БИЗНЕС- ИНФОРМАТИКА

НАУЧНЫЙ ЖУРНАЛ НИУ ВШЭ

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

СОДЕРЖАНИЕ

*В.Л. Макаров, А.Р. Бахтизин, Г.Л. Бекларян,
А.С. Акопов, Н.В. Стрелковский*

Моделирование миграционных и демографических
процессов с использованием FLAME GPU7

Ю.А. Зеленков

Анализ процесса, ведущего к финансовому
краху фирмы, на основе байесовских сетей.....22

Т.К. Богданова, Л.В. Жукова

Информационно-логическая модель
экспресс-анализа соответствия состояния
предприятия, удовлетворяющего
нормативам и регламентам, на основе
общедоступных данных42

А.И. Алтынов

Цифровая трансформация музыкальных
агрегаторов и дистрибьюторов
на примере России56

N. Gautam, N. Kumar

Customer segmentation using k -means clustering
for developing sustainable marketing strategies72

*S. Madadi, F. Hosseinzadeh Lotfi,
M. Fallah Jelodar, M. Rostamy-Malkhalifehd*

Centralized resource allocation based
on energy saving and environmental
pollution reduction using DEA models.....83

И.о. главного редактора
Е.П. Зараменских

Компьютерная верстка
О.А. Богданович

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,
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»

«**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.

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.

В соответствии с решением президиума Высшей аттестационной комиссии Российской Федерации журнал включен в Перечень российских рецензируемых научных журналов, в которых должны быть опубликованы основные научные результаты дис-

сертаций на соискание ученых степеней доктора и кандидата наук. 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) по следующим научным специальностям и соответствующим отраслям науки: 05.13.10 – Управление в социальных и экономических системах (технические науки); 05.13.11 – Математическое и программное обеспечение вычислительных машин, комплексов и компьютерных сетей (технические науки); 05.13.18 – Математическое моделирование, численные методы и комплексы программ (технические науки); 05.25.05 – Информационные системы и процессы (технические науки); 08.00.05 – Экономика и управление народным хозяйством (по отраслям и сферам деятельности) (экономические науки); 08.00.13 – Математические и инструментальные методы экономики (экономические науки).

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 зарегистрирован Федеральной службой по надзору в сфере связи, информационных технологий и массовых коммуникаций (Роскомнадзор), свидетельство ПИ № ФС77-66609 от 08 августа 2016 г.

Международный стандартный серийный номер (ISSN): 1998-0663 (на русском), 2587-814X (на английском).

РЕДАКЦИОННАЯ КОЛЛЕГИЯ

И.О. ГЛАВНОГО РЕДАКТОРА

Зараменских Евгений Петрович

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

ЧЛЕНЫ РЕДКОЛЛЕГИИ

Абдульраб Абиб

Национальный институт прикладных наук, Руан, Франция

Авдошин Сергей Михайлович

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

Акопов Андраник Сумбатович

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

Алескерев 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

Бабкин Эдуард Александрович

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

Баландин Сергей Игоревич

Ассоциация FRUCT, Хельсинки, Финляндия

Баранов Александр Павлович

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

Баракнин Владимир Борисович

Федеральный исследовательский центр информационных
и вычислительных технологий, Новосибирск, Россия

Беккер Йорг

Университет Мюнстера, Мюнстер, Германия

Белов Владимир Викторович

Рязанский государственный радиотехнический университет,
Рязань, Россия

Вестнер Маркус

Регенбургский университет прикладных наук,
Регенбург, Германия

Гаврилова Татьяна Альбертовна

Санкт-Петербургский государственный университет,
Санкт-Петербург, Россия

Глотен Эрве

Тулонский университет, Ла-Гард, Франция

Голосов Алексей Олегович

Компания «ФОРС – Центр разработки», Москва, Россия

Грибов Андрей Юрьевич

Компания «КиберПлат», Москва, Россия

Громов Александр Игоревич

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

Гурвич Владимир Александрович

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

Демидова Лилия Анатольевна

Рязанский государственный радиотехнический университет,
Рязань, Россия

Джейкобс Лоренц

Университет Цюриха, Цюрих, Швейцария

Дискин Иосиф Евгеньевич

Всероссийский центр изучения общественного мнения,
Москва, Россия

Ефимушкин Владимир Александрович

Центральный научно-исследовательский институт связи,
Москва, Россия

Зандкуль Курт

Университет Ростока, Росток, Германия

Иванников Александр Дмитриевич

Институт проблем проектирования в микроэлектронике РАН,
Москва, Россия

Ильин Николай Иванович

Федеральная служба охраны Российской Федерации, 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

Мейер Питер

Комиссия ООН по науке и технологиям, Женева, Швейцария

Миркин Борис Григорьевич

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

Мотгль Вадим Вячеславович

Тульский государственный университет, Тула, 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

Сюняев Али Рашидович

Технологический институт Карлсруэ, Карлсруэ, Германия

Таратухин Виктор Владимирович

Университет Мюнстера, Мюнстер, Германия

Триболе Жозе

Университет Лиссабона, Лиссабон, Португалия

Ульянов Михаил Васильевич

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

Ускенбаева Раиса Кабиевна

Международный университет информационных технологий,
Алматы, Казахстан

Цуканова Ольга Анатольевна

Санкт-Петербургский национальный исследовательский
университет информационных технологий, механики и оптики,
Санкт-Петербург, Россия

Чхартишвили Александр Гелеванович

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

Штраус Кристина

Университет Вены, Вена, Австрия

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

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

Vol. 16 No. 1 – 2022

BUSINESS INFORMATICS

HSE SCIENTIFIC JOURNAL

Publisher:

National Research University
Higher School of Economics

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

CONTENTS

*V.L. Makarov, A.R. Bakhtizin, G.L. Beklaryan,
A.S. Akopov, N.V. Strelkovskii*

Simulation of migration and demographic
processes using FLAME GPU7

Y.A. Zelenkov

Analysing the firm failure process using
Bayesian networks.....22

T.K. Bogdanova, L.V. Zhukova

Information-logical model of express analysis
of the state of the enterprise that meets
the requirements of standards and regulations,
based on publicly available data.....42

A.I. Altynov

Digital transformation of music aggregation
and distribution companies: The case of Russia56

N. Gautam, N. Kumar

Customer segmentation using *k*-means clustering
for developing sustainable marketing strategies72

*S. Madadi, F. Hosseinzadeh Lotfi,
M. Fallah Jelodar, M. Rostamy-Malkhalifehd*

Centralized resource allocation based
on energy saving and environmental
pollution reduction using DEA models.....83

Acting Editor-in-Chief

E. Zaramenskikh

Computer Making-up:

O. Bogdanovich

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

© National Research University
Higher School of Economics

ABOUT THE JOURNAL

Business Informatics is a peer reviewed interdisciplinary academic journal published since 2007 by National Research University Higher School of Economics (HSE), Moscow, Russian Federation. The journal is administered by HSE Graduate School of Business. The journal is published quarterly.

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 areas of, but not limited to: 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.

International Standard Serial Number (ISSN): 2587-814X (in English), 1998-0663 (in Russian).

EDITORIAL BOARD

ACTING EDITOR-IN-CHIEF

Evgeny P. Zaramenskikh

National Research University Higher School of Economics,
Moscow, Russia

EDITORIAL BOARD

Habib Abdulrab

National Institute of Applied Sciences, Rouen, France

Sergey M. Avdoshin

National Research University Higher School of Economics,
Moscow, Russia

Andranik S. Akopov

National Research University Higher School of Economics,
Moscow, Russia

Fuad T. Aleskerov

National Research University Higher School of Economics,
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

Eduard A. Babkin

National Research University Higher School of Economics,
Nizhny Novgorod, Russia

Sergey I. Balandin

Finnish-Russian University Cooperation in Telecommunications
(FRUCT), Helsinki, Finland

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

Vladimir V. Belov

Ryazan State Radio Engineering University, Ryazan, Russia

Alexander G. Chkhartishvili

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

Vladimir A. Efimushkin

Central Research Institute of Communications, Moscow, Russia

Tatiana A. Gavrilova

Saint-Petersburg University, St. Petersburg, Russia

Hervé Glotin

University of Toulon, La Garde, France

Alexey O. Golosov

FORS Development Center, Moscow, Russia

Andrey Yu. Gribov

CyberPlat Company, Moscow, Russia

Alexander I. Gromoff

National Research University Higher School of Economics,
Moscow, Russia

Vladimir A. Gurvich

Rutgers, The State University of New Jersey, Rutgers, USA

Laurence Jacobs

University of Zurich, Zurich, Switzerland

Liliya A. Demidova

Ryazan State Radio Engineering University, Ryazan, Russia

Iosif E. Diskin

Russian Public Opinion Research Center, Moscow, Russia

Nikolay I. Ilyin

Federal Security Guard of the Russian Federation,
Moscow, Russia

Dmitry V. Isaev

National Research University Higher School of Economics,
Moscow, Russia

Alexander D. Ivannikov

Institute for Design Problems in Microelectronics, Russian Academy
of Sciences, Moscow, Russia

Valery A. Kalyagin

National Research University Higher School of Economics,
Nizhny Novgorod, Russia

Tatiana K. Kravchenko

National Research University Higher School of Economics,
Moscow, Russia

Sergei O. Kuznetsov

National Research University Higher School of Economics,
Moscow, Russia

Kwei-Jay Lin

Nagoya Institute of Technology, Nagoya, Japan

Mikhail I. Lugachev

Lomonosov Moscow State University, Moscow, Russia

Svetlana V. Maltseva

National Research University Higher School of Economics,
Moscow, Russia

Peter Major

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

Boris G. Mirkin

National Research University Higher School of Economics,
Moscow, Russia

Vadim V. Mottl

Tula State University, Tula, 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

Christine Strauss

University of Vienna, Vienna, Austria

Ali R. Sunyaev

Karlsruhe Institute of Technology, Karlsruhe, Germany

Victor V. Taratukhin

University of Munster, Munster, Germany

José M. Tribolet

Universidade de Lisboa, Lisbon, Portugal

Olga A. Tsukanova

Saint-Petersburg National Research University of Information
Technologies, Mechanics and Optics, St. Petersburg, Russia

Mikhail V. Ulyanov

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

Raissa K. Uskenbayeva

International Information Technology University, Almaty, Kazakhstan

Markus Westner

Regensburg University of Applied Sciences, Regensburg, Germany

[DOI: 10.17323/2587-814X.2022.1.7.21](https://doi.org/10.17323/2587-814X.2022.1.7.21)

Моделирование миграционных и демографических процессов с использованием FLAME GPU

В.Л. Макаров^a

E-mail: makarov@cemi.rssi.ru

А.Р. Бахтизин^a

E-mail: albert@cemi.rssi.ru

Г.Л. Бекларян^a

E-mail: glbeklaryan@gmail.com

А.С. Акопов^{b, a}

E-mail: aakopov@hse.ru

Н.В. Стрелковский^c

E-mail: strelkon@iiasa.ac.at

^a Центральный экономико-математический институт, Российская академия наук
Адрес: Россия, 117418, г. Москва, Нахимовский проспект, д. 47

^b Национальный исследовательский университет «Высшая школа экономики»
Адрес: Россия, 101000, г. Москва, ул. Мясницкая, д. 20

^c Международный институт прикладного системного анализа (МИПСА)
Адрес: Австрия, г. Лаксенбург

Аннотация

В данной статье представлен подход к моделированию миграционных и демографических процессов с использованием платформы FLAME GPU, предназначенной для крупномасштабного агент-ориентированного моделирования. Данный подход основан на ранее предложенной имитационной модели взаимодействия двух сообществ: мигрантов и коренных жителей, реализованной в системе AnyLogic. Такая модель имела относительно малую размерность дискретного пространства для существования популяций и детерминированную систему принятия решений каждого агента. Вместе с тем, наличие множественных взаимодействий между агентами и переходов между их состояниями обуславливает высокую вычислительную сложность подобной модели. Использование FLAME GPU позволило существенно расширить возможности проведения численных экспериментов, главным образом, за счет распараллеливания вычислительных процессов на уровне каждого агента и занимаемого им ресурса, а также реализации механизма множественных вычислений класса Монте-Карло. В результате исследованы зависимости ключевых характеристик рассматриваемой системы (в частности, общей численности населения, доли мигрантов, количества ассимилированных мигрантов, темпов роста ВВП и др.) от наиболее важных параметров модели (например, доли новых мигрантов, государственных расходов на интеграцию, периодичности создания новых рабочих мест и др.). Предложенный подход может быть использован для разработки систем поддержки принятия решений по планированию найма новых сотрудников на основе прогнозной динамики миграционных и демографических процессов.

Ключевые слова: агентное моделирование, миграционные и демографические процессы, популяционная динамика, крупномасштабное моделирование, параллельные вычисления на GPU, суперкомпьютерное моделирование, поддержка принятия решений

Цитирование: Макаров В.Л., Бахтизин А.Р., Бекларян Г.Л., Акопов А.С., Стрелковский Н.В. Моделирование миграционных и демографических процессов с использованием FLAME GPU // Бизнес-информатика. 2022. Т. 16. № 1. С. 7–21. DOI: 10.17323/2587-814X.2022.1. 7.21

Введение

В настоящее время многие компании и организации сталкиваются с дефицитом трудовых ресурсов, необходимостью формирования плана найма новых сотрудников на долгосрочную перспективу с учётом прогнозируемой динамики миграционных и демографических процессов. В условиях ухудшения внутренней демографической ситуации, многие предприятия вынуждены переориентироваться на привлечение мигрантов. Однако, из-за наличия множества препятствий, обусловленных недостаточным уровнем владения местным языком, отсутствием требуемого уровня квалификации и ряда других факторов, возникают естественные ограничения в привлечении внешней рабочей силы, которые могут быть преодолены только за счёт процессов ассимиляции и интеграции, реализуемых в свою очередь в условиях финансовой поддержки со стороны государства.

Разработка систем поддержки принятия по планированию найма новых сотрудников и созданию новых рабочих мест может быть основана на имитационных моделях, учитывающих прогнозную динамику рынка трудовых ресурсов. Так, например, в условиях распространения эпидемий, государством могут быть введены ограничения на приток внешней рабочей силы, приводящие к дефициту трудовых ресурсов в отраслях экономики, ориентированных на мигрантов. С другой стороны, развитие высокотехнологичных предприятий обуславливает необходимость создания новых рабочих мест, привлекательных для высококвалифицированного местного населения. При этом, ключевым вопросом для бизнеса и государства является обеспечение рационального сосуществования двух взаимодействующих сообществ: мигрантов и коренных жителей.

В результате, актуализируется задача исследования и прогнозирования миграционных и демографических процессов с использованием методов имитационного моделирования. Подобные методы, в

частности, агент-ориентированный подход (АОМ), позволяют построить и исследовать поведение цифрового сообщества, состоящего из агентов со своими индивидуальными правилами поведения.

Среди известных агент-ориентированных моделей дискретного типа (т.е., с дискретным пространством существования агентов) можно выделить хорошо известную «Сахарную модель» (Sugarscape model) [1], которая получила широкое распространение в качестве инструмента анализа привлекательности локальных участков с ресурсами («условным сахаром») для агентов. Следует отметить модель «кочевников и землепашцев» [2, 3], в которой одни агенты («условные землепашцы») создают ресурсы, а другие уничтожают их с целью расширения личного пространства («условные кочевники»). Также, хорошо известны модели сегрегации населения класса Шеллинга [4, 5], модели движения ансамбля беспилотных транспортных средств [6, 7], модели миграционных и демографических процессов [8–10] и др.

Среди инструментов имитационного моделирования, позволяющих реализовать АОМ общего назначения, можно выделить NetLogo, AnyLogic [11], а также системы, предназначенные для суперкомпьютерного агентного моделирования Repast HPC [12], MASS CUDA [13, 14], FLAME GPU [15–18] и др.

В целом, большинство подобных систем различаются способом программной реализации агентов: либо с использованием только одного центрального процессора CPU (например, NetLogo, AnyLogic), либо на основе мультикластерной архитектуры на основе семейства CPU (Repast HPC) и методов MPI (Message Passing Interface), и, наконец, на основе графических процессоров GPU (Graphics Processing Unit) [19]. Среди данных платформ следует выделить, FLAME GPU ², которая характеризуется рядом преимуществ. Данная платформа является свободным программным обеспечением с открытым исходным кодом, поддерживает возможность

¹ <https://flamegpu.com/>

визуализации модели с использованием программной библиотеки OpenGL [20]. Кроме того, она позволяет осуществлять множественный запуск ансамбля моделей [21–24], как на персональном компьютере (ПК) с использованием Visual Studio C++, так и под управлением операционной системы Linux на суперкомпьютерных системах класса NVIDIA CUDA² (например, NVIDIA QUADRO RTX, NVIDIA Tesla и т.д.). В результате обеспечивается гибкий подход к разработке АОМ на обычных ПК и проведению вычислительных экспериментов на кластерах GPU.

Платформа FLAME GPU использовалась для разработки агентных моделей в различных областях – от биологии до экономики. Насколько известно авторам данной статьи, на момент её написания платформа FLAME GPU применялась для моделирования миграционных процессов лишь в двух работах [25, 26]. Другие наиболее близкие работы – моделирование поведения агентов в «сахарной» модели, описанной выше [27]. Моделирование миграционных процессов представляет дополнительную техническую сложность в связи с необходимостью динамически создавать агентов-мигрантов в процессе симуляции.

Данная работа нацелена на разработку агент-ориентированной модели популяционной динамики двух взаимодействующих сообществ: коренных жителей и мигрантов с программной реализацией в системе суперкомпьютерного имитационного моделирования FLAME GPU. Предлагаемый подход позволил осуществить серию вариационных экспериментов и выявить важные зависимости в динамике исследуемых миграционных и демографических процессах.

1. Общее описание модели

Рассматривается искусственная социально-экономическая система, состоящая из коренного и внешнего населения, взаимодействующего друг с другом посредством как личных контактов типа «агент-агент», так и с помощью передачи сообщений. В подобной системе агентами являются как индивидуумы (коренные жители и мигранты), так ресурсы, которые обладают «способностью» оценивать ближайших агентов и отправлять им информацию о своем состоянии и соответствии интересам агентов. В данном случае, высокотехнологичные

ресурсы в большей степени соответствуют коренным жителям, а низкотехнологичные – мигрантам.

Таким образом, важной особенностью реализации имитационной модели взаимодействия сообществ мигрантов и коренных жителей во FLAME GPU, является механизм непрерывного обмена сообщениями между агентами и ресурсами.

Как и ранее, многочастичные взаимодействия агентов моделируются в двумерном дискретном пространстве с относительно небольшой размерностью 100×100 и вместимостью не более 10 000 агентов. При этом реализация модели во FLAME GPU направлена в большей степени на повышение временной эффективности модели в условиях выполнения множественных расчетов с использованием методов класса Монте-Карло. Размерность дискретного пространства, ограничивающего как количество имеющихся рабочих мест, так и численность связанных с ними агентов, может быть существенно увеличена практически без потерь временной эффективности, главным образом, за счет распараллеливания вычислительных процедур («функций уровня агентов») на графических процессорах (GPU). В подобном дискретном пространстве агент может занимать только одну ячейку с рабочим местом или без него в каждый момент времени. Вместе с тем, сложность параллельной реализации рассматриваемой модели и отсутствие автоматической синхронизации агентов во FLAME GPU, обуславливают необходимость дополнительного контроля данного правила и устранения возможных коллизий в случае необходимости.

Как и ранее, в модели обеспечивается создание «высокотехнологичных» и «низкотехнологичных» рабочих мест, на которые нацелены коренные жители и мигранты, соответственно. Оба типа рабочих мест обеспечивают занимающих их агентов-индивидуумов приращением уровня личного комфорта. Вместе с тем, на уровень личного комфорта коренного населения негативно влияет соседство с агентами-мигрантами, что обуславливается имеющимися культурными различиями и психологическими особенностями агентов.

Все рабочие места формируются централизованно и равномерно случайным образом во всех свободных ячейках дискретного пространства с разными вероятностями, заданными для «высокотехнологичных» и «низкотехнологичных» рабочих

² <https://developer.nvidia.com/>

мест, соответственно. Несмотря на то, что данный подход является наиболее затратным для государства, он может помочь избежать дефицита рабочих мест, что особенно важно при высоких темпах миграции. К тому же, большее количество равномерно распределенных рабочих мест, позволяет существенно увеличить количество взаимных контактов между коренными жителями и мигрантов, что положительно влияет на уровень владения местным языком, возможность получения релевантного местного образования и т.д., что способствует снижению времени, требуемого на ассимиляцию и интеграцию.

Вклад «высокотехнологичных» и «низкотехнологичных» рабочих мест, занятых, как правило, коренными жителями и мигрантами, в экономический рост (ВВП) и государственные трансферты (ГТ) различен. Отношение ВВП на единицу трудовых ресурсов в «высокотехнологичных» отраслях экономики, значительно выше по сравнению с «низкотехнологичными». При этом, создание «низкотехнологичных» рабочих мест обуславливает дополнительные государственные расходы, которые также увеличиваются с ростом количества «безработных» агентов.

В модели обеспечивается приток мигрантов с последующей «трансформацией» прибывающих агентов в коренных жителей по истечению срока необходимого на ассимиляцию (1–30 лет). Иммиграция обусловлена в основном «гравитационным эффектом» [10], задающим усиливающую обратную связь между количеством имеющихся неассимилированных мигрантов и интенсивностью притока новых. При этом, в модели доля новых иммигрантов (от числа уже имеющихся), как и затраты на образование и интеграцию являются ключевыми управляющими параметрами. Поэтому, миграционный процесс в подобной системе, можно рассматривать как «управляемый» и «контролируемый» со стороны лица принимающего решения (государства).

На каждом шаге модели агентами реализуется поиск ближайшего рабочего места, соответствующего его типу. Вместе с тем, особенностью технической реализации модели во FLAME GPU является обратный порядок реализации данной процедуры, т.е., ресурсы отбирают себе наиболее подходящих агентов, и, в случае положительного исхода, назначают им свои координаты в качестве целевых ячеек, одновременно блокируя доступ всем остальным агентам.

Также агенты-коренные жители и агенты-мигранты осуществляют поиск наиболее подходящего партнера для брака и рождения детей (т.е., с учетом его возраста, семейного статуса и др.). Если уровень личного комфорта агента ниже заданного порогового уровня, он ищет работу, если выше и он пока не имеет семейных связей, то осуществляется поиск партнера для брака и рождения детей (конечно при условии подходящего возраста и прочих характеристик).

Итак, все агенты-индивидуумы могут находиться в стационарном состоянии, состоянии поиска рабочего места, состоянии поиска партнера, состоянии готовности иметь детей и т.д. Агенты-мигранты могут также перейти в состояние ассимиляции по истечению некоторого срока, являющегося эндогенной характеристикой модели. При этом, коренные жители характеризуются более высокими значениями пороговых характеристик (в частности, минимальный уровень личного комфорта), обуславливающих их переход в новые состояния, например, состояние поиска рабочего места, стационарное состояние, рождение детей и др.

Формальная постановка задачи и детализированное описание модельных зависимостей (без учета эффекта ассимиляции и интеграции) представлены в работе [8].

2. Программная реализация

Основные вычислительные процедуры и функции предложенной имитационной модели представлены в *таблице 1* с учётом условной последовательности их исполнения. Функции типа **FLAMEGPU_STEP_FUNCTION** реализуются в каждый модельный момент времени на уровне центрального процессора (CPU), функции класса **FLAMEGPU_AGENT_FUNCTION** последовательно выполняются в режиме параллельных вычислений с использованием графических процессоров (GPUs). При этом, более высокая производительность в сравнении с традиционным способом реализации агент-ориентированных моделей достигается за счет распараллеливания логики работы каждого агента, обменивающихся друг с другом сообщениями с учётом их пространственного расположения.

В *таблице 1* под данными «по агентам» понимаются характеристики агентов-коренных жителей и агентов-мигрантов (например, пол, возраст, семейный статус, тип агента и т. д.), а «данные по ресурсам»

Таблица 1.

**Основные вычислительные процедуры
и функции имитационной модели**

Название функции	Назначение	Входные сообщения	Выходные сообщения
FLAMEGPU_INIT_FUNCTION (init_function)	Инициализация модели. Формирование начальных популяций коренных жителей, мигрантов и рабочих мест.	Нет	Нет
FLAMEGPU_STEP_FUNCTION (BasicOutput)	Прибытие новых агентов-мигрантов, рождение новых агентов (коренных жителей и мигрантов) у семейных пар (с большей вероятностью) и одиночных агентов (с меньшей вероятностью).	Нет	Нет
FLAMEGPU_STEP_FUNCTION (AgentUpdate)	Оценка (т.е. сбор) результатов вычислений по ансамблю агентов в каждый момент времени.	Нет	Нет
FLAMEGPU_EXIT_CONDITION (exit_condition)	Проверка выполнения критерия останова модели.	Нет	Нет
FLAMEGPU_AGENT_FUNCTION (check_all_agents, MsgArray2D, MsgNone)	Проверка и устранение потенциальных коллизий, обусловленных случайным попаданием агентов в одну ячейку дискретного пространства	Данные по агентам	Нет
FLAMEGPU_AGENT_FUNCTION (workplaces_creation, MsgNone, MsgNone)	Создание новых рабочих мест на основе имеющейся популяции ресурсов. Выбытие рабочих мест.	Нет	Данные по ресурсам
FLAMEGPU_AGENT_FUNCTION (update_cell, MsgArray2D, MsgArray2D)	Распространение информации агентам об имеющихся ресурсах (рабочих местах). Проверка «занятости» ресурса агентом.	Данные по агентам	Данные по ресурсам
FLAMEGPU_AGENT_FUNCTION (check_cell, MsgArray2D, MsgArray2D)	Распространение информации другим агентам (коренным жителям и мигрантам) об имеющихся агентах (со своими характеристиками) и занимаемых ими ресурсах. Определение типа ресурса, занимаемого агентом.	Данные по ресурсам	Данные по агентам
FLAMEGPU_AGENT_FUNCTION (agent_to_agent_contacts, MsgArray2D, MsgNone)	Оценка частоты контактов типа «агент-агент» (в рамках 8-клетого «Мурова соседства») для оценки (пересчета) уровня владения местным языком у мигрантов, и уровня личного комфорта у коренных жителей, снижающегося при контакте с мигрантами.	Данные по агентам	Данные по агентам
FLAMEGPU_AGENT_FUNCTION (looking_for_partner, MsgArray2D, MsgArray2D)	Функция поиска ближайшего партнера, соответствующего заданным критериям (например, пол, возраст, семейный статус и т.д.).	Данные по агентам	Данные по агентам
FLAMEGPU_AGENT_FUNCTION (get_married, MsgArray2D, MsgNone)	Фиксация брака с агентом, отправившим сообщение на основе уникального идентификатора (ID).	Данные по агентам	Нет
FLAMEGPU_AGENT_FUNCTION (looking_for_resource, MsgArray2D, MsgArray2D)	Функция поиска агента, наиболее близко расположенного к каждому рабочему месту и находящегося в состоянии поиска работы. Назначение целевой ячейки с ресурсом отобранному агенту.	Данные по агентам	Данные по ресурсам
FLAMEGPU_AGENT_FUNCTION (update_agent_state, MsgNone, MsgNone)	Обновление состояния каждого агента, в зависимости от значений его характеристик (например, уровня личного комфорта, возраста, семейного статуса и т.д.).	Нет	Нет
FLAMEGPU_AGENT_FUNCTION (moving_transaction, MsgArray2D, MsgNone)	Транзакция перемещения агента в дискретном пространстве с целью занятия рабочего места, на основе данных о целевой ячейке, переданных соответствующим ресурсом.	Данные по ресурсам	Нет

представляют собой характеристики рабочих мест (например, тип ресурса, «занят/свободен» и т.д.).

Разработанная имитационная модель поддерживает два основных способа выполнения вычислительных процедур:

- ◆ одиночный расчет, выполняемый для одного выбранного сценария с фиксированными значениями управляющих параметров и визуализацией состояния агентов с использованием библиотек Open GL [20];
- ◆ множественные вычисления, реализуемые с использованием метода класса Монте-Карло [21–24] за счет параллельного запуска имитационной модели в режиме так называемого «ансамбля». Данный подход позволяет варьировать значениями управляющих параметров в заданных диапазонах, в частности, с использованием равномерного, нормального и др. функций распределения со своими характеристиками.

Визуализация состояний агентов во FLAME GPU выполняется с использованием Open GL и, в частности, представляет собой решетку заданной размерности, в ячейках которой размещаются агенты: мигранты и коренные жители, и ресурсы: высокотехнологичные и низкотехнологичные рабочие места. Также, имеются свободные клетки, не содержащие ресурсов и агентов. При этом, если агент трудоспособного возраста занимает клетку, не имеющую рабочего места, то, он считается без-

работным и уровень его личного комфорта будет постепенно снижаться. Отметим, что визуализация состояний агентов и их динамика, т.е. перемещение в новые клетки дискретного пространства реализуется в каждый момент модельного времени. Подобный подход, позволяет качественно оценить развитие популяций с учётом индивидуального выбора агентами наиболее предпочтительных рабочих мест, а также изучить эффекты сегрегации и др.

3. Результаты численных экспериментов

Все расчеты проводились на суперкомпьютере FORSITE DSWS PRO на базе QUADRO RTX 6000 на временном интервале 80 лет. Общее количество агентов-ресурсов в модели фиксировано (10 000) и ограничено размерностью заданного дискретного пространства (100 × 100). Количество агентов-коренных жителей и мигрантов меняется в диапазоне от 0 до 10 000, и является результатом имитационного эксперимента. Значения основных параметров модели представлены в *таблице 2*.

На *рис. 1–4* представлены частотные диаграммы для наиболее важных характеристик исследуемой системы, полученные с использованием метода класса Монте-Карло, агрегированного с предложенной агентной моделью посредством ее управляющих параметров и целевых функционалов.

Таблица 2.

Основные параметры модели

Наименование параметра	Минимальное значение	Максимальное значение
Доля новых мигрантов (от численности уже имеющихся)	0,1	0,5
Доля государственных расходов на образование в ВВП на душу населения	0,1	0,5
Время жизни высокотехнологичных рабочих мест	5	15
Время жизни низкотехнологичных рабочих мест	5	15
Периодичность формирования новых рабочих мест	5	15
Продолжительность жизни коренных жителей	70	90
Продолжительность жизни мигрантов	60	80
Минимальный возраст вступления в брак и рождения детей коренных жителей	18	30
Минимальный возраст вступления в брак и рождения детей мигрантов	18	30
Минимальный уровень личного комфорта коренных жителей	3	10
Минимальный уровень личного комфорта мигрантов	3	10
Пенсионный возраст	60	75

Рис. 1. Частотная диаграмма для численности популяции.

Рис. 3. Частотная диаграмма для доли неассимилированных мигрантов

Рис. 2. Частотная диаграмма для среднего времени, требуемого на ассимиляцию и интеграцию.

Рис. 4. Частотная диаграмма для общего количества ассимилированных мигрантов.

Отметим, что в ходе выполнения численных экспериментов были проведены множественные прогоны модели (более 1000) и отобраны наиболее различающиеся по оцениваемым характеристикам сценарии, визуализированные на рис. 1–4.

Как следует из рис. 1–4 медианные значения моделируемых показателей имеют явно выраженные значения. Также отметим частую наблюдаемость граничных значений показателей. При этом, по-видимому, существуют сценарии некоторого улучшения требуемых целевых характеристик (например, среднего времени, требуемого на ассимиляцию), однако они требуют больших государственных расходов на образование, увеличение числа рабочих мест и т.д.

Из рис. 5 следует, что не наблюдается однозначной зависимости доли неассимилированных мигрантов от среднего времени, требуемого на их ассимиляцию — для самых частых значений первого показателя (от 7 до 12 лет) возможны разные значения второго: от 0 до 0,55.

Данные, изображенные на рис. 6, показывают практически линейную зависимость численности модельной популяции (общего числа агентов-коренных жителей и агентов-мигрантов) и общего количества ассимилированных мигрантов.

Далее, рассматриваются наиболее важные группы сценариев эволюционного развития сообществ мигрантов и коренных жителей:

◆ сценарии малоинтенсивной и нормальной миграции;

◆ сценарии интенсивной и сверхинтенсивной миграции.

Ключевые характеристики исследуемых сценариев представлены в таблице 3.

Рис. 5. Двумерная частотная диаграмма для среднего времени, требуемого на ассимиляцию и интеграцию и доли неассимилированных мигрантов.

Рис. 6. Двумерная частотная диаграмма для численности модельной популяции и общего количества ассимилированных мигрантов.

Таблица 3.

Исследуемые сценарии и модельные допущения

Группа сценариев	Номер Сценария	Доля новых мигрантов	Доля гос. расходов на образование и интеграцию
Сценарии малоинтенсивной (нормальной) миграции	Сценарий 1	0,1	0,1
	Сценарий 2	0,1	0,25
	Сценарий 3	0,1	0,5
Сценарии интенсивной миграции	Сценарий 4	0,2	0,1
	Сценарий 5	0,2	0,25
	Сценарий 6	0,2	0,5
Сценарии сверхинтенсивной миграции	Сценарий 7	0,3	0,1
	Сценарий 8	0,3	0,25
	Сценарий 9	0,3	0,5

На рис. 7–10 представлена модельная динамика ключевых характеристик рассматриваемой системы на интервале в 80 модельных лет, являющаяся результатом поведения ансамбля взаимодействующих агентов – коренных жителей и мигрантов.

Из рис. 7–8 следуют следующий важный вывод. При существующих паттернах поведения агентов, существенного увеличения численности популяции можно достичь только в условиях интенсивной и сверхинтенсивной миграции. Однако, подобные сценарии вызовут существенный рост доли мигрантов в численности популяции, что может привести к росту социальной напряженности.

Из рис. 9 следует, что наибольшие темпы роста ВВП можно достичь при сценариях интенсивной миграции, однако последующий за этим дефицит ресурсов приводит к постепенному снижению темпов экономического роста.

Из рис. 10 следует, что сценарии интенсивной и сверхинтенсивной миграции обуславливают существенный рост государственных расходов, в основном, связанный с необходимостью увеличения расходов на образование и интеграцию мигрантов, создания соответствующих рабочих мест, выплаты пособий по безработице и т. д.

Рис. 7. Модельная динамика численности популяции.

Рис. 8. Модельная динамика доли неассимилированных мигрантов в популяции.

Рис. 9. Модельная динамика темпов роста ВВП.

Рис. 10. Модельная динамика государственных расходов.

Заключение

В данной статье представлен новый подход к моделированию миграционных и демографических процессов с использованием FLAME GPU – платформы, предназначенной для суперкомпьютерного агент-ориентированного моделирования. Данная платформа позволяет распараллелить логику функционирования имитационной модели на уровне каждого агента, обеспечив существенное повышение временной эффективности соответствующих вычислительных процедур.

В результате с использованием искусственных данных и методов класса Монте-Карло выполнены исследования наиболее важных характеристик модели взаимодействия коренных жителей и мигрантов: численности популяции, среднего времени, требуемого на ассимиляцию, доли неассимилированных мигрантов в популяции и др. Определены сценарии, обеспечивающие положительный вклад в темпы экономического и демографического роста. При этом, реализация подобных сценариев, осно-

ванных преимущественно на интенсивной миграции, обуславливает необходимость существенного увеличения государственных расходов на образование и интеграцию.

Предложенный подход может быть использован для разработки систем поддержки принятия решений по планированию найма новых сотрудников на основе прогнозной динамики миграционных и демографических процессов.

Дальнейшие исследования будут направлены на усложнение и детализацию модели взаимодействия мигрантов и коренных жителей, применение методов кластеризации для формирования рабочих мест, исследование эффектов сегрегации и др., с использованием FLAME GPU. ■

Благодарности

Исследование выполнено при финансовой поддержке Российского фонда фундаментальных исследований (РФФИ), в рамках научного проекта № 18-51-14010.

Литература

1. Epstein J.M., Axtell R. Growing artificial societies: Social sciences from the bottom up. Cambridge, MA: MIT Press. 1996. <https://doi.org/10.7551/mitpress/3374.001.0001>
2. Белоусов Ф.А. Модель «кочевников» и «землепашцев» с ограниченным ресурсом пространственного перемещения // Экономика и математические методы. 2018. Т. 54. № 4. С. 124–131. <https://doi.org/10.31857/S042473880003336-8>
3. Белоусов Ф.А. Модель сообществ с двумя способами воспроизводства продукта (модель «кочевников» и «землепашцев») // Экономика и математические методы. 2017. Т. 53. № 3. С. 93–109.
4. Schelling T.C. Dynamic models of segregation // The Journal of Mathematical Sociology. Informa UK Limited. 1971. Vol. 1. No. 2. P. 143–186. <https://doi.org/10.1080/0022250X.1971.9989794>
5. Акопов А.С., Бекларян А.Л., Бекларян Л.А., Белоусов Ф.А., Хачатрян Н.К. Кластеризация агентов в модели сегрегации населения // Искусственные общества. 2020. Т. 15. № 4 [Электронный ресурс]: <https://artsoc.jes.su/s207751800012764-9-1/> (дата обращения: 30.06.2021). <https://doi.org/10.18254/S207751800012764-9>
6. Акопов А.С., Бекларян Л.А., Бекларян А.Л., Белоусов Ф.А. Моделирование движения ансамбля наземных беспилотных транспортных средств с использованием FLAME GPU // Информационные технологии. 2021. Т. 27. № 7. С. 339–349. <https://doi.org/10.17587/it.27.369-379>
7. Акопов А.С., Бекларян А.Л. Сценарное моделирование движения беспилотных транспортных средств в искусственной дорожной сети с использованием FLAME GPU // Искусственные общества. 2021. Т. 16. № 1. [Электронный ресурс]: <https://artsoc.jes.su/s207751800014028-9-1/> (дата обращения: 30.06.2021). <https://doi.org/10.18254/S207751800014028-9>
8. Макаров В.Л., Бахтизин А.Р., Бекларян Г.Л., Акопов А.С., Ровенская Е.А., Стрелковский Н.В. Агентное моделирование популяционной динамики двух взаимодействующих сообществ: мигрантов и коренных жителей // Экономика и математические методы. 2020. Т. 56. № 2. С. 5–19. <https://doi.org/10.31857/S042473880009217-7>
9. Макаров В.Л., Бахтизин А.Р., Бекларян Г.Л., Акопов А.С. Агентно-ориентированная модель миграции в страны Европейского Союза с учетом индивидуальной системы принятия решений // Искусственные общества. 2019. Т. 14. № 2 [Электронный ресурс]: <https://artsoc.jes.su/s207751800005804-3-1/> (дата обращения: 30.06.2021). <https://doi.org/10.18254/S207751800005804-3>
10. Макаров В.Л., Бахтизин А.Р., Бекларян Г.Л., Акопов А.С., Ровенская Е.А., Стрелковский Н.В. Укрупненная агент-ориентированная имитационная модель миграционных потоков стран европейского союза // Экономика и математические методы. 2019. Т. 55. № 1. С. 3–15. <https://doi.org/10.31857/S042473880004044-7>
11. Borshchev A. The big book of simulation modeling: Multimethod modeling with AnyLogic 6. AnyLogic North America. 2013.
12. Collier N., North M. Parallel agent-based simulation with repast for high performance computing // Simulation. 2013. Vol. 89, No. 10. P. 1215–1235. <https://doi.org/10.1177/0037549712462620>
13. Lysenko M., Roshan M.D. A framework for megascale agent based model simulations on graphics processing units // Journal of Artificial Societies and Social Simulation. 2008. Vol. 11. No. 4. [Электронный ресурс]: <http://jasss.soc.surrey.ac.uk/11/4/10.html> (дата обращения: 30.06.2021).

