латентном пространстве, в частности, некоторые авторы используют для этого градиентный спуск [26, 27], однако, как показано в [28], это связано с потенциальными проблемами.

Авторы методов SE на основе VAE вынуждены учитывать перечисленные выше требования к генерации контрфактуальных объяснений, поэтому они вносят дополнительные ограничения в модель латентных представлений. Так, в [29] адаптируется традиционная схема, при которой энкодер используется только для поиска $P(Z)$ и не участвует в генерации данных, и включают его в процесс генерации. С помощью энкодера находится точка z в латентном пространстве, соответствующая заданному фактуалу x , контрфактуал генерируется из точки $z^* = z + \delta$, где δ — малое возмущение. Это должно обеспечивать требование близости. Кроме того, авторы этой работы кластеризуют латентное пространство на основе Гауссовской смеси, чтобы получить условное распределение $P(Z|J)$, где J — множество неизменяемых признаков.

Авторы работы [28] используют модель VAE, адаптированную для поиска латентных переменных, коррелированных с метками класса [30]. При этом латентное пространство разделяется на две части: одна предназначена для обучения представ-

лений, предсказывающих метки, а другая – для обучения остальных латентных представлений, необходимых для генерации данных. Это позволяет генерировать контрфактуалы, изменяя только релевантные латентные признаки. Сгенерированные примеры затем фильтруются в соответствии с причинно-следственными ограничениями (например, повышение уровня образования заемщика должно сопровождаться соответствующим увеличением его возраста).

Отметим, что помимо VAE могут использоваться и другие модели совместного распределения $P(X)$, в частности, статистические модели, такие как копулы и байесовские сети, однако, эти техники значительно реже применяются в задачах CE (см. обзоры алгоритмов в [5, 8]). Кроме того, в некоторых специфических случаях, например, в задачах анализа изображений, могут применяться генеративные состязательные сети [13].

Каузальная модель может быть представлена как ориентированный ациклический граф (directed acyclic graph, DAG), что позволяет компактно и наглядно отобразить структуру исследуемой системы [10]. Способность DAG кодировать причинно-следственные связи основана на графическом критерии d -разбиения (d -separation), которое соответствует условной независимости переменных в наборе данных. Другими словами, для любых трех непересекающихся подмножеств переменных (X, Y, Z) , если вершины X и Y условно независимы при наличии Z в совместном распределении \mathcal{P} , то они будут d -разделены в графе \mathcal{G} (Марковское условие): $(X \perp_{\mathcal{P}} Y) | Z \Rightarrow (X \perp_{\mathcal{G}} Y) | Z$. Узлы DAG соответствуют переменным, ребра – связям между ними, а направление ребер – причинно-следственным отношениям.

DAG соответствует структурной модели \mathcal{M} :

$$\mathcal{M} = (\mathbf{S}, P_U), \quad \mathbf{S} = \{X_j := f_j(X_{pa(j)}, U_j)\}_{j=1}^m, \\ P_U = P_{U_1} \times \dots \times P_{U_m}.$$

Здесь \mathbf{S} – структурные уравнения, задающие правила генерации наблюдаемых переменных X_j в виде детерминированной функции их предков в каузальной модели $X_{pa(j)} \subseteq X \setminus X_j$. Предположение о взаимной независимости шумов U_j (полная факторизация P_U) подразумевает отсутствие ненаблюдаемых конфаундеров – спутывающих переменных, влияющих на причину и следствие одновременно. Отметим, что во многих исследованиях полагается, что шум является аддитивным, т.е. $\mathbf{S} = \{X_j := f_j(X_{pa(j)} + U_j)\}_{j=1}^m$,

это позволяет построить эффективные алгоритмы идентификации модели по данным [31].

Важным элементом каузального моделирования является аппарат до-вычислений (do-calculus) [10]. Например, интервенция, т.е. присвоение подмножеству переменных X_K ($K \subseteq [m]$) значений θ , описывается с помощью оператора $do(X_K = \theta)$. Распределение оставшихся переменных X_{-K} может быть получено из системы $\mathbf{S}^{do(X_K = \theta)}$, в которой уравнения для X_K заменены соответствующими значениями. Таким образом, каузальная модель может быть использована для нахождения контрфактуалов [20], для экземпляра x контрфактуал определяется как $x^* = \mathbf{X}(a)|x$, где $a = do(X_K = \theta)$, $a \in A$, a – действие, A – множество допустимых действий.

Каузальные модели могут быть восстановлены из наблюдаемых данных или построены на основе экспертных знаний. Однако модель \mathcal{M} , обученная на данных, может быть несовершенной, например, из-за ограниченности выборки или, что более важно, из-за неправильной спецификации модели (т.е. принятия неверной параметрической формы структурных уравнений). С другой стороны, хотя во многих случаях экспертные знания позволяют построить причинно-следственную модель, но предположения о виде структурных уравнений, как правило, не поддаются проверке [32]. В результате контрфактуальные объяснения, вычисленные на основе неверно определенной каузальной модели, могут оказаться неточными и рекомендовать неоптимальные или, что еще хуже, неэффективные действия.

Чтобы преодолеть эти ограничения, авторы [20] предлагают два вероятностных подхода к выбору оптимальных действий при ограниченном знании причинно-следственных связей (например, когда известен только DAG). Первый из них применим к моделям с аддитивным гауссовским шумом и использует байесовское усреднение для оценки контрфактуального распределения. Во втором случае исключаются любые предположения о структурных уравнениях, а вместо этого вычисляется средний эффект действий на объекты, которые похожи на рассматриваемый фактуал.

1.2. Генерация синтетических табличных данных

Генерация синтетических данных (synthetic data generation, SDG) является ключевым элементом решения нескольких проблем машинного обучения: анонимизации данных, дополнения малых

наборов данных, выравнивания классов в случае сильного дисбаланса и т.д. [14].

Определение 3. Модель генерации синтетических данных – это функция $g \in \mathcal{G}$, которая для набора наблюдаемых данных $\mathcal{D} \sim \mathbb{P}$, возвращает набор данных $\mathcal{D}^S = g(\mathcal{D}, \theta)$ заданного размера, $\mathcal{D}^S \sim \mathbb{P}^S$, так что выполняется условие $\mathbb{P}^S \approx \mathbb{P}$, $x_i \neq x_j, \forall x_i \in \mathcal{D} \wedge \forall x_j \in \mathcal{D}^S$. Здесь θ – вектор гиперпараметров, определяющий политику генерации и \mathcal{G} – семейство генеративных функций.

Математически это можно представить как задачу минимизации расстояния Кульбака-Лейблера:

$$\theta^* = \operatorname{argmin}_{\theta} \sum_i \mathbb{P}(x_i) \log g(x_i, \theta).$$

Исходя из данного определения, ключевой метрикой эффективности генеративной модели является точность (fidelity) соответствия распределения синтетических данных \mathbb{P}^S эмпирическому распределению \mathbb{P} . Кроме этого, могут вводиться дополнительные метрики [33], например, разнообразие (diversity) и обобщение (generalization). Согласно требованию разнообразия синтетические экземпляры должны охватывать весь диапазон изменений \mathcal{D} . Свойство обобщения требует, чтобы синтетические данные не были копиями реальных наблюдений.

В данном обзоре мы ограничимся рассмотрением генерации синтетических табличных (кросс-секционных) данных (tSDG). Можно выделить следующие классы методов tSDG:

- ◆ Модели рандомизации, основанные на перемешивании, интерполяции и геометрической трансформации исходных данных и добавлении случайного шума.
- ◆ Вероятностные алгоритмы, которые генерируют данные на основе многомерного распределения \mathbb{P}^S , моделирующего реальное распределение \mathbb{P} . Здесь можно выделить несколько подходов, а именно:
 - ◇ моделирование совместного распределения \mathbb{P} , например, на основе Гауссовской смеси или копул [15];
 - ◇ последовательная генерация атрибутов \mathcal{D} на основе условных распределений $\mathbb{P}(x_i | \mathcal{D} \setminus \{x_1, \dots, x_{i-1}\})$;
 - ◇ моделирование \mathbb{P} с помощью факторизации на основе графической вероятностной модели (байесовской сети) [34].
- ◆ Модели, генерирующие данные из латентного пространства меньшей размерности.

- ◆ Моделирование сэмплирования на основе генеративных состязательных сетей (GAN).

- ◆ Модели, основанные на априорно известной каузальной структуре.

Отметим, что подход на основе моделей условных распределений синтезирует переменные x_i последовательно с помощью регрессионных моделей $x_i = f(x_1, \dots, x_{i-1})$, которые могут быть построены как параметрическими (линейная регрессия), так и непараметрическими (дерево решений) методами [35, 36]. Таким образом, условные распределения $\mathbb{P}(x_i | \mathcal{D} \setminus \{x_1, \dots, x_{i-1}\})$, из которых берутся синтетические значения x_i , определяются для каждой переменной отдельно и зависят от атрибутов x_1, \dots, x_{i-1} , которые находятся раньше в последовательности синтеза. Значение самой первой переменной в последовательности генерируется на основе ее маргинального распределения.

Детальный анализ методов tSDG представлен в [14]. Ряд публикаций [16, 17] сравнивают некоторые из рассмотренных подходов на реальных наборах данных. Из представленных результатов можно сделать вывод, что не существует доминирующего метода и качество генерации зависит от конкретной задачи.

Можно также отметить, что концептуально методы синтетической генерации данных близки к алгоритмам контрфактуальных объяснений: и те, и другие базируются на моделировании распределения наблюдаемых данных, но различаются конечным результатом. Если цель CE – найти объект максимально близкий к исследуемому, но с противоположной меткой (см. Определение 1), то цель tSDG – сгенерировать множество объектов, которые принадлежат распределению наблюдаемых данных (Определение 3). Соответственно, они базируются на разных метриках эффективности.

2. Предлагаемый метод

Как следует из представленного выше обзора, известные алгоритмы CE обладают несколькими ограничениями. Методы, основанные на оптимизации, требуют повторного построения модели для каждого фактуала, подходы на основе прототипов требуют наличия пар «фактуал – контрфактуал» в обучающем наборе \mathcal{D} , подходы на основе генеративных моделей вводят дополнительные ограничения в алгоритм, что также усложняет вычисления. В то же время, как отмечено выше, методы синтетической генерации данных концептуально близки

к СЕ и отличаются лишь результатом и метриками его оценки.

Исходя из этих соображений, мы предлагаем двухэтапный метод генерации контрфактуальных объяснений (рис. 2). На первом этапе обучается модель $g(\mathcal{D}, \theta)$ генерации синтетических данных. Согласно Определению 3, данная модель эмулирует эмпирическое распределение \mathbb{P} реальных данных. С помощью этой модели для данного фактуала x генерируется множество потенциальных контрфактуалов $\{x^*\}_g$.

На втором этапе с помощью модели отбора $s(R)$ из $\{x^*\}_g$ отбирается множество $\{x^*\}_s$, элементы которого удовлетворяют ограничениям R . Множество $\{x^*\}_s$ является решением задачи СЕ. Модель отбора может включать любые ограничения, сформулированные в виде неравенств вида $r(c) = m(c) \leq v(c)$, $r \in R$. Здесь c – требование к результату (например, валидность, близость, разреженность для СЕ или стоимость реализации), $m(c)$ – соответствующая метрика, $v(c)$ – граница допустимых значений. Отметим, что в число требований могут быть также включены ограничения конкретной предметной области.

Предложенный подход обладает следующими преимуществами:

- ◆ генеративная модель строится один раз и позволяет вычислять контрфактуалы для любых новых наблюдений без повторного обучения;
- ◆ разделение процесса на два этапа позволяет использовать достаточно простые, легко изменяемые правила отбора;

- ◆ модель отбора может включать не только требования задач СЕ, но и любые ограничения, специфичные для рассматриваемой предметной области.

3. Эксперимент

Для проверки предложенного метода прежде всего необходимо убедиться, что методы tSGD позволяют генерировать контрфактуалы, удовлетворяющие требованиям, перечисленным в разделе 1.1, а также сравнить результаты с известными методами СЕ.

Модели генерации $g(\mathcal{D}, \theta)$, которые будут использованы в эксперименте, представлены в таблице 1. Мы отобрали простейшие статистические модели, поскольку наша задача – предложить эффективный метод генерации контрфактуалов с небольшими вычислительными затратами. К таким моделям относятся Гауссовская копула (GC), последовательная непараметрическая модель на базе условных распределений (CD) и байесовская сеть (BN), которая моделирует распределение \mathbb{P} как произведение условных распределений факторов (признаков). Для сравнения мы также включили модель, генерирующую данные на основе маргинальных распределений признаков (MD). Ее можно рассматривать как вырожденный случай BN, в котором связи между признаками не учитываются. Как отмечалось выше, такие простые модели практически не используются в задачах СЕ, однако мы предполагаем, что их потенциал может быть использован значительно эффективнее с помощью предлагаемого двухэтапного подхода.

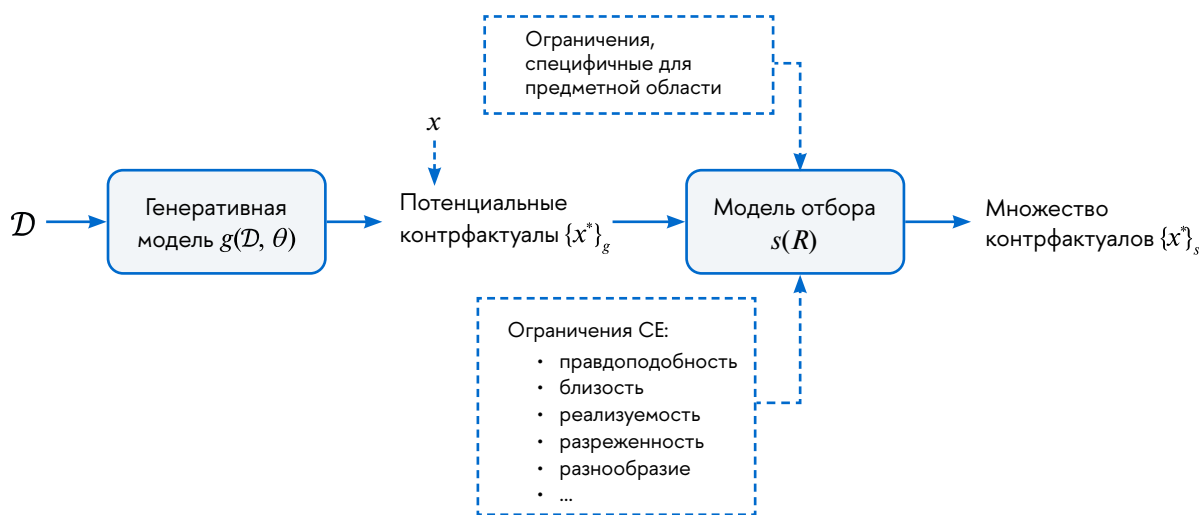


Рис. 2. Двухэтапный метод генерации контрфактуальных объяснений.

Таблица 1.

Методы генерации синтетических табличных данных

ID	Тип модели	Описание	Источник
GC	Совместное распределение \mathbb{P}	Гауссовская копула	[15] ⁵
CD	Условные распределения $\mathbb{P}(x_i \mathcal{D} \setminus x_i)$	Непараметрический метод / дерево решений	[36] ⁶
BN	Факторизация $\mathbb{P} = \prod p(x_i)$	Байесовская сеть	[34] ⁷
MD	Маргинальные распределения x_i	Сэмплинг на основе маргинальных распределений	[38] ⁸
GAN	Глубокое обучение	Генеративная состязательная сеть	[37] ⁹

Кроме того, как следует из обзора литературы, большинство исследователей, использующих генеративные модели для решения задачи СЕ, фокусируются на сложных алгоритмах, основанных на глубоких нейронных сетях, поэтому мы также рассмотрели GAN. Мы также исследовали возможность применения VAE, но в наших экспериментах эти модели не позволили добиться устойчивой генерации $\{x^*\}_g$. Скорее всего, это объясняется недостаточным объемом данных для обучения (таблица 2).

Модель отбора $s(R)$ задана в виде правила

$$R: h(x^*) \neq h(x) \wedge x_i^* \in \left\{ \bar{x}_i \mp 1,5 \cdot IQR(\mathcal{D}) \right\} \wedge dist(x^*, x) \rightarrow \rightarrow \min \wedge |\{x^*\}_s| = k.$$

Это означает, что для данного x из сгенерированного множества $\{x^*\}_g$ будут отбираться k экземпляров, метка которых $h(x^*)$ не равна метке $h(x)$, значения атрибутов x^* находятся в диапазоне трех межквартильных интервалов $IQR(\mathcal{D})$ относительно среднего x_i (граница Тьюки), и расстояние между x и x^* минимально.

Таблица 2 представляет три набора данных, использованных в экспериментах, их общие характеристики и классификацию признаков с точки зрения осуществимости изменений (признак изменяем, изменение не осуществимо, признак не изменяем). Эти общедоступные наборы данных широко используются в работах по машинному обучению и, в частности, исследованиях, касающихся

ся СЕ. Использование открытых наборов данных обеспечивает воспроизводимость результатов.

В таблице 2 также представлены результаты обучения классификатора h , который используется в процессе нахождения СЕ: метрика ROC AUC, полученная с помощью 10-кратной кросс-валидации и модель, показавшая наилучшие результаты. В одном случае это Random Forest (RF), в остальных случаях – CatBoost (CB).

Одной из наиболее популярных библиотек, реализующих методы СЕ, является DiCE13 [19], которая поддерживает три способа поиска контрфактуалов. Помимо случайного поиска, это оптимизация на основе генетических алгоритмов и метод поиска и последующей адаптации прототипов в обучающей выборке [23]. Мы использовали эти модели для сравнительной оценки полученных результатов. Для каждого набора данных обучались все три типа моделей и выбиралась лучшая. Отметим, что подход на основе прототипов не позволил найти контрфактуалы ни для одного набора данных. Очевидно, это связано с ограничением, отмеченным выше: в \mathcal{D} должен присутствовать набор пар (x, x^*) для широкого диапазона фактуалов.

Для оценки результатов вычисления контрфактуалов будем использовать метрики валидности (V), близости (P), разреженности (S), разнообразия (D) и правдоподобия (U), описанные выше. Указание признаков, изменение которых возможно, осуществляется на уровне модели генерации $g(\mathcal{D}, \theta)$.

⁵ <https://sdv.dev>

⁶ <https://www.synthpop.org.uk/>

⁷ <https://github.com/DataResponsibly/DataSynthesizer>

⁸ <https://github.com/vanderschaarlab/synthcity>

⁹ <https://github.com/NextBrain-ai/nbsynthetic>

Таблица 2.

Наборы данных

\mathcal{D}	$n \times m$	Признаки			Классификатор		Описание
		Неизменяем	Изменение не реализуемо	Изменяем	Модель $h(x)$	AUC	
German Credit ¹⁰	1000 × 20	3	14	3	RF	0,79 (0,03)	700 одобренных и 300 заблокированных кредитных заявок
Adult ¹¹	48842 × 14	8	3	3	СВ	0,93 (0,002)	Уровень дохода в зависимости от данных переписи населения
Loan Default ¹²	255347 × 16	8	3	5	СВ	0,76 (0,002)	29653 плохих и 225694 одобренных заявок на кредит

4. Анализ результатов эксперимента

Рассмотрим процесс применения предложенного метода на примере набора данных German Credit. Этот датасет содержит записи о 1000 заявках на кредит, 700 из которых были одобрены. В числе атрибутов сумма и срок кредита, а также показатели социального и финансового положения заемщика (кредитный рейтинг, срок работы на одном месте, доля платежей по кредиту в общем доходе заемщика и т.д.). Большинство атрибутов являются либо категориальными, либо порядковыми.

Задачей СЕ в данном случае является генерация контрфактуалов для заемщиков, которым было отказано в кредите. Анализ данных показывает, что

изменяемыми атрибутами являются *laufzeit* – срок кредита в месяцах, *hoehe* – сумма кредита и *buerge* – наличие созаемщика или поручителя. Все остальные атрибуты либо не изменяемы (пол, гражданство), либо не могут быть изменены прямым воздействием (кредитный рейтинг).

Процедура вычислений выполнена в соответствии с методом, представленным на *рис. 2*. На первом этапе обучена модель генерации $g(\mathcal{D}, \theta)$, с помощью которой для исследуемого фактуала генерируется 200 синтетических экземпляров. Из этого набора отбираются экземпляры в соответствии с правилом, заданным уравнением (1).

В *таблице 3* представлен пример данных, сгенерированных для отклоненной заявки на сумму 2348 DM на срок 36 месяцев. Как следует из представлен-

Таблица 3.

Пример генерируемых данных (атрибуты объяснены в тексте)

	<i>laufzeit</i>	<i>hoehe</i>	<i>buerge</i>	Метка класса
Фактуал	36	2384	1	0
Контрфактуалы	8	1956	1	1
	14	2234	2	1
	26	4276	3	1

¹⁰ South German Credit. UCI Machine Learning Repository. 2019. <https://doi.org/10.24432/C5X89F>.

¹¹ Becker, B., Kohavi, R. Adult. UCI Machine Learning Repository. 1996. <https://doi.org/10.24432/C5XW20>.

¹² Loan Default Dataset. <https://www.kaggle.com/datasets/nikhil1e9/loan-default/data>

¹³ <http://interpret.ml/DiCE/index.html>

ных данных, кредит для данного заемщика может быть одобрен при снижении срока до 8 месяцев и суммы до 1956 марок. Если заемщик представит второе ответственное лицо, которое будет участвовать в погашении кредита (*buerge* = 2), то сумма может быть увеличена до 2234 DM сроком на 14 месяцев. При наличии поручителя (*buerge* = 3) кредит может составить 4276 DM на срок 26 месяцев. Таким образом, даже три представленных контрфактуала по-

зволяют описать ситуацию для конкретного заемщика и предложить ему действия, которые помогут добиться поставленной цели.

Таблица 4 представляет средние значения и стандартные отклонения метрик качества для рассматриваемых методов, рассчитанные по всем трем наборам данных, а рис. 3 – распределения метрик по датасетам. Лучшие значения метрик в таблице 4 выделено жирным шрифтом.

Таблица 4.

Средние значения и стандартные отклонения метрик качества моделей по трем наборам данных

Модель	<i>V</i>	<i>P</i>	<i>S</i>	<i>D</i>	<i>U</i>
BN	1,000 (0,000)	1,230 (0,805)	3,790 (1,251)	1,310 (0,340)	2,053 (0,855)
CD	1,000 (0,000)	1,400 (1,155)	3,303 (1,036)	1,135 (0,228)	2,128 (0,836)
DiCE	0,869 (0,273)	3,138 (1,519)	1,962 (0,556)	1,159 (0,206)	2,797 (0,734)
GAN	0,966 (0,186)	1,984 (1,045)	4,190 (1,640)	1,285 (0,372)	2,298 (0,742)
GC	0,967 (0,183)	1,333 (0,851)	3,887 (1,521)	1,284 (0,402)	2,089 (0,828)
MD	1,000 (0,000)	3,198 (2,094)	4,177 (1,506)	1,314 (0,299)	2,851 (0,760)

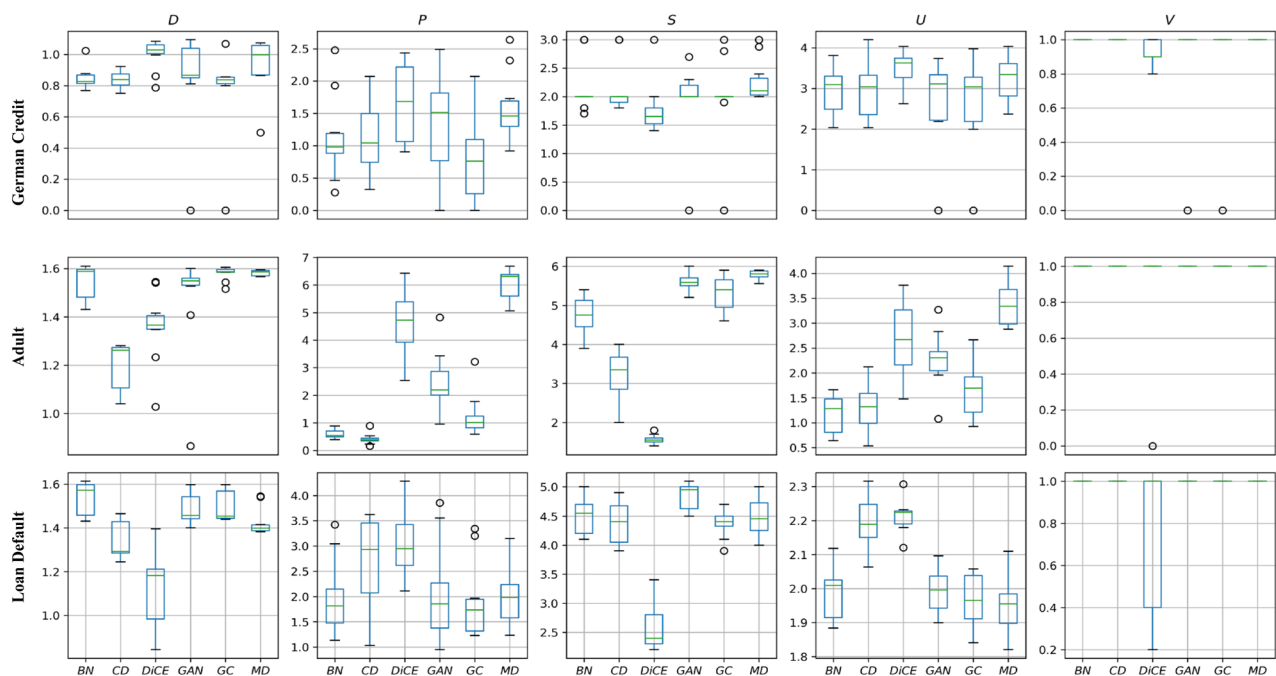


Рис. 3. Метрики качества рассматриваемых моделей по наборам данных.

Отметим, что по большинству метрик (валидность, близость и правдоподобие) лучшие результаты демонстрирует модель на основе байесовской сети (BN), генерирующая выборки на основе условных распределений признаков, т.е. с учетом зависимостей между ними. Если учесть, что по разнообразию эта модель лишь немногим уступает MD, то выбор BN для CE представляется весьма обоснованным. Высокое разнообразие контрфактуалов, генерируемых MD, объясняется тем, что эта модель рассматривает только маргинальные распределения признаков и не учитывает связи между ними. Эта модель должна хорошо работать в случае некоррелированных признаков, но может порождать проблемы, когда такие корреляции присутствуют (см. распределение D для набора данных Loan Default на *рис. 3*). Напротив, BN в случае таких данных показывает лучшие результаты по разнообразию среди всех моделей.

В наших экспериментах самая сложная модель GAN уступила другим моделям, возможно, потому, что было недостаточно данных для обучения, хотя авторы использованной нами реализации [37] подчеркивают, что она ориентирована именно на малые обучающие выборки. *Рисунок 3* показывает, что с возрастанием выборки результаты GAN улучшаются, но не превосходят другие модели.

Методы, разработанные непосредственно для решения задачи CE (DiCE), стали лучшими по метрике разреженности (*табл. 4*), но *рисунок 3* показывает, что это достигнуто за счет высоких результатов на самом большом наборе данных (Loan Default).

На меньших данных этот метод уступает более простым моделям, в частности GC и BN. Кроме того, следует отметить, что DiCE на всех наборах данных не находит требуемое количество контрфактуалов ($V < 1$) и в этом смысле является наихудшим из рассмотренных методов.

Заключение

Таким образом, можно сделать вывод, что предложенный метод поиска контрфактуалов на основе генерации синтетических данных позволяет добиться результатов, как минимум, сравнимых со «стандартными» методами CE, а в ряде случаев их превосходит, особенно на малых наборах данных. Согласно нашим результатам, наиболее очевидным выбором при этом является модель генерации на основе байесовской сети, которая учитывает связи между атрибутами.

Этот результат открывает новые возможные направления исследований. Байесовская сеть является статистической моделью, поскольку строится на ассоциациях, измеряемых с помощью корреляций. Поэтому представляет интерес изучение каузальных моделей, которые отражают причинно-следственные связи в наборе данных.

При этом следует отметить, что, насколько нам известно, направление, связанное с использованием каузальных моделей для CE, только начинает исследоваться [20], а работы, посвященные их применению для генерации синтетических данных, отсутствуют. ■

Литература

1. Samek W., Muller K.-R. Towards explainable artificial intelligence // Explainable AI: Interpreting, Explaining and Visualizing Deep Learning. Lecture Notes in Computer Science. 2019. Vol. 11700. P. 5–22. https://doi.org/10.1007/978-3-030-28954-6_1
2. Giuste F., Shi W., Zhu Y., Naren T., Isgut M., Sha Y., Tong L., Gupte M., Wang M.D. Explainable artificial intelligence methods in combating pandemics: A systematic review // IEEE Reviews in Biomedical Engineering. 2023. Vol. 16. P. 5–21. <https://doi.org/10.1109/RBME.2022.3185953>
3. Barocas S., Selbst A. D., Raghavan M. The hidden assumptions behind counterfactual explanations and principal reasons // Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency (FAT* '20). 2020. P. 80–89. <https://doi.org/10.1145/3351095.3372830>
4. Murdoch W.J., Singh C., Kumbier K., Abbasi-Asl R., Yu B. Definitions, methods, and applications in interpretable machine learning // National Academy of Sciences. 2019. Vol. 116(44). P. 22071–22080. <https://doi.org/10.1073/pnas.1900654116>
5. Guidotti R. Counterfactual explanations and how to find them: Literature review and benchmarking // Data Mining and Knowledge Discovery. 2022. <https://doi.org/10.1007/s10618-022-00831-6>
6. Verma S., Boonsanong V., Hoang M., Hines K. E., Dickerson J. P., Shah C. Counterfactual explanations and algorithmic recourses for machine learning: A review // arXiv:2010.10596. 2020. <https://doi.org/10.4550/arxiv.2010.10596>
7. Stepin I., Alonso J.M., Catala A., Pereira-Fariña M. A survey of contrastive and counterfactual explanation generation methods for explainable artificial intelligence // IEEE Access. 2021. Vol. 9. P. 11974–12001. <https://doi.org/10.1109/ACCESS.2021.3051315>
8. Chou Y.L., Moreira C., Bruza P., Ouyang C., Jorge J. Counterfactuals and causability in explainable artificial intelligence: Theory, algorithms, and applications // Information Fusion. 2022. Vol. 81. P. 59–83. <https://doi.org/10.1016/j.inffus.2021.11.003>

9. Mishra P. Practical explainable AI using Python: Artificial Intelligence model explanations using python-based libraries, extensions, and frameworks. Apress, 2022.
10. Pearl J. Causality: models, reasoning, and inference. 2nd ed. New York: Cambridge University Press, 2009.
11. Cho S.H., Shin K.S. Feature-weighted counterfactual-based explanation for bankruptcy prediction // *Expert Systems with Applications*. 2023. Vol. 216. Article 119390. <https://doi.org/10.1016/j.eswa.2022.119390>
12. Wang D., Chen Z., Florescu I., Wen B. A sparsity algorithm for finding optimal counterfactual explanations: Application to corporate credit rating // *Research in International Business and Finance*. 2023. Vol. 64. Article 101869. <https://doi.org/10.1016/j.ribaf.2022.101869>
13. Mertes S., Huber T., Weitz K., Heimerl A., André E. Ganterfactual – counterfactual explanations for medical non-experts using generative adversarial learning // *Frontiers in Artificial Intelligence*. 2022. Vol. 5. Article 825565. <https://doi.org/10.3389/frai.2022.825565>
14. Fonseca J., Bacao F. Tabular and latent space synthetic data generation: A literature review // *Journal of Big Data*. 2023. Vol. 10(1). Article 115. <https://doi.org/10.1186/s40537-023-00792-7>
15. Patki N., Wedge R., Veeramachaneni K. The synthetic data vault // *Proceedings of the 2016 IEEE International Conference on Data Science and Advanced Analytics (DSAA)*. 2016. P. 399–410. <https://doi.org/10.1109/DSAA.2016.49>
16. Dankar F., Ibrahim M., Ismail L. A multi-dimensional evaluation of synthetic data generators // *IEEE Access*. 2022. Vol. 10. P. 11147–11158. <https://doi.org/10.1109/ACCESS.2022.3144765>
17. Endres M., Mannarapotta Venugopal A., Tran T.S. Synthetic data generation: A comparative study // *Proceedings of the 26th International Database Engineered Applications Symposium*. 2022. P. 94–102. <https://doi.org/10.1145/3548785.3548793>
18. Wachter S., Mittelstadt B., Russell C. Counterfactual explanations without opening the black box: Automated decisions and the GDPR // *Harvard Journal of Law & Technology (Harvard JOLT)*. 2017. Vol. 31. Article 841.
19. Mothilal R.K., Sharma A., Tan C. Explaining machine learning classifiers through diverse counterfactual explanations // *Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency (FAT* '20)*. 2020. P. 607–617. <https://doi.org/10.1145/3351095.3372850>
20. Karimi A.H., Barthe G., Schölkopf B., Valera I. A survey of algorithmic recourse: Contrastive explanations and consequential recommendations // *ACM Computing Surveys*. 2023. Vol. 55(5). Article 95. <https://doi.org/10.1145/3527848>
21. Breunig M.M., Kriegel H.-P., Ng R.T., Sander J. LOF: identifying density-based local outliers // *Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data (ICDM)*. 2000. P. 93–104. <https://doi.org/10.1145/335191.335388>
22. Poyiadzi K., Sokol K., Santos-Rodriguez R., De Bie T., Flach P. FACE: feasible and actionable counterfactual explanations // *Proceedings of the 2020 AAAI/ACM Conference on AI, Ethics, and Society (AIES 2020)*. 2020. P. 344–350. <https://doi.org/10.1145/3351095.3372850>
23. van Looveren A., Klaise J. Interpretable counterfactual explanations guided by prototypes // *Proceedings of the Joint European Conference on Machine Learning and Knowledge Discovery in Databases (ECML PKDD 2021)*. 2021. P. 650–665. https://doi.org/10.1007/978-3-030-86520-7_40
24. Aamodt A., Plaza E. Case-based reasoning: Foundational issues, methodological variations, and system approaches // *Artificial Intelligence Communications*. 1994. Vol. 7(1). P. 39–59.
25. Keane M.T., Smyth B. Good counterfactuals and where to find them: A case-based technique for generating counterfactuals for explainable AI (XAI) // *Proceedings of the 28th International Conference on Case-Based Reasoning Research and Development (ICCBR)*. 2020. P. 163–178. https://doi.org/10.1007/978-3-030-58342-2_11
26. Joshi S., Koyejo O., Vijitbenjaronk W., Kim B., Ghosh J. Towards realistic individual recourse and actionable explanations in black-box decision making systems // *arXiv:1907.09615*. 2019. <https://doi.org/10.48550/arXiv.1907.09615>
27. Guyomard V., Fessant F., Bouadi T., Guyet T. Post-hoc counterfactual generation with supervised autoencoder // *Proceedings of the Joint European Conference on Machine Learning and Knowledge Discovery in Databases (ECML PKDD 2021)*. 2021. P. 105–114. https://doi.org/10.1007/978-3-030-93736-2_10
28. Downs M., Chu J.L., Yacoby Y., Doshi-Velez F., Pan W. CRUDS: Counterfactual recourse using disentangled subspaces // *Proceedings of the 2020 ICML Workshop on Human Interpretability in Machine Learning (WHI 2020)*. 2020. P. 1–23.
29. Pawelczyk M., Broelemann K., Kasneci G. Learning model-agnostic counterfactual explanations for tabular data // *Proceedings of the Web Conference 2020 (WWW'20)*. 2020. P. 3126–3132. <https://doi.org/10.1145/3366423.3380087>
30. Klys J., Snell J., Zemel R. Learning latent subspaces in variational autoencoders // *Advances in Neural Information Processing Systems 31 (NeurIPS 2018)*. 2018.
31. Hoyer P., Janzing D., Mooij J.M., Peters J., Schölkopf B. Nonlinear causal discovery with additive noise models // *Advances in Neural Information Processing Systems 21 (NIPS 2008)*. 2008.
32. Peters J., Janzing D., Schölkopf B. Elements of causal inference: foundations and learning algorithms. MIT press, 2017.
33. Alaa A., van Breugel B., Saveliev E.S., van der Schaar M. How faithful is your synthetic data? Sample-level metrics for evaluating and auditing generative models // *Proceedings of the 39th International Conference on Machine Learning*. 2022. P. 290–306.
34. Ping P., Stoyanovich J., Howe D. DataSynthesizer: Privacy-preserving synthetic datasets // *Proceedings of the 29th International Conference on Scientific and Statistical Database Management (SSDBM'17)*. 2017. <https://doi.org/10.1145/3085504.3091117>

35. Drechsler J., Reiter J.P. An empirical evaluation of easily implemented nonparametric methods for generating synthetic datasets // *Computational Statistics & Data Analysis*. 2011. Vol. 55(12). P. 3232–3243. <https://doi.org/10.1016/j.csda.2011.06.006>
36. Nowok B., Raab G.M., Dibben C. Synthpop: Bespoke creation of synthetic data in R // *Journal of Statistical Software*. 2016. Vol. 74. P. 1–26. <https://doi.org/10.18637/jss.v074.i11>
37. Marin J. Evaluating synthetically generated data from small sample sizes: An experimental study // *arXiv:2211.10760*. 2022. <https://doi.org/10.48550/arXiv.2211.10760>
38. Qian Z., Cebere B.C., van der Schaar M. Synthcity: facilitating innovative use cases of synthetic data in different data modalities // *arXiv:2301.07573*. 2023. <https://doi.org/10.48550/arxiv.2301.07573>

Об авторах

Зеленков Юрий Александрович

д.т.н.;

профессор, департамент бизнес-информатики, Высшая школа бизнеса, Национальный исследовательский университет «Высшая школа экономики», Россия, 119049, г. Москва, ул. Шаболовка, д. 28/11, стр. 4;

E-mail: yzelenkov@hse.ru

ORCID: 0000-0002-2248-1023

Лашкевич Елизавета Витальевна

аспирант, департамент бизнес-информатики, Высшая школа бизнеса, Национальный исследовательский университет «Высшая школа экономики», Россия, 119049, г. Москва, ул. Шаболовка, д. 28/11, стр. 4;

E-mail: evlashkevich@hse.ru

ORCID: 0000-0002-3241-2291

Counterfactual explanations based on synthetic data generation

Yuri A. Zelenkov

E-mail: yzelenkov@hse.ru

Elizaveta V. Lashkevich

E-mail: evlashkevich@hse.ru

Graduate School of Business, HSE University, Moscow, Russia

Abstract

A counterfactual explanation is the generation for a particular sample of a set of instances that belong to the opposite class but are as close as possible in the feature space to the factual being explained. Existing algorithms that solve this problem are usually based on complicated models that require a large amount of training data and significant computational cost. We suggest here a method that involves two stages. First, a synthetic set of potential counterfactuals is generated based on simple statistical models (Gaussian copula, sequential model based on conditional distributions, Bayesian network, etc.), and second, instances satisfying constraints on probability, proximity, diversity, etc. are selected. Such an

approach enables us to make the process transparent, manageable and to reuse the generative models. Experiments on three public datasets have demonstrated that the proposed method provides results at least comparable to known algorithms of counterfactual explanations, and superior to them in some cases, especially on low-sized datasets. The most effective generation model is a Bayesian network in this case.

