

Национальный исследовательский Нижегородский государственный университет  
им. Н. И. Лобачевского

С. Н. Яшин, Н. И. Яшина, Е. В. Кошелев, А. А. Иванов

## МЕТАЭВРИСТИЧЕСКИЕ АЛГОРИТМЫ В УПРАВЛЕНИИ ИННОВАЦИЯМИ

*Монография*

*Исследование выполнено в рамках реализации программы стратегического академического лидерства “Приоритет 2030”, проект Н-426-99\_2022-2023  
“Социально-экономические модели и технологии развития креативного человеческого капитала в инновационном обществе”*

Нижний Новгород  
2023

УДК 681.3.06  
ББК 32.973.26-018.2  
Я96

*Рецензенты:*

Кузнецов В. П. — доктор экономических наук, профессор;  
Шинкевич А. И. — доктор технических наук, доктор экономических наук,  
профессор

Я96 **Яшин С. Н., Яшина Н. И., Кошелев Е. В., Иванов А. А. Метаэвристические алгоритмы в управлении инновациями:** *монография.* Нижний Новгород: ООО “Печатная Мастерская РАДОНЕЖ”, 2023. — 200 с.

ISBN 978-5-6049219-0-6

В информатике и математической оптимизации метаэвристика — это процедура более высокого уровня или эвристика, предназначенная для поиска, генерации или выбора эвристики (частичный алгоритм поиска), которая может обеспечивать достаточно хорошее решение проблемы оптимизации, особенно с неполной или несовершенной информацией или ограниченной вычислительной мощностью. В настоящее время метаэвристические алгоритмы применяются как альтернативный подход искусственного интеллекта в том случае, когда глубокое обучение нейронной сети приводит к проблеме переобучаемости. В данной монографии указанные алгоритмы применяются для управления инновациями крупных инновационных систем путем глобальной оптимизации соответствующих процессов внедрения новшеств. Материал монографии подкреплён множеством примеров из программ *Statistica*, *Wolfram Mathematica*, *Matlab*.

Монография предназначена для государственных служащих и инвесторов, планирующих вложение средств в инновационное развитие регионов, студентов, аспирантов, преподавателей, бизнесменов и широкого круга читателей.

Ил. 66, библиогр. 164 назв.

ISBN 978-5-6049219-0-6

УДК 681.3.06  
ББК 32.973.26-018.2

© Яшин С. Н., Яшина Н. И., Кошелев Е. В., Иванов А. А., 2023  
© ООО “Печатная Мастерская РАДОНЕЖ”, 2023

## Оглавление

<b>Введение</b> .....	5
<b>Глава 1. Метаэвристические алгоритмы и управление инновациями</b> ....	6
<b>1.1. Метаэвристические алгоритмы и искусственный интеллект</b> .....	6
<b>1.2. Основные методы метаэвристики</b> .....	9
<b>1.3. Проблемы глобальной оптимизации управления крупными инновационными системами</b> .....	18
<b>Глава 2. Цифровые двойники межкластерного взаимодействия</b> .....	22
<b>2.1. Создание цифрового двойника межкластерного взаимодействия: имитационный отжиг</b> .....	22
<b>2.2. Отладка цифрового двойника в условиях стохастической неопределенности: поиск по шаблону</b> .....	35
<b>Глава 3. Форсайт эволюции крупной инновационной системы федерального округа</b> .....	48
<b>3.1. Применение многоцелевого генетического алгоритма</b> .....	48
<b>3.2. Определение центра инновационно-индустриальных кластеров округа: генетический алгоритм, имитационный отжиг, поиск по шаблону</b> .....	65
<b>3.3. Определение центра промышленной агломерации округа: муравьиный алгоритм</b> .....	79
<b>Глава 4. Глобальная оптимизация затрат на НИР крупных инновационных систем</b> .....	91
<b>4.1. Одновременное инвестиционное, производственное и финансовое планирование программ инновационного развития региона: генетический алгоритм, имитационный отжиг, поиск по шаблону</b> .....	91
<b>4.2. Оптимизация перекрестного финансирования затрат на НИР регионов: генетический алгоритм, имитационный отжиг, поиск по шаблону</b> .....	106
<b>Глава 5. Моделирование поведения топ-менеджеров для эффективного управления инновациями</b> .....	132
<b>5.1. Моделирование мотивации топ-менеджеров государственных структур федерального округа: двухцелевой генетический алгоритм</b> .....	132
<b>5.2. Моделирование мотивации топ-менеджеров государственных структур регионов страны: трехцелевой генетический алгоритм</b> .....	153

5.3. Оптимизация предвыборной кампании: муравьиный алгоритм, имитационный отжиг .....	177
Заключение .....	187
Список литературы .....	188

## Введение

Искусственный интеллект (ИИ) уже прочно вошел в нашу повседневную жизнь, охватив различные сферы жизнедеятельности человека. Однако данная технология требует еще серьезной доработки как теоретического, так и прикладного характера. Также нельзя забывать о том, что применение ИИ должно способствовать устойчивому развитию общества, а не его дестабилизации. Для этого следует качественно адаптировать соответствующие алгоритмы ИИ под наиболее важные потребности человека, в частности, и общества в целом.

Нейронные сети являются достаточно удобным инструментом развития ИИ. Но они обладают известной проблемой переобучаемости, когда сеть работает по мере дальнейшего обучения уже не так качественно, как требуется. По этой причине специалисты разного профиля — ученые, программисты и прочие исследователи — в свое время стали искать другие алгоритмы ИИ, которые позволили бы преодолеть проблему переобучаемости нейронной сети. Одним из таких направлений стали метаэвристические алгоритмы, основанные на имитационном моделировании и позволяющие проводить глобальную оптимизацию любых самых сложных функций. Хотя эти алгоритмы и позволяют получить приближенное решение какой-либо практической проблемы, современное развитие этого направления привело к существенному скачку в получении более точного решения, решении более сложных задач и повышению скорости получения оптимального решения путем множества итераций.

По этой причине метаэвристические алгоритмы стали применяться в различных областях жизнедеятельности. Мы сконцентрировали наше внимание на управлении крупными инновационными системами, к которым мы относим промышленные регионы с инновационно-индустриальными кластерами в них, федеральные округа и, наконец, всю страну. При этом мы рассматриваем межкластерное взаимодействие по трем направлениями: экономико-финансовое, информационное и логистическое взаимодействие.

Для этого в *главе 2* мы создали необходимые цифровые двойники межкластерного взаимодействия. В *главе 3* мы перешли к форсайту эволюции инновационной системы федерального округа, где кроме самого форсайта округа определяется центр его инновационно-индустриальных кластеров, а также центр промышленной агломерации федерального округа. В *главе 4* мы рассмотрели процесс глобальной оптимизации затрат на НИР крупных инновационных систем. Наконец, *главу 5* мы закончили исследованием важной проблемы моделирования мотивации топ-менеджмента государственных структур, включая также оптимизацию предвыборной кампании. Во всех этих исследованиях мы применяли те метаэвристические алгоритмы, которые, на наш взгляд, более всего подходят к решению той или иной практической задачи.

Решаемые в монографии проблемы обсуждаются сначала на теоретическом уровне, после чего детально изучаются на конкретных расчетных примерах, где также представлены необходимые коды программ — в основном в программе *Matlab*. Также мы применяем пакеты *Statistica* и *WolframAlpha*.

## Глава 1

# Метаэвристические алгоритмы и управление инновациями

### 1.1. Метаэвристические алгоритмы и искусственный интеллект

С тех пор, как человечество начало переходить в информационную эру, данные стали одним из главных ресурсов, а извлечение необходимой информации — жизненно необходимым навыком для науки и бизнеса в XXI веке. И вполне закономерно, что *машинное обучение* стало такой популярной и активно развивающейся наукой. Один раздел машинного обучения получил особенно бурное развитие в последние несколько лет. Мы говорим о *глубоком обучении*, которое основано на использовании многослойных *нейронных сетей* в качестве базового инструмента.

Каждый день появляются новые примеры практического применения глубокого обучения, способы обучения нейронных сетей, новые архитектуры. Количество данных все увеличивается, сети становятся глубже, архитектуры изощренней, а видекарты — более производительными и приспособленными под нужды машинного обучения.

Но нерешенных проблем в глубоком обучении остается достаточно, как в теории, так и на практике. Чем глубже становится архитектура, тем сложнее ее обучать.

Если мы говорим про математику, стоящую за обучением нейронных сетей, то *конечномерная оптимизация здесь* будет на первом плане. Для фиксированной архитектуры сети мы пытаемся найти такой набор весов, который обеспечит минимум некоторому функционалу качества. Обычно поиск такого набора весов осуществляется с помощью процедуры *градиентного спуска*.

*Градиентный подход* — парадигма, проверенная временем, постоянно совершенствующаяся, но не лишенная недостатков и не единственно существующая. Основное ограничение, накладываемое на градиентные методы — это требование дифференцируемости оптимизируемой функции. Основной недостаток — локальность найденного оптимума.

Альтернативный подход, не налагающий на оптимизируемую функцию никаких ограничений кроме того, что функция может быть вычислена в заданных точках, и позволяющий находить глобально лучшее решение — это *метаэвристические алгоритмы*.

Одними из самых известных представителей данного класса алгоритмов являются *генетические алгоритмы*. Мы хотим понять, насколько успешно можно обучать нейронные сети с помощью алгоритмов, подобных генетическим.

Область искусственного интеллекта, которая пытается ответить на подобные вопросы, называется *нейроэволюция*. Несмотря на первоначальный позитивный настрой ученых и исследователей, которые в конце XX века получили некоторые обнадеживающие результаты, сегодня методы нейроэволюции применяются в основном для вспомогательных задач глубокого обучения, например для настройки

гиперпараметров алгоритмов. Также методы нейроэволюции успешно применяются в области обучения с подкреплением, но для решения основных оптимизационных задач все же принято использовать именно градиентный подход. Почему же так вышло и может ли данный подход снова стать популярным в будущем?

Дело в том, что нейронная сеть в компьютере представляется в виде *вычислительного графа*, который мы умеем аналитически дифференцировать. *Функция потерь* (Loss function, objective) алгоритма, рассчитываемая на тренировочной выборке, в отличие от *доли правильных ответов* (accugacy), рассчитываемой на тестовой выборке, выбирается непрерывной. Значит, для нее можно достаточно быстро и точно определить градиент. Поэтому градиентный метод получает свое первое преимущество — дополнительная информация о ландшафте функции потерь. Вторым преимуществом градиентного метода является возможность подстраивать *скорость обучения* (learning rate), что позволяет на более поздних этапах обучения лучше исследовать оптимизируемые параметры на более мелких масштабах.

Некоторые метаэвристические методы так же способны изменять скорость обучения и величину шага. Например, метод эволюции ковариационной матрицы (CMA-ES) с течением времени уменьшает область поиска.

Значит ли все вышесказанное, что градиентный мир победил? На самом деле для каждой задачи найдется алгоритм, который ее решает лучше, чем другие, и для каждого алгоритма найдутся плохие задачи.

Оптимизация — важная и неотъемлемая часть решения задач математического моделирования и машинного обучения. От минимизации эмпирического риска при построении классификаторов до поиска оптимальной стратегии поведения агента в обучении с подкреплением — везде необходимо решать задачи конечномерной и бесконечномерной оптимизации. Каждая конкретная задача требует применения специального метода оптимизации наиболее ей подходящего. Наибольшее распространение получили методы 1-го и 2-го порядков или так называемые градиентные методы и их модификации. Методы обладают рядом преимуществ (целенаправленность поиска, доказанная сходимость к решению и т. д.), позволяющих успешно применять их при решении различных задач машинного обучения. Например, для настройки весов искусственной нейронной сети применяется алгоритм обратного распространения ошибки, принадлежащий семейству градиентных алгоритмов.

Однако, градиентные методы так же обладают рядом недостатков, делающих их применение в конкретных задачах либо проблематичным, либо вовсе невозможным. Например, в задачах негладкой оптимизации или в задачах поиска глобального экстремума для мультиэкстремальных функций, в которых градиентные методы могут выделить лишь локальные экстремумы. Альтернативным подходом служат методы 0-го порядка, не требующие знание структуры оптимизируемой функции и вычисление градиента.

Среди методов 0-го порядка в последние годы особенно выделяются биоинспирированные метаэвристические алгоритмы поиска глобального экстремума. Несмотря на отсутствие доказательств о сходимости этих методов, их часто применяют на практике для решения сложных оптимизационных задач. В частности, в ма-

шинном обучении наиболее известно применение генетических алгоритмов в области обучения с подкреплением. Однако, что касается других областей машинного обучения, несмотря на различные исследования, нет окончательной ясности о том, как и в каких задачах лучше пользоваться теми или иными методами.

Метаэвристические алгоритмы являются довольно эффективным и в последнее время чрезвычайно популярным классом оптимизационных методов, позволяющих находить решения для многих сложных задач из различных приложений, в частности, при решении задач в экономических приложениях. Мощностью разработанных метаэвристик состоит в их способности решения сложных задач без подробного описания пространства поиска решений. Исходя из этого эти методы дают возможность решать трудноразрешимые задачи оптимизации (NP-проблемы).

Можно понимать метаэвристику как алгоритм, реализующий прямой стохастический поиск возможных решений задачи, причем оптимальных или близких к оптимальным, до тех пор, пока не будет выполнено какое-либо определенное условие или же будет достигнуто определенное количество заданных итераций.

В научной литературе считается, что метаэвристики объединяют основные эвристические методы (традиционные классические эвристики) в структуры алгоритмических схем более высокого уровня, которые бы позволяли эффективнее изучать пространства поиска и принимать эффективные решения.

Это, в свою очередь, обычно требует значительно меньше работы, чем разработка новых специализированных эвристик. Задача в данном случае заключается в адаптации общих (метаэвристических) схем решения к решению трудных задач оптимизации. Кроме того, эффективная реализация метаэвристики может обеспечить нахождение решения (достаточно близкого к оптимальному) за приемлемое время.

Разнообразные подходы к пониманию метаэвристик в научной литературе дают возможность сформулировать некоторые фундаментальные свойства, которыми характеризуются метаэвристики.

Следующие определения и свойства метаэвристик эквивалентны.

1. Метаэвристики это некоторые стратегии, которые определяют и управляют процессом поиска оптимального решения.

2. Основная цель применения метаэвристики состоит в том, чтобы эффективно исследовать пространство поиска и найти почти оптимальные решения.

3. Методы, которые представляют метаэвристические алгоритмы, варьируются от самых простейших локальных процедур поиска решений до очень сложных, включающих процессы обучения.

4. Метаэвристические алгоритмы являются приближительными и обычно недетерминированными.

5. Метаэвристические алгоритмы обычно включают в себя эффективные правила непопадания в локальные экстремумы в ограниченной области пространства поиска.

6. Метаэвристики не предназначены для решения конкретных задач и могут быть описаны только на абстрактном математическом уровне.

7. Метаэвристики всегда представляют знания о предметной области в качестве эвристик, которые находятся под управлением стратегии верхнего уровня.

8. Современная метаэвристика использует хранимый поисковый контент в решении оптимизационной проблемы для управления поиском.

## 1.2. Основные методы метаэвристики

Хотя классификация метаэвристических методов в настоящее время носит условный характер, поскольку характерные группы методов базируются на сходных идеях, и имеется устойчивая тенденция к созданию гибридных алгоритмов, выделим четыре группы методов: эволюционные методы; методы, имитирующие физические процессы; мультистартовые методы, методы “роевого” интеллекта [18].

К эволюционным методам относятся генетические алгоритмы; методы, имитирующие иммунные системы организмов; методы рассеивания; методы эволюционного преобразования ковариационной матрицы; методы динамических сеток; методы дифференциальной эволюции; гибридные меметические алгоритмы.

Ко второй группе метаэвристических методов, методов, имитирующих физические процессы, относятся метод гравитационной кинематики, адаптивный метод имитации отжига, метод поиска гармонии.

К третьей группе метаэвристических методов — к мультистартовым методам — относятся метод случайного поиска с последовательной редукцией области исследования, жадный адаптивный метод случайного поиска и метод направленного табу-поиска.

К четвертой группе методов — методам “роевого” интеллекта — относятся метод частиц в стае, метод муравьиных колоний, метод имитации поведения бактерий, методы роя пчел и искусственных пчелиных колоний. Отметим, что методы гравитационной кинематики и поиска гармонии могут быть также отнесены к методам “роевого” интеллекта, поскольку в процессе поиска происходит обмен информацией между решениями на текущей итерации.

*Эволюционные методы* поиска (Evolutionary Methods) имитируют процессы природного развития популяции особей — эволюции. В основе эволюционных методов лежат принципы, заимствованные из биологии и генетики. Основная идея эволюционных методов состоит в создании популяции особей (индивидов, клеток). В задаче оптимизации каждая особь соответствует одному из возможных решений. Для поиска наилучшего решения используется значение целевой функции или связанной с ней функции приспособленности. Значение функции приспособленности показывает, насколько хорошо подходит особь в качестве решения задачи. Для обеспечения процесса эволюционного поиска к текущей популяции применяются основные генетические операции (селекция, скрещивание, мутация, клонирование), в результате которых генерируется новая популяция при помощи добавления новых особей с лучшими значениями функции приспособленности и удаления старых.

Подобно другим метаэвристическим методам, эволюционные методы не гарантируют обнаружения глобального решения, но они успешно работают, когда требуется найти достаточно хорошее решение за приемлемое время.

*Генетические алгоритмы* (Genetic Algorithms, GA) являются представителями эволюционных методов поиска. В GA создается популяция особей, каждая из которых представляется в виде хромосомы. В задаче оптимизации множество допустимых решений кодируется так, чтобы каждая хромосома соответствовала одному из возможных решений. Хромосома состоит из конечного числа генов, представляя генотип объекта. Поиск экстремума ведется на уровне генотипов.

Генетические алгоритмы делятся на две группы: *генетические алгоритмы с бинарным кодированием* и *генетические алгоритмы с вещественным кодированием*.

Первая группа использует двоичный алфавит для кодирования либо точек, либо элементарных “площадок” на множестве допустимых решений (иногда применяется смешанное кодирование). Высокая эффективность отыскания глобального экстремума с помощью генетического алгоритма с бинарным кодированием обоснована теоремой о шаблоне, в которой доказано, что двоичный алфавит позволяет обрабатывать максимальное количество информации по сравнению с другими методами кодирования. Однако двоичное представление хромосом влечет за собой трудности при поиске экстремума в непрерывных пространствах, поскольку дискретизация множества допустимых решений приводит к потере точности.

Вторая группа возникла в результате отказа от идеи кодирования. В таком случае решение в хромосоме представляется в виде набора вещественных чисел. При этом реализация генетических операторов изменяется, а операции кодирования и декодирования отсутствуют. Генетические алгоритмы с вещественным кодированием интенсивно развиваются.

К эволюционным методам относятся методы, имитирующие иммунные системы организмов, — *методы искусственных иммунных систем* (Artificial Immune Systems, AIS), опирающиеся на идеи из иммунологии.

В методах AIS создается популяция иммунных клеток, которая в течение работы метода имитирует борьбу иммунной системы организма с чужеродными телами. В результате этой борьбы, подобно естественным природным процессам, искусственная иммунная система запоминает способы борьбы с чужеродными телами в клетках памяти и приобретает новые свойства. При этом система совершенствуется, повышая эффективность своей работы.

Особенностью работы методов AIS является тщательное исследование множества допустимых решений. Методы находят не только глобальные экстремумы функций, но также и локальные. Модифицированный метод AIS при исследовании множества допустимых решений сочетает в себе глобальный и локальный поиски, что позволяет ему эффективно справляться с поставленной задачей.

Еще одним представителем эволюционных методов является *метод рассеивания* (Scatter Search). Свое название метод получил из-за способа создания базового множества особей, которое формируется таким образом, чтобы особи в нем были достаточно отличны друг от друга, т. е. хорошо “рассеяны” по множеству допустимых решений. Данное множество используется для формирования начальной популяции и пополнения новых популяций в течение работы метода. Таким образом, обеспечивается тщательное исследование множества допустимых решений и эффективное

использование вычислительных ресурсов метода. У метода рассеивания существует несколько модификаций, комбинирующих его с локальными методами поиска — линейным поиском, табу-поиском, методом деформируемого многогранника.

*Метод эволюционного преобразования ковариационной матрицы* (Covariance Matrix Adaptation Evolution Strategy, CMA-ES) свое название получил благодаря способу, которым формируются новые популяции. Формирование происходит при помощи нормального распределения случайного вектора. При этом при переходе от одной популяции к другой происходит преобразование ковариационной матрицы распределения. Также производится постоянное изменение параметров метода в течение его работы. Изменение элементов ковариационной матрицы и параметров метода реализуется таким образом, чтобы обеспечить наиболее эффективную его работу на каждой итерации. Изначально CMA-ES разрабатывался как локальный метод поиска, поэтому его можно использовать в качестве улучшающего решение метода в комбинации с другими методами поиска. Однако CMA-ES и его модификации справляются и с задачами поиска глобального экстремума.

В *методе динамических сеток* (Variable Mesh Optimization) популяция представляется в виде некоторой сетки, состоящей из набора решений, называемых узлами. В процессе поиска сетка подвергается изменениям: расширению (добавлению новых узлов в сетку) и сокращению (удалению узлов, расположенных слишком близко друг к другу). Метод имитирует эволюцию начальной популяции и представляет собой итерационный процесс. Во время работы метода на каждой итерации происходит расширение (локальное, глобальное и дополнительное) и последующее сокращение сетки. Таким образом, формируется новая сетка. Критерием окончания поиска является достижение заранее заданного количества вычислений целевой функции. В качестве приближенного решения задачи из последней популяции выбирается узел, которому соответствует наилучшее значение целевой функции.

*Метод дифференциальной эволюции* (Differential Evolution) относится к классу методов, в которых переход от одной популяции к другой происходит посредством искусственной эволюции. Использование различий между индивидами (значениями аргумента целевой функции) с помощью линейного оператора, названного дифференциацией, привело к появлению нового класса методов, различные модификации которого нашли широкое применение при решении разнообразных прикладных задач. Сначала на множестве допустимых решений генерируется конечный набор векторов, называемый начальной популяцией. Как правило, для этого используется равномерное распределение. Для формирования новой популяции проводится заданное число испытаний. При этом последовательно выбирается каждый элемент текущей популяции (он называется вектором-мишенью) и принимается решение, остается ли он в новой популяции или нет путем сравнения с вектором-образцом, полученным в результате скрещивания и мутации. Если вектор-образец лучше по соответствующей величине целевой функции, чем вектор-мишень, то он его заменяет в популяции. Циклический процесс замены текущей популяции новой заканчивается, когда количество сформированных популяций оказывается равным заданному максимальному числу популяций.

*Меметический алгоритм* (Memetic Algorithm), как правило, реализует идеи взаимодействия эволюционного или другого подхода, основанного на понятии популяции, и индивидуального обучения особей либо другой локальной процедуры улучшения решения для задач поиска глобального оптимума. Теория “универсального дарвинизма” полагает, что понятие эволюции применимо не только к биологическим системам, но и к любой сложной системе, которой присущи принципы наследования, изменения и селекции, т. е. все принципы развития. Таким образом, наука меметика представляет собой аналог генетики в развитии культуры. Термин “мем” был определен как единица передачи культурной информации, распространяемая от одной особи к другой посредством имитации, научения и др.

Термин “меметический алгоритм” (МА) был впервые предложен П. Москато (P. Moscato), где он рассматривал МА как гибрид генетического алгоритма и процедуры индивидуального обучения для уточнения решения задачи. На этапе индивидуального обучения решение (особь или ее генотип) заменяется новым (обученным) решением в случае, если новое решение имеет большую приспособленность, независимо от остальной части популяции. Таким образом, происходит так называемое культурное развитие особи, которое затем передается ее потомкам в течение последующих поколений.

Одной из главных трудностей, возникающих при проектировании алгоритма, сочетающего популяционный и локальный поиск, является соблюдение баланса между ними. Можно говорить об этом как о более общей проблеме соблюдения баланса между экстенсивным и интенсивным исследованиями пространства поиска. Кроме того, следует учитывать тот факт, что при большом числе особей даже простая процедура локального поиска может занять непозволительно много времени. Разные исследователи по-разному оценивали важность локального поиска и объем времени, который ему нужно уделять. В целом не существует универсальных рекомендаций на этот счет. В данный момент МА также называют гибридными эволюционными алгоритмами, эволюционными алгоритмами Болдуина (Baldwinian Evolutionary Algorithms), эволюционными алгоритмами Ламарка (Lamarckian Evolutionary Algorithms), культурными алгоритмами или генетическими алгоритмами локального поиска.

*Метод имитации отжига* (Simulated Annealing) и его модификации основаны на анализе процесса замерзания жидкостей или рекристаллизации металлов в процессе отжига. Кроме классического алгоритма существуют также его модификации, позволяющие ускорить сходимость. Применяемая стратегия поиска, основанная на использовании распределений Больцмана и Гиббса, позволяет проскочить локальные минимумы оптимизируемой функции и попасть в область притяжения глобального минимума. Попадание в эту область происходит с определенной вероятностью, поэтому метод имитации отжига не гарантирует нахождения глобального минимума функции. Однако при правильной политике выбора траектории изменения “температуры” (параметра метода) происходит не только улучшение начального приближения, но и существенное приближение к глобальному экстремуму. Как правило, необходимая эвристическая политика реализуется за счет выбора

удачного начального приближения, высокого значения начальной “температуры” и постепенного ее снижения. Все алгоритмы имитации отжига с некоторой вероятностью допускают переход в состояние с более высоким значением целевой функции в процессе поиска решения для того, чтобы точка могла покинуть окрестность локального минимума. Однако для обеспечения этого свойства в обычном методе отжига требуется снижать “температуру” очень медленно, что значительно увеличивает время счета. В *адаптивном методе имитации отжига* (Adaptive Simulated Annealing) отмеченный недостаток устраняется за счет ввода нового закона уменьшения температуры и возможности ее изменения по каждой координате отдельно с учетом специфики влияния каждого параметра в конкретной задаче оптимизации. Также одним из отличий адаптивного метода имитации отжига от обычного метода и большинства других его модификаций является возможность использования в задачах условной оптимизации, что существенно расширяет область применения методов имитации отжига.

Исторически первым и довольно долгое время единственным широко используемым методом поиска глобального экстремума являлся метод, названный впоследствии *мультистарт*. Этот метод состоит в многократном отыскании локальных минимумов и различных начальных точек. Для повышения эффективности мультистарта используются исключение повторных спусков в те же локальные минимумы, обеспечение выхода траектории спуска из “неглубоких ям” и генерирование перспективных начальных точек. Также находят применение идеи кластеризации поисковых точек для определения уже найденных локальных минимумов. Для обеспечения выхода из “неглубоких ям” спускающейся точке приписывают инерцию, т. е. модифицируют целевую функцию для достижения туннельного эффекта с целью перехода из текущего в более глубокий минимум.

Основная сложность при практической реализации метода мультистарта состоит в следующем. Для того чтобы с высокой надежностью отыскать точку глобального минимума, необходимо взять количество начальных точек для локальных алгоритмов существенно большее, чем число локальных минимумов функции (которое к тому же обычно неизвестно). Но при этом большая часть вычислительных затрат будет связана с нахождением точек локальных минимумов, найденных ранее. Для преодоления указанной сложности мультистарт обычно модифицируют одним из двух следующих способов.

Первый способ состоит в том, что найденные точки локальных минимумов окружаются некоторыми окрестностями, и попадание других точек в эти окрестности считается равносильным попаданию в точки локальных минимумов.

Второй способ, иногда называемый методом конкурирующих точек, заключается в том, что поиск локальных минимумов производится одновременно (параллельно), причем точки, расстояние между которыми мало (не превышает некоторого фиксированного, достаточно малого числа), объединяются, т. е. заменяются одной из них — той, значение целевой функции в которой лучше. Проблема объединения точек является задачей кластерного анализа.

Здесь мы опишем три мультистартовых метода: метод случайного поиска с последовательной редукцией области поиска, жадный адаптивный метод случайного поиска и метод направленного табу-поиска.

*Метод случайного поиска с последовательной редукцией области исследования* (метод Luus–Jaakola) использует идею переменной области поиска новых решений, которая в процессе работы метода подвергается редукции (сокращению) и восстановлению (расширению). При применении данного метода строится последовательность итераций из заданной начальной точки так, что в некоторой окрестности текущей точки с использованием равномерного распределения генерируется определенное количество случайных точек с учетом размеров множества допустимых решений. Среди полученных точек выбирается наилучшая, и из нее процесс продолжается. При этом размер множества поиска сокращается от итерации к итерации вплоть до достижения их заданного числа. Как только заданное число итераций выполнено, завершается проход. При переходе к следующему проходу размер множества поиска восстанавливается, а далее снова выполняется заданное число итераций. На каждой итерации размеры исследуемой области сокращаются, что позволяет обеспечить сходимость последовательности полученных таким образом приближенных решений к искомой точке глобального экстремума.

*Жадный адаптивный метод случайного поиска* (Greedy Randomized Adaptive Search Procedure) использует идею мультистарта, т. е. многократного поиска решения, где каждая итерация включает в себя две фазы: фазу конструирования и фазу локального поиска. Наилучшее из найденных решений принимается за приближенное решение поставленной задачи. В результате первой фазы (фазы конструирования) порождаются решения хорошего качества, из которых начинается вторая фаза — локального поиска. Затем полученные точки берутся в качестве начальных для первой фазы, и процедура продолжается.

*Метод направленного табу-поиска* (TabuSearch) включает в себя три фазы: исследовательскую, перераспределительную и интенсивно-уточняющую. На исследовательской фазе происходит генерация новых точек вблизи текущего решения. Используемая концепция памяти при этом позволяет избежать циклических попаданий в ранее посещенные области. Один из инструментов памяти — лист посещенных областей — является элементом перераспределительной фазы, служащей для организации поиска в непосещенных областях исследуемого пространства. Предполагается, что одна из лучших точек, найденных на исследовательско-перераспределительной фазе, близка к глобальному экстремуму. Поэтому на фазе интенсивного уточнения найденные хорошие точки улучшаются с целью получения результата с заданной точностью.

*Метод частиц в стае* (Particle Swarm Optimization Strategy) имитирует некоторые свойства живой природы и позволяет отыскать приемлемое с точки зрения практики решение, может быть, несколько отличающееся от оптимального. Основная идея метода частиц в стае состоит в моделировании поведения стаи животных при поиске пищи. Каждый член стаи рассматривается как частица в многомерном пространстве, которая имеет положение и скорость (она появляется в процессе

движения). Каждая частица изменяет свое положение, запоминая наилучшее, которому соответствовало наилучшее значение целевой функции. Члены стаи сообщают информацию о хороших позициях друг другу и используют ее для корректировки своего положения и скорости на каждой итерации. Также учитываются найденные ранее позиции. Процедура поиска заканчивается при достижении максимального числа итераций. В качестве приближенного решения выбирается наилучшее среди всех членов стаи.

При реализации метода частиц в стае используются следующие основные принципы, взятые из природы: для достижения цели используется множество особей (частиц); каждая особь получает информацию о передвижении соседей; движение по направлению к цели происходит путем подражания действиям соседа; учитывается информация о цели (величина целевой функции), получаемая через органы чувств (например, запах пищи); используется собственный прошлый опыт. При этом моделируются тенденции живого организма повторять успешное в прошлом поведение, особенно в случае локальной неудачи; подражать успеху остальных; двигаться за лидером, выбираемым среди соседей.

*Метод муравьиных колоний* (Ant Colony Optimization) также относится к методам “роевого” интеллекта, которые в связи со своей эффективностью приобретают все большую популярность. Метод был разработан М. Дориго (M. Dorigo) для дискретных множеств допустимых решений и применялся для решения комбинаторных задач. Постоянно появляются его модификации для решения различных прикладных задач. Метод моделирует действия колонии муравьев при поиске оптимального маршрута в изменяющейся среде обитания. При прохождении по какому-либо участку пути муравей откладывает особое пахучее вещество, называемое феромоном. Чем сильнее концентрация феромонов на тропе, тем более привлекательна она для других муравьев. Таким образом муравьи узнают, какие маршруты чаще всего используются колонией. Кроме того, при поиске муравьи руководствуются также объективной информацией об окружающей среде. Хотя при этом поведение отдельной особи выглядит довольно примитивно, поведение всей популяции таким не является.

*Метод гравитационной кинематики* (Central Force Optimization) в качестве основной расчетной формулы использует модификацию формулы, выражающей закон всемирного тяготения. Главной особенностью метода является использование значения целевой функции в качестве массы частицы, участвующей в гравитационном взаимодействии. Метод гравитационной кинематики принципиально отличается от других метаэвристических методов тем, что является полностью детерминированным. Поиск решения осуществляется только за счет “роевого” интеллекта. Имеются модификации метода гравитационной кинематики, использующие псевдослучайные величины. Основное свойство этих модификаций состоит в том, что они полностью сохраняют детерминированность самого метода, что обеспечивает воспроизводимость экспериментов. Метод гравитационной кинематики является удобным средством для решения задачи поиска глобального экстремума множеством агентов.

В *методе имитации поведения бактерий* (Bacterial Foraging Optimization) моделируются четыре процесса, происходящие внутри колонии бактерий в питательной среде. Хемотаксис (первый процесс) означает движение клетки или организма по градиенту химической концентрации в ответ на стимулирующее воздействие. Движение бактерий (рассматривается бактерия *E. coli*) происходит путем поворота с помощью специальных ворсинок и дальнейшего движения вдоль градиента концентрации питательных веществ. Хемотаксис реализуется следующим образом. Сначала реализацией случайного вектора происходит выбор направления движения, в этом направлении делается пробный шаг. Далее искусственная бактерия оценивает, насколько это движение оказалось удачным с точки зрения наличия питательных веществ и отсутствия вредных субстанций. В роли градиента химической концентрации выступает специальный критерий (“показатель здоровья”), представляющий собой совокупность значения целевой функции в точке и функции, характеризующей близость бактерии к другим особям в колонии. Если движение в выбранном направлении приводит к улучшению значения критерия, то бактерия продолжает “скользить” в этом направлении, пока значение критерия не станет ухудшаться или пока число шагов не превысит максимально допустимое. Движение вдоль выбранного направления — второй процесс, который моделируется в методе имитации поведения бактерий. По истечении времени жизни бактерий им на смену приходит новое поколение, которое учитывает опыт предшественников. В алгоритме это выражается в том, что некоторое количество новых бактерий заменяет собой бактерии с наихудшим значением “показателя здоровья”, но при этом они попадают в точки множества допустимых решений, где находятся бактерии с наилучшим значением “показателя здоровья”. Так реализуется процесс воспроизведения (третий процесс). В алгоритме также моделируется влияние внешних случайных факторов (четвертый процесс). По прошествии нескольких поколений небольшое количество выбранных случайным образом бактерий перемещается в выбранную произвольным образом точку множества допустимых решений. Данное событие называется событием типа “уничтожение-рассеяние”, поскольку процесс можно представить как уничтожение бактерий и появление новых бактерий, никак не связанных со своими предшественниками.

*Методы пчелиных колоний* (Bees Algorithms, Artificial Bee Colony) — метод пчелиного роя и метод искусственной пчелиной колонии используют модели поведения пчел при поиске нектара. Источник нектара характеризуется своей полезностью, которая определяется такими факторами, как удаленность от улья, концентрация нектара, удобство его добычи. В задачах поиска глобального экстремума полезность источника характеризуется значением целевой функции. Среди пчел, образующих рой, выделяются занятые фуражиры-пчелы, которые связаны с одним из источников нектара, т. е. добывают на нем нектар (они владеют следующей информацией о своем источнике нектара: направление от улья на источник и полезность источника); незанятые фуражиры — пчелы-разведчики, которые осуществляют поиск источников нектара для их использования, а также пчелы-наблюдатели, которые в данное время выполняют некоторые работы в улье. Каждый незанятый фура-

жир может полететь к источнику нектара, следуя за пчелой-разведчиком, которая нашла путь к такому источнику. Пчела-разведчик выполняет вербовку незанятых пчел с помощью танца на специальной площадке улья — области танцев. Завербованная пчела следует за соответствующей пчелой-разведчиком к области с нектаром и становится, таким образом, занятым фуражиром. Занятый фуражир после добычи нектара возвращается в улей и оставляет нектар там. После этого данный фуражир может выполнить одно из следующих действий: оставить свой источник нектара и стать незанятым фуражиром; продолжить заготовку нектара из прежнего источника, не вербуя других пчел; выполнить вербовку. Пчела выбирает одно из указанных действий по некоторому вероятностному закону. Описанные действия используются в алгоритме для поиска наилучшего источника нектара — точки глобального экстремума.

В методе искусственной пчелиной колонии среди всех пчел выделяют особей, которые производят поиск нектара, а именно: рабочих пчел, пчел-наблюдателей и пчел-разведчиков. В начальный момент времени имеется предварительная информация о местонахождении источников пищи. Эта информация хранится таким образом, что к ней имеют доступ все особи. Используя имеющуюся информацию, рабочие пчелы направляются к источникам нектара (существующим решениям) и производят поиск в их окрестности. Каждому источнику соответствует одна рабочая пчела. Если новый источник пищи (новая точка на множестве допустимых решений) по определенным параметрам (величине целевой функции) лучше, чем предыдущий источник, хранящийся в памяти пчелы, то она запоминает новый источник. Затем рабочие пчелы возвращаются в улей и передают пчелам-наблюдателям информацию о новых, более привлекательных источниках. Пчелы-наблюдатели оценивают все найденные источники пищи и вероятностным образом выбирают, с какого источника начинать свой поиск. После этого пчелы-наблюдатели производят процесс поиска аналогично тому, как это делали рабочие пчелы. Новые решения также проходят отбор и сохраняются только в том случае, если они приводят к улучшению качества нектара (улучшению значения целевой функции). Если в процессе поиска решение не обновляется в течение нескольких итераций, то оно считается забытым, а пчела, к которой приписан данный источник нектара, освобождается и становится пчелой-разведчиком. Пчела-разведчик в качестве нового источника нектара выбирает произвольную точку множества допустимых решений, и, таким образом, для этой пчелы фактически поиск начинается заново. Процесс поиска решений продолжается, пока количество итераций не станет равным максимальному числу итераций.

*Метод поиска гармонии* (Harmony Search) имитирует процесс импровизации музыканта-исполнителя. В процессе исполнения музыкант подбирает нужную ноту с целью достижения наилучшей гармонии. При реализации метода поиска гармонии каждое подбираемое решение из множества допустимых порождает соответствующее значение целевой функции с целью достижения глобального экстремума. При этом используются идеи метода имитации отжига, метода частиц в стае, стохастического градиента. На множестве допустимых решений генерируется определен-

ное количество решений. Для каждого решения подсчитывается значение целевой функции. Все координаты решения и соответствующее значение функции помещаются в матрицу (по строкам), называемую памятью гармонии. Среди всех решений, имеющихся в памяти, выбирается наихудшее. Далее генерируется новое решение (в результате так называемого процесса импровизации), которое затем сравнивается с наихудшим в памяти. Если оно лучше по величине целевой функции, то это решение помещается в память вместо наихудшего решения. После описанной замены в памяти заново находится наихудшее решение для последующего сравнения. Процесс поиска завершается по достижении максимального числа итераций.

Авторы не ставили перед собой цели рекомендовать наилучший метод из описанных. Выбор метода определяется конкретной задачей оптимизации: видом критерия качества и ограничений, задающих множество допустимых решений.

### **1.3. Проблемы глобальной оптимизации управления крупными инновационными системами**

Одной из мер реализации государственной политики в области развития инфраструктуры и инновационной среды является содействие работе сетевых форм организации научно-технической и инновационной деятельности. Наиболее перспективными формами взаимодействия в данном случае являются кластерные образования и технологические платформы. Несмотря на значительное количество организационных и методических разработок в данных областях сохраняется проблема “невосприимчивости экономики и общества к инновациям”, трансфера технологий между оборонными и гражданскими секторами экономики, между отдельными видами экономической деятельности, а также недостаточной эффективности российских исследовательских организаций с существенной дифференциацией по регионам, “разомкнутость инновационного цикла”.

Современные технологические платформы (ТП) содействуют доведению актуального сформулированного заказа для науки и ускорению коммерциализации результатов НИОКР на основе механизма государственно-частного партнерства. Формат ТП позволяет объединить усилия государства, науки, образования, бизнеса вокруг “прорывного” и коммерциализируемого инновационного проекта. Прообразом технологических платформ в нашей стране являются Европейские технологические платформы (ЕТП), выступающие “коммуникативной площадкой для науки, бизнеса и государства” в различных отраслях экономики страны.

При первичном анализе отечественных кластерных образований и технологических платформ может создаться ошибочное мнение, что задачи, решаемые каждым из них, дублируются. Сопоставление ожидаемых результатов и предназначения, географических и технологических аспектов, а также принадлежности участников этих объединений свидетельствуют о том, что ТП выступают как один из специфических инструментов развития инновационных кластеров, а не наоборот. Прежде всего, инновационные кластеры сосредоточены вокруг одного или нескольких ведущих предприятий, при этом в рамках ТП предполагается равноправное скоорди-

нированное участие. В отличие от ТП инновационные кластеры жестко не регламентируются государством, хотя могут включать средства господдержки. Создание кластера, как правило, связано с определенным регионом/территорией, зависит от поддержки со стороны региональных органов власти; для ТП подобные рамки отсутствуют. Технологическая платформа связывает участников в рамках единого сектора экономики; в кластер могут входить представители различных отраслей и секторов экономики страны. Инновационный кластер обеспечивает экономию за счет оптимизации взаимодействия между всеми участниками технологическо-производственно-хозяйственной цепочки и эффекта масштаба; ТП обеспечивают результат за счет интенсивной инновационности и перспективности в выбранных направлениях.

ТП предполагают разные формы партнерств: 1) между научными организациями и ВУЗами, 2) между 1) и промышленностью, 3) между различными компаниями. Реализация данных видов партнерств также актуальна для инновационных кластеров. Отсутствие территориальных и технологических ограничений позволяет наделять ТП функцией межкластерного межрегионального взаимодействия.

Стоит отметить, что современные высокотехнологичные производства должны отвечать требованиям не только требованиям высокой производительности, наукоемкости продукции и экономической эффективности, но и глобальной конкурентоспособности в аспекте устойчивого развития. Основой данных процессов выступает цифровая трансформация бизнес-процессов и применяемых бизнес-моделей в цифровые на основе применения перспективных технологий, в том числе цифровых двойников. При этом указанная технология адаптируема не только непосредственно к производству, но и к управлению, финансовому и инвестиционному анализу. Кроме того, имеется возможность адаптации моделей цифровых двойников для региональных инновационных систем, в том числе при управлении инновационными кластерами и ТП, а также их межструктурным взаимодействием с целью повышения их социальной, экономической, технической и экологической эффективности. В качестве наиболее важных направлений взаимодействия кластеров и ТП между собой можно назвать:

- 1) экономико-финансовое взаимодействие;
- 2) информационное взаимодействие;
- 3) логистическое взаимодействие.

Масштабность и результаты подобного взаимодействия будут существенным образом влиять не только на инновационный потенциал охватываемых территорий, но и на их общее развитие и благосостояние.

Особенности инновационного развития промышленных регионов предполагают учет особенностей индустриального характера. Это проявляется в инновационных системах разного уровня, т. е. управление развитием инновационных систем промышленных предприятий, индустриальных кластеров и федеральных округов. Наше видение специфики промышленных регионов состоит в необходимости анализа их взаимодействия в рамках федерального округа. Для этого используются следующие методы.

1. Создание и отладка цифрового двойника межкластерного взаимодействия в рамках целого федерального округа. Успешность использования цифровых двойников в производстве дает возможность разработать их для управления инновационным развитием округа. Отладка созданного двойника поможет более качественно планировать важные стратегические государственные решения в отношении межкластерного взаимодействия и соответственно инновационного развития округа. Данный подход важно изучать в условиях стохастической неопределенности.

2. Форсайт эволюции инновационной системы округа уже требует более качественного подхода, который учитывал бы особенности процесса эволюции подобной системы. Это позволяет сделать многоцелевой генетический алгоритм (MGA). Подобный имитационный подход дает возможность оценить и спланировать синергетический эффект межкластерного взаимодействия в округе.

3. Для качественного форсайта эволюции федерального округа необходима технология определения центра инновационно-индустриальных кластеров, которая обеспечивала бы их эффективное экономико-финансовое, информационное и логистическое взаимодействие. Для этого предлагается метод решения задачи размещения информационного и логистического центра кластеров. Для этого применяются генетический алгоритм, метод имитационного отжига и поиск по шаблону.

4. После этого становится возможным спланировать оптимальную промышленную агломерацию федерального округа, которая учитывала бы особенности экономико-финансового, информационного и логистического межкластерного взаимодействия в округе. Для решения обозначенной проблемы используется муравьиный алгоритм.

5. С целью оптимизации затрат на НИР регионов необходима модель планирования программ инновационного развития, которая основывается на одновременном инвестиционном, производственном и финансовом планировании. Наиболее совершенным для решения такой задачи является алгоритм поиска по шаблону.

6. Также требуется модель оптимизации и планирования перекрестного финансирования затрат на НИР в федеральном округе, учитывающая конкретные технологические и экономические результаты НИР регионов округа. В ней оптимизация проводится с помощью генетического алгоритма, имитационного отжига и поиска по шаблону.

7. Наиболее важную часть управления инновационным развитием федерального округа составляет рациональная мотивация топ-менеджмента его управляющих структур. Нематериальную и материальную мотивацию топ-менеджеров предлагается моделировать и оценивать с помощью MGA. Для этого определяются параметры моделирования и оценки, которые ориентированы одновременно на интересы топ-менеджеров и населения федерального округа.

8. Целью дальнейшего исследования является создание модели мотивации топ-менеджмента государственных структур регионов страны, что позволит поставить нематериальную мотивацию топ-менеджеров в зависимость от достигнутого стратегического потенциала региона и их материальной мотивации. Для этого решается

трехцелевая задача глобальной оптимизации коэффициента естественного прироста населения с помощью MGA.

9. Наконец, для эффективного управления инновациями со стороны топ-менеджеров государственных структур необходимо оптимизировать предвыборные кампании. Для решения такой задачи используются муравьиный алгоритм и алгоритм имитационного отжига.

Подобные подходы позволят более конструктивно управлять развитием инновационных систем промышленных регионов, а также принимать более качественные государственные решения, которые учитывали бы экономико-социальные ценности и интересы населения регионов.

## Глава 2

### Цифровые двойники межкластерного взаимодействия

#### 2.1. Создание цифрового двойника межкластерного взаимодействия: имитационный отжиг

В настоящее время технологии программирования и искусственного интеллекта прочно вошли в различные сферы жизнедеятельности и развития общества. Одним из таких направлений является применение цифровых двойников в производстве. Это позволяет корректировать различные параметры модели сложного изделия в режиме реального времени, не прибегая в этом случае к работе с реальным опытным образцом изделия. Так, к примеру, поступают в проектировании и производстве автомобилей.

Подобные модели цифровых двойников начинают применять в других отраслях, например, в финансовом и инвестиционном анализе. Однако использование цифровых двойников дает также широкие возможности и для прочих отраслей. Здесь мы говорим об управлении инновационно-индустриальными кластерами [26], а также об их взаимодействии между собой. Оптимизация подобных процессов, безусловно, позволит развиваться кластерам более эффективно с социальной, экономической и технической точек зрения.

На современных конкурентных рынках при массовом производстве новой продукции цифровые технологии в производстве рассматриваются как возможность для достижения более высокой производительности [155]. Подобные цифровые технологии позволяют интегрировать взаимосвязанные компоненты внутри производств [121], что делает возможным осуществлять дистанционный контроль, мониторинг и управление устройствами через сетевую инфраструктуру, а значит, обеспечивают более надежную интеграцию и перенос данных физического объекта на виртуальный мир [104, 121].

Полученные большие объемы данных (Big Data) обрабатываются, анализируются и оцениваются с помощью алгоритмов имитационного моделирования и глобальной оптимизации, чтобы иметь возможность сделать их доступными для планирования в режиме реального времени [42].

Цифровые двойники (Digital Twin, DT) — это одна из концепций планирования и оптимизации производства с большим потенциалом во многих областях промышленности [149]. Это компьютерный аналог рассматриваемой физической системы. Цифровой двойник может использоваться для имитации работы реального объекта в различных целях. При этом синхронизируются различные данные, поступающие от него в режиме реального времени, что способствует осуществлению выбора оптимального воздействия на реальный объект и позволяет повысить эффективность производства продукции, а следовательно, и эффективность деятельности самого производственного предприятия [121, 136, 155].

Впервые упоминание технологии цифрового двойника произошло в 2002 г. Этот термин ввел Майкл Гривз (Michael Grieves) с целью отраслевой презента-

ции управления жизненным циклом продукта (PLM). Цифровой двойник в своем первоначальном виде описывался как цифровое информационное отражение физического объекта, созданное как единое целое и связанное с исходным физическим объектом. Цифровой двойник должен оптимально включать всю информацию о реальном объекте, что возможно только при его тщательном изучении [73].

В своих публикациях в 2012 г. Глассен и Стардель представили подробное определение: “цифровой двойник представляет собой интегрированное мультифизическое, масштабное, вероятностное моделирование сложного продукта и использует данные о физической модели, поступающие с различных датчиков, чтобы отразить реальное состояние физической модели” [149].

Современный уровень развития техники и технологий позволяет моделировать цифровые модели не только отдельных продуктов производства, но и целых технологических процессов. Первые модели цифровых двойников появились в аэрокосмической отрасли в виде технологических дорожных карт NASA [149]. Ключевым элементом функционирования ДТ является предоставление различной информации об объекте в согласованном формате. ДТ включают в себя не только данные, но и алгоритмы, которые описывают функционирование исходного объекта и определяют действия всей системы на основе этих обработанных данных [42].

В терминологии производства [70] имеется следующее определение цифрового двойника: ДТ состоит из виртуального отображения производственной системы, которая может работать при различных задачах моделирования и характеризуется синхронизацией между виртуальной и реальной системами благодаря считыванию данных и их обработкой интеллектуальными математическими моделями в реальном времени. Ключевая роль ДТ в производственных системах заключается в использовании этих возможностей для прогнозирования и оптимизации поведения производственной системы на каждом этапе ее жизненного цикла [121]. Но в отдельных отраслях существуют различные понимания сути цифровых двойников [105, 136, 149].

Применение цифровых двойников на практике тесно связано с технологиями программирования и искусственного интеллекта. Одним из методов искусственного интеллекта является имитационное моделирование. К наиболее мощным алгоритмам имитационного моделирования можно отнести:

- 1) генетический алгоритм (genetic algorithm);
- 2) имитационный отжиг (simulated annealing);
- 3) поиск по шаблону (pattern search);
- 4) муравьиный алгоритм (ant algorithm).

Наибольший практический интерес представляет алгоритм имитационного отжига в силу ряда его преимуществ:

1. Метод отжига позволяет избежать “ловушки” в локальных экстремумах оптимизируемой функции и продолжить поиск глобального экстремума [14].

2. Даже в условиях нехватки вычислительных мощностей для нахождения глобального экстремума метод отжига, как правило, выдает неплохое решение, т. е. один из локальных экстремумов [14].

3. При сравнении адаптивного метода отжига (Adaptive Simulated Annealing, ASA) и генетических алгоритмов получено, что в большинстве задач метод отжига не проигрывает генетическим алгоритмам, а во многих и выигрывает [85].

Алгоритм имитационного отжига относится к вероятностным методам решения, что подразумевает случайный выбор одного или нескольких возможных решений вместо анализа каждого. Это позволяет существенно сократить время счета. Основная идея имитационного отжига заключается в контролируемом охлаждении, что приводит в итоге к желаемой структуре анализируемой системы. Если дать возможность алгоритму случайно выбирать решение, оптимальное на каждом шаге (жадный алгоритм), то можно пропустить ход, не лучший локально, но дающий в результате более оптимальное решение.

Существуют различные общие схемы метода отжига, среди которых обычно выделяют больцмановский отжиг [95, 112], отжиг Коши (быстрый отжиг) [23, 147], сверхбыстрый отжиг [84], алгоритм Ксин Яо [161] и методы “тушения” [86, 87]. В работе А. С. Лопатина [14] показано, что версия алгоритма сверхбыстрого отжига сходится значительно быстрее других методов. При этом отжиг Коши также приводит к низким значениям невязки при большом числе вызовов функции — порядка 50 000.

Эволюция инновационно-индустриальных кластеров предопределяется не только их самостоятельным развитием, но и эффективным взаимодействием кластеров между собой. Здесь в качестве наиболее важных направлений подобного взаимодействия следует рассматривать три их вида:

- 1) экономико-финансовое взаимодействие;
- 2) информационное взаимодействие;
- 3) логистическое взаимодействие.

Прежде всего эти три вида взаимодействия инновационно-индустриальных кластеров между собой определяют перспективность инновационного развития большой территории, на которой они расположены. Под такими территориями можно понимать федеральные округа России.

При этом основной наиболее значительной характеристикой успешности социально-экономического развития инновационно-индустриальных кластеров в рамках одного федерального округа мы считаем естественный прирост населения региона, в котором находится тот или иной кластер.

Далее следует определиться с параметрами, от которых зависит прирост населения региона, после чего можно перейти к построению и отладке цифрового двойника механизма межкластерного взаимодействия. При этом выбранные параметры должны соответствовать цели создания компьютерной цифровой модели перечисленных ранее трех видов взаимодействия. А затем следует построение и отладка цифрового двойника указанного взаимодействия кластеров между собой (рис. 1).

Использование подхода, представленного на рис. 1, позволит избежать преждевременных необоснованных управленческих решений государственного масштаба в отношении дальнейшего развития инновационно-индустриальных кластеров,

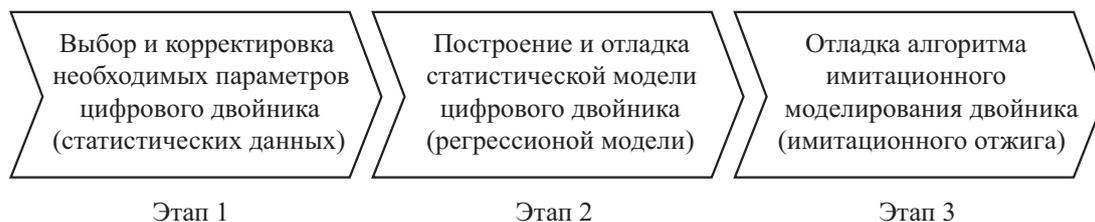


Рис. 1. Этапы создания и отладки цифрового двойника механизма межкластерного взаимодействия

расположенных на территории конкретного федерального округа России, и, напротив, смоделировать механизм межкластерного взаимодействия на компьютере в виде соответствующего цифрового двойника. Это позволит затем отладить указанный цифровой двойник так, чтобы получить оптимальное управленческое решение в смысле глобальной оптимизации, после чего принять его на практике с возможностью планирования и корректировки будущих государственных решений на компьютере, используя уже отлаженный цифровой двойник.

С целью конкретизации модели рассмотрим этапы на рис. 1 более детально.

**Этап 1 — выбор и корректировка необходимых параметров цифрового двойника.** Эффективность межкластерного взаимодействия лучше всего отражает естественный прирост населения ( $y$ ) в анализируемых регионах, в которых расположены соответствующие инновационно-индустриальные кластеры. Именно этот показатель является наиболее оправданной характеристикой образования и дальнейшей эволюции кластеров.

Однако прирост населения необходимо поставить в зависимость от таких факторов модели цифрового двойника, которые отражали бы в достаточной мере направления межкластерного взаимодействия, к числу которых относятся экономико-финансовое, информационное и логистическое виды взаимодействия. К таким факторам мы относим среднедушевые денежные доходы населения (в месяц) ( $x_1$ ), инвестиции в основной капитал ( $x_2$ ) и экспорт минус импорт ( $x_3$ ). Перераспределение величины данных показателей со стороны государства и бизнеса внутри конкретного федерального округа между регионами, где находятся кластеры, совершенно очевидно отражает их экономико-финансовое взаимодействие. Кроме того, перераспределение инвестиций в основной капитал естественным образом происходит из информационного взаимодействия кластеров. К тому же если среднедушевые доходы населения в одном регионе выше, чем в другом, то это приведет к миграции соответствующей рабочей силы и интеллектуального капитала в лице необходимых специалистов между регионами. Следовательно, это также является следствием информационного взаимодействия кластеров между собой. Наконец, логистическое взаимодействие кластеров также отражает процессы миграции капитала и квалифицированных кадров между соответствующими регионами федерального округа, что кроме всего прочего находит отражение и в показателе экспорта минус импорт.

Таким образом, нами рассматривается функция 3-х переменных  $y = f(x_1, x_2, x_3)$  для планирования перераспределения перечисленных ресурсов со стороны государства во взаимодействии с бизнесом с целью увеличения естественного прироста населения федерального округа. Однако по причине того, что исходные статистические данные всех 3-х переменных выражены в рублях или долларах, их, прежде, чем использовать, необходимо скорректировать на соответствующие темпы инфляции для того, чтобы все данные были представлены в ценах последнего анализируемого года.

**Этап 2 — построение и отладка модели цифрового двойника.** В качестве такой модели будем использовать модель множественной нелинейной регрессии как наиболее приближенной к описанию реальных процессов, происходящих в экономике, в том числе и для инновационно-индустриальных кластеров. Практической задачей исследования на данном этапе будет выбор такой регрессии, которая будет наиболее качественной по необходимым статистическим параметрам, а также которая не будет противоречить логике, т. к., следуя рекомендациям А. Дамодарана [51], в любом анализе необходимо руководствоваться здравым смыслом.

