

ISSN 2713-3192
DOI 10.15622/ia.2023.22.1
<http://ia.spcras.ru>

TOM 22 № 1


ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ

INFORMATICS AND AUTOMATION



СПб ФИЦ РАН

Санкт-Петербург
2023



INFORMATICS AND AUTOMATION

Volume 22 № 1, 2023

Scientific and educational journal primarily specialized in computer science, automation, robotics, applied mathematics, interdisciplinary research

Founded in 2002

Founder and Publisher

St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS)

Editor-in-Chief

R. M. Yusupov, Prof., Dr. Sci., Corr. Member of RAS, St. Petersburg, Russia

Editorial Council

A. A. Ashimov	Prof., Dr. Sci., Academician of the National Academy of Sciences of the Republic of Kazakhstan, Almaty, Kazakhstan
N. P. Veselkin	Prof., Dr. Sci., Academician of RAS, St. Petersburg, Russia
I. A. Kalyaev	Prof., Dr. Sci., Academician of RAS, Taganrog, Russia
Yu. A. Merkuruyev	Prof., Dr. Sci., Academician of the Latvian Academy of Sciences, Riga, Latvia
A. I. Rudskoi	Prof., Dr. Sci., Academician of RAS, St. Petersburg, Russia
V. Sgurev	Prof., Dr. Sci., Academician of the Bulgarian Academy of Sciences, Sofia, Bulgaria
B. Ya. Sovetov	Prof., Dr. Sci., Academician of RAE, St. Petersburg, Russia
V. A. Soyfer	Prof., Dr. Sci., Academician of RAS, Samara, Russia

Editorial Board

O. Yu. Gusikhin	Ph. D., Dearborn, USA
V. Delic	Prof., Dr. Sci., Novi Sad, Serbia
A. Dolgui	Prof., Dr. Sci., St. Etienne, France
M. N. Favorskaya	Prof., Dr. Sci., Krasnoyarsk, Russia
M. Zelezny	Assoc. Prof., Ph.D., Plzen, Czech Republic
H. Kaya	Assoc. Prof., Ph.D., Utrecht, Netherlands
A. A. Karpov	Assoc. Prof., Dr. Sci., St. Petersburg, Russia
S. V. Kuleshov	Dr. Sci., St. Petersburg, Russia
A. D. Khomonenko	Prof., Dr. Sci., St. Petersburg, Russia
D. A. Ivanov	Prof., Dr. Habil., Berlin, Germany
K. P. Markov	Assoc. Prof., Ph.D., Aizu, Japan
R. V. Meshcheryakov	Prof., Dr. Sci., Moscow, Russia
N. A. Moldovian	Prof., Dr. Sci., St. Petersburg, Russia
V. V. Nikulin	Prof., Ph.D., New York, United States
V. Yu. Osipov	Prof., Dr. Sci., St. Petersburg, Russia
V. K. Pshikhopov	Prof., Dr. Sci., Taganrog, Russia
A. L. Ronzhin	Prof., Dr. Sci., Deputy Editor-in-Chief, St. Petersburg, Russia
H. Samani	Assoc. Prof., Ph.D., Plymouth, UK
A. V. Smirnov	Prof., Dr. Sci., St. Petersburg, Russia
B. V. Sokolov	Prof., Dr. Sci., St. Petersburg, Russia
L. V. Utkin	Prof., Dr. Sci., St. Petersburg, Russia

Editor: A.S. Lopotova

Interpreter: Ya.N. Berezina

Art editor: N.A. Dormidontova

Editorial office address

SPC RAS, 39 litera A , 14-th line V.O., St. Petersburg, 199178, Russia

e-mail: ia@spcras.ru, web: <http://ia.spcras.ru>

The journal is indexed in Scopus

The journal is published under the scientific-methodological supervision of Department for Nanotechnologies and Information Technologies of the Russian Academy of Sciences

© St. Petersburg Federal Research Center of the Russian Academy of Sciences, 2023

ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ

Том 22 № 1 , 2023

Научный, научно-образовательный журнал с базовой специализацией в области информатики, автоматизации, робототехники, прикладной математики и междисциплинарных исследований.

Журнал основан в 2002 году

Учредитель и издатель

Федеральное государственное бюджетное учреждение науки
«Санкт-Петербургский Федеральный исследовательский центр Российской академии наук»
(СПб ФИЦ РАН)

Главный редактор

Р. М. Юсупов, чл.-корр. РАН, д-р техн. наук, проф., Санкт-Петербург, РФ

Редакционный совет

А. А. Ашимов	академик Национальной академии наук Республики Казахстан, д-р техн. наук, проф., Алматы, Казахстан
Н. П. Веселкин	академик РАН, д-р мед. наук, проф., Санкт-Петербург, РФ
И. А. Каляев	академик РАН, д-р техн. наук, проф., Таганрог, РФ
Ю. А. Меркурьев	академик Латвийской академии наук, д-р, проф., Рига, Латвия
А. И. Рудской	академик РАН, д-р техн. наук, проф., Санкт-Петербург, РФ
В. Сгурев	академик Болгарской академии наук, д-р техн. наук, проф., София, Болгария
Б. Я. Советов	академик РАО, д-р техн. наук, проф., Санкт-Петербург, РФ
В. А. Сойфер	академик РАН, д-р техн. наук, проф., Самара, РФ

Редакционная коллегия

О. Ю. Гусихин	д-р наук, Диаборн, США
В. Делич	д-р техн. наук, проф., Нови-Сад, Сербия
А. Б. Долгий	д-р наук, проф. Сент-Этьен, Франция
М. Железны	д-р наук, доцент, Пльзень, Чешская республика
Д. А. Иванов	д-р экон. наук, проф., Берлин, Германия
Х. Кайя	д-р наук, доцент, Утрехт, Нидерланды
А. А. Карпов	д-р техн. наук, доцент, Санкт-Петербург, РФ
С. В. Кулешов	д-р техн. наук, Санкт-Петербург, РФ
К. П. Марков	д-р наук, доцент, Аизу, Япония
Р. В. Мещеряков	д-р техн. наук, проф., Москва, РФ
Н. А. Молдовян	д-р техн. наук, проф., Санкт-Петербург, РФ
В.В. Никулин	д-р наук, проф., Нью-Йорк, США
В.Ю. Осипов	д-р техн. наук, проф., Санкт-Петербург, РФ
В. Х. Пшихолопов	д-р техн. наук, проф., Таганрог, РФ
А. Л. Ронжин	д-р техн. наук, проф., зам. главного редактора, Санкт-Петербург, РФ
Х. Самани	д-р наук, доцент, Плимут, Соединённое Королевство
А. В. Смирнов	д-р техн. наук, проф., Санкт-Петербург, РФ
Б. В. Соколов	д-р техн. наук, проф., Санкт-Петербург, РФ
Л. В. Уткин	д-р техн. наук, проф., Санкт-Петербург, РФ
М. Н. Фаворская	д-р техн. наук, проф., Красноярск, РФ
А. Д. Хомоненко	д-р техн. наук, проф., Санкт-Петербург, РФ
Л. Б. Шереметов	д-р техн. наук, Мехико, Мексика

Выпускающий редактор: А.С. Лопотова

Переводчик: Я.Н. Березина

Художественный редактор: Н.А. Дормидонтова

Адрес редакции

14-я линия В.О., д. 39, лит. А, г. Санкт-Петербург, 199178, Россия

e-mail: ia@spcras.ru, сайт: <http://ia.spcras.ru>

Журнал индексируется в международной базе данных Scopus

Журнал входит в «Перечень ведущих рецензируемых научных журналов и изданий, в которых должны быть опубликованы основные научные результаты диссертации на соискание ученой степени доктора и кандидата наук»

Журнал выпускается при научно-методическом руководстве Отделения нанотехнологий и информационных технологий Российской академии наук

© Федеральное государственное бюджетное учреждение науки

«Санкт-Петербургский Федеральный исследовательский центр Российской академии наук», 2023
Разрешается воспроизведение в прессе, а также сообщение в эфир или по кабелю опубликованных в составе печатного периодического издания - журнала «ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ» статей по текущим экономическим, политическим, социальным и религиозным вопросам с обязательным указанием имени автора статьи и печатного периодического издания журнала «ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ»

CONTENTS

Robotics, Automation and Control Systems

A. Agafonov, A. Yumaganov COOPERATIVE CONTROL OF TRAFFIC SIGNALS AND VEHICLE TRAJECTORIES	5
N. Gryaznov NAVIGATION DATA EXCHANGE FOR TRAFFIC CONTROL	33
S. Patil, Y. Patil, S. Patil REVIEW ON AUTOMATIC VARIABLE-RATE SPRAYING SYSTEMS BASED ON ORCHARD CANOPY CHARACTERIZATION	57
E. Shmalko MACHINE-SYNTHEZIZED CONTROL OF NONLINEAR DYNAMIC OBJECT BASED ON OPTIMAL POSITIONING OF EQUILIBRIUM POINTS	87
Artificial Intelligence, Knowledge and Data Engineering	
S. Eremeev, A. Abakumov, D. Andrianov, T. Shirabakina VECTORIZATION METHOD OF SATELLITE IMAGES BASED ON THEIR DECOMPOSITION BY TOPOLOGICAL FEATURES	110
A. Ivashko, G. Safonov MACHINE LEARNING MODEL FOR DETERMINATION OF THE OPTIMAL STRATEGY IN AN ONLINE AUCTION	146
A. Obukhov, A. Volkov, N. Vekhteva, K. Patutin, A. Nazarova, D. Dedov THE METHOD OF FORMING A DIGITAL SHADOW OF THE HUMAN MOVEMENT PROCESS BASED ON THE COMBINATION OF MOTION CAPTURE SYSTEMS	168
V. Stoliarova, T. Tulupyeva, M. Abramov, V. Salakhova IDENTIFICATION OF CHARACTERISTICS OF EMPLOYEE'S INDIVIDUAL HUMAN CAPITAL WITH DATA ON SELF-REPORTS OF PROFESSIONAL SKILLS AND PERSONAL CHARACTERISTICS	190

СОДЕРЖАНИЕ

Робототехника, автоматизация и системы управления

- А.А. Агафонов, А.С. Юмаганов
СОВМЕСТНОЕ УПРАВЛЕНИЕ СИГНАЛАМИ СВЕТОФОРОВ И
ТРАЕКТОРИЯМИ ДВИЖЕНИЯ ТРАНСПОРТНЫХ СРЕДСТВ 5
- Н.А. Грязнов
ОБМЕН НАВИГАЦИОННОЙ ИНФОРМАЦИЕЙ ДЛЯ ОПЕРАТИВНОГО
УПРАВЛЕНИЯ ДОРОЖНЫМ ДВИЖЕНИЕМ 33
- С.С. Патил, Ю.М. Патил, С.Б. Патил
ОБЗОР АВТОМАТИЧЕСКИХ СИСТЕМ ОПРЫСКИВАНИЯ С
ПЕРЕМЕННОЙ СКОРОСТЬЮ, ОСНОВАННОЙ НА АНАЛИЗЕ
ХАРАКТЕРИСТИК РАСТИТЕЛЬНОГО ПОКРОВА ФРУКТОВОГО САДА 57
- Е.Ю. Шмалько
МАШИННО СИНТЕЗИРОВАННОЕ УПРАВЛЕНИЕ НЕЛИНЕЙНЫМ
ДИНАМИЧЕСКИМ ОБЪЕКТОМ НА ОСНОВЕ ОПТИМАЛЬНОГО
РАСПОЛОЖЕНИЯ ТОЧЕК РАВНОВЕСИЯ 87
- Искусственный интеллект, инженерия данных и знаний**
- С.В. Еремеев, А.В. Абакумов, Д.Е. Андрианов, Т.А. Ширабакина
МЕТОД ВЕКТОРИЗАЦИИ СПУТНИКОВЫХ СНИМКОВ НА ОСНОВЕ ИХ
РАЗЛОЖЕНИЯ ПО ТОПОЛОГИЧЕСКИМ ОСОБЕННОСТЯМ 110
- А.А. Ивашко, Г.Р. Сафонов
МОДЕЛЬ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОПРЕДЕЛЕНИЯ
ОПТИМАЛЬНОЙ СТРАТЕГИИ В ОНЛАЙН-АУКЦИОНЕ 146
- А.Д. Обухов, А.А. Волков, Н.А. Вехтева, К.И. Патутин, А.О. Назарова,
Д.Л. Дедов
МЕТОД ФОРМИРОВАНИЯ ЦИФРОВОЙ ТЕНИ ПРОЦЕССА
ПЕРЕМЕЩЕНИЯ ЧЕЛОВЕКА НА ОСНОВЕ ОБЪЕДИНЕНИЯ СИСТЕМ
ЗАХВАТА ДВИЖЕНИЙ 168
- В.Ф. Столярова, Т.В. Тулупьева, М.В. Абрамов, В.Б. Салахова
ВЫЯВЛЕНИЕ ХАРАКТЕРИСТИК ИНДИВИДУАЛЬНОГО
ЧЕЛОВЕЧЕСКОГО КАПИТАЛА СОТРУДНИКОВ ОРГАНИЗАЦИИ ПО
ДАННЫМ САМООТЧЕТОВ О ПРОФЕССИОНАЛЬНЫХ НАВЫКАХ И
ЛИЧНОСТНЫМ ОСОБЕННОСТЯМ 190

А.А. АГАФОНОВ, А.С. ЮМАГАНОВ
**СОВМЕСТНОЕ УПРАВЛЕНИЕ СИГНАЛАМИ СВЕТОФОРОВ И
ТРАЕКТОРИЯМИ ДВИЖЕНИЯ ТРАНСПОРТНЫХ СРЕДСТВ**

Агафонов А.А., Юмаганов А.С. Совместное управление сигналами светофоров и траекториями движения транспортных средств.

Аннотация. Транспортная система является одной из важнейших частей экономики страны. В то же время, рост интенсивности транспортного потока оказывает существенное отрицательное влияние на экономические показатели отрасли. Одним из способов повышения эффективности использования транспортной инфраструктуры является управление транспортными потоками. Решение задачи эффективного управления транспортными потоками в настоящее время часто осуществляется путем применения систем управления сигналами светофоров на регулируемых перекрестках. В связи с развитием и постепенным внедрением самоорганизующихся автомобильных сетей, позволяющих обмениваться информацией между транспортными средствами и объектами инфраструктуры, а также развитием автономных транспортных средств другим перспективным подходом к решению рассматриваемой задачи является управление траекторией движения беспилотных транспортных средств. Как следствие, становится возможной постановка задачи совместного управления траекториями движения транспортных средств и сигналами светофоров для повышения пропускной способности перекрестков, снижения потребляемого топлива и времени движения. В данной работе представлен метод управления транспортным потоком на перекрестке, заключающийся в совместном управлении сигналами светофоров и траекториями движения подключенных/автономных транспортных средств. Разработанный метод сочетает метод адаптивного управления сигналами светофоров, основанный на детерминированной модели прогнозирования движения транспортных средств, и двухэтапный алгоритм построения траектории движения транспортных средств. Целевая функция оптимизации, используемая для построения оптимальных траекторий, учитывает расход топлива, время движения по дорожной полосе и время ожидания на перекрестке. Экспериментальные исследования разработанного метода проведены в системе микроскопического моделирования движения транспортных средств SUMO с использованием трех сценариев моделирования, включающих синтетические сценарии и сценарий движения в реальной городской среде. Результаты экспериментальных исследований подтверждают эффективность разработанного метода по критериям потребления топлива, времени движения и времени ожидания по сравнению с методом адаптивного управления сигналами светофоров.

Ключевые слова: траектории движения, управление сигналами светофоров, совместное управление, детерминированная модель, интеллектуальная транспортная система.

1. Введение. Транспортная система является одной из самых важных отраслей экономики многих стран. Согласно данным [1] в странах Евросоюза на долю транспортной системы приходится в среднем около 5% валового внутреннего продукта (ВВП). В России в 2021 году на эту отрасль экономики пришлось 6% ВВП [2]. При этом на экономические показатели транспортной отрасли экономики существенное отрицательное влияние оказывает рост интенсивности

транспортного потока. Согласно аналитическому отчету компании INRIX [3], прогнозируемые потери экономики Великобритании вследствие заторов на дорогах к 2030 году составят 21,4 миллиарда фунтов стерлингов в год. Помимо этого, заторы на дорогах также пагубно влияют на здоровье участников движения [4], способствуют загрязнению окружающей среды [5] и повышают потребление топлива участниками движения [6]. Проблема дорожных заторов также актуальна и для России. По данным Единой межведомственной информационно-статистической системы [7], количество зарегистрированных транспортных средств в Российской Федерации за последние 10 лет увеличилось примерно на 35%. Всего в Российской Федерации на конец 2021 года зарегистрировано более 57 млн. транспортных средств [7]. Такая тенденция роста количества транспортных средств обуславливает необходимость в разработке новых эффективных средств контроля транспортного потока, в т.ч., в составе интеллектуальных транспортных систем [8].

Одним из наиболее распространенных способов решения проблем с заторами на дорогах является применение регулируемого управления на перекрестках. Существуют различные алгоритмы управления светофорами. Один из простейших подходов к управлению светофорным объектом основан на переключении фаз по фиксированному, заранее определенному расписанию. Ввиду того, что интенсивность движения транспортных средств с течением времени часто меняется, такой подход малоэффективен. Более сложные алгоритмы максимизируют пропускную способность перекрестка, используя различную информацию о текущей дорожной ситуации на прилегающих к перекрестку проезжих частях.

В связи с развитием автономных транспортных средств перспективным подходом к решению задач, связанных с эффективным контролем транспортного потока, является контроль движения подключенных беспилотных транспортных средств на регулируемых светофорами перекрестках. Использование технологии подключенных транспортных средств позволяет транспортным средствам обмениваться информацией друг с другом и с окружающей их дорожной инфраструктурой. Подобные технологии уже сейчас активно используются для обмена информацией между водителями о состоянии транспортного потока [9]. Подключенные беспилотные транспортные средства для осуществления движения могут использовать не только информацию, получаемую с различного рода собственных датчиков, но и информацию, получаемую с датчиков ближайших подключенных транспортных средств. Такая информация

также может быть использована, например, для построения надёжного кратчайшего маршрута движения транспортного средства (ТС) [10]. Таким образом, возможность беспилотного ТС осуществлять обмен информацией с другими участниками движения и дорожной инфраструктурой, позволяет безопасно управлять траекторией движения такого транспортного средства на перекрестке.

В настоящей работе представлен метод управления транспортным потоком на перекрестке, использующий совместно подход, основанный на управлении сигналами светофорного объекта, и один из перспективных подходов, основанный на управлении траекторией движения подключенных беспилотных транспортных средств. Работа построена следующим образом. Во втором разделе представлен обзор известных методов и алгоритмов управления транспортным потоком на регулируемых перекрестках. В третьем разделе введены основные понятия и обозначения, представлен предлагаемый метод совместного управления сигналами светофоров и траекториями движения транспортных средств на перекрестке. В четвертом разделе представлены результаты экспериментальных исследований разработанного метода в системе моделирования SUMO [11], продемонстрированы результаты анализа эффективности предлагаемого метода. В заключение работы приведены выводы, представлен список используемой литературы.

2. Современное состояние исследований. Обзор современного состояния исследований по теме совместного управления сигналами светофоров и траекториями движения транспортных средств состоит из трех этапов. На первом этапе был проведен обзор литературы, посвященный задаче построения траектории движения транспортных средств. Далее были рассмотрены основные подходы к управлению сигналами светофоров, включая детерминированные методы и методы на основе машинного обучения с подкреплением. На третьем этапе были рассмотрены работы, посвященные решению задачи совместного управления. Рассмотрим каждую задачу подробнее.

2.1. Построение траектории движения. На городских перекрестках транспортные средства, прибывающие на красный сигнал светофора, часто останавливаются максимально близко к стоп-линии перекрестка, а затем начинают разгоняться, когда светофор загорится зеленым. Такой характер движения увеличивает время в пути и расход топлива транспортных средств, а также снижает пропускную способность перекрестка. При соответствующем планировании траектории беспилотные транспортные средства могут заранее снизить скорость, чтобы избежать остановок и очередей у

перекрестка, снизить расход топлива. Применение методов и алгоритмов формирования траектории движения автономных подключенных транспортных средств направлено на улучшение различных характеристик транспортного потока. В качестве таких характеристик часто используются: безопасность [12], комфорт [13], эффективность [14], расход топлива [15], воздействие на окружающую среду [16].

В работах [17, 18] представлены методы построения траекторий движения автономных подключенных транспортных средств на нерегулируемых перекрестках. В рамках данной группы методов управление движением транспортных средств осуществляется не только на входящей в перекресток дорожной полосе, но и непосредственно на перекрестке. Такой подход к управлению движением транспортных средств допускает возможность резкого торможения транспортных средств с целью избегания столкновения, так как характер движения ТС до въезда в контролируемую зону перекрестка не учитывается. Так же стоит отметить, что данная группа методов не допускает наличие на перекрестке управляемых человеком транспортных средств и пешеходных переходов.

Авторы [19] предложили эвристический алгоритм, который позволяет эффективно сглаживать траектории потока транспортных средств, приближающихся к регулируемому перекрестку, путем управления их скоростью движения. Этот алгоритм формирует для каждого транспортного средства на перекрестке траекторию движения, состоящую из нескольких сегментов аналитических квадратичных кривых. Таким образом, он эффективно строит большое количество траекторий транспортных средств с учетом накладываемых физических ограничений, траекторий движения впереди идущего транспортного средства и сигналов светофорного объекта на перекрестке. В работе [12] данный алгоритм используется для построения оптимальных траекторий движения. В этой работе целевая функция оптимизации, используемая для построения оптимальных траекторий, учитывает расход топлива, время движения по дорожной полосе и безопасность движения.

Способ управления движением транспортного средства, при котором минимизируется расход топлива и негативное воздействие на окружающую среду, называют эко-вождением (eco-driving) [20]. Динамический подход к эко-вождению представлен в [21]. Авторы разработали алгоритм формирования тригонометрического профиля скорости транспортного средства. Данный алгоритм не только минимизирует расход топлива и количество выбросов углекислого

газа в атмосферу, но и не допускает резкого торможения/ускорения, что способствует повышению комфорта езды. В [20] разработана модель эко-вождения для гибридных электромобилей в условиях перегруженного городского движения. При формировании траектории движения транспортных средств данная модель учитывает прогнозируемую загруженность перекрестка.

В данной работе в качестве алгоритма построения траектории движения транспортных средств на регулируемом перекрестке используется модифицированный вариант алгоритма [19]. Данный алгоритм позволяет эффективно строить траектории движения транспортных средств на полосах движения, прилегающих к регулируемым перекресткам различного вида и набора фаз светофорного цикла, что позволяет использовать алгоритм в сложных транспортных сетях, приближенных к реальным.

2.2. Управление сигналами светофоров. Одной из первых работ, посвященных проблеме управления сигналами/фазами светофорного объекта, можно считать работу Вебстера [22]. В работе был предложен метод расчета длины светофорного цикла и фазового цикла для одиночного перекрестка. Развитие метода для использования стратегий координированного управления несколькими перекрестками было продолжено в [23, 24]. Ранние методы управления светофорами использовали так называемые стратегии с фиксированным временем, при которых длительность светофорного цикла и распределение фаз фиксировались и не зависели от состояния движения на сегментах сети, что ограничивает применимость моделей [25].

Следующим этапом развития методов управления светофорами было применение адаптивных схем управления, зависящих от наблюдаемого транспортного потока на перекрестке. Такие схемы позволяют выбирать новую фазу светофорного цикла в зависимости от, например, длины очереди транспортных средств на перекрестке [26]. В [27] авторы предложили адаптивную схему управления, учитывающую введенную величину «давления», которая определяется как разность между количеством въезжающих и выезжающих транспортных средств на перекрестке. Данный метод, согласно работе [28], смог превзойти более современные подходы на небольшой синтетической сети. В [29] был предложен адаптивный алгоритм управления, основанный на выборе фазы светофорного цикла, прогнозируемый транспортный поток для которой будет максимальным.

В последнее десятилетие широкое развитие получили методы машинного обучения и глубокие нейронные сети. Применительно к задаче управления сигналами светофоров, в современных исследованиях активно разрабатываются методы на основе обучения с подкреплением (reinforcement learning – RL) [30 – 39]. Обучение с подкреплением – это класс методов машинного обучения (наряду с методами обучения с учителем и обучения без учителя), обучающихся в процессе взаимодействия агента с окружающей средой с целью максимизации некоторого вознаграждения. В ходе взаимодействия агент получает наблюдаемое состояние среды, выполняет некоторое действие в соответствии с настроенной функцией политики и переходит в следующее состояние. После перехода в новое состояние агент получает численное вознаграждение и обновляет свою функцию политики с целью достижения оптимальной политики и максимизации общего вознаграждения.

В качестве основных RL-методов для решения задачи управления сигналами светофоров часто используются следующие: методы на основе оптимизации функции полезности (Q-обучение [30], глубокое Q-обучение [31], двойное Q-обучение [32, 33]), методы на основе оптимизации политики [34 – 37], методы класса «actor-critic», сочетающие оба подхода [38, 39]. Обзор и сравнение различных RL-методов и алгоритмов, а также используемых настроек алгоритмов (описания наблюдаемого состояния среды, функции вознаграждения) представлен в [40, 41]. В [42] авторы провели обзор основных приложений RL-методов в разработке современных интеллектуальных транспортных систем, включая задачи управления светофорами, контроля электроэнергии и автономного вождения.

Несмотря на активное развитие RL-методов управления сигналами светофоров, остаются открытыми вопросы обучения моделей и сходимости к глобальному максимуму, чувствительности к выбору гиперпараметров алгоритмов, стабильности их работы на сложных сценариях управления. В данной работе в качестве метода управления был выбран детерминированный метод на основе максимизации прогнозируемого потока транспортных средств [29]. Исходя из результатов, представленных в оригинальной работе, данный метод превосходит классические алгоритмы управления сигналами светофоров и современный RL-метод.

2.3. Совместное управление. Заключительная часть обзора современного состояния исследований посвящена анализу литературы, рассматривающей задачу координированного управления движением

автономных/подключенных транспортных средств и сигналами светофоров.

Один из методов построения траекторий движения транспортных средств в смешанном транспортном потоке представлен в [43]. Однако представленный подход использовал предопределенный светофорный цикл. В [44] предлагается система, которая включает в себя как управление сигналами светофоров, так и управление траекториями движения транспортных средств. Предлагаемая структура объединяет компоненты восприятия, прогнозирования, планирования и оптимизации и направлена на повышение эффективности управления смешанным транспортным потоком. Однако в алгоритме не предполагалась смена полос движения, а экспериментальные исследования алгоритма проводились на сценарии, содержащем один изолированный перекресток. В [45] обобщены методы управления сигналами светофоров, активного управления автономными подключенными транспортными средствами и косвенного управления обычными транспортными средствами для изучения стратегии координированного управления несколькими перекрестками для гетерогенного транспортного потока. Согласно [46], решение задачи координированного управления позволит значительно повысить эффективность использования транспортной инфраструктуры.

В данном исследовании представлен метод совместного управления траекториями движения и адаптивного управления сигналами светофоров. Постановка задачи и описание разработанного алгоритма представлены в следующем разделе.

3. Метод совместного управления. Задача, решаемая разработанным методом совместного управления транспортным потоком на регулируемом перекрестке, формулируется следующим образом:

$$\lambda \cdot R_T (TravelT_{\Sigma}(A_{TS}, A_{Tr})) + \eta \cdot R_T (WaitingT_{\Sigma}(A_{TS}, A_{Tr})) + \delta \cdot R_F (FuelC_{\Sigma}(A_{TS}, A_{Tr})) \rightarrow \min_{A_s, A_r}$$

где $TravelT_{\Sigma}(A_{TS}, A_{Tr})$ – общее время (длительность) совершения всех корреспонденций ТС на перекрестке, $WaitingT_{\Sigma}(A_{TS}, A_{Tr})$ – общее время (длительность) ожидания всех ТС на перекрестке; $FuelC_{\Sigma}(A_{TS}, A_{Tr})$ – объем общего потребления топлива всеми ТС при

движении по перекрёстку; R_T – скалярная функция, возвращающая вещественное (безразмерное) число, равное в секундах задаваемой аргументом длительности времени; R_F – скалярная функция, возвращающая вещественное (безразмерное) число, равное в миллилитрах задаваемому аргументом объёму потребленного топлива; A_{TS}, A_{Tr} – используемые алгоритмы управления сигналами светофоров и построения траектории движения (включая их параметры); λ, η, δ – вещественные безразмерные весовые коэффициенты, совместно характеризующие относительную важность того или иного фактора. Для решения данной задачи согласованно используются метод адаптивного управления сигналами светофоров и алгоритм построения траекторий движения транспортных средств.

Для описания метода совместного управления сигналами светофоров и траекториями движения транспортных средств последовательно рассмотрим метод адаптивного управления сигналами светофоров (раздел 3.1), алгоритм построения траекторий движения транспортных средств (раздел 3.2), а также метод их совместного применения.

3.1. Метод адаптивного управления сигналами светофоров

A_{TS} . Для решения задачи адаптивного управления сигналами светофоров в работе используется метод максимального взвешенного потока (MaxPWFlow) [29, 46], предложенный авторами настоящей работы. Метод управления основывается на выборе фазы светофорного цикла, максимизирующей прогнозируемый поток транспортных средств, проходящих через перекресток за рассматриваемый временной интервал. Представим краткое формальное описание используемого метода.

Введем следующие обозначения. Пусть τ_{min} – допустимый минимальный интервал переключения фаз, t_p – длительность текущей активной фазы светофорного объекта $p \in P$, P – множество фаз, *phase* – следующая выбранная фаза.

Тогда в виде псевдокода алгоритм может быть представлен следующим образом (листинг 1).

Основным шагом метода является расчет прогнозируемого «взвешенного» потока транспортных средств через перекресток для заданной фазы $p \in P$, выполняемый функцией $PWFlow(p)$.

Входные данные: τ_{min}, t_p, p, P
Выходные данные: $phase$
 if $t_p < \tau_{min}$ then
 $t_p = t_p + 1$
 $phase = p$
 else
 $t_p = 0$
 $phase = \operatorname{argmax}(\{PWFlow(p) \text{ for } p \text{ in } P\})$
 end if

Листинг 1. Метод максимального взвешенного потока

В работе [46] используется следующий вид функции:

$$PWFlow(phase) = \sum_{l \in L_{phase}^{income}} \sum_{c \in C_l} \eta(c, l) I(t(c) < \tau_{min}). \quad (1)$$

В формуле (1) $t(c)$ – оценка времени, необходимого транспортному средству $c \in C_l$ для достижения перекрестка. C_l – множество транспортных средств, движущихся по полосе l из множества полос L_{phase}^{income} , движение по которым разрешено при активной фазе $phase$ светофорного объекта. $I(val)$ – индикатор, который возвращает значение 1, если $val = True$, и значение 0 в противном случае. Оценка времени движения $t(c)$ формируется с использованием детерминированной прогнозной модели движения [29].

Учет времени ожидания $delay(c, l)$ транспортного средства c на полосе l осуществляется путем корректировки «веса» $\eta(c, l)$ в итоговой оценке $PWFlow(phase)$:

$$\eta(c, l) = 1 + \alpha \cdot delay(c, l),$$

где $\alpha = 0,01$ – эмпирически выбранный коэффициент (единица измерения времени ожидания – секунда).

В следующем подразделе приведено описание алгоритма построения траектории движения транспортного средства.

3.2. Алгоритм построения траектории A_{tr} . Пусть траектория – это квадратичная дифференцируемая функция $tr(t)$, для которой производная первого порядка (скорость) $tr'(t)$ является абсолютно непрерывной функцией и правая производная второго порядка (ускорение) $tr''(t)$ является интегрируемой.

Пусть контролируемое ТС въезжает на смежную с перекрестком полосу движения в момент времени t_0 со скоростью v_0 в позицию l_0 ; L – длина полосы движения; v_{\max} – максимальная допустимая скорость движения на рассматриваемой полосе движения; \bar{a} – максимальное ускорение, с которым может двигаться рассматриваемое ТС; \underline{a} – максимальное торможение, достижимое рассматриваемым ТС. Пусть перекресток управляется светофорным объектом с фиксированным временем переключения фаз. Требуется построить физически достижимую и безопасную траекторию движения ТС до перекрестка tr с учетом следующих ограничений:

$$\begin{aligned} tr(t_0) &= l_0, \\ 0 \leq tr'(t) &\leq v_{\max}, \quad \underline{a} \leq tr''(t) \leq \bar{a}, \quad \forall t \in (-\infty, +\infty), \\ G(T(tr, L)) &= T(tr, L), \end{aligned}$$

где $T(tr, L)$ – время, при котором ТС достигнет позиции L (т.е. въедет на перекресток), двигаясь по траектории tr ; $G(t)$ – функция, которая возвращает ближайшее к t время зеленой фазы светофора ($G(t) = t$, если в момент времени t горит зеленый сигнал светофора, $G(t) > t$, если в момент времени t горит красный). Функция $G(t)$ определяется следующим образом:

$$G(t) = \min\{t' : t' > t \wedge t' \in [T_0 + nT_c, T_0 + nT_c + T_g], n \in \mathbb{Z}^+\},$$

где \mathbb{Z}^+ – множество целых положительных чисел, T_0 – время начала светофорного цикла, $T_c = T_g + T_y + T_r$ – длительности полного

рабочего цикла светофора, которое включает в себя длительности зеленой фазы T_g , желтой фазы T_{yr} и красной фазы T_r .

Для управления движением ТС на перекрестке в работе используется модифицированный вариант Shooting Heuristic алгоритма [19]. В рамках оригинального Shooting Heuristic алгоритма для каждого ТС, находящегося на смежной с контролируемым перекрестком дорожной полосе, строится траектория движения, учитывающая траекторию впереди идущего ТС (при наличии такового). В рамках разработанного метода траектория формируется только для ближайшего к перекрестку ТС на дорожной полосе. Остальные ТС двигаются согласно используемой модели следования за контролируемым ТС. В данной работе в качестве такой модели следования применяется используемая по умолчанию в системе моделирования SUMO модель [47].

На первом этапе Shooting Heuristic алгоритма под названием Forward Shooting Process (FSP), последовательно формируются два сегмента траектории. Первый сегмент соответствует равноускоренному движению с ускорением $\bar{a}^f \in (0, \bar{a}]$ из начального состояния (t_0, v_0, l_0) до достижения крейсерской скорости $v_{cruise} \in (0, v_{max}]$. Движение по этому сегменту траектории занимает $(v_{cruise} - v_0) / \bar{a}^f$ секунд. Второй сегмент траектории соответствует равномерному прямолинейному движению со скоростью v_{cruise} с момента времени $t_0 + (v_{cruise} - v_0) / \bar{a}^f$ до момента въезда непосредственно на перекресток. В результате ТС, двигаясь по рассматриваемому сегменту, въедет на перекресток в момент времени \hat{t}^+ , определяемый следующим образом:

$$\hat{t}^+(v_{cruise}, \bar{a}^f) = t_0 + \begin{cases} \frac{-v_0 - \sqrt{(v_0)^2 + 2\bar{a}^f L}}{\bar{a}^f}, & \text{если } L \leq \frac{v_{cruise}^2 - (v_0)^2}{2\bar{a}^f} \\ \frac{L}{v_{cruise}} + \frac{(v_{cruise} - v_0)^2}{2\bar{a}^f v_{cruise}}, & \text{иначе} \end{cases}.$$


Полученная траектория tr^f , состоящая из двух сегментов, является результирующей, если в момент времени \hat{t}^+ для полосы движения, по которой движется рассматриваемое ТС, горит зеленый

сигнал светофора. В противном случае при $G(T(tr^f, L)) \neq T(tr^f, L)$ начинается второй этап алгоритма – Backward Shooting Process (BSP).


В начале второго этапа алгоритма последний сегмент траектории tr^f сдвигается вправо по оси времени до начала зеленой фазы светофора $G(\hat{t}^+)$. Полученный в результате такого сдвига сегмент является исходным для этапа BSP. Затем из этого исходного сегмента формируются сегменты траектории tr^b с ускорением $\bar{a}^b \in (0, \bar{a})$ и торможением $\underline{a}^b \in [\bar{a}, 0)$, благодаря которым траектории tr^b и tr^f плавно соединяются в результирующую траекторию tr .

Таким образом, используемая в работе модификация Shooting Heuristic алгоритма последовательно формирует траектории для ТС, расположенных наиболее близко к перекрестку на каждой входящей дорожной полосе. Набор параметров $(\bar{a}^f, \bar{a}^b, \underline{a}^b, v_{cruise})$, используемый для построения траектории, определяет ее "гладкость". Следует отметить, что при заданном наборе входных параметров траектории $(\bar{a}^f, \bar{a}^b, \underline{a}^b, v_{cruise})$ и исходных данных положения ТС (t_0, v_0, l_0) не всегда представляется возможным построить траекторию с помощью алгоритма Shooting Heuristic.

Пример построения траекторий с помощью Shooting Heuristic алгоритма представлен на рисунке 1.



а)



б)

Рис. 1. Пространственно-временные диаграммы движения: а) управляемых вручную транспортных средств; б) с помощью Shooting Heuristic алгоритма

На данном рисунке показаны две пространственно-временные диаграммы, содержащие траектории движения транспортных средств на регулируемом перекрестке, контролируемых вручную (а), и транспортных средств, управляемых с помощью Shooting Heuristic алгоритма (б).

Полученную с помощью Shooting Heuristic алгоритма траекторию можно оценить по различным показателям эффективности дорожного движения. В рамках предложенного в данной работе метода была использована взвешенная сумма нескольких критериев оценки траектории:

$$M(tr) = \lambda \cdot R_T(TravelT(tr)) + \eta \cdot R_T(WaitingT(tr)) + \delta \cdot R_F(FuelC(tr)),$$

где $TravelT(tr)$ – время (длительность) совершения корреспонденции ТС при движении по траектории tr , $WaitingT(tr)$ – время (длительность) ожидания/простоя ТС при движении по траектории tr ; $FuelC(tr)$ – объем потребления топлива ТС при движении по траектории tr . Скалярные функции R_T и R_F определены ранее, также как и как весовые коэффициенты λ, η, δ . Значения последних

были подобраны экспериментально: $\lambda = 1, 0; \eta = 2, 0; \delta = 1, 0$. Поскольку в качестве единиц измерения времени движения ТС и времени ожидания ТС использовались секунды, в качестве единиц потребления топлива – миллилитры, чем меньше значение оценки $M(tr)$ для траектории tr , тем «лучше» траектория.

Для расчета потребления топлива была использована модель расчета потребления топлива, основанная на данных из базы данных The Handbook Emission Factors for Road Transport (НБЕФА) версии 3.1. Данная модель используется по умолчанию в системе моделирования SUMO для расчета выбросов в атмосферу и потребления топлива транспортных средств. Согласно модели потребление топлива транспортным средством стандарта Евро-4 с бензиновым двигателем, движущимся со скоростью v ($м/с$) и ускорением a ($м/с^2$) в момент времени t ($с$) рассчитывается по следующей формуле [11]:

$$FuelC(tr(t)) = \begin{cases} 0, & \text{если } tr''(t) < 0 \\ \frac{3014 + tr'(t)(299,3tr''(t) - 149 + 9,014tr'(t))}{2671,2}, & \text{иначе.} \end{cases}$$

Для подбора оптимальных параметров траектории $(\bar{a}^f, \bar{a}^b, \underline{a}^b, v_{cruise})$ использовался субградиентный метод [12]. Задача оптимизации формулируется следующим образом:

$$\begin{aligned} M(tr(\bar{a}^f, \bar{a}^b, \underline{a}^b, v_{cruise})) &\rightarrow \min_{\bar{a}^f, \bar{a}^b, \underline{a}^b, v_{cruise}}, \\ 0 < \bar{a}^f &\leq \bar{a}, 0 < \bar{a}^b \leq \bar{a}, \\ \underline{a} &\leq \underline{a}^b < 0, 0 \leq v_{cruise} \leq v_{\max}. \end{aligned}$$

На первом этапе данного метода выбирается такой набор параметров $(\bar{a}^f, \bar{a}^b, \underline{a}^b, v_{cruise})$, при котором с помощью алгоритма Shooting Heuristic можно построить траекторию. Выбор начального набора параметров осуществляется путем перебора. Затем рассчитывается субградиент путем небольшого изменения текущих входных параметров используемого алгоритма построения траектории. Далее рассчитывается оценка траектории при изменении параметров в субградиентном направлении. Движение в направлении градиента выполняется до тех пор, пока не будет найдена точка решения, которая

приводит к значительному уменьшению значения функции оценки M . Если такая точка найдена, вектор входных параметров изменяется путем перемещения в эту новую точку. В противном случае алгоритм может застрять в локальном оптимуме, поэтому в этом случае вектор входных параметров просто перемещается в ближайшую точку, даже если значение функции оценки не уменьшается. Этот процесс поиска вектора входных параметров повторяется до тех пор, пока не будут удовлетворены определенные конечные критерии (максимальное количество шагов при движении по градиенту). Во время этого процесса всякий раз, когда вычисляется оценка траектории в новой точке, оптимальное решение (в виде набора параметров $(\bar{a}^f, \bar{a}^b, \underline{a}^b, v_{cruise})$) обновляется в том случае, если оценка траектории в этой точке, меньшее, чем все предыдущие оценки.

Общая схема используемого в данной работе алгоритм построения оптимальной траектории движения ТС представлена на рисунке 2.

3.3. Метод совместного управления. В рамках предлагаемого метода совместного управления на перекрестке управление светофорным объектом осуществляется описанным в разделе 3.1 методом адаптивного управления. Траектория движения транспортных средств на входящих к перекрестку дорожных полосах формируется с помощью алгоритма, описанного в разделе 3.2. Однако, для согласованной работы вышеназванного метода и алгоритма, алгоритм построения траектории был адаптирован для работы со светофорным объектом, контролируемым адаптивным методом.

Для возможности применения алгоритма 3.2 на перекрестке, управляемым светофорным объектом, работающем без фиксированного расписания, была изменена функция $G(t)$. Как было отмечено выше, эта функция для заданного момента времени t возвращает следующее ближайшее к нему время зеленой фазы светофора. Она используется в описанном ранее алгоритме Shooting Heuristic на этапе BSP. Так как длительность полного цикла работы светофора при использовании метода, описанного в разделе 3.1, непостоянно, использовать определение функции (2) не представляется возможным.

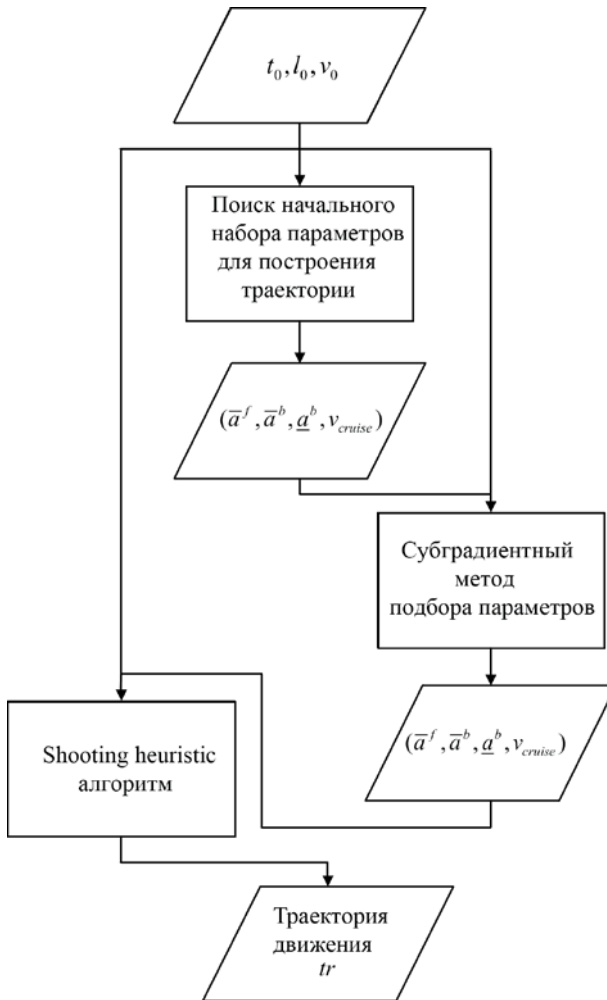


Рис. 2. Общая схема алгоритма построения оптимальной траектории движения ТС

Пусть p – текущая активная фаза светофора для входящей в перекресток полосы движения; p – следующая прогнозируемая фаза светофора; τ_{min} – минимальный интервал переключения фаз; T_o^p – время начала текущей фазы, $T_o^{pnext} = T_o^p + \tau_{min}$ – время

переключения фазы; $c(p, l) \in \{green, yellow, red\}$ – сигнал светофоры фазы p для полосы движения l . Тогда, по аналогии с $G(t)$, определим функцию $G(t, p, l)$ следующим образом:

$$G(t, p, l) = \begin{cases} t, & \text{if } c(p, l) = green \wedge (c(p_{next}, l) = green \vee t < T_o^{p_{next}}) \\ \max\{t, T_o^{p_{next}}\}, & \text{if } c(p, l) \neq green \wedge c(p_{next}, l) = green. \\ \max\{t, T_o^{p_{next}} + \tau_{min}\}, & \text{otherwise} \end{cases}$$

Согласно используемому методу адаптивного управления сигналами светофорного объекта, выбор и установка следующей фазы осуществляется через фиксированный временной интервал τ_{min} по формуле:

$$p_{next} = \operatorname{argmax}(\{PWFlow(p) \text{ for } p \text{ in } P\}). \quad (2)$$

Значение фазы p_{next} является «прогнозируемым», так как построение траектории может осуществляется в те моменты времени, когда установка следующей фазы светофора не выполняется.

Для совместного управления транспортным потоком на перекрестке предлагается обновлять сформированные траектории движения ТС, при изменении результата прогноза следующей фазы светофора. В результате построения траектории сохраняется не только непосредственно построенная траектория для ТС, но и результат прогноза следующей фазы светофора, при котором эта траектория была получена. Обновление траекторий движения ТС осуществляется с заданной периодичностью $\tau_{upd} < \tau_{min}$.

Обновление траекторий осуществляется следующим образом. Сначала по формуле (2) вычисляется прогнозируемая фаза светофорного объекта p_{next} для момента следующего переключения его фазы. Затем для построенной ранее траектории ТС выполняется проверка, изменился ли прогноз следующей фазы. Тогда, если прогноз для ТС на дорожной полосе l поменялся ($c(p, l) \neq c(p_{next}, l)$), то траектория перестраивается (с использованием алгоритма построения траектории, описанного в разделе 3.2 – функция $build_traj()$) с учетом обновленного прогноза для следующей фазы. В противном случае, траектория движения ТС остается неизменной. С учетом сказанного

выше псевдокод процедуры обновления траектории ТС выглядит следующим образом (листинг 2):

Входные данные: l, p, tr, P

Выходные данные: tr, p_{next}

$p_{next} = \operatorname{argmax}(\{PWFlow(p) \text{ for } p \text{ in } P\})$

if $c(p, l) \neq c(p_{next}, l)$ then

$tr = \text{build_traj}(p_{next})$

end if

Листинг 2. Процедура обновления траектории

4. Экспериментальные исследования. Экспериментальные исследования эффективности разработанного метода проводились с использованием системы моделирования SUMO (Simulation of Urban Mobility) [10]. Эта система моделирования с открытым исходным кодом, развиваемая более 20 лет, предназначена для моделирования мультимодального движения транспортных средств в крупномасштабных транспортных сетях.

В экспериментах проводилось сравнение метода совместного управления сигналами светофоров и траекториями движения транспортных средств с методом адаптивного управления сигналами светофоров MaxPWFlow (без управления движением транспортных средств). Разработка алгоритмов и методов совместного управления является областью активных исследований. Существующие работы обладают существенными ограничениями: используют предопределенный цикл фаз [43] или не рассматривают перестроение между полосами в процессе движения [44], а также не предоставляют исходный код и данные для сравнения. Эти особенности делают невозможным сравнение разработанного метода с существующими алгоритмами и методами того же класса.

Экспериментальные исследования проводились при шаге симуляции, равном 0,1 секунде, и при общем времени симуляции 3600 секунд. Для оценки эффективности разработанного метода использовались три сценария моделирования движения транспортных средств:

– изолированный перекресток, являющийся пересечением равнозначных однополосных дорог длиной 150 метров. Количество транспортных средств – 900;

– синтетическая сеть «4х4», состоящая из 16 перекрестков одинаковой структуры: пересечение равнозначных дорог длиной 300

метров с 3 полосами движения. Количество транспортных средств – 1472;

– городская область, являющаяся частью крупномасштабного сценария моделирования «TAPAS Cologne» [48]. Сценарий содержит 8 регулируемых перекрестков различной топологии, количество транспортных средств – 2046.

Дорожные сети рассматриваемых сценариев представлены на рисунке 3.




Рис. 3. Сценарии моделирования движения ТС

В ходе проведения экспериментальных исследований все транспортные средства имели одинаковые характеристики, бензиновый двигатель и соответствовали одному экологическому стандарту – Евро-4.

В экспериментах использовались следующие значения параметров: минимальный интервал переключения фаз $\tau_{min} = 10$ (секунд), интервал обновления траектории движения транспортного средства $\tau_{upd} = 5$ (секунд).

Сравнение методов проводилось по трем критериям:

- средний расход топлива на одно транспортное средство (основной критерий) (в миллилитрах), позволяющий оценить потребление топлива всеми транспортными средствами в сценарии.
- среднее время движения одного транспортного средства (в секундах), затрачиваемое транспортными средствами на совершение поездок в сети;
- среднее время ожидания одного транспортного средства (в секундах), т.е. время, которое транспортное средство провело без движения на перекрестке.

Для оценки показателей качества методов для каждого сценария было проведено 10 запусков моделирования движения транспортных средств (10 эпизодов), полученные результаты были усреднены. Начальные положения транспортных средств, время начала движения и маршруты были различными в различных эпизодах одного сценария. Результаты сравнения методов по критерию «расход топлива» представлены в таблице 1, по критерию «среднее время движения» – в таблице 2, по критерию «среднее время ожидания» – в таблице 3.

Таблица 1. Сравнение методов по критерию «средний расход топлива», мл

	Изолированный перекресток	Сеть 4x4	Городская область
MaxPWFlow	35,45	115,47	87,92
Совместное управление	30,56	111,98	86,47

Таблица 2. Сравнение методов по критерию «среднее время движения», с

	Изолированный перекресток	Сеть 4x4	Городская область
MaxPWFlow	27,07	104,81	88,84
Совместное управление	25,56	103,4	87,23

Таблица 3. Сравнение методов по критерию «среднее время ожидания», с

	Изолированный перекресток	Сеть 4x4	Городская область
MaxPWFlow	2,01	3,61	3,57
Совместное управление	0,04	1,16	1,44

Проведенные эксперименты подтверждают эффективность предложенного метода совместного управления сигналами светофоров и траекториями движения транспортных средств по всем рассмотренным критериям.

На рисунке 4 представлен расход топлива для каждого эпизода моделирования в сценарии «городская область».

Как видно из графика, предложенный метод позволил снизить потребление топлива в каждом из эпизодов рассматриваемого сценария.

Основываясь на результатах проведенных экспериментов, можно сделать вывод, что предложенный в работе метод совместного управления позволяет повысить эффективность использования

транспортной инфраструктуры, снизить расход топлива и время движения.

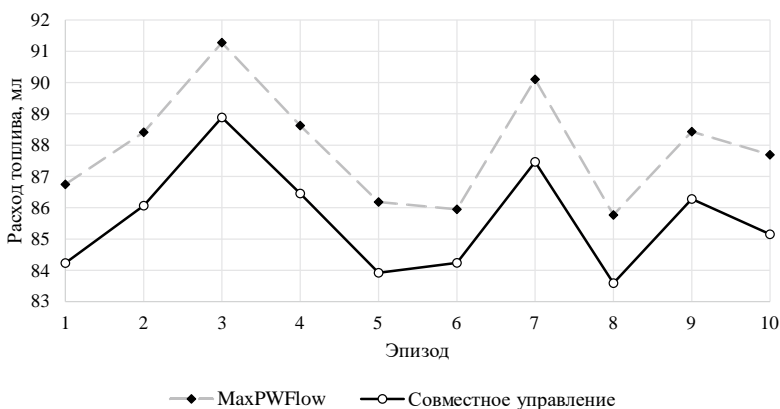


Рис. 4. Расход топлива в каждом эпизоде моделирования движения

4. Заключение. В работе представлен метод совместного (координированного) управления сигналами светофоров и траекториями движения транспортных средств. В рамках предложенного метода управление светофорным объектом осуществляется методом максимального взвешенного потока, построение траекторий – модифицированным Shooting Heuristic алгоритмом. Совместная работа достигается путем обновления траектории движения транспортных средств при смене результата прогноза следующей фазы светофора. Экспериментальные исследования в системе моделирования движения транспортных средств подтверждают эффективность предложенного метода по критериям потребления топлива, времени движения и времени ожидания на синтетических и реальных сценариях движения.

Возможные направления исследований включают в себя адаптацию других известных алгоритмов построения траектории движения транспортных средств для совместной работы с используемым в работе адаптивным методом управления сигналами светофоров, и исследование эффективности разработанного метода на крупномасштабном сценарии моделирования движения транспортных средств.

Литература

1. Transport sector economic analysis // EU Science Hub. URL: https://joint-research-centre.ec.europa.eu/scientific-activities-z/transport-sector-economic-analysis_en. (дата обращения: 30.05.2022).
2. О производстве и использовании валового внутреннего продукта (ВВП) в 2021 году // Официальный сайт федеральной службы государственной статистики. URL: https://rosstat.gov.ru/storage/mediabank/59_08-04-2022.htm. (дата обращения: 30.05.2022).
3. Traffic congestion to cost the UK economy more than £300 billion over the next 16 years // Inrix. 2014. URL: <https://inrix.com/press-releases/traffic-congestion-to-cost-the-uk-economy-more-than-300-billion-over-the-next-16-years/>. (дата обращения: 30.05.2022).
4. Requia W.J. et al. The health impacts of weekday traffic: A health risk assessment of PM 2.5 emissions during congested periods // Environment international. 2018. vol. 111. pp. 164–176.
5. Zhang K., Batterman S. Air pollution and health risks due to vehicle traffic // The Science of the total environment. 2013. vol. 450–451. pp. 307–316.
6. Li X. et al. Stop-and-go traffic analysis: Theoretical properties, environmental impacts and oscillation mitigation // Transportation Research Part B: Methodological. 2014. vol. 70. pp. 319–339.
7. Наличие автомобильного транспорта // Единая межведомственная информационно-статистическая система (ЕМИСС). URL: <https://fedstat.ru/indicator/36228>. (дата обращения: 30.05.2022).
8. ГОСТ Р 56829-2015 Интеллектуальные транспортные системы. Термины и определения // Электронный фонд правовых и нормативно-технических документов. URL: <https://docs.cntd.ru/document/1200128315>. (дата обращения: 20.07.2022).
9. Как работают Яндекс.Пробки // Яндекс. URL: <https://yandex.ru/company/technologies/yaprobki/>. (дата обращения: 30.05.2022).
10. Агафонов А.А., Мясников В.В. Метод определения надежного кратчайшего пути в стохастической сети с использованием параметрически заданных устойчивых распределений вероятностей // SPIIRAS Proc. 2019. Т. 18. № 3. С. 558–582.
11. Lopez P.A. et al. Microscopic Traffic Simulation using SUMO Maui, HI: IEEE, 2018. pp. 2575–2582.
12. Ma J. et al. Parsimonious shooting heuristic for trajectory design of connected automated traffic part II: Computational issues and optimization // Transportation Research Part B: Methodological. 2017. vol. 95. pp. 421–441.
13. Hu J. et al. Integrated optimal eco-driving on rolling terrain for hybrid electric vehicle with vehicle-infrastructure communication // Transportation research. Part C: Emerging technologies. 2016. vol. 68. pp. 228–244.
14. Asadi B., Vahidi A. Predictive cruise control: Utilizing upcoming traffic signal information for improving fuel economy and reducing trip time // IEEE transactions on control systems technology: a publication of the IEEE Control Systems Society. 2011. vol. 19. no. 3. pp. 707–714.
15. Zhang H. et al. A priority-based autonomous intersection management (AIM) scheme for connected automated vehicles (CAVs) // Vehicles. 2021. vol. 3. no. 3. pp. 533–544.
16. Jiang H et al. Eco approaching at an isolated signalized intersection under partially connected and automated vehicles environment // Transportation research. Part C: Emerging technologies. 2017. vol. 79. pp. 290–307.

17. Lee J., Park B. Development and evaluation of a cooperative vehicle intersection control algorithm under the connected vehicles environment // *IEEE transactions on intelligent transportation systems: a publication of the IEEE Intelligent Transportation Systems Council*. 2012. vol. 13. no. 1. pp. 81–90.
18. Yu C. et al. Managing connected and automated vehicles at isolated intersections: From reservation- to optimization-based methods // *Transportation Research Part B: Methodological*. 2019. vol. 122. pp. 416–435.
19. Zhou F., Li X., Ma J. Parsimonious shooting heuristic for trajectory design of connected automated traffic part I: Theoretical analysis with generalized time geography // *Transportation Research Part B: Methodological*. 2017. vol. 95. pp. 394–420.
20. Yang Z. et al. Eco-trajectory planning with consideration of queue along congested corridor for hybrid electric vehicles // *Transportation research record*. 2019. vol. 2673. no. 9. pp. 277–286.
21. Barth M. et al. Dynamic ECO-driving for arterial corridors // *IEEE Forum on Integrated and Sustainable Transportation Systems*. 2011. pp. 182–188.
22. Webster F.V. Traffic Signal Settings. Road Research Technical Paper / Stationery Office, 1958. no 39.
23. Little J., Kelson M., Gartner N. MAXBAND: A Program for Setting Signals on Arteries and Triangular Networks // *Transportation Research Record Journal of the Transportation Research Board*. 1981. vol. 795. pp. 40–46.
24. Li M.-T., Gan A.C. Signal timing optimization for oversaturated networks using TRANSYT-7F // *Transportation Research Record*. 1999. № 1683. pp. 118–126.
25. Papageorgiou M. et al. Review of road traffic control strategies // *Proceedings of the IEEE*. 2003. vol 12. no. 91. pp. 2043–2065.
26. El-Tantawy S., Abdulhai B. An agent-based learning towards decentralized and coordinated traffic signal control 2010. pp. 665–670.
27. Varaiya P. The Max-Pressure Controller for Arbitrary Networks of Signalized Intersections Complex Networks and Dynamic Systems // *Complex Networks and Dynamic Systems*. New York, NY: Springer New York, 2013. pp. 27–66.
28. Genders W., Razavi S. An Open-Source Framework for Adaptive Traffic Signal Control // *arXiv:1909.00395*. 2019.
29. Мясников В.В., Агафонов А.А., Юмаганов А.С. Детерминированная прогнозная модель управления сигналами светофоров в интеллектуальных транспортных и геoinформационных системах // *Компьютерная оптика*. 2021. Т. 45. № 6. С. 917–925.
30. Abdulhai B., Pringle R., Karakoulas G. Reinforcement Learning for True Adaptive Traffic Signal Control // *Journal of Transportation Engineering*. 2003. (129).
31. Wei H. et al. IntelliLight: A Reinforcement Learning Approach for Intelligent Traffic Light Control London United Kingdom: ACM, 2018. pp. 2496–2505.
32. Wang X. et al. Large-Scale Traffic Signal Control Using a Novel Multiagent Reinforcement Learning // *IEEE Transactions on Cybernetics*. 2021. vol. 1. no. 51. pp. 174–187.
33. Agafonov A., Myasnikov V. Traffic Signal Control: A Double Q-learning Approach 2021. pp. 365–369.
34. Schulman J. et al. Proximal Policy Optimization Algorithms // *arXiv:1707.06347*. 2017.
35. Ault J., Hanna J.P., Sharon G. Learning an Interpretable Traffic Signal Control Policy // *arXiv:1912.11023*. 2020.
36. Li Y., He J., Gao Y. Intelligent Traffic Signal Control with Deep Reinforcement Learning at Single Intersection. 2021. pp. 399–406.