Keywords: counterfactual explanations, synthetic data generation, multimodal distribution modelling, Bayesian network, credit scoring

Citation: Zelenkov Yu.A., Lashkevich E.V. (2024) Counterfactual explanations based on synthetic data generation. *Business Informatics*, vol. 18, no. 3, pp. 24–40. DOI: 10.17323/2587-814X.2024.3.24.40

References

1. Samek W., Muller K.-R. (2019) Towards explainable artificial intelligence. *Explainable AI: Interpreting, Explaining and Visualizing Deep Learning. Lecture Notes in Computer Science*, vol. 11700, pp. 5–22. https://doi.org/10.1007/978-3-030-28954-6_1
2. Giuste F., Shi W., Zhu Y., Naren T., Isgut M., Sha Y., Tong L., Gupte M., Wang M.D. (2023) Explainable artificial intelligence methods in combating pandemics: A systematic review. *IEEE Reviews in Biomedical Engineering*, vol. 16, pp. 5–21. <https://doi.org/10.1109/RBME.2022.3185953>
3. Barocas S., Selbst A. D., Raghavan M. (2020) The hidden assumptions behind counterfactual explanations and principal reasons. Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency (FAT* '20), pp. 80–89. <https://doi.org/10.1145/3351095.3372830>
4. Murdoch W.J., Singh C., Kumbier K., Abbasi-Asl R., Yu B. (2019) Definitions, methods, and applications in interpretable machine learning. *National Academy of Sciences*, vol. 116(44), pp. 22071–22080. <https://doi.org/10.1073/pnas.1900654116>
5. Guidotti R. (2022) Counterfactual explanations and how to find them: Literature review and benchmarking. *Data Mining and Knowledge Discovery*. <https://doi.org/10.1007/s10618-022-00831-6>
6. Verma S., Boonsanong V., Hoang M., Hines K. E., Dickerson J. P., Shah C. (2020) Counterfactual explanations and algorithmic recourses for machine learning: A review. *arXiv:2010.10596*. <https://doi.org/10.4550/arxiv.2010.10596>
7. Stepin I., Alonso J.M., Catala A., Pereira-Fariña M. (2021) A survey of contrastive and counterfactual explanation generation methods for explainable artificial intelligence. *IEEE Access*, vol. 9, pp. 11974–12001. <https://doi.org/10.1109/ACCESS.2021.3051315>
8. Chou Y.L., Moreira C., Bruza P., Ouyang C., Jorge J. (2022) Counterfactuals and causability in explainable artificial intelligence: Theory, algorithms, and applications. *Information Fusion*, vol. 81, pp. 59–83. <https://doi.org/10.1016/j.inffus.2021.11.003>
9. Mishra P. (2022) *Practical explainable AI using Python: Artificial Intelligence model explanations using python-based libraries, extensions, and frameworks*. Apress.
10. Pearl J. (2009) *Causality: models, reasoning, and inference. 2nd ed.* New York: Cambridge University Press.
11. Cho S.H., Shin K.S. (2023) Feature-weighted counterfactual-based explanation for bankruptcy prediction. *Expert Systems with Applications*, vol. 216, article 119390. <https://doi.org/10.1016/j.eswa.2022.119390>
12. Wang D., Chen Z., Florescu I., Wen B. (2023) A sparsity algorithm for finding optimal counterfactual explanations: Application to corporate credit rating. *Research in International Business and Finance*, vol. 64, article 101869. <https://doi.org/10.1016/j.ribaf.2022.101869>
13. Mertes S., Huber T., Weitz K., Heimerl A., André E. (2022) Ganterfactual—counterfactual explanations for medical non-experts using generative adversarial learning. *Frontiers in Artificial Intelligence*, vol. 5, article 825565. <https://doi.org/10.3389/frai.2022.825565>
14. Fonseca J., Bacao F. (2023) Tabular and latent space synthetic data generation: A literature review. *Journal of Big Data*, vol. 10(1), article 115. <https://doi.org/10.1186/s40537-023-00792-7>
15. Patki N., Wedge R., Veeramachaneni K. (2016) The synthetic data vault. Proceedings of the 2016 IEEE International Conference on Data Science and Advanced Analytics (DSAA), pp. 399–410. <https://doi.org/10.1109/DSAA.2016.49>
16. Dankar F., Ibrahim M., Ismail L. (2022) A multi-dimensional evaluation of synthetic data generators. *IEEE Access*, vol. 10, pp. 11147–11158. <https://doi.org/10.1109/ACCESS.2022.3144765>
17. Endres M., Mannarapotta Venugopal A., Tran T.S. (2022) Synthetic data generation: A comparative study. Proceedings of the 26th International Database Engineered Applications Symposium, pp. 94–102. <https://doi.org/10.1145/3548785.3548793>
18. Wachter S., Mittelstadt B., Russell C. (2017) Counterfactual explanations without opening the black box: Automated decisions and the GDPR. *Harvard Journal of Law & Technology (Harvard JOLT)*, vol. 31, article 841.
19. Mothilal R.K., Sharma A., Tan C. (2020) Explaining machine learning classifiers through diverse counterfactual explanations. Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency (FAT* '20), pp. 607–617. <https://doi.org/10.1145/3351095.3372850>
20. Karimi A.H., Barthe G., Schölkopf B., Valera I. (2023) A survey of algorithmic recourse: Contrastive explanations and consequential recommendations. *ACM Computing Surveys*, vol. 55(5), article 95. <https://doi.org/10.1145/3527848>

21. Breunig M.M., Kriegel H.-P., Ng R.T., Sander J. (2000) LOF: identifying density-based local outliers. *Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data (ICDM)*, pp. 93–104. <https://doi.org/10.1145/335191.335388>
22. Poyiadzi K., Sokol K., Santos-Rodriguez R., De Bie T., Flach P. (2020) FACE: feasible and actionable counterfactual explanations. *Proceedings of the 2020 AAAI/ACM Conference on AI, Ethics, and Society (AI/ES 2020)*, pp. 344–350. <https://doi.org/10.1145/3351095.3372850>
23. van Looveren A., Klaise J. (2021) Interpretable counterfactual explanations guided by prototypes. *Proceedings of the Joint European Conference on Machine Learning and Knowledge Discovery in Databases (ECML PKDD 2021)*, pp. 650–665. https://doi.org/10.1007/978-3-030-86520-7_40
24. Aamodt A., Plaza E. (1994) Case-based reasoning: Foundational issues, methodological variations, and system approaches. *Artificial Intelligence Communications*, vol. 7(1), pp. 39–59.
25. Keane M.T., Smyth B. (2020) Good counterfactuals and where to find them: A case-based technique for generating counterfactuals for explainable AI (XAI). *Proceedings of the 28th International Conference on Case-Based Reasoning Research and Development (ICCBR)*, pp. 163–178. https://doi.org/10.1007/978-3-030-58342-2_11
26. Joshi S., Koyejo O., Vijitbenjaronk W., Kim B., Ghosh J. (2019) Towards realistic individual recourse and actionable explanations in black-box decision making systems. *arXiv:1907.09615*. <https://doi.org/10.48550/arXiv.1907.09615>
27. Guyomard V., Fessant F., Bouadi T., Guyet T. (2021) Post-hoc counterfactual generation with supervised autoencoder. *Proceedings of the Joint European Conference on Machine Learning and Knowledge Discovery in Databases (ECML PKDD 2021)*, pp. 105–114. https://doi.org/10.1007/978-3-030-93736-2_10
28. Downs M., Chu J.L., Yacoby Y., Doshi-Velez F., Pan W. (2020) CRUDS: Counterfactual recourse using disentangled subspaces. *Proceedings of the 2020 ICML Workshop on Human Interpretability in Machine Learning (WHI 2020)*, pp. 1–23.
29. Pawelczyk M., Broelemann K., Kasneci G. (2020) Learning model-agnostic counterfactual explanations for tabular data. *Proceedings of the Web Conference 2020 (WWW'20)*, pp. 3126–3132. <https://doi.org/10.1145/3366423.3380087>
30. Klys J., Snell J., Zemel R. (2018) Learning latent subspaces in variational autoencoders. *Advances in Neural Information Processing Systems 31 (NeurIPS 2018)*.
31. Hoyer P., Janzing D., Mooij J.M., Peters J., Schölkopf B. (2008) Nonlinear causal discovery with additive noise models. *Advances in Neural Information Processing Systems 21 (NIPS 2008)*.
32. Peters J., Janzing D., Schölkopf B. (2017) *Elements of causal inference: foundations and learning algorithms*. MIT press.
33. Alaa A., van Breugel B., Saveliev E.S., van der Schaar M. (2022) How faithful is your synthetic data? Sample-level metrics for evaluating and auditing generative models. *Proceedings of the 39th International Conference on Machine Learning*, pp. 290–306.
34. Ping P., Stoyanovich J., Howe D. (2017) DataSynthesizer: Privacy-preserving synthetic datasets. *Proceedings of the 29th International Conference on Scientific and Statistical Database Management (SSDBM'17)*. <https://doi.org/10.1145/3085504.3091117>
35. Drechsler J., Reiter J.P. (2011) An empirical evaluation of easily implemented nonparametric methods for generating synthetic datasets. *Computational Statistics & Data Analysis*, vol. 55(12), pp. 3232–3243. <https://doi.org/10.1016/j.csda.2011.06.006>
36. Nowok B., Raab G.M., Dibben C. (2016) Synthpop: Bespoke creation of synthetic data in R. *Journal of Statistical Software*, vol. 74, pp. 1–26. <https://doi.org/10.18637/jss.v074.i11>
37. Marin J. (2022) Evaluating synthetically generated data from small sample sizes: An experimental study. *arXiv:2211.10760*. <https://doi.org/10.48550/arXiv.2211.10760>
38. Qian Z., Cebere B.C., van der Schaar M. (2023) Synthcity: facilitating innovative use cases of synthetic data in different data modalities. *arXiv:2301.07573*. <https://doi.org/10.48550/arxiv.2301.07573>

About the authors

Yuri A. Zelenkov

Dr. Sci. (Tech.);

Professor, Department of Business Informatics, Graduate School of Business, HSE University, 28/11, Shabolovka Str., Moscow 119049, Russia;

E-mail: yzelenkov@hse.ru

ORCID: 0000-0002-2248-1023

Elizaveta V. Lashkevich

Doctoral Student, Department of Business Informatics, Graduate School of Business, HSE University, 28/11, Shabolovka Str., Moscow 119049, Russia;

E-mail: evlashkevich@hse.ru

ORCID: 0000-0002-3241-2291

DOI: 10.17323/2587-814X.2024.3.41.55

Скрытая марковская модель: метод построения модели бизнес-процесса*

А.Ю. Варнухов

E-mail: varnuhov_ayu@usue.ru

Уральский государственный экономический университет, Екатеринбург, Россия

Аннотация

Все больше компаний под воздействием стремительного развития технологий (концепция Индустрия 4.0/5.0) охватывают процессы цифровой трансформации. Внедрение информационных систем обеспечивает возможность накопления большого объема данных о деятельности компании. Исследование такой информации расширяет возможности применения data-driven подхода к управлению бизнес-процессами (business process management, BPM). Обработка и изучение данных из журналов событий с помощью методов интеллектуального анализа процессов позволяет строить цифровые модели бизнес-процессов, которые оказываются полезным источником сведений при проведении работ по анализу, моделированию и реинжинирингу в рамках процессного подхода. В настоящей работе разрабатывается метод построения модели бизнес-процесса на основе скрытой марковской модели с учетом ограничений, налагаемых предметной областью. Применение скрытой марковской модели позволяет использовать аппарат теории вероятностей и математической статистики для анализа бизнес-процессов, а также решать задачи классификации и кластеризации. В статье описываются возможности data-driven подхода к управлению бизнес-процессами и демонстрируются примеры практического применения метода для решения бизнес-задач: построение графа зависимостей, который может быть использован для выявления расхождений между фактическим и ожидаемым исполнением, а также способ предсказания исхода бизнес-процесса на основе последовательности наблюдаемых событий.

Ключевые слова: бизнес-процессы, скрытые марковские модели, интеллектуальный анализ процессов, бизнес-анализ, предсказание, классификация, data-driven подход, информационные системы, журналы событий

Цитирование: Варнухов А.Ю. Скрытая марковская модель: метод построения модели бизнес-процесса // Бизнес-информатика. 2024. Т. 18. № 3. С. 41–55. DOI: 10.17323/2587-814X.2024.3.41.55

* Статья опубликована при поддержке Программы НИУ ВШЭ «Университетское партнерство»

Введение

Развитие возможностей современных информационных технологий стимулирует предприятия различных сфер переводить свои бизнес-процессы из «аналоговой» формы в цифровую. Существует и постоянно совершенствуется множество методологий и методик, которые позволяют выполнять моделирование, проводить реинжиниринг, контролировать и отслеживать бизнес-процессы [1]. Довольно часто моделирование выполняется «вручную» с привлечением соответствующих бизнес-аналитиков и «внутренних» экспертов, которые обладают специальными знаниями о моделируемых явлениях. При этом на практике процесс моделирования и реинжиниринга бизнес-процессов оказывается нетривиальной задачей даже для опытных специалистов [2]. Так, например, имеют место искажения, обусловленные субъективными факторами, собственным положением в структуре организации и другими типичными проблемами, характерными для такого подхода к моделированию: идеализацией, выбором неверного уровня абстракции или неспособностью адекватно воспроизводить наблюдаемое взаимодействие [3]. В результате полученная модель может отражать только часть происходящей «реальности», оказывается недостаточно функциональной и, в конечном счете, будет обладать весьма ограниченной ценностью.

Внедрение автоматизированных информационных систем различного класса и функциональности (ERP, CRM, ECM и прочие) приводит к сопут-

ствующему накоплению в цифровых хранилищах большого объема полезных сведений о деятельности предприятия [4]. Обработка и последующий анализ данных, накопленных в информационных системах предприятия, обеспечивает возможность применения data-driven подхода. В настоящее время ведутся исследования в области интеллектуального анализа процессов [5, 6], создания цифровых двойников [7], предиктивной и прескриптивной аналитики [8, 9], роботизированной автоматизации процессов [10], а также проводятся работы по практическому внедрению результатов этих исследований в различных отраслях [11, 12].

1. Применение data-driven подхода к управлению бизнес-процессами

Процессный подход позволяет представить организацию в виде совокупности взаимосвязанных бизнес-процессов, каждый из которых рассматривается как ценный актив, обеспечивающий поставку продуктов и услуг компании конечным потребителям. Методология **управления бизнес-процессами** (business process management, BPM) определяет жизненный цикл управления, который, как правило, состоит из следующих основных этапов: анализа, моделирования, исполнения, мониторинга, оптимизации и реинжиниринга. Для формулирования возможностей и контекста применения data-driven подхода в рамках BPM можно построить обобщенный жизненный цикл управления, показанный на *рисунке 1*.



Рис. 1. Обобщенный жизненный цикл BPM.

Подразумевается, что все данные в журнале относятся к одному анализируемому бизнес-процессу. Каждая строка в таблице содержит следующие обязательные атрибуты: «ID экземпляра», «Событие» и «Временная метка». Множество строк с одинаковым значением атрибута «ID экземпляра» представляют события, которые связаны с одним экземпляром бизнес-процесса. Атрибут «Событие» содержит название события, которое можно связать с некоторым действием (деятельностью). Атрибут «Временная метка» используется для хронологического упорядочивания событий в рамках одного экземпляра. Журнал бизнес-процесса может содержать и другие дополнительные атрибуты («Сотрудник», «Стоимость», «Клиент», «Офис» и так далее), которые могут быть полезны для мониторинга бизнес-процесса с применением машинного обучения [13]. Для краткости записи будем использовать мультимножество, которое будет состоять из хронологически упорядоченных и сгруппированных последовательностей событий согласно журналу бизнес-процесса. Например, для данных, приведенных в *таблице 1*, можно записать мультимножество:

$$L = \{ \langle a, b, c, d \rangle^n, \langle a, b, e \rangle^m, \dots \}, \quad (1)$$

где L – мультимножество, в котором каждый элемент содержит упорядоченную последовательность событий: a – событие «Поступление запроса», b – событие «Проверка наличия», c – событие «Отправка счета», d – событие «Отгрузка товара», e – событие «Отказ в поставке»; n и m – количество раз, которые встречалась данная упорядоченная последовательность в журнале.

Таким образом, требуется разработать метод построения модели бизнес-процесса на основе поступающих входных данных в виде мультимножества L .

3. Анализ методов построения модели бизнес-процесса

«Альфа-искатель». Является довольно простым и одним из первых методов, который позволяет воссоздать модель бизнес-процесса из имеющегося набора последовательных событий в виде Workflow-net (частный случай сети Петри) [14]. Для этого алгоритм сканирует журнал в поисках определенного набора паттернов: последовательности, XOR разделения и AND разделения. На основе

этого записывается матрица «отпечатков», позволяющая распознать имеющиеся отношения между событиями. По этой матрице, с учетом правил вывода, строится конечная модель. Среди ограничений «альфа-искателя» можно отметить: сложности при обработке зашумленных данных, невозможность распознать циклы длиной 1 или 2 шага, проблемы с локальными зависимостями.

«Эвристический искатель». В отличие от «альфа-искателя» применяет идею подсчета частот появления событий и воспроизводит модель процесса в виде причинно-следственной сети (Causal net) [15, 16]. В начале рассчитываются метрики, которые оценивают количество связей прямого следования между каждой парой событий и измеряют степень их зависимости. При помощи паттернов (последовательности, XOR, AND и цикла), опирающихся на рассчитанные метрики, строится граф зависимости (Dependency graph). Поиск слияний и разделений в графе зависимостей может выполняться скользящим окном по журналу событий с заданным размером или на основе решения оптимизационной задачи, в которой целевой функцией является степень соответствия модели наблюдаемому журналу. Полученная модель процесса в виде Causal net может быть преобразована к другим требуемым нотациям (BPMN, UML, EPC, WF-net и так далее). Этот метод менее восприимчив к зашумленности в данных и устраняет многие недостатки «альфа-искателя», однако имеет проблемы с обработкой нелокальных зависимостей и обнаружением дублирующих событий, а также требует ручной настройки уровней порога отсеечения.

«Искатель на основе областей». Базируется на применении теории регионов и строится на допущении, что модели состояний могут быть преобразованы в сети Петри [17]. Существует несколько подходов реализации этого метода. Первый подход заключается в определении области как множества таких состояний, что действия в модели состояний и переходов согласуется с данной областью. В этом случае все события можно разделить на «входящие», «исходящие» и «внутренние» по отношению к данной области. После разделения областей по этим правилам каждая область может быть сопоставлена с определенной позицией в сети Петри. Второй подход применяет специально заданную языковую модель вместо системы состояний и переходов [18]. Основная идея подхода заключается в том, что удаление P_i позиции не приводит к

удалению любого поведенческого паттерна, однако добавление новой позиции может привести к устранению некоторых возможных вариантов поведения. К достоинствам можно отнести возможность обрабатывать более комплексные структуры потока управления. Слабой стороной этого метода является неспособность обнаруживать некоторые типы конструкций процесса, проблемы с точностью и обобщающей способностью, а также сложность его практической реализации.

«Индуктивный искатель». Состоит из трех рекурсивно выполняемых шагов: построение ориентированного графа, поиск среза и разделение записей журнала [19]. В качестве исходных данных метод использует предварительно подготовленный журнал событий. На первом шаге метод преобразует данные в ориентированный граф, в котором каждый узел соответствует одному событию, а дуги формируют переходы между событиями. После этого выполняется попытка обнаружить места возможных срезов. Если места таких срезов обнаруживаются, то алгоритм образует оператор среза и сегменты разделения. На основе обнаруженных сегментов производится декомпозиция журнала на более мелкие составляющие. Затем происходит рекурсивная обработка каждого полученного таким образом фрагмента до обнаружения базового случая: фрагмент содержит только одно событие. Если в процессе рекурсивного спуска встречается фрагмент, который не сводится к базовому случаю и при этом не имеет допустимых мест для среза, то применяется процесс «проваливания». Базовая реализация метода имела сложности с обнаружением циклов фиксированной длины, обработкой редких событий и ограничений, связанных с рекурсивной природой построения. Однако дальнейшее развитие метода позволило преодолеть первичные недостатки, обеспечило возможность масштабирования и применения распределенных вычислений [20].

Представленные выше методы позволяют построить модель бизнес-процесса различными способами, однако интерес представляет исследование возможности построения модели, которая основана на оценке вероятностей. В качестве основы можно было бы рассмотреть цепь Маркова, но, учитывая характер и природу исходных данных, более приемлемым будет предположение, что зафиксированные в журнале события являются только внешним проявлением некоторого скрытого от наблюдателя процесса. Для моделирования такого

предположения можно рассмотреть скрытую марковскую модель (далее – СММ) первого порядка. Известно, что такие модели со скрытыми состояниями эффективно применяются для задач обработки текста на естественных языках [21], идентификации жестов [22], распознавания речи [23], биоинформатике [24] и других сферах. Исходя из сведений, которые представлены в проанализированных источниках, можно ожидать, что применение СММ для анализа бизнес-процесса сделает возможным не только построение модели бизнес-процесса, но и позволит решать задачу классификации и выполнять кластеризацию данных.

4. Предлагаемый метод построения модели

СММ обладает множеством скрытых состояний $S = \{s_1, s_2, s_3, \dots, s_N\}$. Каждое скрытое состояние может быть связано с некоторыми другими скрытыми состояниями. Схематичное представление модели показано на рисунке 2.




Рис. 2. Схематичное представление СММ.

В данной работе рассматривается полносвязная структурная организация СММ, при которой каждое скрытое состояние s_k связано со всеми отличными от него скрытыми состояниями, а также с самим собой. Помимо скрытых состояний определен конечный алфавит множества наблюдаемых событий $V = \{v_1, v_2, v_3, \dots, v_M\}$ и каждое скрытое состояние воспроизводит события из данного множества V . В любой отдельный момент времени t модель находится в одном из скрытых состояний.

$$\forall t: q_t \in S, 1 \leq t \leq T. \quad (2)$$

СММ совершает переходы между скрытыми состояниями. Так, в момент времени t , находясь в

скрытом состоянии q_t , модель перейдет в другое состояние с определенной вероятностью и в момент времени $t + 1$ будет находиться в скрытом состоянии $q_{t+1} \in S$. В данной работе рассматриваются только дискретные моменты времени, при этом текущее состояние и цепочка выполненных переходов между ними являются невидимыми для наблюдателя. Находясь в некотором скрытом состоянии q_t , модель воспроизводит событие $o_t \in V$, которое видно внешнему наблюдателю. Череда переходов между состояниями и воспроизведенными ими событиями в результате формирует последовательность наблюдений $O = \{o_1, o_2, o_3, \dots, o_T\}$. Схематичное представление работы СММ показано на *рисунке 3*.




Рис. 3. Схематичное представление работы СММ.

Поскольку в данной работе рассматривается СММ первого порядка, то согласно марковскому свойству будем полагать, что вероятность перехода из одного состояния в другое определяется только предыдущим состоянием модели:

$$\begin{aligned} P(q_t = s_i | q_1 = s_n, q_2 = s_m, \dots, q_{t-1} = s_j) = \\ = P(q_t = s_i | q_{t-1} = s_j). \end{aligned} \quad (3)$$

Второе допущение будет заключаться в том, что вероятность произвести наблюдаемое событие o_t зависит только от состояния, в котором находится модель в дискретный момент времени t и не зависит от других состояний и наблюдаемых событий:

$$\begin{aligned} P(o_t = v_k | q_1 = s_n, \dots, q_t = s_i, o_1 = v_m, \dots, o_{t-1} = v_j) = \\ = P(o_t = v_k | q_t = s_i). \end{aligned} \quad (4)$$

Определим начальное распределение по скрытым состояниям модели, которое задает вероятность того, что модель на первом шаге будет находиться в некотором состоянии:

$$\pi = \{\pi_i\}_{i=1}^N, \quad \pi_i = P(q_1 = s_i), \quad \sum_{i=1}^N \pi_i = 1. \quad (5)$$

Определим распределение вероятностей перехода между скрытыми состояниями как матрицу $A = (a_{ij})$, где

$$a_{ij} = P(q_t = s_j | q_{t-1} = s_i), \quad 1 \leq i, j \leq N, \quad \sum_{j=1}^N a_{ij} = 1. \quad (6)$$

Распределение вероятностей появления событий при нахождении модели в некотором скрытом состоянии определим как матрицу $B = (b_{ik})$, где

$$\begin{aligned} b_{ik} = P(o_t = v_k | q_t = s_i), \quad 1 \leq i \leq N, \quad 1 \leq k \leq M, \\ \sum_{k=1}^M b_{ik} = 1. \end{aligned} \quad (7)$$

Исходя из вышеописанного скрытую марковскую модель θ определим как

$$\theta = (S, V, A, B, \pi). \quad (8)$$

Предположим, что представлен исходный журнал и выполнена предварительная подготовка данных. Пусть задано мультимножество

$$\begin{aligned} L = \{ \langle a, e \rangle^5, \langle a, b, c, e \rangle^5, \langle a, c, b, e \rangle^5, \\ \langle a, d, e \rangle^{10}, \langle a, d, d, e \rangle^5, \langle a, d, d, d, e \rangle^1, \\ \langle a, b, c, d, e \rangle^3, \langle a, b, d, c, e \rangle^3, \langle a, c, b, d, e \rangle^3, \\ \langle a, c, d, b, e \rangle^3, \langle a, d, c, b, e \rangle^3, \langle a, d, b, c, e \rangle^3, \\ \langle e, b, c, m \rangle^4, \langle e, c, b, m \rangle^3 \}. \end{aligned} \quad (9)$$

Мультимножество L содержит повторяющиеся несколько раз элементы, которые представляют отдельные экземпляры бизнес-процесса, выполненного в разное время. Можно заметить, что некоторые элементы мультимножества (например, $\langle a, b, c, e \rangle$ и $\langle a, c, b, e \rangle$) содержат почти одинаковые последовательности событий за тем исключением, что порядок, в котором следуют события «b» и «c», переставлен местами. Видимая перестановка в мультимножестве может встречаться из-за того, что зарегистрированные события попадают в исходный журнал упорядоченными по временной метке, однако в реальности представляют собой параллельно исполняемые подпроцессы бизнес-процесса. Пример такой ситуации показан на *рисунке 4*.




Рис. 4. Параллельно исполняемые подпроцессы.

В связи с тем, что такие события всегда встречаются попарно и следуют друг за другом (хоть и в разном порядке), а также учитывая характер моделируемой предметной области, будем полагать, что подобные переставленные местами события образуют логически единую операцию бизнес-процесса. Таким образом, сходные попарные перестановки событий, которые по своему поведению образуют логическую операцию «AND» бизнес-процесса, будем относить к одному и тому же скрытому состоянию модели. Обычно бизнес-процесс имеет одно фиксированное стартовое событие, в котором начинается его исполнение. Финальных событий у бизнес-процесса может быть несколько в силу необходимости представления различных результатов его завершения. Каждое такое финальное событие является логически завершающим и поэтому не должно быть разделимо на несколько параллельно исполняемых подпроцессов. Если параллельно исполняемые подпроцессы не находятся в стартовом или финальном событиях, то следует предположить, что существует некое событие, после которого происходит разветвление исполнения, равно как и событие, соединяющее параллельное исполнение. Таким образом, логическая операция «AND» бизнес-процесса должна находиться между некоторым начальным и конечным событием в наблюдаемой последовательности событий. Для определения групп событий, которые формируют множество логических операций «AND» бизнес-процесса выберем уникальные элементы по правилу (10) из мультимножества L :

$$FSET = \left\{ \begin{array}{l} (\sigma(i) = S_1, \sigma(i+1) = S_2, \sigma(i+2) = \\ = S_3, \sigma(i+3) = S_4): \\ \exists (\delta(l) = S_1, \delta(l+1) = S_3, \delta(l+2) = \\ = S_2, \delta(l+3) = S_4) \end{array} \right\}$$

$$\forall \sigma, \delta \in L : |\sigma| \geq 4, |\delta| \geq 4,$$

$$1 \leq i \leq |\sigma|, 1 \leq l \leq |\delta|. \quad (10)$$

Членами множества $FSET$ являются упорядоченные последовательности событий, каждая из которых удовлетворяет следующим условиям:

- ◆ получена из входящих в исходное мультимножества L элементов;
- ◆ последовательность содержит минимум четыре идущих по порядку события;
- ◆ существует другая четверка с таким же началь-

ным событием S_1 и конечным событием S_4 в которой события S_2 и S_3 переставлены местами.

Для рассматриваемого мультимножества из (9) будет сформировано множество $FSET$, состоящее из следующих элементов:

$$FSET(L) = \{(a, b, c, e), (a, c, b, e), (a, b, c, d), \\ (b, c, d, e), (a, b, d, c), (b, d, c, e), (a, c, b, d), (c, b, d, e), \\ (a, c, d, b), (c, d, b, e), (a, d, c, b), (d, c, b, e), \\ (a, d, b, c), (d, b, c, e), (e, b, c, m), (e, c, b, m)\}. \quad (11)$$

Каждый элемент множества $FSET$ представляет собой минимально допустимую часть возможной перестановки. Так, например, для образования логической операции «AND», составленной из двух параллельно выполняемых подпроцессов « b » и « c », которая начинается после события « a » и заканчивается событием « e », необходимо, чтобы множество $FSET$ содержало обе части такой перестановки (a, b, c, e) и (a, c, b, e) . Элементы множества (a, b, d, c) и (a, d, b, c) также образуют минимальную логическую операцию «AND». Однако из (9) можно заметить, что элементы « b » и « d » являются частью большей логической операции «AND», которая включает также и событие « c ». Таким образом, необходимо определить процедуру наращивания более длинных логических операций «AND», состоящих из базовых минимальных частей. Для этой цели зададим множества стартовых, перестановочных и конечных событий:

$$FS = \{\sigma(1) : \sigma \in FSET\}. \quad (12)$$

$$PS = \{\sigma(2) : \sigma \in FSET\}. \quad (13)$$

$$ES = \{\sigma(4) : \sigma \in FSET\} \setminus PS. \quad (14)$$

Для наращивания максимально возможной перестановки поочередно возьмем каждое стартовое событие из множества FS и перебирая множество элементов $FSET$ будем добавлять каждые встреченные перестановочные символы во второй и третьей позиции, пока не дойдем до элемента, который содержит конечное событие из ES в последний позиции. Процедура наращивания показана в листинге 1.

В результате процедуры наращивания будет сформировано мультимножество, которое содержит элементы с выделенными начальным и конечным состояниями, а также множеством перестановочных событий между ними. Для примера из (9) сформируется мультимножество

Input: *FS*: Start events
Input: *ES*: End events
Input: *FSET*: Set of data
Output: *FPERM*: Multiset of augmented permutations

1. $FPERM \leftarrow \emptyset$
2. **for** each start event *SS* **in** *FS* **do**
3. $ACCPERM \leftarrow \emptyset$
4. **for** each element σ **in** *FSET* **do**
5. **if** $\sigma(1) = SS$ **or** $|ACCPERM| > 0$ **then**
6. $ACCPERM \leftarrow ACCPERM \cup \sigma(2) \cup \sigma(3)$
7. **if** $|ACCPERM| > 0$ **and** $\sigma(4) \in ES$ **then**
8. $FPERM \leftarrow FPERM \uplus (SS, ACCPERM, \sigma(4))$
9. $ACCPERM \leftarrow \emptyset$

Листинг 1. Процедура наращивания.

$$FPRM(L) = \{ \langle e, \{b, c\}, m \rangle^2, \langle a, \{b, c\}, e \rangle^2, \langle a, \{b, c, d\}, e \rangle^6, \langle b, \{c, d\}, e \rangle^2, \langle c, \{b, d\}, e \rangle^2, \langle d, \{b, c\}, e \rangle^2 \}. \quad (15)$$

Кратность элементов в мультимножестве *FPERM* отражает частоту, с которой данная перестановка была встречена в исходных данных. Допустим, что в исходных данных присутствовала группа событий «*b*», «*c*», «*d*», которая образует логическую операцию «AND» бизнес-процесса. Тогда кратность такой группы с одинаковыми начальными и конечными событиями должна быть равной шести. Предположим, что в этой группе отсутствует один элемент, например (*a*, *c*, *b*, *d*, *e*). В этом случае группа событий должна распадаться на две логические операции «AND» формирующие параллельные подпроцессы: первая группа событий начинается с события «*b*» и включает «*c*» и «*d*», вторая начинается с события «*d*» и включает «*c*» и «*b*». Возможна также ситуация с потерей некоторых данных в процессе выгрузки или их предварительной обработки. Для учета этих ситуаций введем метрику контроля:

$$\text{MinLimit}(\sigma) = |\sigma(2)| - \varepsilon, \sigma \in FPERM, \varepsilon \geq 0. \quad (16)$$

Метрика (16) позволяет рассчитать необходимое количество одинаковых элементов с учетом возможности корректировки на недостающие или пропавшие данные. Сформируем множество уникальных групп событий, образующих логические операции «AND», путем включения в него только элементов кратность которых не менее заданного предела:

$$LPERM = \left\{ \sigma : \sum_{s \in FPERM} [s = \sigma] \geq \text{MinLimit}(\sigma) \right\}, \quad \sigma \in FPERM. \quad (17)$$

В получившемся множестве кроме наращенных элементов содержатся также части большей перестановки. Для исключения подобных лишних элементов выполним проверку:

$$ANDGROUP = \left\{ \sigma : \nexists \delta \mid \delta(2) = \{\sigma(1)\} \cup \sigma(2) \wedge \delta(3) = \sigma(3) \right\}, \sigma, \delta \in LPERM. \quad (18)$$

Таким образом множество *ANDGROUP* будет содержать только необходимые группы событий, которые представляют параллельные исполняемые подпроцессы бизнес-процесса. Для примера из (9) получим следующие логические операции «AND»:

$$ANDGROUP(L) = \{ \langle e, \{b, c\}, m \rangle, \langle a, \{b, c\}, e \rangle, \langle a, \{b, c, d\}, e \rangle \}. \quad (19)$$

Из (8) следует, что для определения СММ требуется задать множества скрытых состояний и событий, а также определить матрицы переходов, эмиссии и вектор вероятностей, характеризующий выбор начального состояния. Для произвольного бизнес-процесса никакие из этих параметров модели заранее не известны, поскольку имеется только наблюдаемая последовательность событий, которая получена из исходных данных. Таким образом, требуется сформулировать метод, позволяющий найти параметры, если известна только последовательность наблюдаемых событий бизнес-процесса. Данная проблема была сформулиро-

вана в работе Л. Рабинера и является одной из трех базовых проблем при работе СММ и одновременно самой сложной из них [25]. Сложность обуславливается отсутствием известных аналитических способов решения задачи, позволяющих определить параметры модели для любой конечной последовательности O . Существуют несколько подходов ее решения путем сведения проблемы к задаче оптимизации для поиска таких параметров модели θ , позволяющих максимизировать вероятность $P(O|\theta)$. Одним из таких подходов является алгоритм Баума–Велча, который является разновидностью EM (expectation-maximization) алгоритма поиска оценок наибольшего правдоподобия. В общем виде этот алгоритм состоит из двух шагов (E-шага и M-шага), позволяющих итеративно выполнять пересчет параметров θ и последовательно приближаться к локально максимальной оценке при определенном O .

Однако классическая реализация алгоритма Баума–Велча не учитывает особенности предметной области и специфику функционирования бизнес-процессов. Поэтому в данной работе предлагается доработанная для применения к рассматриваемой задаче модификация алгоритма.

Определим множество наблюдаемых событий V модели как равное множеству уникальных событий бизнес-процесса из мультимножества L :

$$V = \bigcup_{\sigma \in L} \{ \sigma(i), 1 \leq i \leq |\sigma| \}. \quad (20)$$

Поскольку каждый элемент в (18) представляет собой операцию логического «AND» и любая уникальная группа перестановочных событий должна быть отнесена к одному скрытому состоянию модели, зададим множество скрытых состояний:

$$SPU = \{ \sigma(2) : \sigma \in ANDGROUP \}. \quad (21)$$

$$SOU = V \setminus \bigcup \delta, \forall \delta \in SPU. \quad (22)$$

$$S = \{ i : 1 \leq i \leq |SOU| + |SPU| \}. \quad (23)$$

Итеративная природа реализации классического алгоритма Баума–Велча допускает задание матриц A и B произвольными величинами перед началом его работы, поскольку в процессе обновления параметров будет достигнута сходимость к оптимальным значениям. Однако известно, что различные структуры организации СММ (эргодическая, левосторонняя, параллельная левосторон-

няя и так далее) могут оказывать влияние на характер ее поведения и получаемые результаты. Пусть каждое событие из множества V пронумеровано по порядку натуральным числом v_k от 1 до $|V|$. Определим матрицы A и B следующим образом:

$$a_{ij} = \frac{1}{|S|}, 1 \leq i, j \leq |S|. \quad (24)$$

$$b_{ik} = \begin{cases} 1 : \forall i \in \{ 1 \leq i \leq |SOU| \} \wedge \forall k = \\ = v_k \in SOU \mid \forall i \neq j \ b_j \neq b_i \\ \frac{1}{|\sigma|} : \forall i \in \{ |SOU| < i \leq |S| \} \wedge \forall k = \\ = v_k \in \sigma \mid \forall i \neq j \ b_j \neq b_i, \forall \sigma \in SPU \\ 0 : \text{иначе.} \end{cases} \quad (25)$$

Для задания начального распределения будем полагать, что стартовое событие бизнес-процесса единственно и для него определено $v_k = 1$:

$$\pi_i = \begin{cases} 1 : i = v_k \\ 0 : i \neq v_k \end{cases}. \quad (26)$$

Если в мультимножестве L существуют элементы, которые содержат различные стартовые события, то всегда возможно добавить в начало всех элементов мультимножества новое суррогатное событие, чтобы перейти к единственности стартового события.