14. Emau J., Chuang T., Fukuda M. A multi-process library for multi-agent and spatial simulation // In Proc. of 2011 IEEE Pacific Rim Conference on Communications, Computers and Signal Processing – PACRIM'11. P. 369–376. Victoria, BC, Canada, 24–26 August 2011. <https://doi.org/10.1109/PACRIM.2011.6032921>
15. Richmond P., Walker D., Coakley C., Romano D. High performance cellular level agent-based simulation with FLAME for the GPU // Briefings in bioinformatics. 2010. Vol 11. P. 334–347. <https://doi.org/10.1093/bib/bbp073>
16. Kabiri Chimeh M., Heywood P., Pennisi M. et al. Parallelisation strategies for agent based simulation of immune systems. BMC Bioinformatics 2019. Vol. 20. Article number: 579. <https://doi.org/10.1186/s12859-019-3181-y>
17. Kabiri Chimeh M., Richmond P. Simulating heterogeneous behaviours in complex systems on GPUs // Simulation Modelling Practice and Theory. 2018. Vol. 83. P. 3–17. <https://doi.org/10.1016/j.simpat.2018.02.002>
18. Kiran M., Richmond P., Holcombe M., Chin L., Worth D., Greenough C. FLAME: Simulating large populations of agents on parallel hardware architectures // In Proceedings of the 9th International Conference on Autonomous Agents and Multiagent Systems (AAMAS '10). 2010. P. 1633–1636.
19. Vouzis P.D., Sahinidis N.V. GPU-BLAST: using graphics processors to accelerate protein sequence alignment // Bioinformatics. 2011. Vol. 27. No. 2. P. 182–188. <https://doi.org/10.1093/bioinformatics/btq644>
20. Metropolis N., Rosenbluth A.W., Rosenbluth M.N., Teller A.H., Teller E. Equation of state calculations by fast computing machines // The Journal of Chemical Physics. 1953. Vol. 21. No. 6. P. 1087–1092. <https://doi.org/10.1063/1.1699114>
21. Hastings W.K. Monte Carlo sampling methods using Markov chains and their applications // Biometrika. 1970. Vol. 57. No. 1. P. 97–109. <https://doi.org/10.2307/2334940>
22. Fox W.P., Burks R. Monte Carlo simulation and agent-based modeling (ABM) in military decision-making // In: Applications of Operations Research and Management Science for Military Decision Making. International Series in Operations Research & Management Science. 2019. Vol. 283. Springer, Cham. https://doi.org/10.1007/978-3-030-20569-0_8
23. Nianqiao J., Heng J., Jacob P. Sequential Monte Carlo algorithms for agent-based models of disease transmission. arXiv:2101.12156. 2021. <https://doi.org/10.48550/arXiv.2101.12156>
24. McCreynolds T., Blythe D. Advanced graphics programming using OpenGL // In the Morgan Kaufmann series in computer graphics, Morgan Kaufmann, 2005. <https://doi.org/10.1016/B978-1-55860-659-3.X5000-8>
25. Márquez C., César E., Sorribes J. Agent migration in HPC systems using FLAME // In Euro-Par 2013: Parallel Processing Workshops. Lecture Notes in Computer Science. Springer, Berlin, Heidelberg. 2013. Vol. 8374. P. 523–532. https://doi.org/10.1007/978-3-642-54420-0_51
26. Richey M.K. Scalable agent-based modeling of forced migration. Diss. George Mason University, 2020.
27. Kehoe J. The specification of sugarscape. arXiv:1505.060122015. 2015. <https://doi.org/10.48550/arXiv.1505.06012>

Об авторах

Макаров Валерий Леонидович

доктор физико-математических наук; академик Российской академии наук;

научный руководитель, Центральный экономико-математический институт, Российская академия наук, 117418, г. Москва, Нахимовский проспект, д. 47;

E-mail: makarov@cemi.rssi.ru

ORCID: 0000-0002-2802-2100

Бахтизин Альберт Рауфович

доктор экономических наук; член-корреспондент Российской академии наук;

директор, Центральный экономико-математический институт, Российская академия наук, 117418, г. Москва, Нахимовский проспект, д. 47;

E-mail: albert@cemi.rssi.ru

ORCID: 0000-0002-9649-0168

Бекларян Гаянэ Левоновна

кандидат экономических наук;

старший научный сотрудник, лаборатория компьютерного моделирования социально-экономических процессов, Центральный экономико-математический институт, Российская академия наук, 117418, г. Москва, Нахимовский проспект, д. 47;

E-mail: glbeklaryan@gmail.com

ORCID: 0000-0002-1286-0345

Акопов Андраник Сумбатович

доктор технических наук;

профессор, департамент бизнес-информатики, Высшая школа бизнеса, Национальный исследовательский университет «Высшая школа экономики», 101000, г. Москва, ул. Мясницкая, д. 20;

главный научный сотрудник, лаборатория динамических моделей экономики и оптимизации, Центральный экономико-математический институт, Российская академия наук, 117418, г. Москва, Нахимовский проспект, д. 47;

E-mail: aakopov@hse.ru

ORCID: 0000-0003-0627-3037

Стрелковский Никита Витальевич

кандидат физико-математических наук;

научный сотрудник, Международный институт прикладного системного анализа (МИПСА), г. Лаксенбург, Австрия;

E-mail: strelkon@iiasa.ac.at

ORCID: 0000-0001-6862-1768

Simulation of migration and demographic processes using FLAME GPU

Valery L. Makarov^a

E-mail: makarov@cemi.rssi.ru

Albert R. Bakhtizin^a

E-mail: albert@cemi.rssi.ru

Gayane L. Beklaryan^a

E-mail: glbeklaryan@gmail.com

Andranik S. Akopov^{b, a}

E - mail: aakopov @ hse.ru

Nikita V. Strelkovskii^c

E-mail: strelkon@iiasa.ac.at

^a Central Economics and Mathematics Institute, Russian Academy of Sciences
Address: 47, Nakhimovsky Prospect, Moscow 117418, Russia

^b HSE University
Address: 20, Myasnitskaya Street, Moscow 109028, Russia

^c International Institute for Applied Systems Analysis (IIASA)
Address: 1, Schlossplatz, Laxenburg A-2361, Austria

Abstract

This article presents an approach to modelling migration and demographic processes using a framework designed for large-scale agent-based modelling – FLAME GPU. This approach is based on the previously developed simulation model of interaction between two communities: migrants and natives that is implemented in the AnyLogic simulation software. Despite a relatively simple configuration of the basic model, in particular, low dimensionality of the discrete space representing the operating environment of the agent populations and a deterministic decision-making system of each agent, the presence of multiple multiparticle interactions and transitions between agent states determines a high computational complexity of such a model. The use of FLAME GPU enables conducting extensive simulation experiments with the model, mainly due to the parallelisation of computational processes at the level of each agent, as well as the implementation of the mechanism of multiple

computations using Monte Carlo techniques. The developed framework is used to study the impact of the most important parameters of the model (e.g., rate of migration, governmental expenditures on integration, frequency of new workplaces creation, etc.) on the key outputs of the modelled socio-economic system (in particular, population size, share of migrants, number of assimilated migrants, GDP growth rate, etc.). The proposed approach can be used to develop decision-making systems for planning hiring new employees based on the forecast dynamics of migration and demographic processes.

Keywords: agent-based modelling, migration and demographic processes, population dynamics, large-scale modelling, parallel computing on GPU, supercomputer modelling, decision support

Citation: Makarov V.L., Bakhtizin A.R., Beklaryan G.L., Akopov A.S., Strelkovskii N.V. (2022) Simulation of migration and demographic processes using FLAME GPU. *Business Informatics*, vol. 16, no. 1, pp. 7–21.
DOI: 10.17323/2587-814X.2022.1.7.21

References

1. Epstein J.M., Axtell R. (1996) *Growing artificial societies: Social sciences from the bottom up*. Cambridge, MA: MIT Press. <https://doi.org/10.7551/mitpress/3374.001.0001>
2. Belousov F.A. (2018) Model of nomads and plowmen with a limited resource of spatial movement. *Ekonomika I Matematicheskie Metody*, vol. 54, no. 4, pp. 124–131 (in Russian). <https://doi.org/10.31857/S042473880003336-8>
3. Belousov F.A. (2017) Model of civilization with two types of reproduction of product (model of nomads and plowmen). *Ekonomika I Matematicheskie Metody*, vol. 53, no. 4, pp. 93–109 (in Russian).
4. Schelling T.C. (1971) Dynamic models of segregation. *The Journal of Mathematical Sociology*. Informa UK Limited, vol. 1, no. 2, pp. 143–186. <https://doi.org/10.1080/0022250X.1971.9989794>
5. Akopov A.S., Beklaryan A.L., Beklaryan L.A., Belousov F.A., Khachatryan N.K. (2020) Clustering in model of population segregation. *Artificial societies*, vol. 15, no. 4. (in Russian). <https://doi.org/10.18254/S207751800012764-9>
6. Akopov A.S., Beklaryan L.A., Beklaryan A.L., Belousov F.A. (2021) Simulation of motion of an ensemble of unmanned ground vehicles using FLAME GPU. *Information technologies*, vol. 27, no. 7, pp. 339–349 (in Russian). <https://doi.org/10.17587/it.27.369-379>
7. Akopov A.S., Beklaryan A.L. (2021) Scenario simulation of autonomous vehicles motion in artificial road network using FLAME GPU. *Artificial societies*, vol. 16, no. 1 (in Russian). <https://doi.org/10.18254/S207751800014028-9>
8. Makarov V.L., Bakhtizin A.R., Beklaryan G.L., Akopov A.S., Rovenskaya E.A., Strelkovskii N.V. (2020) Agent-based modelling of population dynamics of two interacting social communities: migrants and natives. *Ekonomika I Matematicheskie Metody*, vol. 56, no. 2, pp. 5–19 (in Russian). <https://doi.org/10.31857/S042473880009217-7>
9. Makarov V.L., Bakhtizin A.R., Beklaryan G.L., Akopov A.S. (2019) Agent-based model of migration to European Union countries with taking into account individual decision-making system. *Artificial societies*, vol. 14, no. 2 (in Russian). <https://doi.org/10.18254/S207751800005804-3>
10. Makarov V.L., Bakhtizin A.R., Beklaryan G.L., Akopov A.S., Rovenskaya E.A., Strelkovskii N.V. (2019) Aggregated agent-based simulation model of migration flows of the European Union Countries. *Ekonomika I Matematicheskie Metody*, vol. 55, no. 1. pp. 3–15 (in Russian). <https://doi.org/10.31857/S042473880004044-7>
11. Borshchev A. (2013) *The big book of simulation modeling: Multimethod modeling with AnyLogic 6*. AnyLogic North America.
12. Collier N., North M. (2013) Parallel agent-based simulation with repast for high performance computing. *Simulation*, vol. 89, no. 10, pp. 1215–1235. <https://doi.org/10.1177/0037549712462620>
13. Lysenko M., Roshan M.D. (2008) A framework for megascale agent based model simulations on graphics processing units. *Journal of Artificial Societies and Social Simulation*, vol. 11, no. 4. Available at: <http://jasss.soc.surrey.ac.uk/11/4/10.html> (accessed 30 June 2021).
14. Emau J., Chuang T., Fukuda M. (2011) A multi-process library for multi-agent and spatial simulation. In *Proc. of 2011 IEEE Pacific Rim Conference on Communications, Computers and Signal Processing – PACRIM'11*, pp. 369–376. <https://doi.org/10.1109/PACRIM.2011.6032921>
15. Richmond P., Walker D., Coakley C., Romano D. (2010) High performance cellular level agent-based simulation with FLAME for the GPU. *Briefings in bioinformatics*, vol. 11, pp. 334–347. <https://doi.org/10.1093/bib/bbp073>
16. Kabiri C.M., Heywood P., Pennisi M. et al. (2019) Parallelisation strategies for agent based simulation of immune systems. *BMC Bioinformatics*, vol. 20, Article number: 579. <https://doi.org/10.1186/s12859-019-3181-y>
17. Kabiri Chimeh M., Richmond P. (2018) Simulating heterogeneous behaviours in complex systems on GPUs. *Simulation Modelling Practice and Theory*, vol. 83, pp. 3–17. <https://doi.org/10.1016/j.simpat.2018.02.002>
18. Kiran M., Richmond P., Holcombe M., Chin L., Worth D., Greenough C. (2010) FLAME: Simulating large populations of agents on parallel hardware architectures. In *Proceedings of Proceedings of the 9th International Conference on Autonomous Agents and Multiagent Systems (AAMAS '10)*, pp. 1633–1636.

19. Vouzis P.D., Sahinidis N.V. (2011) GPU-BLAST: using graphics processors to accelerate protein sequence alignment. *Bioinformatics*, vol. 27, no. 2, pp. 182–188. <https://doi.org/10.1093/bioinformatics/btq644>
20. Metropolis N., Rosenbluth A.W., Rosenbluth M.N., Teller A.H., Teller E. (1953) Equation of State Calculations by Fast Computing Machines. *The Journal of Chemical Physics*, vol. 21, no. 6, pp. 1087–1092. <https://doi.org/10.1063/1.1699114>
21. Hastings W.K. (1970) Monte Carlo sampling methods using Markov chains and their applications. *Biometrika*, vol. 57, no. 1, pp. 97–109. <https://doi.org/10.2307/2334940>
22. Fox W.P., Burks R. (2019) Monte Carlo simulation and agent-based modeling (ABM) in military decision-making. In: *Applications of Operations Research and Management Science for Military Decision Making. International Series in Operations Research & Management Science*, vol. 283. Springer, Cham. https://doi.org/10.1007/978-3-030-20569-0_8
23. Nianqiao J., Heng J., Jacob P. (2021) *Sequential Monte Carlo algorithms for agent-based models of disease transmission*. arXiv:2101.12156. <https://doi.org/10.48550/arXiv.2101.12156>
24. McCreynolds T., Blythe D. (2005) Advanced graphics programming using OpenGL. In: *The Morgan Kaufmann series in computer graphics, Morgan Kaufmann*. <https://doi.org/10.1016/B978-1-55860-659-3.X5000-8>
25. Márquez C., César E., Sorribes J. (2013) Agent migration in HPC systems using FLAME. In: *Euro-Par 2013: Parallel Processing Workshops. Lecture Notes in Computer Science*, vol 8374, Springer, Berlin, Heidelberg, pp. 523–532. https://doi.org/10.1007/978-3-642-54420-0_51
26. Richey M.K. (2020) *Scalable agent-based modeling of forced migration*. Diss. George Mason University.
27. Kehoe J. (2015) *The Specification of Sugarscape*. arXiv:1505.060122015. <https://doi.org/10.48550/arXiv.1505.06012>

About the authors

Valery L. Makarov

Dr. Sci. (Phys.-Math.); Academician of Russian Academy of Sciences;

Academic Supervisor, Central Economics and Mathematics Institute, Russian Academy of Sciences, 47, Nakhimovsky Prospect, Moscow 117418, Russia;

E-mail: makarov@cemi.rssi.ru

ORCID: 0000-0002-2802-2100

Albert R. Bakhtizin

Dr. Sci. (Econ.); Corresponding Member of Russian Academy of Sciences;

Director, Central Economics and Mathematics Institute, Russian Academy of Sciences, 47, Nakhimovsky Prospect, Moscow 117418, Russia;

E-mail: albert@cemi.rssi.ru

ORCID: 0000-0002-9649-0168

Gayane L. Beklaryan

Cand. Sci. (Econ.);

Senior Researcher, Laboratory of Computer Modeling of Social and Economic Processes, Central Economics and Mathematics Institute, Russian Academy of Sciences, 47, Nakhimovsky Prospect, Moscow 117418, Russia;

E-mail: glbeklaryan@gmail.com

ORCID: 0000-0002-1286-0345

Andranik S. Akopov

Dr. Sci. (Tech.);

Professor, Department of Business Informatics, Graduate School of Business, National Research University Higher School of Economics, 20, Myasnitskaya Street, Moscow 101000, Russia;

Chief Researcher, Laboratory of Dynamic Models of Economy and Optimization, Central Economics and Mathematics Institute, Russian Academy of Sciences, 47, Nachimovky Prospect, Moscow 117418, Russia;

E-mail: aakopov@hse.ru

ORCID: 0000-0003-0627-3037

Nikita V. Strelkovskii

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

Research Scholar, International Institute for Applied Systems Analysis, Laxenburg, Austria;

E-mail: strelkon@iiasa.ac.at

ORCID: 0000-0001-6862-1768

Анализ процесса, ведущего к финансовому краху фирмы, на основе байесовских сетей

Ю.А. Зеленков

E-mail: yzelenkov@hse.ru

Национальный исследовательский университет «Высшая школа экономики»

Адрес: Россия, 101000, г. Москва, ул. Мясницкая, д. 20

Аннотация

В работе исследуются этапы процесса, ведущего к финансовому краху компании, с использованием байесовской сети в качестве инструмента моделирования, поскольку такой подход позволяет выявить причинно-следственные связи в профиле фирмы. Используются общедоступные данные о французских, итальянских и российских фирмах, содержащие пять выборок, соответствующих периодам от одного года до пяти лет до момента наблюдения. Полученные результаты подтверждают, что существует разница между стадиями процесса, ведущего к банкротству. Для фирм, находящихся в начале длительного процесса (3–5 лет до дефолта), ключевым фактором, определяющим ликвидность, является кумулятивная прибыльность. По мере развития процесса, в среднесрочной перспективе (1–2 года до дефолта) для экономик с большей неопределенностью на первый план выходит способность обслуживать обязательства. Этот фактор ограничивает возможности получения прибыли, что приводит к дальнейшему развитию проблем. Существуют также национальные особенности, которые обусловлены, во-первых, уровнем экономического развития и, во-вторых, неопределенностью экономической политики.

Ключевые слова: банкротство, процесс финансового краха, байесовская сеть

Цитирование: Зеленков Ю.А. Анализ процесса, ведущего к финансовому краху фирмы, на основе байесовских сетей // Бизнес-информатика. 2022. Т. 16. № 1. С. 22–41. DOI: [10.17323/2587-814X.2022.1.22.41](https://doi.org/10.17323/2587-814X.2022.1.22.41)

Введение

Изучение финансовых крахов является одним из ключевых вопросов в бизнес-исследованиях. Его можно разделить на два направления [1]: первое – предсказание дефолтов, второе – теоретические и эмпирические исследования процесса, ведущего к дефолту. Изучение процесса краха позволяет рассмотреть поведение

неуспешных фирм в более длительной перспективе [2, 3], в то время как модели предсказания дефолта часто фокусируются на финансовых показателях только за один или несколько лет до наступления проблем [4, 5].

Основной недостаток моделей краткосрочного прогнозирования заключается в том, что обязательства компании часто бывают длиннее того перио-

да, в течение которого риск дефолта оценивается с приемлемой точностью [6]. Таким образом, компанию следует анализировать в более длительной перспективе. Более того, в то время как одни фирмы с определенным профилем финансовых показателей терпят крах, другие с таким же профилем могут преодолеть трудности и вернуться к нормальной деятельности. Поэтому многие авторы утверждают, что существуют различные типы траекторий, которые могут привести или не привести фирму к дефолту в зависимости от ее предыстории и текущих возможностей [1, 7–9].

Существование различных вариантов процессов краха фирмы (*firm failure process, FFP*) подтверждается многими теоретическими и эмпирическими исследованиями. Однако в научном сообществе нет единого мнения не только о точном определении этих процессов, но даже о количестве их вариантов. Например, в [10] представлены три траектории финансового краха фирм, в [8] описываются четыре различных типа процессов, в [11] выделено семь типов FFP. Эти различия объясняются, во-первых, используемой методологией, например, работы [8] и [10] основаны на кейс-методе, а в [11] анализируются эмпирические данные с помощью самоорганизующихся карт. Во-вторых, авторы рассматривают процесс с разных сторон. Авторы [10, 11] фокусируются на финансовых результатах (этот подход используется и во многих других работах, например, [1, 2] и др.), в то время как [8] рассматривает проблему через призму эффективности управления.

В данной работе мы фокусируемся на определении специфики различных этапов процесса неудачи фирмы. Этой цели соответствуют три исследовательских вопроса (*research questions, RQ*):

- ◆ *RQ1*: как изменяются причинно-следственные связи между финансовыми коэффициентами, описывающими состояние фирмы, в различные периоды до дефолта?
- ◆ *RQ2*: существуют ли различия в процессах финансового краха фирм, которые определяются спецификой страны?
- ◆ *RQ3*: как степень неопределенности экономической политики влияет на процесс краха фирмы?

Мы используем байесовскую сеть в качестве инструмента моделирования, поскольку она позволяет выявить причинно-следственные связи в профиле фирмы. Исследование выполнено на общедоступных данных о французских, итальянских и российских компаниях, представляющих финан-

совые коэффициенты фирм за период от одного года до пяти лет до дефолта.

Полученные результаты подтверждают, что существует разница между стадиями процесса, ведущего к банкротству (*RQ1*). Для фирм в начале длительного процесса (за 3–5 лет до момента наблюдения) кумулятивная прибыльность является ключевым фактором, определяющим ликвидность. Затем, по мере развития процесса, в среднесрочной перспективе (1–2 года до момента наблюдения) для экономик с большей неопределенностью на первый план выходит способность обслуживать обязательства. Этот фактор ограничивает возможности получения прибыли, что приводит к дальнейшему развитию факторов, ведущих к банкротству. Существуют также национальные особенности, которые обусловлены, во-первых, уровнем развития экономики (*RQ2*) и, во-вторых, неопределенностью экономической политики (*RQ3*).

Статья организована следующим образом. После обзора источников, анализирующих FFP, представлены основные концепции байесовских сетей. Далее описаны наборы данных и операции предварительной обработки, необходимые для подготовки данных к моделированию. В заключительной части анализируются полученные сетевые структуры и обсуждаются дальнейшие исследования для расширения предложенного подхода.

1. Обзор литературы

Первые исследования в области прогнозирования банкротств начались в 1930-х годах [12]. Эти исследования в основном фокусировались на сравнении индивидуальных показателей успешных и неуспешных фирм, однако количество публикаций оставалось относительно небольшим. Первая многомерная модель была представлена Альтманом в 1968 г. [13], который использовал дискриминантный анализ на основе пяти финансовых коэффициентов. Эта модель, также известная как Z-модель, открыла эру интенсивных исследований. Исследователи разработали множество прогностических моделей, используя как статистические методы, так и машинное обучение. Следует отметить, что модели, основанные на машинном обучении, в целом обеспечивают более высокие показатели [14, 15]; однако Z-модель с некоторыми модификациями также остается актуальной [4].

Общей особенностью прогнозных моделей является то, что они рассматривают проблему про-

гнозирования банкротства как задачу бинарной классификации. При этом чаще всего рассматриваются данные финансовой отчетности за небольшое количество периодов до дефолта. Фактически, эти модели строятся на кросс-секционных данных; коэффициенты за разные периоды времени часто объединяются в одну точку наблюдения; таким образом, индивидуальная динамика фирмы не учитывается. Такой подход игнорирует тот факт, что компании меняются с течением времени, что вызывает различные проблемы и ограничения [16]. Профиль фирмы, измеренный в момент времени t , не может быть сведен только к измерениям в момент времени $t - 1$, поскольку дефолт в большинстве случаев является результатом длительного процесса [9], а дискриминационная способность коэффициентов нестабильна во времени [17].

Существуют модели, основанные на наблюдениях за один, два или более лет до неудачи в момент времени t , которые, как считается, могут предсказать состояние в годы $t + 1$, $t + 2$ или даже $t + 10$ [2, 18]. Однако, поскольку они не рассматривают крах фирмы как процесс, они имеют те же ограничения, что выделены [16].

В некоторых прогностических исследованиях используются методы, позволяющие учитывать как динамику популяции фирм, так и их уникальные характеристики, например, панельная регрессия [19] или анализ выживаемости [20]. Однако в целом количество таких работ в общем потоке исследований по прогнозированию финансовых проблем сравнительно невелико.

1.1. Процесс, ведущий к дефолту фирмы

Дж. Ардженти [10] был, пожалуй, первым, кто начал изучать процесс краха фирмы. Он выделил три модели спада и обнаружил, что разоряющиеся фирмы не терпят крах сразу после спада. Некоторые из них могут откладывать наступление банкротства на годы.

Р. Д'Авени [7] эмпирически проверил эти выводы на основе изучения отдельных кейсов. По мнению обоих авторов, существуют три процесса финансового краха:

- ◆ Внезапный спад (sudden decline), то есть быстрый крах фирмы. Этот процесс неудачи характерен для небольших или конкурентно неблагоприятных фирм, которые слишком смело переориентировали свою стратегию.

- ◆ Постепенный упадок (gradual decline), т.е. медленный и постепенный процесс, характерный для бюрократических и плохо управляемых фирм, которые не могут адаптироваться к внешней среде.

- ◆ Затяжной упадок (lingering decline). Этот процесс характерен для фирм, которые приходят в упадок либо быстро, либо постепенно, но откладывают банкротство на несколько лет. Такие фирмы после спада часто приобретают жесткую централизованную структуру и демонстрируют стратегический паралич и снижение активности.

Основываясь на этих исследованиях, в [1] постулируется существование трех типов процесса краха:

- ◆ краткосрочный процесс, когда потенциальный финансовый сбой может быть обнаружен не более чем в течение 1 года после последней отчетности;

- ◆ среднесрочный процесс соответствует ситуации, когда первые сигналы потенциального сбоя могут быть обнаружены за 2–3 года до дефолта;

- ◆ долгосрочный процесс, когда потенциальный сбой может быть обнаружен более чем за 3 года до дефолта.

Краткосрочные процессы больше подходят для описания ситуации, когда фирма с хорошими показателями внезапно терпит крах. Среднесрочные и долгосрочные процессы, в свою очередь, могут описывать две ситуации: фирма никогда не становится достаточно успешной или фирма становится хуже постепенно, шаг за шагом.

Для эмпирической проверки этого предположения авторы [1] проанализировали 1234 обанкротившихся производственных предприятия малого и среднего бизнеса из нескольких Европейских стран. Они применили четыре метода кластеризации к восьми различным наборам переменных (представленных в [4]) за последние пять лет до банкротства. Их результаты подтверждают существование трех типов процессов банкротства, различающихся длительностью и, следовательно, скоростью спада.

Обобщая их результаты, можно отметить следующее. Для краткосрочных процессов риск неудачи (failure risk, FR) наблюдаем только в год $t - 1$, а отрицательная годовая прибыльность является наиболее важным индикатором. Для среднесрочных процессов риск неудачи может быть обнаружен в годы $t - 2$ и $t - 3$. При этом наиболее важным индикатором является также отрицательная годовая

рентабельность, а вторым по уровню значимости – размер заемных средств. Для фирм, вовлеченных в долгосрочный процесс, первые сигналы могут быть обнаружены до $t - 3$, индикаторами служат годовая и кумулятивная рентабельность и размер заемных средств. Эти факторы вносят вклад в FR также в годы $t - 2$ и $t - 1$. Ликвидность как показатель FR важна только для последних стадий среднесрочных и долгосрочных процессов.

Однако такой взгляд на процессы финансового краха не является единственным. Например, в [8] представлено четыре различных процесса, объясняемых через призму менеджмента: (1) неудачный старт из-за отсутствия управленческого или отраслевого опыта, (2) рискованный рост фирм с чрезмерно оптимистичным руководством, (3) несбалансированный рост, вызванный ослеплением руководства, и (4) апатичная зрелая фирма, управляемая людьми с недостатком мотивации и приверженности.

В серии работ [6, 9, 11] моделируются различные процессы неудач (также называемые траекториями или профилями) с помощью самоорганизующихся карт (self-organized maps – SOM) Кохонена. Основная идея применения SOM для изучения индивидуальных траекторий фирм проста. Пусть у нас есть панельные данные (наблюдения за объектами, соответствующие измерениям, сделанным в разные периоды времени). Если все наблюдения классифицировать с помощью SOM, как независимые, то можно изучить изменение состояния данного объекта во времени [21]. Насколько нам известно, впервые этот подход был использован в [22] для анализа финансового состояния испанских банков. Автор отметил, что обученная модель SOM группирует объекты в соответствии с их сходством финансового состояния. Таким образом, новые наблюдения будут помещены в определенную зону (банкроты или не банкроты) в соответствии с активированными нейронами на карте. Таким образом, можно наблюдать за эволюцией банка, используя финансовую информацию за разные годы.

Вкратце методологию [6, 9, 11] можно описать следующим образом: на первом этапе все фирмы отображаются на SOM, наблюдения фирмы в разные моменты времени считаются независимыми. Затем строятся траектории фирм, представленные списком нейронов, которые соответствуют наблюдениям одной организации в последовательные моменты времени. На последнем этапе траектории группируются в мета-классы, которые можно рассматривать как процессы, приводящие или не

приводящие к дефолту. Результаты авторов подтверждают, что ошибка обобщения, достигнутая с помощью SOM, остается более стабильной с течением времени, чем ошибка, достигнутая с помощью обычных моделей дефолта (дискриминантный анализ, логистическая регрессия, модель выживания Кокса, нейронные сети и ансамблевые методы). Однако, что более важно в контексте нашего обсуждения, автор рассматриваемой методологии выделяет разное количество процессов, которые показывают перемещение фирм между регионами с разной вероятностью краха: шесть в работе [9], семь в [11], восемь в [6]. Это различие можно объяснить влиянием используемых данных (конкретные годы и временной лаг до дефолта) и влиянием техники группировки траекторий. Это может быть несущественным с точки зрения эффективности модели, поскольку основной целью этих работ является повышение точности прогнозирования за счет учета предыстории фирмы. Однако, даже если этот подход улучшает прогностические возможности, он не позволяет анализировать процессы отказа, поскольку основан на модели «черного ящика».

Таким образом, можно сделать вывод, что существование различных процессов краха фирмы является общепризнанным фактом, однако нет единого мнения относительно определения этих процессов. Чтобы внести вклад в решение этой проблемы, мы предлагаем использовать метод моделирования причинности, а именно байесовские сети. Такой подход позволяет выявить причинно-следственные связи между финансовыми коэффициентами в различные периоды до банкротства, что может пролить свет на динамику развития фирмы.

1.2. Байесовские сети и моделирование причинно-следственных связей

Интуитивно причинно-следственную связь можно определить как влияние, посредством которого причина способствует возникновению следствия, при этом причина частично ответственна за следствие, а следствие частично зависит от причины [23]. Сложные системы характеризуются наличием множества взаимосвязанных аспектов. Таким образом, одной из самых больших проблем является извлечение причинно-следственных связей из эмпирических данных и построение моделей сложных систем, позволяющих изучать эти связи.

Подход, основанный на декларативном представлении [24], базируется на каузальной модели, кото-

рая кодирует знания о том, как работает система. Для представления причинно-следственных связей каузальная модель использует комбинацию уравнений и графиков. Математические уравнения, выражающие форму причинности (например, линейную или нелинейную), являются симметричными объектами, поэтому отношения переменных могут быть инвертированы с помощью простых манипуляций. По этой причине уравнения дополняются диаграммой, которая определяет направления причинно-следственного влияния [25]. Такая модель может быть построена вручную на основе знаний экспертов или автоматически с помощью алгоритмов машинного обучения [26].

Согласно [27], причинный вывод расширяет предиктивное моделирование (которое представляет собой оценку условного распределения $p(\mathbf{Y}|\mathbf{X})$ переменных $\mathbf{Y}$ и $\mathbf{X}$ на основе случайной выборки) до каузального моделирования, где модель должна быть способна оценить условное распределение $p(\mathbf{Y}|\mathbf{X}|\mathbf{M})$ при манипуляции $\mathbf{M}$.

Существует несколько подходов к построению причинно-следственных моделей, в частности моделирование структурными уравнениями (structural equation modeling, SEM) и байесовские сети (Bayesian networks, BN). SEM [28] ограничен, во-первых, тем, что требует априорных гипотез о причинно-следственных связях в системе. Во-вторых, он допускает только линейные типы связей. Поэтому в нашем исследовании мы будем использовать байесовские сети, поскольку они свободны от этих недостатков. Структура сети и ее параметры могут быть извлечены из данных, связи между переменными носят вероятностный характер.

Байесовская сеть кодирует совместное распределение вероятностей $\mathbb{P}(\mathbf{X})$ набора из m случайных категориальных переменных, $\mathbf{X} = (X_1, \dots, X_m)$, в виде направленного ациклического графа (directed acyclic graph, DAG) и набора таблиц условных вероятностей (conditional probability table, CPT). Более формально, это пара $\langle \mathcal{G}, \mathcal{P} \rangle$, где $\mathcal{G}$ – DAG, вершины которого соответствуют переменным в $\mathbf{X}$, а дуги представляют прямые зависимости между переменными, а $\mathcal{P}$ – набор функций, определяющих поведение каждой переменной в $\mathbf{X}$ с учетом ее родителей в графе [27, 29].

Размер полной совместной таблицы $\mathbb{P}(\mathbf{X})$ экспоненциально зависит от числа переменных m . Этот размер может быть сокращен благодаря условию Маркова, которое гласит, что в байесовской сети

каждая переменная условно независима от своих не-потомков и не-родителей. Таким образом, для множества случайных переменных $\mathbf{X}$ в $\mathcal{G}$ плотность $\mathbb{P}(\mathbf{X})$ имеет вид

$$\mathbb{P}(\mathbf{X}) = \mathbb{P}(X_1, \dots, X_m) = \prod_{i=1}^m \mathbb{P}(X_i | \text{parents}(X_i)),$$

где $\text{parents}(X_i)$ обозначает множество переменных $X_j \subset \mathbf{X}$, таких, что в графе существует дуга от узла j к узлу i .

Другими словами, каждый узел в графе $\mathcal{G}$, соответствующий переменной, имеет связанную с ним CPT, которая представляет вероятность каждого состояния переменной с учетом состояния ее родителей в графе. Такой вид представления позволяет компактно описать структуру сложного распределения [30]. С формальной точки зрения, байесовская сеть представляет собой базовое совместное распределение, включая такие вероятностные свойства, как условная независимость переменных друг от друга. С одной стороны, это более компактное представление сложных многомерных распределений. С другой стороны, «хорошая» структура сети должна соответствовать причинности, в том смысле, что ребро $X \rightarrow Y$ часто предполагает, что X «является причиной» Y , поскольку значения x из X определяют распределение значений Y [24, 25].

Байесовские сети имеют много преимуществ [24]. Во-первых, такой тип представления может быть легко интерпретирован. Во-вторых, такая структура позволяет отвечать на запросы, т. е. вычислять вероятность одних переменных при наличии данных о других. В-третьих, модели могут быть построены как экспертом, так и автоматически путем обучения на основе данных. В нашем исследовании мы будем использовать последний подход – обучение на основе данных.

Процесс построения байесовских сетей на основе данных $\mathcal{D}$ включает два этапа: генерацию графа, представляющего оптимальную структуру сети (обучение структуры), и определение условных вероятностей (обучение параметров). Многие авторы применяют байесовские сети для решения задач в различных областях: например, бизнес [31], экология [32], здравоохранение [33], диагностика неисправностей в инженерных системах [34] и многие другие [35].

Следует также отметить, что существует расширение модели байесовской сети для панельных данных, а именно динамические байесовские сети. Однако динамические модели основаны на пред-

положении, что исследуемый процесс является стационарным, то есть его параметры не меняются со временем. Согласно [1] и другим исследованиям, процесс банкротства фирмы не является стационарным. Поэтому в нашем исследовании мы генерируем структуры сетей для разных временных интервалов независимо друг от друга.

1.3. Вывод и объяснение в байесовских сетях

Вывод (inference) — это процесс извлечения новой вероятностной информации из байесовской сети. Он вычисляет совместные апостериорные вероятности для подмножества неизвестных переменных с учетом доказательств, которыми являются значения известных переменных. Такое вычисление является NP-полной задачей, поэтому предложены как алгоритмы, реализующие точное вычисление, так и алгоритмы для приближенного вычисления, которые могут сходиться медленно и даже не точно, но во многих случаях полезны на практике. Эта возможность позволяет использовать байесовскую сеть для контролируемой классификации, целью которой является присвоение меток экземплярам, описываемым набором предиктивных переменных [36].

Однако, в отличие от многих методов машинного обучения, байесовская сеть может использоваться не только для предсказания, но и для объяснения [37]. Задачи объяснения в байесовских сетях можно разделить на три категории [38]:

- ◆ объяснение модели — представление знаний о системе,
- ◆ объяснение рассуждений — представление выведенных результатов и процесса рассуждений,
- ◆ объяснение доказательств, т.е. определение того, какие значения ненаблюдаемых переменных объясняют имеющиеся наблюдения.

Поскольку целью настоящего исследования является анализ структур байесовских сетей, которые моделируют фирмы в разные периоды времени перед финансовым крахом, объяснение модели является наиболее важным вопросом. В [39] авторы приводят примеры объяснений модели. Эти объяснения могут включать свойства узлов и их взаимное влияние, которое может быть отрицательным или положительным. Влияние узла А на узел В является

положительным, когда более высокие значения А делают более вероятными высокие значения В. Определения отрицательного влияния и отрицательной связи аналогичны.

2. Данные

Поскольку одним из вопросов нашего исследования является сравнение FFR для разных стран, для анализа выбраны фирмы трех страны: Франция, Италия и Российская Федерация.

Для сравнения экономик на макроуровне мы используем валовой внутренний продукт (ВВП), пересчитанный в доллары 2017 года по паритету покупательной способности (ППС) и разделенный на общую численность населения¹.

На *рис. 1* показано изменение этого показателя за временной интервал 2009–2019 гг. Франция имеет наиболее стабильную экономику; она демонстрирует постоянный рост ВВП на душу населения в течение всего исследуемого периода. Экономика Италии более нестабильна; после 2010 года наблюдался спад, рост возобновился только в 2015 году. Движущей силой итальянской экономики в значительной степени являются малые и средние предприятия, многие из которых находятся в семейной собственности. В Италии также существует значительная теневая экономика, которая оценивается в 17% от ВВП². Исходя из этих данных, можно ожидать, что модель FFR для французских фирм будет более стабильной, чем для итальянских, поскольку они работают в более предсказуемой среде. Отметим, что согласно классификации Всемирного банка, обе страны относятся к группе развитых стран.

Российская Федерация относится к группе развивающихся стран или стран с переходной экономикой. Российская экономика характеризуется значительной долей государственного сектора и в значительной степени регулируется не рынком, а политическими решениями. Сочетание падения цен на нефть, международных санкций и структурных ограничений ввергло Россию в глубокую рецессию в 2015 году, однако в 2017 году падение ВВП было остановлено, поскольку мировой спрос на нефть вырос. Наличие этих факторов ведет к высокому росту экономической неопределенности. В

¹ <https://data.worldbank.org>

² CIA (2021) The World Factbook. <https://www.cia.gov/the-world-factbook/>

Рис. 1. Изменение ВВП по ППС на душу населения (доллары США).

таких условиях можно ожидать, что модель FFP для российских фирм будет довольно сильно меняться на разных этапах.

Данные, необходимые для исследования, были получены из базы Bureau van Dijk Amadeus³. Отобранные фирмы, относящиеся к малому и среднему бизнесу, работавшие в 2009–2019 гг. (2020 год исключен, чтобы избежать влияния шоков, связанных с пандемией COVID-19). Размер фирмы определялся по количеству сотрудников за последний доступный год, заданы ограничения $\min = 10$, $\max = 250$. Отобранные фирмы для каждой страны размечены согласно следующему правилу:

- ◆ Успешные компании ($Class = 0$), которые имеют статус Active в последнем доступном году.

- ◆ Неуспешные компании ($Class = 1$), которые имеют один из статусов: Active (default of payment), Active (insolvency proceedings), Bankruptcy, Dissolved (liquidation), and Dissolved.

Таким образом, для каждой из рассматриваемых стран получено пять выборок, соответствующих периоду $t - n$, $n = 1, \dots, 5$ до наблюдения в году t . Каждое наблюдение имеет метку класса, которая указывает на состояние фирмы в конце прогнозного периода t : финансовый крах ($Class = 1$) или успешная компания ($Class = 0$). Количество наблюдений для каждого временного периода представлено в *таблице 1*; в скобках указано количество фирм, потерпевших неудачу. Как видно, все наборы данных являются несбалансированными. Значения коэффициента дисбаланса (imbalance ratio, IB), рассчитанного как отношение числа наблюдений отрицательного класса к числу неудачных компаний, также приведены в *таблице 1*.

2.1. Отбор переменных

Поскольку целью работы является построение интерпретируемых причинно-следственных моделей, необходимо сократить количество переменных в исходном наборе данных, оставив только те, которые обеспечивают оптимальный баланс простоты и полноты. Поэтому мы будем следовать подход [1], которые при анализе процесса банкротства использовали четыре переменные, включенных в Z"-модель Альтмана.

В работе, представляющей первоначальную Z-модель, Альтман [13] рассмотрел 22 потенциаль-

Таблица 1.

Характеристики набора данных

		$t - 5$	$t - 4$	$t - 3$	$t - 2$	$t - 1$
Франция	Кол-во фирм	48024 (1509)	47163 (1503)	44151 (1439)	41798 (1382)	39720 (1313)
	IB	30,825	30,379	29,682	29,245	29,251
Италия	Кол-во фирм	55895 (5223)	56036 (5349)	56170 (5522)	56115 (5535)	55728 (5498)
	IB	9,702	9,476	9,172	9,138	9,136
РФ	Кол-во фирм	44354 (1941)	43859 (2077)	43153 (2167)	43050 (2337)	42931 (2398)
	IB	21,851	20,117	18,914	17,421	16,903

³ Bureau van Dijk. Amadeus. <https://amadeus.bvdinfo.com>

Таблица 2.

Финансовые коэффициенты модели Альтмана

Категория	Коэффициент	Формула	Примечания
Ликвидность	WCTA	Working Capital / Total Assets	Оборотный капитал определяется как разница между текущими активами и текущими обязательствами, поэтому данный коэффициент является мерой чистых ликвидных активов фирмы по отношению к общей капитализации [13]. Роль ликвидности основана на юридических соображениях, поскольку неспособность выплатить непогашенный долг является достаточным условием для начала официального процесса банкротства [1].
Кумулятивная прибыльность	RETA	Retained Earnings / Total Assets	Это мера кумулятивной прибыльности во времени, которая неявно включает в себя возраст фирмы [13].
Текущая прибыльность	EBITTA	Earnings before Interest and Taxes / Total Assets	Это показатель истинной производительности активов фирмы, абстрагированный от любых налоговых или факторов леввериджа [13].
Левверидж	BVETL	Book Value of Equity / Book Value of Total Liabilities	В первоначальной Z-модели использовалась рыночная стоимость собственного капитала, но этот подход применим только к публично торгуемым компаниям [4]. Этот коэффициент измеряет способность компании обслуживать обязательства за счет собственного капитала, поскольку дополнительный долг при прочих равных условиях увеличивает вероятность банкротства [1].
Активность	STA (excluded)	Sales / Total Assets	Исключен из пересмотренной Z'-модели, поскольку является переменной, чувствительной к отрасли [4].

но важных финансовых коэффициента, классифицированных по пяти стандартным категориям: ликвидность, прибыльность, левверидж (способность обслуживать обязательства за счет собственных средств), платежеспособность и активность. Только пять финансовых коэффициентов были включены в окончательную дискриминантную модель (таблица 2). Более высокие значения всех выбранных коэффициентов соответствуют более низкой вероятности банкротства.

Позже автор отметил, что оригинальная модель применима только к публично торгуемым компаниям, поскольку включает рыночную стоимость (marked value of equity) фирмы [40]. По этой причине в новой версии модели он заменил рыночную стоимость капитала балансовой (book value of equity) стоимостью (Z'-модель). Следующим значительным усовершенствованием стало исключение коэффициента «Продажи / Общие активы», поскольку его значение сильно зависит от отрасли (Z"-модель).

Таким образом, мы будем использовать четыре коэффициента (WCTA, RETA, EBITTA и BVETL), включенные в Z"-модель. Одним из предварительных условий моделирования на основе байесовской

сети является отсутствие латентных переменных (ненаблюдаемых переменных, влияющих на переменные сети). Основываясь на модели Альтмана, можно с уверенностью считать, что это условие выполнено и латентных факторов в эмпирических данных нет.

В работе [4] Альтман и соавторы проверили эффективность Z"-модели, используя международный набор данных (более 2,6 млн наблюдений фирм из 31 страны в обучающей выборке). В целом их результаты подтверждают, что точность модель достаточно высока, несмотря на ее простоту. Однако авторы сделали несколько важных уточнений:

- ♦ коэффициенты модели должны оцениваться отдельно для каждой выборки,
- ♦ модель, основанная на логистической регрессии, дает лучшие результаты, чем версия на основе множественного дискриминантного анализа.

Поэтому мы будем использовать логистическую регрессию как базовую модель для валидации преобразований данных. В таблице 3 представлены значения ROC AUC, полученные с помощью процедуры 10-кратной кросс-валидации логистической регрессии (LR) для данных, содержащих вышеуказанные четыре признака Альтмана (см.

Таблица 3.