**Этап 3 — отладка алгоритма имитационного моделирования.** В качестве алгоритма имитационного отжига будем использовать отжиг Коши, т. е. быстрый отжиг. Но для достижения глобального экстремума регрессионной функции, полученной на этапе 2, указанный отжиг следует дополнительно отладить, что подразумевает корректировку параметров температуры отжига и определение времени остановки решателя. Подобную отладку необходимо произвести один раз на примере полученной регрессионной функции, глобальный экстремум которой можно найти аналитически. Это позволит отладить алгоритм отжига так, чтобы он гарантировал с достаточной достоверностью достижение глобального экстремума и не требовал последующей отладки алгоритма в случае получения новых регрессий.

Таким образом, мы получаем гибкую адаптированную модель цифрового двойника механизма межкластерного взаимодействия.

**Пример 1.** Рассмотрим процесс создания и отладки цифрового двойника механизма межкластерного взаимодействия на примере Приволжского федерального округа (ПФО).

Согласно перечню, утвержденному Правительством РФ, в России действуют 25 пилотных инновационных территориальных кластеров по регионам Российской Федерации. Тогда будем рассматривать в ПФО только те регионы (области или республики), в которых расположены кластеры из данного перечня (табл. 1).

**Этап 1 — выбор и корректировка необходимых параметров цифрового двойника.** Используя показатели “Статистического обозрения” Федеральной службы государственной статистики, сгруппируем необходимые данные о естественном приросте населения, среднедушевых доходах населения (в месяц), инвестициях в основной капитал и об экспорте минус импорт за 10 лет с 2009 по 2018 г. При этом с целью сравнимости данных скорректируем показатели, измеряемые в рублях или долларах, на инфляцию (табл. 2). Таким образом, получаем данные в ценах 2018 г. в табл. 3.

Таблица 1

### Инновационные территориальные кластеры по регионам ПФО

Регионы	Инновационные кластеры
1. Нижегородская область	Нижегородский индустриальный инновационный кластер в области автомобилестроения и нефтехимии
2. Республика Мордовия	Энергоэффективная светотехника и интеллектуальные системы управления освещением
3. Ульяновская область	Консорциум “научно-образовательно-производственный кластер “Ульяновск-Авиа”
	Ядерно-инновационный кластер г. Димитровград
4. Самарская область	Инновационный территориальный аэрокосмический кластер
5. Пермский край	Инновационный территориальный кластер ракетного двигателестроения “Технополис “Новый Звездный”
	Фотоника
6. Удмуртская республика	Удмуртский машиностроительный кластер
7. Республика Татарстан	Камский инновационный территориально-производственный кластер
8. Республика Башкортостан	Нефтехимический территориальный кластер

Таблица 2

### Годовые темпы инфляции (%)

	2010	2011	2012	2013	2014	2015	2016	2017	2018
Рубль	8,78	6,1	6,58	6,45	11,36	12,91	5,38	2,52	4,27
Доллар	1,5	2,96	1,74	1,5	0,76	0,73	2,07	2,11	1,91

**Этап 2 — построение и отладка модели цифрового двойника.** Используя данные табл. 3, в программе *Statistica* получены две наиболее достоверные модели множественной нелинейной регрессии:

$$\text{регрессия 1: } y = -290,198 + 0,036 x_2 + 57,229\sqrt{x_1} - 33,052\sqrt{x_2},$$

$$\text{регрессия 2: } y = 15\,283 - 148\,867\,881 \frac{1}{x_1} - 35\sqrt{x_2}.$$

При этом сама программа *Statistica* отбросила переменную  $x_3$  как незначимую.

Обе регрессии получились достаточно качественными, что иллюстрируют рис. 2 и 3. Коэффициенты детерминации для регрессий получились примерно одинаковыми, т. е.  $R^2 \approx 0,62$ .

Таблица 3

Данные для построения регрессионной модели в ценах 2018 г.

Регионы	С/душевые денежные доходы населения (в месяц) (руб.)	Инвестиции в основной капитал (млн руб.)	Экспорт минус импорт (млн долл.)	Естест- венный прирост населения (чел.)
1. Нижегородская область	$x_1$	$x_2$	$x_3$	$y$
2009	26 646,5	364 200	323,8	-22 094
2010	27 399	293 805,4	67,1	-22 942
2011	28 948,2	356 243,3	2 097,9	-17 869
2012	32 204,6	389 268,9	1 578,1	-13 890
2013	34 216,8	385 562,5	1 676	-13 457
2014	35 548,8	364 555,9	2 051,8	-12 846
2015	34 663,1	257 909,3	886,4	-10 714
2016	32 503,3	234 809,1	669,4	-11 420
2017	31 967,1	254 493	445,1	-13 556
2018	31 631	259 045,4	1 216,8	-15 917
2. Республика Мордовия	$x_1$	$x_2$	$x_3$	$y$
2009	17 624,5	60 431,5	-61,9	-4 896
2010	18 794,6	65 463,8	-28,1	-5 211
2011	18 495,5	74 836	-17	-4 414
2012	19 478,1	74 621,1	-74,4	-3 691
2013	20 234,8	76 059,2	17,5	-3 855
2014	20 460	70 326,3	93	-3 434
2015	19 843,1	58 975,9	-2,2	-3 567
2016	19 000	56 500	30,3	-3 457
2017	18 914,6	62 474,5	47,9	-4 008
2018	18 048	51 210,1	44,3	-4 094
3. Ульяновская область	$x_1$	$x_2$	$x_3$	$y$
2009	19 362	90 379	70,2	-5 734
2010	21 503,8	76 465,4	117,4	-6 690
2011	22 223	99 259,3	30,2	-5 101
2012	24 621,3	109 859,2	-21,9	-3 551
2013	25 858,6	107 972	-258,1	-3 523
2014	27 545,9	104 511,3	-14	-3 397

Продолжение табл. 3

Регионы	С/душевые денежные доходы населения (в месяц) (руб.)	Инвестиции в основной капитал (млн руб.)	Экспорт минус импорт (млн долл.)	Естест- венный прирост населения (чел.)
3. Ульяновская область	$x_1$	$x_2$	$x_3$	$y$
2015	25 522,8	101 496,5	-67,7	-3 734
2016	23 501,4	73 628,4	-15,3	-3 997
2017	23 980	95 728	-57	-4 944
2018	22 846	81 105,4	-254,9	-5 413
4. Самарская область	$x_1$	$x_2$	$x_3$	$y$
2009	33 303,5	203 968,9	3 420,1	-10 713
2010	34 014,9	226 028,2	5 769,8	-11 809
2011	34 691,1	319 376,7	4 168,6	-9 516
2012	37 031	307 832,4	3 291,7	-5 641
2013	37 254,5	371 560,7	4 276,8	-6 594
2014	33 115,6	381 970,5	5 938,4	-5 402
2015	30 293,5	336 533,9	3 585,7	-4 687
2016	28 315	274 484,7	2 020,4	-4 277
2017	27 781,7	262 201,5	1 594,4	-9 284
2018	27 507	259 152,3	1 723,7	-9 927
5. Пермский край	$x_1$	$x_2$	$x_3$	$y$
2009	31 714,1	249 400,2	1 963,1	-4 511
2010	31 357	221 552,1	3 157,9	-3 153
2011	33 153	215 208	5 058,3	-1 765
2012	34 336,2	238 700,8	6 059,8	1 569
2013	36 360,1	267 302,7	5 366	1 584
2014	36 281,4	236 130,4	5 688,4	2 070
2015	37 117,7	244 438,1	5 035	1 383
2016	30 707,4	253 362,4	3 611,3	889
2017	29 701,3	264 639,6	2 938,4	-2 946
2018	28 777	238 007,9	3 180,2	-5 224
6. Удмуртская Республика	$x_1$	$x_2$	$x_3$	$y$
2009	20 042,8	76 615,2	-17	869
2010	20 968,3	72 199,6	1,5	622

Окончание табл. 3

Регионы	С/душевые денежные доходы населения (в месяц) (руб.)	Инвестиции в основной капитал (млн руб.)	Экспорт минус импорт (млн долл.)	Естест- венный прирост населения (чел.)
6. Удмуртская Республика	$x_1$	$x_2$	$x_3$	$y$
2011	22 351,7	97 862,4	781,7	1 495
2012	24 341	86 273,2	1 184	3 718
2013	26 318,5	101 725,9	452,6	2 776
2014	27 052,4	114 264	342,2	2 651
2015	27 740,9	90 503,7	167,2	2 662
2016	25 543,2	91 296,9	250,7	1 822
2017	24 874,7	83 364,7	51,5	-258
2018	24 415	97 892,8	-57,9	-1 670
7. Республика Татарстан	$x_1$	$x_2$	$x_3$	$y$
2009	28 782	497 040,8	8 170,6	-1 415
2010	30 792,5	521 763,6	11 221,9	-762
2011	31 867,1	620 525	14 488,8	3 752
2012	35 592	700 725,8	15 484,2	9 023
2013	36 843,6	<b>736 854,4</b>	13 959,5	10 218
2014	<b>37 914,6</b>	690 372,2	11 861,9	9 732
2015	35 513,6	695 245,1	7 452,5	10 416
2016	35 076,3	686 810,8	6 861	10 643
2017	33 673	664 837,7	6 496,5	4 240
2018	33 130	629 731	8 223,7	1 600
8. Республика Башкортостан	$x_1$	$x_2$	$x_3$	$y$
2009	29 927,6	259 180,6	3 271,5	2 305
2010	30 390,3	238 457,6	7 754,9	2 686
2011	31 009,2	297 102,9	8 499,9	1 374
2012	32 245,2	351 117,4	9 300,7	5 617
2013	34 085,1	377 093,5	9 156,6	5 895
2014	33 046,9	363 157,3	10 279,8	6 949
2015	31 493,2	356 778,5	5 629,3	5 089
2016	30 082,1	385 843,1	5 292,3	3 298
2017	29 603,3	272 034,6	2 679,4	-1 072
2018	28 645	267 868,1	2 650,2	-3 429

Regression Summary for Dependent Variable: Var4 (Total.sta)						
R= ,78713919 R <sup>2</sup> = ,61958810 Adjusted R <sup>2</sup> = ,57203661						
F(3,24)=13,030 p<,00003 Std.Error of estimate: 2087,9						
N=28	b*	Std.Err. of b*	b	Std.Err. of b	t(24)	p-value
<b>Intercept</b>			-290,198	7065,780	-0,04107	0,967579
Var2	2,60885	1,033753	0,036	0,014	2,52367	0,018644
SQRV2	-2,04652	1,141272	-33,052	18,432	-1,79319	0,085555
SQRV1	0,23914	0,236933	57,229	56,701	1,00932	0,322889

Рис. 2. Регрессия 1 для 8 регионов Приволжского федерального округа с кластерами

Regression Summary for Dependent Variable: Var4 (Total.sta)						
R= ,78749368 R <sup>2</sup> = ,62014630 Adjusted R <sup>2</sup> = ,57266459						
F(3,24)=13,061 p<,00003 Std.Error of estimate: 2086,3						
N=28	b*	Std.Err. of b*	b	Std.Err. of b	t(24)	p-value
<b>Intercept</b>			15283	9929	1,53917	0,136845
Var2	2,73627	1,100996	0	0	2,48526	0,020309
SQRV2	-2,18245	1,222732	-35	20	-1,78489	0,086925
1/V1	-0,25502	0,248224	-148867881	144901692	-1,02737	0,314489

Рис. 3. Регрессия 2 для 8 регионов Приволжского федерального округа с кластерами

Чтобы выбрать окончательно наиболее адекватную регрессию, построим их трехмерные графики в программе *Matlab* (рис. 4 и 5). При этом из табл. 3 берется диапазон среднедушевых денежных доходов населения (в месяц), который составляет сегмент [0; 37 914,6] руб. Соответственно диапазон инвестиций в основной капитал составляет сегмент [0; 736 854,4] млн руб.

Как уже указывалось ранее, следуя рекомендациям А. Дамодарана [51], в любом анализе необходимо руководствоваться здравым смыслом. Тогда неестественной представляется ситуация на рис. 5, где при максимальном доходе населения наибольший прирост населения будет при нуле инвестиций в основной капитал. Как известно, без инвестиций в основной капитал невозможно развитие инновационно-индустриальных кластеров, что, в свою очередь, приведет к падению производства и сокращению доходов населения в таком кластере. По этой причине в дальнейшем не будем рассматривать регрессию 2, а станем анализировать регрессию 1 как наиболее достоверную.

**Этап 3 — отладка алгоритма имитационного моделирования.** Если внимательно посмотреть на рис. 4, то видно, что при максимальном доходе населения 37 914,6 руб. и нулевых инвестициях в основной капитал будет самый большой прирост населения в среднем на один регион (правая часть графика). Далее если при максимальном доходе населения постепенно увеличивать инвестиции до максимума в 736 854,4 млн руб., то прирост населения будет уменьшаться почти до нуля, а затем снова увеличиваться, пока не достигнет нового максимума (левая часть

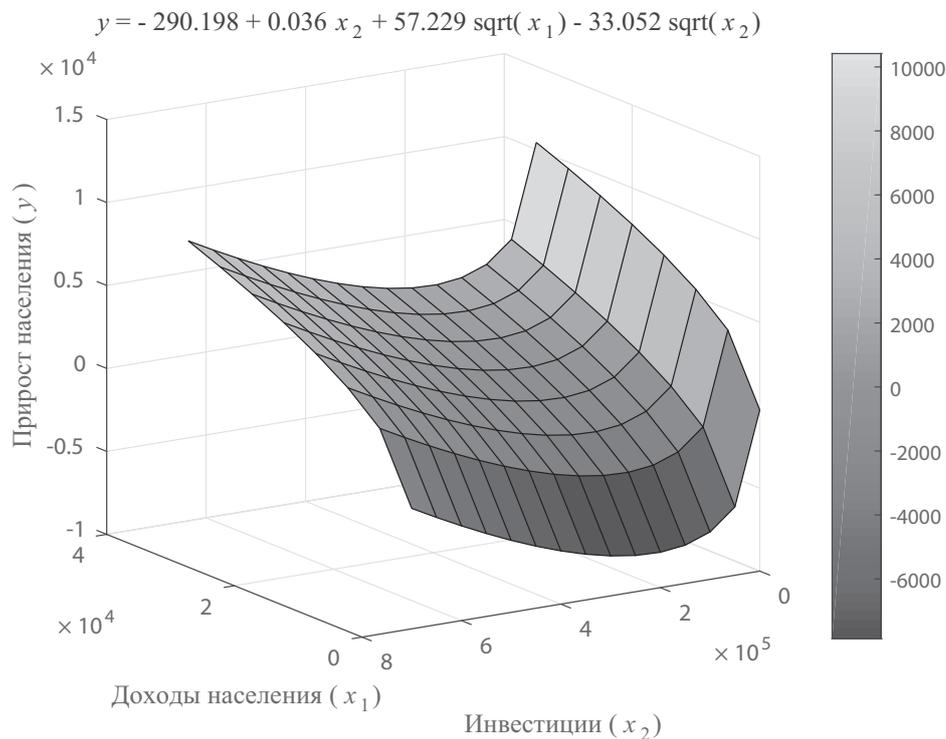


Рис. 4. График регрессии 1 для 8 регионов Приволжского федерального округа с кластерами

графика). Но при этом прирост населения все равно не достигнет глобального максимума (как на правой части графика).

Таким образом, имеем задачу нахождения максимального значения функции  $y$  на заданных сегментах ее аргументов:  $x_1 \in [0; 37\,914,6]$  и  $x_2 \in [0; 736\,854,4]$ . В нашем случае она решается аналитически:

$$\text{инвестиции } x_2 = 0 \text{ и доход населения } x_{1,\max} = 37\,914,6 \text{ руб.},$$

$$\text{тогда } y_{\max} = 10\,853,2 \text{ чел.}$$

Однако это позволяет отладить алгоритм имитационного отжига для выпуклого вниз по  $x_2$  графика функции  $y$  на рис. 4. Это необходимо для того, чтобы при дальнейшем изменении уравнения регрессии, например, при введении в него новых аргументов  $x$ , в процессе применения уже полученного цифрового двойника механизма межкластерного взаимодействия получалось бы наибольшее значение функции глобальное, а не локальное. Для этого подбираем параметры температурного режима и времени остановки решателя опытным путем, причем так, чтобы получилось решение, которое мы получили аналитически.

Отладка цифрового двойника проведена в программе *Matlab*. Для этого сначала создается *M*-файл-функция анализируемой регрессии (рис. 6).

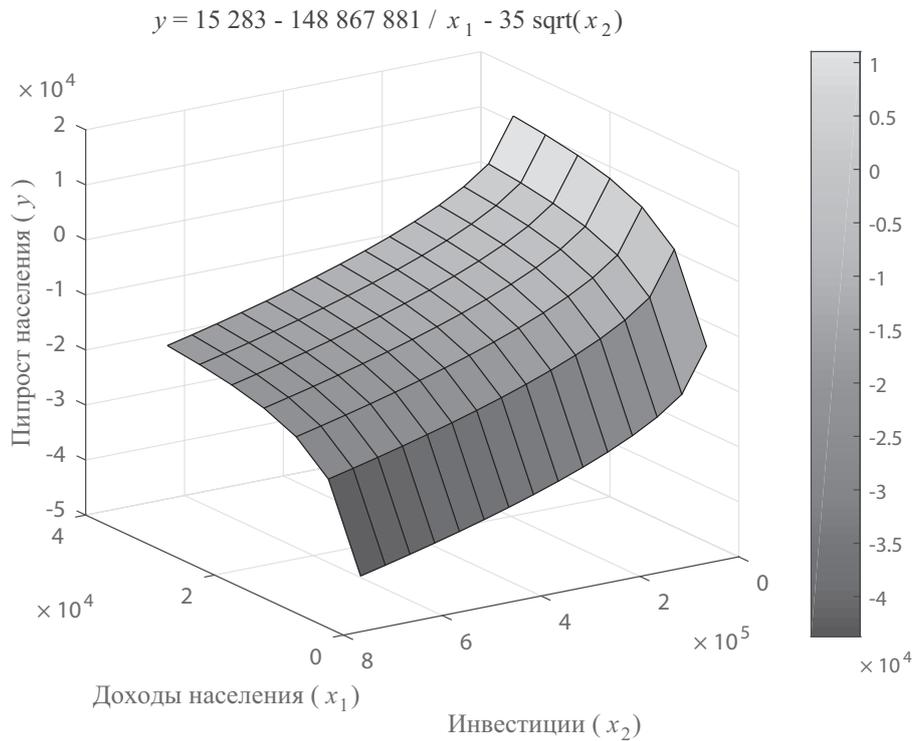


Рис. 5. График регрессии 2 для 8 регионов Приволжского федерального округа с кластерами

```
function y = simple_objective(x)
    y = 290.198 - 0.036*x(2) - 57.229*sqrt(x(1)) + 33.052*sqrt(x(2));
```

Рис. 6. М-файл-функция анализируемой регрессии

Затем выполняется программа с подобранными параметрами температурного режима и времени остановки решателя имитационного отжига (рис. 7).

В результате получается значение целевой функции  $y_{\max} = 10\,853$  чел.

Самым важным результатом для полученного цифрового двойника является то, что увеличение инвестиций в основной капитал далеко не всегда приводит к росту населения в регионах федерального округа. Население инновационно-индустриальных кластеров интересуется прежде всего рост его среднедушевых доходов. Это необходимо учитывать при перераспределении инвестиционных и человеческих ресурсов в рамках одного федерального округа. Временное сокращение инвестиций в основной капитал и одновременное повышение доходов населения в отдельно взятом регионе одного федерального округа может привести к более се-

```

>> % Сбрасываем состояние генератора случайных чисел
>> RandStream.getGlobalStream.State = output.rngstate.state;
>> % Вызываем целевую функцию
>> ObjectiveFunction = @simple_objective;
>> % Задаем начальную точку
>> startingPoint = [0 0];
>> % Задаем диапазон целевой функции
>> lb = [0 0];
>> ub = [37914.6 736854.4];
>> % Указываем вектор температур
>> options = optimoptions(@simulannealbnd, 'InitialTemperature', [600 100]);
>> % Указываем начальную температуру
>> options.InitialTemperature = 6000;
>> % Задаем интервал температуры, с которым происходит повторный отжиг
>> options.ReannealInterval = 50;
>> % Определение времени остановки решателя
>> options.FunctionTolerance = 1e-5;
>> % Запуск решателя simulannealbnd
>> [x, fval, exitFlag, output] = simulannealbnd(ObjectiveFunction, startingPoint, lb, ub, options);
>> fprintf('Количество итераций: %d\n', output.iterations);
>> fprintf('Число оценок функций составило: %d\n', output.funcscount);
>> fprintf('Найдено лучшее значение функции: %g\n', fval);

```

Рис. 7. Текст программы в *Matlab*

рьезному приросту населения в регионе по сравнению с ситуацией, когда недостаток доходов населения компенсируется приростом инвестиций в основной капитал.

Таким образом, более четко спланированное экономико-финансовое, информационное и логистическое взаимодействие между инновационно-индустриальными кластерами в конкретном федеральном округе, которое отражено в полученном цифровом двойнике, поможет решать как тактические, так и стратегические задачи эволюции кластеров, решаемые государством и бизнесом совместно.

## **2.2. Отладка цифрового двойника в условиях стохастической неопределенности: поиск по шаблону**

Стохастическая оптимизация — это целый класс алгоритмов оптимизации, которые используют случайность в процессе поиска оптимального решения. Случайность может проявляться в разных сферах. Обычно алгоритмы стохастической оптимизации используют в случае, если целевая функция сложная, многоэкстремальная, с разрывами, с помехами (шумом) и т. д.

В настоящее время существует множество различных подходов стохастической оптимизации. К примеру, О. А. Измакова [9] описала два новых алгоритма задачи самообучения, принадлежащие классу рандомизированных алгоритмов стохастической аппроксимации. В качестве примера рассмотрена задача обучения нейронной сети Хебба–Хопфилда и предложен метод ее решения, основанный на вариационном подходе.

Л. Сакалаускас [20] рассмотрел метод нелинейной стохастической оптимизации сериями выборок Монте–Карло, предложил процедуру останова алгоритма, которая основана на проверке статистической гипотезы равенства градиента целевой функции нулю и оценке ее доверительного интервала.

С. С. Сысоев [22] для рандомизированного алгоритма стохастической оптимизации ослабил условия состоятельности его оценок, рассмотрел порядки точности при конечном числе наблюдений, а также предложил новую схему реализации данного алгоритма на квантовых компьютерах.

А. В. Гасников, П. Е. Двуреченский и Ю. Е. Нестеров [5] предприняли попытку описать современное состояние методов проекции градиента (в том числе прямых методов и методов покомпонентного спуска) решения задач выпуклой стохастической оптимизации с неточным оракулом (неточность неслучайной природы), выдающим стохастический субградиент.

В качестве основного метода стохастической оптимизации, который будет применяться в настоящем исследовании, рассмотрим метод поиска по шаблону (Pattern Search, Direct Search). Прямой поиск (поиск по шаблону) — это метод решения задач оптимизации, не требующий никакой информации о градиенте целевой функции. В отличие от более традиционных методов оптимизации, которые используют информацию о градиенте или более высоких производных для поиска оптимальной точки, алгоритм прямого поиска ищет множество точек вокруг текущей точки, ищущей точку, где значение целевой функции ниже значения в текущей точке. Этот

метод можно использовать для решения проблем, для которых целевая функция не является дифференцируемой или даже не является непрерывной [48, 49, 98].

Данный метод изначально предложили Р. Хук и Т. А. Дживз [79] для решения численных и статистических проблем.

М. Дж. Д. Пауэлл [133] привел некоторые примеры для дифференцируемых функций трех переменных, имеющих свойство, что если они обрабатываются алгоритмом минимизации, который ищет вдоль направлений координат последовательно, то путь поиска стремится к замкнутому контуру. В этом цикле градиент целевой функции ограничен нулем. Он обсудил актуальность этих примеров для проблемы доказательства общих теорем сходимости для алгоритмов минимизации, которые используют направления поиска.

У. К. Давидон [54], рассматривая минимизацию переменной метрики, предложил метод определения численно локальных минимумов дифференцируемых функций нескольких переменных. В процессе определения местоположения каждого минимума он определял матрицу, которая характеризует поведение функции относительно минимума. Для области, в которой функция квадратично зависит от переменных, требовалось не более  $N$  итераций, где  $N$  — число переменных. При подходящем выборе исходных значений и без модификации процедуры линейные ограничения могли быть наложены на переменные.

К. И. М. МакКиннон [110] проанализировал поведение симплексного метода Нелдера–Мида для семейства примеров, которые вызывают сходимость метода к нестационарной точке. Во всех примерах использовались непрерывные функции двух переменных. Семейство функций содержало строго выпуклые функции с тремя непрерывными производными. Во всех примерах способ повторно применяет этап внутреннего сжатия, при этом лучшая вершина остается фиксированной. Симплексы имеют тенденцию к прямой линии, которая ортогональна наиболее крутому направлению спуска. Показано, что такое поведение не может происходить для функций с более чем тремя непрерывными производными.

В. Дж. Торкзон [153] ввела абстрактное определение методов поиска шаблона для решения нелинейных задач оптимизации без ограничений. Ее определение объединяет важный набор методов оптимизации, которые ни вычислительные, ни явно аппроксимирующие производные. Она использовала свою характеристику методов поиска моделей для создания теории глобальной конвергенции, которая не обеспечивает реализацию понятия достаточного уменьшения. Такой анализ возможен, потому что итерации метода поиска шаблона лежат на масштабированной, преобразованной целочисленной решетке. Это позволяет ослабить классические требования по приему шага за счет более сильных условий по форме шага и все же гарантировать глобальное приближение.

Е. Д. Долан, Р. М. Льюис и В. Дж. Торкзон [57] изучили свойства локальной сходимости методов поиска шаблонов, дополняя ранее установленные свойства глобальной сходимости для этого класса алгоритмов. Они показали, что параметр управления длиной шага, появляющийся в определении алгоритмов поиска шаблона, обеспечивает надежную асимптотическую меру статичности первого порядка.

Это дает аналитическое обоснование традиционного критерия останковки для поиска шаблонов. Используя этот показатель статичности первого порядка, пересмотрены глобальные свойства сходимости поиска по шаблону и проанализировано поведение поиска по шаблону в окрестности изолированного локального минимизатора.

Ч. Одет и Дж. Е. Дэннис [36] предложили новый анализ сходимости для класса методов поиска обобщенных шаблонов Льюис и Торкзон (GPS) для оптимизации без ограничений и с линейными ограничениями. Этот анализ необходим, чтобы понять успешное поведение алгоритма согласно гипотезам, которые подтверждаются многими практическими задачами. В частности, даже если целевая функция является разрывной или расширенной, методы находят предельную точку с некоторыми минимизирующими свойствами. Простые примеры показали, что сила условий оптимальности в предельной точке зависит не только от алгоритма, но и от используемых им направлений и от гладкости целевой функции в рассматриваемой предельной точке. Вклад этого документа состоит в том, чтобы предоставить простой анализ сходимости, который дает подробные сведения о соотношении условий оптимальности к объективным свойствам гладкости и к определяющим направлениям для алгоритма.

Т. Г. Колда, Р. М. Льюис и В. Торкзон [97] в 2003 г. провели обзор методов прямого поиска, который начинается с краткого обобщения истории методов прямого поиска и рассмотрения особых свойств задач, для которых они хорошо подходят. Затем авторы переходят к широкому классу методов, для которых обеспечивается объединяющая основа, которая дает различные результаты конвергенции. Лежащие в основе принципы позволяют обобщению обрабатывать связанные ограничения и линейные ограничения. Также авторы обсудили расширения задач с нелинейными ограничениями.

Р. М. Льюис, А. Шеферд и В. Торкзон [106] изучили реализацию метода поиска без производных генерирующих наборов для линейно ограниченной минимизации без допущения неразрешимости ограничений. Гарантии сходимости для генерации методов поиска набора требуют, чтобы набор направлений поиска обладал определенными геометрическими свойствами, которые позволяют ему аппроксимировать возможную область вблизи текущей итерации. В жестком случае вычисление направлений поиска соответствует нахождению крайних лучей конуса с деформирующей вершиной у истока, что является сложной задачей. Авторы исследовали, как современные методы вычислительной геометрии позволяют решить эту проблему в связи с созданием набора поиска. Также ими изучены ряд других практических вопросов реализации алгоритма, таких как тщательное рассмотрение ограничений на равенство и желательность расширения набора направлений поиска за пределы теоретически минимального набора. Проиллюстрировано поведение реализации по нескольким задачам из набора тестов CUTEr. Она была успешной в задачах с несколькими сотнями переменных при линейных ограничениях.

Ч. Одет и Дж. Дэннис [37] рассмотрели проблему минимизации несимметричной функции при общих несимметричных ограничениях, когда нет доступных производных целевых или ограничительных функций. Они ввели сетчатый адаптивный

прямой поиск (MADS) класса алгоритмов, который расширяет класс обобщенного поиска шаблонов (GPS), позволяя локальное исследование, называемое опрос, в асимптотически плотном наборе направлений в пространстве оптимизационных переменных. Это означает, что при определенной гипотезе, включая слабую квалификацию ограничения, MADS может лечить ограничения с помощью крайнего барьерного подхода, устанавливая цель до бесконечности для бесконечных точек и рассматривая проблему как неограниченную. Главным результатом сходимости GPS является определение предельных точек  $\hat{x}$ , где обобщенные производные Кларка являются неонегативными в конечном наборе направлений, называемых направлениями уточнения. Хотя в неограниченном случае неотрицательные комбинации этих направлений охватывают все пространство, тот факт, что может быть только финально много направлений уточнения GPS, ограничивает строгое обоснование барьерного подхода к финально многим линейным ограничениям для GPS. Основным результатом состоит в том, что общий каркас MADS является достаточно гибким, чтобы позволить генерировать асимптотически плотный набор направлений рафинирования, вдоль которых производные Кларка являются неонегативными. Ученые предложили пример MADS, для которого направления рафинирования являются плотными в гипертоническом конусе при  $\hat{x}$  с вероятностью 1 всякий раз, когда итерации, связанные с направлениями рафинирования сходятся к одному  $\hat{x}$ . Экземпляр MADS сравнивается с версиями GPS на некоторых тестовых проблемах.

М. А. Абрамсон и др. [32] ввели новый способ выбора направлений для сетчатого адаптивного класса прямого поиска (MADS) алгоритмов. Преимущества этого нового экземпляра OrthoMADS заключаются в том, что направления опроса выбираются детерминированно, гарантируя, что результаты данного прогона повторяются и что они ортогональны друг другу, что дает выпуклые конусы пропущенных направлений при каждой итерации, которые минимальны в разумной мере. Результаты сходимости для OrthoMADS следуют непосредственно из уже опубликованных для MADS, и они держатся детерминированно, а не с вероятностью один, как в случае LtMADS, т. е. первого экземпляра MADS. Первоначальные численные результаты весьма хороши как для гладких, так и для негладких, а также ограниченных и неограниченных задач.

Отдельный интерес представляет результат А. Хендры и С. Адинугрохо [77] в области технологий энергетики и автоматизации, где основной темой является оптимизация “Контроль за прогнозом модели” (Model Prediction Control, MPC). MPC использует множество параметров и некоторые из них могут быть настроены автоматически с помощью числовой оптимизации. Эти параметры интересуют исследователей, т. к. точно настроенные параметры дают надежный и стабильный MPC. Есть много методов и алгоритмов, которые могут быть использованы для численной оптимизации, и целью авторов было предоставление эталона для некоторых методов и алгоритмов с точки зрения скорости и результата.

Представим модель стохастической оптимизации экономико-финансового, информационного и логистического межкластерного взаимодействия в рамках отдельно взятого федерального округа на рис. 8.

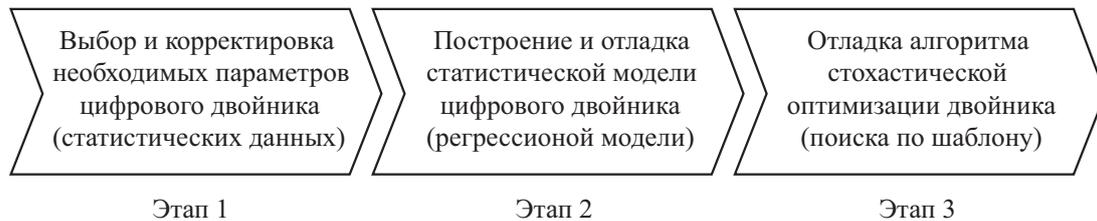


Рис. 8. Модель стохастической оптимизации межкластерного взаимодействия

Как видно на рис. 8, модель основана на идее создания и отладки цифрового двойника механизма указанных видов взаимодействия. Тогда поясним подробнее, как эти виды взаимодействия связаны между собой в данном цифровом двойнике. Для этого перейдем к описанию этапов реализации модели.

Первые два этапа аналогичны таким же этапам на рис. 1 (параграф 2.1).

**Этап 3 — отладка алгоритма стохастической оптимизации цифрового двойника.** Основная идея данного алгоритма заключается в том, что ищется глобальное наибольшее значение функции многих переменных на заданном сегменте при наличии стохастической неопределенности в целевой функции. В качестве целевой функции берется та регрессия, которая наиболее оправдана с позиции эконометрики и при этом не противоречит здравому смыслу аналитика. Однако при этом могут получиться другие регрессионные зависимости, которые будут не хуже целевой функции с позиции качества статистической модели. Их следует рассматривать как элементы шума для исследуемой целевой функции.

После этого определяется примерная величина данного шума, и целевая функция оптимизируется в глобальном смысле с учетом шума. Для этого будем использовать алгоритм поиска по шаблону (Pattern Search, Direct Search). Однако его стандартные настройки могут не позволить найти глобальное наибольшее значение стохастической функции, т. е. есть опасность “застрять” в локальном наибольшем значении в процессе имитационного моделирования. Для решения подобной проблемы будем использовать следующие дополнительные настройки поиска по шаблону.

Функции глобальной оптимизации включают в себя три алгоритма прямого поиска (поиска по шаблону), называемые алгоритмом поиска обобщенных шаблонов (GPS), алгоритмом поиска генерирующих наборов (GSS) и алгоритмом ячеистого адаптивного поиска (MADS). Все они представляют собой алгоритмы поиска шаблонов, которые вычисляют последовательность точек, приближающихся к оптимальной точке. На каждом шаге алгоритм ищет набор точек, называемый сеткой, вокруг текущей точки — точки, вычисленной на предыдущем шаге алгоритма. Сетка формируется путем добавления текущей точки к скалярному множеству набора векторов, называемого массивом. Если алгоритм поиска шаблона находит точку в сетке, которая улучшает целевую функцию в текущей точке, новая точка становится текущей точкой на следующем шаге алгоритма.

Алгоритм GPS использует векторы фиксированного направления. Алгоритм GSS идентичен алгоритму GPS, за исключением случаев, когда существуют

линейные ограничения, и когда текущая точка находится вблизи границы линейного ограничения. Алгоритм MADS использует случайный выбор векторов для определения сетки.

**Пример 1** (продолжение). Рассмотрим снова процесс создания и отладки цифрового двойника механизма межкластерного взаимодействия на примере Приволжского федерального округа (ПФО).

Первые два этапа нами уже пройдены в параграфе 2.1.

Построим обе регрессии (рис. 2 и 3) в программе *Matlab* на одном графике (рис. 9). Неестественной представляется ситуация для регрессии 2 на нижнем графике, где при максимальном доходе населения наибольший прирост населения будет при нуле инвестиций в основной капитал. Как известно, без инвестиций в основной капитал невозможно развитие инновационно-индустриальных кластеров, что, в свою очередь, приведет к падению производства и сокращению доходов населения в таком кластере. Тогда в качестве целевой функции принимаем регрессию 1, а регрессию 2, уравнение которой показано на рис. 9, в дальнейшем будем рассматривать как шум.

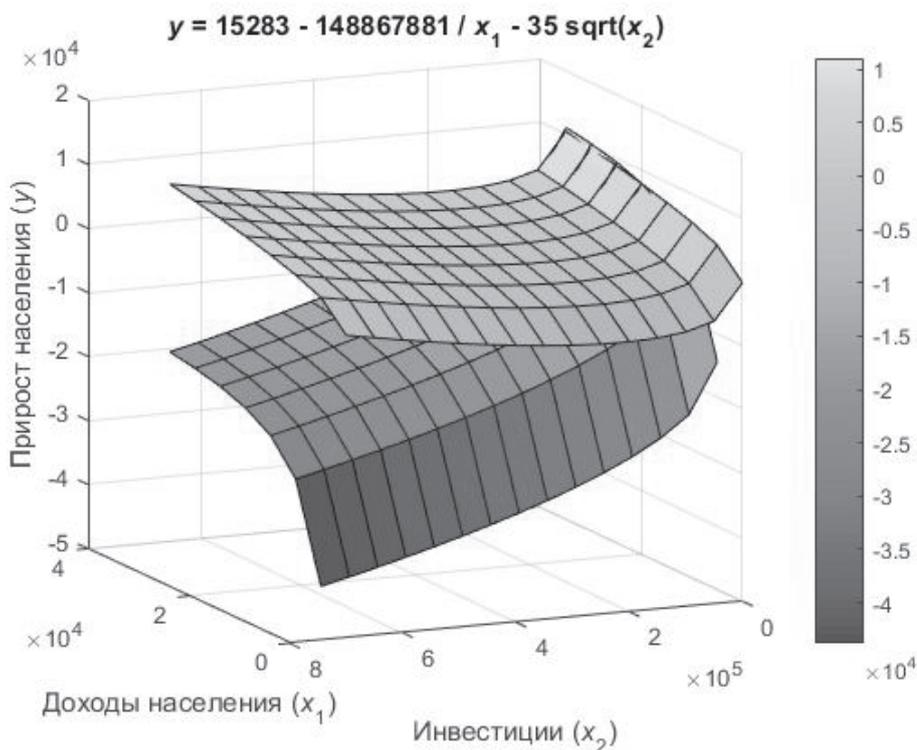


Рис. 9. Графики двух регрессий для 8 регионов Приволжского федерального округа с кластерами

**Этап 3 — отладка алгоритма стохастической оптимизации цифрового двойника.** Чтобы оценить более качественно примерный диапазон шума (рис. 10), вычтем из максимального значения  $y$  шумящей функции, т. е. регрессии 2, максимальное значение  $y$  целевой функции, т. е. регрессии 1. Их можно найти аналитически, используя данные, отмеченные жирным шрифтом в табл. 3. Так, для регрессии 1 получаем, что

инвестиции  $x_2 = 0$  и доход населения  $x_{1,\max} = 37\,914,6$  руб.,  
тогда  $y_{\max} = 10\,853,2$  чел.

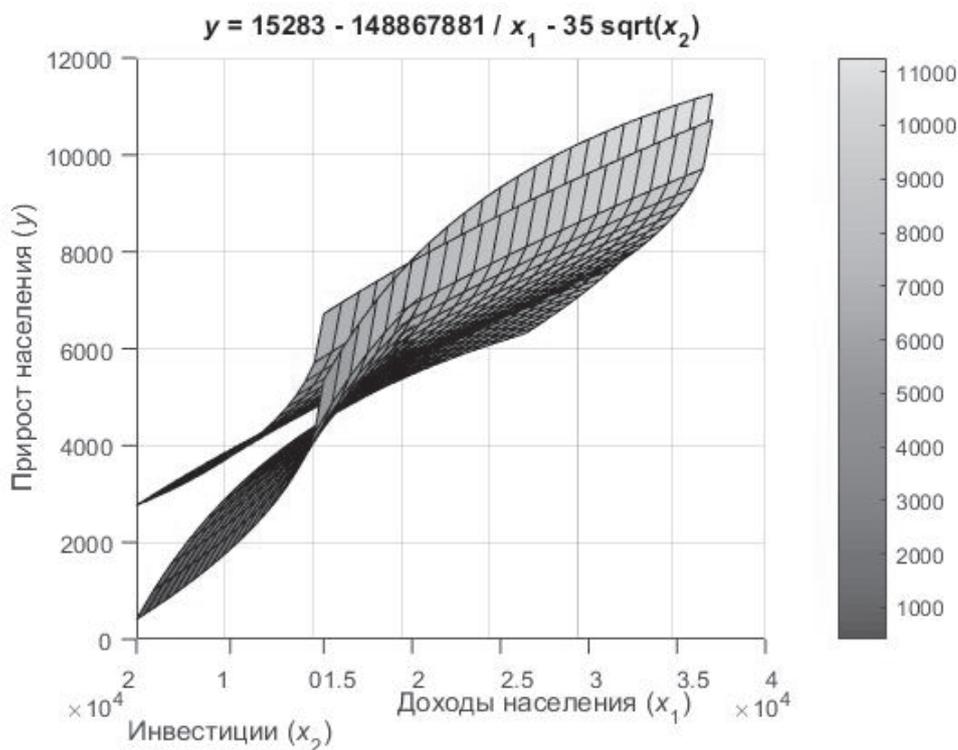


Рис. 10. Максимальные значения графиков двух регрессий для 8 регионов Приволжского федерального округа с кластерами

Аналогично для регрессии 2 —

инвестиции  $x_2 = 0$  и доход населения  $x_{1,\max} = 37\,914,6$  руб.,  
тогда  $y_{\max} = 11\,356,6$  чел.

Тогда шум составляет разницу

$$\Delta y = 11\,356,6 - 10\,853,2 = 503,4 \text{ (чел.)}.$$

Таким образом, имеем задачу нахождения максимального значения стохастической функции  $y$  на заданных сегментах ее аргументов:  $x_1 \in [0; 37914,6]$  и  $x_2 \in [0; 736854,4]$ .

Для дальнейшего анализа в программе *Matlab* используем два *M*-файла (рис. 11–13).

```
function y = smoothFcn1(z,noise)
%smoothFcn Objective function used in nonSmoothOpt demo.
% Copyright 2005-2007 The MathWorks, Inc.
if nargin < 2
    noise = 0;
end
LB = [0 0];           %Lower bound
UB = [37914.6 736854.4]; %Upper bound
y = zeros(1,size(z,1));
for i = 1:size(z,1)
    x = z(i,:);
    if any(x<LB) || any(x>UB)
        y(i) = Inf;
    else
        y(i) = 290.198 - 0.036*x(2) - 57.229*sqrt(x(1)) + 33.052*sqrt(x(2)) ...
            + noise*randn;
    end
end
end
```

Рис. 11. *M*-файл-функция

Наибольшее значение гладкой целевой функции, т. е. регрессии 1 без шума, можно найти в программе *Matlab*, используя метод прямой метод внутренней точки [2]. Результат для искомого максимального прироста населения в одном регионе ( $y$ ) составляет 10 853,2 чел., что отражено на рис. 14. Поскольку *Matlab* решает только задачи минимизации, график целевой функции перевернут и соответственно целевая функция берется с противоположным знаком. Решение, полученное прямым методом внутренней точки, отмечено на рис. 14 как “fmincon solution”.

Наибольшее значение стохастической целевой функции, т. е. регрессии 1 с шумом, можно попытаться найти в программе *Matlab* как с помощью прямого метода внутренней точки (fmincon solution), так и с помощью поиска по шаблону (Pattern Search solution) (рис. 15). Так, прямой метод внутренней точки дает результат оптимизации  $y = 31,7$  чел., а поиск по шаблону —  $y = 381,8$  чел., т. е. фактически найдены локальные, а не глобальные наибольшие значения функции.

Данную проблему можно решить с помощью настройки алгоритма поиска по шаблону, т. е. используя в качестве метода поиска и метода опроса поиск обобщенных шаблонов (GPS), поиск генерирующих наборов (GSS) и ячеистый адаптивный поиск (MADS) (табл. 4). При этом важно, чтобы для методов поиска и опроса использовались разные настройки. В этом случае сам алгоритм поиска по шаблону работает более качественно. Кроме того, для всех трех настроек GPS, GSS и MADS

```

% Инициализация целевой функции
X0 = [0 0]; % Starting point.
LB = [0 0]; % Lower bound
UB = [37914.6 736854.4]; % Upper bound
range = [LB(1) UB(1); LB(2) UB(2)];
Objfcn = @smoothFcn1; % Handle to the objective function.
% Plot the smooth objective function
fig = figure('Color','w');
showSmoothFcn(Objfcn,range);
hold on;
title('Smooth objective function');
ph = [];
ph(1) = plot3(X0(1),X0(2),Objfcn(X0)+30,'or','MarkerSize',10,'MarkerFaceColor','r');
hold off;
view(-109,14)
xlabel('Доходы населения ({\itx}_1)')
ylabel('Инвестиции ({\itx}_2)')
zlabel('Прирост населения ({\ity})')
% Add legend information
legendLabels = {'Start point'};
lh = legend(ph,legendLabels,'Location','SouthEast');
lp = lh.Position;
lh.Position = [1-lp(3)-0.005 0.005 lp(3) lp(4)];
% Запуск fmincon на гладкой целевой функции
% Set options to display iterative results.
options = optimoptions(@fmincon,'Algorithm','active-set','Display','iter');
[Xop,Fop] = fmincon(Objfcn,X0,[],[],[],[],LB,UB,[],options)
figure(fig);
hold on;
% Plot the final point
ph(2) = plot3(Xop(1),Xop(2),Fop,'dm','MarkerSize',10,'MarkerFaceColor','m');
% Add legend to plot
legendLabels = [legendLabels, '|fmincon| solution'];
lh = legend(ph,legendLabels,'Location','SouthEast');
lp = lh.Position;
lh.Position = [1-lp(3)-0.005 0.005 lp(3) lp(4)];
hold off;

```

Рис. 12. Начало текста программы в *Matlab* — для гладкой целевой функции

будем использовать конфигурацию  $2N$ , а не  $N + 1$ , т. к. в случае  $2N$  перебирается 6 ближайших точек по отношению к предыдущей, а в случае  $N + 1$  — только 4.

В результате в табл. 4 видно, что наибольшее значение стохастической целевой функции прироста населения в одном регионе ( $y$ ) наблюдается для метода поиска “GPS Positive basis  $2N$ ” и метода последующего опроса “GSS Positive basis  $2N$ ”. В этом случае максимально достижимый прирост населения составит 11 365 чел. Это несколько больше того, что было получено для функции с шумом, т. е. регрессии 2. Там было 11 356,6 чел. Такое произошло потому, что шум сам по себе шумит. Тем не менее, такой максимальный прирост населения в регионе возможен при инвестициях в основной капитал  $x_2 = 0,5$  млн руб. и доходах населения в месяц  $x_1 = 37 896$  руб. (табл. 4).

Таблица 4

## Лучшие результаты поиска по шаблону

Метод опроса	Полный опрос	Порядок опроса	Полный поиск	Метод поиска	Значение функции $y$ (чел.)	$x_1$ (руб.)	$x_2$ (млн руб.)
GPS Positive basis 2N	оп	Consecutive (последовательный)	оп	GSS Positive basis 2N	11 323	37 873	2
GPS Positive basis 2N	оп	Consecutive (последовательный)	оп	MADS Positive basis 2N	11 313	37 881	1
GSS Positive basis 2N	оп	Consecutive (последовательный)	оп	GPS Positive basis 2N	<b>11 365</b>	<b>37 896</b>	<b>0,5</b>
GSS Positive basis 2N	оп	Consecutive (последовательный)	оп	MADS Positive basis 2N	11 317	37 730	0,707
MADS Positive basis 2N	оп	Consecutive (последовательный)	оп	GPS Positive basis 2N	11 307	37 890	0,004
MADS Positive basis 2N	оп	Consecutive (последовательный)	оп	GSS Positive basis 2N	11 311	37 888	1,5

```

% Стохастическая целевая функция
rng(0,'twister') % Reset the global random number generator
peaknoise = 167.8;
Objfcn = @(x) smoothFcn1(x,peaknoise); % Handle to the objective function.
% Plot the objective function (non-smooth)
fig = figure('Color','w');
showSmoothFcn(Objfcn,range);
title('Stochastic objective function')
view(-109,14)
xlabel('Доходы населения ({\itx}_1)')
ylabel('Инвестиции ({\itx}_2)')
zlabel('Прирост населения ({\ity})')
% Запуск fmincon на стохастической целевой функции
options = optimoptions(@fmincon,'Algorithm','active-set','Display','iter');
[Xop,Fop] = fmincon(Objfcn,X0,[],[],[],[],LB,UB,[],options)
figure(fig);
hold on;
ph = [];
ph(1) = plot3(X0(1),X0(2),Objfcn(X0)+30,'or','MarkerSize',10,'MarkerFaceColor','r');
ph(2) = plot3(Xop(1),Xop(2),Fop,'dm','MarkerSize',10,'MarkerFaceColor','m');
% Add legend to plot
legendLabels = {'Start point','|fmincon| solution'};
lh = legend(ph,legendLabels,'Location','SouthEast');
lp = lh.Position;
lh.Position = [1-lp(3)-0.005 0.005 lp(3) lp(4)];
hold off;
% Запуск patternsearch
PSoptions = optimoptions(@patternsearch,'Display','iter');
[Xps,Fps] = patternsearch(Objfcn,X0,[],[],[],[],LB,UB,PSoptions)
figure(fig);
hold on;
ph(3) = plot3(Xps(1),Xps(2),Fps,'dc','MarkerSize',10,'MarkerFaceColor','c');
% Add legend to plot
legendLabels = [legendLabels, 'Pattern Search solution'];
lh = legend(ph,legendLabels,'Location','SouthEast');
lp = lh.Position;
lh.Position = [1-lp(3)-0.005 0.005 lp(3) lp(4)];
hold off

```

Рис. 13. Конец текста программы в *Matlab* — для стохастической целевой функции

Важным результатом рассмотренной модели стохастической оптимизации экономико-финансового, информационного и логистического межкластерного взаимодействия является то, что увеличение инвестиций в основной капитал далеко не всегда приводит к росту населения в регионах федерального округа (рис. 9). Население инновационно-индустриальных кластеров интересуется прежде всего ростом его среднедушевых доходов. Это необходимо учитывать при перераспределении инвестиционных и человеческих ресурсов в рамках одного федерального округа. Временное сокращение инвестиций в основной капитал и одновременное повышение доходов населения в отдельно взятом регионе одного федерального округа может привести к более серьезному приросту населения в регионе по сравнению с ситуацией, когда недостаток доходов населения компенсируется приростом инвестиций в основной капитал.

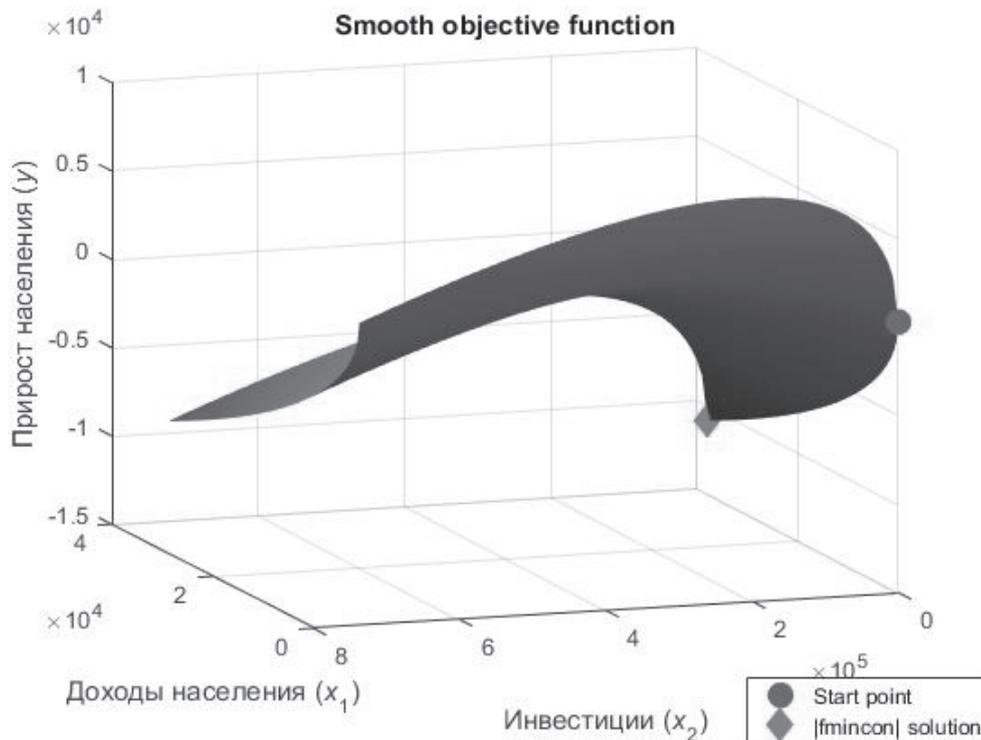


Рис. 14. Поиск наименьшего значения гладкой целевой функции

Сформулируем наиболее существенные выводы, полученные нами в результате исследования.

1. Стохастическая оптимизация работы цифровых двойников межкластерного взаимодействия позволяет заранее отработать оптимальные решения в отношении эволюции крупных инновационных систем, таких, как, например, федеральные округа страны.

2. Модель стохастической оптимизации экономико-финансового, информационного и логистического межкластерного взаимодействия в рамках отдельно взятого федерального округа предполагает в качестве основной наиболее значительной характеристики успешности подобного взаимодействия естественный прирост населения региона, в котором находится тот или иной кластер.

3. Использование цифрового двойника механизма межкластерного взаимодействия позволит избежать преждевременных необоснованных управленческих решений государственного масштаба в отношении дальнейшего развития инновационно-индустриальных кластеров, расположенных на территории конкретного федерального округа России, и, напротив, смоделировать механизм межкластерного взаимодействия на компьютере в виде соответствующего цифрового двойника. Это позволит затем отладить указанный цифровой двойник так, чтобы получить оптимальное управленческое решение в смысле глобальной стохастической оптимизации, по-

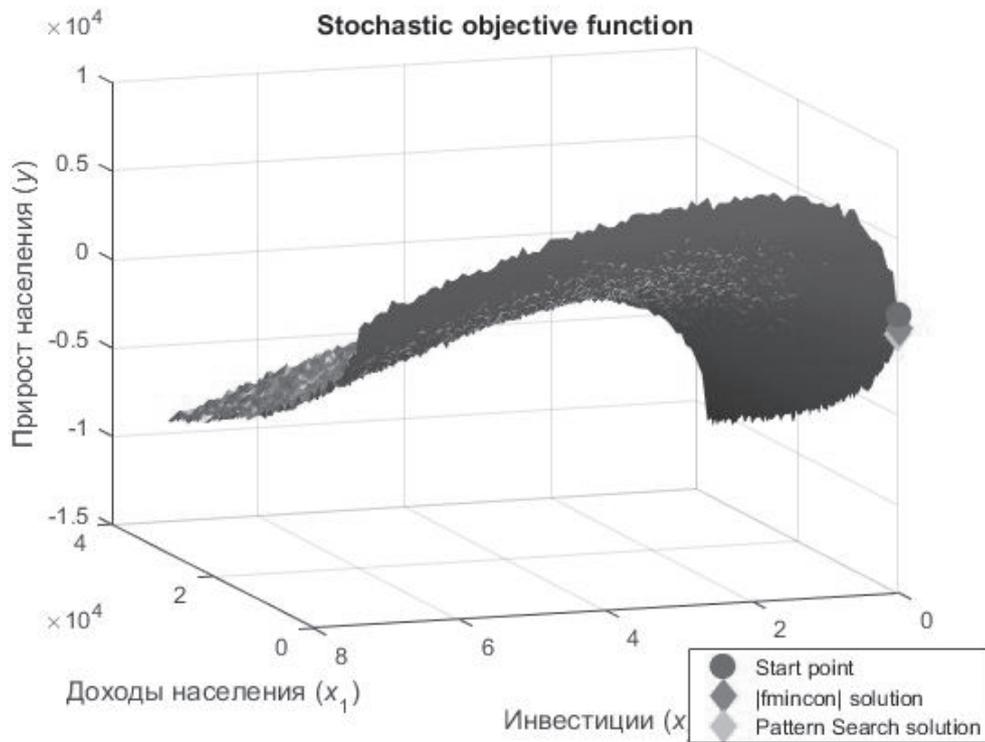


Рис. 15. Поиск наименьшего значения стохастической целевой функции

сле чего принять его на практике с возможностью планирования и корректировки будущих государственных решений на компьютере, используя уже отлаженный цифровой двойник.

## Глава 3

### Форсайт эволюции крупной инновационной системы федерального округа

#### 3.1. Применение многоцелевого генетического алгоритма

В настоящее время фундаментальные исследования по проблемам стратегического развития все в большей мере перемещаются в предметную область региональной экономики. Необходимо детальное рассмотрение данных вопросов для создания модели стратегического управления процессами развития системы промышленных регионов в составе федеративного государства.

Актуальность данного исследования обусловлена современными потребностями инвестирования приоритетных стратегий инновационного развития России и ее регионов, а также целесообразностью использования для этих целей соответствующих экономико-математических и информационных моделей, которые также будут учитывать факторы социально-экономического развития территории. Это связано, прежде всего, с необходимостью обеспечения стабильности экономического развития в рамках государственной и территориальной целостности страны при реализации политики экономического роста.

В региональной науке и практике ощущается острый недостаток математических и информационных моделей, которые позволили бы не только спрогнозировать динамику развития инновационных региональных систем, но также спланировать процесс их эволюции, исходя из социально-экономических ценностей регионов, сформированных на протяжении длительного периода времени.

Одним из наиболее важных подходов в настоящее время является внедрение технологий имитационного моделирования в бизнес-процессах, основанных на обработке большого массива данных (Big Data). Данный подход применяется в различных коммерческих структурах (крупных компаниях и банках). Здесь предлагается применение имитационного моделирования в государственном управлении: на уровне межрегионального взаимодействия в конкретных федеральных округах.

Важной разновидностью эвристических алгоритмов имитационного моделирования являются генетические алгоритмы (GA), которые представляют собой эволюционный метод поиска, используемый для решения задач оптимизации с использованием механизмов, напоминающих биологическую эволюцию.

