

На правах рукописи



Сопов Евгений Александрович

**ОБОБЩЕННЫЙ МЕТОД СИНТЕЗА ГИПЕРЭВРИСТИЧЕСКИХ
ЭВОЛЮЦИОННЫХ АЛГОРИТМОВ ОПТИМИЗАЦИИ
СЛОЖНЫХ СИСТЕМ**

05.13.01 – Системный анализ, управление и обработка информации
(космические и информационные технологии)

Автореферат диссертации на соискание учёной степени
доктора технических наук

Красноярск – 2021

Работа выполнена в Федеральном государственном бюджетном образовательном учреждении высшего образования «Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева» (СибГУ им. М.Ф. Решетнева), г. Красноярск.

Научный консультант: доктор технических наук, профессор
Семенкин Евгений Станиславович

Официальные
оппоненты:

Горнов Александр Юрьевич,
доктор технических наук,
Федеральное государственное бюджетное учреждение
науки Институт динамики систем и теории управления
имени В.М. Матросова Сибирского отделения Российской
академии наук, лаборатория оптимального управления,
главный научный сотрудник
Демидова Лилия Анатольевна,
доктор технических наук, профессор,
ФГБОУ ВО «МИРЭА - Российский технологический
университет», кафедра корпоративных информационных
систем, профессор
Скобцов Юрий Александрович,
доктор технических наук, профессор,
ФГАОУ ВО «Санкт-Петербургский государственный
университет аэрокосмического приборостроения»,
кафедра компьютерных технологий и программной
инженерии, профессор

Ведущая организация: ФГАОУ ВО «Национальный исследовательский
университет ИТМО»

Защита состоится «08» октября 2021 года в 14:00 на заседании диссертационного совета Д 212.249.05, созданного на базе ФГБОУ ВО «Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева» по адресу: 660037, г. Красноярск, проспект имени газеты Красноярский рабочий, 31.

С диссертацией можно ознакомиться в библиотеке ФГБОУ ВО «Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева» и на сайте: <https://www.sibsau.ru>.

Учёный секретарь
диссертационного совета

Панфилов Илья Александрович

ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

Актуальность темы исследования связана с постоянно возрастающей сложностью задач прикладного системного анализа. При этом практически на всех этапах прикладного системного анализа возникают постановки задач, которые сводятся к оптимизационным. К ним относятся как исходно оптимизационные постановки задач (задачи математического программирования и исследования операций, задачи параметрического проектирования, задачи поиска эффективных альтернатив и другие), так и обеспечивающие задачи (структурная и параметрическая оптимизация моделей, синтез и настройка применяемых алгоритмов, оптимальное управление и т.д.). Свойства сложных систем отражаются на свойствах возникающих задач оптимизации, которые можно отнести к классу сложных.

Отсутствие или неполнота информации об исследуемой системе определяет общий признак сложных задач оптимизации — невозможность адекватно выполнить и применить на практике результаты математического анализа, либо сложность такого анализа оказывается сравнимой со сложностью самой задачи оптимизации. Целевые функции подобных задач рассматриваются как модели «черного ящика», а соответствующий класс задач — оптимизация «черного ящика» (*Black-box Optimization*). В свою очередь, отсутствие информации о линейности, гладкости, выпуклости и прочих свойствах целевых функций исключает или существенно затрудняет применение традиционных методов математического программирования. Кроме того, во многих современных задачах оптимизации оценка целевых функций в принципе осуществляется алгоритмически, например, в ходе компьютерных симуляций и экспериментов или путем экспертной оценки.

Среди других свойств, определяющих сложную систему выделяют число факторов и связей. Увеличение количества переменных экспоненциально увеличивает пространство поиска («проклятие размерности»), а в случае немасштабируемых задач, меняет ландшафт целевой функции. Соответствующий класс называется задачи глобальной оптимизации большой размерности (*Large Scale Global Optimization*). Другое свойство сложных систем — нестационарность, связанная с внутренними и внешними изменениями. Изменения в среде могут произвольно влиять на ландшафт целевой функции, меняя положения и свойства глобального и локальных оптимумов, создавая новые и уничтожая ранее существовавшие оптимумы. Изменения могут происходить во время решения задачи оптимизации, при этом момент времени и характер изменений заранее не известны и, в общем случае, могут быть случайными. Соответствующий класс задач называется глобальной оптимизацией в нестационарной среде (*Optimization in the Non-stationary Environment*). В практических задачах анализа сложных систем для повышения устойчивости решений и для обеспечения разнообразия альтернатив для лица принимающего решения, требуется найти не единственное оптимальное решение задачи, а некоторое подмножество глобальных и локальных решений. Данное требование определяет класс задач оптимизации, связанный с аппроксимацией множества оптимумов (*Multimodal Optimization*).

В настоящее время для решения перечисленных классов задач успешно применяются на практике различные метаэвристические алгоритмы прямого («слепого») поиска. Высокую эффективность демонстрируют стохастические

популяционные метаэвристики на основе моделирования процессов из биологии, физики, химии и других естественных процессов. Наиболее известной и применяемой на практике метаэвристикой являются эволюционные алгоритмы (ЭА), которые сегодня рассматриваются как самостоятельное направление в оптимизации – эволюционная оптимизация. Тем не менее, эффективность применения ЭА для решения сложных задач оптимизации зависит от корректно выбранной структуры (типа) ЭА и настройки параметров алгоритма. Для решения задачи настройки параметров предложены и исследованы различные подходы самонастройки, самоадаптации и самоконфигурации. Как показывает практика, больший эффект можно получить за счет создания нестандартных комбинаций эвристик, т.е. проектирования новых ЭА.

В области машинного обучения активно развивается направление автоматизации синтеза алгоритмов, цель которого представить задачу проектирования алгоритма как самостоятельную задачу машинного обучения. Аналогичный подход возник относительно недавно в области комбинаторной оптимизации и получил название гиперэвристики. Гиперэвристику можно рассматривать как метаэвристику верхнего уровня, решающую задачу построения (управления, поиска, выбора) метаэвристики нижнего уровня для решения конкретной задачи оптимизации. На сегодня гиперэвристики синтеза ЭА для решения описанных выше задач оптимизации сложных систем практически не исследованы, поэтому тема выбранного исследования актуальна для развития теории и практики системного анализа.

Степень разработанности темы исследования. Систематизация гиперэвристических подходов и современная терминология предложена Бёрком Э. в 2009. В настоящее время наиболее цитируемые исследования в области гиперэвристик связаны с работами Бёрка Э., Росс П., Пиллей Н., Эпитропакис М., Лиссовой А. Проблемой разработки и исследования гиперэвристик занимаются международная исследовательская группа COSEAL (*COnfiguration and SElection of ALgorithms*), группа «Исследование операций» Лондонского университета королевы Марии, проблеме посвящены ежегодные специальные сессии ведущих конференций по эволюционным вычислениям GECCO (*Genetic and Evolutionary Computation Conference by ACM*), CEC (*IEEE Congress on Evolutionary Computation*) и PPSN (*Parallel Problem Solving from Nature*). Среди российских исследователей, внесших вклад в развитие теории и практики ЭА и их применения при решении сложных задач оптимизации необходимо отметить Шалыто А.А., Буздалова М.В., Скобцова Ю.А., Демидову Л.А., Горнова А.Ю., Курейчика В.М., Карпенко А.П., Дивеева А.И., Пантелеева А.В., Гладкова Л.А. В их работах, помимо традиционных ЭА, систематизированы и обсуждаются гибридные подходы, островные модели и методы самонастройки и самоконфигурации. В Красноярске теорией и практикой автоматизации проектирования ЭА занимается научная школа Семенкина Е.С.