Значение метрики ROC AUC (10-кратная кросс-валидация)

Данные	Модель	Период				
		$t-5$	$t-4$	$t-3$	$t-2$	$t-1$
Франция						
Raw data	LR	0,675(0,034)	0,686(0,034)	0,694(0,026)	0,705(0,024)	0,714(0,028)
Discretized data	LR	0,687(0,030)	0,696(0,029)	0,712(0,022)	0,723(0,019)	0,729(0,027)
	BN	0,686(0,028)	0,697(0,028)	0,712(0,016)	0,726(0,015)	0,727(0,032)
Италия						
Raw data	LR	0,695(0,039)	0,727(0,031)	0,744(0,026)	0,768(0,017)	0,802(0,012)
Discretized data	LR	0,716(0,027)	0,761(0,019)	0,777(0,015)	0,798(0,013)	0,826(0,009)
	BN	0,717(0,028)	0,757(0,019)	0,776(0,013)	0,809(0,021)	0,833(0,015)
Российская Федерация						
Raw data	LR	0,658(0,023)	0,675(0,021)	0,691(0,014)	0,711(0,014)	0,742(0,010)
Discretized data	LR	0,676(0,024)	0,683(0,018)	0,695(0,011)	0,731(0,021)	0,757(0,020)
	BN	0,709(0,034)	0,740(0,038)	0,738(0,034)	0,743(0,030)	0,770(0,037)

строку «Raw data» для каждой страны). Отметим, что качество прогнозирования снижается по мере увеличения интервала между наблюдением и оценкой, поскольку подход классификации игнорирует изменения в фирме с течением времени [16].

2.2 Дискретизация

Еще одна проблема применения байесовских сетей связана с тем, что концепция нелинейной байесовской сети была разработана для работы с дискретными или категориальными данными. Существует три общих подхода к расширению байесовской сети на непрерывные данные [41]. Первый заключается в моделировании условной плотности вероятности непрерывных переменных с помощью параметрических распределений, а затем в перепроектировании алгоритмов обучения сети на основе параметризации [42]. Второй подход заключается в использовании непараметрических распределений, таких как гауссовские процессы [43]. Третий подход – дискретизация, то есть процесс, который преобразует непрерывную переменную в конечное число интервалов и связывает с каждым интервалом дискретное значение [44, 45].

Подход к дискретизации в контексте байесовских сетей можно разделить на две части. Во-первых,

существуют алгоритмы, которые дискретизируют атрибуты на основе взаимозависимостей между метками классов и значениями атрибутов, например метод энтропийного бининга [46]. Эти алгоритмы основаны на подходе классификации данных. Они используются для дискретизации всех непрерывных переменных перед обучением структуры байесовской сети. Следующий класс алгоритмов требует, чтобы структура сети была известна заранее [41, 45, 47]. Эти алгоритмы начинают с некоторой предварительной политики дискретизации, затем запускается алгоритм обучения структуры для определения локально оптимальной структуры графа. Затем политика дискретизации обновляется на основе обученной сети, и этот цикл повторяется до сходимости.

Мы провели серию экспериментов и выяснили, что предварительная дискретизация по методу [46] позволяет обучать сети с более высокой метрикой качества. В таблице 3 приведены оценки ROC AUC логистической регрессии (LR), полученные на дискретизированных данных, которые подтверждают, что выбранный подход к дискретизации улучшает производительность модели.

Для справки, на рис. 2 и 3 показано распределение необработанных и дискретизированных данных соответственно набора данных по Италии за период $t-1$. Отметим, что средние значения преобразованных

Рис. 2. Набор данных Италия $t - 1$: распределение исходных (непрерывных) данных.

Рис. 3. Набор данных Италия $t - 1$: распределение дискретизированных данных.

коэффициентов изменились, поскольку теперь вместо абсолютных значений мы используем определенные интервалы, на которые делится каждая переменная. Для моделирования на основе байесовской сети такое преобразование приемлемо, поскольку в модели используются совместные вероятности. Количество интервалов, согласно [46], определяется на основе совместного распределения дискретизируемого признака и целевой переменной.

3. Эксперимент и результаты

Процесс построения байесовских сетей по данным $\mathcal{D}$ включает два этапа: генерирование направленного ациклического графа $\mathcal{G}$, представляющего оптимальную структуру байесовской сети (обучение структуры), а затем определение таблиц условных вероятностей $\mathcal{P}$ для каждого узла графа (обучение параметров). Для нашего исследования наиболее важно изучить структуру байесовских сетей, соответствующих различным периодам до дефолта. Однако мы выполнили оба этапа обучения, так как СРТ важен для причинного вывода и, следовательно, использования модели в качестве прогностического инструмента.

Обучение структуры байесовских сетей может быть сложным по двум основным причинам: (1) вывод причинности и (2) сверхэкспоненциальное число направленных ребер, которые могут существовать в наборе данных. Большинство методов изучения структуры можно отнести к одной из следующих категорий [24, 29]:

- ♦ обучение структуры в процессе решения задачи оптимизации некоторой метрики $score(G, \mathcal{D})$

$$\operatorname{argmax}_{G \in \mathcal{G}} score(G, \mathcal{D}).$$

Другими словами, задача состоит в том, чтобы найти наилучший ориентированный ациклический граф в соответствии с некоторой функцией оценки, которая измеряет его соответствие данным. Широко распространенными оценками являются метрика Байеса-Дирихле (BDeu), Байесовский информационный критерий (BIC), который аппроксимирует BDeu, и информационный критерий Акаике (AIC).

- ♦ семейство алгоритмов обучения на основе ограничений, которые выполняют серию статистических тестов для поиска взаимно независимых переменных и строят DAG в соответствии с этими ограничениями.

Согласно [24], подход на основе оптимизации метрики оценивает полную структуру сети против нулевой гипотезы о том, что сеть является пустой. Таким образом, он использует более глобальную перспективу, что позволяет найти компромисс между приближениями в различных частях сети. Поэтому мы используем алгоритмы на основе оптимизации метрики.

Для оценки структуры мы используем показатель BIC. Пусть у нас есть набор случайных переменных $\mathcal{D}$, S – оцениваемая структура байесовской сети, а Θ_S – вектор параметров для S . Тогда

$$BIC = \log P(\mathcal{D} | S, \Theta^*) - \frac{d}{2} \log N,$$

где Θ^* – оценка Θ_S ;

d – число свободных параметров в S ;

N – размер набора данных.

Первый член в формуле представляет собой логарифм правдоподобия, а второй – штраф за сложность.

BIC обладает двумя важными свойствами, которые позволяют использовать его в качестве универсальной метрики. Во-первых, BIC инвариантен к эквивалентности, т. е. он дает одинаковые оценки эквивалентным моделям. С ростом числа переменных растет и число возможных сетевых структур. Это свойство BIC гарантирует присвоение одинакового балла эквивалентным сетям. Во-вторых, BIC локально согласован, если размер выборки достаточно велик.

Существует множество различных программных пакетов, реализующих широкий набор методов обучения байесовских сетей (например, см. обзор в [29]). В данной работе использовалась библиотека Python с открытым исходным кодом `omegranate` [48], в которой реализовано несколько методов на основе метрик, в частности точный алгоритм A^* [49], его «жадная» версия и алгоритм [50].

На первом этапе мы протестировали все алгоритмы в пакете `omegranate`, чтобы найти те, которые дают наилучшие результаты на наших данных. Согласно тестам, лучшие результаты показал точный алгоритм A^* . В *таблице 4* представлены полученные значения BIC для байесовской сети. Мы также протестировали Наивную байесовскую модель (Naïve Bayes, NB), чтобы убедиться, что учет вероятностных отношений между переменными повышает качество моделирования. NB – это простейшая форма байесовской сети, вытекающая из

Таблица 4.

Байесовский информационный критерий (ВІС) для байесовской сети (BN) и модели наивный байесовский классификатор (NB)

	<i>t</i> – 5				
Франция					
NB	–201 163	–192 127	–180 853	–178 759	–159 080
BN	–171 651	–162 705	–152 862	–147 833	–129 372
Италия					
NB	–360 293	–375 556	–380 321	–391 209	–394 780
BN	–316 636	–332 979	–324 984	–326 920	–329 246
Российская Федерация					
NB	–199 197	–249 535	–235 613	–240 508	–247 257
BN	–167 615	–214 696	–204 133	–206 716	–211 850

предположения о взаимной независимости экзогенных переменных. Результаты, представленные в *таблице 4*, подтверждают, что наивная байесовская модель уступает по точности байесовским сетям. Соответствующие значения ВІС примерно на 20% хуже, чем полученные для байесовских сетей.

Мы также проверили производительность классификатора, построенного на основе найденной байесовской сети [36]. Учитывая, что данные являются несбалансированными, мы использовали настройку порога принятия решения, вводя различные штрафы за ошибки неправильной классификации [51]. Так, для наблюдения *x* предсказанная метка класса $\hat{y}(x) = 1$ тогда и только тогда, когда $\mathbb{P}(x) \geq t$. Здесь $\mathbb{P}(x)$ — это вывод байесовской сети, когда известны все переменные, кроме *Class*. Порог *t* вычисляется как

$$t = C_{10} / (C_{10} + C_{01}),$$

где C_{ij} — стоимость предсказания класса *i*, когда истинным классом является *j*. Мы задали $C_{10} = 1$ и $C_{01} = IB$, где *IB* — коэффициент дисбаланса обучающего набора данных (см. *таблицу 1*).

В *таблице 3* представлены значения ROC AUC, полученные с помощью 10-кратной перекрестной валидации классификатора на основе байесовской сети (строки «Discretized data / BN»). Как мы видим, производительность такого классификатора, как минимум, сопоставима с логистической регрессией для всех наборов данных и превосходит ее в большинстве случаев, особенно для

экономик с высокой неопределенностью (Россия и Италия).

4. Обсуждение

Сетевые структуры, представленные на *рис. 4–6*, позволяют сделать некоторые важные выводы об особенностях различных стадий процесса, ведущего к финансовому краху фирмы. Переменная *Class*, обозначающая состояние фирмы (0 для успешных фирм и 1 для банкротов), находится в корне графов. Это можно легко интерпретировать следующим образом. Состояние фирмы является первопричиной, определяющей значения ее финансовых коэффициентов. Это согласуется с задачей прогнозирования краха, когда состояние фирмы вычисляется по значениям финансовых коэффициентов.

Как следует из *рис. 4–5*, для развитых экономик (Италия, Франция) ранние стадии долгосрочного процесса (*t* – 5, *t* – 4) совпадают. В период *t* – 5 кумулятивная прибыльность положительно влияет на разницу между активами и обязательствами, т. е. на леверидж (отметим, что числитель BVETL — это разница между совокупными активами и совокупными обязательствами). Оба фактора затем определяют текущую ликвидность и текущую прибыльность фирмы. Отметим также, что ликвидность и текущая рентабельность условно независимы. Однако, начиная с периода *t* – 4 текущая прибыльность становится фактором, влияющим на ликвидность.

Для более предсказуемой экономики (Франция) модель не меняется в периоды *t* – 4, *t* – 3 и *t* – 2.

Рис. 4. Франция: Байесовские сети для различных периодов до дефолта.

Рис. 5. Италия: Байесовские сети для различных периодов до дефолта.

Рис. 6. Российская Федерация: Байесовские сети для различных периодов до дефолта.

За год до финансового краха сетевая структура для Франции меняется и становится похожей на период $t - 5$. В целом можно сделать вывод, что кумулятивная прибыль является ключевым фактором успеха французских фирм.

Модель, представляющая процесс краткосрочного банкротства итальянских фирм ($t - 2$ и $t - 1$), меняется более радикально. Ключевым фактором является разница между активами и обязательствами (леверидж), которая определяет способность фирмы генерировать прибыль и ликвидность. Отметим также, что значения ликвидности условно не зависят от кумулятивной и годовой прибыльности на этих этапах. Очевидно, это связано с повышенной неопределенностью в итальянской экономике. Фирмы, не способные выполнить обязательства за счет собственных активов, не могут быстро исправить ситуацию, увеличив производительность за счет заемных ресурсов.

Для российских компаний ключевыми факторами являются леверидж и кумулятивная прибыльность. Также отметим, что в данном случае ликвидность зависит от всех рассматриваемых переменных (кроме периода $t - 2$). В целом процесс можно описать следующим образом. В средне- и долгосрочном периодах ($t - 3$ и $t - 4$) кумулятивная прибыльность оказывает положительное влияние на годовую рентабельность. Это можно объяснить тем, что коэффициент RETA неявно отражает возраст фирмы [13] и ее способность стабильно генерировать прибыль. Накопленная прибыль также обуславливает количество привлеченных внешних ресурсов. В то же время текущая рентабельность и леверидж условно независимы, однако они совместно полностью определяют ликвидность. Условную независимость текущей прибыльности и способности выполнять обязательства за счет собственных ресурсов можно объяснить тем, что на данных этапах мы рассматриваем достаточно длительный процесс, результаты которого будут оцениваться через 3–4 года. Очевидно, что на этот процесс большее влияние оказывают управленческие решения, основанные на финансовых показателях, которые отражают долгосрочные тенденции (кумулятивная прибыльность), чем краткосрочные результаты (текущая прибыльность).

На этапе $t - 2$ леверидж становится ключевым фактором. Это означает, что способность привлекать ресурсы позволяет отстающим фирмам увеличить прибыльность и повысить ликвидность и избежать финансовых сбоев через 2 года. В год

$t - 1$ кумулятивная прибыльность становится причинным фактором, определяющим леверидж. Это можно объяснить тем, что потенциальные кредиторы оценивают общие результаты деятельности фирмы в долгосрочной перспективе, что может ограничить доступность заемных ресурсов. Годовая рентабельность обусловлена способностью генерировать прибыль в долгосрочной перспективе и обслуживать долг. Леверидж и годовая рентабельность определяют текущее значение ликвидности, которая на данном этапе является основным показателем потенциальных финансовых неудач.

Основной вывод из представленных результатов заключается в том, что взаимное влияние факторов, определяющих состояние фирмы, меняется с течением времени ($RQ1$). В целом, для фирм в начале длительного процесса, который может привести к краху, кумулятивная прибыльность является ключевым фактором, определяющим другие метрики, такие как ликвидность и леверидж. Затем, по мере развития процесса, в среднесрочной перспективе, степень самодостаточности, измеряемая левериджем, выходит на первый план, особенно для экономик с более высокой неопределенностью. На этих этапах низкие значения этих факторов ограничивают возможности получения прибыли. Это приводит к дальнейшему развитию процесса, ведущего к финансовому краху.

Кроме того, существует национальная специфика, обусловленная, во-первых, уровнем развития экономики ($RQ2$) и, во-вторых, неопределенностью экономической политики ($RQ3$). Эта специфика проявляется как в изменении причинно-следственных связей между факторами на разных этапах процесса краха фирмы, так и в скорости смены моделей. Наиболее устойчивый набор моделей получен для Франции, для которой характерна наименьшая неопределенность. Для России, для которой характерен максимальный рост экономической неопределенности за последние 10 лет, модели меняются чаще и радикальнее.

Таким образом, полученные модели проливают свет на специфику различных этапов процесса, ведущего к финансовому краху. Насколько нам известно, данная работа является первой попыткой анализа FFP на основе байесовских сетей. Однако наше исследование в его нынешнем виде имеет некоторые ограничения. В частности, можно отметить следующее:

- ◆ Используемая выборка содержит кросс-секционные данные за различные периоды времени, предшествующие финансовым проблемам. Это позволяет нам выявить различия в причинно-следственных связях на этапах FFP; но невозможно проследить эволюцию конкретных фирм. Для решения такой проблемы необходимы панельные данные. Анализ данных, содержащих последовательные периоды для успешных и провальных фирм, может дать более подробную информацию о причинно-следственных связях в процессе краха фирмы. Однако решение этой задачи требует другого инструмента, которым может стать динамическая байесовская сеть.
- ◆ Анализируемые факторы ограничены только четырьмя финансовыми коэффициентами, представленными в Z"-модели Альтмана. Мы приняли это ограничение, исходя из требований простоты модели и возможности ее дальнейшей интерпретации. Это позволило сделать важные выводы о внутренней динамике фирмы. Однако в дальнейших исследованиях список финансовых коэффициентов может быть расширен для получения более сложных и детальных моделей. Также необходимо изучить влияние других параметров, например, корпоративного управления и факторов внешней среды.

Следующий вопрос, представляющий практический интерес – это определение текущей стадии процесса анализируемой фирмы. Эта информация может быть полезна для прогностических моделей, которые будут рассчитывать вероятность дефолта для нескольких будущих периодов. Этот вопрос также является темой будущих исследований.

Заключение

Основная цель нашей работы – продемонстрировать, что байесовские сети могут служить надежным инструментом для анализа динамики фирм и изучения процесса финансового краха фирмы. Наши результаты, с одной стороны, подчеркивают специфику этапов процесса банкротства для разных экономик. С другой стороны, они позволяют нам строить прогностические модели, превосходящие Z"-модель Альтмана, используя те же переменные. Насколько нам известно, представленная работа является первой, использующей байесовские сети для анализа FFP, поэтому многие вопросы остались за рамками нашего исследования. Возможные области исследования включают:

- ◆ Построение моделей на панельных данных, описывающих динамику множества фирм.
- ◆ Расширение числа анализируемых признаков.
- ◆ Моделирование специфики отраслей.
- ◆ Определение стадии процесса для прогнозирования неудачи в долгосрочной перспективе.

Все это открывает обширное поле для новых исследований, которые, в свете полученных результатов, представляются перспективными, поскольку потенциально могут внести значительный вклад в теоретический и эмпирический анализ процесса краха фирмы. ■

Благодарности

Работа выполнена в рамках проекта «Разработка количественных методов прогнозирования банкротств», поддержанного грантом Высшей школы бизнеса НИУ ВШЭ.

Литература

1. Lukason O., Laitinen E.K. Firm failure processes and components of failure risk: An analysis of European bankrupt firms // *Journal of Business Research*. 2019. Vol. 98. P. 380–390. <https://doi.org/10.1016/j.jbusres.2018.06.025>
2. Altman E.I., Iwanicz-Drozowska M., Laitinen E., Suvas, A. A Race for Long Horizon Bankruptcy Prediction // *Applied Economics*. 2020. Vol. 52. No. 37. P. 4092–4111. <https://doi.org/10.1080/00036846.2020.1730762>
3. du Jardin P. Forecasting corporate failure using ensemble of self-organizing neural networks // *European Journal of Operational Research*. 2021. Vol. 288. No. 3. P. 869–886. <https://doi.org/10.1016/j.ejor.2020.06.020>
4. Altman E.I., Iwanicz-Drozowska M., Laitinen E.K., Suvas A. Financial distress prediction in an international context: A review and empirical analysis of Altman's Z-Score model // *Journal of International Financial Management & Accounting*. 2017. Vol. 28. No. 2. P. 131–171. <http://doi.org/10.1111/jifm.12053>
5. Zelenkov Y., Fedorova E., Chekrizov D. Two-step classification method based on genetic algorithm for bankruptcy forecasting // *Expert Systems with Applications*. 2017. Vol. 88. P. 393–401. <https://doi.org/10.1016/j.eswa.2017.07.025>
6. du Jardin P. Dynamics of firm financial evolution and bankruptcy prediction // *Expert Systems with Applications*. 2017. Vol. 75. P. 25–43. <https://doi.org/10.1016/j.eswa.2017.01.016>

7. D'Aveni R. The aftermath of organizational decline: A longitudinal study of the strategic and managerial characteristics of declining firms // *Academy of Management Journal*. 1989. Vol. 32. No. 3. P. 577–605. <http://doi.org/10.5465/256435>
8. Ooghe H., De Prijcker S. Failure processes and causes of company bankruptcy: A typology // *Management Decision*. 2008. Vol. 46, No. 2. P. 223–242. <https://doi.org/10.1108/00251740810854131>
9. du Jardin P., Séverin E. Forecasting financial failure using a Kohonen map: A comparative study to improve model stability over time // *European Journal of Operational Research*. 2012. Vol. 221. No. 2. P. 378–396. <https://doi.org/10.1016/j.ejor.2012.04.006>
10. Argenti J. *Corporate collapse: The causes and symptoms*. NY: McGraw-Hill, 1976.
11. du Jardin P. Bankruptcy prediction using terminal failure processes // *European Journal of Operational Research*. 2015. Vol. 242. No. 1. P. 276–303. <http://doi.org/10.1016/j.ejor.2014.09.059>
12. Bellovary J.L., Giacominio D.E., Akers M.D. A review of bankruptcy prediction studies: 1930 to present // *Journal of Financial Education*. 2007. Vol. 33. P. 1–42.
13. Altman E.I. Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy // *Journal of Finance*. 1968. Vol. 23. P. 589–609.
14. Barboza F., Kimura H., Altman E. Machine learning models and bankruptcy prediction // *Expert Systems with Applications*. 2017. Vol. 83. P. 405–417. <https://doi.org/10.1016/j.eswa.2017.04.006>
15. Zelenkov Y., Volodarskiy N. Bankruptcy prediction on the base of the unbalanced data using multi-objective selection of classifiers // *Expert Systems with Applications*. 2021. Vol. 185. Article ID 115559. <https://doi.org/10.1016/j.eswa.2021.115559>
16. Balcaen S., Ooghe H. 35 Years of Studies on Business Failure: An Overview of the Classic Statistical Methodologies and Their Related Problems // *The British Accounting Review*. 2006. Vol. 38. P. 63–93. <https://doi.org/10.1016/j.bar.2005.09.001>
17. Bardos M. What is at stake in the construction and use of credit scores? // *Computational Economics*. 2007. Vol. 29. No. 2. P. 159–172. <https://doi.org/10.1007/s10614-006-9083-x>
18. Iwanicz-Drozowska M., Laitinen E.K., Suvas A., Altman E.I. Financial and Nonfinancial Variables as Long-horizon Predictors of Bankruptcy // *Journal of Credit Risk*. 2016. Vol. 12. No. 4. P. 49–78. <https://doi.org/10.21314/JCR.2016.216>
19. Pizzi S., Caputo F., Venturelli A. Does it pay to be an honest entrepreneur? Addressing the relationship between sustainable development and bankruptcy risk // *Corporate Social Responsibility and Environmental Management*. 2020. Vol. 27. No. 3. P. 1478–1486. <https://doi.org/10.1002/csr.1901>
20. Zelenkov Y. Bankruptcy Prediction Using Survival Analysis Technique // *IEEE 22nd Conference on Business Informatics (CBI)*, 2020. Vol. 2. P. 141–149. <https://doi.org/10.1109/CBI49978.2020.10071>
21. Cottrell M. Some other applications of the SOM algorithm: how to use the Kohonen algorithm for forecasting // *7th International Work-Conference on Artificial Neural Networks (IWANN)*, 2003. Invited lecture.
22. Serrano-Cinca C. Let financial data speak for themselves // *Visual Explorations in Finance with Self-Organizing Maps* / Deboeck G., Kohonen T. (eds.). Springer. 1998. P. 3–23.
23. Bunge M. *Causality and modern science: Fourth revised edition*. NY: Routledge, 2017.
24. Koller D., Friedman N. *Probabilistic graphical models: Principles and techniques*. Cambridge, MA: MIT Press, 2009.
25. Pearl J. *Causality*. Cambridge, UK: Cambridge University Press, 2009.
26. Zhao Q., Hastie T. Causal Interpretations of Black-Box Models // *Journal of Business & Economic Statistics*. 2021. Vol. 39. No. 1. P. 272–281. <https://doi.org/10.1080/07350015.2019.1624293>
27. Spirtes P. Introduction to causal inference // *Journal of Machine Learning Research*. 2010. Vol. 11. P. 1643–1662.
28. Hair J.F., Hult G.T.M., Ringle C.M., Sarstedt M., Thiele K.O. Mirror, mirror on the wall: a comparative evaluation of composite-based structural equation modeling methods // *Journal of the Academy of Marketing Science*. 2017. Vol. 45. No. 5. P. 616–632. <https://doi.org/10.1007/s11747-017-0517-x>
29. Scanagatta M., Salmeron A., Stella F. A survey on Bayesian network structure learning from data // *Progress in Artificial Intelligence*. 2019. Vol. 8. P. 425–439. <https://doi.org/10.1007/s13748-019-00194-y>
30. Sucar L.E. *Probabilistic graphical models: Principles and applications*. Cham, Switzerland: Springer Nature, 2021.
31. Erci A., Ekici S.O. Understanding and managing complexity through Bayesian network approach: The case of bribery in business transactions // *Journal of Business Research*. 2021. Vol. 129. P. 757–773. <https://doi.org/10.1016/j.jbusres.2019.10.024>
32. Marcot B.G., Penman T.D. Advances in Bayesian network modelling: Integration of modelling technologies // *Environmental Modelling & Software*. Vol. 111. P. 386–393. <https://doi.org/10.1016/j.envsoft.2018.09.016>
33. McLachlan S., Dube K., Hitman G. A., Fenton N. E., Kyrimi E. Bayesian networks in healthcare: Distribution by medical condition // *Artificial Intelligence in Medicine*. 2020. Vol. 107. Article ID 101912. <https://doi.org/10.1016/j.artmed.2020.101912>
34. Cai B., Huang L., Xie M. Bayesian networks in fault diagnosis // *IEEE Transactions on Industrial Informatics*. 2017. Vol. 13. No. 5. P. 2227–2240. <https://doi.org/10.1109/TII.2017.2695583>
35. Pourret O., Naïm P., Marcot B. *Bayesian Networks: A Practical Guide to Applications*. Hoboken: Wiley, 2008.
36. Bielza C., Larranaga P. Discrete Bayesian Network Classifiers: A Survey // *ACM Computing Surveys*. 2014. Vol. 47. No. 1. Article ID 5. <http://doi.org/10.1145/2576868>

37. Yuan C., Lim H., Lu T.C. Most relevant explanation in Bayesian networks // *Journal of Artificial Intelligence Research*. 2011. Vol. 42. P. 309–352. <https://doi.org/10.1613/jair.3301>
38. Lacave C., Díez F.J. A review of explanation methods for Bayesian networks // *The Knowledge Engineering Review*. 2002. Vol. 17. No. 2. P. 107–127.
39. Lacave C., Luque M., Díez F. Explanation of Bayesian networks and influence diagrams in Elvira // *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*. 2007. Vol. 37. No. 4. P. 952–965. <https://doi.org/10.1109/TSMCB.2007.896018>
40. Altman E.I. *Corporate Financial Distress: A Complete Guide to Predicting, Avoiding, and Dealing with Bankruptcy*. Hoboken: Wiley, 1983.
41. Chen Y.C., Wheeler T.A., Kochenderfer M.J. Learning discrete Bayesian networks from continuous data // *Journal of Artificial Intelligence Research*. 2017. Vol. 59. P. 103–132. <https://doi.org/10.1613/jair.5371>
42. Weiss Y., Freeman W.T. Correctness of belief propagation in Gaussian graphical models of arbitrary topology // *Neural Computation*. 2001. Vol. 13. No. 10. P. 2173–2200. <https://doi.org/10.1162/089976601750541769>
43. Ickstadt K., Bornkamp B., Grzegorzczak M., Wieczorek J., Sheriff M.R., Grecco H.E., Zamir E. Nonparametric Bayesian network // *Bayesian Statistics*. 2010. Vol. 9. P. 283–316.
44. Kurgan L.A., Cios K.J. CAIM discretization algorithm // *IEEE transactions on Knowledge and Data Engineering*. 2004. Vol. 16. No. 2. P. 145–153. <https://doi.org/10.1109/TKDE.2004.1269594>
45. Lustgarten J.L., Visweswaran S., Gopalakrishnan V., Cooper G.F. Application of an efficient Bayesian discretization method to biomedical data // *BMC bioinformatics*. 2011. Vol. 12. No. 1. P. 1–15.
46. Fayyad U.M., Irani K.B. Multi-Interval Discretization of Continuous-Valued Attributes for Classification Learning // *Proceedings of 13th International Joint Conference on Artificial Intelligence (IJCAI'93)*. 1993. P. 1022–1027.
47. Friedman N., Goldszmidt M. Discretization of continuous attributes while learning Bayesian networks // *Proceedings of 13-th International Conference on Machine Learning*. 1996. P. 157–165.
48. Schreiber J. Pomegranate: fast and flexible probabilistic modeling in python // *Journal of Machine Learning Research*. 2018. Vol. 18. No. 164. P. 1–6.
49. Yuan C., Malone B., Wu X. Learning optimal Bayesian networks using A* search // *22nd International Joint Conference on Artificial Intelligence (IJCAI)*. 2011. P. 2186–2191.
50. Chow C. K., Liu C.N. Approximating discrete probability distributions with dependence trees // *IEEE Transactions on Information Theory*. 1968. Vol. 14. No. 3. P. 462–467.
51. Elkan C. The foundations of cost-sensitive learning // *Proceedings of International Joint Conference on Artificial Intelligence (IJCAI'01)*. 2001. P. 973–978.

Об авторе

Зеленков Юрий Александрович

доктор технических наук;

профессор департамента бизнес-информатики, Высшая школа бизнеса, Национальный исследовательский университет «Высшая школа экономики», 101000, г. Москва, ул. Мясницкая, д. 20;

E-mail: yzelenkov@hse.ru

ORCID: 0000-0002-2248-1023

Analysing the firm failure process using Bayesian networks

Yuri A. Zelenkov

E-mail: yzelenkov@hse.ru

HSE University

Address: 20, Myasnitskaya Street, Moscow 101000, Russia

Abstract

This work analyses the firm failure process stages using the Bayesian network as a modelling tool because it allows us to identify causal relationships in the firm profile. We use publicly available data on French, Italian and Russian firms containing five samples corresponding to periods from one to five years before observation. Our results confirm that there is a difference between the stages of the failure process. For firms at the beginning of a lengthy process (3–5 years before observation), cumulative profitability is the key that determines liquidity. Then, as the process develops, leverage comes to the fore in the medium term (1–2 years before observation) for economies with more uncertainty. This factor limits the opportunities for making a profit, leading to further development of the failure. There are also national specifics that are caused, firstly, by the level of economic development and, secondly, economic policy uncertainty.

Keywords: financial failure, firm failure process, Bayesian network

Citation: Zelenkov Y. (2022) Analysing the firm failure process using Bayesian networks. *Business Informatics*, vol. 16, no. 1, pp. 22–41. DOI: 10.17323/2587-814X.2022.1.22.41

References

1. Lukason O., Laitinen E.K. (2019) Firm failure processes and components of failure risk: An analysis of European bankrupt firms. *Journal of Business Research*, vol. 98, pp. 380–390. <https://doi.org/10.1016/j.jbusres.2018.06.025>
2. Altman E.I., Iwanicz-Drozdowska M., Laitinen E., Suvas A. (2020) A Race for Long Horizon Bankruptcy Prediction. *Applied Economics*, vol. 52, no. 37, pp. 4092–4111. <https://doi.org/10.1080/00036846.2020.1730762>
3. du Jardin P. (2021) Forecasting corporate failure using ensemble of self-organizing neural networks. *European Journal of Operational Research*, vol. 288, no. 3, pp. 869–886. <https://doi.org/10.1016/j.ejor.2020.06.020>
4. Altman E.I., Iwanicz-Drozdowska M., Laitinen E.K., Suvas A. (2017) Financial distress prediction in an international context: A review and empirical analysis of Altman's Z-Score model. *Journal of International Financial Management & Accounting*, vol. 28, no. 2, pp. 131–171. <https://doi.org/10.1111/jifm.12053>
5. Zelenkov Y., Fedorova E., Chekrizov D. (2017) Two-step classification method based on genetic algorithm for bankruptcy forecasting. *Expert Systems with Applications*, vol. 88, pp. 393–401. <https://doi.org/10.1016/j.eswa.2017.07.025>
6. du Jardin P. (2017) Dynamics of firm financial evolution and bankruptcy prediction. *Expert Systems with Applications*, vol. 75, pp. 25–43. <https://doi.org/10.1016/j.eswa.2017.01.016>
7. D'Aveni R. (1989) The aftermath of organizational decline: A longitudinal study of the strategic and managerial characteristics of declining firms. *Academy of Management Journal*, vol. 32, no. 3, pp. 577–605. <https://doi.org/10.5465/256435>
8. Ooghe H., De Prijcker S. (2008) Failure processes and causes of company bankruptcy: A typology. *Management Decision*, vol. 46, no. 2, pp. 223–242. <https://doi.org/10.1108/00251740810854131>
9. du Jardin P., Séverin E. (2012) Forecasting financial failure using a Kohonen map: A comparative study to improve model stability over time. *European Journal of Operational Research*, vol. 221, no. 2, pp. 378–396. <https://doi.org/10.1016/j.ejor.2012.04.006>
10. Argenti J. (1976) *Corporate collapse: The causes and symptoms*. New York, NY: McGraw-Hill.
11. du Jardin P. (2015) Bankruptcy prediction using terminal failure processes. *European Journal of Operational Research*, vol. 242, no. 1, pp. 276–303. <https://doi.org/10.1016/j.ejor.2014.09.059>
12. Bellovary J.L., Giacomino D.E., Akers M.D. (2007). A review of bankruptcy prediction studies: 1930 to present. *Journal of Financial Education*, vol. 33, pp. 1–42.
13. Altman E.I. (1968) Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *Journal of Finance*, vol. 23, pp. 589–609.

14. Barboza F., Kimura H., Altman E. (2017) Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, vol. 83, pp. 405–417. <https://doi.org/10.1016/j.eswa.2017.04.006>
15. Zelenkov Y., Volodarskiy N. (2021) Bankruptcy prediction on the base of the unbalanced data using multi-objective selection of classifiers. *Expert Systems with Applications*, vol. 185, article ID 115559. <https://doi.org/10.1016/j.eswa.2021.115559>
16. Balcaen S., Ooghe H. (2006) 35 Years of Studies on Business Failure: An Overview of the Classic Statistical Methodologies and Their Related Problems. *The British Accounting Review*, vol. 38, pp. 63–93. <https://doi.org/10.1016/j.bar.2005.09.001>
17. Bardos M. (2007) What is at stake in the construction and use of credit scores? *Computational Economics*, vol. 29, no. 2, pp. 159–172. <https://doi.org/10.1007/s10614-006-9083-x>
18. Iwanicz-Drozdzowska M., Laitinen E.K., Suvas A., Altman E.I. (2016) Financial and Nonfinancial Variables as Long-horizon Predictors of Bankruptcy. *Journal of Credit Risk*, vol. 12, no. 4, pp. 49–78. <https://doi.org/10.21314/JCR.2016.216>
19. Pizzi S., Caputo F., Venturelli A. (2020) Does it pay to be an honest entrepreneur? Addressing the relationship between sustainable development and bankruptcy risk. *Corporate Social Responsibility and Environmental Management*, vol. 27, no. 3, pp. 1478–1486. <https://doi.org/10.1002/csr.1901>
20. Zelenkov Y. (2020) Bankruptcy Prediction Using Survival Analysis Technique. In: *2020 IEEE 22nd Conference on Business Informatics (CBI)*, vol. 2, pp. 141–149. IEEE. <https://doi.org/10.1109/CBI49978.2020.10071>
21. Cottrell M. (2003) Some other applications of the SOM algorithm: how to use the Kohonen algorithm for forecasting. In: *Invited lecture at the 7th International Work-Conference on Artificial Neural Networks IWANN 2003*.
22. Serrano-Cinca C. (1998) Let financial data speak for themselves. In: Deboeck, G., Kohonen, T. (eds.) *Visual Explorations in Finance with Self-Organizing Maps*. Springer, pp. 3–23.
23. Bunge M. (2017) *Causality and modern science: Fourth revised edition*. Routledge, NY.
24. Koller D., Friedman N. (2009) *Probabilistic graphical models: Principles and techniques*. MIT Press, Cambridge: MA.
25. Pearl J. (2009) *Causality*. Cambridge University Press.
26. Zhao Q., Hastie T. (2021) Causal Interpretations of Black-Box Models. *Journal of Business & Economic Statistics*, vol. 39, no. 1, pp. 272–281. <https://doi.org/10.1080/07350015.2019.1624293>
27. Spirtes P. (2010) Introduction to causal inference. *Journal of Machine Learning Research*, vol. 11, pp. 1643–1662.
28. Hair J.F., Hult G.T.M., Ringle C.M., Sarstedt M., Thiele K.O. (2017) Mirror, mirror on the wall: a comparative evaluation of composite-based structural equation modelling methods. *Journal of the Academy of Marketing Science*, vol. 45, no. 5, pp. 616–632. <https://doi.org/10.1007/s11747-017-0517-x>
29. Scanagatta M., Salmeron A., Stella F. (2019) A survey on Bayesian network structure learning from data. *Progress in Artificial Intelligence*, vol. 8, pp. 425–439. <https://doi.org/10.1007/s13748-019-00194-y>
30. Sucar L.E. (2021) *Probabilistic graphical models: Principles and applications*. Springer Nature. Cham, Switzerland.
31. Ekici A., Ekici S.O. (2021) Understanding and managing complexity through Bayesian network approach: The case of bribery in business transactions. *Journal of Business Research*, vol. 129, pp. 757–773. <https://doi.org/10.1016/j.jbusres.2019.10.024>
32. Marcot B.G., Penman T.D. (2019) Advances in Bayesian network modelling: Integration of modelling technologies. *Environmental Modelling & Software*, vol. 111, pp. 386–393. <https://doi.org/10.1016/j.envsoft.2018.09.016>
33. McLachlan S., Dube K., Hitman G.A., Fenton N.E., Kyrimi E. (2020) Bayesian networks in healthcare: Distribution by medical condition. *Artificial Intelligence in Medicine*, vol. 107, article ID 101912. <https://doi.org/10.1016/j.artmed.2020.101912>
34. Cai B., Huang L., Xie M. (2017) Bayesian networks in fault diagnosis. *IEEE Transactions on Industrial Informatics*, vol. 13, no. 5, pp. 2227–2240. <https://doi.org/10.1109/TII.2017.2695583>
35. Pourret O., Naïm P., Marcot B. (2008) *Bayesian Networks: A Practical Guide to Applications*. Wiley, Hoboken.
36. Bielza C., Larranaga P. (2014) Discrete Bayesian network classifiers: A survey. *ACM Computing Surveys*, vol. 47, no. 1, article ID 5. <https://doi.org/10.1145/2576868>
37. Yuan C., Lim H., Lu T.C. (2011) Most relevant explanation in Bayesian networks. *Journal of Artificial Intelligence Research*, vol. 42, pp. 309–352. <https://doi.org/10.1613/jair.3301>
38. Lacave C., Díez F.J. (2002) A review of explanation methods for Bayesian networks. *The Knowledge Engineering Review*, vol. 17, no. 2, pp. 107–127.
39. Lacave C., Luque M., Díez F. (2007) Explanation of Bayesian networks and influence diagrams in Elvira. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, vol. 37, no. 4, 952–965. <https://doi.org/10.1109/TSMCB.2007.896018>
40. Altman E.I. (1983) *Corporate Financial Distress: A Complete Guide to Predicting, Avoiding, and Dealing with Bankruptcy*. Hoboken: Wiley.
41. Chen Y.C., Wheeler T.A., Kochenderfer M.J. (2017) Learning discrete Bayesian networks from continuous data. *Journal of Artificial Intelligence Research*, vol. 59, pp. 103–132. <https://doi.org/10.1613/jair.5371>
42. Weiss Y., Freeman W.T. (2001) Correctness of belief propagation in Gaussian graphical models of arbitrary topology. *Neural Computation*, vol. 13, no. 10, pp. 2173–2200. <https://doi.org/10.1162/089976601750541769>
43. Ickstadt K., Bornkamp B., Grzegorzczak M., Wieczorek J., Sheriff M.R., Grecco H.E., Zamir E. (2010) Nonparametric Bayesian network. *Bayesian Statistics*, vol. 9, pp. 283–316.

44. Kurgan L.A., Cios K.J. (2004) CAIM discretization algorithm. *IEEE transactions on Knowledge and Data Engineering*, vol. 16, no. 2, pp. 145–153. <https://doi.org/10.1109/TKDE.2004.1269594>
45. Lustgarten J.L., Visweswaran S., Gopalakrishnan V., Cooper G.F. (2011) Application of an efficient Bayesian discretization method to biomedical data. *BMC bioinformatics*, vol. 12, no. 1, pp. 1–15.
46. Fayyad U.M., Irani K.B. (1993) Multi-Interval Discretization of Continuous-Valued Attributes for Classification Learning, In: *Proceedings of 13th International Joint Conference on Artificial Intelligence (IJCAI'93)*, pp. 1022–1027.
47. Friedman N., Goldszmidt M. (1996) Discretization of continuous attributes while learning Bayesian networks. In: *Proceedings of 13-th International Conference on Machine Learning (ICML)*, pp. 157-165.
48. Schreiber J. (2018) Pomegranate: fast and flexible probabilistic modeling in python. *Journal of Machine Learning Research*, vol. 18, no. 164, pp. 1–6.
49. Yuan C., Malone B., Wu X. (2011) Learning optimal Bayesian networks using A* search. In: *22nd International Joint Conference on Artificial Intelligence (IJCAI)*, pp. 2186–2191.
50. Chow C.K., Liu C.N. (1968) Approximating discrete probability distributions with dependence trees. *IEEE Transactions on Information Theory*, vol. 14, no. 3, pp. 462–467.
51. Elkan C. (2001) The foundations of cost-sensitive learning. In *Proceedings of International Joint Conference on Artificial Intelligence (IJCAI'01)*, pp. 973–978.

About the author

Yury A. Zelenkov

Dr. Sci. (Tech.);

Professor, Department of Business Informatics, Graduate School of Business, National Research University Higher School of Economics, 20, Myasnitskaya Street, Moscow 101000, Russia;

E-mail: yzelenkov@hse.ru

ORCID: 0000-0002-2248-1023

Информационно-логическая модель экспресс-анализа соответствия состояния предприятия, удовлетворяющего нормативам и регламентам, на основе общедоступных данных

Т.К. Богданова
E-mail: tanbog@hse.ru

Л.В. Жукова
E-mail: lvzhukova@hse.ru

Национальный исследовательский университет «Высшая школа экономики»
Адрес: Россия, 101000, г. Москва, ул. Мясницкая, д. 20

Аннотация

В последние 10 лет наблюдается взрывной рост объемов информации, размещаемых в сети интернет и цифровой экономики, формирование официальных баз данных различных государственных органов власти. Наличие большой информационной базы, открытой для исследования, способствует развитию новых методов и подходов к решению аналитических задач. Построение систем управления и поддержки принятия решений на основе использования объединенных в единое целое разрозненных открытых источников данных позволяет конечным пользователям принимать наиболее эффективные решения. Именно такой подход является основой для роста бизнеса компаний и повышения уровня зрелости управленческой деятельности на всех уровнях, альтернативы ему на данный момент нет. Такой подход, в конечном итоге, создает условия для дальнейшего роста экономики в целом. В работе предлагается информационно-логическая модель экспресс-анализа соответствия социально-экономического состояния предприятия нормативным требованиям со стороны контрольных и надзорных органов на основе открытой общедоступной информации. Выводы, сделанные на основе проведенного экспресс-анализа, служат обоснованием для принятия решения о необходимости более детального, углубленного анализа состояния отдельных предприятий.