Для снижения количества операций и упрощения расчетов применяется метод прямого и обратного прохода, который основан на принципах динамического программирования. При этом формируется матрица промежуточных значений, позволяющая на каждом шаге оценивать вероятность путем суммирования вычислений, произведенных на предыдущих шагах, посредством вспомогательных функций:

$$\alpha_t(i) = P(o_1, o_2, o_3, \dots, o_t, q_t = s_i | \theta). \quad (27)$$

$$\beta_t(i) = P(o_{t+1}, o_{t+2}, o_{t+3}, \dots, o_T | q_t = s_i, \theta). \quad (28)$$

В классической реализации (27) и (28) не учитываются особенности модели, связанные со спецификой рассматриваемой задачи. Необходимо принять в расчет ограничения, которые налагаются на переходы между скрытыми состояниями, соотношенными с операциями логического «AND». Для этого определим вспомогательные функции следующим образом:

$$\varphi(i) = \{v_k | b_{ik} > 0, 1 \leq k \leq |V|\}. \quad (29)$$

$$HFW_t(i) = \begin{cases} |\varphi(i)| \times \prod_{j=0}^{|\varphi(i)|-1} [o_{t+j} \in \varphi(i)] : T > t + |\varphi(i)| \\ 0 : T \leq t + |\varphi(i)|. \end{cases} \quad (30)$$

Функция (30) задает оценку, которая будет использоваться для выбора наиболее подходящего скрытого состояния при вычислении α и β . Для такого состояния значение функции (30) будем максимальным:

$$HFW_t^{\max} = \operatorname{argmax}_{1 \leq i \leq N} HFW_t(i). \quad (31)$$

Тогда будем иметь:

$$\alpha_1(i) = \pi_i b_i(o_1). \quad (32)$$

$$\alpha_{t+1}(j) = \begin{cases} b_j(o_{t+1}) \sum_{i=1}^N \alpha_t(i) a_{ij} : (j = HFW_{t+1}^{\max} \wedge \\ \wedge o_{t+1} \in PS \wedge o_t \notin PS) \vee (o_{t+1} \notin PS) \\ b_j(o_{t+1}) \alpha_t(j) a_{jj} : o_{t+1} \in PS. \end{cases} \quad (33)$$

Такое определение (33) позволяет ограничить пространство переходов между скрытыми состояниями модели, которые содержат группу событий, образующих операцию логического «AND». Похожим образом определим:

$$HBW_t(i) = \begin{cases} |\varphi(i)| \times \prod_{j=0}^{|\varphi(i)|-1} [o_{t-j} \in \varphi(i)] : t - |\varphi(i)| \geq 0 \\ 0 : t - |\varphi(i)| < 0 \end{cases} \quad (34)$$

$$HBW_t^{\max} = \operatorname{argmax}_{1 \leq i \leq N} HBW_t(i). \quad (35)$$

$$\beta_T(i) = 1. \quad (36)$$

$$\beta_t(i) = \begin{cases} \sum_{j=1}^N \beta_{t+1}(j) a_{ij} b_j(o_{t+1}) : (i = HBW_t^{\max} \wedge \\ \wedge o_t \in PS \wedge o_{t+1} \notin PS) \vee (o_t \notin PS) \\ \beta_{t+1}(i) b_i(o_{t+1}) a_{ii} : o_t \in PS \\ 0 : o_t \in PS \wedge o_{t+1} \notin PS \wedge i \neq HBW_t^{\max}. \end{cases} \quad (37)$$

Поскольку для бизнес-процесса финальное событие означает его полное завершение и невозможность перехода в любые другие состояния, а также для соответствия (7), будем полагать, что такие скрытые со-

стояния должны переходить сами в себя образуя петлю. Определим ξ и γ следующим образом:

$$\xi_t(i, j) = \begin{cases} \frac{\alpha_t(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)}{\sum_{i=1}^N \sum_{j=1}^N \alpha_t(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)} : 1 \leq t \leq T-1 \\ 1 : t = T \wedge i = j \wedge \alpha_{T-1}(i) > 0. \end{cases} \quad (38)$$

$$\gamma_t(i) = \frac{\alpha_t(i) \beta_t(i)}{\sum_{j=1}^N \alpha_t(j) \beta_t(j)}. \quad (39)$$

Учитывая, что обновление коэффициентов должно выполняться по всем элементам мультимножества L будем использовать:

$$a_{ij}^* = \frac{\sum_{\sigma \in L} \sum_{t=1}^T \xi_t(i, j)}{\sum_{\sigma \in L} \sum_{t=1}^T \gamma_t(i)}. \quad (40)$$

$$b_{ik}^* = \frac{\sum_{\sigma \in L} \sum_{t=1}^T [o_t = v_k] \gamma_t(i)}{\sum_{\sigma \in L} \sum_{t=1}^T \gamma_t(i)}. \quad (41)$$

Итеративное выполнение E и M шагов алгоритма выполняется до его сходимости, либо до достижения заданного предельного количества повторений.

5. Варианты применения метода для решения бизнес-задач

5.1. Предсказание исхода бизнес-процесса и поиск отклонений

Допустим, имеется множество экземпляров бизнес-процесса, которые разделены по некоторой характеристике на несколько непересекающихся групп $G_1, G_2, G_3, \dots, G_N$. Например, в рамках бизнес-процесса «продажа товара», можно провести разбиение его экземпляров по исходу сделки. В этом случае могут быть сформированы следующие группы: «отказались от покупки», «отложили покупку» и «успешно совершили покупку». Каждая такая группа соответствует своему мультимножеству $L_1, L_2, L_3, \dots, L_N$. Построим по вышеописанному предлагаемому методу N скрытых марковских моделей, используя эти мультимножества в качестве обучающей выборки. В результате каждому L_n будет соответствовать θ_n . Воспользуемся алгоритмом прямого-обратного прохода и определим (42):

$$\alpha_t(j) = \begin{cases} \pi_j b_j(o_1) : t=1 \\ b_j(o_t) \sum_{i=1}^N \alpha_{t-1}(i) a_{ij} : 1 < t \leq T. \end{cases} \quad (42)$$

Для нового экземпляра бизнес-процесса O_x при помощи построенных СММ можно предсказать его принадлежность к одной из ранее сформированных групп. Группа G_n , для которой наиболее высока оценка $P(O_x | \theta_n)$, будет целевой:

$$F(O_x) = \operatorname{argmax}_{\theta} P(O_x | \theta) = \operatorname{argmax}_{\theta} \sum_{i=1}^N \alpha_T(i). \quad (43)$$

В результате экземпляр O_x с наибольшей вероятностью будет иметь исход, который соответствует группе G_n . Такое предсказание может быть получено и для незавершенных экземпляров бизнес-процесса, то есть для тех случаев, когда имеется только часть последовательности O_x . Обладая возможностью получения такой оценки, можно решать различные практические задачи. Например, для бизнес-процесса продажи товара можно провести анализ сделок, которые находятся на некотором промежуточном этапе, для прогнозирования возможного исхода. Если будет определена высокая вероятность нежелательного исхода, то для таких сделок можно выработать корректирующие меры воздействия, направленные на исправление траектории движения. Кроме этого, имея на входе «эталонную» модель бизнес-процесса и данные из соответствующего журнала событий можно, получив оценку принадлежности каждой последовательности, выявлять девиантные экземпляры с целью дальнейшего анализа причин и принятия управленческих решений.

5.2. Представление бизнес-процесса в виде графа зависимостей

Предположим, что для некоторого процесса, собран и обработан журнал событий, на основе которого сформировано мультимножество L :

$$L = \{ \langle a, z \rangle^5, \langle a, e, b, c, z \rangle^5, \langle a, e, c, b, z \rangle^3, \langle a, b, c, d, z \rangle^5, \langle a, b, d, c, z \rangle^5, \langle a, c, b, d, z \rangle^5, \langle a, c, d, b, z \rangle^5, \langle a, d, c, b, z \rangle^5, \langle a, d, b, c, z \rangle^5, \langle a, l, z \rangle^{10}, \langle a, l, l, z \rangle^5, \langle a, l, l, l, z \rangle^1 \}. \quad (44)$$

Если построить СММ для мультимножества (44) по вышеописанному предлагаемому методу, то получим следующие матрицы A и B :

$$A = \begin{pmatrix} 0 & 0 & 0,51 & 0,14 & 0,27 & 0,08 \\ 0 & 0,5 & 0 & 0 & 0 & 0,5 \\ 0 & 0 & 0,67 & 0 & 0 & 0,33 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0,3 & 0,7 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix},$$

$$B = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0,5 & 0,5 & 0 & 0 & 0 & 0 \\ 0 & 0,33 & 0,33 & 0,33 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix}.$$

Полагаем, что скрытые состояния, для которых $a_{ii} > 0$ и которые содержат несколько событий в матрице B , соотносятся с операцией логического «AND», а имеющие только одно событие образуют цикл. Построенный граф зависимостей для мультимножества (44) показан на рисунке 5.




Рис. 5. Граф зависимостей бизнес-процесса.

При необходимости данный граф зависимостей может быть преобразован в другие представления: BPMN, сети Петри, Casual Net и так далее. Полученный граф зависимостей может быть использован для исследования фактического исполнения бизнес-процесса, проведения сравнительного анализа вариантов реализации между различными структурными подразделениями, поиска отклонений и выявления их причин. Если дополнить модель данными из журнала событий о времени выполнения базовых операций, то можно рассчитать различные показатели производительности

(время обработки и простоя, продолжительность и эффективное время одного цикла и так далее). Кроме того, в журналах событий может содержаться информация об участниках, понесенных затратах и используемых ресурсах, которая позволит расширить модель для анализа других аспектов бизнес-процесса.

Заключение

Data-driven подход не является альтернативой традиционному моделированию с использованием аналитиков и специалистов в предметной области. Однако применение данного подхода позволяет улучшить качество проводимого анализа, моделирования, проектирования и реинжиниринга бизнес-процессов за счет исследования реальных данных, которые накоплены в информационных системах предприятия. Обнаружение неочевидных связей, а также возможность беспристрастного анализа, вне зависимости от субъективной точки зрения участников процесса, способствует минимизации вероятности появления искажений и ошибочных выводов. Построенная модель может применяться для контроля над исполнением конкретных экземпляров бизнес-процесса, выявления отклонений или нетипичного

поведения, а также обеспечит поддержку внедрения ключевых показателей эффективности (KPI), как на уровне отдельных исполнителей, так и для целых подразделений.

В отличие от других описанных в работе алгоритмов, предлагаемый метод основывается на скрытой марковской модели, которая позволяет использовать аппарат теории вероятностей и математической статистики. В частности, продемонстрирован способ получения оценки будущего исхода бизнес-процесса, который делает возможным реализацию упреждающего управленческого воздействия с целью корректировки ожидаемого результата. Помимо этого, при помощи СММ, можно выполнять кластеризацию экземпляров бизнес-процесса и решать задачу классификации.

К выявленным недостаткам относятся: отсутствие гарантированного появления всех событий, образующих логическую операцию «AND» (при использовании модели в качестве генератора), а также узкий горизонт учета зависимостей (из-за допущения первого порядка).

В качестве направления развития метода целесообразно рассмотреть многоуровневую иерархическую организацию модели, внедрение ансамблевых методов машинного обучения и применение СММ более высокого порядка. ■

Литература

1. Lizano-Mora H., Palos-Sanchez P.R., Aguayo-Camacho M. The evolution of business process management: A bibliometric analysis // IEEE Access. 2021. Vol. 9. P. 51088–51105. <https://doi.org/10.1109/ACCESS.2021.3066340>
2. Fetais A., Abdella G.M., Al-Khalifa K.N., Hamouda A.M. Business process re-engineering: A literature review-based analysis of implementation measures // Information. 2022. Vol. 13. No. 4. Article 185. <https://doi.org/10.3390/info13040185>
3. Rosemann M. Potential pitfalls of process modeling: part A // Business Process Management Journal. 2006. Vol. 12. No. 2. P. 249–254. <https://doi.org/10.1108/14637150610657567>
4. Nambiar A., Mundra D. An overview of data warehouse and data lake in modern enterprise data management // Big Data and Cognitive Computing. 2022. Vol. 6. No. 4. Article 132. <https://doi.org/10.3390/bdcc6040132>
5. Pegoraro M., van der Aalst W.M.P. Mining uncertain event data in process mining // 2019 International Conference on Process Mining (ICPM). 2019. P. 89–96. <https://doi.org/10.1109/ICPM.2019.00023>
6. Andrews R., van Dun C.G.J., Wynn M.T., Kratsch W., Röglinger M.K.E., ter Hofstede A.H.M. Quality-informed semi-automated event log generation for process mining // Decision Support Systems. 2020. Vol. 132. Article 113265.
7. Park G., van der Aalst W.M.P. Realizing a digital twin of an organization using action-oriented process mining // 3rd International Conference on Process Mining (ICPM). 2021. P. 104–111. <https://doi.org/10.1109/ICPM53251.2021.9576846>
8. Kratsch W., Manderscheid J., Röglinger M. et al. Machine learning in business process monitoring: a comparison of deep learning and classical approaches used for outcome prediction // Business & Information Systems Engineering. 2021. Vol. 63. P. 261–276. <https://doi.org/10.1007/s12599-020-00645-0>
9. Teinimaa I., Dumas M., Rosa M.L., Maggi F.M. Outcome-oriented predictive process monitoring: Review and benchmark // ACM Transactions on Knowledge Discovery from Data (TKDD). 2019. Vol. 13. No. 2. P. 1–57. <https://doi.org/10.1145/3301300>

10. Leno V., Polyvyanyy A., Dumas M., La Rosa M., Maggi F.M. Robotic process mining: vision and challenges // *Business & Information Systems Engineering*. 2021. Vol. 63. P. 301–314. <https://doi.org/10.1007/s12599-020-00641-4>
11. Munoz-Gama J., Martin N., Fernandez-Llatas C. et al. Process mining for healthcare: Characteristics and challenges // *Journal of Biomedical Informatics*. 2022. Vol. 127. Article 103994. <https://doi.org/10.1016/j.jbi.2022.103994>
12. Grisold T., Mendling J., Otto M., vom Brocke J. Adoption, use and management of process mining in practice // *Business Process Management Journal*. 2021. Vol. 27. No. 2. P. 369–387. <https://doi.org/10.1108/BPMJ-03-2020-0112>
13. Mehdiyev N., Fettke P. Explainable artificial intelligence for process mining: A general overview and application of a novel local explanation approach for predictive process monitoring // *Interpretable artificial intelligence: A perspective of granular computing*. Springer, 2021. P. 1–28. https://doi.org/10.1007/978-3-030-64949-4_1
14. van der Aalst W.M.P., Weijters T., Maruster L. Workflow mining: Discovering process models from event logs // *IEEE transactions on knowledge and data engineering*. 2004. Vol. 16. No. 9. P. 1128–1142. <https://doi.org/10.1109/TKDE.2004.47>
15. Mannhardt F., de Leoni M., Reijers H.A. Heuristic mining revamped: an interactive, data-aware, and conformance-aware miner // *15th International Conference on Business Process Management (BPM 2017)*. 2017. P. 1–5.
16. van der Aalst W.M.P., Adriansyah A., van Dongen B. Causal nets: A modeling language tailored towards process discovery // *International conference on concurrency theory*. 2011. P. 28–42. https://doi.org/10.1007/978-3-642-23217-6_3
17. van Dongen B.F., Busi N., Pinna G.M., van der Aalst W.M.P. An iterative algorithm for applying the theory of regions in process mining // *Proceedings of the Workshop on Formal Approaches to Business Processes and Web Services (FABPWS'07)*. 2007. P. 36–55.
18. Bergenthum R., Desel J., Lorenz R., Mauser S. Process mining based on regions of languages // *Business Process Management: 5th International Conference (BPM 2007)*, Brisbane, Australia, September 24–28, 2007. P. 375–383. https://doi.org/10.1007/978-3-540-75183-0_27
19. Leemans S.J.J., Fahland D., van der Aalst W.M.P. Discovering block-structured process models from event logs: A constructive approach // *Application and Theory of Petri Nets and Concurrency: 34th International Conference (PETRI NETS 2013)*, Milan, Italy, June 24–28, 2013. P. 311–329. https://doi.org/10.1007/978-3-642-38697-8_17
20. Leemans S.J.J., Fahland D., van der Aalst W.M.P. Scalable process discovery with guarantees // *Enterprise, Business-Process and Information Systems Modeling (BPMDS EMMSAD 2015)*. Lecture Notes in Business Information Processing. Vol. 214. Springer, Cham, 2015. P. 85–101. https://doi.org/10.1007/978-3-319-19237-6_6
21. Pande S.D., Kanna R.K., Qureshi I. Natural language processing based on name entity with n-gram classifier machine learning process through ge-based hidden Markov model // *Machine Learning Applications in Engineering Education and Management*. 2022. Vol. 2. No. 1. P. 30–39.
22. Sagayam K.M., Hemanth D.J. A probabilistic model for state sequence analysis in hidden Markov model for hand gesture recognition // *Computational Intelligence*. 2019. Vol. 35. No. 1. P. 59–81. <https://doi.org/10.1111/coin.12188>
23. Srivastava R.K., Pandey D. Speech recognition using HMM and Soft Computing // *Materials Today: Proceedings*. 2022. Vol. 51. P. 1878–1883. <https://doi.org/10.1016/j.matpr.2021.10.097>
24. Du J., Wang C., Wang L. et al. Automatic block-wise genotype-phenotype association detection based on hidden Markov model // *BMC bioinformatics*. 2023. Vol. 24. Article 138. <https://doi.org/10.1186/s12859-023-05265-5>
25. Rabiner L.R. A tutorial on hidden Markov models and selected applications in speech recognition // *Proceedings of the IEEE*. 1989. Vol. 77. No. 2. P. 257–286. <https://doi.org/10.1109/5.18626>

Об авторе

Варнухов Артем Юрьевич

ассистент, кафедра бизнес-информатики, Уральский государственный экономический университет, Россия, 620144, г. Екатеринбург, ул. 8 Марта, д. 62;

E-mail: varnuhov_ayu@usue.ru

Hidden Markov model: Method for building a business process model

Artem Yu. Varnukhov

E-mail: varnuhov_ayu@usue.ru

Ural State University of Economics, Ekaterinburg, Russia

Abstract

More and more companies are influenced by the rapid development of technology (Industry 4.0/5.0 concept), are embracing digital transformation processes. The introduction of information systems makes it possible to accumulate a large amount of data about the company's activities. Study of such information expands the opportunities for applying a data-driven approach to business process management (BPM). Processing and studying data from event logs using process mining methods make it possible to build digital models of business processes which turn out to be a useful source of information when carrying out analysis, modeling and reengineering within the framework of the process approach. In this paper, we develop a method for building a business process model based on a hidden Markov model, taking into account the restrictions imposed by the subject area. The use of a hidden Markov model allows us to use the apparatus of probability theory and mathematical statistics to analyze business processes, as well as to solve classification and clustering problems. This article describes the capabilities of a data-driven approach to business process management and demonstrates examples of the practical application of the method to solve business challenges: drawing a dependency graph that can be used to identify discrepancies between actual and expected execution, as well as a method for predicting the outcome of a business process based on the sequence of observed events.

Keywords: business processes, hidden Markov models, process mining, business analysis, prediction, classification, data-driven approach, information systems, event logs

Citation: Varnukhov A.Yu. (2024) Hidden Markov model: Method for building a business process model. *Business Informatics*, vol. 18, no. 3, pp. 41–55. DOI: 10.17323/2587-814X.2024.3.41.55

References

1. Lizano-Mora H., Palos-Sánchez P.R., Aguayo-Camacho M. (2021) The evolution of business process management: A bibliometric analysis. *IEEE Access*, vol. 9, pp. 51088–51105. <https://doi.org/10.1109/ACCESS.2021.3066340>
2. Fetais A., Abdella G.M., Al-Khalifa K.N., Hamouda A.M. (2022) Business process re-engineering: A literature review-based analysis of implementation measures. *Information*, vol.13, no. 4, 185. <https://doi.org/10.3390/info13040185>
3. Rosemann M. (2006) Potential pitfalls of process modeling: part A. *Business Process Management Journal*, vol. 12, no. 2, pp. 249–254. <https://doi.org/10.1108/14637150610657567>
4. Nambiar A., Mundra D. (2022) An overview of data warehouse and data lake in modern enterprise data management. *Big Data and Cognitive Computing*, vol. 6, no. 4, 132. <https://doi.org/10.3390/bdcc6040132>
5. Pegoraro M., van der Aalst W.M.P. (2019). Mining uncertain event data in process mining. *2019 International Conference on Process Mining (ICPM)*, pp. 89–96. <https://doi.org/10.1109/ICPM.2019.00023>
6. Andrews R., van Dun C.G.J., Wynn M.T., Kratsch W., Röglinger M.K.E., ter Hofstede A.H.M. (2020) Quality-informed semi-automated event log generation for process mining. *Decision Support Systems*, vol. 132, 113265. <https://doi.org/10.1016/j.dss.2020.113265>

7. Park G., van der Aalst W.M.P. (2021) Realizing a digital twin of an organization using action-oriented process mining. *3rd International Conference on Process Mining (ICPM)*, pp. 104–111. <https://doi.org/10.1109/ICPM53251.2021.9576846>
8. Kratsch W., Manderscheid J., Röglinger M. et al. (2021) Machine learning in business process monitoring: A comparison of deep learning and classical approaches used for outcome prediction. *Business & Information Systems Engineering*, vol. 63, pp. 261–276. <https://doi.org/10.1007/s12599-020-00645-0>
9. Teinemaa I., Dumas M., Rosa M.L., Maggi F.M. (2019) Outcome-oriented predictive process monitoring: Review and benchmark. *ACM Transactions on Knowledge Discovery from Data (TKDD)*, vol. 13, no. 2, pp. 1–57. <https://doi.org/10.1145/3301300>
10. Leno V., Polyvyanyy A., Dumas M., La Rosa M., Maggi F.M. (2021) Robotic process mining: vision and challenges. *Business & Information Systems Engineering*, vol. 63, pp. 301–314. <https://doi.org/10.1007/s12599-020-00641-4>
11. Munoz-Gama J., Martin N., Fernandez-Llatas C. et al. (2022) Process mining for healthcare: Characteristics and challenges. *Journal of Biomedical Informatics*, vol. 127, 103994. <https://doi.org/10.1016/j.jbi.2022.103994>
12. Grisold T., Mendling J., Otto M., vom Brocke J. (2021) Adoption, use and management of process mining in practice. *Business Process Management Journal*, vol. 27, no. 2, pp. 369–387. <https://doi.org/10.1108/BPMJ-03-2020-0112>
13. Mehdiyev N., Fettke P. (2021) Explainable artificial intelligence for process mining: A general overview and application of a novel local explanation approach for predictive process monitoring. *Interpretable Artificial Intelligence: A Perspective of Granular Computing*, Springer, pp. 1–28. https://doi.org/10.1007/978-3-030-64949-4_1
14. van der Aalst W.M.P., Weijters T., Maruster L. (2004) Workflow mining: Discovering process models from event logs. *IEEE Transactions on Knowledge and Data Engineering*, vol. 16, no. 9, pp. 1128–1142. <https://doi.org/10.1109/TKDE.2004.47>
15. Mannhardt F., de Leoni M., Reijers H.A. (2017) Heuristic mining revamped: an interactive, data-aware, and conformance-aware miner. *15th International Conference on Business Process Management (BPM 2017)*, pp. 1–5.
16. van der Aalst W.M.P., Adriansyah A., van Dongen B. (2011) Causal Nets: A modeling language tailored towards Process Discovery. *International Conference on Concurrency Theory*, pp. 28–42. https://doi.org/10.1007/978-3-642-23217-6_3
17. van Dongen B.F., Busi N., Pinna G.M., van der Aalst W.M.P. (2007) An iterative algorithm for applying the theory of regions in process mining. Proceedings of the *Workshop on Formal Approaches to Business Processes and Web Services (FABPWS'07)*, pp. 36–55.
18. Bergenthum R., Desel J., Lorenz R., Mauser S. (2007) Process mining based on regions of languages. *Business Process Management: 5th International Conference (BPM 2007), Brisbane, Australia, September 24–28, 2007*, pp. 375–383. https://doi.org/10.1007/978-3-540-75183-0_27
19. Leemans S.J.J., Fahland D., van der Aalst W.M.P. (2013) Discovering block-structured process models from event logs: A constructive approach. *Application and Theory of Petri Nets and Concurrency: 34th International Conference (PETRI NETS 2013), Milan, Italy, June 24–28, 2013*, pp. 311–329. https://doi.org/10.1007/978-3-642-38697-8_17
20. Leemans S.J.J., Fahland D., van der Aalst W.M.P. (2015) Scalable process discovery with guarantees. *Enterprise, Business-Process and Information Systems Modeling (BPMDS EMMSAD 2015). Lecture Notes in Business Information Processing*, vol. 214. Springer, Cham, pp. 85–101. https://doi.org/10.1007/978-3-319-19237-6_6
21. Pande S.D., Kanna R.K., Qureshi I. (2022) Natural language processing based on name entity with n-gram classifier machine learning process through ge-based hidden Markov model. *Machine Learning Applications in Engineering Education and Management*, vol. 2, no. 1, pp. 30–39.
22. Sagayam K.M., Hemanth D.J. (2019) A probabilistic model for state sequence analysis in hidden Markov model for hand gesture recognition. *Computational Intelligence*, vol. 35, no. 1, pp. 59–81. <https://doi.org/10.1111/coin.12188>
23. Srivastava R.K., Pandey D. (2022) Speech recognition using HMM and Soft Computing. *Materials Today: Proceedings*, vol. 51, pp. 1878–1883. <https://doi.org/10.1016/j.matpr.2021.10.097>
24. Du J., Wang C., Wang L. et al. (2023) Automatic block-wise genotype-phenotype association detection based on hidden Markov model. *BMC Bioinformatics*, vol. 24, article 138. <https://doi.org/10.1186/s12859-023-05265-5>
25. Rabiner L.R. (1990) A tutorial on hidden Markov models and selected applications in speech recognition. *Proceedings of the IEEE*, vol. 77, no. 2, pp. 257–286. <https://doi.org/10.1109/5.18626>

About the author

Artem Yu. Varnukhov

Assistant, Department of Business Informatics, Ural State University of Economics, 62, 8 Marta Str., Yekaterinburg 620144, Russia;
E-mail: varnuhov_ayu@usue.ru

DOI: 10.17323/2587-814X.2024.3.56.69

Оптимизация долгосрочного инвестирования на основе диверсификации Марковица

А.В. Куликов 

E-mail: avkulikov15@gmail.com

Д.С. Полозов 

E-mail: polozov.ds@phystech.edu

Н.В. Волков 

E-mail: nikita.v.volkov@phystech.edu

Московский физико-технический институт, Долгопрудный, Россия

Аннотация

В работе рассмотрен алгоритм для долгосрочного инвестирования, позволяющий находить оптимальные решения в пространстве меньшей размерности. Снижение размерности достигается путем применения метода главных компонент или ядерного метода главных компонент. Подбор весов для портфеля осуществляется с помощью метода Марковица. В качестве гиперпараметров для модели рассмотрены размер окна, параметр сглаживания, период ребалансировки и доля объясненной дисперсии в методах уменьшения размерности. Представленный алгоритм содержит регуляризацию весов с учетом комиссии за ребалансировку портфеля. Подбор гиперпараметров осуществляется на основе коэффициента Мартина, что позволяет учитывать максимальную просадку для рассматриваемых алгоритмов. Показано, что предложенный алгоритм, оптимизированный на данных с 1990 по 2016 год, способен обеспечить более высокую доходность и значение коэффициента Шарпа, чем бенчмарк S&P 500 в период с 2017 по 2022 год. Это свидетельствует о том, что с помощью корректировки весов в портфеле можно улучшить производительность алгоритма.

Ключевые слова: PCA, Kernel PCA, размер окна, алгоритм Марковица, сеточный поиск, метод байесовской оптимизации

Цитирование: Куликов А.В., Полозов Д.С., Волков Н.В. Оптимизация долгосрочного инвестирования на основе диверсификации Марковица // Бизнес-информатика. 2024. Т. 18. № 3. С. 56–69.

DOI: 10.17323/2587-814X.2024.3.56.69

Введение

В настоящее время одним из наиболее заметных глобальных трендов является динамичное развитие финансовых рынков. В первые два десятилетия XXI века рыночная капитализация увеличилась более чем в три раза [1]. При этом в США только за период с 2017 по 2021 год количество клиентских инвестиционных счетов в трех крупнейших брокерских фирмах Charles Schwab, Fidelity Investments и Robinhood увеличилось почти вдвое [2]. Стремление частных инвесторов активно искать перспективные инвестиционные возможности стимулировало интерес исследователей к поиску оптимального инвестиционного портфеля с целью максимизации прибыли при учете финансового риска.

Значительный прогресс в области оптимизации портфеля был достигнут с появлением портфельной теории Марковица [3]. Классическая задача оптимизации Марковица заключается в поиске такого распределения долей активов в портфеле, которое минимизирует риск при фиксированном уровне ожидаемой доходности. В более общем виде поиск оптимального распределения активов происходит при заданном коэффициенте баланса между минимизацией риска и максимизацией доходности. Данный коэффициент соответствует степени неприятия риска инвестором.

Алгоритм поиска оптимального распределения долей активов в портфеле для задачи Марковица основан на оценке средней доходности акций и их матрицы ковариаций на исторических данных. Однако данный алгоритм имеет ряд ограничений, в частности, он предполагает, что исторические значения доходности и риски акций сохраняют свое распределение в будущем, что не всегда справедливо [4]. Помимо этого, диверсификация Марковица уязвима к выбросам из-за неустойчивости средних доходностей акций [5]. В матрице ковариаций доходностей, используемой для оценки риска, также могут возникать выбросы.

Одним из способов решения указанных проблем, рассматриваемых в литературе, являются методы уменьшения размерности, такие как анализ главных компонент (PCA) и ядерный анализ главных компонент (KernelPCA). Данные методы помогают усовершенствовать алгоритм Марковица путем устранения выбросов в матрице ковариаций и выделения компонент, на которые стоит ориентироваться при сборе портфеля. PCA помогает выделить наиболее важные направления в пространстве данных (глав-

ные компоненты), которые объясняют наибольшую долю дисперсии. При понижении размерности выбросы имеют меньшее влияние на главные компоненты, так как PCA учитывает общую изменчивость данных. Эти подходы помогают снизить влияние шума в данных и улучшить качество оптимизации портфеля, как, например, в работах [6, 7]. Примером использования Kernel PCA к задаче Марковица является работа [8].

В работе рассмотрена обобщенная задача Марковица, учитывающая комиссию, которую платит инвестор за перебалансировку портфеля, и предложен алгоритм для решения этой оптимизационной задачи. Данный алгоритм предварительно обрабатывает данные о доходности активов, очищая их от шума, затем формирует портфель, используя экспоненциально сглаженные значения доходности акций, и оптимизирует линейную комбинацию риска и доходности с учетом комиссии.

Для того чтобы обойти ограничения классического решения для задачи Марковица, в работе рассмотрены четыре вариации предложенного алгоритма: без перехода в пространство меньшей размерности, переход с использованием PCA, а также переходы с полиномиальным и гауссовским ядрами KernelPCA.

В указанных выше работах исторический временной горизонт для определения ожидаемой доходности и матрицы ковариации определяются эмпирическим образом. В работах [9–17] рассмотрен подход к предсказанию ожидаемых доходностей и матрицы ковариации с помощью методов машинного обучения и статистических моделей типа GARCH. В данной работе для оптимизации работы алгоритма Марковица предлагается оптимизация гиперпараметров модели для определения оптимального портфеля по историческим данным: частота смены портфеля, размера окна, количество отбираемых компаний для дальнейшей работы и параметр уменьшения размерности в KernelPCA и Kernel PCA.

Ввиду большого числа гиперпараметров в алгоритме традиционные методы подбора параметров, — сеточный поиск (GridSearch) и случайный поиск (RandomSearch), — могут не привести к оптимальным результатам. Поэтому в данной работе для сравнения также используется метод байесовской оптимизации, основанный на гауссовских процессах [18]. Метод байесовской оптимизации — это алгоритм для нахождения оптимальных значений параметров функции, когда доступна толь-

ко ограниченная информация о функции и ее поведении. Суть метода заключается в итеративной последовательности выбора следующих пробных точек, основываясь на вероятностной модели, которая аппроксимирует неизвестную функцию. Метод позволяет находить оптимальное решение с использованием относительно небольшого числа итераций, поскольку алгоритм активно адаптируется к информации, полученной из предыдущих итераций. В контексте рассматриваемой задачи оптимизируемой функцией от весов портфеля является индекс Мартина, введенный в работе [19]. Таким образом, для каждой из четырех вариаций алгоритма подбор параметров проводится двумя способами: с помощью случайного поиска по сетке и байесовской оптимизации.

Обучение предложенных алгоритмов было проведено на данных доходности около 300 акций в период с 1990 по 2016 год. Для оценки эффективности каждой из восьми полученных вариаций алгоритма в работе проведено сравнение различных метрик доходности получившихся портфелей и сравнение портфелей с индексом S&P 500. Данный индекс является классическим бенчмарком для разрабатываемых алгоритмов, поскольку считается лучшим индикатором акций компаний с большой капитализацией [20] и отражает общее состояние экономики США [21, 22]. В работе [23] показано, что веса в классическом алгоритме Марковица также связаны с данным бенчмарком.

Результаты исследования показывают, что наиболее эффективным алгоритмом является вариация, использующая гауссовское ядро в KernelPCA и подобранная с помощью байесовской оптимизации. Портфель, оптимизированный с помощью данного метода, имеет наиболее высокую доходность и коэффициент Шарпа, во многом за счет наименьшей просадки в период вспышки пандемии COVID-19, и в то же время демонстрирует наиболее высокую волатильность по сравнению с остальными вариациями. Кроме того, показано, что за 2017–2022 гг. все предложенные алгоритмы показывают доходность выше индекса S&P 500.

Работа имеет следующую структуру: раздел 1 содержит постановку оптимизационной задачи, в разделе 2 представлено описание алгоритма для решения данной задачи и его вариаций, в разделе 3 приведены метрики для сравнения вариаций алгоритма, раздел 4 описывает используемые данные, анализ результатов исследования представлен в разделе 5.

1. Постановка оптимизационной задачи

Рассмотрим модель финансового рынка с N активами (акциями), доходности которых являются случайными величинами r_i , $i = 1, \dots, N$. Вектор ожидаемых доходностей акций будем обозначать как $\bar{\mu} = (\mathbf{E}r_1, \dots, \mathbf{E}r_N)^\top$, а матрицу ковариаций доходностей акций как

$$\Sigma = (\text{cov}(r_i, r_j))_{(i,j=1)}^N$$

Из данных активов инвестор формирует портфель с долями акций $w_i \geq 0$, $i = 1, \dots, N$, где условие $w_i \geq 0$ соответствует отсутствию возможности коротких продаж. Пусть α – степень неприятия риска инвестором. Тогда преобразованная задача оптимизации Марковица для данного инвестора имеет вид:

$$\begin{aligned} \min_{\bar{w}} \quad & \frac{1}{2} \bar{w}^\top \Sigma \bar{w} - \alpha \bar{\mu}^\top \bar{w} \\ \text{s.t.} \quad & \bar{\mathbf{I}}^\top \bar{w} = 1, \\ & \bar{w} \geq \bar{0}. \end{aligned} \quad (1)$$

Согласно [24], данная задача эквивалентна классической задаче Марковица, в которой отсутствует коэффициент α , с точностью до фиксированных параметров: в классической задаче фиксируется параметр ожидаемой доходности, а в преобразованной – коэффициент баланса между минимизацией риска и максимизацией доходности. В рассматриваемом алгоритме $\alpha = 0,05$ однако в общем случае этот параметр можно изменять, больше опираясь на минимизацию риска при меньших α и на максимизацию доходности при больших.

В данной работе мы рассмотрим более общую задачу оптимизации Марковица, в которой добавлена комиссия λ за перебалансировку портфеля. Таким образом, если P – период смены портфеля, а \bar{w}_p – распределение весов акций в предыдущий период времени, то задача оптимизации (1) принимает вид

$$\begin{aligned} \min_{\bar{w}, P} \quad & \frac{1}{2} \bar{w}^\top \Sigma \bar{w} - \alpha \bar{\mu}^\top \bar{w} - \frac{\lambda}{P} \left\| \bar{w} - \bar{w}_p \right\|^2 \\ \text{s.t.} \quad & \bar{\mathbf{I}}^\top \bar{w} = 1, \\ & \bar{w} \geq \bar{0}. \end{aligned} \quad (2)$$

Вектор распределения весов в момент времени 0 полагаем $\bar{w}_p = \bar{0}$.

2. Описание алгоритма

2.1. Принцип работы алгоритма

На вход оптимизационного алгоритма подаются данные о стоимости акций за определенный период времени. Результатом работы алгоритма являются веса w_i — доли соответствующих активов в портфеле инвестора, которые перебалансируются с определенной частотой, которая передается в алгоритм в качестве гиперпараметра.

Работа алгоритма, представленного ниже, условно состоит из двух частей: подбора гиперпараметров портфеля и выбора оптимальных весов, соответствующих этим гиперпараметрам. Из гиперпараметров производится подбор параметров предобработки данных (частота смены портфеля, фактор размера окна, количество отбираемых компаний для дальнейшей работы) и параметров уменьшения размерности (доля объясненной дисперсии и гиперпараметры ядер в KernelPCA).

Подбор весов осуществляется с помощью метода *fit* на обучающем датасете акций за определенный период времени и включает следующие этапы.

Фильтрация данных. На первом этапе происходит фильтрация данных, после которой для анализа остаются наблюдения только в рамках заданного временного окна.

Размер окна определяется двумя гиперпараметрами: *period_change_portfolio* — период смены портфеля, и *size_of_window_rank* — фактор размера окна. Размер окна выражается как произведение указанных параметров. Такая функциональная зависимость позволяет варьировать размер окна вместе с изменением периода смены портфеля.

Обычно фактор размера окна принимает значения от двух до пяти, что соответствует окну примерно 2–5 периодов смены портфеля. Например, для анализа годовой беты актива в работе [25] используется окно размером 5 лет, а в работе [26] для оценки параметров смены портфеля каждые 250 дней используется скользящее окно размером 1000 дней. Применение оконной фильтрации позволяет учитывать ближайшие, наиболее актуальные данные, при этом исключая устаревшие.

Выбор акций для формирования портфеля. На данном этапе оценивается прибыльность акций для включения в портфель наиболее доходных из них.

Чтобы придать больший вес наиболее актуальным данным, применяется экспоненциальное сглаживание с параметром $\alpha \in (0, 1)$. В алгоритме пара-

метр экспоненциального сглаживания принимает значение $\alpha = 0,99$. Если применение фильтрации на предыдущем этапе эквивалентно умножению всех наблюдений в окне на 1, а за его пределами на 0, то экспоненциальное сглаживание можно представить как умножение доходностей на $\alpha^{\Delta t}$, где Δt представляет собой количество торговых дней, прошедших с рассматриваемой даты до текущего момента. Такой подход обеспечивает более высокий вес недавним данным, сохраняя влияние предыдущих периодов с уменьшающимся весом по мере удаления в прошлое.

Для отбора акций, включаемых в портфель, проводится вычисление взвешенной средней доходности для каждой акции с использованием экспоненциально сглаженных весов. Расчет осуществляется по формуле:

$$\bar{r}_{it} = \frac{\sum_{l=\tau-T+1}^{\tau} r_{it} \alpha^{\tau-l}}{\sum_{l=\tau-T+1}^{\tau} \alpha^{\tau-l}},$$

где T — величина окна;

r_{it} — доходность акции i в момент t .

После вычисления взвешенных средних доходностей акции сортируются в порядке убывания и выбираются $n_top_companies$ лучших акций компаний для включения в портфель. Количество отбираемых акций является гиперпараметром алгоритма.

Уменьшение размерности. Данный этап применяется только для вариаций алгоритма с PCA или KernelPCA. Как уже было отмечено, эти методы позволяют усовершенствовать алгоритм Марковица с помощью устранения выбросов в матрице ковариаций и выделения компонент, на которые впоследствии ориентируется алгоритм при формировании портфеля.

При применении этих методов снижения размерности, первоначально определяется количество компонент, включаемых в модель. Это количество определяется с учетом объясненной дисперсии первыми 1, 2, ..., $n_top_companies$ компонентами на основе гиперпараметра *var_ratio*, отвечающего за долю объясненной дисперсии. Доля объясненной дисперсии для d компонент — это величина δ_d , равная отношению суммы квадратов отклонений наблюдаемых данных от их проекции на главные компоненты, к выборочной дисперсии данных. Большая остаточная дисперсия указывает на то, что главные компоненты не объясняют значительную часть изменчивости данных, что может свидетельствовать о наличии дополнительных

факторов, неучтенных в модели. Количество компонент d определяется как число, при котором $\delta_d \geq \text{var_ratio}$, но $\delta_{d-1} < \text{var_ratio}$.

Затем методу уменьшения размерности передается найденное число компонент и гиперпараметры, после чего он обучается на тренировочных данных, что позволяет снизить размерность данных, сохраняя ключевые характеристики и очищая их от выбросов.

Среди гиперпараметров KernelPCA отметим:

- ♦ *kernel* – тип ядра: в алгоритме рассматривались только гауссовское ядро «*rbf*»:

$$k(\bar{x}, \bar{y}) = \frac{e^{-\|\bar{x}-\bar{y}\|^2}}{\gamma},$$

и полиномиальное ядро «*poly*»:

$$k(\bar{x}, \bar{y}) = \frac{(\bar{x}^\top \bar{y} + c)^q}{\gamma};$$

- ♦ *kerneldegree* – степень полиномиального ядра (q в формуле полиномиального ядра);
- ♦ *kernelgamma* – параметр масштаба (γ в формулах выше);
- ♦ *kernelcoef0* – константа полиномиального ядра (c в формуле полиномиального ядра).