37. Yang J., Zhang J., Wang H. Urban Traffic Control in Software Defined Internet of Things via a Multi-Agent Deep Reinforcement Learning Approach // IEEE Transactions on Intelligent Transportation Systems. 2021. vol. 6. no 22. pp. 3742–3754.
38. Yang S. et al. IHG-MA: Inductive heterogeneous graph multi-agent reinforcement learning for multi-intersection traffic signal control // Neural Networks. 2021. vol 139. pp. 265–277.
39. Haarnoja T. et al. Soft Actor-Critic Algorithms and Applications // arXiv:1812.05905. 2019.
40. Yau K.-L.A. et al. A survey on Reinforcement learning models and algorithms for traffic signal control // ACM Computing Surveys. 2017. vol. 3. 50 p.
41. Wei H. et al. A Survey on Traffic Signal Control Methods // arXiv:1904.08117. 2020.
42. Haydari A., Yilmaz Y. Deep Reinforcement Learning for Intelligent Transportation Systems: A Survey // IEEE Transactions on Intelligent Transportation Systems. 2022. vol. 1. no. 23. pp. 11–32.
43. Fang S. et al. Trajectory Planning Method for Mixed Vehicles Considering Traffic Stability and Fuel Consumption at the Signalized Intersection // Journal of Advanced Transportation. 2020. pp. 1–10.
44. Guo Y., Ma J. DRL-TP3: A learning and control framework for signalized intersections with mixed connected automated traffic // Transportation Research Part C: Emerging Technologies. 2021. vol. 132. pp. 103416.
45. Zhang L., Wang Y., Zhu H. Theory and Experiment of Cooperative Control at Multi-Intersections in Intelligent Connected Vehicle Environment: Review and Perspectives // Sustainability. 2022. vol. 3. no. 14. pp. 1542.
46. Agafonov A., Yumaganov A., Myasnikov V. Adaptive Traffic Signal Control Based on Maximum Weighted Traffic Flow // 2022 International Conference on Information Technology and Nanotechnology (ITNT). pp. 1–4.
47. Krauß S. Microscopic modeling of traffic flow: Investigation of collision free vehicle dynamics. – 1998.
48. RESCO. URL: <https://github.com/Pi-Star-Lab/RESCO> (дата обращения: 30.05.2022).

Агафонов Антон Александрович — д-р техн. наук, доцент, старший научный сотрудник, кафедра геоинформатики и информационной безопасности, Самарский университет. Область научных интересов: геоинформационные технологии, анализ данных, управление и прогнозирование в интеллектуальных транспортных системах. Число научных публикаций — 50. ant.agafonov@gmail.com; улица Лукачева, 39Б, 443086, Самара, Россия; р.т.: +7(846)267-4905.

Юмаганов Александр Сергеевич — канд. техн. наук, старший научный сотрудник, научно-исследовательская лаборатория геоинформатики и информационной безопасности, Самарский университет. Область научных интересов: распознавание образов, анализ данных, интеллектуальные транспортные системы. Число научных публикаций — 37. yumagan@gmail.com; улица Лукачева, 39Б, 443086, Самара, Россия; р.т.: +7(846)267-4905.

Поддержка исследований. Работа выполнена при поддержке Российского научного фонда (проект № 21-11-00321, <https://rscf.ru/project/21-11-00321/>).

A. AGAFONOV, A. YUMAGANOV
**COOPERATIVE CONTROL OF TRAFFIC SIGNALS AND
VEHICLE TRAJECTORIES**

Agafonov A., Yumaganov A. Cooperative Control of Traffic Signals and Vehicle Trajectories.

Abstract. The transportation system is one of the most important parts of the country's economy. At the same time, the growth in road traffic has a significant negative impact on the economic performance of the industry. One of the ways to increase the efficiency of using the transportation infrastructure is to manage traffic flows, incl. by controlling traffic signals at signalized intersections. One of the trends in the development of intelligent transportation systems is the creation of vehicular ad hoc networks that allow the exchange of information between vehicles and infrastructure, as well as the development of autonomous vehicles. As a result, it becomes possible to formulate the problem of cooperative control of vehicle trajectories and traffic signals to increase the capacity of intersections and reduce fuel consumption and travel time. This paper presents a method for managing traffic flow at an intersection, which consists of the cooperative control of traffic signals and trajectories of connected/autonomous vehicles. The developed method combines an algorithm for the adaptive control of traffic signals based on a deterministic model for predicting the movement of vehicles and a two-stage algorithm for constructing the trajectory of vehicles. The objective optimization function used to construct the optimal trajectories takes into account fuel consumption, travel time on the road lane, and waiting time at the intersection. Experimental studies of the developed method were carried out in the microscopic traffic simulation package SUMO using three simulation scenarios, including two synthetic scenarios and a scenario in a real urban environment. The results of experimental studies confirm the effectiveness of the developed method in terms of fuel consumption, travel time, and waiting time in comparison with the adaptive traffic signal control algorithm.

Keywords: traffic trajectories, traffic signal control, cooperative control, deterministic model, intelligent transport system.

References

1. Transport sector economic analysis. EU Science Hub. Available at: https://joint-research-centre.ec.europa.eu/scientific-activities-z/transport-sector-economic-analysis_en. (accessed: 30.05.2022).
2. O proizvodstve i ispol'zovanii valovogo vnutrennego produkta (VVP) v 2021 godu. Oficial'nyj sajt federal'noj sluzhby gosudarstvennoj statistiki. [Official website of the Federal State Statistics Service]. Available at: https://rosstat.gov.ru/storage/mediabank/59_08-04-2022.htm. (accessed: 30.05.2022). (In Russ.).
3. Traffic congestion to cost the UK economy more than £300 billion over the next 16 years. Inrix. 2014. Available at: <https://inrix.com/press-releases/traffic-congestion-to-cost-the-uk-economy-more-than-300-billion-over-the-next-16-years/>. (accessed: 30.05.2022).
4. Requia W.J. et al. The health impacts of weekday traffic: A health risk assessment of PM 2.5 emissions during congested periods. *Environment international*. 2018. vol. 111. pp. 164–176.
5. Zhang K., Batterman S. Air pollution and health risks due to vehicle traffic. *The Science of the total environment*. 2013. vol. 450–451. pp. 307–316.

6. Li X. et al. Stop-and-go traffic analysis: Theoretical properties, environmental impacts and oscillation mitigation. *Transportation Research Part B: Methodological*. 2014. vol. 70. pp. 319–339.
7. Nalichie avtomobil'nogo transporta. Edinaja mezhdomestvennaja informacionno-statisticheskaja sistema (EMISS). [Unified Interdepartmental Information and Statistical System]. Available at: <https://fedstat.ru/indicator/36228>. (accessed: 30.05.2022). (In Russ.).
8. GOST R 56829-2015. [Intelligent transport systems. Terms and definitions. Electronic fund of legal and normative-technical documents]. Available at: <https://docs.cntd.ru/document/1200128315>. (accessed: 20.07.2022). (In Russ.).
9. Kak rabotajut Jandeks.Probki. [How Yandex.Traffic works. Yandex]. Available at: <https://yandex.ru/company/technologies/yaprobki/>. (accessed: 30.05.2022). (In Russ.).
10. Agafonov A.A., Myasnikov V.V. [Method for reliable shortest path determination in stochastic networks using parametrically defined stable probability distributions]. *Trudy SPIIRAN – SPIIRAS Proceedings*. 2019. vol. 18. № 3. pp. 558–582. (In Russ.).
11. Lopez P.A. et al. Microscopic Traffic Simulation using SUMO Maui, HI. *IEEE*, 2018. pp. 2575–2582.
12. Ma J. et al. Parsimonious shooting heuristic for trajectory design of connected automated traffic part II: Computational issues and optimization. *Transportation Research Part B: Methodological*. 2017. vol. 95. pp. 421–441.
13. Hu J. et al. Integrated optimal eco-driving on rolling terrain for hybrid electric vehicle with vehicle-infrastructure communication. *Transportation research. Part C: Emerging technologies*. 2016. vol. 68. pp. 228–244.
14. Asadi B., Vahidi A. Predictive cruise control: Utilizing upcoming traffic signal information for improving fuel economy and reducing trip time. *IEEE transactions on control systems technology: a publication of the IEEE Control Systems Society*. 2011. vol. 19. no. 3. pp. 707–714.
15. Zhang H. et al. A priority-based autonomous intersection management (AIM) scheme for connected automated vehicles (CAVs). *Vehicles*. 2021. vol. 3. no. 3. pp. 533–544.
16. Jiang H. et al. Eco approaching at an isolated signalized intersection under partially connected and automated vehicles environment. *Transportation research. Part C: Emerging technologies*. 2017. vol. 79. pp. 290–307.
17. Lee J., Park B. Development and evaluation of a cooperative vehicle intersection control algorithm under the connected vehicles environment. *IEEE transactions on intelligent transportation systems: a publication of the IEEE Intelligent Transportation Systems Council*. 2012. vol. 13. no. 1. pp. 81–90.
18. Yu C. et al. Managing connected and automated vehicles at isolated intersections: From reservation to optimization-based methods. *Transportation Research Part B: Methodological*. 2019. vol. 122. pp. 416–435.
19. Zhou F., Li X., Ma J. Parsimonious shooting heuristic for trajectory design of connected automated traffic part I: Theoretical analysis with generalized time geography. *Transportation Research Part B: Methodological*. 2017. vol. 95. pp. 394–420.
20. Yang Z. et al. Eco-trajectory planning with consideration of queue along congested corridor for hybrid electric vehicles. *Transportation research record*. 2019. vol. 2673. no. 9. pp. 277–286.
21. Barth M. et al. Dynamic ECO-driving for arterial corridors. *IEEE Forum on Integrated and Sustainable Transportation Systems*. 2011. pp. 182–188.
22. Webster F.V. Traffic Signal Settings. *Road Research Technical Paper*. Stationery Office, 1958. no 39.

23. Little J., Kelson M., Gartner N. MAXBAND: A Program for Setting Signals on Arteries and Triangular Networks. Transportation Research Record Journal of the Transportation Research Board. 1981. vol. 795. pp. 40–46.
24. Li M.-T., Gan A.C. Signal timing optimization for oversaturated networks using TRANSYT-7F. Transportation Research Record. 1999. no. 1683. pp. 118–126.
25. Papageorgiou M. et al. Review of road traffic control strategies. Proceedings of the IEEE. 2003. vol 12. no. 91. pp. 2043–2065.
26. El-Tantawy S., Abdulhai B. An agent-based learning towards decentralized and coordinated traffic signal control. 2010. pp. 665–670.
27. Varaiya P. The Max-Pressure Controller for Arbitrary Networks of Signalized Intersections Complex Networks and Dynamic Systems. Complex Networks and Dynamic Systems. New York: Springer New York, 2013. pp. 27–66.
28. Genders W., Razavi S. An Open-Source Framework for Adaptive Traffic Signal Control. arXiv:1909.00395. 2019.
29. Myasnikov V.V., Agafonov A.A., Yumaganov A.S. [A deterministic predictive traffic signal control model in intelligent transportation and geoinformation systems]. Komp'yuternaya optika – Computer optics. 2021. Issue 45. vol. 6. pp. 917–925. (In Russ.).
30. Abdulhai B., Pringle R., Karakoulas G. Reinforcement Learning for True Adaptive Traffic Signal Control. Journal of Transportation Engineering. 2003. vol. 129.
31. Wei H. et al. IntelliLight: A Reinforcement Learning Approach for Intelligent Traffic Light Control London United Kingdom. ACM. 2018. pp. 2496–2505.
32. Wang X. et al. Large-Scale Traffic Signal Control Using a Novel Multiagent Reinforcement Learning. IEEE Transactions on Cybernetics. 2021. vol. 1. no. 51. pp. 174–187.
33. Agafonov A., Myasnikov V. Traffic Signal Control: A Double Q-learning Approach 2021. pp. 365–369.
34. Schulman J. et al. Proximal Policy Optimization Algorithms. arXiv:1707.06347. 2017.
35. Ault J., Hanna J.P., Sharon G. Learning an Interpretable Traffic Signal Control Policy. arXiv:1912.11023. 2020.
36. Li Y., He J., Gao Y. Intelligent Traffic Signal Control with Deep Reinforcement Learning at Single Intersection. 2021. pp. 399–406.
37. Yang J., Zhang J., Wang H. Urban Traffic Control in Software Defined Internet of Things via a Multi-Agent Deep Reinforcement Learning Approach. IEEE Transactions on Intelligent Transportation Systems. 2021. vol. 6. no 22. pp. 3742–3754.
38. Yang S. et al. IHG-MA: Inductive heterogeneous graph multi-agent reinforcement learning for multi-intersection traffic signal control. Neural Networks. 2021. vol 139. pp. 265–277.
39. Haarnoja T. et al. Soft Actor-Critic Algorithms and Applications. arXiv:1812.05905. 2019.
40. Yau K.-L.A. et al. A survey on Reinforcement learning models and algorithms for traffic signal control. ACM Computing Surveys. 2017. vol. 3. 50 p.
41. Wei H. et al. A Survey on Traffic Signal Control Methods. arXiv:1904.08117. 2020. 32 p.
42. Haydari A., Yilmaz Y. Deep Reinforcement Learning for Intelligent Transportation Systems: A Survey. IEEE Transactions on Intelligent Transportation Systems. 2022. vol. 1. no. 23. pp. 11–32.
43. Fang S. et al. Trajectory Planning Method for Mixed Vehicles Considering Traffic Stability and Fuel Consumption at the Signalized Intersection. Journal of Advanced Transportation. 2020. pp. 1–10.

44. Guo Y., Ma J. DRL-TP3: A learning and control framework for signalized intersections with mixed connected automated traffic. *Transportation Research Part C: Emerging Technologies*. 2021. vol. 132. pp. 103416.
45. Zhang L., Wang Y., Zhu H. Theory and Experiment of Cooperative Control at Multi-Intersections in Intelligent Connected Vehicle Environment: Review and Perspectives. *Sustainability*. 2022. vol. 3. no. 14. pp. 1542.
46. Agafonov A., Yumaganov A., Myasnikov V. Adaptive Traffic Signal Control Based on Maximum Weighted Traffic Flow. *International Conference on Information Technology and Nanotechnology (ITNT)*. 2022. pp. 1–4.
47. Krauß S. Microscopic modeling of traffic flow: Investigation of collision free vehicle dynamics. 1998.
48. RESCO. Available at: <https://github.com/Pi-Star-Lab/RESCO>. (accessed: 30.05.2022).

Agafonov Anton — Ph.D., Associate Professor, Senior researcher, Department of geoinformatics and information security, Samara National Research University. Research interests: geoinformation technologies, data analysis, control and forecasting in intelligent transportation systems. The number of publications — 50. ant.agafonov@gmail.com; 39Б, Lukachev St., 443086, Samara, Russia; office phone: +7(846)267-4905.

Yumaganov Alexander — Ph.D., Senior researcher, Scientific research laboratory of geoinformatics and information security, Samara National Research University. Research interests: pattern recognition, data analysis, intelligent transportation systems. The number of publications — 37. yumagan@gmail.com; 39Б, Lukachev St., 443086, Samara, Russia; office phone: +7(846)267-4905.

Acknowledgements. The work was supported by the Russian Science Foundation grant No. 21-11-00321, <https://rscf.ru/en/project/21-11-00321/>.

Н.А. ГРЯЗНОВ
**ОБМЕН НАВИГАЦИОННОЙ ИНФОРМАЦИЕЙ ДЛЯ
ОПЕРАТИВНОГО УПРАВЛЕНИЯ ДОРОЖНЫМ ДВИЖЕНИЕМ**

Грязнов Н.А. Обмен навигационной информацией для оперативного управления дорожным движением.

Аннотация. Снижение эффективности грузопассажирских перевозок в условиях городской инфраструктуры определяется ростом числа автомобилей, опережающим развитие сети дорог. Моделирование неравномерности потоков во времени (час пик) выявило ключевое значение интервала движения транспортных средств как фактора борьбы с эффектом аккумуляции при снижении средней скорости в условиях загруженности дорог. Снижение эффективного времени реакции водителя, определяющего предельную дистанцию между транспортными средствами, требует минимизации влияния человеческого фактора. Для автоматизации процесса (реализации беспилотного управления транспортом) необходимо обеспечить эффективный обмен навигационной и маршрутной информацией между участниками движения. Совокупности требований к системе информационного обмена лучше всего отвечает коммуникационно-навигационная система (КНС) на базе принципов широковещательной радиосвязи. Ее применение позволяет одновременно повысить и безопасность, и эффективность дорожного движения. Рост безопасности обеспечивается за счет повышения предсказуемости действий соседних участников движения. Для увеличения эффективности в зоне высокой плотности потоков формируются Центры управления транспортом (ЦУТ). Распределенные сети приема-передающих станций ЦУТ образуют локальную систему позиционирования на принципах трилатерации. Алгоритмы верификации корректности работы бортовых навигационных средств и автоматического разрешения коммуникационных конфликтов обеспечивают высокую надежность функционирования КНС. Отказ от принципов абонентской радиосвязи обеспечивает ее работоспособность даже в условиях очень высокой плотности транспортных средств (несколько тысяч на квадратный километр). В сочетании с передовыми технологиями организации дорожного движения (реализации решетки транспортных магистралей и режима «тотальной зеленой волны») КНС и ЦУТ способны обеспечить среднюю скорость в городских условиях более 45 км/ч. Совокупная экономия затрат на последнюю милю доставки в результате их внедрения оценивается на уровне единиц процентов ВВП даже без учета социальных и экологических эффектов только за счет снижения аварийности и сокращения числа пробок.

Ключевые слова: коммуникационно-навигационная система, широковещательная радиосвязь, локальная система позиционирования, транспорт, центр управления.

1. Введение. Численность населения Земли достигла 8 млрд. человек. Большинство людей живет в городах, при этом сохраняется устойчивая тенденция урбанизации [1, 2]. Общая обеспеченность всех жителей планеты легковым автотранспортом превышает 10 %. Городской автопарк приближается к 1 млрд. автомобилей. Средняя скорость движения в городской инфраструктуре составляет 30 км в час, которая в часы пиковой нагрузки снижается в 1,5-2 раза, а при наличии проблем, вызывающих образование заторов, и втрое [3 – 5].

Главной задачей автодорожной инфраструктуры является обеспечение высокой эффективности (низкой стоимости и малых временных затрат) грузопассажирских перевозок. Уменьшение затрат времени на транспортировку не только экономит личное время участников движения, но и снижает себестоимость перемещаемых товаров.

Помимо заторов к существенному снижению эффективности перевозок приводят аварии, в которых наносится ущерб людям и технике [6 – 8]. Повышение безопасности дорожного движения за счет снижения эффективности (например, необоснованного ограничения скорости) чаще всего не оправдано с экономической точки зрения.

По разным оценкам экономический ущерб от дорожных заторов и аварий, которые тоже являются причинами заторов, составляет несколько единиц (от 2 до 7 в разных странах) процентов ВВП [9 – 11]. Такой уровень потерь является серьезным вызовом и мотивацией для анализа и поиска методов существенного повышения эффективности дорожного движения, что и является целью данной работы.

2. Автотранспортный коллапс в час пик. Рассмотрим причины возникновения заторов и влияние зон сложения или пересечения потоков на них [12 – 15]. Для анализа пропускной способности магистрали P введем понятие скорости потока F , пропорциональной числу полос N , средней скорости V и обратно пропорциональной среднему интервалу между автомобилями R :

$$F = NV / R, \quad (1)$$

где $R = L + D$, L – средняя длина транспортного средства (ТС), а D – средняя дистанция между ними, зависящая от скорости движения:

$$D(V) = D_0 + V\tau, \quad (2)$$

где D_0 – средняя дистанция между стоящими автомобилями, τ – среднее эффективное время реакции водителя. Интервал при нулевой скорости $R_0 = L + D_0$ определяет максимальное число стоящих автомобилей M , которое помещается на полосе длиной S : $M = S / R_0$.

Пропускная способность дороги между пересечениями с другими дорогами определяется тем ее участком, на котором

скорость потока минимальна при максимально разрешенной скорости движения:

$$P = F_{\min} (V_{\max}). \quad (3)$$

Максимальная скорость реализуется лишь при малой плотности ТС. Для анализа реальной пропускной способности в условиях высокой плотности движения введем понятие скорости потока по полосе F_1 :

$$F_1 = 1 / (\tau + R_0 / V). \quad (4)$$

Типичные значения R_0 находятся в диапазоне 6-10 м (зависит от доли грузовых автомобилей и автобусов), а эффективное время реакции водителей в диапазоне 0,5-1,5 с. Для средних значений (8 м и 1 с) даже при скорости 40 км/ч полоса способна пропускать более 2000 автомобилей за час. Отношение интервала R_0 и времени реакции, равное в данном случае 8 м/с (почти 30 км/ч), определяет точку перелома функции. Это означает, что увеличение скорости потока повышением средней скорости движения эффективно лишь в диапазоне малых скоростей. Например, увеличение разрешенной скорости движения на трассе с 90 до 120 км/час приводит к увеличению скорости потока на 6,6 %. В то же время снижение времени реакции (например, вдвое, с 1 с до 0,5 с за счет уменьшения интервала) на скорости 60 км/ч приводит к увеличению потока в 1,5 раза, а при снижении еще вдвое, до 0,25 с – в 2 раза.

Зависимость дистанции и интервала от скорости (2) приводит и к обратному эффекту, зависимости скорости от числа ТС. Если на трассах общей длиной полос S_t находится M автомобилей, то средний интервал движения составляет S_t / M , а средняя скорость:

$$V = (S_t / M - R_0) / \tau. \quad (5)$$

Подставив (5) в уравнение (4), получим выражение для скорости потока по полосе в зависимости от локальной плотности ТС:

$$F_1 = (1 - M / M_{\max}) / \tau, \quad (6)$$

где $M_{\max} = S_t / R_0$ – максимальное число ТС на полосе длиной S_t с интервалом R_0 . Введем понятие загруженности дорог $z = M / M_{\max}$, меняющейся от 0 до 1. Выражение (5) в этом случае примет вид:

$$V = \frac{(1-z)R_0}{\tau z}. \quad (7)$$

Формулы (6) и (7) корректны лишь при высоких значениях z , так как на свободных дорогах вступает в действие ограничение на допустимую скорость движения (60 км/час для населенных пунктов, например). Как показали расчеты, на городских трассах без пересечений существенное снижение скорости потока наступает лишь при очень высоком уровне загруженности дорог (от 70 до 90 %). На практике пробки возникают при гораздо меньшей плотности машин на дорогах, и их причиной являются перекрестки. На основных транспортных магистралях города в дневные часы движение регулируют светофоры.

Для выявления влияния различных факторов на снижение средней скорости движения в городе из-за заторов на регулируемых перекрестках была разработана численная модель. В ее рамках были введены понятия следующих средних величин: расстояния между светофорами, длительностей полного цикла и разрешающего сигнала, дальности поездки и ускорения при разгоне. Для расчета задержки на светофоре пропускная способность перекрестка определялась в двух вариантах: при разгоне после полной остановки и при движении без замедления. При заданном проценте светофоров «зеленой волны» вычислялась длина очереди автомобилей S_1 , пропускаемых за один такт светофора.

После определения загруженности дорог z через общее число ТС на дорогах города, интервал R_0 и длину полос всех магистралей вычислялось число автомобилей на рассматриваемом участке. Эффективная длина очереди перед светофором определялась произведением среднего расстояния между светофорами S_0 и степени загруженности дорог z : $S_2 = S_0 z$. В случае, когда S_2 превышало S_1 , время задержки на светофоре t_d рассчитывалось по формуле:

$$t_d = t_c (S_2 / S_1 - 1/2), \quad (8)$$

где t_c – средняя длительность цикла светофора. Иначе:

$$t_d = t_g (S_2 / S_1 - 1) (1 - t_g / 2t_c) + t_c / 2, \quad (9)$$

где t_g – средняя длительность разрешающего сигнала светофора. Формула (9) определяет среднюю величину задержки на светофоре при свободных дорогах (проезд перекрестка в период первого разрешающего сигнала светофора, а формула (8) учитывает число циклов, которое придется пропустить при высокой загруженности дорог.

Средняя скорость движения определялась делением расстояния между светофорами S_0 на время прохождения дистанции с учетом максимально разрешенной скорости на свободном участке $S_0 - S_2$. Модельная функция источника (числа ТС, начинающих поездку) позволяла варьировать плотность стартующих автомобилей в дневные часы и в часы пик по отдельности. Для определения общего количества автомобилей на дорогах города в каждый момент времени вычислялось и вычиталось число ТС, достигших средней дальности поездки. Задержки, связанные с перестроениями из полосы в полосу, модель не учитывала.

На рисунке 1 приведена модельная функция источника, средняя скорость движения и время поездки средней дальности от времени суток для рабочих дней. Исходные данные по числу автомобилей и длине полос городских магистралей оценивались для расчета загруженности на примере Санкт-Петербурга (без пригородов).

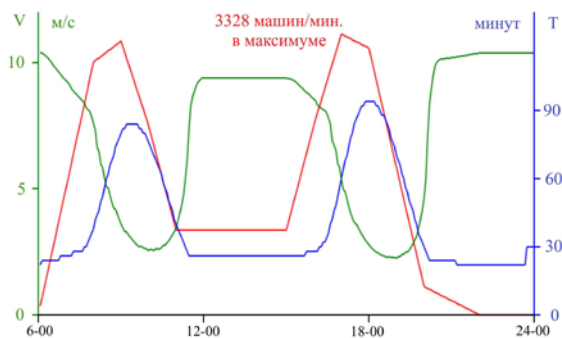


Рис. 1. Средняя скорость (зеленая кривая) и среднее время поездки (синяя кривая) в зависимости от времени суток. Красная кривая представляет модельную функцию источника (число стартующих машин)

При общей протяженности дорог более 3500 км [16] совокупная длина полос городских дорог с движением по двум и более полосам в одном направлении также находится в диапазоне от 3000 до 4000 км. В расчетах использовалось значение, равное 3400 км. По этим дорогам в часы пик передвигается более 50 процентов ТС, общая численность которых в городе превышает 2 млн. единиц. Приведенный пример с почти трехкратным увеличением времени поездки в часы пик соответствует случаю, когда число автомобилей, используемых для поездки на работу и обратно, составляет 360 тысяч единиц.

На рисунке 2 представлена зависимость потерь времени, вызванных загруженностью дорог, от общего времени движения всех ТС за сутки для трех значений средней реакции водителей. В первую очередь необходимо отметить близкий к пороговому характер перехода из состояния свободных дорог в состояние пробок и коллапса. Понятие «пробки» описывает состояние загруженности дорог, когда время на поездку средней дальности в час пик увеличивается в 2-4 раза (1-2 часа вместо 30 минут). При большей задержке фактически наступает коллапс. Дороги считаются свободными, если задержка не превышает 50 % от времени поездки (не более 45 минут для 30-минутной поездки).

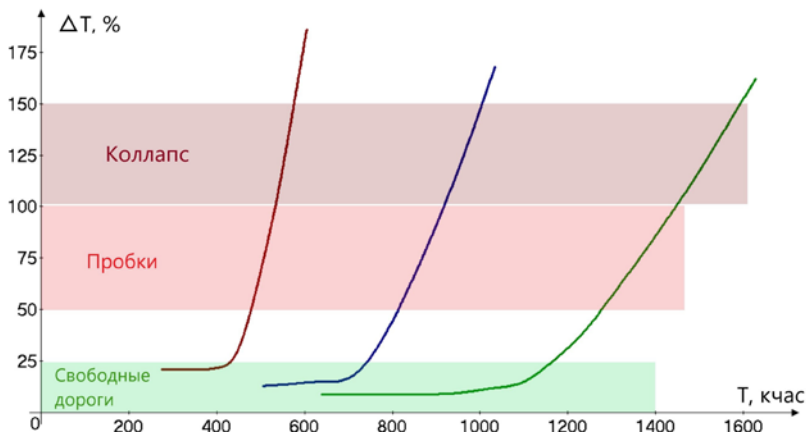


Рис. 2. Зависимость удельных потерь времени от общей загруженности дорог при разных значениях среднего времени реакции (0,5 с – зеленая кривая, 1 с – синяя кривая, 1,5 с – коричневая кривая)

При всех значениях среднего времени реакции водителей переход из состояния свободных дорог в состояние пробок происходит

при увеличении числа машин менее чем на 10 %. Для достижения состояния коллапса количество машин на дороге по сравнению со свободным трафиком должно возрасти не более чем на 20 %. Это вызвано эффектом аккумуляции (накопления), когда скорость освобождения трасс (достижения средней дальности поездки) падает из-за снижения средней скорости движения. В отличие от функции цели функция источника не зависит от загруженности трасс и средней скорости движения (время начала и окончания рабочего дня неизменно).

Кроме того, рисунок 2 демонстрирует сильную зависимость порога эффекта образования пробочного коллапса от времени реакции водителей. Чем меньше дистанция между ТС, тем выше скорость потока, тем быстрее происходит освобождение трасс, тем позже наступает перегруженность трасс из-за накопления автомобилей. Как показали расчеты, другие факторы (максимально разрешенная скорость, среднее ускорение, процент светофоров «зеленой волны» и т.п.) также влияют на величину порога, но в гораздо меньшей степени. Именно среднее время реакции и зависящая от него средняя дистанция между ТС являются ключевыми факторами эффективности автомобильных перевозок.

3. Обмен информацией и время реакции водителей. В настоящее время обмен информацией между участниками движения осуществляется исключительно с помощью простейших визуальных сигналов (указателей поворота и стоп-сигналов). Бинарный характер сигнала (включен или выключен) не позволяет ни оценить интенсивность торможения, ни дифференцировать маневры (перестроение, поворот, разворот). Экстренное торможение от плавного отличается лишь по скорости увеличения угловых габаритов ТС, что в сложных условиях приводит к существенной задержке реагирования на маневр. Другими словами, дистанция между автомобилями помимо факторов, характеризующих водителя (опытность, усталость, концентрация), определяется еще и внешними условиями (видимость, засветка, контраст).

В первом приближении состояние дорожного покрытия не влияет на выбор дистанции, но это верно лишь при одинаковой эффективности торможения следующих друг за другом ТС. Чем больше загруженность автомобиля и хуже состояние его покрышек, тем длиннее безопасная дистанция до впереди идущего автомобиля, особенно на скользком покрытии. Формируя требования к системе информационного обмена (СИО) между участниками движения, следует помимо предупреждения о маневрировании особо выделить

данные об эффективности тормозной системы. Эти сведения позволят бортовому компьютеру формировать рекомендации по выбору дистанции и предупреждать водителя об опасном сближении с соседними автомобилями.

С точки зрения обеспечения безопасности время реакции водителя, умноженное на скорость движения, определяет минимально допустимую дистанцию без учета других факторов, в том числе человеческих. Большинство аварий происходит по причине неверного распределения внимания водителя (потери из виду некоторых важных объектов, например, из-за чрезмерной его концентрации на других объектах). К таким объектам помимо соседних ТС относятся сигналы светофора, дорожные знаки, разметка, дефекты дорожного покрытия и другие предметы, влияющие на изменение вектора скорости автомобиля.

Контролируя обстановку, водитель обязан время от времени смотреть в заднее и боковые зеркала, отвлекаться на показания приборов (температура мотора, уровень топлива). На практике он совершает большое количество действий, не связанных с управлением движением (меняет режимы кондиционера, перемещает солнцезащитный козырек, пользуется навигатором). Ограничение в свободе действий водителя может негативно сказаться на сохранении тонуса и привести к сонливому состоянию на трассах с ограниченной потребностью в маневрировании. Поэтому в заботе о безопасности движения водителям рекомендуется соблюдать «правило двух секунд» при определении дистанции до впереди идущей машины [17].

К сожалению, данное правило, обеспечивая безопасность, радикально снижает эффективность, поскольку двухсекундный интервал соответствует времени реакции неопытного водителя. Для городских условий его соблюдение сегодня неприемлемо, поскольку соответствует очень низкому порогу образования пробок. На практике в условиях затрудненного движения в городе среднее время реакции водителя составляет 0,5-1,5 с (у профессионалов и опытных водителей оно не превышает 0,5 с). Это требует повышенной концентрации внимания и минимизации отвлечений, что с учетом человеческого фактора определяет высокий риск несущественных аварий. К сожалению, даже несущественные аварии, создавая серьезные помехи, являются дополнительным источником заторов и пробок.

Низкая эффективность перевозок в часы пиковой нагрузки определяется недостаточным количеством дорожных полос (для движения, а не для парковки) при существующем объеме автопарка в городах. Увеличение скорости потока за счет сокращения

дистанции между автомобилями невозможно из-за особенностей человеческой физиологии (совокупность факторов отвлечения и эффективная скорость реакции). Это выдвигает еще одно требование к СИО: она должна быть совместима со средствами автоматизации и роботизации управления транспортом. Переход к беспилотным ТС, минимизирующим влияние человеческого фактора, требует эффективного информационного обмена между ними.

Высокая скорость реакции водителю необходима не только для реагирования на экстренное торможение впереди идущего автомобиля. При плотном потоке любое маневрирование (поворот или перестроение) требует учета движения соседних ТС. Сегодня оценка их скорости и направления движения водителем производится визуально («на глазок»). Оценка ускорения или смещения (при том же перестроении) осуществляется практически по результату действия, что никак не способствует повышению безопасности. Другими словами, СИО должна способствовать повышению предсказуемости действий соседних участников движения.

Еще одним требованием к ней является слабая зависимость от погодных условий, что позволит компенсировать недостатки систем, собирающих информацию в оптическом диапазоне (глаз, видеокамер). Подобная зависимость от погоды характерна для электромагнитных волн радиочастотного диапазона. С их помощью в условиях ограниченной видимости (туман, дождь, снегопад) СИО должна обеспечивать дополнительный источник информации о дорожной обстановке.

При реализации перечисленных требований система обмена информацией о маневрировании позволит существенно повысить безопасность при одновременном сокращении интервала движения транспорта. Увеличение средней скорости движения и снижение стоимости перевозок определяется при этом сокращением времени реакции за счет автоматизации процесса соблюдения дистанции.

4. Коммуникационно-навигационная система в качестве СИО. В ряде изобретений [18, 19] авторы предлагают технологии обмена информацией (например, данными глобальной системы позиционирования) между ТС. Реализация СИО предполагает применение модулей связи, использующих существующие алгоритмы передачи информации типа протоколов мессенджеров, WLAN или им подобным. Беспроводные системы связи активно используются для роботизации транспортных операций или ассистирования водителям. В частности, для коммуникаций на дальности до 350 м разработан стандарт DSRC (dedicated short range communications) [20]. Он

использует протокол IEEE 802.11, предложенный Американским обществом интеллектуального транспорта и Департаментом транспорта США.

Недостатком подобных подходов является ориентация на формирование канала связи между двумя абонентами (каждого с каждым), в том числе с подтверждением корректности полученного пакета данных. Реализация интеллектуальных транспортных систем (ИТС) на технологиях V2V и V2X должна обладать универсальностью и, прежде всего, работоспособностью в условиях высокой плотности движения.

Транспортные потоки могут состоять из тысяч участников движения, при абонентской организации связи между ТС возникает потребность в миллионах коммуникационных каналов. Радиочастотный диапазон обладает ограниченными возможностями по объему передаваемой информации. При большом количестве абонентов в рабочей зоне неизбежна интерференция передаваемых сигналов и потеря оперативности, что не позволит организовать централизацию управления.

Альтернативой абонентской радиосвязи (от каждого каждому) является широкоэвещательная (от каждого всем). Данный подход к организации коммуникационно-навигационной системы (КНС) для обеспечения безопасности и эффективности дорожного движения за счет СИО предложен автором статьи в патенте на изобретение [21]. Проблема интерференции в этом случае решается за счет временного, а не спектрального разделения сигналов. При единых для всех ТС частоте повторения и длительности сигнала (например, 1 Гц и 5 мкс) вероятность интерференции даже для 1000 автомобилей составляет доли процента.

Потребность в размерах зоны уверенного приема с точки зрения обеспечения предсказуемости маневрирования соседних ТС составляет от 150 до 300 метров. Эти расстояния соответствуют времени распространения радиоизлучения менее 1 мкс, что почти не увеличивает период приема сигнала. При случайном пересечении двух пакетов во времени бортовые модули КНС участников конфликта автоматически смещают свои сигналы в ближайшие свободные интервалы.

Передача радиочастотного излучения осуществляется по хорошо отработанным технологиям беспроводной высокочастотной связи. Для этого необходимо выделить полосу шириной 100 МГц в гигагерцовом диапазоне (от 4 до 8 ГГц) исключительно для обмена навигационной информацией между участниками движения.

В этом случае уже реализованные скорости передачи информации (40 Мбит в секунду) обеспечат за 5 мкс трансляцию пакета размером до 25 байт.

Всю передаваемую информацию целесообразно разделить на идентификационную, оперативную (навигационную) и экстренную. Так как идентификационная информация не меняется, ее можно передавать в течение нескольких сигналов (например, пяти секунд) по 1 байту. Для присвоения уникальных номеров всем транспортным средствам на Земле достаточно 5 байтов, что соответствует более чем триллиону комбинаций. В состав идентификационной информации целесообразно включать данные об эффективности тормозной системы автомобиля.

Навигационная информация в силу своей оперативности занимает основную часть передаваемого сигнала. Формат передачи данных зависит от режима движения и наличия электронных карт местности в бортовом оборудовании машины. При отсутствии привязки к существующей дорожной системе и использовании системы глобального позиционирования в качестве оперативной рассматриваются секунды и доли секунд долготы и широты места. Передача градусов и минут долготы и широты места не требует оперативности, достаточно трансляции по 1 байту в течение пяти сигналов. Оперативной также является информация о векторе движения ТС (передается ежесекундно).

При наличии электронных карт и привязке к транспортным магистралям формат передачи данных в КНС меняется на сетевой (номер дороги, номер полосы, расстояние от нулевой координаты трассы). В случае транспортного режима движения по навигатору указываются ближайшие две-три точки маневров (поворотов, остановок). Данная информация существенно повышает предсказуемость поведения участников движения с точки зрения перестроений ТС.

Экстренная информация о совершении незапланированного маневра (экстренное торможение, занос, уход от столкновения, смена полосы) передается в ближайший свободный интервал времени. Учитывая тот факт, что бортовой модуль КНС при отслеживании траекторий соседних ТС составляет расписание принимаемых сигналов в виде таблицы, задержка не превысит нескольких десятков микросекунд.

Корректность принимаемых сигналов проверяется по соответствию контрольным суммам. В случае отсутствия соответствия сигнал считается непринятым, и бортовой модуль

ожидает прихода следующего. Для оперативных данных период обновления информации составляет 1 с, для не оперативных – 5 с, а для экстренных – от 10 до 100 мс в зависимости от скорости реакции систем управления ТС.

5. Оперативное управление дорожным движением при помощи СИО. Для оперативного управления движением в зонах высокой плотности автотранспорта предлагается [21] создавать центры управления транспортом (ЦУТ). Ключевой задачей Центров является обеспечение высокой эффективности транспортных потоков (минимизация временных и финансовых затрат на перевозки) в зоне их ответственности.

Задача обеспечения безопасности остается главной для бортовых модулей КНС. ЦУТ не реализует прямого управления транспортом, а лишь вводит ограничения (обязательные для исполнения) и разрабатывает рекомендации (необязательные для исполнения). Выбор маршрута, режима движения и, самое главное, принятие решения о маневре с точки зрения безопасности остается за водителем (бортовой системой управления). ЦУТ же является ИТС с реализацией технологии V2X.

Целью деятельности Центров является не глобальная оптимизация всех транспортных потоков, а лишь разрешение локальных конфликтов, что позволяет им действовать почти независимо друг от друга. По своей сути ЦУТ является виртуальным регулировщиком движения (диспетчером), которому известна дорожная ситуация, режимы и цели всех ТС. При этом он может оперативно менять режимы всех светофоров в рабочей зоне и разрабатывать рекомендации по оптимизации движения для всех автомобилей с бортовыми модулями КНС.

Чтобы повысить надежность навигационной привязки, в зоне ЦУТ формируется локальная система позиционирования (ЛСП), базирующаяся на тех же принципах трилатерации, что и глобальная [22]. Ее принцип действия приведен на рисунке 3. По задержке прихода сигналов определяется разница в расстояниях до стационарных приемо-передающих станций (ППС), находящихся в зоне приема. Положение ТС определяется как точка на подстилающей поверхности, для которой сумма квадратов отклонений от измеренных разниц дистанций минимальна.

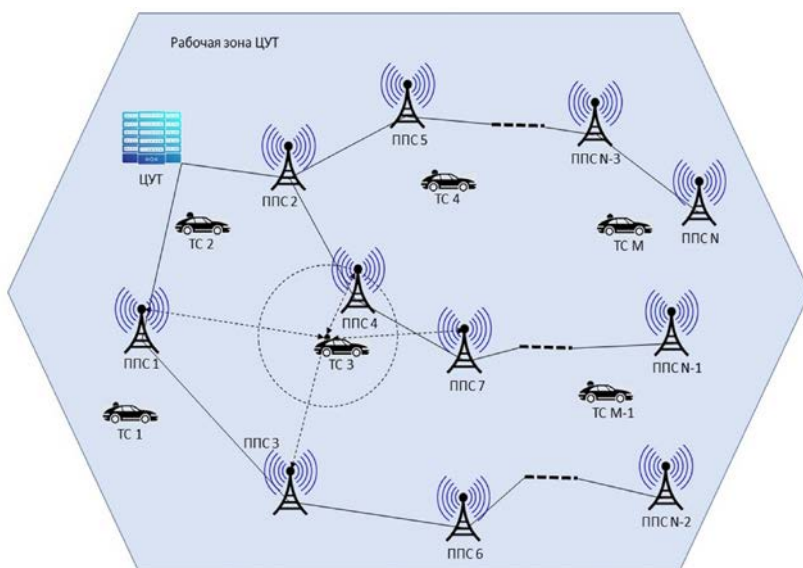


Рис. 3. Принцип функционирования локальной системы позиционирования

Реализация ЛСП потребует выделения еще одного частотного интервала в гигагерцовом диапазоне полосой порядка 100 МГц. Помимо позиционных сигналов данный интервал целесообразно использовать еще и для передачи команд управления индивидуального и группового характера. Стационарные ППС располагаются в зоне ЦУТ так, чтобы на всех основных магистралях погрешность позиционирования не превышала 20 – 25 см.

ЛСП позволяет реализовать режим временной привязки всех сигналов (и позиционных, и КНС) к синхроимпульсу Центра. Для этого все ППС имеют порядковый номер, определяющий временную задержку относительно синхроимпульса их позиционного сигнала. Позиционный сигнал служит для определения бортовым модулем КНС положения ТС. Информация о положении всех ППС размещается в открытых источниках и загружается в бортовой модуль КНС заранее (или при въезде в зону ЦУТ). Из момента времени получения позиционного сигнала вычитается интервал задержки, умноженный на номер станции, и время распространения сигнала от станции до транспорта, полученное делением расстояния на скорость света.

Интервал генерации навигационных сигналов бортовыми модулями КНС делится на такты (например, период в 1 с – на 200 000 тактов по 5 мкс), привязанные к синхроимпульсу Центра. При нахождении в зоне ЦУТ каждому ТС выделяется номер такта для передачи сигнала КНС, что упрощает задачу идентификации. При въезде в зону Центра ТС сообщает ЦУТ свой идентификационный номер, после чего его регистрация завершается выделением ему свободного номера такта.

Другим упрощением информационного обмена в зоне ЦУТ является регистрация транспортных коридоров (полос движения) и парковочных мест. Это позволяет сигнал КНС в зоне ЦУТ ограничить одним байтом признака навигационного сигнала с описанием режима движения, четырьмя байтами описания текущего местоположения транспорта (с субметровой точностью), четырьмя байтами описания ближайших точек маневра (смены транспортного коридора) и одним байтом контрольной суммы. Требования к погрешности описания точек маневра лежат в метровом и декаметровом диапазонах.

Функциональная схема системы, состоящей из бортовых модулей КНС, центра управления транспортом и его приемо-передающих станций приведена на рисунке 4. Для определения позиции автомобиля вне зоны ЦУТ в состав бортового модуля входит приемник глобальной системы позиционирования. Расчет положения автомобиля на момент передачи сигнала КНС осуществляется с помощью бесплатформенной инерциальной навигационной системы (БИНС) и навигационного вычислителя.

Информация со всех ЦУТ города поступает в городской аналитический центр (ГАЦ) для выявления транспортных проблем, требующих оперативного решения на уровне муниципальных властей. Связь ЦУТ с сетью ППС осуществляется по волоконным кабелям, обеспечивающим высокую надежность синхронизации часов станций, генерации позиционных сигналов и привязки сигналов КНС. При необходимости ЦУТ обращается в дорожную службу для оперативного разрешения конфликтов (патруль) и восстановления рабочего состояния дорожной инфраструктуры (ремонт).

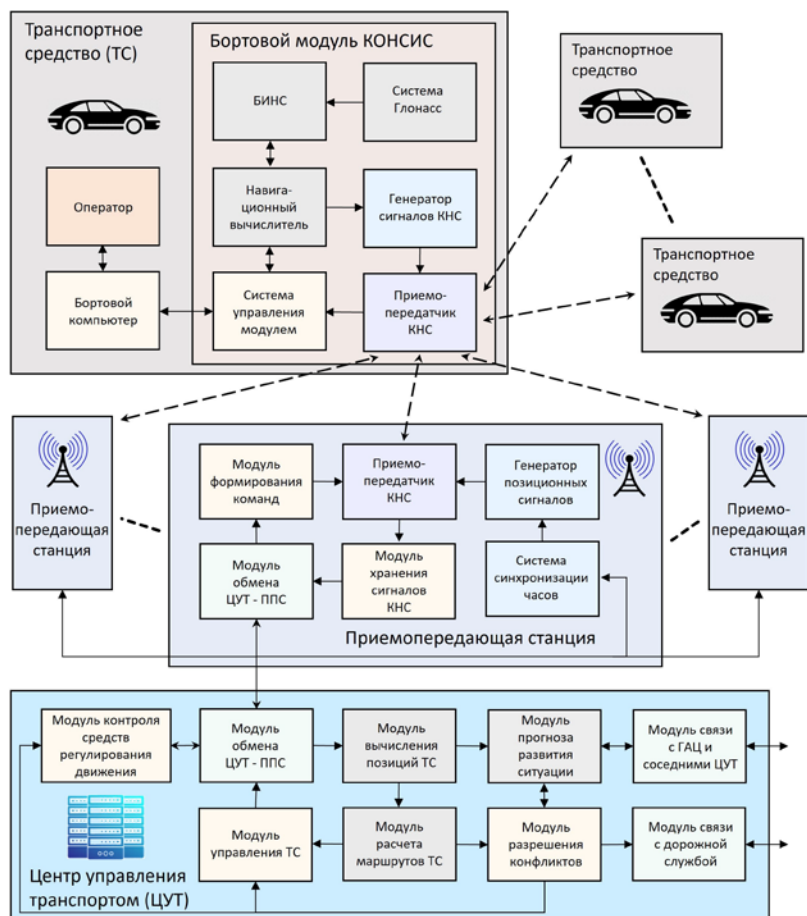


Рис. 4. Функциональная схема коммуникационно-навигационной системы

Реализация ЛСП на базе ППС позволяет осуществлять контроль работоспособности бортовых модулей. Благодаря дуплексному характеру связи не только ТС получает позиционные сигналы нескольких ППС, но и несколько ППС регистрируют сигнал КНС модуля ТС. Это обстоятельство позволяет ЦУТ тоже определять позицию ТС. Алгоритм верификации данных бортового модуля по времени получения сигнала КНС приемо-передатчиками станциями ЦУТ (сравнение расчетов позиции на борту ТС и в ЦУТ) приведен на рисунке 5.

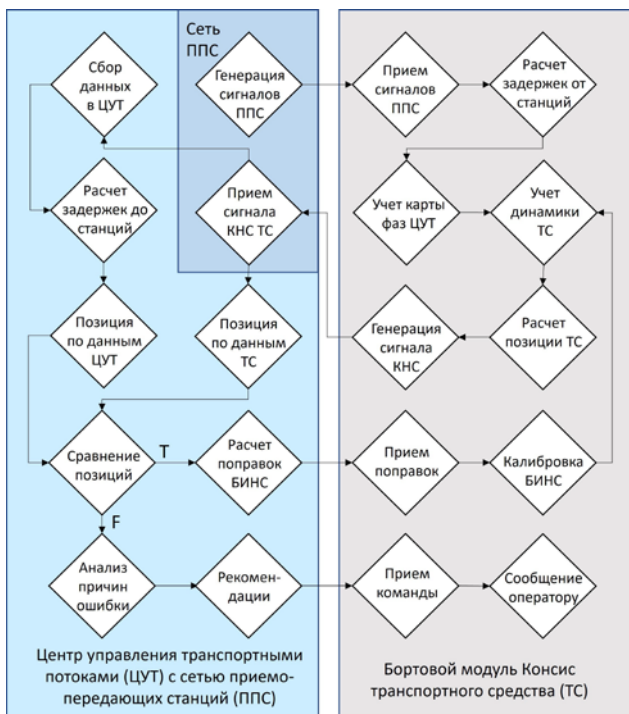


Рис. 5. Алгоритм верификации навигационных расчетов

Для решения ключевой задачи минимизации временных потерь в местах сужения дорог (уменьшения числа полос) необходимо обеспечить увеличение скорости потока, компенсирующее снижение сечения. В первую очередь это можно осуществлять за счет сокращения интервала движения, а при возможности и за счет увеличения скорости. В местах сужения дорог ЦУТ должен осуществлять управление очередностью перестроения и прохождения зоны потенциального затора.

На перекрестках ЦУТ играет роль виртуального регулировщика, который формирует транспортные пакеты сразу после прохождения предыдущего перекрестка. Режим движения рассчитывается так, чтобы к моменту включения разрешающего сигнала светофора передний фронт пакета достиг границ перекрестка на максимальной скорости. Внутри транспортного пакета автомобили располагаются по дальности движения без поворотов (т.е., кому дальше ехать прямо, выдвигаются вперед).

Если по техническим или иным причинам несколько автомобилей из пакета не в состоянии успеть пересечь перекресток по разрешающему сигналу, то команды управления ЦУТ замедляют их заранее. Дальнейший режим движения рассчитывается по алгоритму, описанному выше, но замедление осуществляется при возможности без полной остановки автомобиля.

Наличие бортовых модулей КНС позволяет существенно сократить дистанцию между ТС без снижения уровня безопасности благодаря надежному каналу информирования об экстренной ситуации. По оценкам прохождение перекрестка на максимальной скорости с уменьшением дистанции между автомобилями позволяет втрое увеличить его пропускную способность. Это практически снимает проблему регулируемого перекрестка как основного источника заторов, связанных с эффективным сужением дороги (не в пространстве, а во времени).

Внедрение радиочастотного информационного обмена и централизация управления создает инфраструктуру, необходимую для роботизации автотранспорта. Видеокамеры и лидары собирают большой объем информации, требующей многоэтапной обработки, что накладывает серьезные ограничения на оперативность автономного управления. Для движения в регламентированных условиях городской дорожной инфраструктуры при наличии радиочастотного управления видеопоток играет вспомогательную роль обнаружения нестандартных ситуаций.

6. Информационный обмен как помощь при организации дорожного движения. Внедрение технологий информационного обмена и централизация управления движением с его помощью существенно упрощает решение проблем пробок и эффективного использования магистралей. Между тем, достижение максимальной эффективности транспортных перевозок в городских условиях требует изменения подхода к организации движения. В частности, организация режима зеленой волны на подавляющем большинстве транспортных магистралей по простейшим оценочным расчетам позволяет увеличить среднюю скорость с 25-35 км/ч до 45-50 (ниже представлено моделирование режима).

Авторы изобретения [23] предлагают в городах формировать решетки основных дорог и организовывать синхронную работу светофоров на всех регулируемых перекрестках решетки. Для реализации режима «тотальной зеленой волны» половина светофоров на перекрестках работает в фазе А, а вторая половина – в противофазе

В (со сдвигом на 180 градусов). На пересечениях основных дорог фазы А и В чередуются.

На практике сеть существующих магистралей имеет большое количество дефектов прямоугольной решетки. В частности, к ним относятся элементы радиальной структуры и светофоры на перекрестках основных дорог со второстепенными. Данное обстоятельство снижает эффективность движения, но главным достоинством предложения является повышение предсказуемости работы средств регулирования.

В среднем период цикла сигналов у светофоров составляет 120 с. Если расстояние между перекрестками дорог с противофазными сигналами находится в диапазоне от 660 до 1320 м, рекомендуемая скорость ТС для реализации режима «тотальной зеленой волны» варьируется в диапазоне от 40 до 80 км/ч. На длинных участках дорог, где требуется скорость выше допустимой в городе, можно поставить ограждения.

На рисунке 6 проанализирована возможность формирования решетки транспортных магистралей и режима «тотальной зеленой волны» на примере северной части Санкт-Петербурга. В рассмотренной зоне площадью 130 кв. км проживает четверть населения города (более 1 млн. 300 тысяч жителей, приблизительно 500 тысяч машин). Общая длина полос дорог, выбранных в качестве основных транспортных магистралей, составляет 750 км, что подтверждает оценку, сделанную выше.



Рис. 6. Вариант формирования решетки транспортных магистралей с двухфазным режимом работы светофоров для организации «тотальной зеленой волны» на примере северных районов Санкт-Петербурга

В режиме, предложенном авторами изобретения [23], расстояние между центрами эллипсов разного цвета (зонами синхронно работающих светофоров) преодолевается за 1 минуту. Таким образом, по прямой в любом направлении на проезд 8-13 км тратится от 8 до 13 минут, что соответствует средней скорости в 60 км/ч. На каждом повороте затрачивается в среднем 1 дополнительная минута с соответствующим замедлением без полной остановки.

При средней дистанции поездки в 15 км с учетом выезда из улиц на магистральную решетку, поворотов и съезда на улицы время поездки сокращается до 18-20 минут (45-50 км/ч). На 750 км полос со средней скоростью 60 км/ч при времени реакции водителей 1 с помещаются 30 тысяч ТС (40 автомобилей на 1 км с интервалом в 25 м). С учетом длительности пикового периода в три часа это соответствует пропускной способности магистралей за указанное время в 300 тысяч ТС (более половины автомобилей, базирующихся в рассматриваемой зоне).

Централизация управления движением за счет информационного обмена на базе КНС позволяет обеспечить максимальные преимущества режима «тотальной зеленой волны». Даже при наличии дорожных указателей рекомендуемой скорости трудно ожидать от водителей точного соблюдения рекомендаций, а любое отклонение приводит к снижению пропускной способности перекрестков. Также идея чередования противофазных сигналов не решает проблему сужения дороги перед перекрестком из-за выстраивания очереди автомобилей, осуществляющих повороты (налево или направо) и разворот.

Команды ЦУТ осуществляют между перекрестками перестроение ТС по упомянутому выше принципу: т.е., кому дальше ехать по прямой, выдвигаются вперед. Сформированный транспортный пакет замыкают поворачивающие на ближайшем перекрестке. При этом появляется возможность при достаточной длине перекрестка использовать для поворотов три полосы (правая – направо, центральная – направо и налево, левая – налево и на разворот). ЦУТ имеет возможность менять длительность поворотной части зеленого сигнала в зависимости от числа машин, осуществляющих смену транспортного коридора.

Подводя итог изложенному выше, необходимо отметить техническую реализуемость концепции, поскольку все потребные технологии существуют и отработаны. В данной статье не рассматриваются экономические, социальные, экологические и другие,

не технические, аспекты внедрения технологий обмена навигационной информацией между ТС. Увеличение эффективности перевозок при одновременном повышении их безопасности определяет экономическую перспективность подхода. Оценка затрат оказывается гораздо ниже потенциальной выгоды, что обеспечивает инвестиционную привлекательность. Механизму внедрения технологии, экономическим, социальным и экологических эффектам будет посвящена отдельная статья.

7. Заключение. Основной причиной снижения эффективности дорожного движения в часы пик в городе является накопление ТС на магистралях из-за недостаточной пропускной способности магистралей. Расчеты показали, что доминирующим фактором, определяющим пропускную способность регулируемых перекрестков, является интервал между ТС. Сокращение дистанции между автомобилями требует автоматизации ее соблюдения за счет применения эффективной системы обмена информацией на базе широкополосной радиосвязи.

Разделение сигналов не по спектру, а во времени в этом случае позволяет сформировать коммуникационно-навигационную систему, сохраняющую работоспособность при высокой плотности ТС. На ее базе появляется возможность формировать центры управления транспортом для оперативного управления дорожным движением. Распределение приемо-передающих станций ЦУТ по рабочей зоне обеспечивает формирование локальной системы позиционирования, обеспечивающей оперативный контроль всех ТС с модулями КНС.

Сочетание технологий ИТС с рациональной организацией дорожного движения позволяет добиться положительного синергетического эффекта в вопросе повышения его эффективности. Формирование решетки транспортных магистралей в городах с синхронизацией всех светофоров на ней с чередованием противофазных режимов позволит увеличить среднюю скорость движения до значений, близких к максимально разрешенным. Экономический, социальный и экологический эффект от такого повышения эффективности оценивается в несколько единиц процентов ВВП мира, их более подробному анализу будет посвящена следующая статья.

Литература

1. Babu A.M. Study of Urban Cities Traffic Problems Due to Delay and Overcrowding // International Journal of Latest Engineering and Management Research. 2017. vol. 02, no. 11. pp. 01-08.