Важным понятием в GA считается функция приспособленности (fitness function), по-другому называемая функцией оценки. Она представляет меру приспособленности данной особи в популяции. В задачах оптимизации функция приспособленности, как правило, максимизируется и называется целевой функцией [137].

Сам генетический алгоритм состоит из нескольких шагов: 1) подготовительный шаг — формирование начальной популяции; 2) отбор; 3) скрещивание; 4) мутация; 5) оценка решений и остановка алгоритма [15].

Тейт и Смит разработали стандартный GA. В нем они реализовали мутацию и скрещивание независимо друг от друга в отличие от большинства реализаций GA, в которых мутацию используют как вспомогательную процедуру для отдельных особей в популяции. В алгоритме использовалась хромосомная мутация с парным обменом [11].

Р. К. Ахуа, Дж. Б. Орлин и А. Тивари [33] разработали “жадный” GA. В “жадном” GA реализованы следующие идеи: генерирование начальной популяции случайным образом; новые схемы кроссинговера; схема иммиграции; периодическое использование локального поиска для определенных особей из популяции; использование идеи соревнований среди различных популяций и главная идея, которая заключается в том, чтобы сместить баланс от разнообразия к лучшим вариантам решения.

В настоящее время GA — это целый класс алгоритмов, направленный на решение разнообразных задач [72, 74, 100]. Примерами различных GA могут являться следующие алгоритмы:

1. Канонический GA. Данная модель алгоритма является классической. Она была предложена Дж. Х. Холландом [78].
2. Генитор. В этой модели используется специфичный способ отбора [160].
3. Метод прерывистого равновесия.
4. Гибридный алгоритм.
5. СНС. Расшифровывается как “Cross-population selection, Heterogeneous recombination and Cataclysmic mutation” [65].
6. GA с нефиксированным размером популяции.

Одной из серьезных проблем, возникающих при использовании GA, является преждевременная сходимость. Существуют три основных способа устранения этой проблемы: увеличение размера популяции, применение самоадаптирующихся GA и создание “банка” заменяемых особей.

Наибольший практический интерес представляют самоадаптирующиеся алгоритмы. Одним из способов их организации является применение неоднородной мутации [113]. Также используется стратегия инцеста как механизм самоадаптации оператора мутации [126–129].

Эволюционное программирование используется также как методика обучения общей нейронной сети. Этот подход может дать более быстрые, более эффективные, но при этом надежные процедуры обучения, учитывающие произвольные межсоединения и нейроны, обладающие дополнительными возможностями обработки [38, 68, 69].

Эволюционные алгоритмы являются относительно новыми, но очень мощными методами, используемыми для поиска решений многих реальных проблем поиска и оптимизации. Многие из этих проблем имеют многочисленные цели, что приводит к необходимости получения набора оптимальных решений, известных как эффективные решения. Было обнаружено, что использование эволюционных алгоритмов является высокоэффективным способом поиска множества эффективных решений в одном прогоне моделирования [88].

Форсайт представляет собой набор подходов, обеспечивающих условия для долгосрочного прогнозирования ситуаций в процессе принятия стратегических решений. Ранее нами была предложена методика форсайта, основанная на прогнозировании значений функций капитализации компаний кластера и на вычислении оптимального эквивалентного портфеля компаний кластера с использованием арбитражных технологий [30].

Однако данная методика не является достаточно эффективной для форсайта эволюции крупных инновационных систем, к которым относятся федеральные округа страны. В данном случае необходимо учитывать различные эффекты межкластерного взаимодействия, к числу которых прежде всего следует отнести экономико-финансовое, информационное и логистическое взаимодействия.

Кроме того, ранее с использованием имитационного моделирования мы наглядно продемонстрировали, что основным показателем успешности развития отдельно взятого федерального округа является естественный прирост его населения [26].

Таким образом, учитывая последний результат, мы предлагаем модель форсайта эволюции инновационной системы федерального округа, основанную на использовании многоцелевого генетического алгоритма. Этапы данного форсайта представлены на рис. 16.

Поскольку наибольшее влияние на естественный прирост населения оказывают среднедушевые денежные доходы населения (в месяц) [26], будем ориентироваться, в первую очередь, на максимизацию этой функции ( $y_1$ ) в каждом регионе федерального округа, где есть инновационно-индустриальные кластеры. Другими двумя факторами, которые примем во внимание при построении модели, будут инвестиции в основной капитал ( $y_2$ ) и внутренние текущие затраты на научно-исследовательские разработки (НИР) ( $y_3$ ).

В этом случае мы охватываем межкластерное взаимодействие по трем обозначенным ранее направлениям — экономико-финансовое, информационное и логистическое — поскольку выявленный резерв по функциям  $y_2$  и  $y_3$  в целях повышения синергетического эффекта федерального округа планируется перенаправить в те регионы, где экономико-финансовых ресурсов не хватает. Это позволит в итоге увеличить среднедушевые доходы населения в этих регионах, что приведет, в свою очередь, к приросту населения в них. Если же подобным образом перераспределяются затраты на НИР, то происходят информационное и логистическое взаимодействия, подтверждающие практическую действенность модели открытых инноваций в рамках федерального округа.

Переходя к сути предлагаемой модели форсайта, опишем его этапы, представленные на рис. 16.

**Этап 1 — подготовка статистических данных для кластеров.** Мы уже обозначили основные три составляющие модели —  $y_1$ ,  $y_2$  и  $y_3$ . Однако по причине того, что эти данные представлены в деньгах, их необходимо скорректировать на инфляцию. Тогда будет видна реальная динамика указанных показателей.

**Этап 2 — получение прогнозных функций для кластеров.** Именно эти функции для  $y_1$ ,  $y_2$  и  $y_3$  в дальнейшем будут использоваться при реализации много-

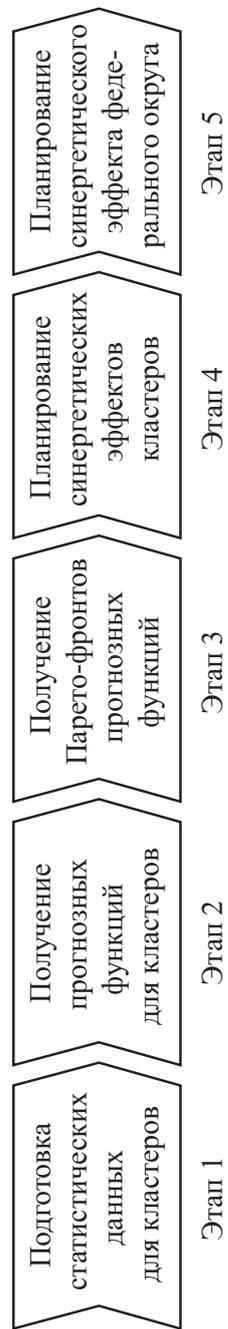


Рис. 16. Этапы форсайта эволюции инновационной системы федерального округа

целевого генетического алгоритма, поэтому важно их построить максимально достоверно. Для этого будем ориентироваться на значение коэффициента детерминации  $R^2$ .

**Этап 3 — получение Парето-фронтон прогнозных функций.** Для этого используем многоцелевой генетический алгоритм. Данный этап форсайта является центральным с технической точки зрения. Опишем его более детально.

Пусть мы хотим максимизировать несколько целевых функций одновременно, каждая из которых имеет глобальный экстремум. Целевые функции имеют свои индивидуальные экстремумы. Однако в многоцелевой проблеме любое решение в диапазоне между крайними экстремумами функций одинаково оптимально. Нет единого решения этой многоцелевой проблемы. Цель многоцелевого генетического алгоритма — найти набор решений в заданном диапазоне (в идеале с хорошим разбросом). Набор решений также известен как фронт Парето. Все решения на фронте Парето оптимальны.

Мы используем визуализацию двух опций графика. Первая опция строит фронт Парето (ограниченный любыми тремя целями) у каждого поколения. Вторая опция строит интервал от глобального экстремума каждой анализируемой функции до другого крайнего экстремума соответствующей функции графика.

**Этап 4 — планирование синергетических эффектов кластеров.** Детальный анализ Парето-фронта для конкретного региона позволяет определить оптимальное значение среднедушевого денежного дохода его населения ( $y_1$ ). Для полученного значения дохода можно определить плановые показатели  $y_2$  и  $y_3$ . Тогда максимально возможный синергетический эффект для каждого региона, где есть инновационно-индустриальные кластеры, вычисляется по формуле

$$S = y_{2,\text{plan}} - y_{2,\text{fact}} + y_{3,\text{plan}} - y_{3,\text{fact}}, \quad (1)$$

где фактические значения принимаются за последний анализируемый год.

**Этап 5 — планирование синергетического эффекта федерального округа.** Если для конкретного региона по показателям  $y_2$  или  $y_3$  будет наблюдаться превышение фактического значения над плановым, расценим эту разницу как резерв. Его следует перенаправить в те регионы, где по данному показателю  $y_2$  или  $y_3$  присутствует превышение планового значения над фактическим. Это, в свою очередь, скорректирует синергетические эффекты регионов — получателей финансовых средств. Подобный механизм перераспределения инвестиций в основной капитал и затрат на НИР позволит федеральному округу развиваться как частично замкнутой инновационной системе с уменьшением внешнего федерального и частного финансирования.

В результате корректируется метод оценки синергетического эффекта для каждого региона — получателя средств на величину принятого от регионов — доноров резерва, т. е.

$$S_{\text{new}} = y_{2,\text{plan}} - y_{2,\text{fact}} + y_{3,\text{plan}} - y_{3,\text{fact}} - \sum_{i=1}^n R_i, \quad (2)$$

где  $R_i$  — принятая величина резерва от  $i$ -го региона — донора (млн руб.),  
 $n$  — количество регионов федерального округа, где есть инновационно-индустриальные кластеры.

После этого скорректированные синергетические эффекты регионов складываются и получается максимально возможный синергетический эффект для всего федерального округа:

$$S_{\text{FD}} = \sum_{i=1}^n S_{i,\text{new}} . \quad (3)$$

**Пример 2.** Рассмотрим процесс форсайта эволюции инновационной системы с использованием многоцелевого генетического алгоритма на примере Приволжского федерального округа (ПФО).

**Этап 1 — подготовка статистических данных для кластеров.** Используя показатели “Статистического обозрения” Федеральной службы государственной статистики, сгруппируем необходимые данные о естественном приросте населения ( $z$ ), среднедушевых денежных доходах населения (в месяц) ( $y_1$ ), инвестициях в основной капитал ( $y_2$ ) и о внутренних текущих затратах на НИР ( $y_3$ ) за 10 лет с 2009 по 2018 г. При этом для сравнимости данных скорректируем показатели, измеряемые в рублях, на инфляцию (табл. 2, параграф 2.1). В результате для 8 регионов ПФО имеем матрицу данных для форсайта размерности  $80 \times 4$  в ценах 2018 г. (табл. 5).

**Этап 2 — получение прогнозных функций для кластеров.** С этой целью используем Интернет-сервис *WolframAlpha* ([www.wolframalpha.com](http://www.wolframalpha.com)). Так, например, для Нижегородской области, используя данные табл. 5, для  $y_1$  получены три лучшие прогнозные функции, представленные на рис. 17. Наибольший коэффициент детерминации  $R^2 = 0,988022$  у полинома 4-й степени, поэтому его принимаем в качестве наилучшей прогнозной функции. Аналогично получают прогнозные функции для  $y_2$  и  $y_3$ .

Построим теперь прогнозные функции  $y_1$ ,  $y_2$ ,  $y_3$  на одном графике в *Matlab* (рис. 18). Поскольку программа *Matlab*, в которой будет реализован многоцелевой генетический алгоритм, решает только задачи на минимум, все три графика перевернуты. Таким образом, минимизируем отрицательные функции. Кроме того, для наглядности две функции из трех мы умножили на 10.

В результате на рис. 18 видно, что мы одновременно ищем минимумы для трех функций. Необходимый нам Парето-фронт будет расположен между крайними минимумами из трех, т. е. примерно на сегменте  $[4,5; 8,5]$  по горизонтальной оси.

**Этап 3 — получение Парето-фронт прогнозные функции.** Для реализации многоцелевого генетического алгоритма сначала создаем  $M$ -файл-функцию (рис. 19). Затем строим необходимый Парето-фронт между оптимальными  $y_1$  и  $y_2$  (рис. 20 и 21). Аналогично можно получить Парето-фронт между оптимальными  $y_1$  и  $y_3$  (рис. 22) и между оптимальными  $y_2$  и  $y_3$  (рис. 23). Также на рис. 21–23 представлены интервалы от глобального экстремума каждой анализи-

Таблица 5

## Данные для форсайта в ценах 2018 г.

Регионы	С/душевые денежные доходы населения (в месяц) (руб.)	Инвестиции в основной капитал (млн руб.)	Внутрен. текущие затраты на НИР (млн руб.)	Естест- венный прирост населения (чел.)
1. Нижегородская область	$y_1$	$y_2$	$y_3$	$z$
2009	26 646,5	364 200	41 456,1	-22 094
2010	27 399	293 805,4	46 022,7	-22 942
2011	28 948,2	356 243,3	48 495,1	-17 869
2012	32 204,6	389 268,9	57 557,7	-13 890
2013	34 216,8	385 562,5	52 691,9	-13 457
2014	35 548,8	364 555,9	66 121,7	-12 846
2015	34 663,1	257 909,3	64 064	-10 714
2016	32 503,3	234 809,1	70 891,4	-11 420
2017	31 967,1	254 493	67 023,1	-13 556
2018	31 631	259 045,4	66 202,2	-15 917
2. Республика Мордовия	$y_1$	$y_2$	$y_3$	$z$
2009	17 624,5	60 431,5	1 195	-4 896
2010	18 794,6	65 463,8	817,7	-5 211
2011	18 495,5	74 836	901,5	-4 414
2012	19 478,1	74 621,1	931,9	-3 691
2013	20 234,8	76 059,2	1 118,4	-3 855
2014	20 460	70 326,3	1 056,3	-3 434
2015	19 843,1	58 975,9	922	-3 567
2016	19 000	56 500	829	-3 457
2017	18 914,6	62 474,5	819,2	-4 008
2018	18 048	51 210,1	970,7	-4 094
3. Ульяновская область	$x_1$	$x_2$	$x_3$	$y$
2009	19 362	90 379	7 738,9	-5 734
2010	21 503,8	76 465,4	8 549	-6 690
2011	22 223	99 259,3	11 668,7	-5 101
2012	24 621,3	109 859,2	12 150,3	-3 551
2013	25 858,6	107 972	10 718,7	-3 523
2014	27 545,9	104 511,3	10 220,5	-3 397

Продолжение табл. 5

Регионы	С/душевые денежные доходы населения (в месяц) (руб.)	Инвестиции в основной капитал (млн руб.)	Внутрен. текущие затраты на НИР (млн руб.)	Естест- венный прирост населения (чел.)
3. Ульяновская область	$y_1$	$y_2$	$y_3$	$z$
2015	25 522,8	101 496,5	8 946,4	-3 734
2016	23 501,4	73 628,4	8 431,1	-3 997
2017	23 980	95 728	11 623,2	-4 944
2018	22 846	81 105,4	11 291,2	-5 413
4. Самарская область	$y_1$	$y_2$	$y_3$	$z$
2009	33 303,5	203 968,9	20 802,5	-10 713
2010	34 014,9	226 028,2	20 978,5	-11 809
2011	34 691,1	319 376,7	22 379,2	-9 516
2012	37 031	307 832,4	25 946,5	-5 641
2013	37 254,5	371 560,7	26 042,5	-6 594
2014	33 115,6	381 970,5	17 891,4	-5 402
2015	30 293,5	336 533,9	18 426,8	-4 687
2016	28 315	274 484,7	12 444,9	-4 277
2017	27 781,7	262 201,5	14 459,3	-9 284
2018	27 507	259 152,3	13 746,4	-9 927
5. Пермский край	$y_1$	$y_2$	$y_3$	$z$
2009	31 714,1	249 400,2	12 243,2	-4 511
2010	31 357	221 552,1	11 385,1	-3 153
2011	33 153	215 208	11 588,4	-1 765
2012	34 336,2	238 700,8	12 563	1 569
2013	36 360,1	267 302,7	15 217,4	1 584
2014	36 281,4	236 130,4	13 389,6	2 070
2015	37 117,7	244 438,1	13 439	1 383
2016	30 707,4	253 362,4	13 048,8	889
2017	29 701,3	264 639,6	13 881,8	-2 946
2018	28 777	238 007,9	12 754,5	-5 224
6. Удмуртская Республика	$y_1$	$y_2$	$y_3$	$z$
2009	20 042,8	76 615,2	949,2	869
2010	20 968,3	72 199,6	759,7	622

Окончание табл. 5

Регионы	С/душевые денежные доходы населения (в месяц) (руб.)	Инвестиции в основной капитал (млн руб.)	Внутрен. текущие затраты на НИР (млн руб.)	Естест- венный прирост населения (чел.)
6. Удмуртская Республика	<i>y</i> <sub>1</sub>	<i>y</i> <sub>2</sub>	<i>y</i> <sub>3</sub>	<i>z</i>
2011	22 351,7	97 862,4	1 183,5	1 495
2012	24 341	86 273,2	1 190,8	3 718
2013	26 318,5	101 725,9	1 553,8	2 776
2014	27 052,4	114 264	1 260,5	2 651
2015	27 740,9	90 503,7	1 200	2 662
2016	25 543,2	91 296,9	1 168,3	1 822
2017	24 874,7	83 364,7	1 837	–258
2018	24 415	97 892,8	2 295,3	–1 670
7. Республика Татарстан	<i>y</i> <sub>1</sub>	<i>y</i> <sub>2</sub>	<i>y</i> <sub>3</sub>	<i>z</i>
2009	28 782	497 040,8	10 146,3	–1 415
2010	30 792,5	521 763,6	10 513,5	–762
2011	31 867,1	620 525	13 360,4	3 752
2012	35 592	700 725,8	14 432,9	9 023
2013	36 843,6	736 854,4	14 410,4	10 218
2014	37 914,6	690 372,2	14 530,6	9 732
2015	35 513,6	695 245,1	12 881,8	10 416
2016	35 076,3	686 810,8	12 803,4	10 643
2017	33 673	664 837,7	16 255,9	4 240
2018	33 130	629 731	17 038,8	1 600
8. Республ. Башкортостан	<i>y</i> <sub>1</sub>	<i>y</i> <sub>2</sub>	<i>y</i> <sub>3</sub>	<i>z</i>
2009	29 927,6	259 180,6	6 300,6	2 305
2010	30 390,3	238 457,6	6 693,5	2 686
2011	31 009,2	297 102,9	8 526,3	1 374
2012	32 245,2	351 117,4	10 373,7	5 617
2013	34 085,1	377 093,5	9 966,4	5 895
2014	33 046,9	363 157,3	10 346,9	6 949
2015	31 493,2	356 778,5	9 128,8	5 089
2016	30 082,1	385 843,1	9 213,2	3 298
2017	29 603,3	272 034,6	9 009,2	–1 072
2018	28 645	267 868,1	10 356,8	–3 429

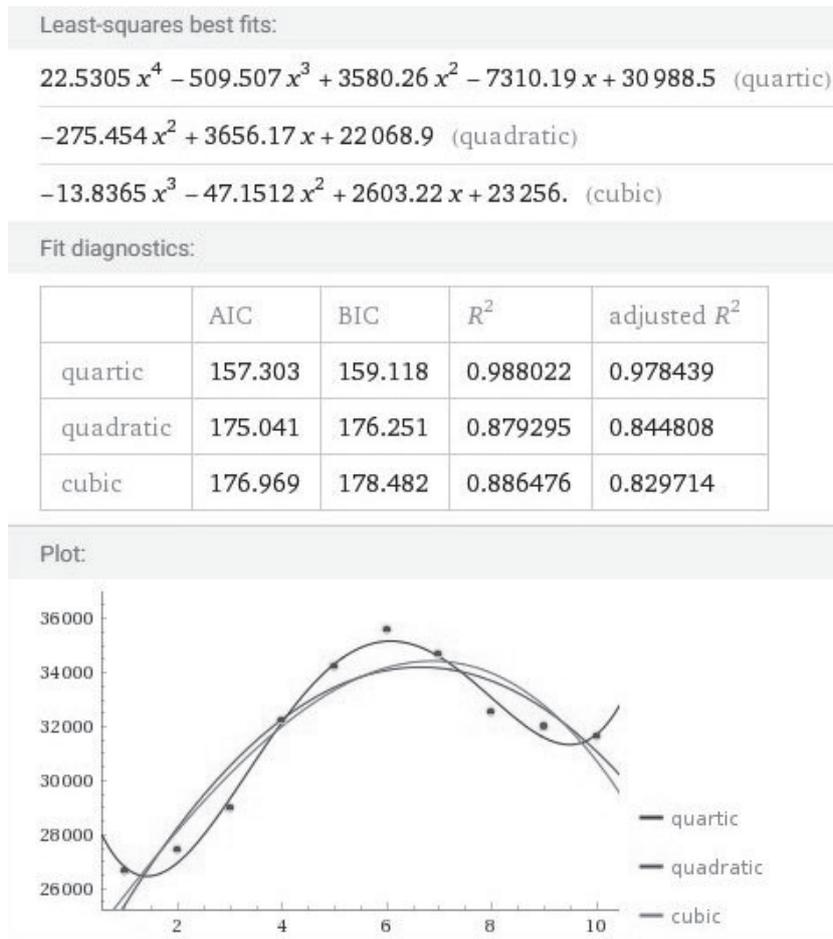


Рис. 17. Графики трех лучших прогнозных функций  $y_1$

руемой функции до другого крайнего экстремума соответствующей функции графика. Данные интервалы будут использоваться на следующем этапе форсайта.

Как уже указывалось ранее, все решения, представленные на Парето-фронте, оптимальны. Однако нас интересует ситуация, в которой у населения региона будет максимальный среднедушевой доход ( $y_1$ ). Это накладывает серьезные коррективы на процесс анализа Парето-фронта. Так, например, на рис. 21 видно, что при движении по оптимальному Парето-фронту в направлении увеличения инвестиций в основной капитал ( $y_2$ ) доход населения сначала растет, затем несколько снижается. Это говорит о том, что для Нижегородской области существует оптимальный размер инвестиций, выше которого доход населения будет снижаться, что приведет в итоге к снижению темпа прироста населения данного региона.

Также, анализируя Парето-фронт на рис. 22, можно сделать аналогичный вывод в отношении затрат на НИР в регионе ( $y_3$ ). Двигаясь по Парето-фронту в направлении увеличения затрат на НИР, нетрудно заметить, что доходы населения

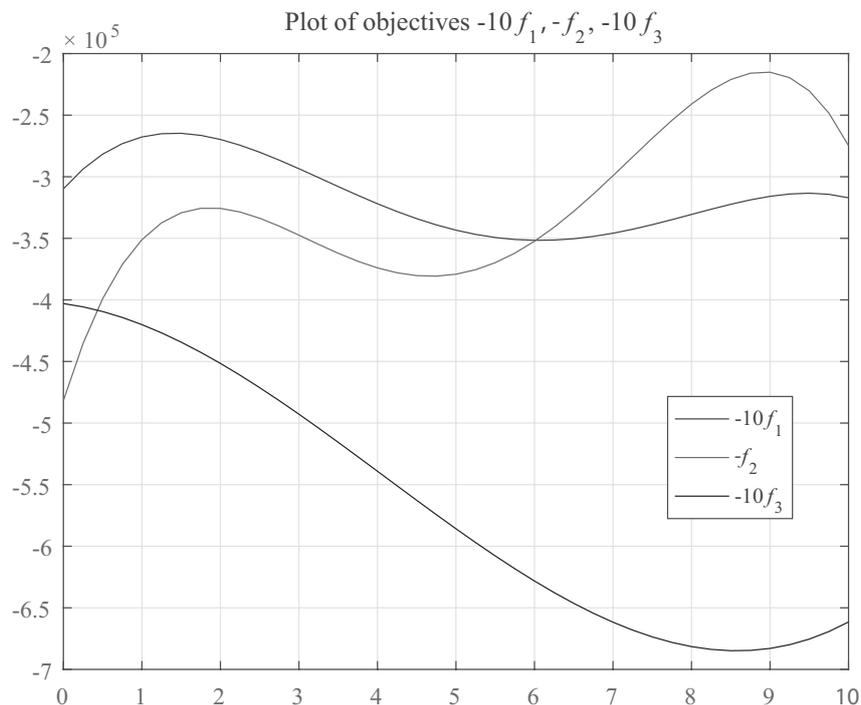


Рис. 18. Графики анализируемых функций  $y_1, y_2, y_3$

при этом сначала несколько увеличиваются, а далее серьезно снижаются. Это означает, что в отношении финансирования НИР в Нижегородской области следует быть еще более осторожным. Нельзя превышать оптимум НИР, представленный на Парето-фронте.

Что же касается анализа графика на рис. 23, то здесь ситуация более прозрачна. Инвестиции в основной капитал и затраты на НИР — конкурирующие цели, что представляется достаточно естественным, т. к. нельзя одновременно успешно, т. е. с хорошей отдачей, финансировать фундаментальные затраты с возможным эффектом через длительное время, т. е. НИР, и текущие потребности производств, т. е. инвестиции в основной капитал.

Таким образом, главным выводом для Нижегородской области на текущем этапе форсайта согласно рис. 21–23 будет то, что в данном регионе есть оптимум инвестиций в основной капитал и НИР для получения максимального дохода населения.

Выводы, полученные аналогичным способом на данном этапе форсайта для всех 8 регионов ПФО, где присутствуют инновационно-индустриальные кластеры, сгруппированы в табл. 6.

Кроме того, сформулируем наиболее важные выводы на данном этапе форсайта:

1. У Нижегородской области есть предел оптимальных инвестиций и НИР, выше которого развитие региона невозможно.

Таблица 6

## Выводы для 8 регионов ПФО на основе анализа Парето-фронтгов прогнозных функций

Регионы	Выводы
1. Нижегородская область	Есть оптимум инвестиций и НИР для максимального дохода населения
2. Республика Мордовия	Инвестиции следует уменьшать, а НИР увеличивать для максимизации дохода населения
3. Ульяновская область	Инвестиции нужно сначала увеличивать, потом несколько понижать. Величину НИР при этом нужно уменьшать
4. Самарская область	Инвестиции следует уменьшать, а НИР увеличивать для максимизации дохода населения
5. Пермский край	Инвестиции надо уменьшать, а НИР увеличивать, потом несколько понижать
6. Удмуртская республика	Инвестиции и НИР следует уменьшать для максимизации доходов населения
7. Республика Татарстан	Инвестиции надо увеличивать, а НИР уменьшать для максимизации доходов населения
8. Республика Башкортостан	Инвестиции следует уменьшать, а НИР увеличивать для максимизации доходов населения

```

function y = simple_multiobjective(x)
    y(1) = - 225.305*x.^4 + 5095.07*x.^3 - 35802.6*x.^2 + 73101.9*x - 309885;
    y(2) = - 663.116*x.^4 + 13674.*x.^3 - 89030.8*x.^2 + 206728.*x - 481811;
    y(3) = 779.706*x.^3 - 9552.1*x.^2 - 8298.72*x - 402988;

```

Рис. 19. М-файл-функция

```

>> % Минимизация, используя gamultiobj
FitnessFunction = @simple_multiobjective;
numberOfVariables = 1;
[x,fval] = gamultiobj(FitnessFunction,numberOfVariables);
Optimization terminated: average change in the spread of Pareto solutions less
than options.FunctionTolerance.
>> % Добавляем связанные ограничения для простой многоцелевой задачи
A = []; b = [];
Aeq = []; beq = [];
lb = 1;
ub = 10;
>> % Построение фронта Парето и разбиения баллов для каждой цели
options = optimoptions(@gamultiobj,'PlotFcn',{@gplotpareto,@gplotscorediversity});
gamultiobj(FitnessFunction,numberOfVariables,[],[],[],lb,ub,options);
Optimization terminated: maximum number of generations exceeded.

```

Рис. 20. Текст программы в *Matlab*

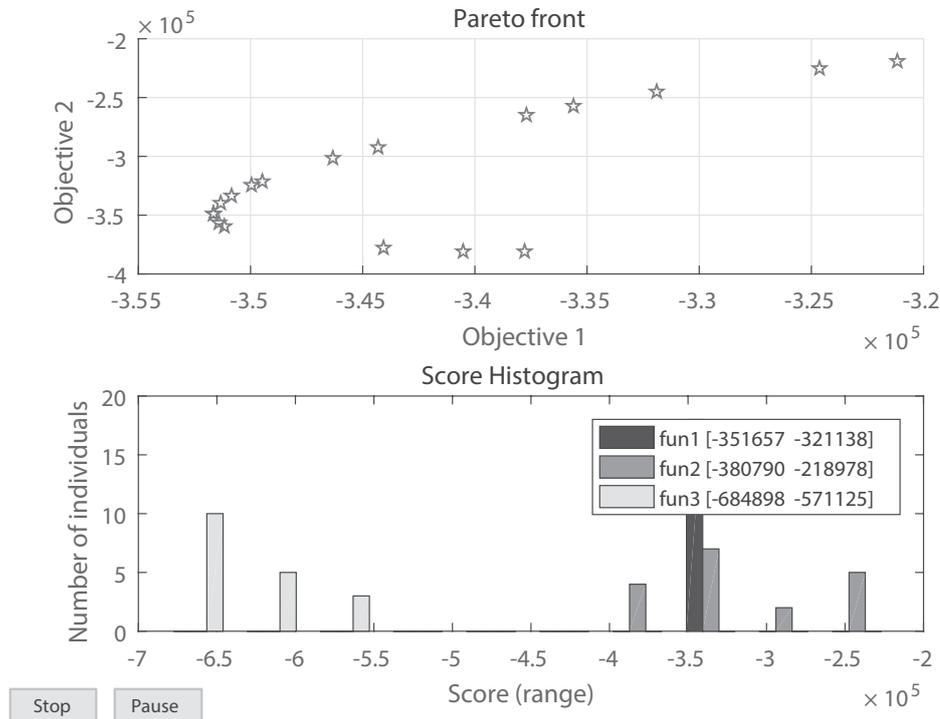


Рис. 21. Парето-фронт между оптимальными  $y_1$  и  $y_2$

2. Наибольшая отдача от НИР наблюдается для республики Мордовия, Самарской области и республики Башкортостан.

3. Наиболее инвестиционно привлекательным регионом является республика Татарстан при условии открытости НИР других регионов ПФО.

**Этап 4 — планирование синергетических эффектов кластеров.** Данные вычисления на основе результатов предыдущего этапа форсайта произведем в табл. 7 по формуле (1).

**Этап 5 — планирование синергетического эффекта федерального округа.** Для Самарской области наблюдается наибольший недостаток текущих затрат на НИР по сравнению с оптимальным планом. Он составляет 10 673 млн руб. Его можно частично восполнить за счет резервов по НИР у Нижегородской и Ульяновской областей, Удмуртской республики, республик Татарстан и Башкортостан. В сумме такой резерв составляет 8 412 млн руб. Его следует направить в Самарскую область. Тогда ее синергетический эффект по формуле (2) составит

$$S_{\text{new}} = 343\,045 - 259\,152,3 + 24\,419,4 - 13\,746,4 - 8\,412 = 86\,153,7 \text{ (млн руб.)}.$$

Также можно резерв величиной 8 412 млн руб. частично распределить на НИР в республику Мордовию и Пермский край, а остаток направить в Самарскую об-

## Расчет синергетических эффектов кластеров и всего ПФО

Ср/душевые ден. доходы населения (в месяц) (руб.)		Инвестиции в основной капитал (млн руб.)		Внутренние текущие затраты на НИР (млн руб.)		Синергетический эффект (млн руб.)	
План	Факт	План	Факт	План	Факт	План	Резерв
1. Нижегородская область							
35 165,7	31 631	350 000	259 045,4	63 000	66 202,2	87 752,4	3 202,2
2. Республика Мордовия							
20 189,9	18 048	70 032,2	51 210,1	1 075	970,7	18 926,4	-104,3
3. Ульяновская область							
26 447,4	22 846	108 000	81 105,4	9 901,5	11 291,2	25 504,9	1 389,7
4. Самарская область							
36 356,8	27 507	343 045	259 152,3	24 419,4	13 746,4	86 153,7	-10 673
5. Пермский край							
36 845,6	28 777	244 113	238 007,9	14 100	12 754,5	7 450,6	-1 345,5
6. Удмуртская республика							
27 225,2	24 415	102 100	97 892,8	1 320,8	2 295,3	3 233,7	974,5
7. Республика Татарстан							
37 271,1	33 130	723 603	629 731	14 200	17 038,8	91 033,2	2838,8
8. Республика Башкортостан							
33 294,9	28 645	377 164	267 868,1	10 350	10 356,8	109 289,1	6,8

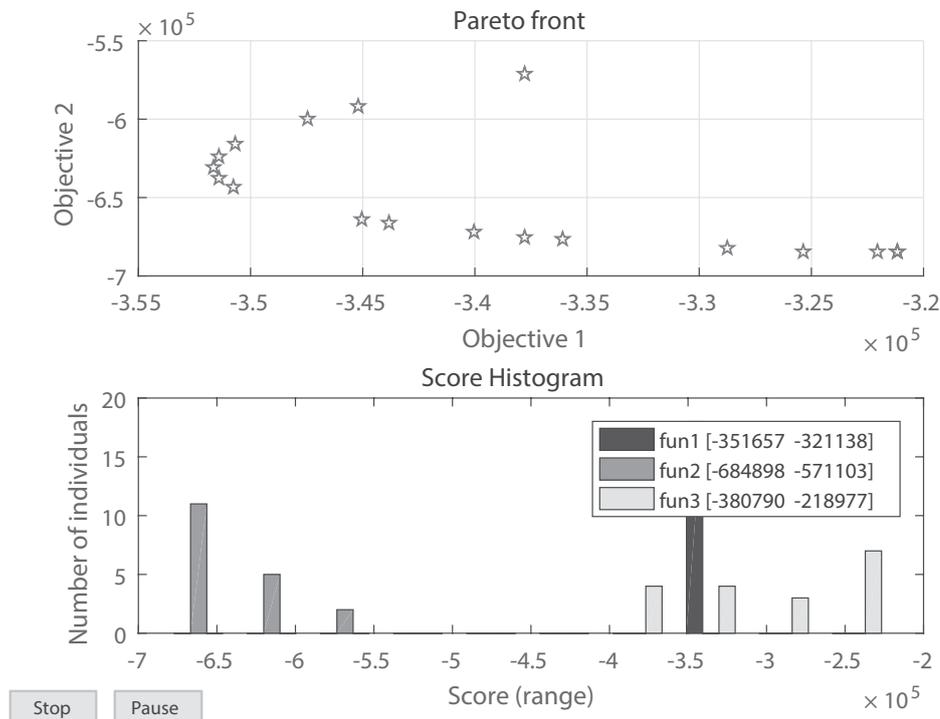


Рис. 22. Парето-фронт между оптимальными  $y_1$  и  $y_3$

ласть. Но синергетический эффект всего ПФО в этом случае будет таким же, как в случае, если весь резерв направить на НИР в Самарской области.

Складывая результаты предпоследнего столбца табл. 7, по формуле (3) получаем, что синергетический эффект всего ПФО составит  $S_{FD} = 429\,344$  млн руб.

Подобное перераспределение ресурсов внутри ПФО позволит ему выйти на плановые показатели среднедушевых денежных доходов населения (в месяц), которые отражены в первом столбце табл. 7. А это, в свою очередь, приведет к максимальным значениям естественного прироста населения в регионах ПФО, которые достаточно легко найти для каждого из 8 анализируемых регионов в табл. 1 (параграф 2.1).

Сформулируем наиболее важные практические выводы, полученные в результате исследования.

1. Одним из наиболее важных подходов в настоящее время является внедрение технологий имитационного моделирования в бизнес-процессах, основанных на обработке большого массива данных (Big Data). В данной работе предлагается применение имитационного моделирования в государственном управлении: на уровне межрегионального взаимодействия в конкретных федеральных округах.

2. Основным показателем успешности развития отдельно взятого федерального округа является естественный прирост его населения. Для этого предлагается мо-

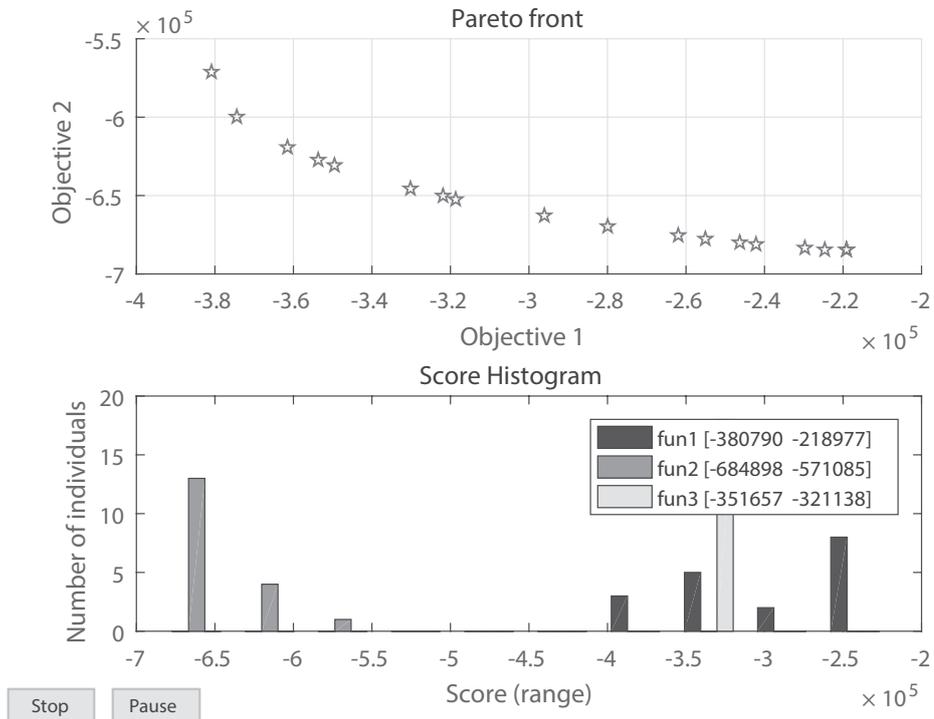


Рис. 23. Парето-фронт между оптимальными  $y_2$  и  $y_3$

дель форсайта эволюции инновационной системы федерального округа, основанная на использовании многоцелевого генетического алгоритма.

3. Этапы данного форсайта включают в себя подготовку статистических данных для кластеров, получение для них прогнозных функций, получение Парето-фронтных прогнозных функций, планирование синергетических эффектов кластеров регионов и всего федерального округа.

4. В этом случае в целях повышения синергетического эффекта федерального округа планируется перенаправить инвестиционные ресурсы и затраты на НИР в те регионы, где экономико-финансовых ресурсов не хватает. Это позволит в итоге увеличить среднедушевые доходы населения в регионах федерального округа, что приведет, в свою очередь, к приросту населения в них. Если же перераспределяются затраты на НИР, то происходят также информационное и логистическое взаимодействия, подтверждающие практическую действенность модели открытых инноваций в рамках федерального округа.

5. Для Приволжского федерального округа в результате форсайта получено, что суммарный положительный резерв по НИР в нем составляет 8412 млн руб. Его следует направить в Самарскую область. Тогда синергетический эффект всего ПФО будет равен 429344 млн руб.

### 3.2. Определение центра инновационно-индустриальных кластеров округа: генетический алгоритм, имитационный отжиг, поиск по шаблону

Форсайт эволюции крупной инновационной системы уровня федерального округа предполагает как прогнозирование данного процесса, так и его планирование. Для устойчивого развития экономики округа необходимо наличие новых условий деятельности, которые приводили бы к появлению дополнительного синергетического эффекта. Одним из таких немаловажных условий является оптимальное информационное и логистическое взаимодействие инновационно-индустриальных кластеров в рамках одного федерального округа. Глобальная оптимизация данного взаимодействия позволит решать государственные стратегические задачи эволюции округа.

С этой целью решаем задачу размещения информационного и логистического центра кластеров федерального округа. Для этого применяются соответствующие технологии имитационного моделирования.

Задача размещения является классической задачей глобальной оптимизации. Существует множество научных статей и книг, подтверждающих эффективность методов, применяемых для ее решения. Первыми базовыми работами в данном направлении считаются следующие. Это разработка Б. М. Хумавалы эффективного алгоритма ветвления с привязкой для задачи размещения склада [92]. Также это исследование Г. Корнуеджолса, М. Л. Фишера и Г. Л. Немхаузера вопроса расположения банковских счетов для оптимизации плавающей точки размещения [50]. Наконец, это изучение проблемы Дж. Крарупа и П. М. Прузана об оптимальном расположении завода [101].

Подобные наработки позволили развивать далее технологии решения задачи размещения многими другими учеными. К примеру, А. Колен [99] установил, что при наличии древовидной сети на  $n$  вершинах поддерево окрестности определяется как набор всех точек на дереве в пределах определенного радиуса данной точки, называемого центром. Показано, что для любых двух поддеревьев окрестности, содержащих одну и ту же конечную точку самого длинного пути в дереве, одно содержится в другом. Этот результат затем используется для получения алгоритмов ( $n^2$ ) для проблемы покрытия минимальной стоимости и проблемы эксплуатации минимальной стоимости, а также алгоритма ( $n^3$ ) для проблемы неинвазивного местоположения установки на дереве.

П. Мирчандани и Р. Джаганнатан [114] сформулировали дискретную проблему местоположения объекта, в которой общие фиксированные затраты на создание объекта включают компонент, который является нелинейной функцией количества создаваемых объектов. Некоторые теоретические свойства решения получаются, когда эта фиксированная стоимость является выпуклой функцией без сдвига числа объектов. На основе этих свойств авторы разрабатывают эффективную биссектрисную эвристику, где на каждой итерации решаются классические подпроблемы “нерасчетного местоположения объекта” и/или “ $m$ -медианные” подпроблемы с использованием доступной эффективной эвристики.

Далее, дискретная теория местоположения П. Б. Мирчандани и Р. Л. Фрэнсиса [115] представляет собой комплексный и строгий подход к широкому спектру исследований, посвященных местоположению объектов. “Общая” проблема, связанная с местоположением объекта, связана с оптимальными возможностями по размещению, например, склады, нефтедобывающие скважины и больницы, для оптимального обслуживания клиентов. В каком-то смысле, общей проблемы местоположения объекта не существует. Скорее, проблемы местоположения объекта возникают во многих различных областях применения, что требует широкого разнообразия подходов к моделированию и решению.

Дж. Ф. Кемпбелл [46] установил, что узлы представляют собой объекты, которые служат перевалочными и коммутационными пунктами для транспортных и телекоммуникационных систем, имеющих большое количество мест происхождения и назначения. Автор представил целочисленные программные композиции для 4-х типов проблем дискретного местоположения концентратора: медианная проблема  $p$ -концентратора, проблема неавтоматизированного местоположения концентратора, проблемы центра  $p$ -концентратора и проблемы покрытия концентратора.

И. П. Вознюк [3] рассмотрел задачу о наилучшем размещении пунктов производства в вершинах сети с ограниченными пропускными способностями коммуникаций и показал, что если сеть является 2-деревом, то задача решается методом динамического программирования за время  $O(nb^4)$  при объеме памяти  $O(nb^2)$ , где  $n$  — число вершин сети,  $b$  — суммарный объем спроса.

Р. Е. Буркад и др. [45] решили проблему центра в графе  $G$ , который запрашивает расположение на краю графа так, чтобы минимальное взвешенное расстояние от этой точки до вершины графа было как можно больше. Авторы получили алгоритмы с линейным временем работы для случаев, когда  $G$  — путь или звезда, тем самым улучшая предыдущие результаты А. Тамира [148]. Для разделенных звезд представлен алгоритм времени выполнения  $O(n \ln n)$ . Для общих деревьев усовершенствован алгоритм А. Тамира с коэффициентом  $\ln n$ . Кроме того, описан линейный алгоритм для невзвешенной центральной задачи на произвольном дереве с нейтральными и ненейтральными вершинами.

А. Т. Мюррей и Д. Тонг [120] установили, что размещение объектов и соответствующее их обслуживание являются основными проблемами городского и регионального планирования. Они описали подход к проблеме покрытия пространственного спроса на услуги, где потенциальные объекты расположены в непрерывной плоскости. Авторы показали, что взвешенная потребность, представленная в виде точек, линий или многоугольников, может оптимально обслуживаться конечным числом потенциальных местоположений объектов, называемых набором точек пересечения многоугольников (PIPS). Такой подход является расширением точечной абстракции спроса на более общие представления (точки, линии или полигоны).

А. А. Агеев, Э. Х. Гимади и А. А. Курочкин [1] рассмотрели задачу размещения на путевом графе в случае одинаковых производственных мощностей предприятий. Ранее Агеев построил точный алгоритм, решающий задачу за время  $O(m^5 n^2 + m^3 n^3)$ , где  $m$  и  $n$  — число предприятий и число пунктов спроса соответственно.

Затем авторы предложили модификацию этого алгоритма с меньшей на порядок по обоим параметрам временной сложностью  $O(m^4n^2)$ .

Т. Вос и др. [158] получили эффективный способ, который способен назначать услуги каждой из потенциальных лампочек в городе таким образом, чтобы все услуги распределялись адекватно (т. е. удовлетворялись требования покрытия), при минимальных затратах. Предлагается двухэтапный подход к поиску умного и экономичного дистрибутива. На первом этапе услуги распределяются по имеющимся ламповым постам с учетом требуемого покрытия и затрат на оснащение фонарного поста услугами. Представлена формулировка этой проблемы, которая называется проблемой покрытия набора множественных услуг. Для решения этой проблемы предлагается несколько эвристических методов. Для получения наилучших результатов показан эвристический метод, основанный на последовательном решении проблемы покрытия набора для каждой из служб. Качество этой эвристики можно отчасти отнести к эффективному способу, который реализуется для решения “проблемы покрытия набора”. Выбранные местоположения с первого этапа затем принимаются в качестве входных данных для второго этапа, который можно рассматривать как этап снижения затрат. На этом этапе выбирают лампочки, которые могут служить концентратором, по меньшей мере, для определенного количества лампочек, которые находятся в заданном диапазоне. Для этой проблемы, называемой проблемой беспроводной сети, представлена формулировка. Для решения проблемы беспроводной сети предлагается несколько подходов. Показано, что метод “Iterated Local Search” способен найти лучшие решения. Наилучшие методы решения используются в двухэтапном подходе для предоставления городам нескольких услуг.

Э. Х. Гимади [7] рассмотрел проблему местоположения сетевого объекта с неограниченными уровнями производства. Эта проблема является NP-трудной в общем случае и, как известно, имеет оптимальное решение с квадратичной сложностью в древовидной сети. Э. Х. Гимади [7] изучил случай сети, представляемой внешним планарным графом, т. е. графом, вершины которого принадлежат одной (внешней) грани. Известно, что эта проблема имеет оптимальный алгоритм с временной сложностью  $O(nm^3)$ , где  $n$  — количество вершин, а  $m$  — количество возможных местоположений объекта. Используя некоторые свойства внешних графов (двоичных 2-деревьев) и наличие оптимального решения с семейством централизованно соединенных доменов услуг, получены отношения повторения для построения оптимального алгоритма со сложностью по времени, которая меньше на коэффициент  $\sqrt{m}$ , чем сложность по времени предыдущего алгоритма.

Т. Хуанг, Д. Бергман и Р. Д. Гопал [81] изучили аналитический подход к выбору мест расширения для розничных продавцов, продающих дополнительные продукты, спрос на которые определяется спросом на другой базовый продукт. Спрос на добавочный продукт реализуется только как дополнение к спросу базового продукта. В этом контексте любой из этих двух продуктов может подвергаться пространственной автокорреляции, когда на спрос в данном месте влияет спрос в других местах. Используя данные промышленного партнера, продающего дополнитель-

ные продукты, авторы создали прогнозирующие модели для понимания производного спроса на дополнительные продукты, а также систему оптимизации для автоматизации решений по расширению для максимального увеличения ожидаемого объема продаж. При этом пространственная автокорреляция и сложность прогнозирующей модели влияют на сложность и структуру предписывающей оптимизационной модели. Результаты показывают, что разработанные модели весьма эффективны при прогнозировании продаж дополнительных продуктов и что использование структуры оптимизации, основанной на прогнозной модели, может привести к значительному увеличению ожидаемых продаж по сравнению с базовыми вариантами.

Таким образом, решение задачи размещения применяется для многих вариантов глобальной оптимизации в экономике, финансах и прочих отраслях.

Для решения подобных задач размещения используются в том числе алгоритмы имитационного моделирования, среди которых мы будем использовать в анализе:

- 1) генетический алгоритм (genetic algorithm);
- 2) имитационный отжиг (simulated annealing);
- 3) поиск по шаблону (pattern search).

Опишем их преимущества подробнее.

1. Эволюционные алгоритмы (genetic algorithm) являются относительно новыми, но очень мощными методами, используемыми для поиска решений многих реальных проблем поиска и оптимизации. Многие из этих проблем имеют многочисленные цели, что приводит к необходимости получения набора оптимальных решений, известных как эффективные решения. Было обнаружено, что использование эволюционных алгоритмов является высокоэффективным способом поиска множества эффективных решений в одном прогоне моделирования [88].

2. Метод отжига позволяет избежать “ловушки” в локальных экстремумах оптимизируемой функции и продолжить поиск глобального экстремума [14]. Кроме того, даже в условиях нехватки вычислительных мощностей для нахождения глобального экстремума метод отжига, как правило, выдает неплохое решение, т. е. один из локальных экстремумов [14]. Наконец, при сравнении адаптивного метода отжига (Adaptive Simulated Annealing, ASA) и генетических алгоритмов получено, что в большинстве задач метод отжига не проигрывает генетическим алгоритмам, а во многих и выигрывает [85].

3. Прямой поиск (pattern search) — метод решения задач оптимизации, не требующий никакой информации о градиенте целевой функции. В отличие от более традиционных методов оптимизации, которые используют информацию о градиенте или более высоких производных для поиска оптимальной точки, алгоритм прямого поиска ищет множество точек вокруг текущей точки, ищущей точку, где значение целевой функции ниже значения в текущей точке. Прямой поиск можно использовать для решения проблем, для которых целевая функция не является дифференцируемой или даже не является непрерывной [48, 49, 98].

Как показывает практика, среди выделенных алгоритмов имитационного моделирования поиск по шаблону позволяет более верно найти глобальный экстремум, причем в результате меньшего количества итераций.

С целью экономико-финансового форсайта эволюции инновационной системы федерального округа будем использовать модель, основанную на этапах, приведенных на рис. 24. Разберем представленные этапы подробнее.

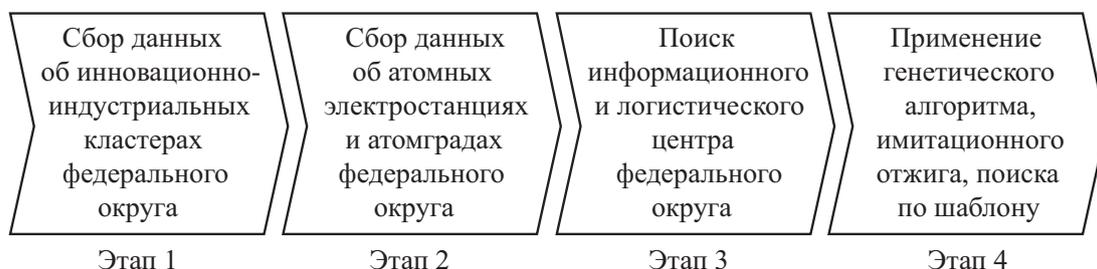


Рис. 24. Этапы решения задачи размещения информационного и логистического центра федерального округа

**Этап 1 — сбор данных о кластерах федерального округа.** Чтобы понять, какие данные понадобятся для решения задачи размещения, приведем формулу функции, которую следует минимизировать:

$$Z(x, y) = \sum_{i=1}^n w_i \sqrt{(x - x_{0,i})^2 + (y - y_{0,i})^2},$$

где  $w_i$  — веса, т. е. население  $i$ -х центров кластеров, а также центров кластеров, расположенных сравнительно недалеко от атомных электростанций (АЭС) и атомградов (чел.);

$(x_{0,i}; y_{0,i})$  — координаты  $i$ -х центров кластеров, а также АЭС и атомградов.

Таким образом, мы хотим минимизировать сумму расстояний от информационного и логистического центра федерального округа до центров кластеров, т. е. городов. При этом веса  $w_i$  входят в данную функцию с плюсом для центров кластеров и с минусом для АЭС и атомградов. Подобным способом мы хотим найти координаты центра округа, который был бы максимально близким к центрам кластеров и при этом максимально удаленным от АЭС и атомградов.

Следовательно, на 1-м этапе необходимо собрать данные о регионах федерального округа, в которых находятся инновационно-индустриальные кластеры, о кластерах и географических координатах их центров, а также о населении данных центров (городов).

**Этап 2 — сбор данных об АЭС и атомградах федерального округа.** Далее нам потребуются координаты АЭС и атомградов, а также данные о численности населения в центрах кластеров, расположенных сравнительно недалеко от них. Если для конкретной АЭС или атомграда таких центров (городов) получается несколько, то в качестве веса  $w_i$  берется сумма населения данных городов.

**Этап 3 — поиск информационного и логистического центра федерального округа.** Функция  $Z(x, y)$ , которая минимизируется, может иметь как глобальный, так и локальные минимумы. Чтобы найти именно глобальный минимум, будем

использовать соответствующие методы имитационного моделирования. Их выбор проводим на следующем этапе.

**Этап 4 — применение генетического алгоритма, имитационного отжига и поиска по шаблону.** Большинство функций  $Z(x, y)$  в задаче размещения достаточно просто минимизируются с точки зрения глобальной оптимизации всеми тремя алгоритмами. Однако, например, для зашумленной стохастической функции результаты оптимизации в зависимости от используемого алгоритма могут получиться разными. Такое также может произойти и с некоторыми гладкими функциями. По этой причине мы используем несколько методов, причем опираемся прежде всего на результаты поиска по шаблону как наиболее точного метода достижения глобального экстремума функции [48, 49, 98].

**Пример 3.** Проиллюстрируем действие представленной модели на примере Приволжского федерального округа (ПФО). Согласно перечню, утвержденному Правительством РФ, в России действуют 25 пилотных инновационных территориальных кластеров по регионам РФ. Тогда будем изучать в ПФО только те регионы (области или республики), в которых расположены кластеры из данного перечня. Тогда с целью экономико-финансового форсайта эволюции инновационной системы ПФО пройдем последовательно представленные в модели этапы.

**Этап 1 — сбор данных о кластерах федерального округа.** Данные о регионах ПФО (рис. 25), в которых расположены инновационно-индустриальные кластеры, о кластерах и географических координатах их центров, а также о населении данных центров (городов) представлены в табл. 8.

**Этап 2 — сбор данных об АЭС и атомградах федерального округа.** Координаты АЭС и атомградов в ПФО (рис. 26), а также данные об общей численности населения в центрах кластеров, расположенных сравнительно недалеко от них, отражены в табл. 9.

**Этап 3 — поиск информационного и логистического центра федерального округа.** Ищем глобальный минимум функции  $Z(x, y)$ , т. е. суммы расстояний от информационного и логистического центра ПФО до центров кластеров (городов). При этом мы хотим найти координаты центра ПФО, который был бы максимально близким к центрам кластеров, а также максимально удаленным от АЭС и атомградов. График  $Z(x, y)$  получен в программе *Matlab* (рис. 27–29).

**Этап 4 — Применение генетического алгоритма, имитационного отжига и поиска по шаблону.** Как отмечалось ранее, будем решать поставленную задачу размещения в программе *Matlab* тремя разными методами имитационного моделирования: генетический алгоритм, имитационный отжиг и поиск по шаблону.

Результаты имитационного моделирования представлены в табл. 9.

Сравнение результатов трех методов (табл. 9) приводит к выводу, что все они позволили получить одни и те же координаты искомого информационного и логистического центра ПФО, т. е.  $55^{\circ}47'$  с. ш. и  $49^{\circ}07'$  в. д. С небольшой долей погрешности это соответствует г. Казань (рис. 30). При этом поиск по шаблону демонстрирует самую быструю сходимость — за 80 итераций. Это свидетельствует о вычислительном преимуществе данного метода.