Ключевые слова: экспресс-анализ, информационно-логическая модель, состояние предприятия, нормативные требования, контрольные и надзорные органы, открытые источники информации, общедоступные данные, структурированные и неструктурированные данные

Цитирование: Богданова Т.К., Жукова Л.В. Информационно-логическая модель экспресс-анализа соответствия состояния предприятия, удовлетворяющего нормативам и регламентам, на основе общедоступных данных // Бизнес-информатика. 2022. Т. 16. № 1. С. 42–55. DOI: [10.17323/2587-814X.2022.1.42.55](https://doi.org/10.17323/2587-814X.2022.1.42.55)

Введение

В работе предлагается информационно-логическая модель экспресс-анализа соответствия социально-экономического состояния предприятия нормативным требованиям со стороны контрольных и надзорных органов на основе общедоступной информации. Информационно-логическая модель построена на основе предложенной концепции, одной из важных особенностей которой является то, что концепция учитывает любые требования разных регуляторов, как количественных, так и качественных, предъявляемых к экономическим объектам разных типов (предприятиям, организациям, образовательным учреждениям и т. п.) [1]. Для разных типов предприятий и требований, предъявляемых к ним со стороны регулятора, необходимо на основе общедоступной информации формировать разные наборы компонент, в результате агрегирования которых с помощью разработанной таблицы поиска рассчитывается значение интегрального показателя, являющегося основой экспресс-анализа. Каждая компонента характеризует различные аспекты деятельности предприятия: экономические, социальные, финансовые, технические и т. п., и оценивается в соответствии с методами машинного обучения, математической статистики и эконометрики [2, 3].

Для проведения экспресс-анализа состояния предприятия используется как структурированная, так и неструктурированная информация. Неструктурированная информация предварительно структурируется с использованием различных методов обработки текстовой информации [4–6].

Динамика окружающей среды возрастает, стабильность внешней среды снижается, при этом требования к быстрому реагированию на кризисы растут. Количество информации, которую необходимо обработать для принятия того или иного решения, последовательно увеличивается, одновременно ужесточаются требования к качеству, безопасности и актуальности этой информации.

Одновременное использование структурированных и неструктурированных статистических данных позволяет получить более точную качественную оценку объекта исследования с учетом изменений, которые еще не отражены в официальной статистической отчетности, предоставляемой с определенной периодичностью и неизбежным запаздыванием.

Результатом проведенного экспресс-анализа является оценка соответствия социально-экономического состояния предприятия нормативным требова-

ниям со стороны регулятора. Выводы, сделанные на основе проведенного экспресс-анализа, служат обоснованием для принятия решения о необходимости более детального, углубленного анализа отдельных предприятий.

Среди научных работ последних лет, посвященных различным экономическим и математическим исследованиям, все чаще делается акцент на применение современных цифровых технологий обработки больших объемов структурированных, слабо структурированных и неструктурированных данных из открытых источников сети интернет, методов машинного обучения и искусственного интеллекта в моделях поддержки принятия решений [7–10].

Использование инновационных цифровых возможностей сбора и анализа общедоступной информации из сети интернет позволяет дополнительно анализировать характеристики качества работы различных предприятий и других объектов исследования. Подобный анализ на открытых данных можно проводить при помощи вспомогательного независимого инструментария оценки состояния объекта исследования, созданного на основе анализа больших объемов структурированных, слабо структурированных и неструктурированных данных из открытых источников сети интернет, и сравнивать результаты с официальной методикой исследования по внутренним или официальным статистическим данным.

Контрольные меры, принятые на основе официальной статистической информации, могут поступать с большим запаздыванием, ведь между окончанием отчетного периода и передачей официальных статистических данных о состоянии объекта в органы государственной власти может проходить от 3 до 8 месяцев, что затрудняет оперативное реагирование в форс-мажорных ситуациях.

В научных исследованиях многими авторами предлагаются различные экономико-математические модели, базирующиеся на официальной статистической информации [11]. Большинство из них представляют собой эконометрические модели или модели, использующие методы машинного обучения. Как правило, имеющиеся статистические данные разбиваются на группы (демографические, социальные, финансовые и т.д.), ранжируются, или каким-то образом объединяются в единый интегральный показатель, а факторам присваиваются веса. Зачастую результатом подобного исследования становится интегральный показатель (коэффициент), который удобен при сопоставлении объектов.

Подобные инструменты в значительной степени опираются на внутренние данные или на имеющуюся статистическую базу [12].

Использование результатов анализа структурированных и неструктурированных данных из открытых источников сети интернет является наиболее полным и разносторонним способом для полноценного всестороннего анализа состояния экономического объекта исследования. Это позволяет получать объективную информацию о текущей ситуации, не подвергнутую промежуточной обработке и полученную на основании анализа большого количества разнообразных актуальных данных, которые хранятся в открытом доступе в любых источниках сети интернет. При необходимости результаты анализа внешних данных могут быть соотнесены с результатами аналогичной аналитической деятельности, проведенной на основе использования внутренних данных. Также результаты анализа по открытым общедоступным источникам могут дополнять официальные или внутренние данные в некоторых аспектах деятельности объекта исследования.

Преимущество использования открытых данных – это возможность получать информацию с любой периодичностью (не привязываясь к регулярности обновления, официально публикуемой статистической отчетности), расширять и проверять соответствие фактического социально-экономического состояния объекта исследования официальным данным.

1. Классификация источников общедоступной информации

Вся общедоступная информация может быть представлена в виде данных различного типа. В настоящее время все существующие данные можно разделить на:

- 1) структурированные;
- 2) слабоструктурированные;
- 3) квазиструктурированные;
- 4) неструктурированные.

К структурированным данным относятся данные, которые упорядочены определенным способом, имеют заданную структуру, и описывают конкретную предметную область. В совокупности это позволяет проводить достоверный и глубокий анализ этих данных. Чаще всего такая информация представлена в виде таблиц.

К слабоструктурированным данным можно отнести те данные, которые не соответствуют четкой структуре таблиц и отношений в БД, но при этом со-

держат в себе специальные разграничители (теги), которые позволяют семантически разделять весь объем данных. В качестве примера можно привести XML-документы.

К квазиструктурированным данным относятся данные с неустойчивым форматом, требующие для своей обработки специальными инструментами больших временных затрат. Примером таких данных может служить страница сайта.

К неструктурированным данным можно отнести данные, которые не имеют определенной формы и не являются строго зафиксированными. В настоящий момент такой формат данных является преобладающим в связи с развитием информатизации населения, примерно 80% всей имеющейся на данный момент информации, являются неструктурированной. Примером таких данных являются изображения, видео, аудио и текстовая информация из социальных сетей.

Данные в зависимости от их типа требуют своих методов предобработки и обработки. Большинство методов математической статистики и эконометрики основаны на анализе структурированной информации. Методы машинного обучения, нейронные сети позволяют анализировать слабоструктурированные, квазиструктурированные и неструктурированные данные, выделяя в них закономерности. Также при проведении различных процедур предобработки эти данные могут быть сведены к структурированным и включены в классические математические модели.

Если неструктурированные данные представлены текстом, то предварительная их обработка с помощью методов векторизации и классификации позволяет привести их к структурированному виду.

Информация для формирования базы исследования для проведения экспресс-анализа может быть получена из различных источников, отличающихся статусом, частотой обновления и степенью достоверности предоставляемой информации. В *таблице 1* представлена классификация источников общедоступной информации с учетом степени надежности источника.

Предложенная в данной статье информационно-логическая модель построения интегрального показателя для экспресс-анализа соответствия социально-экономического состояния предприятия нормативным требованиям со стороны контрольных и надзорных органов, базируется на концептуальной модели экспресс-анализа изложенной в [1]. Отличи-

Таблица 1.

Классификация источников общедоступной информации

Источник информации	Характеристика источника информации	Пример источника информации	Тип информации	Обновление данных на источнике
Официальные генераторы и агрегаторы данных	Сайты федерального и региональных органов статистики, сайты министерств и ведомств, публикующие по положению о раскрытии информации тематические данные, достоверность которых подтверждается соответствующим органом государственной власти.	rosstat.gov.ru zakupki.gov.ru fssp.gov.ru cbr.ru wciom.ru	Структурированные данные.	Как правило, периодичность обновления 1 раз в квартал, или реже.
Сайты и страницы в соц. сетях объектов исследования	Сайты предприятий, организаций всех форм собственности, сайты площадок, на которых они обязаны размещать информацию о своей деятельности. Достоверность информации, как правило, подтверждается только самим объектом исследования.	technomoscow.ru unicof.ru tinkoff.ru 57.mskobr.ru	Все типы данных.	Постоянное обновление.
Неофициальные генераторы данных	Сайты организаций, занимающихся деятельностью, связанной с объектами исследования и публикующие данные о них в открытых источниках. Достоверность обеспечивается внутренним мониторингом и контролем информации.	cian.ru hse.ru/rfms	Преимущественно структурированные данные.	Согласно утвержденной методике обновление может проводиться как с заданной периодичностью, так и на постоянной основе.
Неофициальные агрегаторы данных	Российские и международные агрегаторы данных, обычно предоставляющие их для проведения научных и иных исследований. Достоверность обеспечивается внутренним мониторингом.	bankodrom.ru banki.ru avtostat.ru data.worldbank.org	Преимущественно структурированные данные.	Обычно обновление проводится с периодичностью, соответствующей периодичности обновления официальных данных.
Неофициальные интернет-источники экспертных исследований	Российские и международные сайты экспертных организаций, рейтинговых агентств, персональные страницы признанных экспертов. Достоверность данных обеспечивается репутацией эксперта.	raexpert.ru ra-national.ru	Все типы данных.	Обновление проводится согласно внутренним правилам источника информации.
Неофициальные общедоступные интернет-источники	Страницы в социальных сетях, блоги, комментарии под контентом, страницы неофициальных сообществ. Достоверность данных, как правило, не подлежит проверке.	moneyzz.ru pedsovet.su	Преимущественно неструктурированные или абструктурированные данные.	Постоянное обновление.

тельной особенностью предложенной концептуальной модели является то, что в качестве отправной точки авторами предлагается учитывать требования контролирующих органов, в то время как в большинстве российских и зарубежных исследований оценка состояния объекта исследования осуществляется исходя из требований, предъявляемых к объекту его владельцами или инвесторами. Еще одно преимущество концептуальной модели – это использование общедоступных данных, то есть возможность получать информацию в любой момент времени, не привязываясь к периодам обновления официально

публикуемой статистической отчетности, и возможность проверять соответствие фактического состояния объекта исследования официальным данным. Предлагаемая информационно-логическая модель представляет собой объединение алгоритма расчета отдельных компонент интегрального показателя с применением математических, эконометрических и статистических методов, характеристик входной и выходной информации на каждом этапе, и, собственно, алгоритма расчета значений интегрального показателя с помощью логической функции на основе таблицы поиска.

2. Компоненты интегрального показателя и методы их оценки

Интегральный показатель представляет собой гибкий инструментарий экспресс-анализа на основе общедоступных структурированных и неструктурированных данных. Алгоритм построения интегрального показателя основан на агрегировании отдельных значений каждой компоненты из набора с применением таблицы поиска. Каждая компонента оценивается с использованием математических, эконометрических и статистических методов, таких как: логистическая регрессионная модель, методы кластеризации и группировки, методы тематического моделирования и т.д.

Гибкий инструментарий экспресс-анализа для принятия управленческих решений, разработанный на основе концептуальной модели, представляет собой последовательность из пяти этапов, начиная от требований со стороны контрольных и надзорных органов, разработки и оценки набора компонент, характеризующих объект исследования, их агрегирование в единый интегральный показатель на основе таблицы поиска, и заканчивая мониторингом и ранжированием объектов исследования по результатам расчетов [1].

В зависимости от типа объекта исследования (промышленное предприятие, банковская организация, образовательное учреждение и т.п.), исходя из требований различных регуляторов, формируется перечень источников данных для проведения экспресс-анализа: сайты объектов исследования, новостные источники, электронные площадки или агрегаторы информации, сайты государственных органов власти и т.д. На основе информации из этих источников создается база данных исследования. Гибкость предлагаемого в статье инструментария обусловлена тем, что перечень необходимых для проведения экспресс-анализа компонент может быть дополнен в зависимости от типа объекта исследования, от предъявляемых к объекту исследования часто меняющихся требований со стороны контрольных и надзорных органов и роста числа источников общедоступной информации.

В *таблице 2* приведен перечень выделяемых авторами возможных компонент, относящихся к четырем блокам типов входной информации для расчета компонент, типов переменных рассчитанного значения каждой компоненты (в соответствии с метриками, предложенными Робертом С. Капланом и Дэйвидом П. Нортоном), и методов оценки значений компонент [13].

Для оценивания компонент интегрального показателя на основе информации об объектах исследования из базы данных применяются различные методы оценивания.

2.1. Компонента 1. Вероятность финансового неблагополучия

Представляет собой вероятность наступления неблагоприятного финансового состояния объекта исследования (банкротство, отзыв лицензии по финансовым причинам). Для оценивания этой вероятности применяется регрессионная логистическая модель на основе данных финансовой отчетности, а также показателей их волатильности: стандартного отклонения и дисперсии, данных макроэкономических переменных, данных о государственных закупках в качестве поставщика или покупателя. В общем виде логистическая регрессионная модель принимает вид [1]:

$$P(Y = 1 | x, m, v) = \frac{1}{1 + e^{-z}},$$

$$z = \beta_0 + \sum \beta_i x_i + \sum \gamma_j m_j + \sum \varphi_k v_k, \text{ где:}$$

$P(Y = 1 | x, m, v)$ – условная вероятность неблагоприятного финансового состояния объекта исследования;

β_0 – константа;

x_i – переменные, характеризующие финансовое состояние объекта исследования;

m_j – переменные, характеризующие внешнюю по отношению к объекту исследования среду (макроэкономические факторы);

v_k – неколичественные показатели деятельности объекта исследования;

$\beta_i, \gamma_j, \varphi_k$ – коэффициенты регрессии, которые должны быть оценены.

2.2. Компоненты 2 и 3. Статус объекта исследования по масштабу и принадлежности к аномальной группе

Представляет собой результаты кластеризации по определению принадлежности объекта исследования к одному из классов. Эти компоненты позволяют учесть особенности всех объектов исследования данного типа по признакам местоположения, масштаба, вида деятельности и т.п. При этом учитывается специфика полученного кластера объектов,

Таблица 2.

Компоненты интегрального показателя и методы их оценки

№	Компоненты	Тип исходной информации	Тип переменной рассчитанного значения компоненты	Метод оценки
Характеристика финансового состояния объекта исследования				
1	Вероятность финансового неблагополучия	структурированная	категориальная, порядковая	логистическая регрессионная модель
Статусная идентичность объекта исследования				
2	Статус объекта исследования по масштабу	структурированная	категориальная	кластерный анализ
3	Статус объекта исследования по принадлежности к аномальной группе	структурированная	категориальная	кластерный анализ
Характеристика внешней информационной среды				
4	Медийная активность относительно объекта исследования	слабоструктурированные, квазиструктурированные и неструктурированные данные	количественная	семантический анализ
5	Положительная тональность упоминаний об объекте исследования в интернет-источниках		количественная	семантический анализ
6	Негативная тональность упоминаний об объекте исследования в интернет-источниках		количественная	семантический анализ
Нормативные требования к состоянию объекта исследования				
7	Соответствие требованиям государственных органов	структурированная	бинарная или категориальная	статистический и индексный анализ

что позволяет более объективно оценить состояние предприятия относительно объектов из его класса.

Алгоритмы кластеризации подразделяются на два типа:

1. Иерархические методы.
2. Неиерархические методы.

Методы иерархической кластеризации бывают двух видов [14, 15]:

1. Агломеративные (объединяющие).

В этой категории методов происходит объединение исходных объектов и уменьшение количества кластеров [16]. Такой подход осуществляется «снизу-вверх»: создание небольших кластеров и объединение их в более крупные.

2. Дивизивные (разъединяющие).

Для алгоритмов дивизивного вида характерно начальное условие наличия одного кластера. Этот изначальный кластер делится на более мелкие кластеры.

Разъединяющие алгоритмы работают «сверху-вниз».

Недостатком этих методов является вычислительная сложность на данных большой размерности. Для иерархических методов кластеризации характерной особенностью является то, что наблюдения, попавшие однажды в кластер, при дальнейшем объединении (разъединении) объектов не могут переместиться в другой кластер, в отличие от неиерархических методов.

Основная отличительная идея неиерархических методов кластеризации – определение центра кластера и группировка всех объектов, находящихся на расстоянии от центра кластера в пределах заданного порогового значения [14, 15]. К группе методов неиерархической кластеризации относятся алгоритмы семейства k -means (k -среднее) [16].

Для данных большой размерности с неизвестным числом кластеров предлагается метод BIRCH (двухшаговая или двухступенчатая кластеризация), основанный на методе k -means. Двухступенчатая класте-

ризация не требует задания количества кластеров, так как на первом шаге определяется оптимальное количество кластеров, а затем уже происходит разбиение на однородные группы. Данный метод позволяет анализировать большие объемы как количественных, так и качественных данных, хорошо работает при небольших объемах памяти.

Качество полученной кластеризации может быть оценено с помощью силуэтной меры Sil [17]:

$$Sil = \frac{1}{N} \sum_{c_k \in C} \sum_{x_i \in c_k} \frac{b(x_i, c_k) - a(x_i, c_k)}{\max(a(x_i, c_k), b(x_i, c_k))},$$

где:

Sil – общее значение силуэтной меры кластеризации всех данных;

N – общее количество объектов в выборке;

C – множество всех кластеров;

c_k – k -ый кластер на множестве C ;

x_i – i -ый объект, $i \in [1, N]$;

$$a(x_i, c_k) = \frac{1}{|c_k|} \sum_{x_j \in c_k} \|x_i - x_j\| -$$

среднее расстояние от объекта $x_i \in c_k$ до других объектов x_j из этого кластера c_k (компактность);

$|c_k|$ – количество объектов в кластере c_k ;

$$b(x_i, c_k) = \min_{c_l \in C, c_l \neq c_k} \left\{ \frac{1}{|c_l|} \sum_{x_j \in c_l} \|x_i - x_j\| \right\} -$$

среднее расстояние от объекта $x_i \in c_k$ до объектов x_j из другого кластера c_l ; $k \neq l$, $l \in [1, C]$.

Силуэтная мера Sil принимает значения на отрезке от -1 до $+1$, при этом:

1 – все наблюдения расположены точно в центрах их кластеров;

-1 – все наблюдения расположены в центрах некоторых других кластеров;

0 – наблюдения расположены в среднем на равных расстояниях от центра их кластера и центра ближайшего кластера.

2.3. Компоненты 4, 5 и 6.

Медийная активность относительно объекта исследования, положительная и негативная тональность упоминаний об объекте исследования в интернет-источниках

Оценка этих компонент представляет собой анализ неструктурированных или слабоструктурированных данных, преимущественно текстовых. Для проведения семантического анализа по оценке зна-

чений компонент, характеризующих медийную активность и тональность упоминаний относительно объекта исследования, требуется предварительная предобработка этих данных, техническая и лингвистическая очистка данных, составление словаря употребляемых слов в текстах.

Тональность – это эмоциональное отношение автора к некоторому объекту, выраженное в тексте [18, 19]. Один из способов определения тональности – поиск эмоциональной составляющей в тексте по ранее сформированным тональным словарям с применением анализа лингвистики. Применение готовых словарей к очищенным текстовым данным позволяет классифицировать текстовые единицы (предложения, слова) на три категории: амбивалентное, положительное и отрицательное. Для семантического анализа медийной активности, категоризации текста и применения методов машинного обучения требуется векторизация текста.

Векторизация – это процесс конвертации текстовых документов в числовой вектор. Выбор метода векторизации, как правило, зависит от конкретного случая, условий, имеющихся аппаратных и технологических средств. Постоянное появление новых методов и алгоритмов, улучшающих качество векторизации и скорость обработки, позволяет внедрять процесс обработки естественного языка в модель.

В настоящий момент наиболее популярен реализованный во многих статистических пакетах алгоритм Bag-of-Words («мешок слов»). «Мешок слов» представляет собой векторное представление упорядоченного набора слов в вектор размерности n [20–23]. Схематично алгоритм может быть представлен следующим образом.

Весь текст можно представить как набор обработанных слов, то есть отдельных термов (t_j), которые с помощью данного алгоритма переводятся в числовые данные из пространства R^n .

$$B : \text{words} \rightarrow R^n,$$

$$B(\text{'some text in the Internet'}) = (w_{i,1}, w_{i,2}, \dots, w_{i,n}),$$

где:

t_j – терм j ;

w_{ij} – вес терма j в документе; вес документов нормируют так, чтобы $0 < w_{ij} < 1$, для $\forall i$;

n – количество термов в пространстве.

Документ в таком случае задаётся следующим образом:

$$d = (w_1, w_2, \dots, w_{|V|}),$$

где:

d – вектор документа;

$|V|$ – количество уникальных термов в документе.

Вес термина можно задать несколькими вариантами:

1. Бинарным образом:

$$w_i = \begin{cases} 1, & t_i \in d \\ 0, & t_i \notin d \end{cases}$$

2. По количеству вхождений термина:

$$w_i = n_i,$$

где n_i – количество вхождений термина в документ.

3. Частота термина (Term Frequency, TF):

$$w_i = tf(t_i, d) = \frac{n_i}{\sum_{k=1}^{|V|} n_k},$$

где:

tf – частота термина;

n_i – количество вхождений термина в документ;

$\sum_{k=1}^{|V|} n_k$ – количество термов в документе.

4. Частота термина – обратная частота документа (Term Frequency – Inverse Document Frequency, TF-IDF).

Представление в виде двух параметров: $w_{ij} = tf_i \cdot idf_j$, где tf_{ij} – это отношение числа термов t_i в документе d_j к общему числу термов в этом документе, а idf_j – число, обратное количеству документов, в котором встречается терм t_i . Таким образом, чем чаще слово встречается в этом документе, но реже встречается вообще во всех документах, тем больше вес этого термина в данном документе:

$$tf(t_i, d) = \frac{n_i}{\sum_{k=1}^{|V|} n_k},$$

$$idf(t, d) = \log \frac{|D|}{|d_i \supset t_i|},$$

где:

$d_i \supset t_i$ – количество документов, в которых встречается t_i ;

$|D|$ – количество документов в корпусе.

Тогда вес считается следующим образом:

$$w_i = tf - idf(t_i, d, D) = tf(t_i, d) \cdot idf(t, d).$$

После векторизации применяются алгоритмы семантического анализа текста для определения тональности, главных тем, медийной активности и т.д.

Для расчета значений компонент применяются методы статистики для обобщения информации об

объекте исследования, например, с помощью прямого подсчета встречаемости положительных и отрицательных слов определяется общая тональность текста.

2.4. Компонента 7.

Соответствие требованиям государственных органов

Эта компонента определяется как бинарный или порядковый показатель, рассчитанный с помощью индексов и статистических показателей. Он представляет собой оценку количества нарушений в деятельности объекта исследования, в случае если заданы нормативные и пороговые значения со стороны контрольных или надзорных государственных органов власти.

Консолидированным представлением вышеизложенного является информационно-логическая модель экспресс-анализа соответствия социально-экономического состояния объекта исследования требованиям контрольных и надзорных органов (рис. 1). На рис. 1 этап 3, являющийся ключевым в алгоритме расчета интегрального показателя, показан в общем виде. Детализация этапа 3 информационно-логической модели представлена на рис. 2. В рамках этого этапа производится оценивание компонент интегрального показателя и расчет значений самого интегрального показателя в зависимости от значений каждой компоненты из набора.

Для преобразования значений компонент, характеризующих медийную активность (компонента 4), тональность упоминания об объекте исследования в интернет-источниках (компоненты 5 и 6) и соответствие требованиям государственных органов (компонента 7) предлагается использовать межквартильный размах IQR по выборке размера n . Здесь:

$F_n(x)$ – выборочная функция распределения;

$IQR = Q_3 - Q_1$, где $Q_3 = 0,75$; $Q_1 = 0,25$.

Предложенная информационно-логическая модель была апробирована на базе данных группы промышленных предприятий и предприятий финансовой сферы.

Был проведен экспресс-анализ соответствия потребности в финансовой помощи для 506 промышленных предприятий, зарегистрированных в г. Москве, и целесообразности ее оказания для федеральных и региональных органов власти. Экспресс-анализ проводился на основе открытых данных за 2016, 2017 и 2018 гг. Полученные результаты соот-

Рис. 1. Информационно-логическая модель алгоритма расчета компонент интегрального показателя.

Рис 2. Детализация этапа 3 информационно-логической модели алгоритма расчета компонент интегрального показателя.

ветствовали фактическим данным на следующий год о назначении субсидий и льгот со стороны правительства г. Москвы [24].

Предложенная концептуальная модель проведения экспресс-анализа соответствия социально-экономического состояния объекта исследования заявленным требованиям со стороны контрольных и надзорных органов была апробирована для оценки социально-экономического состояния коммерческого банка. Контрольным органом в данном случае является ЦБ РФ – надзорный орган в банковской сфере. В соответствии с требованиями ЦБ РФ о надежности банка были получены значения четырех компонент интегрального показателя и рассчитано его значение для каждого банка. Прогностическая способность построенной модели была подтверждена их фактическим состоянием на март 2020 года [1].

Заключение

В статье предложена информационно-логическая модель экспресс-анализа соответствия социально-экономического состояния объекта требованиям со стороны контрольных и надзорных органов, с

использованием открытых общедоступных данных. Предложенная информационно-логическая модель базируется на концепции использования интегрального показателя для экспресс-анализа соответствия социально-экономического состояния объекта независимо от его типа требованиям, предъявляемым к нему контрольными и надзорными органами.

Дана классификация информационных источников и методов их обработки в зависимости от типа данных.

Предложен алгоритм расчета выделяемых автoрами возможных компонент, относящихся к четырем блокам типов входной информации, типов переменных рассчитанного значения каждой компоненты (в соответствии с метриками, предложенными Робертом С. Капланом и Дэйвидом П. Нортоном), и методов оценки значений компонент.

Разработанная концептуальная модель была апробирована для проведения экспресс-анализа соответствия социально-экономического состояния двух разных типов объектов предъявленным к ним требованиям со стороны надзорных органов на выборках из 506 промышленных предприятий [24] и 111 банков [1]. ■

Литература

1. Богданова Т.К., Жукова Л.В. Оценка состояния объекта управления на основе универсального комплексного индикатора с использованием структурированных и неструктурированных данных // Бизнес-информатика. 2021. Т. 15. № 2. С. 21–33. <https://doi.org/10.17323/2587-814X.2021.2.21.33>
2. Кричевский М.Л. Методы машинного обучения при выборе стратегии предприятия // Вопросы инновационной экономики. 2019. Т. 9. № 1. С. 251–266. <https://doi.org/10.18334/vinec.9.1.40093>
3. Опекунов А.Н., Кузьмина М.Г. Принципы формирования моделей прогнозирования вероятности банкротства предприятий с использованием элементов машинного обучения // Модели, системы, сети в экономике, технике, природе и обществе. 2019. № 4. С. 24–31.
4. Касевич В.Б. Элементы общей лингвистики. М.: Наука, 1977.
5. Савенков П.А. Использование методов и алгоритмов машинного обучения в системах поддержки принятия управленческих решений обучения // Вестник науки и образования. 2019. №1–2 (55). С. 23–25. <https://doi.org/10.24411/2071-6168-2019-10207>
6. Попова С.В., Ходырев И.А. Извлечение ключевых словосочетаний обучения // Научно-технический вестник информационных технологий, механики и оптики. 2012. №1 (77). С. 67–71.
7. Елисеева Е.Н. Финансовый инструментарий оценки несостоятельности промышленных предприятий обучения // Регион: системы, экономика, управление. 2019. № 3 (46). С. 132–140.
8. Медведев Д.А. Большие данные: причины появления и как их можно использовать обучения // Наука и образование сегодня. 2019. № 4 (39). С. 14–16.
9. Pang B., Lee L. Opinion mining and sentiment analysis // Foundations and Trends in Information Retrieval. 2008. Vol. 2. Nos. 1–2. P. 1–135. <https://doi.org/10.1561/1500000011>
10. Морозов А.Н. Альтернативные источники статистической информации как основа принятия политических решений обучения // Вопросы государственного и муниципального управления. 2018. № 2. С. 50–70.
11. Пузанов А.С., Трутнев Э.К., Маркварт Э., Попов Р.А., Сафарова М.Д. Стратегическое планирование и градорегулирование на муниципальном уровне. М.: Издательский дом «Дело» РАНХиГС, 2017.

12. Андреева Н.А., Угримова С.Н. К вопросу применения статистических методов интегральной оценки эффективности системы управления промышленными предприятиями обучения // Учет и статистика. 2019. № 1 (53). С. 42–49.
13. Нортон Д.П., Каплан Р.С. Сбалансированная система показателей. М: Олимп-Бизнес, 2008.
14. Чугунов В.Р., Жукова Л.В., Ковальчук И.М., Ковалева А.С. Математические методы группирования данных для принятия управленческих решений в задачах планирования обучения // Actual Problems of System and Software Engineering 2017. Proceedings of the 5th International Conference on Actual Problems of System and Software Engineering Supported by Russian Foundation for Basic Research. 2017. Project #17-07-20565. С. 333–341.
15. Баресягин А.А. Технологии анализа данных: Data Mining, Visual Mining, Text Mining, OLAP / А.А. Баресягин, М.С. Куприянов, В.В. Степаненко, И.И. Холод. 2-е изд., перераб. и доп. СПб.: БХВ-Петербург, 2007.
16. Шалымов Д.С. Алгоритмы устойчивой кластеризации на основе индексных функций и функций устойчивости обучения // Стохастическая оптимизация в информатике. 2018. Т. 4. С. 236–248.
17. Kaufman L., Rousseeuw P. Finding groups in data: An introduction to cluster analysis. Wiley-Interscience, 2005.
18. Семина Т.А. Анализ тональности текста: современные подходы и существующие проблемы // Социальные и гуманитарные науки. Отечественная и зарубежная литература. Сер. 6, Языкознание: Реферативный журнал. 2020. № 4. С. 47–64.
19. Liu B. Sentiment analysis and subjectivity. In Handbook of Natural Language Processing, Second Edition (eds. N. Indurkha, F.J. Damerau). London: Chapman and Hall/CRC, 2010.
20. Автоматическая обработка текстов на естественном языке и анализ данных: учеб. пособие / Е.И. Большакова и [др.]. М.: Изд-во НИУ ВШЭ, 2017.
21. Демидова Л.А., Степанов М.А. Подход к решению задачи выявления структурных трансформаций в группах временных рядов обучения // Cloud of science. 2019. № 2. С. 201–226.
22. Попова С.В., Ходырев И.А. Извлечение ключевых словосочетаний обучения // Научно-технический вестник информационных технологий, механики и оптики. 2012. №1 (77). С. 67–71.
23. Краснянский М.Н. Обухов А.Д., Соломатина Е.М., Воякина А.А. Сравнительный анализ методов машинного обучения для решения задачи классификации документов научно-образовательного учреждения обучения // Вестник Воронежского государственного университета. 2018. № 3. С. 173–182. <https://doi.org/10.17308/sait.2018.3/1245>
24. Жукова Л.В. Экспресс-анализ состояния промышленных предприятий Москвы с использованием универсального комплексного индикатора. М: Экономическая наука современной России. 2021. Т 4 (95). С. 89–96. [https://doi.org/10.33293/1609-1442-2021-4\(95\)-89-97](https://doi.org/10.33293/1609-1442-2021-4(95)-89-97)

Об авторах

Богданова Татьяна Кирилловна

кандидат экономических наук

доцент департамента бизнес-информатики, Высшая школа бизнеса, Национальный исследовательский университет «Высшая школа экономики», 101000, г. Москва, ул. Мясницкая, д. 20;

E-mail: tanbog@hse.ru

ORCID: 0000-0002-0018-2946

Жукова Людмила Вячеславовна

старший преподаватель департамента прикладной экономики, Факультет экономических наук, Национальный исследовательский университет «Высшая школа экономики», 101000, г. Москва, ул. Мясницкая, д. 20;

E-mail: lvzhukova@hse.ru

ORCID: 0000-0003-1647-5337

Information-logical model of express analysis of the state of the enterprise that meets the requirements of standards and regulations, based on publicly available data

Tatiana K. Bogdanova

E-mail: tanbog@hse.ru

Liudmila V. Zhukova

E-mail: lvzhukova@hse.ru

HSE University

Address: 20, Myasnitskaya Street, Moscow 101000, Russia

Abstract

The last 10 years have witnessed an explosive growth in the volume of information posted on the Internet and the digital economy, as well as the formation of official databases of various public authorities. The availability of a large information base open for research has facilitated the development of new methods and approaches to solving analytical problems. Building management and decision-making support systems based on the use of united disparate open data sources allows end users to make the most effective decisions. This is the approach that underpins business growth and managerial maturity at all levels – there is no alternative. Such an approach ultimately creates the conditions for further growth of the economy as a whole. This paper proposes the information and logical model of express analysis of compliance of socio-economic condition of the enterprise with the regulatory requirements of the control and supervisory authorities on the basis of open, publicly available information. The conclusions drawn on the basis of express analysis serve as a basis for deciding on the need for a more detailed, in-depth analysis of the state of individual enterprises.

Keywords: express analysis, information-logical model, enterprise status, regulatory requirements, control and supervisory bodies, open sources of information, publicly available data, structured and unstructured data

Citation: Bogdanova T.K., Zhukova L.V. (2022) Information-logical model of express analysis of the state of the enterprise that meets the requirements of standards and regulations, based on publicly available data. *Business Informatics*, vol. 16, no. 1, pp. 42–55. DOI: 10.17323/2587-814X.2022.1.42.55

References

1. Bogdanova T.K., Zhukova L.V. (2021) The concept for valuation the position of the control object based on a universal complex indicator using structured and unstructured data. *Business Informatics*, vol. 15, no. 2, pp. 21–33 (in Russian). <http://doi.org/10.17323/2587-814X.2021.2.21.33>
2. Krichevskiy M.L. (2019) Methods of machine learning in choosing a strategy of an enterprise. *Russian Journal of Innovation Economics*, vol. 9, no. 1, pp. 251–266 (in Russian). <https://doi.org/10.18334/vinec.9.1.40093>
3. Opekunov A.N., Kuzmina M.G. (2019) Principles of forming models for forecasting the probability of bankruptcy of enterprises using machining elements. *Models, Systems, Networks in Economics, Technology, Nature and Society*, no. 4, pp. 24–31 (in Russian).
4. Kasevich V.B. (1977) *Elements of general linguistics*. Moscow: Nauka (in Russian).
5. Savenkov P.A. (2019) Using methods and algorithms of machine learning in management decision support systems. *Bulletin of Science and Education*, nos. 1–2 (55), pp. 23–25 (in Russian). <https://doi.org/10.24411/2071-6168-2019-10207>
6. Popova S.V., Khodyrev I.A. (2012) Keyword extraction. *Scientific and Technical Bulletin of Information Technologies, Mechanics and Optics*, no. 1 (77), pp. 67–71 (in Russian).
7. Eliseeva E.N. (2019) Financial instruments for assessing the insolvency of industrial enterprises. *Region: systems, economy, management*, no. 3 (46), pp. 132–140 (in Russian).

8. Medvedev D.A. (2019) Big data: the reasons for their emergence and how they can be used. *Science and Education Today*, no. 4 (39), pp. 14–16 (in Russian).
9. Pang B., Lee L. (2008) Opinion mining and sentiment analysis. *Foundations and Trends in Information Retrieval*, vol. 2, nos. 1–2, pp. 1–135. <https://doi.org/10.1561/1500000011>
10. Morozov A.N. (2018) Alternative sources of statistical information as the basis for political decision making. *Problems of State and Municipal Management*, no. 2, pp. 50–70 (in Russian).
11. Puzanov A.S., Trutnev E.K., Markvart E., Popov R.A., Safarova M.D. (2017) *Strategic planning and urban regulation at the municipal level*. Moscow: Delo (in Russian).
12. Andreeva N.A., Ugrimova S.N. (2019) To the question of the application of statistical methods of integral estimation of effectiveness of system of management of industrial enterprises. *Accounting and Statistics*, no. 1 (53), pp. 42–49 (in Russian).
13. Norton D. P., Kaplan R.S. (2008). *Balanced scorecard*. Moscow: Olymp-Business.
14. Chugunov V.R., Zhukova L.V., Kovalchuk I.M., Kovaleva A.S. (2017) Mathematical methods of data grouping for making management decisions in planning tasks. *Actual Problems of System and Software Engineering 2017. Proceedings of the 5th International Conference on Actual Problems of System and Software Engineering Supported by Russian Foundation for Basic Research. Project #17-07-20565*, pp. 333–341 (in Russian).
15. Baresyagin A.A., Kupriyanov M.S., Stepanenko V.V., Kholod I.I. (2007) *Data analysis technologies: Data Mining, Visual Mining, Text Mining*, OLAP. 2nd edition. St. Petersburg: BXV-Petersburg (in Russian).
16. Shalymov D.S. (2008) Stable clustering algorithms based on index functions and stability functions. *Stochastic optimization in computer science*, vol. 4, pp. 236–248 (in Russian).
17. Kaufman L., Rousseeuw P. (2005) *Finding groups in data: An introduction to cluster analysis*. Wiley-Interscience.
18. Semina T.A. (2020) Sentiment analysis: modern approaches and existing problems. *Social sciences and humanities. Domestic and foreign literature. Ser. 6, Linguistics*, no. 4, pp. 47–64 (in Russian).
19. Liu B. (2010) Sentiment analysis and subjectivity. In *Handbook of Natural Language Processing, Second Edition* (eds. N. Indurkha, F.J. Damerau). London: Chapman and Hall/CRC.
20. Bolshakova E.I., Vorontsov K.V., Efremova N.E., Klyshinsky E.S., Lukashevich N.V., Sapin A.S. (2017) *Automatic text processing in natural language and data analysis. Tutorial*. Moscow: HSE (in Russian).
21. Demidova L.A., Stepanov M.A. (2019) An approach to solving problem of the structural transformations detection in the time series' groups. *Cloud of science*, no. 2. pp. 201–226 (in Russian).
22. Popova S.V., Khodyrev I.A. (2012) Extraction of keyword combinations. *Scientific and Technical Bulletin of Information Technologies, Mechanics and Optics*, no. 1 (77), pp. 67–71 (in Russian).
23. Krasnyansky M.N., Obukhov A.D., Solomatina E.M., Voyakina A.A. (2018) Comparative analysis of machine learning methods for solving the problem of classifying documents of scientific and educational institution. *Bulletin of Voronezh State University*, no. 3, pp. 173–182 (in Russian).
24. Zhukova L.V. (2021) Express-analysis of the state of industrial enterprises of Moscow using the universal comprehensive indicator. *Economic Science of Modern Russia*, vol. 4 (95), pp. 89–96 (in Russian).

About the authors

Tatiana K. Bogdanova

Cand. Sci. (Econ.);

Assistant Professor, Department of Business Informatics, Graduate School of Business, National Research University Higher School of Economics, 20, Myasnitskaya Street, Moscow 101000, Russia;

E-mail: tanbog@hse.ru

ORCID: 0000-0002-0018-2946

Liudmila V. Zhukova

Assistant Professor, Department of Applied Economics, Faculty of Economic Sciences, National Research University Higher School of Economics, 20, Myasnitskaya Street, Moscow 101000, Russia;

E-mail: lvzhukova@hse.ru

ORCID: 0000-0003-1647-5337

Цифровая трансформация музыкальных агрегаторов и дистрибьюторов на примере России

А.И. Алтынов

E-mail: aaltynov@hse.ru

Национальный исследовательский университет «Высшая школа экономики»

Адрес: Россия, 109028, г. Москва, Покровский бульвар, д. 11

Аннотация

Сегодня дистрибьюторы обеспечивают функционирование всей цепочки создания стоимости в музыкальной индустрии. Большинство авторов изучает влияние технологий, стриминга и авторского права в контексте цифровизации, в то время как роли дистрибьюторов посвящено всего несколько исследований. Исходя из этого, в статье предложена методология по анализу роли дистрибьюторов, с помощью которой выявлены операционные процессы и изменения с ними связанные в результате цифровизации, а также барьеры и мероприятия по их преодолению. С помощью ретроспективного кейс-исследования, основанного на интервью с генеральным директором, в статье анализируется опыт российской компании в области музыкальной дистрибуции Vgoma16. В статье описаны цели трансформации бизнес-модели, драйверы, предпринятые шаги и их результаты. В работе выявлено четыре особенности цифровизации для дистрибуции музыки: дистрибьюторы являются скорее технологическими компаниями, чем музыкальными; дистрибуция полагается на цифровые инструменты для управления и маркетинга; возникает больше возможностей для выхода на зарубежные рынки, но компаниям приходится создавать инновации новые для этих рынков; дистрибьюторы функционируют на пересечении правовых и технологических аспектов. Исследование основывается на теории изучения цифровой трансформации бизнес-моделей. Подобный подход может быть использован для исследования компаний в музыкальной и других креативных индустриях, проведения семинаров с представителями рынка. Работа представляет ценность для специалистов-практиков на развивающихся музыкальных рынках, например, в Бразилии, Аргентине и Мексике, благодаря обзору подходов к управлению в области цифровизации и последствий трансформации для дистрибьюторов.