Подбор долей акций в портфеле. После формирования набора акций для включения в портфель, алгоритм определяет их веса.

Алгоритм решает задачу (2), в которой последнее слагаемое является по сути регуляризацией весов. Параметр λ , отвечающий за комиссию при ребалансировке портфеля, в работе принят равным 1%.

Помимо этого, если используются методы уменьшения размерности, то для решения задачи необходимо перейти из латентного пространства в исходное путем обратного преобразования $\bar{w} = \phi^{-1}(\bar{w}_q)$. Положим \bar{r} – вектор средних доходностей в латентном пространстве, C – выборочная матрица ковариаций в латентном пространстве. Тогда преобразованная задача оптимизации примет вид:

$$\begin{aligned} \min_{\bar{w}_q} \quad & \frac{1}{2} \phi^{-1}(\bar{w}_q)^\top C \phi^{-1}(\bar{w}_q) - \alpha \bar{r}^\top \phi^{-1}(\bar{w}_q) + \frac{\lambda}{P} \left\| \phi^{-1}(\bar{w}_q) - \bar{w}_p \right\|^2 \\ \text{s.t.} \quad & \bar{1}^\top \phi^{-1}(\bar{w}_q) = 1, \\ & \phi^{-1}(\bar{w}_q) \geq \bar{0}. \end{aligned} \quad (3)$$

В случае с PCA обратное преобразование осуществляется посредством домножения весов на ма-

трицу компонент: $\phi^{-1}(\bar{w}_q) = Q \bar{w}_q$. Получается задача квадратичного программирования, которая хорошо решается с помощью пакета *cvxpy* [27].

В методе KernelPCA вектор $\phi^{-1}(\bar{w}_q)$ в исходном пространстве находится посредством поиска приближительного прообраза вектора \bar{w}_q решением задачи минимизации с помощью Ridge-регрессии [28]:

$$\phi^{-1}(\bar{w}_q) = \arg \min_{\bar{z} \in \mathbb{R}^d} \left\| \phi(\bar{z}) - \bar{w}_q \right\|^2.$$

Данная задача не является задачей квадратичного программирования, и поэтому решается менее точно с помощью библиотеки *scipy.optimize* [29].

Обратное преобразование весов $\bar{w} = \phi^{-1}(\bar{w}_q)$ происходит по формулам выше вместе с отсечением весов по пороговому значению: если $w_i < \text{threshold}$, то $w_i = 0$. Пороговое значение установлено порядка 10^{-6} , чтобы отсекал слишком маленькие веса, которые в реальности невозможно получить, так как необходимо покупать целые количества лотов акций.

Оценка доходности портфеля. После обучения алгоритма на тренировочном датасете мы можем собрать портфель, используя полученные веса, и оценить его работу на тестовом датасете. Однако портфель с постоянными весами показывает себя хуже, так как распределение доходностей акций меняется со временем. Поэтому периодически необходимо ребалансировать портфель: через *period_change_portfolio* торговых дней алгоритм обучается на тренировочных данных и уже известной ему тестовой части данных. Период смены портфеля в алгоритме выбирался довольно длительным: он мог варьироваться от трех–четырёх месяцев до нескольких лет. Это связано с тем, что метод Марковица неплохо работает на больших промежутках времени с редкой сменой портфеля. Например, в [30] портфели с минимальным риском, т.е. классические портфели Марковица, подвергались ребалансировке 2–3 раза в год.

Для оценки доходности портфеля используется метод *predict*, который принимает на вход обученный алгоритм и тестовый датасет. Результатом работы метода является датафрейм с индексом – временем и колонкой – рассчитанным доходом. После этого возможна визуализация результатов в виде временного ряда доходностей портфеля, а также расчет экономических показателей посредством метода *score*.

2.2. Подбор гиперпараметров

В работе рассмотрено четыре вариации исходного алгоритма: без перехода в пространство меньшей размерности, переход с использованием PCA и KernelPCA с полиномиальным и гауссовским ядром. В каждом из методов проводился подбор параметров двумя способами: с помощью случайного поиска по сетке *RandomizedSearchCV* [31] и байесовской оптимизации. Таким образом, получилось восемь алгоритмов с различными наборами гиперпараметров.

В рассматриваемых способах нахождения оптимальных весов производился подбор следующих гиперпараметров:

- ♦ в методе, который не включает переход в пространство меньшей размерности, проводился только выбор гиперпараметров предобработки матрицы доходностей. Эти параметры включают период смены портфеля (в промежутке от трех месяцев до двух с половиной лет), фактор размера окна (от 2 до 5) и количество топ-компаний, отбираемых на основе их средней доходности (от 50 до 200);
- ♦ в методе PCA, помимо вышеназванных параметров, была подобрана также доля объясненной дисперсии (от 80% до 95%);
- ♦ в KernelPCA с полиномиальным ядром были подобраны гиперпараметры, указанные выше, плюс параметры полиномиального ядра – степень (от 2 до 4), свободный член (от 0,5 до 1) и параметр порядка (от 0,02 до 0,04).
- ♦ в методе KernelPCA с гауссовским ядром, помимо параметров предобработки матрицы доходностей и доли объяснимой дисперсии, был подобран параметр порядка (от 0,001 до 0,1). Стоит также отметить, что согласно статье [8], портфель, сформированный с помощью преобразования KernelPCA с гауссовским ядром, является более рискованным, поэтому диверсифицировать риск в данном случае было решено меньше: количество *n_top_companies* по доходности было оптимизировано в диапазоне от 5 до 30 (для gbf и Bayes rbf).

3. Метрики сравнения портфелей

Для сравнения методов оптимизации портфелей в работе рассмотрены несколько метрик.

Доходность портфеля (portfolio value). Отношение текущей цены портфеля к начальной:

$$V_p(\tau) = \prod_{t=1}^{\tau} \left(1 + \bar{r}_t^{\top} \bar{w}_t\right).$$

Среднегодовая доходность портфеля (average rate of return, AR). Средняя инвестиционная прибыль, получаемая за год. Этот показатель используется для сравнения доходности различных инвестиционных инструментов. Пусть L – суммарный срок инвестиций в годах, T – суммарное число торговых дней. Тогда среднегодовую доходность можно вычислить следующим образом:

$$AR_p = \left(V_p(T)\right)^{\frac{1}{L}} - 1.$$

Стоимость под риском (value at risk, VaR) портфеля уровня α . Обратный выборочный α -квантиль доходностей портфеля, вычисляемый по формуле:

$$VaR_p(\alpha) = -\hat{q}_{\alpha}^{\top} \left(\bar{r}_t^{\top} \bar{w}_t\right).$$

Премия портфеля за риск (избыточная доходность). Выигрыш от держания портфеля по сравнению с безрисковым активом. Для инвестиционного портфеля \mathcal{P} с весами активов \bar{w}_t , относительной доходностью \bar{r}_t и безрисковой процентной ставкой rf_t в момент $t = 1, \dots, T$:

$$\mu_p = \frac{1}{T} \sum_{t=1}^T \left(\bar{r}_t^{\top} \bar{w}_t - rf_t\right).$$

Стандартное отклонение портфеля. Выборочное стандартное отклонение избыточной доходности, вычисляемое по формуле:

$$\sigma_p = \frac{1}{T-1} \sqrt{\sum_{t=1}^T \left(\bar{r}_t^{\top} \bar{w}_t - rf_t - \mu_p\right)^2}.$$

Коэффициент Шарпа (Sharpe ratio). Отношение премии за риск к стандартному отклонению портфеля:

$$ShR_p = \frac{\mu_p}{\sigma_p}.$$

Относительная просадка (relative drawdown). Относительная разница максимальной цены портфеля до настоящего момента и текущей его цены. Формально, если $V_p(t)$ – отношение цены портфеля в момент t к начальной, то

$$RD_p(t) = 1 - \frac{V_p(t)}{\max_{\tau=1, \dots, t} V_p(\tau)}.$$

Коэффициент Мартина (Martin Ratio, Ulcer performance index, UPI) [10]. Отношение избыточной до-

ходности портфеля к среднеквадратичной относительной просадке:

$$PF_p = \frac{\mu_p}{\sqrt{RD_p^2}}$$

Коэффициент Мартина используется для подбора гиперпараметров на этапе валидации.

4. Описание данных

Для проведения исследования использовались данные, полученные из базы Yahoo с использованием библиотеки *yfinance* [32]. В перечень анализируемых активов были включены акции компаний, входящих в индекс S&P 500, а также 500 случайно отобранных акций из базы данных Yahoo. Таким образом, выбор активов обеспечивает независимость весов, полученных в результате работы алгоритма, от весов, построенных только на основе бенчмарка. Сформированный датасет включает дневную динамику стоимости по 1000 акциям за период с 1990 по 2022 год.

Далее была проведена предварительная фильтрация данных, исключающая акции, где более чем в 10% наблюдений отсутствовали значения. Для остальных наблюдений, где отсутствовали значения, доходность была определена как среднее значение за весь предыдущий исторический период. Также из рассмотрения были исключены акции с высокой волатильностью, стоимость которых изменялась более чем в два раза по сравнению с предыдущим днем хотя бы один раз.

После проведенной фильтрации было отобрано 300 акций, представляющих различные секторы. Среди них оказались компании из ИТ-сектора, такие как Apple и Microsoft, из финансовой сферы – JPMorgan

Chase и Citigroup, а также представители медицинской отрасли, включая Johnson & Johnson и Pfizer. Кроме того, в список вошли компании из сектора потребительских товаров: PepsiCo, The Coca-Cola Company, McDonald's, Procter & Gamble и Walmart.

Полученные данные были разделены на два периода: обучающий (1990–2016 гг.) и тестовый (2017–2022 гг.). Для подбора гиперпараметров использовалась кросс-валидация для временных рядов. Методика такой кросс-валидации предполагает разделение данных на блоки, идущие последовательно по времени. Обучение модели происходит на всех предыдущих блоках данных, а проверка – на последующем (*рис. 1*). Данный процесс повторяется несколько раз и может быть реализован методом *TimeSeriesSplit* из *sklearn* [33].

5. Результаты

Конфигурации подобранных гиперпараметров для всех методов представлены в *таблице 1*. Стоит отметить, что у большинства методов оптимальный период смены портфеля составил примерно полгода (180 дней), что может указывать на глобальную оптимальность данного временного интервала. Интересно отметить, что для ядерных моделей фактор масштаба ядра приблизительно одинаков и составляет около 0,04.

После проведения процессов подбора гиперпараметров с использованием байесовской оптимизации и метода поиска по случайной сетке для четырех методов была вычислена доходность на тестовой выборке. Графики доходностей на тестовом наборе данных для всех восьми алгоритмов и базового бенчмарка S&P 500 приведены на *рис. 2*, а также доступны на интерактивном HTML-графике [34].

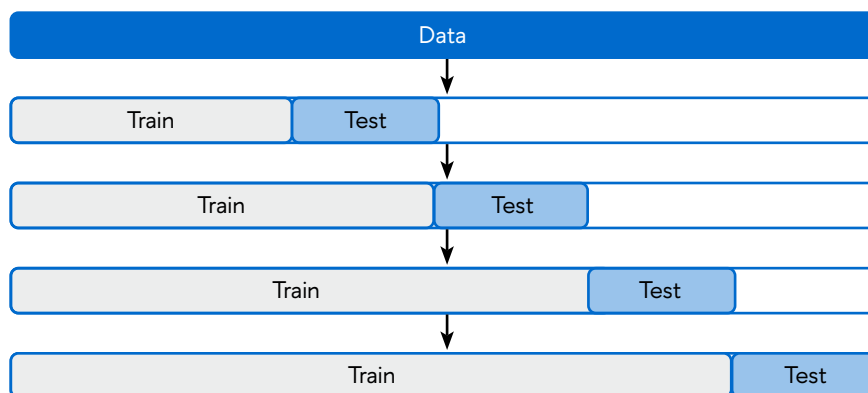


Рис. 1. Визуализация кросс-валидации *TimeSeriesSplit* из *sklearn*.

Таблица 1.

Подобранные гиперпараметры для всех 8 алгоритмов

	size_of_window_rank	period_change_portfolio	n_top_companies	var_ratio	kernel	kernelgamma	kerneldegree	kernelcoef0
Без оптимизации	3,20	190	97	–	–	–	–	–
РСА	4,90	192	150	0,935	–	–	–	–
Poly KPCA	2,10	249	86	0,86	poly	0,04	4	0,77
rbf	4,90	170	27	0,91	rbf	0,04	–	–
Bayes	4,79	190	100	–	–	–	–	–
Bayes PCA	3,45	189	71	0,891	–	–	–	–
Bayes Poly KPCA	3,37	190	66	0,921	poly	0,034	2	0,844
Bayes rbf	2,44	188	17	0,764	rbf	0,044	–	–

Помимо графиков, были рассчитаны экономические показатели из раздела 3. Для каждого из портфеля и S&P 500 они представлены в *таблице 2*.

Результаты исследования показывают, что наиболее эффективным алгоритмом является метод Bayes rbf, использующий гауссовское ядро в KernelPCA, подобранный с помощью байесовской

оптимизации. Портфель, оптимизированный с помощью данного метода, в период февраля – апреля 2020 г., связанного с первой вспышкой пандемии COVID-19, имеет наименьшую просадку 28,5%, что на 5 п.п. ниже уровня просадки S&P 500. Данное наблюдение подтверждает результат исследования [8], демонстрирующего, что алгоритмы с га-



Рис. 2. Значения доходности на тестовом датасете для всех 8 алгоритмов и S&P 500.

Таблица 2.

Экономические показатели на тесте для всех 8 алгоритмов и S&P 500

	S&P 500	Без оптимизации	PCA	Poly KPCA	rbf	Bayes	Bayes PCA	Bayes Poly KPCA	Bayes rbf
Профит фактор	1,09	1,1	1,13	1,09	1,09	1,1	1,1	1,09	1,15
Кoeffициент Шарпа	0,41	0,57	0,65	0,46	0,63	0,58	0,53	0,45	0,85
Кoeffициент Мартина	0,26	1,05	1,9	0,71	1,47	1,11	1,09	0,54	3,64
Годовая доходность	10,87%	18,75%	18,11%	12,9%	17,17%	18,71%	16,54%	13,01%	26,98%
Годовая волатильность	20,26%	28,14%	23,97%	22,5%	27,71%	27,83%	26,08%	23,13%	28,51%
5% VaR	1,935%	2,815%	2,4%	2,113%	2,715%	2,817%	2,442%	2,151%	2,897%
Максимальная просадка	33,92%	44,41%	38,04%	43,51%	37,03%	42,99%	43,29%	34,1%	28,27%
Winning days	54,5%	54,2%	55,3%	53,6%	53,6%	54,1%	54,1%	53,4%	54,0%

уссовским ядром показывают лучшие результаты на рынке кризисных ситуаций. В то же время алгоритмы с гауссовским ядром rbf и Bayes rbf демонстрируют наиболее высокую волатильность (27,7% и 28,5% соответственно). Этот результат обусловлен ограниченным числом рассматриваемых акций и, следовательно, меньшей диверсификацией риска портфеля.

Наименьшую волатильность, помимо индекса S&P 500, показали портфели с полиномиальным ядром Poly KPCA и Bayes Poly KPCA: 22,5% и 23,1% соответственно. Это свидетельствует о способности полиномиального ядра эффективно фильтровать шумы. Кроме того, данные портфели характеризуются наилучшими значениями 5% VaR (около 2,1%), что немного больше значения для S&P 500. Однако среднегодовые значения доходности этих портфелей одни из самых низких – 12,9% и 13,0%.

Портфели PCA и Bayes PCA, основанные на методе главных компонент, показали средние результаты по риску и доходности. Это свидетельствует о том, что даже такие классические алгоритмы с дополнительной оптимизацией превзошли бенчмарки по большинству метрик.

В то же время результаты исследования не позволяют установить, что байесовская оптимизация

или случайный поиск по сетке более эффективны при отборе гиперпараметров.

Хотя S&P 500 характеризуется наименьшим риском, его доходность также низка, что отразилось на показателях отношений. Таким образом, построенные портфели, хоть и более волатильны, чем S&P 500, показывают лучшие результаты по остальным метрикам, демонстрируя, что оптимальная перебалансировка портфеля может обеспечить дополнительную доходность за счет риска.

Чтобы привести полученные нами портфели в соответствие с уровнем риска S&P, т.е. среднегодовой волатильностью индекса S&P рассмотрим результаты алгоритма Bayes rbf в случае, если часть денег вкладывается в данный алгоритм, а оставшаяся – в безрисковый актив (таблица 3). Заметим, что если 50% капитала вкладывается в лучший алгоритм, а 50% в безрисковый актив, то доходность и риск портфеля лучше по сравнению с индексом S&P. Если ограничить риск риском, соответствующим индексу, то среднегодовая доходность вырастет с 10,9% до 19,9%. Соответственно, рассматриваемый алгоритм на протяжении длительного периода времени и получать доходность выше S&P при том же уровне риска.

Таблица 3.

Сравнение лучшего алгоритма и S&P 500

	S&P 500	Bayes rbf	S&P-risk Bayes rbf	0% Bayes rbf	50% Bayes rbf	75% Bayes rbf	90% Bayes rbf
Годовая доходность	10,87%	26,98%	19,93%	2,61%	14,8%	20,89%	24,54%
Годовая волатильность	20,26%	28,51%	20,26%	0,0%	14,26%	21,38%	25,66%
Коэффициент Шарпа	0,41	0,85	0,85	0,0	0,85	0,85	0,85

Заключение

В работе был исследован алгоритм долгосрочного инвестирования, основанный на решении задачи Марковица с предварительным переходом в пространство меньшей размерности при помощи различных вариаций метода главных компонент.

Периодическая перебалансировка портфеля позволяет гибко реагировать на изменения на рынке, что подтверждает сравнимая с бенчмарком просадка некоторых моделей, несмотря на более высокий показатель риска. Однако перебалансировка портфеля проводилась не слишком часто, чтобы метод Марковица смог показать себя на достаточно больших промежутках времени. Наконец, оптимизация коэффициента Мартина при подборе гиперпараметров показывает высокую доходность портфелей и не слишком резкую просадку.

Помимо этого, были получены портфели, показывающие более доходные траектории, чем бенчмарк, однако немного более рискованные. Важно

отметить, что риск портфелей можно регулировать посредством коэффициента risk aversion, что позволяет подбирать портфели, исходя из предпочтений инвестора относительно риска. Риск можно регулировать и с помощью выбираемых методов: метод с ядерным PCA с полиномиальным ядром подбирает менее рискованный, но и менее доходный портфель, в то время как метод без уменьшения размерности позволяет больше рисковать, но и при этом больше получать. Золотой серединой в этой дилемме может оказаться простой метод главных компонент, который позволяет соблюдать баланс между риском и доходностью. Отметим также, что лучшими экономическими показателями обладает алгоритм, использующий ядерный анализ главных компонент с гауссовским ядром в основном за счет незначительной просадки в пандемийный период в сравнении с другими алгоритмами. Можно сделать вывод, что в кризисные моменты наиболее эффективно применение гауссовского ядра к доходностям акций в качестве перехода в пространство меньшей размерности. ■

Литература

1. Market capitalization of listed domestic companies. World Federation of Exchanges database // The World Bank. [Электронный ресурс]: <https://data.worldbank.org/indicator/CM.MKT.LCAP.CD> (дата обращения 20.11.2023).
2. Абрамов А.Е., Косырев А.Г., Радыгин А.Д., Чернова М.И. Поведение частных инвесторов на фондовых рынках России и США // Мониторинг экономической ситуации в России. 2021. Вып. 18 С. 11–16.
3. Markowitz H. Portfolio Selection // The Journal of Finance. 1952. Vol. 7. No. 1. P. 77–91. <https://doi.org/10.2307/2975974>
4. Durall R. Asset allocation: From Markowitz to deep reinforcement learning // arXiv:2208.07158. 2022. <https://doi.org/10.48550/arXiv.2208.07158>
5. Best M.J., Grauer R.R. On the sensitivity of mean–variance-efficient portfolios to changes in asset means: Some analytical and computational results // The Review of Financial Studies. 1991. Vol. 4. No. 2. P. 315–342. <https://doi.org/10.1093/rfs/4.2.315>
6. Stefatos G., Hamza A.B. Cluster PCA for outliers detection in high-dimensional data // Proceedings of the 2007 IEEE International Conference on Systems, Man and Cybernetics, Montreal, QC, Canada. 2007. P. 3961–3966. <https://doi.org/10.1109/ICSMC.2007.4414244>
7. Saha B.N., Ray N., Zhang H. Snake validation: A PCA-based outlier detection method // IEEE Signal Processing Letters. 2009. Vol. 16. No. 6. P. 549–552. <https://doi.org/10.1109/LSP.2009.2017477>

8. Peng Y., Albuquerque P.H.M., do Nascimento I.F., Machado J.V.F. Between nonlinearities, complexity, and noises: An application on portfolio selection using kernel principal component analysis // *Entropy*. 2019. Vol. 21. No. 4. Article 376. <https://doi.org/10.3390/e21040376>
9. Ma Y., Han R., Wang W. Portfolio optimization with return prediction using deep learning and machine learning // *Expert Systems with Applications*. 2021. Vol. 165. Article 113973. <https://doi.org/10.1016/j.eswa.2020.113973>
10. Heaton J.B., Polson N., Witte J. Deep learning for finance: deep portfolios // *Applied Stochastic Models in Business and Industry*. 2016. Vol. 33. No. 1. P. 3–12. <https://dx.doi.org/10.2139/ssrn.2838013>
11. Chen K., Zhou Y., Dai F. A LSTM-based method for stock returns prediction: A case study of china stock market // *Proceedings of the 2015 IEEE International Conference on Big Data (Big Data)*, Santa Clara, CA, USA. 2015. P. 2823–2824.
12. Yun H., Lee M., Kang Y.S., Seok J. Portfolio management via two-stage deep learning with a joint cost // *Expert Systems with Applications*. 2020. Vol. 143. Article 113041. <https://doi.org/10.1016/j.eswa.2019.113041>
13. Chong E., Han C., Park F. Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies // *Expert Systems with Applications*. 2017. Vol. 83. P. 187–205. <https://doi.org/10.1016/j.eswa.2017.04.030>
14. Fischer T., Krauss C. Deep learning with long short-term memory networks for financial market predictions // *European Journal of Operational Research*. 2018. Vol. 270. No. 2. P. 654–669. <https://doi.org/10.1016/j.ejor.2017.11.054>
15. Hoseinzade E., Haratizadeh S. CNNpred: Cnn-based stock market prediction using a diverse set of variables // *Expert Systems with Applications*. 2019. Vol. 129. P. 273–285. <https://doi.org/10.1016/j.eswa.2019.03.029>
16. Kim J., Lee M. Portfolio optimization using predictive auxiliary classifier generative adversarial networks // *Engineering Applications of Artificial Intelligence*. 2023. Vol. 125. Article 106739. <https://doi.org/10.1016/j.engappai.2023.106739>
17. Siaw R., Ofosu-Hene E., Tee E. Investment Portfolio Optimization with GARCH Models // *Elk Asia Pacific Journal of Finance and Risk Management*. 2017. Vol. 8. No. 2. [Электронный ресурс]: <https://ssrn.com/abstract=2987932> (дата обращения 4.08.2024).
18. Bardenet R., Bengio Y., Bergstra J., Kégl B. Algorithms for hyper-parameter optimization // *Proceedings of the Advances in Neural Information Processing Systems 24 (NIPS 2011)*. 2011.
19. Martin P.G., McCann B.B. The investor's guide to fidelity funds // *John Wiley & Sons*, 1989.
20. S&P 500. S&P Dow Jones Indices // S&P Global. [Электронный ресурс]: <https://www.spglobal.com/spdji/en/indices/equity/sp-500/#overview> (дата обращения 20.11.2023).
21. Beneish M.D., Whaley R.E. A scorecard from the S&P game // *Journal of Portfolio Management*. 1997. Vol. 16. No. 2. Article 23.
22. Latham S., Braun M. Does short-termism influence firm innovation? An examination of S&P 500 firms 1990–2003 // *Journal of Managerial Issues*. 2010. Vol. 22. No. 3. P. 368–382.
23. Zhang Z. Study of portfolio performance under certain restraint comparison: Markowitz Model and Single Index Model on S&P 500 // *Proceedings of the 2022 7th International Conference on Social Sciences and Economic Development*. 2022. P. 1930–1938. <https://doi.org/10.2991/aebmr.k.220405.323>
24. Lien G. Non-parametric estimation of decision makers' risk aversion // *Agricultural Economics*. 2002. Vol. 27. No. 1. P. 75–83. [https://doi.org/10.1016/S0169-5150\(01\)00063-9](https://doi.org/10.1016/S0169-5150(01)00063-9)
25. Fama E.F., MacBeth J. Risk, return, and equilibrium: Empirical tests // *Journal of Political Economy*. 1973. Vol. 71. P. 607–636.
26. Paoletta M.S. The univariate collapsing method for portfolio optimization // *Econometrics*. 2017. Vol. 5. No. 2. Article 18. <https://doi.org/10.3390/econometrics5020018>
27. CVXPY 1.4 Manual // The CVXPY authors. [Электронный ресурс]: <https://www.cvxpy.org/index.html> (дата обращения 20.11.2023).
28. Bakir G., Weston J., Schölkopf B. Learning to find pre-images // *Proceedings of the Advances in Neural Information Processing Systems 16 (NIPS 2003)*. 2003.
29. SciPy v1.11.4 Manual // The SciPy community. [Электронный ресурс]: <https://docs.scipy.org/doc/scipy/tutorial/optimize.html> (дата обращения 20.11.2023).
30. Drenovak M., Rankovic V. Markowitz portfolio rebalancing with turnover monitoring // *Economic Horizons*. 2014. Vol. 16. No. 3. P. 207–217. <https://doi.org/10.5937/ekonhor1403211D>
31. API Reference. sklearn.model_selection.RandomizedSearchCV // scikit-learn. Machine Learning in Python. [Электронный ресурс]: https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.RandomizedSearchCV.html (дата обращения 20.11.2023).
32. yfinance documentation // GitHub. [Электронный ресурс]: <https://yfinance.readthedocs.io/en/documentation/> (дата обращения 20.11.2023).
33. API Reference. sklearn.model_selection.TimeSeriesSplit // scikit-learn. Machine Learning in Python. [Электронный ресурс]: https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.TimeSeriesSplit.html (дата обращения 20.11.2023).
34. Интерактивный график результатов исследования. [Электронный ресурс]: <https://disk.yandex.ru/d/5nF7RiXKIWp1ig> (дата обращения 20.11.2023).

Об авторах

Куликов Александр Владимирович

к.ф.-м.н.;

доцент, кафедра высшей математики, Московский физико-технический институт, Россия, 141701, Московская область, г. Долгопрудный, Институтский пер., д. 9;

E-mail: avkulikov15@gmail.com

ORCID: 0000-0002-3963-0814

Полозов Дмитрий Сергеевич

магистрант, Московский физико-технический институт, Россия, 141701, Московская область, г. Долгопрудный, Институтский пер., д. 9;

E-mail: polozov.ds@phystech.edu

ORCID: 0009-0008-1108-4955

Волков Никита Васильевич

аспирант, Московский физико-технический институт, Россия, 141701, Московская область, г. Долгопрудный, Институтский пер., д. 9;

E-mail: nikita.v.volkov@phystech.edu

ORCID: 0009-0007-8434-9822

Long-term investment optimization based on Markowitz diversification

Alexander V. Kulikov

E-mail: avkulikov15@gmail.com

Dmitriy S. Polozov

E-mail: polozov.ds@phystech.edu

Nikita V. Volkov

E-mail: nikita.v.volkov@phystech.edu

Moscow Institute of Physics and Technology, Dolgoprudny, Russia

Abstract

The article introduces a long-term investment algorithm that identifies optimal solutions in lower dimensional spaces constructed through principal component analysis or kernel principal component analysis. Portfolio weights optimization is carried out using the Markowitz method. Hyperparameters of the model include window size, smoothing parameter, rebalancing period and the fraction of explained variance in dimensionality reduction methods. The algorithm presented incorporates weights regularization taking into account portfolio rebalancing transaction costs. Hyperparameters' selection is based on the Martin coefficient, which allows us to consider the maximum drawdown for the suggested algorithms. The results demonstrate that the proposed algorithm, trained from 1990 to 2016, shows higher returns and Sharpe ratios compared to the S&P 500 benchmark from 2017 to 2022. This indicates that weights optimization can improve the algorithm's performance through rebalancing.

Keywords: PCA, Kernel PCA, window size, Markowitz algorithm, Grid Search, Bayesian optimization

Citation: Kulikov A.V., Polozov D.S., Volkov N.V. (2024) Long-term investment optimization based on Markowitz diversification. *Business Informatics*, vol. 18, no. 3, pp. 56–69. DOI: 10.17323/2587-814X.2024.3.56.69

References

1. The World Bank Group (2023) *Market capitalization of listed domestic companies*. *World Federation of Exchanges database*. Available at: <https://data.worldbank.org/indicator/CM.MKT.LCAP.CD> (accessed 20 November 2023).
2. Abramov A.E., Kosyrev A.G., Radygin A.D., Chernova M.I. (2021) Behavior of private investors in the stock markets of Russia and the US. *Russian Economic Developments*, vol. 18, pp. 11–16 (in Russian).
3. Markowitz H. (1952) Portfolio selection. *The Journal of Finance*, vol. 7, no. 1, pp. 77–91. <https://doi.org/10.2307/2975974>
4. Durall R. (2022) Asset allocation: From Markowitz to deep reinforcement learning. *arXiv:2208.07158*. <https://doi.org/10.48550/arXiv.2208.07158>
5. Best M.J., Grauer R.R. (1991) On the sensitivity of mean–variance-efficient portfolios to changes in asset means: Some analytical and computational results. *The Review of Financial Studies*, vol. 4, no. 2, pp. 315–342. <https://doi.org/10.1093/rfs/4.2.315>
6. Stefatos G., Hamza A.B. (2007) Cluster PCA for outliers detection in high-dimensional data. *Proceedings of the 2007 IEEE International Conference on Systems, Man and Cybernetics, Montreal, QC, Canada*, pp. 3961–3966. <https://doi.org/10.1109/ICSMC.2007.4414244>.
7. Saha B.N., Ray N., Zhang H. (2009) Snake validation: A PCA-based outlier detection method. *IEEE Signal Processing Letters*, vol. 16, no. 6, pp. 549–552. <https://doi.org/10.1109/LSP.2009.2017477>
8. Peng Y., Albuquerque P.H.M., do Nascimento I.F., Machado J.V.F. (2019) Between nonlinearities, complexity, and noises: An application on portfolio selection using kernel principal component analysis. *Entropy*, vol. 21, no. 4, 376. <https://doi.org/10.3390/e21040376>
9. Ma Y., Han R., Wang W. (2021) Portfolio optimization with return prediction using deep learning and machine learning. *Expert Systems with Applications*, vol. 165, 113973. <https://doi.org/10.1016/j.eswa.2020.113973>
10. Heaton J.B., Polson N., Witte J. (2016) Deep learning for finance: Deep portfolios. *Applied Stochastic Models in Business and Industry*, vol. 33, no. 1, pp. 3–12. <https://doi.org/10.2139/ssrn.2838013>
11. Chen K., Zhou Y., Dai F. (2015) A LSTM-based method for stock returns prediction: A case study of China stock market. *Proceedings of the 2015 IEEE International Conference on Big Data (Big Data), Santa Clara, CA, USA*, pp. 2823–2824. <https://doi.org/10.1109/BigData.2015.7364089>
12. Yun H., Lee M., Kang Y.S., Seok J. (2020) Portfolio management via two-stage deep learning with a joint cost. *Expert Systems with Applications*, vol. 143, 113041. <https://doi.org/10.1016/j.eswa.2019.113041>
13. Chong E., Han C., Park F. (2017) Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies. *Expert Systems with Applications*, vol. 83, pp. 187–205. <https://doi.org/10.1016/j.eswa.2017.04.030>
14. Fischer T., Krauss C. (2018) Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, vol. 270, no. 2, pp. 654–669. <https://doi.org/10.1016/j.ejor.2017.11.054>
15. Hoseinzade E., Haratizadeh S. (2019) CNNpred: CNN-based stock market prediction using a diverse set of variables. *Expert Systems with Applications*, vol. 129, pp. 273–285. <https://doi.org/10.1016/j.eswa.2019.03.029>
16. Kim J., Lee M. (2023) Portfolio optimization using predictive auxiliary classifier generative adversarial networks. *Engineering Applications of Artificial Intelligence*, vol. 125, 106739. <https://doi.org/10.1016/j.engappai.2023.106739>
17. Siaw R., Ofosu-Hene E., Tee E. (2017) Investment portfolio optimization with GARCH models. *Elk Asia Pacific Journal of Finance and Risk Management*, vol. 8, no. 2. Available at: <https://ssrn.com/abstract=2987932> (accessed 04 August 2024).
18. Bardenet R., Bengio Y., Bergstra J., Kégl B. (2011) Algorithms for hyper-parameter optimization. *Proceedings of the Advances in Neural Information Processing Systems 24 (NIPS 2011)*.
19. Martin P.G., McCann B.B. (1989) *The investor's guide to fidelity funds*. John Wiley & Sons.
20. S&P Global (2023) *S&P 500. S&P Dow Jones Indices*. Available at: <https://www.spglobal.com/spdji/en/indices/equity/sp-500/#overview> (accessed 20 November 2023).
21. Beneish M.D., Whaley R.E. (1997) A scorecard from the S&P game. *Journal of Portfolio Management*, vol. 16, no. 2, 23.
22. Latham S., Braun M. (2010) Does short-termism influence firm innovation? An examination of S&P 500 firms 1990–2003. *Journal of Managerial Issues*, vol. 22, no. 3, pp. 368–382.
23. Zhang Z. (2022) Study of portfolio performance under certain restraint comparison: Markowitz Model and Single Index Model on S&P 500. *Proceedings of the 2022 7th International Conference on Social Sciences and Economic Development*, pp. 1930–1938. <https://doi.org/10.2991/aebmr.k.220405.323>
24. Lien G. (2002) Non-parametric estimation of decision makers' risk aversion. *Agricultural Economics*, vol. 27, no. 1, pp. 75–83. [https://doi.org/10.1016/S0169-5150\(01\)00063-9](https://doi.org/10.1016/S0169-5150(01)00063-9)
25. Fama E.F., MacBeth J. (1973) Risk, return, and equilibrium: Empirical tests. *Journal of Political Economy*, vol. 71, pp. 607–636.

26. Paoletta M.S. (2017) The univariate collapsing method for portfolio optimization. *Econometrics*, vol. 5, no. 2, 18. <https://doi.org/10.3390/econometrics5020018>
27. The CVXPY authors (2023) *CVXPY 1.4 Manual*. Available at: <https://www.cvxpy.org/index.html> (accessed 20 November 2023).
28. Bakir G., Weston J., Schölkopf B. (2003) Learning to find pre-images. Proceedings of the *Advances in Neural Information Processing Systems 16 (NIPS 2003)*.
29. The SciPy community (2023) *SciPy v1.11.4 Manual*. Available at: <https://docs.scipy.org/doc/scipy/tutorial/optimize.html> (accessed 20 November 2023).
30. Drenovak M., Rankovic V. (2014) Markowitz portfolio rebalancing with turnover monitoring. *Economic Horizons*, vol. 16, no. 3, pp. 207–217. <https://doi.org/10.5937/ekonhor1403211D>
31. scikit-learn. Machine Learning in Python (2023) *API Reference. sklearn.model_selection. RandomizedSearchCV*. Available at: https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.RandomizedSearchCV.html (accessed 20 November 2023).
32. GitHub (2023) *yfinance documentation*. Available at: <https://yfinance.readthedocs.io/en/documentation/> (accessed 20 November 2023).
33. scikit-learn. Machine Learning in Python (2023) *API Reference. sklearn.model_selection. TimeSeriesSplit*. Available at: https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.TimeSeriesSplit.html (accessed 20 November 2023).
34. *Interactive chart of research results*. Available at: <https://disk.yandex.ru/d/5nF7RiXKIWp1ig> (accessed 20 November 2023).

About the authors

Alexander V. Kulikov

Cand. Sci. (Phys.-Math.);

Associate Professor, Moscow Institute of Physics and Technology, 9, Institutskiy Ln., Dolgoprudny 141701, Moscow Region, Russia;

E-mail: avkulikov15@gmail.com

ORCID: 0000-0002-3963-0814

Dmitriy S. Polozov

Master's Student, Moscow Institute of Physics and Technology, 9, Institutskiy Ln., Dolgoprudny 141701, Moscow Region, Russia;

E-mail: polozov.ds@phystech.edu

ORCID: 0009-0008-1108-4955

Nikita V. Volkov

Doctoral Student, Moscow Institute of Physics and Technology, 9, Institutskiy Ln., Dolgoprudny 141701, Moscow Region, Russia;

E-mail: nikita.v.volkov@phystech.edu

ORCID: 0009-0007-8434-9822

DOI: 10.17323/2587-814X.2024.3.70.86

Проектирование многоагентной системы сетевого предприятия

Ю.Ф. Тельнов 

E-mail: Telnov.YUF@rea.ru

В.А. Казаков 

E-mail: Kazakov.VA@rea.ru

А.В. Данилов 

E-mail: Danilov.AV@rea.ru

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

Аннотация

Необходимость повышения эффективности современных сетевых предприятий на основе технологий цифровых платформ, двойников и нитей обуславливает актуальность внедрения в производственную практику динамических многоагентных технологий. Архитектурная сложность существующих многоагентных систем (МАС) и недостаточность научных работ в области обоснования методов и средств их создания обуславливает цель исследования по разработке комплексной технологии проектирования МАС, которая затрагивала бы все уровни архитектуры и позволяла бы адаптировать типовые и наилучшие проектные решения. В статье проведен анализ возможностей применения цифровых двойников и нитей при создании сетевых предприятий и предложены методы их реализации с помощью МАС. Разработана технология проектирования МАС в соответствии с архитектурными фреймворками IIRA (Industrial Internet Reference Architecture) и RAMI (Reference Architectural Model Industrie 4.0), которая позволяет осуществлять взаимосвязанное формирование и отображение результатов проектирования между различными уровнями архитектуры. На бизнес-уровне предлагается метод формирования бизнес-требований к МАС на основе выбора и адаптации бизнес-моделей и прикладных сценариев. На уровне построения производственных и бизнес-процессов представлен метод формирования функциональных требований к МАС, раскрывающий переход от сети ценностей к структурам производственных и бизнес-процессов. На уровне функционального проектирования многоагентной системы сетевого предприятия представляется метод формирования основных проектных решений с позиции реализации различных категорий сервисов с помощью административных оболочек активов и их специализации. На уровне проектирования технологической реализации МАС предлагается метод реализации программных агентов с помощью микросервисной организации программного обе-

спечения. Представленная методика адаптации типовых и наилучших моделей проектирования многоагентных систем позволяет осуществлять выбор из библиотек типовых моделей и баз знаний прецедентов адекватных проектных решений для последующей доработки, что дает возможность ускорить и повысить качество процесса проектирования. Внедрение разработанной технологии проектирования многоагентных систем позволит повысить адаптивность сетевых предприятий к динамически изменяемым потребностям бизнеса с учетом интересов и возможностей всех заинтересованных сторон.