## Инновационные территориальные кластеры по регионам ПФО

Регион	Инновационный кластер	Центр кластера	Координаты центра	Население (чел.)
1. Нижегородская область	1. Нижегородский индустриальный инновационный кластер в области автомобилестроения и нефтехимии	г. Нижний Новгород	56°19'37" с. ш. 44°00'27" в. д. $x = 44,1; y = 56,33$	1 253 511
	2. Саровский инновационный кластер	г. Саров	54°56' с. ш. 43°19' в. д. $x = 43,32; y = 54,93$	95 388
2. Республика Мордовия	3. Энергоэффективная светотехника и интеллектуальные системы управления освещением	г. Саранск	54°11' с. ш. 45°11' в. д. $x = 45,18; y = 54,18$	318 578
3. Ульяновская область	4. Консорциум "научно-образовательно-производственный кластер "Ульяновск-Авиа"	г. Ульяновск	54°19' с. ш. 48°22' в. д. $x = 48,37; y = 54,32$	627 870
	5. Ядерно-инновационный кластер г. Димитровграда	г. Димитровград	54°14' с. ш. 49°35' в. д. $x = 49,58; y = 54,23$	115 253
4. Самарская область	6. Инновационный территориальный аэрокосмический кластер	г. Самара	53°11' с. ш. 50°07' в. д. $x = 50,12; y = 53,18$	1 156 644

Окончание табл. 8

Регион	Инновационный кластер	Центр кластера	Координаты центра	Население (чел.)
5. Пермский край	7. Инновационный территориальный кластер ракетного двигателестроения "Технополис "Новый Звездный"	г. Пермь	58°00'50" с. ш. 56°14'56" в. д. $x = 56,25; y = 58,01$	1 053 938
	8. Фотоника	г. Пермь		
6. Удмуртская республика	9. Удмуртский машиностроительный кластер	г. Ижевск	56°51'11" с. ш. 53°12'44" в. д. $x = 53,21; y = 56,85$	648 944
7. Республика Татарстан	10. Камский инновационный территориально-производственный кластер	г. Казань	55°47'27" с. ш. 49°06'52" в. д. $x = 49,12; y = 55,79$	1 251 969
8. Республика Башкортостан	11. Нефтехимический территориальный кластер	г. Уфа	54°44' с. ш. 55°58' в. д. $x = 55,97; y = 54,73$	1 124 226

Таблица 9

## Атомные электростанции и атомграды по регионам ПФО

Регион	АЭС и атомграды	Ближние города	Координаты АЭС	Население (чел.)
1. Нижегородская область	Саров (Арзамас-16)	г. Саров,	54°56' с. ш.	95 388
		г. Нижний Новгород, г. Саранск	43°19' в. д. $x = 43,32; y = 54,93$	1 253 511 318 578 (1 667 477)
2. Республика Мордовия	Заречный (Пенза-19)	г. Саранск	53°12' с. ш.	318 578
			45°10' в. д. $x = 45,17; y = 53,2$	
3. Ульяновская	Ядерно-инновационный кластер г. Димитровграда	г. Димитровград, г. Ульяновск	54°14' с. ш.	115 253 627 870 (743 123)
			49°35' в. д. $x = 49,58; y = 54,23$	
4. Самарская область	Балаковская АЭС (г. Балаково)	г. Самара	52°05'34" с. ш.	1 156 644
			47°57'14" в. д. $x = 47,95; y = 52,09$	
5. Пермский край	Лесной (Свердловск-45) Новоуральск (Свердловск-44)	г. Пермь	58°38' с. ш.	1 053 938
			59°47' в. д. $x = 59,78; y = 58,63$	
8. Республика Башкортостан	Трехгорный (Златоуст-36)	г. Пермь	57°15' с. ш.	1 053 938
			60°05' в. д. $x = 60,08; y = 57,25$	
		г. Уфа	54°48' с. ш. 58°27' в. д. $x = 58,45; y = 54,8$	1 124 226



Рис. 25. Регионы Приволжского федерального округа (ПФО)

Таблица 9

**Сравнение результатов имитационного моделирования**

Алгоритм	$x$	$y$	$Z(x, y)$	Итерации
Генетический алгоритм	49,12	55,79	-1,97	178
Имитационный отжиг	49,12	55,79	-1,97	1 610
Поиск по шаблону	49,12	55,79	-1,97	80

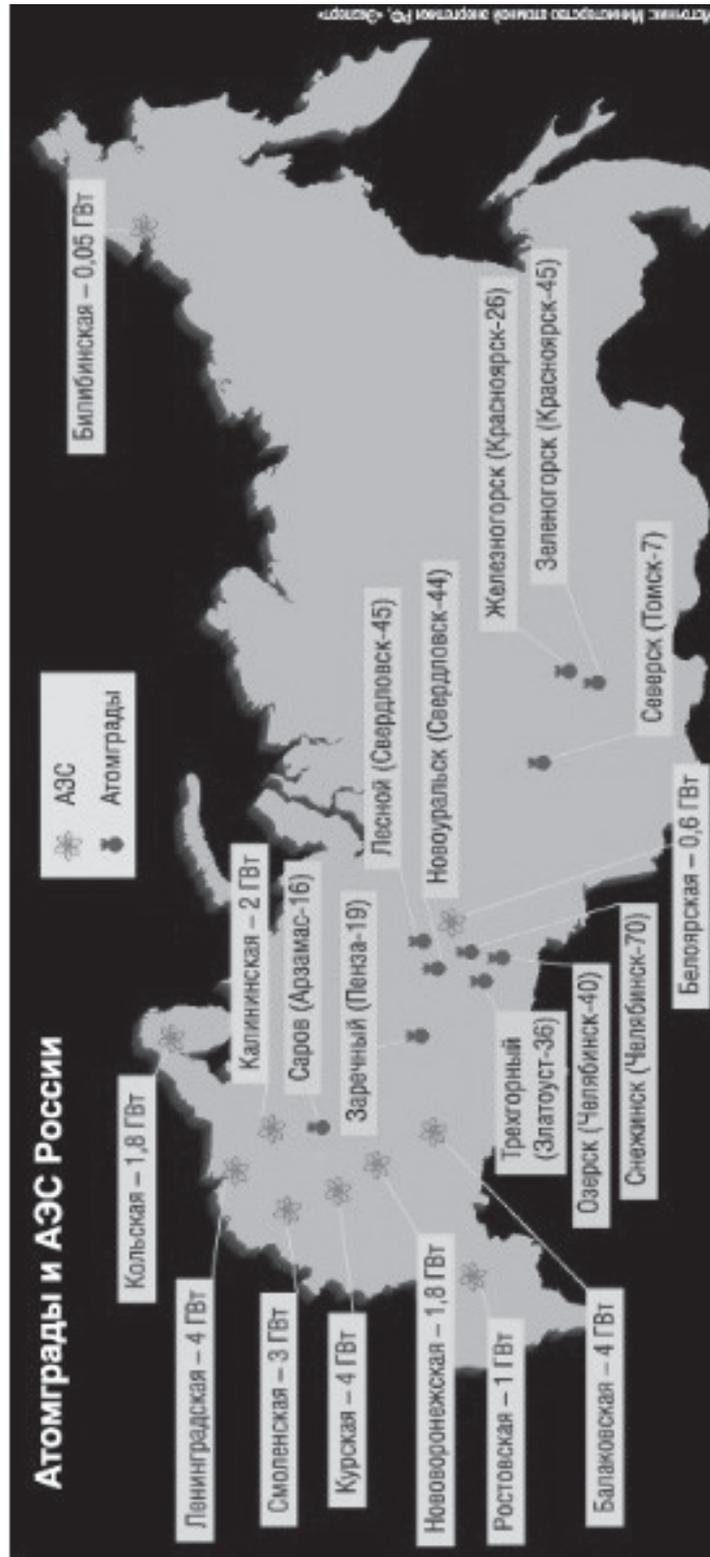


Рис. 26. Атомграды и АЭС России

```
function value = weber_obj(x, centers, weights)
value = weights*sqrt((x(:,1)-centers(:,1)).^2+(x(:,2)-centers(:,2)).^2);
```

Рис. 27. М-файл-функция

```
centers = [44.1 56.33; 43.32 54.93; 45.18 54.18; 48.37 54.32; 49.58 54.23; ...
          50.12 53.18; 56.25 58.01; 53.21 56.85; 49.12 55.79; 55.97 54.73; ...
          43.32 54.93; 45.17 53.2; 49.58 54.23; 47.95 52.09; 59.78 58.63; ...
          60.08 57.25; 58.45 54.8];
weights = [1253511; 95388; 318578; 627870; 115253; ...
          1156644; 1053938; 648944; 1251969; 1124226; ...
          -1667477; -318578; -743123; -1156644; -1053938; ...
          -1053938; -1124226];
x = 40:0.25:65;
y = 40:0.25:65;
Z = zeros(numel(x), numel(y));
for I = 1:numel(x)
    for J = 1:numel(y)
        Z(I, J) = weber_obj([x(I), y(J)], centers, weights);
    end
end
surf(x,y,Z)
shading interp
title('Graph of function {\itZ}({\itx},{\ity})')
xlabel('{\itx}')
ylabel('{\ity}')
zlabel('{\itZ}')
```

Рис. 28. Текст программы в *Matlab*

Если информационный и логистический центр ПФО, действительно, разместить в г. Казань, то это значительно сократит транзакционные издержки, связанные как с регулированием потоков информации, так и с транспортными потоками в пределах исследуемого федерального округа. А это, в свою очередь, приведет к сокращению финансовых издержек в ПФО, а главное, к увеличению синергетического эффекта крупной инновационной системы, объединяющей инновационно-индустриальные кластеры на значительной территории федерального округа.

Получение дополнительного синергетического эффекта позволит проводить более качественную политику экономико-финансового форсайта эволюции ПФО, которая будет основана на оптимальном экономико-финансовом, информационном и логистическом межкластерном взаимодействии инновационно-индустриальных кластеров в рамках одного федерального округа.

В заключение сформулируем наиболее важные практические выводы.

1. Для устойчивого экономико-финансового развития округа необходимо наличие новых условий деятельности, которые приводили бы к появлению дополнительного синергетического эффекта. Одним из таких немаловажных условий явля-

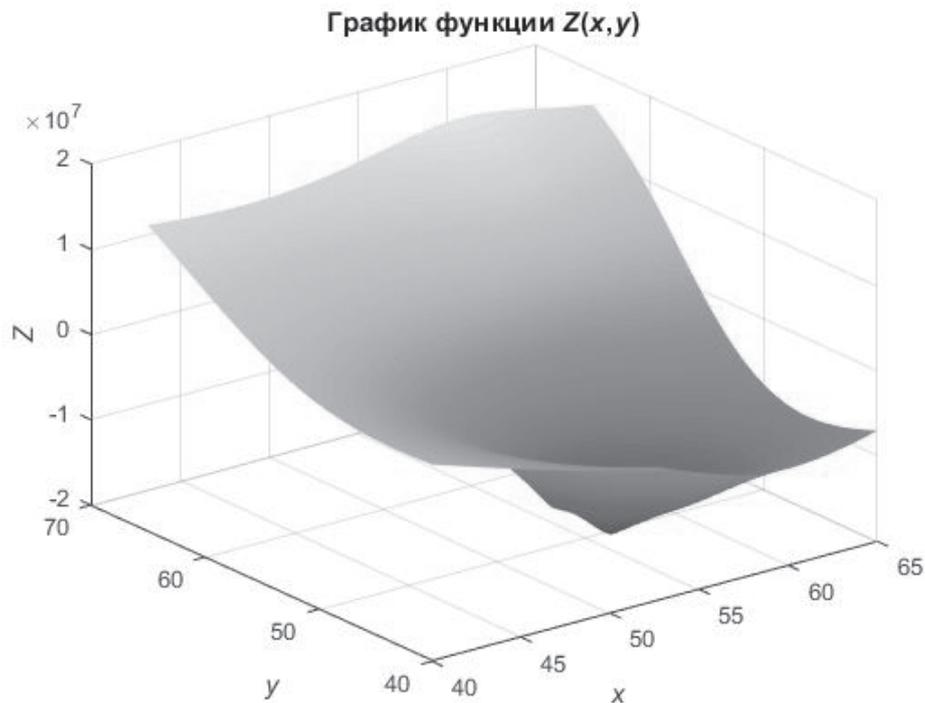


Рис. 29. График оптимизируемой функции

ется оптимальное информационное и логистическое взаимодействие инновационно-индустриальных кластеров в рамках одного федерального округа.

2. С этой целью решена задача размещения информационного и логистического центра кластеров федерального округа. Для этого применялись соответствующие технологии имитационного моделирования.

3. Поиск информационного и логистического центра инновационно-индустриальных кластеров федерального округа проводился, исходя из минимизации суммы расстояний от планируемого центра до кластеров. Также принималась во внимание максимальная удаленность центра от атомных электростанций и атомградов округа. Для этого использовались генетический алгоритм, метод имитационного отжига и поиск по шаблону.

4. В результате получено, что информационным и логистическим центром Приволжского федерального округа должен быть г. Казань.

5. Это привело бы к сокращению финансовых издержек в ПФО, а главное, к увеличению синергетического эффекта крупной инновационной системы, объединяющей инновационно-индустриальные кластеры на значительной территории целого федерального округа.

6. Получение дополнительного синергетического эффекта позволит проводить более качественную политику экономико-финансового форсайта эволюции ПФО,



Рис. 30. Координаты информационного и логистического центра ПФО

которая будет основана на оптимальном экономико-финансовом, информационном и логистическом межкластерном взаимодействии инновационно-индустриальных кластеров в рамках одного федерального округа.

Представленный подход позволит принимать более качественные решения государственным структурам и их экспертам в отношении форсайта развития крупных территорий страны, например, федеральных округов.

### **3.3. Определение центра промышленной агломерации округа: муравьиный алгоритм**

Технологии искусственного интеллекта уже достаточно широко используются в различных сферах управления. Они позволяют оптимизировать многие сложные процессы, используя для этого соответствующие алгоритмы, к числу которых относится и муравьиный алгоритм. Его можно применить для разработки модели управления крупными территориями, такими, как, например, федеральные округа.

В этом случае важно выделить наиболее важные направления взаимодействия регионов, входящих в федеральный округ. Экономика регионов становится успешной, когда эффективно функционируют инновационно-индустриальные кластеры, расположенные в соответствующих регионах. В этой связи целесообразно рассматривать также межкластерное взаимодействие регионов. К числу его приоритетных направлений мы относим экономико-финансовое, информационное и логистическое взаимодействие.

Для решения подобных вопросов можно использовать методы решения квадратичной задачи о назначениях (Quadratic Assignment Problem, QAP), к числу которых относится и муравьиный алгоритм. Его основное преимущество заключается в том, что искусственный интеллект (муравьи) продолжает искать более оптимальный путь даже тогда, когда оптимум уже найден. Это позволяет в итоге, действительно, существенно сократить издержки экономико-финансового, информационного и логистического межкластерного взаимодействия, а, следовательно, приводит к новому синергетическому эффекту функционирования инновационных систем промышленных регионов в условиях экономической неопределенности. Подобные эффекты крайне важны в процессе форсайта эволюции инновационной системы федерального округа [29].

Сама по себе задача QAP остается очень сложной, но прогресс в алгоритмах и вычислительных платформах способствовали точному решению давно уже существующих проблем, которые до недавнего времени считались неразрешимыми. Использование более сложных параметров, сильное разветвление и реализация распределенной обработки сыграли важную роль в недавних решениях крупных проблем. Дальнейший прогресс в этих областях, а также рассмотрение конкретной структуры проблем, вероятно, приведут к решению еще более сложных ситуаций в ближайшем будущем [35].

Проблема квадратичного назначения (QAP) является одной из самых сложных задач комбинаторной оптимизации. Некоторые случаи размерности  $n = 30$

остаются нерешенными уже в течение десятилетий. Решение этих проблем требует как совершенствования алгоритмов математического программирования, так и использования мощных вычислительных платформ. Так, к примеру, К. М. Анстрейхер и др. [34] описали новый подход к решению QAP с использованием современного алгоритма ветвления и привязки, выполняемого на федерации географически распределенных ресурсов, известной как вычислительная сетка.

З. Дрезнер, П. Хан и Е. Д. Тейлард [61] сообщили об эвристических и точных достижениях решения задачи QAP. Наиболее часто обсуждаемые в литературе примеры QAP относительно хорошо решаются эвристическими подходами. Действительно, решения с долей одного процента от наиболее известных значений быстро находят с помощью большинства эвристических методов. Точные методы не могут доказать оптимальность для этих экземпляров, как только размер проблемы приближается к 30 или 40. Авторы представили новые экземпляры QAP, которые плохо решаются многими методами, основанными на метаэвристике. Однако эти новые случаи, как показано, решаются относительно хорошо некоторыми точными способами, поскольку точно решены случаи проблемы размерности до 75.

Полудефинированное программирование (SDP) в последнее время оказалось очень мощным инструментом для аппроксимации некоторых NP-жестких проблем. Характер задачи QAP предполагает SDP как способ получения отслеживаемых релаксаций. Ф. Рендл и Р. Сотиров [135] привели некоторые SDP-релаксации QAP и решили их приблизительно с помощью динамической версии метода пакета. Результаты вычислений демонстрируют эффективность подхода. Полученные границы задачи в настоящее время являются одними из самых сильных, доступных для QAP. Авторы исследовали их потенциал для настройки метода ветвей и границ, принимая во внимание также границы на первых уровнях дерева ветвления.

П. М. Хан и др. [76] сообщили о новом алгоритме для обобщенной задачи квадратичного назначения (GQAP). GQAP описывает широкий класс проблем квадратичного целочисленного программирования, в котором  $M$  попарно связанных объектов назначены  $N$  адресатам, ограниченным способностью адресатов приспособиться к ним. Этот новый алгоритм основан на процедуре двойного подъема метода лиnearизации переформуляции (RLT). Экспериментальные результаты показывают, что время выполнения этого алгоритма так же хорошо или лучше, как и другие известные методы точного решения для таких больших задач, как случай  $M = 20$  и  $N = 15$ .

Недавно оказалось, что полуопределенные релаксации задачи QAP обеспечивают хорошие приближения к оптимальному значению. Дж. Пов и Ф. Рендл [132] изучили различные конические релаксации QAP. Сначала они показали, что QAP может быть эквивалентно сформулирована как линейная программа для конуса полностью положительных матриц. Поскольку этот конус трудно оптимизировать, авторы изучили прослеживаемые приближения и сравнили их с несколькими релаксациями из литературы. Авторы показали, что несколько хорошо изученных моделей фактически эквивалентны. Решить самую сложную из этих моделей до разумной точности в случаях умеренного размера задачи все еще непросто.

Г. Эрдоган и Б. К. Тансел [63] представили два новых класса экземпляров задачи QAP, которые можно свести к задаче линейного назначения, и построили полиномиальные временные процедуры для проверки, является ли экземпляр элементом этих классов.

Для решения задач с большими размерностями чаще всего используют генетические алгоритмы (GA), среди которых на данный момент лучше всего проявил себя “жадный” GA, разработанный Р. К. Ахуа, Дж. Б. Орлин и А. Тивари [33]. Однако и у этого алгоритма имеются недостатки — это сложная настройка параметров поиска и трудная балансировка между разнообразием и “жадностью” [11].

М. Ф. Тасгетирен и др. [150] представили два метаэвристических алгоритма для решения задачи QAP. Итерируемый жадный алгоритм имеет два основных компонента — процедуры разрушения и построения. Алгоритм начинается от начального решения и затем итерируется через основной цикл, где сначала получают частичное решение — кандидат путем удаления ряда компонентов решения из полного решения — кандидата. Затем полное решение восстанавливается путем вставки компонентов частичного решения в разрушенное решение. Эти простые шаги повторяются до тех пор, пока не будет выполнен определенный критерий завершения. Авторы также представили свой предыдущий алгоритм дифференциальной эволюции, модифицированный для задачи QAP. Проблема QAP является классической NP-трудной проблемой, и ее применение в реальной жизни по-прежнему считается сложной задачей. Предлагаемые алгоритмы были оценены на примерах задач QAP, возникающих из реальных проблем, а также на ряде контрольных примеров из QAPLIB. Результаты вычислений показывают, что предложенные алгоритмы превосходят алгоритм оптимизации мигрирующих птиц, который появился совсем недавно в литературе.

Задачу QAP также исследовал З. Дрезнер [62]. Он привел веса между парами объектов и расстояния между одним и тем же количеством мест. Проблема заключалась в том, чтобы найти распределение объектов по местоположениям, которое минимизирует взвешенную сумму расстояний. Эта проблема считается одной из самых сложных задач комбинаторной оптимизации.

С. Ким, М. Коджима и К. К. Тох [94] предложили эффективный вычислительный метод для задач линейно ограниченной квадратичной оптимизации (QOP) с ограничениями комплементарности, основанными на их лагранжевой и дважды неотрицательной (DNN) релаксации и алгоритмах первого порядка.

Муравьиный алгоритм также является одним из наиболее мощных инструментов для решения задачи QAP. В течение предпоследнего десятилетия искусственные муравьи переживали бурное развитие в исследовательском сообществе, в основном для решения задач оптимизации. Н. Монмарч, Ф. Гуйнанд и П. Сьярри [116] представили обзор ситуации, в которую попали алгоритмы муравьиных колоний. Искусственные муравьи включают методы решения сложных задач оптимизации и новые тенденции для коллективного интеллекта.

Одним из самых удивительных поведенческих паттернов, проявляемых муравьями, является способность определенных видов муравьев находить то, что про-

граммисты называют кратчайшими путями. Биологи экспериментально показали, что это возможно путем использования связи на основе только феромонов, пахучем химическом веществе, которое муравьи могут откладывать. Именно эта поведенческая закономерность вдохновила программистов на разработку алгоритмов решения задач оптимизации. Первые попытки в этом направлении появились в начале 90-х годов и могут рассматриваться скорее как “игрушечные” демонстрации, хотя и важны для указания на общую обоснованность подхода. С тех пор эти и подобные идеи привлекли неуклонно растущее количество исследований, и оптимизация муравьиных колоний (АСО) является одним из результатов этих исследований. Действительно, алгоритмы АСО являются наиболее успешными и широко признанными алгоритмическими методами, основанными на поведении муравьев. Об их успехе свидетельствует обширный спектр различных проблем, к которым они были применены, и, кроме того, тот факт, что АСО-алгоритмы применяются для многих проблем среди современных высокопроизводительных алгоритмов [60].

В роевой робототехнике связь между роботами имеет важное значение. Вдохновленные биологическими роями с использованием феромонов, Ф. Рьюсуке и др. [138] предложили использовать химические соединения для реализации поведения группового фуражирования в роях роботов. Они разработали полностью автономный робот, а затем создали рой с использованием этанола в качестве феромона следа, позволяющий роботам связываться друг с другом косвенно через феромонные тропы. Их групповой набор и совместные транспортные алгоритмы обеспечили роботам требуемое поведение роя. Авторы провели как моделирование, так и эксперименты с реальными роями роботов и проанализировали данные статистически, чтобы исследовать любые изменения, вызванные феромонной связью в производительности роя при решении задач подбора кормов и совместного транспорта. Результаты показывают, что роботы могут общаться, используя феромонные тропы, и что улучшение за счет феромоновой связи может быть нелинейным, в зависимости от размера роя робота.

Исследование Л. Даниелли и Г. Оливьера [52] предлагает модель памяти муравьиных автоматов (СААМ), которая управляет роем робота при выполнении задачи фуражирования в ранее известной среде с гнездами. Поле хорошо известно всем роботам, которые совместно используют одну и ту же среду, общаясь через перевернутый феромон. Это вещество осаждается каждым роющим роботом на каждом шаге поиска, что приводит к отталкивающей силе между членами команды. Кроме того, кратковременная память, вдохновленная “Tabu Search”, применяется для того, чтобы роботы могли запомнить свои последние позиции и избежать бесполезных исследований. С другой стороны, самонаведение основано на поведении, наблюдаемом при эвакуации пешеходов, что приводит к притягивающей силе через гнезда. Более того, динамическая информация используется, чтобы избежать очередей роботов и узких мест рядом с гнездами. Каждый шаг робота — движение первого выбора со стохастическим решателем конфликтов, что приводит к недетерминированной характеристике модели. Предложенная модель была реализована и представлена несколькими моделированиями для оценки ее результирующего

поведения. Для уточнения ее собственных параметров использовались различные условия окружающей среды. Результаты показали, что предлагаемая модель способна выполнять задачу фуражирования конкурентным способом: при поиске роя выполнять хороший охват окружающей среды и при самонаведении роботы способны находить наиболее адекватные гнезда.

Примечательно, что муравьиные алгоритмы используются также в финансовых исследованиях. Так, Й. Занг, С. Ванг и Г. Джи [164] предложили гибридную систему для прогнозирования корпоративного банкротства. Вся процедура состоит из следующих четырех этапов: во-первых, для извлечения наиболее важных признаков использовался последовательный прямой отбор; во-вторых, модель на основе правил была выбрана для соответствия данному набору данных, поскольку она может представлять физический смысл; в-третьих, был введен алгоритм генетической колонии муравьев (GACA); стратегия масштабирования фитнеса и оператор хаотики были включены в GACA, сформировав новый алгоритм — “fitness-scaling” хаотичный GACA (FSCGACA), который использовался для поиска оптимальных параметров основанной на правилах модели; и, наконец, метод стратифицированной  $K$ -кратной перекрестной проверки был использован для усиления обобщения модели. Эксперименты по моделированию данных 1 000 корпораций, собранных с 2006 по 2009 г., показали, что предлагаемая модель была эффективной. Она выбрала 5 наиболее важных факторов: “чистый доход для равенства брокеров”, “быстрый коэффициент”, “нераспределенная прибыль для совокупных активов”, “собственный капитал акционеров для совокупных активов” и “финансовые расходы на продажи”. Общая ошибка неправильной классификации предлагаемого FSCGACA составила всего 7,9%, превзойдя результаты генетического алгоритма (GA), алгоритма муравьиных колоний (ACA) и GACA. Среднее время вычисления модели — 2,02 с.

Опишем тогда уже известные способы применения муравьиного алгоритма к решению задачи QAP. К примеру, Ш. Цуцуи [154] предложил несколько типов параллельных алгоритмов ACO с симметричной многопроцессорной обработкой (SMP) для решения задачи QAP. Они включают модель “ведущий — ведомый” и модель “остров”. Авторы оценили каждый параллельный алгоритм с условием, что время выполнения для каждого параллельного алгоритма и базового последовательного алгоритма одинаковы. Результаты показывают, что использование модели “ведущий — ведомый” с повышенной итерацией алгоритмов ACO перспективно в решении задачи QAP.

Алгоритмы ACO, а точнее “min-max ant systems” (MMAS), используются зачастую с двумя видами стохастических методов локального поиска (SLS): “2-opt local search” и “tabu local search”. М. Маухауб и Ж. Ванг [118] предложили улучшение этих двух методов в соответствии со свойствами ACO и QAP. В случае “MMAS 2opt” ими использовалась новая стратегия случайного обхода, чтобы избежать быстрого застоя в локальной оптимизации. Кроме того, предлагается перспективная стратегия более тщательного изучения окрестностей. В случае “MMAS tabu” используется также стратегия случайной ходьбы, чтобы избежать застревания в локальной оптимуме. Чтобы показать достоинства предлагаемых методов,

авторы провели экспериментальные тесты, сравнивая соответственно “ММАС 2opt” и “ММАС tabu” с улучшениями и без них. Результаты показывают, что улучшенный локальный метод имеет более высокую производительность с точки зрения качества возвращаемого решения, чем исходные. Более того, М. Маухауб и Ж. Ванг [118] также заметили, что усовершенствованные методы превосходят друг друга для различных классов проблем.

Популяционный алгоритм оптимизации муравьиных колоний (P-ACO) отличается от других алгоритмов АСО из-за его реализации обновления феромона. Он отслеживает популяцию решений, которая служит архивом решений, генерируемых колонией муравьев. Обновления феромона в P-ACO выполняются только на основе решений, которые входят или выходят из архива решений. Популяционная схема значительно уменьшает время вычислений, необходимое для обновления феромона, по сравнению с классическими алгоритмами АСО, такими как “Ant System”. С. Оливьера и др. [124, 125] изучили поведение P-ACO для решения задачи коммивояжера (TSP) и задачи квадратичного назначения (QAP). В частности, они исследовали влияние локального поиска на параметры и производительность P-ACO. Результаты ясно показывают, что P-ACO является очень конкурентным инструментом, параметры и поведение которого сильно зависят от решаемой проблемы и от того, используется ли локальный поиск.

Учитывая требования рассматриваемой нами задачи QAP, представим этапы реализации муравьиного алгоритма в виде трехэтапной модели (рис. 31). Далее опишем данные этапы подробнее.

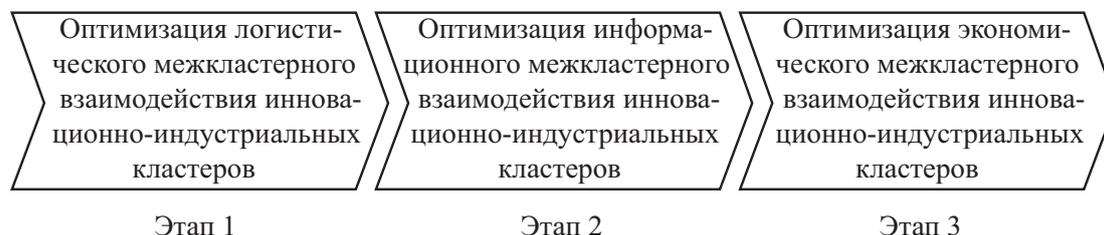


Рис. 31. Этапы реализации муравьиного алгоритма для оптимизации межкластерного взаимодействия

**Этап 1 — оптимизация логистического межкластерного взаимодействия.** Целью реализации представленной модели является определение оптимального центра промышленной агломерации. Он должен включать в себя те инновационно-индустриальные кластеры, месторасположение которых позволит сократить логистические, информационные и, следовательно, экономико-финансовые издержки в рамках одного федерального округа. Для этого сначала ищется центр агломерации с целью сокращения общих для округа логистических издержек. К таковым мы относим затраты на перевозку продукции кластеров тремя видами транспорта: 1) на грузовых автомобилях, 2) по железной дороге и 3) самолетами. Таким образом, предварительно кластеры разбиваются на три отрасли согласно перечис-

ленным видам перевозки грузов. В результате составляется матрица средних цен перевозок (матрица весов), каждый элемент которой показывает среднюю цену перевозки продукции из отрасли  $i$  в отрасль  $j$ .

После этого с помощью муравьиного алгоритма ищется центр промышленной агломерации федерального округа, для чего необходимо на множестве кластеров  $P$  найти минимум функции

$$\sum_{a,b \in P} w_{a,b} d_{f(a),f(b)},$$

где  $W$  – матрица весов для кластеров  $a$  и  $b$ ;

$D$  – матрица расстояний между кластерами  $a$  и  $b$ ;

$f(a)$  и  $f(b)$  – перестановки на множестве  $P$ .

В результате получаются три города, которые являются географическими центрами кластеров и соответствуют оптимальным местоположениям центров трех соответствующих отраслей.

**Этап 2 — оптимизация информационного межкластерного взаимодействия.** Полученные на предыдущем этапе центры отраслей учитываются на этапе оптимизации информационного взаимодействия кластеров. Таким образом, новые списки кластеров в трех отраслях корректируются.

Затем ищем географические центры для тех же трех отраслей на предмет минимизации естественной убыли населения в федеральном округе. Она обусловлена информацией об уровне жизни в регионах при условии наличия промышленной агломерации в округе. Для этого сначала вычисляется общая для каждой отрасли естественная убыль населения. Потом составляется матрица средней естественной убыли населения (матрица весов), каждый элемент которой отражает среднюю величину убыли с учетом возможных миграций населения между кластерами из отрасли  $i$  в отрасль  $j$ .

После этого с помощью муравьиного алгоритма заново ищется центр промышленной агломерации федерального округа. Если получается то же множество трех городов — центров кластеров, то задача решена.

**Этап 3 — оптимизация экономико-финансового межкластерного взаимодействия.** Данный этап уже носит формальный характер, т.к. в результате проведенной оптимизации логистического и информационного межкластерного взаимодействия значительно сокращаются общие для округа транспортные издержки и убыль населения. Разница между прежними и новыми общими транспортными издержками и убылью населения представляет собой величину синергетического эффекта от проведенной оптимизации. В результате определение и размещение центра промышленной агломерации позволит качественно улучшить процесс форсайта эволюции крупной инновационной системы, представленной федеральным округом.

**Пример 4.** Проиллюстрируем реализацию представленной модели на примере Приволжского федерального округа (ПФО). Будем рассматривать только регионы округа, в которых расположены инновационно-индустриальные кластеры

из перечня 25 пилотных инновационных территориальных кластеров, утвержденных Правительством РФ. Они описаны их в табл. 8 (параграф 3.2). Имея данную информацию, можно перейти к этапам реализации модели.

**Этап 1 — оптимизация логистического межкластерного взаимодействия.** Учитывая, что для широты и долготы в одном градусе примерно 111 км, оценим стоимости перевозки продукции кластеров.

1. Цена перевозки на грузовом автомобиле на 1 км — 33 руб. (3663 руб. на 1 градус).

2. Цена железнодорожной перевозки на 1 км — 29 руб. (3219 руб. на 1 градус).

3. Цена перевозки на самолете на 1 км — 103 руб. (11433 руб. на 1 градус).

Тогда матрица средних цен перевозок из отрасли  $i$  в отрасль  $j$  будет иметь вид

$$\begin{pmatrix} 0 & 3441 & 7548 \\ 3441 & 0 & 7326 \\ 7548 & 7326 & 0 \end{pmatrix}.$$

К 1-й отрасли относим кластеры 1, 3, 8, 9, 10, ко 2-й отрасли — кластеры 4, 6, 7, 11, а к 3-й — кластеры 2, 5 из табл. 8 (параграф 3.2).

После этого решаем квадратичную задачу о назначениях (QAP) для ПФО. То есть ищем для него оптимальную промышленную агломерацию. Для решения используем муравьиный алгоритм в *Matlab* (Mostapha Kalami Heris, Ant Colony Optimization in MATLAB (<https://yarpiz.com/53/ypea103-ant-colony-optimization>), Yarpiz, 2015).

Результаты представлены на рис. 32 и 33. Они означают, что центр 1-й отрасли должен быть в г. Самара, 2-й отрасли — в г. Ульяновск, а 3-й — в г. Дмитровград. В этом случае будут минимальными общие для ПФО затраты на перевозки, т. е. 24987,77 руб. в одном градусе.

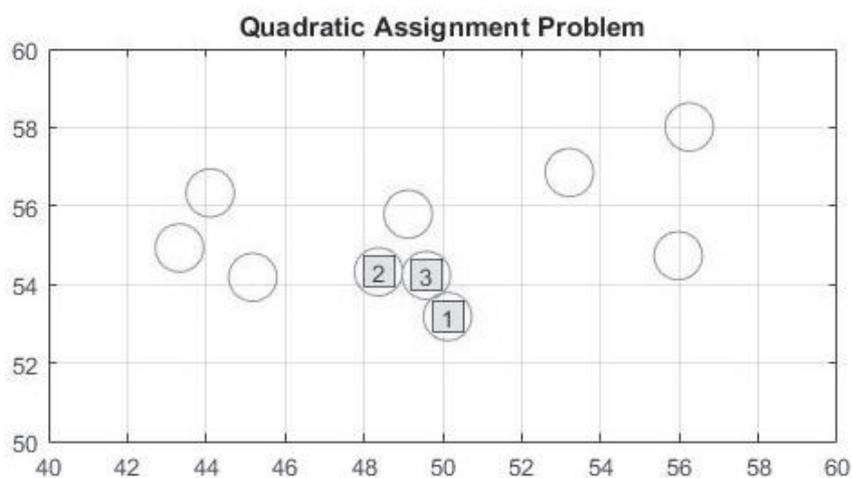


Рис. 32. Оптимальная промышленная агломерация Самара–Ульяновск–Дмитровград

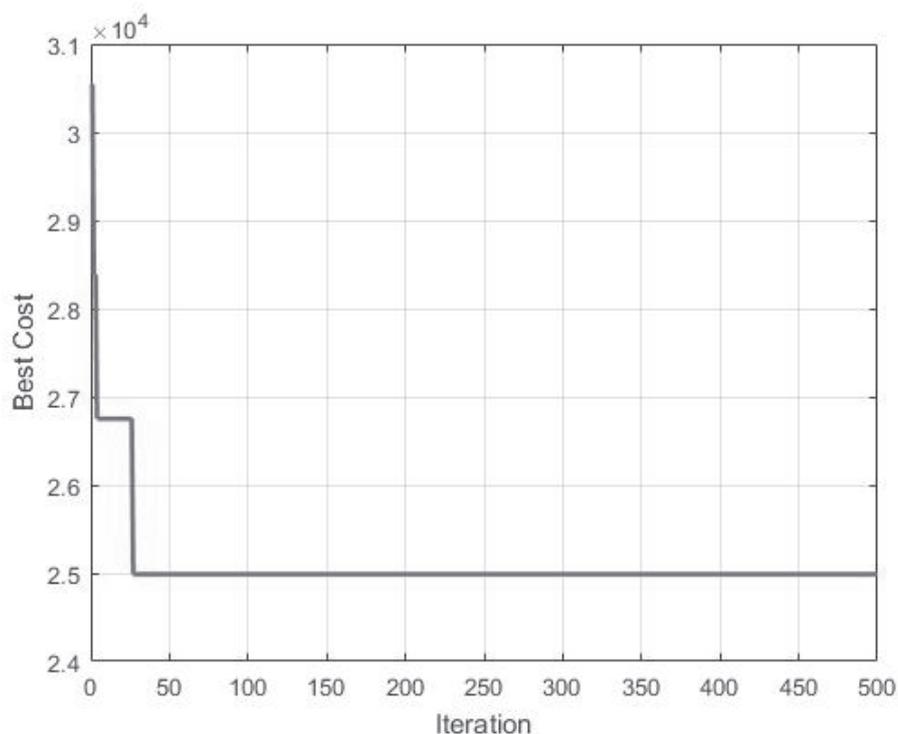


Рис. 33. Минимум затрат на перевозки — 24 987,77 руб. в одном градусе

**Этап 2 — оптимизация информационного межкластерного взаимодействия.** В табл. 10 собирается информация о естественной убыли населения по регионам ПФО в 2019 г. Затем корректируем новые списки кластеров в трех отраслях с учетом результатов предыдущего этапа анализа. Так, к 1-й отрасли относим регионы 1, 2, 4, 6, 7, ко 2-й отрасли — регионы 5, 8, а к 3-й — регион 3 из табл. 10.

*Таблица 10*

**Информация о населении регионов ПФО с кластерами**

Регион	Естественная убыль населения в 2019 г. (чел.)
1. Нижегородская область	18 107
2. Республика Мордовия	4 536
3. Ульяновская область	6 197
4. Самарская область	12 454
5. Пермский край	7 777
6. Удмуртская Республика	3 269
7. Республика Татарстан	180
8. Республика Башкортостан	7 348

Всего по отраслям естественная убыль населения составляет соответственно 38 546, 15 125 и 6 197 чел.

Тогда матрица средней естественной убыли с учетом возможных миграций населения между кластерами из отрасли  $i$  в отрасль  $j$  будет выглядеть как

$$\begin{pmatrix} 0 & 26\,835,5 & 22\,371,5 \\ 26\,835,5 & 0 & 10\,661 \\ 22\,371,5 & 10\,661 & 0 \end{pmatrix}.$$

После этого ищем географические центры для тех же 3-х отраслей на предмет минимизации естественной убыли населения в ПФО, т. е. решаем новую задачу QAP. Для этого также используем муравьиный алгоритм в *Matlab* (Mostapha Kalami Heris, Ant Colony Optimization in MATLAB (<https://yarpiz.com/53/ypea103-ant-colony-optimization>), Yarpiz, 2015).

Результаты представлены на рис. 34 и 35. Они означают, что сохранилось прежнее множество городов — центров кластеров, т. е. задача успешно решена. При этом будет наблюдаться минимальное значение естественной убыли населения во всем ПФО, т. е. 79 915 чел./111 км в градусе.

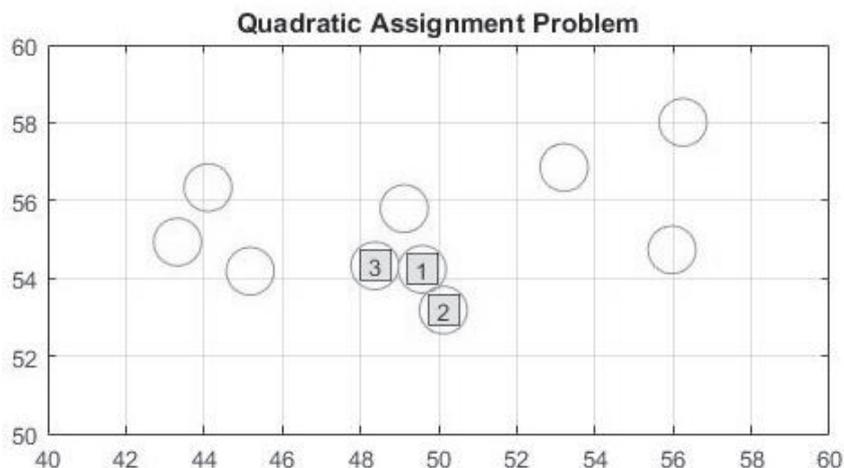


Рис. 34. Оптимальная промышленная агломерация Димитровград–Самара–Ульяновск

**Этап 3 — оптимизация экономико-финансового межкластерного взаимодействия.** Сокращение общих транспортных издержек и естественной убыли населения в ПФО в случае размещения центра промышленной агломерации в полученных трех городах позволит качественно улучшить процесс форсайта эволюции крупной инновационной системы, представленной исследуемым округом.

В заключение сформулируем наиболее важные результаты исследования.

1. Экономика федерального округа становится успешной, когда эффективно функционируют инновационно-индустриальные кластеры, расположенные в соот-

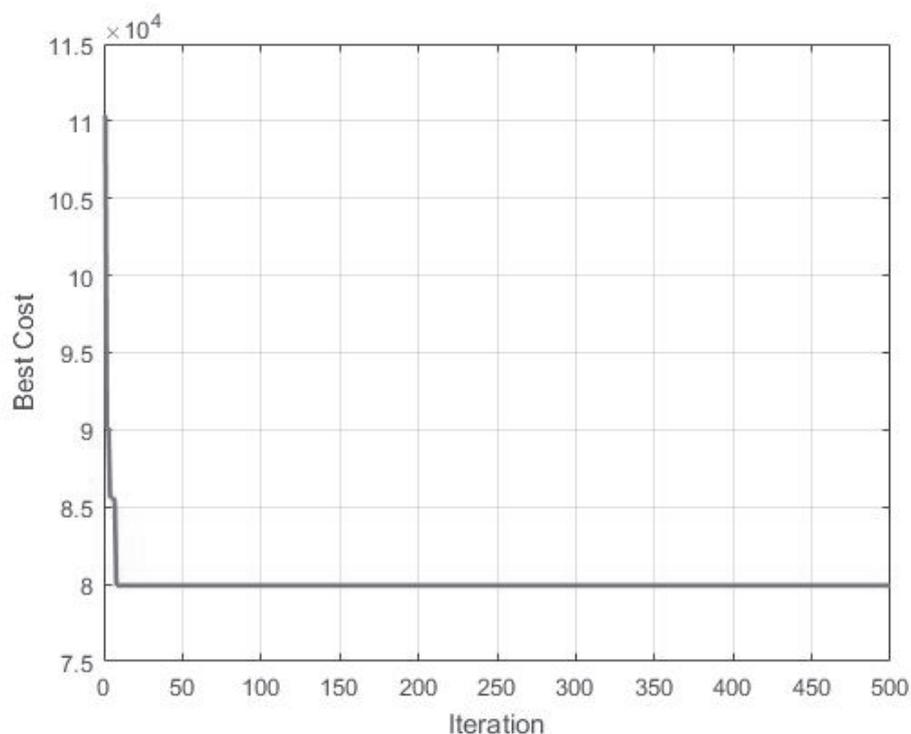


Рис. 35. Минимум естественной убыли населения — 79 915 чел./111 км в градусе

ветствующих его регионах. В этой связи целесообразно анализировать межкластерное взаимодействие регионов в следующей последовательности: 1) логистическое, 2) информационное и 3) экономико-финансовое взаимодействие.

2. Для решения подобных вопросов можно использовать методы решения квадратичной задачи о назначениях, к числу которых относится и муравьиный алгоритм. Его основное преимущество заключается в том, что искусственный интеллект (муравьи) продолжает искать более оптимальный путь даже тогда, когда оптимум уже найден. Это позволяет существенно сократить издержки межкластерного взаимодействия, а, следовательно, приводит к новому синергетическому эффекту функционирования инновационных систем промышленных регионов в условиях экономической неопределенности. Подобные эффекты крайне важны в процессе форсайта эволюции инновационной системы федерального округа.

3. Целью реализации представленной модели является определение оптимального центра промышленной агломерации. Он должен включать в себя те инновационно-индустриальные кластеры, месторасположение которых позволит сократить логистические, информационные и, следовательно, экономико-финансовые издержки в рамках одного федерального округа. Для этого сначала ищется центр агломерации с целью сокращения общих для округа логистических издержек.

4. Затем ищем географические центры на предмет минимизации естественной убыли населения в федеральном округе. Она обусловлена информацией об уровне жизни в регионах при условии наличия промышленной агломерации в округе.

5. В результате проведенной оптимизации логистического и информационного межкластерного взаимодействия значительно сокращаются общие для округа транспортные издержки и убыль населения. Разница между прежними и новыми общими транспортными издержками и убылью населения представляет собой величину синергетического эффекта от проведенной оптимизации.

Представленный подход позволит принимать более качественные решения государственным структурам и их экспертам в отношении форсайта развития крупных территорий страны, например, федеральных округов.

## Глава 4

### Глобальная оптимизация затрат на НИР крупных инновационных систем

#### 4.1. Одновременное инвестиционное, производственное и финансовое планирование программ инновационного развития региона: генетический алгоритм, имитационный отжиг, поиск по шаблону

В настоящее время условия внешнего окружения Российской Федерации предполагают рассмотрение вопросов национального эффективного и сбалансированного социально-экономического и инновационного развития промышленных регионов РФ с позиций моделирования процессов их инновационного развития.

Большинство текущих исследований региональных инновационных процессов производятся с использованием методов социологических наук. При этом ощущается острый недостаток математических и информационных моделей, которые позволили бы не только спрогнозировать динамику развития региональных инновационных процессов и систем, но и спланировать процесс их эволюции, исходя из сложившихся социально-экономических ценностей региона.

В этой связи труды по проблемам функционирования региональных инновационных систем, разработанные российскими и зарубежными учеными, резюмируют, что большинство систем имеет устойчивую совокупность структурных элементов, которые достаточно хорошо изучены и описаны, определены институциональные взаимосвязи инновационных цепочек.

В то же время роль региональных инновационных систем до сих пор недооценена, большая часть работ посвящено национальным инновационным системам, также большинство исследований имеют социальную направленность без должного экономического и математического описания. Авторское исследование будет отличаться анализом и обобщением значительного массива информации по элементам взаимодействия на региональном уровне на основе экономико-математического моделирования.

Мы предлагаем в рамках данного исследования проводить анализ закономерностей и предпосылок формирования региональных инновационных систем именно с учетом данных предпосылок.

Целью исследования является разработка научно-обоснованной гибкой управленческой модели, с одной стороны, учитывающей специфику цикличности развития инновационной системы промышленного региона, а также уровень его социально-экономического развития, с другой стороны, способствующей преодолению экономического детерминизма территорий и стимулирующей экономический рост промышленного региона. Для достижения поставленной цели необходимо создать региональную модель одновременного инвестиционного, производственного и финансового планирования программ инновационного развития.

Проблемами планирования инвестиционных, производственных и финансовых программ в их взаимосвязи занимались такие ученые как Ю. Бригхем и Л. Гапенски [44], Л. Крушвиц и Д. Лоренц [102], М. А. Лимитовский [12]. Так, Ю. Бригхем и Л. Гапенски исследовали процессы планирования инвестиционных программ проектов коммерческих компаний [44]. Л. Крушвиц и Д. Лоренц изучали процессы одновременного инвестиционного и финансового планирования, а также одновременного инвестиционного и производственного планирования [102]. М. А. Лимитовский дополнил их результаты учетом системных финансовых эффектов инвестиционных программ [12]. Однако недостаточно исследованы процессы одновременного инвестиционного, производственного и финансового планирования. Кроме того, до сих пор данные технологии не адаптированы в государственных структурах к планированию программ инновационного развития регионов.

В большей степени различными учеными исследовались процессы одновременного инвестиционного и финансового планирования. Данный опыт может позволить сформировать собственную точку зрения по данному вопросу, дополнив уже разработанные технологии еще и производственным планированием.

Так, С. В. Науменкова и О. И. Глазун [16] провели исследование, которое посвящено использованию имитационных и аналитических методов количественного анализа и прогнозирования процессов управления инвестиционной и финансовой деятельностью предприятия. При помощи дополнительного включения параметра времени они взаимно увязали во времени ключевые переменные и функциональные области созданной ими модели.

Г. Хан и Г. Кун [75] выяснили, что, поскольку укрупненное планирование капитальных (разовых) инвестиций осуществляется на долгосрочном уровне, подробные сроки их корректировки остаются на среднесрочном уровне. В сочетании с мерами регулирования мощности для оптимизации использования активов можно использовать также время корректировки мощности. Исследование ученых представляет собой соответствующую технологию для оптимизации производительности на основе стоимости и рисков в цепочках поставок, охватывающих одновременно инвестиции, операции и финансовое планирование.

А. О. Недосекин и З. И. Абдулаева [17] в своей монографии провели обзор моделей и методов различных вариантов планирования: стратегического, инвестиционного, операционного, финансового в узком смысле, привели упрощенные виды планов, рассмотрели вопрос нормирования параметров плана.

С. А. Рытиков, А. В. Богданов и А. Д. Кулаков [19] представили модель одновременного планирования и инструментальное средство, учитывающие условия финансовой реализуемости, ликвидности и влияние налоговой нагрузки. Модель позволяет проводить оптимизацию схемы финансирования проекта (его полного финансового плана) по одному из двух критериев (максимум конечной стоимости имущества или максимальный чистый дисконтированный доход). Исследование показало, что модель позволяет находить сбалансированные схемы финансирования инвестиционных проектов; определять оптимальную очередность ввода их мощностей; эффективно использовать свободные средства, генерируемые проектом.

Э. В. Дингес и С. Н. Поздеева [8] в своей монографии предложили методы оптимизации инвестиционно-финансовых программ деятельности дорожных организаций, предусматривающие: 1) динамическую постановку задачи развития предприятия в краткосрочной и среднесрочной перспективе; 2) взаимоувязанное рассмотрение возможных вариантов инвестиционной и финансовой деятельности предприятий; 3) использование в качестве критерия оптимальности формирования программы показателя максимизирующего стоимость капитала предприятия в конце срока ее осуществления.

Несмотря на полезный опыт данных исследований одновременного и финансового планирования, следует все же использовать его для создания программ инновационного развития производственных компаний и промышленных регионов. В этой связи отдельный интерес представляют работы следующих исследователей.

Для эффективной реализации соответствующих программ инновационного развития региона необходимо четко формулировать его цели и задачи, исходя из его социально-экономических ценностей. Так, М. А. Гершман [6] приводит рекомендации, которые могут служить определенными ориентирами для совершенствования государственной политики в рассматриваемой сфере. Это 1) дифференциация стимулирующих мер; 2) содействие развитию кооперации между государственными компаниями (с «открытыми» моделями функционирования) и другими субъектами; 3) согласование различных направлений корпоративной политики госкомпаний (социальной, экологической, финансовой, информационной и др.) с их инновационными стратегиями; 4) разработка мер, упреждающих риски имитации инновационной активности; 5) конкретизация инновационных стратегий, их интеграция в дорожные карты технологического развития секторов, рынков, регионов.

О. А. Строева [21] разработала программу инновационного развития региональных экономических систем, которая включает в себя цели и задачи, этапы и конкретные мероприятия, а также ожидаемые результаты и источники финансирования на основе согласования макроинтересов регионов и микроинтересов хозяйствующих субъектов. Новизна исследования состоит в определении комплекса мероприятий, посредством которых администрация стимулирует развитие экономики региона.

М. С. Фабиана и др. [66] исследовали, как технологический инновационный процесс происходит в малых и средних технологических компаниях, расположенных в столичном регионе долина Параиба и Северное побережье — Бразилия. Используемая теоретическая методология состояла из шести авторских моделей инноваций: технологический толчок, вытягивание рынка, процесс объединения инноваций, процесс функциональной интеграции инноваций, процесс системной интеграции и сетевых инноваций и открытые инновации. В результате наблюдения за моделями инновационного развития, принятыми компаниями, ученым представляется, что модель ближе к тому, что было предложено в модели цепных взаимодействий. Получено, что развитие инноваций зависит от вида экономической деятельности, который развивает компания, и взаимодействий, которые она имеет с внутренней и внешней средой.

Е. П. Г. Васконцеллос и др. [157] утверждают, что ресурсы, вложенные в исследования, не гарантируют немедленного практического применения. Компании и правительства все чаще ищут механизмы для определения приоритетности проектов НИОКР в случае нехватки ресурсов. В этой связи цель исследования ученых состояла в разработке и представлении методологии, используемой для оценки портфеля исследований и помощи в выборе наилучших инвестиций в исследования. Выводы показывают, что для управления портфелем НИОКР следует использовать критерии риска и отдачи при выборе проектов.

Таким образом, актуальной становится проблема планирования затрат на научно-исследовательские работы (НИР). Так, О. А. Феоктистова [24] выделяет в этом процессе следующие ключевые принципы:

- 1) понимание, что научно-исследовательская работа представляет собой уникальный по своим характеристикам процесс, отличающийся от любой другой работы, и требует особого методологического и законодательного подхода;
- 2) использование проектного подхода при планировании НИОКР и их финансирования как наиболее эффективного и доказавшего свою состоятельность в российской и международной практике;
- 3) обязательное применение конкурсных принципов финансирования научно-исследовательских проектов и независимой экспертной научной оценки, что позволит отбирать действительно лучших исполнителей и обеспечит высокое качество результатов;
- 4) выбор в качестве одного из ключевых критериев при планировании затрат на научно-исследовательский проект ожидаемых результатов от его реализации;
- 5) выбор в качестве ключевого критерия при определении финансирования научно-исследовательского проекта результатов, уже достигнутых его потенциальным исполнителем.

В. Ф. Гапоненко [4] рассмотрел ситуации, в которых потенциально возможно снизить фактические затраты на выполнение НИР. К ним он отнес следующие:

- 1) выполнение НИР, аналогичной работам, выполненным ранее тем же исполнителем — организацией науки или исследователем;
- 2) выполнение НИР, близких к выполненным ранее другими исполнителями — организациями науки;
- 3) выполнение (возможно одновременное) схожих НИР для разных заказчиков;
- 4) использование ранее полученных результатов исследований, ранее собранных установок в новом исследовании при отсутствии аналогии между темами старых и новых исследований;
- 5) включение в ТЗ задач, не соответствующих цели НИР, результаты которых могут быть использованы, например, в другой НИР или публикации, патенте.

Таким образом, мы приходим к необходимости решения проблемы снижения затрат на НИР, причем таким образом, чтобы это повышало эффективность экономики промышленных регионов. Так, в работе С. Н. Яшина и др. [163] в результате проведенного форсайта эволюции инновационной системы федерального округа, основанного на использовании многоцелевого генетического алгоритма, было полу-

чено, что в целях повышения синергетического эффекта федерального округа планируется перенаправить инвестиционные ресурсы и затраты на НИР в те регионы, где экономико-финансовых ресурсов не хватает. Это позволит в итоге увеличить среднедушевые доходы населения в регионах федерального округа, что приведет, в свою очередь, к приросту населения в них.

В этой связи актуальным является вопрос управления затратами на НИР в инновационно-индустриальных кластерах, которые способствуют социально-экономическому развитию регионов, где данные кластеры находятся. Для этого необходимо решать соответствующие проблемы управления кластерами. Так, А. Полянин и др. [130] разработали научно-методические рекомендации, которые могут способствовать своевременному выявлению реальных и потенциальных экономических угроз в кластере. Авторы создали методику оценки экономической безопасности кластера, которая характеризуется комплексным подходом, учитывающим все возможные риски и угрозы в функционировании отдельных компонентов кластерной структуры.

Л. Ташенова и др. [151] разработали метод оценки цифрового потенциала магистральных инновационных активных промышленных кластеров. Метод разработан на основе существующих методов и подходов к оценке инновационного потенциала промышленных кластеров и цифрового потенциала промышленных предприятий, и позволяет рассчитать итоговую интегральную оценку. Предложенный метод успешно опробован на примере кластера “Развитие информационных технологий, радиоэлектроники, приборостроения, связи и информационно-телекоммуникационных устройств Санкт-Петербурга”.

Решение перечисленных проблем подводит к центральному вопросу настоящего исследования: как оптимизировать затраты на НИР в промышленном регионе? Несмотря на безусловную важность выявления необходимых параметров оптимизируемой целевой функции, необходимо также определиться с методами глобальной оптимизации, т. е. выбрать те из них, которые позволят получить наиболее достоверное конечное решение проблемы. Для решения нашей задачи будем применять следующие подходы:

- 1) генетический алгоритм (Genetic Algorithm, GA);
- 2) имитационный отжиг (Simulated Annealing, SA);
- 3) поиск по шаблону (Pattern Search, PS).

Таким образом, используя три разных алгоритма для оптимизации затрат на НИР, мы можем проверить полученное решение.

Оптимизацию затрат на НИР промышленного региона будем проводить в зависимости от следующих факторов:

1. *Инвестиционное планирование.* Для этого будем использовать информацию о динамике инвестиций в основной капитал в регионе.

2. *Производственное планирование.* Здесь будем опираться на данные о динамике валового регионального продукта (ВРП).

3. *Финансовое планирование.* Поскольку в данной задаче мы рассматриваем возможности внешнего финансирования, которое дает дополнительную возможность

промышленным компаниям региона развивать свои инновации, здесь будем использовать информацию о динамике кредиторской задолженности организаций.

Таким образом, оптимизация затрат на НИР ставится в зависимость от одновременных процессов инвестиционного, производственного и финансового планирования, что позволит получить наиболее эффективную комбинацию значений этих трех факторов.

Наконец, следует определить, что понимать под оптимизацией затрат на НИР: их максимизацию или минимизацию. В идеальном случае, естественно, необходимо исследовать проблему нахождения возможностей увеличения затрат на НИР, т.к. в этом случае промышленный регион будет развиваться интенсивнее за счет получения и внедрения новых технологий, что, в свою очередь, положительно отразится на инновационном развитии всей страны. Однако мы будем искать возможности снижения затрат на НИР до того оптимального значения, которое будет достижимо при одновременном инвестиционном, производственном и финансовом планировании региона, позволяющем определить наиболее целесообразные пропорции перечисленных трех факторов планирования в денежном выражении.