Ключевые слова: цифровизация, цифровая трансформация, музыкальная дистрибуция, Россия, кейс-исследование

Цитирование: Алтынов А.И. Цифровая трансформация музыкальных агрегаторов и дистрибьюторов на примере России // Бизнес-информатика. 2022. Т. 16. № 1. С. 56–71. DOI: 10.17323/2587-814X.2022.1.56.71

Введение

Прослушивание музыки – одна из основных цифровых практик в России и мире [1, 2]. Цифровизация предполагает создание совершенно новых бизнес-моделей, полностью опирающихся на применение цифровых технологий и анализ данных для создания инновационных продуктов и услуг [3]. В музыкальной индустрии это связано с сервисами потоковой передачи музыки (далее – стриминг сервисы). В 2019 г. мировая выручка от продаж физических копий составила 4,4 млрд долл. США, а выручка от стриминга – 11,4 млрд долл. США или 50% от общей выручки отрасли [4].

У российской музыкальной индустрии оптимистичное будущее в контексте мировых тенденций. Восточные рынки, включая Россию, характеризуются высокими темпами роста, и это привлекает западные фирмы [5]. Российские стриминговые сервисы, разработанные Яндексом и ВКонтакте, успешно конкурируют с западными платформами iTunes и Spotify и занимают почти 70% национального рынка [2]. 87% российских слушателей пользуются стриминговыми сервисами, в то время как среднемировое значение показателя составляет 61% слушателей [6]. По популярности стриминга Россия обгоняет развитые страны, например, США (68%), Канаду (56%), Великобританию (56%) [7]. Российская музыкальная индустрия уникальна благодаря активности слушателей и успехам отечественных компаний, которые разрабатывают музыкальные сервисы.

Стриминговые платформы не могут сотрудничать со всеми людьми, производящими музыку по всему миру [8]. Дистрибьюторы агрегируют и представляют права большого числа артистов, обеспечивая функционирование всей цепочки создания стоимости [9]. Изучение влияния цифровизации на роль дистрибьюторов даст нам представление о том, как изменились процессы функционирования отрасли. В работе поставлен следующий исследовательский вопрос: как цифровая трансформация повлияла на бизнес-модель и роль музыкальных дистрибьюторов в цепочке создания стоимости? В статье на примере российской компании Yroma16 определены функциональные процессы, которые подверглись трансформации, возникшие барьеры и принятые решения по их преодолению. Методология основывается на ретроспективном кейс-исследовании компании Yroma16, которая

представляет права 1000 клиентов по всему миру и имеет более 25 лет опыта работы в музыкальной дистрибуции. В рамках исследования проведено интервью с генеральным директором компании. В качестве теоретической основы используется структура бизнес-модели, предложенная в работе [10] для анализа цифровизации фирм в креативных индустриях.

Главным драйвером цифровизации фирмы стали изменения во внешней среде. В России отсутствовали инструменты для управления музыкой на стриминговых платформах, а дистрибьюторам приходилось покупать дорогостоящее программное обеспечение у иностранных фирм. Ориентируясь на развитие отрасли на западных рынках, компания приступила к разработке собственной платформы для управления музыкой до официального запуска стриминговых сервисов в России. Yroma16 стала одной из первых компаний, которые начали предоставлять услуги цифровой дистрибуции российским артистам. Руководство фирмы решило выделить разработки в отдельную компанию Heaven11, которая занимается поставками цифровых инструментов для дистрибуции. Yroma16 столкнулась с консерватизмом среди партнеров, связанным с отсутствием необходимых навыков у артистов. Развивающиеся рынки стриминговых сервисов в других странах представляли собой растущий потенциал, и обе компании сосредоточились на зарубежных рынках. В настоящее время 90% клиентов Yroma16 – международные артисты и лейблы.

Исследования цифровизации музыкальных дистрибьюторов можно разделить по нескольким темам (*табл. 1*). Первая группа работ изучает влияние технологий на подходы к производству, качество продукции, формирующиеся рынки, а также практику потребления. Несколько статей посвящено появлению новых посредников, кураторов, которые в значительной степени полагаются на анализ данных [11], а также внештатных менеджеров и дизайнеров [12]. Вторая группа статей изучает влияние стриминговых сервисов на опыт потребителей, артистов и продюсеров в музыкальной индустрии. Авторы исследуют бизнес-модели и стратегический менеджмент ведущих стриминговых компаний. Третья группа статей связана с вопросами авторского права, где основные темы охватывают причины пиратства, негативное влияние пиратства на артистов, подходы к борьбе с пиратством, в т.ч. на национальном уровне. Как показывают основные

направления исследований, развитие цифровых технологий, распространение стриминговых сервисов и вопросы авторского права являются ключевыми тенденциями, которые формируют будущее музыкальной индустрии.

В научной литературе наблюдается большой пробел в анализе ролей посредников в музыкальной индустрии и их изменения в контексте цифровизации. Лишь в нескольких статьях делается попытка изучить эту тему [9, 12, 19]. Авторы стремятся выяснить, как возникают посредники, какие роли они выполняют, как развиваются бизнес-модели этих компаний в условиях цифровизации. В то же время отмечается недостаток исследований, посвященных изучению музыкальных посредников, работающих на пересечении бизнес- и технологических аспектов. Данная работа предлагает следующую гипотезу: дистрибьюторов следует рассматривать как технологические, а не музыкальные компании, чья деятельность связана с обработкой огромных объемов данных и решением юридических вопросов.

Проведенный анализ восполняет имеющийся пробел и дает представление о цифровизации фирмы *Woma16*, последствиях этого процесса для бизнес-модели фирмы и роли компании в цепочке создания стоимости. Данные последствия связаны с важностью технологий в рабочих процессах современных музыкальных дистрибьюторов; новыми возможностями для локальных дистрибьюторов в связи с цифровизацией; пересечением правовых

и технологических вопросов в работе дистрибьюторов. Результаты статьи актуальны для стран, где наблюдается стремительное развитие рынка стриминговых сервисов: Мексика, Бразилия, Аргентина [4, 7]. Рассмотренные практики представляют интерес для стран, где национальные компании стремятся конкурировать с зарубежными лидерами *Apple*, *Spotify* и другими фирмами, которые предоставляют музыкальные услуги [4, 26]. Зарубежные компании также ориентированы на Россию, но отечественные фирмы устанавливают конкуренцию на рынке, поэтому их опыт может быть полезен [4].

1. Цифровизация музыкальной индустрии

В эпоху виниловых пластинок специальные лаборатории производили пластинки, а дистрибьюторы отвечали за их продажу. После обнаружения возможности получать более высокие доходы они начали вкладывать собственные деньги в лаборатории, которые позже превратились в студии звукозаписи [12, 22]. Студии отвечали за производство музыки, а дистрибьюторы начали формировать рынок и исследовать аудиторию [14]. Это привело к созданию ответственных за репертуар отделов внутри дистрибьюторских фирм, что привлекло внимание студий [12]. Студии решили также заняться анализом спроса и аудитории, несмотря на отсутствие каналов дистрибуции, и со временем превратились в крупные лейблы, которые находили новых ар-

Таблица 1.

Ключевые темы и изучаемые аспекты, выявленные в ходе обзора литературы

Темы	Изучаемые аспекты	Примеры статей
Влияние технологий	Влияние цифровых технологий на производство музыки, продвижение, дистрибуцию, потребительские практики, структуру отрасли и бизнес-модели артистов и лейблов	[11, 13–15]
Влияние стриминг-сервисов	Влияние стриминговых сервисов на расходы на музыку у населения, поведение слушателей, цепочки создания стоимости в отрасли, бизнес- и производственные практики	[8, 16–18]
Посредники	Появление музыкальных агрегаторов Роли посредников в контексте цифровизации	[9, 12, 19]
Бизнес-аспекты технологий	Бизнес-модели стриминговых сервисов, платформ, ориентированных на продюсеров Партнерства между артистами и платформами	[20–22]
Вопросы авторского права	Феномен пиратства Политика в области авторских прав и их регулирование на национальном уровне Подходы фирм к борьбе с пиратством	[23–25]

тистов и создавали записи [22]. Дистрибьюторы, в свою очередь, занимались тиражированием копий [12]. Так, образовалась цепочка создания стоимости для продажи музыки на физических носителях (см. рис. 1). Подобная цепочка просуществовала до тех пор, пока в начале 2010-х годов не началась эра цифровизации [22].

Цифровые инструменты (ноутбуки и программное обеспечение, готовые музыкальные отрывки, электронные инструменты) трансформировали производство музыки и удешевили его для независимых музыкантов [11, 14, 20]. Создание музыки не требует больших инвестиций, и лейблы переориентировались на предоставление маркетинговых услуг для перспективных артистов, где продуктом является маркетинговая единица (контент + маркетинговая стратегия) [7, 22]. При этом музыканты могут сами выполнять управленческие функции и развиваться в профессиональных артистов без продюсеров и лейблов [12, 20].

Сегодня артисты получают доход не от продаж, а при помощи лицензирования и передачи прав на дистрибуцию стриминговым сервисам [14, 18]. Посредники необходимы, потому что отношения

между стримингом и артистами характеризуются асимметрией информации, где одна сторона обладает переговорной силой [8, 17]. Стриминговые сервисы могут захватить большую долю рынка, оказывая давление на партнеров [9, 16]. Найм одного дистрибьютора позволяет многим артистам сократить операционные издержки за счет ширины музыкального каталога и прав, которые определяют переговорную силу [8]. Стриминговые сервисы также заинтересованы в дистрибьюторах, так как им необходимо заключать контракты с миллионами владельцев авторских прав (рекорд-лейблы или отдельные исполнители) во всем мире [8, 9, 17]. В настоящее время дистрибьюторы находятся в центре цепочки создания стоимости, обеспечивая ее функционирование (см. рис. 2).

У дистрибьюторов больше механизмов влияния на рынок. В то время как лейблы концентрируются на перспективных артистах, приносящих прибыль, дистрибьюторы стараются обслужить наибольшее число артистов, чтобы максимизировать доход [14]. Благодаря ширине каталога дистрибьюторы получают больше рыночной власти с точки зрения коммуникации со стриминговыми сервисами. Так, дистрибьюторы – единственная “музыкальная” сторона, которая может ограничить влияние технологических компаний, например, предоставляя эксклюзивный контент.

2. Методы

В данной работе используется в качестве метода исследования используется кейс-исследование по нескольким причинам. Во-первых, кейс-исследование представляет собой интенсивное изучение одной единицы с целью понимания более широкого класса аналогичных единиц [27]. Сосредоточение внимания на одном объекте повышает однородность при проектировании кейса, что позволяет сделать обоснованные выводы [28, 29]. Подбор кейса для исследования основан на выборе типичного кейса, как наиболее репрезентативного [30]. Выбор компании Broma16 основан на двух критериях: опыт работы компании в музыкальной индустрии и использование цифровых технологий. Фирма основана более десяти лет назад, а ее сотрудники имеют более чем 25-летний опыт работы в музыкальной индустрии [31]. Broma16 официально аффилирована с фирмой Heaven11, которая предоставляет инновационные цифровые решения для музыкальных компаний [32]. Кейс ограничивается

Рис. 1. Цепочка создания стоимости в музыкальной индустрии до цифровизации [9, 12].

Рис. 2. Цепочка создания стоимости в музыкальной индустрии после цифровизации [9, 12].

десятилетним периодом с момента официального запуска iTunes в России в 2012 г.

В работе применяется теоретическая структура бизнес-модели для конструирования рамок кейс-исследования [33]. Теоретическая база обеспечивает основу для формулирования вопросов и определения проблем [29]. В исследовании используется структура бизнес-модели, разработанная в [10] для анализа цифровизации на корпоративном уровне в креативных индустриях. Данная структура выбрана благодаря нескольким преимуществам. Во-первых, она разработана на основе анализа более 70 определений и концепций бизнес-модели, сформированных в научной литературе. Таким образом, она представляет собой синтез предыдущих исследований. Во-вторых, модель протестирована и доработана на 80 конкретных примерах, а также рассмотрена в ходе трех семинаров с представителями компаний в креативных индустриях (см. рис. 3). Бизнес-модель охватывает все ключевые аспекты, иллюстрируя, как фирма ведет бизнес и будет рабо-

тать в будущем, и считается идеальным типом для планирования инноваций [34, 35].

Данное исследование фокусируется на фундаментальном слое, так как он отражает основные процессы, подверженные трансформации. Данный слой также называют функциональной архитектурой, поскольку он отражает основные виды деятельности фирмы [10]. Исследование сфокусировано на трех основных аспектах бизнес-модели: инновации и коммерциализация продукта, инфраструктура для производства и дистрибуции, управление взаимоотношениями с клиентами. Кейс-анализ позволит отразить изменения в этих аспектах, произошедшие в следствие цифровизации.

Сбор данных основан на интервью, что позволило получить глубокие знания о феномене и выявить наиболее значимые проблемы [29]. Все интернет-материалы о компании использованы для формулировки бэкграунда интервью (Приложение 1). Предложенный набор вопросов для проведения интервью не имеет жесткой структуры (Приложение 2). Для получения релевантных данных необходимо провести интервью с топ-менеджерами, проработавшими в компании достаточное количество времени, так как кейс является ретроспективным. У всех сотрудников есть соглашение о неразглашении информации (NDA), которое подразумевает все данные об использовании технологий. Преодоление данного барьера возможно при помощи проведения интервью с генеральным директором фирмы. В течение последних десяти лет он принимал ключевые решения по цифровизации компании.

Интервью с генеральным директором позволило определить драйверы для цифровизации и развития архитектуры предприятия. Основываясь на интервью, мотивация может быть рассмотрена в контексте Модели бизнес-мотивации (Business Motivation Model), разработанной организацией Object Management Group (OMG). Эта структура охватывает цели компании, объясняет, как фирма намерена их достичь, рассматривает возможности и угрозы для бизнеса, его сильные и слабые стороны. Модель уделяет внимание внешней среде, охватывая драйверы развития [36]. Исследование информации, собранной в рамках интервью, основано на описательном анализе. Поскольку проведено одно интервью, применение кодирования сопряжено с риском упустить важные детали.

Рис. 3. Структура бизнес-модели [10].

3. Описание кейса

Broma16 – дистрибьюторская компания, основанная в 2010 г. в Москве. Фирма представляет права 1000 клиентов, лейблов, артистов и других дистрибьюторских компаний, а также более миллиона музыкальных записей. Деятельность компании можно разделить на две группы (см. рис. 4). Первая группа – услуги для продюсеров по лицензированию репертуара, управлению авторскими правами, сбору роялти. Компания также помогает с маркетингом релизов, предоставляя гибкие контракты с различными пакетами услуг. Вторая группа связана

с услугами по доставке лицензий от имени издатель продюсерским студиям, создающим музыкальные продукты (подкасты, рекламу и т.д.), физические продукты (компакт-диски и т.д.), фоновые музыкальные сервисы для общественных мест [31].

Компания разработала технологический подход к предоставлению услуг на основе цифровой платформы для управления репертуаром и лицензирования. Платформа предоставляет информацию о каждой сделке, независимо от географии, в формате детализированного отчета, чтобы обеспечить прозрачность авторских прав и распределения ро-

Group of services	Music publishing	Music licensing
Customers	<ul style="list-style-type: none"> ◆ Authors ◆ Performers ◆ Producers ◆ Labels ◆ Distributors 	<ul style="list-style-type: none"> ◆ Production studios ◆ Theaters ◆ Telecom operators ◆ Radios ◆ Film, game and companies
Services	<ul style="list-style-type: none"> ◆ Administration of copyrights, including adjacent rights ◆ Collection of royalties from streaming services, YouTube (cover versions or user-generated content) ◆ Tracking of plays at online and terrestrial radios, TV, in public places ◆ Handling of release details (artworks, title, additional information) ◆ Consulting and marketing services (pitching to playlists and TV, movie, games, ads production collectives) 	<ul style="list-style-type: none"> ◆ Delivering licenses for streaming services, podcasts, online, NV and radio advertising, online and live performances, karaoke services, mass media products ◆ Delivering licenses for retail audio products (CDs and vinyls); audio products for promotion; audio-visual products (DVD, Blu-Ray); digital memory devices; background music services ◆ Delivering licenses to play music in public places

Рис. 4. Ключевые услуги, предоставляемые Broma16 [31].

ялти. Архитектура платформы позволяет управлять репертуаром и потоками доходов в нескольких странах независимо от типа прав. Платформа является ядром бизнес-модели, обеспечивая работу всех сервисов, но так было не всегда.

Первоначально фирма была основана для продюсирования репертуара артистов и предоставления маркетинговых услуг. Изменения в стимулах компании иллюстрирует следующее заявление генерального директора: «... переориентация рынка с альбомов на синглы была очевидна более десяти лет назад, и первоначальная цель компании заключалась в продвижении синглов. Но переход к лицензионной модели дистрибуции, начавшийся в 2012 г., требовал от продюсеров загружать музыку и собирать роялти, где проблема заключалась в документировании музыки».

Broma16 стала одной из первых компаний в России, которая предоставила данные услуги артистам. Российские дистрибьюторы вынуждены были покупать дорогое программное обеспечение у иностранных компаний. Broma16 начала собственную разработку цифровой платформы в 2010–2011 гг. С 2012 г. разработка ведется в рамках дочерней компании Heaven11 (см. рис. 5), которая предоставляет общую базу данных и платформу для управления музыкой. В настоящее время работа всех сервисов Broma16 обеспечивается платформой.

Heaven11 предлагает продукты различным участникам цепочки поставок, которые создают, лицензируют или используют музыку в коммерческих целях [32]. Основным продуктом является мульти-территориальная база данных, объединяющая различные виды прав на музыкальные произведения, мастер-записи, релизы, аудиовизуальные продукты и тексты песен. Ключевые технические компоненты системы включают базу данных музыкальных произведений,

дополненную инструментами для импорта/экспорта данных в различных форматах, дедупликации и очистки, автоматизации обработки отчетов цифровых поставщиков услуг, идентификации прослушиваний. Это позволяет отправлять релизы на платформы, отслеживать отправленные материалы и управлять репертуаром, автоматически распределять роялти среди всех правообладателей, готовить отчеты и документацию. Ключевыми клиентами компании являются издатели и лейблы, стриминговые сервисы.

4. Выводы

Цифровые технологии сильно изменяют бизнес-модели компаний в креативных индустриях, и Broma16 также является примером [34]. Фирма создавалась для продвижения синглов, но процессы создания ценности и взаимодействия с клиентами трансформировались после внедрения платформы для управления музыкой. Эти изменения сильно повлияли на бизнес-модель компании. Фирма передвинулась вдоль цепочки создания стоимости от продвижения к дистрибуции.

Для анализа изменений в бизнес-модели рассматривается слой функциональной архитектуры в рамках структуры бизнес-модели, представленной в работе [10] (рис. 3). Изменения затронули все три компонента слоя. Broma16 создавалась для продвижения синглов, но в связи с распространением стриминговых сервисов высшее руководство решило сосредоточиться на дистрибуции. Таким образом, ключевая услуга полностью изменилась. В настоящее время компания располагается после маркетинговых услуг в цепочке создания стоимости (рис. 2). Вместо маркетинга Broma16 занимается музыкальной документацией, лицензированием и распределением роялти.

Рис. 5. Хронология с ключевыми событиями в ходе цифровизации компании.

Лицензии стали ключевым продуктом в музыкальной индустрии, поскольку они определяют суммы средств, переходящих от фанатов к артистам и лейблам через стриминговые сервисы и дистрибьюторов. Работая напрямую с лицензиями, дистрибьюторы получают более высокие доходы и большую рыночную власть. Чтобы установить этот контроль, дистрибьюторы должны обслуживать максимальное число клиентов, и цифровые технологии позволяют достичь этой цели.

Платформа для управления музыкой позволила Broma16 выйти на российский рынок музыкальной дистрибуции в числе первых. Инфраструктурная составляющая становится ключевой в бизнес-модели в связи с цифровизацией [10]. Все отношения с клиентами были автоматизированы через платформу. Группа потенциальных клиентов расширилась от исполнителей, выпускающих синглы, до всех заинтересованных сторон, желающих продать или купить музыкальные лицензии (рис. 4). Сегодня Broma16 представляет права более чем 1000 клиентов, артистов и лейблов.

Модель бизнес-мотивации (OMG Business Motivation Model) применяется для понимания преобразований бизнес-модели Broma16. При создании компании мотивацией генерального директора являлось продвижение синглов из-за их растущей популярности на рынке. Объявление о запуске iTunes вызвало изменения в целях фирмы. У российских артистов и лейблов не было инструмента для загрузки музыки на стриминговые сервисы, отслеживания всех покупок, сбора и распределения роялти. Таким образом, цифровая трансформация практик потребления выявила пробел в российской музыкальной индустрии.

Основным драйвером можно считать появление новой рыночной ниши для цифровой дистрибуции. Понимая это, высшее руководство компании решило сместить акцент с роли промоутера на роль дистрибьютора. С 2011 г. мотивацией Broma16 является создание удобного цифрового инструмента для загрузки музыки на стриминговые платформы.

Компания столкнулась с некоторыми барьерами для развития бизнеса. Российским дистрибьюторам пришлось закупать программное обеспечение для управления музыкой у иностранных компаний. Фирмы не могли позволить себе дорогостоящие зарубежные цифровые решения. Broma16 являлась молодой компанией, что давало гибкость для стратегического развития. Топ-менеджеры имели

более 15 лет опыта работы в отрасли и предвидели движение к потреблению цифровой музыки еще до объявления о запуске iTunes. Анализируя музыкальную индустрию в западных странах, высшее руководство решило начать собственную разработку платформы для управления музыкой. Когда Apple объявила о запуске iTunes в России, разработка уже была выделена в компанию Heaven11. Успешный прогноз развития отрасли и активная разработка платформы позволили обеим фирмам оказаться в числе первых компаний на рынке: Broma16 как дистрибьютор музыки и Heaven11 как технологический провайдер для музыкальных дистрибьюторов.

Еще одним барьером для бизнеса компании стал консерватизм клиентов (артистов и лейблов). По словам генерального директора: «... технологически Broma16 могла предоставить сегодняшний набор услуг восемь лет назад, но артисты не были готовы использовать платформу для управления музыкой. Даже сегодня некоторые артисты пытаются связаться с Broma16, чтобы проверить статус доставки музыки на стриминговые сервисы, хотя они могут сделать это на платформе».

От артистов требуются навыки использования профессионального программного обеспечения, платформ, решений по управлению контентом и базами данных. Компания использовала несколько подходов к решению этой проблемы. Первый – образовательные услуги для клиентов, объясняющие, как регистрировать песни в базе данных, управлять контентом, использовать собранные данные в коммерческих целях. Второй – смещение фокуса на внешние рынки. По словам генерального директора: «в настоящее время более 90% клиентов Broma16 – международные артисты и лейблы». В начале 2010-х годов рынки стриминговых сервисов возникали во многих странах. Благодаря рыночной конъюнктуре обе компании добились успеха в международном масштабе. В настоящее время компании имеют офисы в Амстердаме (Broma16) и Дублине (Heaven11).

5. Обсуждение

Внешнее развитие отрасли стимулировало трансформацию Broma16, что характерно для креативных индустрий [34, 37]. Возможность загрузки музыки в iTunes определила необходимость в цифровом решении для сбора и распределения роялти. Спрос на новых посредников часто связан с циф-

ровизацией [35]. Развитие программного обеспечения для управления музыкой показывает растущую важность инфраструктуры [38]. Broma16 представила платформу для устранения этого разрыва. Это привело к трансформации всех компонентов в функциональном слое бизнес-модели, что следует опыту других фирм в креативных индустриях [39]. Как правило, компании чаще экспериментируют с бизнес-моделями, чтобы построить более гибкие и адаптивные модели с различными потоками доходов [35, 37, 40, 41]. В случае Broma16, экспериментов не наблюдалось. У компании мало опыта тестирования различных моделей, так как она сосредоточилась на конкретном разрыве в отрасли, но платформа позволила компании дифференцировать наборы услуг, где гибкость дает возможность привлечь новых клиентов [37, 40].

Исследование выявило несколько барьеров для трансформации бизнес-модели. Российским дистрибьюторам приходилось покупать дорогостоящее программное обеспечение у иностранных фирм. Высокие затраты на ИТ часто считаются основным барьером для цифровизации [39, 41]. Прогноз перехода к цифровому потреблению музыки и своевременная внутренняя разработка платформы позволили Broma16 успешно трансформироваться, но обычно трудно предсказать время, необходимое для радикальной перестройки [34]. Внутренняя разработка не является распространенным подходом. Технологические партнерства более типичны для данного сектора [37, 42]. Собственные проекты часто сталкиваются со значительными временными и финансовыми затратами. Данный кейс иллюстрирует важные преимущества внутренней разработки, так как это позволило компании выйти на новые технологические рынки, поставляя аналогичные услуги другим фирмам. Heaven11 представила совершенно новую технологию, где отсутствие аналогичных решений и конкурентов позволило успешно выйти на рынок. Такие примеры встречаются редко. Обычно технологические компании захватывают креативные рынки и контролируют инфраструктуру для распространения, а не наоборот [38, 41].

Второй барьер, связанный с консерватизмом в цепочке создания стоимости, встречается не так часто, поскольку клиенты привыкли быстро реагировать на новые технологии [36, 42, 43]. Broma16 предоставляет образовательные услуги клиентам, но в краткосрочной перспективе они могут оказаться бесполезными из-за ранней стадии развития рын-

ка и отсутствия спроса [35]. Фирмы могут сосредоточиться на зарубежных рынках, где легче найти партнеров и запустить цифровые проекты [37, 40]. Broma16 придерживалась аналогичного подхода.

Результаты кейс-исследования в основном следуют теории. Цифровизация, обусловленная внешним развитием отрасли, стимулировала изменения в функциональном слое бизнес-модели. Broma16 изменила свой ключевой продукт и сосредоточилась на распространении музыки, а не на продвижении музыки, как планировалось вначале. Фирма столкнулась с высокими ИТ-затратами из-за необходимости закупать зарубежное программное обеспечение. Проблема преодолена за счет внутренней разработки, что не является типичным путем. Это позволило создать новую компанию Heaven11 и выйти на технологические рынки. Для решения проблемы консерватизма в цепочке создания стоимости разработаны образовательные услуги, организован выход на зарубежные рынки, что является широко распространенной практикой.

Рассматривая опыт музыкальной дистрибьюторской компании Broma16, можно сделать несколько выводов о влиянии цифровизации на бизнес-модель фирмы и роль компании в цепочке создания стоимости.

Вывод 1: Музыкальные дистрибьюторы – технологические компании, а не музыкальные компании.

Цифровые технологии стали важной инфраструктурной частью бизнес-моделей фирм в креативных индустриях [10]. Ключевая для бизнес-модели Broma16 платформа разработана фирмой Heaven11, которая поставляет продукты и для других дистрибьюторов. Таким образом, Heaven11 является основной компанией для дистрибьюторской роли, поскольку она технологически обеспечивает функционирование цепочки создания стоимости. Цифровизация является причиной растущего значения ИТ-мощностей в посреднических компаниях, где технологические фирмы могут успешно выполнять посреднические роли [22, 41]. Так, дистрибьюторов сегодня можно рассматривать как технологические компании, а не музыкальные компании. Однако инновации требуют экспертизы в выбранной области, чтобы определить правильный момент для запуска нового решения, оценить спрос и перспективы его внедрения. Цифровизация способствует появлению новых рынков, основанных на сочетании отраслевых и технологических знаний. Напри-

мер, в выбранном случае фирма создала новый посреднический «слой» компаний, предоставляющих технологические услуги дистрибьюторам.

Вывод 2: Дистрибуция музыки сегодня основывается на цифровых инструментах для управления и маркетинга.

С тех пор как музыка стала цифровой, компании вынуждены использовать цифровые инструменты для распространения и сопутствующих услуг. В Broma16 все коммуникации, методы управления и статистика перенесены на цифровую платформу. Артисты могут собирать данные по огромному количеству метрик (частота пропусков композиции, число сохранений композиции и др.) для оценки производительности [18]. Лейблы разрабатывают маркетинговые стратегии, основанные на данных [17, 20], что создает дополнительное давление на производителей [13]. Артисты должны использовать инструменты цифрового маркетинга, развивать социальные сети, анализировать данные и метрики, собранные и подсчитанные Broma16, а также развивать специфический нетворческий набор навыков. Данный тренд называется переходом от «музыканта-художника» к «музыканту-предпринимателю» [14]. Однако это актуально только для независимых музыкантов, когда крупные артисты передают эти обязанности лейблам [16]. Успешность маркетинга в данном случае зависит от объема ресурсов (времени, денег), который артист или лейбл готовы вложить.

Вывод 3: Локальные посредники получают больше возможностей для выхода на внешние рынки, но им приходится внедрять инновации, новые для этих рынков.

Цифровизация приводит к глобализации креативных индустрий, и местным компаниям легче успешно выходить на международные рынки [37, 40]. В представленном кейсе и Broma16, и Heaven11 внедрили инновации и продукты новые для зарубежных рынков, что позволило выйти на данные рынки. Платформа для управления музыкой и базой данных всех песен стала инновацией для российского рынка в 2012 г. Запуск iTunes в России произошел в конце 2012 г., а регистрация компании Heaven11 – в начале года. Предоставляя услуги цифровой дистрибуции российским артистам в числе первых компаний, Broma16 выявила растущий спрос в других странах и осуществила попытку выйти на данные рынки. Но платформа была также инновационной и для зарубежных рынков, где

только зарождались стриминговые сервисы. Локальные посредники могут получить больше возможностей для выхода на зарубежные рынки, но для их реализации необходимы инновационные решения.

Вывод 4: Музыкальные дистрибьюторы работают на комплексном пересечении правовых и технологических аспектов.

Основной проблемой для дистрибуции является документирование музыки, так как многочисленные авторы со смежными правами могут создавать песню, воспроизводимую в разных источниках как в цифровом, так и в физическом виде. Из-за отсутствия единого реестра всех песен с авторами и продажами (прослушиваниями) сложно контролировать авторские права на цифровой контент. Дистрибьюторы вынуждены искать вышеперечисленных проблем. Фирмы обязаны вести реестр всех песен со всеми правообладателями и идентифицировать все прослушивания и продажи для каждой песни. Компании должны регулярно обновлять этот реестр для тысяч песен, чтобы распределять роялти. Broma16 автоматизировала большинство этих процессов при помощи цифровой платформы для управления музыкой. В то же время дистрибьюторы должны контролировать авторские права клиентов и защищать их, платить налоги с доходов и роялти, учитывая местные налоговые системы. Часто дистрибьюторы используют цифровые технологии для решения проблем, связанных с цифровой дистрибуцией и законодательством, а не музыкой, и работают на пересечении этих аспектов.

Подводя итог, можно сказать, что гипотеза исследования подтвердилась. Дистрибьюторы предоставляют музыкантам цифровые инструменты для управления музыкой и ее продвижения, поскольку потребление музыки перешло в цифровой формат. Это позволяет рассматривать дистрибьюторов как технологические компании. В то же время дистрибьюторам приходится иметь дело с огромными объемами данных и юридическими вопросами, чтобы предоставлять клиентам качественные услуги.

Заключение

В данной статье выявляются управленческие практики для корпоративной цифровизации на примере российского музыкального дистрибьютора Broma16. Стимулируемая изменениями внешней среды, внутренняя трансформация столкнулась с

высокими затратами на зарубежные продукты и нехваткой навыков у партнеров в цепочке создания стоимости. Для преодоления этих барьеров необходима внутренняя разработка цифрового решения за счет привлечения ИТ-специалистов, переориентация на новые технологические и зарубежные рынки, предоставление образовательных услуг. В ходе исследования выделены четыре основных последствия цифровой трансформации для бизнес-модели фирмы и ее роли в цепочке создания стоимости:

- ◆ фирму нужно рассматривать как технологическую компанию, а не как музыкальную;
- ◆ распространение музыки в значительной степени зависит от цифровых инструментов для управления и маркетинга;
- ◆ локальные компании получают больше возможностей для выхода на внешние рынки, но им приходится внедрять новые для этих рынков инновации;
- ◆ музыкальные дистрибьюторы работают на комплексном пересечении технологических и законодательных вопросов.

В настоящем исследовании применяется а теоретическая структура бизнес-модели для изучения цифровизации музыкальных дистрибуторов, которая не очень распространена среди исследователей, особенно в России. Данная статья охватывает мотивацию заинтересованных сторон к трансформации бизнес-модели, важные драйверы и барьеры, сильные стороны и угрозы для бизнеса B2B16. Аналогичный подход может быть использован для сравнительного анализа цифровой трансформации на корпоративном уровне в других креативных индустриях.

Представлены практики управления цифровой трансформацией, применяемые одной из самых инновационных компаний музыкальной дистрибуции в России. Поскольку исследование проведено на основе теоретической структуры бизнес-модели, барьеры, с которыми столкнулась компания, и

действия, предпринятые для их преодоления, рассмотрены в контексте предыдущего опыта. Статья иллюстрирует изменения в мотивации и целях фирмы руководством для переориентации на новую рыночную нишу цифровых дистрибьюторов. Прогноз развития отрасли и активная внутренняя разработка цифровой платформы позволили захватить данную нишу и выйти на зарубежные рынки. Музыкальные дистрибьюторы на развивающихся рынках и фирмы в других креативных индустриях могут адаптировать некоторые из указанных практик.

Результаты исследования могут быть полезны для менеджеров по цифровизации в креативных индустриях. Сделанные выводы актуальны для рынков, где стриминговые сервисы формируются в данный момент. Так, результаты актуальны для компаний в странах Латинской Америки, например Бразилии, Аргентине, Мексике [7, 26]. Рассмотренный опыт может быть интересен азиатским странам (Южная Корея, Китай, Япония), которые стремятся развивать национальные компании и навязывать конкуренцию западным фирмам, Apple, Spotify. Эти компании ориентированы Россию, но отечественные фирмы показывают, что у них есть достаточные преимущества для конкуренции [4].

Исследование имеет несколько ограничений. Во-первых, работа основана на единичном кейсе, что не позволяет сделать выводы, охватывающие все аспекты отрасли. Исследователи могут использовать схожую теоретическую модель для проведения нескольких кейс-исследований и выявления связей и различий между компаниями, что позволит лучше понять развитие отрасли. Второе ограничение возникает из-за невозможности проведения глубинных интервью с сотрудниками компаний из-за соглашений о неразглашении. Чтобы смягчить этот барьер, дальнейшие исследования могут использовать схожую теоретическую модель для проведения семинаров с представителями отрасли и углубленного изучения изменений, вызванных цифровизацией. ■

Литература

1. Полякова В.В., Фурсов К.С. Цифровые практики россиян в период самоизоляции / Бюллетени ИСИЭЗ серии «Цифровая экономика». 2021. [Электронный ресурс]: <https://issek.hse.ru/news/438496284.html> (дата обращения 13.07.2021).
2. Обзор индустрии развлечений и медиа: прогноз на 2019–2023 годы / PwC, 2019. [Электронный ресурс]: <https://www.pwc.ru/ru/publications/media-outlook/mediaindustriya-v-2019.pdf> (дата обращения 13.07.2021).
3. A roadmap toward a common framework for measuring the digital economy. Report for the G20 digital economy task force / OECD, 2020. [Электронный ресурс]: <https://www.oecd.org/sti/roadmap-toward-a-common-framework-for-measuring-the-digital-economy.pdf> (дата обращения 07.04.2021).

4. Global music report / IFPI, 2021. [Электронный ресурс]: https://www.ifpi.org/wp-content/uploads/2020/03/GMR2021_STATE_OF_THE_INDUSTRY.pdf (дата обращения 27.07.2021).
5. The show must go on / Goldman Sachs, 2020. [Электронный ресурс]: <https://www.goldmansachs.com/insights/pages/infographics/music-in-the-air-2020/report.pdf> (дата обращения 07.04.2021).
6. Российский рынок музыкальных стриминговых услуг продолжит быстрый рост / J'Son & Partners, 2019. [Электронный ресурс]: <https://www.sostav.ru/publication/ostalnoe-vidimost-po-prognozu-j-son-and-partners-rossijskij-rynok-muzykalnykh-strimingovykh-uslug-prodolzhit-bystryj-rost-37158.html> (дата обращения 27.03.2021).
7. Music Consumer Insight Report / IFPI, 2018. [Электронный ресурс]: https://www.ifpi.org/wp-content/uploads/2020/07/091018_Music-Consumer-Insight-Report-2018.pdf (дата обращения 27.03.2021).
8. Herbert D., Lotz A.D., Marshall L. Approaching media industries comparatively: A case study of streaming // *International journal of cultural studies*. 2019. Vol. 22. No. 3. P. 349–366. <https://doi.org/10.1177/1367877918813245>
9. Galuszka P. Music aggregators and intermediation of the digital music market // *International Journal of Communication*. 2015. Vol. 9. P. 254–273.
10. Li F. The digital transformation of business models in the creative industries: A holistic framework and emerging trends // *Technovation*. 2020. Vol. 92. Article ID 102012. <https://doi.org/10.1016/j.technovation.2017.12.004>
11. Bonini T., Gandini A. “First week is editorial, second week is algorithmic”: Platform gatekeepers and the platformization of music curation // *Social Media + Society*. 2019. Vol. 5. No. 4. Article ID 2056305119880006. <https://doi.org/10.1177/2056305119880006>
12. Hracs B.J. Cultural intermediaries in the digital age: The case of independent musicians and managers in Toronto // *Regional Studies*. 2015. Vol. 49. No. 3. P. 461–475. <https://doi.org/10.1080/00343404.2012.750425>
13. Morris J.W. Curation by code: Infomediaries and the data mining of taste // *European journal of cultural studies*. 2015. Vol. 18. Nos. 4–5. P. 446–463. <https://doi.org/10.1177/1367549415577387>
14. Eiriz V., Leite F.P. The digital distribution of music and its impact on the business models of independent musicians // *The Service Industries Journal*. 2017. Vol. 37. Nos. 13–14. P. 875–895. <https://doi.org/10.1080/02642069.2017.1361935>
15. Koh B., Hann I.H., Raghunathan S. Digitization of music: Consumer adoption amidst piracy, unbundling, and rebundling // *MIS Quarterly*. 2019. Vol. 43. No. 1. P. 23–45. <https://doi.org/10.25300/MISQ/2019/14812>
16. Vonderau P. The Spotify effect: Digital distribution and financial growth // *Television & New Media*. 2019. Vol. 20. No. 1. P. 3–19. <https://doi.org/10.1177/1527476417741200>
17. Kjus Y. Musical exploration via streaming services: The Norwegian experience // *Popular Communication*. 2016. Vol. 14. No. 3. P. 127–136. <https://doi.org/10.1080/15405702.2016.1193183>
18. Morgan B.A. Revenue, access, and engagement via the in-house curated Spotify playlist in Australia // *Popular Communication*. 2020. Vol. 18. No. 1. P. 32–47. <https://doi.org/10.1080/15405702.2019.1649678>
19. Street J., Laing D., Schroff S. Regulating for creativity and cultural diversity: the case of collective management organisations and the music industry // *International Journal of Cultural Policy*. 2018. Vol. 24. No. 3. P. 368–386. <https://doi.org/10.1080/10286632.2016.1178733>
20. Hesmondhalgh D., Jones E., Rauh A. SoundCloud and Bandcamp as alternative music platforms // *Social Media + Society*. 2019. Vol. 5. No. 4. Article ID 2056305119883429. <https://doi.org/10.1177/2056305119883429>
21. Fleischer R. If the song has no price, is it still a commodity? Rethinking the commodification of digital music // *Culture Unbound*. 2017. Vol. 9. No. 2. P. 146–162. <https://doi.org/10.3384/cu.2000.1525.1792146>
22. Meier L.M., Manzerolle V.R. Rising tides? Data capture, platform accumulation, and new monopolies in the digital music economy // *New Media & Society*. 2019. Vol. 21. No. 3. P. 543–561. <https://doi.org/10.1177/1461444818800998>
23. Burmester A.B., et al. Accepting or fighting unlicensed usage: Can firms reduce unlicensed usage by optimizing their timing and pricing strategies? // *International Journal of Research in Marketing*. 2016. Vol. 33. No. 2. P. 343–356. <https://doi.org/10.1016/j.ijresmar.2015.06.005>
24. Mróz B. Online piracy: An emergent segment of the shadow economy. Empirical insight from Poland // *Journal of Financial Crime*. 2016. Vol. 23, No. 3, P. 637–654. <https://doi.org/10.1108/JFC-04-2015-0022>
25. Mazziotti G., Simonelli F. Another breach in the wall: copyright territoriality in Europe and its progressive erosion on the grounds of competition law // *Info*. 2016. Vol. 18, No. 6, P. 55–66. <https://doi.org/10.1108/info-06-2016-0026>
26. Year-End Report / MRC Data, Billboard, 2021. [Электронный ресурс]: https://www.musicbusinessworldwide.com/files/2021/01/MRC_Billboard_YEAR_END_2020_US-Final.pdf (дата обращения 27.07.2021).
27. Gerring J. What is a case study and what is it good for? // *American political science review*. 2004. Vol. 98. No. 2. P. 341–354. <https://doi.org/10.1017/S0003055404001182>
28. Huyghe A., et al. Technology transfer offices as boundary spanners in the pre-spin-off process: The case of a hybrid model // *Small Business Economics*. 2014. Vol. 43. No. 2. P. 289–307. <https://doi.org/10.1007/s11187-013-9537-1>

29. Simons H. Case study research: In-depth understanding in context // The Oxford handbook of qualitative research. 2014. P. 455–470. <https://doi.org/10.1093/oxfordhb/9780199811755.013.005>
30. Seawright J., Gerring J. Case selection techniques in case study research: A menu of qualitative and quantitative options // Political research quarterly. 2008. Vol. 61. No. 2. P. 294–308. <https://doi.org/10.1177/1065912907313077>
31. Official website / Broma16, 2021. [Электронный ресурс]: <https://broma16.com/en/> (дата обращения 07.04.2021).
32. Official website / Heaven11, 2021. [Электронный ресурс]: <https://www.heaven11.pro/#intro> (дата обращения 07.04.2021).
33. Thomas G. A typology for the case study in social science following a review of definition, discourse, and structure // Qualitative inquiry. 2011. Vol. 17. No. 6. P. 511–521. <https://doi.org/10.1177/1077800411409884>
34. Øiestad S., Bugge M.M. Digitisation of publishing: Exploration based on existing business models // Technological Forecasting and Social Change. 2014. Vol. 83. P. 54–65. <https://doi.org/10.1016/j.techfore.2013.01.010>
35. Landoni P., et al. Business model innovation in cultural and creative industries: Insights from three leading mobile gaming firms // Technovation. 2020. Vol. 92. Article ID 102084. <https://doi.org/10.1016/j.technovation.2019.102084>
36. Business Model Motivation: Version 1.3 / Object Management Group, 2015. [Электронный ресурс]: <https://www.omg.org/spec/BMM/1.3/PDF> (дата обращения 13.07.2021).
37. Towse R. Economics of music publishing: copyright and the market // Journal of Cultural Economics. 2017. Vol. 41. No. 4. P. 403–420. <https://doi.org/10.1007/s10824-016-9268-7>
38. Lee J.A. Tripartite perspective on the copyright-sharing economy in China // Computer Law & Security Review. 2019. Vol. 35. No. 4. P. 434–452. <https://doi.org/10.1016/j.clsr.2019.05.001>
39. Kim H.J., Kim B.H. Implementation of young children English education system by AR type based on P2P network service model // Peer-to-Peer Networking and Applications. 2018. Vol. 11. No. 6. P. 1252–1264. <https://doi.org/10.1007/2fs12083-017-0612-2>
40. Lyubareva I., Benghozi P.J., Fidele T. Online business models in creative industries: Diversity and structure // International studies of management & organization. 2014. Vol. 44. No. 4. P. 43–62. <https://doi.org/10.2753/IMO0020-8825440403>
41. Nakano D., Fleury A. Recorded music supply network reconfiguration: the dual effect of digital technology // International Journal of Manufacturing Technology and Management. 2017. Vol. 31. No. 1–3. P. 153–175. <https://doi.org/10.1504/IJMTM.2017.10002918>
42. Benghozi P.J., Paris T. The cultural economy in the digital age: a revolution in intermediation? // City, Culture and Society. 2016. Vol. 7. No. 2. P. 75–80. <https://doi.org/10.1016/j.ccs.2015.12.005>
43. Dobusch L., Schübler E. Copyright reform and business model innovation: Regulatory propaganda at German music industry conferences // Technological Forecasting and Social Change. 2014. Vol. 83. P. 24–39. <https://doi.org/10.1016/j.techfore.2013.01.009>

Приложение 1.