Идея настоящего диссертационного исследования состоит в обосновании и совершенствовании теории, систематизирующей идеи и принципы создания и комбинирования эвристик различных ЭА или выбора среди известных комбинаций (известных ЭА) как при проектировании ЭА для решения частных задач или класса задач оптимизации, так и адаптивно в процессе решения конкретной задачи оптимизации.

Объектом диссертационного исследования является проблема автоматизированного (с минимальным участием или без участия человека) синтеза ЭА решения сложных задач глобальной оптимизации с алгоритмически заданными целевыми функциями, включая задачи глобальной оптимизации большой размерности, задачи аппроксимации множества экстремумов и задачи оптимизации в нестационарной среде, а **предметом исследования** – методы и алгоритмы решения данных задач на основе гиперэвристик.

Целью диссертационного исследования является расширение области применения и повышение обоснованности выбора методов эволюционной оптимизации сложных систем за счет адаптивного синтеза эволюционных алгоритмов с помощью гиперэвристик.

Поставленная цель достигается путем решения следующих **задач**:

1. Провести системный анализ проблемы синтеза ЭА и выполнить систематизацию подходов на основе эволюционных мета- и гиперэвристик, формализовать цели синтеза новых алгоритмов для выбранных классов задач оптимизации и критерии оценки эффективности ЭА, полученных в результате синтеза.

2. Обосновать и разработать алгоритмы синтеза ЭА для исследуемых в диссертации классов задач оптимизации, провести численные исследования их эффективности и сравнительный анализ эффективности с известными подходами и другими специальными подходами.

3. Провести апробацию предложенных подходов путем решения прикладных задач оптимизации и сравнительный анализ с результатами, полученными традиционными подходами.

4. Обобщить результаты диссертационного исследования, обосновать и формализовать обобщенный метод синтеза ЭА для решения задач оптимизации сложных систем с помощью разработанных гиперэвристик.

Научная новизна работы состоит в следующем:

1. Впервые систематизированы знания о способах синтеза эволюционных алгоритмов решения сложных задач глобальной оптимизации с алгоритмически заданными функциями, предложена общая методика применения гиперэвристик синтеза ЭА для решения этих задач. Обобщенный метод позволяет адаптивно создавать новые эффективные ЭА в зависимости от целей и требований к решению задачи оптимизации и управлять применением предложенных гиперэвристик в зависимости от комбинации свойств исследуемой сложной системы.

2. Предложена и исследована новая конструктивная офлайн гиперэвристика для синтеза операторов селекции ЭА на основе алгоритма генетического программирования. Гиперэвристика отличается от известных подходов способом представления решений и вариантами оценки пригодности синтезируемых операторов.

3. Впервые предложена и исследована селективная онлайн гиперэвристика синтеза ЭА оптимизации в нестационарной среде, объединяющая идеи метода портфолио и идеи метода адаптации вероятностей на уровне популяции ЭА. Новая гиперэвристика позволяет идентифицировать изменения в среде и адаптировать ЭА

путем формирования эффективной комбинации эвристик нестационарной оптимизации.

4. Впервые предложена и исследована селективная гиперэвристика синтеза ЭА идентификации множества экстремумов, включающая базовые эвристики, которые не используют в явном виде какую-либо информацию о свойствах целевой функции и пространства поиска. Новая гиперэвристика позволяет адаптивно формировать эффективную комбинацию эвристик поддержки разнообразия в популяции на основе анализа скопления решений в областях притяжения оптимумов.

5. Предложена и исследована новая эвристика для группировки переменных на основе алгоритма оценки распределений для применения бинарного генетического алгоритма в задаче глобальной оптимизации большой размерности. Новая эвристика на основе анализа распределения генов позволяет определять подмножество компонентов вектора решения, значения которых могут быть зафиксированы, сокращая таким образом пространство поиска.

6. Предложена и исследована новая эвристика, использующая распределения вероятностей для адаптивной группировки переменных в компоненты переменного размера на этапе декомпозиции в кооперативной коэволюции. Новая эвристика является обобщением метода DECC-G.

7. Впервые предложена и исследована селективная онлайн гиперэвристика синтеза ЭА для задач глобальной оптимизации большой размерности на основе островной модели ЭА. В новой гиперэвристике каждый остров реализует свою декомпозицию задачи, при этом гиперэвристика позволяет адаптивно управлять эвристиками декомпозиции путем изменения размеров островов.

Теоретическая значимость работы заключается получении новых знаний о способах решения задач оптимизации сложных систем и эффективности их применения. Систематизация подходов к синтезу ЭА и результаты исследования эффективности конкретных алгоритмов решения сложных задач оптимизации разных классов, дополняют знания об эвристических методах оптимизации. Метод синтеза ЭА позволяет формировать новые комбинации эвристик для решения конкретных задач оптимизации, а исследование сформированных эффективных комбинаций эвристик может быть использовано при проведении фундаментального анализа свойств класса задач, изначально представленных моделью типа «черный ящик».

Практическая значимость работы обусловлена практикой системного анализа, связанной с исследованием и управлением сложными системами, для которых характерно сочетание различных свойств, затрудняющих выбор и применение многих традиционных методов решения возникающих задач оптимизации. Использование предложенных в работе гиперэвристик позволяет без участия или с минимальным вовлечением предметного специалиста формировать новые эвристики и создавать комбинации эвристик (новые метаэвристики), которые являются эффективными для решения конкретных задач. Автоматизированный синтез алгоритмов оптимизации позволит предметным специалистам сфокусироваться на исходных задачах прикладного системного анализа.

В работе показано, что предложенные подходы позволяют повысить точность решения задач глобальной оптимизации большой размерности в среднем по сравнению с точностью, усредненной по базовым метаэвристикам. Это означает, что

в случае решения задач с алгоритмически заданными целевыми функциями, когда обоснование выбора конкретного ЭА затруднено, использование предложенных гиперэвристик более предпочтительно, чем случайный выбор одного из базовых подходов. Аналогичный эффект наблюдается при решении задач аппроксимации множества экстремумов – предложенный подход позволяет получать лучшую в среднем аппроксимацию (большой процент идентифицированных оптимумов), а при решении задач оптимизации в нестационарной среде – лучшее в среднем значение онлайн-ошибки (разницы между лучшим найденным решением и истинным глобальным оптимумом на каждой итерации алгоритма).