2. Parupalli S.C. Trends in global urbanization // *Engineering Review*. 2022. URL: engmag.in/trends-in-global-urbanization (дата обращения: 17.09.2022).
3. Cheevarunothai P., Kaewpikul R. Empirical Study on Maximum Traffic Throughputs at Intersections // *MATEC Web of Conferences*. 2019. vol. 259. art. no.02008.
4. Dhamaniya A., Chandra S. Influence of Operating Speed on Capacity of Urban Arterial Midblock Sections // *International Journal of Civil Engineering*. 2017. vol. 15, pp. 1053–1062.
5. Sardari R., Hamidi S., Pouladi R. Effects of Traffic Congestion on Vehicle Miles Traveled // *Transportation Research Record*. 2018. vol. 2672(47). pp. 92-102.
6. Zhenga Z., Wanga Z., Zhub L., et al. Determinants of the congestion caused by a traffic accident in urban road networks // *Accident Analysis & Prevention*. 2020. vol. 136, art. no. 105327.
7. Retallack A.E., Ostendorf B., Current Understanding of the Effects of Congestion on Traffic Accidents // *International Journal of Environmental Research and Public Health*, 2019. vol. 16. iss. 18. art. no. 3400.
8. Sharifi, A. Urban form resilience: A meso-scale analysis // *Cities*. 2019. vol. 93, pp. 238-252.
9. Wijnen W., Weijermars W., Vanden Berghe W., et al. Crash cost estimates for European countries // Report “Deliverable 3.2 of the H2020 project SafetyCube”. 2017. URL: swov.nl/nl/publicatie/crash-cost-estimates-european-countries (дата обращения: 17.09.2022).
10. Suwa A., Iguchi M. Sustainability and the Automobile Industry in Asia: Policy and Governance // *Routledge*. 2020. 178 p.
11. Черемисина Н.В., Черемисина Т.Н., Гришко Ю.С. Дорожно-транспортные происшествия в России: экономико-статистический анализ // *Вестник Северо-Кавказского федерального университета*. 2020. № 3 (78). С. 113-121.
12. Sun C., Pei X., Hao J., Wang Y., et al. Role of road network features in the evaluation of incident impacts on urban traffic mobility // *Transportation Research Part B: Methodological*, 2018. vol. 117. pp. 101-116.
13. Koźlak A., Wach D. Causes of traffic congestion in urban areas. Case of Poland // *SHS Web of Conferences*. 2018. vol. 57, art. no. 01019.
14. Song J., Zhao C., Zhong S., et al. Mapping spatiotemporal patterns and detecting the factors of traffic congestion with multi-source data fusion and mining techniques // *Computers, Environment and Urban Systems*. 2019. vol. 77. art. no. 101364.
15. He F., Yan X., Liu Y., et al. A traffic congestion assessment method for urban road networks based on speed performance index // *Procedia Engineering*. 2016. vol. 137, pp. 425-433.
16. Официальный сайт Администрации Санкт-Петербурга. URL: www.gov.spb.ru (дата обращения: 17.09.2022).
17. Toma S. Take your time for the two-second rule: This is what it means and how it's done // *Autoevolution*, 2022. Apr 16. URL: www.autoevolution.com/news/take-your-time-for-the-two-second-rule-this-is-what-it-means-and-how-it-s-done-186579.html (дата обращения: 17.09.2022).
18. Stählin U., Menzel M.Dr., Baier R. Communication device for vehicle for wireless transmission of vehicle-relevant data to another vehicle or to infrastructure, has communication unit for transmitting vehicle-relevant data to other vehicle. Patent DE102008009330A1. Germany. 2008.
19. Hee B.L. Navigation system and method for exchange mutual location information using messenger. Patent CN101910797A, China, 2007.
20. Kenney J.B. Dedicated Short-Range Communications (DSRC) Standards in the United States // *Proceedings of the IEEE*. 2011. vol. 99. no. 7. pp. 1162-1182.

21. Грязнов Н.А. Коммуникационно-навигационная система для управления транспортными потоками. Патент на изобретение № 2770938. Россия. 2022.
22. Djuknic G.M., Richton R.E. Geolocation and Assisted GPS // Computer. 2001. pp. 123-125.
23. Huixi Z., Yuhuai W., Kang A. et al. Urban road traffic control signal generation method. Patent CN113763729A. China. 2021.

Грязнов Николай Анатольевич — канд. физ.-мат. наук, директор, институт цифровой безопасности, Санкт-Петербургский государственный морской технический университет. Область научных интересов: робототехника, автоматизация технологических процессов, лазерные системы, сбор и обработка информации, сенсорное оснащение роботов, подводные и космические роботизированные системы, навигация и связь. Число научных публикаций — 110. gna@corp.smtu.ru; Лоцманская улица, 3, 190121, Санкт-Петербург, Россия; р.т.: +7(812)495-2648.

N. GRYAZNOV
NAVIGATION DATA EXCHANGE FOR TRAFFIC CONTROL

Gryaznov N. Navigation Data Exchange for Traffic Control.

Abstract. An increase in the number of cars is higher than rates of transport infrastructure development, resulting in a reduction of cargo and passenger transportation efficiency in city conditions. Simulation of flow irregularity in time (peak hour) shows the key role of a car motion interval as a factor of overcoming accumulation at average speed reduction in conditions of highly loaded roads. To reduce the effective time of driver reaction, defining the least distance between cars, it is necessary to minimize the influence of human factors. Automation of the process (unmanned control) requires an effective exchange of navigation and route data between traffic participants. A summary of requirements for such an information exchange system defines the priority of the suggested communication and navigation system (CNS) on the base of radio broadcast communication. Its application gives an opportunity to rise simultaneously traffic safety and efficiency. An increase in neighbor driver action predictability leads to traffic safety ensuring. The exchange of data with traffic control centers (TCC) enables the centralization of motion regulation. A distributed network of transceiver stations forms a local positioning system based on trilateration principles. Algorithms of onboard positioning result verification and automatic resolution of communication conflicts ensure high reliability of CNS functioning. Refusal from point-to-point communication principles allows it to operate even in conditions of high car density up to several thousand per square kilometer. In cooperation with advanced technologies of traffic organization (formation of city highway grid and “total green wave” mode), CNS and TCC are capable of rising the average speed in city conditions higher than 45 km/hour. The aggregate economy of expense on last mile transportation because of the suggested innovations is to be at the level of several GDP percent due to a decrease in accidents and congestion even without accounting for social and ecological effects.

Keywords: communication and navigation system, broadcast communication, local positioning system, transport control center, transport, control center.

References

1. Babu A.M. Study of Urban Cities Traffic Problems Due to Delay and Overcrowding. *International Journal of Latest Engineering and Management Research*. 2017. vol. 02, no. 11, pp. 01-08.
2. Parupalli S.C. Trends in global urbanization. *Engineering Review*. 2022. URL: engmag.in/trends-in-global-urbanization (дата обращения: 17.09.2022).
3. Cheevarunothai P., Kaewpikul R. Empirical Study on Maximum Traffic Throughputs at Intersections. *MATEC Web of Conferences*. 2019. vol. 259. art. no.02008.
4. Dhamaniya A., Chandra S. Influence of Operating Speed on Capacity of Urban Arterial Midblock Sections. *International Journal of Civil Engineering*. 2017. vol. 15, pp. 1053–1062.
5. Sardari R., Hamidi S., Pouladi R. Effects of Traffic Congestion on Vehicle Miles Traveled. *Transportation Research Record*. 2018. vol. 2672(47). pp. 92-102.
6. Zhenga Z., Wanga Z., Zhub L., et al. Determinants of the congestion caused by a traffic accident in urban road networks. *Accident Analysis & Prevention*. 2020. vol. 136, art. no. 105327.

7. Retallack A.E., Ostendorf B., Current Understanding of the Effects of Congestion on Traffic Accidents. *International Journal of Environmental Research and Public Health*, 2019. vol. 16. iss. 18. art. no. 3400.
8. Sharifi, A. Urban form resilience: A meso-scale analysis. *Cities*. 2019. vol. 93, pp. 238-252.
9. Wijnen W., Weijermars W., Vanden Berghe W., et al. Crash cost estimates for European countries. Report "Deliverable 3.2 of the H2020 project SafetyCube". 2017. Available at: swov.nl/nl/publicatie/crash-cost-estimates-european-countries (accessed: 17.09.2022).
10. Suwa A., Iguchi M. Sustainability and the Automobile Industry in Asia: Policy and Governance. Routledge. 2020. 178 pages.
11. Cheremisina N.V., Cheremisina T.N., Grishko Yu.S. [Road transport accidents in Russia: economical statistical analysis]. *Vestnik Severo-Kavkazskogo federal'nogo universiteta [North-Caucasus federal university bulletin]*. 2020. no. 3 (78). pp. 113-121. (In Russ.).
12. Sun C., Pei X., Hao J., Wang Y., et al. Role of road network features in the evaluation of incident impacts on urban traffic mobility. *Transportation Research Part B: Methodological*, 2018. vol. 117. pp. 101-116.
13. Koźlak A., Wach D. Causes of traffic congestion in urban areas. Case of Poland. *SHS Web of Conferences*. 2018. vol. 57, art. no. 01019.
14. Song J., Zhao C., Zhong S., et al. Mapping spatiotemporal patterns and detecting the factors of traffic congestion with multi-source data fusion and mining techniques. *Computers, Environment and Urban Systems*. 2019. vol. 77. art. no. 101364.
15. He F., Yan X., Liu Y., et al. A traffic congestion assessment method for urban road networks based on speed performance index. *Procedia Engineering*. 2016. vol. 137, pp. 425-433.
16. Oficial'nyi sait Administratsii Sankt-Peterburga [Official site of St. Petersburg Administration]. Available at: www.gov.spb.ru (accessed: 17.09.2022). (In Russ.).
17. Toma S. Take your time for the two-second rule: This is what it means and how it's done. *Autoevolution*, 2022. Apr 16. Available at: www.autoevolution.com/news/take-your-time-for-the-two-second-rule-this-is-what-it-means-and-how-it-s-done-186579.html (accessed: 17.09.2022).
18. Stählin U., Menzel M.Dr., Baier R. Communication device for vehicle for wireless transmission of vehicle-relevant data to another vehicle or to infrastructure, has communication unit for transmitting vehicle-relevant data to other vehicle. Patent DE102008009330A1. Germany. 2008.
19. Hee B.L. Navigation system and method for exchange mutual location information using messenger. Patent CN101910797A, China, 2007.
20. Kenney J.B. Dedicated Short-Range Communications (DSRC) Standards in the United States. *Proceedings of the IEEE*. 2011. vol. 99. no. 7. pp. 1162-1182.
21. Gryaznov N.A. Kommunikatsionno-navigatsionnaya Sistema dlya upravleniya transportnymi potokami [Communication and navigation system for traffic control]. Patent RU2770938C1. Russia. 2022. (In Russ.).
22. Djuknic G.M., Richton R.E. Geolocation and Assisted GPS. *Computer*. 2001. pp. 123-125.
23. Huixi Z., Yuhuai W., Kang A. et al. Urban road traffic control signal generation method. Patent CN113763729A. China. 2021.

Gryaznov Nikolay — Ph.D., Director, Digital safety institute, State Marine Technical University. Research interests: robotics, automation of technological processes, laser systems, data gathering and processing, robot sensorics, undersea and space robotic systems, navigation and communication. The number of publications — 110. gna@corp.smtu.ru; 3, Lotsmanskaya St., 190121, St. Petersburg, Russia; office phone: +7(812)495-2648.

S.S. PATIL, Y.M. PATIL, S.B. PATIL
**REVIEW ON AUTOMATIC VARIABLE-RATE SPRAYING
SYSTEMS BASED ON ORCHARD CANOPY
CHARACTERIZATION**

Patil S.S., Patil Y.M., Patil S.B. Review on Automatic Variable-Rate Spraying Systems Based on Orchard Canopy Characterization.

Abstract. Pesticide consumption and environmental pollution in orchards can be greatly decreased by combining variable-rate spray treatments with proportional control systems. Nowadays, farmers can use variable-rate canopy spraying to apply weed killers only where they are required which provides environmental friendly and cost-effective crop protection chemicals. Moreover, restricting the use of pesticides as Plant Protection Products (PPP) while maintaining appropriate canopy deposition is a serious challenge. Additionally, automatic sprayers that adjust their application rates to the size and shape of orchard plantations has indicated a significant potential for reducing the use of pesticides. For the automatic spraying, the existing research used an Artificial Intelligence and Machine Learning. Also, spraying efficiency can be increased by lowering spray losses from ground deposition and off-target drift. Therefore, this study involves a thorough examination of the existing variable-rate spraying techniques in orchards. In addition to providing examples of their predictions and briefly addressing the influences on spraying parameters, it also presents various alternatives to avoiding pesticide overuse and explores their advantages and disadvantages.

Keywords: variable-rate spraying system, canopy detection and characterization, deep learning, machine learning, canopy structural characteristics, sensing.

1. Introduction. A canopy is a portion of a plant community that is found above ground and is generated by the crowns of individual plants [1]. In horticulture, a canopy is a topmost tree, or branches of trees, moreover, in a desert that has been well-maintained for a long time. Also, in a forestry environment, the canopy is the uppermost layer of bioactivity, since the understory layer is shorter than the canopy layer. In the orchard, the canopy is the most likely to find both the edible fruits of plants and the insects that feed on those fruits and the leaves of the plants. On the other hand, a canopy can refer to an elevated physical structure to shade or stop rain or other precipitation from falling in a specific region. Since tree crops come in various forms and sizes, even throughout the same growing season, it's essential to optimize the applied dose regularly to enhance squirt application productivity. Sprayers with the authentic control process must maintain a consistent squirt installment on harvest awnings while minimizing squirt failures. These technologies depend upon various substantial features that can permit canopy checking. For example, reflected light spectrum analysis, laser-based probes, and ultrasonic sensors can be used.

The author [2] proposes outfitting an air-assisted sprayer with a technology demonstrator of a digital system based on ultrasonic sensor and approximately equal control devices for roughly equivalent proposals to the tree crown thickness of forest plantations. The sprayer movement cost was adjusted depending on the connection between the orchard's maximum tree thickness and the actual thickness of the plant recorded by ultrasonic sensor. The design was put through its paces in almond, peach, and apple trees to evaluate the performance of systems in varied crop geometries. In comparison to traditional air-assisted applications, the spray deposit distribution was measured. Squirt reserves were found on the same samples for every therapy using metal tracers, decreasing sampling variability.

The group or longitudinal layout three-dimensional (3D) shape of a tree canopy is known as canopy structure. The leaf area index, or the number of leaves per land surface unit, is critical for assessing plant canopies [3]. Farmers can utilize canopy density mapping to better manage their orchards, which can enable them to improve the average tree volume and regulate the most appropriate squirt quantity. Various sensing technologies have been used to map canopy density in orchards, including 2D LiDARs, 3D LiDARs, Ultrasonic sensors, RGB cameras, Depth cameras, Infrared sensors, and Hyperspectral and Stereo cameras. Others have combined these sensors to provide a better picture of canopy density whereas some existing researchers choose ultrasonic sensors to calculate the canopy density.

The laser scanner LiDAR stands for Light Detection and Ranging. The author [4] compares measurements by citrus foliage volume to the manual measurements technique for fifteen plants. As a result of the findings, 1 lasers may provide higher ultrasonic and laser range sensors resolution, faster data collection, and the capacity to deal with defoliated trees or minor replanting. Canopy density and evaluation procedures must be constructed for evaluation.

The author [5] uses a convex hull and alpha shape algorithms to calculate canopy volume. The convex hull will overestimate the tree's structure, but the alpha shape is considered a good option. The noise in LiDAR scans has a significant impact on both methods. They simply compared two approaches and demonstrated identical results rather than providing ground truth for assessment.

The author [6] determined the canopy volume analysis of point cloud. The correlation between measured canopy volume and LiDAR measurements ranged from $r = 0.56$ to 0.82 , depending on the techniques used. Manually measuring canopy volume for 2D trees is more difficult.

The canopy porosity problem is not solved since it tends to overstate the volume. The approaches stated above may not be appropriate for 2D trees.

Author [7] proposes methods for evaluating canopy density mapping system of apple foliage as an insight for variable rate sprayer. The author's [7] mobile terrestrial system consists of a 2D (LiDAR) Light Detection and Ranging Sensor, three Red Green Blue-Depth cameras, and a Global Positioning System-Real Time Kinematic positioning module. A three-dimensional point cloud was created for a trellis-structure or standalone structure row queue for the variable-rate sprayer and then translated to a two-dimensional array with density distribution data. Ground truth data for GPS validation and canopy density were obtained by placing quad frames in the trees.

The canopy cover visible to human eyes is referred to as canopy volume. It is filled with various plant organs such as leaves and branches. The organ modifies its form and size during the growing season [8]. Thus, many agricultural applications, such as pesticide treatments, plant watering, fertilization, and crop training, heavily rely on the fundamental and symmetrical properties of plants' above-ground organs. An automated process capable of identifying canopy characteristics is required to reduce environmental contamination and manufacturing costs [9]. Some applications, such as automatic pesticide sprayers, necessitate exact canopy size calculations. The number of pesticide dosages required will differ as the canopy volume changes. As a result, each tree has a different pesticide requirement, which is determined by the size of the tree canopy. Calculating canopy volume is critical for improving spray application efficiency and lowering pollution levels in the atmosphere [10].

An important aspect of the plant is that it must have escaped insect and disease attacks. Farmers mostly utilize a huge amount of pesticide treatment or chemical application [11]. However, excessive chemical use harms fruit and productivity, polluting the ecosystem. As per the outcome, it is serious about projecting an automatic spraying system that calculates tree metrics such as height, width, and diameter as well as canopy volume so that the correct amount of pesticide spray can be determined to provide an optimal solution for efficient and effective pest control with no or minimum environmental pollution [12].

Automatic variable rate sprayers have been equipped with a number of machine learning systems that use Bayesian classifiers and deep learning neural networks. For real-time applications, the majority of machine learning algorithms have substantial training data sets and significant complexity. According to the author [45], the kernel mutual subspace method (KMSM) offers a strong potential for real-time tracking features

and action recognition, with accuracy levels of more than 80%. In addition, the Hankel matrix and KMSM were utilised to recognise the actions of the machinery operator, with a processing time of 0.07 s. The mutual subspace approach is far more promising than the KMSM for identification or verification in machine learning systems. Utilizing MSM, features can be recognised quickly and accurately in onboard spraying applications utilizing UAVs [45]. Therefore, the objective of this paper is to review the existing automatic variable rate spraying system based on canopy characterization.

The following is the structure of this research article: Section 2 examines current studies on canopy characterization using automatic spraying systems. Section 3 discusses the future direction, and following that, a summary and conclusion provided in Section 4.

2. Literature review. This section reviews the variable-rate spraying system for orchards, sensor-based spraying system, Ultrasonic and LiDAR sensor-based spraying, and Artificial Intelligence-based Canopy Spray System.

2.1. Variable Spraying System for orchards. In agriculture, variable rate spraying is an essential element. The author [13] used real-time sensor technology to collect target spray volume information on the unit operating area. The pressure-regulated and variable flow-controlled approach allows for precise and quick spray operations. The following Figure 1 shows the architecture of the variable rate spraying system. Orchard sprayer designs have evolved over the past decades from hand-boom-based horse-drawn wagons to sensor-controlled tractor-pulled sprayers due to increased concern about contaminant waste production and groundwater pollution, variations in orcharding, increased improvement in the quality materials, and the development of new technologies. Pumps, nozzles, bellows, and steam-powered sprayers were among the first pesticide application technologies created in the early twentieth century. Because of human resource shortage concerns, air blast sprayers were quickly adopted in the 1940s. The high level of agriculturalist concentration in this technology increased the adoption of spraying with the help of air-assisted spraying. Sprayers for pesticides and other European developments (such as mist blowers and weapons) permitted cultivators to spread chemicals more professionally. Chemical application tactics changed when plane designs that might hold the mist up and through the foliage were invented. Instead of just being sprayed from planes, airstream models allowed toxins to be squirted from the surface. In the last two to three decades, modern sprayers, including tunnel sprayers, tower sprayers, and precision sprayers, have enabled orchard producers to decrease the off-target deposition of spray ingredients and drift. Various innovative sensing

systems and frameworks are required to measure tree canopy properties. This section reviews the variable-rate spraying for orchards. The plant foliage info and critically analyze tree crown dimensions and goals, machine learning techniques use Sensors including Red Green Blue, Near Infrared, hyperspectral, multispectral, and infrared. In contrast, range-sensing systems use ultrasonic and laser range sensors.

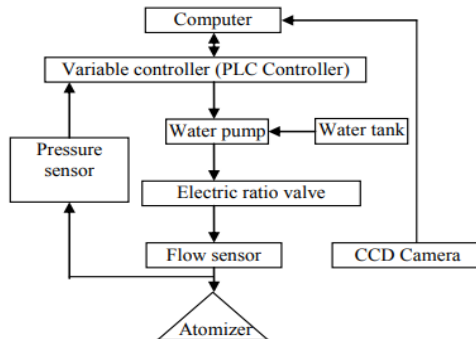


Fig. 1. Variable Rate Spraying System [13]

In paper [14] the authors designed investigational changeable spraying with the help of air-assisted spraying with a high-speed laser scanning sensor to adjust the squirt outcome of the air and liquid delivery system which is shown in Figure 2.




Fig. 2. Air-assisted spraying with a high-speed laser-scanning sensor [14]

The sprayer included a control system with laser scanning sensor system and air and liquid provisions. The distribution program's nozzles worked with a pulse width modulated control valve to achieve changeable supply based on the target tree's occurrence, height, width, and leaf density. The sensor control system also included a new variable-rate control algorithm that analyzed real-time readings from the tree crown coatings.

In paper [15] the authors developed an investigational variable rate sprayer to automatically adjust squirt outcomes in response to the size of the lining foliage. The sprayer was built with two linear booms, an ultrasonic sensor sensing mechanism, a squirt flow rate regulating unit, a microcontroller, and a squirt supply system. Two booms were outfitted with five oppositional sets of uniformly spaced sprayers. As a result, despite differences in vertical tree crown length and sprayer flow rate, the newly developed sprayer ensured uniform squirt accumulation and visibility for orchard center liner applications.

In paper [16] the authors developed a flow rate control system based on microcontrollers and pulse width modulation-managed electro-pneumatic cylinders to manage the mass flow of multi-channel valves individually for changeable sprayers. The system is comprised of an information-gathering subsystem, an information-processing subsystem, and a mass flow monitoring system. Control algorithms were run on an Arduino microcontroller with a touch panel, allowing the sprayer controller to interact with the management system.

In study [17] the authors compared the usage of Ultrasonic and Light Detection and Ranging (LiDAR) sensors to a conventional manual and damaging canopy measurement approach. The ethics of critical factors such as plant tallness, plant size, plant capacity, and leaf part were compared for both techniques. According to the findings, an infrared sensor is a great method for analyzing tree crown qualities, whereas a Laser scanning sensor offers better accuracy and detail about the canopy. Ultrasonic sensors enable useful information about plant thickness and inconsistency throughout the line. However, restrictions are based on the sensor's actuation series and the rise in wave amplitude with the location.

Study [18] created spraying with the help of an air-assisted variable-rate intelligent sprayer. This innovative splattering scheme provides the maximum speed laser-scanning sensor with a made-to-order detector monitoring system and a changeable controller to operate varying valves in a multi-channel distribution system. It detects plants, measures their length, structure, and foliage mass, and then adjusts the squirt outcome of individual nozzles in real-time to fit foliage quantity and flow rate.

Variable-rate sprayers featuring machine vision, computer control, and lower spray volumes than constant-rate sprayers are now commercially available [19]. However, little study has been done to compare variable-rate versus constant-rate spray administrations as crop attributes change over the growing season. Squirt quantity, squirt efficiency (e.g., coverage and remit frequency), and off-target squirt failures were investigated in an apple (*Malus Domestica*) orchard and a grape (*Vitis vinifera*) wineries using variable- as well as steady sprayer across multiple phenophases.

In study [20] the authors developed two destination-splattering processes. Three spattered procedures were carried out on juvenile cherry blossoms and elderly apple trees. It discovered that the two targeted spraying processes could substantially decrease ground deposition caused by off-target spraying. The ground deposition from sprayers equipped with a photoelectric-based targeted splattering structure (trunk-based target-oriented detection) and an ultrasonic-based targeted splattering structure was greater than commercial sprayers not equipped with a canopy-based target-oriented detection. Feature information like canopy volume, profile, and leaf area density, on the other hand, varies by growth stage. Creating a method appropriate for the whole development lifecycle of fruit plants will be the focus of future research on target-oriented spraying.

Study [21] presented a real time control approach for the application flow rate and precision variable spray scheme focusing on a limited microcontroller and micro diaphragm pump that can adjust the pump's flow rate actual as the operating condition varies. The response speed of the changeable squirt model has been evaluated. The system's average control reaction time was 0.18 seconds, while the pump flow change's average stability time was 0.75 seconds. The test findings revealed that the system responds fast to changes in working conditions and that the pump's target flow is adjusted quickly to provide the variable-rate spray function.

In paper [22] the authors presented a technical solution in which the Convolutional Neural Network procedure is used to detect agricultural infections, and automatic chemical spraying is utilized to spritzed herbicides on the damaged plants on a local level. Pesticide sprays are used in the system. The design includes object recognition, picture pre-processing, segmentation techniques, extraction and classification, categorization, and automatic pesticide splattering on the plant.

Study [23] compared the economics of a traditional sprayer reconfigured with a Variable Rate Sprayer versus a traditional Constant Rate Sprayer for herbicides throughout apple manufacturing. While preserving efficacy against insects and diseases, a sophisticated laser-guided variable rate sprayer could increase squirt deposition regularity and reduce

herbicide sludge. Despite these advantages, equipping a traditional sprayer with laser-guided variable-rate squirting capabilities increases the cost. However, these benefits do not account for additional environmental benefits such as reduced pesticide losses due to air drift and ground losses to soil and water and lower CO₂ output due to reduced fuel usage.

Study [24] recognized fruit trees; the sprayer uses two infrared sensors on each side of the machine. The control system detects the tractor's speed in real-time, which processes the pulse output from a Hall sensor. If the target is detected, the location and speed saved in the memory are used to determine the spraying position and width. The spraying valves are activated once the tractor has traveled a specific distance. The sprayer will begin spraying if there is a tree and cease spraying if there is a space. To change the spraying width, control settings are modified to suit varying tree sizes.

In study [25] the authors described a mechanism for precise pesticide spraying that can handle amorphous shapes and targets of varying sizes. This paper's key contribution is developing and evaluating a unique spraying device that assures complete coverage of the identified target with minimal spray by spraying each target independently, reducing pesticide application. It is accomplished by utilizing a pan tilt unit (PTU) to aim the spraying device toward the target's center and adjust the spraying diameter to its form and size. Future research should focus on individual crops, pests, and pesticides, including evaluating spraying characteristics and their agronomic impact and real-time and economic performance.

Study [26] proposed a height-adaptive pesticide spraying system. The system is based on the use of an automated guided vehicle. The actual distance between the plant and the camera is calculated using depth data. By combining the vertical field of the sensor with the height of the plant, the height of the plant may be estimated. And the controller can open or close the solenoid valve. The system can precisely recognize plant height and open or close matching nozzles based on that information, demonstrating the usefulness of the proposed design strategy. In the future, the author will concentrate the research on a more advanced approach that is ideal for height-adaptive pesticide spraying systems. Table 1 provides a brief overview of the above-illustrated state art approaches.

These studies show that actual variable rate innovation is essential for accuracy splattering in fruit orchards. This technique minimizes herbicide failures and protects the environment by reducing drift. The authors changed the hose release predicated on foliage length, foliage quantity, greenery mass, and other factors that used an appropriate monitoring device, authority to monitor, and proportional valves.

Table 1. Review on Variable Rate Spraying Systems

Citation	Technique Used	Dataset	Advantages	Limitations/ Future research	Performance Parameters
[14]	Variable-rate air-assisted sprayer	Field Experiment	The innovative sprayer's device controller system met design criteria for variable-rate application, with great implications for reducing spray volume and drift, thus lowering ecological consequences	Larger capacity nozzles are to be used in the future	Lag time, Spray coverage uniformity, Required duty cycle
[15]	Real-time variable rate sprayer	Data obtained manually from the data log record	Uniform spray deposition and coverage	Time-consuming process	Consistency, Delay time
[16]	MCU based PWM	Real-world data	Compact structure and easy installation	Overvoltage injury caused by control valve switch actions	Variable flow rate accuracy
[17]	Light detection and ranging sensors and infrared sensors for tree crown categorization	LIDAR sensors	Canopy quantity and Leaf Area Index were predicted exactly	Moreover, there are some limitations due to the device's actuation scope and the rise in signal amplitude with the role and some risk of error, point crop width extension of dimensions to a specified foliage region	Leaf wall area estimation

Continuation of Table 1

Citation	Technique Used	Dataset	Advantages	Limitations/ Future research	Performance Parameters
[18]	Air-assisted variable-rate intelligent sprayer	Real-time data	Extra squirt accumulation within the tree crowns significantly less air-borne drift and surface damages	It is not very effective	Spray volume
[19]	Variable- and constant-rate sprayers	Real-time data	It has high efficiency	It is not suitable for large-scale operation	Spray coverage, water-sensitive cards
[20]	Targeted Splattering Mechanisms for Farmlands Using Photoelectric or Ultrasonic Sensors	Real-time data	Less cost, Easy to implement	Creating a method appropriate for the whole development progression of plants will be the focus of future research on target-oriented spraying	-
[21]	Automatic controller for differential spraying system based on unmanned aerial vehicles (UAVs)	Real-world dataset	The process reacts immediately, with a steady, quick, and continuously adjustable flow volume	In future research, we'll look at the stabilization approach for acquiring UAV status information and the variable-rate spray control's actual operating efficiency	Duty ratio, pressure flow
[22]	Convolutional Neural Network	Fruit disease dataset	Spraying the pesticide on a defective plant efficiently and accurately	In the future, the author will detect leaf diseases using this algorithm	Accuracy

Continuation of Table 1

Citation	Technique Used	Dataset	Advantages	Limitations/ Future research	Performance Parameters
[23]	Variable Rate Sprayer (VRS)	A field experiment in orchards in Ohio, USA	Compared with a Constant rate sprayer, VRS significantly reduced herbicide usage, spraying time, and resource needs	A life cycle assessment might assess the total decrement in ecological effects of reduced insecticide use. The analysis technique used in this study could be applied to a variety of highly specialized plants in the future	Sensitivity Analysis, Uncertainty of VRS
[24]	Programmable logic controller (PLC)	A field experiment	Improve the detection sensitivity	The pressure is exceeded, and the spraying machine cannot perform consistently	Relative Error (%)
[25]	Adjustable Spraying Device	Real-time	Optimal Spray Coverage	Future research should focus on individual crops, pests, and pesticides, including evaluating spraying characteristics and their agronomic impact and real-time and economic performance	Spraying reduction estimation
[26]	Height Adaptive Pesticide Spraying System	Real-time	Highest accuracy	In the future, the author will concentrate our research on a more advanced approach that is ideal for height-adaptive pesticide spraying systems	Flow rate, Probability (%)

2.2. Sensor-based Spraying System. The measurement of tree canopy parameters necessitates using a wide range of new sensors and deployments. The following sections provide an overview of how various


sensors are used for precise squirting. Machine learning techniques gather plant tree crown information and closely examine tree crown variables and objectives using camera sensors (Chrominance, Near-infrared, hyperspectral, multispectral, and infrared). In contrast, range-sensing systems use ultrasonic and laser scanner sensor.

In paper [27] the authors designed spraying with the help of an air-assisted integrated laser-scanning system to provide toward-target variable-rate splattering to develop a better understanding of spraying strategy and avoid over-application of herbicides in fruit trees. The spray control system developed a method for calculating foliage gridding quantities to ensure that the crown was divided into the unified standard set. The flow rate selection application implemented a variable-rate squirt design to regulate the squirt image based on the foliage blueprinting quantities and flow rate. A technique for preserving and obtaining squirt information was implemented to regulate squirt latency. The effects of different grid sizes and travel speeds on squirt achievement were assessed by measuring spray coverage uniformity inside tree canopies.

The laser-scanning sensor (Model LMS111, SICK Inc., Germany), a speed-measuring device, a microcontroller, flow-rate control units, and an onboard computer were the crucial parts of the sprayer control system (Figure 3).

In study [28] the authors proposed various flow monitoring systems in actual time based on deep learning using fruit tree fragmentation in a nectarine orchard. This research proposes a theoretical modeling, undesirable pressure fluctuation, and real-time flow rate management which may vary from those in actual life. Two basic tests were designed to test flow velocity modeling's direct correlation. In a preliminary study, the PWM (Pulse Width Modulation) controller variables were tuned, and the effectiveness of the monitoring system for flow rate was confirmed in a field study.

Study [29] provided a minimal sensor device based on tree canopy detection on a varying quantity of water for crop protection applications in farmlands. A target detection device was installed on a 2000-liter traditional remotely operated air-blast orchard sprayer. The target detection technique used in this study was "sensor-equipped spraying." Optical sensors were used to identify the tree cover and transmit the message to the PLC, turning the control switch valves. According to a variation data analysis on the sprayed area on water-sensitive paper, the effects of forwarding motion and transverse and longitudinal placement of water-sensitive papers on the area of WSPs coated by squirted moisture have been substantial at the 1% confidence level.



1) On-board Computer 2) Laser-Scanning Sensor 3) Micro controller and flow
4) Nozzles 5) Solenoid valves 6) Speed measuring device

Fig. 3. Prototype of the variable-rate sprayer incorporates a sprayer control system [27]

In paper [30] the authors created a moveable squirt method to tackle the challenges of spray droplets, on the other hand, frequently disperse and spread unevenly, posing a threat to their use and the environment. Computational fluid dynamics simulation determines the sharing features of particle accumulation in a wide range of squirt regions (flight state, environment state, nozzle state). The airflow anomaly of many specimen nodes in the verification experiment is fewer than 1 m/s, and the deposition ratio error is fewer than 10%, showing that the simulation is accurate. A simulation data set trains linear regression and backpropagation neural networks with distinct variables. In the coming years, the variety and quality of various squirt provinces must be improved in computation before being used to generate excellent computation statistical models. Multi-layer neural networks, such as long short-term memory, can be used to predict droplet deposition distribution features.

Study [31] integrated a sensing system with an actual explanation of the prescribing illustration in procedure to obtain the prescribing valuation of the STMICROELECTRONICS-32 (STM32) processor. An oscillation frequency digital signal with different switching frequencies is then used to adjust the flow rate. A shuttered Proportional-Integral-Derivative (PID) control technique is used to shorten the time it takes for the system to achieve a stable condition. Unmanned aerial vehicle (UAV) differential watering technology has progressed rapidly in recent years as the future development path of aviation for crop protection. Table 2 provides a brief overview of the above-illustrated state art approaches.

Table 2. Sensor-based Spraying Systems

Citation	Technique Used	Dataset	Advantages	Limitations/ Future research	Performance Parameters
[27]	An experimental Smart Sprayer with a laser-scanning system	Real-time data	It provides a good Spray coverage area under various travel speeds	Future research will provide a more thorough examination of the sprayer's performance for trees at various stages of development	Spray coverage of the different grids, Travel speed
[28]	PWM based controller	Real-time dataset by using Intel RealSense D435 camera	Efficiency is high	Gravity causes the water droplets that develop on the leaf surface to droop in this scenario. Separating and analyzing these cases is a significant problem	Accuracy, precision
[29]	Sensor equipped spraying	Field experiment	Pesticide consumption, Reduces the convexity of tree canopies	Time consumption	Geographic Latency, Lag in starting and stopping watering
[30]	Multi-rotor Unmanned Aerial Vehicles	Duplicate information	The squirt process resulted in unified accumulation	The distribution features of droplet deposition can be predicted using complex neural networks, such as long short-term memory	Error prediction
[31]	Variable system based on PWM-PID	Field experiment	Effectively reduce the herbicide, and enhance the chemical effect	Variable-rate splattering technique for unmanned aerial vehicles (UAVs) has advanced rapidly as the future way to progress aviation for soil conservation	Duty ratio, Droplet coverage density

2.3. Ultrasonic and LIDAR Sensor-based Spraying System. An electronic control process for identifying and calculating tree crown measurements for application rate modification. Three ultrasonic Sensor USS3 sensor nodes were used at three different heights to calculate the distance to an object. A Multi-layer perceptron neural network with gradient-descent backpropagation, tangent-sigmoid transfer function, and 3-7-6 architecture was used to estimate the volume of tree sections.

In study [33] the authors created a sensor-based, tractor-mounted autonomous spraying system for crop foliage recognition and liquid chemical spraying over the identified foliage for small orchard producers based on sensing technology for fully automated squirt regulation of pumps, control valves, and hoses were interfaced with a programmed Atmega328P. The microcontroller system was triggered by the sensing signals to spray as requested. The sprayer was verified with two distinct nozzle types to determine the best input for optimal spray coverage and fruit infection impact. An ultrasonic Sensor, a micro-controller board, a control valve, a relief valve, a solenoid valve, a fixed displacement pump, a pressure regulator, hoses, and a 200-liter storage tank are all included, and a 12 V battery makes up the system. The tractor's PTO powered the pump. With a detection range of 0–3 m, the infrared sensor could detect a specific object. The technique is efficient for real-time spray modification, but it is confined to greenhouses with a consistent atmosphere, which could be excellent for picture capture and analysis. However, the authors provided no evidence that it could be used successfully in open-field orchards with non-uniform and uncontrolled circumstances.

Study [34] offered a method for calculating foliage thickness using ultrasonic sensors. The authors led a series of experimental tests using synthetic foliage to examine the method's usefulness. The results indicate that the author can effectively assess foliage thickness when the sensor length, foliage mass, and foliage width are between 0.5 and 1.5 m, 1.2 and 1.4 m, and 0.3 and 0.6 m, respectively. The relative inaccuracy of the simulated canopy thickness between the assessed and real cost is no more than 8.8%.

Study [35] presented an innovative, minimal-price light detection and ranging sensor for detecting Boom Height depending upon the single-point ranging principle. The sensing execution of the LiDAR sensor was tested using a step height detection experiment, a field ground detection trial, a wheat stubble height sensing test, and a correlation with an ultrasonic sensor. The findings revealed that the Light Detection and Ranging sensor could detect Hb. When utilized to identify the WS height, the Light Detection and Ranging Sensor detected the Wheat Stubble roots and the inside of the Wheat Stubble foliage.

Study [36] developed a model to describe the distribution of tree canopy density within four sections based on the position of the trellis wires in two orchards. Tree leaves from each section were manually counted. Researchers are carried in two plantation spots, one with Gold Rush apple trees (bigger trees) and the other with Fuji apple trees (smaller trees). The number of tree leaves in each segment separated by trellis wires was

manually counted. Previous research focused mainly on the number of leaves space and the amount of the entire plant, which is insufficient for minimizing spray spread during pesticide application. Precision spraying will benefit from thickness data estimated from the number of points/leaves, which will be evaluated in future research. Table 3 provides a brief overview of the above-illustrated state art approaches.

Table 3. Review on Ultrasonic and LIDAR Sensor-based Spraying Systems

Citation	Technique Used	Dataset	Advantages	Limitations/ Future research	Performance Parameters
[32]	Multi-layer perceptron neural network with a back-propagation algorithm based on linear regression	Real-time data	Rapid installation and easy calibration	-	Mean Squared Error, Relative Span Factor
[33]	Tractor-mounted ultrasonic sensor-based orchard sprayer	Real-time data	Real-time robust system	It is confined to greenhouses with a consistent atmosphere	Relative Deviation (RD), Spray coverage
[34]	Canopy thickness detection by using ultrasonic sensors	Real-time data	Low-cost sensors	Large data computation	Accuracy and reliability
[35]	A low-cost LiDAR sensor is developed	Field experiment	Boom sprayers are increasingly large and efficient	Future research will focus on growing autonomous Hb control systems based on the Light Detection And Ranging Sensor used by the author [4] and conducting high-speed field experiments and worldwide research of various plant foliage at various phases	Mean Detection Error
[36]	Ground-based Light Detection And Ranging directed recognizing methods	Data collection by Velo View Software	This prototype reduces the excessive pesticide use	Because of the smaller diameter of the tree trunks and the resolution limits of Light detection and ranging, most of the Fuji apple tree trunk points were not obtained	Tree canopy volume, the Correlation factor

2.4. Artificial Intelligence-based Canopy Spray Systems. In paper [37] the authors suggested a sprayer fitted with a sprinkling framework in the form of a fruit tree based on UAV to improve sprinkling variables for real-world use. The variables are the flying speed and software percentage, while the observable metrics particle reportage, mass, dimensions, and permeation were verified. Water Sensitive Papers (WSPs) are used to gather droplets on the canopy's outside, bottom, and inside layers. However, further evaluation tests should be considered and undertaken in future work to better understand the effects of control parameters and hose wide-angle on particle dispersion in the foliage of a citrus tree. In addition, a novel particle allocation detecting technique based on machine learning may be created to increase assessment efficiency.

In study [38] the authors proposed a crop protection Unmanned aerial dynamic squirt scheme with machine-learning strategic planning based on established differential squirt studies. The elements influencing particle accumulation of an error backpropagation (BP) neural network model are trained using current information from crop protection Unmanned aerial processes associated with artificial neural network technology. Droplet deposition is influenced by room temperature, moisture, wind velocity, flying speed, height, propeller pitch, and nozzle pitch, which prescribe the important parameters. As a result, the Back Propagation neural network model is used for crop protection. Unmanned Aerial Vehicles integrated with floating interest squirt regulation are used to obtain real-time multi-sensor data.

In paper [39] the authors offered a minimal-rate intelligent sensor method for airblast fruit tree sprayers. The prototype is used in Light Detection and Ranging, machine vision, Global Positioning Systems (GPS), Flow meters, sensor fusion and Artificial Intelligence to examine plants for plant tallness, plant categorization, and fruit count. This new sensing method can monitor and extract features like trees or non-tree (e.g., humans, field buildings), measure plant tallness and foliage mass, and identify and count fruit. And the new sensing scheme's plant tallness estimation revealed a comparatively small normal inaccuracy of 6%. More research will be performed in commercial orchards with tall weeds and other environmental noises to assess the system's robustness. The data from other tree crops will be collected to examine the use of this detecting method in other tree plant systems (e.g., peaches, apples, and pecans).

In study [40] the authors proposed a low-cost automated method to identify, count, and geo-locate Asian citrus psyllids (ACP) in a citrus orchard using machine learning and artificial intelligence. The purpose of this cutting-edge device was to automate the traditional stem tap approach

for ACP scouting. Insects fall over a board with a grid of cameras used for picture capture thanks to a tapping mechanism that strikes the tree's branches. In order to identify and differentiate ACPs from other insects and detritus, two convolutional neural networks were used in the software development process.

For real-time applications that reduce the quantity of agrochemicals as a function of pest density, a variable rate sprayer could be positioned at the front of a device. Figure 4 illustrates the overall flow of this system [40]. A Global Positioning System was used to save specific plant positions mechanically to improve data assessment on big groves.

Study [41] presented a complete pipeline from model training to the deployment of the Tensor RT-optimized model on a single board computer in which actual-time multi-class marijuana detection enables lifeforms to weed control, reducing herbicide use dramatically. Using five standard Convolutional Neural Network models, the authors also proposed a reference point for classifier performance based on AI Weeds and the pipeline. MobileNetV2, which has the shortest predictable time and consumes the lowest storage, is the best contender for real-world applications.

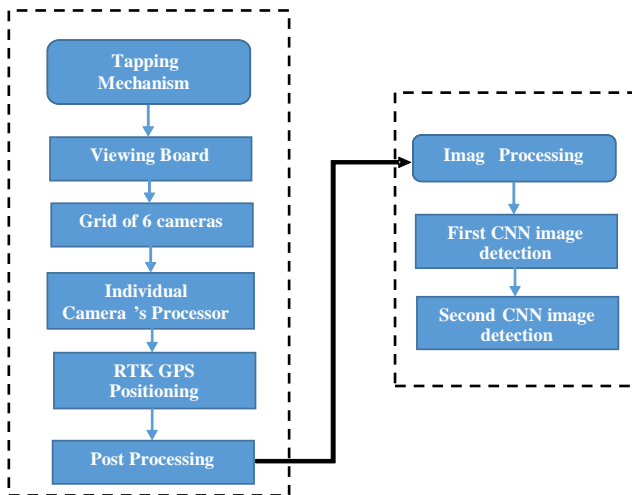


Fig. 4. Prototype of the Hardware and Software Structures [40]

In paper [42] the authors offered combined Ag-YOLO, a light deep neural network system that allows crop protection UAVs to detect targets and operate autonomously. This approach is limited in size, cost, flexibility,

speed, and power efficiency. The hardware is only 18 grams and consumes 1.5 watts of power, and the Deep Neural Network model produced requires only 838 kilobytes of disc space. To detect individual palms in a plantation, we compared the advanced hardware and software to YOLOv3-Tiny, a miniature version of the cutting-edge YOLOv3 framework.

Study [43] proposed a real-time variable flow control system based on deep learning using the fragmentation of fruit trees in a peach orchard. Two types of initial tests were designed to test the linear relationship of the flow rate modeling. In a preliminary experiment, the variables of the pulse width modulation controller were optimized, and the achievement of the flow rate control system was confirmed.

In paper [44] the authors used deep learning approaches to construct new models for classifying weeds and precisely spraying on intended weed targets, resulting in a variable rate spraying system. Three classification CNNs (Convolutional Neural Networks) models were used in laboratory and field studies to evaluate sprayer presentation for unwanted plant organization and exact scattering of marked weeds. According to the findings of the tests, the sprayer with the VGG-16 model may reach excellent performance, making it extra suitable for actual-time spraying.

In study [45] the authors developed a machine-learning model capable of distinguishing sprayer and non-spraying areas for Unmanned Aerial Vehicle-based sprayers while retaining strong computing precision and agility in this research. A computer vision system was designed using the mutual subspace method for images captured by an Unmanned Aerial Vehicle. Two target fields were investigated in developing two classifiers for identifying spray and non-spray areas: farm croplands and plantation regions. In future trials, the author intends to incorporate an artificial neural network (ANN) and machine learning into the training and testing system to build an Unmanned Aerial Vehicle-based independent splattering device for farmland and orchards.

In paper [46] the authors described a real-time computer vision-based crop/weed detection system for variable rate spraying. Crops and weeds were detected and categorized using the Random Forest classifier. Before being tested in the field, the classifier model was tested temporarily using our set of data. Spraying agrochemicals was done with application equipment that included a PWM-based liquid flow flow control system capable of splattering the target quantity of pesticides as guided by a vision-based feedback system. Multiple field experiments show that the proposed vision-based pesticide spraying framework works in real time.

In study [47] the authors established a new weed recognition and categorization method that autonomous weed control robots could use.

Plants must be sorted into crops and weeds based on their attributes, which is accomplished using a machine vision algorithm. Plants growing between rows are regarded as weeds, whereas crops mixed with weeds require a categorization procedure inside a row. The author first devised an adaptive method for segmenting the background from an image and wavelet transform to extract characteristics from the images. Finally, herbicide sprayers are instructed to spray directly on desired weed locations based on weed positions. Table 4 provides a brief overview of the above-illustrated state art approaches.

Table 4. Artificial Intelligence-based Spraying Systems

Citation	Technique Used	Dataset	Advantages	Limitations/ Future research	Performance Parameters	Obtained Results
[37]	Unmanned Aerial vehicle-based sprayer	Field experiment	It is easier to get the particle accumulation	In addition, to improve the assessment efficiency, a new particle-sharing detecting technique based on machine learning might be established	Droplet size, Density coverage, and penetration	Flight Velocity – 2 m s ⁻¹ Application Rate – 60 L ha ⁻¹ Flight height – 1.6 ~ 2
[38]	Artificial Neural Network	Field Experiment in China	The model is stable and reliable	Not robust	The correlation coefficient, Root Mean Square Error, and Mean Absolute Error	Measurement accuracy – 0.01 m/s Training error of BP Neural Network – 0.003
[39]	Convolutional Neural Network	SWFREC	High accuracy	More research will be performed to assess the system's robustness on tall weeds in commercial orchards, as well as other environmental noises	Accuracy, F1-score	Accuracy – 84% F1-score – 89%

Continuation of Table 4

[40]	Convolutional Neural Network	A real-time kinematic Global Positioning System (RTK-GPS)	Reduce labor costs, decrease data collection time	Image resolution and camera focus	Precision, Recall	Precision – 80% Recall – 95% F1-score – 87%
[41]	Convolutional Neural Network	AI Weeds	Robust, Eliminate over-fitting	Distortion, Shadows, Blur	F1-score, accuracy	Accuracy – 90% F1-score – 90%
[42]	Ag-YOLO	Real-time dataset	High accuracy, Eliminate the redundancy	Increases complexity	F1-score, Precision, Recall	F1-score – 0.9205 at speed of 36.5 fps Recall – 92.86% Precision-96.30%
[43]	Deep learning model for segmentation of fruit trees	Real-world dataset	Cost-efficient	droplet size is required	Accuracy	Accuracy – 83.79
[44]	Deep Convolutional Neural Network	Real-world dataset	High performance in real-time application	Artificial lighting setups will be incorporated for future studies to improve performance	Accuracy, Recall, F1-Score	Accuracy, Precision, Recall, and F1-score values VGG 16 model are 0.97, 0.96, 0.94, and 0.94
[45]	Machine learning-based spraying system	Real-world dataset	Low computational complexity	In the future author will construct an Unmanned Aerial Vehicles-based automatic splitting set for grassland and plant farms	Accuracy	Accuracy – 70%
[46]	Gray Level Co-occurrence Matrix (GLCM)	Real-world dataset	Smooths the image while removing the noises	It is a challenging task in real-time	Accuracy	Accuracy – 95%
[47]	Machine vision algorithm	Real-world dataset	Robust	High computational complexity	Accuracy	Error value – 5%

Even though many computer vision techniques have already proven to become very helpful and effective in marijuana identification, plant stress tracking, and harvest forecasting, among other applications, there are still limitations, particularly in out-of-field conditions. Image includes are more sensitive to ambient light and climate than other sensors used in computer vision applications. In the case of tree fruits, camera vision techniques may be better suited for spot scattering spray based on the disorder or parasite stress at the site) rather than varying spray. Recent advancements in multispectral and hyperspectral cameras have resulted in smaller spectral channels entering tree coverings and detecting tree states correctly (diseases, insect pressures, and nutritional stress).

3. Future research. In the future, variable-rate spraying systems will combine humanoid and device splattering processes with information on fruit mature trees and structures to achieve precise herbicide distribution and avoid an off-target deposition. Several sensor-based splattering systems are available to determine the amount of spray volume required; however, it is also vital to investigate the durability of these innovations so that many sensors can be introduced at a fair price to farm owners. Location disorder, pest, and anxiety tracking using techniques such as machine learning and deep learning will improve the performance of current sensor-based splattering systems while also advancing sensor development.

Additional decision-making characteristics for additional exact insecticide presentations in tree fruits could be added by fusing/integrating various sensors. Beyond the standard agrochemicals currently utilized, future spraying systems must be able to handle an extensive series of insecticide formulations. Even though tractor-based spraying methods are most commonly employed for pesticide treatments, another Unmanned Aerial Vehicle-based application approach could eventually supplant old-style sprayers. Unmanned Aerial Vehicles have been verified for infection review, anxiety checking, and squirting in field crops, with promising preliminary findings for spraying.

However, most existing Unmanned Aerial Vehicle-based squirting processes might not be suitable for splattering in large evergreen crop fields due to the inadequate CubeSats and dynamic squirt accumulation capacity. Further research and development into Unmanned aerial massive numbers and large-capacity Unmanned aerial vehicles, similar to unmanned choppers, could result in a more efficient method for commercial/large-scale crop fields. As a result, the use of enhanced variable rate sprayers in the future will necessitate the implementation of multiple sensing and actuation processes.

4. Summary and conclusion. This paper reviews variable rate spraying technology and discussed the existing spraying techniques in orchards, computer vision tools for variable rate spraying, device variable-rate spraying system deployment in orchards, and device constraints and related difficulties. According to surveys, the variable rate spraying technique can be utilized efficiently in orchards for precise pesticide applications. Moreover, laser scanners have been more popular in agriculture over the last decade, which uses ranging from fully-automated plant length measurement to location pesticide application. Sensors of various types, such as ultrasonic sensors, laser sensors, infrared sensors, and lidar detectors, could be used to characterize the canopy accurately. The webcam sensor-based sprayer can be useful for finding canopy spots and spot spraying, but environmental and sensor restrictions limit its effectiveness. As a result, a real-time land-checking method and a sensor system for precision spraying may be required. To overcome this, deep learning-based artificial intelligence systems have produced the best tree crown detection and segmentation. Wide crop canopy has the advantage of enhanced classifier recognition. The MSM (mutual subspace method) was used for training and testing the datasets from the three various types of experimental fields, which resulted in the excellent accuracy of the recognition system. More work and research are needed to grow an active and reliable system for automatic variable-rate spraying. In the future, the evolution and development of novel sensors devoted to the geometric characterization of the canopy will lead to effective developments in the optimization of the use of variable-rate sprayers in agriculture as well as an increase in productivity and quality by improving training systems. It is important to recognize that variable spray has great outcomes on millions of cultivated hectares, which have a direct impact on our society and the environment. Therefore, it is essential to keep investing considerable resources in the establishment of increasingly precise, reliable, and cost-effective technologies capable of measuring the geometric properties of plantations, which enable the growth of the different factors of sustainable agriculture. To develop a UAV-based autonomous spraying unit for orchards, we will conduct future research to enhance the training and testing system by incorporating an artificial neural network (ANN) and deep learning.

References

1. Schumann A.W., Zaman Q.U. Software development for real-time ultrasonic mapping of tree canopy size. *Computers and electronics in agriculture*. 2005. vol. 47. no. 1. pp. 25-40.

2. Solanelles F., Escolà A., Planas S., Rosell J.R., Camp F., Gràcia F. An electronic control system for pesticide application proportional to the canopy width of tree crops. *Biosystems engineering*. 2006. vol. 95. no. 4. pp. 473-481.
3. Wang H., Li S., Guo J., Liang Z. Retrieval of the leaf area density of Magnolia woody canopy with terrestrial Laser-scanning data. *J. Remote Sens.* 2016. vol. 20. no. 4. pp. 570-578.
4. Tumbo S.D., Salyani M., Whitney J.D., Wheaton T.A., Miller W.M. Investigation of laser and ultrasonic ranging sensors for measurements of citrus canopy volume. *Applied Engineering in Agriculture*. 2002. vol. 18. no. 3. p. 367.
5. Colaco A.F., Trevisan R.G., Molin J.P., Rosell-Polo J.R., Escolà A. A method to obtain orange crop geometry information using a mobile terrestrial laser scanner and 3D modeling. *Remote Sensing*. 2017. vol. 9. no. 8. p. 763.
6. Martínez-Casasnovas J.A., Rufat J., Arnó J., Arbonés A., Sebé F., Pascual M., Rosell-Polo J.R. Mobile terrestrial laser scanner applications in precision fructiculture/horticulture and tools to extract information from canopy point clouds. *Precision Agriculture*. 2017. vol. 18. no. 1. pp. 111-132.
7. Hu M., Whitty M. An evaluation of an apple canopy density mapping system for a variable-rate sprayer. *IFAC-PapersOnLine*. 2019. vol. 52. no. 30. pp. 342-348.
8. Gil E., Escolà A., Rosell J.R., Planas S., Val L. Variable rate application of plant protection products in vineyard using ultrasonic sensors. *Crop Protection*. 2007. vol. 26. no. 8. pp. 1287-1297.
9. Salyani M. Optimization of deposition efficiency for airblast sprayers. *Transactions of the ASAE*. 2000. vol. 43. no. 2. p. 247.
10. Liu H., Zhu H. Evaluation of a laser scanning sensor in detection of complex-shaped targets for variable-rate sprayer development. *Transactions of the ASABE*. 2016. vol. 59. no. 5. pp. 1181-1192.
11. Esau T.J., Zaman Q.U., Chang Y.K., Schumann A.W., Percival D.C., Farooque A.A. Spot-application of fungicide for wild blueberry using an automated prototype variable rate sprayer. *Precision agriculture*. 2014. vol. 15. no. 2. pp. 147-161.
12. Wandkar S.V., Bhatt Y.C., Jain H.K., Nalawade S.M., Pawar S.G. Real-time variable rate spraying in orchards and vineyards: A review. *Journal of The Institution of Engineers (India): Series A*. 2018. vol. 99. no. 2. pp. 385-390.
13. Zhang R., Song L. Study of variable spray control system based on machine vision. In *2014 IEEE 13th International Conference on Cognitive Informatics and Cognitive Computing*, 2014. pp. 455-458.
14. Chen Y., Zhu H., Ozkan H.E. Development of a variable-rate sprayer with laser scanning sensor to synchronize spray outputs to tree structures. *Transactions of the ASABE*. 2012. vol. 55. no. 3. pp. 773-781.
15. Jeon H.Y., Zhu H. Development of a variable-rate sprayer for nursery liner applications. *Transactions of the ASABE*. 2012. vol. 55. no. 1. pp. 303-312.
16. Liu H., Zhu H., Shen Y., Chen Y., Ozkan H.E. Development of digital flow control system for multi-channel variable-rate sprayers. *Transactions of the ASABE*. 2014. vol. 57. no. 1. pp. 273-281.
17. Llorens J., Gil E., Llop J., Escolà A. Ultrasonic and LIDAR sensors for electronic canopy characterization in vineyards: Advances to improve pesticide application methods. *Sensors*. 2011. vol. 11. no. 2. pp. 2177-2194.
18. Zhu H., Ozkan E. An update on the intelligent spraying system development for fruit and nursery crop applications. In *15th Workshop on Spray Application and Precision Technology in Fruit Growing Programme and Abstracts*, 2019. p.35.
19. Nackley L.L., Warneke B., Fessler L., Pscheidt J.W., Lockwood D., Wright W.C., Fulcher A. Variable-rate spray technology optimizes pesticide application by

- adjusting for seasonal shifts in deciduous perennial crops. *HortTechnology*. 2021. vol. 31. no. 4. pp. 479-489.
20. Dou H., Zhai C., Chen L., Wang X., Zou W. Comparison of Orchard Target-Oriented Spraying Systems Using Photoelectric or Ultrasonic Sensors. *Agriculture*. 2021. vol. 11. no. 8. pp. 753.
21. Lian Q., Tan F., Fu X., Zhang P., Liu X., Zhang W. Design of precision variable-rate spray system for unmanned aerial vehicle using automatic control method. *International Journal of Agricultural and Biological Engineering*. 2019. vol. 12. no. 2. pp. 29-35.
22. Kotkar V.A. An automatic pesticide sprayer to detect the crop disease using machine learning algorithms and spraying pesticide on affected crops. *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*. 2021. vol. 12. no. 1S. pp. 65-72.
23. Manandhar A., Zhu H., Ozkan E., Shah A. Techno-economic impacts of using a laser-guided variable-rate spraying system to retrofit conventional constant-rate sprayers. *Precision Agriculture*. 2020. vol. 21. no. 5. pp. 1156-1171.
24. Shirzadifar A.M. Automatic weed detection system and smart herbicide sprayer robot for corn fields. In *2013 First RSI/ISM International Conference on Robotics and Mechatronics (ICRoM)*, 2013. pp. 468-473.
25. Wei Z., Xiu W., Wei D., Shuai S., Songlin W., Pengfei F. Design and test of automatic toward-target sprayer used in orchard. In *2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER)*, 2015. pp. 697-702.
26. Berenstein R., Edan Y. Automatic adjustable spraying device for site-specific agricultural application. *IEEE Transactions on Automation Science and Engineering*, 2017. vol. 15. no. 2. pp. 641-650.
27. Cai J., Wang X., Gao Y., Yang S., Zhao C. Design and performance evaluation of a variable-rate orchard sprayer based on a laser-scanning sensor. *International Journal of Agricultural and Biological Engineering*. 2019. vol. 12. no. 6. pp. 51-57.
28. Seol J., Kim J., Son H.I. Field evaluations of a deep learning-based intelligent spraying robot with flow control for pear orchards. *Precision Agriculture*. 2022. vol. 23. no. 2. pp. 712-732.
29. Khodabakhshian R., Javadpour S.M. Design and development of a sensor-based precision crop protection autonomous system for orchard sprayer. *Agricultural Engineering International: CIGR Journal*. 2021. vol. 23. no. 3.
30. Ni M., Wang H., Liu X., Liao Y., Fu L., Wu Q., Li J. Design of Variable Spray System for Plant Protection UAV Based on CFD Simulation and Regression Analysis. *Sensors*. 2021. vol. 21. no. 2. pp. 638.
31. Wen S., Zhang Q., Deng J., Lan Y., Yin X., Shan J. Design and experiment of a variable spray system for unmanned aerial vehicles based on PID and PWM control. *Applied Sciences*. 2018. vol. 8. no. 12. pp. 2482.
32. Maghsoudi H., Minaei S., Ghobadian B., Masoudi H. Ultrasonic sensing of pistachio canopy for low-volume precision spraying. *Computers and Electronics in Agriculture*. 2015. vol. 112. pp. 149-160.
33. Tewari V.K., Chandel A.K., Nare B., Kumar S. Sonar sensing predicated automatic spraying technology for orchards. *Current Science*. 2018. vol. 115. no. 6. pp. 1115-1123.
34. Zhou H., Jia W., Li Y., Ou M. Method for Estimating Canopy Thickness Using Ultrasonic Sensor Technology. *Agriculture*. 2021. vol. 11. no. 10. pp. 1011.
35. Dou H., Wang S., Zhai C., Chen L., Wang X., Zhao X. A LiDAR Sensor-Based Spray Boom Height Detection Method and the Corresponding Experimental Validation. *Sensors*. 2021. vol. 21. no. 6. pp. 2107.