Справочные материалы для интервью

Источник	Ссылка
О компании	https://broma16.com/en/about/
Технологии в компании	https://broma16.com/en/technology/
Услуги, предоставляемые компанией	https://broma16.com/en/
Новости компании	https://broma16.com/en/news/
Партнеры компании	https://broma16.com/en/roster/artists/featured/
Аккаунты компании в социальных сетях: Facebook, ВКонтакте	https://www.facebook.com/BroMa16/ https://vk.com/broma16
Презентация генерального директора компании на конференции “Coliseum 2019”	https://www.youtube.com/watch?v=NWCg3N_uEww

Приложение 2.

Вопросы для интервью

Интервью проводится в рамках некоммерческого исследования. Цель интервью – понять, как изменились функции музыкальных дистрибьюторов в условиях цифровизации. Интервью проводится

в онлайн-формате. Продолжительность интервью не должна превышать двух часов. Информация о респондентах не разглашается, за исключением должности сотрудника и стажа работы. Необработанные данные, собранные в ходе интервью, не будут опубликованы.

Часть 1. Информация о респонденте

1. Должность сотрудника
2. Стаж работы в компании

Часть 2. Технологическое развитие компании

3. Какую роль информационные и цифровые технологии играют в основной деятельности компании?
4. Как эта роль менялась в процессе развития компании и индустрии?
5. Как различные информационные и цифровые инструменты используются для решения повседневных задач сегодня?
6. Возникали ли в процессе развития компании барьеры, сложности для внедрения новых информационных и цифровых технологий? Если да, то как они были нейтрализованы?

Часть 3. Взаимодействие с клиентами

7. Как складываются отношения компании с клиентами?
8. Как информационные и цифровые инструменты используются для предоставления услуг клиентам?
9. Происходили ли изменения в наборе предоставляемых услуг, связанные с технологическим развитием компании/индустрии?

Часть 4. Будущее развитие

10. Как часто возникает необходимость в новых технологических решениях и с чем она связана?
11. Существует ли на рынке технология, внедрение которой станет необходимо в скором времени?
12. Что будет являться стимулами и барьерами для внедрения новых решений в ближайшем будущем?

Об авторе**Алтынов Артём Игоревич**

стажер-исследователь лаборатории исследований науки и технологий, Институт статистических исследований и экономики знаний, Национальный исследовательский университет «Высшая школа экономики», 109028, г. Москва, Покровский бульвар, д. 11;

E-mail: aaltynov@hse.ru

ORCID: 0000-0001-9209-438X

Digital transformation of music aggregation and distribution companies: The case of Russia

Artem I. Altynov

E-mail: aaltynov@hse.ru

HSE University

Address: 11 Pokrovsky Bulvar, Moscow 109028, Russia

Abstract

Currently distributors ensure the operation of the whole value chain in the music industry, while most researchers focus on technological, streaming and copyright impact in light of digitalization. This paper tries to understand the influence of digitalization on business models and the role of music distributors in a value chain. Research identifies operational processes that were changed due to digitalization, barriers that arose, and actions taken to overcome them on the corporate level. Through retrospective case study based on an interview with the CEO, the experience of the Russian music distribution company Broma 16 is analyzed. This paper describes the goals of business model transformation, drivers, performed activities and their results. The research derives four consequences of digitalization for the firm's business

model and role in a value chain: the firm can be considered as a technological company rather than a music company. Distribution relies on digital instruments for management and marketing. Local intermediaries get more opportunities to enter foreign markets, but they have to perform innovations in these markets. Music distributors operate at the complicated intersection of copyright and technological aspects. The research applies a general theoretical framework for the study of digital transformation of business models. A similar approach can be used to do research on companies in music and other creative industries, and to conduct workshops with industry representatives. The paper provides value for practitioners in emerging music markets, for example, Brazil, Argentina and Mexico, due to the presentation of management practices towards digitalization and the consequences of transformation for the distribution role.

Keywords: digitalization, digital transformation, music distribution, Russia, case study

Citation: Altynov A.I. (2022) Digital transformation of music aggregation and distribution companies: The case of Russia. *Business Informatics*, vol. 16, no. 1, pp. 56–71. DOI: 10.17323/2587-814X.2022.1.56.71

References

1. Polyakova V., Fursov K. (2021) *Digital practices of people in Russia in a period of self-quarantine*. ISSEK series of regular bulletins “Digital Economy” (in Russian). Available at: <https://issek.hse.ru/news/438496284.html> (accessed 13 July 2021).
2. *Entertainment and media industry overview: Forecast for 2019–2023* (2019) PwC (in Russian). Available at: <https://www.pwc.ru/publications/media-outlook/mediaindustriya-v-2019.pdf> (accessed 27 March 2021).
3. *A roadmap toward a common framework for measuring the digital economy. Report for the G20 digital economy task force* (2020) OECD. Available at: <https://www.oecd.org/sti/roadmap-towards-a-common-framework-for-measuring-the-digital-economy.pdf> (accessed 07 April 2021).
4. *Global music report* (2021) IFPI. Available at: https://www.ifpi.org/wp-content/uploads/2020/03/GMR2021_STATE_OF_THE_INDUSTRY.pdf (accessed 27 July 2021).
5. *The show must go on* (2020) Goldman Sachs. Available at: <https://www.goldmansachs.com/insights/pages/infographics/music-in-the-air-2020/report.pdf> (accessed 07 April 2021).
6. *The Russian market of music streaming services will continue to grow rapidly* (2019) J’Son & Partners (in Russian). Available at: <https://www.sostav.ru/publication/ostalnoe-vidimost-po-prognozu-j-son-and-partners-rossijskij-rynok-muzykalnykh-strimingovykh-uslug-prodolzhit-bystryj-rost-37158.html> (accessed 27 March 2021).
7. *Music consumer insight report* (2018) IFPI. Available at: https://www.ifpi.org/wp-content/uploads/2020/07/091018_Music-Consumer-Insight-Report-2018.pdf (accessed 27 March 2021).
8. Herbert D., Lotz A.D., Marshall L. (2019) Approaching media industries comparatively: A case study of streaming. *International Journal of Cultural Studies*, vol. 22, no. 3, pp. 349–366. <https://doi.org/10.1177/1367877918813245>
9. Galuszka P. (2015) Music aggregators and intermediation of the digital music market. *International Journal of Communication*, vol. 9, pp. 254–273.
10. Li F. (2020) The digital transformation of business models in the creative industries: A holistic framework and emerging trends. *Technovation*, vols. 92–93, article ID 102012. <https://doi.org/10.1016/j.technovation.2017.12.004>
11. Bonini T., Gandini A. (2019) “First week is editorial, second week is algorithmic”: Platform gatekeepers and the platformization of music curation. *Social Media + Society*, vol. 5, no. 4, article ID 2056305119880006. <https://doi.org/10.1177/2056305119880006>
12. Hracs B.J. (2015) Cultural intermediaries in the digital age: The case of independent musicians and managers in Toronto. *Regional Studies*, vol. 49, no. 3, pp. 461–475. <https://doi.org/10.1080/00343404.2012.750425>
13. Morris J.W. (2015) Curation by code: Infomediaries and the data mining of taste. *European Journal of Cultural Studies*, vol. 18, nos. 4–5, pp. 446–463. <https://doi.org/10.1177/1367549415577387>
14. Eiriz V., Leite F.P. (2017) The digital distribution of music and its impact on the business models of independent musicians. *The Service Industries Journal*, vol. 37, nos. 13–14, pp. 875–895. <https://doi.org/10.1080/02642069.2017.1361935>
15. Koh B., Hann I.-H., & Raghunathan, S. (2019) Digitization of music: Consumer adoption amidst piracy, unbundling, and rebundling. *MIS Quarterly*, vol. 43, no. 1, pp. 23–45. <https://doi.org/10.25300/MISQ/2019/14812>
16. Vonderau P. (2019) The Spotify effect: Digital distribution and financial growth. *Television & New Media*, vol. 20, no. 1, pp. 3–19. <https://doi.org/10.1177/1527476417741200>
17. Kjus Y. (2016) Musical exploration via streaming services: The Norwegian experience. *Popular Communication*, vol. 14, no. 3, pp. 127–136. <https://doi.org/10.1080/15405702.2016.1193183>
18. Morgan B.A. (2020) Revenue, access, and engagement via the in-house curated Spotify playlist in Australia. *Popular Communication*, vol. 18, no. 1, pp. 32–47. <https://doi.org/10.1080/15405702.2019.1649678>
19. Street J., Laing D., Schroff S. (2018) Regulating for creativity and cultural diversity: The case of collective management organisations and the music industry. *International Journal of Cultural Policy*, vol. 24, no. 3, pp. 368–386. <https://doi.org/10.1080/10286632.2016.1178733>

20. Hesmondhalgh D., Jones E., Rauh A. (2019) SoundCloud and Bandcamp as alternative music platforms. *Social Media + Society*, vol. 5, no. 4, article ID 2056305119883429. <https://doi.org/10.1177/2056305119883429>
21. Fleischer R. (2017) If the song has no price, is it still a commodity? Rethinking the commodification of digital music. *Culture Unbound*, vol. 9, no. 2, pp. 146–162. <https://doi.org/10.3384/cu.2000.1525.1792146>
22. Meier L.M., Manzerolle V.R. (2019) Rising tides? Data capture, platform accumulation, and new monopolies in the digital music economy. *New Media & Society*, vol. 21, no. 3, pp. 543–561. <https://doi.org/10.1177/1461444818800998>
23. Burmester A.B., et al. (2016) Accepting or fighting unlicensed usage: Can firms reduce unlicensed usage by optimizing their timing and pricing strategies? *International Journal of Research in Marketing*, vol. 33, no. 2, pp. 343–356. <https://doi.org/10.1016/j.ijresmar.2015.06.005>
24. Mróz B. (2016) Online piracy: An emergent segment of the shadow economy. Empirical insight from Poland. *Journal of Financial Crime*, vol. 23, no. 3, pp. 637–654. <https://doi.org/10.1108/JFC-04-2015-0022>
25. Mazziotti G., Simonelli F. (2016) Another breach in the wall: copyright territoriality in Europe and its progressive erosion on the grounds of competition law. *Info*, vol. 18, no. 6, pp. 55–66. <https://doi.org/10.1108/info-06-2016-0026>
26. *Year-End Report* (2021) MRC Data, Billboard. Available at: https://www.musicbusinessworldwide.com/files/2021/01/MRC_Billboard_YEAR_END_2020_US-Final.pdf (accessed 27 July 2021).
27. Gerring J. (2004) What is a case study and what is it good for? *American political science review*, vol. 98, no. 2, pp. 341–354. <https://doi.org/10.1017/S0003055404001182>
28. Huyghe A., et al. (2014) Technology transfer offices as boundary spanners in the pre-spin-off process: The case of a hybrid model. *Small Business Economics*, vol. 43, no. 2, pp. 289–307. <https://doi.org/10.1007/s11187-013-9537-1>
29. Simons H. (2014) Case study research: In-depth understanding in context. *The Oxford handbook of qualitative research*, edited by Leavy P., pp. 455–470. <https://doi.org/10.1093/oxfordhb/9780199811755.013.005>
30. Seawright J., Gerring J. (2008) Case selection techniques in case study research: A menu of qualitative and quantitative options. *Political research quarterly*, vol. 61, no. 2, pp. 294–308. <https://doi.org/10.1177/1065912907313077>
31. *Broma16* (2021) Official website. Available at: <https://broma16.com/en/> (accessed 07 April 2021).
32. *Heaven11* (2021) Official website. Available at: <https://www.heaven11.pro/#intro> (accessed 07 April 2021).
33. Thomas G. (2011) A typology for the case study in social science following a review of definition, discourse, and structure. *Qualitative inquiry*, vol. 17, no. 6, pp. 511–521. <https://doi.org/10.1177/1077800411409884>
34. Oiestad S., Bugge M.M. (2014) Digitisation of publishing: Exploration based on existing business models. *Technological Forecasting and Social Change*, vol. 83, no. 1, pp. 54–65. <https://doi.org/10.1016/j.techfore.2013.01.010>
35. Landoni P. et al. (2020) Business model innovation in cultural and creative industries: Insights from three leading mobile gaming firms. *Technovation*, vols. 92–93, article ID 102084. <https://doi.org/10.1016/j.technovation.2019.102084>
36. *Business Motivation Model: Version 1.3* (2015) Object Management Group. Available at: <https://www.omg.org/spec/BMM/1.3/PDF> (accessed 27 July 2021).
37. Towse R. (2017) Economics of music publishing: Copyright and the market. *Journal of Cultural Economics*, vol. 41, no. 4, pp. 403–420. <https://doi.org/10.1007/s10824-016-9268-7>
38. Lee J.-A. (2019) Tripartite perspective on the copyright-sharing economy in China. *Computer Law and Security Review*, vol. 35, no. 4, pp. 434–452. <https://doi.org/10.1016/j.clsr.2019.05.001>
39. Kim H.-J., Kim B.-H. (2018) Implementation of young children English education system by AR type based on P2P network service model. *Peer-to-Peer Networking and Applications*, vol. 11, no. 6, pp. 1252–1264. <https://doi.org/10.1007/2fs12083-017-0612-2>
40. Lyubareva I., Benghozi P.-J., Fidele T. (2014) Online business models in creative industries: Diversity and structure. *International Studies of Management and Organization*, vol. 44, no. 4, pp. 43–62. <https://doi.org/10.2753/IMO0020-8825440403>
41. Nakano D., Fleury A. (2017) Recorded music supply network reconfiguration: The dual effect of digital technology. *International Journal of Manufacturing Technology and Management*, vol. 31, nos. 1–3, pp. 153–175. <https://doi.org/10.1504/IJMTM.2017.10002918>
42. Benghozi P.-J., Paris T. (2014) The cultural economy in the digital age: A revolution in intermediation? *City, Culture and Society*, vol. 7, no. 2, pp. 75–80. <https://doi.org/10.1016/j.ccs.2015.12.005>
43. Dobusch L., Schüller E. (2014) Copyright reform and business model innovation: Regulatory propaganda at German music industry conferences. *Technological Forecasting and Social Change*, vol. 83, no. 1, pp. 24–39. <https://doi.org/10.1016/j.techfore.2013.01.009>

About the author

Artem I. Altynov

Research Assistant, Laboratory for Science and Technology Studies, Institute for Statistical Studies and Economics of Knowledge, National Research University Higher School of Economics, 11, Pokrovsky Bulvar, Moscow 109028, Russia;

E-mail: aaltynov@hse.ru

ORCID: 0000-0001-9209-438X

Customer segmentation using *k*-means clustering for developing sustainable marketing strategies

Nidhi Gautam^a

E-mail: nidhi.uiams@pu.ac.in

Nitin Kumar^b

E-mail: nk2268913@gmail.com

^a University Institute of Applied Management Sciences, Panjab University

Address: South Campus, Behind P.U. Alumni House Udyog Path, Punjab University Rd, Sector 25, Chandigarh 160014, India

^b Housing Development Finance Corporation Limited

Address: Dalhousie Road, near Shani Dev Mandir, Pathankot, Punjab 145001, India

Abstract

Sales and marketing is the indispensable department of an organization which leads to the generation of revenue and building customer relationship. Marketing is the process of finding the potential customers and sales is the process of converting those potential customers into real customers. Hence, it is imperative that marketing and sales go hand in hand. Developing marketing strategies needs proper market research which can cover the relevant pointers like demographics, culture, spending power, income and many more. The process of segmentation, targeting and positioning (STP) is carried out to develop marketing and sales strategies. STP is done by collection of the marketing intelligence. For this process, surveys are also used but data mining has far more effective and better results so far. Organizations tend to take risk because of the importance and relevance of the marketing and sales department. Most of the budget in the organizations is allocated for marketing and promotional activities. For making data-driven and accurate decisions, data mining is used in various fields to extract valuable information and patterns. This paper discusses the use of the data mining concept on marketing. This paper aims to analyze marketing data with *k*-means data mining clustering techniques and to find the relationship between marketing and *k*-means data mining clustering techniques.

Keywords: marketing, *k*-means, clustering, data mining tools, data mining techniques

Citation: Gautam N., Kumar N. (2022) Customer segmentation using *k*-means clustering for developing sustainable marketing strategies. *Business Informatics*, vol. 16, no. 1, pp. 72–82. DOI: [10.17323/2587-814X.2022.1.72.82](https://doi.org/10.17323/2587-814X.2022.1.72.82)

Introduction

Marketing is a value creation process according to Philip Kotler [1]. It is all about what you deliver to your customer. People consider marketing and sales as the same but both are different and have their own relevance and impact in the organization. Marketing is the process of finding the potential customer and sales is the process of converting those potential customers into real customers [2]. The concept of marketing can be explained using different marketing concepts. First, there is a production concept, which explains that supply will create the demand. Second, the sales concept emphasis on selling the product by hook or by crook. Third, the product concept gives importance to product innovation and differentiation. Fourth, the marketing concept, which believes in catering to the needs of the customer as customer, is king for them. Lastly, the societal marketing concept focuses on the customer as well as society and the environment. It totally depends upon the organization to decide which concept it wants to follow. Whenever anyone considers marketing strategies, marketing mix is used. According to Philip Kotler, marketing mix comprises four components i.e., product, price, place and promotion [1].

Data mining is a process of extracting knowledge from large amounts of data. It is a technique to find trends, patterns, correlations, anomalies in databases which can be helpful to make accurate future decisions. It is also known as knowledge discovery in databases (KDD) results. Data mining helps experts to understand the data and leads to better and data driven decisions. Data mining is an intersection of three fields: databases, artificial intelligence and machine learning. The steps of data mining includes data cleansing (for the removal of noisy and inconsistent data), data integration (to combine data from multiple sources for efficient data processing), data selection (to select and retrieve the relevant data for analysis), data transformation (to transform the collected data into a desirable form for further data processing), data mining (a technique applied on data for various pattern matching methods), pattern evolution (to determine important patterns which represent knowledge and data insights) and knowledge presentation (this is done by various visualization methods for knowledge representation pictorially or graphically). The various applications of data mining include market basket analysis (association mining). Market basket analysis is the method to discover relations or correlations among the set of data items. Classification analyzes a training set of objects with known labels and tries to form a model for each

class based on the features in the data. Regression is to predict values of some missing data or to build a model for some attributes using other attributes of the data. Time Series Analysis analyzes time series data to find certain regularities and interestingness in data. Clustering is used to identify clusters embedded in the data. The task of clustering is to find clusters for which intra-cluster similarity is high and inter-cluster similarity is low. Outlier analysis is used to find outliers in the data, namely detect data which are very far away from average behavior of the data [3].

This paper focuses on the importance of data mining approaches, specifically clustering, for formalizing the marketing strategies by understanding customer needs and spending behavior. The paper highlights the importance of visualization tools to understand the important relationships between various parameters in the dataset. It shows that how a pair-plot can be helpful in identifying clusters and the silhouette score for deciding the k value for k -means clustering method.

The rest of the paper is organized as follows: Section 1 presents the motivation and research rationale of the study. Section 2 describes numerous existing models and related work using various clustering methods. Section 3 presents the research design and methodology followed for this work. Section 4 describes the results and discussions. The last Section concludes the paper with future recommendations.

1. Motivation and research rationale

This study aims to work on the transaction dataset of a store which is taken from an internet source [4] for making clusters of customers depending upon their income and spending score. This will lead to segmentation, targeting and positioning (STP) of the customers and their behavior patterns will help us to develop sustainable marketing strategies. Nowadays, everything is connected to the customer with the help of the Internet of things. You just need space to store data to perform analysis to keep track of the customers. This study can help organizations to gain new customers and maintain loyal customers. The main contributions of this paper are summarized as follows:

- ◆ to perform market segmentation of the customers depending upon their spending using unsupervised machine learning;
- ◆ to perform STP;
- ◆ to know the target customer and develop marketing strategies.

2. Existing models with literature review

Association rule mining is a data-mining concept which is used to optimize the patterns associated with dynamic behaviors of transactions made by customers when purchasing some specific products. The insights generated from this technique can be used by the retailing business for making data-driven decision-making. Using this algorithm, the frequent transactions made by the customers have been analyzed using the support and confidence of the customers in buying associated items. The analysis conducted by Association rule mining model can best be used in managing product placement on the shelves in the supermarket [5–7]. The study was conducted in order to make a market basket analysis by using association rules. The data used in the study was the sales data of a supermarket from the Vancouver Island University website. Data was analyzed in the Weka tool where the dataset contained 225 different products for analysis [8].

The study focused on small and medium enterprises (SMEs), where customer behavior was analyzed from the perspective of SMEs. The model proposed the integration of customer relationship management (CRM) and the data mining techniques to provide effective rules and new patterns for better decision-making. The model suggested that as the era of big data is unwinding itself, the data mining application may enhance accuracy of rules and patterns, all of which can further help the enterprises to improve customers' satisfaction and loyalty, reduce customer churn and so on. The suggested models can also help SMEs to classify the priority customer groups and offer them better facilities and ranges to retain them. The suggested models can help the enterprises to further improve their market share, position in the market and maintain a positive development process [9–11].

The model incorporated a new graphical display for clustering techniques. In this model, each cluster is represented by a silhouette. The silhouette is based on the comparison of its tightness and separation. This silhouette showed which objects lie well within their cluster and which ones are merely somewhere in between clusters. The whole clustering is displayed by combining the silhouettes into a single plot. The average silhouette width provides an evaluation of clustering validity and may help to select an 'appropriate' number of clusters [12–13].

Classification of aquifer vulnerability using *k*-means cluster analysis uses the application of the cluster analysis in ground vulnerability assessment using the *k*-means technique. In this study, a clustering technique is used

because it removes some of the subjectivity associated with the indexing method. It creates a vulnerability map that does not rely on fixed weights and ratings and provides a more objective representation of the system's physical characteristics. The model was applied to an aquifer in Iran and compared with the standard DRASTIC approach using the water quality parameters nitrate, chloride and total dissolved solids (TDS) as surrogate indicators of aquifer vulnerability. The model having clustering techniques outperformed the other methods [14–16].

The paper discovered the segments of organic food consumers in Lebanon by using a market segmentation based on lifestyle and attitude variables to generate appropriate marketing strategies for each market segment [17]. Market basket analysis (MBA) is a very powerful data mining technique which provides various types of information, like buying behavior of the customer, likes, dislikes, etc. to the retailer, all of which can help the retailer perform correct decision-making. It can be used in various fields, such as marketing, management, bioinformatics, the education field and many more. MBA is a very useful technique to find out interesting patterns from a large amount of data which can automatically track any type of changes in facts from previous data [18–20].

The authors used a *k*-means clustering algorithm to identify the customer segmentation in a supervised manner. The methodology could understand the complex relationships existing in the data attributes [21]. The authors analyzed the data of an e-commerce portal to understand the requirements of the customers so as to provide them better services in the future. A *k*-means clustering algorithm was used to analyze the data, considering customer segmentation as an important aspect of it [22–23]. The authors analyzed data of three online food chains and applied various clustering algorithms on the same. Though there is no fixed model of a particular algorithm which could show best results, *k*-means clustering has shown promising results on the data [24]. The authors suggested how customer segmentation can be implemented and can be useful to understand the customers. Customer segmentation can be a stepping-stone for identifying future prospective customers and specific marketing strategies can be formulated considering the customer segment [25]. The authors have stressed the use of machine learning algorithms for customer segmentation, since it can enhance productivity and profitability of an organization. *K*-means clustering was used for the study and it has shown very promising results for customer segmentation [26].

3. Research design and methodology (data collection method)

A. Sampling method. Secondary data, mall customer segmentation dataset from an internet source [4].

B. Sample size. The dataset which is used for the analysis contains people’s purchasing attributes in the Malls. This dataset has five features – customerID, age, gender, credit score and income. There are data for about 200 transactions used for data analysis.

C. Research rationale. To devise a comprehensive model that can be used to classify customers based on spending score and annual income for developing appropriate marketing strategies.

D. Tools used. R Studio [27], Weka [28], MS Excel [29].

R Studio and Weka are freeware which are used for data analytics. These tools are mostly used for data analytics in the field of industry as well as academia. MS Excel is a sub-tool of Microsoft Office, which is generally used for data preparation and preprocessing.

E. Clustering algorithms used. The *k*-means clustering algorithm [24] is based on the Euclidian

distance to figure out *k* clusters in the data. The clusters are homogeneous within them and represent similar types of data. *K*-means clustering is most suitable to handle big and hyper spherical data. It is best suited for market segmentation, social network analytics, image segmentation and so on.

4. Results and discussion

The dataset is preprocessed and cleansed in Excel [29] by using descriptive statistics. The dataset is balanced as the distribution of males and females are almost the same. The distribution of data is checked in Weka [28] and pair plots are generated to show the same.

From the pair plot in *Fig. 1*, we found that the last row is insightful since it gives an indication of hidden clusters in the data. There is cluster formation between the Spending score (1–100) vs. CustomerID, the Spending score vs. Age and the Spending score (1–100) vs. Annual income (in thousands of US dollars).

The joint-plots, distributions, correlation matrix, silhouette coefficient and *k*-means clusters are generated in R-Studio [27] by using its libraries. The joint-plot of spending score and age as shown in *Fig. 2a* shows that there are two bright core areas where density is very high.

Fig. 1. Pair-plot of variables representing a pairwise relationship among CustomerID, Age, Annual Income (in thousands of US dollars) and Spending Score (1–100).

There are two different spending habits in different age groups represented in the plot.

The joint-plot of the spending score and annual income as shown in Fig. 2b shows that there is one area where density is very high i.e., in the middle. The other four areas show different patterns for the user. This may be possible because of the different purchasing power of the customers and their different spending habits. The five groups from the observations include Low income & High spending habits, Low income & Low spending habits, Moderate income & Moderate spending habits,

Fig. 2a. Joint plots for describing (Spending score and Age) distributions on the same plot.

Fig 2b. Joint plots for describing (Spending score and Annual income) distributions on the same plot.

Fig 2c. Joint plots for describing (Annual income and Age) distributions on the same plot.

High income & High spending habits and High income & Low spending habits. Joint-plot of Annual income and Age as shown in Fig. 2c and Fig. 3 shows that the people in mid-30s have roughly a mean income of \$80 000. If we compare the yearly income of more than \$100 000, we find that males have more than \$100 000 income in their early 30s and in the case of females it's around mid-40s. Perhaps, this is due to the disparity in pay.

The average value of the spending score of females is slightly more than that of the males. Notice the bulge of the graph in Fig. 3, which shows the mean value. Figure 4 shows the Annual income of Males and Females. Thus, the average income of females (Female = 0) is less than that of males (Male = 1).

Fig. 3. Annual income (in thousands of USD) vs. Gender.

Fig. 4. Box-plot for Spending score (1-100) vs. Gender.

The distribution of the data showed that most of the people are less than 45 years of age. For most of the customers, the spending score centers between 40 and 60. Annual income and gender have a positive correlation. There is a positive correlation between annual income and the spending score as shown in Fig. 5.

Customer Segmentation with *k*-means using the Silhouette Score. The Silhouette coefficient in *k*-means clustering is calculated using the mean intra-cluster distance “*a*” and the mean nearest-cluster distance “*b*” for each sample. The Silhouette coefficient for a sample is $(b - a) / \max(a, b)$ where *b* is the distance between a sample and the nearest cluster that the sample is not a part

of. Note that the Silhouette coefficient is only defined if the number of labels is $2 \leq n_labels \leq (n_samples - 1)$. Trying to find clusters based on features like Annual income & Spending score. Since the Silhouette score is maximum for *k* = 5, it is a good idea to cluster the data into five subgroups.

The Silhouette coefficient has helped us to decide on the number of clusters to be taken for the study. In *k*-means clustering, selecting the value of *k* is of utmost importance. By using the Silhouette coefficient, selecting the value *k* has become very clear and simple. From the plot in Fig. 6 there are five clusters: *cluster A*, *cluster B*, *cluster C*, *cluster D* and *cluster E*. Customers of the *cluster E* are misers as they have more purchasing power but they have a lower spending score. Customers of the *cluster A*, *cluster B* and *cluster C* are easy to handle. The customers of *cluster D* groups are a threat to the organization because they have less income but a larger spending score. They can be defaulters in the future. Therefore, by using *k*-means clustering and the Silhouette coefficient, customer classifications can be easily visualized. Hence, the marketing teams can easily identify potential customers.

Conclusion

Nowadays, it is very crucial to identify your potential customers in order to have a more data driven strategy to target customers. From the above data analysis, it is concluded that the distribution of males and females

Fig. 5. Correlation matrix to show the correlation among variables such as customerID, Gender, Age, Annual income, Spending score.

Fig. 6. K-means clusters for customer classification.

is nearly same. The pair-plot helps us to explain the permutation of the attributes, which helps in pattern, or cluster identification. With the help of the joint-plot between the spending score and annual income, purchasing capacity as well as spending habits of the customers can be analyzed. It is observed from the *k*-means clustering that customers can be classified into five groups such as “Low income & High spending habits,” “Low income & Low spending habits,” “Moderate income & Moderate spending habits,” “High income & High spending habits” and “High income & Low spending habits.” The box-plot for Spending score and Gender shows that the mean Spending scores of females are slightly more than that of the males whereas the violin plot shows that the average income of females is less than that of males. In this data, the majority of the people are less than 45 years of age and most of the customers, spending score centers between 40 and 60. Annual income and gender have positive correlation. There is a positive correlation annual income and spending score. The segmentation of the customers is done by a *k*-means algorithm. The value of the *k* is decided by the Silhouette score. We tried to find clusters based on features like Annual income & Spending score. The algorithm divided the data into five subgroups from which one could formulate marketing strategies in order to sell their products to the target audience.

In this study, the following problems have been resolved:

- ◆ to perform STP;
- ◆ to know the target customer and develop marketing strategies;

- ◆ to solve this problem, the dataset of a retail store was taken and we performed exploratory data analysis by using data visualization using various plots starting from the pair plot to the *k*-means plot.

The pair plot explains the relationships and patterns, which act as a stepping-stone for further analysis. There is cluster formation between Spending score (1-100) vs. CustomerID, Spending score vs. Age and Spending score (1-100) vs. Annual income (in thousands of USD) and these attributes were taken up for the study using joint plots. The joint-plot of Spending score and Annual income shows that there is one area where density is very high i.e., in the middle. The other four areas show different patterns for customers. This may be because of the different purchasing capacity of the customers and their different spending habits. The five groups from the observations includes Low income & High spending habits, Low income & Low spending habits, Moderate income & Moderate spending habits, High income & High spending habits and High income & Low spending habits.

The data visualization between Spending score and Annual income was presented. To know the accurate number of clusters, the Silhouette coefficient was used and its value came out to be five in this dataset, i.e. five clusters were considered for this study. Customers in *cluster E* have an annual income but they are spending very less from their income because their spending score is very low. This is a very important segment because they have the money to pay. A lot of marketing and promotional activities are required to influence this segment (group). A market basket analysis should be done to know the pattern associated with the purchase of goods. This can help us to know the better product placement of the product on the aisle. Marketing should be done in such a way that the consumers relate the product with their lifestyle; this will boost sales. A discount and offer can help the store to get more revenue. Customers who are in *cluster A*, *cluster B* and *cluster C* clusters have nearly the same annual income and spending score. These customers do not need more marketing and promotional activities. They can be tackled by the salesmen directly. Customers in *cluster D* are the ones who rely on the credit card because their annual income is very much less than their spending score. These customers have higher chances of becoming defaulters because their income is low but they are spendthrifts. The difference of outcomes in comparison with other competitive approaches and solutions is that our solutions are accurate because they have scientific and mathematical backup. The solution proposed in this paper is based on logic and data, not on

gut feeling and experiences. The solutions are safer and more reliable than traditional methods of STP. These solutions can be applicable to SMEs and small business persons with low investment and help them to use their hard-earned money in a justified way. In this paper, an algorithm divided the data into five subgroups which could be used to formulate marketing strategies in order to sell products to the target audience. IT systems can be developed for the SMEs and small business for the management of the sales and marketing of the business

so that they can allocate their limited resources and budget for maximum benefits. Data scientists have a crucial role in this field because it is very important to understand the data of a particular organization. The exponential generation of the data and the growth of artificial intelligence has given an opportunity to data scientists and marketing tycoons so they can come together and build an IT system at affordable rates which will enhance the business process. ■

References

1. Kotler P., Cunningham M.H., Keller K.L. (2008) *A framework for marketing management*. Toronto: Pearson Prentice Hall.
2. Rust R.T. (2020) Outside-in marketing: Why, when and how? *Industrial Marketing Management*, vol. 89, pp. 102–104. <https://doi.org/10.1016/j.indmarman.2019.12.003>
3. Gupta M.K., Chandra P. (2020) A comprehensive survey of data mining. *International Journal of Information Technology*, vol. 12, pp. 1243–1257. <https://doi.org/10.1007/s41870-020-00427-7>
4. Chaudhary V. (2018) *Mall customer segmentation data: Market basket analysis*. Data set. Available at: <https://www.kaggle.com/vjchoudhary7/customer-segmentation-tutorial-in-python> (accessed 2 March 2021).
5. Guney S., Peker S., Turhan C. (2020) A combined approach for customer profiling in video on demand services using clustering and association rule mining. *IEEE Access*, vol. 8, pp. 84326–84335. <https://doi.org/10.1109/ACCESS.2020.2992064>
6. Wang S., Zhang H., Chen H., Shi Q., Li Y. (2020) Association rule mining for precision marketing of power companies with user features extraction. *2020 IEEE Power & Energy Society General Meeting (PESGM)*, pp. 1–5, <https://doi.org/10.1109/PESGM41954.2020.9281644>
7. Ananda I., Salamah U. (2020) The application of product marketing strategy using an association rule mining apriori method. *International Journal of Information System and Computer Science*, vol. 4, no. 2, pp. 80–88. Available at: <https://ojs.stmikpringsewu.ac.id/index.php/ijiscs/article/download/899/pdf> (accessed 21 February 2021).
8. Ünvan Y.A. (2020) Market basket analysis with association rules. *Communications in Statistics – Theory and Methods*, vol. 50, no. 7, pp. 1615–1628. <https://doi.org/10.1080/03610926.2020.1716255>
9. Ranjan J., Bhatnagar V. (2008) Critical success factors for implementing CRM using data mining. *Interscience Management Review*, vol. 1, no. 1, article 7. <https://doi.org/10.47893/IMR.2008.1006>
10. Ngai E.W.T., Xiu L., Chau D.C.K. (2009) Application of data mining techniques in customer relationship management: A literature review and classification. *Expert Systems with Applications*, vol. 36, no. 2, pp. 2592–2602. <https://doi.org/10.1016/j.eswa.2008.02.021>
11. Hosseini S.M.H., Maleki A., Gholamian M.R. (2010) Cluster analysis using data mining approach to develop CRM methodology to assess the customer loyalty. *Expert Systems with Applications*, vol. 37, no. 7, pp. 5259–5264. <https://doi.org/10.1016/j.eswa.2009.12.070>
12. Silva S., Cortez P., Mendes R., Pereira P.J., Matos L.M., Garcia L. (2018) A categorical clustering of publishers for mobile performance marketing. In: *The 13th International Conference on Soft Computing Models in Industrial and Environmental Applications*. Springer, Cham. https://doi.org/10.1007/978-3-319-94120-2_14
13. Beheshtian-Ardakani A., Fathian M., Gholamian M. (2018) A novel model for product bundling and direct marketing in e-commerce based on market segmentation. *Decision Science Letters*, vol. 7, no. 1, pp. 39–54. <https://doi.org/10.5267/j.dsl.2017.4.005>
14. Javadi S., Hashemy S.M., Mohammadi K., Howard K.W.F., Neshat A. (2017) Classification of aquifer vulnerability using k-means cluster analysis. *Journal of Hydrology*, vol. 549, pp. 27–37. <https://doi.org/10.1016/j.jhydrol.2017.03.060>
15. Rahmani B., Javadi S., Shahdany S.M.H. (2021) Evaluation of aquifer vulnerability using PCA technique and various clustering methods. *Geocarto International*, vol. 36, no. 18, pp. 2117–2140. <https://doi.org/10.1080/10106049.2019.1690057>
16. Jahwar A.F., Abdulazeez A.M. (2020) Meta-heuristic algorithms for k-means clustering: A review. *PalArch's Journal of Archaeology of Egypt / Egyptology*, vol. 17, no. 7, pp. 12002–12020. Available at: <https://archives.palarch.nl/index.php/jae/article/view/4630> (accessed 21 February 2021).
17. Tleis M., Callieris R., Roma, R. (2017) Segmenting the organic food market in Lebanon: An application of k-means cluster analysis. *British Food Journal*, vol. 119, no. 7, pp. 1423–1441. <https://doi.org/10.1108/BFJ-08-2016-0354>
18. Kaur M., Kang S. (2016) Market basket analysis: Identify the changing trends of market data using association rule mining. *Procedia Computer Science*, vol. 85, pp. 78–85. <https://doi.org/10.1016/j.procs.2016.05.180>
19. Gupta S., Mamtora R. (2014) A survey on association rule mining in market basket analysis. *International Journal of Information and Computation Technology*, vol. 4, no. 4, pp. 409–414. Available at: http://ripublication.com/irph/ijict_spl/ijictv4n4spl_11.pdf (accessed 21 February 2021).
20. Aguinis H., Forcum L.E., Joo H. (2013) Using market basket analysis in management research. *Journal of Management*, vol. 39, no. 7, pp. 1799–1824. <https://doi.org/10.1177/0149206312466147>

21. Muhal H., Jain H. (2021) Two-stage customer segmentation using k-means clustering and artificial. *International Research Journal of Engineering and Technology*, vol. 8, no. 3, pp. 485–490.
22. Punhani R., Arora V.P.S., Sabitha S., Kumar Shukla V. (2021) Application of clustering algorithm for effective customer segmentation in E-Commerce. In: *Proceedings of the 2021 International Conference on Computational Intelligence and Knowledge Economy (ICCIKE), 17-18 March 2021, Dubai, United Arab Emirates*, pp. 149–154. <https://doi.org/10.1109/ICCIKE51210.2021.9410713>
23. Popović N., Savić A., Bjelobaba G., Veselinović R., Stefanović H., Ilić P.M. (2021) The implementation of hierarchical and nonhierarchical clustering for customer segmentation in one luxury goods company. In: *Proceedings of the 37th International Business Information Management Association (IBIMA), 30–31 May 2021, Cordoba, Spain*, pp. 8370–8381.
24. Aktaş A.A., Tunali O., Bayrak A.T. (2021) Comparative unsupervised clustering approaches for customer segmentation. In: *Proceedings of the 2021 2nd International Conference on Computing and Data Science (CDS), 28-29 Jan. 2021, Stanford, CA, USA*, pp. 530–535. <https://doi.org/10.1109/CDS52072.2021.00097>
25. Suresh Y., Senthilkumar J., Mohanraj V., Kesavan S. (2021) Customer segmentation using machine learning in python. *Turkish Journal of Physiotherapy and Rehabilitation*, vol. 32, no. 3, pp. 4338–4342. Available at: <https://turkjphysiotherrehabil.org/pub/pdf/321/32-1-521.pdf> (accessed 21 February 2021).
26. Pradana M., Ha H. (2021) Maximizing strategy improvement in mall customer segmentation using k-means clustering. *Journal of Applied Data Sciences*, vol. 2, no. 1, pp. 19–25. <https://doi.org/10.47738/jads.v2i1.18>
27. RStudio Team (2020) *RStudio: Integrated Development for R*. RStudio, PBC, Boston, MA. Available at: <http://www.rstudio.com/> (accessed 21 February 2021).
28. Ngo T. (2011) Data mining: practical machine learning tools and technique, Third Edition by Ian H. Witten, Eibe Frank, Mark A. Hell. *ACM SIGSOFT Software Engineering Notes*, vol. 36, no. 5, pp. 51–52. <https://doi.org/10.1145/2020976.2021004>
29. Microsoft Corporation (2018) *Microsoft Excel*. Available at: <https://office.microsoft.com/excel> (accessed 21 February 2021).