Наконец, региональная модель одновременного инвестиционного, производственного и финансового планирования программ инновационного развития должна быть достаточно детальной, для чего будут исследоваться несколько целевых функций внутренних текущих затрат на НИР промышленного региона: всего затраты на НИР, а также три их компоненты — фундаментальные исследования, прикладные исследования и разработки. Это позволит в итоге сделать более обоснованные выводы о том, как следует развивать промышленному региону свои внутренние текущие затраты на НИР в зависимости от планирования инвестиций в основной капитал, ВРП и кредиторской задолженности организаций.

Учитывая обозначенные допущения, представим этапы реализации рассматриваемой модели на рис. 36. Опишем эти этапы подробнее.

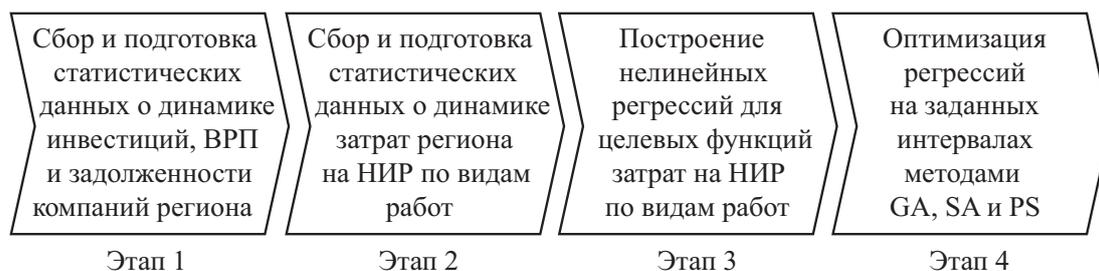


Рис. 36. Этапы реализации региональной модели одновременного инвестиционного, производственного и финансового планирования программ инновационного развития

**Этап 1 — сбор и подготовка статистических данных о динамике инвестиций, ВРП и задолженности компаний региона.** Для построения качественных будущих нелинейных регрессий целевых функций затрат на НИР нужны данные о динамике инвестиций в основной капитал ( $x_1$ ), ВРП ( $x_2$ )

и кредиторской задолженности организаций ( $x_3$ ) за большой срок, охватывающий 10 лет. Поскольку на сайте Федеральной службы государственной статистики ([www.gks.ru](http://www.gks.ru)) есть данные о внутренних текущих затратах на НИР, инвестициях в основной капитал и кредиторской задолженности организаций за период до 2020 г. включительно, но при этом нет таких данных о ВРП за 2019 и 2020 гг., их будем прогнозировать самостоятельно, используя для этого Интернет-сервис *WolframAlpha* ([www.wolframalpha.com](http://www.wolframalpha.com)).

Кроме того, с целью сравнимости собранных данных их необходимо будет скорректировать на все годовые темпы инфляции за рассматриваемый период.

**Этап 2 — сбор и подготовка статистических данных о динамике затрат региона на НИР по видам работ.** На данном этапе собирается статистическая информация о внутренних текущих затратах на НИР всего ( $y$ ), а также по видам работ: фундаментальные исследования ( $y_1$ ), прикладные исследования ( $y_2$ ) и разработки ( $y_3$ ). При этом эти данные также должны быть за тот же срок, охватывающий 10 лет, как и срок на предыдущем этапе. После этого данные также корректируются на все годовые темпы инфляции за рассматриваемый период.

**Этап 3 — построение нелинейных регрессий для целевых функций затрат на НИР по видам работ.** Нелинейные регрессии более реально отражают экономические процессы по сравнению с линейными. Кроме того, в нашем случае регрессии вида  $y = f(x_1, x_2, x_3)$  будут множественными. Чтобы их получить, используем пакет *Statistica*. О качестве регрессий целевых функций будем судить по коэффициенту детерминации ( $R^2$ ) и скорректированному коэффициенту детерминации (adjusted  $R^2$ ), т. е. по близости их значений к 1.

**Этап 4 — оптимизация регрессий на заданных интервалах методами GA, SA и PS.** Данную глобальную оптимизацию будем проводить в пакете *Matlab*, используя для этого генетический алгоритм (GA), имитационный отжиг (SA) и поиск по шаблону (PS). Для уточнения результатов методов GA и SA будем результаты оптимизации целевых функций дополнять гибридными функциями поиска по шаблону и метода внутренней точки [2]. То есть сначала запускаются алгоритмы GA или SA, а затем их результаты используются в качестве отправной точки для последующей оптимизации целевой функции с помощью гибридной функции. Это позволит получить более качественное решение в каждом конкретном случае оптимизации всех затрат на НИР, фундаментальных исследований, прикладных исследований и разработок.

Кроме того, если не задавать нижнее и верхнее значение каждого параметра целевой функции соответствующих затрат на НИР, ее минимальное значение может получиться равным минус бесконечности. Поэтому для каждого параметра  $x_1$ ,  $x_2$ ,  $x_3$  соответствующей целевой функции будем задавать их фактические нижние и верхние значения за исследуемый период. Такой подход позволит также нам в дальнейшем сравнить оптимальное (минимальное) значение соответствующих затрат на НИР с их фактическим минимальным значением за исследуемый период.

**Пример 5.** Проиллюстрируем реализацию представленной модели на примере Нижегородской области, являющейся крупным промышленным регионом.

**Этап 1 — сбор и подготовка статистических данных о динамике инвестиций, ВРП и задолженности компаний региона.** На данном этапе необходимые исходные данные собираются с сайта Федеральной службы государственной статистики (*www.gks.ru*). Они представлены в колонках  $x_1$ ,  $x_2$  и  $x_3$  табл. 11. Поскольку на указанном сайте есть данные о внутренних текущих затратах на НИР лишь за период с 2015 по 2020 г., а также за 2010 г., данные об инвестициях в основной капитал и кредиторской задолженности организаций берем за те же годы. Кроме того, с целью сравнимости собранных данных их корректируем на все годовые темпы инфляции за рассматриваемый период согласно данным табл. 12. То есть все данные табл. 13 представлены в ценах 2020 г.

Также решаем проблему недостатка данных о ВРП за 2019 и 2020 гг. на сайте Федеральной службы государственной статистики. Их прогнозируем самостоятельно в ценах 2020 г., используя для этого период с 2009 по 2018 гг. и Интернет-сервис *WolframAlpha* (*www.wolframalpha.com*) (рис. 37). Несмотря на самые низкие значения  $R^2$  и уточненного  $R^2$ , прогноз согласно натуральному логарифму представляется наиболее правдоподобным с экономической точки зрения, т. к. в 2020 г. мы ожидаем снижение значений ВРП вследствие пандемии.

**Этап 2 — сбор и подготовка статистических данных о динамике затрат региона на НИР по видам работ.** На данном этапе собирается статистическая информация о внутренних текущих затратах на НИР всего, а также по видам работ: фундаментальные исследования, прикладные исследования и разработки. Они представлены соответственно в колонках  $y$ ,  $y_1$ ,  $y_2$  и  $y_3$  табл. 11. При этом эти данные за тот же срок, что и на предыдущем этапе. После этого они также корректируются на все годовые темпы инфляции за рассматриваемый период (табл. 12). Результаты представлены в табл. 13.

**Этап 3 — построение нелинейных регрессий для целевых функций затрат на НИР по видам работ.** На основе значений табл. 13 в пакете *Statistica* получены следующие наиболее точные нелинейные регрессии:

— регрессия для всех затрат на НИР (рис. 38):

$$y = 1\,741\,889 - 0,8089667 x_1 - 0,4449632 x_2 - \frac{75\,140\,630\,000}{x_1} - \frac{715\,718\,200\,000}{x_2} - \frac{36\,550\,920\,000}{x_3}, \quad R^2 = 0,999, \quad \text{скорректированный } R^2 = 0,995;$$

— регрессия для фундаментальных исследований (рис. 39):

$$y_1 = 25\,140,5 - 0,04 x_3, \quad R^2 = 0,992, \quad \text{скорректированный } R^2 = 0,985;$$

— регрессия для прикладных исследований (рис. 40):

$$y_2 = 5\,310,287 + 0,003 x_3, \quad R^2 = 0,41, \quad \text{скорректированный } R^2 = 0,292;$$

— регрессия для разработок (рис. 41):

$$y_3 = -814\,037 + x_2, \quad R^2 = 0,9999, \quad \text{скорректированный } R^2 = 0,9996.$$

Таблица 11

## Исходные данные о Нижегородской области (млн руб.)

Год	Инвестиции в основной капитал $x_1$	Валовой региональный продукт $x_2$	Кредиторская задолженность организаций $x_3$	Внутренние текущие затраты на НИР по видам работ			
				Всего $y$	Фундаментальные исследования $y_1$	Прикладные исследования $y_2$	Разработки $y_3$
2010	192 072,4	652 805,9	313 700	26 992,8	1 224,7	4 211,6	21 556,4
2015	235 066,7	1 104 643,2	623 100	56 870,6	1 912,0	5 222,2	49 736,4
2016	232 010,4	1 160 782,3	836 700	66 317,1	1 901,6	6 592,4	57 823,2
2017	245 268	1 261 939,4	869 200	64 278,4	2 026,0	6 620,8	55 631,5
2018	259 392,9	1 367 544	999 200	66 202,2	2 219,5	9 123,8	54 858,9
2019	295 252,2		1 249 100	76 896,2	4 738,0	9 506,0	62 652,2
2020	383 102,1		1 425 600	68 750,3	5 220,1	8 560,3	54 969,9

Таблица 12

## Годовые темпы инфляции (%)

2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020
8,78	6,1	6,58	6,45	11,36	12,91	5,38	2,52	4,27	3,05	4,91

Исходные данные о Нижегородской области в ценах 2020 года (млн руб.)

Год	Инвестиции в основной капитал	Валовой региональный продукт	Кредиторская задолженность организаций	Внутренние текущие затраты на НИР по видам работ			
				Всего	Фундаментальные исследования	Прикладные исследования	Разработки
	$x_1$	$x_2$	$x_3$				
2010	354 041,7	1 203 298,9	578 234,4	49 755,1	2 257,5	7 763,1	39 734,3
2015	286 274,2	1 345 281,2	758 837,5	69 259,4	2 328,5	6 359,8	60 571,1
2016	268 126,9	1 341 478,2	966 946,9	76 640,5	2 197,6	7 618,6	66 824,4
2017	276 480,9	1 422 534,3	979 814,8	72 458,5	2 283,8	7 463,4	62 711,2
2018	280 429	1 478 448,5	1 080 232,7	71 571	2 399,5	9 863,7	59 307,8
2019	309 749,1	1 462 385,4	1 310 430,8	80 671,8	4 970,6	9 972,7	65 728,4
2020	383 102,1	1 474 349,6	1 425 600	68 750,3	5 220,1	8 560,3	54 969,9

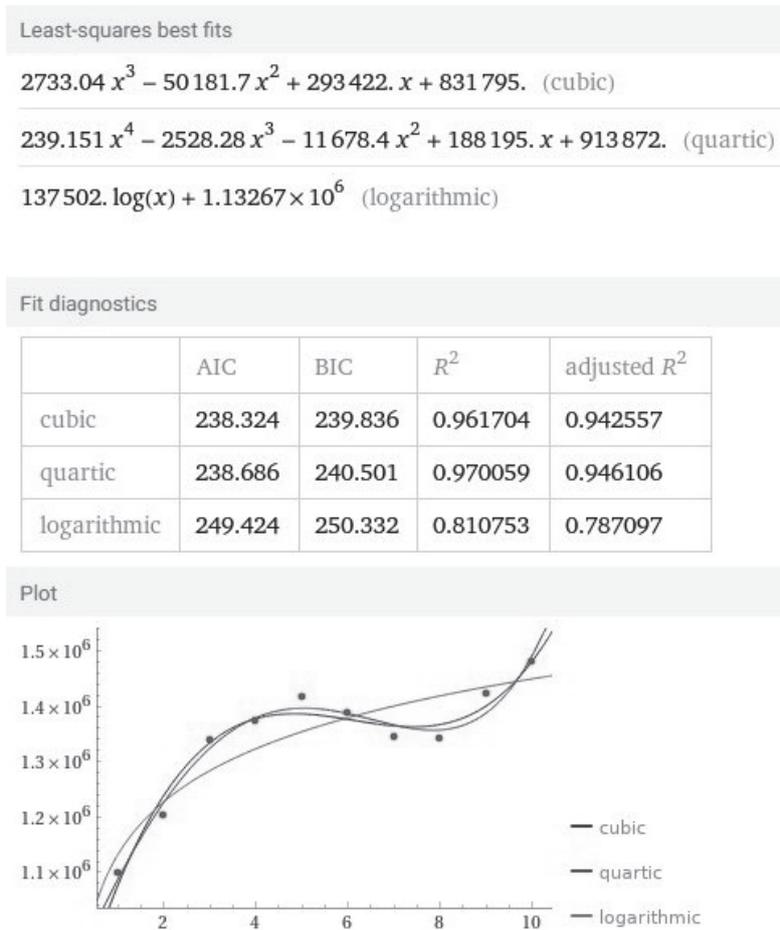


Рис. 37. Графики трех лучших прогнозных функций ВРП Нижегородской области в ценах 2020 года (млн руб.)

**Этап 4 — оптимизация регрессий на заданных интервалах методами GA, SA и PS.** Данная глобальная оптимизация проведена в пакете Matlab. Для этого применялись генетический алгоритм (GA), имитационный отжиг (SA) и поиск по шаблону (PS). Для уточнения результатов методов GA и SA результаты оптимизации целевых функций дополнялись гибридными функциями поиска по шаблону (PS) и метода внутренней точки (fmincon). При этом все целевые функции исследовались на сегментах фактических значений параметров  $x_1$ ,  $x_2$ ,  $x_3$  за исследуемый период согласно данным табл. 13, т.е.  $x_1 \in [268126,9; 383102,1]$ ,  $x_2 \in [1203298,9; 1478448,5]$ ,  $x_3 \in [578234,4; 1425600]$ . Результаты оптимизации для всех затрат на НИР, фундаментальных исследований, прикладных исследований и разработок представлены в табл. 14–17.

Regression Summary for Dependent Variable: **y** (Cross.sta)  
R= ,99957302 R<sup>2</sup>= ,99914621 Adjusted R<sup>2</sup>= ,99487728  
F(5,1)=234,05 p<,04958 Std.Error of estimate: 702,70

N=7	b*	Std.Err. of b*	b	Std.Err. of b	t(1)	p-value
<b>Intercept</b>			1,741889E+06	2,176480E+05	8,0032	0,079135
1/V3	-1,31691	0,102641	-3,655092E+10	2,848815E+09	-12,8302	0,049519
<b>x_1</b>	-3,61954	0,406411	-8,089667E-01	9,083286E-02	-8,9061	0,071183
<b>x_2</b>	-4,54900	0,720896	-4,449632E-01	7,051478E-02	-6,3102	0,100055
1/V1	-3,27668	0,414248	-7,514063E+10	9,499501E+09	-7,9100	0,080059
1/V2	-4,07007	0,757026	-7,157182E+11	1,331222E+11	-5,3764	0,117072

Рис. 38. Регрессия для всех затрат на НИР

Regression Summary for Dependent Variable: **y\_1** (Cross.sta)  
R= ,99614314 R<sup>2</sup>= ,99230115 Adjusted R<sup>2</sup>= ,98460231  
F(3,3)=128,89 p<,00114 Std.Error of estimate: 170,06

N=7	b*	Std.Err. of b*	b	Std.Err. of b	t(3)	p-value
<b>Intercept</b>			25140,50	3987,287	6,30516	0,008061
V3**2	10,47812	1,515373	0,00	0,000	6,91455	0,006200
<b>x_3</b>	-9,32000	1,453882	-0,04	0,007	-6,41042	0,007692
V1**2	-0,95417	0,207388	-0,00	0,000	-4,60090	0,019302

Рис. 39. Регрессия для фундаментальных исследований

Таблица 14

**Результаты глобальной оптимизации регрессии для всех затрат на НИР  
(млн руб.)**

Алгоритм	Инвестиции в основной капитал	Валовой региональный продукт	Кредиторская задолженность организаций	Всего затраты на НИР
	$x_1$	$x_2$	$x_3$	$y$
GA	383 039,2	1 473 402,4	582 875,9	31 776,3
GA + fmincon	383 102,1	1 478 448,5	578 234,4	30 666,8
GA + PS	383 102,1	1 478 448,5	578 234,4	30 666,8
SA	363 744,5	1 203 308,3	578 253,4	47 626,6
SA + fmincon	383 102,1	1 203 298,9	578 234,4	42 402,3
SA + PS	383 101,9	1 478 448,1	578 235,1	30 667
PS	383 102,1	1 478 448,5	578 234,4	30 666,8

Regression Summary for Dependent Variable: **y\_2** (Cross.sta)  
R= ,64059923 R<sup>2</sup>= ,41036737 Adjusted R<sup>2</sup>= ,29244084  
F(1,5)=3,4799 p<,12112 Std.Error of estimate: 1112,3

	b*	Std.Err. of b*	b	Std.Err. of b	t(5)	p-value
N=7						
<b>Intercept</b>			5310,287	1620,024	3,277906	0,022005
<b>x_3</b>	0,640599	0,343404	0,003	0,002	1,865437	0,121122

Рис. 40. Регрессия для прикладных исследований

Regression Summary for Dependent Variable: **y\_3** (Cross.sta)  
R= ,99996781 R<sup>2</sup>= ,99993563 Adjusted R<sup>2</sup>= ,99961377  
F(5, 1)=3106,8 p<,01362 Std.Error of estimate: 180,98

	b*	Std.Err. of b*	b	Std.Err. of b	t(1)	p-value
N=7						
<b>Intercept</b>			-814037	32060,55	-25,3906	0,025060
<b>x_1</b>	1,7259	0,234579	0	0,05	7,3574	0,086001
V3**2	0,8865	0,024724	0	0,00	35,8565	0,017750
V2**2	-13,7069	0,420469	-0	0,00	-32,5991	0,019523
<b>x_2</b>	13,5392	0,429830	1	0,04	31,4989	0,020204
V1**2	-2,4474	0,229255	-0	0,00	-10,6754	0,059461

Рис. 41. Регрессия для разработок

Таблица 15

**Результаты оптимизации регрессии для фундаментальных исследований (млн руб.)**

Алгоритм	Инвестиции в основной капитал	Валовой региональный продукт	Кредиторская задолженность организаций	Фундаментальные исследования
	$x_1$	$x_2$	$x_3$	$y_1$
Аналитически	—	—	628 512,5	0

Таблица 16

**Результаты оптимизации регрессии для прикладных исследований (млн руб.)**

Алгоритм	Инвестиции в основной капитал	Валовой региональный продукт	Кредиторская задолженность организаций	Прикладные исследования
	$x_1$	$x_2$	$x_3$	$y_1$
Аналитически	—	—	0	5 310,3

Таблица 17

## Результаты оптимизации регрессии для разработок (млн руб.)

Алгоритм	Инвестиции в основной капитал	Валовой региональный продукт	Кредиторская задолженность организаций	Разработки
	$x_1$	$x_2$	$x_3$	$y_1$
Аналитически	—	814 037	—	0

Как видно из табл. 14, наиболее совершенным для решения рассматриваемой задачи является алгоритм поиска по шаблону (PS). Кроме того, добавление данного алгоритма в качестве гибридной функции для генетического алгоритма (GA) или имитационного отжига (SA) позволяет достигнуть достаточно качественного решения проблемы оптимизации. Напротив, добавление метода внутренней точки (fmincon) в качестве гибридной функции далеко не всегда значительно повышает качество глобальной оптимизации.

Сравнивая теперь оптимальное (минимальное) значение соответствующих затрат на НИР с их фактическим минимальным значением за исследуемый период, получаем следующие выводы.

Для всех внутренних текущих затрат на НИР — на основе результатов табл. 14:

1. Алгоритмы глобальной оптимизации позволяют спланировать минимум всех затрат на НИР (30 666,8 млн руб.), который меньше минимального значения, наблюдавшегося в исследуемый период (49 755,1 млн руб.).

2. Минимума всех затрат на НИР возможно достичь при максимальных наблюдавшихся инвестициях в основной капитал (383 102,1 млн руб.), максимальном ВРП (1 478 448,5 млн руб.) и минимальной кредиторской задолженности организаций (578 234,4 млн руб.). Это означает, что инвестиции и объем ВРП нужно увеличивать, а задолженность организаций снижать.

Для фундаментальных исследований — на основе вида регрессии и результатов табл. 15:

1. Объем затрат на фундаментальные исследования зависит лишь от кредиторской задолженности организаций.

2. Уменьшение данной задолженности ниже 628 512,5 млн руб. требует затрат на фундаментальные исследования.

3. Увеличение задолженности выше 628 512,5 млн руб. нецелесообразно, т. к. приводит к оттоку необходимых средств на фундаментальные исследования.

Для прикладных исследований — на основе вида регрессии и результатов табл. 16:

1. Объем затрат на прикладные исследования зависит лишь от кредиторской задолженности организаций.

2. Минимальное значение данных затрат 70 045 млн руб. достигается при минимальном фактическом значении кредиторской задолженности организаций 578 234,4 млн руб.

3. Увеличение данной задолженности требует повышения затрат на прикладные исследования.

Для разработок — на основе вида регрессии и результатов табл. 17:

1. Объем затрат на разработки зависит лишь от ВРП.
2. Увеличение объема ВРП выше 814 037 млн руб. требует затрат на разработки.
3. Уменьшение объема ВРП ниже 814 037 млн руб. нецелесообразно, т. к. приводит к оттоку необходимых средств на разработки.

В заключение обозначим наиболее важные выводы.

1. Региональная модель планирования программ инновационного развития подразумевает оптимизацию внутренних текущих затрат на НИР промышленного региона в зависимости от его инвестиционного планирования по данным о динамике инвестиций в основной капитал в регионе, производственного планирования согласно данным о динамике ВРП и финансового планирования по данным о динамике кредиторской задолженности организаций.

2. Под оптимизацией затрат на НИР мы понимаем возможности их снижения до того оптимального значения, которое будет достижимо при одновременном инвестиционном, производственном и финансовом планировании региона, позволяющем определить наиболее целесообразные пропорции перечисленных трех факторов планирования в денежном выражении.

3. Представленная региональная модель должна быть достаточно детальной, для чего исследуются несколько целевых функций внутренних текущих затрат на НИР промышленного региона: всего затраты на НИР, а также три их компоненты — фундаментальные исследования, прикладные исследования и разработки. Это позволит в итоге сделать более обоснованные выводы о том, как следует развивать промышленному региону свои внутренние текущие затраты на НИР в зависимости от планирования инвестиций в основной капитал, ВРП и кредиторской задолженности организаций.

4. Наиболее совершенным для решения рассматриваемой задачи является алгоритм поиска по шаблону. Кроме того, добавление данного алгоритма в качестве гибридной функции для генетического алгоритма или имитационного отжига позволяет достигнуть достаточно качественного решения проблемы оптимизации. Напротив, добавление метода внутренней точки в качестве гибридной функции далеко не всегда значительно повышает качество глобальной оптимизации.

5. В Нижегородской области для минимизации всех внутренних текущих затрат на НИР следует увеличивать инвестиции в основной капитал и объем ВРП, а также снижать размер кредиторской задолженности организаций.

6. При этом для фундаментальных исследований существует предел задолженности организаций, превышение которого нецелесообразно, т. к. это приводит к оттоку необходимых средств на фундаментальные исследования.

7. Увеличение данной задолженности приводит также к повышению затрат на прикладные исследования.

8. Для разработок существует нижний предел объема ВРП, ниже которого опускаться нецелесообразно, т. к. это приводит к оттоку необходимых средств на раз-

работки. Поскольку разработки составляют основную часть всех затрат на НИР, управление ВРП, т. е. производством составляет основную часть успешного финансирования всех затрат на НИР в рассматриваемом промышленном регионе.

Представленная модель позволит государственным структурам и их экспертам принимать более качественные решения в отношении планирования инновационного развития промышленных регионов страны.

#### **4.2. Оптимизация перекрестного финансирования затрат на НИР регионов: генетический алгоритм, имитационный отжиг, поиск по шаблону**

В настоящее время затраты на научно-исследовательские работы (НИР) являются важной составляющей расходов государственного бюджета. Финансирование НИР позволяет государству решать задачи глобальных технологических вызовов, включая проблемы реализации политики импортозамещения.

Однако не до конца решенными остаются вопросы оптимального объема финансирования затрат на НИР в пределах страны и ее регионов, имеющих соответствующий научный потенциал. Под научным потенциалом мы понимаем как научно-исследовательские институты и ВУЗы, так и ученых, работающих в данных институтах.

Решать подобного рода задачи представляется невозможным в отрыве от конкретных технологических и экономических результатов НИР регионов. Планирование данных результатов, а также необходимых для их достижения ресурсов является актуальной задачей оптимизации затрат на НИР. В этой связи мы выделяем три вида планирования: инвестиционное, производственное и финансовое. При этом все три процесса мы рассматриваем одновременно. Это позволит охватить широкий круг задач оптимизации затрат на НИР в регионах и способствовать их инновационному развитию.

Подобные вопросы достаточно подробно исследовались многими учеными применительно к планированию развития бизнеса компаний. Так, например, Л. Крушвиц и Д. Лоренц [102] изучали процессы одновременного инвестиционного и финансового планирования, а также одновременного инвестиционного и производственного планирования. М. А. Лимитовский [12] дополнил их результаты учетом системных финансовых эффектов инвестиционных программ. Под такими эффектами он понимал кросс-финансирование, кросс-субсидирование, кросс-холдинг и кросс-хеджирование.

И хотя результаты, полученные в том числе этими учеными, представляют реальный практический интерес для реализации успешного развития коммерческих фирм, мы стремимся использовать их опыт для оптимизации и планирования национальных и региональных затрат на НИР. В этой области также есть полезные результаты, полученные различными исследователями.

С. П. Дэхмер и др. [55], основываясь на последних изменениях в области расходов на науку в таких странах, как Китай, Корея, Индия и Бразилия, установили,

что мировая научная деятельность переживает крупные перестановки. Но не ясно, ограничивается ли эта новая упорядоченность краткосрочными высокими расходами на НИР или же эти изменения происходят в долгосрочной перспективе. Новые, более всеобъемлющие оценки расходов на исследования и разработки (НИОКР), представленные и обсуждаемые в работе ученых, свидетельствуют о возможной нерегулярной перестановке глобальной структуры НИОКР. Эти изменения могут иметь глубокие внутренние и международные последствия для экономического развития в среднесрочной и долгосрочной перспективе. Используя эволюционирующую структуру прошлых расходов на НИОКР для перспективного прогнозирования и при отсутствии заметных изменений в научной политике и приоритетах расходов, авторы прогнозируют продолжение существенного сдвига в географии НИОКР в сторону стран Азии, а также продолжающийся большой и во многих отношениях растущий разрыв между научными имущими и неимущими в мире.

Д. Киселякова и др. [96] рассматривают отношения между расходами на НИОКР и развитием глобальной конкурентоспособности в Словакии, а также в государствах — членах Европейского союза из Центральной и Восточной Европы (СЕЕ EU (11)). Для оценки конкурентоспособности стран СЕЕ EU (11) ученые использовали Глобальный индекс конкурентоспособности (GCI), обработанный Всемирным экономическим форумом (ВЭФ). Используя корреляционный анализ, авторы сосредоточились на обнаружении взаимосвязей между ростом расходов на НИОКР на душу населения с использованием пяти переменных GERD и значениями общего показателя GCI, а также его тремя основными подиндексами в случае стран СЕЕ EU (11) за период 2007–2016 гг. При этом ученые установили, что увеличение расходов на НИОКР может в значительной степени способствовать повышению уровня конкурентоспособности стран СЕЕ EU (11). Все проведенные анализы подтвердили важность сосредоточения внимания на увеличении расходов на НИОКР, особенно в секторе высшего образования, поскольку это оказывает значительное влияние на повышение глобальной конкурентоспособности стран СЕЕ EU (11) в случае ряда субиндексов GCI.

Здесь особую важность приобретает вопрос национальных и региональных затрат на НИР. О. А. Феоктистова [24] при планировании НИОКР и их финансировании выделяет: использование проектного подхода, выбор в качестве одного из ключевых критериев ожидаемых результатов от реализации научно-исследовательского проекта, выбор в качестве ключевого критерия уже достигнутых результатов научно-исследовательского проекта его потенциальным исполнителем.

В. Ф. Гапоненко [4] рассмотрел ситуации, в которых потенциально возможно снизить фактические затраты на выполнение НИР: выполнение НИР, аналогичной работам, выполненным ранее тем же исполнителем — организацией науки или исследователем; выполнение НИР, близких к выполненным ранее другими исполнителями — организациями науки; выполнение (возможно одновременное) схожих НИР для различных заказчиков; использование ранее полученных результатов исследований, ранее собранных установок в новом исследовании при отсутствии аналогии между темами старых и новых исследований; включение в ТЗ задач, не соответ-

ствующих цели НИР, результаты которых могут быть использованы, например, в другой НИР или публикации, патенте.

Тем не менее, в данных работах, на наш взгляд, недостаточно проработано решение проблемы выбора обоснованных количественных ориентиров для планирования затрат на НИР регионов страны. Также открытым остается вопрос планирования перераспределения затрат на НИР между регионами. Напротив, в работе С. Н. Яшина и др. [163] в результате проведенного форсайта эволюции инновационной системы федерального округа, основанного на использовании многоцелевого генетического алгоритма, было получено, что в целях повышения синергетического эффекта федерального округа планируется перенаправить инвестиционные ресурсы и затраты на НИР в те регионы, где ресурсов не хватает. Это позволит в итоге увеличить среднедушевые доходы населения в регионах федерального округа, что приведет к приросту населения в них.

Это подводит нас к необходимости решения задачи оптимизации региональных затрат на НИР и, прежде всего, к выбору для этой цели наиболее рациональных методов. Так, М. Ильдирар, М. Озмен и Э. Искан [83] предоставили новые оценки влияния расходов на НИОКР на экономический рост. С другой стороны, они установили, что есть различные виды расходов на НИОКР, и каждый из них имеет различное значение для экономического роста. Таким образом, авторы рассмотрели влияние различных видов расходов на НИОКР на экономический рост в отдельных странах ОЭСР с использованием данных, относящихся к периоду 2003–2014 гг. Учеными было установлено, что все расходы на НИОКР оказывают положительное и значительное влияние на экономический рост в отдельных странах ОЭСР, однако их значение различно. Поэтому директивные органы должны разрабатывать политику стимулирования НИОКР в зависимости от особенностей стран. Соответственно страны должны выделять больше ресурсов на различные виды расходов на НИОКР для достижения устойчивых темпов роста.

Н. Салими и Дж. Резаи [140] установили, что придание одинакового уровня важности различным показателям НИОКР, что является общим подходом в существующих исследованиях, может чрезмерно упростить процесс измерения НИОКР и привести к неправильному толкованию эффективности и, как следствие, ошибочности выбранных стратегий НИОКР. Цель авторского исследования состояла в том, чтобы измерить исполнение НИОКР с учетом различных уровней важности мер НИОКР с использованием метода принятия решений, применяя несколько критериев, который называется “лучшим наихудшим методом” (BWM) для определения весов важности мер НИОКР и измерения исполнения НИОКР 50 высокотехнологичных компаний в Нидерландах на основе данных, собранных в опрос среди этих компаний и экспертов в области НИОКР. Результаты показывают, что присвоение различных весов различным показателям НИОКР (в отличие от простых средних показателей) приводит к различному ранжированию фирм и позволяет руководителям НИОКР формулировать более эффективные стратегии повышения эффективности НИОКР своей фирмы путем применения знаний о важности различных показателей НИОКР.

А. Бина и др. [41] предложили всеобъемлющие критерии для отбора проектов НИОКР и инноваций в условиях неопределенности и с учетом реальных ограничений, применимых к бразильскому сектору электроэнергетики, с использованием комбинации целочисленных формулировок программирования и метода, основанного на технологии *PROMETHEE*. Цель работы авторов состояла в том, чтобы внести свой вклад в эту область, предлагая подход, подходящий для решения проблем данного сектора, но также применимый к другим ситуациям, связанным с инвестициями в НИОКР и инновации в аналогичных условиях. Ученые сравнили предложенный ими способ с аналогичными подходами, найденными в литературе, такими как *PROMETHEE II* и *V*. Авторы выявили наилучшие результаты предлагаемого приложения в решении регулятивных проблем сектора электроэнергетики, которые подчеркивают выполнение фирмами обязательств по НИОКР и расходам на инновации. Таким образом, хотя выбор проектов НИОКР и инноваций не является типичным примером оптимизации, при определенных региональных, секторальных или организационных ограничениях это может быть лучшим решением.

М. Ц. Хуанг, М. Х. Леу и Й. Иваки [80], принимая во внимание парадокс побочного эффекта НИОКР, избавленного от глобальной цепочки поставок, использовали расчетную модель общего равновесия с базой данных *GTAP v10* для анализа влияния государственных инвестиций Японии в НИОКР на ключевые секторы глобальной цепочки поставок, а именно, химическое и фармацевтическое, электронное оборудование, машины и транспортное оборудование для проверки его выпуска, внешней торговли и благосостояния. Параметры производительности, инициируемые государственными инвестициями в НИОКР, откалиброваны из Интеллектуальной системы содействия разработке политики *SciREX* — экономического симулятора (*SPIAS-e*). Результаты моделирования показывают значительное увеличение производства и экспорта Японии для химического и фармацевтического, электронного оборудования и транспортного оборудования. Рост ВВП был повышен на 0,6% при существенном улучшении благосостояния на 78 000 млн долл. США, в то время как для других стран, таких как Малайзия и Тайвань, — на 0,4–0,6%. Напротив, экономические показатели Китая показывают негативное влияние, подразумевающее структурные изменения в составе производственной сети. Примечательно, что в азиатском регионе наблюдается более высокая экономическая интеграция Океании благодаря ее динамичному производству и торговле. В исследовании содержится всеобъемлющий глобальный анализ производственных сетей и анализ для оценки побочных эффектов инвестиций в НИОКР.

А. Садогла, М. Насир и З. В. Гим [139] основной целью оптимизации поставили улучшение общей устойчивости, включая экологическую, социальную, экономическую устойчивость и устойчивость энергетических ресурсов, посредством реализации соответствующих целевых функций. Вклад ученых представляет собой значительный обзор используемых методологий оптимизации устойчивости и устойчивого развития, включая устойчивые энергетику, строительство и окружающую среду. Поскольку оптимизация энергетики является одной из основных задач устойчивого развития, оно изучается с энергетической точки зрения. Также были представлены

концепция, определения и элементы устойчивости и оптимизации, а также проведен обзор метаэвристических алгоритмов оптимизации, использованных в недавно опубликованных статьях, касающихся устойчивости и устойчивого развития.

В. Хик [82] целью своего исследования поставил определение оптимальной структуры затрат для инноваций и ее влияния на выручку от продаж. При этом внимание сосредоточено на использовании элементов экономико-математического моделирования. Научная новизна заключается в разработке модели, которая обосновывает взаимосвязь между изученными показателями затрат на инновации, позволит прогнозировать размер дохода от продаж и обеспечит достижение его оптимального значения. Установлено, что предлагаемая множественная линейная регрессия достаточно четко описывает исходные данные и может использоваться для прогнозирования. Практическая значимость полученных результатов заключается в прикладной направленности подходов, использование которых улучшает управление затратами на инновации и повышает уровень достоверности экономической информации промышленных предприятий Украины и в результате улучшит экологическую обстановку. В рамках этого исследования проведена оценка воздействия экономики инноваций на окружающую среду, в результате чего будет сохранен потенциал природных ресурсов в целях достижения устойчивого экономического развития.

В настоящем исследовании мы будем применять метаэвристические алгоритмы для оптимизации затрат на НИР в регионах федерального округа. Это позволит в дальнейшем спланировать перекрестное финансирование НИР в рамках одного округа. Среди метаэвристических алгоритмов будем использовать три из них, обладающих существенными преимуществами:

- 1) генетический алгоритм (Genetic Algorithm, GA);
- 2) имитационный отжиг (Simulated Annealing, SA);
- 3) поиск по шаблону (Pattern Search, PS).

Используя данные метаэвристические алгоритмы, построим модель оптимизации и планирования перекрестного финансирования затрат на НИР в федеральном округе (рис. 42). Она включает в себя 5 этапов, которые опишем подробнее.

**Этап 1 — сбор и подготовка статистических данных о динамике инвестиций, ВРП и задолженности юридических лиц регионов.** На данном этапе собираются и корректируются на инфляцию данные о динамике инвестиций в основной капитал ( $x_1$ ), валовом региональном продукте (ВРП) ( $x_2$ ) и задолженности юридических лиц по кредитам ( $x_3$ ) регионов федерального округа за большой срок, охватывающий 10 лет. Чтобы собрать эти данные, используем сайт Федеральной службы государственной статистики ([www.gks.ru](http://www.gks.ru)). Таким образом, параметр  $x_1$  характеризует инвестиционное планирование,  $x_2$  — производственное планирование, а  $x_3$  — финансовое планирование округа.

**Этап 2 — сбор и подготовка статистических данных о динамике затрат на НИР регионов по видам работ.** Здесь собирается и корректируется на инфляцию статистическая информация о внутренних текущих затратах на НИР всего ( $y$ ), а также по видам работ, которые подразделяются на фундаментальные

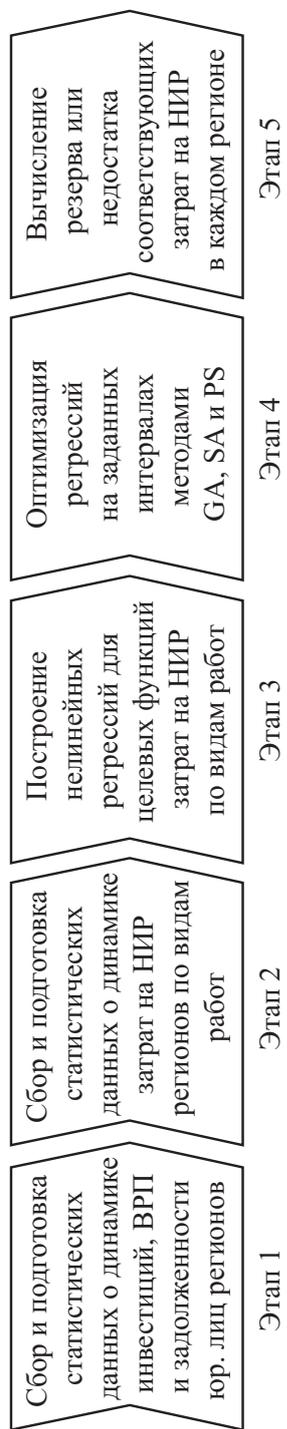


Рис. 42. Модель оптимизации и планирования перекрестного финансирования затрат на НИР в федеральном округе

исследования ( $y_1$ ), прикладные исследования ( $y_2$ ) и разработки ( $y_3$ ). Эти данные собираются за тот же срок, что и на предыдущем этапе.

**Этап 3 — построение нелинейных регрессий для целевых функций затрат на НИР по видам работ.** Нелинейные регрессии затрат на НИР вида  $y = f(x_1, x_2, x_3)$ , более реально отражающие экономические процессы по сравнению с линейными, будут множественными. Чтобы их получить, используем программу *Statistica*.

**Этап 4 — оптимизация регрессий на заданных интервалах методами GA, SA и PS.** Глобальную оптимизацию целевых функций регрессий будем проводить в программе *Matlab*, используя для этого три метаэвристических алгоритма: генетический алгоритм (GA), имитационный отжиг (SA) и поиск по шаблону (PS). Для уточнения результатов методов GA и SA результаты оптимизации целевых функций будем дополнять гибридными функциями поиска по шаблону и метода внутренней точки [2]. То есть сначала применяются алгоритмы GA или SA, а затем их результаты используются в качестве начальной точки для последующей оптимизации целевой функции. Это позволит получить более качественные решения в каждом конкретном случае оптимизации затрат на НИР.

При этом в каждом конкретном случае будем искать глобальный максимум затрат на НИР в федеральном округе, т. е. вычисляем сколько максимально средств можно выделить на НИР и от каких значений параметров  $x_1$ ,  $x_2$ ,  $x_3$  этот максимум зависит. Затем полученные регрессии для каждого вида НИР оптимизируем на сегментах параметров  $x_1$ ,  $x_2$ ,  $x_3$ , характерных для каждого исследуемого региона федерального округа.

**Этап 5 — вычисление резерва или недостатка соответствующих затрат на НИР в каждом регионе.** На данном этапе сравниваем полученный оптимум затрат на НИР для каждого региона округа с его фактическим максимальным значением за исследуемый период и вычисляем резерв или недостаток соответствующих затрат на НИР в каждом регионе как разницу между фактическим и оптимальным значением. Это позволит более детально, т. е. по регионам, спланировать возможности перекрестного финансирования НИР в рамках одного округа.

**Пример 6.** Покажем, как работает данная модель на примере Приволжского федерального округа (ПФО). При этом будем рассматривать в ПФО только те регионы (области или республики), в которых расположены пилотные инновационные территориальные кластеры из перечня, утвержденного Правительством РФ. Именно в таких промышленных регионах проводятся основные НИР федерального округа.

**Этап 1 — сбор и подготовка статистических данных о динамике инвестиций, ВРП и задолженности юридических лиц регионов.** На данном этапе необходимые исходные данные собираются с сайта Федеральной службы государственной статистики ([www.gks.ru](http://www.gks.ru)) и корректируются на инфляцию. Они представлены в ценах 2020 г. в колонках  $x_1$ ,  $x_2$  и  $x_3$  табл. 18. Поскольку на указанном сайте есть данные о внутренних текущих затратах на НИР лишь за период с 2015

## Исходные данные о Приволжском федеральном округе в ценах 2020 года (млн руб.)

Год	Инвестиции в основной капитал	Валовой региональный продукт	Задолженность юридических лиц по кредитам	Внутренние текущие затраты на НИР по видам работ			
				Всего	Фундаментальные исследования	Прикладные исследования	Разработки
	<i>x1</i>	<i>x2</i>	<i>x3</i>	<i>y</i>	<i>y1</i>	<i>y2</i>	<i>y3</i>
1. Нижегородская область							
2010	354 041	1 203 299	335 116	49 755,1	2 257,5	7 763,1	39 734,3
2015	286 275	1 345 281	438 699	69 259,4	2 328,5	6 359,8	60 571,1
2016	268 126	1 341 478	392 014	76 640,5	2 197,6	7 618,6	<b>66 824,4</b>
2017	276 481	1 422 534	356 981	72 458,5	2 283,8	7 463,4	62 711,2
2018	280 429	1 478 448	361 167	71 571	2 399,5	9 863,7	59 307,8
2019	309 749	<i>1 462 590</i>	385 278	<b>80 671,8</b>	4 970,6	<b>9 972,7</b>	65 728,4
2020	383 102	<i>1 474 561</i>	361 554	68 750,3	<b>5 220,1</b>	8 560,3	54 969,9
2. Республика Мордовия							
2010	75 165	<b>194 177</b>	80 800	884	156,1	267,3	460,6
2015	64 242	219 641	114 539	996,8	147,6	293,9	555,3
2016	60 822	233 116	97 935	896,2	141,2	173,2	581,9
2017	65 984	242 754	112 000	885,7	126,5	212,9	546,4
2018	56 551	245 720	98 970	1 049,4	168,1	470	411,4
2019	54 751	<i>240 875</i>	102 512	1 009,9	125,3	438	446,6
2020	<b>48 969</b>	<i>238 909</i>	88 007	1 081,5	107,1	433,5	540,9

Год	Инвестиции в основной капитал	Валовой региональный продукт	Задолженность юридических лиц по кредитам	Внутренние текущие затраты на НИР по видам работ			
				Всего	Фундаментальные исследования	Прикладные исследования	Разработки
	<i>x</i> <sub>1</sub>	<i>x</i> <sub>2</sub>	<i>x</i> <sub>3</sub>	<i>y</i>	<i>y</i> <sub>1</sub>	<i>y</i> <sub>2</sub>	<i>y</i> <sub>3</sub>
3. Ульяновская область							
2010	88 464	328 536	75 419	9 242,4	175,8	1 451,9	7 614,6
2015	96 771	370 808	96 010	9 672	228	5 190	4 254,2
2016	81 562	375 920	99 058	9 114,9	262,8	4 511,5	4 340,6
2017	94 796	375 951	71 717	12 565,8	230,2	2 038,7	10 296,8
2018	89 649	376 064	84 054	12 206,9	302,8	1 267,4	10 636,7
2019	75 555	339 226	78 955	9 659,3	218,5	1 791,1	7 649,6
2020	61 181	312 577	85 313	10 288,1	265,6	2 607,6	7 414,9
4. Самарская область							
2010	284 644	1 282 274	390 241	22 679,8	665,6	1 249,4	20 764,6
2015	368 865	1 540 461	423 126	19 921,2	681,9	1 616,6	17 622,8
2016	296 748	1 468 075	449 779	13 454,2	641,7	1 220,8	11 591,5
2017	292 574	1 520 781	453 792	15 631,9	844,7	1 282,3	13 504,9
2018	286 479	1 633 018	398 565	14 861,2	649	1 197,6	13 014,5
2019	301 737	1 632 825	319 233	19 929,2	614,4	1 020,9	18 294
2020	202 462	1 648 019	298 558	15 492,5	761	713,0	14 018,6

Год	Инвестиции в основной капитал	Валовой региональный продукт	Задолженность юридических лиц по кредитам	Внутренние текущие затраты на НИР по видам работ			
				Всего	Фундаментальные исследования	Прикладные исследования	Разработки
				<i>y</i> <sub>1</sub>	<i>y</i> <sub>2</sub>	<i>y</i> <sub>3</sub>	
5. Пермский край							
2010	257 417	1 148 574	276 981	12 308,4	2 383,9	1 325,1	8 599,4
2015	275 493	1 295 517	312 592	14 528,9	982,9	1 873,9	11 671,9
2016	276 655	1 266 576	221 842	14 107	1 027,2	1 568,8	11 511
2017	276 337	1 343 064	215 175	15 007,6	843,4	1 745,3	12 418,8
2018	263 369	1 425 398	243 162	13 788,9	1 032,6	1 428,7	11 327,6
2019	305 392	1 456 557	274 316	15 591	1 090,2	1 716,1	12 784,6
2020	290 460	1 467 320	306 550	15 636,3	1 148,2	1 797,1	12 691
6. Удмуртская Республика							
2010	94 280	506 122	121 689	821,4	451,2	85,2	285
2015	99 676	630 842	114 739	1 297,2	380,9	163,9	752,4
2016	100 692	614 648	119 263	1 263	337,2	155,7	770,1
2017	94 358	622 590	89 959	1 986	237,5	458,6	1 289,9
2018	104 844	682 300	89 920	2 481,4	657,3	233,1	1 591,1
2019	105 451	668 360	110 349	2 332,8	731,4	126,8	1 474,5
2020	107 187	675 545	85 536	1 846,9	811,5	123,1	912,2

Год	Инвестиции в основной капитал	Валовой региональный продукт	Задолженность юридических лиц по кредитам	Внутренние текущие затраты на НИР по видам работ			
				Всего	Фундаментальные исследования	Прикладные исследования	Разработки
	<i>x</i> <sub>1</sub>	<i>x</i> <sub>2</sub>	<i>x</i> <sub>3</sub>	<i>y</i>	<i>y</i> <sub>1</sub>	<i>y</i> <sub>2</sub>	<i>y</i> <sub>3</sub>
7. Республика Татарстан							
2010	606 333	1 846 263	540 376	11 366,2	1 526,8	1 864,5	7 974,9
2015	<b>751 565</b>	2 274 027	660 546	13 926,5	2 495,5	1 772,2	9 658,8
2016	735 575	2 234 011	<b>710 836</b>	13 841,8	2 196,6	1 856,1	9 789,2
2017	718 755	2 412 123	699 269	17 574,2	2 626,4	2 249,4	12 698,4
2018	680 801	<b>2 669 465</b>	594 273	18 420,6	2 422,4	2 444,6	13 553,6
2019	672 302	<i>2 522 721</i>	496 504	16 617,8	2 611,1	2 232	11 774,7
2020	<i>655 319</i>	<i>2 549 636</i>	414 215	16 878,6	2 896,6	2 557,3	11 424,7
8. Республика Башкортостан							
2010	283 173	1 772 189	213 167	7 236,3	1 806	1 958,3	3 472
2015	386 986	1 603 409	371 940	9 869,2	1 420,5	996	7 452,7
2016	410 388	1 546 257	334 792	9 960,4	1 193,1	2 229,1	6 538,3
2017	314 046	1 589 666	328 141	9 739,9	1 161,9	2 568,5	6 009,5
2018	289 657	1 809 428	327 419	11 196,7	1 408,7	2 582,6	7 205,5
2019	337 919	<i>1 746 876</i>	328 865	10 490,5	1 361	2 644,6	6 484,9
2020	<i>326 850</i>	<i>1 754 979</i>	323 670	10 527,2	1 417,7	2 483,4	6 626,1

по 2020 г., а также за 2010 г., данные об инвестициях в основной капитал, ВРП и задолженности юридических лиц по кредитам берем за те же годы.

Недостающие данные об инвестициях в основной капитал и ВРП прогнозируем самостоятельно в ценах 2020 г., используя для этого период с 2009 по 2018 г. и Интернет-сервис *WolframAlpha* ([www.wolframalpha.com](http://www.wolframalpha.com)). Результаты прогноза показаны в табл. 18 курсивом.

**Этап 2 — сбор и подготовка статистических данных о динамике затрат на НИР регионов по видам работ.** На этом этапе собираем и корректируем на инфляцию статистическую информацию о внутренних текущих затратах на НИР всего, а также по видам работ: фундаментальные исследования, прикладные исследования и разработки. Эти данные собираются за тот же срок, что и на предыдущем этапе. Они представлены в ценах 2020 г. в колонках  $y$ ,  $y_1$ ,  $y_2$  и  $y_3$  табл. 18.

**Этап 3 — построение нелинейных регрессий для целевых функций затрат на НИР по видам работ.** По данным табл. 18 в программе *Statistica* получены следующие наиболее точные нелинейные регрессии:

— регрессия для всех затрат на НИР (рис. 43 и 44):

$$y = 82\,426,01 + 0,06 x_2 - 8\,303,97 \ln x_3 ,$$

$$R^2 = 0,948, \quad \text{скорректированный } R^2 = 0,938 ;$$

Regression Summary for Dependent Variable: y (Cross_1.sta)						
R= ,97341230 R?= ,94753150 Adjusted R?= ,93799177						
F(2,11)=99,325 p<,00000 Std.Error of estimate: 1240,7						
N=14	b*	Std.Err. of b*	b	Std.Err. of b	t(11)	p-value
Intercept			82426,01	31406,31	2,62450	0,023638
x_2	0,839853	0,077622	0,06	0,01	10,81972	0,000000
LN-V3	-0,240455	0,077622	-8303,97	2680,65	-3,09775	0,010145

Рис. 43. Регрессия для всех затрат на НИР

— регрессия для фундаментальных исследований (рис. 45 и 46) —

$$y_1 = 1\,782 - \frac{57\,170\,107}{x_1} - \frac{73\,870\,171}{x_3} ,$$

$$R^2 = 0,484, \quad \text{скорректированный } R^2 = 0,444 ;$$

— регрессия для прикладных исследований (рис. 47 и 48) —

$$y_2 = -58\,921,7 + 3\,523,1 \ln x_1 + 1\,925,2 \ln x_3 ,$$

$$R^2 = 0,244, \quad \text{скорректированный } R^2 = 0,185 ;$$

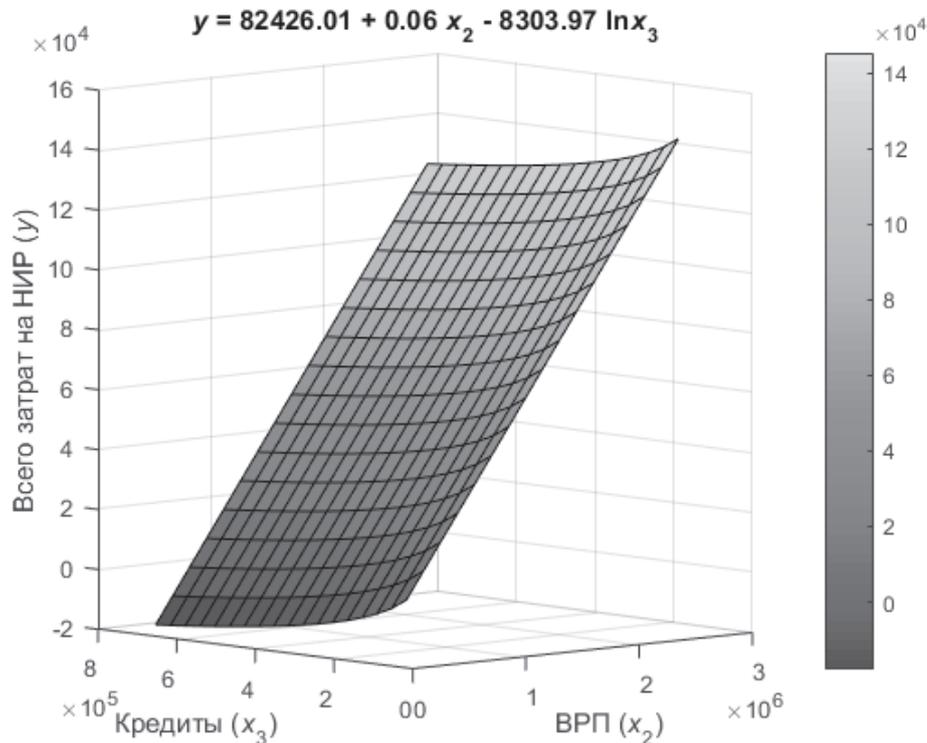


Рис. 44. График регрессии для всех затрат на НИР

— регрессия для разработок (рис. 49) —

$$y_3 = -315\,317,4 - 0,02542966 x_2 - 0,6432493 x_3 - \frac{950\,912\,100}{x_1} + 981,9057\sqrt{x_3} + \frac{9\,314\,139\,000}{x_3}, \quad R^2 = 0,447, \quad \text{скорректированный } R^2 = 0,392.$$

**Этап 4 — оптимизация регрессий на заданных интервалах методами GA, SA и PS.** Глобальная оптимизация целевых функций проводилась в программе *Matlab*. Для этого применялись генетический алгоритм (GA), имитационный отжиг (SA) и поиск по шаблону (PS). Для уточнения результатов методов GA и SA результаты оптимизации дополнялись гибридными функциями поиска по шаблону и метода внутренней точки (*fmincon*). При этом все целевые функции исследовались на сегментах фактических значений параметров  $x_1$ ,  $x_2$ ,  $x_3$  за исследуемый период согласно данным табл. 18, отмеченных в ней жирным шрифтом.

Результаты оптимизации для всех затрат на НИР, фундаментальных исследований, прикладных исследований и разработок в ПФО представлены в соответствующих табл. 19–22. Как видно из таблиц наиболее достоверный результат позволяет получить поиск по шаблону (PS). Добавление данного алгоритма или метода внутренней точки (*fmincon*) в качестве гибридной функции для генетического алгоритма

Таблица 19

Результаты глобальной оптимизации регрессии всех затрат на НИР для ПФО  
(млн руб.)

Алгоритм	Инвестиции в основной капитал	Валовой региональный продукт	Задолженность юридических лиц по кредитам	Всего затраты на НИР	Максимальное фактическое значение
	$x_1$	$x_2$	$x_3$	$y$	$y$
GA	—	2 655 302	84 056	147 583,4	
GA + fmincon	—	2 669 465	71 717	149 751,5	
GA + PS	—	2 669 465	71 717	149 751,5	
SA	—	1 474 311	381 367	64 166,1	80 671,8
SA + fmincon	—	2 669 465	71 717	149 751,5	
SA + PS	—	2 669 465	71 717	149 751,5	
PS	—	2 669 465	71 717	149 751,5	

Таблица 20

Результаты глобальной оптимизации регрессии фундаментальных исследований для ПФО  
(млн руб.)

Алгоритм	Инвестиции в основной капитал	Валовой региональный продукт	Задолженность юридических лиц по кредитам	Фундаментальные исследования	Максимальное фактическое значение
	$x_1$	$x_2$	$x_3$	$y_1$	$y_1$
GA	747345	—	698384	1599,7	
GA + fmincon	751565	—	710836	1602	
GA + PS	751565	—	710836	1602	
SA	389233	—	371116	1436,1	5220,1
SA + fmincon	751565	—	710836	1602	
SA + PS	751565	—	710836	1602	
PS	751565	—	710836	1602	

Таблица 21  
**Результаты глобальной оптимизации регрессии прикладных исследований для ПФО**  
 (млн руб.)

Алгоритм	Инвестиции в основной капитал	Валовой региональный продукт	Задолженность юридических лиц по кредитам	Прикладные исследования	Максимальное фактическое значение
	$x_1$	$x_2$	$x_3$	$y_2$	$y_2$
GA	751 466	—	707 749	14 677,2	
GA + fmincon	751 565	—	710 836	14 686,1	
GA + PS	751 565	—	710 836	14 686,1	
SA	320 881	—	390 409	10 533,9	9 972,7
SA + fmincon	751 565	—	710 836	14 686,1	
SA + PS	751 565	—	710 836	14 686,1	
PS	751 565	—	710 836	14 686,1	

Таблица 22

Результаты глобальной оптимизации регрессии разработок для ПФО (млн руб.)