Практическая реализация результатов. С помощью предложенных в работе подходов синтеза ЭА на основе гиперэвристик решены прикладные задачи оптимизации. Разработанные алгоритмы реализованы в виде программных систем для ЭВМ, которые используются в исследовательских и практических целях.

Предложенные в диссертационном исследовании методы проектирования ЭА были использованы при решении прикладных задач (акты использования представлены в тексте диссертации): Проектирование алгоритмического и программного обеспечения для системы автоматизированного формирования и контроля специальных партий электрорадиоизделий космического применения (АО «Испытательный технический центр НПО-ПМ», г. Железногорск), Проектирование и внедрение системы поддержки инвестиционного планирования для задач внешнего и конкурсного управления (ООО «Инвент», г. Красноярск), Проектирование алгоритмического и программного обеспечения системы диспетчеризации распределенной энергетической системы (АО «Назаровская ГРЭС», г. Назарово).

Научные и научно-технические результаты были получены и использованы в рамках НИР при руководстве следующими проектами: ФЦП «Научные и научно-педагогические кадры инновационной России на 2009-2013 годы», Российско-германский проект «Разработка эффективного алгоритмического обеспечения для автоматизированного проектирования распределенных мультилингвистических систем поддержки электронного документооборота на облачных вычислениях» госконтракт N14.740.12.1341 (2011-2013), Грант Президента РФ для молодых кандидатов наук «Самоконфигурируемая метаэвристика решения задач нестационарной оптимизации стохастическими поисковыми алгоритмами» МК-3285.2015.9 (2015-2016), Государственное задание по проекту «Разработка и исследование самоконфигурируемых гиперэвристик решения сложных задач нестационарной мультимодальной оптимизации бионическими алгоритмами» №2.1676.2017/ПЧ (2017-2019).

Отдельные результаты работы были использованы при проведении работ в рамках более 15 НИР, включая проекты в рамках ФЦП, проектную часть государственных заданий Минобрнауки, грантов РФФИ и другие. Результаты диссертационного исследования в целом сформулированы и представлены к защите в рамках государственного задания по проекту «Развитие теории самоконфигурирующихся алгоритмов машинного обучения для моделирования и прогнозирования характеристик компонентов сложных систем» № FEFE-2020-0013 (2020-2022).

Методы исследования. Основные теоретические и практические результаты получены с применением методов прикладного системного анализа, исследования операций, теории оптимизации, теории вероятностей и математической статистики, теории алгоритмов и методов программирования.

Основные положения, выносимые на защиту:

1. Конструктивная офлайн гиперэвристика для синтеза операторов селекции ЭА на основе алгоритма генетического программирования позволяет автоматически создавать новые способы отбора индивидов в ЭА, которые для исследуемого множества задач глобальной оптимизации с алгоритмически заданными целевыми функциями обеспечивают большую среднюю эффективность ЭА по сравнению с использованием стандартных операторов селекции по критериям точности нахождения или скорости нахождения глобального оптимума с заданной точностью.

2. Селективная онлайн гиперэвристика синтеза ЭА оптимизации в нестационарной среде обеспечивает в среднем лучшее значение по критерию онлайн-ошибки независимо от комбинации типов изменений в среде по сравнению со значением, усредненным по результатам применения отдельных базовых эвристик.

3. Селективная гиперэвристика синтеза ЭА идентификации множества экстремумов позволяет получить в среднем больший процент идентифицированных оптимумов по сравнению со значением, усредненным по результатам применения отдельных базовых эвристик для задач как с бинарными переменными, так и с вещественными.

4. Селективная гиперэвристика синтеза ЭА для задач глобальной оптимизации большой размерности с алгоритмически заданными целевыми функциями превосходит по средней точности нахождения глобального оптимума оценку случайного выбора ЭА на основе одной из базовых эвристик и оценку случайного выбора одного из ведущих ЭА для задач большой размерности.

5. Обобщенный метод синтеза ЭА обеспечивает специалистов в области эволюционной оптимизации эффективным инструментом для создания новых гиперэвристик, расширяя область применения ЭА решения сложных задач оптимизации.

Степень достоверности полученных в работе результатов и выводов обеспечивается корректным применением методов статистической обработки и анализа данных экспериментального исследования алгоритмов оптимизации на репрезентативном множестве эталонных задач оптимизации, результатами решения прикладных задач, а также многократной апробацией на ведущих международных конференциях.

Апробация. Основные положения и результаты диссертационного исследования представлялись и прошли всестороннюю апробацию на всероссийских, международных и зарубежных научных и научно-практических конференциях и семинарах, включая: The Genetic and Evolutionary Computation Conference (GECCO, 2019, Прага, Чехия), IEEE Symposium Series on Computational Intelligence (IEEE SSCI 2015, Кейптаун, ЮАР, IEEE SSCI 2020, Канберра, Австралия), International Conference on Swarm Intelligence (6th ICSI 2015, Пекин, Китай, 7th ICSI 2016, Бали, Индонезия, 9th ICSI 2018, Шанхай, Китай), 7th World Congress on Nature and Biologically Inspired Computing (NaBIC 2015, Питермаритцбург, ЮАР), International

Conference on Evolutionary Computation Theory and Applications (ECTA) в рамках International Joint Conference on Computational Intelligence (IJCCI) (7th ECTA/IJCCI 2015, Лиссабон, Португалия, 8th ECTA/IJCCI 2016, Порто, Португалия, 9th IJCCI 2017, Мадейра, Португалия, 10th IJCCI 2018, Севилья, Испания, 11th IJCCI 2019, Вена, Австрия), International Conference on Informatics in Control, Automation and Robotics (11th ICINCO 2014, Вена, Австрия, 12th ICINCO 2015, Кольмар, Франция, 13th ICINCO 2016, Лиссабон, Португалия, 15th ICINCO 2018, Порто, Португалия, 16th ICINCO 2019, Прага, Чехия), 4th International Congress on Advanced Applied Informatics (IAI-AAI 2015, Окаяма, Япония), International Conference on Applied Mathematics and Computational Science (ICAMCS 2018, Будапешт, Венгрия), 2019 IEEE International Conference on Information Technologies, InfoTech-2019, София, Болгария, International Conference on Computer Science and Artificial Intelligence (ICCSAI 2014, Ухань, Китай), International Conference on Network Security and Communication Engineering (NSCE 2014, Гонконг, Китай), International Workshop on Mathematical Models and their International Workshop on Mathematical Models and their Applications (IWMMA 2014-2020, Красноярск, Россия), Международная научно-практическая конференция «РЕШЕТНЕВСКИЕ ЧТЕНИЯ» (2009-2020, Красноярск, Россия), Пятая Международная конференция «Системный анализ и информационные технологии» (2013, Красноярск, Россия), 9th International Siberian Conference on Control and Communications (SIBCON 2011, Красноярск, Россия) и др.

Основные результаты исследований были отмечены Правительством и Законодательным собранием Красноярского края Государственной премией Красноярского края в области профессионального образования в 2016 году.