About the authors

Nidhi Gautam

PhD (Computer Science & Engineering);

Assistant Professor, Fellow Senate Panjab University, University Institute of Applied Management Sciences, Panjab University, Chandigarh, India;

E-mail: nidhi.uiams@pu.ac.in

ORCID: 0000-0002-9454-3625

Nitin Kumar

MBA (IT & Telecommunications);

Management Trainee, Housing Development Finance Corporation Limited, Pathankot, Punjab, India;

E-mail: nk2268913@gmail.com

ORCID: 0000-0002-8887-2350

Сегментация клиентов с использованием кластеризации на основе метода k -средних для разработки устойчивых маркетинговых стратегий

Н. Гаутам^a

E-mail: nidhi.uiams@pu.ac.in

Н. Кумар^b

E-mail: nk2268913@gmail.com

^a University Institute of Applied Management Sciences, Panjab University
Адрес: South Campus, Behind P.U. Alumni House Udyog Path, Punjab University Rd, Sector 25, Chandigarh 160014, India

^b Housing Development Finance Corporation Limited
Адрес: Dalhousie Road, near Shani Dev Mandir, Pathankot, Punjab 145001, India

Аннотация

Департаменты продаж и маркетинга являются незаменимыми подразделениями организации, обеспечивающими получение дохода и поддержку взаимоотношений с клиентами. Маркетинг представляет собой процесс поиска потенциальных клиентов, а продажи – это процесс превращения потенциальных клиентов в реальных. Поэтому взаимодействие подразделений маркетинга и продаж представляется крайне важным. Разработка маркетинговых стратегий требует соответствующего исследования рынка, которое может охватывать такие факторы как демография, культура, покупательная способность, доход и многое другое. Разработка маркетинговых стратегий и стратегий продаж связана с процессом сегментации, таргетинга и позиционирования (segmentation, targeting and positioning, STP). Процесс STP реализуется путем сбора маркетинговой информации. Для этого также используются опросы, но интеллектуальный анализ данных в настоящее время дает гораздо более эффективные и лучшие результаты. Организации склонны принимать определенные риски ввиду важности и актуальности подразделений маркетинга и продаж. Значительная часть бюджета в организациях выделяется на маркетинговые и рекламные мероприятия. Для принятия точных решений, основанных на данных, интеллектуальный анализ данных используется в различных областях для извлечения ценной информации и поиска закономерностей. В данной статье обсуждается использование концепции интеллектуального анализа данных в маркетинге. Цель статьи – проанализировать маркетинговые данные с применением метода k -средних для кластеризации, а также найти взаимосвязь между маркетингом и методами кластеризации на основе k -средних.

Ключевые слова: маркетинг, метод k -средних, кластеризация, средства интеллектуального анализа данных, методы интеллектуального анализа данных

Цитирование: Gautam N., Kumar N. Customer segmentation using k -means clustering for developing sustainable marketing strategies // Business Informatics. 2022. Vol. 16. No. 1. P. 72–82. DOI: 10.17323/2587-814X.2022.1.72.82

Литература

1. Kotler P., Cunningham M.H., Keller K.L. A framework for marketing management. Toronto: Pearson Prentice Hall, 2008.
2. Rust R.T. Outside-in marketing: Why, when and how? // Industrial Marketing Management, 2020. Vol. 89. P. 102–104. <https://doi.org/10.1016/j.indmarman.2019.12.003>
3. Gupta M.K., Chandra P. A comprehensive survey of data mining // International Journal of Information Technology. 2020. Vol. 12. P. 1243–1257. <https://doi.org/10.1007/s41870-020-00427-7>
4. Chaudhary V. Mall customer segmentation data: Market basket analysis. Data set. Available at: <https://www.kaggle.com/vjchoudhary7/customer-segmentation-tutorial-in-python> (accessed 2 March 2021).
5. Guney S., Peker S., Turhan C. A combined approach for customer profiling in video on demand services using clustering and association rule mining // IEEE Access. 2020. Vol. 8. P. 84326–84335. <https://doi.org/10.1109/ACCESS.2020.2992064>
6. Wang S., Zhang H., Chen H., Shi Q., Li Y. Association rule mining for precision marketing of power companies with user features extraction // 2020 IEEE Power & Energy Society General Meeting (PESGM). 2020. P. 1–5. <https://doi.org/10.1109/PESGM41954.2020.9281644>
7. Ananda I., Salamah U. The application of product marketing strategy using an association rule mining apriori method // International Journal of Information System and Computer Science. 2020. Vol. 4. No. 2. P. 80–88. Available at: <https://ojs.stmikpringsewu.ac.id/index.php/ijiscs/article/download/899/pdf> (accessed 21 February 2021).
8. Ünvan Y.A. Market basket analysis with association rules // Communications in Statistics – Theory and Methods. 2020. Vol. 50. No. 7. P. 1615–1628. <https://doi.org/10.1080/03610926.2020.1716255>
9. Ranjan J., Bhatnagar V. Critical success factors for implementing CRM using data mining // Interscience Management Review. 2008. Vol. 1. No. 1, article 7. <https://doi.org/10.47893/IMR.2008.1006>
10. Ngai E.W.T., Xiu L., Chau D.C.K. Application of data mining techniques in customer relationship management: A literature review and classification // Expert Systems with Applications. 2009. Vol. 36. No. 2. P. 2592–2602. <https://doi.org/10.1016/j.eswa.2008.02.021>

11. Hosseini S.M.H., Maleki A., Gholamian M.R. Cluster analysis using data mining approach to develop CRM methodology to assess the customer loyalty // *Expert Systems with Applications*. 2010. Vol. 37. No. 7. P. 5259–5264. <https://doi.org/10.1016/j.eswa.2009.12.070>
12. Silva S., Cortez P., Mendes R., Pereira P.J., Matos L.M., Garcia L. A categorical clustering of publishers for mobile performance marketing // *Proceedings of the 13th International Conference on Soft Computing Models in Industrial and Environmental Applications*. Springer, Cham, 2018. https://doi.org/10.1007/978-3-319-94120-2_14
13. Beheshtian-Ardakani A., Fathian M., Gholamian M. A novel model for product bundling and direct marketing in e-commerce based on market segmentation // *Decision Science Letters*. 2018. Vol. 7. No. 1. P. 39–54. <https://doi.org/10.5267/j.dsl.2017.4.005>
14. Javadi S., Hashemy S.M., Mohammadi K., Howard K.W.F., Neshat A. Classification of aquifer vulnerability using *k*-means cluster analysis // *Journal of Hydrology*. 2017. Vol. 549. P. 27–37. <https://doi.org/10.1016/j.jhydrol.2017.03.060>
15. Rahmani B., Javadi S., Shahdany S.M.H. Evaluation of aquifer vulnerability using PCA technique and various clustering methods // *Geocarto International*. 2021. Vol. 36. No. 18. P. 2117–2140. <https://doi.org/10.1080/10106049.2019.1690057>
16. Jahwar A.F., Abdulazeez A.M. Meta-heuristic algorithms for *k*-means clustering: A review // *PalArch's Journal of Archaeology of Egypt / Egyptology*. 2020. Vol. 17. No. 7. P. 12002–12020. Available at: <https://archives.palarch.nl/index.php/jae/article/view/4630> (accessed 21 February 2021).
17. Tleis M., Callieris R., Roma R. Segmenting the organic food market in Lebanon: An application of *k*-means cluster analysis // *British Food Journal*. 2017. Vol. 119. No. 7. P. 1423–1441. <https://doi.org/10.1108/BFJ-08-2016-0354>
18. Kaur M., Kang S. Market basket analysis: Identify the changing trends of market data using association rule mining // *Procedia Computer Science*. 2016. Vol. 85. P. 78–85. <https://doi.org/10.1016/j.procs.2016.05.180>
19. Gupta S., Mamtara R. A survey on association rule mining in market basket analysis // *International Journal of Information and Computation Technology*. 2014. Vol. 4. No. 4. P. 409–414. Available at: http://ripublication.com/irph/ijict_spl/ijictv4n4spl_11.pdf (accessed 21 February 2021).
20. Aguinis H., Forcum L.E., Joo H. Using market basket analysis in management research // *Journal of Management*. 2013. Vol. 39. No. 7. P. 1799–1824. <https://doi.org/10.1177/0149206312466147>
21. Muhal H., Jain H. Two-stage customer segmentation using *k*-means clustering and artificial // *International Research Journal of Engineering and Technology*. 2021. Vol. 8. No. 3. P. 485–490.
22. Punhani R., Arora V.P.S., Sabitha S., Kumar Shukla V. Application of clustering algorithm for effective customer segmentation in E-Commerce // *Proceedings of the 2021 International Conference on Computational Intelligence and Knowledge Economy (ICCIKE)*, 17-18 March 2021, Dubai, United Arab Emirates. P. 149–154. <https://doi.org/10.1109/ICCIKE51210.2021.9410713>
23. Popović N., Savić A., Bjelobaba G., Veselinović R., Stefanović H., Ilić P.M. The implementation of hierarchical and nonhierarchical clustering for customer segmentation in one luxury goods company // *Proceedings of the 37th International Business Information Management Association (IBIMA)*, 30–31 May 2021, Cordoba, Spain. P. 8370–8381.
24. Aktaş A.A., Tunali O., Bayrak A.T. Comparative unsupervised clustering approaches for customer segmentation 2021 // *Proceedings of the 2021 2nd International Conference on Computing and Data Science (CDS)*, 28-29 Jan. 2021, Stanford, CA, USA. P. 530–535. <https://doi.org/10.1109/CDS52072.2021.00097>
25. Suresh Y., Senthilkumar J., Mohanraj V., Kesavan S. Customer segmentation using machine learning in python // *Turkish Journal of Physiotherapy and Rehabilitation*. 2021. Vol. 32. No. 3. P. 4338–4342. Available at: <https://turkjphysiotherrehabil.org/pub/pdf/321/32-1-521.pdf> (accessed 21 February 2021).
26. Pradana M., Ha H. Maximizing strategy improvement in mall customer segmentation using *k*-means clustering // *Journal of Applied Data Sciences*. 2021. Vol. 2. No. 1. P. 19–25. <https://doi.org/10.47738/jads.v2i1.18>
27. RStudio Team. RStudio: Integrated Development for R / RStudio, PBC, Boston, MA, 2020. Available at: <http://www.rstudio.com/> (accessed 21 February 2021).
28. Ngo T. Data mining: practical machine learning tools and technique, Third Edition by Ian H. Witten, Eibe Frank, Mark A. Hell // *ACM SIGSOFT Software Engineering Notes*. 2011. Vol. 36. No. 5. P. 51–52. <https://doi.org/10.1145/2020976.2021004>
29. Microsoft Corporation. Microsoft Excel. Available at: <https://office.microsoft.com/excel> (accessed 21 February 2021).

Об авторах

Нидхи Гаутам

PhD (Computer Science & Engineering);

Assistant Professor, Fellow Senate Panjab University, University Institute of Applied Management Sciences, Panjab University, Chandigarh, India;

E-mail: nidhi.uiams@pu.ac.in

ORCID: 0000-0002-9454-3625

Нитин Кумар

MBA (IT & Telecommunications);

Management Trainee, Housing Development Finance Corporation Limited, Pathankot, Punjab, India;

E-mail: nk2268913@gmail.com

ORCID: 0000-0002-8887-2350

DOI: [10.17323/2587-814X.2022.1.83.100](https://doi.org/10.17323/2587-814X.2022.1.83.100)

Centralized resource allocation based on energy saving and environmental pollution reduction using data envelopment analysis models

Sima Madadi^a

E-mail: sima.madadi@gmail.com

Farhad Hosseinzadeh Lotfi^{a*}

E-mail: farhad@hosseinzadeh.ir

Mehdi Fallah Jelodar^b

E-mail: Mehdi.fallah_jelodar@yahoo.com

Mohsen Rostamy-Malkhalifeh^a

E-mail: Mohsen_rostamy@yahoo.com

^a Department of Mathematics, Science and Research Branch, Islamic Azad University
Address: Shahid Sattari Square, Tehran 14515/775, Iran

^b Department of Mathematics, Ayatollah Amoli Branch, Islamic Azad University
Address: 5 Km of the old road from Amol to Babol, Amol 678, Iran

Abstract

Environmental pollution has caused governments to be concerned about energy saving and the reduction of environmental pollution. Some researchers have presented resource allocation models as multi-objective linear programming (MOLP) in order to pay more attention to energy saving and environmental pollution reduction. Energy saving affects both desirable and undesirable outputs. In this paper, we argue for the inapplicability of the existing models for reducing the undesirable outputs through energy saving. The purpose of this paper is to design a model based on data envelopment analysis (DEA) that would result in reduced pollution through energy saving. Moreover, since an undesirable output is considered as a function of the total desirable outputs, if necessary, the changes should be applied to the total desirable outputs and there is no need to reduce each desirable output individually. Finally, the model proposed based on goal programming (GP) is used in 20 different regions in China. The results produced by this model indicate that the reduction proportion of total environmental pollution emissions per energy saving was larger than the reduction proportion of total desirable outputs.

* Corresponding author

Keywords: resource allocation, data envelopment analysis, energy saving, environmental pollution, desirable output, undesirable output

Citation: Madadi S., Hosseinzadeh Lotfi F., Fallah Jelodar M., Rostamy-Malkhalifeh M. (2022) Centralized resource allocation based on energy saving and environmental pollution reduction using data envelopment analysis models. *Business Informatics*, vol. 16, no. 1, pp. 83–100. DOI: 10.17323/2587-814X.2022.1.83.100

Introduction

One of the outputs of industrial development is environmental pollution. Carbon dioxide gas accounts for about 60 percent of all greenhouse gases, and about 81 percent of all greenhouse gas emissions come from fossil fuel consumption. Fossil fuels, on the one hand, are the most important sources of energy for cities, while being the main source of pollution. Iran is one of the highest carbon emission-intensive countries in the world. Total CO₂ emissions in 1990 were 201.8 million metric tons (MMT), which has increased rapidly at an average annual rate of 5.7% to 372 MMT by 2003 [1].

The amount of particulate matters in the atmosphere is one of the most important indicators of air pollution. Aerosols have a great impact on the climate and human environment. Tropospheric aerosols, known as particulate matter, have an adverse effect on human health [2]. One of the atmospheric pollutants, sulfur dioxide, causes acid rain and many other adverse environmental effects and health hazards [3].

The main reason for the increasing CO₂ emissions in industries is high levels of energy consumption. Based on reports from the International Energy Agency [4], the global industrial sector is responsible for about 40% of total energy consumption in the world. Due to the raised awareness about environmental issues and technological advancements that help reduce environmental damage, there has been a decline in CO₂ emissions from industries in developed countries; however, such emissions are greatly increasing in developing countries [5].

Data envelopment analysis (DEA) is novel area of study, as well as a necessary mathematical tool for evaluating the relative efficiency of a set of homogenous decision-making units (DMU). This method has attracted a lot of attention in various fields of management sciences [6]. DEA, which is a non-parametric method, has had many applications in solving the problem of resource allocation when all DMUs are under the control of a single centralized decision maker (DM). There is no prior functional form in DEA, and there is no need for the many assumptions that emerge by using statistical methods for function estimation. At the same time, DEA produces good results when used in resource allocation [5, 7]. Many papers have

been presented based on DEA for allocating resources to a set of DMUs in which the purpose of the DM has been to minimize the total input consumption or to maximize the total output production of all DMUs instead of considering each one individually and set separate targets for each DMU. Centralized resource allocation was presented by [8] for the first time, which sought radical reduction in the total consumption of every input by all units. In [7], the authors designed a multi-objective model for resource allocation to find the maximum amount of production. They defined a transformation possibility set for each DMU with two assumptions; the first one was to assume that the unit's efficiency stays constant during the planning period, and the other assumption was that each unit could have a proportional scaling of changes in inputs and outputs. Later, [9] considered one of the models presented by [8] and modified it to adjust the inefficient units. The study [10] extended a simplified model of [8]. This model recognized more efficient units and was much simpler to execute than the previous models. The special characteristic of this model was that the centralized DM did not necessarily need to keep the original number of DMUs fixed. For other extensions of the model proposed by [8], one can refer to [11, 12]. Other proposed models for centralized resource allocation can be found in [13–15]. The study [14] proposed two ideas: one idea maximized the total efficiency, while the other one simultaneously maximized the output production and minimized the input consumption. In this method, the new efficiency of all DMUs becomes equal to one after production design; this efficiency improvement is not logical and feasible in practice. On the other hand, there is no guarantee that the inputs (outputs) will decrease (increase) significantly. Also, there is no logical connection between these changes and they may not be fair. In [16], the authors extended a method that implemented the demand and supply changes in a centralized decision-making environment under a predictable assumption. The study [17] presented a DEA model for centralized resource allocation with the assumption of adjustable and non-adjustable inputs and transferable and non-transferable outputs. Then, he analyzed the structural efficiency of the model using the structural efficiency analysis presented by [18]. The study [19] combined energy consumption reduction

through resource allocation with DEA models with undesirable outputs, and proposed a multi-objective model for resource allocation under energy saving constraints. Since energy saving decreases both the desirable and undesirable outputs, the aim of their model was to make the reduction proportion of the desirable outputs would be less than the reduction proportion of the harmful outputs. This way, recommendations can be made regarding energy and environmental policies toward saving energy and reducing air pollution. They also studied the classification of natural resources in China and used an input-oriented slacks-based model for measuring the efficiency of provinces [20]; then, they proposed a DEA-based approach for allocating the total natural resources. Unlike conventional DEA models, it seems necessary to consider both desirable and undesirable outputs in environmental performance evaluation [21].

Many of the findings of DEA studies have been used for environmental performance measurement. The study [22] focused on the analysis of optimal energy allocation and environmental performance of China's three major urban agglomerations. In particular, that study first used a fixed-input DEA model to obtain the optimal allocation of energy input. Then, an evaluation model based on the optimal allocation of energy input was proposed to evaluate the environmental performance. In [23], the researchers constructed an evaluation indicator system based on three stages, namely economic production, wastewater treatment, and human health, and used the undesirable three-stage dynamic data envelopment analysis model to empirically evaluate the total efficiency, stage efficiency, and the efficiency of various indicators.

Goal Programming (GP) is a developed form of Linear Programming. GP tries to achieve several goals simultaneously and allows deviation from the goal. Therefore, it has flexibility in decision-making processes. The main approach of GP is to allocate a special target value to each objective function and then look for a solution that would minimize unwanted deviations from the intended goals [24]. GP was used as a method for solving multi-objective problems with the aim of minimizing unwanted deviations from the set goals. There exist two main algorithms for solving a GP problem: the weighted sum model and the lexicographic model. The studies [25, 26] proposed using GP for MCDEA models. The difficulty in solving a multi-objective problem is finding a solution that would optimize all the objectives simultaneously [27]. Since there is no such solution in most cases, a non-dominated solution set is needed. Paper [25] proposed using the lexicographic model to solve GP problems and allocating priority to the objective functions of MCDEA.

In [26] was proposed the weighted goal programming method (GPDEA). The studies [28, 29] addressed the connections between multi-objective problems and DEA. Furthermore, there have been some models that maximized the efficiency of all DMUs simultaneously (e.g., [30–33]). Industrial production is always associated with energy consumption and greenhouse gas emission (the most important is CO₂ emission). As energy consumption decreases, the desirable output will also decrease, but when industrial estates are required by governments to reduce and control pollution, if energy storage does not lead to a reduction in environmental pollution, the model is not valid in the eyes of the central manager. In the centralized resource allocation model proposed by [19], we show that undesirable output changes become zero by saving energy. In this paper, we modify their model so that with a reduction in energy consumption, a significant reduction in CO₂ emission is achieved, and show that if the centralized DM considers boundaries for changes in the inputs and outputs, the model may be infeasible, since choosing suitably and feasibly will be a difficult task for the centralized DM. Therefore, the model is modified through GP in a way that makes it feasible.

On the other hand, the reduction of individual desirable outputs due to reductions in the undesirable outputs has the weakness that some undesirable outputs may have been out of the acceptable standard range. In such cases, some undesirable outputs may be reduced without any reduction in the desirable outputs.

What this paper proposes is that since an undesirable output is considered to be a function of the total desirable outputs, if necessary, the changes should be applied to the total desirable outputs. According to the above-mentioned, the innovations of this research are:

- ◆ Rectifying the infeasibility of the allocation model in cases where unsuitable boundaries are selected for the input/output changes, which are assigned by the DM.
- ◆ Modifying the pre-presented model and eliminating the weakness of the respective model in reducing the undesirable outputs.
- ◆ Presenting a new model that does not require the reduction of each and every desirable output in the units (production industries) in order to save energy and reduce pollution, since there could be a case where in a given region, some units have a large amount of undesirable outputs due to performance weaknesses, in which case the reduction of a portion of undesirable outputs in the entirety of units may not require a reduction of desirable outputs in all units.

The rest of the paper is organized as follows: In section 1 (Theoretical background), an introduction is provided to the conventional DEA model and the centralized resource allocation models, as well as the method of using GP to solve multi-objective problems. This section also discusses the defects of the previously mentioned model. In section 2 (Proposed model), we present our proposed model for centralized resource allocation with the aim of energy saving and reducing environmental pollution emissions. The advantages to the model are also included in this section. The application of GP in the proposed resource allocation model is illustrated through a numerical example in section 3 (Numerical example). Finally, some conclusions and remarks are provided.

1. Theoretical background

Data envelopment analysis (DEA) is a powerful tool for evaluating the relative efficiency of a set of DMUs that consume multiple inputs to produce multiple outputs. Suppose there are n DMUs that are in need of evaluation, and each one consumes m different inputs to produce s different outputs. Suppose $X_j = (x_{1j}, \dots, x_{mj})^T$ and $Y_j = (y_{1j}, \dots, y_{sj})^T$, $X_j \geq 0$, $Y_j \geq 0$ are the input and output vectors, respectively. The production possibility set T is defined as:

$$T = \{(x, y) \mid y \text{ can be produced from } x\}. \tag{1}$$

In [34] is defined the following PPS using the constant returns to scale (CRS) assumption.

$$T_{CCR} = \left\{ (x, y) \in R_{\geq 0}^{m+s} \mid \sum_{j=1}^n \lambda_j x_{ij} \leq x, \sum_{j=1}^n \lambda_j y_{rj} \geq y, \lambda_j \geq 0, j = 1, \dots, n \right\}. \tag{2}$$

The input-oriented model for evaluating DMU_o , $o \in \{1, \dots, n\}$ under the assumption of CRS can be achieved by solving the following ratio programming problem [34].

$$\begin{aligned} & \max \frac{\sum_{r=1}^s u_r y_{ro}}{\sum_{i=1}^m v_i x_{io}}, & (3) \\ \text{s.t.} & \frac{\sum_{r=1}^s u_r y_{ro}}{\sum_{i=1}^m v_i x_{io}} \leq 1, \\ & u_r, v_i \geq \varepsilon \quad r = 1, \dots, s, \quad i = 1, \dots, m. \end{aligned}$$

Here $\varepsilon > 0$ is a non-Archimedean element defined to be smaller than any positive real number.

GP provides the means for attempting to achieve several objectives simultaneously. Many researchers, including [28, 29, 35], have investigated the relationships between DEA and MOP. Several methods have been developed to solve multi-objective problems (see: [36–38]), one of which is Goal programming [24, 39].

1.1. Resource allocation models

In recent years, various applications of DEA have been seen in most countries around the world for the purposes of evaluating the performance of organizations and other common activities in different areas. In the context of planning and resource allocation, a number of optimization techniques have been introduced, such as multi-objective programming. The purpose of a central unit is to design a reasonable resource allocation mechanism that can bring the greatest benefits for the central organization [7, 40, 41]. In many real-world scenarios, all of the DMUs may be under the influence of a central decision maker who can supervise the resource consumption of these units. The main purpose of resource allocation is to allocate resources in such a way that the general goals of the organization are achieved as far as possible. Unlike conventional DEA models, [42] considered undesirable factors as an important factor in efficiency evaluation. The studies [43–45] suggested an alternative approach in environmental technology in which the desirable outputs increased while the undesirable outputs decreased. The study [19] considered both desirable and undesirable outputs in their evaluation, as there are undesirable outputs in the production process. Their model helped the DM allocate future resources while taking energy saving into account. They combined the energy consumption reduction targets with resource allocation and proposed a multi-objective programming model that not only reduced the undesirable outputs but also decreased the desirable outputs in order to improve the undesirable output production.

They defined the transformation possibility set as follows:

$$F_j = \left\{ \left(\begin{array}{l} x_j - \Delta x_j \\ y_j^g - \Delta y_j^g \\ y_j^b - \Delta y_j^b \end{array} \right) \mid \Delta y_j^g \geq \delta_j y_j^g, \Delta y_j^b \leq \delta_j y_j^b \right\}, \tag{4}$$

$$\delta_j = \max \left\{ \frac{\Delta x_{ij}}{x_{ij}} \mid i = 1, \dots, m \right\}.$$

Their model, based on the CRS assumption, is formulated as follows:

$$\begin{aligned} \min \quad & \Delta Y^g = \sum_{r=1}^{s_1} \sum_{j=1}^n \frac{\Delta y_{rj}^g}{\sum_{j=1}^n y_{rj}^g}, \\ \max \quad & \Delta X = \sum_{i=1}^m \sum_{j=1}^n \frac{\Delta x_{ij}}{\sum_{j=1}^n x_{ij}}, \end{aligned} \quad (5)$$

s.t.

$$\Delta y_j^g \geq \delta_j y_j^g, \quad j = 1, \dots, n, \quad (5-1)$$

$$\Delta y_j^b \leq \delta_j y_j^b, \quad j = 1, \dots, n, \quad (5-2)$$

$$\Delta x_j \leq \delta_j x_j, \quad j = 1, \dots, n, \quad (5-3)$$

$$y_j^g - \Delta y_j^g \leq Y^g \Lambda_j, \quad j = 1, \dots, n, \quad (5-4)$$

$$y_j^b - \Delta y_j^b \geq Y^b \Lambda_j, \quad j = 1, \dots, n, \quad (5-5)$$

$$x_j - \Delta x_j \geq X \Lambda_j, \quad j = 1, \dots, n, \quad (5-6)$$

$$A_j \leq \Delta y_j^g \leq B_j, \quad j = 1, \dots, n, \quad (5-7)$$

$$\Delta Y^b = \sum_{j=1}^n \Delta y_j^b \leq M. \quad (5-8)$$

Where the vectors

$$\begin{pmatrix} X_j - \Delta X_j \\ Y_j^g - \Delta Y_j^g \\ Y_j^b - \Delta Y_j^b \end{pmatrix} \in R_{\geq 0}^{m+s_1+s_2}$$

and the matrices X , Y^g , Y^b are defined as follows:

$$X = [x_1, x_2, \dots, x_n] \in R^{m \times n},$$

$$Y^g = [y_1^g, y_2^g, \dots, y_n^g] \in R^{s_1 \times n},$$

$$Y^b = [y_1^b, y_2^b, \dots, y_n^b] \in R^{s_2 \times n},$$

$$X > 0, Y^g > 0, Y^b > 0.$$

ΔX_j represents the saving amount of inputs in DMU_j , any Δy_j^g , Δy_j^b denote the reduction amounts of desirable and undesirable outputs in DMU_j , respectively. F_j (transformation possibility set) represents the capacity of input and output changes for DMU_j . $[A_j, B_j]$ indicates the capacity of desirable output changes, and M is the maximum emission reduction, which is determined by the DM.

2. Proposed model: resource allocation models based on goal programming

In Model (5), independent of what the value of δ_j^* (positive or zero) is in the optimal solution, in the con-

straints (5-2) and (5-8), $\Delta y_j^b = 0$ is true. It has also already been established that $\Delta y_j^b = 0$ is true in constraint (5-5). Therefore, in all constraints, $\Delta y_j^b = 0$ ($j = 1, \dots, n$) is a solution, and since it does not exist in the objective function, then $\Delta y_j^b = 0$ is always true, which indicates a defect in Model (5). Let us also assume that the manager considers the following goals:

$$A_j \leq \Delta x_j \leq B_j, \quad C_j \leq \Delta y_j^g \leq D_j,$$

$$\sum_{j=1}^n \Delta y_j^b \geq M, \quad A_j, B_j \in R_{\geq 0}^m,$$

$$C_j, D_j \in R_{\geq 0}^{s_1}, \quad M \in R_{\geq 0}^{s_2}.$$

If A_j , B_j , C_j , D_j , M for $j = 1, \dots, n$ are not chosen properly, Model (5) will be infeasible. In this paper, this model is modified using GP in a way that it becomes feasible and $\Delta y_j^b > 0$ is obtained.

Therefore, we define F_j as follows.

$$F_j = \left\{ \begin{pmatrix} x_j - \Delta x_j \\ y_j^g - \Delta y_j^g \\ y_j^b - \Delta y_j^b \end{pmatrix} \middle| \Delta y_j^g \geq \delta_j y_j^g, \quad \Delta y_j^b \geq \delta_j y_j^b \right\}, \quad (6)$$

$$\delta_j = \max \left\{ \frac{\Delta x_{ij}}{x_{ij}} \mid i = 1, \dots, m \right\}.$$

And assuming that the production possibility set remains unchanged in each step,

$$T = \left\{ (x, y^g, y^b) \in R_{\geq 0}^{m+s_1+s_2} \middle| \begin{aligned} x &\geq \sum_{j=1}^n \lambda_j x_j, y^g \leq \sum_{j=1}^n \lambda_j y_j^g, \\ y^b &\geq \sum_{j=1}^n \lambda_j y_j^b, \lambda_j \geq 0, j = 1, \dots, n \end{aligned} \right\}, \quad (7)$$

$$\Delta X = \sum_{i=1}^m \sum_{j=1}^n \frac{\Delta x_{ij}}{\sum_{j=1}^n x_{ij}}, \quad \Delta Y^g = \sum_{r=1}^{s_1} \sum_{j=1}^n \frac{\Delta y_{rj}^g}{\sum_{j=1}^n y_{rj}^g}. \quad (8)$$

Now, the resource allocation model is presented using GP as follows:

$$\begin{aligned} \min \quad & Z_1 = \sum_{j=1}^n (n_j^1 + n_j^2) + \sum_{j=1}^n (p_j^1 + p_j^2) + L, \\ \min \quad & Z_2 = \Delta Y^g, \\ \min \quad & Z_3 = \Delta X. \end{aligned} \quad (9)$$

s.t.

$$x_{ij} - \Delta x_{ij} \geq \sum_{l=1}^n \lambda_{jl} x_{il}, \quad j = 1, \dots, n, \quad i = 1, \dots, m, \quad (9-1)$$

$$y_{rj}^g - \Delta y_{rj}^g \leq \sum_{l=1}^n \lambda_{jl} y_{rl}^g, \quad j = 1, \dots, n, \quad r = 1, \dots, s_1, \quad (9-2)$$

$$y_{pj}^b - \Delta y_{pj}^b \geq \sum_{l=1}^n \lambda_{jl} y_{pl}^b, \quad j = 1, \dots, n, \quad p = 1, \dots, s_2, \quad (9-3)$$

$$\Delta x_{ij} \leq \delta_j x_{ij}, j = 1, \dots, n, i = 1, \dots, m, \quad (9-4)$$

$$\Delta y_{rj}^g \geq \delta_j y_{rj}^g, j = 1, \dots, n, r = 1, \dots, s_1, \quad (9-5)$$

$$\Delta y_{pj}^b \geq \delta_j y_{pj}^b, j = 1, \dots, n, p = 1, \dots, s_2 \quad (9-6)$$

$$\Delta y_j^g \geq C_j - n_j^1, j = 1, \dots, n, \quad (9-7)$$

$$\Delta y_j^g \leq D_j + n_j^2, j = 1, \dots, n, \quad (9-8)$$

$$\Delta x_j \geq A_j - p_j^1, j = 1, \dots, n, \quad (9-9)$$

$$\Delta x_j \leq B_j - p_j^2, j = 1, \dots, n, \quad (9-10)$$

$$\sum_{j=1}^n \Delta y_j^b \geq M - L, \quad (9-11)$$

$$\Delta y_j^g \leq y_j^g, j = 1, \dots, n, \quad (9-12)$$

$$\lambda_{jl} \geq 0, j = 1, \dots, n, l = 1, \dots, p,$$

where ΔY^g and ΔX are as defined in equation (8), and $n_j^1, n_j^2 \in R_{\geq 0}^{s_1}, p_j^1, p_j^2 \in R_{\geq 0}^m, L \in R_{\geq 0}^{s_2}, \Delta x_j = [\Delta x_{1j}, \Delta x_{2j}, \dots, \Delta x_{mj}]$, $\Delta y_j^g = [\Delta y_{1j}^g, \Delta y_{2j}^g, \dots, \Delta y_{s_1j}^g], \Delta y_j^b = [\Delta y_{1j}^b, \Delta y_{2j}^b, \dots, \Delta y_{s_2j}^b]$.

Constraints (9-1) – (9-3) in model (9) indicate that the reduced outputs and inputs belong to the PPS. Constraints (9-4) – (9-6) ensure that the changed output and input values for each DMU belong to its own transformation possibility set. In constraints (9-7) and (9-8), if the management’s expectation for Δy_j^g to fall within the interval of C_j, D_j is unattainable, the deviation variables n_j^1, n_j^2 will modify it and make the problem feasible. This is also true for constraints (9-9) – (9-11).

The optimal values of this model can be obtained in two steps. The first step is to obtain the minimum of the total deviation variables for the goal considered by the central manager, which is considered as the first priority for the problem to be feasible, and then obtain the optimal solution to this model using the lexicographic method. The second step is to obtain the weighted sum of the two next objective functions in order to minimize the desirable output reduction and maximize energy saving in the optimal solution obtained from the first step.

Theorem. $\Delta y_j^b > 0$ is true for all $j = 1, \dots, n$ that have a positive Δx_j .

Proof: Since $x_j > 0$ and $\Delta x_j > 0$ in constraint (9-4), $\delta_j > 0$ is true. On the other hand, based on constraint (9-6) and the fact that $y_j^b > 0$ and $\delta_j > 0$, we arrive at $\Delta y_j^b > 0$.

On the other hand, since an undesirable output is a function of the total desirable outputs, if necessary, the required changes shall be applied to the totality of the desirable outputs. Therefore, reducing individual desirable outputs is not logical, as some of the unde-

sirable outputs may have been out of the acceptable standard range. For example, the carbon monoxide gas produced in industrial plants in a geographical region would cause pollution in that region. However, reduced pollution may be achieved by a reduction in any one of the factories, so all factories are not necessarily forced to reduce their emissions. In this regard, the transformation possibility set defined in this paper will, in addition to energy saving, reduce the undesirable outputs following a minimum reduction in the total desirable outputs. Therefore, the set F is defined as a transformation possibility set for the total inputs and outputs as follows:

$$F = \left\{ \left(\begin{array}{l} \sum_{j=1}^n (x_j - \Delta x_j) \\ \sum_{j=1}^n (y_j^g - \Delta y_j^g) \\ \sum_{j=1}^n (y_j^b - \Delta y_j^b) \end{array} \right) \left| \begin{array}{l} \sum_{j=1}^n \Delta y_{rj}^g \geq \delta \sum_{j=1}^n y_{rj}^g, \\ \sum_{j=1}^n \Delta y_{pj}^b \geq \delta \sum_{j=1}^n y_{pj}^b \\ r = 1, \dots, s_1, p = 1, \dots, s_2 \end{array} \right. \right\}, \quad (10)$$

$$\delta_j = \max \left\{ \frac{\Delta x_{ij}}{x_{ij}} \mid i = 1, \dots, m \right\},$$

$$\delta = \min_j \delta_j$$

Now, by considering a tradeoff of reductions in the desirable and undesirable outputs and using GP, the centralized resource allocation model is presented as follows:

$$\min \quad Z_1 = \sum_{j=1}^n (n_j^1 + n_j^2) + \sum_{j=1}^n (p_j^1 + p_j^2) + L, \quad (11)$$

$$\min \quad Z_2 = \Delta Y^g,$$

$$\max \quad Z_3 = \Delta X,$$

s.t.

$$\sum_{j=1}^n (x_{ij} - \Delta x_{ij}) \geq \sum_{j=1}^n \sum_{l=1}^n \lambda_{jl} x_{il}, i = 1, \dots, m, \quad (11-1)$$

$$\sum_{j=1}^n (y_{rj}^g - \Delta y_{rj}^g) \leq \sum_{j=1}^n \sum_{l=1}^n \lambda_{jl} y_{rl}^g, r = 1, \dots, s_1, \quad (11-2)$$

$$\sum_{j=1}^n (y_{pj}^b - \Delta y_{pj}^b) \geq \sum_{j=1}^n \sum_{l=1}^n \lambda_{jl} y_{pl}^b, p = 1, \dots, s_2 \quad (11-3)$$

$$\Delta x_{ij} \leq \delta_j x_{ij}, j = 1, \dots, n, i = 1, \dots, m, \quad (11-4)$$

$$\sum_{j=1}^n \Delta y_{rj}^g \geq \delta \sum_{j=1}^n y_{rj}^g, r = 1, \dots, s_1, \quad (11-5)$$

$$\sum_{j=1}^n \Delta y_{pj}^b \geq \delta \sum_{j=1}^n y_{pj}^b, p = 1, \dots, s_2 \quad (11-6)$$

$$\delta \leq \delta_j, j = 1, \dots, n, \quad (11-7)$$

$$\Delta y_j^g \geq A_j - n_j^1, j = 1, \dots, n, \quad (11-8)$$

$$\Delta y_j^g \leq B_j + n_j^2, j = 1, \dots, n, \quad (11-9)$$

$$\Delta x_j \geq C_j - p_j^1, j = 1, \dots, n, \quad (11-10)$$

$$\Delta x_j \leq D_j + p_j^2, j = 1, \dots, n, \quad (11-10)$$

$$\sum_{j=1}^n \Delta y_j^b \geq M - L, \quad (11-12)$$

$$x_j - \Delta x_j \geq 0, y_j^g - \Delta y_j^g \geq 0, \quad (11-13)$$

$$y_j^g - \Delta y_j^g \geq 0, j = 1, \dots, n,$$

$$\lambda_{jl} \geq 0, j = 1, \dots, n, l = 1, \dots, p.$$

Constraints (11-1) – (11-3) in model (8) indicate that the total reduced outputs and inputs belong to the PPS. That is to say,

$$\begin{pmatrix} \sum_{j=1}^n (x_j - \Delta x_j) \\ \sum_{j=1}^n (y_j^g - \Delta y_j^g) \\ \sum_{j=1}^n (y_j^b - \Delta y_j^b) \end{pmatrix} \in T$$

and constraints (11-4) – (11-7) indicate that

$$\begin{pmatrix} \sum_{j=1}^n (x_j - \Delta x_j) \\ \sum_{j=1}^n (y_j^g - \Delta y_j^g) \\ \sum_{j=1}^n (y_j^b - \Delta y_j^b) \end{pmatrix} \in F.$$

In other words, it is guaranteed that the total changed values of inputs and outputs belong to the transformation possibility set for all inputs and outputs. Constraints (11-8) – (11-12) are conditions set by the central manager. The model above is converted to a model under variable returns to scale (VRS) assumption by adding $\sum_{l=1}^p \lambda_{jl} = 1$. The optimal values of model (11) can be obtained through prioritization.

Lemma 1. Models (9) and (11) are always feasible regardless of the goals set by the manager.

Proof: In Model (9), by choosing $\forall j, \forall l \lambda_{jl} = 0, x_j = 0, \Delta y_j^b = y_j^b, \Delta y_j^g = y_j^g, n_j^1 = A_j, n_j^2 = y_j^g, p_j^1 = C_j, p_j^2 = 0, L = M, \delta_j = 0.2$ we have a feasible solution to the model. Similarly, Model (11) is also feasible.

Lemma 2. If the first objective function receives a positive value in optimality, it means that the goals set by the manager are unreachable and deviation variables play an important role in the feasibility.

For the computational comparison of models (5) and (11), the conditions considered for changes in the inputs and outputs can be discarded, because in each problem, depending on the opinion of the central manager, these conditions may or may not apply. When the conditions imposed by the central manager are set aside in both models (constraints (5-7) and (5-8) in model (5), and constraints (11-8) and (11-13), then in model (11), we will have only the second and third objective functions, which are equivalent to both objective functions in model (5). As can be seen in the calculations *Table 1*, model (11) has less computational volume than model (5).

Table 1.

Comparison of the constraints of model (5) and model (11)

Model (5)	Number of constraints	Model (11)	Number of constraints
(5-1)	$s_1 \times n$	(11-1)	m
(5-2)	$s_2 \times n$	(11-2)	s_1
(5-3)	$m \times n$	(11-3)	s_2
(5-4)	$s_1 \times n$	(11-4)	$(m \times n)$
(5-5)	$s_2 \times n$	(11-5)	s_1
(5-6)	$m \times n$	(11-6)	s_2
		(11-7)	n
Total:	$(2s_1 + 2s_2 + 2m) \times n$	Total:	$2s_1 + 2s_2 + mn + m + n$

Even if the conditions imposed by the central manager are considered the same in each model, for model (5) to be always feasible, the first objective function of model (11) must be added to model (5), in which case since the model is solved by lexicography's prioritization method, the computational volume in both cases will be doubled, which again makes model (11) computationally eco-nomical, especially when the number of units is significant.

Advantages of model (11) compared with model (5):

1. While in model (5), $\Delta y^b = 0$ is obtained along with the reduction of energy, model (11) was changed so that Δy^b can receive a positive value (these have been proven at the beginning of part 2 and the theorem). That is, model (11) can reduce environmental pollution by reducing energy consumption, while model (5) cannot.

2. Even if the parameters are chosen inappropriately, the proposed model (11) is always feasible (due to the existence of deviation variables, while these variables do not exist in model (5)).

3. Since the undesirable outputs may not be within the acceptable standard range, Model (11) is not forced to reduce each desirable output individually. Thus, the required changes are applied to the totality of the desirable outputs and inputs.

4. The number of constraints is significantly reduced in model (11).

3. Numerical example

In this section, we apply Models (9) and (11) to a numerical example for the purposes of analysis. *Table 1* exhibits a simple data set for six DMUs that produce two outputs using one input (desirable and undesirable), which are under the supervision of a central management. We solve Model (9) and Model (11) under CRS and VRS assumptions by lexicography’s prioritization method. The first objective function is considered as the first priority for the problem to be feasible. In other words, $Z_1^* > 0$ means that the deviation variable makes the problem feasible, and if we had not considered the problem as GP, then it would be infeasible. The second step is to obtain the sum of the next two weighted objective functions in order to minimize desirable output reduction and maximize input saving in the optimal solution, which is obtained from the first step. *Table 2* shows the input and output data for the 6 DMUs. The following *Tables 3* and *4* provide the results of solving the model (9) using Gams software under CRS assumption and entering the parameters as $A_j = 0, B_j = 0.6x_j, c_j = 0, D_j = 0.3y_j^g, M = 0.8 \sum_{j=1}^n y_j^b$.