Ключевые слова: многоагентные системы, цифровые нити, цифровые двойники, сетевое предприятие, административная оболочка активов, онтология проекта, микросервисная архитектура

Цитирование: Тельнов Ю.Ф., Казаков В.А., Данилов А.В. Проектирование многоагентной системы сетевого предприятия // Бизнес-информатика. 2024. Т. 18. № 3. С. 70–86. DOI: 10.17323/2587-814X.2024.3.70.86

Введение

Для производства инновационных продуктов и услуг под конкретные потребности заказчиков могут создаваться динамически образуемые гибкие сетевые или распределенные в Интернет-среде предприятия, требующие внедрения новых систем управления на основе применения современных цифровых и интеллектуальных технологий. В результате создания таких предприятий должен сократиться жизненный цикл выпускаемой продукции и оказываемых услуг как на стадии выведения на рынок, так и на стадии производства, обеспечивая высокое качество и адаптивность конфигурации продуктов для различных категорий потребителей [1].

Создание сетевых или виртуальных предприятий на основе современных цифровых платформ, с одной стороны, приводит к повышению уровня интеграции и кооперации взаимодействующих в рамках общей сетевой структуры предприятий [2], а с другой стороны, порождает новые задачи формирования механизмов координации участников сетевых предприятий, отбора надежных партнеров, организации совместного владения и определения прав использования данных, нерешенность которых может привести к потере доверия потенциальных участников сетевого предприятия к возможности осуществления совместной деятельности в рамках общей сетевой структуры [3]. Решение задач создания сетевых предприятий в промышленности усложняется вследствие, как правило, большого числа кооперативных связей, высокой ресурсоемкости и больших инвестиционных циклов.

Внедрение технологий промышленного интернета вещей, цифровых двойников и нитей в практику цифровой трансформации предприятий на основе концепции индустрии четвертого поколения создает объективные предпосылки для повышения эффективности управления сетевыми взаимодействиями предприятий, осуществляющих совместную деятельность за счет создания современных цифровых систем [4–7]. При этом в основе цифровых двойников и нитей лежат цифровые модели, которые представляют системы математических и компьютерных моделей, позволяющих отображать информационное состояние, прогнозировать поведение моделируемых объектов в реальном масштабе времени, формировать принимаемые решения.

Одним из действенных подходов к реализации перечисленных технологий является создание цифровых систем управления производственными и бизнес-процессами сетевого предприятия на основе применения многоагентных технологий — многоагентных систем (МАС) сетевого предприятия. В работах [8, 9] разработаны компьютерные модели на основе применения методов агентного и дискретно-событийного моделирования, которые встраиваются в структуру цифровых двойников для оптимизации производственных процессов на различных этапах жизненного цикла. Для повышения эффективности применения компьютерных моделей производственных и бизнес-процессов необходимо обеспечивать их взаимодействие с системами оперативного сбора данных с помощью средств промышленного интернета вещей (IIoT), а также их интеграции с другими интеллектуальными тех-

нологиями, базирующимися на правилах принятия решений, анализе больших объемов данных и машинном обучении [10–13].

Архитектурная сложность МАС обуславливает цель исследования по разработке комплексной технологии проектирования программной реализации, которая затрагивала бы все уровни архитектуры сетевого предприятия в соответствии с архитектурными фреймворками IIRA и RAMI [14, 15] и применение многообразных инструментов поддержки принятия решений в компьютерных моделях агентов. В существующих работах по проектированию многоагентной реализации цифровых систем в основном рассматривается функциональный уровень проектирования [16–19] и практически не рассматривается проектирование МАС на других уровнях архитектуры.

В статье решаются задачи проведения анализа возможностей цифровых двойников и цифровых нитей для создания сетевых предприятий, их реализации с помощью многоагентной системы и разработки технологии проектирования МАС на уровнях формирования бизнес и пользовательских требований, функционального проектирования и реализации с взаимным отображением между уровнями получаемых результатов. Особенностью предлагаемой технологии является увязка этапов проектирования МАС путем последовательного отображения проектных сущностей (категорий) между уровнями архитектуры и адаптации проектных решений на основе библиотек типовых проектных решений и баз знаний наилучших прецедентов использования [20–22].

1. Анализ возможностей применения цифровых двойников и цифровых нитей для создания сетевых предприятий на основе многоагентной технологии

Технология цифровых двойников (ЦД) находит широкое применение в промышленности и позволяет управлять активами предприятия (продуктами, оборудованием, любыми ресурсами) на разных этапах их существования. При этом ЦД не только отражают текущее состояние активов, но и позволяют с помощью набора процедур моделировать, прогнозировать и формировать решения по оптимизации их поведения. С этой точки зрения ЦД представляют собой интегрированную систему данных, моделей и инструментов анализа и формирования решений, применяемых на протяжении

всего жизненного цикла различных активов [8, 23].

В связи с необходимостью отслеживания и управления поведением не только отдельных активов, но и динамических процессов, в которых они участвуют, объективно возникает потребность в реализации более сложных производственных технологий на основе цифровизации, которые нашли отражение в концепции цифровых нитей (ЦН). Концепция ЦН предполагает применение современных инструментов моделирования и управления, которые связывают процессы жизненного цикла взаимосвязанных активов и позволяют повысить технологичность, возможность контроля и устойчивость производственных систем [24]. ЦН в экономическом смысле реализует управление цепочкой создания стоимости. В архитектурном фреймворке RAMI [15] ЦН связывается с взаимодействующими активами: производственными цепочками и цепочками поставок.

Использование ЦД и ЦН обеспечивают гибкость и адаптируемость, необходимые для быстрой разработки и внедрения продукции при одновременном снижении рисков. Так, данные, полученные из существующих или проектируемых производственных систем могут лечь в основу усовершенствованных моделей, которые позволят выполнять прогнозирование как на уровне компонентов, так и на уровне актива в целом. Архивирование цифровых описаний активов позволяет значительно облегчить любое необходимое в будущем перепроектирование производственной системы. Совокупность ЦД и ЦН составляют цифровую систему для конкретной производственной системы или всего сетевого предприятия.

Единая информационная модель ЦД и ЦН может быть представлена с помощью программного обеспечения с открытым исходным кодом, которое позволяет внедрять цифровые технологии в сложные проекты [25]. Такой вариант обеспечивает внедрение ЦД и ЦН не только в проекты цифровизации отдельных предприятий, но и в создание сетевых предприятий за счет интеграции различных программных систем на основе единой цифровой платформы. С помощью технологий ЦД и ЦН обеспечивается передача информации от отдельных звеньев цепочки создания стоимости в производственную систему сетевого предприятия, что позволяет отслеживать соответствие требованиям и влияние полученных результатов на эффективность всего сетевого предприятия [26].

Динамическая природа технологий ЦД и ЦН делает естественным применение многоагентных систем для организации взаимодействия ЦД в рамках ЦН, при этом инструментом реализации ЦД являются программные агенты, а ЦН – МАС в целом. Вопросы реализации производственных систем с помощью технологий многоагентного взаимодействия достаточно хорошо теоретически проработаны [9, 10, 13, 16, 17, 27].

Современное развитие концепций цифровой индустрии четвертого поколения, которое привело к новым архитектурам организации ЦД в виде административных оболочек активов, функционирующих на общих цифровых платформах, предоставляет возможность развития МАС на новой технологической основе, прежде всего с использованием микросервисной реализации механизмов исполнения функций агентов [18, 19, 28].

В перечисленных работах основной упор делается на функциональной реализации МАС для создания цифровых и сетевых предприятий и в меньшей степени посвящены вопросам технологии их проектирования. Вместе с тем, построение многоагентных систем взаимодействия участников сетевого предприятия делает актуальными вопросы создания технологии проектирования МАС, учитывающей уровень сложности создаваемых сетевых предприятий. Ранее разработанные технологии проектирования МАС, например, такие, как ASEME [29], RTMIAS [30], X-Machine [31] и др., носят локальный характер применения, основаны на компонентной технологии объектно-ориентированного проектирования, в некоторых случаях используют онтологии для разработки взаимодействия агентов, но для таких сложных систем, как сетевые предприятия, являются малоприменимыми.

С точки зрения применения концепции индустрии четвертого поколения проектирование МАС сетевого предприятия сводится к проектированию административных оболочек активов (АО), которые соответствуют агентам, реализующим активный и проактивный режим функционирования [21, 28, 32], а также проектированию сценариев их взаимодействия в рамках единых ЦН посредством обмена сообщениями между АО в соответствии с протоколами, установленными FIPA [33]. Отличительной особенностью реализации АО на принципах многоагентной технологии является возможность применения баз знаний для выработки решений и механизмов имитационного моделирования и машинного обучения для анализа и интерпретации событий.

Для реализации программных агентов и их взаимодействия необходимо разработать набор функциональных сервисов АО, а для цифровой платформы, обслуживающей множество взаимодействующих АО, – набор инфраструктурных сервисов, которые обеспечивают создание и регистрацию АО и их пользователей, коммерческую и информационную безопасность использования и ряд других функций.

С учетом сложности процесса создания МАС сетевого предприятия в статье предлагается технология проектирования, которая базируется на последовательном уточнении проектных решений по уровням архитектуры сетевого предприятия в соответствии с фреймворками PIRA и RAMI [14, 15] с использованием методики адаптации типовых и наилучших моделей проектирования.

2. Этапы технологии проектирования МАС сетевого предприятия

Этапы проектирования МАС сетевого предприятия хорошо определяются точками зрения на архитектуру системы в соответствии с фреймворком PIRA [14]:

- ♦ бизнес-моделирование – точка зрения бизнеса (Business Viewpoint);
- ♦ построение производственных и бизнес-процессов – точка зрения использования (Usage Viewpoint);
- ♦ функциональное проектирование МАС – функциональная точка зрения (Functional Viewpoint);
- ♦ проектирование технологии реализации – точка зрения реализации (Implementation Viewpoint).

Перечисленные точки зрения на архитектуру или уровни архитектуры являются взаимосвязанными: каждый последующий уровень архитектуры конкретизирует предыдущий уровень архитектуры на своем специфическом языке и подтверждает возможность реализации сформулированных выше требований. Особенностью предлагаемой технологии проектирования МАС является последовательная декомпозиция и детализация проектных решений и итерационное повторение этапов в случае возникновения необходимости.

Набор используемых в предлагаемой технологии проектирования МАС сущностей цифровой системы на различных уровнях архитектуры PIRA, а также инструментов проектирования представлен в *таблице 1*.

Таблица 1.

**Сущности и инструменты проектирования МАС
на различных уровнях архитектурного фреймворка IIRA**

Сущность	Уровни архитектуры МАС сетевого предприятия			
	Бизнес-уровень	Уровень использования	Функциональный уровень	Уровень реализации
Субъект	Участник, Роль	Роль исполнителя	Интерфейс (Граничный класс)	Клиентское приложение
			Агент субъекта (АО)	Составной микросервис
Объект	Актив	Продукт, Ресурс	Агент объекта (АО)	Составной микросервис
			Класс сущностей	База данных
Функция	Активность/ Деятельность	Процесс	Операция (метод, сервис)	Микросервис
			Класс сущностей	Реестр микросервисов
Инструменты моделирования и проектирования				
Вид модели	Сеть ценности (Санкт-Галлен); Диаграмма прецедентов (UML)	Диаграмма деятельности (UML); BPMN диаграмма; Модель использования (IIRA)	UML диаграммы: последовательности; классов; состояний	UML диаграммы: компонентов; развёртывания

Под участником сети ценности (сетевого предприятия) будем понимать любые предприятия или организации, участвующие в цепочке создания ценности в качестве субъектов.

Под ролью будем понимать специфический сценарий поведения, который выполняет участник сети ценности в производственных или бизнес-процессах. Причем один и тот же участник может играть разные роли в одном и том же процессе, например, предприятие может быть поставщиком оборудования и провайдером сервисов, а предприятие-эксплуатант может быть также оператором частной облачной инфраструктуры. Роли на уровне использования могут быть уточнены до уровня конкретных исполнителей.

На функциональном уровне роль выполняется непосредственно либо актором (организационной единицей), либо программным агентом-субъектом. В первом случае для субъекта должен быть создан интерфейс, реализуемый в виде клиентского приложения, через которое он взаимодействует с МАС. Во втором случае для субъекта создается ЦД, который автоматизирует ряд функций актора, по сути, заменяя его. В этом отношении предлагается на функциональном уровне представлять ЦД субъекта так же, как и ЦД актива, — в виде АО, которая реализуется составным микросервисом в

том смысле, что составной программный компонент включает реестр сервисов, соответствующих отдельным функциям [34].

Под активом сетевого предприятия в соответствии с архитектурным фреймворком RAMI будем понимать любые физические или программные объекты (продукты — изделия, услуги или их компоненты, и ресурсы — отдельные устройства, оборудование, производственные линии, производственные системы) [15], которые представляются АО [33]. АО объектов (продуктов или ресурсов), предлагается реализовывать с помощью микросервисов [35, 36]. В случае если какая-либо часть информации об активах не требует активного управления, то она технологически реализуется в виде локальной для микросервиса пассивной базы данных или общей для нескольких микросервисов базы данных.

Под активностью сетевого предприятия с точки зрения бизнеса будем понимать некоторую функцию, которая производит потоки материальных ценностей, информации и стоимости (затрат). Каждая активность детализируется в виде процесса, выполняемого с помощью МАС, который состоит из отдельных операций. Выявленные операции задаются в качестве элементов структуры АО, которые ссылаются через API-интерфейс на реализацию в виде микросервиса. При этом метаописа-

ние операции как класс сущностей помещается в реестр сервисов [21, 34].

Для моделирования и проектирования MAC используется комбинация различных инструментов. В статье для представления сквозного примера процесса проектирования MAC в качестве комплексного инструмента используется объектно-ориентированный язык моделирования UML.

Рассмотрим этапы технологии проектирования MAC сетевого предприятия, соответствующие точкам зрения PRA, более детально.

Бизнес-моделирование. Точка зрения бизнеса (Business Viewpoint) определяет стратегию создания и функционирования сетевого предприятия. С этой позиции на этапе бизнес-моделирования определяются заинтересованные стороны и их видение функционирования предприятия в условиях применения общих цифровых платформ, а также ценности и цели цифровизации производственных и бизнес-процессов. На этом этапе формируются бизнес-требования к проектируемой многоагентной системе. Важнейшую роль на этом этапе играет построение бизнес-моделей функционирования сетевых предприятий, конкретизируемых в бизнес-сценариях [21, 37]. В качестве нотации описания бизнес-моделей широко используется фреймворк сетей ценности Санкт-Галлена [38]. С позиции многоагентной реализации важнейшее значение приобретает метод определения основных активностей и их акторов, поддерживаемых в дальнейшем программными агентами и их процессами. Основные активности сетей ценности можно отражать с помощью диаграмм вариантов использования UML.

Процесс бизнес-моделирования начинается со SWOT-анализа предлагаемой организации сетевого предприятия, который выявляет достоинства и недостатки цифровизации с позиции использования внутренних ресурсов, а также возможностей и угроз с позиции влияния внешней среды. В результате SWOT анализа определяется видение компании, основные формируемые ценности и строится дерево целей. Для целей формируются наборы мероприятий по их достижению, включающих в том числе создание новой или настройку существующей программно-технической платформы.

Выбор бизнес-моделей и соответствующих прикладных сценариев реализации осуществляется по методике, описанной в [22, 39]. В соответствии с этой методикой в зависимости от типа бизнес-модели (модель применения промышленного интерне-

та, модель предоставления услуг в цепочке создания стоимости, модели доверенного доступа к данным) и типа бизнес-процесса (процессы управления жизненным циклом создания продукции, управления жизненным циклом производственной системы, управления цепочками поставок, управления сервисным обслуживанием активов) выбираются прикладные сценарии реализации сетевого предприятия (Адаптивная фабрика, Сеть создания стоимости «Инновационная разработка продукта», Сеть создания стоимости «Производство, управляемое заказом», Сценарий, основанный на ценности и др.). Выбор прикладного сценария реализации сетевого предприятия осуществляется на основе базы знаний типовых шаблонов сценариев, упорядоченной с помощью онтологии цифровой трансформации, и последующего анализа сетевых эффектов.

Выбранный прикладной сценарий представляется в виде модели сети ценности и адаптируется к условиям функционирования конкретного предприятия. В модели сети ценностей в первую очередь определяется состав участников предприятия и их роли (головное предприятие, субподрядчики, провайдеры функциональных сервисов, операторы платформы, разработчики программного обеспечения, системные интеграторы и др.). Выполнение активностей участниками сетевого предприятия в соответствии с их ролями можно представить в виде диаграммы вариантов использования. Пример диаграммы вариантов использования для прикладного сценария, основанного на ценности [40], представлен на *рисунке 1*.

Построение производственных и бизнес-процессов в соответствии с точкой зрения на использование системы (Usage Viewpoint). На данном этапе определяются функциональные требования к организации производственных и бизнес-процессов в части конкретизации участников сетевых предприятий, их ролей в различных активностях (процессах). При этом активности определяются с позиции условий инициации, рабочего потока задач, получаемых эффектов и ограничений на исполнение процессов, причем для задач назначаются роли исполнителей [37, 40].

Переход от модели сети ценностей к моделям производственных и бизнес-процессов осуществляется в соответствии со следующим методом: каждому потоку ценностей и сопровождающим информационным и финансовым потокам соответствуют производственные или бизнес-процессы, которые




Рис. 1. Пример диаграммы вариантов использования для прикладного сценария, основанного на ценности (VBS).

могут быть промоделированы в виде диаграммы активностей или BPMN диаграммы, отражающей закрепление ролей участников процессов за выполнением конкретных операций (сервисов). В результате построения диаграмм активности формируются функциональные требования к будущему составу программных агентов, реализующих выделенные роли, и составу операций (сервисов) соответствующих АО.

Функциональное проектирование MAC, отражающее функциональную точку зрения на архитектуру системы (Functional Viewpoint). На этом этапе представляется метод формирования основных проектных решений по построению MAC сетевого предприятия с позиции реализации различных категорий сервисов с помощью АО и их специализации: взаимодействия с внешними бизнес-сервисами (ERP, MES, PLM и др.); приложений (Application) – функциональных сервисов цифровых систем; системных сервисов (System Management) – сервисов платформы; сервисов интеграции с активами – физическими устройствами, продуктами (Control); сервисов коммуникации компонентов цифровой системы (табл. 2) [14, 34].

Таблица 2.

Подуровни функционального уровня фреймворка ПРА

Подуровни функционального уровня	Описание
Уровень бизнеса (BUSINESS DOMAIN)	Сервисы по обмену информацией с внешними приложениями различных информационных систем: ERP, CRM, PLM, MES, HRM и др.
Уровень приложений (APPLICATION DOMAIN)	Функциональные сервисы, выполняющие функции по мониторингу, диагностике, прогнозированию, согласованию, оптимизации, обеспечению, управлению производственными и бизнес-процессами
Операционный уровень (SYSTEM MANAGEMENT DOMAIN)	Общие инфраструктурные сервисы управления программной системой (платформой): развертывания, настройки, мониторинга, диагностики и обновления ее компонентов, а также оркестрации по координации работы различных компонентов системы
Информационный уровень (INFORMATION DOMAIN)	Сервисы сбора, очистки, синтаксических и семантических преобразований, накопления и выдачи данных для функциональных компонентов. Вспомогательные сервисы управления данными: обеспечения безопасности данных, контроля доступа к данным и управления правами на данные, резервного копирования и восстановления и др. Сервисы, реализующие универсальные методы анализа данных, в т.ч. методы анализа больших данных, машинного обучения, имитационного моделирования, извлечений знаний
Уровень коммуникаций	Рассматривается между сервисами (компонентами) на всех подуровнях
Уровень управления (CONTROL DOMAIN)	Сервисы взаимодействие программных компонентов с физическими устройствами (активами): сбор данных с помощью датчиков от физических устройств, мониторинг работы и исполнение управляющих команд на физических устройствах.
Физические системы	Физические устройства: части оборудования, оборудование, производственные линии, производственные системы (фабрики), сетевые предприятия (Connection World) Программные средства: библиотеки программных средств, базы знаний, онтологии, репозитории

С функциональной точки зрения в соответствии с концепцией платформы индустрии четвертого поколения каждый компонент сетевого предприятия представляет актив и его АО [41, 42]. Структура АО включает набор свойств (property), операций (operation) и событий (event), которые могут быть также разнесены по подмоделям (submodel) [42]. При этом информационная часть (пассивная) АО в виде набора свойств позволяет отражать динамическую информационную модель актива, а операционная (активная) часть – осуществлять взаимодействие с активами, другими АО и внешними приложениями, исполнять функциональные сервисы. В соответствии с видами активов программные агенты, которые представляются АО, разделяются на агентов продуктов и агентов ресурсов (оборудования) [43]. Цифровая платформа может быть представлена АО с набором системных сервисов, актором для которой является оператор (администратор) платформы. ЦД субъектов управления производственной системой также представляются агентами – АО.

АО как программные агенты хорошо представляются классами в объектно-ориентированной парадигме. Взаимодействие программных агентов в процессе выполнения отдельных активностей с добавлением необходимых интерфейсных классов (Boundary) и классов-сущностей, связанных с базой

данных (Entity), отображается в виде диаграммы последовательностей (Sequence Diagram). На рисунке 2 представлен фрагмент диаграммы последовательностей, отражающей процесс формирования рекомендаций по работе оборудования в соответствии с прикладным сценарием, основанным на ценности.

В данном случае в роли агента субъекта выступает агент аналитика, а в роли агента объекта – агент оборудования и как конечный продукт для производителя оборудования, и как ресурс – для предприятия-эксплуатанта. Запуск процесса осуществляется через граничный класс – клиентское приложение «Анализ данных» (Boundary), а запись полученной рекомендации в локальную базу данных через класс сущностей «Рекомендации» (Entity).

На сформированной диаграмме классов АО «Агент аналитика» реализует функции программного агента уровня функционального домена (Functional Domain). Сервис (операция) «Выполнить прогноз» с помощью одного из методов машинного обучения, например, нейронной сети, выполняет прогнозирование неисправностей, а сервис «Сформировать рекомендацию» с помощью набора правил и/или имитационной модели на основе методов агентного и дискретно-событийного моделирования, реализованной, например, в системе AnyLogic [9].

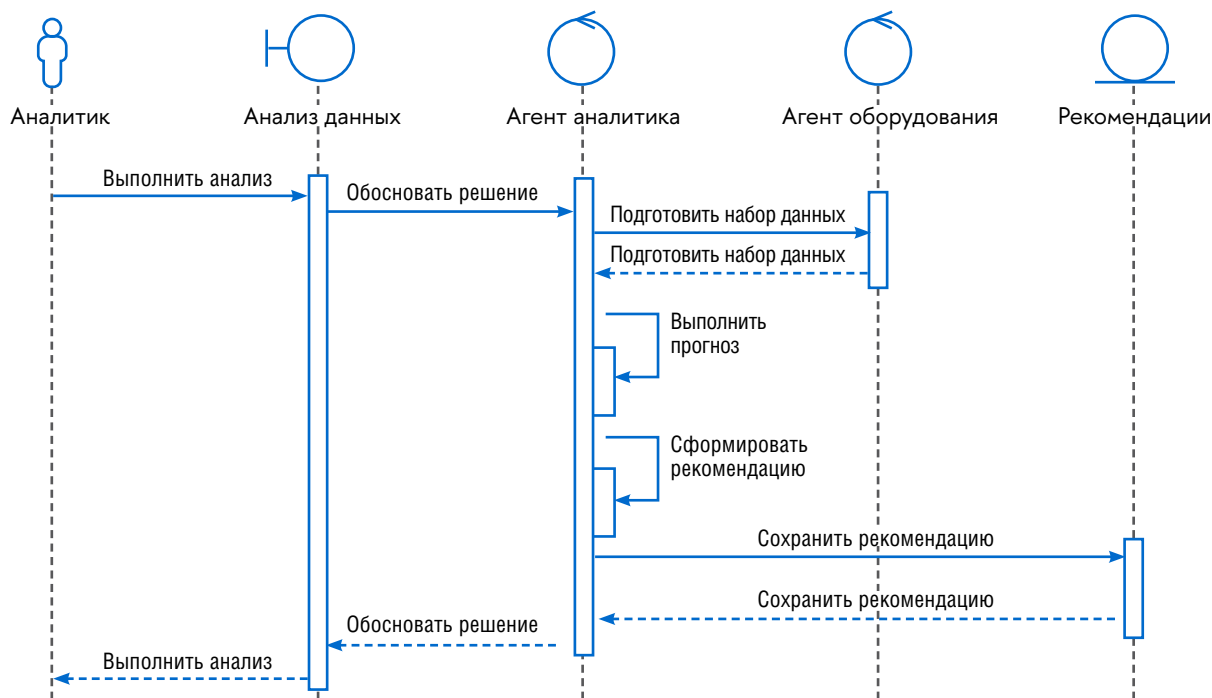


Рис. 2. Фрагмент диаграммы последовательностей для процесса формирования рекомендаций по работе оборудования.

АО «Агент оборудования» является программным агентом, который собирает данные в исторический набор данных для прогнозирования состояния и обновляет состояние актива. В этом смысле АО выполняет функции уровня управления (Control Domain). Информационные сервисы по преобразованиям форматов данных, проверке безопасности доступа и др., связанные с выполнением сервисов «Анализ данных» и «Сохранить рекомендации», вызываются внутри этих сервисов. Аналогично сервис коммуникации АО «Агент аналитика» и АО «Агент оборудования» вызывается внутри сервиса «Подготовить набор данных».

Проектирование технологической реализации (Implementation Viewpoint). Точка зрения на реализацию цифровой системы отражает физическое построение системы из создаваемых компонентов. Учитывая автономность основных компонентов — программных агентов, их распределенность в вычислительной сети, необходимость независимого обращения к инфраструктурным сервисам общей цифровой платформы, наличие локальных баз дан-

ных в составе компонентов, предлагается реализовывать МАС на основе технологии микросервисов в облачной среде контейнеризации. При этом могут использоваться архитектурные шаблоны, которые являются примерами и справочными материалами для концептуализации реальных архитектур IoT.

Применение микросервисов предлагается осуществлять на двух уровнях: на уровне АО в виде составных микросервисов и на уровне микросервисной реализации операций (сервисов, методов) АО. Во втором случае операция в информационной части АО связана через API интерфейс с микросервисом, который хранится в выделенной библиотеке АО, организованной с помощью реестра сервисов (Registry) [34].

Интеграция и развертывание микросервисов осуществляется на технологической платформе управления контейнерными микросервисами. Пример диаграммы развертывания всего программного обеспечения цифровой многоагентной системы для процесса формирования рекомендаций по работе оборудования представлен на *рисунке 3*.

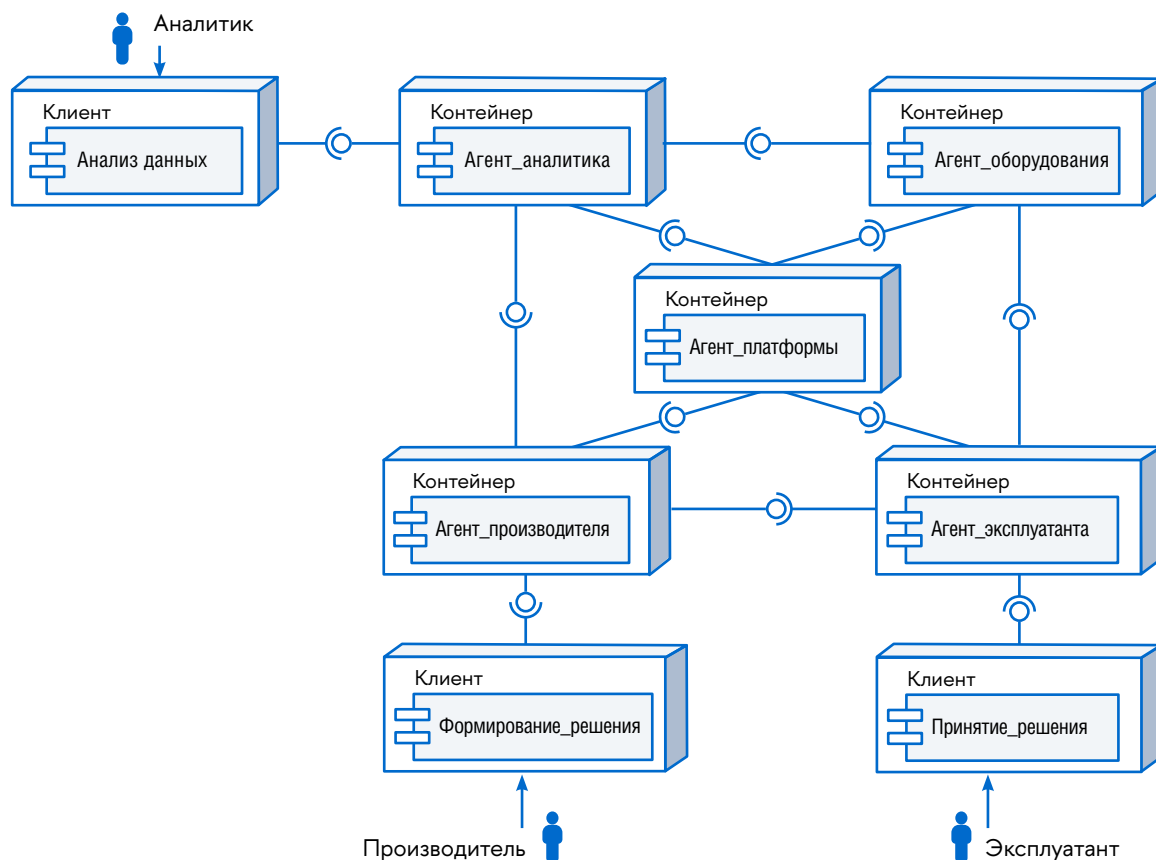


Рис. 3. Диаграмма развертывания МАС.

В качестве архитектурного шаблона реализации сетевого предприятия в концепции Промышленного Интернета (IIIA) предлагается использовать шаблон ЦД в качестве промежуточного программного слоя (между приложением и физическим миром) [14]. В этом шаблоне подразумевается построение промышленных приложений на основе ЦД, которые в свою очередь реализуются на основе типовых сервисов платформы IIoT.

3. Методика адаптации моделей проектирования многоагентной системы сетевого предприятия

В основе технологии проектирования МАС предлагается использовать методику адаптации моделей (шаблонов) проектирования. Для этого организуются базы знаний (библиотеки) моделей проектирования, которые систематизируются в соответствии с набором словарей (онтологий).

В Государственном стандарте «Структура цифровой фабрики» [20] шаблоны проектирования задаются в библиотеках классов активов цифровой фабрики, а также определяется набор словарей, в соответствии с которыми строятся классы активов. В материалах проекта «Платформа Индустрия 4.0» [21] модели (шаблоны) проектирования представляются в библиотеке функциональных блоков. В работе [22] было предложено использовать не только типовые модели прикладных сценариев из базы знаний, но также накапливать модели прецедентов, относящихся к выполненным проектам, и использовать иерархию онтологий для организации доступа к этим моделям.

В данной работе подход к использованию шаблонов проектирования МАС развивается с точки зрения их применения на всех этапах технологии проектирования. Методика адаптации моделей проектирования многоагентной системы сводится к выборке из библиотек типовых моделей и баз знаний прецедентов адекватных моделей и их последующей доработке (рис. 4).

Для отражения текущего состояния проекта создания МАС организуется репозиторий проекта, который фиксирует состояние проекта после каждого этапа. При этом также осуществляется уточнение и развитие онтологии проекта.

Организация проекта на стадии инициирования начинается с определения онтологии сетевого предприятия и выбора соответствующих словарей из набора онтологий, которые могут быть реализованы

различными органами стандартизации, консорциумами и исследовательскими проектами, и включающими онтологии верхнего уровня, проблемные онтологии и онтологии предметной области. Выбранные онтологии формируют прототип онтологии проекта (сетевого предприятия). Кроме того, по мере реализации проекта к существующей онтологии через ссылки подключаются и онтологии внешних участников сетевого предприятия. Необходимым условием их объединения является выравнивание внешних онтологий с онтологией проекта (сетевого предприятия).

Развитие репозитория и метаданных онтологии в последующем предполагает версионирование не только данных (реализуется «снимок» параметров моделей системы по состоянию на некоторый момент времени), но и онтологии сетевого предприятия. Такой вариант позволяет использовать все накопленные в исторической перспективе данные для развития проекта по созданию и функционированию сетевого предприятия. Механизмы, реализующие версионирование, выравнивание и развитие онтологий, их связывание друг с другом, должны быть реализованы как самостоятельные сервисы в рамках платформы, поддерживающей функционирование многоагентной системы.

Каждый последующий этап проектирования многоагентной системы формирует на выходе набор входных параметров для формирования следующего этапа, в рамках которого эти входные параметры служат основой для отбора новых моделей из библиотеки типовых моделей. По уровням типизации моделей, которые хранятся в библиотеке типовых моделей (шаблонов проектирования), модели могут быть как достаточно абстрактными, высокоуровневыми, так и специфичными для конкретной предметной области.

Отличительной особенностью предлагаемой методики адаптации моделей проектирования МАС сетевого предприятия является применение наряду с библиотекой типовых моделей (шаблонов проектирования) также и базы знаний, направленной на сохранение сформированных и апробированных структур и описаний реальных бизнес-моделей, бизнес-сценариев, производственных и бизнес-процессов, программных агентов (АО), наборов сервисов (моделей прецедентов).

Модели прецедентов представляются как описание кейсов, которые хранятся в системе с привязкой к описанию начальных условий (требований), а также результатов работы сетевого предприятия, каче-

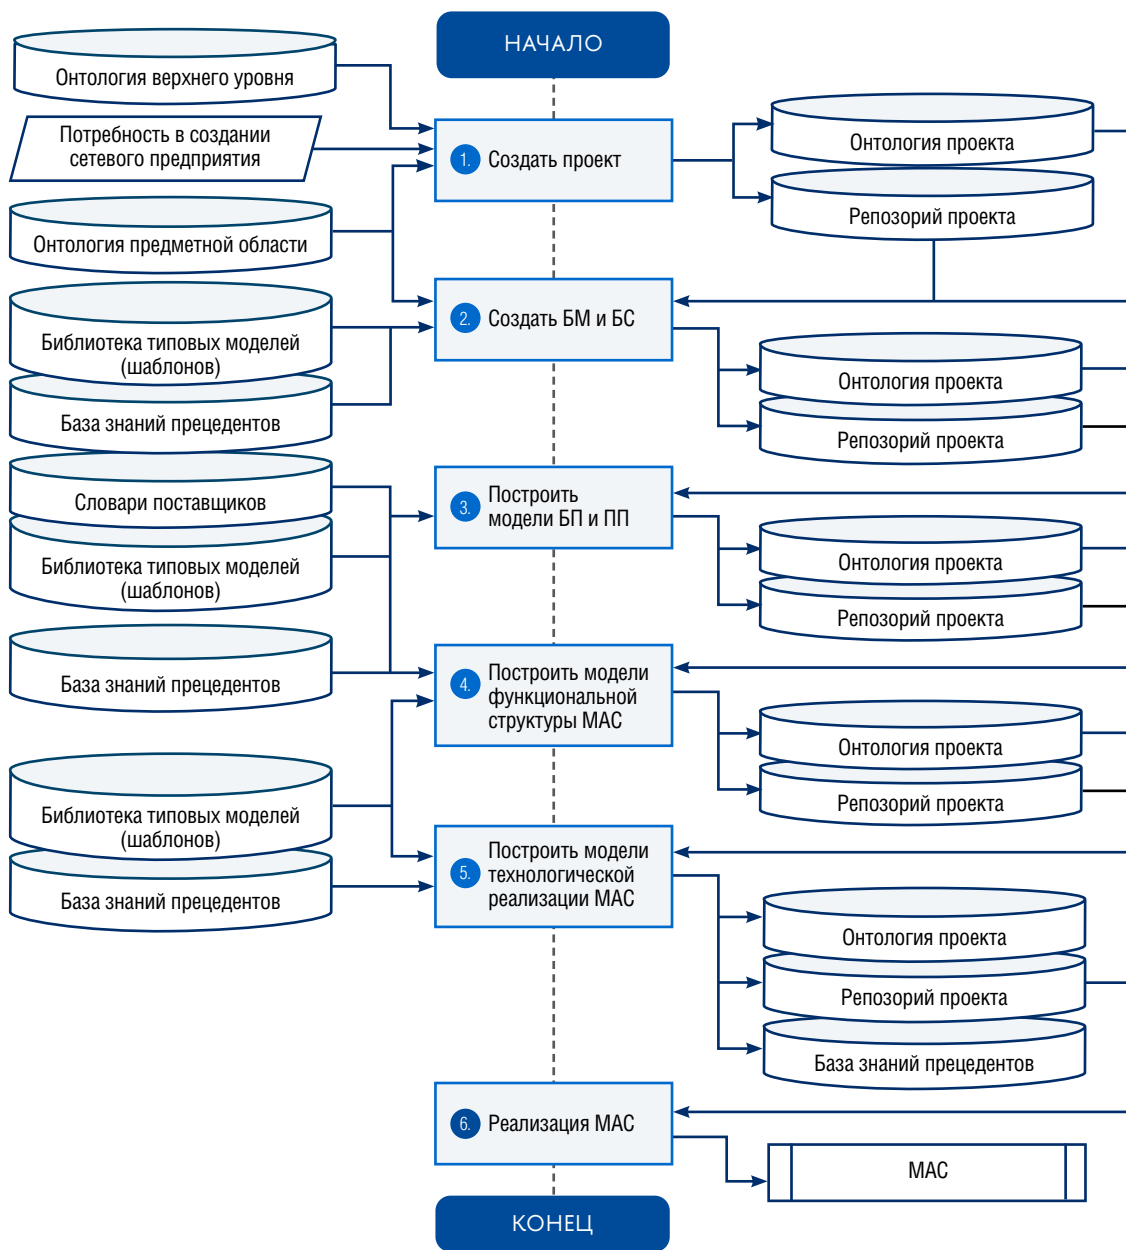


Рис. 4. Методика адаптации шаблонов проектирования MAC.

ственных характеристик выпущенных изделий (продуктов) и полученного экономического эффекта. Таким образом при поиске подходящих моделей отбираются не только типовые модели (шаблоны проектирования определенного типа), но и адаптированные, реальные модели с учётом степени близости (максимального значения подобия S) соответствующих характеристик моделей $M_i \in M$ и имеющихся входных и требуемых выходных параметров, определяющих проблемную ситуацию C^{Bx} [44]:

$$S(C^{Bx}, M) = \max_i \left(\frac{\sum_{j=1}^n w_j \cdot \text{sim}(f_j^{Bx}, f_{ij}^M)}{\sum_{j=1}^n w_j} \right), \text{ где}$$

$i = \overline{1, N}$, где N – общее число моделей, имеющихся в библиотеке и базе знаний прецедентов;
 $j = \overline{1, CR}$, где CR – постоянное число сравниваемых элементов описания (свойств, отношений);
 f_{ij}^M – j -е свойство (отношение), описывающее i -ю модель;

f_j^{Bx} – j -е свойство (отношение), описывающее набор требуемых входных или выходных параметров;
 w_j – вес j -го свойства (отношения);
sim – функция определения подобия f_j^{Bx}, f_{ij}^M .

После завершения процесса проектирования многоагентной системы результаты проектирования, отраженные в репозитории, используются для выполнения следующих этапов создания МАС: программной реализации, тестирования и внедрения. Результат процесса проектирования также заносится в базу знаний прецедентов для последующего использования в других проектах.

Заключение

В результате проведенного исследования можно сделать вывод, что применение МАС в полной мере обеспечивает создание эффективных сетевых предприятий на основе реализации принципов индустрии четвертого поколения и использования технологий ЦД и ЦН, обеспечивающих сбор информации, моделирование и планирование поведения активов, организацию и контроль исполнения производственных и бизнес-процессов.