Диссертационная работа в целом обсуждалась на научных семинарах кафедры «Системного анализа и исследования операций» Сибирского университета науки и технологий (Красноярск) и факультета информационных технологий и программирования Университета ИТМО (Санкт-Петербург).

Публикации. По материалам диссертации опубликовано более 60 работ, в том числе 20 статей в российских рецензируемых периодических изданиях, рекомендуемых ВАК РФ для опубликования основных научных результатов диссертационных исследований, 39 работ в зарубежных изданиях, включенных в международную базу цитирования Scopus, 26 работы в зарубежных изданиях, включенных в международную базу цитирования Web of Science, опубликована глава в издании *Advances in Swarm Intelligence* (LNSC, Springer). В Роспатенте зарегистрированы 24 программы для ЭВМ.

Диссертация соответствует пункту 4 паспорта специальности 05.13.01 – разработка методов и алгоритмов решения задач системного анализа, оптимизации, управления, принятия решений и обработки информации.

Структура и объем работы. Диссертация изложена на 325 страницах, состоит из введения, шести глав, заключения, списка литературы из 444 наименований и шести приложений.

ОСНОВНОЕ СОДЕРЖАНИЕ РАБОТЫ

Во **введении** дана общая характеристика проблем оптимизации сложных систем и синтеза ЭА, обоснована актуальность темы исследования, определены цели и задачи, сформулированы основные положения, выносимые на защиту, научная новизна и практическая значимость полученных результатов.

В **Главе 1** проведен анализ свойств сложных систем и их отражение на свойствах задач оптимизации, возникающих на различных этапах прикладного системного анализа. Проведен анализ современных подходов к преодолению выявленных трудностей задач оптимизации, показаны сложности отнесения подобных задач к известным классам задач, изучаемых в математическом программировании и проблемы применения традиционных методов оптимизации. Рассмотрены традиционные подходы из области эволюционной оптимизации, даны определения эвристического, метаэвристического и гиперэвристического подходов в оптимизации.

В работе рассматривается следующая общая постановка задачи оптимизации:

$$f(\bar{x}) \rightarrow \min_{\bar{x} \in S} (\max), f: S \rightarrow R^1, \quad (1)$$

где $\bar{x} = (x_1, x_2, \dots, x_n)$ – независимые переменные задачи оптимизации, f – целевая функция (критерий качества решения задачи оптимизации), $S \subset R \times F \times N \times P$ – пространство поиска, R – область изменения вещественных переменных, F – область изменения дискретных переменных, N – область изменения переменных наименований, P – область изменения переменных перестановок.

Решением задачи (1), в предположении существования экстремума, является:

$$\bar{x}^* = \arg \min_{\bar{x} \in S} f(\bar{x}) \left(\arg \max_{\bar{x} \in S} f(\bar{x}) \right). \quad (2)$$

В данном исследовании на вид целевой функции $f(\bar{x})$ не накладываются никакие ограничения типа линейности, непрерывности, выпуклости и необходимость быть определенной во всех точках, запрашиваемых алгоритмом поиска. В общем случае целевая функция задана алгоритмически, информация о свойствах ее ландшафта отсутствует, целевая функция задачи (1) представляет собой модель «черного ящика».

Задачи оптимизации (1), в которых число переменных n велико, и это существенно затрудняет процесс решения задачи оптимизации, называют задачами оптимизации большой размерности. Во многих работах, посвященных проблеме оптимизации «черного ящика» показано, что для задач глобальной оптимизации с вещественными переменными и алгоритмически заданными функциями большинство известных метаэвристик перестают быть эффективными при $n \geq 100$. В настоящее время мировое научное сообщество, рассматривает подобные задачи при $n \geq 1000$.

В задачах оптимизации в нестационарной среде целевая функция может меняться во времени: изменяется ландшафт функции, а также количество, положения, размеры областей притяжения и значения глобального и локальных оптимумов. При этом задача (1)–(2) ставится в следующей форме:

$$f(\bar{x}, t) \rightarrow \min(\max)_{\bar{x} \in S(t)}, f: S(t) \rightarrow R^1, \quad (3)$$

$$X^* = \left\{ \bar{x}^*(t) = \arg \min_{\bar{x} \in S(t)} f(\bar{x}, t) \left(\arg \max_{\bar{x} \in S(t)} f(\bar{x}, t) \right), \forall t \in [0, t_{max}] \right\}, \quad (4)$$

где t – параметр времени.

Задача аппроксимации множества экстремумов, известная в англоязычных источниках как мультимодальная оптимизация (*Multimodal Optimization*), использует постановку задачи (1), но вместо решения (2) ищется множество решений (5):

$$X^* = \{x_i^{glob}, x_j^{local}, i = \overline{1, Global}, j = \overline{1, Local}\}, \quad (5)$$

где x_i^{glob} – решения, являющиеся глобальными экстремумами, x_j^{local} – решения, являющиеся локальными оптимумами. Замечание: решение (5) – идеальное требование для тестовых задач, используемых при разработке и исследовании новых методов, при решении практических задач, требуется дополнительная информация, чтобы отличить локальный оптимум от глобального.

В данной работе под эвристикой будем понимать способ (идею, алгоритм) решения частной задачи оптимизации, который обеспечивает более быстрое (по количеству вычисления целевой функции) решение задачи, чем традиционный формализованный метод или позволяет найти приемлемое приближенное решение, в случаях, когда традиционный формализованный метод не может получить точное решение задачи. Метаэвристиками называют более сложные и универсальные подходы, оперирующие в разных комбинациях более простыми эвристиками, которые могут применяться для целого класса задач оптимизации (Ф. Гловер, 1986).

Эволюционные алгоритмы оптимизации представляют собой один из наиболее популярных и эффективных при решении многих сложных задач оптимизации класс метаэвристик, которые используют общие принципы построения конкретного поискового алгоритма. Практика применения ЭА показала, что их эффективность существенно зависит от выбранной структуры и настройки параметров. Структуру конкретного ЭА для решения задач выбранного класса можно описать как:

$$EA = \{selection, \{p_{selection}\}, recombination, \{p_{recombination}\}, mutation, \{p_{mutation}\}, \{heuristic\}, \{p_{heuristic}\}, \{control\}\}, \quad (6)$$

где $selection \in Selection$ и $\{p_{selection}\}$ – выбранная эвристика управления операцией селекции и множество ее параметров, $recombination \in Recombination$ и $\{p_{recombination}\}$ – выбранная эвристика управления операцией рекомбинации и множество ее параметров, $mutation \in Mutation$ и $\{p_{mutation}\}$ – выбранная эвристика управления операцией мутации и множество ее параметров, $\{heuristic\} \subset Heuristic$ и $\{p_{heuristic}\}$ – множество эвристик, учитывающих особенности класса задач и их параметры, $\{control\} \in Control$ – множество эвристик управления алгоритмом (способ инициализации, стратегия замещения при формировании новой популяции, критерии останова и др.).