By solving the model (9), the optimal value obtained for the first objective function is $Z_1^* = 3.16$; this means that the deviation variables have played an important role in making the problem feasible, and if we did not consider the problem as a GP, then it would be infeasible. *Table 3* shows the reduced values of inputs and outputs, as well as the reduction proportion of each one. In general, the reduction proportion of inputs is 0.19, the reduction proportion of desirable outputs is 0.38, and the reduction proportion of undesirable outputs is 0.75, which shows that overall, the reduction proportion of undesirable outputs is larger than the reduction proportion of desirable outputs. *Table 4* presents the values allocated to the inputs and outputs (desirable and undesirable) after energy saving and reducing environmental pollutions for the purposes of providing recommendations to the central decision maker. Furthermore, the amount of reduction and the reduction proportion of inputs and outputs under VRS assumption model (9) are shown in *Table 5*.

Table 2.

Input and output data for illustrating the proposed models

Unit	x	y ^g	y ^b
A	3.00	2.00	2.00
B	4.20	3.00	7.10
C	2.70	4.00	5.00
D	5.00	6.00	4.50
E	6.00	4.00	2.00
F	3.80	2.00	5.00
Total	24.7	21	25.6

Table 3.

Reduction amounts of inputs and outputs under CRS assumption in model (9)

Unit	Δx	Δy ^g	Δy ^b	Reduction proportion		
				x	y ^g	y ^b
A	0.90	0.60	1.30	0.30	0.30	0.65
B	1.05	0.90	6.05	0.25	0.30	0.01
C	0.00	2.20	4.10	0.00	0.55	0.82
D	0.00	2.66	2.83	0.00	0.44	0.62
E	1.80	1.20	0.60	0.30	0.30	0.30
F	1.14	0.60	4.30	0.30	0.30	0.86
Total	4.89	8.16	19.18	0.19	0.38	0.75

Table 4.

Allocated values for inputs and outputs under CRS assumption in model (9)

Unit	$x - \Delta x$	$y^g - \Delta y^g$	$y^b - \Delta y^b$
A	2.10	1.40	0.70
B	3.15	2.10	1.05
C	2.70	1.80	0.90
D	5.00	3.33	1.66
E	4.20	2.80	1.40
F	2.66	1.40	0.70

Table 5.

Reduction amounts of inputs and outputs with VRS assumption model (9)

Unit	Δx	Δy^g	Δy^b	Reduction proportion		
				x	y^g	y^b
A	0.00	0.00	0.00	0.00	0.00	0.00
B	1.05	0.90	5.10	0.25	0.30	0.72
C	0.00	0.00	0.00	0.00	0.00	0.00
D	0.00	1.80	1.68	0.00	0.30	0.37
E	0.00	0.00	0.00	0.30	0.00	0.00
F	0.80	0.42	3.00	0.21	0.21	0.60
Total	1.85	3.12	9.78	0.07	0.14	0.38

Table 6.

Reduction amounts of inputs and outputs under CRS assumption in model (5)

Unit	Δx	Δy^b	Δy^g
A	0.90	0.60	0
B	1.26	0.90	0
C	0.00	0.00	0
D	0.00	0.00	0
E	1.80	1.20	0
F	1.14	0.60	0
Total	5.10	3.30	0

As can be observed, in some DMUs, the reduction proportion of desirable outputs exceeds the proportion that was considered, and the reduction proportion of undesirable outputs is less than the lower bound that was set. This is due to the existence of deviation variables that make the problem feasible. To compare model (9) with model (5), the results obtained by placing the above parameters in

model (5) are given in Table 6 (we even set the conditions for Δx to be the same conditions for both models). As can be seen from the results of Table 6, the amount of reduction in the undesirable outputs for each unit is zero. This is the weakness of the respective model, which does not allow the reduction of undesirable outputs by reducing the desirable outputs and desirable outputs of the model.

Table 7.

Reduction amounts of inputs and outputs with CRS assumption model (11)

Unit	Δx	Δy^g	Δy^b	Reduction proportion		
				x	y^g	y^b
A	1.80	0.60	2.00	0.60	0.30	1.00
B	0.85	0.90	7.10	0.20	0.30	1.00
C	0.00	1.20	5.00	0.00	0.30	1.00
D	0.00	1.80	4.15	0.00	0.30	0.92
E	0.00	1.20	0.00	0.00	0.30	0.00
F	0.00	0.60	0.00	0.00	0.30	0.00
Total	2.65	6.30	18.25	0.10	0.30	0.71

Table 8.

Results of Allocated value for inputs and outputs with CRS assumption model (11)

Unit	$x - \Delta x$	$y^g - \Delta y^g$	$y^b - \Delta y^b$
A	1.20	1.40	0.00
B	3.35	2.10	0.00
C	2.70	2.80	0.00
D	5.00	4.20	0.35
E	6.00	2.80	2.00
F	3.80	1.40	5.00

By solving Model (11), the optimal value obtained for the first objective function is $Z_1^* = 2.23$. In general, the reduction proportion of inputs is 0.10, the reduction proportion of desirable outputs is 0.30, and the reduction proportion of undesirable outputs is 0.71 (according to Table 7).

Table 8 provides the values allocated to the inputs and outputs (desirable and undesirable) after energy saving and reducing environmental pollution by considering a tradeoff of reductions in the inputs and outputs. Now we analyze our model through a real example of 20 Chinese regions. The values regarding China’s total fossil fuel energy consumption (i.e., raw coal, clean coal, briquettes, coke, coke oven gas, crude oil, gasoline, kerosene, fuel oil, diesel oil, refinery gas, liquefied petroleum gas and natural gas), non-fossil fuel consumption, CO₂ emissions and regional GDP were collected from [46]. These values are listed in Table 9.

As can be observed in Table 10, Model (11) has changed a number of inputs and outputs, not necessarily all of them. In general, for a 0.44 reduction in total energy consumption and a 0.04 reduction in non-fossil fuel consumption, we will have a 0.62 reduction in environmental pollution, whereas the desirable outputs are reduced by 0.30. These results provide important information to the decision maker, namely to reduce CO₂ emission by about 0.62 through saving energy in fossil fuel energy consumption by 0.44 and saving energy in Non-fossil fuel energy consumption by 0.04. This reduces the desirable output (GDP) by 0.30.

Conclusion

Controlling the pollution from manufacturing industries in developed and developing countries has become a common concern among researchers and governments. The use of DEA-based models as a powerful tool in problems of pollution reduction and energy consumption has attracted the attention of researchers. This also relates to the allocation of resources in organizations that have a central decision maker, such as the Ministry of Health, the Ministry of Education, and the World Health Organization, which are able to implement policies for their subdivisions. In these systems, the central manager is interested in evaluating all units individually at the same time, so that total input consumption is minimized or total desirable output production is maximized, or to achieve two or more goals as multi-objective functions. When energy consumption is reduced, it will affect both the desirable and undesirable outputs. Regarding environmental pollution control policies, if energy storage does not lead to a reduction in

Table 9.

The data set are compiled from 30 regions of China in 2005 [51]

Unit	Total fossil fuel Energy consumption (million tce)	Non-fossil fuel consumption (million tce)	GDP (billion RMB at 2005) (million tce)	CO ₂ emissions (million tone)
1	55.2	2.6	697.0	110.5
2	41.2	0.5	390.6	99.3
3	197.5	3.7	1001.2	507.1
4	123.1	1.8	423.1	307.1
5	96.4	1.2	390.5	266.5
6	146.9	4.3	804.7	334.2
7	59.6	3.8	362.0	162.7
8	80.3	2.7	551.4	172.2
9	80.7	1.4	924.8	179.7
10	169.0	2.1	1859.9	425.0
11	120.3	14.1	1341.8	254.4
12	65.2	1.0	535.0	162.7
13	61.6	10.3	655.5	133.4
14	42.9	3.5	405.7	104.1
15	236.1	2.6	1836.7	579.3
16	146.3	3.0	1058.7	337.2
17	98.5	11.3	659.0	197.2
18	91.1	10.9	659.6	191.6
19	177.7	19.5	2255.7	352.8
20	49.8	8.5	398.4	112.1
Total	2139.4	108.8	17211.3	4989.1

environmental pollution, this indicates that the model has a weakness and needs to be modified. A model had already been proposed that did not reduce environmental pollution by reducing energy consumption, and hence, we modified the model to reduce environmental pollution. Depending on the decision of the central manager to adopt a policy based on energy saving and reduced environmental pollution emissions, in this paper we developed two new general centralized resource allocation models that the manager can choose from. The first model is modified such that Δy^b can receive a positive value and become feasible. The second model is defined based on the idea that the required changes should be applied to the totality of the desirable outputs.

It is not logical to reduce individual desirable outputs, as the reduction of undesirable outputs may not be within the acceptable standard range. In each of the presented models, the undesirable outputs are changed by a larger proportion than the desirable outputs. We added goal programming to the problem so as to prevent the infeasibility of the problem. We also analyzed our model through a real example of 20 Chinese regions. The results showed that the proposed methods significantly reduced the CO₂ emissions compared with the competing model. These models can be effective in preventing energy waste and protecting the environment. The second EU (European Union) clean air outlook report looks at the prospects for EU member states' air quality up to

Table 10.

Results of Allocated value for inputs and outputs with model (11)

Unit	Allocation value				Reduction proportion			
	Total fossil fuel Energy consumption (million tce)	Non-fossil fuel consumption (million tce)	GDP (billion RMB at 2005) (million tce)	CO ₂ emissions (million tone)	x_1	x_2	y^s	y^b
1	22	1.04	490	0.00	0.59	0.60	0.30	1.00
2	16	0.35	270	0.00	0.60	0.29	0.30	1.00
3	79	1.48	700	0.00	0.60	0.60	0.30	1.00
4	49	1.80	300	0.00	0.60	0.00	0.30	1.00
5	39	0.48	270	0.00	0.60	0.60	0.30	1.00
6	59	4.30	560	0.59	0.59	0.00	0.29	1.00
7	24	3.80	250	0.00	0.60	0.00	0.30	1.00
8	32	2.70	390	0.00	0.59	0.00	0.30	1.00
9	32	1.40	650	0.00	0.59	0.00	0.30	1.00
10	68	2.10	130	0.00	0.59	0.00	0.30	1.00
11	48	14.1	940	0.00	0.59	0.00	0.29	1.00
12	26	1.0	370	0.00	0.59	0.00	0.30	1.00
13	25	10.3	655.5	0.00	0.60	0.00	0.30	0.89
14	17	3.50	460	104.1	0.60	0.00	0.29	0.00
15	190	2.60	280	579.3	0.20	0.00	0.30	0.00
16	59	3.00	130	337.2	0.60	0.00	0.30	0.00
17	39	11.30	740	197.2	0.59	0.00	0.30	0.00
18	36	10.90	460	191.6	0.60	0.00	0.30	0.00
19	71	19.50	1600	352.8	0.62	0.00	0.30	0.00
20	20	8.50	280	112.1	0.60	0.00	0.30	0.00
Total					0.44	0.04	0.30	0.60

2050. According to the European Commission targets, by 2030, the amount of greenhouse gases in EU member states will be reduced by 55% compared with 1990 [47]. To achieve this target, manufacturing industries in the EU must purchase permits to produce a certain amount of greenhouse gases. Any industrial unit that produces less harmful gas than its allowed amount can sell its remaining permits to other units and benefit from it. Any plant that produces more harmful gas than its allowed amount will have to buy more permits. In other words, there is a trade-off between industrial units. Therefore,

the authors suggest the model presented in this paper to reduce pollution in industrial units under the supervision of the EU. The total amount of permits issued can be considered as the amount obtained after reallocation for environmental pollution in model (11). This means that the allowable amount of pollution considered for all industrial units should be equal to the allocated amount of undesirable outputs from model (11), and the same number of permits should be issued. Furthermore, the proposed models are applicable to any similar system to reduce pollution and save energy. ■

References

1. Sabetghadam M. (2006) Energy and sustainable development in Iran. In: *Sustainable Energy watch. HELIO International*. Available at: <https://sustainabledevelopment.un.org/content/documents/854Iran-EN.pdf>
2. Wang Z., Chen L., Tao J., Zhang L., Su L. (2010) Satellite-based Estimation of regional particulate matter (PM) in Beijing using vertical-and-RH correcting method. *Remote of Environment*, vol. 114, pp. 50–63. <https://doi.org/10.1016/j.rse.2009.08.009>
3. Song X.-D., Wang S., Hao C., Qiu J. (2014) Investigation of SO₂ gas adsorption in metal-organic frameworks by molecular simulation. *Inorganic Chemistry Communications*, vol. 46, pp. 277–281. <https://doi.org/10.1016/j.inoche.2014.06.003>
4. *CO₂ emissions from fuel combustion: Overview 2020* (2020) International Energy Agency (IEA). Available at: [https://enerji.mmo.org.tr/wp-content/uploads/2020/08/IEA-CO₂ Emissions_from_Fuel_Combustion_Overview_2020_edition.pdf](https://enerji.mmo.org.tr/wp-content/uploads/2020/08/IEA-CO2_Emissions_from_Fuel_Combustion_Overview_2020_edition.pdf)
5. Wu J., Zhu Q., Liang L. (2016) CO₂ emissions and energy intensity reduction allocation over provincial industrial sectors in China. *Applied Energy*, vol. 166, pp. 282–291. <https://doi.org/10.1016/j.apenergy.2016.01.008>
6. Emrouznejad A., Yang G.L. (2018) A survey and analysis of the first 40 years of scholarly literature in DEA: 1978–2016. *Socio-Economic Planning Sciences*, vol. 61, pp. 4–8. <https://doi.org/10.1016/j.seps.2017.01.008>
7. Korhonen P., Syrjanen M. (2004) Resource allocation based on efficiency analysis. *Management Science*, vol. 50, pp. 1134–1144. <https://doi.org/10.1287/mnsc.1040.0244>
8. Lozano S., Villa G. (2004) Centralized resource allocation using data envelopment analysis. *Journal of Productivity Analysis*, vol. 22, pp. 143–161. <https://doi.org/10.1023/B:PROD.0000034748.22820.33>
9. Asmild M., Paradi J.C., Pastor J.T. (2009) Centralized resource allocation BCC models. *Omega*, vol. 37, pp. 40–49. <https://doi.org/10.1016/j.omega.2006.07.006>
10. Mar-Molinero C., Prior D., Segovia M.M. et al. (2009) On centralized resource utilization and its reallocation by using DEA. *Annals of Operations Research*, vol. 221, pp. 273–283. <https://doi.org/10.1007/s10479-012-1083-8>
11. Lozano S., Villa G., Canca D. (2011) Application of centralized DEA approach to capital budgeting in Spanish ports. *Computers & Industrial Engineering*, vol. 60, pp. 455–465. <https://doi.org/10.1016/j.cie.2010.07.029>
12. Lotfi F.H., Noora A.A., Jahanshahloo G.R., Geramias J., Mozaffari M.R. (2010) Centralized resource allocation for enhanced Russell models. *Journal of Computational and Applied Mathematics*, vol. 235, no. 1, pp. 1–10. <https://doi.org/10.1016/j.cam.2010.05.029>
13. Fang L., Zhang C.Q. (2008) Resource allocation based on the DEA model. *Journal of the Operational Research Society*, vol. 59, no. 8, pp. 1136–1141.
14. Du J., Liang L., Chen Y., Bi G. (2010) DEA-based production planning. *Omega*, vol. 38, pp. 105–112. <https://doi.org/10.1016/j.omega.2009.07.001>
15. Du J., Cook W.D., Liang L., Zhu J. (2014) Fixed cost and resource allocation based on DEA cross-efficiency. *European Journal of Operational Research*, vol. 235, no. 1, pp. 206–214. <https://doi.org/10.1016/j.ejor.2013.10.002>
16. Amirteimoori A., Kordrostami S. (2012) Production planning in data envelopment analysis. *International Journal of Production Economics*, vol. 140, no. 1, pp. 212–218. <https://doi.org/10.1016/j.ijpe.2011.09.025>
17. Fang L. (2013) A generalized DEA model for centralized resource allocation. *European Journal of Operational Research*, vol. 228, no. 2, pp. 405–412. <https://doi.org/10.1016/j.ejor.2013.01.049>
18. Li S.-k., Cheng Y.-s. (2007) Solving the puzzle of structural efficiency. *European Journal of Operational Research*, vol. 180, no. 2, pp. 713–722. <https://doi.org/10.1016/j.ejor.2006.05.010>
19. Hong L., Yang W., Zhou Z., Huang C. (2013) Resource allocation model's construction for the reduction of undesirable outputs based on DEA methods. *Mathematical and Computer Modelling*, vol. 58, nos. 5–6, pp. 913–926. <https://doi.org/10.1016/j.mcm.2012.10.026>
20. Zhu Q., Wu J., Li X., Xiong B. (2017) China's regional natural resource allocation and utilization a DEA-based approach in a big data environment. *Journal of Cleaner Production*, vol. 142, no. 2, pp. 809–818. <https://doi.org/10.1016/j.jclepro.2016.02.100>
21. Wang H., Bi J., Wheeler D., Wang J., Cao D., Lu G., Wang Y. (2004) Environmental performance rating and disclosure: China's Green Watch program. *Journal of Environmental Management*, vol. 71, no. 2, pp. 123–133. <https://doi.org/10.1016/j.jenvman.2004.01.007>
22. Sun J., Wang Z., Zhu Q. (2020) Analysis of resource allocation and environmental performance in China's three major urban agglomerations. *Environmental Science and Pollution Research*, vol. 27, pp. 34289–34299. <https://doi.org/10.1007/s11356-020-09665-5>
23. Shi Z., Huang H., Chiu Yh., et al. (2021) Linkage analysis of water resources, wastewater pollution, and health for regional sustainable development – using undesirable three-stage dynamic data envelopment analysis. *Environmental Science and Pollution Research*, vol. 28, pp. 19325–19350. <https://doi.org/10.1007/s11356-020-12067-2>
24. Tamiz M., Jones D., Romero C. (1998) Goal programming for decision making: An overview of the current state-of-the-art. *European Journal of Operational Research*, vol. 111, pp. 569–581. [https://doi.org/10.1016/S0377-2217\(97\)00317-2](https://doi.org/10.1016/S0377-2217(97)00317-2)
25. Bal H., Örkücü H.H. (2007) A goal programming approach to weight dispersion in data envelopment analysis. *Gazi University Journal of Science*, vol. 20, pp. 117–125. Available at: <https://dergipark.org.tr/en/pub/gujs/issue/7399/96859>
26. Bal H., Örkücü H.H., Celebioglu S. (2010) Improving the discrimination power and weights dispersion in the data envelopment analysis. *Computers and Operations Research*, vol. 37, pp. 99–107. <https://doi.org/10.1016/j.cor.2009.03.028>
27. Ghasemi M.-R., Ignatius J., Emrouznejad A. (2014) A bi-objective weighted model for improving the discrimination power in MCDEA. *European Journal of Operational Research*, vol. 233, pp. 640–650. <https://doi.org/10.1016/j.ejor.2013.08.041>

28. Yang J.B., Wong B.Y.H., Xu, D.-L., Stewart T.J. (2009) Integrating DEA-oriented performance assessment and target setting using interactive MOLP methods. *European Journal of Operational Research*, vol. 195, pp. 205–222. <https://doi.org/10.1016/j.ejor.2008.01.013>
29. Lotfi F.H., Jahanshaloo G.R., Ebrahimnejad A., Soltanifar M., Manosourzadeh S.M. (2010) Target setting in the general combined-oriented CCR model using an interactive MOLP method. *Journal of Computational and Applied Mathematics*, vol. 234, pp. 1–9. <https://doi.org/10.1016/j.cam.2009.11.045>
30. Jahanshaloo G.R., Lotfi F.H., Moradi M. (2005) A DEA approach for fair allocation of common revenue. *Applied Mathematics and Computation*, vol. 160, pp. 719–724. <https://doi.org/10.1016/j.amc.2003.11.027>
31. Chiang C.I., Hwang M.J., Liu Y.H. (2011) Determining a common set of weights in DEA problem using a separation vector. *Mathematical and computer modeling*, vol. 54, pp. 2464–2470. <https://doi.org/10.1016/j.mcm.2011.06.002>
32. Lotfi F.H., Hatami-Marbini A., Agrell P.J., Aghayi N., Gholami K. (2013) Allocating fixed resources and setting targets using a common-weights DEA approach. *Computers & Industrial Engineering*, vol. 64, no. 2, pp. 631–640. <https://doi.org/10.1016/j.cie.2012.12.006>
33. Fang L., Li H. (2015) Multi-criteria decision analysis for efficient location-allocation problem combining DEA and goal programming. *RAIRO-Operations Research*, vol. 49, pp. 753–772. <https://doi.org/10.1051/ro/2015003>
34. Charnes A., Cooper W.W., Rhodes E. (1978) Measuring the efficiency of decision making units. *European Journal of Operational Research*, vol. 2, pp. 429–444.
35. Golany B. (1988) An interactive MOLP procedure for the extension of DEA to effectiveness analysis. *The Journal of the Operational Research Society*, vol. 39, no. 8, pp. 725–734. <https://doi.org/10.1057/jors.1988.127>
36. Hwang C.L., Masud A.S.M. (1979) *Multiple objective decision making – Methods and applications: A State-of-the-art survey*. Springer, Berlin, Heidelberg. <https://doi.org/10.1007/978-3-642-45511-7>
37. Steuer R.E. (1986) *Multiple criteria optimization: Theory, computation, and application*. New York: Wiley.
38. Hatami-Marbini A., et al. (2015) A common weights data envelopment analysis for centralized resource reduction and target setting. *Computers & Industrial Engineering*, vol. 79, pp. 195–203. <https://doi.org/10.1016/j.cie.2014.10.024>
39. Davoodi A., Zhiani Rezai H. (2012) Common set of weights in data envelopment analysis: a linear programming problem. *Central European Journal of Operational Research*, vol. 20, no. 2, pp. 355–365. <https://doi.org/10.1007/s10100-011-0195-6>
40. Athanassopoulos D. (1995) Goal programming & data envelopment analysis (GODEA) for target-based multi-level planning: Allocating central grants to the Greek local authorities. *European Journal of Operational Research*, vol. 87, no. 3, pp. 535–550. [https://doi.org/10.1016/0377-2217\(95\)00228-6](https://doi.org/10.1016/0377-2217(95)00228-6)
41. Golany B., Tamir E. (1995) Evaluating efficiency-effectiveness-equality trade-offs: A data envelopment analysis approach. *Management Science*, vol. 41, no. 7, pp. 1172–1184. Available at: <http://www.jstor.org/stable/2632774>
42. Seiford L.M., Zhu J. (2002) Modeling undesirable factors in efficiency evaluation. *European Journal of Operational Research*, vol. 142, no. 1, pp. 16–20. [https://doi.org/10.1016/S0377-2217\(01\)00293-4](https://doi.org/10.1016/S0377-2217(01)00293-4)
43. Färe, R., Grosskopf, S. and Hernandez-Sancho, F. (2004) Environmental performance: an index number approach. *Resource and Energy Economics*, vol. 26, no. 4, pp. 343–352. <https://doi.org/10.1016/j.reseneeco.2003.10.003>
44. Zhou P., Ang B.W., Poh K.L. (2008) Measuring environmental performance under different environmental DEA technologies. *Energy Economics*, vol. 30, no. 1, pp. 1–14. <https://doi.org/10.1016/j.eneco.2006.05.001>
45. Wang J., Wang S., Li S., Cai Q., Gao S. (2019) Evaluating the energy-environment efficiency and its determinants in Guangdong using a slack-based measure with environmental undesirable outputs and panel data model. *Science of the Total Environment*, vol. 663, pp. 878–888. <https://doi.org/10.1016/j.scitotenv.2019.01.413>
46. Wang K., Zhang X., Wei Y.-M., Yu S. (2013) Regional allocation of CO₂ emissions allowance over provinces in china by 2020. *Energy policy*, vol. 54, pp. 214–229. <https://doi.org/10.1016/j.enpol.2012.11.030>
47. Jager-Waldau A., Kougias I., Taylor N., Thiel Ch. (2020) How photovoltaic can contribute to GHG emission reductions of 55% in the EU by 2030. *Renewable and Sustainable Energy Reviews*, vol. 126, Article ID 109836. <https://doi.org/10.1016/j.rser.2020.109836>

About the authors

Sima Madadi

Doctoral Student, Department of Mathematics, Science and Research Branch, Islamic Azad University, Shahid Sattari Square, Tehran 14515/775, Iran;

E-mail: sima.madadi@gmail.com

ORCID: 0000-0002-2558-7501

Farhad Hosseinzadeh Lotfi

Ph.D.

Professor, Department of Mathematics, Science and Research Branch, Islamic Azad University, Shahid Sattari Square, Tehran 14515/775, Iran;

Editor-in-Chief, Journal of New Research in Mathematics, Science and Research Branch, Islamic Azad University Square, Shohadaye Hesarak Boulevard, North Sattari Highway, Tehran, Iran;

E-mail: farhad@hosseinzadeh.ir

ORCID: 0000-0001-5022-553X

Mehdi Fallah Jelodar

Ph.D.

Associate Professor, Department of Mathematics, Ayatollah Amoli Branch, Islamic Azad University, 5 Km of the old road from Amol to Babol, Amol 678, Iran;

Email: Mehdi.fallah_jelodar@yahoo.com

ORCID: 0000-0002-8473-564X

Mohsen Rostamy-Malkhalifeh

Ph.D.

Associate Professor, Department of Mathematics, Science and Research Branch, Islamic Azad University, Shahid Sattari Square, Tehran 14515/775, Iran;

Editor-in-Chief, International Journal of Data Envelopment Analysis (IJDEA), Science and Research Branch, Daneshgah Blvd, Simon Bulivar Blvd, Tehran, Iran;

E-mail: Mohsen_rostamy@yahoo.com

ORCID: 0000-0001-6105-7674

Централизованное распределение ресурсов на основе энергосбережения и снижения загрязнения окружающей среды с применением моделей анализа среды функционирования

С. Мадади^a

E-mail: sima.madadi@gmail.com

Ф. Хоссейзаде Лотфи^{a*}

E-mail: farhad@hosseinzadeh.ir

М. Фаллах Джелодар^b

E-mail: Mehdi.fallah_jelodar@yahoo.com

М. Ростами-Малхалифех^a

E-mail: Mohsen_rostamy@yahoo.com

^a Department of Mathematics, Science and Research Branch, Islamic Azad University
Адрес: Shahid Sattari Square, Tehran 14515/775, Iran

^b Department of Mathematics, Ayatollah Amoli Branch, Islamic Azad University
Адрес: 5 Km of the old road from Amol to Babol, Amol 678, Iran

* Автор, ответственный за переписку

Аннотация

В настоящее время уровень загрязнения окружающей среды заставляет правительства задумываться об энергосбережении и сокращении негативного влияния на природу. Некоторыми исследователями разработаны модели распределения ресурсов в виде многоцелевого линейного программирования, чтобы уделять больше внимания энергосбережению и снижению загрязнения окружающей среды. В то же время энергосбережение приводит как к желаемым, так и к нежелательным результатам. Для снижения нежелательных результатов энергосбережения в данной статье мы приводим аргументы, подтверждающие неприменимость существующих моделей. Целью статьи является разработка модели, основанной на анализе среды функционирования (data envelopment analysis, DEA), которая привела бы к снижению загрязнения за счет экономии энергии. Более того, поскольку нежелательный результат рассматривается как функция общих желаемых результатов, требуемые изменения должны быть направлены на общие желаемые результаты, без необходимости уменьшения каждого из желаемых результатов в отдельности. В результате предложенная модель, основанная на целевом программировании (goal programming, GP), используется в двадцати различных регионах Китая. Результаты, полученные с помощью модели, показывают, что доля сокращения общих выбросов загрязняющих веществ в окружающую среду в соотношении с экономией энергии была больше, чем доля сокращения общих желаемых результатов.

Ключевые слова: распределение ресурсов, анализ среды функционирования, энергосбережение, загрязнение окружающей среды, желаемый результат, нежелательный результат

Цитирование: Madadi S., Hosseinzadeh Lotfi F., Fallah Jelodar M., Rostamy-Malkhalifeh M. Centralized resource allocation based on energy saving and environmental pollution reduction using data envelopment analysis models // *Business Informatics*. 2022. Vol. 16. No. 1. P. 83–100. DOI: 10.17323/2587-814X.2022.1.83.100

Литература

1. Sabetghadam M. Energy and sustainable development in Iran // In: Sustainable Energy watch. HELIO International. 2006. [Электронный ресурс]: <https://sustainabledevelopment.un.org/content/documents/854Iran-EN.pdf>
2. Wang Z., Chen L., Tao J., Zhang L., Su L. Satellite-based Estimation of regional particulate matter (PM) in Beijing using vertical-and-RH correcting method // *Remote of Environment*. 2010. Vol. 114. P. 50–63. <https://doi.org/10.1016/j.rse.2009.08.009>
3. Song X.-D., Wang S., Hao C., Qiu J. Investigation of SO₂ gas adsorption in metal-organic frameworks by molecular simulation // *Inorganic Chemistry Communications*. 2014. Vol. 46. P. 277–281. <https://doi.org/10.1016/j.inoche.2014.06.003>
4. CO₂ emissions from fuel combustion: Overview 2020 / International Energy Agency (IEA). 2020. [Электронный ресурс]: [https://enerji.mmo.org.tr/wp-content/uploads/2020/08/IEA-CO₂_Emissions_from_Fuel_Combustion_Overview_2020_edition.pdf](https://enerji.mmo.org.tr/wp-content/uploads/2020/08/IEA-CO2_Emissions_from_Fuel_Combustion_Overview_2020_edition.pdf)
5. Wu J., Zhu Q., Liang L. CO₂ emissions and energy intensity reduction allocation over provincial industrial sectors in China // *Applied Energy*. 2016. Vol. 166. P. 282–291. <https://doi.org/10.1016/j.apenergy.2016.01.008>
6. Emrouznejad A., Yang G.L. A survey and analysis of the first 40 years of scholarly literature in DEA: 1978–2016 // *Socio-Economic Planning Sciences*. 2018. Vol. 61. P. 4–8. <https://doi.org/10.1016/j.seps.2017.01.008>
7. Korhonen P., Syrjanen M. Resource allocation based on efficiency analysis // *Management Science*. 2004. Vol. 50. P. 1134–1144. <https://doi.org/10.1287/mnsc.1040.0244>
8. Lozano S., Villa G. Centralized resource allocation using data envelopment analysis // *Journal of Productivity Analysis*. 2004. Vol. 22. P. 143–161. <https://doi.org/10.1023/B:PROD.0000034748.22820.33>
9. Asmild M., Paradi J.C., Pastor J.T. Centralized resource allocation BCC models // *Omega*. 2009. Vol. 37. P. 40–49. <https://doi.org/10.1016/j.omega.2006.07.006>
10. Mar-Molinero C., Prior D., Segovia M.M. et al. On centralized resource utilization and its reallocation by using DEA // *Annals of Operations Research*. 2009. Vol. 221. P. 273–283. <https://doi.org/10.1007/s10479-012-1083-8>
11. Lozano S., Villa G., Canca D. Application of centralized DEA approach to capital budgeting in Spanish ports // *Computers & Industrial Engineering*. 2011. Vol. 60. P. 455–465. <https://doi.org/10.1016/j.cie.2010.07.029>
12. Lotfi F.H., Noora A.A., Jahanshahloo G.R., Geramias J., Mozaffari M.R. Centralized resource allocation for enhanced Russell models // *Journal of Computational and Applied Mathematics*. 2010. Vol. 235. No. 1. P. 1–10. <https://doi.org/10.1016/j.cam.2010.05.029>
13. Fang L., Zhang C.Q. Resource allocation based on the DEA model // *Journal of the Operational Research Society*. 2008. Vol. 59. No. 8. P. 1136–1141.
14. Du J., Liang L., Chen Y., Bi G. DEA-based production planning // *Omega*. 2010. Vol. 38. P. 105–112. <https://doi.org/10.1016/j.omega.2009.07.001>

15. Du J., Cook W.D., Liang L., Zhu J. Fixed cost and resource allocation based on DEA cross-efficiency // *European Journal of Operational Research*. 2014. Vol. 235. No. 1. P. 206–214. <https://doi.org/10.1016/j.ejor.2013.10.002>
16. Amirteimoori A., Kordrostami S. Production planning in data envelopment analysis // *International Journal of Production Economics*. 2012. Vol. 140. No. 1. P. 212–218. <https://doi.org/10.1016/j.ijpe.2011.09.025>
17. Fang L. A generalized DEA model for centralized resource allocation // *European Journal of Operational Research*. 2013. Vol. 228. No. 2. P. 405–412. <https://doi.org/10.1016/j.ejor.2013.01.049>
18. Li S.-k., Cheng Y.-s. Solving the puzzle of structural efficiency // *European Journal of Operational Research*. 2007. Vol. 180. No. 2. P. 713–722. <https://doi.org/10.1016/j.ejor.2006.05.010>
19. Hong L., Yang W., Zhou Z., Huang C. Resource allocation model's construction for the reduction of undesirable outputs based on DEA methods // *Mathematical and Computer Modelling*. 2013. Vol. 58. Nos. 5–6. P. 913–926. <https://doi.org/10.1016/j.mcm.2012.10.026>
20. Zhu Q., Wu J., Li X., Xiong B. China's regional natural resource allocation and utilization a DEA-based approach in a big data environment // *Journal of Cleaner Production*. 2017. Vol. 142. No. 2. P. 809–818. <https://doi.org/10.1016/j.jclepro.2016.02.100>
21. Wang H., Bi J., Wheeler D., Wang J., Cao D., Lu G., Wang Y. Environmental performance rating and disclosure: China's Green Watch program // *Journal of Environmental Management*. 2004. Vol. 71. No. 2. P. 123–133. <https://doi.org/10.1016/j.jenvman.2004.01.007>
22. Sun J., Wang Z., Zhu Q. Analysis of resource allocation and environmental performance in China's three major urban agglomerations // *Environmental Science and Pollution Research*. 2020. Vol. 27. P. 34289–34299. <https://doi.org/10.1007/s11356-020-09665-5>
23. Shi Z., Huang H., Chiu Yh., et al. Linkage analysis of water resources, wastewater pollution, and health for regional sustainable development – using undesirable three-stage dynamic data envelopment analysis // *Environmental Science and Pollution Research*. 2021. Vol. 28. P. 19325–19350. <https://doi.org/10.1007/s11356-020-12067-2>
24. Tamiz M., Jones D., Romero C. Goal programming for decision making: An overview of the current state-of-the-art // *European Journal of Operational Research*. 1998. Vol. 111. P. 569–581. [https://doi.org/10.1016/S0377-2217\(97\)00317-2](https://doi.org/10.1016/S0377-2217(97)00317-2)
25. Bal H., Örkücü H.H. A goal programming approach to weight dispersion in data envelopment analysis // *Gazi University Journal of Science*. 2007. Vol. 20. P. 117–125. [Электронный ресурс]: <https://dergipark.org.tr/en/pub/gujs/issue/7399/96859>
26. Bal H., Örkücü H.H., Celebioglu S. Improving the discrimination power and weights dispersion in the data envelopment analysis // *Computers and Operations Research*. 2010. Vol. 37. P. 99–107. <https://doi.org/10.1016/j.cor.2009.03.028>
27. Ghasemi M.-R., Ignatius J., Emrouznejad A. A bi-objective weighted model for improving the discrimination power in MCDEA // *European Journal of Operational Research*. 2014. Vol. 233. P. 640–650. <https://doi.org/10.1016/j.ejor.2013.08.041>
28. Yang J.B., Wong B.Y.H., Xu, D.-L., Stewart T.J. Integrating DEA-oriented performance assessment and target setting using interactive MOLP methods // *European Journal of Operational Research*. 2009. Vol. 195. P. 205–222. <https://doi.org/10.1016/j.ejor.2008.01.013>
29. Lotfi F.H., Jahanshaloo G.R., Ebrahimnejad A., Soltanifar M., Manosourzadeh S.M. Target setting in the general combined-oriented CCR model using an interactive MOLP method // *Journal of Computational and Applied Mathematics*. 2010. Vol. 234. P. 1–9. <https://doi.org/10.1016/j.cam.2009.11.045>
30. Jahanshaloo G.R., Lotfi F.H., Moradi M. A DEA approach for fair allocation of common revenue // *Applied Mathematics and Computation*. 2005. Vol. 160. P. 719–724. <https://doi.org/10.1016/j.amc.2003.11.027>
31. Chiang C.I., Hwang M.J., Liu Y.H. Determining a common set of weights in DEA problem using a separation vector // *Mathematical and computer modeling*. 2011. Vol. 54. P. 2464–2470. <https://doi.org/10.1016/j.mcm.2011.06.002>
32. Lotfi F.H., Hatami-Marbini A., Agrell P.J., Aghayi N., Gholami K. Allocating fixed resources and setting targets using a common-weights DEA approach // *Computers & Industrial Engineering*. 2013. Vol. 64. No. 2. P. 631–640. <https://doi.org/10.1016/j.cie.2012.12.006>
33. Fang L., Li H. Multi-criteria decision analysis for efficient location-allocation problem combining DEA and goal programming // *RAIRO-Operations Research*. 2015. Vol. 49. P. 753–772. <https://doi.org/10.1051/ro/2015003>
34. Charnes A., Cooper W.W., Rhodes E. Measuring the efficiency of decision making units // *European Journal of Operational Research*. 1978. Vol. 2. P. 429–444.
35. Golany B. An interactive MOLP procedure for the extension of DEA to effectiveness analysis // *The Journal of the Operational Research Society*. 1988. Vol. 39. No. 8. P. 725–734. <https://doi.org/10.1057/jors.1988.127>
36. Hwang C.L., Masud A.S.M. Multiple objective decision making – Methods and applications: A State-of-the-art survey. Springer, Berlin, Heidelberg, 1979. <https://doi.org/10.1007/978-3-642-45511-7>
37. Steuer R.E. Multiple criteria optimization: Theory, computation, and application. New York: Wiley, 1986.
38. Hatami-Marbini A., et al. A common weights data envelopment analysis for centralized resource reduction and target setting // *Computers & Industrial Engineering*. 2015. Vol. 79. P. 195–203. <https://doi.org/10.1016/j.cie.2014.10.024>
39. Davoodi A., Zhiani Rezai H. Common set of weights in data envelopment analysis: a linear programming problem // *Central European Journal of Operational Research*. 2012. Vol. 20. No. 2. P. 355–365. <https://doi.org/10.1007/s10100-011-0195-6>
40. Athanassopoulos D. Goal programming & data envelopment analysis (GODEA) for target-based multi-level planning: Allocating central grants to the Greek local authorities // *European Journal of Operational Research*. 1995. Vol. 87. No. 3. P. 535–550. [https://doi.org/10.1016/0377-2217\(95\)00228-6](https://doi.org/10.1016/0377-2217(95)00228-6)
41. Golany B., Tamir E. Evaluating efficiency-effectiveness-equality trade-offs: A data envelopment analysis approach // *Management Science*. 1995. Vol. 41. No. 7. P. 1172–1184. [Электронный ресурс]: <http://www.jstor.org/stable/2632774>
42. Seiford L.M., Zhu J. Modeling undesirable factors in efficiency evaluation // *European Journal of Operational Research*. 2002. Vol. 142. No. 1. P. 16–20. [https://doi.org/10.1016/S0377-2217\(01\)00293-4](https://doi.org/10.1016/S0377-2217(01)00293-4)

43. Färe, R., Grosskopf, S. and Hernandez-Sancho, F. Environmental performance: an index number approach // *Resource and Energy Economics*. 2004. Vol. 26. No. 4. P. 343–352. <https://doi.org/10.1016/j.reseneeco.2003.10.003>
44. Zhou P., Ang B.W., Poh K.L. Measuring environmental performance under different environmental DEA technologies // *Energy Economics*. 2008. Vol. 30. No. 1. P. 1–14. <https://doi.org/10.1016/j.eneco.2006.05.001>
45. Wang J., Wang S., Li S., Cai Q., Gao S. Evaluating the energy-environment efficiency and its determinants in Guangdong using a slack-based measure with environmental undesirable outputs and panel data model // *Science of the Total Environment*. 2019. Vol. 663. P. 878–888. <https://doi.org/10.1016/j.scitotenv.2019.01.413>
46. Wang K., Zhang X., Wei Y.-M., Yu S. Regional allocation of CO2 emissions allowance over provinces in china by 2020 // *Energy policy*. 2013. Vol. 54. P. 214–229. <https://doi.org/10.1016/j.enpol.2012.11.030>
47. Jager-Waldau A., Kougias I., Taylor N., Thiel Ch. How photovoltaic can contribute to GHG emission reductions of 55% in the EU by 2030 // *Renewable and Sustainable Energy Reviews*. 2020. Vol. 126. Article ID 109836. <https://doi.org/10.1016/j.rser.2020.109836>

Об авторах

Сима Мадади

Doctoral Student, Department of Mathematics, Science and Research Branch, Islamic Azad University, Shahid Sattari Square, Tehran 14515/775, Iran;
 E-mail: sima.madadi@gmail.com
 ORCID: 0000-0002-2558-7501

Фархад Хоссейнзаде Лотфи

Ph.D.
 Professor, Department of Mathematics, Science and Research Branch, Islamic Azad University, Shahid Sattari Square, Tehran 14515/775, Iran;
 Editor-in-Chief, Journal of New Research in Mathematics, Science and Research Branch, Islamic Azad University Square, Shohadaye Hesarak Boulevard, North Sattari Highway, Tehran, Iran;
 E-mail: farhad@hosseinzadeh.ir
 ORCID: 0000-0001-5022-553X

Мехди Фаллах Джелодар

Ph.D.
 Associate Professor, Department of Mathematics, Ayatollah Amoli Branch, Islamic Azad University, 5 Km of the old road from Amol to Babol, Amol 678, Iran;
 E-mail: Mehdi.fallah_jelodar@yahoo.com
 ORCID: 0000-0002-8473-564X

Мохсен Ростами-Малхалифе

Ph.D.
 Associate Professor, Department of Mathematics, Science and Research Branch, Islamic Azad University, Shahid Sattari Square, Tehran 14515/775, Iran;
 Editor-in-Chief, International Journal of Data Envelopment Analysis (IJDEA), Science and Research Branch, Daneshgah Blvd, Simon Bulivar Blvd, Tehran, Iran;
 E-mail: Mohsen_rostamy@yahoo.com
 ORCID: 0000-0001-6105-7674