36. Mahmud M.S., Zahid A., He L., Choi D., Krawczyk G., Zhu H., Heinemann P. Development of a LiDAR-guided section-based tree canopy density measurement system for precision spray applications. *Computers and Electronics in Agriculture*. 2021. vol. 182. pp. 106053.
37. Meng Y., Zhong W., Liu Y., Wang M., Lan Y. Droplet Distribution of an Autonomous UAV-based Sprayer in Citrus Tree Canopy. In *Journal of Physics: Conference Series*. 2022. vol. 2203. no. 1. pp. 012022.
38. Wen S., Zhang Q., Yin X., Lan Y., Zhang J., Ge Y. Design of plant protection UAV variable spray system based on neural networks. *Sensors*. 2019. vol. 19. no. 5. pp. 1112.
39. Partel V., Costa L., Ampatzidis Y. Smart tree crop sprayer utilizing sensor fusion and artificial intelligence. *Computers and Electronics in Agriculture*. 2021. vol. 191. pp. 106556.
40. Partel V., Nunes L., Stansly P., Ampatzidis Y. Automated vision-based system for monitoring Asian citrus psyllid in orchards utilizing artificial intelligence. *Computers and Electronics in Agriculture*. 2019. vol. 162. pp. 328-336.
41. Du Y., Zhang G., Tsang D., Jawed M.K. Deep-CNN based Robotic Multi-Class Under-Canopy Weed Control in Precision Farming. *arXiv preprint arXiv:2112.13986*, 2021.
42. Qin Z., Wang W., Dammer K.H., Guo L., Cao Z. A real-time low-cost artificial intelligence system for autonomous spraying in palm plantations. *arXiv preprint arXiv:2103.04132*, 2021.
43. Seol J., Kim J., Son H.I. Field evaluations of a deep learning-based intelligent spraying robot with flow control for pear orchards. *Precision Agriculture*. 2022. vol. 23. no. 2. pp. 712-732.
44. Liu J., Abbas I., Noor R.S. Development of Deep Learning-Based Variable Rate Agrochemical Spraying System for Targeted Weeds Control in Strawberry Crop. *Agronomy*. 2021. vol. 11. no. 8. pp. 1480.
45. Gao P., Zhang Y., Zhang L., Noguchi R., Ahamed T. Development of a recognition system for spraying areas from unmanned aerial vehicles using a machine learning approach. *Sensors*. 2019. vol. 19. no. 2. pp. 313.
46. Alam M., Alam M.S., Roman M., Tufail M., Khan M.U., Khan M.T. Real-time machine-learning based crop/weed detection and classification for variable-rate spraying in precision agriculture. In *2020 7th International Conference on Electrical and Electronics Engineering (ICEEE)*, 2020. pp. 273-280.
47. Chen T., Meng F. Development and performance test of a height-adaptive pesticide spraying system. *IEEE Access*, 2018. vol. 6. pp. 12342-12350.

Patil Seema — Researcher, KIT's College of Engineering. Research interests: electronics engineering, computer network. The number of publications — 10. seema.patil9@gmail.com; 199B/1-3, Gokul - Shirgoan, 416234, Kolhapur, India; office phone: +919834104353.

Patil Yuvraj — Ph.D., Dr.Sci., Professor of the department, Department of electronics and telecommunication engineering, KIT's College of Engineering. Research interests: communication systems, control systems. The number of publications — 43. ymp2002@rediffmail.com; 199B/1-3, Gokul - Shirgoan, 416234, Kolhapur, Russia; office phone: +917769001199.

Patil Suhas — Ph.D., Dr.Sci., Professor, Director, D.Y. Patil College of Agricultural Engineering and Technology. Research interests: farm machinery, power engineering. The number of publications — 80. sbpatilprincipal@dypcaet@gmail.com; Talsande, 416112, Kolhapur, India; office phone: +919823381191.

С.С. ПАТИЛ, Ю.М. ПАТИЛ, С.Б. ПАТИЛ
**ОБЗОР АВТОМАТИЧЕСКИХ СИСТЕМ ОПРЫСКИВАНИЯ
С ПЕРЕМЕННОЙ СКОРОСТЬЮ, ОСНОВАННОЙ НА АНАЛИЗЕ
ХАРАКТЕРИСТИК РАСТИТЕЛЬНОГО ПОКРОВА
ФРУКТОВОГО САДА**

Патил С.С., Патил Ю.М., Патил С.Б. Обзор автоматических систем опрыскивания с переменной скоростью, основанной на анализе характеристик растительного покрова фруктового сада.

Аннотация. Использование пестицидов и загрязнение окружающей среды в садах можно значительно снизить, сочетая опрыскивание с переменной скоростью с пропорциональными системами управления. В настоящее время фермеры могут использовать опрыскивание с переменной скоростью для применения средств от сорняков только там, где они необходимы, что обеспечивает экологически чистые и экономичные химические средства для защиты растений. Кроме того, серьезной проблемой является ограничение использования пестицидов в качестве средств защиты растений (СЗР) при сохранении надлежащего отложения растительного покрова. Кроме того, автоматические опрыскиватели, которые регулируют норму внесения в соответствии с размером и формой садовых насаждений, показали значительный потенциал для сокращения использования пестицидов. Для автоматического распыления в существующем исследовании использовались искусственная нейронная сеть (ИНС) и машинное обучение. Кроме того, эффективность опрыскивания можно повысить за счет снижения потерь при распылении из-за осаждения на грунт и нецелевого сноса. Таким образом, это исследование включает в себя тщательное изучение существующих методов опрыскивания с переменной скоростью в садах. Помимо предоставления примеров их прогнозов и краткого рассмотрения влияния на параметры опрыскивания, в нем также представлены различные альтернативы предотвращению чрезмерного использования пестицидов и исследуются их преимущества и недостатки.

Ключевые слова: система опрыскивания с переменной скоростью, обнаружение и характеристика растительного покрова, глубокое обучение, машинное обучение, структурные характеристики растительного покрова, зондирование.

Литература

1. Schumann A.W., Zaman Q.U. Software development for real-time ultrasonic mapping of tree canopy size. Computers and electronics in agriculture. 2005. vol. 47. no. 1. pp. 25-40.
2. Solanelles F., Escolà A., Planas S., Rosell J.R., Camp F., Gràcia F. An electronic control system for pesticide application proportional to the canopy width of tree crops. Biosystems engineering. 2006. vol. 95. no. 4. pp. 473-481.
3. Wang H., Li S., Guo J., Liang Z. Retrieval of the leaf area density of Magnolia woody canopy with terrestrial Laser-scanning data. J. Remote Sens. 2016. vol. 20. no. 4. pp. 570-578.
4. Tumbo S.D., Salyani M., Whitney J.D., Wheaton T.A., Miller W.M. Investigation of laser and ultrasonic ranging sensors for measurements of citrus canopy volume. Applied Engineering in Agriculture. 2002. vol. 18. no. 3. p. 367.
5. Colaco A.F., Trevisan R.G., Molin J.P., Rosell-Polo J.R., Escolà A. A method to obtain orange crop geometry information using a mobile terrestrial laser scanner and 3D modeling. Remote Sensing. 2017. vol. 9. no. 8. p. 763.

6. Martínez-Casasnovas J.A., Rufat J., Arnó J., Arbonés A., Sebé F., Pascual M., Rosell-Polo J.R. Mobile terrestrial laser scanner applications in precision fructiculture/horticulture and tools to extract information from canopy point clouds. *Precision Agriculture*. 2017. vol. 18. no. 1. pp. 111-132.
7. Hu M., Whitty M. An evaluation of an apple canopy density mapping system for a variable-rate sprayer. *IFAC-PapersOnLine*. 2019. vol. 52. no. 30. pp. 342-348.
8. Gil E., Escolà A., Rosell J.R., Planas S., Val L. Variable rate application of plant protection products in vineyard using ultrasonic sensors. *Crop Protection*. 2007. vol. 26. no. 8. pp. 1287-1297.
9. Salyani M. Optimization of deposition efficiency for airblast sprayers. *Transactions of the ASAE*. 2000. vol. 43. no. 2. p. 247.
10. Liu H., Zhu H. Evaluation of a laser scanning sensor in detection of complex-shaped targets for variable-rate sprayer development. *Transactions of the ASABE*. 2016. vol. 59. no. 5. pp. 1181-1192.
11. Esau T.J., Zaman Q.U., Chang Y.K., Schumann A.W., Percival D.C., Farooque A.A. Spot-application of fungicide for wild blueberry using an automated prototype variable rate sprayer. *Precision agriculture*. 2014. vol. 15. no. 2. pp. 147-161.
12. Wandkar S.V., Bhatt Y.C., Jain H.K., Nalawade S.M., Pawar S.G. Real-time variable rate spraying in orchards and vineyards: A review. *Journal of The Institution of Engineers (India): Series A*. 2018. vol. 99. no. 2. pp. 385-390.
13. Zhang R., Song L. Study of variable spray control system based on machine vision. In *2014 IEEE 13th International Conference on Cognitive Informatics and Cognitive Computing*, 2014. pp. 455-458.
14. Chen Y., Zhu H., Ozkan H.E. Development of a variable-rate sprayer with laser scanning sensor to synchronize spray outputs to tree structures. *Transactions of the ASABE*. 2012. vol. 55. no. 3. pp. 773-781.
15. Jeon H.Y., Zhu H. Development of a variable-rate sprayer for nursery liner applications. *Transactions of the ASABE*. 2012. vol. 55. no. 1. pp. 303-312.
16. Liu H., Zhu H., Shen Y., Chen Y., Ozkan H.E. Development of digital flow control system for multi-channel variable-rate sprayers. *Transactions of the ASABE*. 2014. vol. 57. no. 1. pp. 273-281.
17. Llorens J., Gil E., Llop J., Escolà A. Ultrasonic and LIDAR sensors for electronic canopy characterization in vineyards: Advances to improve pesticide application methods. *Sensors*. 2011. vol. 11. no. 2. pp. 2177-2194.
18. Zhu H., Ozkan E. An update on the intelligent spraying system development for fruit and nursery crop applications. In *15th Workshop on Spray Application and Precision Technology in Fruit Growing Programme and Abstracts*, 2019. p.35.
19. Nackley L.L., Warneke B., Fessler L., Pscheidt J.W., Lockwood D., Wright W.C., Fulcher A. Variable-rate spray technology optimizes pesticide application by adjusting for seasonal shifts in deciduous perennial crops. *HortTechnology*. 2021. vol. 31. no. 4. pp. 479-489.
20. Dou H., Zhai C., Chen L., Wang X., Zou W. Comparison of Orchard Target-Oriented Spraying Systems Using Photoelectric or Ultrasonic Sensors. *Agriculture*. 2021. vol. 11. no. 8. pp. 753.
21. Lian Q., Tan F., Fu X., Zhang P., Liu X., Zhang W. Design of precision variable-rate spray system for unmanned aerial vehicle using automatic control method. *International Journal of Agricultural and Biological Engineering*. 2019. vol. 12. no. 2. pp. 29-35.
22. Kotkar V.A. An automatic pesticide sprayer to detect the crop disease using machine learning algorithms and spraying pesticide on affected crops. *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*. 2021. vol. 12. no. 1S. pp. 65-72.

23. Manandhar A., Zhu H., Ozkan E., Shah A. Techno-economic impacts of using a laser-guided variable-rate spraying system to retrofit conventional constant-rate sprayers. *Precision Agriculture*. 2020. vol. 21. no. 5. pp. 1156-1171.
24. Shirzadifar A.M. Automatic weed detection system and smart herbicide sprayer robot for corn fields. In 2013 First RSI/ISM International Conference on Robotics and Mechatronics (ICRoM), 2013. pp. 468-473.
25. Wei Z., Xiu W., Wei D., Shuai S., Shuain W., Pengfei F. Design and test of automatic toward-target sprayer used in orchard. In 2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER), 2015. pp. 697-702.
26. Berenstein R., Edan Y. Automatic adjustable spraying device for site-specific agricultural application. *IEEE Transactions on Automation Science and Engineering*, 2017. vol. 15. no. 2. pp. 641-650.
27. Cai J., Wang X., Gao Y., Yang S., Zhao C. Design and performance evaluation of a variable-rate orchard sprayer based on a laser-scanning sensor. *International Journal of Agricultural and Biological Engineering*. 2019. vol. 12. no. 6. pp. 51-57.
28. Seol J., Kim J., Son H.I. Field evaluations of a deep learning-based intelligent spraying robot with flow control for pear orchards. *Precision Agriculture*. 2022. vol. 23. no. 2. pp. 712-732.
29. Khodabakhshian R., Javadpour S.M. Design and development of a sensor-based precision crop protection autonomous system for orchard sprayer. *Agricultural Engineering International: CIGR Journal*. 2021. vol. 23. no. 3.
30. Ni M., Wang H., Liu X., Liao Y., Fu L., Wu Q., Li J. Design of Variable Spray System for Plant Protection UAV Based on CFD Simulation and Regression Analysis. *Sensors*. 2021. vol. 21. no. 2. pp. 638.
31. Wen S., Zhang Q., Deng J., Lan Y., Yin X., Shan J. Design and experiment of a variable spray system for unmanned aerial vehicles based on PID and PWM control. *Applied Sciences*. 2018. vol. 8. no. 12. pp. 2482.
32. Maghsoudi H., Minaei S., Ghobadian B., Masoudi H. Ultrasonic sensing of pistachio canopy for low-volume precision spraying. *Computers and Electronics in Agriculture*. 2015. vol. 112. pp. 149-160.
33. Tewari V.K., Chandel A.K., Nare B., Kumar S. Sonar sensing predicated automatic spraying technology for orchards. *Current Science*. 2018. vol. 115. no. 6. pp. 1115-1123.
34. Zhou H., Jia W., Li Y., Ou M. Method for Estimating Canopy Thickness Using Ultrasonic Sensor Technology. *Agriculture*. 2021. vol. 11. no. 10. pp. 1011.
35. Dou H., Wang S., Zhai C., Chen L., Wang X., Zhao X. A LiDAR Sensor-Based Spray Boom Height Detection Method and the Corresponding Experimental Validation. *Sensors*. 2021. vol. 21. no. 6. pp. 2107.
36. Mahmud M.S., Zahid A., He L., Choi D., Krawczyk G., Zhu H., Heinemann P. Development of a LiDAR-guided section-based tree canopy density measurement system for precision spray applications. *Computers and Electronics in Agriculture*. 2021. vol. 182. pp. 106053.
37. Meng Y., Zhong W., Liu Y., Wang M., Lan Y. Droplet Distribution of an Autonomous UAV-based Sprayer in Citrus Tree Canopy. In *Journal of Physics: Conference Series*. 2022. vol. 2203. no. 1. pp. 012022.
38. Wen S., Zhang Q., Yin X., Lan Y., Zhang J., Ge Y. Design of plant protection UAV variable spray system based on neural networks. *Sensors*. 2019. vol. 19. no. 5. pp. 1112.
39. Partel V., Costa L., Ampatzidis Y. Smart tree crop sprayer utilizing sensor fusion and artificial intelligence. *Computers and Electronics in Agriculture*. 2021. vol. 191. pp. 106556.

40. Partel V., Nunes L., Stansly P., Ampatzidis Y. Automated vision-based system for monitoring Asian citrus psyllid in orchards utilizing artificial intelligence. *Computers and Electronics in Agriculture*. 2019. vol. 162. pp. 328-336.
41. Du Y., Zhang G., Tsang D., Jawed M.K. Deep-CNN based Robotic Multi-Class Under-Canopy Weed Control in Precision Farming. arXiv preprint arXiv:2112.13986, 2021.
42. Qin Z., Wang W., Dammer K.H., Guo L., Cao Z. A real-time low-cost artificial intelligence system for autonomous spraying in palm plantations. arXiv preprint arXiv:2103.04132, 2021.
43. Seol J., Kim J., Son H.I. Field evaluations of a deep learning-based intelligent spraying robot with flow control for pear orchards. *Precision Agriculture*. 2022. vol. 23. no. 2. pp. 712-732.
44. Liu J., Abbas I., Noor R.S. Development of Deep Learning-Based Variable Rate Agrochemical Spraying System for Targeted Weeds Control in Strawberry Crop. *Agronomy*. 2021. vol. 11. no. 8. pp. 1480.
45. Gao P., Zhang Y., Zhang L., Noguchi R., Ahamed T. Development of a recognition system for spraying areas from unmanned aerial vehicles using a machine learning approach. *Sensors*. 2019. vol. 19. no. 2. pp. 313.
46. Alam M., Alam M.S., Roman M., Tufail M., Khan M.U., Khan M.T. Real-time machine-learning based crop/weed detection and classification for variable-rate spraying in precision agriculture. In *2020 7th International Conference on Electrical and Electronics Engineering (ICEEE)*, 2020. pp. 273-280.
47. Chen T., Meng F. Development and performance test of a height-adaptive pesticide spraying system. *IEEE Access*, 2018. vol. 6. pp. 12342-12350.

Патил Сима Сухас — научный сотрудник, Инженерный колледж Колхапурского технологического института. Область научных интересов: электроника, компьютерная сеть. Число научных публикаций — 10. seema.patil9@gmail.com; Гокул Ширгаон, 199В/1-3, 416234, Колхапур, Индия; р.т.: +919834104353.

Патил Юврадж Махадев — Ph.D., Dr.Sci., профессор кафедры, кафедра электроники и телекоммуникаций, Инженерный колледж Колхапурского технологического института. Область научных интересов: системы связи, системы управления. Число научных публикаций — 43. umr2002@rediffmail.com; Гокул Ширгаон, 199В/1-3, 416234, Колхапур, Россия; р.т.: +917769001199.

Патил Сухас Банусо — Ph.D., Dr.Sci., профессор, директор, Колледж сельскохозяйственной инженерии и технологий Д.Ю. Патила. Область научных интересов: сельскохозяйственная техника, энергетика. Число научных публикаций — 80. sbratilprincipalpdrcaet@gmail.com; Талсанд, 416112, Колхапур, Индия; р.т.: +919823381191.

Е.Ю. ШМАЛЬКО

**МАШИННО СИНТЕЗИРОВАННОЕ УПРАВЛЕНИЕ
НЕЛИНЕЙНЫМ ДИНАМИЧЕСКИМ ОБЪЕКТОМ НА ОСНОВЕ
ОПТИМАЛЬНОГО РАСПОЛОЖЕНИЯ ТОЧЕК РАВНОВЕСИЯ**

Шмалько Е.Ю. Машинно синтезированное управление нелинейным динамическим объектом на основе оптимального расположения точек равновесия.

Аннотация. При решении задачи оптимального управления как прямыми так и непрямыми подходами основной прием состоит в переводе задачи оптимального управления из класса бесконечномерной оптимизации в конечномерную. Однако, при всех этих подходах в результате получается разомкнутое программное управление, чувствительное к неопределенностям, и для реализации которого в реальном объекте необходимо построить систему стабилизации. Введение системы стабилизации изменяет динамику объекта, а значит оптимальное управление и оптимальная траектория должны рассчитываться для объекта уже с учетом системы стабилизации. В итоге получается, что изначальная задача оптимального управления является сложной, и часто возможность ее решения крайне зависима от типа объекта и функционала, а в случае усложнения объекта за счет введения системы стабилизации сложность задачи значительно увеличивается и применение классических подходов решения задачи оптимального управления оказывается трудоемким или невозможным. В настоящей работе предложен метод синтезированного оптимального управления, который реализует обозначенную логику разработки систем оптимального управления, преодолевая вычислительную сложность поставленной задачи за счет применения современных методов машинного обучения на основе символьной регрессии и эволюционных алгоритмов оптимизации. Согласно подходу сначала строится система стабилизации объекта относительно некоторой точки, а далее положение этой точки равновесия становится параметром управления. Таким образом, удается перевести задачу бесконечномерной оптимизации в задачу конечномерной оптимизации, а именно оптимального расположения точек равновесия. Эффективность подхода продемонстрирована на решении задачи оптимального управления мобильным роботом.

Ключевые слова: оптимальное управление, точка равновесия, нелинейный объект, машинное обучение, стабилизация.

1. Введение. Классическая теория оптимального управления с ее обширным набором методов и инструментариев разрабатывалась под влиянием двух основных факторов. Во-первых, развитие сильных аналитических методов являлось по сути единственной альтернативой в виду недостаточных вычислительных мощностей. А во-вторых, основными прикладными областями использования данных методов являлись оборонная и ракетно-космическая отрасли, где предъявляются высочайшие требования к точности и надежности разрабатываемых систем в виду как высокой стоимости данных объектов управления, так и вопросов, связанных с безопасностью, политической значимостью и охраной государства.

Сегодня с обширным внедрением и массовой разработкой разнофункциональных робототехнических устройств, требования к разрабатываемым системам управления несколько изменились. На первые планы выходят быстрота разработки систем управления и универсальность подходов. К новым вызовам при разработке систем управления можно добавить требование ускорения процессов создания систем автоматического управления, необходимость иметь дело со все более сложными и разнообразными системами, а также необходимость разработки с меньшими предварительными знаниями об объекте и его окружении, включая управления в условиях неопределенности. Эти потребности привели к переоценке традиционных методов управления и сделали совершенно очевидной потребность в новых методах теории управления.

Для достижения обозначенных целей и всесторонней автоматизации и универсализации подходов в управлении необходимо, все-таки, сначала поставить требуемые задачи в универсальных математических формулировках, а затем найти общие методы их решения.

В теории управления такой наиболее общей задачей является задача оптимального управления, в исходной постановке представленная Л.С. Понтрягиным [1]:

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}, \mathbf{u}), \mathbf{x} \in \mathbb{R}^n, \\ \mathbf{x}(0) = \mathbf{x}^0, \\ \mathbf{x}(t_f) = \mathbf{x}^f, \\ J = \int_0^{t_f} f_0(\mathbf{x}, \mathbf{u}) dt \rightarrow \min, \\ \mathbf{u} \in U \subseteq \mathbb{R}^m, m \leq n, \end{cases} \quad (1)$$

где \mathbf{x} – вектор, описывающий состояние объекта управления, \mathbf{u} – управление, U – компактное множество, t_f – терминальное время, может быть не задано, но ограничено $t_f \leq t^+$, t^+ – заданная величина границы по времени.

В этой задаче (1) необходимо найти функцию управления:

$$\mathbf{u} = \mathbf{v}(t) \in U, \quad (2)$$

такую, что если ее подставить в уравнения модели, то получится следующая система:

$$\dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}, \mathbf{v}(t)), \quad (3)$$

и частное решение $\mathbf{x}(t, \mathbf{x}^0)$ этой системы (3) из заданного начального состояния $\mathbf{x}(0) = \mathbf{x}^0$ попадет в терминальное состояние $\mathbf{x}(t_f, \mathbf{x}^0) = \mathbf{x}^f$, $t_f \leq t^+$ с оптимальным значением показателя критерия качества:

$$J = \int_0^{t_f} f_0(\mathbf{x}(t, \mathbf{x}^0), \mathbf{v}(t)) dt = \min_{\mathbf{u} \in \bar{U}}. \quad (4)$$

В дальнейшем постановка задачи (1) видоизменялась. В нее были введены различные типы фазовых ограничений [2–4], такие как терминальные ограничение типа равенства [5], фазовые ограничения в виде неравенств [6], динамические фазовые ограничения в задачах управления для групп объектов [7], оптимальное управление системами при неопределенных воздействиях [8]. В любом случае задача оптимального управления всегда должна и может быть поставлена, когда необходимо найти управление для динамического объекта, который должен выполнять некоторые действия с заданным критерием качества. Различные задачи для роботов, как и любых других объектов управления, можно сформулировать как задачи оптимального управления, например, для нахождения оптимального пути в текущих реальных условиях, задачи предотвращения столкновений со статическими и динамическими препятствиями, задачи взаимодействия с другими объектами управления, задачи точного достижения заданных граничных условий и т.д.

Решению задачи машинно синтезированного управления с учетом практической ее реализации на объекте управления посвящена настоящая работа. На основании обзора существующих подходов к решению задачи оптимального управления и выявленных недостатков, в работе вводится свойство, которым должна обладать система оптимального управления, чтобы она могла быть реализуемой на объекте. В качестве практического метода решения задачи оптимального управления, обладающего введенным свойством, предложен метод синтезированного оптимального управления, который можно отнести к классу непрямых методов оптимального управления. Согласно методу, сначала в объект управления вводится система стабилизации, обеспечивающая объекту свойство устойчивости относительно некоторой точки равновесия. Далее оптимальное управление объектом реализуется через изменение положения точки равновесия. В работе представлена

математическая постановка описанного подхода и предложены алгоритмы реализации его этапов с помощью современных вычислительных методов машинного обучения. Использование машинных подходов для обучения систем управления [9] позволяет найти хорошее близкое к оптимальному решение за ограниченное время. Но в связи с новизной этих методов возникает необходимость обосновать результаты, полученные машинным обучением. В этой связи в статье введены несколько определений некоторых машинных свойств системы. В экспериментальной части работы приведен пример реализации метода синтезированного оптимального управления на задаче оптимального управления мобильным роботом.

2. Обзор существующих подходов. Среди общих подходов к решению задачи оптимального управления (1) выделяют два направления: прямой и непрямой методы. Непрямой подход, основанный на принципе максимума Понтрягина [10, 11], решает задачу оптимального управления, формулируя ее в виде краевой задачи, в которой необходимо найти начальные условия для системы дифференциальных уравнений для сопряженных переменных. Найденное оптимальное решение обладает высокой точностью, однако технология вычислительно сложна, особенно в части интегрирования системы сопряженных уравнений в виду отсутствия начальных условий для них, и обеспечения максимума Гамильтониана, что, очень трудно рассчитать, например, для задач со сложными фазовыми ограничениями. Прямой подход сводит задачу оптимального управления к задаче нелинейного программирования [12–14]. В итоге оба метода обеспечивают переход от задачи оптимизации в бесконечномерном пространстве к задаче оптимизации в конечномерном пространстве. Для таких задач на сегодняшний день уже разработаны различные оптимизационные алгоритмы, в том числе глобальной оптимизации [15–17], включая современные эволюционные и популяционные алгоритмы [18].

Однако в этих классических подходах к решению задачи оптимального управления обычно основное внимание уделяется характеристикам номинальной траектории без учета возможных неопределенностей. На практике же в правых частях моделей и в начальных условиях объективно присутствуют неопределённости различной природы. Как правило, они не учитываются, но наличие таких неопределенностей может привести как к потере оптимальности получаемого управления, так и к попаданию в целевое терминальное положение.

Существуют также подходы, когда влияние неопределенностей учитывается заранее при расчете опорной траектории [19]. Например, десенсibiliзованное оптимальное управление [20, 21] изменяет номинальную оптимальную траекторию таким образом, что она становится менее чувствительной к неопределенным параметрам путем добавления соответствующей стоимости за чувствительность. Но при реализации такие решения не гарантируют устойчивости и все равно требуют построения системы стабилизации в обратной связи.

При практическом проектировании систем управления существующие неопределенности, которые впоследствии вызывают расхождение между реальной траекторией объекта и полученной оптимальной, компенсируются синтезом системы стабилизации движения относительно оптимальной траектории [22, 23]. То есть введение управления с обратной связью в систему дифференциальных уравнений придает системе некоторое свойство, позволяющее достичь цели с оптимальным значением качества, то есть быть реализуемым.

Понятно, что не все системы управления реализуемы. Например, оптимальные, но разомкнутые системы управления не обладают свойством реализуемости. И наоборот, устойчивые по Ляпунову системы реализуемы. Однако, есть примеры, когда решение не является устойчивым по Ляпунову, но в то же время реализуемо. Например, при движении по точкам само движение к точке устойчиво по Ляпунову, а движение по траектории, состоящей из точек, не устойчиво по Ляпунову, но именно такой способ управления сейчас реализуется чаще всего. Таким образом, возникает необходимость сформулировать свойство, позволяющее определить реализуемость системы.

Согласно качественному анализу решений систем дифференциальных уравнений [24], реализуемость означает, что небольшие изменения в модели не приводят к потере качества. Другими словами, необходимо, чтобы решение обладало бы свойством сжимаемости.

Определение 1. *Частное решение $\mathbf{x}(t, \mathbf{x}^0)$ дифференциального уравнения $\dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}, \mathbf{g}(\mathbf{x}, t))$ обладает свойством сжимаемости, если для любого другого частного решения $\mathbf{x}(t, \mathbf{x}^*)$ выполняются следующие условия:*

если:

$$\|\mathbf{x}(t', \mathbf{x}^0) - \mathbf{x}(t', \mathbf{x}^*)\| \leq \sigma, \quad (5)$$

где $t' > 0$, $\sigma > 0$,

тогда $\alpha > 0$ такое, что для любого $\varepsilon^+ > 0$:

$$\|\mathbf{x}(t' + \alpha, \mathbf{x}^0) - \mathbf{x}(t' + \alpha, \mathbf{x}^*)\| \leq \varepsilon^+. \quad (6)$$

С математической точки зрения, вводя стабилизирующее управление по состоянию $\mathbf{g}(\mathbf{x}, t)$ в обратной связи, мы изменяем дифференциальные уравнения самой системы объекта так, что вокруг некоторого частного решения системы (вокруг оптимальной траектории) появляется некоторая область, такая, что другие траектории, попадающие в эту область, не покидали бы ее.

Гипотеза. Для того, чтобы найденная функция оптимального управления $\mathbf{g}(\mathbf{x}, t)$ обладала свойством реализуемости в реальном объекте управления, оптимальная траектория $\mathbf{x}(t, \mathbf{x}^0)$ должна обладать свойством сжимаемости (5), (6).

Таким образом, для получения реализуемого решения задачи оптимального управления (1) необходимо построить такую функцию управления $\mathbf{g}(\mathbf{x}, t)$, которая заставляет объект достигать заданной цели с оптимальным значением критерия качества и удовлетворяет требуемым свойствам (5), (6).

Технически выполнение свойств (5), (6) можно обеспечить за счет введения в обратную связь системы стабилизации. Например, система стабилизации вводится после построения оптимальной программной траектории, в [25] точки расставляются на траектории и объект стабилизируется в этих точках. Это наиболее популярный практический подход к проектированию оптимальной системы управления с обратной связью. Однако по критерию оптимальности такой подход не совсем корректен, так как получается, что оптимальная траектория рассчитывалась для одного объекта управления, а введенная система стабилизации меняет объект, так что расчетный путь может быть не оптимальным для измененного объекта. Кроме того, при приближении к заданной точке пути система замедляется, поэтому необходимо проводить дополнительные оценки в каждой конкретной задаче, по оптимальным моментам переключения точек.

Вполне корректно сначала ввести в обратную связь систему стабилизации и уже потом производить расчет оптимального управления для объекта с системой стабилизации. Именно такой принцип лежит в основе метода синтезированного оптимального управления на основе положения точки равновесия, представленного в работе. Приведем далее математическую формулировку подхода.

3. Метод синтезированного оптимального управления.

Основная идея подхода состоит в том, что ищется функция управления, при которой система дифференциальных уравнений, описывающих объект, всегда будет иметь устойчивую точку равновесия в пространстве состояний. При этом функция управления содержит параметры, влияющие на положение точки равновесия. Следовательно, управление объектом осуществляется за счет изменения положения точки равновесия, а именно оптимального их расположения на заданных интервалах.

Формально согласно методу реализуются последовательно решение двух задач [26]: задачи синтеза системы стабилизации и задачи оптимального расположения точек устойчивости, т.е. задачи параметрической оптимизации. Приведем их математические постановки.

Задана математическая модель объекта управления:

$$\dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}, \mathbf{u}). \quad (7)$$

Задано множество начальных условий:

$$X_0 = \{\mathbf{x}^{0,1}, \dots, \mathbf{x}^{0,K}\}, \quad (8)$$

где $\mathbf{x}^{0,j} \in X_0 \subseteq \mathbb{R}^n$, $\|\mathbf{x}^{0,i} - \mathbf{x}^{0,j}\| \leq \delta$, $i, j \in \{1, \dots, K\}$, δ – заданная величина, определяющая размер области X_0 начальных условий.

Задано одно терминальное состояние:

$$\mathbf{x}^* = [x_1^* \dots x_n^*]^T. \quad (9)$$

Задан критерий качества:

$$J_1 = \sum_{i=1}^K (p_1 \|\mathbf{x}(t_{f,i}, \mathbf{x}^{0,i}) - \mathbf{x}^*\| + t_{f,i}) \rightarrow \min_{\mathbf{u} \in U}, \quad (10)$$

где p_1 – весовой коэффициент, $t_{f,i}$ – время достижения терминального состояния (9):

$$t_{f,i} = \begin{cases} t, & \text{если } t < t^+ \text{ и } \|\mathbf{x}(t, \mathbf{x}^{0,i}) - \mathbf{x}^*\| \leq \varepsilon \\ t^+ & \text{иначе} \end{cases}, \quad i = 1, \dots, K, \quad (11)$$

ε и t^+ – заданные положительные величины.

Для решения задачи синтеза системы стабилизации необходимо найти функцию управления в форме:

$$\mathbf{u} = \mathbf{g}(\mathbf{x}, \mathbf{x}^*) \in U, \quad (12)$$

доставляющую минимум функционалу J_1 .

В полученную функцию управления введем вектор параметров \mathbf{q}^* , влияющий на положение точки равновесия. Функция управления (12) обеспечивает системе:

$$\dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}, \mathbf{g}(\mathbf{x}, \mathbf{q}^*)), \quad (13)$$

существование точки равновесия:

$$\mathbf{f}(\mathbf{x}^*(\mathbf{q}^*), \mathbf{g}(\mathbf{x}^*(\mathbf{q}^*), \mathbf{q}^*)) = 0, \quad (14)$$

где $\mathbf{x}^*(\mathbf{q}^*)$ – вектор координат точки равновесия, зависящий от вектора параметров \mathbf{q}^* . Система (13) удовлетворяет условиям (5), (6) в точке $\mathbf{x}^*(\mathbf{q}^*)$.

На втором этапе решаем задачу оптимального управления как задачу конечномерной оптимизации вектора параметров \mathbf{q}^* . Математическая постановка задачи имеет следующее описание.

Задана модель объекта управления:

$$\dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}, \mathbf{g}(\mathbf{x}, \mathbf{q}^*)). \quad (15)$$

Возможные неопределенности, согласно теории устойчивости Ляпунова [27], можно рассматривать как неопределенности в начальных условиях. Поэтому задачу оптимального управления будем рассматривать не из одного начального состояния, как в классической постановке (1), а из области начальных значений.

Пусть задано следующее множество начальных значений:

$$\tilde{X}_0 = \{\mathbf{x}^{0,1}, \dots, \mathbf{x}^{0,j}, \dots, \mathbf{x}^{0,M}\}, \quad (16)$$

где M – заданное количество точек начальных значений.

Терминальное условие и критерий качества определены в исходной постановке задачи оптимального управления (1). С учетом найденной функции стабилизации (12), множества начальных значений (16) и с включением точности попадания в терминальное состояние в критерий качества, функционал для задачи оптимального управления положениями

точек равновесия имеет следующий вид:

$$J_2 = \sum_{i=1}^M \left(\| \mathbf{x}(t_{f,i}, \mathbf{x}^{0,i}) - \mathbf{x}^f \| + \int_0^{t_{f,i}} f_0(\mathbf{x}, \mathbf{g}(\mathbf{x}, \mathbf{q}^*)) dt \right) \rightarrow \min_{\mathbf{q}^* \in Q}, \quad (17)$$

где Q – компакт в пространстве параметров, $t_{f,i}$ определяется из соотношения (11) с заменой \mathbf{x}^* на \mathbf{x}^f .

В общем случае вектором параметров \mathbf{q}^* может быть некоторая функция $\mathbf{q}^*(t)$. Свойства этой функции и методы ее нахождения требуют дополнительных исследований. В частном случае, управление \mathbf{q}^* можно рассматривать в форме кусочно-постоянной функции времени. Разбиваем временной отрезок $[0; t^+]$ на равные интервалы Δt . Таким образом, в задаче оптимального управления необходимо найти значения координат точки устойчивости для каждого интервала через определение оптимального значения вектора параметров, доставляющее минимум функционалу качества J_2 :

$$\mathbf{q}^*(t) = \mathbf{q}^{*,j}, \text{ если } t \in [(j-1)\Delta t; j\Delta t), j = 1, \dots, N, \quad (18)$$

где N – количество интервалов,

$$N = \lfloor t^+ / \Delta t \rfloor + 1. \quad (19)$$

Таким образом, благодаря такому синтезированному подходу к решению задачи оптимального управления, мы, с одной стороны, обеспечиваем свойство реализуемости найденному управлению, и, с другой стороны, переводим задачу из класса задач бесконечномерной оптимизации к конечномерной, обеспечивая тем самым возможность применения для ее решения широкого набора численных методов оптимизации.

4. Особенности применения машинных алгоритмов обучения систем управления. В соответствии с представленной формальной постановкой метода синтезированного оптимального управления для его реализации потребуется применение методов синтеза систем управления и методов оптимизации.

В теории управления задача синтеза управления является одной из наиболее сложных. В подавляющем большинстве случаев задача синтеза управления решается аналитически или технически с учетом специфики математической модели. Сегодня для решения задачи синтеза для нелинейных динамических объектов различной сложности могут быть

применены современные численные методы машинного обучения [28]. Задача машинного обучения состоит в поиске неизвестной функции. В нашем случае неизвестной функцией является функция управления.

Новая парадигма машинного обучения систем управления [29] позволяет найти хорошее близкое к оптимальному решение за предельное время. Но в этой связи возникает необходимость обосновать результаты, полученные машинным обучением. Обобщая различные определения машинного обучения [30–32], можно сделать вывод, что машинное обучение – это неточное численное решение некоторой математической задачи оптимизации, то есть решение, полученное машинным обучением, отличается от точного на некоторую величину, но удовлетворяет исследователя, и его можно улучшить, продолжив обучение. Во всех случаях для машинного обучения используются различные алгоритмы оптимизации, но для этих алгоритмов достаточно найти близкое к оптимальному решение.

Определение 2. *Машинное обучение – это процесс поиска решения задачи оптимизации в Δ -окрестности оптимального решения.*

Особенность машинного обучения в том, что обучение не требует достижения точного минимума показателя критерия:

$$J \leq \min J + \Delta, \quad (20)$$

где Δ – некоторое положительное значение отклонения, определяющее значение функционала, достижимое при обучении.

Если в результате машинного обучения найденная функция управления должна приобрести некоторые свойства, то доказательство наличия этих свойств подтверждается моделированием и статистическим обобщением результатов моделирования:

$$\tilde{J} = \sum_{i=0}^K \vartheta(\phi(\alpha(\mathbf{x}^i, \mathbf{q}))), \quad (21)$$

где $\vartheta(z)$ – функция Хевисайда:

$$\vartheta(z) = \begin{cases} 1, & \text{если } z > 0 \\ 0, & \text{иначе,} \end{cases} \quad (22)$$

$\phi(\mathbf{x}, \mathbf{q})$ – условие, которое определяет, обладает ли функция этим свойством:

$$\phi(\mathbf{x}, \mathbf{q}) \leq 0, \quad (23)$$

K – количество последовательных экспериментов, выполненных с удовлетворением (23), установленных для доказательства наличия свойства.

Определение 3. Если проводятся D экспериментов, и в каждом i эксперименте K_i частных решений дифференциального уравнения выполняют требуемое свойство из любых $M_i \geq K_i$ случайно выбранных начальных условий из начальной области, и:

$$\lim_{D \rightarrow \infty} \sum_{i=1}^D \frac{K_i}{M_i} \rightarrow 1, \quad (24)$$

существование этого свойства для дифференциального уравнения в этой области считаем машинно доказанным.

Введенные машинные интерпретации свойств объектов позволяют в дальнейшем решать сложные технические задачи машинными методами и проверять достижение требуемых свойств также на машинах.

5. Машинное обучение систем управления на основе символьной регрессии. Применение методов машинного обучения открывает широкие перспективы с точки зрения решения тех задач, которые раньше считались очень сложными или вообще трудно разрешимыми. Сегодня эти методы завоевывают все большую популярность у разработчиков. Например, мы наблюдаем широкое применение нейросетевых технологий, особенно в задачах распознавания [34, 35] или классификации [36, 37]. Здесь хорошую эффективность показали технологии, основанные на машинном обучении с учителем, когда есть достаточный набор обучающих данных и критерием обучения является уменьшение ошибки.

Однако при разработке систем управления у инженера обычно нет необходимого набора обучающих данных, разве что получать их при ручном управлении и аппроксимировать режимы управления, произведенные оператором. Но такой подход не сильно популярен, поскольку, во-первых, скорее всего не является оптимальным, а, во вторых, для обучения все-таки требуется значительное количество обучающих примеров управления. В итоге при обучении оптимальной системы управления разработчик может опираться только на значение функционала качества. К методам машинного обучения без учителя,

которые показали свою эффективность для задач синтеза систем управления [33, 38], относятся методы символьной регрессии. Выгодная особенность этих методов состоит в том, что они позволяют искать не только оптимальные параметры функции управления, но и оптимальную структуру. Поиск структуры функции управления осуществляется на базе заданного алфавита элементарных функций. Методы символьной регрессии используют алгоритмы эволюционной оптимизации для структурно-параметрического поиска функции управления непосредственно на основе значения функционала качества.

6. Пример решения задачи оптимального управления синтезированным методом для мобильного робота. В качестве демонстрационного примера применения синтезированного оптимального управления рассмотрим задачу оптимального управления с фазовыми ограничениями для мобильного робота с дифференциальным приводом:

$$\begin{aligned} \dot{x}_1 &= 0.5(u_1 + u_2) \cos(x_3) \\ \dot{x}_2 &= 0.5(u_1 + u_2) \sin(x_3) \ , \\ \dot{x}_3 &= 0.5(u_1 - u_2) \end{aligned} \quad (25)$$

$$-10 = u_i^- \leq u_i \leq u_i^+ = 10, \quad i = 1, 2, \quad (26)$$

$$\mathbf{x}(0) = \mathbf{x}^0 = [0 \ 0 \ 0]^T, \quad (27)$$

$$\mathbf{x}(t_f) = \mathbf{x}^f = [10 \ 10 \ 0]^T, \quad (28)$$

где:

$$t_f = \begin{cases} t, & \text{если } t < t^+, \text{ и } \|\mathbf{x}(t) - \mathbf{x}^f\| \leq \varepsilon = 0.01 \\ t^+ = 2.8, & \text{иначе.} \end{cases} \quad (29)$$

Задан критерий качества по быстродействию, который включает также точность достижения терминального состояния и штраф за нарушение фазовых ограничений:

$$J_3 = t_f + p_1 \|\mathbf{x}(t_f) - \mathbf{x}^f\| + p_2 \sum_{i=1}^L \int_0^{t_f} \vartheta(\phi_i(\mathbf{x})) dt \rightarrow \min_{\mathbf{u}}, \quad (30)$$

где $p_1 = 1, p_2 = 3$,

$$\vartheta(\alpha) = \begin{cases} 1, & \text{если } \alpha > 0 \\ 0, & \text{иначе} \end{cases}, \quad (31)$$

$$\phi_i(\mathbf{x}) = r_i - \sqrt{(x_1 - x_{1,i})^2 + (x_2 - x_{2,i})^2}, \quad i = 1, 2, \quad (32)$$

$r_1 = r_2 = 2, x_{1,1} = 4, x_{1,2} = 8, x_{2,1} = x_{2,2} = 5$.

Для наглядности сравнения результатов, сначала решим задачу оптимального управления (25)–(32) прямым методом, аппроксимируя функцию управления кусочно-линейной функцией времени. Разобьем временной процесс управления $[0; t^+] = [0; 2.8)$ на интервалы длиной $\Delta t = 0.4$, всего $M = 7$ интервалов, и будем искать значение управления на границах интервалов. С учетом ограничений функция управления имеет следующий вид:

$$u_i = \begin{cases} u_i^- = -10, & \text{если } \tilde{u}_i \leq u_i^- \\ u_i^+ = -10, & \text{если } \tilde{u}_i \geq u_i^+ \\ \tilde{u}_i, & \text{иначе} \end{cases}, \quad i = 1, 2, \quad (33)$$

где

$$\tilde{u}_i = (q_{j+1+(i-1)2} - q_{j+(i-1)2}) \frac{t - j\Delta t}{\Delta t} + q_{j+(i-1)2}, \quad j = 1, \dots, 8. \quad (34)$$

Для поиска оптимальных значений параметров $\tilde{\mathbf{q}} = [\tilde{q}_1 \dots \tilde{q}_{16}]^T$ был выбран эволюционный гибридный алгоритм [39], так как за счет фазовых ограничений функционал имеет невыпуклую форму, а значит градиентные методы могут не найти глобальный минимум. Эволюционные алгоритмы не требуют дифференцируемости функции, а также способны широко исследовать пространство поиска и находить глобальный минимум с большой вероятностью [18, 40].

В результате было получено следующее решение:

$$\tilde{\mathbf{q}} = \begin{bmatrix} 11.67230 & 15.97750 & 15.04710 & 15.21120 \\ -0.96060 & -19.20990 & -6.49860 & 14.60860 \\ -3.24170 & 18.05050 & 9.92270 & 15.93800 \\ 4.21270 & 12.68960 & 0.19430 & -0.27080 \end{bmatrix}^T. \quad (35)$$




Рис. 1. Оптимальная и возмущенная траектории на плоскости для прямого метода решения задачи оптимального управления

Значение функционала для найденного решения (35) составило $\tilde{J}_3 = 1.6749$. Найденная оптимальная траектория представлена на рисунке 1 синим цветом.

Далее начальные условия (27) подвергались случайным возмущениям из диапазонов:

$$x_1(0) = x_1^0 \pm 0.8, \quad x_2(0) = x_2^0 \pm 0.8, \quad x_3(0) = x_3^0 \pm \pi/18. \quad (36)$$

При моделировании было установлено, что найденное оптимальное управление в результате возмущений существенно менялось, траектории нарушали фазовые ограничения, терминальное состояние не достигалось, в итоге значение функционала существенно возрастало. На рисунке 1 приведены синим цветом оптимальная и черным типичная возмущенная траектории на плоскости $\{x_1; x_2\}$, полученная для начальных значений:

$$\tilde{x} = [0.2 \quad -0.5 \quad -0.12]^T. \quad (37)$$

Красными окружностями обозначены фазовые ограничения. Значение функционала для возмущенного решения составило $\tilde{J}_3 = 8.6665$, т.е. возросло по сравнению с оптимальным более, чем в пять раз.

Решим эту же задачу методом синтезированного оптимального управления. Первоначально решим задачу синтеза управления для обеспечения устойчивости относительно точки в пространстве состояний. Для решения задачи используем машинное обучение методом сетевого оператора [41]. Базисная матрица сетевого оператора имела размерность

24×24 , при обучении использовалось двадцать элементарных функций с одним аргументом и две функции с двумя аргументами.

Была получена следующая функция управления:

$$u_i = g_i(x^* - x) = \begin{cases} u_i^+ & \text{если } \hat{u}_i > u_i^+ \\ u_i^- & \text{если } \hat{u}_i < u_i^- \\ \hat{u}_i & \text{иначе} \end{cases}, \quad i = 1, 2, \quad (38)$$

где \hat{u}_1, \hat{u}_2 вычисляются по матрице сетевого оператора (39) с найденными оптимальными значениями параметров $q_1 = 14.7288$, $q_2 = 2.0271$, $q_3 = 4.0222$. Данная матрица Ψ_{NOP} (39) позволяет вычислять значения управлений в зависимости от значений состояния объекта в каждый момент времени, согласно заложенному алгоритму [41].

$$\Psi_{NOP} = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 1 & 10 & 0 & 0 & 12 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 10 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 12 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 2 & 9 & 0 & 0 & 0 & 0 & 10 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 13 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 19 \\ 0 & 0 & 0 & 0 & 0 & 0 & 2 & 0 & 0 & 8 & 0 & 5 & 0 & 4 & 13 & 10 & 0 & 0 & 0 & 14 & 15 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 2 & 0 & 1 & 10 & 9 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 2 & 1 & 0 & 0 & 8 & 0 & 0 & 0 & 12 & 0 & 0 & 0 & 19 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 8 & 0 & 0 & 0 & 1 & 8 & 0 & 0 & 0 & 14 & 12 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 0 & 5 & 4 & 23 & 1 & 0 & 0 & 0 & 15 & 0 & 0 & 23 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 17 & 10 & 10 & 0 & 0 & 0 & 0 & 16 & 0 & 16 & 0 & 16 & 0 & 16 & 0 & 16 & 16 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 15 & 0 & 14 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 9 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 10 & 0 & 0 & 0 & 0 & 12 & 0 & 13 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 8 & 0 & 0 & 16 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 2 & 1 & 0 & 15 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 2 & 0 & 17 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 5 & 0 & 0 & 17 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 0 & 13 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 1 & 17 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \quad (39)$$

Полученное управление, в закодированной в виде матрицы сетевого оператора форме, может быть непосредственно в таком виде реализовано на борту объекта, для чего был разработан ROS-узел контроллера на языке C++ [42], который принимает на вход наземные координаты робота и цели, а на выходе формирует управляющие сигналы. На втором этапе находим оптимальные положения точек равновесия с учетом вариаций начальных условий (16). На каждом интервале ищем по три координаты точки устойчивости $\mathbf{q}^{*,j} = [q_1^{*,j} \ q_2^{*,j} \ q_3^{*,j}]^T$, $j = 1, \dots, 7$. Всего необходимо найти 21 параметр. Для поиска используем тот же гибридный эволюционный алгоритм [39], что и для прямого решения задачи оптимального управления.

В результате вычислений гибридный эволюционный алгоритм нашел следующее решение:

$$\begin{aligned} \mathbf{q}^{*,1} &= [2.48120 \ 0.74430 \ 0.10550]^T, \\ \mathbf{q}^{*,2} &= [3.79378 \ 0.34142 \ 0.82870]^T, \\ \mathbf{q}^{*,3} &= [6.26951 \ 3.18267 \ 0.74528]^T, \\ \mathbf{q}^{*,4} &= [5.92748 \ 3.09719 \ 1.66135]^T, \\ \mathbf{q}^{*,5} &= [7.23992 \ 6.03574 \ 1.04254]^T, \\ \mathbf{q}^{*,6} &= [8.22390 \ 7.03889 \ 1.40074]^T, \\ \mathbf{q}^{*,7} &= [10.02005 \ 8.83120 \ 0.50842]^T. \end{aligned} \quad (40)$$

Алгоритм запускался 10 раз. В результате вычислений наилучшее найденное решение имело значение функционала $J_3^* = 2.8444$, среднее значение всех прогонов равно $J_3^* = 2.865471$, а среднеквадратичное отклонение составило 0,009193.

Далее для найденного решения начальные состояния подвергались тем же возмущениям (36), что и в вычислительном эксперименте для прямого решения. Оптимальная траектория движения практически не изменялась и значение функционала также изменялось незначительно.

На рисунке 2 приведены найденные методом синтезированного оптимального управления оптимальная (синим цветом) и возмущенная (черным цветом) траектории движения робота на плоскости. Возмущенная траектория получена при тех же начальных значениях (37), что и возмущенная траектория прямого решения, приведенная на рисунке 1.




Рис. 2. Оптимальная и возмущенная траектории на плоскости при синтезированном оптимальном управлении

На рисунке малыми черными квадратами показаны проекции найденных оптимальных точек равновесия. Как видно из графиков, приведенных на рисунке 2, возмущенная и оптимальная траектории практически полностью совпадают. Значение функционала для возмущенного решения составило величину $J_3^* = 2.8246$.

7. Заключение. В представленном подходе машинно синтезированного управления на основе оптимального расположения точек равновесия возможные неопределенности компенсируются устойчивостью системы относительно точки равновесия в пространстве состояний. Вблизи точки равновесия все решения сжимаются, а значит выполняются введенные в работе дополнительные условия реализуемости оптимального управления. Этап синтеза системы стабилизации является ключевой идеей подхода, он обеспечивает достижение лучших результатов в задачах с неопределенностями, которые неизбежно существуют в реальных системах. Применение алгоритмов машинного обучения делают представленный подход универсальным и позволяют применять его к различным нелинейным моделям объектов и функционалам любой сложности.

Литература

1. Pontryagin L.S., Boltyanskii V.G., Gamkrelidze R.V., Mishchenko E.F. The Mathematical Theory of Optimal Processes. New York: Division of John Wiley and Sons Inc. 1962. 360 p.
2. Hartl R.F., Sethi S.P., Vickson R.G. A survey of the maximum principles for optimal control problems with state constraints // SIAM Review. 1995. vol. 37. no. 2. pp. Informatics and Automation. 2023. Vol. 22 No. 1. ISSN 2713-3192 (print) 103
ISSN 2713-3206 (online) www.ia.spcras.ru

- 181–218.
3. Dmitruk A.V. Maximum principle for the general optimal control problem with phase and regular mixed constraints // *Computational Mathematics and Modeling*. 1993. vol. 4. no. 4. pp. 364–377.
 4. Karamzin D., Antunes de Oliveira V., Lobo Pereira F.M., Nunes Silva G. Minimax optimal control problem with state constraints // *Eur. J. Control*. 2016. vol. 32. pp. 24–31.
 5. Schwarzkopf A.B. Optimal controls with equality state constraints // *J. Optim. Theory Appl.* 1976. vol. 19. pp. 455–468.
 6. Gao X., Zhang X., Wang Ya. A Simple Exact Penalty Function Method for Optimal Control Problem with Continuous Inequality Constraints // *Abstract and Applied Analysis*. 2014. vol. 2014. p. 12.
 7. Diveev A., Shmalko E. Optimal control design for a group of mobile robots with uncertainties // *Proceedings of the 15th IEEE Conference on Industrial Electronics and Applications*. 2020. vol. 15. pp. 308–313.
 8. Sullivan T.J. *Introduction to Uncertainty Quantification*. Texts in Applied Mathematics. Springer, Cham. 2015. vol. 63. 356 p.
 9. Moe S., Rustad A.M., Hanssen K.G. *Machine Learning in Control Systems: An Overview of the State of the Art* // 38th SGAI International Conference on Artificial Intelligence (Eds.: Brauer M., Petridis M.). Springer, Cham. 2018.
 10. Chertovskih R., Karamzin D., Khalil N.T., Lobo Pereira F. Regular path-constrained time-optimal control problems in three-dimensional flow fields // *Eur. J. Control*. 2020. vol. 56. pp. 98–106.
 11. Arutyunov A., Karamzin D.A. Survey on Regularity Conditions for State-Constrained Optimal Control Problems and the Non-degenerate Maximum Principle // *J. Optim. Theory Appl.* 2020. vol. 184. 697–723.
 12. Gill P.E., Murray W., Wright M.H. *Practical Optimization*. Academic Press: Cambridge. 1981. 402 p.
 13. Евтушенко Ю.Г. Оптимизация и быстрое автоматическое дифференцирование. М.: Научное издание ВЦ РАН. 2013.
 14. Betts J.T. Survey of Numerical Methods for Trajectory Optimization // *J. Guid. Control. Dyn.* 1998. vol. 21. pp. 193–207.
 15. Газизов Т.Т. *Методы глобальной оптимизации: учебное пособие*. Томск: В-Спектр. 2017.
 16. Amirkhanova G., Gorchakov A., Duysenbaeva A., Posypkin M. Multistart method with deterministic restart mechanism // *Vestnik of Saint Petersburg University. Applied Mathematics. Computer Science. Control Processes*. 2020. vol. 16 (2). pp. 100–111.
 17. Евтушенко Ю.Г., Посыпкин М.А. Варианты метода неравномерных покрытий для глобальной оптимизации частично-целочисленных нелинейных задач // *Докл. Академии наук*. 2011. Т. 437(2). С. 168–172.
 18. Карпенко А.П. *Современные алгоритмы поисковой оптимизации. Алгоритмы, вдохновленные природой: учебное пособие*. М.: Издательство МГТУ им. Н.Э. Баумана. 2014.
 19. Saunders B.R. *Optimal Trajectory Optimization under Uncertainty*. Massachusetts Institute of Technology. 2012.
 20. Seywald H., Kumar R. Desensitized Optimal Trajectories // *AIAA/AAS Spaceflight Mechanics Meeting*. 1996. vol. 96 (107). pp. 103–115. doi:10.2514/6.2019-0651.
 21. Makkapati V.R., Dor M., Tsiotras P. Trajectory desensitization in optimal control problems // *Proceedings of the IEEE Conference on Decision and Control*. 2018. pp. 2478–2483.
- 104 Информатика и автоматизация. 2023. Том 22 № 1. ISSN 2713-3192 (печ.)
ISSN 2713-3206 (онлайн) www.ia.spcras.ru

22. Zhou B., Shi Y. Prescribed-Time Stabilization of a Class of Nonlinear Systems by Linear Time-Varying Feedback // *IEEE Transactions on Automatic Control*. 2021. vol. 66. no. 12. pp. 6123-6130.
23. Chen C.C., Qian C., Sun Z.Y., Liang Y.W. Global output feedback stabilization of a class of nonlinear systems with unknown measurement sensitivity // *IEEE Trans. Autom. Control*. 2018. vol. 63. no. 7. pp. 2212-2217.
24. Колмогоров А.Н., Фомин С.В. Элементы теории функций и функционального анализа. М.: Наука.1976.
25. Walsh G., Tilbury D., Sastry S., Murray R., Laumond J.P. Stabilization of trajectories for systems with nonholonomic constraints // *IEEE Transactions on Automatic Control*. 1994. vol. 39. no. 1. pp. 216-222. doi: 10.1109/9.273373.
26. Diveev A.I., Shmalko E.Yu., Serebrenny V.V., Zentay P. Fundamentals of Synthesized Optimal Control // *Mathematics*. 2021. vol. 9(21). pp. 1-18.
27. Малкин И.Г. Теория устойчивости движения. Изд. 4. URSS. 2017.
28. Diveev A., Shmalko E. *Machine Learning Control by Symbolic Regression*. Springer, Cham. 2021.
29. Duriez T., Brunton S.L., Noack B.R. *Machine Learning Control—Taming Nonlinear Dynamics and Turbulence*. Springer: Switzerland. 2017.
30. Deisenroth M.P., Faisal A.A., Ong C.S. *Mathematics for Machine Learning*. Cambridge: Cambridge University Press. 2020.
31. Burkov A. *The Hundred-Page Machine Learning Book*. 2019. 160 p.
32. Geron A. *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. Sebastopol: O'Reilly Media Inc. 2019. 856 p.
33. Diveev A.I., Shmalko E.Y. Machine-Made Synthesis of Stabilization System by Modified Cartesian Genetic Programming // *IEEE Transactions on Cybernetics*. 2022. vol. 52. no. 7. pp. 6627-6637.
34. Savchenko A.V. Probabilistic Neural Network With Complex Exponential Activation Functions in Image Recognition // *IEEE Transactions on Neural Networks and Learning Systems*. 2020. vol. 31. no. 2. pp. 651-660.
35. Zhang W., Wang J., Lan F. Dynamic hand gesture recognition based on short-term sampling neural networks // *IEEE/CAA Journal of Automatica Sinica*. 2021. vol. 8. no. 1. pp. 110-120.
36. Xiao J., Jia Y., Jiang X., Wang S. Circular Complex-Valued GMDH-Type Neural Network for Real-Valued Classification Problems // *IEEE Transactions on Neural Networks and Learning Systems*. 2020. vol. 31. no. 12. pp. 5285-5299.
37. Pelchat N., Gelowitz C.M. Neural Network Music Genre Classification // *Canadian Journal of Electrical and Computer Engineering*. 2020. vol. 43. no. 3. pp. 170-173.
38. Shmalko E., Diveev A. Control Synthesis as Machine Learning Control by Symbolic Regression Methods // *Applied Sciences*. 2021. vol. 11. p. 5468. doi: 10.3390/app11125468.
39. Дивеев А.И. Гибридный эволюционный алгоритм для решения задачи оптимального управления // *Вопросы теории безопасности и устойчивости систем*. 2021. Т. 23. С. 3-12.
40. Дивеев А.И., Константинов С.В. Исследование практической сходимости эволюционных алгоритмов оптимального программного управления колесным роботом // *Известия РАН. Теория и системы управления*. 2018. Т. 57(4). С. 80-106.
41. Дивеев А.И. *Метод сетевого оператора*. М.: Изд-во ВЦ РАН. 2010.