Задача синтеза ЭА оптимизации может быть представлена как задача комбинаторной оптимизации более высокого уровня, в которой пространство поиска – это множество метаэвристик, описанных как (6), а целевая функция отражает оценку эффективности решения задач выбранного класса (7):

$$\psi(EA) \rightarrow \min_{EA \in HS}(\max), \psi: HS \rightarrow R^1, \quad (7)$$

где $HS \subset Selection \times Recombination \times Mutation \times Heuristic \times Control$ – пространство поиска метаэвристик.

Методы решения задачи (7) для целого класса задач оптимизации называются гиперэвристики. Очевидно, что для каждого класса задач оптимизации требуется формализовать свой критерий ψ . Более того, практические задачи могут накладывать на ψ дополнительные ограничения, например, связанные с программно-аппаратной реализацией синтезированных алгоритмов. В более сложной постановке элементы множеств *Selection*, *Recombination*, *Mutation*, *Heuristic* и *Control* заранее не определены, поэтому синтез базовых эвристик является самостоятельной задачей поисковой оптимизации, для которой критерий эффективности также совпадает с критерием ψ .

Одна из наиболее полных классификаций гиперэвристик, предложенная Эдмундом Бёрком, выделяет гиперэвристики с онлайн и офлайн обучением. Онлайн обучение подразумевает решение задачи (7) одновременно с задачами (1), (3) или (5), т.е. синтез метаэвристик осуществляется адаптивно под конкретную задачу оптимизации в процессе ее решения. Офлайн обучение связано с синтезом алгоритма, обеспечивающим высокую эффективность в среднем на некотором множестве (классе) задач. В главе 1 проведен анализ современного состояния подходов, связанных с решением задачи (7), обоснована необходимость развития подхода на основе эволюционных гиперэвристик.

Поскольку ЭА являются эвристическими, аналитическая оценка их эффективности затруднена. В настоящее время общепризнанной практикой является многократное независимое решение задач, накопление данных о процессе и результатах решения задачи с последующей статистической обработкой и анализом результатов. При проверке статистической значимости разницы в оценках ЭА сильное смещение оценок при «неудачных» прогонах ЭА приводит к известной проблеме множественного сравнения, сказывающейся на групповой вероятности ошибки первого рода. В настоящем исследовании, данная проблема решается за счет применения идей нового метода глубокого статистического сравнения (*Deep Statistical Comparison*, DSC), предложенного в 2018 году Томе Эфтимов. Для оценки эффективности офлайн гиперэвристик используются оценки обобщающей способности ЭА, т.е. оценки валидации, аналогичные применяемым в методах машинного обучения.

В ходе анализа различных тестовых задач оптимизации, в данной работе были выбраны наборы эталонных тестовых задач, которые разрабатывались, обсуждались и позже использовались при проведении соревнований по оптимизации в рамках ведущих (ранг А по метрикам ERA и Qualis) конференций по эволюционной оптимизации: Конгресса по эволюционным вычислениям (*Congress on Evolutionary Computation*, CEC) при поддержке международного сообщества вычислительного интеллекта IEEE и Конференции по генетическим и эволюционным вычислениям (*The Genetic and Evolutionary Computation Conference*, GECCO) при поддержке международной ассоциации вычислительной техники (*Association for Computing Machinery*, ACM). Данные эталонные задачи, во-первых, отражают различные особенности задач оптимизации для различных классов, что затрудняет разработку и

выбор ЭА, эффективного на всем множестве задач, а во-вторых, в открытом доступе представлены исходные коды для каждого набора задач и результаты численных экспериментов для некоторых ведущих ЭА, что обеспечивает честное сравнение эффективности алгоритмов и позволяет сопоставить результаты оценки новых ЭА с мировым уровнем. Стоит отметить, что эталонные задачи моделируют свойства реальных задач оптимизации, но на практике вся совокупность свойств встречается крайне редко, поэтому предполагается, что ЭА, эффективно решающие эталонные задачи, легче справляются с прикладными.

Глава 2 посвящена проблеме разработки гиперэвристик на основе алгоритма генетического программирования (ГП) для формирования эвристик ЭА. Метод ГП был предложен как метод автоматического синтеза компьютерных программ, но в последствии был адаптирован к решению многих других задач, в которых требуется синтезировать решение из набора предопределенных функций и терминальных элементов. В настоящее время ГП часто используют для построения различных алгоритмов (классификаторов, архитектур нейронных сетей, систем управления на нечеткой логике и других), а направление в целом называется гиперэвристики на основе ГП (*Genetic Programming Hyper-heuristics*, GPHH).

Экспериментальные исследования ЭА показывают, что оператор селекции является одним из наиболее важных в ЭА, т.к. именно он обеспечивает сходимость алгоритма в целом, а модификации оператора селекции часто применяются для учета свойств класса задач оптимизации. Селекция может быть рассмотрена как распределение вероятностей, определяющих выбор индивидов популяции для последующих операций с ними. Представим операцию селекции как некоторое отображение оценок пригодности индивидов на интервал $[0, 1]$. В общем случае оценки пригодности могут быть выражены вещественным числом (значение фитнес-функции) или рангом после попарного сравнения и сортировки решений:

$$selection(i): rank_i \rightarrow [0, 1], rank_i \in \mathbb{Z}, i = \overline{1, N}, \quad (8)$$

$$selection(i): fitness_i \rightarrow [0, 1], fitness_i \in R, i = \overline{1, N}, \quad (9)$$

$$\sum_{i=1}^N selection(i) = 1, \quad (10)$$

где $selection(i)$ – оператор селекции, i – индивид из текущей популяции размера N , $rank_i$ – значение ранга после упорядочивания индивидов, $fitness_i$ – значение пригодности индивида, условие (10) обеспечивает выполнение условия нормировки для закона распределения вероятностей.

В работе предложен следующий подход к синтезу операторов селекции, который, согласно классификации Бёрка, можно отнести к конструктивной офлайн гиперэвристике:

Метод 1. Конструктивная офлайн гиперэвристика на основе алгоритма ГП для синтеза операторов селекции ЭА.

Вход: Обучающее и тестовое множество задач оптимизации.

Инициализация: Определить основные параметры ГП и ЭА, задать функциональное и терминальное множества для ГП.

Повторять, пока не выполнится условие остановки ГП (внешний цикл ГП):

Сформировать очередную популяцию в ГП.

Повторять, пока не решены все задачи из обучающего множества (внутренний цикл ЭА):

Выбрать очередную задачу, применить ЭА с оператором селекции, синтезированным в ГП.

Собрать статистику о результатах независимых прогонов ЭА на текущей задаче, оценить эффективность ЭА.

Оценить среднюю эффективность ЭА на множестве задач и присвоить это значение в качестве пригодности решения в ГП, используя (11)-(13) или (15)-(18).

Выход: Лучшее найденное решение в ГП.

Для исследования эффективности метода 1 было выбрано обучающее множество задач, которое содержит 24 эталонные тестовые задачи (*Black-Box Optimization Benchmark*, ВВОВ), сгруппированные по свойствам в 5 групп, при разбишке на обучающее и тестовое множество используется стратифицированный отбор. Кросс-валидация применялась к 5 случайным наборам.