Предлагаемые методы и технология проектирования МАС в соответствии с архитектурными фреймворками IIRA и RAMI обеспечивают на бизнес-уровне и уровне использования построение основных прикладных сценариев применения МАС и ролей акторов-агентов, формирование структур производственных и бизнес-процессов; на функциональном уровне – построение набор функциональных компонентов в виде АО и моделей их взаимодействия в общем информационном пространстве; на технологическом уровне реализации – адаптацию шаблонов микросервисной реализации к конкретным условиям построения сетевого предприятия.

Отличительной особенностью разработанной технологии проектирования является взаимосвя-

занное представление всех используемых категорий (сущностей) на различных уровнях архитектуры, что позволяет осуществлять согласованный переход между этапами проектирования МАС.

Комплексный характер предлагаемой технологии проектирования МАС взаимодействия участников сетевого предприятия обуславливает организацию эффективного участия всех заинтересованных сторон в создании сетевого предприятия, ориентированного на реализацию бизнес-стратегии с учетом адаптации типовых и наилучших моделей прикладных сценариев, функциональных компонентов и микросервисных структур с использованием библиотек шаблонов, баз знаний и онтологий. Последовательное отображение результатов проектирования между различными уровнями архитектуры в репозитории проекта позволяет в полной мере реализовывать функциональные и нефункциональные требования с учетом имеющихся информационно-вычислительных ресурсов.

Предложенная методика адаптации моделей проектирования многоагентной системы сетевого предприятия развивает подход к адаптации шаблонов МАС из библиотек типовых проектных решений и баз знаний наилучших прецедентов использования на всех этапах технологии проектирования.

Применение представленной в статье технологии проектирования МАС сетевого предприятия будет способствовать повышению уровня качества и надежности функционирования сетевого предприятия, адаптивности к динамически изменяемым потребностям бизнеса и возможностям всех заинтересованных сторон. ■

Благодарности

Исследование выполнено за счет гранта Российского научного фонда (проект № 22-11-00282¹).

Литература

1. Matthyssens P. Reconceptualizing value innovation for Industry 4.0 and the Industrial Internet of Things // Journal of Business & Industrial Marketing. 2019. Vol. 34. No. 6. P. 1203–1209. <https://doi.org/10.1108/JBIM-11-2018-0348>
2. Феофанов А.Н., Бондарчук Е.Ю., Тясто С.А. Организация виртуального предприятия – будущее производства // Вестник МГТУ «Станкин». 2018. № 3 (46). С. 101–105.
3. Müller J.M. Antecedents to digital platform usage in Industry 4.0 by established manufacturers // Sustainability. 2019. Vol. 11. No. 4. Article 1121. <https://doi.org/10.3390/su11041121>

¹ <https://rscf.ru/project/22-11-00282/>

4. Головин С.А., Лоцманов А.Н., Позднеев Б.М. Программа «Промышленность РФ 4.0» – шанс не отстать навсегда в области промышленного производства // Мир информационных технологий. 2021. № 1–2. С. 38–40.
5. Боровков А.И., Прохоров А., Лысачев М. Цифровой двойник. Анализ, тренды, мировой опыт. М.: АльянсПринт, 2020.
6. ГОСТ Р 57700.37–2021. Компьютерные модели и моделирование. Цифровые двойники изделий. Общие положения. Дата введения 2022-01-01.
7. Digital thread for smart manufacturing // National Institute of Standards and Technology, 2018. [Электронный ресурс]: <https://www.nist.gov/programs-projects/digital-thread-smart-manufacturing> (дата обращения 01.08.2024).
8. Макаров В.Л., Бахтизин А.Р., Бекларян Г.Л. Разработка цифровых двойников для производственных предприятий // Бизнес-информатика. 2019. Т. 13. № 4. С. 7–16. <http://doi.org/10.17323/1998-0663.2019.4.7.16>
9. Макаров В.Л., Бахтизин А.Р., Бекларян Г.Л., Акопов А.С. Цифровой завод: методы дискретно-событийного моделирования и оптимизации производственных характеристик // Бизнес-информатика. 2021. Т. 15. № 2. С. 7–20. <http://doi.org/10.17323/2587-814X.2021.2.7.20>
10. Городецкий В.И. Поведенческие модели киберфизических систем и групповое управление. Основные понятия // Известия ЮФУ. Технические науки. 2019. № 1 (203). С. 144–162.
11. Corsini R.R., Costa A., Fichera S., Framinan J.M. Digital twin model with machine learning and optimization for resilient production–distribution systems under disruptions // Computers & Industrial Engineering. 2024. Vol. 191. Article 110145. <https://doi.org/10.1016/j.cie.2024.110145>
12. Кабалдин Ю.Г., Шатагин Д.А., Аносов М.С., Кузьмишина А.М. Разработка цифрового двойника станка с ЧПУ на основе методов машинного обучения // Вестник Донского государственного технического университета. 2019. Т. 19. № 1. С. 45–55. <https://doi.org/10.23947/1992-5980-2019-19-1-45-55>
13. Skobelev P., Mayorov I., Simonova E., Goryanin O., Zhilyaev A., Tabachinskiy A., Yalovenko V. Development of models and methods for creating a digital twin of plant within the cyber-physical system for precision farming management // Journal of Physics: Conference Series. 2020. Vol. 1703. P. 12–22. <https://doi.org/10.1088/1742-6596/1703/1/012022>
14. The industrial internet reference architecture // Industry IoT Consortium, 2022. [Электронный ресурс]: <https://www.iiconsortium.org/wp-content/uploads/sites/2/2022/11/IIRA-v1.10.pdf> (дата обращения 01.08.2024).
15. Plattform Industrie 4.0. Reference architectural model Industrie 4.0 (RAMI4.0) – An introduction // Plattform Industrie 4.0, 2018. [Электронный ресурс]: <https://www.plattform-i40.de/IP/Redaktion/EN/Downloads/Publikation/rami40-an-introduction.html> (дата обращения 01.08.2024).
16. Seitz M., Gehlhoff F., Cruz Salazar L.A., Fay A., Vogel-Heuser B. Automation platform independent multi-agent system for robust networks of production resources in industry 4.0 // Journal of Intelligent Manufacturing. 2021. Vol. 32. P. 2023–2041. <https://doi.org/10.1007/s10845-021-01759-2>
17. Karnouskos S., Leitao P., Ribeiro L., Colombo A.W. Industrial agents as a key enabler for realizing industrial cyber-physical systems: Multiagent systems entering Industry 4.0 // IEEE Industrial Electronics Magazine. 2020. Vol. 14. No. 3. P. 18–32. <https://doi.org/10.1109/MIE.2019.2962225>
18. Vogel-Heuser B., Ocker F., Scheuer T. An approach for leveraging Digital Twins in agent-based production systems // at – Automatisierungstechnik. 2021. Vol. 69. No. 12. P. 1026–1039. <https://doi.org/10.1515/auto-2021-0081>
19. Тельнов Ю.Ф., Казаков В.А., Данилов А.В., Денисов А.А. Требования к программной реализации системы Индустрии 4.0 для создания сетевых предприятий // Программные продукты и системы. 2022. Т. 35. № 4. С. 557–571.
20. ГОСТ Р 70265.1–2022. Измерение, управление и автоматизация промышленного процесса. Структура цифровой фабрики. Часть 1. Основные положения. Дата введения 30.11.2022.
21. Discussion Paper: Usage View of the Asset Administration Shell // Plattform Industrie 4.0, 2019. [Электронный ресурс]: <https://www.plattform-i40.de/IP/Redaktion/EN/Downloads/Publikation/2019-usage-view-asset-administration-shell.html> (дата обращения 01.08.2024).
22. Тельнов Ю.Ф., Казаков В.А., Брызгалов А.А., Федоров И.Г. Методы и модели обоснования прикладных сценариев цифровизации производственных и бизнес-процессов сетевых предприятий // Бизнес-информатика. 2023. Т. 17. № 4. С. 73–93. <http://doi.org/10.17323/2587-814X.2023.4.73.93>
23. Segovia M., Garcia-Alfaro J. Design, modeling and implementation of digital twins // Sensors. 2022. Vol. 22. No. 14. Article 5396. <https://doi.org/10.3390/s22145396>
24. Bajaj M., Hedberg T. System lifecycle handler – Spinning a digital thread for manufacturing // INCOSE International Symposium. 2018. Vol. 28. No. 1. P. 1636–1650. <https://doi.org/10.1002/j.2334-5837.2018.00573.x>
25. Deep-Lynx // Idaho National Laboratory. [Электронный ресурс]: <https://github.com/idaholab/Deep-Lynx> (дата обращения 01.08.2024).
26. Bonham E., McMaster K., Thomson E., Panarotto M., Müller J.R., Isaksson O., Johansson E. Designing and integrating a digital thread system for customized additive manufacturing in multi-partner kayak production // Systems. 2020. Vol. 8. No. 4. Article 43. <https://doi.org/10.3390/systems8040043>
27. Tarassov V.B. Enterprise total agentification as a way to Industry 4.0: Forming artificial societies via goal-resource networks // Proceedings of the Fourth International Scientific Conference “Intelligent Information Technologies for Industry” (ITI’19). Advances in Intelligent Systems and Computing (AISC). 2019. Vol. 1156. P. 26–40.
28. Sakurada L., Leitao P., de la Prieta F. Agent-based asset administration shell approach for digitizing industrial assets // IFAC-PapersOnLine. 2022. Vol. 55. No. 2. P. 193–198. <https://doi.org/10.1016/j.ifacol.2022.04.192>

29. Spanoudakis N.I., Moraitis P. The agent systems methodology (ASEME): A preliminary report // Computer Science. 2007.
30. Julian V., Botti V. Developing real-time multi-agent system // Integrated Computer-Aided Engineering. 2004. Vol. 11. No. 2. P. 135–149. <https://doi.org/10.3233/ICA-2004-11204>
31. Eleftherakis G., Kefalas P., Kehris E. A methodology for developing component-based agent systems focusing on component quality // Proceedings of the Federated Conference on Computer Science and Information Systems (FedCSIS 2011), Szczecin, Poland, 18-21 September 2011. P. 561–568.
32. Digital twin and asset administration shell concepts and application in the industrial internet and Industrie 4.0 // Plattform Industrie 4.0, 2020. [Электронный ресурс]: <https://www.plattform-i40.de/IP/Redaktion/EN/Downloads/Publikation/Digital-Twin-and-Asset-Administration-Shell-Concepts.pdf> (дата обращения 01.08.2024).
33. FIPA ACL message structure specification // Foundation for Intelligent Physical Agents, 2002. [Электронный ресурс]: <http://www.fipa.org/specs/fipa00061/SC00061G.pdf> (дата обращения 01.08.2024).
34. Functional view of the asset administration shell in an Industrie 4.0 system environment // Plattform Industrie 4.0, 2021. [Электронный ресурс]: <https://www.plattform-i40.de/IP/Redaktion/DE/Downloads/Publikation/Functional-View.html> (дата обращения 01.08.2024).
35. Lewis J., Fowler M. Microservices. A definition of this new architectural term. 2014. [Электронный ресурс]: <https://martinfowler.com/articles/microservices.html> (дата обращения 01.08.2024).
36. Ричардсон К. Микросервисы. Паттерны разработки и рефакторинга: Пер. с англ. СПб.: Питер, 2019.
37. Exemplification of the Industrie 4.0 application scenario value-based service following IIRA structure // Plattform Industrie 4.0, 2017. [Электронный ресурс]: <https://www.plattform-i40.de/IP/Redaktion/EN/Downloads/Publikation/exemplification-i40-value-based-service.pdf> (дата обращения 01.08.2024).
38. Gassmann O., Csik M., Frankenberg K. The business model navigator: 55 models that will revolutionise your business. FT Press, 2014.
39. Тельнов Ю.Ф., Брызгалов А.А., Козырев П.А., Королева Д.С. Выбор типа бизнес-модели для реализации стратегии цифровой трансформации сетевого предприятия // Бизнес-информатика. 2022. Т. 16. № 4. С. 50–67. <http://doi.org/10.17323/2587-814X.2022.4.50.67>
40. Usage viewpoint of application scenario value-based service // Plattform Industrie 4.0, 2018. [Электронный ресурс]: <https://www.plattform-i40.de/I40/Redaktion/DE/Downloads/Publikation/hm-2018-usage-viewpoint.html> (дата обращения 01.08.2024).
41. ГОСТ Р 59799–2021. Умное производство. Модель эталонной архитектуры индустрии 4.0 (RAMI 4.0). Дата введения 30.04.2022.
42. Details of the asset administration shell – Part 1. The exchange of information between partners in the value chain of Industrie 4.0 // Plattform Industrie 4.0, 2022. [Электронный ресурс]: https://www.plattform-i40.de/IP/Redaktion/EN/Downloads/Publikation/Details_of_the_Asset_Administration_Shell_Part1_V3.html (дата обращения 01.08.2024).
43. Тельнов Ю.Ф., Казаков В.А., Данилов А.А., Брызгалов А.А. Разработка моделей производственных и бизнес-процессов сетевых предприятий на основе многоагентных систем // Программные продукты и системы. 2023. Т. 36. № 4. С. 632–643.
44. Kolodner J. Case-based reasoning. Morgan Kaufmann, 1993.

Об авторах

Тельнов Юрий Филиппович

д.э.н., проф.;

заведующий кафедрой прикладной информатики и информационной безопасности, Российский экономический университет им. Г.В. Плеханова, Россия, 117997, г. Москва, Стремянный пер., д. 36;

E-mail: Telnov.YUF@rea.ru

ORCID: 0000-0002-2983-8232

Казаков Василий Александрович

к.э.н.;

доцент, кафедра прикладной информатики и информационной безопасности, Российский экономический университет им. Г.В. Плеханова, Россия, 117997, г. Москва, Стремянный пер., д. 36;

E-mail: Kazakov.VA@rea.ru

ORCID: 0000-0001-8939-2087

Данилов Андрей Владимирович

старший преподаватель, кафедра прикладной информатики и информационной безопасности, Российский экономический университет им. Г.В. Плеханова, Россия, 117997, г. Москва, Стремянный пер., д. 36;

E-mail: Danilov.AV@rea.ru

ORCID: 0000-0002-0433-9701

Designing a multi-agent system for a network enterprise

Yury F. Telnov

E-mail: Telnov.YUF@rea.ru

Vasiliy A. Kazakov

E-mail: Kazakov.VA@rea.ru

Andrey V. Danilov

E-mail: Danilov.AV@rea.ru

Plekhanov Russian University of Economics, Moscow, Russia

Abstract

The necessity to enhance the efficiency of modern network enterprises based on digital platform technologies, Digital Twins, and Digital Threads determines the relevance of implementing dynamic multi-agent technologies in production practice. The architectural complexity of existing multi-agent systems (MAS) and the lack of scientific research in the field of justifying methods and tools for their creation motivate the goal of this study to develop a comprehensive MAS design technology. This technology should encompass all architectural levels and allow for the adaptation of reference and best design practices. This article analyzes the possibilities of applying Digital Twins and Digital Threads in the creation of network enterprises and proposes methods for their implementation using MAS. A design technology for MAS has been developed in accordance with the IIRA (Industrial Internet Reference Architecture) and RAMI (Reference Architectural Model Industrie 4.0) architectural frameworks, which enables the interconnected formation and display of design results across various architectural levels. At the business level, a method is proposed for formulating business requirements for MAS based on the selection and adaptation of business models and application scenarios. At the level of constructing manufacturing and business processes, a method for formulating functional requirements for MAS is presented, revealing the transition from value networks to manufacturing and business process structures. At the level of functional design of the network enterprise's multi-agent system, a method is proposed for forming key design solutions from the perspective of implementing various service categories using AAS (Asset Administrative Shells) and their specialization. At the technological implementation design level of MAS, a method for implementing software agents using a microservice software organization is proposed. The method presented for adapting reference and best MAS design models allows for the selection of appropriate design solutions from libraries of reference models and knowledge bases for subsequent refinement. This accelerates and improves the quality of the design process. The implementation of the developed technology for designing multi-agent systems will increase the adaptability of network enterprises to dynamically changing business needs, taking into account the interests and capabilities of all stakeholders.

Keywords: multi-agent systems, digital threads, digital twins, network enterprise, asset administrative shell, project ontology, microservice architecture

Citation: Telnov Yu.F., Kazakov V.A., Danilov A.V. (2024) Designing a multi-agent system for a network enterprise. *Business Informatics*, vol. 18, no. 3, pp.70–86. DOI: 10.17323/2587-814X.2024.3.70.86

References

1. Matthyssens P. (2019) Reconceptualizing value innovation for Industry 4.0 and the Industrial Internet of Things. *Journal of Business & Industrial Marketing*, vol. 34, no. 6, pp. 1203–1209. <https://doi.org/10.1108/JBIM-11-2018-0348>
2. Feofanov A.N. Bondarchuk E.Yu., Tyasto S.A. (2018) Organization of a virtual enterprise – the future of production. *Bulletin of MSTU "Stankin"*, no. 3 (46), pp. 101–105 (in Russian).

3. Müller J.M. (2019) Antecedents to digital platform usage in Industry 4.0 by established manufacturers. *Sustainability*, vol. 11, no. 4, article 1121. <https://doi.org/10.3390/su11041121>
4. Golovin S.A., Lotsmanov A.N., Pozdneev B.M. (2021) The Russian Federation Industry 4.0 program is a chance not to fall behind forever in the field of industrial production. *World of Information Technologies*, no. 1–2, pp. 38–40 (in Russian).
5. Borovkov A.I., Prokhorov A., Lysachev M. (2020) *Digital twin. Analysis, trends, world experience*. Moscow: Alliance Print (in Russian).
6. Rosstandart (2021) *National Standard of the Russian Federation GOST R 57700.37–2021. Computer models and simulation. Digital twins of products. General provisions* (in Russian).
7. National Institute of Standards and Technology (2018) *Digital thread for smart manufacturing*. Available at: <https://www.nist.gov/programs-projects/digital-thread-smart-manufacturing> (accessed 1 August 2024).
8. Makarov V.L., Bakhtizin A.R., Beklaryan G.L. (2019) Developing digital twins for production enterprises. *Business Informatics*, vol. 14, no. 1, pp. 7–16. <http://doi.org/10.17323/1998-0663.2019.4.7.16>
9. Makarov V.L., Bakhtizin A.R., Beklaryan G.L., Akopov A.S. (2021) Digital plant: methods of discrete-event modeling and optimization of production characteristics. *Business Informatics*, vol. 15, no. 2, pp. 7–20. <http://doi.org/10.17323/2587-814X.2021.2.7.20>
10. Gorodetsky V.I. (2019) Behavioral models of cyberphysical systems and group management. Basic concepts. *News of the Southern Federal University. Technical Sciences*, no. 1 (203), pp. 144–162.
11. Corsini R.R., Costa A., Fichera S., Framinan J.M. (2024) Digital twin model with machine learning and optimization for resilient production–distribution systems under disruptions. *Computers & Industrial Engineering*, vol. 191, article 110145.
12. Kabaldin Yu.G., Shatagin D.A., Anosov M.S., Kuzmishina A.M. (2019) Development of digital twin of CNC unit based on machine learning methods. *Vestnik of Don State Technical University*, vol. 19, no. 1, pp. 45–55 (in Russian). <https://doi.org/10.23947/1992-5980-2019-19-1-45-55>
13. Skobelev P., Mayorov I., Simonova E., Goryanin O., Zhilyaev A., Tabachinskiy A., Yalovenko V. (2020) Development of models and methods for creating a digital twin of plants within the cyber–physical system for precision farming management. *Journal of Physics: Conference Series*, vol. 1703, pp. 12–22. <https://doi.org/10.1088/1742-6596/1703/1/012022>
14. Industry IoT Consortium (2022) *The industrial internet reference architecture*. Available at: <https://www.iiconsortium.org/wp-content/uploads/sites/2/2022/11/IIRA-v1.10.pdf> (accessed 1 August 2024).
15. Plattform Industrie 4.0 (2018) *Plattform Industrie 4.0. Reference architectural model Industry 4.0 (RAMI4.0) – An introduction*. Available at: <https://www.plattform-i40.de/IP/Redaktion/EN/Downloads/Publikation/rami40-an-introduction.html> (accessed 1 August 2024).
16. Seitz M., Gehlhoff F., Cruz Salazar L.A., Fay A., Vogel-Heuser B. (2021) Automation platform independent multi-agent system for robust networks of production resources in industry 4.0. *Journal of Intelligent Manufacturing*, vol. 32, pp. 2023–2041.
17. Karnouskos S., Leitao P., Ribeiro L., Colombo A.W. (2020) Industrial agents as a key enabler for realizing industrial cyber–physical systems: Multiagent systems entering Industry 4.0. *IEEE Industrial Electronics Magazine*, vol. 14, no. 3, pp. 18–32. <https://doi.org/10.1109/MIE.2019.2962225>
18. Vogel-Heuser B., Ocker F., Scheuer T. (2021) An approach for leveraging Digital Twins in agent-based production systems. *at – Automatisierungstechnik*, vol. 69, no. 12, pp. 1026–1039. <https://doi.org/10.1515/auto-2021-0081>
19. Telnov Yu.F., Kazakov V.A., Danilov A.V., Denisov A.A. (2022). Requirements for the software implementation of the Industrie 4.0 system for creating network enterprises. *Software & Systems*, vol. 35, no. 4, pp. 557–571 (in Russian).
20. Rosstandart (2022) *National Standard of the Russian Federation GOST R 70265.1–2022. Industrial-process measurement, control and automation. Digital factory framework. Part 1. Basic provisions* (in Russian).
21. Plattform Industrie 4.0 (2019) *Discussion Paper: Usage View of the Asset Administration Shell*. Available at: <https://www.plattform-i40.de/IP/Redaktion/EN/Downloads/Publikation/2019-usage-view-asset-administration-shell.html> (accessed 1 August 2024).
22. Telnov Yu.F., Kazakov V.A., Bryzgalov A.A., Fiodorov I.G. (2023) Methods and models for substantiating application scenarios for the digitalization of manufacturing and business processes of network enterprises. *Business Informatics*, vol. 17, no. 4, pp. 73–93. <http://doi.org/10.17323/2587-814X.2023.4.73.93>
23. Segovia M., Garcia-Alfaro J. (2022) Design, modeling and implementation of digital twins. *Sensors*, vol. 22, no. 14, article 5396. <https://doi.org/10.3390/s22145396>
24. Bajaj M., Hedberg T. (2018) System lifecycle handler – Spinning a digital thread for manufacturing. *INCOSE International Symposium*, vol. 28, no. 1, pp. 1636–1650. <https://doi.org/10.1002/j.2334-5837.2018.00573.x>
25. Idaho National Laboratory (2020) *Deep-Lynx*. Available at: <https://github.com/idaholab/Deep-Lynx> (accessed 1 August 2024).
26. Bonham E., McMaster K., Thomson E., Panarotto M., Müller J.R., Isaksson O., Johansson E. (2020) Designing and integrating a digital thread system for customized additive manufacturing in multi-partner kayak production. *Systems*, vol. 8, no. 4, article 43. <https://doi.org/10.3390/systems8040043>
27. Tarassov V.B. (2019) Enterprise total agentification as a way to Industry 4.0: Forming artificial societies via goal–resource networks. Proceedings of the *Fourth International Scientific Conference “Intelligent Information Technologies for Industry” (IITP 19). Advances in Intelligent Systems and Computing (AISC)*, vol. 1156, pp. 26–40.
28. Sakurada L., Leitao P., de la Prieta F. (2022) Agent-based asset administration shell approach for digitizing industrial assets. *IFAC-PapersOnLine*, vol. 55, no. 2, pp. 193–198.

29. Spanoudakis N.I., Moraitis P. (2007) The agent systems methodology (ASEME): A preliminary report. *Computer Science*.
30. Julian V., Botti V. (2004) Developing real-time multi-agent system. *Integrated Computer-Aided Engineering*, vol. 11, no. 2, pp. 135–149. <https://doi.org/10.3233/ICA-2004-11204>
31. Eleftherakis G., Kefalas P., Kehris E. (2011) A methodology for developing component-based agent focusing systems on component quality. Proceedings of the *Federated Conference on Computer Science and Information Systems (FedCSIS 2011)*, Szczecin, Poland, 18–21 September 2011, pp. 561–568.
32. Plattform Industrie 4.0 (2020) *Digital Twin and Asset Administration Shell Concepts and Application in the Industrial Internet and Industrie 4.0*. Available at: <https://www.plattform-i40.de/IP/Redaktion/EN/Downloads/Publikation/Digital-Twin-and-Asset-Administration-Shell-Concepts.pdf> (accessed 1 August 2024).
33. Foundation for Intelligent Physical Agents (2002) *FIPA ACL message structure specification*. Available at: <http://www.fipa.org/specs/fipa00061/SC00061G.pdf> (accessed 1 August 2024).
34. Plattform Industrie 4.0 (2021) *Functional view of the asset administration shell in an Industrie 4.0 system environment*. Available at: <https://www.plattform-i40.de/IP/Redaktion/DE/Downloads/Publikation/Functional-View.html> (accessed 1 August 2024).
35. Lewis J., Fowler M. (2014) *Microservices. A definition of this new architectural term*. Available at: <https://martinfowler.com/articles/microservices.html> (accessed 1 August 2024).
36. Richardson C. (2018) *Microservices Patterns: With examples in Java*. Manning Publications.
37. Plattform Industrie 4.0 (2017) *Exemplification of the Industrie 4.0 application scenario value-based service following IIRA structure*. Available at: <https://www.plattform-i40.de/IP/Redaktion/EN/Downloads/Publikation/exemplification-i40-value-based-service.pdf> (accessed 1 August 2024).
38. Gassmann O., Csik M., Frankenberg K. (2014) *The business model navigator: 55 models that will revolutionise your business*. FT Press.
39. Telnov Yu.F., Bryzgalov A.A., Kozyrev P.A., Koroleva D.S. (2022) Choosing the type of business model to implement the digital transformation strategy of a network enterprise. *Business Informatics*, vol. 16, no. 4, pp. 50–67. <http://doi.org/10.17323/2587-814X.2022.4.50.67>
40. Plattform Industrie 4.0 (2018) *Usage viewpoint of application scenario value-based service*. Available at: <https://www.plattform-i40.de/I40/Redaktion/DE/Downloads/Publikation/hm-2018-usage-viewpoint.html> (accessed 1 August 2024).
41. Rosstandart (2021) *National Standard of the Russian Federation GOST R 59799–2021. Smart manufacturing. Reference architecture model industry 4.0 (RAMI 4.0)* (in Russian).
42. Plattform Industrie 4.0 (2022) *Details of the asset administration shell – Part 1. The exchange of information between partners in the value chain of Industrie 4.0*. Available at: https://www.plattform-i40.de/IP/Redaktion/EN/Downloads/Publikation/Details_of_the_Asset_Administration_Shell_Part1_V3.html (accessed 1 August 2024).
43. Telnov Yu.F., Kazakov V.A., Danilov A.V., Bryzgalov A.A. (2023) Network enterprises: Production and business process models based on multi-agent systems. *Software & Systems*, vol. 36, no. 4, pp. 632–643.
44. Kolodner J. (1993) *Case-based reasoning*. Morgan Kaufmann.

About the authors

Yury F. Telnov

Dr. Sci. (Econ.), Prof.;

Head of the Department of Applied Informatics and Information Security, Plekhanov Russian University of Economics, 36, Stremyanny Lane, Moscow 117997, Russia;

E-mail: Telnov.YUF@rea.ru

ORCID: 0000-0002-2983-8232

Vasily A. Kazakov

Cand. Sci. (Econ.);

Associate Professor, Department of Applied Informatics and Information Security, Plekhanov Russian University of Economics, 36, Stremyanny Lane, Moscow 117997, Russia;

E-mail: Kazakov.VA@rea.ru

ORCID: 0000-0001-8939-2087

Andrey V. Danilov

Senior Lecturer, Department of Applied Information Technologies and Information Security, Plekhanov Russian University of Economics, 36, Stremyanny Lane, Moscow 117997, Russia;

E-mail: Danilov.AV@rea.ru

ORCID: 0000-0002-0433-9701

DOI: 10.17323/2587-814X.2024.3.87.107

The impact of artificial intelligence on re-purchase intentions: the mediation approach

Raed N. Alkaied 

E-mail: Raedalkaied@bau.edu.jo

Shadi A. Khattab 

E-mail: Shadikhattab@bau.edu.jo

Ishaq M. Al Shaar 

E-mail: I.shaar@bau.edu.jo

Mohammed K. Abu Zaid 

E-mail: Mohammed_abu_zaid@bau.edu.jo

Sakher A.I. Al-Bazaiah 

E-mail: bazaiah1@bau.edu.jo

Al Balqa Applied University, Salt, Jordan

Abstract

Purchases made on online platforms have heavily incorporated artificial intelligence (AI) to shape consumer purchasing behavior. To investigate re-purchase intentions, this study combines AI, social media engagement, conversion rate optimization, brand experience and brand preference. A survey was conducted with a questionnaire sent to 355 people who had at least once purchased or used services offered online from any site associated with aviation. The questionnaire was analyzed using structural equation modeling. Utilizing Amos V.22, the study hypotheses were assessed. The empirical results show that social media engagement, brand experience, brand preference and conversion rate optimization were all impacted by AI. Conversion rate optimization and social media interaction also have an impact on brand preference and experience. Re-purchase intention is influenced by brand preference and brand experience. Additionally, the association between AI and re-purchase intention was mediated by social media engagement, brand experience, conversion rate optimization and brand preference. The study will support airline companies in developing AI and creating more effective branding and marketing campaigns to increase customer intention to re-purchase. This study discovered that the use of AI in

marketing significantly improved brand preference, which subsequently affected consumers' desire to make additional purchases. Furthermore, to improve long-term commercial performance and brand attractiveness, the airline should focus brand-building efforts on AI. Thus, the airline ought to make greater investments in AI and booking service technology, both to draw in new business and to strengthen existing ones.

Keywords: artificial intelligence, conversion rate optimization, social media engagement, brand experience, brand preference, re-purchase intention

Citation: Alkaied R.N., Khattab S.A., Al Shaar I.M., Abu Zaid M.K., Al-Bazaiah S.A.I. (2024) The impact of artificial intelligence on re-purchase intentions: the mediation approach. *Business Informatics*, vol. 18, no. 3, pp. 87–107. DOI: 10.17323/2587-814X.2024.3.87.107

Introduction

Every facet of our real lives – both individually and collectively – has been impacted by technology, including both the real and virtual worlds [1]. Among its most crucial concerns was the various methods for increasing public awareness. According to predictions made by [2], the economic impact of artificial intelligence (AI) would increase from \$20.82 billion in 2020 to \$15 trillion in 2030.

One of the most significant technical advancements is AI, whose applications have completely transformed a wide range of societal fields [3, 4]. AI technologies are described as “natural genetic predisposition genetic inheritance or learned skills that form the essence of individual personalities” [5]. AI technologies rely on pre-defined computer programs, algorithms, and function similarly to the human mind in making decisions [6, 7].

Businesses may improve the customer experience by identifying innovation, developing strategies and identifying long-term solutions through business automation that leverages AI. Critical decisions can also be made with AI in a corporate environment that is surprisingly competitive and unstable [2].

According to [8], AI chatbot content recommendations are now a part of marketing AI activities. They also help to boost customer engagement on social media platforms, give online users a personalized experience and increase the likelihood that suggested goods and services will be purchased [2, 9]. For instance, Amazon is leading the way in utilizing AI technology and extending its use beyond object recognition, language understanding and conversation to include search and suggestion. This increases the conversion rate toward product purchases

by personalizing and refining the recommendations of related and complementary products in real-time [10]. AI-driven digital businesses are attempting to interact with clients on social media in an effort to build, maintain and nurture enduring client relationship [11]. As a result, it is important to recognize the growing significance of online shopping. By 2025, the worldwide e-commerce market is expected to reach \$1.2 trillion, growing at a rate three times faster than traditional commerce [12]. Marketers use customer engagement to get customers' attention by providing them with valuable knowledge [13]. Through their customer experience, marketers want to keep their goods or services at the front of consumers' minds. Social networking is one of the best platforms for connecting with customers. Customers should be able to use social media to interact with businesses [14]. Clients that are happy with the goods and services will write content for social media platforms. Companies may alter their current goods and services in response to negative customer feedback on social media [15]. These days, it's commonplace to see creative marketing. Marketers can expedite intelligent marketing by utilizing AI [9]. In order to boost the rate of conversion (from user to customer), businesses can also track customer opinions on social media and utilize that data to tailor marketing initiatives for each individual customer [16].

Social media consumer conversion is a continuous process rather than a one-time occurrence. The association between conversion rate and customer purchase intentions is not well understood [9]. Businesses are utilizing AI to forecast customer behavior as more and more consumers make purchases online. With a major influence on consumer decision-making, AI has been a crucial part of the digital transformation. AI technolo-

gies can be leveraged to entice consumers to make exciting new purchases [17].

AI technology has the potential to enhance user experiences in interactive environments and foster faster response times for products and services [18].

According to [19], intelligent service bots have become increasingly prevalent in gauging customer experiences with products and services in recent times. One of the primary motivations for implementing AI is to enhance customer experience, as AI technologies are becoming a more significant aspect of our daily lives and form the foundation for novel value propositions and unique consumer experiences. Delivering improved customer experiences is therefore essential for strengthening the bond between consumers and brands as well as for promoting brand distinctiveness [20].

Thus, businesses employ hardware, software, networks and AI for a range of objectives, including improving customer experience and fostering continuous harmonization and collaboration among stakeholders [21]. Based on whether the AI offers the services that customers have asked for, the consumer experience will differ. According to [22], customers felt more intellectual and sensory experiences when AI offered the services, and vice versa, when humans supplied the services, customers felt more emotional experiences. Even though AI and human services differ in how they are experienced, AI services are crucial to giving clients an enjoyable journey [23].

If customers receive the proper experience from the company, they feel content and joyful thanks to AI procedures [24]. A pleasant customer experience will create positive value for the company in terms of brand preference, helping companies achieve excellence and competitive advantage [25]. Research on how AI affects brands is scarce and dispersed, despite the significance of AI for consumer-brand connections. While improvements in technology may save customers time and effort during transactions, errors and a lack of human support can still generate dissatisfaction [20]. Therefore, it's still unknown how AI will affect branding.

Most marketers lack a strong knowledge of AI and how it may assist both organizations and consumers, despite expanding research in this field [26]. A road map for effective AI initiatives is necessary, according to comprehensive AI frameworks and empirical research, particularly in the area of digital marketing [27]. Furthermore, the literature that has already been written has not looked at AI in the setting of interactive marketing, where sellers and buyers work together to impact marketing choices that encourage active consumer participation, commu-

nication and interaction [18]. Accordingly, the real value of AI is not in the technology per se, but rather in the way it is applied to build robust, interactive buyer-seller interactions that are based on generating value together and keeping commitments [28]. There are few studies assessing how AI and digital innovations affect social media customer involvement. More investigation into the ways AI-powered marketing tools affect consumer views, opinions, and actions is advised by [29].

1. Literature review and hypothesis development

1.1. Artificial intelligence

Nowadays, online platforms are used for the majority of the shopping process. When it comes to buying things online, trust and client awareness are crucial factors. Organizations are working to get the most out of the enhanced trust and intent that customers have toward specific products and services as a result of the experience that AI has given them [30]. Studying client habits, purchasing patterns, behaviors and choices are only a few of the activities and functions where AI in marketing has been demonstrated to be widely applied [7]. Personalizing advertising messaging [31] in addition to tailoring items and other offerings to fit client demands and managing and altering prices in real-time in response to customer demand, rivals and supply chains [32].

AI provides virtual experiences to customers who are sitting in the right places, helping them make a final purchase decision. Because AI is a cutting-edge technology that selects the best choice from a range of options provided with a variety of facts through exchange and combinations, it saves customers money [7]. AI-powered augmented reality applications let consumers view things in new ways and facilitate enhanced decision-making [33]. Businesses have integrated most AI-enabled technology to offer clients the best and most customized solutions [34].

Thanks to AI's cutting-edge technologies, customers can easily understand their purchase preferences. Previous research [30, 35, 36] indicates that AI aims to develop software with human-like problem-solving capabilities that enhances ability to make decisions about purchase intention. Studies show that people who visit websites with the integration of AI feel more confident when making judgments about what to buy, which lowers the risk [37]. AI is a lightweight technology that helps consumers make informed purchasing decisions. Because consumers are more interested in AI's promise and capabilities, they are using it widely [30]. AI's ability to manage the massive

amount of relevant, high-quality data that consumers may access, and that is tied to their purchase activities, determines both its usefulness and efficacy [38, 39].

Because AI is an advanced technology, customers often discover the best virtual experience when they make purchases from online retailers. Customers' virtual experience is important whenever it concerns their purchasing intentions, and studies have indicated that positive virtual experiences affect consumers' intentions to purchase [33].

1.2. Artificial intelligence and social media engagement

Engaging customers and building customer loyalty is critical for providers who value face-to-face communication with consumers. Few studies have examined customer engagement from a technological perspective, even though several social and technological factors have been demonstrated to support customer engagement [40]. Research [40, 41] suggests that AI can enhance moral consumer behavior. Businesses that use AI may change the social media buying experience to give shoppers a social media platform experience, as AI has greatly changed consumer behavior [42].

By using AI to forecast consumer behavior and interact with customers on social media platforms, these businesses may increase the effectiveness of their online marketing campaigns and use it to make more analytical judgments [2, 17]. For instance, AI closes the gap between companies and customers by gathering and evaluating data about goods and services [43]. This changes the online buying experience. AI also offers solutions for a range of problems pertaining to social networking. For instance, evaluating the vast volume of data produced by social media platforms may cause stress for sales staff [2].

To address these issues, businesses utilizing AI may employ a range of AI-based methods for predictive analysis in marketing [9]. The use of AI in social media platforms is one of the outside variables that is believed to motivate consumers to engage with these platforms more. For instance, users can join any community of interest on e-commerce platforms like Facebook, Taobao and Etsy. From there, they can engage with other users, follow other buyers and sellers who share their interests, look up information about products and/or share their own related buying experiences [12]. According to [27], there is a connection across AI and dynamic marketing when real-time technologies are utilized to build personalized, response-focused relationships between buyers and sellers. If businesses provide several options for evaluating the qualities of their products or services, in-

tegrating AI increases the likelihood that customers will engage on social media platforms [44]. Thus, it can be assumed that:

H1: AI has a positive effect on social media engagement.

1.3. Artificial intelligence and conversion rate optimization

AI has been used in purchasing procedures to give customers more dependable, individualized services [10]. Wang and Lei [18] claim that artificial intelligence AI technology can manage interactions between consumers and goods or services as well as quickly responding to client demands in interactive environments. As part of AI marketing efforts, chatbots, content features and buyer sales recognition are artificially becoming autonomous [8].

Online social networking platforms give businesses the ability to interact with a wide variety of customers and customize their products to meet their needs [45]. To improve digital marketers' ability to use AI to raise visitor conversion rates, it is crucial to study the buying habits of customers on social networking sites [9]. Businesses on social networking platforms also use AI to entice consumers and win them over as devoted customers [2]. In order to elevate the rate of conversion (from user to customer), businesses can also track consumer behavior on social media and use that data to craft customized promotional campaigns for each individual customer [9, 16]. AI encompasses more than just conversation, language comprehension and object identification; it also includes consumer recommendation and research. This increases the rate at which products are purchased by improving the suggestion of related and complementary products in a more customized and real-time manner [10].