Алгоритм	Инвестиции в основной капитал	Валовой региональный продукт	Задолженность юридических лиц по кредитам	Разработки	Максимальное фактическое значение
	$x_1$	$x_2$	$x_3$	$y_3$	$y_3$
GA	666 821	194 177	519 251	69 800,7	
GA + fmincon	751 565	194 177	526 041	69 973,4	
GA + PS	751 565	194 177	526 041	69 973,4	
SA	269 086	1 336 735	403 685	34 424,4	66 824,4
SA + fmincon	751 565	194 177	526 041	69 973,4	
SA + PS	751 565	194 177	526 041	69 973,4	
PS	751 565	194 177	526 041	69 973,4	

Regression Summary for Dependent Variable: $y_1$ (Cross_1.sta)						
R= ,69603614 R <sup>2</sup> = ,48446631 Adjusted R <sup>2</sup> = ,44403230						
F(4,51)=11,982 p<,00000 Std.Error of estimate: 837,99						
N=56	b*	Std.Err. of b*	b	Std.Err. of b	t(51)	p-value
Intercept			1782	923	1,93163	0,058971
x_2	-0,257014	0,406340	-0	0	-0,63251	0,529879
1/V3	-0,263385	0,244038	-73870171	68444069	-1,07928	0,285542
x_1	0,470888	0,275054	0	0	1,71198	0,092975
1/V1	-0,270176	0,255550	-57170107	54075330	-1,05723	0,295388

Рис. 45. Регрессия для фундаментальных исследований

ма (GA) или имитационного отжига (SA) также позволяет достигнуть достаточно качественного решения проблемы оптимизации.

Кроме того, почти во всех табл. 19–22 видно, что максимальное фактическое значение всех затрат на НИР существенно ниже максимально возможных всех затрат на НИР при соответствующих значениях параметров  $x_1$ ,  $x_2$ ,  $x_3$ . Это говорит о том, что имеются реальные возможности профинансировать НИР в большем объеме. Однако данный вопрос требует более детального решения. Для этого проведем такую же глобальную оптимизацию всех видов затрат на НИР для каждого региона ПФО в отдельности, применяя для этого те же самые метаэвристические алгоритмы. При этом прежние целевые функции регрессий исследуем для каждого региона на его сегментах фактических значений параметров  $x_1$ ,  $x_2$ ,  $x_3$  за исследуемый период согласно данным табл. 18. Результаты глобальной оптимизации показаны в табл. 23–26.

**Этап 5 — вычисление резерва или недостатка соответствующих затрат на НИР в каждом регионе.** На данном этапе в последних колонках табл. 23–26 вычисляем резерв или недостаток соответствующих затрат на НИР в каждом регионе как разницу между фактическим и оптимальным значением. Это позволяет спланировать возможности перекрестного финансирования НИР в рамках одного округа. А именно, как видно, например, в табл. 23, в Нижегородской и Ульяновской областях фактические максимальные все затраты на НИР превышают оптимальные затраты. Это подводит к предварительному выводу, что в условиях экономии федеральных бюджетных средств ПФО может частично сам профинансировать все затраты на НИР в тех регионах, которые в этом нуждаются. К таким регионам согласно данным последней колонки табл. 3 о недостатке всех затрат на НИР мы можем отнести республику Мордовия, Самарскую область, Пермский край, Удмуртскую республику, а также республики Татарстан и Башкортостан. Причем, согласно данным табл. 23 получается, что наиболее нуждающимся регионом является республика Татарстан.

Чтобы более обоснованно ответить на данный вопрос, необходимо проанализировать эту ситуацию подробнее — в разрезе различных затрат на НИР по видам работ. В этом могут существенно помочь результаты, отраженные в табл. 24–26.

Таблица 23

## Результаты глобальной оптимизации регрессии всех затрат на НИР по регионам ПФО (млн руб.)

Регион	Инвестиции в основной капитал	Валовой региональный продукт	Задолженность юридических лиц по кредитам	Всего затраты на НИР	Максимальное фактическое значение	Резерв (+), недостаток (-)
	$x_1$	$x_2$	$x_3$	$y$	$y$	$\Delta y$
1. Нижегородский	—	1 478 448	335 116	65 487,9	80 671,8	15 183,9
2. Мордовия	—	245 720	80 800	3 336,6	1 049,4	-2 287,2
3. Ульяновский	—	376 064	71 717	12 147,5	12 565,8	418,3
4. Самарский	—	1 648 019	298 558	76 621,3	22 679,8	-53 941,5
5. Пермский	—	1 467 320	215 175	68 499	15 636,3	-52 862,7
6. Удмуртский	—	682 300	85 536	29 058,4	2 481,4	-26 577
7. Татарстан	—	2 669 465	414 215	135 189,2	18 420,6	-116 768,6
8. Башкортостан	—	1 809 428	213 167	89 103,4	11 196,7	-77 906,7

Таблица 24

Результаты глобальной оптимизации регрессии фундаментальных исследований по регионам ПФО  
(млн руб.)

Регион	Инвестиции в основной капитал	Валовой региональный продукт	Задолженность юридических лиц по кредитам	Фундамен- тальные исследования	Максимальное фактическое значение	Резерв (+), недостаток (-)
	$x_1$	$x_2$	$x_3$	$y_1$	$y_1$	$\Delta y_1$
1. Нижегородский	383 102	—	438 699	1 464,4	5 220,1	3 755,7
2. Мордовия	75 165	—	114 539	376,5	168,1	-208,4
3. Ульяновский	96 771	—	99 058	445,5	302,8	-142,7
4. Самарский	368 865	—	453 792	1 464,2	844,7	-619,5
5. Пермский	305 392	—	312 592	1 358,5	2 383,9	1 025,4
6. Удмуртский	107 187	—	121 689	641,6	811,5	169,9
7. Татарстан	751 565	—	710 836	1 602	2 896,6	1 294,6
8. Башкортостан	410 388	—	371 940	1 444,1	1 806	361,9

Таблица 25

Результаты глобальной оптимизации регрессии прикладных исследований по регионам ПФО  
(млн руб.)

Регион	Инвестиции в основной капитал	Валовой региональный продукт	Задолженность юридических лиц по кредитам	Прикладные исследования	Максимальное фактическое значение	Резерв (+), недостаток (-)
	$x_1$	$x_2$	$x_3$	$y_2$	$y_2$	$\Delta y_2$
1. Нижегородский	383 102	—	438 699	11 382,8	9 972,7	-1 410,1
2. Мордовия	75 165	—	114 539	3 059,7	470	-2 589,7
3. Ульяновский	96 771	—	99 058	3 670,3	5 190	1 519,7
4. Самарский	368 865	—	453 792	11 314,5	1 616,6	-9 697,9
5. Пермский	305 392	—	312 592	9 931,7	1 873,9	-8 057,8
6. Удмуртский	107 187	—	121 689	4 426,6	458,6	-3 968
7. Татарстан	751 565	—	710 836	14 686,1	2 557,3	-12 128,8
8. Башкортостан	410 388	—	371 940	11 307,4	2 644,6	-8 662,8

Таблица 26

## Результаты глобальной оптимизации регрессии разработок по регионам ПФО (млн руб.)

Регион	Инвестиции в основной капитал	Валовой региональный продукт	Задолженность юридических лиц по кредитам	Разработки	Максимальное фактическое значение	Резерв (+), недостаток (-)
	$x_1$	$x_2$	$x_3$	$y_3$	$y_3$	$\Delta y_3$
1. Нижегородский	383 102	1 203 299	438 699	40 998,4	66 824,4	25 826
2. Мордовия	75 165	194 177	80 800	9 503,2	581,9	-8 921,3
3. Ульяновский	96 771	312 577	71 717	13 603,7	10 636,7	-2 967
4. Самарский	368 865	1 282 274	453 792	39 572,4	18 294	-21 278,4
5. Пермский	305 392	1 148 574	312 592	30 065,7	12 784,6	-17 281,1
6. Удмуртский	107 187	506 122	121 689	3 732,2	1 591,1	-2 141,1
7. Татарстан	751 565	1 846 263	526 041	27 961,4	13 553,6	-14 407,8
8. Башкортостан	410 388	1 546 257	371 940	27 670,3	7 452,7	-20 217,6

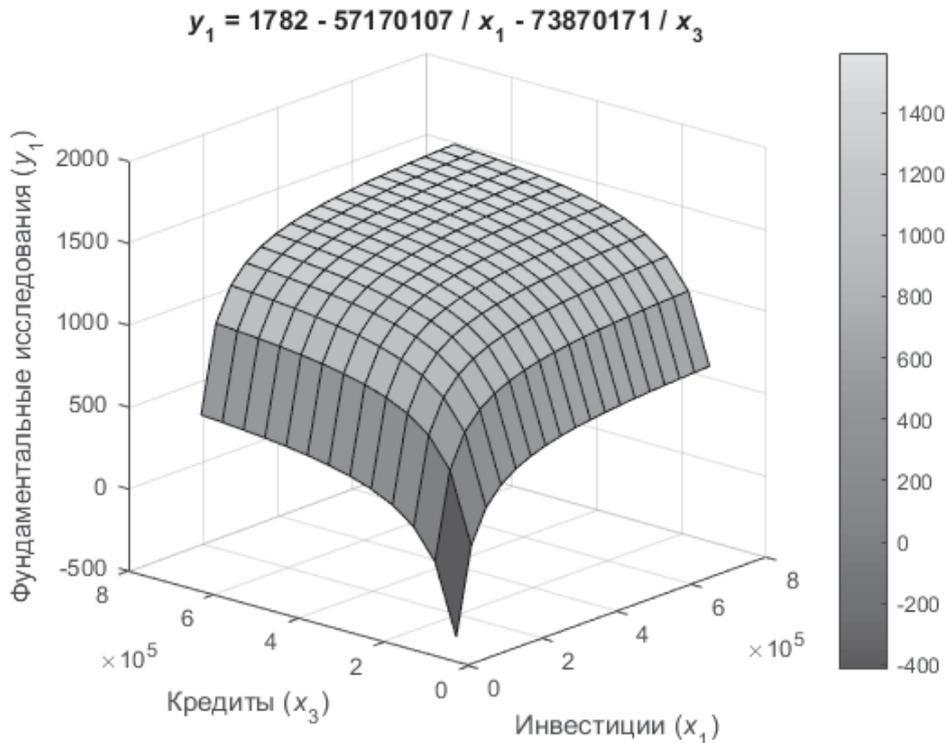


Рис. 46. График регрессии для фундаментальных исследований

Так, к примеру, согласно данным табл. 24 республика Татарстан, напротив, имеет некоторый резерв по затратам на фундаментальные исследования, который можно перенаправить в другие регионы ПФО. Кроме того, для Татарстана недостаток затрат на прикладные исследования (табл. 25) и разработки (табл. 26) в сумме существенно ниже, чем недостаток всех затрат на НИР, отраженный в табл. 23.

Напротив, как видно из табл. 24–26, наиболее нуждающимися в финансировании различных видов затрат на НИР оказываются Самарская область, республика Башкортостан и Пермский край. Но при этом основным донором резерва затрат на различные виды НИР остается Нижегородская область, если опять же мы рассматриваем внутреннее перекрестное самофинансирование затрат на НИР в пределах ПФО. Это позволило бы существенно сэкономить федеральные бюджетные средства, выделяемые на научное и, как следствие, инновационное развитие регионов страны.

В заключение обозначим наиболее важные выводы, полученные в результате исследования.

1. В настоящее время еще не до конца решенными остаются вопросы оптимального объема финансирования затрат на НИР в пределах страны и ее регионов, имеющих соответствующий научный потенциал. Решать подобного рода задачи представляется невозможным в отрыве от конкретных технологических и экономиче-

Regression Summary for Dependent Variable: y_2 (Cross_1.sta)						
R= ,49388343 R?= ,24392085 Adjusted R?= ,18462052						
F(4,51)=4,1133 p<,00578 Std.Error of estimate: 2264,3						
N=56	b*	Std.Err. of b*	b	Std.Err. of b	t(51)	p-value
<b>Intercept</b>			-58921,7	17523,99	-3,36234	0,001472
LN-V3	0,547084	0,378458	1925,2	1331,83	1,44556	0,154417
x_2	-0,928846	0,485821	-0,0	0,00	-1,91191	0,061513
LN-V1	1,118485	0,595084	3523,1	1874,43	1,87954	0,065889
x_1	-0,441857	0,349556	-0,0	0,00	-1,26405	0,211958

Рис. 47. Регрессия для прикладных исследований

ских результатов НИР регионов. Планирование данных результатов, а также необходимых для их достижения ресурсов является актуальной задачей оптимизации затрат на НИР. В этой связи мы выделяем три вида планирования: инвестиционное, производственное и финансовое. При этом все три процесса мы рассматриваем одновременно. Это позволит охватить широкий круг задач оптимизации затрат на НИР в регионах и способствовать их инновационному развитию.

2. В настоящем исследовании применялись метаэвристические алгоритмы для оптимизации затрат на НИР в регионах федерального округа. Это позволяет планировать перекрестное финансирование НИР в рамках одного округа. Среди метаэвристических алгоритмов использовались генетический алгоритм, имитационный отжиг и поиск по шаблону. При этом наиболее достоверный результат позволяет получить поиск по шаблону. Добавление данного алгоритма или метода внутренней точки в качестве гибридной функции для генетического алгоритма или имитационного отжига также позволяет достигнуть достаточно качественного решения проблемы оптимизации.

3. Результаты глобальной оптимизации позволяют сделать вывод, что в условиях экономии федеральных бюджетных средств федеральный округ может частично сам профинансировать затраты на НИР в тех регионах, которые в этом нуждаются. Чтобы более обоснованно определить такие регионы, необходимо проанализировать эту ситуацию подробнее — в разрезе различных затрат на НИР по видам работ.

4. Для ПФО получено, что наиболее нуждающимися в финансировании различных видов затрат на НИР оказываются Самарская область, республика Башкортостан и Пермский край. Но при этом основным донором резерва затрат на различные виды НИР является Нижегородская область. В этом заключается суть внутреннего перекрестного самофинансирования затрат на НИР в пределах ПФО. Это позволило бы существенно сэкономить федеральные бюджетные средства, выделяемые на научное и, как следствие, инновационное развитие регионов страны.

Представленный подход может способствовать принятию более качественных решений государственными структурами и их экспертами в отношении планирования инновационного развития промышленных регионов страны.

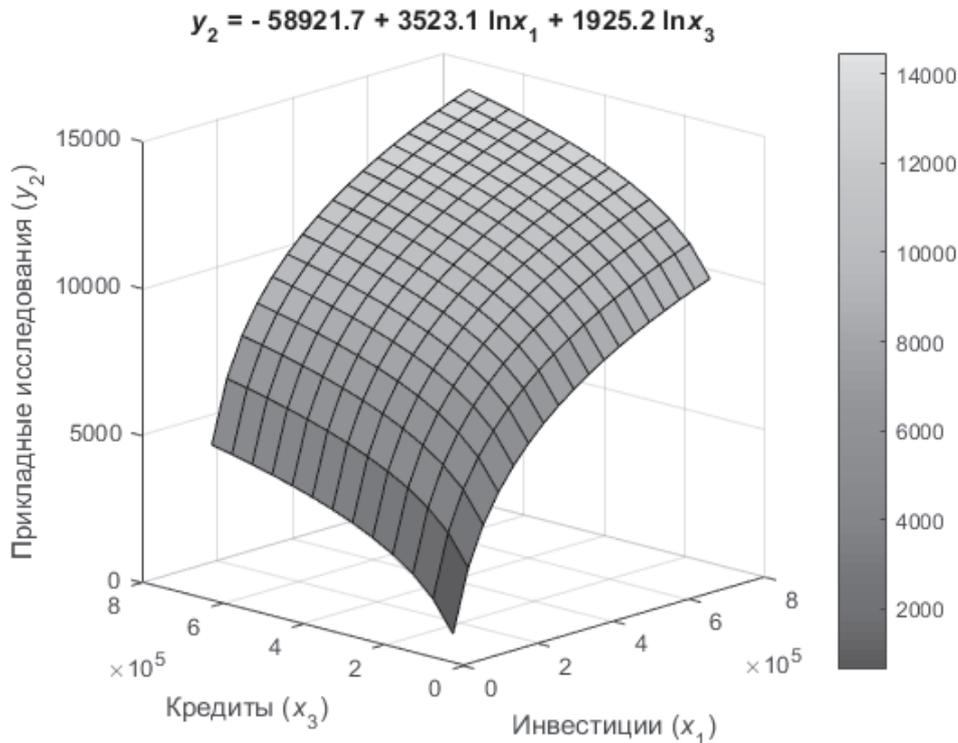


Рис. 48. График регрессии для прикладных исследований

Механизм стимулирования регионального инновационного развития включает в себя сбалансированный (между действиями органов власти, приоритетами бизнеса и интересами населения) комплекс мероприятий, стратегий, проектов и программ для повышения инновационного потенциала региона.

Структурное представление региональной инновационной системы через множество организаций различных форм собственности, отраслевой и ведомственной принадлежности в соответствующей сфере, позволяет учитывать совокупный уровень инновационной активности организаций как один из критериев эффективности развития инновационной системы. Так Нижегородская область традиционно входит в число ведущих регионов — инноваторов. Однако показатели официальной статистики последних лет свидетельствуют о замедлении темпов инновационного развития региона и расхождении плановых и фактических индикаторов достижения целей стратегических документов регионального значения. Уровень инновационной активности компаний Нижегородской области по итогам 2019 г. снизился на 5% и составил 13,7%, уступая Мордовии, Татарстану и Чувашии. Рост объемов затрат на инновационную деятельность в размере 62,3% по сравнению с предшествующим годом существенно опережает прирост объемов отгрузки инновационных товаров (в 2019 г. показатель вырос всего на 8,3%). С точки зрения оценки эффективности, соотношение объема отгруженной инновационной продукции к об-

Regression Summary for Dependent Variable: y_3 (Cross_1.sta)						
R= ,66863247 R?= ,44706938 Adjusted R?= ,39177632						
F(5,50)=8,0855 p<,00001 Std.Error of estimate: 14050,						
N=56	b*	Std.Err. of b*	b	Std.Err. of b	t(50)	p-value
<b>Intercept</b>			-3,153174E+05	1,226551E+05	-2,57076	0,013171
1/V3	2,07173	0,887007	9,314139E+09	3,987830E+09	2,33564	0,023562
x_2	-0,98686	0,322736	-2,542966E-02	8,316301E-03	-3,05781	0,003576
1/V1	-0,28034	0,287437	-9,509121E+08	9,749835E+08	-0,97531	0,334101
SQRV3	9,18409	2,948177	9,819057E+02	3,152007E+02	3,11518	0,003042
x_3	-6.21574	2.142328	-6.432493E-01	2.217034E-01	-2.90140	0.005511

Рис. 49. Регрессия для разработок

щему размеру затрат на техинновации в Нижегородской области (1,72 руб. инновационной продукции на рубль затрат на инновации) уступает Республике Татарстан (5,44 руб. в 2019 г.), Самарской (3,18 руб.) и Пензенской (7,95 руб.) областям. С организационной точки зрения, для Нижегородской области характерны дисбаланс спроса и предложения на рынке инноваций (недостаточно реализуются возможности нижегородской науки в части внедрения результатов НИОКР); низкий уровень активности малых предприятий; низкая патентная активность.

## Глава 5

### Моделирование поведения топ-менеджеров для эффективного управления инновациями

#### 5.1. Моделирование мотивации топ-менеджеров государственных структур федерального округа: двухцелевой генетический алгоритм

В условиях внедрения технологий имитационного моделирования и искусственного интеллекта в систему государственного управления становится важным разрабатывать и внедрять комплексные модели эволюции региональных инновационных систем и инновационной инфраструктуры.

В данном контексте приобретают особую актуальность методы и модели мотивации топ-менеджмента управляющих структур регионов и округов с учетом внешних и внутренних связей. Решение данной практической проблемы усложняется тем, что в настоящее время недостаточно детально исследованы вопросы мотивации топ-менеджмента государственных структур. Напротив, задача конструктивной мотивации топ-менеджеров частных корпораций изучена более подробно. Здесь можно привести результаты, которые могут быть полезны для выбора некоторых ориентиров мотивации топ-менеджмента государственных структур.

Так, в работе С. Н. Яшина, Е. В. Кошелева и А. В. Купцова [27] предлагается применять фактический показатель модифицированной экономической добавленной стоимости вместо обычной экономической добавленной стоимости. Это позволяет привести в соответствие приоритеты топ-менеджеров и собственников в отношении того, какой проект из имеющихся альтернатив следует реализовать.

Для решения проблемы настоящего параграфа также следует привести в соответствие интересы топ-менеджеров государственных структур и населения.

В монографии С. Н. Яшина и др. [28] представлена теория материальной и нематериальной мотивации топ-менеджеров компаний на основе эталонных функций полезности. Была разработана модель приведения нематериальной мотивации к материальной, рассмотренная в контексте управления инновациями в фирме.

Здесь мы также будем исследовать взаимосвязь материальной и нематериальной мотивации топ-менеджеров государственных структур для разработки рациональной системы их поощрения.

Наконец, М. А. Лимитовский [13] создал модель, по которой определяется доля топ-менеджера — инсайдера в доходах фирмы и которая при этом перевешивает потерю альтернативных доходов (диверсант) и вместе с тем не создает деструктивной мотивации (регент). В результате был получен важный вывод, что рациональный инсайдер, не несущий материальной ответственности за принятие неэффективных проектов, не может быть конструктивно мотивирован.

В отличие от позиции М. А. Лимитовского [13], мы не будем рассматривать систему наказаний топ-менеджеров государственных структур, но при этом более

детально изучим систему их поощрения (премирования) с позиции материальной и нематериальной мотивации, используя для этого многоцелевой генетический алгоритм (MGA) как один из эволюционных подходов, применяемых в имитационном моделировании.

Естественным становится вопрос, почему для исследования выбирается именно многоцелевой генетический алгоритм. Обсудим это подробнее.

Современные достижения в области развития информационных технологий в динамических средах представляют собой углубленное обсуждение революции в области информационных технологий в таких областях, как государственное управление, игры, социальные сети и облачные вычисления [91].

Эволюционные алгоритмы являются относительно новыми, но очень мощными методами, используемыми для поиска решений многих реальных проблем поиска и оптимизации. Многие из этих проблем имеют многочисленные цели, что приводит к необходимости получения набора оптимальных решений, известных как эффективные решения. Было обнаружено, что использование эволюционных алгоритмов является высокоэффективным способом поиска множества эффективных решений в одном прогоне моделирования [88].

Эволюционное программирование используется также как методика обучения общей нейронной сети. Этот подход может дать более быстрые, эффективные и надежные процедуры обучения, учитывающие произвольные межсоединения и нейроны, обладающие дополнительными возможностями обработки [38, 68, 69].

Решение многоцелевых задач — это развивающееся усилие, а информатика и другие смежные дисциплины породили множество мощных детерминированных и стохастических методов для решения этих масштабных задач оптимизации. Эволюционные алгоритмы являются одним из таких общих стохастических подходов, который оказался успешным и широко применимым в решении как одноцелевых, так и многоцелевых задач [47].

Многоцелевая оптимизация связана с решением задач, имеющих не один, но и несколько, часто противоречащих друг другу критериев. Такие проблемы могут возникнуть практически во всех областях науки, техники и бизнеса, и потребность в эффективных и надежных методах решения возрастает. Задача является сложной из-за того, что вместо единого оптимального решения многоцелевая оптимизация приводит к ряду решений с различными компромиссами между критериями, также известными как оптимальные или эффективные решения Парето. Поэтому для предоставления дополнительной информации о предпочтениях и определения наиболее удовлетворительного решения требуется лицо, принимающее решение (ЛПР). В зависимости от используемой парадигмы такая информация может вводиться до, во время или после процесса оптимизации. Очевидно, что исследования и приложения в области многоцелевой оптимизации предполагают экспертные знания в области оптимизации, а также поддержки принятия решений [43].

Рассмотрим, в чем заключаются основные идеи подхода MGA.

А. Мессак, А. Исмаил-Яхая и К. А. Мэтсон [111] предложили метод нормального ограничения (NC) для генерации набора равномерно разнесенных решений

на границе Парето — для задач многоцелевой оптимизации. Поскольку немногие способы предлагают эту желательную характеристику, данный метод может иметь существенное практическое применение при выборе оптимального решения в многоцелевых условиях. Конкретный вклад авторов является двояким. Во-первых, представлена новая формулировка метода NS, которая включает критическое линейное отображение целей проектирования. Это отображение имеет желательное свойство, заключающееся в том, что результирующая производительность способа полностью не зависит от масштаба целей проектирования. При этом масштабирование проблем может создавать огромные трудности. Во-вторых, представлено понятие фильтра Парето и разработан его алгоритм. Как следует из его названия, фильтр Парето — это алгоритм, который сохраняет только глобальные точки Парето, учитывая множество точек в целевом пространстве. Фильтр Парето полезен при применении NS и других методов.

Оптимизация является одной из наиболее важных и сложных частей любого инженерного проекта. В реальном дизайне необходимо учитывать многоцелевую оптимизацию с ограничениями. Оптимальное решение в этом случае не является уникальным, поскольку цели могут противоречить друг другу. Поэтому следует рассмотреть комплекс оптимальных решений, который формирует границу Парето. Существует много алгоритмов для генерации набора Парето. Однако лишь немногие из них потенциально способны обеспечить равномерно распределенный набор решений [64].

Это свойство особенно важно в реальном дизайне, поскольку ЛПР обычно может анализировать только очень ограниченное количество решений. Так, Т. Эрфани и С. В. Утюжников [64] разработали и дали подробное описание алгоритма, способного генерировать равномерно распределенный набор Парето в общей формулировке. Подход основан на сокращении области поиска для генерации оптимального решения Парето в выбранной области на границе Парето. Эффективность алгоритма демонстрируется рядом сложных тестовых случаев.

Подобные достижения позволили применять подход MGA в разных областях знаний.

Так, К. Сим и Дж. Ким [144] нашли эволюционно стабильную стратегию (ESS) как решение задачи мультиобъектной оптимизации (MOP), используя коэволюционный алгоритм, основанный на эволюционной теории игр. Применяя вновь разработанные коэволюционные алгоритмы к нескольким MOP, авторы подтвердили, что эволюционная теория игр может быть воплощена коэволюционным алгоритмом, и этот коэволюционный алгоритм может найти оптимальные равновесные точки в качестве решений для MOP. К. Сим и Дж. Ким также показали производительность оптимизации совместного эволюционного алгоритма, основанного на эволюционной теории игр, применяя эту модель к нескольким MOP и сравнивая решения с решениями предыдущих эволюционных моделей оптимизации.

С. М. Р. Рафей, А. Амирахмади и Г. Грива [134] разработали простой, но оптимальный контроллер PID для преобразователя *Boost*, чтобы получить набор лучших характеристик, которые являются хорошим переходом, а также устойчивые

отклики и стабильность переключения. Это делается с помощью многоцелевого подхода оптимизации под названием “алгоритм силы Парето”, который основан на концепции оптимальности Парето, используемой в литературе теории игр. В первом сценарии оптимизирован режим запуска преобразователя. Время установки и превышение принимается за две целевые функции, в то время как усиления контроллера PID ( $K_p$ ,  $K_i$  и  $K_d$ ) являются конструктивными переменными. Программа генерирует набор оптимальных усиления под названием “набор Парето”, соответствующий фронту Парето, который представляет собой набор оптимальных результатов для целевых функций. Можно легко выбрать любой из результатов на основе его функций и собственного инженерного представления. Тогда максимальная и минимальная полосы жесткого ограничителя в цикле рассматриваются как дополнительные переменные, которые значительно улучшают отклик. В другой конструкции, помимо длительного режима запуска сигнала, динамическая характеристика преобразователя также оптимизирована. Наконец, в оптимальном запуске определена новая целевая функция, обеспечивающая стабильность переключения и отказ от хаоса, и концепция имеет весьма важное значение. Обширное моделирование и некоторые экспериментальные результаты доказывают превосходство предлагаемой методики проектирования для достижения широкого набора желаемых технических целей.

А. Бемпорад и Д. Муноз де ла Пена [40] предложили новую схему прогностического контроля модели (MPC), основанную на многоцелевой оптимизации. В каждый момент времени выборки управляющее действие MPC выбирается из набора оптимальных решений Парето на основе изменяющегося во времени зависящего от состояния критерия решения. По сравнению со стандартными одноцелевыми составами MPC такой критерий позволяет учитывать несколько, часто непримиримых, спецификаций управления, таких как высокая полоса пропускания (быстрота замкнутого цикла), когда вектор состояния находится далеко от равновесия и низкая полоса пропускания (хорошие свойства подавления шума) вблизи равновесия. После повторной обработки задачи оптимизации, связанной с мультиобъективным MPC-контроллером, в виде многопараметрической мультиобъективной линейной или квадратичной программы, авторы показали, что можно вычислить каждое оптимальное решение Парето как явную кусочно-аффинную функцию вектора состояния и вектора весов, которые должны быть присвоены различным целям, чтобы получить это конкретное оптимальное решение Парето. Кроме того, авторы представили условия для выбора оптимальных решений Парето, чтобы контур управления MPC был асимптотически стабильным, и показали эффективность подхода в примерах моделирования.

Дж. О. Х. Сэндин, А. А. Алонсо и Дж. Р. Банга [143] описали эффективный и надежный метод мультикритериальной оптимизации, который может быть успешно применен к крупным динамическим системам, подобным тем, которые возникают при моделировании термической обработки пищевых продуктов. Кроме того, их возможности по улучшению разработки и эксплуатации этих процессов были подчеркнуты в отдельных тематических исследованиях, где проанализированы вы-

работанные решения Парето. Наконец, авторы продемонстрировали их преимущества по сравнению с другими недавно предложенными стратегиями.

С. Р. Мотта, А. М. Б. Сильвана и Л. Р. М. Пауло [117] протестировали несколько хорошо известных процедур для решения задач многоцелевой оптимизации (MOP) и предложили новую модифицированную процедуру, которая при применении к существующему методу нормального пересечения границ (NBI) и методу нормального ограничения (NC) для более чем двух целей преодолевает некоторые из их недостатков. Для трех и четырех объективных приложений, проанализированных в работе, предлагаемая схема представляет наилучшую производительность как по качеству, так и по эффективности для получения набора правильных точек Парето по сравнению с проанализированными существующими подходами.

Ф. Доминго-Перес и др. [58] применили систему поддержки принятия решений, которая основана на эволюционной многоцелевой оптимизации для развертывания датчиков в системе локализации внутри помещений. Их методы направлены на то, чтобы предоставить специалисту, работающему менеджером ресурсов сенсора, полный набор эффективных решений Парето проблемы размещения сенсора. В анализе авторы использовали пять скалярных показателей производительности в качестве целевых функций, полученных из ковариационной матрицы оценки, а именно, трассировку, детерминанту, максимальное собственное значение, отношение максимального и минимального собственных значений и неопределенность в данном направлении. Авторы запустили многоцелевой генетический алгоритм для оптимизации этих целей и получения фронтов Парето. Также они подробно объяснили каждый аспект системы и применение предлагаемой системы поддержки принятия решений к системе позиционирования в инфракрасном диапазоне внутри помещений. Окончательные результаты показывают различные альтернативы размещения в соответствии с целями, и можно четко увидеть компромисс между различными показателями точности. Этот подход способствует современному уровню техники в том, что авторы указали на проблемы оптимизации одного показателя точности и предложили использовать систему поддержки принятия решений, которая предоставляет менеджеру ресурсов полный обзор набора эффективных решений Парето с учетом нескольких метрик точности. Поскольку менеджер будет знать все оптимальные решения Парето до принятия решения об окончательной схеме размещения датчика, этот метод предоставляет больше информации, чем работа с одной функцией взвешенных целей. Кроме того, можно использовать эту систему для оптимизации целей, получаемых из довольно сложных функций.

Х. А. Нгаен и др. [122] представили разработку по включению алгоритмов многоцелевой оптимизации в научные рабочие процессы. Авторы продемонстрировали эффективность этих возможностей, формулируя трехобъективную задачу оптимизации аэродинамики. Целью было улучшить аэродинамические особенности типичного  $2D$ -профиля крыла, рассматривающего также пластинчато-бурное местоположение перехода для более точной оценки полного сопротивления. Авторы использовали два различных эвристических алгоритма оптимизации и сравнили их результаты.

При всей привлекательности подхода MGA нельзя забывать о том, что зачастую существует проблема определения многоцелевой функции, которую необходимо оптимизировать на некоторых интервалах параметров. В этом случае А. Абакаров, Ю. Сушков и Р. Х. Масчерони [31] предложили использовать множественный нелинейный регрессионный анализ для набора экспериментальных данных, чтобы получить конкретные многоцелевые функции. Мы в нашем исследовании будем действовать аналогично.

Наконец, результаты, полученные с помощью MGA, необходимо дополнительно проверять. Для этого, на наш взгляд, удачно подойдет метод поиска по шаблону (Pattern Search).

Моделирование и оценку материальной и нематериальной мотивации топ-менеджмента управляющих структур регионов и округов с учетом внешних и внутренних связей, используя для этого подход MGA, будем проводить в несколько этапов (рис. 50).

**Этап 1 — сбор данных о социально-экономическом развитии регионов федерального округа.** Эффективное межкластерное взаимодействие внутри одного федерального округа принимает экономико-финансовый, информационный и логистический характер. Для регионов с инновационно-индустриальными кластерами это будут внешние связи, а для округа — внутренние. Также следует учитывать внешние связи округа с остальными территориями России и другими странами. Эффективность таких связей позволяет определить система оценки социально-экономического развития регионов России с помощью мест, занимаемых данными субъектами в РФ, по ряду факторов, к числу которых мы относим:

- 1) валовой региональный продукт (ВРП) на душу населения ( $x_1$ );
- 2) инвестиции в основной капитал на душу населения ( $x_2$ );
- 3) внутренние затраты на научно-исследовательские работы (НИР) ( $x_3$ );
- 4) среднедушевые денежные доходы населения (в месяц) ( $x_1$ );
- 5) общая площадь жилых помещений на душу населения ( $x_2$ );
- 6) удельный вес автодорог с твердым покрытием ( $x_3$ ).

Данные факторы непосредственно влияют на естественный прирост населения ( $y$ ) в регионах федерального округа.

Первые три из перечисленных факторов позволяют разработать систему нематериального поощрения топ-менеджмента в государственных структурах регионов округа, а остальные три — систему материального поощрения. То есть, таким образом, мы утверждаем, что первые три фактора характеризуют эффективность решения общегосударственных задач, а остальные три — эффективность решения задач, приоритетных для населения. Поскольку приоритеты населения важнее, эффективность их выполнения следует мотивировать материально. Реализацию общегосударственных задач тогда предлагается мотивировать нематериально.

Таким образом, определяются две цели в MGA, т. е. материальная и нематериальная мотивация топ-менеджмента управляющих структур регионов и округов. Похожие по своей экономической природе факторы, от которых зависит естественный прирост населения, обозначим одинаковыми переменными  $x_i$  ( $i = \overline{1, 3}$ ).

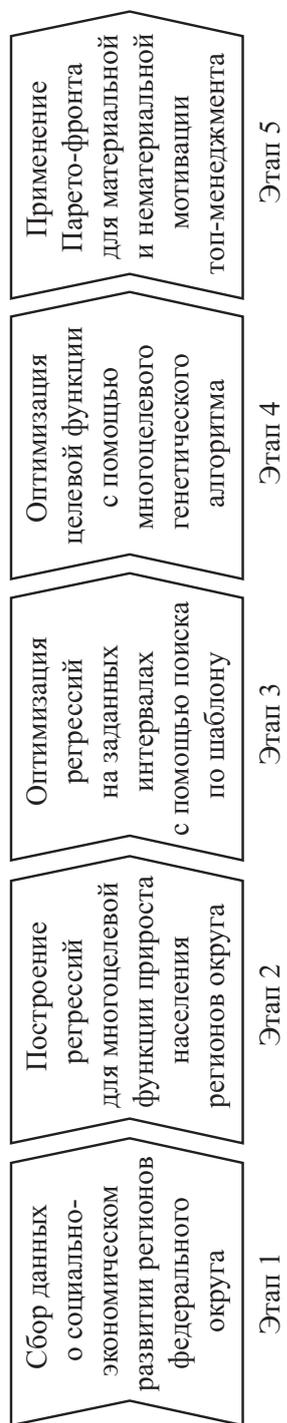


Рис. 50. Моделирование и оценка материальной и нематериальной мотивации топ-менеджмента

Это позволяет сформировать одну систему координат для многоцелевой (двухцелевой) функции прироста населения регионов округа ( $y$ ).

**Этап 2 — построение регрессий для многоцелевой функции прироста населения регионов округа.** На данном этапе для материальной и нематериальной мотивации топ-менеджмента можно построить соответствующие нелинейные регрессии, например, в программе *Statistica*, которые будут использоваться затем в процессе глобальной оптимизации двухцелевой функции прироста населения.

**Этап 3 — оптимизация регрессий на заданных интервалах с помощью поиска по шаблону.** Места, занимаемые субъектами (регионами) в РФ, по шести приведенным ранее факторам позволяют получить сегменты по всем  $x_i$  ( $i = \overline{1, 3}$ ), на которых будет оптимизироваться двухцелевая функция  $y$ . Поиск ее глобальных наибольших значений для каждой из двух регрессий с помощью поиска по шаблону дает возможность проверить будущие крайние значения Парето-фронта, который будет получен с использованием MGA.

**Этап 4 — оптимизация целевой функции с помощью многоцелевого генетического алгоритма.** Подход MGA позволяет получить Парето-фронт для двухцелевой функции, все решения которого одинаково оптимальны. Он показывает набор наилучших  $y$ , а также значения факторов  $x_i$  ( $i = \overline{1, 3}$ ) для всех полученных  $y$ .

**Этап 5 — применение Парето-фронта для материальной и нематериальной мотивации топ-менеджмента.** Выбирая любую точку Парето-фронта, можно найти в ней доли материальной и нематериальной мотивации топ-менеджеров. Они определяются близостью к крайним точкам Парето-фронта, в которых максимальна лишь одна из двух регрессий (мотиваций).

Вывод о фактическом поощрении (премировании) топ-менеджеров делается следующим образом. Для обеих регрессий оцениваются плановые значения естественного прироста населения ( $y$ ) в каждом регионе, исходя из значений  $x_1, x_2, x_3$ . Затем они сравниваются с фактическими значениями  $y$ . Если фактический прирост населения положительный, то оценивается его близость к тому или иному плановому значению и соответственно выбираются доли нематериального и материального поощрения (премирования).

**Пример 7.** Рассмотрим процесс моделирования и оценки материальной и нематериальной мотивации топ-менеджмента управляющих структур регионов и округов, используя для этого подход MGA, на примере Приволжского федерального округа (ПФО).

Согласно перечню, утвержденному Правительством РФ, в России действуют 25 пилотных инновационных территориальных кластеров по регионам Российской Федерации. Тогда будем рассматривать в ПФО только те регионы (области или республики), в которых расположены кластеры из данного перечня.

**Этап 1 — сбор данных о социально-экономическом развитии регионов федерального округа.** Используя показатели “Статистического обозрения” Федеральной службы государственной статистики, сгруппируем необходимые для анализа данные за 10 лет в табл. 27.

Данные для построения регрессионных моделей

Регион	Место, занимаемое субъектом в РФ							Естественный прирост населения (чел.)
	Нематериальная мотивация		Материальная мотивация			Удельный вес автоторого с твердым покрытием		
	ВРП на душу населения	Инвестиции в основной капитал на душу населения	Внутренние затраты на НИР	Средне-душевые денежные доходы (в месяц)	Общая площадь жилых помещений на душу населения		$x_3$	
$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$	$y$		
2018 год								
1. Нижегородский	39	44	4	20	33	49	-15 917	
2. Мордовия	62	60	55	80	29	76	-4 094	
3. Ульяновский	60	58	15	70	25	44	-5 413	
4. Самарский	27	43	12	35	37	<b>82</b>	-9 927	
5. Пермский	23	35	11	34	64	50	-5 224	
6. Удмуртский	44	59	36	59	71	68	-1 670	
7. Татарстан	15	13	9	18	40	34	1 600	
8. Башкортостан	46	56	16	31	46	9	-3 429	

Продолжение табл. 27

Регион	Место, занимаемое субъектом в РФ						Естественный прирост населения (чел.)
	Нематериальная мотивация		Материальная мотивация		Удельный вес автотрасс с твердым покрытием		
	ВРП на душу населения	Инвестиции в основной капитал на душу населения	Внутренние затраты на НИР	Средне-душевые денежные доходы (в месяц)			
$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$	$y$	
2017 год							
1. Нижегородский	37	45	4	20	32	49	-13 556
2. Мордовия	62	46	59	80	29	77	-4 008
3. Ульяновский	59	47	13	62	27	45	-4 944
4. Самарский	27	39	11	35	36	81	-9 284
5. Пермский	23	27	10	26	66	52	-2 946
6. Удмуртский	41	64	43	56	72	69	-258
7. Татарстан	16	11	8	17	38	35	4 240
8. Башкортостан	45	52	16	27	47	9	-1 072

Продолжение табл. 27

Регион	Место, занимаемое субъектом в РФ						Естественный прирост населения (чел.)
	Нематериальная мотивация		Материальная мотивация		Удельный вес автотрасс с твердым покрытием		
	ВРП на душу населения	Инвестиции в основной капитал на душу населения	Внутренние затраты на НИР	Среднедушевые денежные доходы (в месяц)			
$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$	$y$	
2016 год							
1. Нижегородский	41	46	4	20	33	48	-11 420
2. Мордовия	63	47	56	81	29	76	-3 457
3. Ульяновский	62	60	17	62	28	45	-3 997
4. Самарский	28	33	12	36	38	81	-4 277
5. Пермский	23	27	9	26	66	50	889
6. Удмуртский	40	56	52	52	72	69	1 822
7. Татарстан	16	10	11	16	36	37	<b>10 643</b>
8. Башкортостан	43	28	16	28	48	10	3 298

Продолжение табл. 27

Регион	Место, занимаемое субъектом в РФ						Естественный прирост населения (чел.)
	Нематериальная мотивация		Материальная мотивация		Удельный вес автотрасс с твердым покрытием		
	ВРП на душу населения	Инвестиции в основной капитал на душу населения	Внутренние затраты на НИР	Среднедушевые денежные доходы (в месяц)		Общая площадь жилых помещений на душу населения	
$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$	$y$	
2015 год							
1. Нижегородский	35	40	4	21	28	45	-10 714
2. Мордовия	62	46	56	80	26	76	-3 567
3. Ульяновский	60	38	16	56	28	43	-3 734
4. Самарский	25	25	7	27	41	78	-4 687
5. Пермский	23	30	11	18	65	56	1 383
6. Удмуртский	42	61	52	48	70	69	2 662
7. Татарстан	14	10	12	17	36	38	10 416
8. Башкортостан	36	34	17	26	49	12	5 089

Продолжение табл. 27

Регион	Место, занимаемое субъектом в РФ						Естественный прирост населения (чел.)
	Нематериальная мотивация		Материальная мотивация		Удельный вес автотрасс с твердым покрытием		
	ВРП на душу населения	Инвестиции в основной капитал на душу населения	Внутренние затраты на НИР	Среднедушевые денежные доходы (в месяц)			
$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$	$y$	
2014 год							
1. Нижегородский	36	28	4	21	29	46	-12 846
2. Мордовия	64	41	55	79	24	78	-3 434
3. Ульяновский	61	45	15	53	35	33	-3 397
4. Самарский	25	24	9	24	44	79	-5 402
5. Пермский	23	36	12	19	66	51	2 070
6. Удмуртский	41	56	51	54	70	71	2 651
7. Татарстан	14	9	10	16	39	39	9 732
8. Башкортостан	26	38	16	25	49	12	6 949

Продолжение табл. 27

Регион	Место, занимаемое субъектом в РФ						Естественный прирост населения (чел.)
	Нематериальная мотивация		Материальная мотивация		Удельный вес автотрасс с твердым покрытием		
	ВРП на душу населения	Инвестиции в основной капитал на душу населения	Внутренние затраты на НИР	Средне-душевые денежные доходы (в месяц)			
$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$	$y$	
2013 год							
1. Нижегородский	37	26	4	24	28	44	-13 457
2. Мордовия	69	39	52	80	27	77	-3 855
3. Ульяновский	58	48	15	60	33	27	-3 523
4. Самарский	26	27	6	16	45	75	-6 594
5. Пермский	21	34	9	18	58	46	1 584
6. Удмуртский	42	66	46	58	70	68	2 776
7. Татарстан	15	12	10	17	38	40	10 218
8. Башкортостан	30	40	16	26	49	9	5 895

Регион	Место, занимаемое субъектом в РФ						Естественный прирост населения (чел.)
	Нематериальная мотивация		Материальная мотивация		Удельный вес автотрасс с твердым покрытием		
	ВРП на душу населения	Инвестиции в основной капитал на душу населения	Внутренние затраты на НИР	Средне-душевые денежные доходы (в месяц)			
$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$	$y$	
2012 год							
1. Нижегородский	33	29	4	23	30	46	-13 890
2. Мордовия	60	41	56	79	27	79	-3 691
3. Ульяновский	53	48	14	63	39	19	-3 551
4. Самарский	26	40	5	17	51	57	-5 641
5. Пермский	18	42	12	20	63	45	1 569
6. Удмуртский	39	<b>74</b>	53	62	72	73	3 718
7. Татарстан	12	17	10	18	43	41	9 023
8. Башкортостан	31	47	16	26	54	10	5 617

Продолжение табл. 27

Регион	Место, занимаемое субъектом в РФ						Естественный прирост населения (чел.)
	Нематериальная мотивация		Материальная мотивация		Удельный вес автотранспорта с твердым покрытием		
	ВРП на душу населения	Инвестиции в основной капитал на душу населения	Внутренние затраты на НИР	Среднедушевые денежные доходы (в месяц)		Общая площадь жилых помещений на душу населения	
$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$	$y$	
2011 год							
1. Нижегородский	32	32	4	27	31	40	-17 869
2. Мордовия	61	42	57	78	29	77	-4 414
3. Ульяновский	57	50	14	65	39	17	-5 101
4. Самарский	27	36	7	17	49	49	-9 516
5. Пермский	20	48	12	19	62	38	-1 765
6. Удмуртский	42	63	52	61	72	76	1 495
7. Татарстан	15	19	11	20	43	57	3 752
8. Башкортостан	35	56	16	23	58	28	1 374

Продолжение табл. 27

Регион	Место, занимаемое субъектом в РФ						Естественный прирост населения (чел.)
	Нематериальная мотивация		Материальная мотивация		Удельный вес автотрасс с твердым покрытием		
	ВРП на душу населения	Инвестиции в основной капитал на душу населения	Внутренние затраты на НИР	Среднедушевые денежные доходы (в месяц)			
$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$	$y$	
2010 год							
1. Нижегородский	33	31	4	27	33	48	-22 942
2. Мордовия	60	41	54	74	34	53	-5 211
3. Ульяновский	57	55	17	64	39	20	-6 690
4. Самарский	25	46	6	17	51	55	-11 809
5. Пермский	17	34	9	18	61	45	-3 153
6. Удмуртский	41	69	57	70	72	76	622
7. Татарстан	14	18	13	20	45	63	-762
8. Башкортостан	37	57	20	22	62	31	2 686

Окончание табл. 27

Регион	Место, занимаемое субъектом в РФ						Естественный прирост населения (чел.)
	Нематериальная мотивация			Материальная мотивация			
	ВРП на душу населения	Инвестиции в основной капитал на душу населения	Внутренние затраты на НИР	Средне-душевые денежные доходы (в месяц)	Общая площадь жилых помещений на душу населения	Удельный вес автоторог с твердым покрытием	
$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$	$y$	
2009 год							
1. Нижегородский	30	23	4	28	30	56	-22 094
2. Мордовия	60	44	49	75	28	57	-4 896
3. Ульяновский	59	49	17	67	36	18	-5 734
4. Самарский	20	54	6	17	42	59	-10 713
5. Пермский	19	31	8	18	62	51	-4 511
6. Удмуртский	40	69	53	63	<b>73</b>	63	869
7. Татарстан	12	17	13	22	44	71	-1 415
8. Башкортостан	28	55	20	21	58	35	2 305

**Этап 2 — построение регрессий для многоцелевой функции прироста населения регионов округа.** Используя данные табл. 27, в программе *Statistica* получены две наиболее достоверные модели множественной нелинейной регрессии:

— нематериальная мотивация (рис. 51) —

$$y = -218,221 - 198,754 x_1 - 877,781 x_2 + 2\,212,374 x_3 + 12,888 x_2^2 - 45,879 x_3^2 - 0,001 x_2^4 + 0,005 x_3^4,$$

Regression Summary for Dependent Variable: Var7 (Spreadsheet1)						
R= ,87393742 R?=- ,76376662 Adjusted R?=- ,74079948						
F(7,72)=33,255 p<0,0000 Std.Error of estimate: 3537,3						
N=80	b*	Std.Err. of b*	b	Std.Err. of b	t(72)	p-value
<b>Intercept</b>			-218,221	4082,229	-0,05346	0,957516
Var3	5,93269	0,596695	2212,374	222,515	9,94259	0,000000
V3**2	-7,72702	1,122842	-45,879	6,667	-6,88166	0,000000
Var1	-0,46761	0,090479	-198,754	38,458	-5,16814	0,000002
V3**4	2,40297	0,625833	0,005	0,001	3,83964	0,000262
Var2	-1,95555	0,626509	-877,781	281,219	-3,12134	0,002591
V2**2	2,31897	1,028935	12,888	5,718	2,25376	0,027257
V2**4	-0,62468	0,464438	-0,001	0,001	-1,34502	0,182841

Рис. 51. Регрессия нематериальной мотивации

— материальная мотивация (рис. 52) —

$$y = 139\,588,7 + 2\,202 x_2 - 34\,383\sqrt{x_2} - 521,1\sqrt{x_3}.$$

Regression Summary for Dependent Variable: Var7 (Spreadsheet1)						
R= ,81139214 R?=- ,65835720 Adjusted R?=- ,61736007						
F(3,25)=16,059 p<,00001 Std.Error of estimate: 1974,9						
N=29	b*	Std.Err. of b*	b	Std.Err. of b	t(25)	p-value
<b>Intercept</b>			139588,7	54079,38	2,58118	0,016101
SQRV5	-9,65394	4,156456	-34383,0	14803,42	-2,32264	0,028631
Var5	9,05348	4,253440	2202,0	1034,54	2,12851	0,043331
SQRV6	-0,29081	0,222370	-521,1	398,45	-1,30778	0,202848

Рис. 52. Регрессия материальной мотивации

**Этап 3 — оптимизация регрессий на заданных интервалах с помощью поиска по шаблону.** Согласно данным табл. 27 сегменты мест, занимаемых субъектами в РФ, получаются следующие:

$$x_1 \in [1; 81], \quad x_2 \in [1; 74], \quad x_3 \in [1; 82].$$

Оптимизация регрессий в программе *Matlab* на заданных сегментах с помощью поиска по шаблону дает результаты:

— для нематериальной мотивации —

$$y_{\max} = 97\,703 \text{ чел. при } (x_1, x_2, x_3) = (1; 1; 82),$$

— для материальной мотивации —

$$y_{\max} = 106\,887 \text{ чел. при } (x_1, x_2, x_3) = (1; 1; 1).$$

**Этап 4 — оптимизация целевой функции с помощью многоцелевого генетического алгоритма.** Подход MGA позволяет получить в программе *Matlab* Парето-фронт для двухцелевой функции, который представлен на рис. 53 и 54.

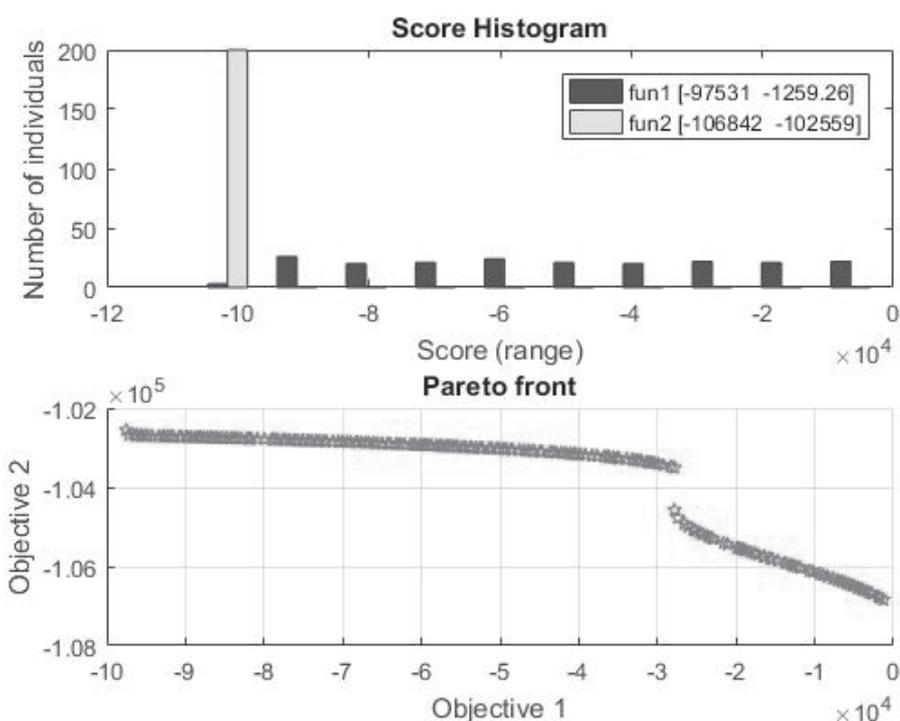


Рис. 53. Парето-фронт нематериальной (fun1) и материальной (fun2) мотивации

**Этап 5 — применение Парето-фронта для материальной и нематериальной мотивации топ-менеджмента.** Анализ полученного Парето-фронта позволяет сделать следующие выводы:

1. Максимальный прирост населения в отдельном регионе ПФО в случае ориентации на нематериальную мотивацию топ-менеджмента получается при минимальных внутренних затратах на НИР ( $x_3$ ). Это говорит о том, что они выгодны

Pareto front - function values and decision variables					
Index	f1	f2	x1	x2	x3 ▲
1	-884,631	-106 886,6	1	1	1
2	-884,631	-106 886,6	1	1	1
9	-5 194,583	-106 482,637	1,027	1	3,133
15	-16 448,459	-105 743,429	1,058	1	10,119
10	-20 405,595	-105 482,619	1,026	1,001	13,521
13	-25 131,439	-105 071,709	1,051	1,002	19,512
14	-31 725,35	-103 330,308	1,095	1,001	60,609
18	-33 475,959	-103 300,486	1,074	1	62,064
8	-40 088,508	-103 154,033	1,167	1,001	66,189
6	-44 272,34	-103 096,418	1,054	1,001	68,159
16	-48 558,622	-103 042,443	1,121	1,001	69,908
7	-52 721,125	-102 998,532	1,056	1	71,398
19	-54 869,141	-102 966,639	1,071	1,001	72,111
12	-61 164,736	-102 915,002	1,139	1,001	74,017
5	-65 533,9	-102 872,558	1,127	1,001	75,206
4	-68 286,507	-102 858,452	1,126	1,001	75,91
3	-73 711,96	-102 819,218	1,132	1,001	77,213
17	-84 847,32	-102 750,339	1,145	1,001	79,603
21	-88 993,297	-102 734,071	1,148	1	80,414
11	-92 610,426	-102 700,475	1,206	1,001	81,094
20	-97 622,505	-102 587,594	1,376	1,007	82

Рис. 54. Координаты точек Парето-фронта для нематериальной (f1) и материальной (f2) мотивации

топ-менеджерам, а не населению. Население интересуется удовлетворением насущных потребностей в виде денежных доходов, площади жилья и качества автодорог.

2. В случае ориентации на материальную мотивацию максимальный прирост населения будет наблюдаться при наибольшей площади жилых помещений на душу населения ( $x_2$ ) и наибольшем удельном весе автодорог с твердым покрытием ( $x_3$ ). Следовательно, для прироста населения важна инфраструктура, т.е. увеличение площади жилья и качества автодорог. Такова приоритетная цель в премировании топ-менеджеров государственных структур.

3. На рис. 53 и 54 наблюдается возможность качественного скачка прироста населения (функция f2) в случае повышения затрат на автодороги. При этом отдельный регион в таких условиях может резко перейти с 60 на 19 место, занимаемое субъектом в РФ.

В заключение сформулируем наиболее важные выводы:

1. Необходимо привести в соответствие интересы топ-менеджеров государственных структур и населения. Для этого важно исследовать взаимосвязь материальной и нематериальной мотивации топ-менеджеров для разработки рациональной системы их поощрения.

2. Эффективное межкластерное взаимодействие внутри одного федерального округа принимает экономико-финансовый, информационный и логистический характер. Эффективность таких связей позволяет определить система оценки социально-экономического развития регионов России с помощью мест, занимаемых данными субъектами в РФ, по ряду факторов, которые непосредственно влияют на естественный прирост населения в регионах округа. Одна группа факторов позволяет разработать систему нематериального поощрения топ-менеджмента в государственных структурах регионов округа, а другая — систему материального поощрения. То есть первая группа характеризует эффективность решения общегосударственных задач, а вторая — эффективность решения задач, приоритетных для населения. Поскольку приоритеты населения важнее, эффективность их выполнения следует мотивировать материально. Реализацию общегосударственных задач тогда предлагается мотивировать нематериально.

3. Многоцелевой генетический алгоритм позволяет получить Парето-фронт для двухцелевой функции естественного прироста населения, все решения которого одинаково оптимальны. Выбирая любую точку Парето-фронта, можно найти в ней доли материальной и нематериальной мотивации топ-менеджеров. Они определяются близостью к крайним точкам Парето-фронта, в которых максимальна лишь одна из двух регрессий (мотиваций).