Терминальное множество ГП содержит только одну независимую переменную – ранг индивида после попарного сравнения и сортировки по пригодности, а также случайные константы. Функциональное множество содержит математические операции (+, −, ×, ÷) и математические функции (*sin*, *exp*), а также 2 автоматически определяемые функции (*Automatically Defined Functions*, ADF), представляющие собой операторы линейного ранжирования и экспоненциального ранжирования с коэффициентом $c = 0.8$.

В методе 1 критерий (7) зависит лишь от эвристики управления операцией селекции $\psi(selection, \{p_{selection}\})$ и вычисляется как пригодность в ГП по следующим формулам:

$$fitnessGP(A_k) = \frac{1}{F} \sum_{i=1}^F \left(\frac{1}{R} \sum_{j=1}^R PerformanceEA_{ij}(A_k) \right), k = \overline{1, N_{GP}}, \quad (11)$$

$$PerformanceEA_{ij} = \frac{\max(Dist_i) - Dist_{ij}}{\max(Dist_i)}, \quad (12)$$

$$Dist_{ij} = \|\bar{x}_i^* - (\bar{x}_{bestFound})_{ij}\|, \quad (13)$$

где $fitnessGP$ – пригодность решения A_k в ГП, решение A_k представляет собой формулу (алгоритм) вычисления вероятностей отбора, N_{GP} – размер популяции в ГП, F – число задач обучающего множества, R – число независимых запусков ЭА на одной задаче, $PerformanceEA_{ij}$ – оценка эффективности ЭА на i -й задаче в j -м запуске, $Dist_{ij}$ – расстояние от лучшего найденного решения $\bar{x}_{bestFound}$ до истинного значения глобального оптимума $\bar{x}^*$, $\max(Dist_i)$ – максимально возможное расстояние для i -й задачи.

Решение задачи и график сходимости ГП для одного из вариантов разделения задач на обучающие и тестовые показан на рисунке 1. На рисунке 2 показаны результаты ранжирования различных типов селекции на множестве задач ВВОВ (меньший ранг соответствует лучшему значению). Синтезированная эвристика селекции показала статистически значимое превосходство над известными типами селекции на 20 эталонных задачах из 24.

Синтезированный оператор селекции имеет вид:

$$p_{synth}(rank_i) = \frac{10 \sin(0.1 rank_i - 5) + rank_i - 9.82453}{707.405}, \quad (14)$$




Рисунок 1. График лучшего найденного распределения вероятностей (слева), график изменения лучшей и средней пригодности в ГП (справа)




Рисунок 2. Ранжирование эффективности применения операторов селекции на множестве задач ВВОВ

Оператор селекции может быть спроектирован и с учетом других требований. Для многих прикладных задач требуется повысить скорость нахождения решения, выраженную через число итераций или число вычислений целевой функции. Поскольку требования точности и скорости нахождения решения являются конфликтующими, данную задачу можно сформулировать как задачу условной оптимизации (15) при наличии ограничения (16). Функция пригодности в методе ГП с использованием метода динамических штрафов имеет вид (17)–(18):

$$ERT(A_k) = \frac{1}{F} \sum_{i=1}^F \left(\frac{1}{R} \sum_{j=1}^R \left[1 - \frac{\min\{RT_{ij}(A_k), ERT_r\}}{ERT_r} \right] \right), \quad (15)$$

$$g_{perf}(A_k) = \left[\frac{1}{F} \sum_{i=1}^F \left(\frac{1}{R} \sum_{j=1}^R SuccessRate_{ij}(A_k) \right) - \theta \right] \geq 0, \quad (16)$$

$$fitnessGP(A_k) = ERT(A_k) - \left(\frac{t}{2} \right)^2 \cdot \left(\hat{g}_{perf}(A_k) \right)^2, \quad (17)$$

$$\hat{g}_{perf}(A_k) = \min\{0, g_{perf}(A_k)\}, \quad (18)$$

где ERT – оценка среднего числа вычислений целевых функции обучающего множества для решения A_k в ГП, ERT_r – оценка вычислений целевых функции обучающего множества, полученная для стандартного генетического алгоритма (оценка снизу), $RT_{ij}(A_k)$ – число вычислений целевой функции для нахождения глобального оптимума с заданной точностью на i -й задаче в j -м запуске, θ – пороговое значение потери эффективности ЭА (определяется экспертно или по результатам решения задачи (11)), $g_{perf}(A_k)$ – ограничение задачи, $SuccessRate$ – процент успешных прогонов (когда глобальный оптимум найден с заданной точностью), $k = \overline{1, N_{GP}}$, $t = \overline{1, T}$, T – максимальное число итераций ЭА в одном независимом запуске.

При решении задачи (17) было получено решение (19) при пороговом значении $\theta = 60$ и решение (20) при $\theta = 70$ и $\theta = 80$:

$$p_{synth}(rank_i) = \frac{0.25rank_i^2 + 50 \sin(0.1rank_i - 5)}{10349.4}, \quad (19)$$

$$p_{synth}(rank_i) = \frac{0.1 \cdot e^{0.2 \cdot rank_i} - 0.5 \cdot (rank_i - 40)^2 + 760.38}{39707.08}, \quad (20)$$

Экспериментальное исследование предложенной гиперэвристики для синтеза оператора селекции в ЭА показало, что данный подход позволяет формировать новые базовые эвристики ЭА, которые демонстрируют высокую эффективность в среднем на всем множестве исследуемых задач и превосходят среднюю эффективность базовых операторов селекции, следовательно, использование новой эвристики предпочтительнее случайного выбора одного из стандартных операторов для задач типа «черный ящик».

Для апробации подхода была решена практическая задача проектирования эвристики для ЭА в задаче идентификации партий электронных компонентов аэрокосмического применения. В данной задаче ЭА используется для определения начальных координат центров кластеров для процедуры чередующихся размещений-распределений. Синтезированный с помощью метода 1 оператор селекции обеспечивает большую эффективность решения задач идентификации партий микросхем 140УД25АС1В и 1526ИЕ10 по критериям суммы расстояний от объектов до центров кластеров и ошибки классификации по сравнению со стандартным ГА с линейной ранговой селекцией и методом к-медиан со случайной инициализацией кластеров. Более того, применение синтезированной эвристики позволяет улучшить решения, полученные ранее с применением других подходов.

Глава 3 посвящена проблеме разработки и исследования гиперэвристик для решения задач оптимизации в нестационарной среде. Нестационарность является одним из основных свойств сложных систем и связана с динамической природой системы, изменениями внешней среды, изменениями целей системного анализа и управления, недостатком информации о системе и т.д.