42. Программный пакет расчета значений управляющих сигналов по матрице сетевого оператора https://github.com/urock/network_operator.

Шмалько Елизавета Юрьевна — канд. техн. наук, старший научный сотрудник, отдел управления робототехническими устройствами, Федеральный исследовательский центр "Информатика и управление" Российской академии наук (ФИЦ ИУ РАН); доцент, кафедра робототехнических систем и мехатроники, Московский государственный технический университет имени Н.Э. Баумана (МГТУ им. Н.Э. Баумана). Область научных интересов: современные вычислительные методы в управлении техническими устройствами, машинное обучение, методы символьной регрессии и эволюционные вычисления с приложениями для идентификации, оптимизации и синтеза систем управления. Число научных публикаций — 120. e.shmalko@gmail.com; улица Вавилова, 44/2, 119333, Москва, Россия; р.т.: +7(964)636-6669.

E.Yu. SHMALKO

MACHINE-SYNTHESIZED CONTROL OF NONLINEAR DYNAMIC OBJECT BASED ON OPTIMAL POSITIONING OF EQUILIBRIUM POINTS

Shmalko E.Yu. Machine-Synthesized Control of Nonlinear Dynamic Object Based on Optimal Positioning of Equilibrium Points.

Abstract. When solving an optimal control problem with both direct and indirect approaches, the main technique is to transfer the optimal control problem from the class of infinite-dimensional optimization to a finite-dimensional one. However, with all these approaches, the result is an open-loop program control that is sensitive to uncertainties, and for the implementation of which in a real object it is necessary to build a stabilization system. The introduction of the stabilization system changes the dynamics of the object, which means that the optimal control and the optimal trajectory should be calculated for the object already taking into account the stabilization system. As a result, it turns out that the initial optimal control problem is complex, and often the possibility of solving it is extremely dependent on the type of object and functionality, and if the object becomes more complex due to the introduction of a stabilization system, the complexity of the problem increases significantly and the application of classical approaches to solving the optimal control problem turns out to be time-consuming or impossible. In this paper, a synthesized optimal control method is proposed that implements the designated logic for developing optimal control systems, overcoming the computational complexity of the problem posed through the use of modern machine learning methods based on symbolic regression and evolutionary optimization algorithms. According to the approach, the object stabilization system is first built relative to some point, and then the position of this equilibrium point becomes a control parameter. Thus, it is possible to translate the infinite-dimensional optimization problem into a finite-dimensional optimization problem, namely, the optimal location of equilibrium points. The effectiveness of the approach is demonstrated by solving the problem of optimal control of a mobile robot.

Keywords: optimal control, equilibrium point, nonlinear object, machine learning, stabilization.

References

1. Pontryagin L.S., Boltyanskii V.G., Gamkrelidze R.V., Mishchenko E.F. The Mathematical Theory of Optimal Processes. New York: Division of John Wiley and Sons Inc. 1962. 360 p.
2. Hartl R.F., Sethi S.P., Vickson R.G. A survey of the maximum principles for optimal control problems with state constraints. SIAM Review. 1995. vol. 37. no. 2. pp. 181–218.
3. Dmitruk A.V. Maximum principle for the general optimal control problem with phase and regular mixed constraints. Computational Mathematics and Modeling. 1993. vol. 4. no. 4. pp. 364–377.
4. Karamzin D., Antunes de Oliveira V., Lobo Pereira F.M., Nunes Silva G. Minimax optimal control problem with state constraints. Eur. J. Control. 2016. vol. 32. pp. 24–31.
5. Schwarzkopf A.B. Optimal controls with equality state constraints. J. Optim. Theory Appl. 1976. vol. 19. pp. 455–468.
6. Gao X., Zhang X., Wang Ya. A Simple Exact Penalty Function Method for Optimal Control Problem with Continuous Inequality Constraints. Abstract and Applied Analysis. 2014. vol. 2014. p. 12.

7. Diveev A., Shmalko E. Optimal control design for a group of mobile robots with uncertainties. *Proceedings of the 15th IEEE Conference on Industrial Electronics and Applications*. 2020. vol. 15. pp. 308-313.
8. Sullivan T.J. *Introduction to Uncertainty Quantification*. Texts in Applied Mathematics. Springer, Cham. 2015. vol. 63. 356 p.
9. Moe S., Rustad A.M., Hanssen K.G. *Machine Learning in Control Systems: An Overview of the State of the Art*. 38th SGAI International Conference on Artificial Intelligence (Eds.: Bramer M., Petridis M.). Springer, Cham. 2018.
10. Chertovskih R., Karamzin D., Khalil N.T., Lobo Pereira F. Regular path-constrained time-optimal control problems in three-dimensional flow fields. *Eur. J. Control*. 2020. vol. 56. pp. 98–106.
11. Arutyunov A., Karamzin D.A. Survey on Regularity Conditions for State-Constrained Optimal Control Problems and the Non-degenerate Maximum Principle. *J. Optim. Theory Appl.* 2020. vol. 184. 697–723.
12. Gill P.E., Murray W., Wright M.H. *Practical Optimization*. Academic Press: Cambridge. 1981. 402 p.
13. Evtushenko Y.G. *Optimizatsiya i bystroe avtomaticheskoe differencirovanie [Optimization and fast automatic differentiation]*. M.: Nauchnoe izdanie VC RAN, 2013. (In Russ.).
14. Betts J.T. Survey of Numerical Methods for Trajectory Optimization. *J. Guid. Control. Dyn.* 1998. vol. 21. pp. 193–207.
15. Gazizov T.T. *Metody global'noy optimizatsii: uchebnoye posobiye [Methods of global optimization: tutorial]*. Tomsk: V-Spektr, 2017. (In Russ.).
16. Amirkhanova G., Gorchakov A., Duysenbaeva A., Pospypkin M. Multistart method with deterministic restart mechanism. *Vestnik of Saint Petersburg University. Applied Mathematics. Computer Science. Control Processes*. 2020. vol. 16 (2). pp. 100-111.
17. Yevtushenko Yu.G., Pospypkin M.A. [Variants of the method of non-uniform coverings for global optimization of partial-integer nonlinear problems] *Dokl. Akademii nauk – Reports of the Academy of Sciences*. 2011. vol. 437. no. 2. pp. 168–172. (In Russ.).
18. Karpenko A.P. *Sovremennyye algoritmy poiskovoy optimizatsii. Algoritmy, vdokhnovlennyye prirodoy: uchebnoye posobiye [Modern search engine optimization algorithms. Algorithms inspired by nature: textbook]*. M.: Izdatel'stvo MGTU im. N.E. Baumana. 2014. (In Russ.).
19. Saunders B.R. *Optimal Trajectory Optimization under Uncertainty*. Massachusetts Institute of Technology. 2012.
20. Seywald H., Kumar R. Desensitized Optimal Trajectories // *AIAA/AAS Spaceflight Mechanics Meeting*. 1996. vol. 96 (107). pp. 103-115. doi:10.2514/6.2019-0651.
21. Makkapati V.R., Dor M., Tsiotras P. Trajectory desensitization in optimal control problems. *Proceedings of the IEEE Conference on Decision and Control*. 2018. pp. 2478–2483.
22. Zhou B., Shi Y. Prescribed-Time Stabilization of a Class of Nonlinear Systems by Linear Time-Varying Feedback. *IEEE Transactions on Automatic Control*. 2021. vol. 66. no. 12. pp. 6123-6130.
23. Chen C.C., Qian C., Sun Z.Y., Liang Y.W. Global output feedback stabilization of a class of nonlinear systems with unknown measurement sensitivity. *IEEE Trans. Autom. Control*. 2018. vol. 63. no. 7. pp. 2212-2217.
24. Kolmogorov A.N., Fomin S.V. *Jelementy teorii funkcij i funkcional'nogo analiza [Elements of the theory of functions and functional analysis]*. M.: Nauka, 1976.
25. Walsh G., Tilbury D., Sastry S., Murray R., Laumond J.P. Stabilization of trajectories for systems with nonholonomic constraints. *IEEE Transactions on Automatic Control*. 1994. vol. 39. no. 1. pp. 216-222. doi:10.1109/9.273373.
26. Diveev A.I., Shmalko E.Yu., Serebrenny V.V., Zentay P. *Fundamentals of Synthesized Optimal Control*. *Mathematics*. 2021. vol. 9(21). pp. 1-18.

27. Malkin I.G. Teoriya ustoychivosti dvizheniya [Theory of motion stability.] Izd. 4. URSS. 2017. (In Russ.).
28. Diveev A., Shmalko E. Machine Learning Control by Symbolic Regression. Springer, Cham. 2021.
29. Duriez T., Brunton S.L., Noack B.R. Machine Learning Control – Taming Nonlinear Dynamics and Turbulence. Springer: Switzerland. 2017.
30. Deisenroth M.P., Faisal A.A., Ong C.S. Mathematics for Machine Learning. Cambridge: Cambridge University Press. 2020.
31. Burkov A. The Hundred-Page Machine Learning Book. 2019. 160 p.
32. Geron A. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems. Sebastopol: O'Reilly Media Inc., 2019. 856 p.
33. Diveev A.I., Shmalko E.Y. Machine-Made Synthesis of Stabilization System by Modified Cartesian Genetic Programming. IEEE Transactions on Cybernetics. 2022. vol. 52. no. 7. pp. 6627-6637.
34. Savchenko A.V. Probabilistic Neural Network With Complex Exponential Activation Functions in Image Recognition. IEEE Transactions on Neural Networks and Learning Systems. 2020. vol. 31. no. 2. pp. 651-660.
35. Zhang W., Wang J., Lan F. Dynamic hand gesture recognition based on short-term sampling neural networks . IEEE/CAA Journal of Automatica Sinica. 2021. vol. 8. no. 1. pp. 110-120.
36. Xiao J., Jia Y., Jiang X., Wang S. Circular Complex-Valued GMDH-Type Neural Network for Real-Valued Classification Problems. IEEE Transactions on Neural Networks and Learning Systems. 2020. vol. 31. no. 12. pp. 5285-5299.
37. Pelchat N., Gelowitz C.M. Neural Network Music Genre Classification. Canadian Journal of Electrical and Computer Engineering. 2020. vol. 43. no. 3. pp. 170-173.
38. Shmalko E., Diveev A. Control Synthesis as Machine Learning Control by Symbolic Regression Methods. Applied Sciences. 2021. vol. 11. p. 5468. doi: 10.3390/app11125468.
39. Diveev A.I. Hybrid evolutionary algorithm for solving the problem of optimal control. Voprosy teorii bezopasnosti i ustoychivosti sistem [Questions of the theory of safety and stability of systems]. 2021. vol. 23. p. 3-12. (In Russ.).
40. Diveev A.I., Konstantinov S.V. Study of the Practical Convergence of Evolutionary Algorithms for the Optimal Program Control of a Wheeled Robot. Izvestija RAN. Teorija i sistemy upravlenija – Journal of Computer and Systems Sciences International. 2018. vol. 57. no. 4. pp. 80-106.
41. Diveev A.I. Metod setevogo operatora [Network operator method]. M.: Izd-vo VTS RAN, 2010. (In Russ.).
42. Programmnyj paket rascheta znachenij upravljajushhih signalov po matrice setevogo operatora [Software package for calculating the values of control signals by the network operator matrix]. Available at: https://github.com/urock/network_operator. (accessed 26.11.2022). (In Russ.).

Shmalko Elizabeth — Ph.D., Senior researcher, Department of robotic control, Federal Research Center "Computer Science and Control" of the Russian Academy of Sciences (FRC CSC RAS); Associate professor, department of robotic systems and mechatronics, Bauman Moscow State Technical University (BMSTU). Research interests: modern computational methods in control of technical systems, symbolic regression methods and evolutionary computation with applications for identification, optimization and synthesis of control systems. The number of publications — 120. e.shmalko@gmail.com; 44/2, Vavilova St., 119333, Moscow, Russia; office phone: +7(964)636-6669.

С.В. ЕРЕМЕЕВ, А.В. АБАКУМОВ, Д.Е. АНДРИАНОВ, Т.А. ШИРАБАКИНА
**МЕТОД ВЕКТОРИЗАЦИИ СПУТНИКОВЫХ СНИМКОВ НА
ОСНОВЕ ИХ РАЗЛОЖЕНИЯ ПО ТОПОЛОГИЧЕСКИМ
ОСОБЕННОСТЯМ**

Еремеев С.В., Абакумов А.В., Андрианов Д.Е., Ширабакина Т.А. Метод векторизации спутниковых снимков на основе их разложения по топологическим особенностям.

Аннотация. Получение из растрового изображения объектов в векторном виде необходимо во многих сферах. Существующие методы векторизации спутниковых снимков не обеспечивают нужной точности автоматизации. В данной области требуется применять ручной труд, но объём поступающей информации зачастую превышает скорость обработки. Поэтому необходимы новые подходы для решения подобного рода задач. В статье предложен метод векторизации объектов на снимках с использованием разложения изображения на топологические особенности, который разбивает изображение на отдельные связанные структуры и при дальнейшей работе опирается уже на них. В результате уже на этом этапе изображение разбивается на древовидную структуру. Данный метод уникален по своему образу работы и в корне отличается от традиционных способов векторизации снимков. Большинство методов работает с помощью пороговой бинаризации, и основной задачей для них становится подбор порогового коэффициента. Главной проблемой в таком случае становится ситуация, когда на изображении имеется несколько объектов, для которых необходим разный порог. Метод отходит от непосредственной работы с яркостной характеристикой в сторону анализа топологической структуры каждого объекта. Предлагаемый метод имеет корректное математическое обоснование, в основе которого лежит алгебраическая топология. На основе метода разработана геоинформационная технология для автоматической векторизации растровых снимков с целью поиска находящихся на нем объектов. Тестирование проводилось на спутниковых снимках с разных масштабов. Разработанный метод сравнился со специальным инструментом для векторизации R2V и превзошел его по средней точности. Средний процент у автоматической векторизации предложенного метода составил 81%, а у полуавтоматического векторизирующего модуля R2V – 73%.

Ключевые слова: пространственные данные, разложение изображений, топологические особенности, векторизация.

1. Введение. Геоинформационные системы (ГИС) используют широкий набор различных пространственных данных, среди которых можно выделить растровые изображения, гиперспектральные снимки, векторные объекты, 3D облако точек, 3D поверхности. Для каждого типа пространственных объектов существуют свои методы для анализа и обработки данных. Модели местности в виде растровых изображений позволяют быстро получать актуальную информацию. Однако для компьютерного понимания расположения объектов требуется векторный формат. Кроме того, векторные объекты используют намного меньше компьютерной памяти для хранения объектов, что особенно актуально для передачи данных по сети.

В статье рассматривается задача векторизации пространственных объектов на спутниковых снимках. Под векторизацией понимается процесс перевода растровых изображений в векторный формат. Несмотря на то, что задача векторизации данных решается уже достаточно давно, до сих пор полностью эта задача не решена.

Выделим несколько особенностей, которые затрудняют решение задачи векторизации: насыщенность различных объектов городской инфраструктуры; наличие помех на изображении в виде тени объекта; перекрытие объектов другими объектами, такими как деревья, облака и т.д.

При векторизации пространственные объекты представляются в виде набора геометрических объектов: точки, отрезки, полигоны, сплайны. Рассмотрим подходы, использующие эти примитивы на растровом изображении.

Наиболее часто для решения этой задачи используют преобразование Хафа, основная суть которого заключается в описании прямой в виде выражения: $r = x \cos \theta + y \sin \theta$, где r – это длина нормали, проведенной из начала координат, к прямой, причем $r \geq 0$; θ – это угол между осью абсцисс и нормалью, при этом $\theta \in [0, 2\pi]$. Через каждую точку исходного изображения проводятся прямые с квантованными значениями θ и r . В двумерной таблице, состоящей из параметров θ и r , суммируется количество точек изображения, через которые можно провести прямые с этими параметрами. Локальные максимумы в этой таблице позволяют определить искомые отрезки.

В работе [1] показано использование преобразования Хафа для автоматизированной векторизации. Предварительно пользователь указывает места расположения зданий, имеющих прямоугольную форму. Проводится сегментация в этой области и далее поиск четырех отрезков, образующих здание.

С помощью преобразования Хафа можно выделить объекты произвольной формы, что характерно для пространственных данных на спутниковых снимках. Однако преобразование Хафа целесообразно использовать для объектов простой формы, т.к. для любой формы увеличивается количество параметров, что влечет увеличение вычислительных затрат и усложняет выделение необходимых объектов по этим параметрам. Кроме того, после преобразования Хафа могут образовываться разрывы ломаной линии. Поэтому в этом случае для множества точек на бинарном изображении можно применить

кусочно-линейную аппроксимацию, а также сплайны Безье. Сплайны Безье имеют достаточно простую реализацию, но при этом высокую ошибку соответствия требуемой линии.

В исследовании [2] показано выделение отрезков на изображении в градациях серого. Основу метода PLSD (Persistent Line Segment Detector) составляет использование персистентной гомологии. Сначала для каждой точки на изображении строятся 8 прямых линий с одинаковым углом между любой парой линий, проходящих через точку, по аналогии с преобразованием Хафа, но с меньшим количеством линий. Далее для каждой отдельно взятой линии L рассматриваются значения точек, лежащих на этой линии. Происходит переход от двумерной задачи поиска линий к одномерной. Каждая линия L представляет собой отдельный набор для анализа. Для множества точек на линии L применяется поиск связанных компонент на основе идей топологического анализа данных [3, 4]. Поиск компонент начинается с максимального уровня градации яркости и идет до минимального уровня. Выделяются устойчивые компоненты, которые поглощают другие позже появившиеся компоненты. Для каждого уровня яркости и для каждой линии L анализируются наиболее устойчивые компоненты с продолжительным периодом существования, имеющие наибольшую длину в пикселях, а также наибольший разрыв с соседними компонентами. Те компоненты, которые отвечают этим критериям, являются результатом в виде прямых отрезков.

Метод PLSD хорошо аппроксимирует сложные фигуры. При этом отрезки не пересекаются, что является одним из основных преимуществ метода. Однако, как и в случае с преобразованием Хафа между отдельными отрезками не предусмотрено топологических связей, из-за этого могут быть разрывы на ломаных линиях и полигональных объектах.

Для сохранения топологической согласованности между геометрическими примитивами в статье [5] разработан метод векторизации на основе двунаправленного градиента. Данный метод предназначен и хорошо работает для анализа чертежей с небольшим количеством объектов.

Очень популярным для выделения отрезков и контуров на изображении является алгоритм Канни. Зачастую на спутниковых снимках границы размыты и предпочтительно совместно использовать алгоритм Канни и нечетко-логические методы [6].

Для выделения отрезков на изображении также существуют следующие подходы: LSD [7], EDLines [8]. Недостатком первого

из них является большое количество пропущенных отрезков при увеличении размера изображений, а во втором случае появляется дублирование отрезков. Отметившие эти недостатки авторы статьи [9] решают обозначенную проблему для метода LSD путем разделения изображения на отдельные сегменты меньшего размера.

Отдельную группу составляют алгоритмы для получения контуров зданий в виде полигонов [10]. Для этого применяют волновой алгоритм [11, 12], гиперграфовое представление связанных компонент изображения с дальнейшей полигональной аппроксимацией [13], а также метод на основе триангуляции Делоне [14].

Метод осевых линий [15] предполагает скелетизацию растрового объекта путем его заполнения окружностями максимального радиуса. Центры окружностей соединяются отрезками и представляют собой скелет.

В работе [16] показаны следующие проблемы при автоматическом выделении контуров зданий на изображениях: очень часто контуры не содержат идеально прямых элементов; в одном месте могут сходиться сразу несколько контуров, относящихся к крышам зданий и другим посторонним объектам; границы крыш зданий порождают двойные или тройные контуры.

В отдельный класс методов выделяют подходы, которые используют следующие основные этапы: сегментация объектов, классификация объектов по набору признаков и непосредственно перевод классифицируемого объекта в векторный формат.

Для сегментации используют графовые методы, k-means, EM-алгоритм, алгоритм водораздела, суперпиксельная сегментация, текстурная сегментация по фрактальным характеристикам.

Для классификации применяются различные признаки, включающие статистические, геометрические, структурные, спектральные подходы [17]. Отдельно стоит выделить нейросетевые алгоритмы для классификации объектов [18, 19]: с использованием архитектуры U-Net [20, 21, 22], прогнозирование полигонов на основе сверточной сети графов GCN [23, 24]. В статье [25] каждому пикселю на здании присваивается значение насколько далеко этот пиксель стоит от границы. Если пиксель во внутренней части здания, то значение будет положительным, а иначе отрицательным. Полученные расстояния нормализуются от -1 до 1. После этого идет процесс обучения сверточной нейронной сети. Тем не менее, очень много зависит от правильно выбранного обучающего множества. Стоит использовать те изображения, которые обладают необходимыми свойствами и нужно опасаться значительного преобладания

конкретного свойства в тренировочном множестве, не должны преобладать пустые изображения или изображения, полностью заполненные строениями. Как показано в [26] после выделения зданий методом PPGNet требуется дополнительная постобработка. Кроме того, в сочетании с нейросетью используются дополнительные признаки в виде вейвлетов [27], разложение изображения на основе преобразования Гильберта-Хуанга [28].

Решение задачи векторизации объектов на растровых изображениях с учетом перечисленных особенностей требует поиск новых методов и подходов.

2. Цель исследования. Цель исследования заключается в разработке метода, который позволит распределить пространственные объекты на спутниковом снимке по разным слоям ГИС в векторном виде. Для достижения поставленной цели требуется выделить объекты интереса на изображении. Для этого предполагается использовать оригинальный подход для разложения изображения на топологические особенности. Предлагается две вариации метода: с использованием яркостного разложения изображения и яркостно-метрического.

На основе этого разложения ставится также задача классификации сегментированных областей интереса, т. к. полученные матрицы разложения представляют собой признаки для классификации. Распределенные по выбранным тематическим слоям сегментированные объекты планируется аппроксимировать для получения векторных данных.

3. Основная концепция

3.1. Яркостное разложение изображения по топологическим особенностям (Метод I). В качестве исходных данных будем рассматривать спутниковые снимки, представляющие собой растровые изображения. Эти изображения содержат набор пространственных объектов, подлежащих векторизации. Исходное изображение обозначим в виде матрицы $I = (p_{ij})_{m \times n}$, элементами которой являются пиксели в градациях серого со значениями от 0 до 255, m и n – размеры матрицы. В случае цветных изображений используется стандартный подход RGB (R – Red, G – Green, B – Blue), в котором пиксель описывается тройкой чисел (0..255, 0..255, 0..255).

В основе предлагаемой концепции лежит использование метода разложения изображения на матрицы специального типа: J_1, J_2, \dots, J_q , где q – количество матриц разложения. Теоретические основы

и перспективы практического использования этого метода изложены нами в работе [4].

Покажем основную суть метода и его дальнейшее развитие. Будем рассматривать компоненты, которые соответствуют набору точек на изображении. При анализе компонент возможны следующие ситуации, которые требуют отдельного рассмотрения (рисунок 1):

1. Одновременное появление сразу двух компонент (рисунок 1б).

Изображения рассматриваются слева направо и сверху вниз. Тем самым нумерация компонент идет в порядке их появления. В данном случае сначала появляется первая компонента, которую обозначим как J_1 , а затем вторая, обозначенная как J_2 . Причем J_2 содержит сразу две точки.

2. Присоединение точек к одной из компонент (рисунок 1в).

В примере пиксель со значением 3 присоединяется к компоненте J_2 . Для каждой текущей точки в качестве соседних рассматриваются четыре точки: слева, сверху, справа и снизу.

3. Поглощение одной компоненты другой (рисунок 1г).

Пиксель со значением 2 объединяет сразу две компоненты J_1 и J_2 . Приоритет при поглощении будет у компоненты J_2 т.к. у нее большее количество точек. В качестве критерия при поглощении также можно использовать более ранний порядковый номер компоненты.




Рис. 1. Возможные ситуации при работе с компонентами

Покажем численный пример формирования матриц разложения.

$$\text{Пусть дана матрица } I = \begin{bmatrix} 4 & 5 & 6 & 3 & 5 \\ 1 & 4 & 4 & 3 & 4 \\ 1 & 2 & 1 & 1 & 2 \\ 5 & 3 & 7 & 2 & 1 \\ 5 & 6 & 6 & 4 & 3 \end{bmatrix}.$$

Будем рассматривать сначала все такие точки, что $p_{ij} \geq 7$. Этому условию соответствует лишь одна точка. Будем считать, что появилась первая компонента J_1 .

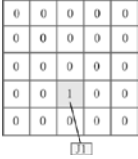
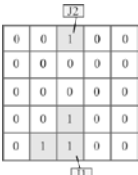

Далее перебираем все пороги $1 \leq T \leq 6$ и по аналогии получаем на каждом шаге бинарное изображение, состоящее из нулей и единиц. Матрицы J_1, J_2, \dots, J_q постепенно заполняются новыми значениями. Размеры каждой из этих матриц совпадают с размерами исходной матрицы. При этом проверяется следующее условие для каждого порога T в случае наращивания матрицы J :

$$b_{ij} = \begin{cases} b_{ij} + 1, & \text{если } a_{ij} = 1 \\ b_{ij}, & \text{иначе} \end{cases},$$

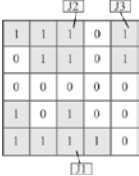
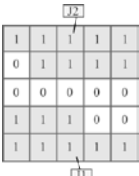
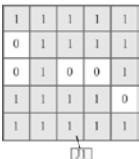
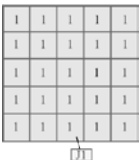
где b_{ij} – текущее значение матрицы J , a_{ij} – бинарная матрица для порога T .

В таблице 1 хорошо видно, что всего было образовано 3 матрицы: J_1 , J_2 и J_3 , начало формирования которых соответствует порогам 7, 6 и 5 соответственно. Кроме того, матрица J_2 поглощает J_3 на пороге 3, а J_1 поглощает J_2 на пороге 2. Критерием при поглощении в примере является более ранний порядковый номер компоненты.

Таблица 1. Формирование матриц разложения по Методу I

Порог T	Бинарное изображение	Итерационный процесс формирования матриц разложения
$T \geq 7$		$J_1 = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}.$
$T \geq 6$		$J_1 = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 2 & 0 & 0 \\ 0 & 1 & 1 & 0 & 0 \end{bmatrix}, J_2 = \begin{bmatrix} 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}.$
$T \geq 5$		$J_1 = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 3 & 0 & 0 \\ 1 & 2 & 2 & 0 & 0 \end{bmatrix}, J_2 = \begin{bmatrix} 0 & 1 & 2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix},$ $J_3 = \begin{bmatrix} 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}.$

Продолжение Таблицы 1

$T \geq 4$		$J_1 = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 2 & 0 & 4 & 0 & 0 \\ 2 & 3 & 3 & 1 & 0 \end{bmatrix}, J_2 = \begin{bmatrix} 1 & 2 & 3 & 0 & 0 \\ 0 & 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix},$ $J_3 = \begin{bmatrix} 0 & 0 & 0 & 0 & 2 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}.$
$T \geq 3$		$J_1 = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 3 & 1 & 5 & 0 & 0 \\ 3 & 4 & 4 & 2 & 1 \end{bmatrix}, J_2 = \begin{bmatrix} 2 & 3 & 4 & 1 & 1 \\ 0 & 2 & 2 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}.$
$T \geq 2$		$J_1 = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 1 & 1 \\ 0 & 1 & 0 & 0 & 1 \\ 4 & 2 & 6 & 1 & 0 \\ 4 & 5 & 5 & 3 & 2 \end{bmatrix}.$
$T \geq 1$		$J_1 = \begin{bmatrix} 2 & 2 & 2 & 2 & 2 \\ 1 & 2 & 2 & 2 & 2 \\ 1 & 2 & 1 & 1 & 2 \\ 5 & 3 & 7 & 2 & 1 \\ 5 & 6 & 6 & 4 & 3 \end{bmatrix}.$

В итоге будем иметь следующие матрицы:

$$J_1 = \begin{bmatrix} 2 & 2 & 2 & 2 & 2 \\ 1 & 2 & 2 & 2 & 2 \\ 1 & 2 & 1 & 1 & 2 \\ 5 & 3 & 7 & 2 & 1 \\ 5 & 6 & 6 & 4 & 3 \end{bmatrix}, J_2 = \begin{bmatrix} 2 & 3 & 4 & 1 & 1 \\ 0 & 2 & 2 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix},$$

$$J_3 = \begin{bmatrix} 0 & 0 & 0 & 0 & 2 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}. \quad (1)$$

Чтобы получить исходное изображение необходимо сложить эти матрицы:

$$I = J_1 + J_2 + J_3.$$

Теоретически каждая матрица соответствует определенному объекту интереса. Каждая из матриц, которая поглощает другую матрицу, обладает интересным свойством. Если некоторый объект высоты h положить на другой объект, то по рассматриваемому методу при разделении можно будет выделить этот объект с той же высотой h .

3.2. Яркостно-метрическое разложение изображения по топологическим признакам (Метод II). Рассмотрим теперь формирование J_1, J_2, \dots, J_q с использованием не только яркости, но и расстояния между пикселями. Под расстоянием между двумя пикселями будем понимать модуль разности между значениями соседних пикселей, т.е.:

$$d = |p_1 - p_2|,$$

где p_1, p_2 – два соседних пикселя. У каждого пикселя, как и в Методе I, может быть 4 соседа, т.е. рассматриваем только пиксели слева, сверху, справа и снизу от текущего.

Алгоритм формирования матриц при яркостно-метрическом разложении изображения по топологическим признакам состоит из следующих шагов:

Шаг 1. Рассчитывается список расстояний между соседними пикселями. Общее количество таких расстояний для изображения размером $m \times n$ равно $n(m-1) + m(n-1)$. По сути, получаем граф, где вершинами являются пиксели, а ребрами – расстояния между ними.

Шаг 2. Сортируется список расстояний по возрастанию значений.

Шаг 3. Сначала на исходном изображении I выделяются в компоненты все точки, расстояния между которыми $d \leq 0$, т.е. в группы объединяются точки одного цвета со значением 0. В этом случае исходное изображение не изменяется. Оно будет изменяться для параметра $d > 0$.

Шаг 4. На втором и следующих этапах объединяются компоненты, расстояние между которыми не больше d ($d = 1, 2, \dots, 255$). При поглощении компонентой других компонент их точки становятся цветом поглощающей компоненты. Очевидно, что расстояния между компонентами будут изменяться, т.к. меняется цвет компонент. В этом случае необходимо произвести перерасчет расстояний между компонентами, изменяя при этом и поддерживая в актуальном состоянии сортированный список расстояний. При каждом следующем шаге d анализируется текущее изображение с измененными значениями, после чего выбираются из списка расстояний обновленные связи между компонентами.

Шаг 5. Для каждого d ($d = 0, 1, 2, \dots, 255$) получаем изображение $I_{\leq d}$, которое является исходным для разложения по Методу I из пункта 3.1. Тем самым, для каждого d получим свой набор матриц разложения.

Покажем сказанное на примере (рисунок 2).

На рисунке 2 в левом столбце показан итерационный процесс формирования исходных изображений для их дальнейшего разложения по яркости. В первой строке разложение ничем не отличается от рассматриваемого выше по Методу I, т.к. исходное изображение не меняет значения точек. Для $d \leq 1$, $d \leq 2$ и $d \leq 3$ исходное изображение изменяется за счет слияния компонент, между которыми расстояние не больше d .

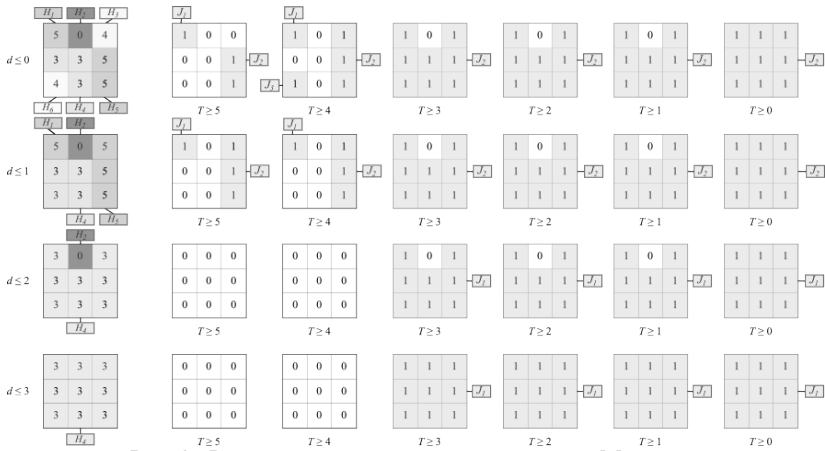


Рис. 2. Формирование матриц разложения по Методу II

В итоге для каждого значения d получим свой набор матриц разложения, а именно:

$$\text{для } d \leq 0: J_1 = \begin{bmatrix} 2 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}, J_2 = \begin{bmatrix} 4 & 1 & 5 \\ 4 & 4 & 6 \\ 4 & 4 & 6 \end{bmatrix}, J_3 = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 1 & 0 & 0 \end{bmatrix};$$

$$\text{для } d \leq 1: J_1 = \begin{bmatrix} 2 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}, J_2 = \begin{bmatrix} 4 & 1 & 6 \\ 4 & 4 & 6 \\ 4 & 4 & 6 \end{bmatrix};$$

$$\text{для } d \leq 2: J_1 = \begin{bmatrix} 4 & 1 & 4 \\ 4 & 4 & 4 \\ 4 & 4 & 4 \end{bmatrix};$$

$$\text{для } d \leq 3: J_1 = \begin{bmatrix} 4 & 4 & 4 \\ 4 & 4 & 4 \\ 4 & 4 & 4 \end{bmatrix}.$$

Заметим, что при увеличении d исходное изображение становится более однотонным, что, в свою очередь, влияет на количество и структуру матриц разложения для каждого d .

При поглощении матриц здесь мы используем такой критерий, что при слиянии двух компонент приоритет на продолжение существования получает та компонента, которая имеет большее количество точек. Такой подход позволяет отслеживать более крупные по площади объекты.

Отличительной особенностью Метода II является формирование дополнительных матриц H_1, H_2, \dots, H_f . Они формируются по тому же самому принципу, что и матрицы J_1, J_2, \dots, J_q , но имеют характерную для себя структуру. В качестве изменяемого параметра используется не порог T , а расстояние d между компонентами. Каждая матрица H_k соответствует компоненте, которая была создана на первом этапе при $d \leq 0$. Значение ячейки в H_k показывает, сколько этапов d существовала эта компонента с номером k в этой ячейке, т.е. сколько сохранялся этот цвет в каждой ячейке.

Более устойчивые компоненты имеют достаточно большую наполняемость ячеек без нулевых элементов. Именно эти матрицы представляют особый интерес для анализа. Для примера из рисунка 2 матрицы H_1, H_2, \dots, H_6 имеют следующий вид:

$$H_1 = \begin{bmatrix} 2 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}, H_2 = \begin{bmatrix} 0 & 3 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}, H_3 = \begin{bmatrix} 0 & 0 & 1 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix},$$

$$H_4 = \begin{bmatrix} 2 & 1 & 2 \\ 4 & 4 & 2 \\ 3 & 4 & 2 \end{bmatrix}, H_5 = \begin{bmatrix} 0 & 0 & 1 \\ 0 & 0 & 2 \\ 0 & 0 & 2 \end{bmatrix}, H_6 = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 1 & 0 & 0 \end{bmatrix}.$$

3.3. Особенности представления объектов городской инфраструктуры. Городские объекты имеют вложенную структуру. Например, город состоит из кварталов, разделенных улицами, квартал включает домовые территории, каждая территория содержит объекты на ней. Если рассматривать более детально, то каждый объект включает в себя более мелкие объекты, например, трубы на зданиях.

Это соответствует стандартам детализации в геоинформатике, а также при 3D моделировании с большим количеством деталей.

Для объектов городской инфраструктуры будем применять концепцию из разделов 3.1. и 3.2. для описания вложенных элементов. При разложении изображения на матрицы получим объекты в виде областей интереса.

Матрицы разложения можно объединить по разным критериям. Это позволит выделить в отдельные слои объекты со схожей структурой, например, слои дорог, домов и деталей на этих домах.

Таким образом, иерархическая структура городских объектов хорошо сочетается с концепцией метода разложения по топологическим признакам. Однако существуют определенные проблемы, связанные с плавным переходом градиента на изображении. Для преодоления подобных проблем предлагается алгоритм для сегментации изображений по матрицам разложения.

4. Методология

4.1. Сегментация изображения на основе предлагаемой концепции. После разложения исходного изображения I на матрицы J_1, J_2, \dots, J_q либо по Методу I, либо по Методу II необходимо провести анализ этих матриц. Новое изображение I' формируется следующим образом. Для каждого пикселя в $I' = (p'_{ij})_{m \times n}$ вычисляется максимальное значение в соответствующей ячейке среди всех матриц J_1, J_2, \dots, J_q , т.е.:

$$I' = \begin{bmatrix} \max b_{11}^k & \max b_{12}^k & \dots & \max b_{1n}^k \\ \max b_{21}^k & \max b_{22}^k & \dots & \max b_{2n}^k \\ \dots & \dots & \dots & \dots \\ \max b_{m1}^k & \max b_{m2}^k & \dots & \max b_{mn}^k \end{bmatrix} \quad (k = 1, 2, \dots, q), \quad (2)$$

где b_{ij}^k ($i = 1, 2, \dots, m; j = 1, 2, \dots, n$) – значение элемента матрицы J_k .

Если рассмотреть полученные матрицы (1), то:

$$I' = \begin{bmatrix} 2 & 3 & 4 & 2 & 2 \\ 1 & 2 & 2 & 2 & 2 \\ 1 & 2 & 1 & 1 & 2 \\ 5 & 3 & 7 & 2 & 1 \\ 5 & 6 & 6 & 4 & 3 \end{bmatrix}.$$

В этом примере три нижние строки полностью совпадают с исходным изображением I и являются частью самой большой компоненты J_1 . Вызывает интерес анализ первых двух строк. Большинство пикселей имеют значение 2, и на этом фоне выделяется пара пикселей в первой строке со значением 3 и 4, которые соответствуют некоторому бугорку на исходном изображении.

Рассмотрим две компонента A и B в вертикальном разрезе изображения. Пусть компонента A поглощает компоненту B . Схематично покажем это на рисунках 3 и 4.

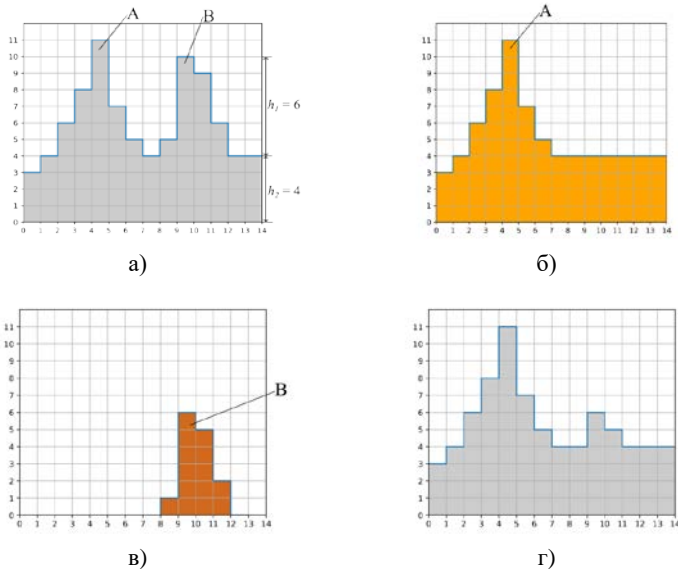


Рис. 3. Формирование изображения I' при $h_1 \geq h_2$: а) исходный вертикальный разрез изображения; б) выделение компоненты A ; в) выделение компоненты B ; г) результирующий вертикальный разрез изображения

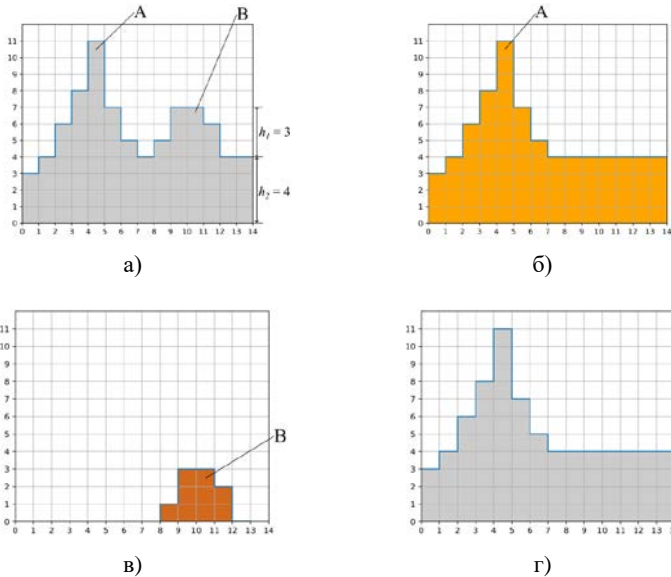


Рис. 4. Формирование изображения I' при $h_1 < h_2$: а) исходный вертикальный разрез изображения; б) выделение компоненты A ; в) выделение компоненты B ; г) результирующий вертикальный разрез изображения

Рассмотрим возможные случаи формирования нового расположения компонент в зависимости от значений h_1 и h_2 , используя формулу (2):

1. $h_1 \geq h_2$. В этом случае в p_{ij} изначально было значение $h_1 + h_2$, где h_2 – это значение, при котором компонента A поглощает B , h_1 – это период существования компоненты B . После применения формулы (2) новым значением в этой точке будет h_1 .

2. $h_1 < h_2$. Новым значением для точки p'_{ij} будет h_2 , т.е. цвет фона.

Заметим из рисунка 4, что не только максимальная точка B принимает значение фона, но и все точки этой компоненты. Т.е. в новом изображении I' та область, которая соответствует значениям B , полностью принимает значение h_2 , т.е.:

$$p'_{ij} = h_2, \quad \text{если } (i, j) \in \text{координаты}(B).$$

Заметим теперь, что можно найти яркость g , на которой главная компонента будет всех включать в себя. Если $g \geq 128$, то по формуле (2) получим главную компоненту и фон g на всем изображении, т.к. высота каждой компоненты будет заведомо меньше, т.е. $h_1 \leq 127$.

Таким образом, можно сделать следующий вывод, что для отделения объектов друг от друга в рамках одной матрицы имеет смысл производить анализ не всех значений, а только эксклюзивных (т.е. за исключением поглощенных компонент) или инклюзивных (только поглощенных). Это может дать более точное определение поглощенного объекта и его контура.

4.2. Классификация пространственных объектов по топологическим признакам матриц разложения. Для классификации пространственных объектов также будем использовать матрицы разложения по топологическим особенностям. Для этого воспользуемся такими признаками, как баркоды.

Баркод определяется как множество пар значений из начала появления $birth_k$ компонент и их длин len_k :

$$Barcode = \left\{ (birth_k, len_k)_{k=1}^q \right\}. \quad (3)$$

Покажем, как можно получить баркодную характеристику из матриц разложения.

Пусть матрица разложения J_k состоит из элементов b_{ij}^k ($i = 1, 2, \dots, m; j = 1, 2, \dots, n; k \in \{1, 2, \dots, q\}$). Длина существования компоненты будет рассчитываться как максимальный элемент среди b_{ij}^k :

$$len_k = \max(b_{ij}^k). \quad (4)$$

Для того чтобы определить начало появления компоненты потребуется информация о вложенной структуре компонент, представленной в виде графа:

$$G = (V, E),$$

где V – множество компонент, E – множество ребер, обозначающих связи между компонентами.

После этого необходимо найти максимальное значение в матрице рассматриваемой компоненты J_k , которое находится в координатах (i_0, j_0) , и прибавить значения во всех вышестоящих родительских матрицах в ячейке с такими же координатами (i_0, j_0) :

$$birth_k = \begin{cases} \max(b_{ij}^k), & \text{если } J_k \text{ является корнем дерева} \\ \max(b_{ij}^k) + \sum_{u \in U} b_{i_0, j_0}^u, & \text{иначе} \end{cases}, \quad (5)$$

где U – множество всех индексов тех компонент, которые расположены выше компоненты J_k в графе G .

На основе выражений (4, 5) выразим баркод через свойства матриц разложения J_1, J_2, \dots, J_q :

$$Barcode = \left\{ \left(\max(b_{ij}^k) + \sum_{u \in U} b_{i_0, j_0}^u, \max(b_{ij}^k) \right)_{k=1}^n \right\}. \quad (6)$$

$(i = 1, 2, \dots, m; j = 1, 2, \dots, n).$

Для примера из таблицы 1 баркод будет состоять из матриц J_1, J_2, J_3 (1) и графически будет иметь вид (рисунок 5):




Рис. 5. Графическое отображение баркода для матриц разложения (1)

На рисунке 5 для каждой матрицы жирным шрифтом выделен максимальный элемент с координатами (i_0, j_0) , а в выделенных прямоугольником клетках показаны соответствующие ячейки в родительских матрицах на основе информации из вложенной структуры компонент. Эти значения позволяют вычислить начало появления каждой из компонент. Для примера имеем: $birth_1 = 7$, т.к. J_1 является корнем дерева, и поэтому находим только максимальный элемент в матрице этой компоненты, $birth_2 = 4 + 2 = 6$ и $birth_3 = 2 + 1 + 2 = 5$.

Такую характеристику будем использовать для классификации текстур пространственных объектов. Неплохие результаты в этом направлении нами были получены при исследовании топологических признаков для классификации объектов на изображениях с учетом их деформации и в сравнении с нейросетевыми подходами [29, 30].

Алгоритм классификации с использованием матриц разложения будет состоять из следующих шагов:

Шаг 1. Разложить исходное изображение I на матрицы J_1, J_2, \dots, J_q .

Шаг 2. Произвести сегментацию изображения на объекты интереса по алгоритму из п.4.1.


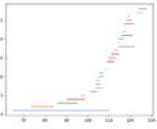

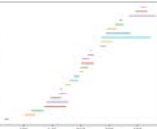

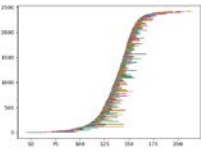
Шаг 3. Построить баркодную характеристику $Barcode_1, Barcode_2, \dots, Barcode_k$ для каждого объекта интереса. Заметим, что объект интереса может включать в себя не только одну, а несколько матриц разложения, образуя иерархическую структуру, т.е. $J = \{J_{\alpha_1}, J_{\alpha_2}, \dots, J_{\alpha_k}, \dots, J_{\alpha_q}\}$, где α_k – это номер матрицы разложения.

С учетом этого, совокупность объектов интереса разделяется на непересекающееся множество матриц из J_1, J_2, \dots, J_q . Они рассчитываются один раз и далее используются для анализа.

Шаг 4. Отнесение объекта интереса к определенному классу. Для этого заранее подготавливается набор шаблонов из пространственных объектов, соответствующих некоторому классу. Для каждого из них рассчитывается баркодная характеристика. Далее происходит сравнение баркодов путем наложения друг на друга и находится наиболее близкий класс, т.е. сравнение происходит в пространстве топологических признаков.

В качестве примера покажем баркоды нескольких пространственных объектов (таблица 2):

Таблица 2. Примеры пространственных объектов и их баркоды

Номер	Тип объекта	Изображение	Баркод
1	Односкатная крыша		
2	Двускатная крыша		
3	Дорога		

4.3. Геоинформационная технология для получения векторного изображения. Выше показано, что метод базируется на присоединении соседних точек, поэтому важно, чтобы в рамках одного объекта эмпирия стремилась к минимуму. В связи с этим, а также для подавления потенциальных шумов и искажений, в качестве предобработки проводится размытие по Гауссу.

Принцип векторизации с учетом баркодов исходит от утверждения, что каждая компонента поглощает конкретный объект на изображении, поэтому на первом этапе следует провести некий отбор, убрав наиболее неподходящие элементы.

Стоит заметить, что в случае обработки городских улиц следует использовать построение баркодов по расстоянию (Метод II). В случае простых изображений без лишних объектов можно применять более быструю обработку по яркости (Метод I).

Эксперименты показали, что после формирования баркода подавляющее большинство отрезков являются шумовыми, как, например, показано на рисунке 6. Также наиболее продолжительные компоненты могут образовывать большие зоны, которые покрывают почти все изображение, но не несут топологического смысла. В итоге получается следующее условие отбора:

$$N_{\min} < size < N_{\max} ,$$

где N_{\min} – минимально установленный процент размера компоненты относительно размера изображения, N_{\max} – максимально установленный процент размера компоненты относительно размера изображения, $size$ – размер компоненты относительно размера входного изображения.

Помимо геометрических параметров отбора присутствуют и топологические. В частности, имеет смысл ввести ограничение по трем характеристикам: глубина компоненты, время существования и время появления. Например, на космоснимках присутствуют тени, но путем установки начала появления компоненты их легко можно отсечь.




Рис. 6. Формирование компонент: а) исходное изображение, взятое по координатам * 55.794857, 37.497917 с увеличением 16^{\dagger} ; б) визуализация компонент

Второй этап предполагает использование баркодowego классификатора. Подробнее про технологию написано в [30]. Входной баркод сравнивается с набором эталонов, и выбирается тот класс, где соответствие выше. Таким образом, можно классифицировать не только спутниковые снимки, но и вообще любые объекты с разной топологией.

Для примера наглядно покажем процесс классификации, начиная с рисунка 7. После фильтрации получаем компоненты, показанные белым цветом.

* Здесь и в дальнейшем используется система координат WGS84 (EPSG:3857)

† Увеличение рассчитывается согласно формулам OpenStreetMap (https://wiki.openstreetmap.org/wiki/Zoom_levels)



Рис. 7. Все найденные компоненты, прошедшие отбор с параметрами size [0.0015, 10], minStart = 15, minLen = 10. Размер ядра размытия по Гауссу – 3^{\ddagger} . Параметры: size – диапазон размера относительно исходного изображения, т.е. площадь объекта должна быть от 0.0015% до 10% от площади всего изображения; minStart – минимальное значение начала существования компоненты, значение 15 позволяет отсеять тень; minLen – минимальная длина компоненты

Для классификации используем 3 класса: здания с двускатными и односкатными крышами, а также прочие объекты. После добавления одной компоненты получается результат, показанный на рисунке 8.




Рис. 8. Выделение зданий с двускатными крышами: а) после добавления обведенной компоненты; б) результат с отображением только классифицированных объектов

[‡] Все дальнейшие эксперименты проводились с аналогичными параметрами

Как видно, всего один эталон позволил выделить почти все двускатные крыши. Топологически дорога оказалась похожа на выбранный объект, поэтому добавим ее к прочим объектам, а также один дом с односкатной крышей к своему классу. Результат показан на рисунке 9.

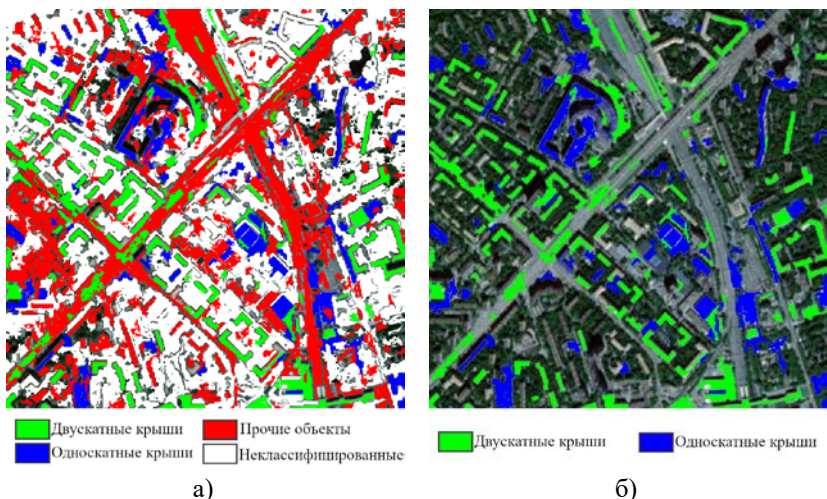


Рис. 9. Классификация на различные типы объектов: а) отображение зданий с двускатными и односкатными крышами, а также прочих объектов; б) отображение только классов крыш

Дальнейшее добавление эталонов позволит полностью выделить и векторизовать нужные объекты, и при этом готовый классификатор будет работать на всех схожих по топологии изображениях. С учетом малого размера обучающей выборки это является огромным плюсом по сравнению с другими возможными подходами.

Отобранные баркоды хранят в себе набор пикселей. Их контур можно найти с помощью алгоритма жука. Сначала определяется начальная точка. Она может быть любой, главное, чтобы находилась на краю объекта. В реализованном алгоритме берется самая верхняя справа. Затем происходит процесс обхода: жук проверяет сначала левый пиксель, потом угловой слева, передний, угловой правый и правый. Потом перемещается на первый найденный пиксель. Таким образом, он все время поворачивает налево, совершая обход. Если же пиксель не найден, то есть жук зашел в тупик, то он возвращается, пометая пиксель как неликвидный. Процесс заканчивается, когда алгоритм вернется в начальную точку.

При формировании контура есть возможность его аппроксимировать путем сохранения только ключевых (угловых) точек. Например, у квадрата таких точек будет только 4. Определяются они путем проверки направлений: если жук повернул, то предыдущая точка – ключевая. Существуют и более продвинутые алгоритмы. Одним из них является алгоритм контурной аппроксимации Teh-Chin [31], который используется в библиотеке OpenCV для обработки изображений. Не смотря на это, в работе применяется простая аппроксимация отрезков, чтобы не создавать дополнительный фактор при оценке численных результатов найденных объектов. После получения первичного векторного представления объектов коррекция их формы в большинстве случаев реализуется вручную.

Зная координаты и проекцию (EPSG:3857), можно перевести пиксели контура в полигон и экспортировать его для последующей работы с ним в ГИС. Пример экспорта двух слоев показан на рисунке 10.

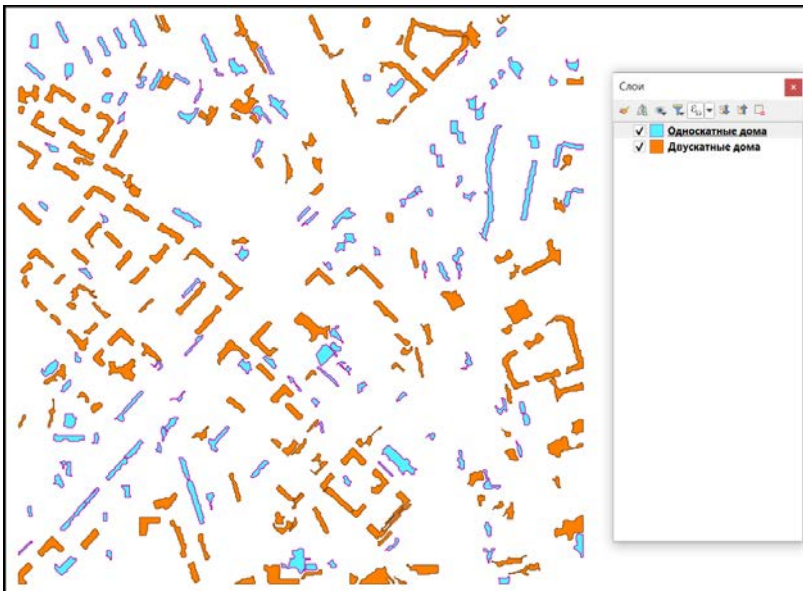


Рис. 10. Выходные данные, отображённые в ГИС QGIS

Общая схема предложенной геоинформационной технологии представлена на рисунке 11. Основными шагами являются: загрузка

спутникового снимка, вычисление и фильтрация матриц разложения, классификация объектов, а также выгрузка полученных векторных данных в geojson файл для чтения ГИС-программами.



Рис. 11. Общая схема геоинформационной технологии для векторизации областей интереса на спутниковом снимке с помощью матриц разложения. Пунктиром показаны шаги, выполняемые программой в фоновом режиме

5. Результаты экспериментальных исследований. Для оценки точности использовался классификатор с 80 эталонами и 3 классами: дома с односкатными крышами, двускатными, прочие объекты. Для оценки использовались только здания. Параметры были такие же, как и при обработке изображения 6. Также необходимо было подобрать аналог и провести аналогичную проверку на нем.

В последнее время многие статьи, решающие подобную задачу, основаны на использовании нейронных сетей с большими обучающими выборками. Вместо них было решено подобрать разработку, которая решала бы задачу векторизации максимально схожим образом с предлагаемым подходом. Таковым является инструмент Able R2V, способный работать с двумерными и трехмерными данными и векторизовать спутниковые снимки.