The relationship between the client and the business may be strengthened by AI-based social media initiatives that increase consumer involvement, feedback, and conversion [15]. AI could encourage people to buy goods and services by improving their interaction with social media adverts [2]. Because AI on social networking platforms allows users to examine items or services through the platform, it also encourages prospective consumers to buy a certain product or service. Companies can utilize AI to differentiate their goods or services from competitors' offerings and entice consumers to purchase them. The [46] have reported that prior research has furnished empirical proof of the affirmative correlation between social networking sites and consumer conversion rate. Thus, it can be assumed that:

H2: AI has a positive effect on conversion rate optimization.

1.4. Social media engagement and brand experience

According to [47], there are two types of consumer engagement: uncontrolled (word-of-mouth) and controlled (corporate-sponsored). By sharing knowledge with others, such as through sharing across online platforms, consumers can contribute to the improvement of customer experiences with brands [14]. Satisfactory brand buying experiences can be facilitated by customer engagement [48, 49]. According to research by [20], mobile applications for customer interaction have a favorable impact on customer equity and increase the likelihood that current consumers will make another purchase. A variety of studies [50–52] have also investigated the connection between brand experiences and customer engagement, concluding that there is a substantial impact from consumer involvement. Based on the explanation provided by [51] regarding how customer engagement functions as a mediator to enhance the brand experience and encourage repeat purchases, thus, it can be assumed that:

H3: Social media engagement has a positive effect on brand experience.

1.5. Conversion rate optimization and brand experience

Interaction with customers is important to every business. The shopping experience for customers in a virtual environment is mediated by technology. With the introduction of augmented reality, mixed reality and virtual reality technology, a new environment integrating virtual and physical elements at various levels has emerged. The customer experience environment is changing into new kinds of hybrid experiences as a result of the growth of mobile and wearable devices as well as highly dynamic physical-virtual interactions [9, 53]. Since shoppers of these businesses are more likely to express their favorable experiences with the brand in question, marketers must engage customers and offer a unique social media experience. This is because the most satisfied customers are those who are more involved on social media [2, 11].

72% of businesses prioritize improving the customer experience and appealing to customers throughout the buying process is a marketing trend. Businesses are concentrating on offering value-added ideas to create the greatest possible customer experiences in the digital age [53].

The consumer experience is being drastically changed by emerging technologies including the Internet of Things (IoT), chatbots, bots, augmented reality (AR), virtual reality (VR), mixed reality (MR) and virtual assistants, which are usually powered by AI. Concerns about privacy for clients who would rather buy goods and services online and through social media are crucial when trying to find a consistent way to incorporate the client experience. Instead, marketers must comprehend how digital technologies affect the customer experiences [54].

The cognitive component ingrained in the customer's relation with the brand is satisfaction. Positive remarks affect other users' cognitive processes [55]. Key clients may be drawn to interactive involvement and end up giving products or services favorable reviews [56]. Different client categories will likely require different approaches to customer interaction; after all, in the digital age, consumer engagement is essential [57]. For marketers to comprehend customer segmentation, they must create strong social media analytics. These analyses' findings show how marketers may use social media platforms to sway consumers and raise conversion rates, which in turn have a big impact on customer happiness. For businesses to increase sales, it is essential to comprehend users' attitudes regarding digital media [58]. Thus, it can be assumed that:

H4: Conversion rate optimization has a positive effect on brand experience.

1.6. Brand experience and brand preference

According to [50, 59], brand experience is defined as "the consumer's subjective responses (sensations, feelings and perceptions) and behavioral responses elicited by brand-related stimuli that are part of the brand's design, identity, packaging, communications and surrounding environment." Four categories can be used to categorize brand experience: sensory, intellectual, emotional and behavioral. The stimulation that a brand provides through the senses of sight, sound, smell, taste and touch is known as the sensory brand experience [60]. The emotions evoked by a brand are known as the emotional brand experience. According to [61], behavioral brand experience encompasses actual experiences, behaviors and brand interactions, whereas intellectual brand experiences refer to a company's capacity to elicit thought from consumers.

Perceptions of brand qualities by consumers influence their preferences, which in turn affect their intent and brand selections. As a result, according to [62], brand preference is a pattern of behavior that represents customers' views about the brand. Customers like a spe-

cific brand whenever they have positive thoughts regarding it, and their perceptions of a brand's features impact their preferences, which in turn determine their intentions and selection of brands [20].

Brand experience has an impact on brand loyalty and affection, according to [59].

Positive brand experiences help customers form strong bonds with brands and grow to love them [63]. Brand experience has an impact on brand preferences, according to [20]. The notion of brand experience was validated by [64], who found that brand experience is a key indicator of brand preference. It has been noted that brand preference and memorable brand experiences are related. A memorable brand experience positively influences brand preference, which then positively impacts usage intentions, word-of-mouth and readiness to pay more, according to the findings of a study conducted by [65]. Therefore, it can be assumed that:

H5: Brand experience has a positive effect on brand preference.

1.7. Brand preference and re-purchase intention

When comparing a company's products to those of other companies, consumers' preferences toward certain products determine their brand preference. In terms of capturing customers' hearts so they will re-purchase the company's brand, it can be said that this preference for a brand is the first phase of branding [66].

Re-purchase intention is the consumer's plan to carry out the behavioral act of purchasing a brand again [67, 68]. It is the process by which clients choose to re-purchase services or goods from the same company [69]. This probably happens because customers can buy the same thing again. Re-purchase intentions, according to [70], refers to a customer's willingness to make additional purchases from the same merchant or supplier, whereas re-purchases are, in theory, actual actions. According to Sullivan and Kim [71], reactionary intention to re-purchase can be understood as a consumer's wish to reevaluate the brand in light of their present circumstances. The intention to re-purchase is of particular relevance to marketers since it may result from the influence of prior purchases. Re-purchase intention is likely to be lower if consumers' perceptions of price, experience, brand and fulfillment differ from what they paid and received [70].

Customers are more likely to repeat purchases when they have a preferred brand. Only when consumers feel positive about a brand will they choose to re-purchase it and replicate their experience [23]. Additionally, research indicates that customers' decisions to buy

a product are influenced by their information processing, which is reflected in their choice of a brand [70]. According to [62], re-purchase intention was positively impacted by brand preference. The [66] claim that a product's identity as a brand and preference are responsible for its resurgence in popularity. Research from Ho & Chow [20] has shown that brand preference affects consumers' likelihood to make more purchases. According to [64], brand preference and re-purchase intentions were positively correlated statistically. The [65] investigation confirmed that brand preference affects re-purchase intentions. Thus, it can be assumed that:

H6: Brand preference has a positive effect on re-purchase intentions.

1.8. Brand experience and re-purchase intentions

Consumer brand experience precedes actual purchase because favorable brand experiences have a positive and significant impact on consumer purchase intentions, and prior experiences become memorable during brand purchase [72, 73]. The positive feelings that consumers have for a brand can impact their intention to make a purchase if they are feeling good about it [74]. This suggests that consumers' behavioral intentions may grow as a result of their brand experience. According to [62], a favorable brand experience can affect the propensity to re-purchase. According to [70], the re-purchase intention is positively impacted by brand experience. Therefore, it can be assumed that:

H7: Brand experience has a positive effect on re-purchase intentions.

2. Methodology

2.1. Procedures and respondents

Data was gathered from Jordanian users of the internet who have at least once made a purchase or used services available online from any website relevant to aviation. An additional eight weeks were added to the data gathering period.

The data was gathered using convenience sampling, which is a non-random sampling technique [75]. Based on their actual usage of the web services for the websites of the aviation companies, the study's respondents were selected. A non-probability sampling design was used in this investigation, meaning that there are no odds associated with any member of the study population being selected as a sample subject [76]. The questionnaire was created in English, therefore with the assistance of two multilingual specialists, we translated it first into Arabic

before translating it back into English. The individuals who participated were informed that they might opt out of the study at any moment and that participation in it was entirely optional. Pens were used by the participants to rate the questions. The participants' answers to the surveys were gathered directly. A survey was disregarded and the next one was chosen if it was not completed correctly. Surveys filled out by participants who had no prior e-commerce experience were disqualified. An amount of 800 questionnaires together with cover letters were given out, and 387 respondents brought the completed forms back. Thirty-two questionnaires were eliminated due to incomplete information. In the end, 355 replies were considered for study. 44.4% of respondents responded.

2.2. Measures

A five-point Likert scale, with 1 denoting "strongly disagree" and 5 denoting "strongly agree," was used to rate each scale item.

Artificial Intelligence: [2, 45] produced a 6-item scale that we used to gauge technological advancements in AI. "Multiple types of data about customers, such as sales, purchases, or demographic and behavioral data," was the sample item.

Social Media Engagement: An instrument consisting of five items was created by [2, 14] to gauge consumer participation on social media. "Using social networking websites sparks my curiosity about brands" was the sample item.

Conversion Rate Optimization: Utilizing a 4-item scale created by [2, 46], conversion rate optimization was examined. "I am influenced to buy products and services by web-based promotions and messages on social networking sites" was the sample item.

Brand Experience: We used a 5-item measure that was created by [20, 24]. The sample item was, "the experience of using AI".

Brand Preference: A 5-item scale created by [20, 77] was used to measure brand preference. The sample item was, "preferred brand over any other brand."

Re-purchase Intention: We used a 4-item measure that was created by [2, 20]. To gauge technological advancements in AI. To gauge the re-purchase intentions of the consumer. "I plan to keep using the site that I frequently use for booking flights" was the sample item.

2.3. Reliability and validity

Factor analysis, average variance extracted (AVE) and composite reliability (CR) are computed using AMOS. One method for condensing a large range of variables

into a smaller number of factors is a confirmatory factor analysis. Using this method, all variables' highest common variance is extracted, and the results are combined into a single score. Confirmatory factor analysis also known as a CFA, was carried out to examine the multiple-item measures' discriminant validity, convergent validity and reliability. According to [78] recommendation, the analysis's findings supported each measuring scale's convergent validity. The theoretical constructs appear to have convergent validity, as indicated by the statistically significant ($p < 0.05$) factor loadings of 0.60 to 0.90 for all indicators in their respective constructs, as presented in *Table 1* [79]. Furthermore, every construct's average variance extracted (AVE) is greater than the minimal value of 0.5 that is advised [80]. The average variance extracted (AVE) results were used to evaluate the discriminant validity. According to the results of *Table 1*, the square roots of AVE are greater than correlations, which suggests that the discriminant validity is satisfactory [80]. The [81] suggested using composite reliability (CR) to assess the dependability of the measures. *Table 1* shows the discriminant and convergent validity as well as the reliability across all reflection measures based on CR values that are over the 0.70 threshold.

Cronbach's alpha is calculated using the average correlations between the concept-measuring items. The internal consistency reliability increases with Cronbach's alpha's proximity to 1 [76]. The Cronbach's coefficient is employed to assess the reliability of each concept. It is a metric for assessing a multi-item scale's internal consistency. According to the SPSS results, all alpha coefficient values are higher than 0.7, indicating that the measuring scales' reliability is sufficient [82].

3. Results

3.1. Descriptive statistics

The mean, standard deviations, and correlation matrix are the primary descriptive statistics that were utilized to characterize the study constructs. The study model constructs' mean scores ranged from 3.46 to 3.80, as shown in *Table 2*. Furthermore, the correlations showed that the research variables had a strong link and ranged from 3.46 to 3.80.

3.2. Research model and hypotheses

The links between the constructs were estimated by the application of structural equation modeling (SEM). Amos V.22 was used to calculate SEM estimates. Regarding the proposed connections, the path that leads from AI to Social Media Engagement has a coefficient

Table 1.

Confirmatory factor analysis & reliabilities

Construct	Items	Loading factor	t-value	CR	AVE	α
Artificial Intelligence	AI1	0.719		0.881	0.557	0.898
	AI2	0.868	15.523			
	AI3	0.892	15.833			
	AI4	0.668	11.994			
	AI5	0.633	11.345			
	AI6	0.654	11.739			
Social Media Engagement	SME1	0.777		0.850	0.532	0.858
	SME 2	0.803	14.679			
	SME 3	0.716	13.066			
	SME 4	0.63	11.32			
	SME 5	0.71	13.013			
Conversion Rate Optimization	CRO1	0.813		0.856	0.598	0.855
	CRO2	0.82	16.009			
	CRO3	0.724	13.986			
	CRO4	0.732	14.171			
Brand Experience	BE1	0.603		0.861	0.557	0.852
	BE2	0.735	10.932			
	BE3	0.876	12.181			
	BE 4	0.822	11.766			
	BE 5	0.663	10.159			
Brand Preference	BR1	0.814		0.897	0.635	0.897
	BR2	0.726	14.915			
	BR3	0.816	17.39			
	BR4	0.792	14.723			
	BR5	0.833	17.783			
Re-purchase Intention	RI1	0.773		0.827	0.546	0.930
	RI2	0.788	15.291			
	RI3	0.698	13.308			
	RI4	0.691	13.145			

of 0.449 ($p < 0.01$) regarding the linkages. Therefore, the positive correlation implies that H1 is validated. Furthermore, the results confirm hypothesis H2 by demonstrating that the relationship among AI and Conversion Rate Optimization ($\beta = 0.305, p > 0.01$) follows the expected direction. Furthermore, the findings demonstrate that Brand Experience is positively and significantly impacted by Social Media Engagement ($\beta = 0.317, t = 5.519, p < 0.01$) and positively and significantly impacted by Conversion Rate Optimization ($\beta = 0.346, t = 5.592, p < 0.01$). As a result, theories H3 and H4 are validated. Additionally, according to the findings, Brand Experience significantly and favorably influences Brand Preference ($\beta = 0.684, t = 9.419, p < 0.01$). Re-purchase Intention is favorably correlated with both Brand Preference and Brand Experience, supporting hypotheses H6 and H7.

3.3. Mediating test

5000 bootstrap samples were chosen, with a 95% confidence level. According to the study model, there are four ways that indirect impacts can manifest.

- ◆ H8 AI → Social Media Engagement → Brand Experience → e-purchase Intention
- ◆ H9 AI → Social Media Engagement → Brand Experience → Brand Preference → Re-purchase Intention
- ◆ H10 AI → Conversion Rate Optimization → Brand Experience → Re-purchase Intention
- ◆ H11 AI → Conversion Rate Optimization → Brand Experience → Brand Preference → Re-purchase Intention

The product of the route coefficients between AI and Re-purchase Intention was used to determine the indirect effect of AI on Re-purchase Intentions. Significant indirect effects of AI on Re-purchase Intentions were discovered from the study model for the four paths. To be more precise, there is an indirect effect by means of Conversion Rate Optimization and Brand Experience ($\beta = 0.020, p < 0.01$), Social Media Engagement and Brand Experience ($\beta = 0.027, p < 0.01$), and Social Media Engagement, Brand Experience and Brand Preference ($\beta = 0.068, p < 0.01$). Lastly, there is an indirect effect through Conversion Rate Optimization, Brand Experience and Brand Preference ($\beta = 0.050, p < 0.01$). Therefore, the influence of AI on Re-purchase Intentions was mediated by Social Media Engagement, Brand Experience, Brand Preference and Conversion Rate Optimization.

Bootstrap approaches were used to evaluate the indirect effect of AI on Re-purchase Intention.

Table 2.

Means, standard deviations, and correlations for the study variables

Study variables	Mean	Std. dev	1	2	3	4	5	6
Artificial Intelligence	3.80	0.665	0.746					
Social Media Engagement	3.53	0.715	0.315*	0.729				
Conversion Rate Optimization	3.46	0.833	0.225*	0.313*	0.773			
Brand Experience	3.83	0.687	0.282*	0.307*	0.366*	0.746		
Brand Preference	3.56	0.709	0.282*	0.411*	0.433*	0.611*	0.796	
Re-purchase Intention	3.65	0.657	0.335*	0.392*	0.333*	0.620*	0.754*	0.740

Notes: * $p < 0.01$; square root of AVE is on the diagonal

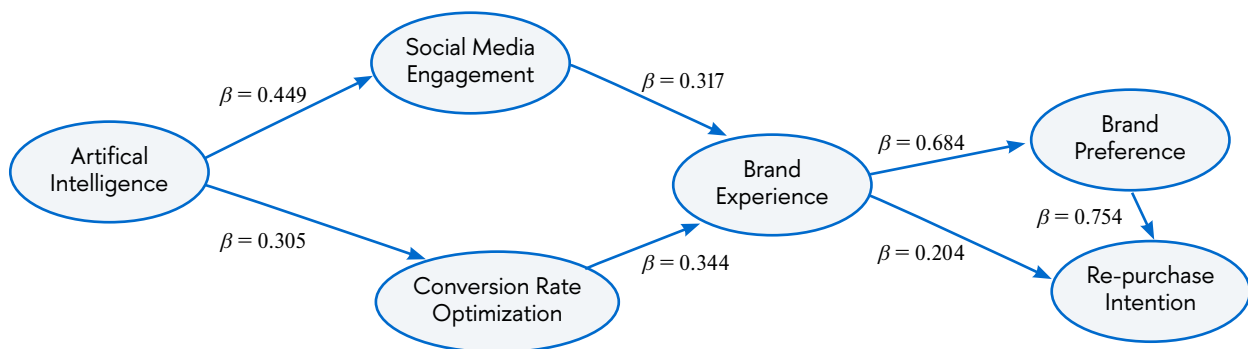


Fig. 1. Structural model with parameter estimates [2, 9, 51].

4. Discussion

The [45] reported that the results showed how AI technology affects social media participation. This implies that in order for businesses to remain competitive in the present business environment, they have used social media campaigns to transform their offline operations into online ones and generate website traffic that eventually converts into actual customers. Businesses that use AI technology have a good correlation with social media user engagement [83]. This result supports the hypothesis that social media integration of AI could enable marketers to interact with prospective clients to promote the products and services they offer [84]. The study discovered an effect on businesses' adoption of AI to raise conversion rates. This lends credence to the idea that social networking sites might boost a business's amount of sales. Social media marketing powered by AI may increase consumer feedback and engagement as well as the customer-

business relationship's conversion rate. AI improves user engagement with social media marketing, which encourages users to buy goods or services. This outcome is in line with the findings of [2, 85].

Customer conversion rates have been shown to affect the brand experience. Businesses may better understand client segmentation and increase conversion rates on online platforms with the help of social media analytics. Social media marketers can tailor their commercial practices and professional activities by leveraging AI technologies to learn customer attitudes. To provide a positive experience and increase sales volume; this outcome is in line with [2, 85].

According to [70], this study demonstrated the relationship between social media engagement and brand experience, indicating that consumers who are more active in social networks are more likely to interact with the brand. Our results align with earlier studies that have demonstrated positive consumer evaluations of goods

Table 3.

Path analysis for the constructs of the study

Path	Relation		Coefficients	t-value*	Support/ nonsupport
	Artificial Intelligence	Social Media Engagement	0.449	7.108*	Support
Artificial Intelligence	Conversion Rate Optimization	0.305	4.998*	Support	
Social Media Engagement	Brand Experience	0.317	5.159*	Support	
Conversion Rate Optimization	Brand Experience	0.346	5.592*	Support	
Brand Experience	Brand Preference	0.684	9.419*	Support	
Brand Experience	Re-purchase Intention	0.204	3.405*	Support	
Brand Preference	Re-purchase Intention	0.754	10.597*	Support	
Explained variance proportion R ² of Conversion Rate Optimization				0.093	
Explained variance proportion R ² of Social Media Engagement				0.202	
Explained variance proportion R ² of Brand Experience				0.251	
Explained variance proportion R ² of Brand Preference				0.467	
Explained variance proportion R ² of Re-purchase Intention				0.82	

Notes: * $p < 0.01$

and services on social networking platforms are given by those who are happy with their purchases [2].

Consistent with earlier research [20, 62, 70], the results show that brand experience influences brand choice and that a favorable brand experience can boost consumer-based brand preference. As a result, customers' brand preference may be increased by a favorable brand experience. Consumers mostly base their brand choice on their experiences. Customers are more inclined to like a brand when they have had numerous positive interactions with it. According to an earlier study [62], consumers will ex-

hibit positive behavioral intentions when they perceive a high degree of brand experience. This highlights the significance of an unforgettable brand experience in the context of consumer behavior.

As previously said in the literature, brand experience aids in encapsulating a brand's behavioral, emotional, social, pragmatic, sensory, intellectual and lifestyle elements [70]. The consumer will develop preferences and make judgments about what to buy through this interactive experience [74, 86].

Table 4.

Indirect effects of SCC on NPP through KS and IC

Indirect effect	β	95% Bootstrap CI		p
		Lower limit	Upper limit	
AI → SME → BE → RI	0.027	0.011	0.069	0.003
AI → SME → BE → BR → RI	0.068	0.032	0.132	0.001
AI → CRO → BE → RI	0.020	0.008	0.047	0.003
AI → CRO → BE → BR → RI	0.050	0.020	0.105	0.001

(AI) Artificial Intelligence; (SME) Social Media Engagement; (CRO) Conversion Rate Optimization; (BR) Brand Experience; (RI) Re-purchase Intention.

The findings indicate that the re-purchase intention is significantly influenced by brand preference and brand experience. Because consumer preferences and brand experiences are sustainable ideas that represent unreasonable elements related to the customer who engages with the brand and goes over the limits of rational assumptions, this means that if customers like the product and have a stimulating interaction with it, they are more likely to intend to re-purchase it. Customers will thus have a strong desire to buy without using reason [70].

The findings showed that the impact of AI on the intention to re-purchase is mediated by brand experience. The findings further indicate that the impact of AI on intention to re-purchase was mediated by brand preference. This is understandable given that AI offers a novel consumer experience that increases brand preference, customer satisfaction and product re-purchases [20].

The findings showed that the impact of AI on brand experience and propensity to re-purchase is mediated by social media engagement and conversion rate optimization. The majority of the research on social networking sites engagement has been on online brand communities and social media [51]. This demonstrates how crucial consumer engagement with AI technology is to brand marketing. Using AI technology for marketing brands necessitates higher social media engagement since it makes it easier for brand marketers to convey their experiences to consumers, which leads to the formation of positive brand experiences and re-purchase intentions [51]. Using AI, marketers can also raise visitor conversion rates [9]. Organizations on social networking sites also employ AI as a technique to entice consumers and win them over as devoted customers [2].

5. Theoretical implications

According to this study, businesses may assess the relative value of each element of their products and services and how it affects customer satisfaction on social media platforms by utilizing AI-enabled solutions. The rising use of social media platforms has resulted in a huge increase in consumer interaction, suggesting that social media sites are becoming a new marketplace for establishing relationships with customers to sell products and services. According to [45], AI tracks and analyzes user habits on social media platforms. Technology is playing a bigger role in customer engagement. To improve consumers' re-purchase intention, AI and consumer behavior should be taken into account while implementing a customer engagement plan.

According to this study, AI can improve social media platforms' capacity to attract new clients for Airline companies. Acknowledge the importance of AI, which efficiently manages data processing for specialized services through automation. Studies on customer contact on social media platforms and AI-powered automated business responses are still in their early stages. However, there is a gap in the way companies use real-time data to offer personalized customer service when interacting with clients [2].

Because AI can successfully generate brand preference and purchasing commitment, this study validates AI's overall effectiveness. As a result, by offering a thorough framework that clarifies the connections between AI and branding, our research adds to the body of knowledge on marketing and branding. This study's discussions will be beneficial to marketing academics who wish to apply this approach to other domains.

The study validates the impact of AI marketing methods on brand experience and preference, as well as the correlation among brand preference and re-purchase intention. A few studies have been conducted on AI preference for brands. By elucidating the function of AI in customer interactions within the setting of airline services, this study seeks to close this knowledge gap. By showing the predictive power of AI marketing techniques on brand preference, this work advances the field of service research and offers researchers with an interest in deploying AI to customer decision-making and behavior valuable information. Furthermore, the partial mediation arrangement of brand experience between AI marketing tactics and brand preference shows how these strategies predict brand preference and re-purchase intentions in airlines both directly and indirectly via brand encounters [20].

6. Practical implications

There are various implications of this study for academics and professionals. First, social media platforms are gradually being used by customers in Jordan. These days, the majority of consumers would rather buy goods and services via the Internet and on social networking platforms than leave the comfort of their homes. Additionally, social media and online channels let companies boost sales. Companies may easily keep an eye on what their clients are doing on social media [10]. As a result, they implement efficient communication strategies that aid in raising the conversion rate. According to [2], organizations must deal directly with their clients to ascertain their requirements and

expectations. Although it is essential to businesses, customer involvement on social media is insufficient to help them. Managers will benefit from the current research's understanding of the technological context and its effects on behavior and society. Third, incorporating social media platforms facilitates the analysis of client feedback and the conversion of those responses into actual sales [1]. Social media networks with AI capabilities can assist executives in forecasting customer behavior patterns within the aviation sector. The suggested structure enables managers to influence consumers on social media platforms, hence increasing sales capacity. This report encourages managers to increase social networking conversion rates by utilizing the newest digital technology.

Fourth, companies may boost sales and develop a computerized digital system that assesses and analyzes the social media user experience by integrating AI into their social media marketing campaigns. Social media sites are a useful tool for marketing goods and services internationally. The study's findings also demonstrate that after returning customers get used to online buying, they alter their decision-making processes [2]. Therefore, by providing vouchers for savings and promotions and cultivating customer re-purchase behaviors, airlines may entice frequent travelers.

Fifth, this study discovered that the use of AI in marketing significantly improved brand preference, which subsequently turn affected consumers' desire to make additional purchases. According to these findings, AI marketing initiatives should be seen as a vital instrument for enhancing the brand image in addition to being a means of improving the consumer experience [20]. To improve long-term commercial performance and brand attractiveness, the airline should focus brand-building efforts on AI. Thus, the airline ought to make greater investments in AI and booking service technology, both to draw in new business and to strengthen existing ones.

An airline that is reluctant to use AI may need to reevaluate its investment strategies because the first-mover advantage is still quite significant. Since this study shows how consumers appreciate AI activities after realizing their values, verification of AI campaigns is a crucial sign of the return on investment. Therefore, managers must make sure AI can provide accurate, dependable and efficient airline-related services. Managers can use AI to send clients tailored marketing communications about services and goods at the right time.

In order to meet customer requests, AI assistants and agents should be designed with the capacity to provide knowledgeable customer support and guidance. Airlines' practitioners can also consider improving the AI interface.

7. Limitations and future research

This study has several limitations.

First, the 355 valid samples were obtained by online questionnaires from individuals who had made travel reservations through websites, suggesting that our knowledge of AI brand interactions may be restricted.

Secondly, a cross-sectional approach was employed to gather data from the participants. A longitudinal study might be pertinent to evaluate the suggested model to investigate consumers' intention to re-purchase because habits are amassed over time. To increase validity, future research might employ a bigger sample size.

Third, the study's focus is on the airline business. The results could apply to other businesses or philosophies, even if they are probably most helpful in the context of airlines. This study could be repeated in the future and expanded to include different sectors or nations. This study is quantitative in style; future research may use mixed or qualitative methodologies.

Lastly, producing a response rate that is higher than 44.4%.

To generalize these findings, researchers can also analyze consumer behavior across national borders and industry sectors through cross-cultural studies.

Conclusion

The study explores the mediating role of social media engagement, conversion rate optimization, brand experience and brand preference in the relationship between AI and re-purchase intentions. It also empirically evaluates a model for the implementation of AI in re-purchase intentions and its role in improving conversion rate optimization. The study discovered that through social media interaction, brand experience, brand preference and conversion rate optimization, AI significantly influences re-purchase intentions indirectly. In a similar vein, it has been discovered that social media interaction and conversion rate optimization significantly affect brand experience. Additionally, the re-purchase intention is significantly impacted by brand experience. ■

References

1. Dwivedi Y.K., Wang Y. (2022) Guest editorial: Artificial intelligence for B2B marketing: Challenges and opportunities. *Industrial Marketing Management*, vol. 105, pp. 109–113. <https://doi.org/10.1016/j.indmarman.2022.06.001>
2. Nazir S., Khadim S., Asadullah M.A., Syed N. (2023) Exploring the influence of artificial intelligence technology on consumer repurchase intention: The mediation and moderation approach. *Technology in Society*, vol. 72, 102190. <https://doi.org/10.1016/j.techsoc.2022.102190>
3. Collins C., Dennehy D., Conboy K., Mikalef P. (2021) Artificial intelligence in information systems research: A systematic literature review and research agenda. *International Journal of Information Management*, vol. 60, 102383. <https://doi.org/10.1016/j.ijinfomgt.2021.102383>
4. Chen P., Kim S. (2023) The impact of digital transformation on innovation performance – The mediating role of innovation factors. *Heliyon*, vol. 9, no. 3, e13916. <https://doi.org/10.1016/j.heliyon.2023.e13916>
5. Vishnoi S.K., Bagga T.E.E.N.A., Sharma A.A.R.U.S.H.I., Wani S.N. (2018) Artificial intelligence enabled marketing solutions: A review. *Indian Journal of Economics and Business*, vol. 17, no. 4, pp. 167–177.
6. Fan J., Fang L., Wu J., Guo Y., Dai Q. (2020) From brain science to artificial intelligence. *Engineering*, vol. 6, no. 3, pp. 248–252. <https://doi.org/10.1016/j.eng.2019.11.012>
7. Uzir M.U.H., Bukari Z., Al Halbusi H., et al. (2023) Applied artificial intelligence: Acceptance-intention-purchase and satisfaction on smartwatch usage in a Ghanaian context. *Heliyon*, vol. 9, no. 8, e18666. <https://doi.org/10.1016/j.heliyon.2023.e18666>
8. Overgoor G., Chica M., Rand W., Weishampel A. (2019) Letting the computers take over: Using AI to solve marketing problems. *California Management Review*, vol. 61, no. 4, pp. 156–185. <https://doi.org/10.1177/0008125619859318>
9. Bag S., Srivastava G., Bashir M.M.A., Kumari S., Giannakis M., Chowdhury A.H. (2022) Journey of customers in this digital era: Understanding the role of artificial intelligence technologies in user engagement and conversion. *Benchmarking: An International Journal*, vol. 29, no. 7, pp. 2074–2098. <https://doi.org/10.1108/BIJ-07-2021-0415>
10. Yin J., Qiu X. (2021) AI technology and online purchase intention: Structural equation model based on perceived value. *Sustainability*, vol. 13, no. 10, 5671. <https://doi.org/10.3390/su13105671>
11. Majeed M., Asare C., Fatawu A., Abubakari A. (2022) An analysis of the effects of customer satisfaction and engagement on social media on repurchase intention in the hospitality industry. *Cogent Business & Management*, vol. 9, no. 1, 2028331. <https://doi.org/10.1080/23311975.2022.2028331>
12. Busalim A., Hollebeek L.D., Lynn T. (2023) The effect of social commerce attributes on customer engagement: an empirical investigation. *Internet Research*, vol. 34, no. 7, pp. 187–214. <https://doi.org/10.1108/INTR-03-2022-0165>
13. Thakur R. (2016) Understanding customer engagement and loyalty: a case of mobile devices for shopping. *Journal of Retailing and Consumer Services*, vol. 32, pp. 151–163. <https://doi.org/10.1016/j.jretconser.2016.06.004>
14. Hollebeek L.D., Glynn M.S., Brodie R.J. (2014) Consumer brand engagement in social media: Conceptualization, scale development and validation. *Journal of Interactive Marketing*, vol. 28, no. 2, pp. 149–165. <https://doi.org/10.1016/j.intmar.2013.12.002>
15. Dwivedi Y.K., Ismagilova E., Hughes D.L., et al. (2021) Setting the future of digital and social media marketing research: Perspectives and research propositions. *International Journal of Information Management*, vol. 59, 102168. <https://doi.org/10.1016/j.ijinfomgt.2020.102168>
16. Al-Natour S., Turetken O. (2020) A comparative assessment of sentiment analysis and star ratings for consumer reviews. *International Journal of Information Management*, vol. 54, 102132. <https://doi.org/10.1016/j.ijinfomgt.2020.102132>
17. Duan Y., Edwards J.S., Dwivedi Y.K. (2019) Artificial intelligence for decision making in the era of Big Data – evolution, challenges and research agenda. *International Journal of Information Management*, vol. 48, pp. 63–71. <https://doi.org/10.1016/j.ijinfomgt.2019.01.021>
18. Wang X., Lei S. (2018) Research on the impact of artificial intelligence on consumption and shopping experience in the new retail environment – Based on the perspective of commercial retail reform and the reconstruction of the human-goods-scene system. *Journal of Commercial Economics*, vol. 37, no. 17, pp. 5–8.
19. Murphy J., Gretzel U., Pesonen J. (2019) Marketing robot services in hospitality and tourism: The role of anthropomorphism. *Journal of Travel and Tourism Marketing*, vol. 36, no. 7, pp. 784–795. <https://doi.org/10.1080/10548408.2019.1571983>
20. Ho S.P.S., Chow M.Y.C. (2024) The role of artificial intelligence in consumers' brand preference for retail banks in Hong Kong. *Journal of Financial Services Marketing*, vol. 29, pp. 292–305. <https://doi.org/10.1057/s41264-022-00207-3>
21. Stylos N., Zwiendelaar J., Buhalis D. (2021) Big data empowered agility for dynamic, volatile, and time-sensitive service industries: the case of tourism sector. *International Journal of Contemporary Hospitality Management*, vol. 33, no. 3, pp. 1015–1036. <https://doi.org/10.1108/IJCHM-07-2020-0644>
22. Chan A.P.H., Tung V.W.S. (2019) Examining the effects of robotic service on brand experience: the moderating role of hotel segment. *Journal of Travel and Tourism Marketing*, vol. 36, no. 4, pp. 458–468. <https://doi.org/10.1080/10548408.2019.1568953>
23. Kim Y.J., Park J.S., Jeon H.M. (2021) Experiential value, satisfaction, brand love, and brand loyalty toward robot barista coffee shop: The moderating effect of generation. *Sustainability*, vol. 13, no. 21, 12029. <https://doi.org/10.3390/su132112029>
24. Trivedi J. (2019) Examining the customer experience of using banking chatbots and its impact on brand love: The moderating role of perceived risk. *Journal of Internet Commerce*, vol. 18, no. 1, pp. 91–111. <https://doi.org/10.1080/15332861.2019.1567188>
25. Kumar V., Rajan B., Venkatesan R., Lecinski J. (2019) Understanding the role of artificial intelligence in personalized engagement marketing. *California Management Review*, vol. 61, no. 4, pp. 135–155. <https://doi.org/10.1177/0008125619859317>

26. Mishra S., Ewing M.T., Cooper H.B. (2022) Artificial intelligence focus and firm performance. *Journal of the Academy of Marketing Science*, vol. 50, no. 6, pp. 1176–1197. <https://doi.org/10.1007/s11747-022-00876-5>
27. Peltier J.W., Dahl A.J., Schibrowsky J.A. (2024) Artificial intelligence in interactive marketing: A conceptual framework and research agenda. *Journal of Research in Interactive Marketing*, vol. 18, no. 12, pp. 54–90. <https://doi.org/10.1108/JRIM-01-2023-0030>
28. Manser Payne E.H., Peltier J., Barger V.A. (2021) Enhancing the value co-creation process: artificial intelligence and mobile banking service platforms. *Journal of Research in Interactive Marketing*, vol. 15, no. 1, pp. 68–85. <https://doi.org/10.1108/JRIM-10-2020-0214>
29. Vlačić B., Corbo L., e Silva S.C., Dabić M. (2021) The evolving role of artificial intelligence in marketing: A review and research agenda. *Journal of Business Research*, vol. 128, pp. 187–203. <https://doi.org/10.1016/j.jbusres.2021.01.055>
30. Bhagat R., Chauhan V., Bhagat P. (2023) Investigating the impact of artificial intelligence on consumer's purchase intention in e-retailing. *Foresight*, vol. 25, no. 2, pp. 249–263. <https://doi.org/10.1108/FS-10-2021-0218>
31. Huang M.H., Rust R.T. (2021) A strategic framework for artificial intelligence in marketing. *Journal of the Academy of Marketing Science*, vol. 49, pp. 30–50. <https://doi.org/10.1007/s11747-020-00749-9>
32. Dekimpe M.G. (2020) Retailing and retailing research in the age of big data analytics. *International Journal of Research in Marketing*, vol. 37, no. 1, pp. 3–14. <https://doi.org/10.1016/j.ijresmar.2019.09.001>
33. Pantano E., Rese A., Baier D. (2017) Enhancing the online decision-making process by using augmented reality: A two country comparison of youth markets. *Journal of Retailing and Consumer Services*, vol. 38, pp. 81–95. <https://doi.org/10.1016/j.jretconser.2017.05.011>
34. Reinartz W., Wiegand N., Imschloss M. (2019) The impact of digital transformation on the retailing value chain. *International Journal of Research in Marketing*, vol. 36, no. 3, pp. 350–366. <https://doi.org/10.1016/j.ijresmar.2018.12.002>
35. Astawa I.G.N.M.W., Sukawati T.G.R.S. (2019) The role of perceived value mediate the effect of utilitarian and hedonic shopping value on intent to online repurchase. *International Journal of Management and Commerce Innovations*, vol. 6, no. 1, pp. 1232–1242.
36. Qian M., Xu Z. (2019) A study of dynamic recognition of consumer brand decision-making preference based on machine learning method. *Nankai Business Review*, vol. 22, no. 1, pp. 66–76.
37. Haenlein M., Kaplan A., Tan C.W., Zhang P. (2019) Artificial intelligence (AI) and management analytics. *Journal of Management Analytics*, vol. 6, no. 4, pp. 341–343. <https://doi.org/10.1080/23270012.2019.1699876>
38. Sohn K., Kwon O. (2020) Technology acceptance theories and factors influencing artificial Intelligence-based intelligent products. *Telematics and Informatics*, vol. 47, 101324. <https://doi.org/10.1016/j.tele.2019.101324>
39. Attig C., Franke T. (2020) Abandonment of personal quantification: A review and empirical study investigating reasons for wearable activity tracking attrition. *Computers in Human Behavior*, vol. 102, pp. 223–237. <https://doi.org/10.1016/j.chb.2019.08.025>
40. Yan Y., Chen H., Shao B., Lei Y. (2023) How IT affordances influence customer engagement in live streaming commerce? A dual-stage analysis of PLS-SEM and fsQCA. *Journal of Retailing and Consumer Services*, vol. 74, 103390. <https://doi.org/10.1016/j.jretconser.2023.103390>
41. Sun Y., Shao X., Li X., Guo Y., Nie K. (2019) How live streaming influences purchase intentions in social commerce: An IT affordance perspective. *Electronic Commerce Research and Applications*, vol. 37, 100886. <https://doi.org/10.1016/j.elerap.2019.100886>
42. De Oliveira Santini F., Ladeira W.J., Pinto D.C., Herter M.M., Sampaio C.H., Babin B.J. (2020) Customer engagement in social media: a framework and meta-analysis. *Journal of the Academy of Marketing Science*, vol. 48, no. 6, pp. 1211–1228. <https://doi.org/10.1007/s11747-020-00731-5>
43. Garg P., Gupta B., Dzever S., Sivarajah U., Kumar V. (2020) Examining the relationship between social media analytics practices and business performance in the Indian retail and IT industries: The mediation role of customer engagement. *International Journal of Information Management*, vol. 52, 102069. <https://doi.org/10.1016/j.ijinfomgt.2020.102069>
44. Busalim A.H., Ghabban F. (2021) Customer engagement behaviour on social commerce platforms: An empirical study. *Technology in Society*, vol. 64, 101437. <https://doi.org/10.1016/j.techsoc.2020.101437>
45. Capatina A., Kachour M., Lichy J., Micu A., Micu A.E., Codignola F. (2020) Matching the future capabilities of an artificial intelligence-based software for social media marketing with potential users' expectations. *Technological Forecasting and Social Change*, vol. 151, 119794. <https://doi.org/10.1016/j.techfore.2019.119794>
46. Di Fatta D., Patton D., Viglia G. (2018) The determinants of conversion rates in SME e-commerce websites. *Journal of Retailing and Consumer Services*, vol. 41, pp. 161–168. <https://doi.org/10.1016/j.jretconser.2017.12.008>
47. Roy S.K., Eshghi A., Sarkar A. (2013) Antecedents and consequences of brand love. *Journal of Brand Management*, vol. 20, pp. 325–332. <https://doi.org/10.1057/bm.2012.24>
48. Chang C.W., Huang H.C., Wang S.J., Lee H. (2021) Relational bonds, customer engagement, and service quality. *The Service Industries Journal*, vol. 41, no. 5–6, pp. 330–354. <https://doi.org/10.1080/02642069.2019.1611784>
49. Khattab S.A., Al Shaar I.M., Zaid M.K.A., Qutaishat F.T. (2023) The effect of relational bonds on e-commerce use, the mediating effect of customers' online trust: evidence from Jordan. *International Journal of Business and Systems Research*, vol. 17, no. 5, pp. 483–503.
50. Brakus J.J., Schmitt B.H., Zarantonello L. (2009) Brand experience: what is it? How is it measured? Does it affect loyalty? *Journal of Marketing*, vol. 73, no. 3, pp. 52–68. <https://doi.org/10.1509/jmkj.73.3.052>