Если изменения в среде происходят достаточно редко, то задача (3)–(4) может быть упрощена до серии независимых стационарных задач оптимизации. В общем случае изменения ландшафта целевой функции могут проявляться в произвольные, заранее неизвестные моменты времени, а сами изменения могут быть разного типа и разной интенсивности. Традиционные подходы прямого поиска, включая ЭА, имеют тенденцию сходиться к найденному оптимуму, теряя накопленную на прошлых этапах поиска информацию о пространстве поиска. ЭА для задачи (3)–(4) должны иметь возможность отслеживать изменения и адаптироваться к новым условиям, с целью обеспечить точность нахождения глобального оптимума и скорость адаптации к изменениям.

Известный специалист о области оптимизации в нестационарной среде Шенгшиян Янг отмечает, что для большинства практических задач этого класса не проявляется зависимость от времени, меняются не только координаты, но топология целевой функции, часто изменения непредсказуемые, изменения могут быть циклическими. Таким образом, каждая реализация задачи (3)–(4) является уникальной. В настоящее время не предложены метаэвристики, одинаково эффективные для всех типов изменений в среде, и, следовательно, возникает задача синтеза алгоритма

оптимизации в процессе решения задачи путем выбора эвристик из предопределённого множества.

В данной работе предложен следующий подход, объединяющий идеи метода портфолио алгоритмов (*Algorithm Portfolio*) из области машинного обучения и идеи метода адаптации вероятностей на уровне популяции (*Population-Level Dynamic Probabilities*, PDP), используемой в эволюционных алгоритмах:

Метод 2. Селективная онлайн гиперэвристика синтеза ЭА оптимизации в нестационарной среде.

Вход: множество H базовых эволюционных эвристик и метаэвристик, метод обнаружения изменений в среде, критерий оценки эффективности ЭА (21).

Инициализация: Случайная популяция решений делится на равные подпопуляции, подпопуляциям назначаются используемые эвристики.

Повторять, пока решается задача оптимизации в нестационарной среде (цикл глобальной адаптации):

Пересчитать вектор параметров глобальной адаптации v^{glob} , используя (22)-(25).

Повторять, пока не обнаружены изменения в среде (цикл локальной адаптации):

Перераспределить размеры подпопуляций на основе векторов глобальной и локальной адаптации (26).

Повторять заданное число итераций (период локальной адаптации):

Решать задачу оптимизации применяя выбранные эвристики к соответствующим подпопуляциям.

Если обнаружены изменения, то конец цикла локальной адаптации.

Пересчитать вектор параметров локальной адаптации v^{local} .

Выход: множество лучших найденных решений на каждой итерации.

Множество базовых эвристик ($H = \{h_i\}, i = \overline{1, |H|}$) содержит следующие эвристики, применяемые в области оптимизации в нестационарной среде: перезапуск процедуры оптимизации, локальная адаптация к изменениям, реализованный в виде изменяющегося локального поиска (VLS), механизм явной памяти, механизм поддержания разнообразия на основе метода ниш и самонастраиваемый ЭА с управляемой мутацией. Каждая из эвристик имеет преимущества на определенных типах изменений среды.

Выбор эвристики осуществляется путем перераспределения количества вычислений целевой функции для каждой из эвристик (размеры подпопуляций $subpop_i, i = \overline{1, |H|}$, $pop_size = \sum_{i=1}^{|H|} subpop_i$ – размер популяции для гиперэвристики). Вектор параметров глобальной адаптации (v^{glob}) используется для оценки вероятности появления изменений конкретного типа. Поскольку идентификация типа (или комбинации типов) изменений является задачей сравнимой по сложности с исходной задачей оптимизации, вектор параметров глобальной адаптации определяет вероятности применения конкретной эвристики. Вероятности использования эвристик, продемонстрировавших большую эффективность в предыдущем локальном цикле, должны увеличиваться. Пересчет значений параметров глобальной адаптации основан на модели изменяющихся вероятностей на уровне популяции (PDP), иногда применяемой для самоконфигурации ЭА.

Вектор параметров локальной адаптации (v^{local}) определяет ранжирование эвристик по эффективности в локальном цикле адаптации до очередного изменения среды. Пул перераспределяемых ресурсов формируется путем вычитания из каждой подпопуляции Δ_{subpop} индивидов ($\Delta_{subpop}: subpop_i - \Delta_{subpop} \geq subpop_{min}$). Оценка

эффективности для каждой из эвристик в одном цикле определяется с помощью, модифицированной офлайн ошибки, которая минимизируется (21):

$$mOE^{glob}(h_i) = \frac{1}{T_c} \sum_{t=1}^{T_c} f(x_{bestFound}(h_i), t), \quad (21)$$

где mOE^{glob} – оценка эффективности для эвристики h_i , T_c – число поколений между двумя изменениями в среде, c – номер цикла ($c = 1, 2, \dots$), f – значение целевой функции для лучшего найденного эвристикой h_i индивида $x_{bestFound}(h_i)$ на момент времени t .

Оценка эффективности для вычисления коэффициента локальной адаптации определяется на каждой итерации по значению целевой функции $f(x_{bestFound}(h_i), t)$ для лучшего найденного эвристикой h_i индивида $x_{bestFound}(h_i)$.

Для вычисления коэффициентов глобальной $v_i^{glob}(t, c)$ и локальной $v_i^{local}(t)$ адаптации эвристики ранжируются по значениям mOE^{glob} и по $f(x_{bestFound}(h_i), t)$ соответственно:

$$\begin{aligned} Rank_i^{glob} &\leq Rank_j^{glob}, \text{ если } mOE^{glob}(h_i) \leq mOE^{glob}(h_j), \\ Rank_i^{local} &\leq Rank_j^{local}, \text{ если } f(x_{bestFound}(h_i), t) \leq f(x_{bestFound}(h_j), t), \\ Rank_i^{glob}, Rank_i^{local} &\in [1, |H|], i = \overline{1, |H|}, \\ v_i^{glob}(0, 0) &= \frac{1}{|H|}, i = \overline{1, |H|}, \end{aligned} \quad (22)$$

$$v_i^{glob}(t, c + 1) = (1 - \eta) \cdot v_i^{glob}(t, c) + \eta \cdot \frac{2 \cdot (|H| - Rank_i^{glob} + 1)}{|H| \cdot (|H| + 1)}, \quad (24)$$

$$v_i^{local}(t) = Rank_i^{local}, \quad (25)$$

где $\eta \in [0, 1]$ – параметр, определяющий скорость глобальной адаптации.

$$\begin{aligned} subpop_i(0) &= \frac{pop_size}{|H|}, \\ subpop_i(t + 1) &= \\ &= subpop_i(t) - \Delta_{subpop} + \frac{\Delta_{subpop} \cdot |H|}{2} \cdot \left[\frac{2 \cdot (|H| - v_i^{local}(t) + 1)}{|H| \cdot (|H| + 1)} + v_i^{glob}(t) \right]. \end{aligned} \quad (26)$$

После определения новых размеров подпопуляций происходит перераспределение индивидов путем случайных миграций. Традиционный подход «лучший замещает худшего» неэффективен, т.к. приводит к преждевременной сходимости и потере разнообразия популяции. Контроль изменений в среде осуществляется путем повторного вычисления пригодности текущего лучшего найденного решения (так называемый детектор).