4. Вывод о фактическом поощрении (премировании) топ-менеджеров делается следующим образом. Для регрессий материальной и нематериальной мотивации оцениваются плановые значения естественного прироста населения в каждом регионе, исходя из значений факторов социально-экономического развития регионов России. Если фактический прирост населения положительный, то оценивается его близость к тому или иному плановому значению и соответственно выбираются доли нематериального и материального поощрения (премирования).

Полученные результаты могут быть полезны государственным структурам в целях разработки рациональной системы материальной и нематериальной мотивации своих топ-менеджеров.

## **5.2. Моделирование мотивации топ-менеджеров государственных структур регионов страны: трехцелевой генетический алгоритм**

Создание конкурентных преимуществ отечественной экономики невозможно без разработки и применения необходимых методов управления в государственных структурах страны. Соответствующие стратегии, например, “Национальная стратегия развития искусственного интеллекта на период до 2030 года” направлены на достижение подобных инновационных преимуществ РФ на глобальном рынке.

Метаэвристические алгоритмы являются составной частью технологий искусственного интеллекта и позволяют проводить глобальную оптимизацию процессов, имеющих большую размерность. К таким процессам следует отнести в том числе и мотивацию топ-менеджмента государственных структур как на уровне всей страны, так и на уровне ее регионов. При этом сложность построения рациональной системы мотивации топ-менеджеров связана с тем, что их можно мотивировать как материально, так и нематериально. Во втором случае мы имеем в виду прежде всего карьерный рост государственных служащих, занимающих серьезные руководящие посты.

Моделирование системы мотивации топ-менеджеров целесообразно начинать с изучения основополагающих принципов их мотивирования, которые принципиально отличаются от подходов, применяемых для мотивации рядовых работников.

Так, О. Хитрова и др. [93] установили, что своевременное выявление и диагностика проблемных ситуаций, возникающих на пути развития и роста организаций, существенно зависит от уровня квалификации и профессионализма руководителя.

Кроме того, согласно точке зрения А. Мунна [119] руководитель всегда имеет возможность влиять на других, и существует три типа навыков управленческого руководства: технические навыки, навыки межличностного общения и навыки принятия решений. Технические навыки в идеале связаны с возможностью использования методов и приемов для выполнения задачи. Межличностные навыки сосредоточены исключительно на способности понимать, общаться и хорошо работать с отдельными лицами и группами посредством развития эффективных отношений.

М. Н. Догар [56] изучил выявление динамики исключения внутренних заинтересованных сторон из процесса принятия организационных стратегических решений, а также ее влияния на эффективность и устойчивость деятельности организации. Автор предложил механизм предотвращения таких конфликтов в организациях социального развития, в частности, и организациях в целом.

Следующим важным этапом построения рациональной системы мотивации топ-менеджмента является создания необходимых для этого моделей. Так, Р. Кампф и др. [89] определили значительные различия между потребностями старших руководителей и работников — «синих воротничков», используя для этого *t*-тест Стьюдента с двумя выборками. По результатам тестирования ученые сделали вывод, что в сфере мотивационных факторов в Словакии невозможно установить единую мотивационную программу для анализируемых групп работников. В дальнейшем, после удовлетворения потребностей сотрудников, не исключено, что со смелой требований может измениться и мотивация.

Еще одной удачной моделью стала модель управления мотивацией работы руководителей, оформленной в виде структурно-логической схемы, основанной на системном подходе и разложении и отражающей взаимодействие субъекта и объекта в процессе формирования и внедрения системы мотивации руководителей на предприятии (И. Попадинец и др. [131]). По методу линейной множественной регрессии была построена система уравнений для описания экономико-математической модели мотивации менеджмента на нефтегазовых предприятиях, которая после повтор-

ных экспериментов обеспечивала диагностику показателей до, во время и после реализации модели мотивации менеджмента.

Мотивация в государственном секторе заслуживает от дельного пристального внимания в процессе моделирования топ-менеджмента. Так, Г. Шварц, Н. Эва и А. Ньюмен [142], чтобы лучше понять лидерство в государственном секторе, рассмотрели связь между подотчетностью, следованием правилам, политической лояльностью и подходами к управлению сетью для руководства и мотивации сотрудников к государственной службе (PSM) и индивидуальной работой. Используя выборку из 300 гражданских служащих и их 64 менеджеров в Китае, исследование показывает, что подотчетность, следование правилам, политическая лояльность и руководство сетью в значительной степени положительно связаны с уровнями PSM-сотрудников и эффективностью работы.

Поскольку в представляемом нами подходе мы применяем для моделирования мотивации топ-менеджмента государственных структур многоцелевой генетический алгоритм, принадлежащий классу метаэвристических алгоритмов, исследуем его преимущества и последние достижения в различных областях научного знания.

Сам по себе многоцелевой генетический алгоритм (MGA) — это метод прямого поиска задач многоцелевой оптимизации. Он основан на процессе генетического алгоритма; популяционное свойство генетического алгоритма хорошо применяется в MGA. Сравнивая с традиционным многоцелевым алгоритмом, целью которого является поиск единого решения Парето, MGA пытается определить количество решений Парето [108].

А. Фита [67] своей исследовательской целью поставил нахождение четко определенной и значимой аппроксимации набора решений для линейных и нелинейных трехцелевых задач оптимизации, поскольку для лица, принимающего решение, важно получить как можно больше информации о наборе возможных решений. Автор использовал непрерывный вариабельный генетический алгоритм, чтобы найти приближительный почти оптимальный набор решений.

А. Хан и А. Р. Байг [90] представили метод, основанный на эволюционном алгоритме, для решения задачи выбора многоцелевого подмножества признаков. Таким образом, перед построением классификатора необходимо выбрать подмножество элементов. Эта предложенная методика рассматривает выбор подмножества признаков как многоцелевую задачу оптимизации. В этом исследовании используется один из последних многоцелевых генетических алгоритмов.

С. Дас, Ш. Чаудхури и А. К. Дас [53] предложили метод кластерного анализа на основе многоцелевого генетического алгоритма для нахождения оптимального набора перекрывающихся кластеров. Общая производительность метода исследуется на некоторых популярных наборах данных и микрочипов, и оптимальность кластеров измеряется некоторыми важными индексами проверки кластера. Экспериментальные результаты показывают эффективность предлагаемого способа.

Б. Ли и Б. Джин [107] представили исследования по стратегии перепланирования сроков и новому гибриднему генетическому алгоритму для включения новой

задачи обработки. При этом, во-первых, временной интервал устанавливается в соответствии с моментом времени новой задачи, и гарантируется оптимизация многозначного планирования. Затем за счет совершенствования генетического алгоритма и объединения с моделируемым алгоритмом отжига представлен новый гибридный алгоритм, реализующий оптимизационную обработку в гибком планировании цеха. Эксперимент показывает, что алгоритм улучшает возможности глобальной оптимизации. Наконец, результаты моделирования показывают, что алгоритм может получить решение Парето более высокого качества при статическом планировании и вставке новой задачи.

Как утверждают В. Тананант и С. Ауванатамонгкол [152], контролируемая кластеризация стремится достичь нескольких целей, таких как компактность кластеров, однородность данных в кластерах по отношению к их меткам классов и раздельность кластеров. С учетом этих целей ученые предложили новый контролируемый алгоритм кластеризации, основанный на многоцелевом генетическом алгоритме скопления, названном SC-MOGA. Алгоритм ищет оптимальное решение кластеризации, которое одновременно достигает трех указанных целей. Экспериментальные результаты показывают, что предлагаемый метод выборки данных не только помогает сократить число экземпляров данных, подлежащих кластеризации с помощью SC-MOGA, но и повышает качество результатов кластеризации данных.

М. Сардараз и М. Тахир [141] представили многоцелевой алгоритм планирования для планирования научных рабочих процессов в облачных вычислениях. Результаты показывают, что предложенный алгоритм обеспечивает улучшение времени выполнения и снижает стоимость при использовании системы, сбалансированной по нагрузке.

Дж. Ванг и др. [159] разработали математическую модель многоцелевой оптимизации на основе генетического алгоритма (GA) для проектирования конструкции сгорающих ядов в реакторе под давлением. Затем была разработана программа оптимизации путем объединения параллельного многоцелевого GA с транспортным кодом частиц Монте-Карло в качестве решателя нейтроники и истощения.

А. Магхаури и др. [109] предложили гибридный генетический алгоритм (HGA), который использует генетический алгоритм (GA) для выполнения глобального поиска, поддерживаемого алгоритмом оптимизации роя частиц (PSO), для выполнения локального поиска. Предложенный алгоритм был опробован на основе 4 контрольных многоцелевых функций оптимизации, где удалось достичь максимального баланса между поисковой разведкой и поисковой эксплуатацией космоса. Алгоритм также преуспел в улучшении общей производительности HGA путем ограничения среднего числа итераций до сходимости.

М. Никсерешт и М. Раджи [123] для гетерогенной встраиваемой системы представили новое многоцелевое отображение и планирование задач на основе генетических алгоритмов (сокращенно MOGATS). Задачи картирования и планирования моделируются как подход оптимизации на основе генетических алгоритмов. Таким образом, авторский инструмент планирования задач является первым многоцелевым планированием задач на стадии проектирования встроженных систем, чтобы

помочь проектировщику определить, какой набор планирования обеспечит их желаемый результат.

Однако многоцелевой генетический алгоритм (MGA) требует проверки его решений в крайних точках полученного Парето-фронта, для чего мы будем использовать в нашем исследовании алгоритм поиска по шаблону (Direct Search, Pattern Search) в силу его высокого качества оптимизации. Опишем ряд его преимуществ.

В условиях неопределенности и турбулентности классические и традиционные подходы не способны с удовлетворением найти полное решение реальных проблем оптимизации. Поэтому для серьезного решения этих проблем требуются новые методы глобальной оптимизации. Одним из таких методов являются гибридные генетические алгоритмы и поиск шаблонов, универсальная, гибкая, надежная и универсальная структура для решения сложных задач глобальной оптимизации и поиска в реальных приложениях [156].

Производительность алгоритма поиска по шаблону была тщательно протестирована Е. Байенсом, А. Херреросом и Ж. Р. Пераном [39] с использованием функций эталона и сопоставлена с некоторыми известными алгоритмами глобальной оптимизации. Результаты исследования показывают, что алгоритм сочетает в себе простоту и эффективность и конкурентоспособен со стратегиями на основе эвристики, используемыми в настоящее время для глобальной оптимизации.

Наконец, предлагаемый нами подход к необходимости проверки решений MGA с помощью других алгоритмов глобальной оптимизации применяется также и другими авторами, которые используют для этого иные алгоритмы, отличные от поиска по шаблону. Так, Г. Джорджио и М. Санджорджио [71] утверждают, что полный взгляд на границу возможен, если сначала решить одноцелевые задачи, соответствующие крайностям границы Парето, а затем использовать такие решения в качестве элитных представителей первоначального решения. Эти ученые этот подход сравнивают с более привычной инициализацией с использованием некоторых классических тестов с переменным числом целей и известных аналитических решений.

В работе С. Яшина и др. [162] уже решалась более простая задача материальной и нематериальной мотивации топ-менеджмента управляющих структур регионов и округов. Для этого оценивалась эффективность межкластерного взаимодействия внутри одного федерального округа с помощью системы факторов социально-экономического развития регионов России, непосредственно влияющих на естественный прирост населения в регионах округа. Для решения поставленной задачи также применялся MGA, который позволил получить Парето-фронт для двухцелевой функции естественного прироста населения, все решения которого одинаково оптимальны. Выбирая любую точку Парето-фронта, можно найти в ней доли материальной и нематериальной мотивации топ-менеджеров.

Однако теперь исследуется более сложная задача трехцелевой глобальной оптимизации мотивации топ-менеджмента государственных структур регионов, что позволит поставить нематериальную мотивацию топ-менеджеров в зависимость от достигнутого стратегического потенциала региона и их материальной мотивации. Кроме того, новая задача решается для регионов всей страны, в которых имеются

инновационные территориальные кластеры из перечня, утвержденного Правительством РФ.

С целью моделирования мотивации топ-менеджмента государственных структур регионов определим трехцелевую целевую функцию — коэффициент естественного прироста населения на 1 000 человек:

$$y_{\max} = f_m(x_1, x_2, x_3), \quad m = \overline{1, 3},$$

где  $f_1$  — нематериальная мотивация топ-менеджмента;

$f_2$  — материальная мотивация топ-менеджмента;

$f_3$  — стратегический потенциал региона.

Каждая из данных целей зависит от трех факторов  $x_1, x_2, x_3$  в одной системе координат  $(x_1, x_2, x_3, y)$ .

Моделирование мотивации топ-менеджмента государственных структур регионов с учетом внешних и внутренних связей, применяя для этого MGA, будем проводить в несколько этапов (рис. 55).

**Этап 1 — сбор данных о социально-экономическом развитии регионов с инновационными кластерами.** Эффективное межкластерное взаимодействие внутри страны принимает экономико-финансовый, информационный и логистический характер. Для регионов с инновационными территориальными кластерами это будут внешние связи, а для кластеров внутри региона — внутренние. Также следует учитывать внешние связи регионов с другими странами. Эффективность подобного взаимодействия можно оценить, используя систему оценки социально-экономического развития регионов России с помощью мест, занимаемых данными субъектами в РФ, по ряду факторов:

- 1) валовой региональный продукт (ВРП) на душу населения ( $x_1$ );
- 2) инвестиции в основной капитал на душу населения ( $x_2$ );
- 3) внутренние затраты на научно-исследовательские работы (НИР) ( $x_3$ );
- 4) среднедушевые денежные доходы населения (в месяц) ( $x_1$ );
- 5) общая площадь жилых помещений на душу населения ( $x_2$ );
- 6) удельный вес автодорог с твердым покрытием ( $x_3$ );
- 7) поступление налогов на душу населения ( $x_1$ );
- 8) уровень занятости населения ( $x_2$ );
- 9) численность студентов на 10 000 человек населения ( $x_3$ ).

Данные факторы непосредственно влияют на значение коэффициента естественного прироста населения на 1 000 человек ( $y$ ) в регионах страны.

Первые три фактора характеризуют систему нематериального поощрения топ-менеджеров в государственных структурах, следующие три — систему их материального поощрения, а последние три — имеющийся стратегический потенциал региона, необходимый для его дальнейшего успешного развития. При этом первые три фактора отражают эффективность решения общегосударственных задач, а следующие три — эффективность решения приоритетных для населения задач. Приоритеты населения важнее, следовательно, эффективность их выполнения нужно мотивировать материально. Реализацию же общегосударственных задач мы рекомендуем мотивировать нематериально.

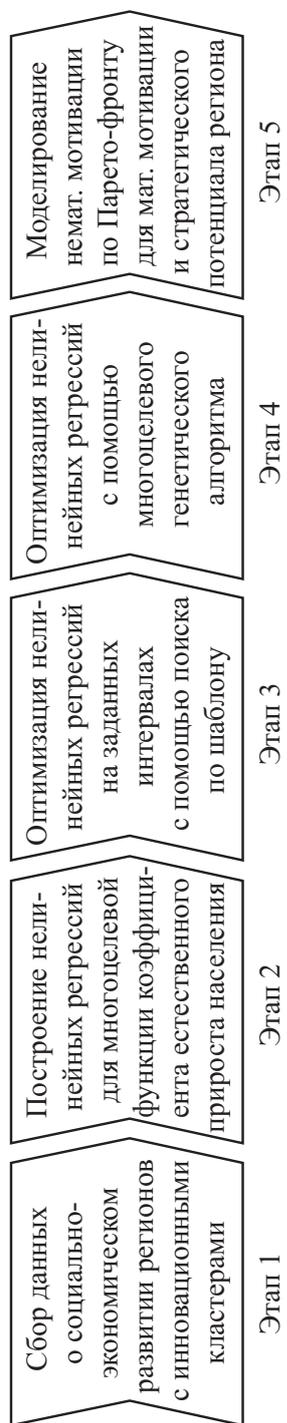


Рис. 55. Этапы моделирования мотивации топ-менеджмента государственных структур регионов

Однако, как уже указывалось ранее, нематериальная мотивация топ-менеджеров — это прежде всего возможность их карьерного роста. Мы определяем эту возможность в зависимости от успешности выполнения приоритетных для населения задач, а также от успешности наращивания стратегического потенциала региона. Таким образом, построение множества эффективных решений с помощью Парето-фронта будет выполняться для двух первоочередных целей — стратегический потенциал региона и материальная мотивация топ-менеджмента, после чего уже как следствие будет получено множество оптимальных решений для нематериальной мотивации.

**Этап 2 — построение нелинейных регрессий для многоцелевой функции коэффициента естественного прироста населения.** На этом этапе для стратегического потенциала региона и материальной мотивации топ-менеджмента получаем необходимые нелинейные регрессии, к примеру, в программе *Statistica*, которые затем будут использоваться нами с целью глобальной оптимизации трехцелевой функции коэффициента естественного прироста населения ( $y$ ).

**Этап 3 — оптимизация нелинейных регрессий на заданных интервалах с помощью поиска по шаблону.** В России имеется 85 субъектов (регионов). Поэтому сегмент, на котором будем оптимизировать трехцелевую функцию  $y$ , составит значения [1; 85]. Поиск ее глобальных наибольших значений для каждой нелинейной регрессии, используя для этого алгоритм поиска по шаблону, позволит проверить крайние значения Парето-фронта, который мы получим впоследствии, используя MGA.

**Этап 4 — оптимизация нелинейных регрессий с помощью многоцелевого генетического алгоритма.** Данный алгоритм позволяет получить фронт Парето для двухцелевой функции, все точки которого являются одинаково оптимальными решениями. Он отражает набор наибольших  $y$ , а также значений его факторов  $x_1$ ,  $x_2$ ,  $x_3$ . Таким образом, выбирая любую точку Парето-фронта, можно найти в ней оптимальные значения функций стратегического потенциала и материальной мотивации, а также соответствующие им значения факторов  $x_1$ ,  $x_2$ ,  $x_3$ .

**Этап 5 — моделирование нематериальной мотивации по Парето-фронту для материальной мотивации и стратегического потенциала региона.** Проводя двухцелевую оптимизацию, мы одновременно получаем в пакете *Matlab* значение третьей функции — нематериальной мотивации — в каждой точке, соответствующей фронту Парето для первых двух функций. Это позволяет спланировать нематериальную мотивацию топ-менеджеров в зависимости от выполнения приоритетных для населения задач, а также наращивания стратегического потенциала, необходимого для развития региона.

Вывод о фактическом премировании (поощрении) топ-менеджеров государственных структур регионов делается следующим образом. Для каждой из трех функций в конкретном регионе сравниваем последние фактические значения факторов  $x_1$ ,  $x_2$ ,  $x_3$  с ближайшими плановыми (оптимальными) значениями. Положительное отклонение от оптимума оцениваем позитивно, что позволяет дополнитель-

но поощрять топ-менеджеров материально либо нематериально. Отрицательное отклонение свидетельствует о принятии ими в прошлом некачественных управленческих решений, что, безусловно, должно отразиться на их поощрении.

**Пример 8.** Рассмотрим процесс моделирования мотивации топ-менеджмента государственных структур регионов страны, применяя для этого MGA. В конце сделаем выводы для конкретного региона.

Согласно перечню, который утвержден Правительством РФ, в России действуют 25 пилотных инновационных территориальных кластеров по соответствующим регионам страны. По этой причине будем изучать только те регионы (области или республики), в которых находятся кластеры из указанного перечня.

**Этап 1 — сбор данных о социально-экономическом развитии регионов с инновационными кластерами.** Используя показатели “Статистического обзора” Федеральной службы государственной статистики, соберем необходимые данные за 10 лет с 2010 по 2019 г. для исследуемых регионов (табл. 28). Получается матрица размерности  $200 \times 10$ .

**Этап 2 — построение нелинейных регрессий для многоцелевой функции коэффициента естественного прироста населения.** По данным табл. 28 в пакете *Statistica* можем получить три наиболее достоверные множественные нелинейные регрессии:

— нематериальная мотивация (рис. 56) —

$$y = 9,96172 + 0,1769 x_1 + 0,3188 x_3 - 1,32628\sqrt{x_1} - 4,052206\sqrt{x_3} - 1,04676 \ln x_2 + 2,72664 \ln x_3 ,$$

Regression Summary for Dependent Variable: Var10 (Regions_3.sta)						
R= ,92594578 R²= ,85737558 Adjusted R²= ,84515063						
F(6,70)=70,133 p<0,0000 Std.Error of estimate: 1,0057						
N=77	b*	Std.Err. of b*	b	Std.Err. of b	t(70)	p-value
<b>Intercept</b>			9,96172	1,784829	5,58133	0,000000
Var3	2,93552	0,692518	0,31880	0,075207	4,23890	0,000067
SQRV3	-3,63084	1,065548	-4,05206	1,189163	-3,40748	0,001090
LN-V3	1,32485	0,497763	2,72664	1,024436	2,66160	0,009638
LN-V2	-0,23202	0,079658	-1,04676	0,359385	-2,91264	0,004806
Var1	1,43075	0,542308	0,17690	0,067053	2,63825	0,010262
SQRV1	-0,94981	0,545310	-1,32628	0,761453	-1,74178	0,085939

Рис. 56. Регрессия нематериальной мотивации

— материальная мотивация (рис. 57) —

$$y = -2,77578 + 0,30824 x_2 - 0,01069 x_2^2 + 0,00001 x_1^3 + 0,00009 x_2^3 - 0,00001 x_3^3 + 1,18178 \ln x_1 ,$$

Данные для построения регрессионных моделей

Регион	Место, занимаемое субъектом в РФ						Функция			
	Нематериал. мотивация			Материал. мотивация						
	$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$				
2019 год										
1. Калужская область	27	31	20	27	10	65	25	20	59	-5,7
2. Московская область	16	19	3	9	1	23	22	8	80	-2,5
3. Москва	6	10	1	4	82	1	6	6	2	1,2
4. Архангельская область	33	47	48	19	28	66	34	70	68	-4,4
5. Ленинградская область	17	11	18	24	17	26	16	24	82	-5,3
6. Санкт-Петербург	9	23	2	10	47	2	10	7	1	-0,1
7. Республика Башкортостан	44	50	16	32	46	10	30	67	38	-1,8
8. Республика Мордовия	63	65	56	81	30	76	57	19	13	-5,7
9. Республика Татарстан	15	14	11	16	37	34	12	17	6	-0,1
10. Пермский край	24	28	10	31	65	50	20	71	51	-3,0
11. Нижегородская область	34	41	4	20	33	49	31	16	29	-5,6
12. Самарская область	29	42	9	35	35	82	17	21	21	-3,9
13. Ульяновская область	60	70	15	70	23	46	38	60	22	-5,0
14. Свердловская область	22	33	5	14	45	29	32	43	26	-2,6
15. Республика Алтай	76	78	40	69	63	53	68	61	47	3,5
16. Красноярский край	10	17	6	26	55	19	9	22	39	-1,7
17. Кемеровская область	47	27	45	63	57	22	54	63	65	-5,2
18. Новосибирская область	35	45	7	33	50	44	40	33	8	-2,0
19. Томская область	23	43	12	41	62	52	13	39	3	-1,4
20. Хабаровский край	20	24	38	13	67	11	28	15	12	-2,4

Регион	Место, занимаемое субъектом в РФ						Функция			
	Нематериал. мотивация			Материал. мотивация						
	$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$				
2018 год										
1. Калужская область	32	39	20	29	12	66	23	15	63	-4,7
2. Московская область	19	23	2	10	1	24	22	9	80	-1,2
3. Москва	6	11	1	4	81	1	6	5	1	0,8
4. Архангельская область	29	36	46	19	26	65	40	68	67	-3,7
5. Ленинградская область	16	9	19	21	18	26	16	23	82	-5,3
6. Санкт-Петербург	12	17	3	9	50	2	9	6	2	0,8
7. Республика Башкортостан	44	56	16	31	46	9	26	60	38	-0,8
8. Республика Мордовия	61	60	55	80	29	76	57	38	12	-5,1
9. Республика Татарстан	15	13	9	18	40	34	13	13	6	0,5
10. Пермский край	26	35	11	34	64	50	20	66	52	-2,2
11. Нижегородская область	40	44	4	20	33	49	32	16	31	-5,1
12. Самарская область	28	43	12	35	37	82	17	17	18	-3,1
13. Ульяновская область	63	58	15	70	25	44	42	56	21	-4,6
14. Свердловская область	23	48	5	14	45	33	33	47	26	-1,9
15. Республика Алтай	73	55	81	79	76	40	73	77	78	5,2
16. Красноярский край	11	16	7	25	57	18	11	21	33	-0,7
17. Кемеровская область	30	32	47	67	56	21	41	67	65	-4,5
18. Новосибирская область	34	50	6	32	53	48	38	41	10	-1,3
19. Томская область	21	37	10	38	61	51	10	46	3	-0,2
20. Хабаровский край	22	31	35	13	67	11	30	10	8	-1,4

Регион	Место, занимаемое субъектом в РФ									Функция
	Нематериал. мотивация			Материал. мотивация			Стратег. потенциал			
	$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$	
2017 год										
1. Калужская область	32	38	21	29	11	68	29	15	65	-4,0
2. Московская область	17	30	3	10	1	24	23	7	81	-0,4
3. Москва	6	12	1	4	80	1	5	4	1	1,1
4. Архангельская область	29	28	47	18	25	66	36	55	67	-2,7
5. Ленинградская область	16	10	20	31	19	30	9	12	82	-5,0
6. Санкт-Петербург	9	18	2	9	52	2	8	5	3	1,1
7. Республика Башкортостан	46	52	16	27	47	9	32	53	36	-0,3
8. Республика Мордовия	62	46	59	80	29	77	47	19	12	-5,0
9. Республика Татарстан	15	11	8	17	38	35	14	13	7	1,1
10. Пермский край	23	27	10	26	66	52	18	61	54	-1,2
11. Нижегородская область	39	45	4	20	32	49	31	11	31	-4,2
12. Самарская область	27	39	11	35	36	81	17	16	17	-2,9
13. Ульяновская область	60	47	13	62	27	45	41	41	21	-3,9
14. Свердловская область	21	40	5	14	44	31	33	44	24	-1,0
15. Республика Алтай	74	58	79	79	78	40	73	77	77	6,1
16. Красноярский край	12	14	9	30	56	19	11	34	32	0,1
17. Кемеровская область	38	42	38	69	55	21	43	65	62	-3,6
18. Новосибирская область	33	55	7	44	54	48	37	39	10	-0,5
19. Томская область	22	33	12	52	62	50	12	71	2	0,5
20. Хабаровский край	19	34	25	12	67	10	28	14	19	-1,0

Регион	Место, занимаемое субъектом в РФ						Функция			
	Нематериал. мотивация			Материал. мотивация						
	$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$		$x_1$	$x_2$	$x_3$
2016 год										
1. Калужская область	35	37	15	24	12	68	31	15	66	-2,9
2. Московская область	17	30	3	10	1	24	21	8	81	0,1
3. Москва	6	14	1	4	78	1	6	3	1	1,8
4. Архангельская область	32	32	44	19	23	64	44	67	71	-1,9
5. Ленинградская область	15	12	21	34	25	30	10	20	83	-4,8
6. Санкт-Петербург	9	19	2	8	53	2	8	5	2	2,1
7. Республика Башкортостан	45	28	16	28	48	10	32	55	40	0,8
8. Республика Мордовия	62	47	56	81	29	76	48	14	12	-4,3
9. Республика Татарстан	16	10	11	16	36	37	14	10	8	2,7
10. Пермский край	23	27	9	26	66	50	24	57	50	0,3
11. Нижегородская область	37	46	4	20	33	48	30	13	30	-3,5
12. Самарская область	27	33	12	36	38	81	15	11	19	-1,4
13. Ульяновская область	59	60	17	62	28	45	42	41	23	-3,2
14. Свердловская область	20	35	5	14	45	31	33	39	31	-0,2
15. Республика Алтай	70	54	79	80	77	40	73	78	77	8,1
16. Красноярский край	13	13	8	29	52	23	13	45	29	1,4
17. Кемеровская область	48	53	43	71	56	21	56	63	63	-2,2
18. Новосибирская область	28	61	6	41	54	47	35	40	10	0,8
19. Томская область	21	25	13	49	61	51	11	65	3	1,8
20. Хабаровский край	18	29	34	12	65	12	28	17	11	0,3

Регион	Место, занимаемое субъектом в РФ						Функция			
	Нематериал. мотивация			Материал. мотивация						
	$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$		$x_1$	$x_2$	$x_3$
2015 год										
1. Калужская область	39	26	15	29	12	70	28	20	65	-2,4
2. Московская область	18	27	2	11	1	24	21	9	81	-0,1
3. Москва	6	13	1	4	78	1	6	3	1	1,7
4. Архангельская область	33	69	45	20	23	61	34	51	72	-1,4
5. Ленинградская область	15	18	18	46	34	29	11	21	83	-5,0
6. Санкт-Петербург	11	22	3	9	57	2	9	5	3	1,7
7. Республика Башкортостан	43	34	17	26	49	12	30	54	39	1,2
8. Республика Мордовия	63	46	56	80	26	76	48	15	12	-4,4
9. Республика Татарстан	16	10	12	17	36	38	15	12	7	2,7
10. Пермский край	23	30	11	18	65	56	20	65	50	0,5
11. Нижегородская область	41	40	4	21	28	45	32	17	33	-3,2
12. Самарская область	28	25	7	27	41	78	17	10	17	-1,4
13. Ульяновская область	62	38	16	56	28	43	47	48	28	-3,0
14. Свердловская область	22	33	5	14	44	30	33	30	27	0,3
15. Республика Алтай	73	62	79	78	77	40	65	69	80	7,9
16. Красноярский край	12	11	8	31	52	17	12	40	26	1,7
17. Кемеровская область	48	52	43	67	53	20	52	63	62	-2,0
18. Новосибирская область	30	55	6	51	54	47	35	42	10	1,1
19. Томская область	19	23	13	44	60	49	10	77	2	2,1
20. Хабаровский край	20	32	39	13	62	10	26	28	9	0,9

Регион	Место, занимаемое субъектом в РФ									Функция
	Нематериал. мотивация			Материал. мотивация			Стратег. потенциал			
	$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$	
2014 год										
1. Калужская область	32	20	13	29	12	70	25	23	69	-3,5
2. Московская область	21	30	2	9	1	27	21	10	79	-1,3
3. Москва	6	12	1	4	79	2	6	4	1	1,6
4. Архангельская область	34	60	43	20	22	61	41	58	74	-0,9
5. Ленинградская область	17	19	19	55	41	32	11	22	84	-5,4
6. Санкт-Петербург	11	21	3	10	69	3	10	5	2	1,3
7. Республика Башкортостан	36	38	16	25	49	12	30	60	44	1,7
8. Республика Мордовия	62	41	55	79	24	78	38	15	15	-4,3
9. Республика Татарстан	14	9	10	16	39	39	15	14	8	2,5
10. Пермский край	23	36	12	19	66	51	18	68	53	0,7
11. Нижегородская область	35	28	4	21	29	46	31	18	28	-4,0
12. Самарская область	25	24	9	24	44	79	17	12	19	-1,7
13. Ульяновская область	60	45	15	53	35	33	53	52	31	-2,7
14. Свердловская область	20	29	5	13	43	31	33	35	30	0,5
15. Республика Алтай	73	46	79	75	78	40	71	72	81	9,6
16. Красноярский край	12	13	7	30	53	19	13	26	32	1,7
17. Кемеровская область	47	27	41	63	51	18	52	47	66	-1,4
18. Новосибирская область	30	43	6	38	58	48	34	36	10	0,7
19. Томская область	19	18	14	52	59	44	8	59	3	2,0
20. Хабаровский край	16	26	42	14	61	8	24	24	6	0,7

Регион	Место, занимаемое субъектом в РФ						Функция					
	Нематериал. мотивация			Материал. мотивация								
	$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$		$x_1$	$x_2$	$x_3$	$y$	
2013 год												
1. Калужская область	31	22	12	12	28	12	67	14	29	14	64	-3,5
2. Московская область	20	29	2	2	10	13	29	8	21	8	76	-1,8
3. Москва	5	15	1	1	3	77	2	4	6	4	1	1,7
4. Архангельская область	30	37	45	45	21	21	58	48	39	48	70	-0,7
5. Ленинградская область	16	13	19	19	46	65	30	12	11	12	82	-5,6
6. Санкт-Петербург	11	33	3	3	12	46	1	5	10	5	2	0,7
7. Республика Башкортостан	26	40	16	16	26	49	9	60	28	60	37	1,5
8. Республика Мордовия	64	39	52	52	80	27	77	10	57	10	15	-4,7
9. Республика Татарстан	14	12	10	10	17	38	40	14	14	14	9	2,6
10. Пермский край	23	34	9	9	18	58	46	55	16	55	53	0,7
11. Нижегородская область	36	26	4	4	24	28	44	20	30	20	28	-4,1
12. Самарская область	25	27	6	6	16	45	75	17	13	17	19	-2,0
13. Ульяновская область	61	48	15	15	60	33	27	41	52	41	32	-2,8
14. Свердловская область	19	28	5	5	13	42	32	31	31	31	27	0,7
15. Республика Алтай	75	57	76	76	77	78	34	71	69	71	79	9,8
16. Красноярский край	12	14	11	11	20	52	20	36	80	36	33	1,7
17. Кемеровская область	46	31	47	47	54	50	18	47	51	47	61	-0,9
18. Новосибирская область	27	42	7	7	29	57	47	37	32	37	10	0,7
19. Томская область	17	19	14	14	44	60	43	76	9	76	3	2,1
20. Хабаровский край	21	17	40	40	14	61	8	27	35	27	6	0,6

Регион	Место, занимаемое субъектом в РФ						Функция			
	Нематериал. мотивация			Материал. мотивация						
	$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$				
2012 год										
1. Калужская область	27	23	11	30	15	71	25	14	64	-4,1
2. Московская область	19	37	3	10	1	32	21	6	78	-2,4
3. Москва	6	25	1	3	76	3	5	5	1	1,4
4. Архангельская область	34	16	45	19	21	66	48	36	71	-1,2
5. Ленинградская область	14	9	18	46	13	30	19	8	81	-5,7
6. Санкт-Петербург	11	36	2	13	40	1	11	4	2	0,2
7. Республика Башкортостан	30	47	16	26	54	10	30	52	40	1,4
8. Республика Мордовия	69	41	56	79	27	79	57	17	16	-4,5
9. Республика Татарстан	15	17	10	18	43	41	13	13	10	2,3
10. Пермский край	21	42	12	20	63	45	16	47	49	0,6
11. Нижегородская область	37	29	4	23	30	46	32	12	25	-4,3
12. Самарская область	26	40	5	17	51	57	12	19	17	-1,8
13. Ульяновская область	58	48	14	63	39	19	53	43	36	-2,7
14. Свердловская область	20	27	6	14	41	25	31	31	27	0,3
15. Республика Алтай	74	66	76	73	79	38	73	72	76	10,9
16. Красноярский край	12	13	9	21	52	21	9	33	38	1,5
17. Кемеровская область	35	22	46	41	53	13	39	58	63	-1,4
18. Новосибирская область	44	44	7	29	61	49	33	32	11	0,3
19. Томская область	18	20	15	47	59	42	8	79	3	1,7
20. Хабаровский край	22	15	37	16	58	5	23	30	6	0,2

Регион	Место, занимаемое субъектом в РФ						Функция			
	Нематериал. мотивация			Материал. мотивация						
	$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$		$x_1$	$x_2$	$x_3$
2011 год										
1. Калужская область	34	30	10	31	15	75	30	15	59	-4,5
2. Московская область	17	45	2	12	2	54	19	7	78	-3,1
3. Москва	4	27	1	2	78	1	5	4	1	1,1
4. Архангельская область	10	16	49	18	22	71	45	22	67	-1,9
5. Ленинградская область	15	8	19	47	14	19	14	9	81	-6,1
6. Санкт-Петербург	8	39	3	10	42	2	9	5	2	-0,9
7. Республика Башкортостан	31	56	16	23	58	28	26	51	44	0,4
8. Республика Мордовия	60	42	57	78	29	77	60	10	21	-5,3
9. Республика Татарстан	12	19	11	20	43	57	17	12	8	1,0
10. Пермский край	18	48	12	19	62	38	21	37	49	-0,6
11. Нижегородская область	33	32	4	27	31	40	33	27	20	-5,4
12. Самарская область	26	36	7	17	49	49	15	18	18	-2,9
13. Ульяновская область	53	50	14	65	39	17	56	38	35	-4,0
14. Свердловская область	20	23	5	14	40	32	29	31	31	-0,6
15. Республика Алтай	70	40	77	71	79	41	54	73	77	10,5
16. Красноярский край	9	17	9	21	48	43	13	33	42	0,5
17. Кемеровская область	24	25	44	38	53	5	32	60	66	-2,8
18. Новосибирская область	41	46	6	29	61	51	31	28	9	-0,5
19. Томская область	16	22	15	40	65	56	8	72	3	0,8
20. Хабаровский край	19	13	40	16	56	4	24	21	6	-1,6

Регион	Место, занимаемое субъектом в РФ						Функ-				
	Нематериал. мотивация			Материал. мотивация			Стратег. потенциал				
	$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$	ция	$y$
2010 год											
1. Калужская область	39	22	10	35	19	74	30	13	55	-5,5	
2. Московская область	18	35	2	15	2	59	19	8	78	-4,5	
3. Москва	4	29	1	2	78	1	5	4	1	-0,3	
4. Архангельская область	13	23	50	19	16	72	45	35	66	-2,3	
5. Ленинградская область	12	6	18	43	9	24	14	11	81	-7,0	
6. Санкт-Петербург	9	20	3	10	41	2	9	5	2	-2,0	
7. Республика Башкортостан	35	57	20	22	62	31	26	63	44	0,6	
8. Республика Мордовия	61	41	54	74	34	53	60	12	19	-6,2	
9. Республика Татарстан	15	18	13	20	45	63	17	17	9	-0,2	
10. Пермский край	20	34	9	18	61	45	21	36	51	-1,2	
11. Нижегородская область	32	31	4	27	33	48	33	27	18	-7,0	
12. Самарская область	27	46	6	17	51	55	15	16	17	-3,6	
13. Ульяновская область	57	55	17	64	39	20	56	65	37	-5,1	
14. Свердловская область	19	32	5	16	42	33	29	32	29	-0,9	
15. Республика Алтай	71	40	73	57	79	51	54	71	77	8,3	
16. Красноярский край	7	15	11	21	46	16	13	14	41	0,1	
17. Кемеровская область	22	39	46	33	54	6	32	57	65	-3,0	
18. Новосибирская область	40	47	7	28	59	57	31	30	7	-0,7	
19. Томская область	14	21	14	38	63	61	8	41	3	0,4	
20. Хабаровский край	16	11	39	14	55	9	24	37	6	-1,7	

Regression Summary for Dependent Variable: Var10 (Regions_3.sta)						
R= ,90849012 R?= ,82535430 Adjusted R?= ,81038467						
F(6,70)=55,135 p<0,0000 Std.Error of estimate: 1,1129						
N=77	b*	Std.Err. of b*	b	Std.Err. of b	t(70)	p-value
Intercept			-2,77578	1,445985	-1,91965	0,058979
V4**3	0,41765	0,132844	0,00001	0,000002	3,14391	0,002446
V5**3	5,51764	1,081397	0,00009	0,000018	5,10233	0,000003
V5**2	-6,88600	1,494558	-0,01069	0,002319	-4,60739	0,000018
Var5	1,77997	0,505659	0,30824	0,087565	3,52010	0,000763
LN-V4	0,40928	0,130853	1,18178	0,377837	3,12777	0,002567
V6**3	-0,12534	0,063423	-0,00001	0,000003	-1,97632	0,052060

Рис. 57. Регрессия материальной мотивации

— стратегический потенциал (рис. 58) —

$$y = 15,0191 - 0,2383 x_1 + 0,1342 x_2 + 0,4561 x_3 + 8,1069\sqrt{x_1} - 1,4168\sqrt{x_2} - 7,4633\sqrt{x_3} - 13,0338 \ln x_1 + 6,8303 \ln x_3 .$$

Regression Summary for Dependent Variable: Var10 (Regions_3.sta)						
R= ,88245455 R?= ,77872604 Adjusted R?= ,75269381						
F(8,68)=29,914 p<0,0000 Std.Error of estimate: 1,2709						
N=77	b*	Std.Err. of b*	b	Std.Err. of b	t(68)	p-value
Intercept			15,0191	2,906653	5,16714	0,000002
Var7	-1,90463	1,940789	-0,2383	0,242775	-0,98137	0,329889
SQRV7	5,93936	3,810889	8,1069	5,201640	1,55852	0,123751
Var9	4,70427	0,887557	0,4561	0,086052	5,30024	0,000001
SQRV9	-7,87952	1,619837	-7,4633	1,534268	-4,86439	0,000007
LN-V9	3,91653	0,976773	6,8303	1,703455	4,00966	0,000154
LN-V7	-3,99155	2,031972	-13,0338	6,635115	-1,96437	0,053575
Var8	1,35475	0,775240	0,1342	0,076766	1,74752	0,085062
SQRV8	-1,32725	0,802079	-1,4168	0,856196	-1,65477	0,102581

Рис. 58. Регрессия стратегического потенциала

**Этап 3 — оптимизация нелинейных регрессий на заданных интервалах с помощью поиска по шаблону.** Оптимизация регрессий в пакете *Matlab* на сегменте [1; 85], используя алгоритм поиска по шаблону, дает результаты:

— для нематериальной мотивации —

$$y_{\max} = 14,6 \text{ при } (x_1, x_2, x_3) = (85; 1; 85),$$

— для материальной мотивации —

$$y_{\max} = 12,9 \text{ при } (x_1, x_2, x_3) = (85; 85; 1),$$

— для стратегического потенциала —

$$y_{\max} = 21,9 \text{ при } (x_1, x_2, x_3) = (85; 1; 85).$$

**Этап 4 — оптимизация нелинейных регрессий с помощью многоцелевого генетического алгоритма.** Подход MGA позволяет получить в пакете *Matlab* фронт Парето для функции двух целей — стратегического потенциала и материальной мотивации (рис. 59–61).

```
function f = mymulti3(x)
f(1) = - 15.0191 + 0.2383*x(1) - 0.1342*x(2) - 0.4561*x(3) ...
      - 8.1069*sqrt(x(1)) + 1.4168*sqrt(x(2)) + 7.4633*sqrt(x(3)) ...
      + 13.0338*log(x(1)) - 6.8303*log(x(3));
f(2) = 2.77578 - 0.30824*x(2) + 0.01069*(x(2).^2) - 0.00001*(x(1).^3) ...
      - 0.00009*(x(2).^3) + 0.00001*(x(3).^3) - 1.18178*log(x(1));
f(3) = - 9.96172 - 0.1769*x(1) - 0.3188*x(3) + 1.32628*sqrt(x(1)) ...
      + 4.05206*sqrt(x(3)) + 1.04676*log(x(2)) - 2.72664*log(x(3));
```

Рис. 59. М-файл-функция

**Этап 5 — моделирование нематериальной мотивации по Парето-фронту для материальной мотивации и стратегического потенциала региона.** На рис. 60 и 61 отражены также значения третьей функции — нематериальной мотивации, которые соответствуют оптимальным значениям функций стратегического потенциала и материальной мотивации.

Анализ полученного на рис. 60 и 61 фронта Парето позволяет сделать следующие выводы:

1. Максимальный прирост населения будет наблюдаться в случае ориентации на стратегический потенциал. Коэффициент естественного прироста населения на 1 000 человек здесь равен 20,5.

2. В этом случае для функции нематериальной мотивации должны быть максимальными ВРП на душу населения ( $x_1 \approx 1$ ) и инвестиции в основной капитал на душу населения ( $x_2 \approx 1$ ). А внутренние затраты на НИР должны быть почти минимальными ( $x_3 \approx 75$ ). Такая ситуация объясняется тем, что инвестиции в основной капитал и затраты на НИР — конкурирующие цели в условиях ограниченности финансовых ресурсов.

3. Для функции материальной мотивации максимальными должны быть среднедушевые денежные доходы населения (в месяц) ( $x_1 \approx 1$ ) и общая площадь жилых помещений на душу населения ( $x_2 \approx 1$ ). А удельный вес автомобильных дорог с твердым покрытием допускается тоже почти минимальным ( $x_3 \approx 75$ ).

4. Для функции стратегического потенциала должны быть максимальными поступления налогов на душу населения ( $x_1 \approx 1$ ) и уровень занятости населения ( $x_2 \approx 1$ ). При этом допускается почти минимальное значение численности студентов на 10 000 человек населения ( $x_3 \approx 75$ ).

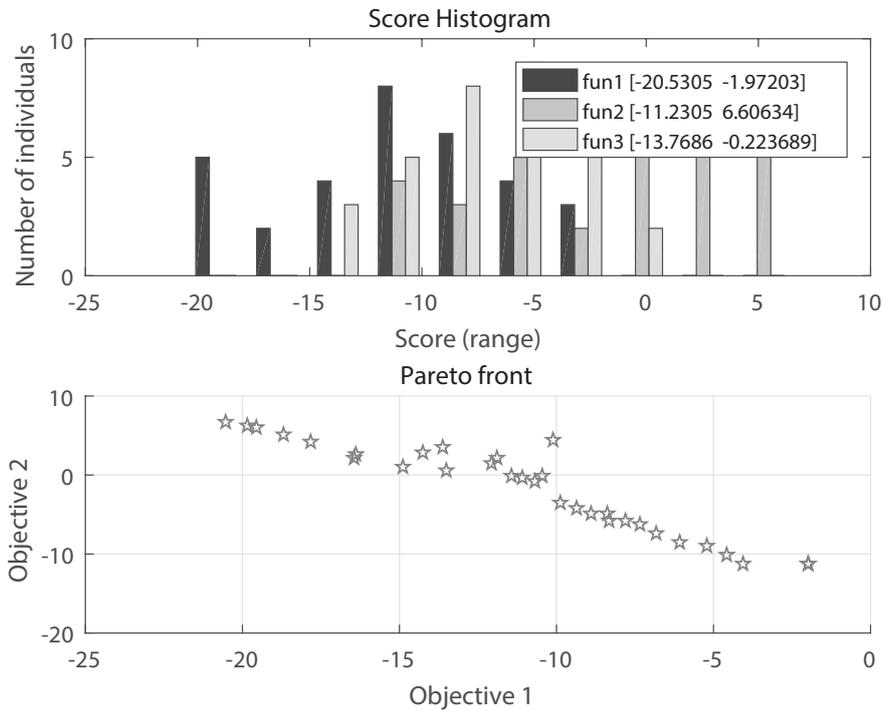


Рис. 60. Парето-фронт стратегического потенциала (fun1) и материальной мотивации (fun2)

Но это предварительные выводы для 20 исследуемых регионов с инновационными территориальными кластерами. А чтобы сделать выводы для конкретного региона, сравним фактические значения в 2019 г. исследуемых факторов с оптимальными значениями на фронте Парето, например, для Нижегородской области (табл. 29).

Согласно данным рис. 61 самый три наиболее близких оптимума Парето-фронта находятся в строках под номерами 21, 23, 6 (или 15). Они отражены в табл. 29 как оптимумы 1, 2, 3. Отклонение от каждого оптимума смотрим как разницу между соответствующими значениями  $x_i$  ( $i = \overline{1,3}$ ) для конкретной целевой функции  $y$ . Так, для функции стратегического потенциала наиболее близкий оптимум 1. Тогда сумма отклонений мест по  $x_1$ ,  $x_2$ ,  $x_3$  составит 39. Для функции материальной мотивации наиболее близкий оптимум 2 и сумма отклонений мест для него составит тоже 39. Для функции нематериальной мотивации наиболее близкий оптимум 3 и сумма отклонений мест для него составит 76. При этом отклонение коэффициента естественного прироста населения ( $y$ ) наименьшее в случае ориентации на оптимум 1 и составляет 16,1.

В этом случае согласно результатам табл. 29 численность студентов на 10 000 человек населения и уровень занятости населения примерно соответствуют плановым оптимальным значениям. Но удельный вес автодорог с твердым покрытием нужно

Index	f1 ▲	f2	f3	x1	x2	x3
1	-20,531	6,606	-9,209	1,002	1,17	74,763
25	-19,844	6,157	-8,316	1,011	2,666	74,541
4	-19,563	6,057	-8,205	1,033	2,906	74,458
10	-18,69	5,024	-7,217	1,034	5,079	71,066
7	-17,855	4,194	-6,708	1,074	2,888	61,316
19	-16,472	2,267	-4,735	1,041	16,171	59,517
8	-16,414	2,642	-5,039	1,084	17,797	63,568
23	-14,877	0,974	-3,336	1,104	17,069	44,988
31	-14,261	2,833	-5,5	1,459	7,462	60,791
29	-13,621	3,479	-6,218	1,716	3,902	62,026
16	-13,509	0,537	-2,897	1,255	16,782	39,524
14	-12,078	1,401	-4,162	1,675	16,8	56,698
18	-11,91	2,198	-5,076	1,889	12,55	63,303
30	-11,436	-0,009	-1,736	1,537	24,714	25,712
13	-11,115	-0,284	-0,364	1,998	80,293	26,14
32	-10,711	-0,696	-0,224	2,15	80,993	20,844
21	-10,471	-0,074	-2,179	1,744	20,876	34,257
27	-10,103	4,409	-7,233	3,306	3,682	73,935
3	-9,901	-3,508	-13,769	83,951	1,169	80,488
2	-9,36	-4,199	-13,124	83,973	1,477	77,276
28	-8,924	-4,821	-12,709	83,651	1,269	72,825
9	-8,378	-4,946	-11,986	81,659	1,415	69,391
5	-8,315	-5,687	-12,032	83,945	1,415	67,703
24	-7,778	-5,755	-11,213	82,773	2,881	68,12
11	-7,348	-6,216	-10,699	82,868	4,594	67,809
12	-6,843	-7,403	-10,23	84,816	6,029	64,308
20	-6,061	-8,423	-9,345	84,835	10,684	61,603
22	-5,239	-9,085	-8,305	83,66	11,702	53,291
17	-4,555	-10,081	-7,217	84,293	9,74	35,426
26	-4,075	-11,194	-6,715	84,905	17,378	3,199
6	-1,974	-11,23	-6,231	85	18,994	1,352
15	-1,972	-11,23	-6,242	85	18,741	1,348

Рис. 61. Координаты точек Парето-фронта стратегического потенциала (f1) и материальной мотивации (f2)

## Оценка деятельности Нижегородской области

Показатели	Место, занимаемое субъектом в РФ									Функция
	Нематериал. мотивация			Материал. мотивация			Стратег. потенциал			
	$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$	$x_1$	$x_2$	$x_3$	
Фактическое значение (2019)	34	41	4	20	33	49	31	16	29	-5,6
Самый близкий оптимум 1	2	21	34	2	21	34	2	21	34	10,5
Отклонение от оптимума 1	-32	-20	30	-18	-12	-15	-29	5	5	-16,1
Фактическое значение (2019)	34	41	4	20	33	49	31	16	29	-5,6
Самый близкий оптимум 2	1	17	45	1	17	45	1	17	45	14,9
Отклонение от оптимума 2	-33	-24	41	-19	-16	-4	-30	1	16	-20,5
Фактическое значение (2019)	34	41	4	20	33	49	31	16	29	-5,6
Самый близкий оптимум 3	85	19	1	85	19	1	85	19	1	11,2
Отклонение от оптимума 3	51	-22	-3	65	-14	-48	54	3	-28	-16,8

увеличить, чтобы Нижегородской области подняться с 49 на 34 место, общую площадь жилых помещений на душу населения — также увеличить, чтобы подняться с 33 на 21 место, среднедушевые денежные доходы (в месяц) — значительно увеличить, чтобы подняться с 20 на 2 место.

При этом внутренние затраты на НИР следует уменьшить, чтобы опуститься с 4 на 34 место, а инвестиции в основной капитал на душу населения увеличить, чтобы подняться с 41 на 21 место. Так происходит по причине того, что эти две цели являются конкурирующими при ограниченном бюджете финансирования. Также ВРП на душу населения необходимо значительно увеличить, чтобы Нижегородской области подняться с 34 на 2 место.

В результате исследования получены следующие основные выводы:

1. Для моделирования мотивации топ-менеджмента государственных структур регионов целесообразно решать трехцелевую задачу глобальной оптимизации, что позволит поставить нематериальную мотивацию топ-менеджеров в зависимость от достигнутого стратегического потенциала региона и их материальной мотивации.

2. Каждая из данных целей зависит от трех факторов  $x_1$ ,  $x_2$ ,  $x_3$  в одной системе координат. Данные факторы непосредственно влияют на значение коэффициента естественного прироста населения на 1 000 человек в регионах страны.

3. Первые три из девяти факторов характеризуют систему нематериального поощрения топ-менеджеров в государственных структурах, следующие три — систему их материального поощрения, а последние три — имеющийся стратегический потенциал региона, необходимый для его дальнейшего успешного развития.

4. Построение множества эффективных решений с помощью Парето-фронта следует выполнять для двух первоочередных целей — стратегический потенциал региона и материальная мотивация топ-менеджмента, после чего уже как следствие будет получено множество оптимальных решений для нематериальной мотивации.

5. Вывод о фактическом премировании (поощрении) топ-менеджеров государственных структур регионов делается следующим образом. Для каждой из трех функций в конкретном регионе сравниваются последние фактические значения факторов  $x_1$ ,  $x_2$ ,  $x_3$  с ближайшими плановыми (оптимальными) значениями. Положительное отклонение от оптимума оценивается позитивно, что позволяет дополнительно поощрять топ-менеджеров материально либо нематериально. Отрицательное отклонение свидетельствует о принятии ими в прошлом некачественных управленческих решений, что, безусловно, должно отразиться на их поощрении.

Полученные результаты могут быть полезны государственным структурам для разработки рациональной системы материальной и нематериальной мотивации своих топ-менеджеров.

### **5.3. Оптимизация предвыборной кампании: муравьиный алгоритм, имитационный отжиг**

В современных условиях развития технологий искусственного интеллекта становится важным применять их для государственного управления. Одной из практиче-

ских задач применения данных технологий может стать политическое управление, в частности, проведение предвыборных кампаний.

В данном случае кроме чисто политических вопросов организаторы предвыборной кампании должны оптимизировать и расходы на нее, к числу которых относятся также транспортные расходы. Немаловажным фактором оптимизации является также время, столь ценное в данном процессе.

Поскольку самая эффективная предвыборная кампания будет в случае прямого диалога представителей какой-либо партии с избирателями, необходимы агитации в конкретных городах вживую. Пытаясь охватить значительное число таких городов, представители политической партии должны предварительно разработать оптимальный маршрут перемещения между городами, который позволил бы им значительно сэкономить время и транспортные расходы.

Таким образом, для оптимизации предвыборной кампании следует решать классическую задачу коммивояжера [10, 59, 145]. Однако более эффективным является подход, который подразумевает проведение агитаций сначала в тех городах, где данную партию избиратели поддерживают более всего. Тогда можно из маршрута, планируемого посредством решения задачи коммивояжера, исключить такие города. То есть политическая партия будет сначала проводить агитацию в городах, где ее больше всего поддерживают, а затем — в городах согласно маршруту, полученному посредством решения задачи коммивояжера.

Для решения задачи коммивояжера на практике чаще всего используют муравьиный алгоритм [10, 25, 59, 145, 146] и алгоритм имитационного отжига [10, 14].

**Муравьиный алгоритм.** Функция, управляющая переходом из данной вершины  $i$  в вершину  $j$  [10]:

$$P_{ij,k} = \frac{\tau_{ij}^{\alpha} \eta_{ij}^{\beta}}{\sum_m \tau_{im}^{\alpha} \eta_{im}^{\beta}},$$

где  $k$  — номер муравья, движущегося по дугам графа;

$\tau_{ij}$  — количество феромона (pheromon), оставленного муравьями на дуге  $[i, j]$ ;

$\eta_{ij}$  — величина, обратная весу (длине) дуги  $[i, j]$ ;

$\alpha, \beta$  — эмпирические коэффициенты;

$t$  — в сумме пробегает по всем непройденным вершинам, смежным с  $i$ .

Преимуществом муравьиного алгоритма является то, что даже после того, как оптимальный маршрут найден, колония муравьев все равно продолжает искать более оптимальный маршрут. По этой причине в случае проведения большого числа итераций муравьиный алгоритм может дать существенно более точное решение.

**Алгоритм отжига.** Вероятность принятия нового состояния [10]:

$$P = \exp\{-\Delta L/T\},$$

где  $\Delta L$  — положительная разность между качеством тестируемого и ранее полученного оптимального решения;

$T$  — некоторый постоянно уменьшающийся параметр (условно — температура).