51. Hsu C.L. (2023) Enhancing brand love, customer engagement, brand experience, and repurchase intention: Focusing on the role of gamification in mobile apps. *Decision Support Systems*, vol. 174, 114020. <https://doi.org/10.1016/j.dss.2023.114020>
52. Islam J.U., Hollebeek L.D., Rahman Z., Khan I., Rasool A. (2019) Customer engagement in the service context: An empirical investigation of the construct, its antecedents and consequences. *Journal of Retailing and Consumer Services*, vol. 50, pp. 277–285. <https://doi.org/10.1016/j.jretconser.2019.05.018>
53. Flavián C., Ibáñez-Sánchez S., Orús C. (2019) The impact of virtual, augmented and mixed reality technologies on the customer experience. *Journal of Business Research*, vol. 100, pp. 547–560. <https://doi.org/10.1016/j.jbusres.2018.10.050>
54. Hoyer W.D., Kroschke M., Schmitt B., Kraume K., Shankar V. (2020) Transforming the customer experience through new technologies. *Journal of Interactive Marketing*, vol. 51, no. 1, pp. 57–71. <https://doi.org/10.1016/j.intmar.2020.04.001>
55. Chen Y., Fay S., Wang Q. (2011) The role of marketing in social media: How online consumer reviews evolve. *Journal of Interactive Marketing*, vol. 25, no. 2, pp. 85–94. <https://doi.org/10.1016/j.intmar.2011.01.003>
56. Choi H., Kandampully J. (2019) The effect of atmosphere on customer engagement in upscale hotels: An application of SOR paradigm. *International Journal of Hospitality Management*, vol. 77, pp. 40–50. <https://doi.org/10.1016/j.ijhm.2018.06.012>
57. Eigenraam A.W., Eelen J., Van Lin A., Verlegh P.W. (2018) A consumer-based taxonomy of digital customer engagement practices. *Journal of Interactive Marketing*, vol. 44, no. 1, pp. 102–121. <https://doi.org/10.1016/j.intmar.2018.07.002>
58. He W., Wu H., Yan G., Akula V., Shen J. (2015) A novel social media competitive analytics framework with sentiment benchmarks. *Information & Management*, vol. 52, no. 7, pp. 801–812. <https://doi.org/10.1016/j.im.2015.04.006>
59. Bae B.R., Kim S.-E. (2023) Effect of brand experiences on brand loyalty mediated by brand love: the moderated mediation role of brand trust. *Asia Pacific Journal of Marketing and Logistics*, vol. 35, no. 10, pp. 2412–2430. <https://doi.org/10.1108/apjml-03-2022-0203>
60. Andreini D., Pedeliento G., Zarantonello L., Solerio C. (2019) A renaissance of brand experience: Advancing the concept through a multi-perspective analysis. *Journal of Business Research*, vol. 96, pp. 355–365. <https://doi.org/10.1016/j.jbusres.2018.05.046>
61. Bapat D., Thanigan J. (2016) Exploring relationship among brand experience dimensions, brand evaluation and brand loyalty. *Global Business Review*, vol. 17, no. 6, pp. 1357–1372. <https://doi.org/10.1177/0972150916660401>
62. Ebrahim R., Ghoneim A., Irani Z., Fan Y. (2016) A brand preference and repurchase intention model: the role of consumer experience. *Journal of Marketing Management*, vol. 32, no. 13–14, pp. 1230–1259. <https://doi.org/10.1080/0267257X.2016.1150322>
63. Singh D., Bajpai N., Kulshreshtha K. (2021) Brand experience – brand love relationship for Indian hypermarket brands: The moderating role of customer personality traits. *Journal of Relationship Marketing*, vol. 20, no. 1, pp. 20–41. <https://doi.org/10.1080/15332667.2020.1715179>
64. Hwang J., Choe J.Y.J., Kim H.M., Kim J.J. (2021) The antecedents and consequences of memorable brand experience: Human baristas versus robot baristas. *Journal of Hospitality and Tourism Management*, vol. 48, pp. 561–571. <https://doi.org/10.1016/j.jhtm.2021.08.013>
65. Hwang J., Kim H., Kim H.M. (2023) Relationships among memorable brand experience, brand preference, and behavioral intentions: focusing on the difference between robot servers and human servers. *Journal of Hospitality and Tourism Technology*, vol. 14, no. 3, pp. 430–443. <https://doi.org/10.1108/JHTT-09-2021-0254>
66. Dias R.P., Kusuma N.I. (2023) The effect of brand identity and brand preference on Starbucks repurchase interest in Bekasi City. *Jurnal Ekonomi dan Bisnis Digital*, vol. 2, no. 3, pp. 1031–1054. <https://doi.org/10.55927/ministal.v2i3.4207>
67. Can Y., Erdil O. (2018) Determining antecedent of re-purchase intention: The role of perceived value and consumer's interest factor. *International Business Research*, vol. 11, no. 4, pp. 17–31. <https://doi.org/10.5539/ibr.v11n4p17>
68. Ibazan E., Balarabe F., Jakada B. (2016) Consumer satisfaction and repurchase intentions. *Developing Country Studies*, vol. 6, no. 2, pp. 96–100.
69. Langga A., Kusumawati A., Alhabsji T. (2021) Intensive distribution and sales promotion for improving customer-based brand equity (CBBE), re-purchase intention and word-of-mouth (WOM). *Journal of Economic and Administrative Sciences*, vol. 37, no. 4, pp. 577–595. <https://doi.org/10.1108/JEAS-03-2019-0041>
70. Yasri Y., Susanto P., Hoque M.E., Gusti M.A. (2020) Price perception and price appearance on repurchase intention of Gen Y: do brand experience and brand preference mediate? *Heliyon*, vol. 6, no. 11, e05532. <https://doi.org/10.1016/j.heliyon.2020.e05532>
71. Sullivan Y.W., Kim D.J. (2018) Assessing the effects of consumers' product evaluations and trust on repurchase intention in e-commerce environments. *International Journal of Information Management*, vol. 39, pp. 199–219. <https://doi.org/10.1016/j.ijinfomgt.2017.12.008>
72. Tynan C., McKechnie S. (2009) Experience marketing: a review and reassessment. *Journal of Marketing Management*, vol. 25, no. 5–6, pp. 501–517. <https://doi.org/10.1362/026725709X461821>
73. Diallo M.F., Siqueira J.R. (Jr.) (2017) How previous positive experiences with store brands affect purchase intention in emerging countries: A comparison between Brazil and Colombia. *International Marketing Review*, vol. 34, no. 4, pp. 536–558. <https://doi.org/10.1108/IMR-07-2014-0224>
74. Moreira A.C., Fortes N., Santiago R. (2017) Influence of sensory stimuli on brand experience, brand equity and purchase intention. *Journal of Business Economics and Management*, vol. 18, no. 1, pp. 68–83. <https://doi.org/10.3846/16111699.2016.1252793>
75. Bell E., Bryman A. (2007) The ethics of management research: an exploratory content analysis. *British Journal of Management*, vol. 18, no. 1, pp. 63–77. <https://doi.org/10.1111/j.1467-8551.2006.00487.x>
76. Sekaran U., Bougie R. (2016) *Research methods for business: A skill building approach*. Wiley.

77. Amoako G.K., Anabila P., Asare Effah E., Kumi D.K. (2017) Mediation role of brand preference on bank advertising and customer loyalty: A developing country perspective. *International Journal of Bank Marketing*, vol. 35, no. 6, pp. 983–996. <https://doi.org/10.1108/IJBM-07-2016-0092>
78. O’Leary-Kelly S.W., Vokurka R.J. (1998) The empirical assessment of construct validity. *Journal of Operations Management*, vol. 16, no. 4, pp. 387–405. [https://doi.org/10.1016/S0272-6963\(98\)00020-5](https://doi.org/10.1016/S0272-6963(98)00020-5)
79. Anderson J.C., Gerbing D.W. (1988) Structural equation modeling in practice: A review and recommended two-step approach. *Psychological Bulletin*, vol. 103, no. 3, 411–423. <https://doi.org/10.1037/0033-2909.103.3.411>
80. Fornell C., Larcker D.F. (1981) Evaluating structural equation models with unobservable variables and measurement error. *Journal of Marketing Research*, vol. 18, no. 1, pp. 39–50. <https://doi.org/10.2307/3151312>
81. Henseler J., Ringle C.M., Sarstedt M. (2015) A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, vol. 43, no. 1, pp. 115–135. <https://doi.org/10.1007/s11747-014-0403-8>
82. Nunnally J.C. (1978) *Psychometric Theory (2nd edition)*. New York: McGraw-Hill Book Company.
83. Prentice C., Dominique Lopes S., Wang X. (2020) The impact of artificial intelligence and employee service quality on customer satisfaction and loyalty. *Journal of Hospitality Marketing and Management*, vol. 29, no. 7, pp. 739–756. <https://doi.org/10.1080/19368623.2020.1722304>
84. Huang M.H., Rust R.T. (2018) Artificial intelligence in service. *Journal of Service Research*, vol. 21, no. 2, pp. 155–172. <https://doi.org/10.1177/1094670517752459>
85. McDowell W.C., Wilson R.C., Kile C.O. (Jr.) (2016) An examination of retail website design and conversion rate. *Journal of Business Research*, vol. 69, no. 11, pp. 4837–4842. <https://doi.org/10.1016/j.jbusres.2016.04.040>
86. Chang P.L., Chieng M.H. (2006) Building consumer–brand relationship: A cross-cultural experiential view. *Psychology & Marketing*, vol. 23, no. 11, pp. 927–959. <https://doi.org/10.1002/MAR.20140>

About the authors

Raed Naser Alkaied

Instructor and Head of Department, Faculty of Business, Management Information System Department, Al Balqa Applied University, Salt 19117, Jordan, PO Box 206;

E-mail: Raedalkaied@bau.edu.jo

ORCID: 0000-0002-6288-7503

Shadi Ahmed Khattab

Associate Professor, Faculty of Business, Management Information System Department, Al Balqa Applied University, Salt 19117, Jordan, PO Box 206;

E-mail: Shadikhattab@bau.edu.jo

ORCID: 0000-0002-0824-1437

Ishaq M. Al Shaar

Professor, Faculty of Business, Department of Business Administration, Al Balqa Applied University, Salt 19117, Jordan, PO Box 206;

E-mail: I.shaar@bau.edu.jo

ORCID: 0000-0001-6036-4189

Mohammed Khair Abu Zaid

Professor, Faculty of Business, Planning and Project Management Department, Al Balqa Applied University, Salt 19117, Jordan, PO Box 206;

E-mail: Mohammed_abu_zaid@bau.edu.jo

ORCID: 0000-0002-6687-1285

Sakher A.I. Al-Bazaiah

Associate Professor, Faculty of Business, Department of Business Administration, Al Balqa Applied University, Salt 19117, Jordan, PO Box 206;

E-mail: bazaiah1@bau.edu.jo

ORCID: 0000-0002-6648-8091

Влияние искусственного интеллекта на намерения совершить повторную покупку: медиативный подход

Алькаид Р.Н.

E-mail: Raedalkaied@bau.edu.jo

Хаттаб С.А.

E-mail: Shadikhattab@bau.edu.jo

Аль Шаар И.М.

E-mail: I.shaar@bau.edu.jo

Абу Заид М.Х.

E-mail: Mohammed_abu_zaid@bau.edu.jo

Аль-Базаия С.А.И.

E-mail: bazaiah1@bau.edu.jo

Университет прикладных наук Аль-Балка, Эс-Салт, Иордания

Аннотация

Покупки, совершаемые на онлайн-платформах, в значительной степени основаны на искусственном интеллекте (ИИ), который формирует покупательское поведение потребителей. Для изучения намерений повторных покупок в данном исследовании использованы данные об ИИ, вовлеченности в социальные сети, оптимизации коэффициента конверсии, опыте использования бренда и предпочтениях бренда. Был проведен опрос с помощью анкеты, разосланной 355 респондентам, которые хотя бы раз покупали или пользовались услугами, предлагаемыми онлайн на любом сайте, связанном с авиацией. Гипотезы исследования были проанализированы с использованием Amos V.22. Эмпирические результаты показывают, что ИИ повлиял на вовлеченность в социальные сети, восприятие бренда, предпочтения к бренду и оптимизацию коэффициента конверсии. Оптимизация коэффициента конверсии и взаимодействие с социальными сетями также влияют на предпочтения и опыт использования бренда, которые, в свою очередь, влияют на намерение совершить повторную покупку. Кроме того, связь между искусственным интеллектом и намерением повторной покупки обусловлена вовлеченностью в социальные сети, опытом работы с брендом, оптимизацией коэффициента конверсии и предпочтениями бренда. Результаты исследования могут помочь авиакомпаниям в разработке ИИ и создании более эффективных кампаний по брендингу и маркетингу, чтобы повысить желание клиентов совершать повторные покупки. Исследование также показало, что использование ИИ в маркетинге значительно улучшило предпочтения бренда, что впоследствии повлияло на желание потребителей совершать дополнительные покупки. Кроме того, для улучшения долгосрочных коммерческих показателей и привлекательности бренда авиакомпаниям рекомендуется сосредоточить усилия по созданию бренда на ИИ и, таким образом, увеличить инвестиции в ИИ и технологии бронирования, как для привлечения новых клиентов, так и для удержания существующих.

Ключевые слова: искусственный интеллект, оптимизация коэффициента конверсии, вовлечение в социальные сети, опыт работы с брендом, предпочтения бренда, намерение совершить повторную покупку

Цитирование: Alkaied R.N., Khattab S.A., Al Shaar I.M., Abu Zaid M.K., Al-Bazaiah S.A.I. (2024) The impact of artificial intelligence on re-purchase intentions: the mediation approach // *Business Informatics*. 2024. Vol. 18. No. 3. P. 87–107. DOI: 10.17323/2587-814X.2024.3.87.107

Литература

1. Dwivedi Y.K., Wang Y. Guest editorial: Artificial intelligence for B2B marketing: Challenges and opportunities // *Industrial Marketing Management*. 2022. Vol. 105. P. 109–113. <https://doi.org/10.1016/j.indmarman.2022.06.001>
2. Nazir S., Khadim S., Asadullah M.A., Syed N. Exploring the influence of artificial intelligence technology on consumer repurchase intention: The mediation and moderation approach // *Technology in Society*. 2023. Vol. 72. Article 102190. <https://doi.org/10.1016/j.techsoc.2022.102190>
3. Collins C., Dennehy D., Conboy K., Mikalef P. Artificial intelligence in information systems research: A systematic literature review and research agenda // *International Journal of Information Management*. 2021. Vol. 60. Article 102383. <https://doi.org/10.1016/j.ijinfomgt.2021.102383>
4. Chen P., Kim S. The impact of digital transformation on innovation performance – The mediating role of innovation factors // *Heliyon*. 2023. Vol. 9. No. 3. Article e13916. <https://doi.org/10.1016/j.heliyon.2023.e13916>
5. Vishnoi S.K., Bagga T.E.E.N.A., Sharma A.A.R.U.S.H.I., Wani S.N. Artificial intelligence enabled marketing solutions: A review // *Indian Journal of Economics and Business*. 2018. Vol. 17. No. 4. P. 167–177.
6. Fan J., Fang L., Wu J., Guo Y., Dai Q. From brain science to artificial intelligence // *Engineering*. 2020. Vol. 6. No. 3. P. 248–252. <https://doi.org/10.1016/j.eng.2019.11.012>
7. Uzir M.U.H., Bukari Z., Al Halbusi H., et al. Applied artificial intelligence: Acceptance-intention-purchase and satisfaction on smartwatch usage in a Ghanaian context // *Heliyon*. 2023. Vol. 9. No. 8. Article e18666. <https://doi.org/10.1016/j.heliyon.2023.e18666>
8. Overgoor G., Chica M., Rand W., Weishampel A. Letting the computers take over: Using AI to solve marketing problems // *California Management Review*. 2019. Vol. 61. No. 4. P. 156–185. <https://doi.org/10.1177/0008125619859318>
9. Bag S., Srivastava G., Bashir M.M.A., Kumari S., Giannakis M., Chowdhury A.H. Journey of customers in this digital era: Understanding the role of artificial intelligence technologies in user engagement and conversion. Benchmarking: An International Journal. 2022. Vol. 29. No. 7. P. 2074–2098. <https://doi.org/10.1108/BIJ-07-2021-0415>
10. Yin J., Qiu X. AI technology and online purchase intention: Structural equation model based on perceived value // *Sustainability*. 2021. Vol. 13. No. 10. Article 5671. <https://doi.org/10.3390/su13105671>
11. Majeed M., Asare C., Fatawu A., Abubakari A. An analysis of the effects of customer satisfaction and engagement on social media on repurchase intention in the hospitality industry // *Cogent Business & Management*. 2022. Vol. 9. No. 1. Article 2028331. <https://doi.org/10.1080/23311975.2022.2028331>
12. Busalim A., Hollebeek L.D., Lynn T. The effect of social commerce attributes on customer engagement: an empirical investigation // *Internet Research*. 2024. Vol. 34. No. 7. P. 187–214. <https://doi.org/10.1108/INTR-03-2022-0165>
13. Thakur R. Understanding customer engagement and loyalty: a case of mobile devices for shopping // *Journal of Retailing and Consumer Services*. 2016. Vol. 32. P. 151–163. <https://doi.org/10.1016/j.jretconser.2016.06.004>
14. Hollebeek L.D., Glynn M.S., Brodie R.J. Consumer brand engagement in social media: Conceptualization, scale development and validation // *Journal of Interactive Marketing*. 2014. Vol. 28. No. 2. P. 149–165. <https://doi.org/10.1016/j.intmar.2013.12.002>
15. Dwivedi Y.K., Ismagilova E., Hughes D.L., et al. Setting the future of digital and social media marketing research: Perspectives and research propositions // *International Journal of Information Management*. 2021. Vol. 59. Article 102168. <https://doi.org/10.1016/j.ijinfomgt.2020.102168>
16. Al-Natour S., Turetken O. A comparative assessment of sentiment analysis and star ratings for consumer reviews // *International Journal of Information Management*. 2020. Vol. 54. Article 102132. <https://doi.org/10.1016/j.ijinfomgt.2020.102132>
17. Duan Y., Edwards J.S., Dwivedi Y.K. Artificial intelligence for decision making in the era of Big Data – evolution, challenges and research agenda // *International Journal of Information Management*. 2019. Vol. 48. P. 63–71. <https://doi.org/10.1016/j.ijinfomgt.2019.01.021>
18. Wang X., Lei S. Research on the impact of artificial intelligence on consumption and shopping experience in the new retail environment – Based on the perspective of commercial retail reform and the reconstruction of the human-goods-scene system // *Journal of Commercial Economics*. 2018. Vol. 37. No. 17. P. 5–8.
19. Murphy J., Gretzel U., Pesonen J. Marketing robot services in hospitality and tourism: The role of anthropomorphism // *Journal of Travel and Tourism Marketing*. 2019. Vol. 36. No. 7. P. 784–795. <https://doi.org/10.1080/10548408.2019.1571983>
20. Ho S.P.S., Chow M.Y.C. The role of artificial intelligence in consumers' brand preference for retail banks in Hong Kong // *Journal of Financial Services Marketing*. 2024. Vol. 29. P. 292–305. <https://doi.org/10.1057/s41264-022-00207-3>
21. Stylos N., Zwiegelhaar J., Buhalis D. Big data empowered agility for dynamic, volatile, and time-sensitive service industries: the case of tourism sector // *International Journal of Contemporary Hospitality Management*. 2021. Vol. 33. No. 3. P. 1015–1036. <https://doi.org/10.1108/IJCHM-07-2020-0644>
22. Chan A.P.H., Tung V.W.S. Examining the effects of robotic service on brand experience: the moderating role of hotel segment // *Journal of Travel and Tourism Marketing*. 2019. Vol. 36. No. 4. P. 458–468. <https://doi.org/10.1080/10548408.2019.1568953>

23. Kim Y.J., Park J.S., Jeon H.M. Experiential value, satisfaction, brand love, and brand loyalty toward robot barista coffee shop: The moderating effect of generation // *Sustainability*. 2021. Vol. 13. No. 21. Article 12029. <https://doi.org/10.3390/su132112029>
24. Trivedi J. Examining the customer experience of using banking chatbots and its impact on brand love: The moderating role of perceived risk // *Journal of Internet Commerce*. 2019. Vol. 18. No. 1. P. 91–111. <https://doi.org/10.1080/15332861.2019.1567188>
25. Kumar V., Rajan B., Venkatesan R., Lecinski J. Understanding the role of artificial intelligence in personalized engagement marketing // *California Management Review*. 2019. Vol. 61. No. 4. P. 135–155. <https://doi.org/10.1177/0008125619859317>
26. Mishra S., Ewing M.T., Cooper H.B. Artificial intelligence focus and firm performance // *Journal of the Academy of Marketing Science*. 2022. Vol. 50. No. 6. P. 1176–1197. <https://doi.org/10.1007/s11747-022-00876-5>
27. Peltier J.W., Dahl A.J., Schibrowsky J.A. Artificial intelligence in interactive marketing: A conceptual framework and research agenda // *Journal of Research in Interactive Marketing*. 2024. Vol. 18. No. 12. P. 54–90. <https://doi.org/10.1108/JRIM-01-2023-0030>
28. Manser Payne E.H., Peltier J., Barger V.A. Enhancing the value co-creation process: artificial intelligence and mobile banking service platforms // *Journal of Research in Interactive Marketing*. 2021. Vol. 15. No. 1. P. 68–85. <https://doi.org/10.1108/JRIM-10-2020-0214>
29. Vlačić B., Corbo L., e Silva S.C., Dabić M. The evolving role of artificial intelligence in marketing: A review and research agenda // *Journal of Business Research*. 2021. Vol. 128. P. 187–203. <https://doi.org/10.1016/j.jbusres.2021.01.055>
30. Bhagat R., Chauhan V., Bhagat P. Investigating the impact of artificial intelligence on consumer's purchase intention in e-retailing // *Foresight*. 2023. Vol. 25. No. 2. P. 249–263. <https://doi.org/10.1108/FS-10-2021-0218>
31. Huang M.H., Rust R.T. A strategic framework for artificial intelligence in marketing // *Journal of the Academy of Marketing Science*. 2021. Vol. 49. P. 30–50. <https://doi.org/10.1007/s11747-020-00749-9>
32. Dekimpe M.G. Retailing and retailing research in the age of big data analytics // *International Journal of Research in Marketing*. 2020. Vol. 37. No. 1. P. 3–14. <https://doi.org/10.1016/j.ijresmar.2019.09.001>
33. Pantano E., Rese A., Baier D. Enhancing the online decision-making process by using augmented reality: A two country comparison of youth markets // *Journal of Retailing and Consumer Services*. 2017. Vol. 38. P. 81–95. <https://doi.org/10.1016/j.jretconser.2017.05.011>
34. Reinartz W., Wiegand N., Imschloss M. The impact of digital transformation on the retailing value chain // *International Journal of Research in Marketing*. 2019. Vol. 36. No. 3. P. 350–366. <https://doi.org/10.1016/j.ijresmar.2018.12.002>
35. Astawa I.G.N.M.W., Sukawati T.G.R.S. The role of perceived value mediate the effect of utilitarian and hedonic shopping value on intent to online repurchase // *International Journal of Management and Commerce Innovations*. 2019. Vol. 6. No. 1. P. 1232–1242.
36. Qian M., Xu Z. A study of dynamic recognition of consumer brand decision-making preference based on machine learning method // *Nankai Business Review*. 2019. Vol. 22. No. 1. P. 66–76.
37. Haenlein M., Kaplan A., Tan C.W., Zhang P. Artificial intelligence (AI) and management analytics // *Journal of Management Analytics*. 2019. Vol. 6. No. 4. P. 341–343. <https://doi.org/10.1080/23270012.2019.1699876>
38. Sohn K., Kwon O. Technology acceptance theories and factors influencing artificial Intelligence-based intelligent products // *Telematics and Informatics*. 2020. Vol. 47. Article 101324. <https://doi.org/10.1016/j.tele.2019.101324>
39. Attig C., Franke T. Abandonment of personal quantification: A review and empirical study investigating reasons for wearable activity tracking attrition // *Computers in Human Behavior*. 2020. Vol. 102. P. 223–237. <https://doi.org/10.1016/j.chb.2019.08.025>
40. Yan Y., Chen H., Shao B., Lei Y. How IT affordances influence customer engagement in live streaming commerce? A dual-stage analysis of PLS-SEM and fsQCA // *Journal of Retailing and Consumer Services*. 2023. Vol. 74. Article 103390. <https://doi.org/10.1016/j.jretconser.2023.103390>
41. Sun Y., Shao X., Li X., Guo Y., Nie K. How live streaming influences purchase intentions in social commerce: An IT affordance perspective // *Electronic Commerce Research and Applications*. 2019. Vol. 37. Article 100886. <https://doi.org/10.1016/j.elerap.2019.100886>
42. De Oliveira Santini F., Ladeira W.J., Pinto D.C., Herter M.M., Sampaio C.H., Babin B.J. Customer engagement in social media: a framework and meta-analysis // *Journal of the Academy of Marketing Science*. 2020. Vol. 48. No. 6. P. 1211–1228. <https://doi.org/10.1007/s11747-020-00731-5>
43. Garg P., Gupta B., Dzever S., Sivarajah U., Kumar V. Examining the relationship between social media analytics practices and business performance in the Indian retail and IT industries: The mediation role of customer engagement // *International Journal of Information Management*. 2020. Vol. 52. Article 102069. <https://doi.org/10.1016/j.ijinfomgt.2020.102069>
44. Busalim A.H., Ghabban F. Customer engagement behaviour on social commerce platforms: An empirical study // *Technology in Society*. 2021. Vol. 64. Article 101437. <https://doi.org/10.1016/j.techsoc.2020.101437>
45. Capatina A., Kachour M., Lichy J., Micu A., Micu A.E., Codignola F. Matching the future capabilities of an artificial intelligence-based software for social media marketing with potential users' expectations // *Technological Forecasting and Social Change*. 2020. Vol. 151. Article 119794. <https://doi.org/10.1016/j.techfore.2019.119794>
46. Di Fatta D., Patton D., Viglia G. The determinants of conversion rates in SME e-commerce websites // *Journal of Retailing and Consumer Services*. 2018. Vol. 41. P. 161–168. <https://doi.org/10.1016/j.jretconser.2017.12.008>
47. Roy S.K., Eshghi A., Sarkar A. Antecedents and consequences of brand love // *Journal of Brand Management*. 2013. Vol. 20. P. 325–332. <https://doi.org/10.1057/bm.2012.24>
48. Chang C.W., Huang H.C., Wang S.J., Lee H. Relational bonds, customer engagement, and service quality // *The Service Industries Journal*. 2021. Vol. 41. No. 5–6. P. 330–354. <https://doi.org/10.1080/02642069.2019.1611784>
49. Khattab S.A., Al Shaar I.M., Zaid M.K.A., Qutaishat F.T. The effect of relational bonds on e-commerce use, the mediating effect of customers' online trust: evidence from Jordan // *International Journal of Business and Systems Research*. 2023. Vol. 17. No. 5. P. 483–503.

50. Brakus J.J., Schmitt B.H., Zarantonello L. Brand experience: what is it? How is it measured? Does it affect loyalty? // *Journal of Marketing*. 2009. Vol. 73. No. 3. P. 52–68. <https://doi.org/10.1509/jmkg.73.3.052>
51. Hsu C.L. Enhancing brand love, customer engagement, brand experience, and repurchase intention: Focusing on the role of gamification in mobile apps // *Decision Support Systems*. 2023. Vol. 174. Article 114020. <https://doi.org/10.1016/j.dss.2023.114020>
52. Islam J.U., Hollebeek L.D., Rahman Z., Khan I., Rasool A. Customer engagement in the service context: An empirical investigation of the construct, its antecedents and consequences // *Journal of Retailing and Consumer Services*. 2019. Vol. 50. P. 277–285. <https://doi.org/10.1016/j.jretconser.2019.05.018>
53. Flavián C., Ibáñez-Sánchez S., Orús C. The impact of virtual, augmented and mixed reality technologies on the customer experience // *Journal of Business Research*. 2019. Vol. 100. P. 547–560. <https://doi.org/10.1016/j.jbusres.2018.10.050>
54. Hoyer W.D., Kroschke M., Schmitt B., Kraume K., Shankar V. Transforming the customer experience through new technologies // *Journal of Interactive Marketing*. 2020. Vol. 51. No. 1. P. 57–71. <https://doi.org/10.1016/j.intmar.2020.04.001>
55. Chen Y., Fay S., Wang Q. The role of marketing in social media: How online consumer reviews evolve // *Journal of Interactive Marketing*. 2011. Vol. 25. No. 2. P. 85–94. <https://doi.org/10.1016/j.intmar.2011.01.003>
56. Choi H., Kandampully J. The effect of atmosphere on customer engagement in upscale hotels: An application of SOR paradigm // *International Journal of Hospitality Management*. 2019. Vol. 77. P. 40–50. <https://doi.org/10.1016/j.ijhm.2018.06.012>
57. Eigenraam A.W., Eelen J., Van Lin A., Verlegh P.W. A consumer-based taxonomy of digital customer engagement practices // *Journal of Interactive Marketing*. 2018. Vol. 44. No. 1. P. 102–121. <https://doi.org/10.1016/j.intmar.2018.07.002>
58. He W., Wu H., Yan G., Akula V., Shen J. A novel social media competitive analytics framework with sentiment benchmarks // *Information & Management*. 2015. Vol. 52. No. 7. P. 801–812. <https://doi.org/10.1016/j.im.2015.04.006>
59. Bae B.R., Kim S.-E. Effect of brand experiences on brand loyalty mediated by brand love: the moderated mediation role of brand trust // *Asia Pacific Journal of Marketing and Logistics*. 2023. Vol. 35. No. 10. P. 2412–2430. <https://doi.org/10.1108/apjml-03-2022-0203>
60. Andreini D., Pedeliento G., Zarantonello L., Solerio C. A renaissance of brand experience: Advancing the concept through a multi-perspective analysis // *Journal of Business Research*. 2019. Vol. 96. P. 355–365. <https://doi.org/10.1016/j.jbusres.2018.05.046>
61. Bapat D., Thanigan J. Exploring relationship among brand experience dimensions, brand evaluation and brand loyalty // *Global Business Review*. 2016. Vol. 17. No. 6. P. 1357–1372. <https://doi.org/10.1177/0972150916660401>
62. Ebrahim R., Ghoneim A., Irani Z., Fan Y. A brand preference and repurchase intention model: the role of consumer experience // *Journal of Marketing Management*. 2016. Vol. 32. No. 13–14. P. 1230–1259. <https://doi.org/10.1080/0267257X.2016.1150322>
63. Singh D., Bajpai N., Kulshreshtha K. Brand experience – brand love relationship for Indian hypermarket brands: The moderating role of customer personality traits // *Journal of Relationship Marketing*. 2021. Vol. 20. No. 1. P. 20–41. <https://doi.org/10.1080/15332667.2020.1715179>
64. Hwang J., Choe J.Y.J., Kim H.M., Kim J.J. The antecedents and consequences of memorable brand experience: Human baristas versus robot baristas // *Journal of Hospitality and Tourism Management*. 2021. Vol. 48. P. 561–571. <https://doi.org/10.1016/j.jhtm.2021.08.013>
65. Hwang J., Kim H., Kim H.M. Relationships among memorable brand experience, brand preference, and behavioral intentions: focusing on the difference between robot servers and human servers // *Journal of Hospitality and Tourism Technology*. 2023. Vol. 14. No. 3. P. 430–443. <https://doi.org/10.1108/JHTT-09-2021-0254>
66. Dias R.P., Kusuma N.I. The effect of brand identity and brand preference on Starbucks repurchase interest in Bekasi City // *Jurnal Ekonomi dan Bisnis Digital*. 2023. Vol. 2. No. 3. P. 1031–1054. <https://doi.org/10.55927/ministal.v2i3.4207>
67. Can Y., Erdil O. Determining antecedent of re-purchase intention: The role of perceived value and consumer's interest factor // *International Business Research*. 2018. Vol. 11. No. 4. P. 17–31. <https://doi.org/10.5539/ibr.v11n4p17>
68. Izbán E., Balarabe F., Jakada B. Consumer satisfaction and repurchase intentions // *Developing Country Studies*. 2016. Vol. 6. No. 2. P. 96–100.
69. Langga A., Kusumawati A., Alhabsji T. Intensive distribution and sales promotion for improving customer-based brand equity (CBBE), re-purchase intention and word-of-mouth (WOM) // *Journal of Economic and Administrative Sciences*. 2021. Vol. 37. No. 4. P. 577–595. <https://doi.org/10.1108/JEAS-03-2019-0041>
70. Yasri Y., Susanto P., Hoque M.E., Gusti M.A. Price perception and price appearance on repurchase intention of Gen Y: do brand experience and brand preference mediate? // *Heliyon*. 2020. Vol. 6. No. 11. Article e05532. <https://doi.org/10.1016/j.heliyon.2020.e05532>
71. Sullivan Y.W., Kim D.J. Assessing the effects of consumers' product evaluations and trust on repurchase intention in e-commerce environments // *International Journal of Information Management*. 2018. Vol. 39. P. 199–219. <https://doi.org/10.1016/j.ijinfomgt.2017.12.008>
72. Tynan C., McKechnie S. Experience marketing: a review and reassessment // *Journal of Marketing Management*. 2009. Vol. 25. No. 5–6. P. 501–517. <https://doi.org/10.1362/026725709X461821>
73. Diallo M.F., Siqueira J.R. (Jr.) How previous positive experiences with store brands affect purchase intention in emerging countries: A comparison between Brazil and Colombia // *International Marketing Review*. 2017. Vol. 34. No. 4. P. 536–558. <https://doi.org/10.1108/IMR-07-2014-0224>
74. Moreira A.C., Fortes N., Santiago R. Influence of sensory stimuli on brand experience, brand equity and purchase intention // *Journal of Business Economics and Management*. 2017. Vol. 18. No. 1. P. 68–83. <https://doi.org/10.3846/16111699.2016.1252793>
75. Bell E., Bryman A. The ethics of management research: an exploratory content analysis // *British Journal of Management*. 2007. Vol. 18. No. 1. P. 63–77. <https://doi.org/10.1111/j.1467-8551.2006.00487.x>
76. Sekaran U., Bougie R. *Research methods for business: A skill building approach*. Wiley, 2016.

77. Amoako G.K., Anabila P., Asare Effah E., Kumi D.K. Mediation role of brand preference on bank advertising and customer loyalty: A developing country perspective // *International Journal of Bank Marketing*. 2017. Vol. 35. No. 6. P. 983–996. <https://doi.org/10.1108/IJBM-07-2016-0092>
78. O’Leary-Kelly S.W., Vokurka R.J. The empirical assessment of construct validity // *Journal of Operations Management*. 1998. Vol. 16. No. 4. P. 387–405. [https://doi.org/10.1016/S0272-6963\(98\)00020-5](https://doi.org/10.1016/S0272-6963(98)00020-5)
79. Anderson J.C., Gerbing D.W. Structural equation modeling in practice: A review and recommended two-step approach // *Psychological Bulletin*. 1988. Vol. 103. No. 3. Article 411423. <https://doi.org/10.1037/0033-2909.103.3.411>
80. Fornell C., Larcker D.F. Evaluating structural equation models with unobservable variables and measurement error // *Journal of Marketing Research*. 1981. Vol. 18. No. 1. P. 39–50. <https://doi.org/10.2307/3151312>
81. Henseler J., Ringle C.M., Sarstedt M. A new criterion for assessing discriminant validity in variance-based structural equation modeling // *Journal of the Academy of Marketing Science*. 2015. Vol. 43. No. 1. P. 115–135. <https://doi.org/10.1007/s11747-014-0403-8>
82. Nunnally J.C. *Psychometric Theory* (2nd edition). New York: McGraw-Hill Book Company, 1978.
83. Prentice C., Dominique Lopes S., Wang X. The impact of artificial intelligence and employee service quality on customer satisfaction and loyalty // *Journal of Hospitality Marketing and Management*. 2020. Vol. 29. No. 7. P. 739–756. <https://doi.org/10.1080/19368623.2020.1722304>
84. Huang M.H., Rust R.T. Artificial intelligence in service // *Journal of Service Research*. 2018. Vol. 21. No. 2. P. 155–172. <https://doi.org/10.1177/1094670517752459>
85. McDowell W.C., Wilson R.C., Kile C.O. (Jr.) An examination of retail website design and conversion rate // *Journal of Business Research*. 2016. Vol. 69. No. 11. P. 4837–4842. <https://doi.org/10.1016/j.jbusres.2016.04.040>
86. Chang P.L., Chieng M.H. Building consumer–brand relationship: A cross-cultural experiential view // *Psychology & Marketing*. 2006. Vol. 23. No. 11. P. 927–959. <https://doi.org/10.1002/MAR.20140>

Об авторах

Раед Насер Алькаид

преподаватель, заведующий кафедрой, факультет бизнеса, департамент информационных систем управления, Университет прикладных наук Аль-Балка, Эс-Салт 19117, Иордания, а/я 206;

E-mail: Raedalkaied@bau.edu.jo

ORCID: 0000-0002-6288-7503

Шади Ахмед Хаттаб

доцент, факультет бизнеса, департамент информационных систем управления, Университет прикладных наук Аль-Балка, Эс-Салт 19117, Иордания, а/я 206;

E-mail: Shadikhattab@bau.edu.jo

ORCID: 0000-0002-0824-1437

Исхак М. Аль Шаар

профессор, факультет бизнеса, департамент информационных систем управления, Университет прикладных наук Аль-Балка, Эс-Салт 19117, Иордания, а/я 206;

E-mail: I.shaar@bau.edu.jo

ORCID: 0000-0001-6036-4189

Мохаммед Хайр Абу Заид

профессор, факультет бизнеса, департамент информационных систем управления, Университет прикладных наук Аль-Балка, Эс-Салт 19117, Иордания, а/я 206;

E-mail: Mohammed_abu_zaid@bau.edu.jo

ORCID: 0000-0002-6687-1285

Сахер А.И. Аль-Базаян

доцент, факультет бизнеса, департамент информационных систем управления, Университет прикладных наук Аль-Балка, Эс-Салт 19117, Иордания, а/я 206;

E-mail: bazaiah1@bau.edu.jo

ORCID: 0000-0002-6648-8091