С помощью модуля на языке Python были получены векторные спутниковые снимки по координатам и их векторные слои. По вторым построена маска зданий для оценки точности. Для этого сначала на маске выделялись контуры всех зданий. Затем каждый базовый контур сравнивался с получившимся в результате тестирования. Векторизация для отдельного строения считалась успешной, если при наложении контур совпадал минимум на 85%. Это сделано, во-первых, чтобы нивелировать возможные расхождения между растром и вектором, а во-вторых, потому что поперечная зона может быть спорной.

При успешном выделении здания к счетчику добавляется единица, умноженная на отношение площади этого здания к сумме всех площадей – чем больше здание, тем больше вклада в результат.

После сравнения из итогового показателя вычитается отношение суммы всех лишних ложных полигонов к площади снимка.

Результаты проверки приведены в таблице 3. Исходные изображения показаны на рисунке 12.

Можно представить и более обширную выборку, однако, это имеет мало смысла, так как топологически схожие объекты останутся схожими вне зависимости от смежных данных.

Таблица 3. Результаты тестирования для оценки точности векторизации объектов на снимках

Номер изображения	Долгота	Широта	Предложенный метод, точность, %	R2V, точность, %
1	37,613656	127,019822	82	67
2	47,917771	106,902695	81	59
3	53,210474	50,224138	78	75
4	53,229711	50,275348	74	73
5	55,740047	37,632779	87	60
6	55,78629	37,573403	78	72
7	55,813148	37,570192	71	75
8	55,824066	37,58251	69	72
9	55,610299	37,705359	83	71
10	56,138963	40,39506	77	76
11	56,144008	40,423329	84	74
12	56,172059	40,482485	90	79
13	56,126108	40,357699	89	73
14	55,781155	37,474521	82	75
15	55,777904	37,495079	76	77
16	55,781020	37,518276	92	75
17	55,780875	37,551987	73	67
18	55,817086	37,591099	86	80
19	55,823973	37,564358	75	73
20	55,834031	37,56841	86	84
Итого			81	73



Рис. 12. Тестовые изображения (нумерация построчная слева направо)

Единственное, что может негативно повлиять на результат, это ложные срабатывания у объектов со схожей топологией, об этом и говорит средний результат в 81%. Наихудший процент (61) был получен на изображении № 8. Его обработанный результат показан на рисунке 13.




Рис. 13. Результаты классификации изображения №8: а) предложенный метод; б) R2V

Для баркодов проблемы вызывают два фактора: во-первых, если посмотреть на дома слева, то можно увидеть ребра, из-за которых отдельные компоненты не соединяются, и не образуется общего баркода крыши. Вторая – у дорог и некоторых других поверхностей схожий баркод с представленными эталонами. Поэтому следует использовать дополнительные топологические параметры при сравнении.

Программа R2V ориентируется на цвет, после векторизации использовалась фильтрация слишком маленьких объектов. Как видно, неровная текстура некоторых зданий не позволила получить цельные контуры, вместо этого алгоритм выявил множество отдельных полигонов, которые отсеялись. Также заметно несколько ложных срабатываний из-за того, что эти области имеют схожий с объектами цвет и топологию.

Одним из наилучших результатов у предложенного метода (90%) был получен на снимке №12 и отражен на рисунке 14. Почти все здания на исходном изображении четко выделены и не сливаются с фоном, что позволяет получить точный баркод. Хотя, стоит заметить, кусочек дороги ошибочно классифицировался как крыша. Такая же картина прослеживается и на снимках 16 (92%) и 13 (89%).

Аналог также хорошо показал себя, однако некоторые здания остались невыделенными. У него остаются все те же проблемы с ликвидным цветом и параметрами фильтрации, что были описаны выше.

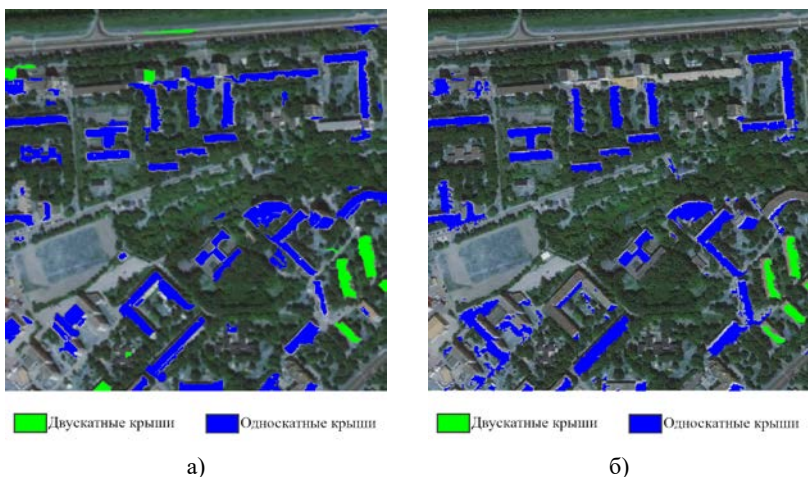


Рис. 14. Результаты классификации изображения №12: а) предложенный метод; б) R2V

Сравнение показало, что баркоды, строясь по яркости, почти от нее не зависят, что доказывает состоятельность теории как базы для совершенно нового подхода сегментации изображений.

Что касается результатов сравнения, то, безусловно, можно добиться и среднего показателя в 90%, однако это затруднено из-за пока вышеупомянутых проблем, а также еще одного фактора: деградации скорости выполнения при увеличении эталонов (в том числе для решения этой проблемы и была проведена начальная фильтрация).

Отдельно следует сказать про затрачиваемое время на работу. У программ, подобных R2V, при анализе каждого снимка требуется вручную задать пороги бинаризации, по обстоятельствам выбрать алгоритм фильтрации, а потом кропотливо выравнять полигоны, тогда как предлагаемая разработка лишена первых двух требований и частично третьего. Использование матриц разложения позволяет получить более точные выходные полигоны, что делает работу продуктивнее.

6. Заключение. В статье разработан метод для получения из спутниковых снимков векторных данных, распределенных по разным слоям ГИС. Предложенный метод включает комплексное решение для векторизации пространственных объектов и содержит основные этапы в виде сегментации, классификации и аппроксимации областей интереса на изображении. Основная часть методологии базируется на

предложенной концепции разложения растрового изображения по топологическим особенностям.

На основе концепции разработан алгоритм сегментации, который позволяет выделить объекты интереса с устойчивыми топологическими признаками и избежать настраивания порога бинаризации, что свойственно многим методам. Разложение изображения позволяет также получить в качестве признаков матрицы специального типа для классификации сегментированных объектов. Выбрано несколько типов зданий для их классификации и дальнейшего распределения по слоям в векторном виде.

Проведенные эксперименты реальных данных показали высокие результаты (81% в режиме автоматической векторизации против 73% у полуавтоматического аналога). В качестве ГИС, в которую загружались обработанные данные в векторном виде, использованы инструменты QGIS, что позволяет интегрировать данные с существующей ГИС организации. При практическом использовании предложенного метода планируется расширить тематические слои, что даст возможность ускорить процесс перевода спутниковых снимков в векторный формат.

Представлен совершенно новый тип just-in-time классификатора, который работает с малым числом эталонов и выдает достойный результат. Сама разработка и тестовые данные доступны по ссылке: <https://github.com/Noremos/SatelliteVectorization>.

Литература

1. Miroshnichenko S.Yu., Titov V.S., Dremov E.N., Mosin S.A. Hough Transform Application to Digitize Rectangular Spatial Objects on Aerospace Imagery // *Trudy SPIIRAN*. 2018. vol. 61. pp. 172–196.
2. Kurlin V., Muszynski G. A Persistence-Based Approach to Automatic Detection of Line Segments in Images // *Proc. CTIC: Comp. Topology in Image Context*. 2019. pp. 137–150.
3. Edelsbrunner H., Harer J. *Computational topology. An introduction*. 2010.
4. Еремеев С.В., Абакумов А.В., Андрианов Д.Е., Титов Д.В. Метод разложения изображения по топологическим признакам // *Компьютерная оптика*. 2022. Т. 46. № 6. С. 939–947.
5. Bessmeltsev M., Solomon J. Vectorization of Line Drawings via Polyvector Fields // *ACM Transactions on Graphics*. 2019. vol. 38. no. 1. pp. 1–12.
6. Бобырь М.В., Архипов А.Е., Горбачев С.В., Цао Ц., Бхаттачарья С. Нечеткологические методы в задаче детектирования границ объектов // *Информатика и автоматизация*. 2022. Т. 21. № 2. С. 376–404.
7. Von Gioi R.G., Jakubowicz J., Morel J.M., Randall G. LSD: A Fast Line Segment Detector with a False Detection Control // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2010. vol. 32. no. 4. pp. 722–732.
8. Akinlar C., Topal C. Edlines: A Real-Time Line Segment Detector with a False Detection Control // *Pattern Recognition Letters*. 2011. vol. 32. no. 13. pp. 1633–1642.

9. Новоторцев Л.В., Волобой А.Г. Обнаружение и трехмерная реконструкция строений по аэрофотоснимкам // Программирование. 2019. № 6. С. 13–22.
10. Чернов А.В., Чушнев Н.В. Автоматическое распознавание контуров зданий на картографических изображениях // Компьютерная оптика. 2007. Т. 31. № 4. С. 101–103.
11. Кудряшов А.П., Соловьёв И.В. Выделение объектов на топографическом плане для реконструкции сцены городского пространства // Программная инженерия. 2019. Т. 10. № 11–12. С. 464–470.
12. Москаленко С.В., Гатчин Ю.А. Помехоустойчивый волновой алгоритм векторизации линейных растровых объектов // Вестник компьютерных и информационных технологий. 2009. № 5. С. 16–21.
13. Стержанов М.В. Быстрый алгоритм векторизации бинарных штриховых изображений // Доклады БГУИР. 2010. Т. 50. № 4. С. 88–94.
14. Костюк Ю.Л., Кон А.Б., Новиков Ю.Л. Алгоритмы векторизации цветных растровых изображений на основе триангуляции и их реализация // Вестник Томского Государственного Университета. 2003. № 280. С. 275–280.
15. Местецкий Л.М. Скелетизация многосвязной многоугольной фигуры на основе дерева смежности ее границы // Сибирский журнал вычислительной математики. 2006. Т. 9. № 3. С. 299–314.
16. Залесский Б.А. Комбинаторный алгоритм выделения контуров объектов на цифровых изображениях // Информатика. 2013. № 3. С. 13–20.
17. Фраленко В.П. Методы текстурного анализа изображений, обработка данных дистанционного зондирования Земли // Программные системы: теория и приложения. 2014. Т. 5. № 4. С. 19–39.
18. Бычков И.В., Ружников Г.М., Федоров Р.К., Попова А.К., Авраменко Ю.В. Классификация космоснимков Sentinel-2 Байкальской природной территории // Компьютерная оптика. 2022. Т. 46. № 1. С. 90–96.
19. Yan K., Xu Y., Chen H. Building Boundary Vectorization from Satellite Images Using Generative Adversarial Networks // The International Conference on Image, Vision and Intelligent Systems (ICIVIS 2021). Lecture Notes in Electrical Engineering, 2022. vol. 813. pp. 671–678.
20. Alsabhan W., Alotaiby T., Dudin B. Detecting Buildings and Nonbuildings from Satellite Images Using U-Net // Computational Intelligence and Neuroscience. 2022. vol. 2022.
21. Temenos A., Temenos N., Doulamis A., Doulamis N. On the Exploration of Automatic Building Extraction from RGB Satellite Images Using Deep Learning Architectures Based on U-Net // Technologies. 2022. vol. 10.
22. Guo M, Liu H, Xu Y, Huang Y. Building Extraction Based on U-Net with an Attention Block and Multiple Losses // Remote Sensing. 2020. vol. 12. no. 9.
23. Wei S., Ji S. Graph Convolutional Networks for the Automated Production of Building Vector Maps From Aerial Images // IEEE Transactions on Geoscience and Remote Sensing. 2022. vol. 60. pp. 1–11.
24. Xu Y., Jin S., Chen Z., Xie X., Hu S., Xie Z. Application of a Graph Convolutional Network with Visual and Semantic Features to Classify Urban Scenes // International Journal of Geographical Information Science. 2022. vol. 36. pp. 1–26.
25. Chartock E., LaRow W., Singh V. Extraction of Building Footprints from Satellite Imagery // Stanford University Report. 2017.
26. Hensel S., Goebels S., Kada M. Building Roof Vectorization with PPGNET // The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. XLVI-4/W4-2021. 2021. pp. 85–90.
27. Форгуна-Сервантес Х.М., Рамирес-Торрес М.Т., Мартинес-Карранса Х., Мургуя-Ибарра Х.С., Мехия-Карлос М. Обнаружение объектов в

- аэронавигации с использованием вейвлет-преобразования и сверточных нейронных сетей: первый подход // Труды института системного программирования РАН. 2021. Т. 33. № 2. С. 149–162.
28. Нежевенко Е.С., Феоктистов А.С., Дашевский О.Ю. Нейросетевая классификация гиперспектральных изображений на основе преобразования Гильберта – Хуанга // Автометрия. 2017. Т. 53. № 2. С. 79–85.
 29. Еремеев С.В., Абакумов А.В. Программный комплекс для обнаружения и классификации природных объектов на основе топологического анализа // Программные продукты и системы. 2021. Т. 34. № 1. С. 201–208.
 30. Еремеев С.В., Абакумов А.В. Классификация объектов на изображениях с учетом искажений на основе двухэтапного топологического анализа // Научно-технический вестник информационных технологий, механики и оптики. 2022. Т. 22. № 1. С. 82–92.
 31. Teh C.-H., Chin R.T. On the detection of dominant points on digital curves // IEEE Transactions on Pattern Analysis and Machine Intelligence. 1989. vol. 11. no. 8. pp. 859–872.

Еремеев Сергей Владимирович — канд. техн. наук, доцент кафедры, кафедра информационных систем факультета информационных технологий, Муромский институт (филиал) ФГБОУ ВО «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых». Область научных интересов: обработка пространственных данных, геоинформационные системы, топологический анализ данных. Число научных публикаций — 101. sv-eremeev@yandex.ru; улица Орловская, 23, 602264, Муром, Россия; р.т.: 8(492)347-7122.

Абакумов Артём Владимирович — аспирант, Муромский институт (филиал) ФГБОУ ВО «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых». Область научных интересов: обработка пространственных данных, геоинформационные системы, топологический анализ данных. Число научных публикаций — 10. artem210966@yandex.ru; улица Орловская, 23, 602264, Муром, Россия; р.т.: 8(492)347-7112.

Андрианов Дмитрий Евгеньевич — д-р техн. наук, доцент, заведующий кафедрой, кафедра информационных систем факультета информационных технологий, Муромский институт (филиал) ФГБОУ ВО «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых». Область научных интересов: обработка пространственных данных, геоинформационные системы, топологический анализ данных. Число научных публикаций — 102. AndrianovDE@inbox.ru; улица Орловская, 23, 602264, Муром, Россия; р.т.: 8(492)347-7112.

Ширабакина Тамара Александровна — канд. техн. наук, профессор кафедры, кафедра вычислительной техники факультета фундаментальной и прикладной информатики, Юго-Западный государственный университет. Область научных интересов: обработка изображений, системы технического зрения. Число научных публикаций — 89. tas_06@mail.ru; улица 50 лет Октября, 94, 305040, Курск, Россия; р.т.: +7(471)222-2665.

Поддержка исследований. Исследование выполнено в рамках Программы развития ЯРГУ, проект № П2-ГМЗ-2021.

S. EREMEEV, A. ABAKUMOV, D. ANDRIANOV, T. SHIRABAKINA
**VECTORIZATION METHOD OF SATELLITE IMAGES BASED ON
THEIR DECOMPOSITION BY TOPOLOGICAL FEATURES**

Eremeev S., Abakumov A., Andrianov D., Shirabakina T. Vectorization Method of Satellite Images Based on Their Decomposition by Topological Features.

Abstract. Vectorization of objects from an image is necessary in many areas. The existing methods of vectorization of satellite images do not provide the necessary quality of automation. Therefore, manual labor is required in this area, but the volume of incoming information usually exceeds the processing speed. New approaches are needed to solve such problems. The method of vectorization of objects in images using image decomposition into topological features is proposed in the article. It splits the image into separate related structures and relies on them for further work. As a result, already at this stage, the image is divided into a tree-like structure. This method is unique in its way of working and is fundamentally different from traditional methods of vectorization of images. Most methods work using threshold binarization, and the main task for them is to select a threshold coefficient. The main problem is the situation when there are several objects in the image that require a different threshold. The method departs from direct work with the brightness characteristic in the direction of analyzing the topological structure of each object. The proposed method has a correct mathematical description based on algebraic topology. On the basis of the method a geoinformation technology has been developed for automatic vectorization of raster images in order to search for objects located on it. Testing was carried out on satellite images from different scales. The developed method was compared with a special tool for vectorization R2V and showed a higher average accuracy. The average percentage of automatic vectorization of the proposed method was 81%, and the semi-automatic vectorizing module R2V was 73%.

Keywords: spatial data, image decomposition, topological features, vectorization.

References

1. Miroshnichenko S.Yu., Titov V.S., Dremov E.N., Mosin S.A. Hough Transform Application to Digitize Rectangular Spatial Objects on Aerospace Imagery. *Trudy SPIIRAN – SPIIRAS Proceedings*. 2018. vol. 61. pp. 172–196.
2. Kurlin V., Muszynski G. A Persistence-Based Approach to Automatic Detection of Line Segments in Images. *Proc. CTIC: Comp. Topology in Image Context*. 2019. pp. 137–150.
3. Edelsbrunner H., Harer J. *Computational topology. An introduction*. 2010.
4. Eremeev S.V., Abakumov A.V., Andrianov D.E., Titov D.V. [Image Decomposition Method by Topological Features]. *Komp'yuternaja optika – Computer Optics*. 2022. vol. 46. no. 6. pp. 939–947. (In Russ.).
5. Bessmeltsev M., Solomon J. Vectorization of Line Drawings via Polyvector Fields. *ACM Transactions on Graphics*. 2019. vol. 38. no. 1. pp. 1–12.
6. Bobyr M.V., Arhipov A.E., Gorbachev S.V., Cao C., Bhattachar'ja S. [Fuzzy Logic Approaches in the Task of Object Edge Detection]. *Informatika i avtomatizacija – Informatics and Automation*. 2022. vol. 21. no. 2. pp. 376–404. (In Russ.).
7. Von Gioi R.G., Jakubowicz J., Morel J.M., Randall G. LSD: A Fast Line Segment Detector with a False Detection Control. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2010. vol. 32. no. 4. pp. 722–732.

8. Akinlar C., Topal C. Edlines: A Real-Time Line Segment Detector with a False Detection Control. *Pattern Recognition Letters*. 2011. vol. 32. no. 13. pp. 1633–1642.
9. Novotortsev L.V., Voloboy A.G. Detection and 3D Reconstruction of Buildings from Aerial Images. *Programming and Computer Software*. 2019. vol. 45. no. 6. pp. 311–318.
10. Chernov A.V., Chupshev N.V. [Automatic Recognition of Building Contours on Cartographic Images]. *Komp'yuternaja optika – Computer Optics*. 2007. vol. 31. no. 4. pp. 101–103. (In Russ.).
11. Kudryashov A.P., Solovyev I.V. [Detection of Objects on the Topographical Map for Reconstruction of the Scene of Urban Space]. *Programmhnaja inzhenerija – Software Engineering*. 2019. vol. 10. no. 11-12. pp. 464–470. (In Russ.).
12. Moskalenko S.V., Gatchin Y.A. [Noise Stayable Wave Method of Raster Line Vectorization]. *Vestnik komp'yuternyh i informacionnyh tehnologij – Herald of Computer and Information Technologies*. 2009. no. 5. pp. 16–21. (In Russ.).
13. Sterjanov M.V. [Fast Vectorization Algorithm of Line Image Drawings]. *Doklady BGUIR*. 2010. vol. 50. no. 4. pp. 88–94. (In Russ.).
14. Kostyuk Y.L., Kon A.B., Novikov Y.L. [Algorithms for Vectorization of a MultiColor Raster Image Based on Triangulation and Their Realization]. *Vestnik Tomskogo Gosudarstvennogo Universiteta – Tomsk State University Journal*. 2003. no. 280. pp. 275–280. (In Russ.).
15. Mestetskiy L.M. [Skeletonization of a Multiply-Connected Polygonal Domain Based on Its Boundary Adjacent Tree]. *Sibirskij zhurnal vychislitel'noj matematiki – Siberian J. of Numer. Mathematics*. 2006. vol. 9. no. 3. pp. 299–314. (In Russ.).
16. Zalesky B.A. [Combinatorial Algorithm for Object Contours Detection of Digital Images]. *Informatika – Informatics*. 2013. no. 3. pp. 13–20. (In Russ.).
17. Fralenko V.P. [Methods of Image Texture Analysis, Earth Remote Sensing Data Processing]. *Programmnyye sistemy: teorija i prilozhenija – Program Systems: Theory and Applications* . 2014. vol. 5. no. 4. pp. 19–39. (In Russ.).
18. Bychkov I.V., Ruzhnikov G.M., Fedorov R.K., Popova A.K., Avramenko Y.V. [Classification of Sentinel-2 satellite images of the Baikal Natural Territory]. *Komp'yuternaja optika – Computer Optics*. 2022. vol. 46. no. 1. pp. 90-96. (In Russ.).
19. Yan K., Xu Y., Chen H. Building Boundary Vectorization from Satellite Images Using Generative Adversarial Networks. *The International Conference on Image, Vision and Intelligent Systems (ICIVIS 2021)*. *Lecture Notes in Electrical Engineering*. 2022. vol. 813. pp. 671–678.
20. Alsabhan W., Alotaiby T., Dudin B. Detecting Buildings and Nonbuildings from Satellite Images Using U-Net. *Computational Intelligence and Neuroscience*. 2022. vol. 2022.
21. Temenos A., Temenos N., Doulamis A., Doulamis N. On the Exploration of Automatic Building Extraction from RGB Satellite Images Using Deep Learning Architectures Based on U-Net. *Technologies*. 2022. vol. 10.
22. Guo M, Liu H, Xu Y, Huang Y. Building Extraction Based on U-Net with an Attention Block and Multiple Losses. *Remote Sensing*. 2020. vol. 12. no. 9.
23. Wei S., Ji S. Graph Convolutional Networks for the Automated Production of Building Vector Maps from Aerial Images. *IEEE Transactions on Geoscience and Remote Sensing*. 2022. vol. 60. pp. 1–11.
24. Xu Y., Jin S., Chen Z., Xie X., Hu S., Xie Z. Application of a Graph Convolutional Network with Visual and Semantic Features to Classify Urban Scenes. *International Journal of Geographical Information Science*. 2022. vol. 36. pp. 1–26.
25. Chartock E., LaRow W., Singh V. Extraction of Building Footprints from Satellite Imagery. *Stanford University Report*. 2017.

26. Hensel S., Goebbels S., Kada M. Building Roof Vectorization with PPGNET. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. XLVI-4/W4-2021. 2021. pp. 85–90.
27. Fortuna-Cervantes J.M., Ramirez-Torres M.T., Martinez-Carranza J., Murguia-Ibarra J.S., Mejia-Carlos M. [Object Detection in Aerial Navigation Using Wavelet Transform and Convolutional Neural Networks: a First Approach]. Trudy instituta sistemnogo programirovaniya RAN – Proceedings of ISP RAS. 2021. vol. 33. no. 2. pp. 149–162. (In Russ.).
28. Nezhevenko E.S., Feoktistov A.S., Dashevskii O.Y. Neural Network Classification of Hyperspectral Images on the Basis of the Hilbert – Huang Transform. Optoelectronics, Instrumentation and Data Processing. 2017. vol. 53. no. 2. pp. 165–170.
29. Ereemeev S.V., Abakumov A.V. [Software Complex for Detection and Classification of Natural Objects Based on Topological Analysis]. Programmnye produkty i sistemy – Software & Systems. 2021. vol. 34. no. 1. pp. 201–208. (In Russ.).
30. Ereemeev S.V., Abakumov A.V. [Classification of Objects in Images with Distortions Based on a Two-Stage Topological Analysis]. Nauchno-tehnicheskij vestnik informacionnyh tehnologij, mehaniki i optiki – Scientific and Technical Journal of Information Technologies, Mechanics and Optics. 2022. vol. 22. no. 1. pp. 82–92. (In Russ.).
31. Teh C.-H., Chin R.T. On the detection of dominant points on digital curves. IEEE Transactions on Pattern Analysis and Machine Intelligence. 1989. vol. 11. no. 8. pp. 859–872.

Ereemeev Sergey — Ph.D., Associate professor of the department, Department of information systems, faculty of information technology, Murom Institute (branch) of Vladimir State University. Research interests: spatial data processing, geographic information systems and topological data analysis. The number of publications — 101. sv-eremeev@yandex.ru; 23, Orlovskaya St., 602264, Murom, Russia; office phone: 8(492)347-7122.

Abakumov Artyom — Postgraduate student, Murom Institute (branch) of Vladimir State University. Research interests: spatial data processing, geoinformation systems and topological data analysis. The number of publications — 10. artem210966@yandex.ru; 23, Orlovskaya St., 602264, Murom, Russia; office phone: 8(492)347-7112.

Andrianov Dmitry — Ph.D., Dr.Sci., Associate Professor, Head of the department, Department of information systems, faculty of information technology, Murom Institute (branch) of Vladimir State University. Research interests: spatial data processing, geographic information systems and topological data analysis. The number of publications — 102. AndrianovDE@inbox.ru; 23, Orlovskaya St., 602264, Murom, Russia; office phone: 8(492)347-7112.

Shirabakina Tamara — Ph.D., Professor of the department, Department of computer engineering, faculty of fundamental and applied informatics, Southwest State University. Research interests: image processing and computer vision systems. The number of publications — 89. tas_06@mail.ru; 94, 50 let Oktyabrya St., 305040, Kursk, Russia; office phone: +7(471)222-2665.

Acknowledgements. The reported study was funded by the YSU Programme (the research project No. P2-GM3-2021).

А.А. ИВАШКО, Г.Р. САФОНОВ
**МОДЕЛЬ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОПРЕДЕЛЕНИЯ
ОПТИМАЛЬНОЙ СТРАТЕГИИ В ОНЛАЙН-АУКЦИОНЕ**

Ивашко А.А., Сафонов Г.Р. Модель машинного обучения для определения оптимальной стратегии в онлайн-аукционе.

Аннотация. В работе рассмотрено применение модели машинного обучения для определения оптимальной стратегии пользователя для победы в аукционе на покупку товара/услуги с использованием задачи наилучшего выбора. Применение модели наилучшего выбора позволяет участникам аукциона определить стратегию, которая минимизирует ожидаемую стоимость товара/услуги на основе функции распределения его цен. На практике наиболее часто цены на товар, услугу или ресурс имеют распределение, близкое к нормальному или к смеси нормальных распределений. Возникают задачи определения числа компонент смеси нормальных распределений и определения ее параметров. Одним из распространенных методов для определения числа компонент смеси распределений является *BIC* критерий. Оценить неизвестные параметры смеси нормальных распределений при фиксированном числе компонент можно с помощью *EM*-алгоритма, однако временные затраты на оценку параметров данным методом возрастают как при увеличении объема выборки, так и при увеличении числа рассматриваемых компонент смеси. Разработана классификационная модель машинного обучения на основе сверточной нейронной сети для автоматизации и ускорения процесса определения числа компонент смеси нормальных распределений и оценки ее параметров. Приведены результаты тренировки и тестирования модели машинного обучения. Проведено сравнение применения разработанной модели с другими алгоритмами, не использующими нейронные сети. Результаты показывают, что предложенная модель позволяет эффективно определить наиболее подходящее число компонент для смеси нормальных распределений и уменьшает скорость вычисления параметров распределения при применении *EM*-алгоритма. Модель машинного обучения может быть применена в различных областях, например, в финансовом анализе или для определения оптимальной стратегии в аукционе на аренду вычислительного ресурса.

Ключевые слова: машинное обучение, аукцион, задача наилучшего выбора, смесь нормальных распределений, *EM*-алгоритм.

1. Введение. Системы онлайн-аукционов в современном мире широко распространены в различных областях. Пользователи заинтересованы в покупке/продаже товаров или услуг, аренде жилья или вычислительных ресурсов по сниженной цене. Удобным решением для осуществления сделок являются различные торговые площадки (Ozon, Wildberries, eBay), поисковые системы (Yandex, Google), системы облачных вычислений (Yandex.Cloud, AmazonEC2, Google), площадки биржевых торгов (фондовый рынок). Данные сервисы стали особенно популярны в связи с возрастающим спросом на удаленный формат участия в них. Использование аукциона позволяет пользователям снизить затраты на приобретение товара или услуги. Поэтому актуальной

является задача определения оптимальной ценовой стратегии для победы в аукционе.

Вызывает интерес исследование подходов к определению цены на товар или ресурс с использованием схем аукционов и конкурсов. Исследованиям в данном направлении посвящено много работ, связанных как с теоретическими исследованиями поведения пользователей различных сервисов, механизмов аукционов и ценообразования, так и с практическими исследованиями, связанными с математическим моделированием, возможностью применения искусственного интеллекта. Различные механизмы аукционов рассматривались в работах [1, 2]. Обзор разных видов аукционов, включая онлайн-аукционы и аукционы в России, приведены в работе [3]. Вероятностные и статистические модели ценообразования исследовались в работах [4, 5]. Конкурентная модель аукциона рассматривалась в работе [6].

Модели с оптимальной остановкой часто используются для исследования поведения участников в различных схемах конкурсов и аукционов, например, в работах [7–9] представлены примеры использования таких моделей в онлайн-аукционах на покупку товара. Работа [10] содержит решение задачи определения ставки в многошаговом аукционе с неполной информацией о распределении цен. В работе [11] рассмотрено применение задач с оптимальной остановкой к онлайн-аукционам, проводимым поисковой системой Яндекс.

В данной работе был использован подход, который заключается в применении задачи наилучшего выбора для определения оптимальной ставки, чтобы выиграть аукцион на предоставление товара или услуги. Данный подход был использован, например, в работе [12] для определения оптимальной ставки в аукционе на аренду облачного вычислительного ресурса.

Для применения модели наилучшего выбора необходимо знать закон распределения цен и его параметры. При этом площадка, на которой происходит аукцион, может хранить информацию о ценах покупки/продажи за определенный период времени. Для того чтобы выиграть аукцион и получить товар по сниженной цене, пользователю необходимо установить ставку, основываясь на динамике цен. Как показывают исследования, цены могут иметь различное распределение. Возникает важная задача сбора и анализа уже имеющейся статистики цен, определения закона распределения и оценки его параметров.

В данной работе предполагается, что динамика цен характеризуется смесью нормальных распределений, что часто встречается на практике. В этом случае возникает задача определения числа компонент смеси.

Если известно число компонент смеси, то одним из подходящих методов для оценки ее параметров является *EM*-алгоритм [13]. Однако, оценка параметров таким способом занимает много времени. Одним из удобных инструментов решения подобных задач являются модели машинного обучения. Так как такие модели интенсивно используются в задачах классификации, представляется возможным разработать архитектуру модели машинного обучения для определения видов вероятностных распределений и оценки их параметров. В работе [14] описаны методы сбора и анализа данных с различных аукционов. В работе [15] рассмотрено применение нейронных сетей к исследованию инфокоммуникационных сетей для определения вида распределения. Работа [16] посвящена рассмотрению возможностей использования нейронных сетей для решения задачи классификации.

Смеси вероятностных распределений повсеместно применяются при математическом моделировании многих явлений и анализе данных в таких областях, как биология, экономика, физика, финансовый анализ [17–19]. В работах [20, 21] с помощью таких методов проведена оценка параметров распределения цен на платформе облачных вычислительных ресурсов, если известен их закон распределения.

В данной работе описывается применение классификационной модели машинного обучения для автоматизации и ускорения процесса определения вида распределения цен, оценки параметров этого распределения и дальнейшего получения оптимальной ставки пользователя, который хочет принять участие в аукционе. Данный подход иллюстрируется на примере платформы Amazon EC2, для которой доступны исторические данные о ценах, но он может быть использован и адаптирован для более широкого круга задач принятия решений и классификации.

2. Модель определения ставки в аукционе. В данном разделе описана математическая модель аукциона, предложенная в работе [12]. Также приведены *EM*-алгоритм для оценки параметров распределения, если известно число компонент смеси [21].

2.1. Модель наилучшего выбора для определения оптимальной ставки в аукционе. Для определения оптимальной ставки для победы в аукционе за основу берется математическая модель наилучшего выбора. Задачи наилучшего выбора изучаются в теории оптимальной остановки случайных процессов. Эта теория имеет дело с задачами выбора времени принятия какого-либо решения на основе последовательного наблюдения за случайными величинами с целью максимизации выигрыша.

Задача наилучшего выбора имеет прямое сходство с задачей определения наилучшей ставки на аукционе. Предполагается, что для победы в аукционе доступно n шагов. Пользователь, желающий купить товар в определенный момент времени, как и в задаче наилучшего выбора, наблюдает последовательность X_1, X_2, X_3, \dots цен, представляющих собой независимые и одинаково распределенные случайные величины с известной непрерывной функцией распределения $F(x)$ на интервале $[p_{min}, p_{max}]$. p_{min} соответствует минимальной возможной стоимости товара на аукционе, а p_{max} максимальной не превышающей цену данного товара. Стратегией пользователя является пороговое значение (ставка) τ_i перед i -м шагом, $i = 1, \dots, n$. Если ставка превышает текущую цену, то пользователь выигрывает в аукционе. Целью является минимизация ожидаемой стоимости товара за весь период времени.

Описанная выше задача наилучшего выбора с полной информацией и конечным горизонтом времени решается методом динамического программирования. Не выиграв аукцион по окончании периода n , пользователь должен купить его по максимальной цене p_{max} , поэтому ставка $\tau_n = p_{max}$. Далее на предыдущем шаге ставка пользователя представляет собой ожидаемое значение цены, которую он заплатит, если выигрывает аукцион.

Таким образом, получается система рекуррентных уравнений, позволяющая определить оптимальное значение ставки τ_i для каждого шага i для заданного периода n :

$$\begin{aligned} \tau_n &= p_{max}, \\ \tau_i &= \mathbf{E}[\min\{X, \tau_{i+1}\}] = \int_{p_{min}}^{p_{max}} \min\{x, \tau_{i+1}\} dF(x) = \\ & \int_{p_{min}}^{\tau_{i+1}} x f(x) dx + \int_{\tau_{i+1}}^{p_{max}} \tau_{i+1} f(x) dx, \quad i = 1, \dots, n-1, \end{aligned} \quad (1)$$

где $\mathbf{E}[X]$ – математическое ожидание случайной величины X , $f(x)$ – плотность распределения X .

Если ставка τ_1 на первом шаге не выиграла, следующая ставка τ_2 используется на втором шаге. Продолжая процесс, пользователь гарантированно получает товар за период n с минимальной ожидаемой стоимостью.

2.2. Определение распределения цен и нахождение его параметров. Для применения модели наилучшего выбора для определения ставки в аукционе, описанной формулой (1), необходимо знать распределение цен на товар. Для этого может быть исследована

динамика цен на основе исторических данных. По полученным значениям цен строятся гистограммы относительных частот. Предполагается, что динамика цен характеризуется смесью нормальных распределений.

Далее необходимо оценить неизвестные параметры распределения. Оценку параметров нормального распределения можно провести методом моментов. А оценку параметров распределения смеси нормальных распределений проводится с помощью *EM*-алгоритма.

Рассмотрим процесс оценки параметров с помощью *EM*-алгоритма. Плотность распределения смеси нормальных распределений с k компонентами имеет вид:

$$f(x) = \sum_{j=1}^k \omega_j f_j(x, a_j, \sigma_j),$$

$$f_j(x, a_j, \sigma_j) = \frac{1}{\sqrt{2\pi}\sigma_j} e^{-\frac{(x-a_j)^2}{2\sigma_j^2}}, \quad (2)$$

где $j = 1, \dots, k$, $\sum_{j=1}^k \omega_j = 1$.

Рассмотрим шаги *EM*-алгоритма [13]:

1) **Е-шаг**, вычисляется ожидаемое значение (expectation) вектора скрытых переменных:

$$g_{ij} = \frac{\omega_j f_j(x_i, a_j, \sigma_j)}{\sum_{s=1}^k \omega_s f_s(x_i, a_s, \sigma_s)}, \quad i = 1, \dots, m, j = 1, \dots, k;$$

2) **М-шаг**, решается задача максимизации правдоподобия (maximization) и находится следующее приближение вектора параметров:

$$\omega_j = \frac{1}{m} \sum_{i=1}^m g_{ij},$$

$$a_j = \frac{1}{m\omega_j} \sum_{i=1}^m g_{ij} x_i,$$

$$\sigma_j^2 = \frac{1}{m\omega_j} \sum_{i=1}^m g_{ij} (x_i - a_j)^2, \quad j = 1, \dots, k,$$

где m – количество элементов в выборке, а g_{ij} – вероятность того, что элемент x_i выборки принадлежит j -го компоненте смеси распределений.

Последовательные итерации шагов E и M повторяются до тех пор, пока максимальное изменение переменных g_{ij} при переходе с t -й к $(t + 1)$ -й итерации не станет меньше 10^{-5} .

Для применения модели наилучшего выбора необходимо сформулировать гипотезу о виде вероятностного распределения цен, провести оценку его параметров и затем провести проверку гипотезы. EM-алгоритм является основным инструментом для оценки параметров смеси нормальных распределений, если известно число ее компонент. Однако временные затраты на оценку параметров данным методом возрастают как при увеличении объема выборки, так и при увеличении числа рассматриваемых компонент смеси. Данная особенность алгоритма не позволяет сформулировать и проверить гипотезы для каждого рассматриваемого распределения, так как этот процесс будет крайне затратным как относительно времени, так и вычислительных ресурсов.

3. Модель машинного обучения для определения вида распределения. В настоящей работе описано применение модели машинного обучения для определения наиболее подходящего вида распределения цен и нахождения его параметров. Для этого была реализована модель, предназначенная для автоматизированной постановки гипотезы о виде распределения цен на основе получаемой истории цен. Для рассматриваемой модели задачей машинного обучения является задача классификации по трём классам, соответствующим следующим видам распределений: нормальное распределение, смесь двух нормальных распределений и смесь трёх нормальных распределений.

3.1. Описание архитектуры нейронной сети. Сверточные нейронные сети (CNN) успешно используются для решения задачи распознавания образов на изображениях. Использование свертки позволяет получить новое изображение из исходного с более выраженными ключевыми особенностями [22, 23]. В данной работе используется этот тип нейронных сетей для ускорения процесса классификации. Дополнительно использование сверточной нейронной сети позволяет решить задачу, используя меньшее число обучаемых параметров и сохраняя достаточную точность. Для решения данной задачи применялись и иные популярные виды архитектур нейронных сетей, такие как полносвязные и рекуррентные (LSTM и GRU). Однако, в случае с полносвязными сетями обучение модели не давало удовлетворительных результатов в связи с проблемой переобучения, в случае с рекуррентными моделями не удалось достичь удовлетворительного качества классификации.

Описание структуры, предлагаемой свёрточной нейронной сети представлена на рисунке 1.




Рис. 1. Описание структуры нейронной сети

На рисунке 1 использованы следующие обозначения:

- Input – входной полносвязный слой, принимающий 25 значений интервальных частот;
- Conv1D – слои одномерной свёртки;
- Dense – полносвязные слои;
- Dropout – слой исключения;
- Output – выходной слой, каждый нейрон которого соответствует одному из рассматриваемых распределений.

Модель машинного обучения была реализована на языке программирования Python 3.6 с использованием программной библиотеки Keras.

В результате модель содержит 2995 обучаемых параметров, что позволяет решать поставленную задачу с незначительным потреблением вычислительных ресурсов.

3.2. Генерация данных. Для обучения и тестирования нейронной сети были использованы стандартизированные последовательности, сгенерированные из трёх рассматриваемых распределений (нормального, смеси двух нормальных, смеси трёх нормальных). Длина генерируемой последовательности варьируется от 500 до 950 значений. Генерация последовательности происходит в три этапа:

1. Генерация параметров распределения;
2. Генерация псевдослучайных величин из распределения;
3. Проверка соответствия полученной последовательности распределению.

Параметры распределения определяются псевдослучайным образом из равномерного распределения с дополнительными ограничениями. Математическое ожидание каждой i -й компоненты смеси не должно попадать в интервалы $(a_j - 2 \cdot \sigma_j, a_j + 2 \cdot \sigma_j)$ при $j \neq i$, где a_j – математическое ожидание j -й компоненты, σ_j – среднеквадратическое отклонение j -й компоненты. Веса каждой из компонент ограничены интервалом $(0,1, 0,8)$.

После генерации последовательности из распределения с заданными параметрами, проводится проверка на соответствие полученной последовательности заданному распределению с помощью алгоритма, основанного на BIC -критерии, его описание представлено на рисунке 2. Если полученная последовательность не проходит проверку на соответствие, то осуществляется переход на первый этап.

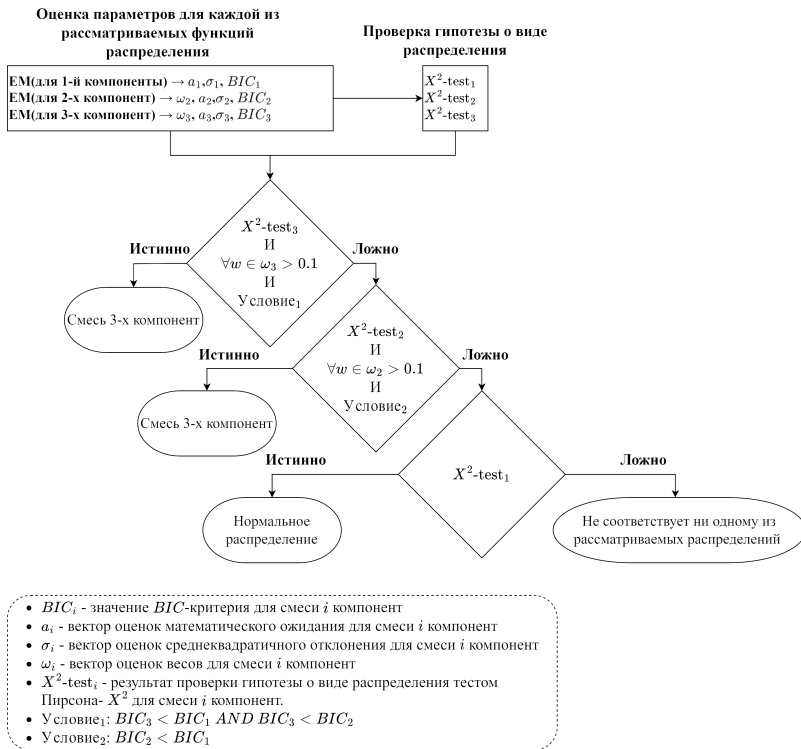


Рис. 2. Описание алгоритма разметки на основе BIC

3.3. Тренировка и тестирование нейронной сети. Для формирования тренировочной выборки выше описанным методом было сгенерировано 8400 наборов векторов интервальных частот с распределением по классам, представленным таблице 1.

Таблица 1. Распределение наборов тренировочных данных по классам

Класс	Количество наборов
Нормальное распределение	2785
Смесь 2-х нормальных распределений	2790
Смесь 3-х нормальных распределений	2850

Для формирования тестовой выборки было сгенерировано 3600 наборов интервальных частот.

Для обучения модели было применено 200 эпох, в результате чего на основе тренировочных данных получены значения метрик, которые даны в таблице 2.

Таблица 2. Результаты обучения модели (на тренировочных данных)

Метрика	Значение
Точность	0.963
Полнота	0.962
Значение функции потерь	0.113

На рисунках 3 и 4 представлены графики значений точности для тренировочной и валидационной выборок, для формирования валидационной выборки было использовано 25% наборов от тренировочной выборки.

На рисунках 3 и 4 показано, что график точности возрастает, в то время как график функции потерь убывает на всем протяжении эпох обучения для тренировочной и валидационной выборок. Следовательно, обучение нейронной сети прошло успешно без переобучения.




Рис. 3. Графики изменения точности для тренировочной и валидационной выборок в зависимости от эпохи обучения




Рис. 4. Графики изменения функции потерь для тренировочной и валидационной выборок в зависимости от эпохи обучения

В результате применения предложенной модели на тестовых данных были получены значения метрик, которые представлены в таблице 3.

Таблица 3. Результаты применения модели на тестовой выборке

Метрика	
Точность	0.875
F1-метрика	0.874
Значение функции потерь	0.355

3.4. Сравнение скорости работы. Основной задачей применения полученной модели является ускорение процесса определения типа распределения и его параметров, связанного с применением *EM*-алгоритма, поэтому было проведено сравнение скорости работы трёх алгоритмов по определению количества компонент в смеси нормальных распределений:

1. Оценка параметров с помощью *EM*-алгоритма для максимального числа рассматриваемых компонент.

2. Применение алгоритма, основанного на *BIC*-критерии, аналогичного тому, который применялся для предварительной разметки исходных данных.

3. Применение полученной модели машинного обучения для определения числа компонент.

Первый алгоритм основан на идее о том, что если оценка параметров будет проводиться для большего количества компонент, чем имеется в действительном распределении цен, то полученные в результате применения *EM*-алгоритма веса тех компонент, которые не согласованы с реальными данными, будут близки к 0. Данный подход потребует применения *EM*-алгоритма для каждого набора данных, а с увеличением максимального числа компонент будут увеличиваться и временные затраты на применение *EM*-алгоритма.

Второй алгоритм, основанный на *BIC*-критерии, является самым затратным относительно вычислительных и временных ресурсов, так как требует применить *EM*-алгоритм дважды для каждого набора данных.

Третий алгоритм, основанный на модели машинного обучения, предполагает следующие этапы обработки данных:

1. Получение интервальных частот для входного набора цен.

2. Применение свёрточной нейронной сети для определения количества компонент в смеси.

3. Применение *EM*-алгоритма для определения параметров смеси нормальных распределений с найденным на прошлом шаге количеством компонент.

4. Проверка гипотезы о виде распределения на основе критерия Пирсона- χ^2 .

На тестовой выборке, содержащей 150 равновзвешенных по классам наборов данных, было проведено сравнение скорости обработки всего набора данных тремя ранее указанными алгоритмами. При проведении тестирования было использовано устройство со следующими техническими характеристиками:

- CPU: Intel Core i5-1035G1;
- RAM: DDR4, 8Gb.

При применении нейронной сети графический ускоритель не применялся. В таблице 4 представлены значения времени обработки всех 150 значений тремя алгоритмами в секундах для 5 итераций.

Таблица 4. Время выполнения алгоритмов для 5 итераций по 150 наборов

	CNN	EM для 3-х компонент	BIC
Итерация 1	62.55	91.55	169.85
Итерация 2	63.38	86.3	161.37
Итерация 3	61.12	85.15	181.11
Итерация 4	58.43	86.77	198.37
Итерация 5	64.25	86.51	194.03
Среднее время	58.79	87.26	180.95

Как видно из таблицы 4, разработанная модель машинного обучения позволила ускорить процесс определения вида распределения цен.

4. Применение модели машинного обучения к реальным данным. Полученная модель может быть использована как для автоматизации анализа данных, так и для построения различных моделей оптимального поведения.

Смеси распределений часто встречаются в различных сферах, в частности, в финансовой области [19]. Например, в помесечном разбиении истории цен акций ВТБ с 2015 по 2021 год:

- 31% последовательностей имеет нормальное распределение;
- 34% последовательностей имеют распределение в виде смеси двух нормальных распределений;
- 18% последовательностей имеют распределение в виде смеси трёх нормальных распределений.

С помощью модели машинного обучения возможно автоматизировать и ускорить процесс определения вида распределения

и его параметров, и затем применить различные модели финансового анализа.

Другим примером применения предложенной модели машинного обучения может служить анализ данных площадки облачных вычислений Amazon EC2 [24, 25], которые являются открытыми для пользователей, и определение оптимальной ставки в аукционе на аренду облачного ресурса.

На площадке Amazon EC2 одним из способов аренды вычислительного ресурса (инстанса) является спотовый аукцион. Пользователи делают ставки на максимальную стоимость часа пользования инстансом. Если сделанная ставка выше спотовой цены, то она является выигрышной. Все победившие пользователи платят одинаковую цену, которая равна значению минимальной выигравшей ставки.

Рассмотрим пример определения оптимальных ставок для инстанса типа *us-west-2c m5ad.4xlarge*, для которого было получено 500 значений цен.

График статистики цен изображен на рисунке 5.




Рис. 5. Динамика спотовых цен инстанса *us-west-2c m5ad.4xlarge*

В результате применения модели машинного обучения и *EM* - алгоритма получим, что исторические данные в период с 26.11.2021 по 23.12.2021 (всего 500 значений) описываются смесью трёх нормальных распределений с параметрами $a_1 = 0.405$, $a_2 = 0.726$, $a_3 = 0.624$; $\sigma_1 = 0.024$, $\sigma_2 = 0.005$, $\sigma_3 = 0.056$; $\omega_1 = 0.402$, $\omega_2 = 0.237$, $\omega_3 = 0.361$. Гистограмма значений цен представлена на рисунке 6.

Далее применим формулу (1) для определения оптимальных ставок, $p_{min} = 0.379$, $p_{max} = 0.736$.




Рис. 6. Гистограмма спотовых цен

В таблице 5 представлены оптимальные пороги (ставки) для $n = 10$ шагов модели. Заметим, что ставки возрастают по i , $i = 1, \dots, n$.

Таблица 5. Значения ставок в соответствии с оптимальной стратегией для $n = 10$

i	1	2	3	4	5	6	7	8	9	10
τ_i	0.358	0.367	0.377	0.387	0.399	0.415	0.438	0.478	0.546	0.736

Для иллюстрации оптимального поведения участника аукциона рассмотрим один из периодов с количеством шагов $n = 10$. На рисунке 7 представлены оптимальные пороги (серая линия) и цены на каждом из шагов (чёрная линия). В данном периоде оптимальным шагом для остановки будет $i = 3$, так как цена станет меньше ставки для данного шага. При этом значение ставки необходимо установить равной 0.377.




Рис. 7. Спотовые цены и оптимальные пороги для $n = 10$

Для проверки эффективности предложенной оптимальной стратегии было проведено сравнение с тремя другими возможными стратегиями:

1. *Постоянная стратегия.*

Пользователь определяет значение ставки, постоянное для всех шагов. Эта ставка дает минимальное значение ожидаемой стоимости инстанса. Если за n шагов пользователь не получает инстанс, то он покупает инстанс по максимальной цене. Значение ставки x^* определяется по формуле $x^* = \operatorname{argmin}(P(x))$, где:

$$P(x) = \sum_{i=1}^n \left[\int_x^{p_{max}} f(y) dy \right]^{i-1} \int_{p_{min}}^x y f(y) dy + \left[\int_x^{p_{max}} f(y) dy \right]^n p_{max}. \quad (3)$$

В формуле (3) вычисляется ожидаемая стоимость инстанса при постоянном пороге x .

2. *Линейная стратегия.*

Пользователь использует ставки, имеющие линейный вид: $\tau_n = ki + b$, где i номер шага, а значения k и b зависят от общего числа шагов n .

3. Случайная стратегия.

Ставка пользователя является случайной величиной, имеющей распределение вида смеси нормальных распределений с определенными ранее параметрами. Пользователь определяет значение ставки как псевдослучайное число, которое может быть вычислено следующим образом:

- Генерируется псевдослучайное число из равномерного распределения с параметрами 0 и 1. На основании полученного значения определяется компонента смеси распределений.

- Генерируется псевдослучайное число из нормального распределения с параметрами, соответствующими выбранной компоненте. Полученное число представляет собой значение ставки для выбранного шага.

Таким образом, генерируются значения для каждого из n шагов.

Сравнение стратегий проводилось на основе данных из истории цен *Amazon EC2* в регионе *us-west-2c*, полученных с января по май 2022 года, всего было рассмотрено 302 инстанса и 1787865 значений истории цен. Для последовательности цен каждого инстанса были сформированы наборы, содержащие данные для постановки гипотезы о виде распределения (включающие в себя данные за 60 предшествующих дней) и наборы значений для применения стратегий для $n = 10$ и $n = 15$. Значение итоговой цены выхода из аукциона каждой стратегии сравнивалось с максимальным значением цены за предшествующие 60 дней. В таблице 6 представлены средние значения процента прибыли при применении каждой стратегии в сравнении с покупкой по максимальной цене.

Таблица 6. Результаты сравнения стратегий

Стратегия	Средняя прибыль в % для $n = 10$ шагов	Средняя прибыль в % для $n = 15$ шагов
Оптимальная	44	49
Линейная	40	44
Постоянная	34	34
Случайная	19	18

Как видно из таблицы 6, приобретение инстанса через аукцион позволяет пользователю сэкономить до 49 % от его максимальной цены. Также результаты показывают, что ставки пользователя, которые представляют собой оптимальные пороги, найденные по формуле (1),

позволяют уменьшить стоимость приобретаемого инстанса на аукционе по сравнению с другими возможными стратегиями.

5. Заключение. В данной работе рассмотрена задача определения оптимальных ставок пользователя онлайн-аукциона на приобретение товара или услуги. Применен подход, основанный на применении задачи наилучшего выбора, которая, в свою очередь, использует исторические данные цен. Для автоматизации и ускорения процесса определения вида распределения истории цен и оценки его параметров была разработана модель машинного обучения на основе сверточной нейронной сети. Представлены результаты обучения и тестирования данной модели.

Результаты показывают, что предложенная сверточная нейронная сеть может быть успешно применена для определения наиболее подходящего количества компонент в смеси нормальных распределений для цен и ускорит процесс применения *EM*-алгоритма для оценки параметров распределения. Приведены результаты сравнения скорости работы разработанной модели машинного обучения с другими алгоритмами по определению количества компонент смеси распределений. Также рассмотрены возможные сферы применения полученных результатов для определения вида распределения, например, финансовых данных и оптимальной стратегии в аукционе на аренду облачного вычислительного ресурса. На основе реальных данных была проведена демонстрация последовательности действий определения оптимальной стратегии, включающая в себя применение предложенной модели машинного обучения, оценку параметров с помощью *EM*-алгоритма и применение алгоритма построения оптимальной стратегии. Проведено сравнение эффективности предложенной модели машинного обучения, использующей задачу наилучшего выбора для определения оптимальных ставок, с другими возможными стратегиями пользователя в аукционе.

В дальнейшем для увеличения точности предложенной модели машинного обучения размер и разнообразие тренировочных выборок могут быть увеличены. Также распределения цен не ограничены только нормальным распределением и его смесью. Можно встретить другие типы распределений, такие как экспоненциальное и логнормальное распределения. Следовательно, модель может быть расширена на более широкий класс распределений.

Полученные в работе результаты могут быть применены для исследования других типов аукционов, конкурсов, финансовых торгов. Предложенная модель машинного обучения может быть использована не только для аукционов, но и для других задач, в которых необходимо

проанализировать и классифицировать данные или оценить закон распределения поступающих наблюдений.

Литература

1. Myerson R.B. Optimal Auction Design // *Mathematics of Operations Research*. 1981. vol. 6. no. 1. pp. 58–73.
2. Сонин К.И. Основы теории аукционов (Нобелевская премия по экономике 2020 года) // *Вопросы экономики*. 2021. № 1, С. 5–32.
3. Савватеев А.В., Филатов А.Ю. Теория и практика аукционов // *Вестник ВГУ. Серия: Экономика и управление*. 2018. № 3. С. 119–131.
4. Wang Y., Liu X., Zheng Z., Zhang Z., Xu M., Yu C., Wu F. On Designing a Two-stage Auction for Online Advertising // *WWW '22: Proceedings of the ACM Web Conference*. 2022. pp. 90–99.
5. Shmueli G., Russo R.P., Jank W. Modeling Bid Arrivals in Online Auctions. Robert H. Smith School Research Paper No. RHS-06-001, 2004. Available at SSRN: <https://ssrn.com/abstract=902868> (accessed 26.07.2022).
6. Maslov A., Schwartz J. Imperfect Competition in Online Auctions // *Journal of Mathematical Economics*. 2022 Advance Access, Available at SSRN: <https://ssrn.com/abstract=4025920> (accessed 26.07.2022).
7. Harrell G., Harrison J., Mao G., Wang J. Online Auction and Secretary Problem // *Int'l Conf. Scientific Computing*. 2015. pp. 241–244.
8. Babaioff M., Immorlica N., Kempe D., Kleinberg R. Online auctions and generalized secretary problems // *SIGecom Exch.* 2008. vol. 7. no. 2. pp. 1–11.
9. Guo X. An optimal strategy for sellers in an online auction // *Authors Info & Claims ACM Transactions on Internet Technology*. 2002. Vol. 2, Issue 1. pp. 1–13.
10. Mazalov V.V., Ivashko A.A. Online Auction and Optimal Stopping Game with Imperfect Observation // *Intelligent Information and Database Systems. ACIIDS 2020, LNCS*. 2020. vol. 12033. Springer. pp. 145–156.
11. Мазалов В.В., Фалько (Ивашко) А.А. Задача наилучшего выбора и ее применение в рекламных кампаниях поисковой системы Яндекс // *Интернет-Математика 2007*. Яндекс. 2007. С. 126–134.
12. Ивашко Е.Е., Черных А., Ивашко А.А., Сафонов Г.Р. Эффективная по цене стратегия аренды облачных ресурсов при неопределенности цены // *Математическая Теория Игр и ее Приложения*. 2019. Т. 11. Вып. 3. С. 5–30.
13. McLachlan G.J., Lee S.X., Rathnayake S.I. Finite Mixture Models // *Annual Review of Statistics and Its Application*. 2019. vol. 6, no. 1. pp. 355–378.
14. Jank W., Shmueli G. *Modeling Online Auctions*. 2010. Wiley. 336 p.
15. Гойхман В., Лапий А. Построение архитектуры нейронной сети для выявления вида распределения случайных величин // *Технологии и средства связи*. 2016. Вып. 3, С. 36–40.
16. Khoussi S., Heckert N., Battou A., Bensalem S. Neural Networks for Classifying Probability Distributions, Technical Note (NIST TN), National Institute of Standards and Technology, Gaithersburg, MD. Available at: https://tsapps.nist.gov/publication/get_pdf.cfm?pub_id=931221 (accessed 12.10.2022).
17. Королев В. Ю., Ломской В.А., Пресняков Р.Р., Рэй М. Анализ компонент волатильности с помощью метода скользящего разделения смесей // *Системы и средства информатики. Специальный выпуск*. 2005. М.: ИПИРАН. С. 180–206.
18. Волков Н.А., Буденный С.А., Андрианова А.М. Смесей вероятностных распределений в задачах регрессии и проверки на аномальность и их применение для PVT-свойств // *ТРУДЫ МФТИ*. 2020. Т. 12, № 3, С. 17–43.