Таблица 30

## Координаты городов ПФО с численностью более 100 000 чел.

Регионы	Города	Координаты городов
1. Нижегородская область	1. Нижний Новгород	56°19'37" с. ш. 44°00'27" в. д. $x = 44,1; y = 56,33$
	2. Дзержинск	56°14' с. ш. 43°27' в. д. $x = 43,45; y = 56,23$
	3. Арзамас	55°23' с. ш. 43°48' в. д. $x = 43,8; y = 55,38$
2. Республика Мордовия	4. Саранск	54°11' с. ш. 45°11' в. д. $x = 45,18; y = 54,18$
3. Пензенская область	5. Пенза	53°12' с. ш. 45°00' в. д. $x = 45; y = 53,2$
4. Саратовская область	6. Саратов	51°32' с. ш. 46°00' в. д. $x = 46; y = 51,53$
	7. Энгельс	51°28' с. ш. 46°07' в. д. $x = 46,12; y = 51,47$
	8. Балаково	52°02' с. ш. 47°47' в. д. $x = 47,78; y = 52,03$
5. Кировская область	9. Киров	58°36' с. ш. 49°39' в. д. $x = 49,65; y = 58,6$
6. Республика Марий Эл	10. Йошкар-Ола	56°37'58" с. ш. 47°53'45" в. д. $x = 47,9; y = 56,63$
7. Чувашская республика	11. Чебоксары	56°07' с. ш. 47°14' в. д. $x = 47,23; y = 56,12$
	12. Новочебоксарск	56°07'19" с. ш. 47°29'33" в. д. $x = 47,49; y = 56,12$
8. Республика Татарстан	13. Казань	55°47'27" с. ш. 49°06'52" в. д. $x = 49,12; y = 55,79$
	14. Набережные Челны	55°42' с. ш. 52°20' в. д. $x = 52,33; y = 55,7$
	15. Нижнекамск	55°38' с. ш. 51°49' в. д. $x = 51,82; y = 55,63$
	16. Альметьевск	54°54' с. ш. 52°18' в. д. $x = 52,3; y = 54,9$
	17. Зеленодольск	55°51' с. ш. 48°31' в. д. $x = 48,52; y = 55,85$

Регионы	Города	Координаты городов
9. Ульяновская область	18. Ульяновск	54°19' с. ш. 48°22' в. д. $x = 48,37; y = 54,32$
	19. Димитровград	54°14' с. ш. 49°35' в. д. $x = 49,58; y = 54,23$
10. Самарская область	20. Самара	53°11' с. ш. 50°07' в. д. $x = 50,12; y = 53,18$
	21. Тольятти	53°31' с. ш. 49°25' в. д. $x = 49,42; y = 53,52$
	22. Сызрань	53°10' с. ш. 48°28' в. д. $x = 48,47; y = 53,17$
	23. Новокуйбышевск	53°06' с. ш. 49°55' в. д. $x = 49,92; y = 53,1$
11. Пермский край	24. Пермь	58°00'50" с. ш. 56°14'56" в. д. $x = 56,25; y = 58,01$
	25. Березники	59°24'29" с. ш. 56°48'19" в. д. $x = 56,81; y = 59,41$
12. Удмуртская республика	26. Ижевск	56°51'11" с. ш. 53°12'44" в. д. $x = 53,21; y = 56,85$
13. Республика Башкортостан	27. Уфа	54°44' с. ш. 55°58' в. д. $x = 55,97; y = 54,73$
	28. Стерлитамак	53°38' с. ш. 55°57' в. д. $x = 55,95; y = 53,63$
	29. Салават	53°22' с. ш. 55°56' в. д. $x = 55,93; y = 53,37$
	30. Нефтекамск	56°05'20" с. ш. 54°14'47" в. д. $x = 54,25; y = 56,09$
	31. Октябрьский	54°29' с. ш. 53°29' в. д. $x = 53,15; y = 54,48$
14. Оренбургская область	32. Оренбург	51°46' с. ш. 55°06' в. д. $x = 55,1; y = 51,77$
	33. Орск	51°12' с. ш. 58°37' в. д. $x = 58,62; y = 51,2$

```

tic
clearvars
age = 2000;
countage = 10;
n = 33;
a = 1;
b = 2;
e = 0.1;
p = 0.1;
Q = 1;
q = 0.9;
    ph = Q/(n*2000);
dist = zeros(n,n);
returndist = zeros(n,n);
ROUTEant = zeros(countage,n);
DISTant = zeros(countage,1);
bestDistVec = zeros(age,1);
bestDIST = inf;
ROUTE = zeros(1,n+1);
RANDperm = randperm(n);
P = zeros(1,n);
val = zeros(1);
getcity = zeros(1);
indexP = zeros(1);
minDISTiteration = zeros(1);
cities = [44.1 56.33; 45.18 54.18; 45 53.2; 46 51.53; 49.65 58.6; ...
    47.9 56.63; 47.23 56.12; 49.12 55.79; 48.37 54.32; 50.12 53.18; ...
    56.25 58.01; 53.21 56.85; 55.97 54.73; 55.1 51.77; ...
    43.45 56.23; 43.8 55.38; 46.12 51.47; 47.78 52.03; 47.49 56.12; ...
    52.33 55.7; 51.82 55.63; 52.3 54.9; 48.52 55.85; 49.58 54.23; ...
    49.42 53.52; 48.47 53.17; 49.92 53.1; 56.81 59.41; 55.95 53.63; ...
    55.93 53.37; 54.25 56.09; 53.15 54.48; 58.62 51.2];
tao = ph*(ones(n,n));
tao(logical(eye(size(tao)))) = 0;
for i = 1:n
    for j = 1:n
        dist(i,j) = sqrt((cities(i,1) - cities(j,1))^2 + ...
            (cities(i,2) - cities(j,2))^2);
        if i ~= j
            returndist(i,j) = 1/sqrt((cities(i,1) - cities(j,1))^2 + ...
                (cities(i,2) - cities(j,2))^2);
        end
    end
end
end
for iteration = 1:age
    for k = 1:countage
        ROUTEant(k,1) = randi([1 n]);
        for s = 2:n
            ir = ROUTEant(k,s-1);
            P = tao(ir,:).^a .* returndist(ir,:).^b;
            P(ROUTEant(k,1:s-1)) = 0;
            RANDONE = rand;
            if RANDONE <= q
                [val, getcity] = max(P);
            else
                P = P ./ sum(P);
                getcity = find(cumsum(P) >= RANDONE, 1, 'first');
            end
            ROUTEant(k,s) = getcity;
        end
    end
end

```

Рис. 62. Начало текста программы в *Matlab* для муравьиного алгоритма

```

ROUTE = [ROUTEant(k,1:end),ROUTEant(k,1)];
S = 0;
for i = 1:n
    S = S + dist(ROUTE(i),ROUTE(i+1));
end
DISTant(k) = S;
if DISTant(k) < bestDIST
    bestDIST = DISTant(k);
    bestROUTE = ROUTEant(k,[1:end,1]);
    iter = iterration;
end
for tL = 1:n
    xL = ROUTE(tL);
    yL = ROUTE(tL+1);
    tao(xL,yL) = (1-p)*tao(xL,yL) + p*ph;
    tao(yL,xL) = (1-p)*tao(yL,xL) + p*ph;
end
end
tao(tao < 2.5000000000000000e-150) = 2.5000000000000000e-150;
for t = 1:n
    xG = bestROUTE(t);
    yG = bestROUTE(t+1);
    tao(xG,yG) = tao(xG,yG) + e*(Q/bestDIST);
    tao(yG,xG) = tao(yG,xG) + e*(Q/bestDIST);
end
end
citiesOP(:,[1,2]) = cities(bestROUTE(:),[1,2]);
plot([citiesOP(:,1);citiesOP(1,1)],[citiesOP(:,2);citiesOP(1,2)],'k-o',...
    'MarkerSize',5,...
    'MarkerFaceColor','y',...
    'LineWidth',1)
grid on
xlabel('\itx (в. д.)')
ylabel('\ity (с. ш.)')
title('Оптимальный маршрут между 33 городами ПФО')
disp(num2str(bestDIST))
msgbox('Выполнено!')
clearvars -except cities bestDIST bestROUTE iter
toc

```

Рис. 63. Конец текста программы в *Matlab* для муравьиного алгоритма

Снижение температуры чаще всего производится по формуле  $T_{k+1} = \alpha T_k$ , где  $0 < \alpha < 1$ .

Алгоритм имитационного отжига позволяет избежать “ловушки” в локальных экстремумах. При выборе соответствующих температурных параметров отжига данный подход позволяет достаточно точно найти глобальный экстремум оптимизируемой функции.

**Пример 9.** В качестве примера рассмотрим ситуацию, когда какая-то политическая партия планирует провести широкомасштабную предвыборную кампанию, встречаясь вживую с избирателями, на крупной территории. К примеру, это планируется сделать в Приволжском федеральном округе (ПФО) (рис. 25, параграф 3.2). В целях упрощения предположим, что данный округ для партии проблемный, поэтому приоритетности посещения городов нет, т.к. в них еще нет достаточного количества избирателей, кто данную партию более или менее серьезно

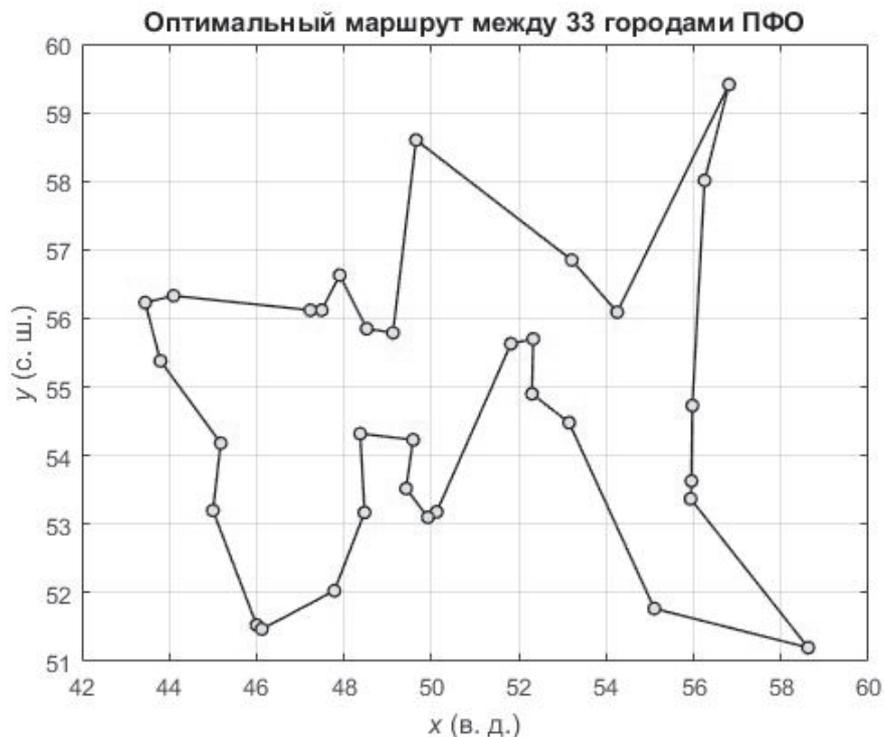


Рис. 64. Длина оптимального пути для всех городов ПФО с численностью более 100 000 чел. — 53,2556 градусов (5 911 км)

поддерживает. Таким образом, предполагается охватить все города ПФО с населением более 100 000 человек. Список и географические координаты городов представлены в табл. 30. Требуется найти оптимальный, т. е. самый короткий, маршрут между представленными в табл. 30 городами.

Решим поставленную задачу сначала с помощью муравьиного алгоритма в программе *Matlab* (рис. 62 и 63). Результат оптимизации маршрута после нескольких запусков алгоритма представлен на рис. 64. При этом за 1 градус географической широты и долготы берется 111 км.

После этого проверим полученный результат с помощью алгоритма имитационного отжига — также в программе *Matlab* (рис. 65 и 66). После нескольких запусков алгоритма имитационного отжига оптимальный маршрут получается такой же, как на рис. 64. Значит, оба подхода позволили получить один и тот же результат.

Таким образом, представленный подход к оптимизации предвыборной кампании, действительно, позволит значительно сэкономить время и транспортные расходы политической партии, которая собирается проводить свою предвыборную кампанию вживую на крупной территории, например, охватывающей целый федеральный округ.

```

tic
clearvars
m = 1000000;
Tstart = 100000;
Tend = 0.1;
T = Tstart;
S = inf;
n = 33;
g = 1;
dist = zeros(n,n);
cities = [44.1 56.33; 45.18 54.18; 45 53.2; 46 51.53; 49.65 58.6; ...
47.9 56.63; 47.23 56.12; 49.12 55.79; 48.37 54.32; 50.12 53.18; ...
56.25 58.01; 53.21 56.85; 55.97 54.73; 55.1 51.77; ...
43.45 56.23; 43.8 55.38; 46.12 51.47; 47.78 52.03; 47.49 56.12; ...
52.33 55.7; 51.82 55.63; 52.3 54.9; 48.52 55.85; 49.58 54.23; ...
49.42 53.52; 48.47 53.17; 49.92 53.1; 56.81 59.41; 55.95 53.63; ...
55.93 53.37; 54.25 56.09; 53.15 54.48; 58.62 51.2];
RANDONE = rand(m,1);
D = randi(n,m,2);
ROUTE = randperm(n);
for i = 1:n
    for j = 1:n
        dist(i,j) = sqrt((cities(i,1) - cities(j,1))^2 + ...
(cities(i,2) - cities(j,2))^2);
    end
end
for k = 1:m
    Sp = 0;
    ROUTEp = ROUTE;
    transp = D(k,[1,2]);
    if transp(1) < transp(2)
        if transp(1) ~= 1 && transp(2) ~= n
            S = dist(ROUTE(transp(1)-1),ROUTE(transp(1))) + ...
dist(ROUTE(transp(2)),ROUTE(transp(2)+1));
        elseif transp(1) ~= 1 && transp(2) == n
            S = dist(ROUTE(transp(1)-1),ROUTE(transp(1))) + ...
dist(ROUTE(transp(2)),ROUTE(1));
        elseif transp(1) == 1 && transp(2) ~= n
            S = dist(ROUTE(end),ROUTE(transp(1))) + ...
dist(ROUTE(transp(2)),ROUTE(transp(2)+1));
        end
    else
        if transp(2) ~= 1 && transp(1) ~= n
            S = dist(ROUTE(transp(2)-1),ROUTE(transp(2))) + ...
dist(ROUTE(transp(1)),ROUTE(transp(1)+1));
        elseif transp(2) ~= 1 && transp(1) == n
            S = dist(ROUTE(transp(2)-1),ROUTE(transp(2))) + ...
dist(ROUTE(transp(1)),ROUTE(1));
        elseif transp(2) == 1 && transp(1) ~= n
            S = dist(ROUTE(end),ROUTE(transp(2))) + ...
dist(ROUTE(transp(1)),ROUTE(transp(1)+1));
        end
    end
end
end

```

Рис. 65. Начало текста программы в *Matlab* для алгоритма отжига

```

if transp(1) < transp(2)
    ROUTEp(transp(1):transp(2)) = ROUTEp(transp(2):-1:transp(1));
    if transp(1) ~= 1 && transp(2) ~= n
        Sp = dist(ROUTEp(transp(1)-1),ROUTEp(transp(1))) + ...
            dist(ROUTEp(transp(2)),ROUTEp(transp(2)+1));
    elseif transp(1) ~= 1 && transp(2) == n
        Sp = dist(ROUTEp(transp(1)-1),ROUTEp(transp(1))) + ...
            dist(ROUTEp(transp(2)),ROUTEp(1));
    elseif transp(1) == 1 && transp(2) ~= n
        Sp = dist(ROUTEp(end),ROUTEp(transp(1))) + ...
            dist(ROUTEp(transp(2)),ROUTEp(transp(2)+1));
    end
else
    ROUTEp(transp(2):transp(1)) = ROUTEp(transp(1):-1:transp(2));
    if transp(2) ~= 1 && transp(1) ~= n
        Sp = dist(ROUTEp(transp(2)-1),ROUTEp(transp(2))) + ...
            dist(ROUTEp(transp(1)),ROUTEp(transp(1)+1));
    elseif transp(2) ~= 1 && transp(1) == n
        Sp = dist(ROUTEp(transp(2)-1),ROUTEp(transp(2))) + ...
            dist(ROUTEp(transp(1)),ROUTEp(1));
    elseif transp(2) == 1 && transp(1) ~= n
        Sp = dist(ROUTEp(end),ROUTEp(transp(2))) + ...
            dist(ROUTEp(transp(1)),ROUTEp(transp(1)+1));
    end
end
if Sp < S
    ROUTE = ROUTEp;
    iter = k;
else
    P = exp(-(Sp - S) / T);
    if RANDONE(k) <= P
        ROUTE = ROUTEp;
    end
end
T = Tstart / k;
if T < Tend
    break;
end;
end
citiesOP(:,[1,2]) = cities(ROUTE(:),[1,2]);
plot([citiesOP(:,1);citiesOP(1,1)],[citiesOP(:,2);citiesOP(1,2)],'k-o',...
    'MarkerSize',5,...
    'MarkerFaceColor','y',...
    'LineWidth',1)
grid on
xlabel('\itx (в. д.)')
ylabel('\ity (с. ш.)')
title('Оптимальный маршрут между 33 городами ПФО')
msgbox ('Выполнено!')
clearvars -except cities ROUTE S iter
toc

```

Рис. 66. Конец текста программы в *Matlab* для алгоритма отжига

Однако на практике политические партии планируют начинать свою предвыборную агитацию в тех городах, где их поддерживает наибольшее число избирателей. Этот факт можно также учесть при разработке оптимального маршрута. В этом случае необходимо сначала посетить города с наибольшей поддержкой избирателей, после чего составить оптимальный маршрут для оставшегося набора городов исследуемой территории.

Результаты исследования могут быть полезны топ-менеджменту управляющих структур государственной власти и специалистам по предвыборным технологиям.

## Заключение

В монографии обстоятельно разобраны основные проблемы управления крупными инновационными системами, используя для этого метаэвристические алгоритмы. Здесь стоит отметить, что, во-первых, далеко не все подобные алгоритмы подходят для решения той или иной практической задачи в области внедрения инноваций. Универсальных методов не существует. Во-вторых, не стоит решать конкретную практическую проблему, используя лишь один какой-то алгоритм. Лучше решение проверять разными методами. В-третьих, как уже было показано, даже наиболее мощные алгоритмы следует дополнять другими подходами. Иначе задачу бывает просто не решить. То есть существуют задачи, требующие комплексного подхода к их решению — последовательно разными методами.

При этом мы лишь показали примеры кодов, которые реализую на практике тот или иной алгоритм. Пытливый читатель, подкованный в программировании, возможно, сможет их улучшить. Однако в такой работе не следует забывать о том, что правильная постановка задачи — это уже наполовину решенная задача. Поэтому задачи следует ставить реальные и делать это грамотно, как с точки зрения управления инновациями в крупных инновационных системах, так и с точки зрения будущего математического и информационного их решения.

Мы надеемся, что настоящая книга поможет государственным служащим и инвесторам, планирующим вложение средств в инновационное развитие регионов, достаточно легко и быстро разобраться в основных проблемах межкластерного взаимодействия на уровне регионов, федеральных округов и всей страны в целом. Также монография может быть полезна студентам математических и экономических специальностей и широкому кругу уже сложившихся практиков-инноваторов.

## Список литературы

1. Агеев А. А., Гимади Э. Х., Курочкин А. А. Полиномиальный алгоритм решения задачи размещения на цепи с одинаковыми производственными мощностями предприятий // Дискретный анализ и исследование операций. Сентябрь–октябрь 2009. Том 16, № 5. С. 3–18.
2. Бабынин М. С., Жадан В. Г. Прямой метод внутренней точки для линейной задачи полуопределенного программирования // Ж. вычисл. матем. и матем. физ. 2008. Том 48, № 10. С. 1780–1801.
3. Вознюк И. П. Задача размещения пунктов производства на два-дерева с ограниченными пропускными способностями коммуникаций // Дискретный анализ и исследование операций. Январь–июнь 2000. Том 7, серия 2, № 1. С. 3–8.
4. Галоненко В. Ф. Вопросы планирования затрат на выполнение научно-исследовательских работ в системе МВД России // Труды Академии управления МВД России. 2018. Т. 1, № 45. С. 58–62.
5. Гасников А. В., Двуреченский П. Е., Нестеров Ю. Е. Стохастические градиентные методы с неточным оракулом // ТРУДЫ МФТИ. 2016. Том 8, № 1. С. 41–91.
6. Гершман М. А. Программы инновационного развития компаний с государственным участием: первые итоги // Форсайт. 2013. Т. 7, № 1. С. 28–43.
7. Гимади Э. Х. Точный алгоритм решения внешнепланарной задачи размещения с улучшенной временной сложностью // Труды Института математики и механики УрО РАН. 2017. Том 23, № 3. С. 74–81. <https://doi.org/10.21538/0134-4889-2017-23-3-74-81>
8. Дингес Э. В., Поздеева С. Н. Методы планирования инвестиционно-финансовой деятельности предприятий дорожного хозяйства: монография. М.: МАДИ, 2018, 116 с.
9. Измакова О. А. Рандомизированные алгоритмы самообучения для настройки ассоциативных нейронных сетей // Стохастическая оптимизация в информатике. 2005. Вып. 1. С. 81–102.
10. Кирсанов М. Н. Графы в Maple. Задачи, алгоритмы, программы: учеб. пособие. М.: Издательство ФИЗМАТЛИТ, 2007, 168 с.
11. Кравец О. Я., Сафронова А. П. Обзор методов структурного синтеза для решения квадратичных задач о назначениях // Современная наука: Актуальные проблемы теории и практики: научно-практический журнал. 2013. № 9/10: Сер. Естеств. и техн. науки. С. 66–72.
12. Лимитовский М. А. Инвестиционные проекты и реальные опционы на развивающихся рынках. М.: Юрайт, 2019, 486 с.
13. Лимитовский М. А. Репутация, квалификация и мотивация как драйверы ценности // Российский журнал менеджмента. 2009. Т. 7, № 2. С. 51–68.
14. Лопатин А. С. Метод отжига // Стохастическая оптимизация в информатике. 2005. Вып. 1. С. 133–149.
15. Мороз В. А. Применение генетического алгоритма к задачам оптимизации. Реализация генетического алгоритма для задачи коммивояжера // Вестник Амурского государственного университета. 2012. Вып. 57: Сер. Естеств. и экон. науки. С. 18–22.

16. Науменкова С. В., Глазун О. И. Использование методов количественного прогнозирования в процессе финансового планирования деятельности предприятия // Вісник Української академії банківської справи. 2002. № 1. С. 32–36.
17. Недосекин А. О., Абдулаева З. И. Модели и методы финансового планирования: монография. СПб.: Изд-во Политехн. ун-та, 2013, 176 с.
18. Пантелеев А. В., Скавинская Д. В., Алешина Е. А. Метаэвристические алгоритмы поиска оптимального программного управления: учебник. М.: Инфра-М, 2020.
19. Рытиков С. А., Богданов А. В., Кулаков А. Д. Применение моделей одновременного инвестиционно-финансового планирования при экспертизе инвестиционных проектов резидентов особой экономической зоны // Экономический анализ: теория и практика. 2014. Т. 40, вып. 391. С. 57–68.
20. Сакалаускас Л. Нелинейная стохастическая оптимизация методом Монте-Карло // Стохастическая оптимизация в информатике. 2005. Вып. 1. С. 190–205.
21. Строева О. А. Разработка программы инновационного развития региональных экономических систем // Вестник УрФУ. Серия экономика и управление. 2011. № 5. С. 115–124.
22. Сысоев С. С. Рандомизированные алгоритмы стохастической оптимизации, квантовые компьютеры, искусственный интеллект // Стохастическая оптимизация в информатике. 2005. Вып. 1. С. 206–221.
23. Тихомиров А. С. О быстрых вариантах алгоритма отжига (simulated annealing) // Стохастическая оптимизация в информатике. 2009. Вып. 5. С. 65–90.
24. Феоктистова О. А. Планирование затрат на научные исследования: проектный подход // Финансовый журнал. 2014. № 1. С. 69–80.
25. Штовба С. Д. Муравьиные алгоритмы // Математика в приложениях. 2003. № 4(4). С. 70–75.
26. Яшин С. Н., Кошелев Е. В., Костригин Р. В. Составление линейного функционала ценности инновационно-индустриального кластера для региона // Управление экономическими системами: электронный научный журнал. 2019. № (130) УЭКС, 12/2019. Режим доступа к журн.: <http://uecs.ru/innovacii-investicii/item/5774-2019-12-21-11-28-53>
27. Яшин С. Н., Кошелев Е. В., Купцов А. В. Применение метода экономической добавленной стоимости для мотивации топ-менеджеров корпорации // Финансы и кредит. 2018. Т. 24, вып. 1. С. 52–64.
28. Яшин С. Н., Кошелев Е. В., Купцов А. В., Подшибякин Д. В. Инвестиционное планирование модернизации оборудования производственной компании: монография. Н. Новгород: ООО «Печатная Мастерская РАДОНЕЖ», 2015, 201 с.
29. Яшин С. Н., Кошелев Е. В., Суханов Д. А. Форсайт эволюции инновационной системы федерального округа с использованием многоцелевого генетического алгоритма // Финансы и кредит. 2020. Т. 26, вып. 6. С. 1208–1227.
30. Яшин С. Н., Трифонов Ю. В., Кошелев Е. В. Методика форсайта развития кластера с использованием арбитражных технологий // Инновации. 2017. № 11. С. 42–53.

31. Abakarov A., Sushkov Yu., Mascheroni R.H. (2012). Multi-criteria Optimization and Decision-Making Approach for Improving of Food Engineering Processes. *International Journal of Food Studies*, vol. 2, pp. 1–21. <https://doi.org/10.7455/ijfs/2.1.2013.a1>
32. Abramson M.A., Audet Ch., Dennis J.E., Digabel S.L. (2009). ORTHOMADS: A Deterministic MADS Instance with Orthogonal Directions. *SIAM Journal on Optimization*, vol. 20, no. 2, pp. 948–966.
33. Ahuja R.K., Orlin J.B., Tivari A. (1995). A Greedy Genetic Algorithm for the Quadratic Assignment Problem. *Working Paper Sloan School of Management*, vol. 2, pp. 13–17.
34. Anstreicher K.M., Brixius N.W., Linderoth J., Goux J.P. (2002). Solving Large Quadratic Assignment Problems on Computational Grids. *Mathematical Programming, Series B*, no. 91, pp. 563–588. URL: <https://doi.org/10.1007/s101070100255>
35. Anstreicher K.M. (2003). Recent Advances in the Solution of Quadratic Assignment Problems. *Mathematical Programming, Series B*, no. 97, pp. 27–42. <https://doi.org/10.1007/s10107-003-0437-z>
36. Audet Ch., Dennis J.E. (2003). Analysis of Generalized Pattern Searches. *SIAM Journal on Optimization*, vol. 13, no. 3, pp. 889–903.
37. Audet Ch., Dennis J. (2006). Mesh Adaptive Direct Search Algorithms for Constrained Optimization. *SIAM Journal on Optimization*, vol. 17, pp. 188–217. <https://doi.org/10.1137/060671267>
38. Back T., Fogel D., Michalewicz Z. (2000). *Evolutionary Computations. Advanced Algorithms and Operators*, no. 4, pp. 23–30.
39. Baeyens E., Herreros A., Peran J.R. (2016). A Direct Search Algorithm for Global Optimization. *Algorithms*, vol. 9, no. 40. <https://doi.org/10.3390/a9020040>
40. Bemporad A., Munoz de la Pena D. (2009). Multiobjective Model Predictive Control. *Automatica*, vol. 45, no. 12, 2009, pp. 2823–2830. <https://doi.org/10.1016/j.automatica.2009.09.032>
41. Bina A., Azevedoa A., Duartea L., Salles-Filho S., Massaguer P. (2015). R&D and Innovation Project Selection: Can Optimization Methods Be Adequate? *Procedia Computer Science*, no. 55, pp. 613–621.
42. Boschert S., Rosen R. (2016). Digital Twin – the Simulation Aspect. In Peter Hehenberger, David Bradley (Eds.): *Mechatronic Futures*, Cham, Springer International Publishing, pp. 59–74.
43. Branke J., Kalyanmoy D., Miettinen K., Slowinski R. (2008). *Multiobjective Optimization: Interactive and Evolutionary Approaches*. Springer Science & Business Media.
44. Brigham E.F., Gapenski L.C. (1993). *Intermediate financial management*. Orlando, FL: The Dryden Press, 4th edn.
45. Burkard R., Dollani H., Lin Yi., Rote G. (2001). The Obnoxious Center Problem on a Tree. *SIAM J. Discrete Math.*, vol. 14, pp. 498–509. <https://doi.org/10.1137/S0895480198340967>

46. Campbell J. F. (1994). Integer Programming Formulations of Discrete Hub Location Problems. *European Journal of Operational Research*, vol. 72, issue 2, 27 January 1994, pp. 387–405. [https://doi.org/10.1016/0377-2217\(94\)90318-2](https://doi.org/10.1016/0377-2217(94)90318-2)
47. Coello Coello C. A., Lamont G. B., Van Veldhuisen D. A. (2007). *Evolutionary Algorithms for Solving Multi-Objective Problems*. Springer Science & Business Media.
48. Conn A. R., Gould N. I. M., Toint Ph. L. (1991). A Globally Convergent Augmented Lagrangian Algorithm for Optimization with General Constraints and Simple Bounds. *SIAM Journal on Numerical Analysis*, Vol. 28, no. 2, pp. 545–572.
49. Conn A. R., Gould N. I. M., Toint Ph. L. (1997). A Globally Convergent Augmented Lagrangian Barrier Algorithm for Optimization with General Inequality Constraints and Simple Bounds. *Mathematics of Computation*, Vol. 66, no. 217, pp. 261–288.
50. Cornuejols G., Fisher M. L., Nemhauser G. L. (1977). Location of Bank Accounts to Optimize Float. *Management Science*, vol. 22, pp. 789–810.
51. Damodaran A. (2002). *Investment valuation: Tools and techniques for determining the value of any asset*. New York: John Wiley & Sons, Inc.
52. Danielli L. A., Oliveira G. (2017). A Cellular Automata Ant Memory Model of Foraging in a Swarm of Robots. *Applied Mathematical Modelling*, no. 47, pp. 551–572. <https://doi.org/10.1016/j.apm.2017.03.021>
53. Das S., Chaudhuri Sh., Das A. K. (2017). Optimal Set of Overlapping Clusters Using Multi-objective Genetic Algorithm. *ICMLC 2017: Proceedings of the 9th International Conference on Machine Learning and Computing*, February 2017, pp. 232–237. <https://doi.org/10.1145/3055635.3056653>
54. Davidon W. C. (1991). Variable Metric Method for Minimization. *SIAM Journal on Optimization*, vol. 1, no. 1, pp. 1–17. <https://doi.org/10.1137/0801001>
55. Dehmer S. P., Pardey P. G., Beddow J. M., Chai Y. (2019). Reshuffling the Global R&D Deck. *PLoS ONE*, vol. 14, no. 3, pp. 1980–2050. <https://doi.org/10.1371/journal.pone.0213801>
56. Dogar M. N. (2020). Breach of Psychological Contract: Impact on Workforce Motivation and Organizational Sustainability. *Emerald Emerging Markets Case Studies*, vol. 10, no. 1. <https://doi.org/10.1108/EEMCS-01-2019-0005>
57. Dolan E. D., Lewis R. M., Torczon V. J. (2003). On the Local Convergence of Pattern Search. *SIAM Journal on Optimization*, vol. 14, no. 2, pp. 567–583. <https://doi.org/10.1137/S1052623400374495>
58. Domingo-Perez F., Lazaro-Galilea J. L., Wieser A., Martin-Gorostiza E., Salido-Monzu D., Llana A. (2016). Sensor Placement Determination for Range-Difference Positioning Using Evolutionary Multi-objective Optimization. *Expert Systems with Applications*, vol. 47, pp. 95–105. <https://doi.org/10.1016/j.eswa.2015.11.008>
59. Dorigo M., Gambardella L. M. (1997). Ant Colony System: A Cooperative Learning Approach to the Traveling Salesman Problem. *IEEE Transactions on Evolutionary Computation*, vol. 1, no. 1, pp. 53–66.
60. Dorigo M., Stultze T. (2004). *Ant colony optimization*. Cambridge, Massachusetts, London, England: The MIT Press.

61. Drezner Z., Hahn P., Taillard E.D. (2005). Recent Advances for the Quadratic Assignment Problem With Special Emphasis on Instances That are Difficult for Meta-Heuristic Methods. *Operation Research*, no. 139, pp. 65–94. <https://doi.org/10.1007/s10479-005-3444-z>
62. Drezner Z. (2015). The Quadratic Assignment Problem. In G. Laporte, S. Nickel, & F.S. da Gama (Eds.), *Chum, Heidelberg: Springer. Location science*, pp. 345–363. [https://doi.org/10.1007/978-3-319-13111-5\\_13](https://doi.org/10.1007/978-3-319-13111-5_13)
63. Erdogan G., Tansel B.C. (2011). Two Classes of Quadratic Assignment Problems That are Solvable as Linear Assignment Problems. *Discrete Optimization*, vol. 8, issue 3, pp. 446–451. <https://doi.org/10.1016/j.disopt.2011.03.002>
64. Erfani T., Utyuzhnikov S.V. (2011). Directed Search Domain: A Method for Even Generation of Pareto Frontier in Multiobjective Optimization. *Journal of Engineering Optimization*, vol. 43, no. 5, pp. 1–18.
65. Eshelman L. (1991). The CHC Adaptive Search Algorithm. How to Have Safe Search When Engaging in Nontraditional Genetic Recombination. *Foundations of Genetic Algorithms*, vol. 1, pp. 265–283. <https://doi.org/10.1016/B978-0-08-050684-5.50020-3>
66. Fabiana M.S., Edson A.A., Querido O., Marcela B.M. (2016). Innovation Development Process in Small and Medium Technology-based Companies. *RAI Revista de Administracao e Inovacao*, no. 13, pp. 176–189. <http://dx.doi.org/10.1016/j.rai.2016.04.005>
67. Fita A. (2014). Three-Objective Programming with Continuous Variable Genetic Algorithm. *Applied Mathematics*, vol. 5, pp. 3297–3310. <https://doi.org/10.4236/am.2014.521307>
68. Fogel D.B., Fogel L.J., Porto V.W. (1990). Evolving Neural Networks. *Biological Cybernetics*, t. 63, pp. 487–493. <https://doi.org/10.1007/BF00199581>
69. Fogel D.B. (1995). *Evolutionary Computation. Towards a New Philosophy of Machine Intelligence*. IEEE Press.
70. Garetti M., Rosa P., Terzi S. (2012). Life Cycle Simulation for the Design of Product-service Systems. *Computers in Industry*, vol. 63, no. 4, pp. 361–369.
71. Giorgio G., Sangiorgio M. (2020). Improving the Performance of Multiobjective Genetic Algorithms: An Elitism-Based Approach. *Information*, vol. 11, no. 12, p. 587. <https://doi.org/10.3390/info11120587>
72. Grafeeva N., Grigorieva L., Kalinina-Shuvalova N. (2013). Genetic Algoritms and Genetic Programming. *International Journal of Advanced Computer Science and Applications*, vol. 3, no. 9, pp. 465–480.
73. Grieves M., Vickers J. (2017). Digital Twin: Mitigating Unpredictable, Undesirable Emergent Behavior in Complex Systems. In Franz-Josef Kahlen, Shannon Flumerfelt, Anabela Alves (Eds.): *Transdisciplinary Perspectives on Complex Systems: New Findings and Approaches*, Cham, Springer International Publishing, pp. 85–113.
74. Gwiazda T.D. (1995). *Algorytmy Genetyczne. Wstep do Teorii*. Warszawa, Biblioteka Sztucznej Inteligencji.

75. Hahn G., Kuhn H. (2012). Simultaneous Investment, Operations, and Financial Planning in Supply Chains: A Value-Based Optimization Approach. *International Journal of Production Economics*, no. 140, pp. 559–569. <https://doi.org/10.1016/j.ijpe.2012.02.018>
76. Hahn P.M., Kim B., Monique G., Smith J., Zhu Y. (2008). An Algorithm for the Generalized Quadratic Assignment Problem. *Computational Optimization and Applications*, no. 40, pp. 351–372. <https://doi.org/10.1007/s10589-007-9093-1>
77. Hendra A., Adinugroho S. (2015). Matlab solvers benchmark for ABB’s model predictive control optimization. Speed vs result. Project in computational science: Report. Uppsala, Uppsala Universitet, January 2015. Available at: [http://www.it.uu.se/edu/course/homepage/projektTDB/ht14/project05/Project\\_05.Report.pdf](http://www.it.uu.se/edu/course/homepage/projektTDB/ht14/project05/Project_05.Report.pdf)
78. Holland J.H. (1992). *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence*. Cambridge, The MIT Press.
79. Hooke R., Jeeves T.A. (1961). "Direct Search" Solution of Numerical and Statistical Problems. *Journal of the ACM*, vol. 8, no. 2, pp. 212–229. <https://doi.org/10.1145/321062.321069>
80. Huang M. C., Liou M. H., Iwaki Y. (2020). The Impact of R&D and Innovation on Global Supply Chain Transition: GTAP Analysis on Japan’s Public R&D Investment. *J. Soc. Econ. Dev.* <https://doi.org/10.1007/s40847-020-00113-1>
81. Huang T., Bergman D., Gopal R.D. (2019). Predictive and Prescriptive Analytics for Location Selection of Add-on Retail Products. *Production and Operations Management*, vol. 28, issue 7, pp. 1858–1877. <https://doi.org/10.1111/poms.13018>
82. Hyk V. (2021). Optimization of Costs for Innovations of Industrial Enterprises Western Ukraine in Ensuring Sustainable Environmental Development. *The International Conference on Innovation, Modern Applied Science & Environmental Studies (ICIES2020)*, vol. 234, pp. 1–5. <https://doi.org/10.1051/e3sconf/202123400049>
83. Ildirar M., Ozmen M., Iscan E. (2016). The Effect of Research and Development Expenditures on Economic Growth: New Evidences. *International Conference on Eurasian Economies*, pp. 36–43.
84. Ingber L. (1989). Very Fast Simulated Re-annealing. *Mathematical and Computer Modelling*, no. 12, pp. 967-973.
85. Ingber L., Rosen B. (1992). Genetic Algorithms and Very Fast Simulated Reannealing: A Comparison. *Mathematical and Computer Modelling*, vol. 16, no. 11, pp. 87–100.
86. Ingber L. (1993). Simulated Annealing: Practice Versus Theory. *Mathematical and Computer Modelling*, vol. 18, no. 11, pp. 29–57.
87. Ingber L. (1996). Adaptive Simulated Annealing (ASA): Lessons Learned. *Control and Cybernetics*, vol. 25, no. 1, pp. 33–54.
88. Kalyanmoy D. (2001). *Multiobjective optimization using evolutionary algorithms*. New York: John Wiley & Sons, Inc.

89. Kampf R., Lorincova S., Kapustina L., Lizbetinova L. (2017). Motivation Level and Its Comparison Between Senior Managers and Blue-collar Workers in Small and Medium-sized Transport Enterprises. *Communications – Scientific Letters of the University of Zilina*, vol. 19, no. 4, pp. 43–49.
90. Khan A., Baig A.R. (2015). Multi-Objective Feature Subset Selection using Non-dominated Sorting Genetic Algorithm. *Journal of Applied Research and Technology. JART*, vol. 13, issue 1, pp. 145–159. [https://doi.org/10.1016/S1665-6423\(15\)30013-4](https://doi.org/10.1016/S1665-6423(15)30013-4)
91. Khosrow-Pour M. (2014). *Contemporary Advancements in Information Technology Development in Dynamic Environments*. U. S., Idea Group.
92. Khumawala B.M. (1972). An Efficient Branch-Bound Algorithm for the Warehouse Location Problem. *Management Science*, vol. 18, pp. 718–731.
93. Khytrova O., Sysoieva I., Dolha H., Peniuk V., Motuzenko O. (2020). Ensuring the Growth of Enterprises and Organizations Through the Motivation of Managerial Staff. *International Journal of Economics and Business Administration*, vol. 8, no. 2, pp. 219–228. <https://doi.org/10.35808/ijeba/454>
94. Kim S., Kojima M., Toh K. C. (2016). A Lagrangian-DNN Relaxation: A Fast Method for Computing Tight Lower Bounds for a Class of Quadratic Optimization Problems. *Mathematical Programming*, no. 156, pp. 161–187. <https://doi.org/10.1007/s10107-015-0874-5>
95. Kirkpatrick S., Gelatt Jr. C.D., Vecchi M.P. (1983). Optimization by Simulated Annealing. *Science*, no. 220, pp. 671–680.
96. Kiselakova D., Sofrankova B., Cabinova V., Onuferova E., Soltesova J. (2018). The Impact of R&D Expenditure on the Development of Global Competitiveness within the CEE EU Countries. *Journal of Competitiveness*, vol. 10, no. 3, pp. 34–50. <https://doi.org/10.7441/joc.2018.03.03>
97. Kolda T. G., Lewis R. M., Torczon V. (2003). Optimization by Direct Search: New Perspectives on Some Classical and Modern Methods. *SIAM Review*, vol. 45, issue 3, pp. 385–482.
98. Kolda T. G., Lewis R. M., Torczon V. (2006). A Generating Set Direct Search Augmented Lagrangian Algorithm for Optimization with a Combination of General and Linear Constraints. Technical Report SAND2006-5315. Oak Ridge, Sandia National Laboratories, August 2006.
99. Kolen A. (1983). Solving Covering Problems and the Uncapacitated Plant Location on the Trees. *European Journal of Operational Research*, vol. 12, issue 3, pp. 266–278.
100. Koza J.R. (1994). *Genetic Programming II. Automatic Discovery of Reusable Programs*. Cambridge, Massachusetts, MIT Press.
101. Krarup J., Pruzan P.M. (1983). The Simple Plant Location Problem: Survey and Synthesis. *European Journal of Operational Research*, vol. 12, pp. 36–81.
102. Kruschwitz L., Lorenz D. (2019). *Investitionsrechnung*. De Gruyter Oldenbourg (Verlag).
103. Kuhn T. (2017). Digitaler Zwilling. *Informatik Spektrum*, vol. 40, no. 5, pp. 440–444.

104. Lee J., Bagheri B., Kao H. (2015). A Cyber-physical Systems Architecture for Industry 4.0-based Manufacturing Systems. *Manufacturing Letters*, no. 3, pp. 18–23.
105. Lee J., Lapira E., Bagheri B., Kao H. (2013). Recent Advances and Trends in Predictive Manufacturing Systems in Big Data Environment. *Manufacturing Letters*, vol. 1, no. 1, pp. 38–41.
106. Lewis R. M., Shepherd A., Torczon V. (2007). Implementing Generating Set Search Methods for Linearly Constrained Minimization. *SIAM Journal on Scientific Computing*, vol. 29, issue 6, pp. 2507–2530.
107. Li B., Jin B.-f. (2018). Research on Dynamic Multi-objective FJSP Based on Genetic Algorithm. 2018 IEEE 16th Intl Conf on Dependable, Autonomic and Secure Computing, 16th Intl Conf on Pervasive Intelligence and Computing, 4th Intl Conf on Big Data Intelligence and Computing and Cyber Science and Technology Congress (DASC/PiCom/DataCom/CyberSciTech), pp. 347–352. <https://doi.org/10.1109/DASC/PiCom/DataCom/CyberSciTec.2018.00-97>
108. Long Q., Wu Ch., Wang X., Jiang L., Li J. (2015). A Multiobjective Genetic Algorithm Based on a Discrete Selection Procedure. *Mathematical Problems in Engineering*, vol. 2015, 17 pages, <https://doi.org/10.1155/2015/349781>
109. Maghawry A., Hodhod R., Omar Y., Kholief M. (2021). An Approach for Optimizing Multi-objective Problems Using Hybrid Genetic Algorithms. *Soft Computing*, vol. 25, no. 9, pp. 389–405. <https://doi.org/10.1007/s00500-020-05149-3>
110. McKinnon K. I. M. (1996). Convergence of the Nelder-Mead Simplex Method to a Non-Stationary Point. *SIAM Journal on Optimization*, vol. 9, pp. 148–158. <https://doi.org/10.1137/S1052623496303482>
111. Messac A., Ismail-Yahaya A., Mattson C. A. (2003). The Normalized Normal Constraint Method for Generating the Pareto Frontier. *Structural and Multidisciplinary Optimization*, vol. 25, no. 2, pp. 86–98. <https://doi.org/10.1007/s00158-002-0276-1>
112. Metropolis N., Rosenbluth A. W., Rosenbluth M. N., Teller A. H., Teller E. (1953). Equation of State Calculations by Fast Computer Machines. *Chemical Physics*, vol. 21, no. 6, June, pp. 1087–1092.
113. Michalewicz Z. (1996). *Genetic Algorithms + Data Structures = Evolution Programs*. New York, Springer-Verlag.
114. Mirchandani P., Jagannathan R. (1989). Discrete Facility Location with Nonlinear Diseconomies in Fixed Costs. *Annals of Operations Research*, vol. 18, pp. 213–224. <https://doi.org/10.1007/BF02097804>
115. Mirchandani P. B., Francis R. L. (1990). *Discrete Location Theory*. New York, John Wiley & Sons.
116. Monmarche N., Guinand F., Siarry P. (2010). *Artificial Ants*. Wiley-ISTE, 2010.
117. Motta S. R., Silvana A. M. B., Paulo L. R. M. (2012). A Modified NBI and NC Method for the Solution of N-Multiobjective Optimization Problems. *Structural and Multidisciplinary Optimization*, vol. 46, no. 2, pp. 239–259. <https://doi.org/10.1007/s00158-011-0729-5>

118. Mouhoub M., Wang Zh. (2008). Improving the Ant Colony Optimization Algorithm for the Quadratic Assignment Problem. 2008 IEEE Congress on Evolutionary Computation (IEEE World Congress on Computational Intelligence). Hong Kong, pp. 250–257. <https://doi.org/10.1109/CEC.2008.4630807>
119. Munna A. (2021). Strategic Management, Leadership and Staff Motivation: Literature Review. *International Education and Culture Studies*, vol. 1, no. 1, pp. 21–29.
120. Murray A. T., Tong D. (2007). Coverage Optimization in Continuous Space Facility Siting. *International Journal of Geographical Information Science*, vol. 21, issue 7, pp. 757–776.
121. Negri E., Fumagalli L., Macchi M. (2017). A Review of the Roles of Digital Twin in CPS-based Production Systems. *Procedia Manufacturing*, no. 11, pp. 939–948.
122. Nguyen H. A., Van Iperen Z., Raghunath S., Abramson D., Kipouros T., Somasekharan S. (2017). Multi-objective Optimisation in Scientific Workflow. *Procedia Computer Science*, vol. 108, pp. 1443–1452.
123. Nikseresht M., Raji M. (2021). MOGATS: a Multi-objective Genetic Algorithm-based Task Scheduling for Heterogeneous Embedded Systems. *International Journal of Embedded Systems*, vol. 14, no. 2, pp. 171–184. <https://doi.org/10.1504/IJES.2021.113811>
124. Oliveira S., Hussin M. S., Stutzle T., Roli A., Dorigo M. (2011). A Detailed Analysis of the Population-Based Ant Colony Optimization Algorithm for the TSP and the QAP. *Genetic and Evolutionary Computation Conference, GECCO'11 – Companion Publication*. pp. 13–14. <https://doi.org/10.1145/2001858.2001866>
125. Oliveira S., Hussin M. S., Roli A., Dorigo M., Stutzle T. (2017). Analysis of the Population-Based Ant Colony Optimization Algorithm for the TSP and the QAP. 2017 IEEE Congress on Evolutionary Computation (CEC). San Sebastian, pp. 1734–1741, <https://doi.org/10.1109/CEC.2017.7969511>
126. Periaux J. (1998). Genetic Algorithms for Electromagnetic Backscattering Multiobjective Optimization. *Genetic Algorithms for Electromagnetic Computation*, no. 6, pp. 30–39.
127. Periaux J., Sefrioui M. (1998). *Evolutionary Computational Methods for Complex Design in Aerodynamics*. Reno.
128. Periaux J., Sefrioui M., Ganascia J. G. (1998). Fast Convergence Thanks to Diversity. *Evolutionary Computing*, San Diego, pp. 9–15.
129. Periaux J. (2001). Combining Game Theory and Genetic Algorithms with Application to DDM-Nozzle Optimization Problems. *Finite Elements in Analysis and Design*, vol. 37, issue 5, May 2001, pp. 417–429. URL: [https://doi.org/10.1016/S0168-874X\(00\)00055-X](https://doi.org/10.1016/S0168-874X(00)00055-X)
130. Polyanin A., Pronyaeva L., Pavlova A., Fedotenkova O., Rodionov D. (2020). Integrated Approach for Assessing the Economic Security of a Cluster. *International Journal of Technology*, vol. 11, issue 6, pp. 1148–1160. <https://doi.org/10.14716/ijtech.v11i6.4420>

131. Popadinets I., Andrusiv U., Galtsova O., Bahorka M., Yurchenko N. (2021). Management of Motivation of Managers' Work At the Enterprises of Ukraine: Innovative Aspects. *Management Systems in Production Engineering*, vol. 29, pp. 120–131. <https://doi.org/10.2478/mspe-2021-0016>
132. Povh J., Rendl F. (2009). Copositive and Semidefinite Relaxations of the Quadratic Assignment Problem. *Discrete Optimization*, no. 6, pp. 231–241. <https://doi.org/10.1016/j.disopt.2009.01.002>
133. Powell M. J. D. (1973). On Search Directions for Minimization Algorithms. *Mathematical Programming*, vol. 4, pp. 193–201.
134. Rafiei S. M. R., Amirahmadi A., Griva G. (2009). Chaos Rejection and Optimal Dynamic Response for Boost Converter Using SPEA Multi-objective Optimization Approach. 2009 35th Annual Conference of IEEE Industrial Electronics, Porto, pp. 3315–3322. <https://doi.org/10.1109/IECON.2009.5415056>
135. Rendl F., Sotirov R. (2007). Bounds for the Quadratic Assignment Problem Using the Bundle Method. *Mathematical Programming*, no. 109, pp. 505–524. <https://doi.org/10.1007/s10107-006-0038-8>
136. Rosen R., Wichert G., Lo G., Bettenhausen K. D. (2015). About the Importance of Autonomy and Digital Twins for the Future of Manufacturing. *IFAC-PapersOnLine*, vol. 48, no. 3, pp. 567–572.
137. Rutkowska D., Pilinski M., Rutkowski L. (1999). *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*. Warszawa, Lodz: Wydawnictwo Naukowe PWN.
138. Ryusuke F., Dobata S., Sugawara K., Matsuno F. (2014). Designing Pheromone Communication in Swarm Robotics: Group Foraging Behavior Mediated by Chemical Substance. *Swarm Intelligence*, vol. 8, no. 3, pp. 227–246. <https://doi.org/10.1007/s11721-014-0097-z>
139. Sadollah A., Nasir M., Geem Z. W. (2020). Sustainability and Optimization: From Conceptual Fundamentals to Applications. *Sustainability*, vol. 12, no. 2027, pp. 2–34. <https://doi.org/10.3390/su12052027>
140. Salimi N., Rezaei J. (2018). Evaluating Firms' R&D Performance Using Best Worst Method. *Evaluation and Program Planning*, vol. 66, pp. 147–155. <https://doi.org/10.1016/j.evalprogplan.2017.10.002>
141. Sardaraz M., Tahir M. (2020). A Parallel Multi-objective Genetic Algorithm for Scheduling Scientific Workflows in Cloud Computing. *International Journal of Distributed Sensor Networks*, vol. 16, issue 8. <https://doi.org/10.1177/1550147720949142>
142. Schwarz G., Eva N., Newman A. (2020). Can Public Leadership Increase Public Service Motivation and Job Performance?. *Public Administration Review*, vol. 80. <https://doi.org/10.1111/puar.13182>
143. Sendin J. O. H., Alonso A. A., Banga J. R. (2010). Efficient and Robust Multi-objective Optimization of Food Processing: A Novel Approach with Application to Thermal Sterilization. *Journal of Food Engineering*, vol. 98, no. 3, pp. 317–324. <https://doi.org/10.1016/j.jfoodeng.2010.01.007>

144. Sim K., Kim J. (2004). Solution of Multiobjective Optimization Problems: Coevolutionary Algorithm Based on Evolutionary Game Theory. *Artif Life Robotics*, vol. 8, pp. 174–185. <https://doi.org/10.1007/s10015-004-0308-6>
145. Stutzle T., Hoos H. (1997). MAX-MIN Ant System and Local Search for the Traveling Salesman Problem. *IEEE International Conference on Evolutionary Computation*, pp. 309–314.
146. Stutzle T., Lopez-Ibanez M., Pellegrini P., Maur M., De Oca M., Birattari M., Dorigo M. (2011). Parameter Adaptation in Ant Colony Optimization. In: Hamadi Y., Monfroy E., Saubion F. (eds) *Autonomous Search*. Berlin, Heidelberg: Springer, pp. 191–215. [https://doi.org/10.1007/978-3-642-21434-9\\_8](https://doi.org/10.1007/978-3-642-21434-9_8)
147. Szu H. H., Hartley R. L. (1987). Fast Simulated Annealing. *Physical Letters*, no. 122, pp. 157–162.
148. Tamir A. (1988). Improved Complexity Bounds for Center Location Problems on Networks by Using Dinamic Data Structures. *SIAM J. Discrete Math.*, vol. 1, no. 3, pp. 377–396.
149. Tao F., Cheng J., Qi Q., Zhang M., Zhang H., Sui F. (2017). Digital Twin-driven Product Design, Manufacturing and Service with Big Data. *Int. J. Adv. Manuf. Technol.*, vol. 10, no. 4, pp. 22–33.
150. Tasgetiren M. F., Pan Q., Suganthan P. N., Dizbay I. E. (2013). Metaheuristic Algorithms for the Quadratic Assignment Problem. *2013 IEEE Symposium on Computational Intelligence in Production and Logistics Systems (CIPLS)*. Singapore, pp. 131–137. <https://doi.org/10.1109/CIPLS.2013.6595210>
151. Tashenova L., Babkin A., Mamrayeva D., Babkin I. (2020). Method for Evaluating the Digital Potential of a Backbone Innovative Active Industrial Cluster. *International Journal of Technology*, vol. 11, issue 8, pp. 1499–1508. <https://doi.org/10.14716/ijtech.v11i8.4537>
152. Thananant V., Auwatanamongkol S. (2019). Supervised Clustering based on a Multiobjective Genetic Algorithm. *Pertanika Journal of Science & Technology*, vol. 27, issue 1, January 2019, pp. 81–121.
153. Torczon V. J. (1997). On the Convergence of Pattern Search Algorithms. *SIAM Journal on Optimization*, vol. 7, no. 1, pp. 1–25. <https://doi.org/10.1137/S1052623493250780>
154. Tsutsui Sh. (2008). Parallel Ant Colony Optimization for the Quadratic Assignment Problems with Symmetric Multi Processing. *ANTS 2008: Ant Colony Optimization and Swarm Intelligence*, pp. 363–370. [https://doi.org/10.1007/978-3-540-87527-7\\_38](https://doi.org/10.1007/978-3-540-87527-7_38)
155. Uhlemann T. H.-J., Schock C., Lehmann C., Freiberger S., Steinhilper R. (2017). The Digital Twin. Demonstrating the Potential of Real Time Data Acquisition in Production Systems. *Procedia Manufacturing*, no. 9, pp. 113–120.
156. Vasant P. (2012). A Novel Hybrid Genetic Algorithms and Pattern Search Techniques for Industrial Production Planning. *International Journal of Modeling, Simulation, and Scientific Computing*, vol. 03, no. 04. <https://doi.org/10.1142/S1793962312500201>

157. Vasconcellos E.P.G., Muritiba S.N., Prado S.M.A., Vancetto M.D.C., Muritiba P.M. (2016). Analyzing R&D Projects on Health Products. *RAI Revista de Administracao e Inovacao*, no. 13, pp. 199–210. <http://dx.doi.org/10.1016/j.rai.2016.06.001>
158. Vos T., Heuvel W., Phillipson F., Huisman D. (2016). Using Lampposts to Provide Urban Areas with Multiple Services. Master's Thesis, *Econometrics and Management Science, Operations Research and Quantitative Logistics*. Rotterdam, Erasmus School of Economics, August 20. Available at: <https://scholar.google.com/citations?user=fnDQwyIAAAAJ&hl=nl>
159. Wang J., Liu Sh., Li M., Xiao P., Wang Zh., Wang L., Gui N., Chen Y. (2021). Multiobjective Genetic Algorithm Strategies for Burnable Poison Design of Pressurized Water Reactor. *International Journal of Energy Research*, vol. 45, issue 8, Special Issue: Progress in Emerging Nuclear Energy Systems, no. 25, June 2021, pp. 11930–11942. <https://doi.org/10.1002/er.5926>
160. Whitley D. (1994). A Genetic Algorithm Tutorial. *Stat Comput*, vol. 4, pp. 65–85. <https://doi.org/10.1007/BF00175354>
161. Yao X. (1995). A New Simulated Annealing Algorithm. *International Journal of Computer Mathematics*, no. 56, pp. 161–168.
162. Yashin S., Koshelev E., Tsymbalov S., Yashina N., Potashnik Y. (2020). Assessment of Material and Intangible Motivation of Top Management in Regions Using Multipurpose Genetic Algorithm. *Proceedings of the International Conference Digital Age: Traditions, Modernity and Innovations (ICDATMI 2020)*, vol. 489, pp. 33–39. <https://doi.org/10.2991/assehr.k.201212.009>
163. Yashin S., Yashina N., Koshelev E., Kashina O., Pronchatova-Rubtsova N. (2020). Foresight of Volga Federal District Innovation System Development using a Multi-Objective Genetic Algorithm. *International Journal of Technology*, vol. 11, issue 6, pp. 1171–1180. <https://doi.org/10.14716/ijtech.v11i6.4432>
164. Zhang Y., Wang S., Ji G. (2013). A Rule-Based Model for Bankruptcy Prediction Based on an Improved Genetic Ant Colony Algorithm. *Mathematical Problems in Engineering*, pp. 1–10. <https://doi.org/doi:10.1155/2013/753251>

Подписано в печать 29.11.2022.  
Формат 60×84 1/16.  
Бумага офсетная. Гарнитура Times New Roman. Печать цифровая.  
Усл. печ. л. 12,5.  
Тираж 500 экз. Заказ № 22\_1109.

Отпечатано в полном соответствии  
с предоставленным электронным оригинал-макетом  
в ООО «Печатная Мастерская РАДОНЕЖ»  
603002, Нижний Новгород, ул. Интернациональная, 100.  
Тел.: +7 (831) 418-53-23.