19. Abba Mallam Hassane, Barro Diakarya, Yaméogo WendKouni, Saley Bisso Pricing Multivariate European Equity Option Using Gaussians Mixture Distributions and EVT-Based Copulas // International Journal of Mathematics and Mathematical Sciences. 2021. vol. 2021. Article ID 7648093, 9 pages.
20. Javadi B., Thulasiram K.R., Rajkumar B. Characterizing spot price dynamics in public cloud environments // Future Generation Computer Systems. 2013. vol. 29. Issue 4, June 2013. pp. 988–999.
21. Ivashko A., Safonov G. Optimal strategy modelling in an online auction for the rent of computing resources // CEUR Workshop Proceedings, Volume 2792, 2020, 2nd International Workshop on Stochastic Modeling and Applied Research of Technology, SMARTY 2020; Petrozavodsk; Russian Federation; 16 August 2020. 2020. pp. 66–75.
22. Buduma N., Buduma N., Papa J. Fundamentals of Deep Learning, 2nd Edition O'Reilly Media, Inc., 2022. 296 p.
23. Голубинский А. Н., Толстых А. А. Гибридный метод обучения сверточных нейронных сетей // Информатика и автоматизация. 2021. Т. 20, Вып. 2. С. 463–490.
24. Amazon Inc. Amazon Elastic Compute Cloud (Amazon EC2). Available at: <http://aws.amazon.com/ec2> (accessed 8.06.2022).
25. Kumar D., Baranwal G., Raza Z., Vidyarthi D.P. A Survey on Spot Pricing in Cloud Computing // Journal of Network and Systems Management. 2018. pp. 809–856.

Ивашко Анна Антоновна — канд. физ.-мат. наук, старший научный сотрудник, институт прикладных математических исследований, Карельский научный центр Российской академии наук; доцент, кафедра математического анализа, Петрозаводский государственный университет. Область научных интересов: теория вероятностей, математическая статистика, теория оптимальной остановки случайных процессов, теория игр. Число научных публикаций — 63. aivashko@krc.karelia.ru; улица Пушкинская, 11, 185910, Петрозаводск, Россия; р.т.: +7(8142)766-312.

Сафонов Георгий Романович — студент магистратуры, Петрозаводский государственный университет. Область научных интересов: машинное обучение, теория игр, теория вероятностей и математическая статистика. Число научных публикаций — 4. jiri.safonov@gmail.com; проспект Ленина, 33, 185910, Петрозаводск, Россия; р.т.: +7(953)535-8814.

A.A. IVASHKO, G.R. SAFONOV
**MACHINE LEARNING MODEL FOR DETERMINATION OF THE
OPTIMAL STRATEGY IN AN ONLINE AUCTION**

Ivashko A.A., Safonov G.R. Machine Learning Model for Determination of the Optimal Strategy in an Online Auction.

Abstract. We apply a machine learning model to determine the optimal strategy in an online auction for the rent of computing resources using the best-choice model. The best-choice model allows clients to minimize the expected cost of renting a computing resource based on the spot price distribution function. The spot price dynamics platform is investigated. The most suitable price distributions in an auction are the normal distribution and its mixtures. In this case, the problems of determining the number of components in the mixture and estimating its parameters arise. One of the well-known methods for determining the number of components in a mixture of normal distributions is the BIC criterion. The EM algorithm is a basic tool for estimating the parameters of a mixture of distributions if we know the number of components. However, parameter estimation by this method takes more time when both the sample size and the number of components of the mixture increase. To automate and expedite the process of determining the number of components for a mixture of normal distributions and estimating its parameters, a classification machine learning model based on a convolutional neural network is developed. The results of the model training and validation are presented. The suggested model is compared with other algorithms which do not use neural networks. The results show that the suggested model performs well in determining the most appropriate number of components for a mixture of normal distributions and in reducing the time spent on applying the EM algorithm to estimate its parameters. This model can be used in different areas, for example, in finance or for determination of the optimal strategy in an online auction for the rent of computing resources.

Keywords: machine learning, auction, best-choice problem, mixture of normal distributions, EM-algorithm.

References

1. Myerson, R. B. Optimal Auction Design. *Mathematics of Operations Research*. 1981. vol. 6. no. 1. pp. 58–73.
2. Sonin K.I. [The principles of auction theory (Nobel Memorial Prize in Economic Sciences 2020)] *Voprosy Ekonomiki*. [Problems of Economics]. 2021. no. 1, pp. 5–32. (In Russ.).
3. Savvateev A.V, Filatov A.Yu. [Theory and practice of auctions]. *Vestnik VGU. Serija: Jekonomika i upravlenie* [Proceedings of Voronezh State University. Series: Economics and Management]. 2018. no. 3. pp. 119–131. (In Russ.).
4. Wang Y., Liu X., Zheng Z., Zhang Z., Xu M., Yu C., Wu F. On Designing a Two-stage Auction for Online Advertising. *WWW '22: Proceedings of the ACM Web Conference*. 2022. pp. 90–99.
5. Shmueli G., Russo R.P., Jank W. Modeling Bid Arrivals in Online Auctions. Robert H. Smith School Research Paper No. RHS-06-001, 2004. Available at SSRN: <https://ssrn.com/abstract=902868> (accessed 26.07.2022).
6. Maslov A., Schwartz J., Imperfect Competition in Online Auctions. *Journal of Mathematical Economics*. 2022 Advance Access, Available at SSRN: <https://ssrn.com/abstract=4025920> (accessed 26.07.2022).

7. Harrell G., Harrison J., Mao G., Wang J. Online Auction and Secretary Problem. *Int'l Conf. Scientific Computing*. 2015. pp. 241–244.
8. Babaioff M., Immorlica N., Kempe D., Kleinberg R. Online auctions and generalized secretary problems. *SIGecom Exch*. 2008. vol. 7. no. 2. pp. 1–11.
9. Guo X. An optimal strategy for sellers in an online auction. *Authors Info & Claims ACM Transactions on Internet Technology*. 2002. Vol. 2, Issue 1. pp. 1–13.
10. Mazalov V.V., Ivashko A.A. Online Auction and Optimal Stopping Game with Imperfect Observation. *Intelligent Information and Database Systems. ACIIDS 2020, LNCS*. 2020. vol. 12033. Springer. pp. 145–156.
11. Mazalov V.V., Falko (Ivashko) A.A. [Best-choice problem and its application in the advertising campaign of the search engine Yandex] *Internet-Matematika 2007 [Internet-Mathematics 2007]*. Yandex. 2007. pp. 126–134. (In Russ.).
12. Ivashko E.E., Tchernykh A., Ivashko A.A., Safonov G.R. [Cost-efficient strategy in clouds with spot price uncertainty] *Matematicheskaja teorija igr i ee prilozhenija. [Mathematical Game Theory and Applications.]* 2019. vol. 11, no. 3. pp. 5–30. (In Russ.).
13. McLachlan G.J., Lee S.X., Rathnayake S.I. Finite Mixture Models. *Annual Review of Statistics and Its Application*. 2019. vol. 6. no. 1. pp. 355–378.
14. Jank W., Shmueli G. *Modeling Online Auctions*. 2010. Wiley. 336 p.
15. Goikhman V., Lapiy A. [Development of the neural network's architecture for identifying type of distribution of random variables] *Tehnologii i sredstva svjazi.[Technology and Communication.]* 2016. v. 3. pp. 36-40. (In Russ.).
16. Khoussi S., Heckert N., Battou A., Bensalem S. *Neural Networks for Classifying Probability Distributions, Technical Note (NIST TN)*. 2021. National Institute of Standards and Technology, Gaithersburg, MD. Available at: https://tsapps.nist.gov/publication/get_pdf.cfm?pub_id=931221 (accessed 12.10.2022)
17. Korolev V., Lomskoy V., Presnyakov N., Rey M. [Analysis of volatility components by the method of moving separation of mixtures] *Sistemy i sredstva informatiki. Special'nyj vypusk. [Systems and Means of Informatics]*. 2005. pp. 180–206. (In Russ.).
18. Volkov N.A., Budennyj S.A., Andrianova A.M. [Mixture of probability distributions in the problems of regression and anomaly detection and its applications to PVT properties] *TRUDY MFTI. [Proceedings of MIPT.]* 2020. Vol. 12, No. 3, pp. 17–43. (In Russ.).
19. Abba Mallam Hassane, Barro Diakarya, Yaméogo WendKouni, Saley Bisso, Pricing Multivariate European Equity Option Using Gaussians Mixture Distributions and EVT-Based Copulas. *International Journal of Mathematics and Mathematical Sciences*. 2021. vol. 2021. Article ID 7648093. 9 pages.
20. Javadi B., Thulasiram K.R., Rajkumar B. Characterizing spot price dynamics in public cloud environments. *Future Generation Computer Systems*. 2013. vol. 29. Issue 4, June 2013. pp. 988–999.
21. Ivashko A., Safonov G. Optimal strategy modelling in an online auction for the rent of computing resources. *CEUR Workshop Proceedings*. 2020. Volume 2792, 2nd International Workshop on Stochastic Modeling and Applied Research of Technology, SMARTY 2020; Petrozavodsk; Russian Federation; 16 August 2020. pp. 66–75.
22. Buduma N., Buduma N., Papa J. *Fundamentals of Deep Learning, 2nd Edition*, O'Reilly Media, Inc., 2022. 296 p.
23. Golubinsiy A., Tolstykh A. Hybrid Method of Conventional Neural Network Training. *Informatika i avtomatizacija. [Informatics and Automation]*. 2021. vol. 20. no. 2, pp. 463–490. (In Russ.).
24. Amazon Inc. *Amazon Elastic Compute Cloud (Amazon EC2)*. Available at: <http://aws.amazon.com/ec2> (accessed 8.06.2022).

25. Kumar D., Baranwal G., Raza Z., Vidyarthi D.P. A Survey on Spot Pricing in Cloud Computing. *Journal of Network and Systems Management*. 2018. pp. 809–856.

Ivashko Anna — Ph.D., Senior researcher, Institute of applied mathematical research, Karelian Research Centre of the Russian Academy of Sciences; Associate professor, Department of mathematical analysis, Petrozavodsk State University. Research interests: probability theory, mathematical statistics, optimal stopping theory, game theory. The number of publications — 63. aivashko@krc.karelia.ru; 11, Pushkinskaya St., 185910, Petrozavodsk, Russia; office phone: +7(8142)766-312.

Safonov Georgy — Master student, Petrozavodsk State University. Research interests: machine learning, game theory, probability theory and mathematical statistics. The number of publications — 4. jiri.safonov@gmail.com; 33, Lenin Ave., 185910, Petrozavodsk, Russia; office phone: +7(953)535-8814.

А.Д. ОБУХОВ, А.А. ВОЛКОВ, Н.А. ВЕХТЕВА, К.И. ПАТУТИН,
А.О. НАЗАРОВА, Д.Л. ДЕДОВ

**МЕТОД ФОРМИРОВАНИЯ ЦИФРОВОЙ ТЕНИ ПРОЦЕССА
ПЕРЕМЕЩЕНИЯ ЧЕЛОВЕКА НА ОСНОВЕ ОБЪЕДИНЕНИЯ
СИСТЕМ ЗАХВАТА ДВИЖЕНИЙ**

Обухов А.Д., Волков А.А., Вехтева Н.А., Патутин К.И., Назарова А.О., Дедов Д.Л. **Метод формирования цифровой тени процесса перемещения человека на основе объединения систем захвата движений.**

Аннотация. В статье рассматривается задача формирования цифровой тени процесса перемещения человека. Проведен анализ предметной области, который показал необходимость формализации процесса создания цифровых теней для имитации движений человека в виртуальном пространстве, тестировании программно-аппаратных комплексов, функционирующих на основе действий человека, а также в различных системах опорно-двигательной реабилитации. Выявлено, что среди существующих подходов к захвату движений человека нельзя выделить универсальный и стабильно работающий при различных условиях внешней среды. Разработан метод формирования цифровой тени на основе комбинирования и синхронизации данных из трех систем захвата движений (трекеры виртуальной реальности, костюм motion capture и камеры с использованием технологий компьютерного зрения). Объединение перечисленных систем позволяет получить комплексную оценку положения и состояния человека независимо от условий внешней среды (электромагнитные помехи, освещенность). Для реализации предложенного метода проведена формализация цифровой тени процесса перемещения человека, включающая описание механизмов сбора и обработки данных от различных систем захвата движений, а также этапы объединения, фильтрации и синхронизации данных. Научная новизна метода заключается в формализации процесса сбора данных о перемещении человека, объединении и синхронизации аппаратного обеспечения используемых систем захвата движений для создания цифровых теней процесса перемещения человека. Полученные теоретические результаты будут использоваться в качестве основы для программной абстракции цифровой тени в информационных системах для решения задач тестирования, имитации человека и моделирования его реакции на внешние раздражители за счет обобщения собранных массивов данных о его перемещении.

Ключевые слова: цифровые тени, процесс перемещения человека, системы захвата движений, математическая модель, виртуальная реальность.

1. Введение. Технологии цифрового двойника и цифровой тени активно развиваются в разных сферах промышленности в качестве центрального элемента построения высокотехнологичного производства. В соответствии с ГОСТ Р 57700.37-2021 под цифровым двойником некоторого изделия понимается система, состоящая из цифровой модели (системы математических и компьютерных моделей, описывающей структуру и функциональность реального объекта) и двусторонних информационных связей с изделием. основоположник понятия «цифровой двойник» М. Гривс определяет его как

«конструкцию, которая полностью описывает потенциальный или реальный физически производимый продукт от микроатомного уровня до макрогеометрического уровня» [1, 2]. Наряду с термином «цифровой двойник» существуют такие понятия, как цифровая модель и тень. В соответствии с классификацией, представленной в работе [3], можно выделить три различные категории, обладающие следующими принципиальными различиями: цифровая модель (математическое или цифровое представление объекта без автоматизированного канала обмена данными между цифровыми и физическими объектами), цифровая тень (в дополнение к цифровой модели существует автоматизированный канал обмена информацией от физических объектов, оказывающих влияние на цифровой объект) и цифровой двойник (существует полностью автоматизированный и интегрированный канал данных в обоих направлениях, воздействия на цифровой объект могут вызывать изменения состояний физических объектов). Концепция цифровых теней была предложена в рамках Индустрии 4.0 [4] как некоторая платформа, которая объединяет информацию из различных источников, чтобы обеспечить возможность анализа объекта в режиме реального времени для принятия решений. В отличие от цифрового двойника для формирования цифровой тени необходима не всеобъемлющая база данных, а ограниченная потребностями определенной задачи. Кроме того, для ряда областей, включающих объекты с заранее неопределенным поведением, создание цифрового двойника является задачей высокой сложности и трудоемкости с необходимостью верификации, валидации, проверки полноты и адекватности полученной модели. Например, создание цифрового двойника человека или даже животного остается трудно реализуемой на текущем уровне технологий задачей [5]. В области создания цифровых теней и двойников оборудования и технических систем, наоборот, наблюдается прогресс за счет использования в качестве основы формализованных закономерностей их функционирования.

Процедура формирования цифровых теней сопряжена со сбором и обработкой больших объемов информации. Необходима формализация данного процесса, выработка единого подхода к созданию цифровых теней. Рассмотрим несколько примеров реализации цифровых теней и двойников. В исследовании [6] представлена концепция цифрового двойника для решения задачи повышения прозрачности процесса закупок между компаниями. Из результатов описания их практической деятельности можно сделать выводы о том, что структура данных является главной частью

системы, которая закладывает необходимый фундамент для реализации цифрового двойника, как инструмента анализа и прогноза работы реально функционирующей системы. Реализация цифровой тени робота-сборщика кабин является центральной темой исследования в статье [7]. Целью реализации данной технологии на производстве была необходимость предсказания и предотвращения возникновения аномалий в функционировании роботов, что потребовало осуществить всесторонний сбор данных о функционировании как роботов, так и среды вокруг них.

В области формирования цифровых теней человека можно говорить о прогрессе в моделировании только отдельных составляющих: фрагментов тела или отдельных действий. Так, например, в работе [8] реализована комплексная модель скелетно-мышечной системы, которая воспроизводит реалистичные движения человека в соответствии с динамикой мышечных сокращений. Авторами реализован алгоритм имитации обучения, который может работать с 346 мышцами тела для моделирования различных сценариев перемещения, включая деформацию костей, мышечную слабость, использование протеза. Несмотря на то, что полученная модель является искусственно сгенерированной и отличается от реальной скелетно-мышечной системы, подобные цифровые тени и двойники даже с учетом допущений могут найти применение при решении многих задач (прототипирование, тестирование, имитация деятельности человека в виртуальном пространстве) [9, 10]. В работе [11] рассматривается цифровой двойник человека, выполняющего операции на складе. Предложенная авторами архитектура используется для передачи данных о реальных действиях сотрудника, собранных с помощью набора датчиков, в информационную систему для формирования виртуального аватара. Действия аватара оцениваются с целью улучшения и оптимизации эргономики складских операций без прерывания реального производственного процесса.

Из анализа рассмотренных исследований сделан вывод о том, что вопрос формализации процесса формирования цифровой тени для некоторого произвольного объекта, в частности человека, проработан недостаточно. В вышеперечисленных исследованиях используются различные подходы, акцентирующие внимание на практическом использовании существующих технологий (компьютерное зрение или датчики), но не на формализации методологического подхода. Применение цифровых теней в системах, построенных на базе виртуальной реальности, открывает новые возможности по имитации

объектов и процессов реального мира, тестированию нового оборудования в виртуальных условиях, созданию более совершенных информационных систем, приближенных по своим характеристикам к реальным [12].

В качестве предметной области мы рассматриваем человеко-машинные системы, где создание цифровой тени отдельных процессов взаимодействия человека с техническими или программными комплексами является актуальной задачей. Для создания такой цифровой тени необходимо сформулировать алгоритм сбора и обработки больших объемов информации от систем захвата движений, которые осуществляют отслеживание перемещения человека. Необходимо принять во внимание, что данные с различных датчиков захвата движений не учитывают индивидуальное строение каждого человека, могут передаваться с ошибками и отклонениями [13]. Также при создании новых систем (например, беговых платформ, костюмов и т. д.) для виртуального пространства необходимо проведение множества новых тестов непосредственно с участием человека в качестве пользователя. Создание цифровой тени процесса перемещения человека может упростить решение этих проблем за счет анализа накопленных экспериментальных данных и их сравнения с получаемыми новыми данными. Эта задача также имеет актуальность при имитации движений человека в виртуальном пространстве, тестировании программно-аппаратных комплексов, функционирующих на основе действий человека, а также в различных системах опорно-двигательной реабилитации [14].

Задача исследования состоит в разработке метода формирования цифровой тени процесса перемещения, что является важным аспектом создания виртуальных тренажерных комплексов, систем адаптивного перемещения, опорно-двигательной реабилитации, где точность воспроизведения поведения человека имеет большое значение.

2. Метод формирования цифровой тени процесса перемещения. Построение цифровой тени связано со сбором большого объема данных для получения закономерностей функционирования процесса или объекта и последующей программной реализации в виде некоторой платформы. Для ее создания необходимо формализовать основные этапы формирования цифровой тени, начиная от автоматизированного сбора и анализа исходных данных из различных источников и заканчивая программной реализацией цифрового представления физического объекта или процесса.

Анализируя различные подходы к фиксации движений человека, можно схематично отразить процесс формирования цифровой тени в данной предметной области следующим образом (рисунок 1).




Рис. 1. Схема формирования цифровой тени процесса перемещения

Первый этап метода основан на объединении различных подходов к отслеживанию состояния человека в процессе перемещения. В рамках данного исследования мы выделяем следующие направления на этом этапе:

- отслеживание траекторий движений человека с использованием костюма захвата движения (Perseption Neuron, система захвата движения на основе инерциальных датчиков [15]), позволяющего зафиксировать изменение положения 59 сегментов тела человека относительно базовой (опорной) точки. Недостатком данного подхода является отсутствие информации об абсолютном значении положения человека в трехмерном пространстве и высокая вероятность возникновения искажений в данных при близком расположении к источнику электромагнитных помех;

- высокоточное отслеживание ключевых точек человека с использованием трекеров и контроллеров виртуальной реальности, обладающих низкой погрешностью измерения в зоне видимости

базовых станций (до 9x9 метров) [16, 17]. В случае выхода из зоны видимости базовых станций или их перекрытии возможна потеря сигнала от датчиков, что ведет к получению некорректных данных; размеры и масса трекеров ограничивают возможное количество закрепленных на человеке датчиков;

– применение технологий компьютерного зрения на основе одной камеры, стереокамер или системы из нескольких синхронизированных камер для получения скорректированных и более точных данных о положении человека в трехмерном пространстве при помощи распознавания ключевых точек тела человека, в том числе пальцев и лица [18 – 20]. При использовании данного инструмента возникают проблемы с распознаванием ключевых фрагментов силуэта человека при быстром движении объекта или слабой освещенности в кадре.

Сравнение трех подходов захвата движений по объективным метрикам представлено в таблице 1.

Таблица 1. Сравнение подходов к захвату движений

	Набор камер	Трекеры VR	Костюм motion capture
Зона отслеживания	Ограничена видимостью камеры и освещенностью	От 1.5x2 м до 9x9 м	Радиус до 150 м
Максимальное количество точек отслеживания	От 17 до 33 (зависит от алгоритма распознавания). Возможно отслеживание точек рук (до 21), ног (до 8) и лица (до 468)	От 1 до N (зависит от количества N трекеров, максимум 68)	От 12 до 32
Точность позиционирования	От ± 5мм до ± 40мм. Ухудшается при удалении от камеры	±0.7 мм	± 1мм
Скорость получения данных	От 15 до 120 раз в секунду	От 60 до 120 раз в секунду	До 250 раз в секунду
Структура данных	Массив 2D или 3D точек	Три значения координаты (по осям X, Y, Z), три значения угла поворота (по осям X, Y, Z)	Три значения углов поворота сегмента (по осям X, Y, Z), координаты сегмента (по осям X, Y, Z)

В результате представленного сравнительного анализа необходимо отметить невозможность использования единственного

метода отслеживания движений человека. Наличие рассмотренных недостатков перечисленных инструментов приводит к необходимости при формировании цифровой тени процесса перемещения применения комплексного подхода к сбору и обработке исходной информации. Таким образом, на втором этапе создания цифровой тени формируется программно-аппаратный комплекс для сбора данных о состоянии человека в процессе перемещения из трех различных источников, что позволит компенсировать слабые стороны каждого из инструментов за счет остальных.

При объединении данных, полученных с разных источников и имеющих различные форматы и объем, частоту получения и область анализа, необходимо обеспечить их синхронизацию и согласованность. Для этого на третьем этапе метода необходимо осуществить математическое описание цифровой тени процесса перемещения, используя верифицированный математический аппарат. Это позволит формализовать процессы сбора, обработки и анализа данных, а также процедуру их объединения в единый объект для получения исчерпывающей информации об исследуемом процессе.

На финальном этапе выявленные закономерности и сформулированные соотношения преобразуются в программную реализацию цифровой тени, которая и является ожидаемым результатом работы метода. Поведение цифровой тени в виртуальном пространстве за счет обработки и обобщения больших объемов собранных данных о реальном процессе перемещения соответствует реальному объекту, что позволяет использовать ее для имитации поведения человека, тестирования новых объектов и моделирования процессов без необходимости проведения натуральных экспериментов.

В дальнейших исследованиях возможна интеграция дополнительного аппаратного обеспечения для сбора данных о физическом состоянии человека в процессе перемещения или иной двигательной активности. Это оборудование может использоваться для анализа относительной величины напряжения, полученной от закрепленных на ключевых мышцах датчиков ЭМГ, измерения частоты пульса и дыхания, а также исследования электрической активности кожи, отражающей стрессовую реакцию пользователя в процессе контроля тревоги [21]. Полученный массив данных может привести к формированию расширенной цифровой тени человека, применимой уже в более широких классах задач. Однако объединение систем захвата движений и медицинского оборудования для сбора данных о состоянии человека в процессе двигательной активности является темой отдельного исследования.

Таким образом, первый и второй этапы метода не вызывают затруднений и неоднократно рассмотрены в различных исследованиях и на практике [22, 23]. На третьем этапе необходимо проведение дополнительных исследований для разработки формализованного (например, теоретико-множественного) представления цифровой тени процесса перемещения человека. Это позволит успешно осуществить завершающий этап метода, приводящий к программной реализации цифровой тени.

3. Формализация цифровой тени процесса перемещения человека. В общем случае, математическое описание цифровой тени – это многомерный вектор характеристик объекта/процесса в каждый момент времени. В этот вектор входят как значения входных переменных (внутренних и внешних параметров среды), так и выходные параметры (внутренние и внешние). Тогда для получения такого представления последовательно формализуем в математической форме составляющие процесса перемещения в соответствии со следующими тремя направлениями:

- костюм для захвата движений человека;
- трекеры виртуальной реальности;
- система компьютерного зрения.

Эти компоненты позволяют осуществить сбор данных о процессе движения человека, дублировать и верифицировать данные друг друга. Рассмотрим формализацию процессов сбора и обработки информации от каждого из них.

В результате использования костюма motion capture формируется набор из одной опорной точки и множества расположенных относительно нее сегментов (костей), положение которых указывается при помощи углов наклона по трем осям. При необходимости система позволяет записывать помимо изменения угла поворота датчика также его перемещение относительно предыдущего замера [24].

Пусть задано множество сегментов (костей) $B = \{b_i \mid i = 1..N_b\}$, общим количеством N_b . Для каждого сегмента b_i задано в зависимости от режима 6 или 3 значений:

$$b_i = \langle bx_i, by_i, bz_i, bax_i, bay_i, baz_i \rangle \text{ ИЛИ } b_i = \langle bax_i, bay_i, baz_i \rangle, \quad (1)$$

где bx_i, by_i, bz_i – значения позиции i -го датчика по трем осям, относительно предыдущего замера; bax_i, bay_i, baz_i – значения

поворота i - го датчика по трем осям, относительно предыдущего замера.

Тогда обозначим опорную точку на спине пользователя, как $b_0 = \langle bx_0, by_0, bz_0, bax_0, bay_0, baz_0 \rangle$. Множество сегментов B задается для каждого замера, таким образом, существует соответствие между множеством дискретных отметок времени $T = \{t_j\}$ и множеством значений датчиков B . Так как между сегментами заданы связи, определим порядок их следования и соединения как $OB: B \times B$, являющееся частично упорядоченным множеством. Тогда систему захвата движений на основе motion capture MC представим следующим образом:

$$MC = B \times T. \quad (2)$$

Далее рассмотрим формализацию системы захвата движений на основе трекеров виртуальной реальности VR . Пусть задано N_{tr} трекеров $TR = \{tr_i | i = 1..N_{tr}\}$, каждый из которых характеризуется кортежем:

$$tr_i = \langle tx_i, ty_i, tz_i, tax_i, tay_i, taz_i \rangle, \quad (3)$$

где $tx_i, ty_i, tz_i, tax_i, tay_i, taz_i$ – абсолютные значения координат i - го трекера по осям X, Y, Z , а также углы их поворота по этим осям соответственно.

Примем, что по умолчанию tr_0 размещается на спине пользователя, tr_1 и tr_2 – на ногах, tr_3 и tr_4 – на руках (либо являются контроллерами, которые пользователь держит в руках).

Аналогично (2) система захвата движений VR примет вид:

$$VR = TR \times T. \quad (4)$$

Формализация системы захвата движений на основе компьютерного зрения CV включает ряд дополнительных этапов, так как изначально данными для этого подхода является кадр (или набор кадров), на которых необходимо осуществить распознавание человека и его ключевых точек [25]. Поэтому на первом этапе необходимо осуществить следующее преобразование для каждого кадра f с целью получения набора точек $P = \{p_i\}$:

$$f \rightarrow P, \quad (5)$$

$$p_i = \langle px_i, py_i, pz_i \rangle. \quad (6)$$

где px_i, py_i, pz_i – координаты точки p_i в кадре f по трем осям.

Реализация (5) возможна с применением различных инструментов, основанных, например, на нейронных сетях. Такие библиотеки как MediaPipe, BlazePose, PoseNet, MoveNet [26, 27] и другие позволяют определить на кадре силуэт человека и выделить от 17 до 33 точек с возможностью расширения этого количества за счет выделения ключевых точек лица, пальцев и т.д. Схема расположения точек вдоль тела человека зависит от выбранного метода, но всегда включает опорные точки рук, ног, туловища и головы. Большинство моделей нейронных сетей осуществляет позиционирование точек по двум координатам (X и Y) из-за сложности оценки глубины при использовании камеры. Ряд алгоритмов (например, MediaPipe) имитирует определение координаты pz_i относительно некоторой опорной точки, но это значение является неточным и не позволяет позиционировать объект в пространстве. Поэтому для устранения данной проблемы необходимо обеспечить вычисление положения человека в пространстве по всем трем осям с использованием нескольких (минимум двух) камер следующим образом:

$$\begin{aligned} px_i &= cx_i^1/kx, \\ py_i &= (cy_{\max} - 0.5(cy_i^1 + cy_i^2))/ky, \\ pz_i &= (cx_{\max} - cx_i^2)/kx, \end{aligned} \quad (7)$$

где cx_i^1 и cx_i^2 – положение точки p_i на первой и второй камере соответственно по оси X; cy_i^1 и cy_i^2 – положение точки p_i на первой и второй камере соответственно по оси Y; cx_{\max} и cy_{\max} – максимальные значения пикселей по осям X и Y; kx и ky – коэффициенты для перевода пикселей в метры.

Помимо непосредственно ключевых точек скелета человека, распознанных алгоритмами компьютерного зрения, значение имеют углы между ребрами, соединяющими эти точки. Введем следующие

обозначения $PA = \{pa_i\}$ – множество ребер распознанного силуэта человека, где каждому ребру соответствует пара связанных точек:

$$pa_i = \langle p_i, p_k \rangle, i \neq k. \quad (8)$$

Между элементами множества PA и множеством костей B можно сформировать следующее однозначное соответствие:

$$(\forall pa_i) \exists (pa_i \rightarrow b_k), \quad (9)$$

причем отношение, заданное между PA и B , является инъективным (различным pa_i соответствуют различные b_k), но не сюръективным (так как не для любого b_k существует pa_i). Обозначим как $BP \subseteq B$ подмножество элементов, принадлежащих отношению (9).

Таким образом, получим следующую систему захвата движений:

$$CV = P \times PA \times T. \quad (10)$$

После формализации всех компонентов цифровой тени процесса перемещения необходимо осуществить процесс компоновки данных в единую структуру. Данный метод включает следующие этапы.

Этап калибровки. Получение данных от всех систем захвата движений (MC , VR , CV) в начальный момент времени ($t_0 \in T$). В момент калибровки отслеживаемый человек должен находиться в особой позиции (чаще всего выбирается Т-поза) в течение момента калибровки. После успешного завершения калибровки осуществляется формирование начальной (нулевой) точки h_0 по следующим правилам:

$$h_0 = \langle b_0, tr_0, p_b \rangle, \quad (11)$$

$$p_b = \left\langle \frac{px_{23} + px_{24}}{2}, \frac{py_{23} + py_{24}}{2}, \frac{pz_{23} + pz_{24}}{2} \right\rangle, \quad (12)$$

где p_b – усредненная точка между элементами p_{23} и p_{24} , наиболее близкая к tr_0 .

Таким образом, точка h_0 – это объединение элементов: опорной точки b_0 , закрепленного на спине трекера tr_0 и некоторой точки p_0 , наиболее близкой по расположению к tr_0 . Для остальных трекеров tr_i ($i > 0$) устанавливается соответствие между i -им трекером и ближайшей k -ой точкой множества P :

$$\forall tr_i \left(tr_i \rightarrow p_k \mid p_k = \arg \min_P \left(\begin{array}{l} (px_k - tx_i)^2 + \\ (py_k - ty_i)^2 + \\ (pz_k - tz_i)^2 \end{array} \right)^{0.5} \right). \quad (13)$$

Этап отслеживания. Рабочий такт всех систем отслеживания, приводящий к получению их значений в следующий момент времени $t_j \in T$. Полученные данные из-за их различной размерности могут быть нормированы к единому интервалу. Также это позволяет получить для всех элементов разницу между текущим (в момент t_j) и предыдущим (в момент t_{j-1}) состоянием:

$$\Delta B = \left\{ \Delta b_i = \left\langle \begin{array}{l} bx_i - bx_{ij-1}, \\ by_i - by_{ij-1}, \\ bz_i - bz_{ij-1}, \\ bax_{ij} - bax_{ij-1}, \\ bay_i - bay_{ij-1}, \\ baz_i - baz_{ij-1} \end{array} \right\rangle \right\}, \quad (14)$$

$$\Delta TR = \left\{ \Delta tr_i = \left\langle \begin{array}{l} tx_{ij} - tx_{ij-1}, \\ ty_i - ty_{ij-1}, \\ tz_i - tz_{ij-1}, \\ tax_i - tax_{ij-1}, \\ tay_i - tay_{ij-1}, \\ taz_i - taz_{ij-1} \end{array} \right\rangle \right\}, \quad (15)$$

$$\Delta P = \left\{ \Delta p_i = \left\langle \begin{array}{l} px_{ij} - px_{ij-1}, \\ py_i - py_{ij-1}, \\ pz_i - pz_{ij-1} \end{array} \right\rangle \right\}, \quad (16)$$

$$\Delta PA = \left\{ \Delta pa_i = \left\langle \begin{array}{l} pax_{ij} - pax_{ij-1}, \\ pay_i - pay_{ij-1}, \\ paz_i - paz_{ij-1} \end{array} \right\rangle \right\}, \quad (17)$$

где индекс j определяет текущее значение координат или угла для элементов множеств B , TR , P и PA , а индекс $j-1$ – предыдущее значение этих элементов соответственно.

Этап фильтрации. Ввиду несовершенства используемых технических средств возникает возможность появления помех и искажений в собранных данных, вызванных потерей сигнала, электромагнитными помехами, быстрым перемещением человека (в случае компьютерного зрения). Для выявления элемента, значения которого искажены помехами, используются следующие правила:

- для метода MC :

$$\forall (b_i \in BP)(|\Delta b_i| > \beta) \text{ И } (|\Delta pa_k| < \rho), \quad (18)$$

- для метода VR :

$$\forall (tr_i)(|\Delta tr_i| > \tau) \text{ И } (|\Delta p_k| < \varphi), \quad (19)$$

- для метода CV :

$$\forall (p_i, pa_i)(|\Delta pa_k| > \rho \text{ ИЛИ } |\Delta p_k| > \varphi) \text{ И } (|\Delta b_i| < \beta \text{ И } |\Delta tr_i| < \tau), \quad (20)$$

где β – допустимый порог отклонения угла кости в методе захвата MC за время $\Delta t = t_j - t_{j-1}$; ρ – допустимый порог отклонения угла ребра силуэта в методе захвата CV за время Δt ; τ – допустимый порог отклонения перемещения трекера в методе захвата VR за время Δt ; φ – допустимый порог отклонения перемещения точки в методе захвата CV за время Δt .

Нарушение правил (18 – 20) для соответствующего элемента приводит к исключению его из рассмотрения и использованию значений дублирующего его элемента.

Этап синхронизации. Необходимо отметить, что каждый из методов MC, VR, CV осуществляет отправку данных с различными временными интервалами. Время на получение и обработку пакета информации также может значительно отличаться. Это приводит к рассинхронизации информации из различных источников. В рамках данного исследования мы не фокусируемся на этой проблеме, принимая, что на этапе синхронизации пакеты информации от каждого из методов привязаны к текущему времени $t_j \in T$ (при необходимости с выполнением усреднения значений или аппроксимации). Тогда после каждого рабочего такта и фильтрации осуществляется объединение значений в единый массив $ds_j \in DS$, относящийся к времени $t_j \in T$:

$$ds_j = \langle B, TR, P, PA \rangle. \quad (21)$$

Тогда $DS = \{ds_j\}$ – это формализованное представление цифровой тени процесса перемещения.

Так как представленное математическое описание цифровой тени основано на данных, полученных от трех независимых систем захвата движений, оно может обеспечить достаточную полноту решения задачи позиционирования человека в пространстве. Указанные в таблице 1 значения точности позиционирования по выбранным технологиям захвата движений обеспечивают необходимую точность и валидацию получаемых значений для построения цифровой тени.

Таким образом, с использованием теории множеств формализована цифровая тень процесса перемещения человека, включающая процедуры сбора и обработки данных от различных систем захвата движений. Новизна исследования заключается в комплексном подходе к анализу процесса перемещения, синхронизации и фильтрации этих данных для создания цифровой тени.

4. Реализация цифровой тени процесса перемещения человека. После формализации цифровой тени процесса перемещения осуществляется ее реализация в виде программной абстракции. Данный этап включает разработку следующих программных модулей:

1. Модуль сбора данных с костюма захвата движений.
2. Модуль сбора данных с трекеров виртуальной реальности.

3. Модуль компьютерного зрения для распознавания позиции человека в трехмерных координатах.
4. Модуль синхронизации данных.
5. База данных для хранения собранной информации.

Особенности сбора данных отображены на рисунке 2: действия пользователя фиксируются с использованием системы захвата движений, компьютерного зрения и трекеров виртуальной реальности. Для сбора информации используются апробированные программные библиотеки (OpenCV и MediaPipe для компьютерного зрения, OpenVR для получения информации с трекеров и Axis Neuron для костюма захвата движения Perception Neuron), что обеспечивает верификацию разработанного программного обеспечения в области сбора информации.




Рис. 2. Схема сбора данных для формирования цифровой тени

Собранные данные далее обобщаются в цифровую абстракцию с использованием статистических и интеллектуальных методов.

Полученный «черный ящик», повторяющий при известных условиях поведение реального объекта, используется в составе других информационных систем. Цифровая тень тогда может использоваться на этапе тестирования информационной системы, выступая в качестве имитации реального объекта (человека). Кроме того, сохраненная цифровая тень с корректно записанными данными является эталоном, с которым можно сравнивать текущие данные в процессе функционирования системы, взаимодействующей с человеком. Тогда значительное отклонение текущей информации от показателей цифровой тени является индикатором ее некорректности либо сбоя в работе системы.

5. Заключение. Цифровые тени являются перспективным направлением современной промышленности, так как направлены на создание информационных копий объектов и процессов, обобщение больших объемов данных об их функционировании и состоянии при различных условиях. Использование цифровых теней позволяет значительно сократить затраты на проведение научно-исследовательских и конструкторских работ за счет замены реального объекта на его цифровую тень с подобными свойствами. Однако алгоритмическое и математическое обеспечение процесса создания цифровых теней недостаточно регламентировано, отсутствует единый подход к их реализации для различных предметных областей.

В работе представлен метод формирования цифровой тени процесса перемещения человека на основе объединения систем захвата движений, что позволяет получить комплексное представление о перемещении человека при различных условиях внешней среды.

Для реализации метода формализована цифровая тень процесса перемещения, учитывающая сбор и обработку информации от трех различных технологий захвата движения, этапы фильтрации и синхронизации данных, что позволяет сформировать массив данных о перемещении человека в различных условиях. Полученные теоретические результаты используются для реализации программной абстракции цифровой тени процесса перемещения и соответствующих программных модулей сбора, анализа и обработки информации о действиях человека.

Областью применения результатов исследования являются человеко-машинные системы, основанные на анализе процесса перемещения человека. К ним относятся продвинутые тренажерные комплексы с подключаемыми беговыми платформами, системы захвата движений и опорно-двигательной реабилитации.

Литература

1. Grieves M. Origins of the Digital Twin Concept. 2016. URL: <https://www.researchgate.net/publication/307509727> (дата обращения: 03.11.2022).
2. Царев М.В., Андреев Ю.С. Цифровые двойники в промышленности: история развития, классификация, технологии, сценарии использования // Известия высших учебных заведений. Приборостроение. 2021. Т. 64. №. 7. С. 517-531.
3. Kritzinger W. et al. Digital Twin in manufacturing: A categorical literature review and classification // IFAC-PapersOnLine. 2018. vol. 51. no. 11. pp. 1016-1022.
4. Krüger J. et al. Innovative control of assembly systems and lines // CIRP annals. 2017. vol. 66. no. 2. pp. 707-730.
5. Botín-Sanabria D.M. et al. Digital twin technology challenges and applications: A comprehensive review // Remote Sensing. 2022. vol. 14. no. 6. p. 1335.
6. Pause D., Blum M. Conceptual Design of a Digital Shadow for the Procurement of Stocked Products // IFIP International Conference on Advances in Production Management Systems (APMS). IEEE, 2018. pp. 288-295.
7. Srinivasan V. et al. Digital Shadow Model for automated Cabin assembly process. 2021.
8. Lee S. et al. Scalable muscle-actuated human simulation and control // ACM Transactions on Graphics (TOG). 2019. vol. 38. no. 4. pp. 1-13.
9. Park S. et al. Learning predict-and-simulate policies from unorganized human motion data // ACM Transactions on Graphics (TOG). 2019. vol. 38. no. 6. pp. 1-11.
10. Mourot L. et al. A Survey on Deep Learning for Skeleton-Based Human Animation // Computer Graphics Forum. 2022. vol. 41 (1). pp. 122-157.
11. Nikolakis N. et al. The digital twin implementation for linking the virtual representation of human-based production tasks to their physical counterpart in the factory-floor // International Journal of Computer Integrated Manufacturing. 2019. vol. 32. no. 1. pp. 1-12.
12. Gagneré G., Ternova A. A CAstelet in Virtual reality for shadOw AVatar (CAVOV) // ConVRgence (VRIC) Virtual Reality International Conference Proceedings. Simon Richir (dir.). International Journal of Virtual Reality. 2020. vol. 3316.
13. Liu S., Zhang J., Zhang Y., Zhu R. A wearable motion capture device able to detect dynamic motion of human limbs // Nature communications. 2020. vol. 11. no. 1. pp. 1-12.
14. Богомолов А.В. Информационные технологии цифровой адаптационной медицины // Информатика и автоматизация. 2021. Т. 20. №. 5. С. 1154-1182.
15. Wu Y. et al. A Comprehensive Analysis of the Validity and Reliability of the Perception Neuron Studio for Upper-Body Motion Capture // Sensors. 2022. vol. 22. no. 18. pp. 6954.
16. Niehorster D.C., Li L., Lappe M. The accuracy and precision of position and orientation tracking in the HTC vive virtual reality system for scientific research // i-Perception. 2017. vol. 8. no. 3. pp. 2041669517708205.
17. Ikbal M.S., Ramadoss V., Zoppi M. Dynamic pose tracking performance evaluation of HTC Vive virtual reality system // IEEE Access, 2020. vol. 9. pp. 3798-3815.
18. Cherkasov K.V. et al. The use of open and machine vision technologies for development of gesture recognition intelligent systems // Journal of Physics: Conference Series, IOP Publishing. 2018. vol. 1015. no. 3. pp. 032166.
19. Moeslund T.B., Hilton A., Krüger V. A survey of advances in vision-based human motion capture and analysis // Computer vision and image understanding. 2006. vol. 104. no. 2-3. pp. 90-126.
20. Hellsten T. et al. The Potential of Computer Vision-Based Marker-Less Human Motion Analysis for Rehabilitation // Rehabilitation Process and Outcome. 2021. vol. 10. pp. 11795727211022330.

21. Mekruksavanich S., Hnoohom N., Jitpattanakul A. A Deep Residual-based Model on Multi-Branch Aggregation for Stress and Emotion Recognition through Biosignals // 2022 19th International Conference on Electrical Engineering / Electronics, Computer, Telecommunications and Information Technology (ECTI-CON). IEEE, 2022. pp. 1-4.
22. Zielinski E. Live Perception and Real Time Motion Prediction with Deep Neural Networks and Machine Learning // Diss. Harvard University. 2021.
23. Ohri A., Agrawal S., Chaudhary G.S. On-device Realtime Pose Estimation & Correction // International Journal of Advances in Engineering and Management (IAEM). 2021.
24. Choo C.Z.Y., Chow J.Y., Komar J. Validation of the Perception Neuron system for full-body motion capture // PloS one. 2022. vol. 17. no. 1. pp. e0262730.
25. Obukhov A. et al. Organization of Three-Dimensional Gesture Control Based on Machine Vision and Learning Technologies // Computer Science On-line Conference. Springer, Cham, 2022. pp. 70-81.
26. Bazarevsky V. et al. BlazePose: On-device real-time body pose tracking // arXiv preprint arXiv: 2006.10204. 2020.
27. Chen Y. et al. Adversarial poseNet: A structure-aware convolutional network for human pose estimation // Proceedings of the IEEE International Conference on Computer Vision, 2017. pp. 1212-1221.

Обухов Артем Дмитриевич — д-р техн. наук, руководитель лаборатории, управление фундаментальных и прикладных исследований, Тамбовский государственный технический университет. Область научных интересов: адаптивные информационные системы, структурно-параметрический синтез, нейронные сети, машинное обучение. Число научных публикаций — 214. obuhov.art@gmail.com; улица Советская, 106, 392000, Тамбов, Россия; р.т.: +7(915)867-6915.

Волков Андрей Андреевич — младший научный сотрудник, управление фундаментальных и прикладных исследований, Тамбовский государственный технический университет. Область научных интересов: информационные технологии, архитектуры информационных систем, распределенные системы управления. Число научных публикаций — 25. didim@eclabs.ru; улица Советская, 106, 392000, Тамбов, Россия; р.т.: +7(953)703-0619.

Вехтева Надежда Андреевна — младший научный сотрудник, управление фундаментальных и прикладных исследований, Тамбовский государственный технический университет. Область научных интересов: информационные технологии, 3D моделирование, адаптивные информационные системы. Число научных публикаций — 16. magicanloner@gmail.com; улица Советская, 106, 392000, Тамбов, Россия; р.т.: +7(908)298-1042.

Патутин Кирилл Игоревич — младший научный сотрудник, управление фундаментальных и прикладных исследований, Тамбовский государственный технический университет. Область научных интересов: компьютерное зрение, машинное обучение, нейронные сети. Число научных публикаций — 14. kirill-patutin@mail.ru; улица Советская, 106, 392000, Тамбов, Россия; р.т.: +7(915)862-7022.

Назарова Александра Олеговна — техник-программист, управление фундаментальных и прикладных исследований, Тамбовский государственный технический университет. Область научных интересов: информационные технологии, разработка программного обеспечения, виртуальная реальность, анализ данных. Число

научных публикаций — 12. nazarova.al.ol@yandex.ru; улица Советская, 106, 392000, Тамбов, Россия; р.т.: +7(920)496-3910.

Дедов Денис Леонидович — канд. техн. наук, старший научный сотрудник, управление фундаментальных и прикладных исследований, Тамбовский государственный технический университет. Область научных интересов: виртуальные тренажерные комплексы, обучение персонала, информационные технологии, адаптивные информационные системы. Число научных публикаций — 117. hammer68@mail.ru; улица Советская, 106, 392000, Тамбов, Россия; р.т.: +7(915)672-9838.

Поддержка исследований. Исследование выполнено за счет гранта Российского научного фонда № 22-71-10057, <https://rscf.ru/project/22-71-10057/>.

A. OBUKHOV, A. VOLKOV, N. VEKHTOVA, K. PATUTIN, A. NAZAROVA,
D. DEDOV

THE METHOD OF FORMING A DIGITAL SHADOW OF THE HUMAN MOVEMENT PROCESS BASED ON THE COMBINATION OF MOTION CAPTURE SYSTEMS

Obukhov A., Volkov A., Vekhtova N., Patutin K., Nazarova A., Dedov D. The Method of Forming a Digital Shadow of the Human Movement Process Based on the Combination of Motion Capture Systems.

Abstract. The article deals with the problem of forming a digital shadow of the process of moving a person. An analysis of the subject area was carried out, which showed the need to formalize the process of creating digital shadows to simulate human movements in virtual space, testing software and hardware systems that operate on the basis of human actions, as well as in various systems of musculoskeletal rehabilitation. It was revealed that among the existing approaches to the capture of human movements, it is impossible to single out a universal and stable method under various environmental conditions. A method for forming a digital shadow has been developed based on combining and synchronizing data from three motion capture systems (virtual reality trackers, a motion capture suit, and cameras using computer vision technologies). Combining the above systems makes it possible to obtain a comprehensive assessment of the position and condition of a person regardless of environmental conditions (electromagnetic interference, illumination). To implement the proposed method, a formalization of the digital shadow of the human movement process was carried out, including a description of the mechanisms for collecting and processing data from various motion capture systems, as well as the stages of combining, filtering, and synchronizing data. The scientific novelty of the method lies in the formalization of the process of collecting data on the movement of a person, combining and synchronizing the hardware of the motion capture systems to create digital shadows of the process of moving a person. The obtained theoretical results will be used as a basis for software abstraction of a digital shadow in information systems to solve the problems of testing, simulating a person, and modeling his reaction to external stimuli by generalizing the collected data arrays about his movement.

Keywords: digital shadows, human movement process, motion capture systems, mathematical model, virtual reality.

References

1. Grieves M. Origins of the Digital Twin Concept. 2016. Available at: <https://www.researchgate.net/publication/307509727> (accessed 03.11.2022).
2. Carev M.V., Andreev Yu.S. [Digital twins in industry: development history, classification, technologies, use cases] Cifrovye dvojniki v promyshlennosti: istoriya razvitiya, klassifikatsiya, tekhnologii, scenariy ispolzovaniya – [Journal of Instrument Engineering] Izvestiya vysshikh uchebnykh zavedeniy. Priborostroenie. 2021. vol. 64. no. 7. pp. 517-531. (In Russ.).
3. Kritzinger W. et al. Digital Twin in manufacturing: A categorical literature review and classification. IFAC-PapersOnLine. 2018. vol. 51. no. 11. pp. 1016-1022.
4. Krüger J. et al. Innovative control of assembly systems and lines. CIRP annals. 2017. vol. 66. no. 2. pp. 707-730.
5. Botín-Sanabria D.M. et al. Digital twin technology challenges and applications: A comprehensive review. Remote Sensing. 2022. vol. 14. no. 6. p. 1335.

6. Pause D., Blum M. Conceptual Design of a Digital Shadow for the Procurement of Stocked Products. IFIP International Conference on Advances in Production Management Systems (APMS). IEEE, 2018. pp. 288-295.
7. Srinivasan V. et al. Digital Shadow Model for automated Cabin assembly process. 2021.
8. Lee S. et al. Scalable muscle-actuated human simulation and control. ACM Transactions on Graphics (TOG). 2019. vol. 38. no. 4. pp. 1-13.
9. Park S. et al. Learning predict-and-simulate policies from unorganized human motion data. ACM Transactions on Graphics (TOG). 2019. vol. 38. no. 6. pp. 1-11.
10. Mourot L. et al. A Survey on Deep Learning for Skeleton-Based Human Animation. Computer Graphics Forum. 2022. vol. 41. vol. 1. pp. 122-157.
11. Nikolakis N. et al. The digital twin implementation for linking the virtual representation of human-based production tasks to their physical counterpart in the factory-floor. International Journal of Computer Integrated Manufacturing. 2019. vol. 32. no. 1. pp. 1-12.
12. Gagneré G., Ternova A. A Castelet in Virtual reality for shadOw AVatar (CAVOV). ConVRgence (VRIC) Virtual Reality International Conference Proceedings. Simon Richir (dir.). International Journal of Virtual Reality. 2020. vol. 3316.
13. Liu S., Zhang J., Zhang Y., Zhu R. A wearable motion capture device able to detect dynamic motion of human limbs. Nature communications. 2020. vol. 11 no. 1. pp. 1-12.
14. Bogomolov A.V. [Information technologies of digital adaptive medicine] Информационные технологии цифровой адаптивной медицины – [Informatics and automation] Информатика и автоматизация. 2021. vol. 20. no. 5. pp. 1154-1182. (In Russ.).
15. Wu Y. et al. A Comprehensive Analysis of the Validity and Reliability of the Perception Neuron Studio for Upper-Body Motion Capture. Sensors. 2022. vol. 22. no. 18. pp. 6954.
16. Niehorster D.C., Li L., Lappe M. The accuracy and precision of position and orientation tracking in the HTC vive virtual reality system for scientific research. i-Perception. 2017. vol. 8. no. 3. pp. 2041669517708205.
17. Ikbal M.S., Ramadoss V., Zoppi M. Dynamic pose tracking performance evaluation of HTC Vive virtual reality system. IEEE Access, 2020. vol. 9. pp. 3798-3815.
18. Cherkasov K.V. et al. The use of open and machine vision technologies for development of gesture recognition intelligent systems. Journal of Physics: Conference Series, IOP Publishing. 2018. vol. 1015. no. 3. pp. 032166.
19. Moeslund T.B., Hilton A., Krüger V. A survey of advances in vision-based human motion capture and analysis. Computer vision and image understanding. 2006. vol. 104. no. 2-3. pp. 90-126.
20. Hellsten T. et al. The Potential of Computer Vision-Based Marker-Less Human Motion Analysis for Rehabilitation. Rehabilitation Process and Outcome. 2021. vol. 10. pp. 11795727211022330.
21. Mekruksavanich S., Hnoohom N., Jitpattanakul A. A Deep Residual-based Model on Multi-Branch Aggregation for Stress and Emotion Recognition through Biosignals. 2022 19th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON). IEEE, 2022. pp. 1-4.
22. Zielinski E. Live Perception and Real Time Motion Prediction with Deep Neural Networks and Machine Learning. Diss. Harvard University. 2021.
23. Ohri A., Agrawal S., Chaudhary G.S. On-device Realtime Pose Estimation & Correction. International Journal of Advances in Engineering and Management (IJAEM). 2021.

24. Choo C.Z.Y., Chow J.Y., Komar J. Validation of the Perception Neuron system for full-body motion capture. *PloS one*. 2022. vol. 17. no. 1. pp. e0262730.
25. Obukhov A. et al. Organization of Three-Dimensional Gesture Control Based on Machine Vision and Learning Technologies. *Computer Science On-line Conference*. Springer, Cham, 2022. pp. 70-81.
26. Bazarevsky V. et al. BlazePose: On-device real-time body pose tracking. *arXiv preprint arXiv:2006.10204*. 2020.
27. Chen Y. et al. Adversarial poseNet: A structure-aware convolutional network for human pose estimation. *Proceedings of the IEEE International Conference on Computer Vision*. 2017. pp. 1212-1221.

Obukhov Artem — Ph.D., Dr.Sci., Head of the laboratory, Department of fundamental and applied research, Tambov State Technical University. Research interests: adaptive information systems, structural-parametric synthesis, neural networks, machine learning. The number of publications — 214. obuhov.art@gmail.com; 106, Sovetskaya St., 392000, Tambov, Russia; office phone: +7(915)867-6915.

Volkov Andrey — Junior researcher, Department of fundamental and applied research, Tambov State Technical University. Research interests: information technologies, information system architectures, distributed control systems. The number of publications — 25. didim@eclabs.ru; 106, Sovetskaya St., 392000, Tambov, Russia; office phone: +7(953)703-0619.

Vekhteva Nadezhda — Junior researcher, Department of fundamental and applied research, Tambov State Technical University. Research interests: information technologies, 3D modeling, adaptive information systems. The number of publications — 16. magicloner@gmail.com; 106, Sovetskaya St., 392000, Tambov, Russia; office phone: +7(908)298-1042.

Patutin Kirill — Junior researcher, Department of fundamental and applied research, Tambov State Technical University. Research interests: computer vision, machine learning, neural networks. The number of publications — 14. kirill-patutin@mail.ru; 106, Sovetskaya St., 392000, Tambov, Russia; office phone: +7(915)862-7022.

Nazarova Alexandra — Programmer technician, Department of fundamental and applied research, Tambov State Technical University. Research interests: information technology, software development, virtual reality, data analysis. The number of publications — 12. nazarova.al.ol@yandex.ru; 106, Sovetskaya St., 392000, Tambov, Russia; office phone: +7(920)496-3910.

Dedov Denis — Ph.D., Senior researcher, Department of fundamental and applied research, Tambov State Technical University. Research interests: virtual training complexes, personnel training, information technologies, adaptive information systems. The number of publications — 117. hammer68@mail.ru; 106, Sovetskaya St., 392000, Tambov, Russia; office phone: +7(915)672-9838.

Acknowledgements. The research was carried out at the expense of the grant of the Russian Science Foundation No. 22-71-10057, <https://rscf.ru/en/project/22-71-10057/>.

В.Ф. Столярова, Т.В. Тулупьева, М.В. Абрамов, В.Б. Салахова
**ВЫЯВЛЕНИЕ ХАРАКТЕРИСТИК ИНДИВИДУАЛЬНОГО
ЧЕЛОВЕЧЕСКОГО КАПИТАЛА СОТРУДНИКОВ
ОРГАНИЗАЦИИ ПО ДАННЫМ САМООТЧЕТОВ О
ПРОФЕССИОНАЛЬНЫХ НАВЫКАХ И ЛИЧНОСТНЫМ
ОСОБЕННОСТЯМ**

Столярова В.Ф., Тулупьева Т.В., Абрамов М.В., Салахова В.Б. Выявление характеристик индивидуального человеческого капитала сотрудников организации по данным самоотчетов о профессиональных навыках и личностным особенностям.

Аннотация. В области рекрутинга и менеджмента персонала существует задача автоматизации процесса оценки характеристик человеческого капитала, учитывающего в том числе особенности личности сотрудника. Статья посвящена вопросу выявления характеристик индивидуального человеческого капитала, имеющих наибольший вклад в некоторые показатели эффективности сотрудника организации, таких как карьерный успех, по данным самоотчетов о профессиональных навыках и ответов на вопросы–утверждения о различных психологических аспектах личности. Предлагается общая структура опросного инструментария, опирающегося на самоотчеты сотрудников, а также формализация предполагаемых методов анализа таких вопросов. Для выявления групп респондентов, обладающих схожими профессиональными навыками, было предложено использовать кластерный анализ, который позволяет сохранить сложную структуру их взаимосвязи. Для выявления личностных особенностей сотрудников из вопросов–утверждений предлагается формировать шкалы и посредством методов современной теории тестирования получить оценки латентной переменной, отражающей личностные особенности. На завершающем этапе исследования предполагается использование аппарата регрессии для оценивания взаимосвязи выявленных кластеров и латентных характеристик личности с тем или иным индикатором успешности сотрудника. Предлагаемый подход представляет собой структуру пилотного исследования, позволяющего выделить характеристики человеческого капитала (профессиональные навыки и особенности личности), обладающие наибольшим вкладом в показатели эффективности сотрудника организации, и направлен на снижение трудозатрат на последующих этапах более подробного и прицельного исследования. Возможности предложенного подхода продемонстрированы на примере данных, собранных среди государственных гражданских служащих различных структур Российской Федерации. В качестве индикатора эффективности сотрудника рассматривается наиболее доступный к наблюдению аспект карьерного успеха, выраженный фактом наличия руководящей должности.

Ключевые слова: оценивание человеческого капитала, кластерный анализ, современная теория тестирования, опросный инструментарий, самоотчет.

1. Введение. Задача оценки характеристик индивида, имеющих наибольший вклад в успех определенной деятельности или функционирования некоторой системы, возникает в различных социоориентированных областях. Например, кредитный скоринг клиентов в сфере банковского обслуживания [1, 2] направлен на выявление благонадежных плательщиков; оценка уровня защищенности

пользователей информационных систем от социоинженерных атак является частью системы кибербезопасности организации [3 – 5]; скоринг водителей используется при оценке риска дорожно–транспортных происшествий [6 – 8].

В области рекрутинга важную роль играют методы оценки человеческого капитала сотрудников при определении потенциала успеха в выбранной сфере деятельности. Корректные и обоснованные решения по найму напрямую влияют на процветание организации [9, 10]. В свою очередь потеря недавно обученных сотрудников или ключевых специалистов всегда сопряжена со значительными издержками со стороны организации [11], и потому управление человеческими ресурсами требует как разработки систем оценки человеческого капитала, так и систем мониторинга производительности сотрудников.

Одной из особенностей подобных систем является многогранность понятия индивидуального человеческого капитала [12], и, соответственно, разнородность характеризующих его факторов. Среди них выделяют как уровень владения профессиональными навыками, так и некоторые психологические особенности личности [9] и когнитивные способности [13]. Кроме того отмечается [13, 14], что в контексте парадигмы Индустрии 4.0 востребованными являются навыки владения техническими инструментами и надпрофессиональные навыки (*soft skills*), которые также относятся к человеческому капиталу сотрудника. В настоящее время существует несколько подходов к измерению человеческого капитала организации [12]: субъективный, приблизительный и прямой. Последний предполагает оценку ненаблюдаемых характеристик человеческого капитала посредством использования уже существующих психометрических шкал и разработки новых. Различают два уровня: микроуровень, который включает оценку факторов *индивидуального* человеческого капитала и их вклада в индикаторы личной успешности сотрудника; и макроуровень, то есть уровень фирмы [15], который заключается в оценке влияния совокупного набора человеческих капиталов сотрудников на эффективность работы организации в целом.

Часто информация о профессиональных успехах сотрудника: пройденных курсах повышения квалификации, завершенных проектах, премировании, а также данные из социальных медиа [11, 16], доступны внутри организации, и могут использоваться для оценки человеческого капитала [11]. Однако опросы и интервью респондентов об их профессиональных навыках также являются ценным источником знаний, который используется, например, в ситуации приема на

работу нового сотрудника или при мониторинге эффективности повышения квалификации. Такие самоотчеты являются составной частью современных подходов к оценке эффективности сотрудников, выявлению ключевых черт их человеческого капитала, как например, в методике 360 градусов (360 degrees feedback) [18], и используются в комбинации с экспертной информацией. Кроме того, сведения о надпрофессиональных навыках сотрудника и его психологических особенностях извлекаются при помощи специализированных тестов, часто основанных на вопросах—утверждениях, результаты которых также важно учитывать при оценивании человеческого капитала. Такие данные используются при исследовании различных аспектов труда, например, его ценностно–мотивационных основ [19].

Таким образом, актуальной является задача разработки методов и подходов к оцениванию человеческого капитала сотрудников, позволяющих использовать информацию из разных источников, а также автоматизации сбора и анализа такой информации.

Для оценивания характеристик человеческого капитала используются методы машинного обучения [11, 16, 17], в том числе и *кластерный анализ* [16, 20], который направлен на выделение схожих по характеристикам групп сотрудников, и *регрессионный анализ* — для построения предсказательных моделей. Кластерный анализ, к примеру, лежит в основе систем ранжирования младшего медицинского персонала [21], оценки эффективности использования цифровых инструментов учителями [22]. На макроуровне взаимосвязь между характеристиками человеческого капитала и экономическими показателями часто имеет сложный характер, который затруднительно уловить посредством классических эконометрических моделей, и потому в этой области нашли свое применение нейронные сети [23, 24]. Однако такие модели опираются на уже выявленные наборы характеристик человеческого капитала, ключевых для каждого контекста деятельности предприятия. В этом плане не существует метода оценивания человеческого капитала, общего для всех областей функционирования организации, всегда требуется учитывать особенности конкретного вида деятельности [25]. Например, в сфере государственного и муниципального управления создаются и функционируют различные ассессмент–центры [26, 27], в которых используются разнородные данные для оценки компетенций сотрудников, большое влияние имеет и экспертная информация.

Таким образом, возникает задача выявления наборов и паттернов характеристик индивидуального человеческого капитала,

которые являются ключевыми в контексте деятельности отдельного предприятия и исследуемого показателя эффективности сотрудника (или организации). Подходы к решению поставленной задачи во многом являются эвристическими, и потому разработка методов, допускающих автоматизацию сбора и обработки информации, является актуальной.

Целью исследования является формализация подхода к оценке индивидуального человеческого капитала по данным из самоотчетов сотрудников о профессиональных навыках и психологических аспектах личности, измеренных с помощью вопросов–утверждений, с целью выявления тех характеристик, которые имеют наибольший вклад в значение показателей эффективности. Под эффективностью сотрудника понимается набор разнородных показателей, отражающих «уровень соответствия результатов какой-либо деятельности поставленным задачам» [28], одним из которых является, например, карьерный успех, индикатором которого служит факт наличия руководящей должности. Предлагается использовать кластерный анализ для выявления паттернов среди профессиональных навыков. Этот метод позволяет создать картину взаимосвязей между навыками, критичными для каждой отдельной области. Для выявления латентных характеристик личности, отраженных в ответах на вопросы–утверждения, предлагается использовать подход современной теории тестирования. На последнем этапе используется модель регрессии для выявления тех факторов человеческого капитала, которые несут наибольший вклад в некоторую характеристику эффективности сотрудника или организации, как карьерный успех. Предлагаемый подход представляет собой структуру пилотного исследования, результаты которого позволяют сконцентрироваться на наиболее важных в контексте конкретного показателя эффективности и области функционирования организации факторах человеческого капитала при разработке дальнейших этапов исследований. Кроме того, предложенный подход позволяет автоматизировать сбор информации о факторах человеческого капитала, и частично автоматизировать процесс обработки полученных данных. Возможности применения этого подхода продемонстрированы на примере пилотного опроса, предложенного государственным гражданским служащим.

Полученный в рамках исследования результат является новым в области оценивания человеческого капитала государственных гражданских служащих и составляет базу для дальнейшего изучения детерминант индивидуального человеческого капитала в этой области деятельности, равно как для разработки методов оценивания взаимосвязи человеческого капитала организации и ее эффективности. В области

информатики и автоматизации новой является формализация задачи выявления характеристик человеческого капитала сотрудников организации по данным самоотчетов, а также сформулированный подход к автоматизации процесса анализа полученных данных с целью определения тех факторов, которые оказывают наибольшее влияние.

2. Используемые методы. Для выявления групп схожих по самооценке профессиональных навыков респондентов предлагается использовать кластерный анализ, для формирования психометрических шкал — анализ ответов в рамках современной теории тестирования (Item Response Theory).

2.1. Кластерный анализ. Кластерный анализ относится к методам машинного обучения без учителя и позволяет выделять паттерны в многомерных таблицах данных. Существуют множество методов кластеризации [29], одни из них основаны на анализе матрицы различий объектов (иерархические), другие — на определении оптимального разбиения пространства данных на заданное число кластеров (k -средних и k -медоидов), третьи — на анализе расположения точек пространства данных (DBScan). При работе с категориальными данными, которые часто являются результатом различных опросов, используются иерархический кластерный анализ на основе подходящей метрики или же метод k -медоидов [29].

Ключевым шагом для проведения кластерного анализа является вычисление матрицы различий объектов [20]. Для признаков, измеренных в ранговой шкале, могут использоваться различные метрики, в частности L_1 -метрика Манхэттен. Для векторов $a = \{a_1, a_2, \dots, a_n\}$ и $b = \{b_1, b_2, \dots, b_n\}$, измеренных в порядковой шкале, расстояние между ними выражается как:

$$r_{\text{Manhattan}} = \sum_{i=1}^n |a_i - b_i|.$$

Для кластеризации категориальных данных используются иерархическая кластеризация и кластеризация при помощи k -медоидов [29, 30], который является методом неиерархического разделения пространства данных. Он опирается на известное заранее число определяемых групп и в ходе реализации алгоритма итеративно выполняет поиск заранее заданного числа точек пространства данных, наиболее удаленных друг от друга, причем точки x_i внутри соответствующих им кластеров C имеют минимальный возможный разброс в смысле выбранной метрики $d(\cdot)$:

$$\text{medoid}(C) := \arg \min_{x_i \in C} \sum_{x_j \in C} d(x_i, x_j).$$

Так как центром кластера является одно из наблюдений выборки, медоид, то этот метод кластеризации является более устойчивым к выбросам и робастным по сравнению с методом k -средних [29]. Алгоритм кластеризации методом k -медоидов РАМ является наиболее распространенным, и состоит из следующих шагов (приведено согласно [29]):

1. Случайно выбрать заранее заданное число k точек — начальных медоидов из выборки объема N .

2. Отнести все остальные наблюдения к ближайшему начальному медоиду согласно матрице расстояний и вычислить штраф, который является суммой расстояний всех точек кластера до его медоида.

3. Для каждого медоида k из множества $1 \dots K$ рассмотреть все остальные $N - K$ точек, и вычислить для каждой такой точки o штраф (как в пункте 2).

4. Выбрать в качестве медоида ту точку, которая дает наименьшее значение штрафа из всех.

5. Повторить пункты 2–4 до тех пор, пока медоид не будет меняться.

Существует несколько способов валидации полученных кластеров, например, средняя ширина силуэтов [29] и оценка устойчивости кластера при репликации исходной выборки (метод бутстреп) [31]. Значение силуэта является внутренней метрикой принадлежности объекта кластеру и может использоваться как для определения оптимального числа кластеров, так и для валидации качества кластеризации. Для отдельной точки x_i , отнесенной к кластеру C_k , значение силуэта определяется как:

$$s_i = \frac{b_i - a_i}{\max\{a_i, b_i\}}, \quad (1)$$

где $a_i = \frac{1}{n_k - 1} \sum_{c(j)=k} d(x_i, x_j)$ есть среднее расстояние от x_i до остальных точек из этого же кластера k , а $b_i = \min_{l \neq k} \frac{1}{n_l} \sum_{c(j)=l} d(x_i, x_j)$ есть среднее различие точки x_i с точками из другого ближайшего кластера l . В приведенных формулах n_k и n_l представляют собой число точек в кластерах с номерами n и l соответственно.

Соответственно, средняя ширина силуэтов (average silhouette width) определяется как среднее индивидуальных значений силуэтов.

Метод бутстреп является методом имитационного моделирования, который опирается на создание репликаций исходного набора данных путем формирования новой выборки из исходных элементов, выбранных с повторением. Для валидации результатов кластерного анализа, этот метод используется следующим образом [29]. Пусть D обозначает набор данных, разделенный на K кластеров C_k .

1. Построить бутстреп выборку T^i размера n , определить проверяющее множество $E^i = T^i \cup D$.

2. Вычислить коэффициент соответствия Жаккара s_k^i между оригинальными кластерами C_k и кластерами, выделенными на бутстреп выборке: $C_k^{ET,i}$.

3. Среднее значение коэффициентов $s_k = 1/n \sum s_k^i$ отражает внутреннюю стабильность кластера.

Если значение s_k выше, чем 0.75, то кластер является стабильным, и воспроизводится при различных репликациях исходной выборки.

2.2. Современная теория тестирования (Item Response Theory, теория IRT). Современная теория тестирования [32, 33] возникла для анализа ситуаций, когда при проведении тестирования используются задания разного уровня сложности, при этом требуется учитывать, как респонденты с различными личностными особенностями справляются с каждым вопросом в отдельности. Для этого предполагается что существует некоторая *латентная характеристика* личности, которая отражает паттерн ответов на такие вопросы. Целью методов теории IRT является как оценка этой латентной характеристики, так и анализ вопросов, составляющих психометрическую шкалу. Модели современной теории тестирования используются в самых различных приложениях [34], в том числе при оценке различных характеристик сотрудников организаций [35], измерения состояния здоровья [36], маркетинговых исследованиях [37].

Математическая модель IRT отражает взаимосвязь вопросов теста и латентной характеристики личности. Основными предпосылками использования таких моделей являются:

- существование латентных характеристик респондентов;
- существование доступных для наблюдения факторов, отражающих значения ненаблюдаемых факторов;
- задания, измеряющие такие факторы, независимы для каждого респондента.

В рамках работы используется двухпараметрическая логистическая модель IRT (2PL IRT) [32, 33], увязывающая вероятность положительного ответа на вопрос q_i в дихотомической шкале с латентной характеристикой

θ , имеющей нормальное распределение вероятности, посредством уравнения:

$$P_i(q_i = 1|\theta) = \frac{e^{a_i(\theta - b_i)}}{1 + e^{a_i(\theta - b_i)}},$$

где a_i – параметр дифференцирующей способности (дискриминативности) и b_i – параметр трудности задания.

В рамках исследования модель 2PL IRT использовалась для формирования шкалы и оценивания латентной характеристики. При формировании шкал использовались те характеристики, для которых показатель дискриминативности выше 0.5, что является эвристическим правилом.

3. Формализация подхода к выявлению характеристик человеческого капитала на основании гетерогенных данных из самоотчетов сотрудников. Математически поставленную задачу выявления характеристик человеческого капитала, которые имеют наибольший вклад в индикаторы эффективности сотрудника в контексте деятельности организации, можно сформулировать следующим образом. Пусть для каждого индивида $i \in 1 \dots n$ измеряется набор взаимосвязанных характеристик человеческого капитала $\{x_i^j, j = 1 \dots K\}$ и некоторый индикатор эффективности сотрудника Y_i . Кроме того, вся ситуация разворачивается в некотором внешнем контексте, влияние которого моделируется с помощью случайных величин $E_t, t = 1 \dots T$. Такие внешние факторы могут отражать как и оценку деятельности сотрудника другими сотрудниками (как при опросе в формате методики 360 градусов), так и иные организационные факторы. Требуется построить статистическую модель взаимосвязи паттернов, т.е. подгрупп среди измеренных характеристик человеческого капитала $\{x_i^j, j = 1 \dots K\}$, и значений индикатора эффективности сотрудника Y_i в контексте $E_t, t = 1 \dots T$, и выявить наиболее значимые для конкретной ситуации факторы. Отметим, что переменные, отражающие контекст, также могут требовать предварительного анализа.

Данные самооценки сотрудниками уровня владения профессиональными навыками являются одним из самых простых и дешевых способов получения информации об этом аспекте человеческого капитала. Такие самооценки могут проводиться как при рутинном опросе сотрудников в системах мониторинга, так и при найме на работу, а также являются составной частью существующих методик оценки человеческого капитала. Среди возможных типов вопросов широко распространены

измерения в пятиступенчатой шкале Ликерта, варьирующейся от уровня «не владею навыком» до «имею профессиональные сертификаты, подтверждающие владений навыком». Отметим, что профессиональные навыки, которые составляют человеческий капитал взаимосвязаны друг с другом и формируют паттерны. Поэтому для анализа такой информации в рамках настоящего подхода предлагается использовать кластерный анализ, результат работы которого обладает высокой интерпретируемостью и позволяют сохранить сложную структуру зависимостей паттерна внутри кластера.

Если говорить о психологической составляющей индивидуального человеческого капитала, то существуют различные шкалы для измерения релевантных характеристик личности, при этом они могут быть специфичными для каждой отдельной области функционирования организации. Поэтому на этапе пилотного исследования бывает важно определить те шкалы, которые релевантны в конкретном контексте: сфере деятельности организации. Для этого предлагается использовать вопросы–утверждения. При этом шкалы могут быть как определены экспертным путем для каждой ситуации, так и быть заранее разработанными. Данные, составленные из ответов на такие вопросы–утверждения, представляют собой набор бинарных взаимозависимых переменных, которые отражают латентную переменную – характеристику личности. Для анализа таких данных предлагается использовать подходы современной теории тестирования.

Итак, предлагаемый подход к сбору и анализу данных, получаемых в результате самоотчетов, для использования в задаче оценки человеческого капитала состоит из следующих этапов.

1. Формирование опросного инструментария, в котором респондентам предлагается оценить профессиональные навыки по пятибалльной шкале.

2. Формирование опросного инструментария о психологических особенностях личностей сотрудников на основе вопросов–утверждений (опирающихся на уже известные психометрические шкалы или же разработанные экспертом).

3. Сбор данных, формирование выборки объема n .

4. Формирование на основании данных самоотчетов о профессиональных навыках k классов респондентов, обладающих сходными паттернами профессиональных навыков: $C_i, i = 1 \dots k$.

5. Формирование на основе данных ответов на вопросы–утверждения p психометрических шкал (возможно, уже существующих),

оценка при помощи методов современной теории тестирования значений латентных переменных $L_j, j = 1 \dots p$.

6. Построение статистической модели, увязывающей вектор выявленных факторов человеческого капитала $\mathbf{X} = (C_1, \dots, C_k, L_1, \dots, L_p)$ с некоторым индикатором эффективности сотрудника, как, например, индикаторы его карьерного успеха, \mathbf{Y} , который может быть измерен как в шкале интервалов, так и в шкале категорий. Для того, чтобы выявить наиболее значимые характеристики, можно использовать модель обобщенной линейной регрессии:

$$E(Y|X) = g(\mathbf{X}\beta).$$

В качестве ключевой характеристики капитала могут выступать различные индикаторы, в том числе индикаторы карьерного успеха [38] или экономические показатели деятельности сотрудника, как например уровень заработной платы.

4. Пилотное исследование подхода на данных опросов государственных гражданских служащих Российской Федерации.

В рамках пилотного исследования был проведен опрос среди государственных гражданских служащих различных структур Российской Федерации, в котором респондентов просили оценить навыки владения различными техническими средствами (как например офисные и аналитические программы, базы данных юридической информации и прочее). Кроме того, респондентам были предложены также 300 вопросов–утверждений, которые легли в основу психометрических шкал для оценки характеристик личности. Были получены данные от 371 респондента.

4.1. Выделение кластеров респондентов со сходными паттернами профессиональных навыков. Для выделения групп использовались следующие данные, релевантные для офисных работников.

1. Самооценка уровня профессиональных навыков: ведения деловой переписки (*переписка*); составления официальных документов (*документы*); сложного форматирования документов (*форматирование*); подготовки презентаций (*презентации*); построения инфографики и сложной визуализации данных (*инфографика*); анализа нормативных правовых актов (*НПА*); систематизации и анализа международного опыта (*международный опыт*); обработки больших объемов данных (*обработка данных*); визуализации и анализа статистической информации (*статанализ*); проведения социологических опросов, интервью

(соцопросы); построение моделей в эконометрических пакетах (эконометрика). Уровень навыка оценивался респондентом по пятибалльной шкале, где 1 – отсутствие навыка, 5 – профессиональный уровень (есть подтверждение о прохождении курсов, действующие сертификаты, соответствующий опыт работы).

2. Самооценка уровня владения программными продуктами: MS Word, MS Excel, MS Access, MS Power Point, MS Visio, MS Project, SPSS, STATA, e-Views, Консультант Плюс, Гарант по шкале, аналогичной п.1.

3. Уровень владения английским языком оценивался по шестибалльной шкале, соответствующей общеевропейской шкале компетенции владения иностранным языком (A1 – начальный уровень; A2 – элементарный уровень; B1 – средний уровень; B2 – средне–продвинутый уровень; C1 – продвинутый уровень; C2 – владение в совершенстве).

Все данные трактовались как порядковые величины. Для простоты интерпретации, вместо пяти уровней владения навыком использовались три: 1 – нет опыта или мало опыта (баллы 1 и 2 по исходной шкале опроса), 2 – владение навыком, не подтвержденное сертификатами (баллы 3 и 4 по исходной шкале), 3 – профессиональное владение, подтвержденное сертификатом (соответствует оценке 5 исходной шкалы). Для определения оптимального числа кластеров были вычислены средние значения коэффициентов силуэтов (формула 1) для различного числа кластеров, анализ позволяет выделить два кластера (рисунок 1).




Рис. 1. Средние значения силуэтов для различного числа кластеров при кластеризации алгоритмом k -медоидов, метрика Манхэттен

В таблице 1 представлены медианы и средние значения факторов для двух различных метрик категориальных данных: метрики Манхэттен и корреляционной метрики Кендалла.

Таблица 1. Характеристики выделенных при помощи алгоритма k–медоидов кластеров, метрики Манхэттен и корреляционная метрика. В ячейках указаны медиана (среднее значение) каждой характеристики. Выделены те факторы, которые статистически значимо отличаются между кластерами в отдельной классификации (тест Манна–Уитни, p–значение ниже 0.05)

Характеристики	Классификация I: РАМ, метрика Манхэттен		Классификация II: РАМ, корр. метрика Кендалла	
	кластер I.1	кластер I.2	кластер II.1	кластер II.2
Медоид кластера (номер наблюдения)	196	266	40	57
Переписка	3 (2.74)	2 (2.27)	2 (2.48)	2 (2.34)
Документы	2 (2.36)	2 (1.98)	2 (2.35)	2 (1.8)
Форматирование	2 (2.31)	2 (1.82)	2 (2.1)	2 (1.7)
Презентации	3 (2.87)	2 (2.29)	3 (2.5)	2 (2.46)
Инфографика	2 (2.36)	2 (1.8)	2 (2.1)	2 (1.72)
НПА	2 (2.26)	2 (1.91)	2 (2.17)	2 (1.7)
Международный опыт	2 (2.4)	2 (1.95)	2 (2.25)	2 (1.75)
Обработка данных	3 (2.53)	2 (1.93)	2 (2.25)	2 (1.86)
Статанализ	3 (2.58)	2 (1.99)	2 (2.25)	2 (2.06)
Соопросы	2 (2.4)	2 (2.11)	2 (2.19)	2 (2.26)
Эконометрика	2 (1.76)	1 (1.31)	1 (1.43)	2 (1.52)
MS Word	3 (2.98)	2 (2.34)	3 (2.55)	3 (2.6)
MS Excel	3 (2.65)	2 (2.02)	2 (2.25)	2 (2.19)
MS Access	2 (1.86)	1 (1.21)	1 (1.39)	1 (1.5)
MS Power Point	3 (2.96)	2 (2.28)	3 (2.49)	3 (2.57)
MS Visio	2 (1.69)	1 (1.14)	1 (1.27)	1 (1.43)
MS Project	2 (1.84)	1 (1.20)	1 (1.35)	1 (1.56)
SPSS	2 (1.89)	1 (1.44)	1 (1.53)	2 (1.74)
Stata	1 (1.49)	1 (1.20)	1 (1.24)	1 (1.43)
e-Views	1 (1.2)	1 (1.07)	1 (1.06)	1 (1.21)
Консультант Плюс	3 (2.38)	2 (1.89)	2 (2.2)	1 (1.71)
Гарант	2 (2.19)	2 (1.72)	2 (2.04)	1 (1.48)
Уровень англ.яз.	2 (2.4)	2 (2.22)	2 (2.27)	2 (2.30)

Для валидации выделенных кластеров было проведено имитационное моделирование методом бутстреп, в рамках которого на основе исходного набора данных были сформированы 100 репликаций. На каждом шаге в репликации выборки были выделены два кластера, для которых был рассчитан коэффициент сходства Жаккара с кластерами в исходной классификации [29]. Высокие средние значения коэффициента указывают на стабильность выделения предложенных кластеров. В таблице 2 представлены значения показателей валидации кластеров для

двух рассматриваемых подходов: k-медоидов с метрикой Манхэттен и k-медоидов с корреляционной метрикой Кендалла.

Таблица 2. Значения показателей валидации кластеров для рассматриваемых методов кластеризации

Показатель	Классификация I		Классификация II	
	I.1	I.2	II.1	II.2
Средняя ширина силуэта	0.13	0.19	0.13	0.15
Средний коэффициент Жаккарда, бутстреп, 100 репликаций	0.78	0.89	0.81	0.67

Статистический анализ данных был проведен с помощью системы обработки данных R и пакетов factoextra [20] и fpc [39].

Описание кластеров. Для дальнейшего анализа использовалась классификация I, основанная на метрике Манхэттен, так как различия между двумя группами в этом случае статистически значимы. Классификация II использовалась для подтверждения выводов описания кластеров. Итак, анализ таблицы 1 позволяет выделить следующие особенности двух кластеров.

- Доля респондентов с дипломами, подтверждающими владение заявленными навыками, выше в кластере I.1, чем в кластере I.2, особенно для навыков «переписка», «презентации», «международный опыт», «обработка данных», «статанализ», «соцопросы», «MS Word», «MS Excel», «MS Power Point», «Консультант Плюс».

- Доля респондентов, отмечающих владение навыком без подтверждения сертификатом, выше в кластере I.1, чем в кластере I.2 для навыков: «форматирование», «анализ нормативных правовых актов», «эконометрика», «MS Access», «MS Visio», «MS Project», «SPSS», «Гарант».

- Отметим, что респонденты в кластерах I.1 и I.2 не различаются значительно по уровню владения английским языком (подтверждается классификацией II). Однако не владеют английским языком только респонденты из группы I.2.

- Только респонденты из кластера I.1 обладают профессиональными навыками в области эконометрики (SPSS и e-Views), работы с базами данных (MS Access) и MS Project, а также MS Visio.

- Практически все респонденты из кластера I.1 профессионально владеют продуктами MS Word и MS Excel.

Для иллюстрации таблицы 1 был построен график, представляющий самооценки навыков для каждого индивида (рисунок 2). Чтобы точки не сливались воедино, к значениям 1, 2 и 3 был добавлен небольшой случайный шум, поэтому все точки, расположенные напротив отдельного значения, имеют точно это значение фактора.




Рис. 2. Значения навыков для групп I.1 и I.2 (зашумленные наблюдения)

В целом можно сказать, что к кластеру I.1 относятся более квалифицированные сотрудники, чем к кластеру I.2, в том числе владеющие узкоспециализированными навыками, как работа в статистических пакетах. В пункте 4.3 построена регрессионная модель, позволяющая определить, какой из двух кластеров может служить фактором карьерного успеха сотрудника.

4.2. Формирование шкал личностных особенностей. В рамках пилотного тестирования респондентам были предложены специально разработанные 300 вопросов–утверждений, предполагающих ответ да или нет. Набор вопросов–утверждений был сформирован на основе следующих психологических шкал: комплексный подход Хоган [40], 16-ти факторный опросник Кеттелла [41], личностный тест Маиерс–Бриггс [42]. Ответы на эти вопросы легли в основу нескольких шкал личностных особенностей, отражающих некоторые характеристики личности, определенные экспертами как важные для государственной гражданской службы. Каждая шкала содержит от 5 до 15 вопросов–утверждений.

Каждая из шкал была проанализирована при помощи подхода IRT, в результате чего была получена оценка латентной (ненаблюдаемой) характеристики личности. Для подгонки регрессионной модели 2PL IRT использовался пакет ltm среды статистической обработки данных R [43].

4.3. Выявление факторов человеческого капитала государственных гражданских служащих в контексте их руководящей позиции. В контексте собранного набора данных в качестве ключевого индикатора карьерного успеха сотрудника использовался факт наличия у него руководящей должности. В выборке присутствуют 156 руководителей и 215 не-руководителей. Для выявления тех факторов человеческого капитала, которые вносят значительный вклад в индикаторы карьерной успешности сотрудника, использовался аппарат логистической регрессии. В таблице 3 представлены исходные значения коэффициентов, их доверительные интервалы и уровень значимости, а также экспонированные коэффициенты для простоты интерпретации в терминах отношения шансов. Отметим, что значимыми являются как паттерны профессиональных навыков, выявленные в рамках кластерного анализа (таблица 1), так и латентные характеристики личностных особенностей. В частности, чем выше у человека значение латентных характеристик «лидерских способностей», «моральных качеств», «амбициозности», тем выше шанс, что этот человек занимает руководящую должность. Кроме того, паттерны профессиональных навыков также могут служить индикатором наличия руководящей должности: если человек хорошо владеет офисными и узкоспециализированными программами, то шанс выше. Однако необходима осторожность при интерпретации последней взаимосвязи, так как она может носить и обратный характер: если сотрудник является руководителем, то он имеет больше возможностей для повышения квалификации.

Так как набор данных невелик для 14 переменных, то для выявления тех коэффициентов, для которых могут быть получены оценки, была использована регрессия по методу лассо. Те коэффициенты, которые отличны от нуля при использовании этого метода, отмечены звездочкой в таблице 3.

Построенная только на значимых переменных модель логистической регрессии позволяет классифицировать поступающие данные с точностью 0.63, 95% доверительный интервал: (0.52, 0.72). Коэффициент корреляции D Соммерса между наблюдаемым значением факта наличия руководящей должности и предсказанными логистической регрессией вероятностями составил 0.362, что говорит об умеренной согласованности этих данных. Вычисленные метрики качества классификации указывают на то, что выбранные факторы индивидуального человеческого капитала находят свое отражение в рассматриваемом индикаторе карьерного успеха, однако необходимо

дополнить модель классификации некоторыми другими более релевантными факторами. Действительно, в контексте карьерного успеха основополагающими могут оказаться пол, возраст или же иные факторы, как например, слабые связи сотрудника [44].

Для получения представленных результатов исходная выборка была разбита на тренировочную, состоящую из 264 наблюдений, на которых была подогнана модель логистической регрессии, и тестовую (107 наблюдений), на которой оценивалось качество классификации.

Таблица 3. Значения коэффициентов логистической регрессии, увязывающей факторы человеческого капитала государственных служащих и их руководящую позицию как индикатор карьерного успеха сотрудника

Переменная	Коэффициент (b)	Уровень значимости	Экспонированный коэффициент (exp(b))
* Принадлежность к кластеру 2	-0.998	< 0.001	0.369
Коммуникативный потенциал	-0.431	0.065	0.650
Когнитивный потенциал	0.015	0.937	1.015
Шкала лжи	-0.302	0.165	0.739
* Лидерские способности	0.724	0.015	2.063
* Моральные качества	0.457	0.089	1.579
Предпочтение стабильности	-0.257	0.279	0.773
* Амбициозность	0.537	0.029	1.711
Целеустремленность	-0.172	0.555	0.842
Эмоциональная устойчивость	-0.323	0.179	
Творческий потенциал	-0.165	0.482	0.724
Уверенность в себе	0.026	0.928	1.026
Внимание к финансовому благополучию	-0.113	0.676	0.893

5. Обсуждение. Предложенный подход к оценке факторов человеческого капитала опирается как на экспертную информацию в плане выявления латентных характеристик личности и интерпретации кластеров, так и на конкретные данные. Эти особенности подхода обусловлены тем, что задача оценки человеческого капитала организации зависит от структуры самой организации, области ее функционирования и ключевых индикаторов эффективности ее деятельности. Поэтому в ряде ситуаций прежде, чем определить, какие шкалы использовать при анкетировании сотрудников, необходимо предварительно выявить те характеристики личности и ключевые навыки, которые играют роль для отдельного индикатора эффективности сотрудника и/или организации. Предлагаемый метод является быстрым и недорогим, так как опирается лишь на опросы сотрудников.

Отметим также, что в зависимости от ситуации различной может быть и опора на данные, полученные из самоотчетов, которые могут обладать свойствами неполноты и неточности. Например, информация о профессиональном владении навыками может быть доступна отделам кадров организации без обращения к самоотчетам.

Личностные особенности являются составной частью человеческого капитала и оказывают влияние как на карьерную успешность сотрудника, так и на эффективность деятельности организации. Выявление характеристик личности, важных для каждой отдельной области функционирования организации, является сложной задачей, требующей пилотных исследований и экспертных знаний. В рамках представленного подхода предлагается экспертным путем сформировать набор шкал, складывающихся из вопросов–утверждений, и выявить те, которые имеют наибольший вклад в ключевые показатели эффективности сотрудника или организации. Дальнейшим этапом исследований следует рассматривать формирование психометрических опросов, направленных на обоснованную оценку латентной характеристики личности, выявленной на этапе пилотного исследования.

Отметим, что предложенный подход может использоваться как для выявления ключевых характеристик индивидуального человеческого капитала, так и для оценки человеческого капитала небольших сходных по выполняемым функциям групп сотрудников. Например, если говорить о компетенциях сотрудников государственных гражданских служащих различных структур Российской Федерации, то наличие руководящей должности связано с самооценкой лидерских способностей, опоры на моральные принципы и амбициозностью: руководители оценивают себя выше по этим пунктам, чем не-руководители. При этом сотрудник, занимающий руководящую должность, в целом обладает большим количеством профессиональных навыков, в паттерне которых определяющим являются проведение социологических опросов, обработка данных и построение инфографики, а также использование узкоспециализированных программ как эконометрические пакеты, MS Access, MS Project.

Предложенный подход имеет ряд ограничений. Во-первых, методы, предлагаемые для выявления факторов человеческого капитала, являются описательными, привязанными к конкретному набору данных. Это ограничение связано с тем, что внутри каждой области функционирования предприятия эти факторы являются уникальными, и потому не существует универсального набора показателей. Предлагаемый подход играет роль

своего рода пилотного, для каждой отдельной области требует экспертного анализа. Во-вторых, в рамках предлагаемого подхода предполагается сбор данных в результате длинного опроса, и потому требуется проведение мероприятий по обеспечению достоверности получаемых ответов.

6. Заключение. В статье был предложен подход к выявлению и моделированию факторов индивидуального человеческого капитала, составляющих наибольший вклад в некоторые показатели эффективности, такие как карьерный успех. Предложенный подход предполагает как формирование пилотного набора данных на основе самоотчетов сотрудников об уровне их профессиональных навыков, так и психометрическое тестирование на основе набора вопросов–утверждений.

На первом этапе предполагается формирование опросного инструментария, охватывающего различные профессиональные навыки, используемые сотрудниками подразделения, и включающего ряд вопросов–утверждений, которые отражают ненаблюдаемые особенности личности. На втором этапе проводится анализ собранных данных. Для анализа первого блока данных предлагается использовать кластерный анализ для выявления интерпретируемых паттернов среди используемых навыков. Ответы на вопросы–утверждения предлагается комбинировать при помощи экспертных знаний в психометрические шкалы с использованием модели 2PL современной теории тестирования. Предложенные методы тесно связаны с конкретным набором данных, и имеют ограниченные возможности распространения на уровень популяции, однако обладают высокой интерпретируемостью и устойчивостью в каждой конкретной задаче.

На финальном этапе при помощи регрессионного анализа (или другого метода статистического вывода) предлагается увязывать оцененные факторы индивидуального человеческого капитала с выбранным показателем эффективности сотрудника, как, например, факт наличия руководящей должности.

Предлагаемый подход может использоваться как при найме на работу, так и при рутинной оценке квалификации сотрудников для выявления наиболее перспективных для выполнения руководящих обязанностей. Среди возможных дальнейших направлений исследования можно отметить включение в подход других показателей человеческого капитала, а также развитие методов комбинации характеристик индивидуального человеческого капитала для оценки человеческого капитала самой организации или ее подразделения.

Литература

1. Dastile X., Celik T., Potsane M. Statistical and machine learning models in credit scoring: A systematic literature survey // *Applied Soft Computing*. 2020. vol. 91. pp. 106263.
 2. Djeundje V.B., Crook J., Calabrese R., Hamid M. Enhancing credit scoring with alternative data // *Expert Systems with Applications*. 2021. vol. 163. pp. 113766.
 3. Абрамов М.В., Тулупьева Т.В., Тулупьев А.Л. Социоинженерные атаки: социальные сети и оценки защищенности пользователей. СПб.: ГУАП, 2018. 266 с.
 4. Олисеенко В.Д., Абрамов М.В., Тулупьев А.Л., Иванов К.А. Прототип программного комплекса для анализа аккаунтов пользователей социальных сетей: веб-фреймворк Django // Программные продукты и системы. 2022. Т. 35. № 1. С. 45–53. doi: 10.15827/0236-235X.137.
 5. Khlobystova A., Korepanova A., Maksimov A., Tulupyeva T. An Approach to Quantification of Relationship Types between Users Based on the Frequency of Combinations of Non-numeric Evaluations // *Proceedings of the Fourth International Scientific Conference “Intelligent Information Technologies for Industry” (ITI'19)*. Advances in Intelligent Systems and Computing. 2020. vol. 1156. pp. 206–213.
 6. Kashevnik A., Karelskaya K., Repp M. Dangerous situations determination by smartphone in vehicle cabin: Classification and algorithms // 2019 24th Conference of Open Innovations Association (FRUCT). IEEE, 2019. С. 130–139.
 7. Shirmohammadi H., Hadadi F., Saeedian M. Clustering analysis of drivers based on behavioral characteristics regarding road safety // *International Journal of Civil Engineering*. 2019. vol. 17. no. 8. pp. 1327-1340.
 8. Wang X., Xu X. Assessing the relationship between self-reported driving behaviors and driver risk using a naturalistic driving study // *Accident Analysis Prevention*. 2019. vol. 128. pp. 8–16.
 9. Boudreaux M.J., Ferrell B.T., Hundley N.A., Sherman R.A. A personality-based measure of employability // *Journal of Personnel Psychology*. 2022. vol. 21. no. 1. pp. 11–22.
 10. Sharma M., Luthra S., Joshi S., Kumar A. Analysing the impact of sustainable human resource management practices and industry 4.0 technologies adoption on employability skills // *International Journal of Manpower*. 2022. vol. 43. no. 2. pp. 463–485.
 11. Nicolaescu S.S., Florea A., Kifor C.V., Fiore U., Cocan N., Receu I., Zanetti P. Human capital evaluation in knowledge-based organizations based on big data analytics // *Future Generation Computer Systems*. 2020. vol. 111. pp. 654–667.
 12. Wright P.M., McMahan G.C. Exploring human capital: putting 'human' back into strategic human resource management // *Human resource management journal*. 2012. vol. 21. no. 2. pp. 93–104.
 13. Fajaryati N., Akhyar M. The employability skills needed to face the demands of work in the future: Systematic literature reviews // *Open Engineering*. 2020. vol. 10. no. 1. pp. 595–603.
 14. Smaldone F., Ippolito A., Lagger J., Pellicano M. Employability skills: Profiling data scientists in the digital labour market // *European Management Journal*. 2022. vol. 40. no. 5. pp. 671-684.
 15. Ployhart R.E., Moliterno T.P. Emergence of the human capital resource: A multilevel model // *Academy of management review*. 2011. vol. 36. no. 1. pp. 127–150.
 16. Zhang Y., Xu S., Zhang L., Yang M. Big data and human resource management research: An integrative review and new directions for future research // *Journal of Business Research*. 2021. vol. 133. pp. 34–50.
 17. Liu J. Impact of enterprise human capital on technological innovation based on machine learning and SVM algorithm // *Journal of Ambient Intelligence and Humanized Computing*. 2021. pp. 1-13.
- 208 Информатика и автоматизация. 2023. Том 22 № 1. ISSN 2713-3192 (печ.)
ISSN 2713-3206 (онлайн) www.ia.spcras.ru

18. Fleenor J.W., Taylor S., Chappelow C. Leveraging the impact of 360-degree feedback // Berrett-Koehler Publishers, Incorporated. 2020. 184 p.
19. Эфендиев А.Г., Гоголева А.С., Пашкевич А.В., Балабанова Е.С. Ценностно–мотивационные основы и реальность трудовой жизни российских работников: проблемы и противоречия // Мир России. Социология. Этнология. 2020. 29(2). С. 108–133.
20. Kassambara A. Practical guide to cluster analysis in R: Unsupervised machine learning // STHDA. 2017. 187 p.
21. Forsman H., Jansson I., Leksell J., Lepp M., Sundin Andersson C., Engstrom M., Nilsson J. Clusters of competence: Relationship between self-reported professional competence and achievement on a national examination among graduating nursing students // Journal of Advanced Nursing. 2020. vol. 76. no. 1. pp. 199–208. .
22. Schmid M., Brianza E., Petko D. Self-reported technological pedagogical content knowledge (TPACK) of pre-service teachers in relation to digital technology use in lesson plans // Computers in Human Behavior. 2021. vol. 115. pp. 106586.
23. Yang L., Sang-Bing T. Construction of a Hierarchical Neural Network Power Source Model for Human Capital Technology Innovation and Benefit Distribution with Big Data Analysis // Mathematical Problems in Engineering. 2021. vol. 2021. pp. 3939511.
24. Li X., Zhang P. A research on value of individual human capital of high-tech enterprises based on the bp neural network algorithm // The 19th International Conference on Industrial Engineering and Engineering Management. Berlin: Springer, 2013. pp. 71-79.
25. Baron A. Measuring human capital // Strategic HR Review. 2011. vol. 10. no 2. pp. 30–35.
26. Гончарова Е.А., Рукин К.Н. Использование методики ассесмент-центра при оценке государственных гражданских служащих Липецкой области // Государственная служба. 2021. Т. 23. № 3(131). С. 24–32.
27. Литвина С.А., Еварович С.А. Ассесмент-центр как технология оценки компетенций персонала в практике государственного управления: учебное пособие. Томск: Томский государственный университет, 2013. 104 с.
28. Родионова Е.А. Психологические факторы эффективности сотрудников современного предприятия // Общество. Коммуникация. Образование. 2011. Т. 2. № 124. С. 109–114.
29. Hennig C., Meila M., Murtagh F., Rocci R. (Eds.). Handbook of cluster analysis // CRC Press, 2015. 730 p.
30. Schubert E., Rousseeuw P.J. Faster k–medoids clustering: improving the PAM, CLARA, and CLARANS algorithms // International conference on similarity search and applications. Springer, Cham. 2019. pp. 171–187.
31. Hennig C. Dissolution point and isolation robustness: robustness criteria for general cluster analysis methods // Journal of Multivariate Analysis. 2009. vol. 99. pp. 1154–1176.
32. Крокер Л., Алгина Д. Введение в классическую и современную теорию тестов. Учебник. М.: Логос, 2010. 668 с.
33. Van der Linden W.J. Handbook of Item Response Theory, Volume One: Models. Chapman and Hall/CRC, 2016. 624 p.
34. Van der Linden W.J. Handbook of Item Response Theory, Volume Three: Applications. Chapman and Hall/CRC, 2018. 608 p.
35. Lang J.W., Tay L. The science and practice of item response theory in organizations // Annual Review of Organizational Psychology and Organizational Behavior. 2021. vol. 8. pp. 311–338.

36. Cella D., Choi S.W., Condon D.M., Schalet B., Hays R.D., Rothrock N.E., Yount S., Cook K.F., Gershon R.C., Amtmann D., DeWalt D.A. PROMIS® adult health profiles: efficient short-form measures of seven health domains. *Value in health*. 2019. vol. 22. no. 5. pp. 537–544.
37. De Jong M.G., Pieters R. Assessing sensitive consumer behavior using the item count response technique. *Journal of Marketing Research*. 2019. vol. 56. no. 3. pp. 345–360.
38. Abele A.E., Spurk D., Volmer J. The construct of career success: measurement issues and an empirical example // *ZAF*. 2011. vol. 43. pp. 195–206.
39. Hennig C. fpc: Flexible Procedures for Clustering. R package version 2.2-9. 2020. <https://CRAN.R-project.org/package=fpc>.
40. Hogan R. Hogan development survey manual. Tulsa, OK: Hogan Assessment Systems, 2009. 199 p.
41. Cattell R.B., Cattell H.E.P. Personality structure and the new fifth edition of the 16PF // *Educational and Psychological Measurement*. 1995. vol. 55. no. 6. pp. 926–937.
42. Myers I.B. *The Myers-Briggs Type Indicator: Manual*. Consulting Psychologists Press, 1962. 110 p.
43. Rizopoulos D. An R package for Latent Variable Modelling and Item Response Theory Analyses // *Journal of Statistical Software*. 2006. vol. 17. no. 5. pp. 1–25.
44. Granovetter M. The strength of weak ties: A network theory revisited // *Sociological theory*. 1983. pp. 201–233.

Столярова Валерия Фуатовна — младший научный сотрудник, лаборатория теоретических и междисциплинарных проблем информатики, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН). Область научных интересов: анализ данных, байесовские сети доверия, искусственный интеллект. Число научных публикаций — 40. vfs@dscs.pro; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)328-3337.

Тулупьева Татьяна Валентиновна — канд. психол. наук, доцент, старший научный сотрудник, лаборатория теоретических и междисциплинарных проблем информатики, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН); профессор, Северо-Западный институт управления РАНХиГС. Область научных интересов: психология личности, искусственный интеллект, социальная инженерия, методы обработки данных. Число научных публикаций — 170. tvt@dscs.pro; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)328-3337.

Абрамов Максим Викторович — канд. техн. наук, руководитель лаборатории, лаборатория теоретических и междисциплинарных проблем информатики, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН). Область научных интересов: информационная безопасность, социоинженерные атаки, социокompьютинг. Число научных публикаций — 170. mva@dscs.pro; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: +7(812)328-3337.

Салахова Валентина Борисовна — канд. психол. наук, ведущий научный сотрудник, Центр исследования проблем безопасности РАН; ведущий научный сотрудник, лаборатория гуманной педагогики, Московский городской педагогический университет (МГПУ). Область научных интересов: психология девиантного поведения, психология личности, цифровизация образования. Число научных публикаций — 158. Valentina_naula@mail.ru; улица Гарибальди, 21Б, 117335, Москва, Россия; р.т.: +7(985)221-4051.

V. STOLIAROVA , T. TULUPYEVA , M. ABRAMOV , V. SALAKHOVA
**IDENTIFICATION OF CHARACTERISTICS OF EMPLOYEE'S
INDIVIDUAL HUMAN CAPITAL WITH DATA ON SELF-REPORTS
OF PROFESSIONAL SKILLS AND PERSONAL CHARACTERISTICS**

Stoliarova V., Tulupyeva T., Abramov M., Salakhova V. **Identification of Characteristics of Employee's Individual Human Capital with Data on Self-Reports of Professional Skills and Personal Characteristics.**

Abstract. In the field of recruitment and human resources management, the problem arises of automatization of the assessment process of the characteristics of human capital, taking into account, among other things, the personality characteristics of the employee. The article is devoted to the problem of identification of such characteristics that have the greatest contribution to some indicators of the effectiveness of an employee of an organization with self-reported data on professional skills and answers to questions—statements about various psychological aspects of personality. The general structure of the survey tools based on self-reports of employees is proposed, as well as the formalization of the proposed methods of data analysis. The cluster analysis was used for the identification of groups with similar professional skills. Special psychometric scales based on the questions—statements are selected and analyzed via the item response theory approach, giving the estimates of the latent variable, that reflects personal characteristics. At the final stage of the study, the relationship between the estimated factors (identified clusters and estimated latent variables) and the indicator of employee effectiveness was assessed. As such indicator, the fact of a managerial position was used. The proposed approach is a structure of a pilot study that allows to identify the characteristics of human capital (professional skills and personality traits) that have the greatest contribution to the performance indicators of an employee or organization, and is aimed at reducing labor costs at subsequent stages of a more detailed and targeted study. The possibilities of the proposed approach are demonstrated with data collected among state civil servants in Russia. The fact of having a managerial position is used as an indicator of effectiveness.

Keywords: human capital assessment, cluster analysis, item response theory, questionnaire design, self-report.

References

1. Dastile X., Celik T., Potsane M. Statistical and machine learning models in credit scoring: A systematic literature survey. *Applied Soft Computing*. 2020. vol. 91. pp. 106263.
2. Djeundje V.B., Crook J., Calabrese R., Hamid M. Enhancing credit scoring with alternative data. *Expert Systems with Applications*. 2021. vol. 163. pp. 113766.
3. Abramov M.V., Tulupyeva T.V., Tulupyev A.L. Socioinzhenernye ataki: social'nye seti i ochenki zashhishhennosti pol'zovatelej [Socialengineering attacks: social media and user security assessment]. SPb.: GUAP, 2018. 266 p. (in Russ.).
4. Oliseenko V.D., Abramov M.V., Tulupyev A.L., Ivanov K.A. [A software package prototype for analyzing user accounts insocial networks: Django web framework]. *Programmnye produkty i sistemy – Software Systems*. 2022. vol. 35. no. 1. pp. 45–53. doi: 10.15827/0236-235X.137. (In Russ.).
5. Khlobystova A., Korepanova A., Maksimov A., Tulupyeva T. An Approach to Quantification of Relationship Types between Users Based on the Frequency of

- Combinations of Non-numeric Evaluations. Proceedings of the Fourth International Scientific Conference «Intelligent Information Technologies for Industry» (ITI' 19). Advances in Intelligent Systems and Computing. 2020. vol. 1156. pp. 206–213.
6. Kashevnik A., Karelskaya K., Repp M. Dangerous situations determination by smartphone in vehicle cabin: Classification and algorithms. 2019 24th Conference of Open Innovations Association (FRUCT). IEEE, 2019. pp. 130–139.
 7. Shirmohammadi H., Hadadi F., Saeedian M. Clustering analysis of drivers based on behavioral characteristics regarding road safety. International Journal of Civil Engineering. 2019. vol. 17. no. 8. pp. 1327–1340.
 8. Wang X., Xu X. Assessing the relationship between self-reported driving behaviors and driver risk using a naturalistic driving study. Accident Analysis Prevention. 2019. vol. 128. pp. 8–16.
 9. Boudreaux M.J., Ferrell B.T., Hundley N.A., Sherman R.A. A personality-based measure of employability. Journal of Personnel Psychology. 2022. vol. 21. no. 1. pp. 11–22.
 10. Sharma M., Luthra S., Joshi S., Kumar A. Analysing the impact of sustainable human resource management practices and industry 4.0 technologies adoption on employability skills. International Journal of Manpower. 2022. vol. 43. no. 2. pp. 463–485.
 11. Nicolaescu S.S., Florea A., Kifor C.V., Fiore U., Cocan N., Receu I., Zanetti P. Human capital evaluation in knowledge-based organizations based on big data analytics. Future Generation Computer Systems. 2020. vol. 111. pp. 654–667.
 12. Wright P.M., McMahan G.C. Exploring human capital: putting 'human' back into strategic human resource management. Human resource management journal. 2012. vol. 21. no. 2. pp. 93–104.
 13. Fajaryati N., Akhyar M. The employability skills needed to face the demands of work in the future: Systematic literature reviews. Open Engineering. 2020. vol. 10. no. 1. pp. 595–603.
 14. Smaldone F., Ippolito A., Lagger J., Pellicano M. Employability skills: Profiling data scientists in the digital labour market. European Management Journal. 2022. vol. 40. no. 5, pp. 671-684.
 15. Ployhart R.E., Moliterno T.P. Emergence of the human capital resource: A multilevel model. Academy of management review. 2011. vol. 36. no. 1. pp. 127–150.
 16. Zhang Y., Xu S., Zhang L., Yang M. Big data and human resource management research: An integrative review and new directions for future research Journal of Business Research. 2021. vol. 133. pp. 34–50.
 17. Liu J. Impact of enterprise human capital on technological innovation based on machine learning and SVM algorithm. Journal of Ambient Intelligence and Humanized Computing. 2021. pp. 1–13.
 18. Fleenor J.W., Taylor S., Chappelow C. Leveraging the impact of 360-degree feedback. Berrett-Koehler Publishers, Incorporated, 2020. 184 p.
 19. Efendiev A.G., Gogoleva A.S., Pashkevitch A.V., Balabanova E.S. [The values, Motives and Work life reality of Russian employees: problems and contradictions]. Mir Rossii. Sociologija. Jetnologija – Universe of Russia Sociology, Ethnology. 2020. vol. 29. no. 2. pp. 108–133. (In Russ.).
 20. Kassambara A. Practical guide to cluster analysis in R: Unsupervised machine learning. STHDA, 2017. 187 p.
 21. Forsman H., Jansson I., Leksell J., Lepp M., Sundin Andersson C., Engstrom M., Nilsson J. Clusters of competence: Relationship between self-reported professional competence and achievement on a national examination among graduating nursing students. Journal of Advanced Nursing. 2020. vol. 76. no. 1. pp. 199–208.

22. Schmid M., Brianza E., Petko D. Self-reported technological pedagogical content knowledge (TPACK) of pre-service teachers in relation to digital technology use in lesson plans. *Computers in Human Behavior*. 2021. vol. 115. pp. 106586.
23. Yang L., Sang-Bing T. Construction of a Hierarchical Neural Network Power Source Model for Human Capital Technology Innovation and Benefit Distribution with Big Data Analysis. *Mathematical Problems in Engineering*. 2021. vol. 2021. pp. 3939511.
24. Li X., Zhang P. A research on value of individual human capital of high-tech enterprises based on the bp neural network algorithm. *The 19th International Conference on Industrial Engineering and Engineering Management*. Berlin: Springer, 2013. pp. 71-79.
25. Baron A. Measuring human capital. *Strategic HR Review*. 2011. vol. 10. no 2. pp. 30–35.
26. Goncharova E.A., Rukin K.N. [Using the assessment center methodology while evaluating the civil servants of the Lipetsk region]. *Gosudarstvennaja sluzhba – Public Administration*. 2021. vol. 23. no. 3(131). pp. 24–32. (in Russ).
27. Litvina S.A., Yevarovich S.A. Assessment-centr kak tehnologiya ocenki kompetencii personala v praktike gosudarstvennogo upravleniya [Assessment Center as a technology for assessing the competencies of personnel in the practice of public administration]. *Tomsk: Tomsk State University*, 2013. 104 p. (in Russ).
28. Rodionova E.A. Psychological factors of efficiency of employees of a modern enterprise. *Obshhestvo. Kommunikacija. Obrazovanie – Society. Communication. Education*. 2011. vol. 2. no. 124. pp. 109–114. (in Russ).
29. Hennig C., Meila M., Murtagh F., Rocci R. (Eds.). *Handbook of cluster analysis*. New York: CRC Press, 2015. 773 p.
30. Schubert E., Rousseeuw P.J. Faster k-medoids clustering: improving the PAM, CLARA, and CLARANS algorithms. *International conference on similarity search and applications*. Springer, Cham. 2019. pp. 171–187.
31. Hennig C. Dissolution point and isolation robustness: robustness criteria for general cluster analysis methods. *Journal of Multivariate Analysis*. 2009. vol. 99. pp. 1154–1176.
32. Krockner L., Algina D. Vvedenie v klassicheskuyu i sovremennuyu teoriyu testov [An introduction to the classical and contemporary testing theory]. M.: Logos, 2010. 668 p. (in Russ.).
33. Van der Linden W.J. *Handbook of Item Response Theory, Volume One: Models*. Chapman and Hall/CRC, 2016. 624 p.
34. Van der Linden W.J. *Handbook of Item Response Theory, Volume Three: Applications*. Chapman and Hall/CRC, 2018. 608 p.
35. Lang J.W., Tay L. The science and practice of item response theory in organizations. *Annual Review of Organizational Psychology and Organizational Behavior*. 2021. vol. 8. pp. 311–338.
36. Cella D., Choi S.W., Condon D.M., Schalet B., Hays R.D., Rothrock N.E., Yount S., Cook K.F., Gershon R.C., Amtmann D., DeWalt D.A. PROMIS® adult health profiles: efficient short-form measures of seven health domains. *Value in health*. 2019. vol. 22. no. 5. pp. 537–544.
37. De Jong M.G., Pieters R. Assessing sensitive consumer behavior using the item count response technique. *Journal of Marketing Research*. 2019. vol. 56. no. 3. pp. 345–360.
38. Abele A.E., Spurk D., Volmer J. The construct of career success: measurement issues and an empirical example. *ZAF*. 2011. vol. 43. pp. 195–206.
39. Hennig C. fpc: Flexible Procedures for Clustering. R package version 2.2-9. 2020. Available at: <https://CRAN.R-project.org/package=fpc>. (accessed 03.11.2022).
40. Hogan R. *Hogan development survey manual*. Tulsa, OK: Hogan Assessment Systems, 2009. 199 p.

41. Cattell R.B., Cattell H.E.P. Personality structure and the new fifth edition of the 16PF. Educational and Psychological Measurement. 1995. vol. 55. no. 6. pp. 926–937.
42. Myers I.B. The Myers-Briggs Type Indicator: Manual. Consulting Psychologists Press, 1962. 110 p.
43. Rizopoulos D. An R package for Latent Variable Modelling and Item Response Theory Analyses. Journal of Statistical Software. 2006. vol. 17. no. 5. pp. 1–25.
44. Granovetter M. The strength of weak ties: A network theory revisited. Sociological theory. 1983. pp. 201–233.

Stoliarova Valerie — Junior researcher, Laboratory of theoretical and interdisciplinary problems of computer science, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS). Research interests: data analysis, probabilistic graphical models. The number of publications — 40. vfs@dscs.pro; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)328-3337.

Tulupyeva Tatiana — Ph.D., Associate Professor, Senior researcher, Laboratory of theoretical and interdisciplinary problems of computer science, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS); Professor, State and Municipal Management at the North-West Institute of management (NWIM), the branch of the Russian Presidential Academy of National Economy and Public Administration. Research interests: personal psychology, artificial intelligence, social engineering, data analysis. The number of publications — 170. tvt@dscs.pro; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)328-3337.

Abramov Maxim — Ph.D., Head of the laboratory, Laboratory of theoretical and interdisciplinary problems of computer science, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS). Research interests: information security, social engineering attacks, social computing. The number of publications — 170. mva@dscs.pro; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: +7(812)328-3337.

Salakhova Valentina — Ph.D., Leading researcher, Center research security problems the RAS; Leading researcher, Laboratory of humanistic approach in education, Moscow City University. Research interests: psychology of deviant behavior, personal psychology, digitalization of education. The number of publications — 158. Valentina_naula@mail.ru; 21Б, Garibaldi St., 117335, Moscow, Russia; office phone: +7(985)221-4051.

Руководство для авторов

Взаимодействие автора с редакцией осуществляется через личный кабинет на сайте журнала «Информатика и автоматизация» <http://ia.spcras.ru/>. При регистрации авторам рекомендуется заполнить все предложенные поля данных. Подготовка статьи ведется с помощью текстовых редакторов MS Word 2007 и выше или LaTeX. Объем основного текста (до раздела Литература) - от 20 до 30 страниц включительно. Переносы разрешены. Номера страниц не проставляются. Основная часть текста статьи разбивается на разделы, среди которых являются обязательными: введение, хотя бы один «содержательный» раздел и заключение. Допускается также мотивированное содержанием и структурой материал а выделение подразделов. В основную часть опускается помещать рисунки, таблицы, листинги и формулы. Правила их оформления подробно рассмотрены на нашем сайте в разделе «Руководство для авторов».

Author guidelines

Interaction between each potential author and the Editorial board is realized through the pesoal account on the website of the journal "Informatics and Automation" <http://ia.spcras.ru/>. At the registration the authors are requested to fill out all data fields in the proposed form. The submissions should be prepared using MS Word 2007, LaTeX. The text of the paper in the main part should not exceed 30 pages. Pages are not numbered; hyphenations are allowed. Certain figures, tables, listings and formulas are allowed in the main section, and their typography is considered in more detail at the journal web.

Signed to print 26.01.2023. Passed for print 01.02.2023.

Printed in Publishing center GUAP.

Address: 67 litera A, B. Morskaya, St. Petersburg, 190000, Russia

Founder and Publisher: SPC RAS.

Address: 39 litera A, 14th Line V.O., St. Peterburg, 199178, Russia.

The journal is registered in the Federal Service for Supervision of Communications,
Information Technology, and Mass Media,

Registration Certificate (registration number) ПИ № ФС77-79228 dated September 25, 2020

Subscription Index П5513, Russian Post Catalog

Подписано к печати 26.01.2023. Дата выхода в свет 01.02.2023.

Формат 60×90 1/16. Усл. печ. л. 12,5. Заказ № 29. Тираж 300 экз., цена свободная.

Отпечатано в Редакционно-издательском центре ГУАП.

Адрес типографии: Б. Морская, д. 67, лит. А, г. Санкт-Петербург, 190000, Россия

Учредитель и издатель: СПб ФИЦ РАН.

Адрес учредителя и издателя: 14-я линия В.О., д. 39, лит. А, г. Санкт-Петербург, 199178, Россия

Журнал зарегистрирован Федеральной службой по надзору в сфере связи,
информационных технологий и массовых коммуникаций,
свидетельство о регистрации (регистрационный номер) ПИ № ФС77-79228 от 25 сентября 2020 г.

Подписной индекс П5513 по каталогу «Почта России»