Экспериментальное исследование эффективности метода 2 проводилось на двух наиболее часто используемых для оценки ЭА модельных задачах: «задача подвижных пиков» (*The Moving Peaks Benchmark*, МРВ) и динамическая функция Растригина, а также на множестве эталонных тестовых задач, предложенных на соревновании по оптимизации в нестационарной среде в рамках конференции IEEE CEC 2009. Эталонные тестовые задачи содержат 6 задач оптимизации, для которых моделируются 7 различных комбинаций типов изменений в среде. Оценка эффективности алгоритма для всех задач осуществляется по значению абсолютной ошибки лучшего найденного решения на последней итерации каждого цикла между двумя изменениями в среде (27). Ошибка усредняется по количеству изменений в

одном независимом запуске и по числу независимых запусков (28). Результаты ранжирования подходов на модельных задачах показаны на рисунке 3.

$$E_{c,r}^{last} = |f(\bar{x}_{bestFound}, T_c) - f(\bar{x}^*, T_c)|, \quad (27)$$

$$avgE^{last} = \frac{1}{numRun \cdot numChange} \sum_{r=1}^{numRun} \sum_{c=1}^{numChange} (E_{c,r}^{last}), \quad (28)$$

где $E_{c,r}^{last}$ – значение ошибки решения на последней итерации T_c цикла c для независимого запуска r , $numRun$ – число независимых запусков, $numChange$ – число изменений в среде в одном независимом запуске.




Рисунок 3. Ранжирование алгоритмов на задачах МРВ (слева) и динамической функции Растригина (справа)

Пример выбора эвристик путем перераспределения размеров подпопуляций в методе 2 для одного из прогонов показан на рисунке 4. Вертикальные линии – моменты, когда происходят изменения в среде. Размер подпопуляции эвристики механизма явной памяти не уменьшается постоянно, после накопления информации, в повторяющихся ситуациях, механизм явной памяти быстрее находит лучшее решение. При появлении новых состояний среды, метод 2 переключается на использование других подходов, гиперэвристика чаще выбирала механизм поддержания разнообразия и перезапуск, при некоторых изменениях в среде, более эффективными оказывались и другие эвристики.

Обобщенные результаты оценки гиперэвристики на эталонных задачах представлены на рисунке 5. Результаты сравнены с результатами известных алгоритмов, участвовавших в конкурсе CEC (*Self-Adaptive Differential Evolution Algorithm* (jDE), *Clustering Particle Swarm Optimizer* (CPSO), *Evolutionary Programming with Ensemble of Explicit Memories* (EP with EEM)), а также с традиционным генетическим алгоритмом (GA) и алгоритмом роя частиц (PSO).




Рисунок 4. Перераспределение подпопуляций в методе 2




Рисунок 5. Диаграмма разброса оценок (слева) и ранжирование алгоритмов (справа) на задачах IEEE CEC

Экспериментальное исследование предложенной селективной онлайн гиперэвристики синтеза ЭА оптимизации в нестационарной среде показало, что данный подход позволяет синтезировать эффективный ЭА в процессе решения задачи, адаптируясь к типам изменений путем выбора подходящей базовой эвристики. Гиперэвристика всегда превосходит по эффективности среднюю эффективность ЭА, использующих базовые эвристики, а с увеличением сложности задачи может превосходить и ЭА с лучшей эвристикой. Разброс оценок эффективности по серии независимых экспериментов показывает, что метод 2 дает повторяемые результаты, сравнимые с наиболее эффективными из исследованных алгоритмов. Аналогично и с разбросом оценок усредненных по типам изменений. Учитывая, что целевые функции заданы алгоритмически, а тип и характеристики изменений не известны заранее, выбор подходящего специализированного алгоритма затруднен. В то же время, предложенная гиперэвристика превосходит оценку эффективности случайного выбора алгоритма независимо от типа изменений в среде.

Для апробации подхода была решена практическая задача оптимизации для идентификации параметров боковой динамики движения (тангаж, крен и рыскание в зависимости от положения элеронов, руля высоты, руля направления и рычага управления двигателем) малого беспилотного летательного аппарата с фиксированным крылом в реальном времени. Идентификация параметров осуществляется с помощью нелинейной авторегрессионной нейронной сети. Ранее было продемонстрировано (Путтиге и Анаватти, 2007), что данная задача обучения нейронной сети является нестационарной и традиционный алгоритм обратного распространения ошибки неэффективен. Применение метода 2 для настройки параметров нейронной сети позволяет получить меньшее среднее значение ошибки идентификации параметров по сравнению с алгоритмом обратного распространения и ЭА, использующими одну базовую эвристику для задач оптимизации в нестационарной среде.

Глава 4 посвящена проблеме разработки и исследования гиперэвристики для решения задач аппроксимации множества экстремумов. При решении многоэкстремальных задач глобальной оптимизации многие эвристические подходы имеют тенденцию сходиться к лучшему найденному оптимуму, который может оказаться локальным. В случае задач с алгоритмически заданными целевыми функциями, без дополнительной информации, обычно сложно определить, является ли оптимум локальным или глобальным. Задача (1), (5) направлена на идентификацию множества экстремумов, т.е. поиск множества всех (глобальных и

локальных) экстремумов или его репрезентативной аппроксимации. Данная постановка имеет как теоретическую (исследование ландшафта целевой функции, разработка новых методов), так и практическую (идентифицированные оптимумы являются различными альтернативами при решении исходной проблемы) пользу. Попытки повысить надежность ЭА за счет поиска многих оптимумов предпринимались со времен работ Голдберга и Де Йонга, однако наибольшее развитие задача идентификации множества экстремумов получила лишь в последние годы (первая специальная сессия и соревнование в рамках IEEE CEC были организованы в 2013 году).

В настоящее время предложено множество подходов для решения данной задачи с помощью ЭА, которые можно объединить в две группы. Первая содержит базовые эвристики, которые используются как модификация или замена базовых операций в ЭА: метод ниш и разделение пригодности, «ограничение спаривания», метод вытеснения, модифицированная турнирная селекция и другие. Вторая группа связана с анализом топологии пространства поиска: алгоритмы прямого исследования и анализа топологии, островные, кооперативные и «многонациональные» ЭА, ЭА на основе кластерного анализа и другие. Многие подходы основаны на понимании некоторых свойств вещественных задач оптимизации, а потому могут терять эффективность при решении произвольных задач вещественной оптимизации и могут быть вовсе неприменимы для дискретных задач и задач со смешанными переменными.

В данной работе предложена гиперэвристика, осуществляющая выбор и комбинацию базовых эвристик (подходы первой группы), т.к. они не используют в явном виде какую-либо информацию о свойствах целевой функции и пространства поиска, а значит могут применяться для произвольных задач с алгоритмически заданными целевыми функциями. Множество эвристик включает: обнуление пригодности (*Clearing*), разделение пригодности (*Sharing*), анализ кластеров решений (*Clustering*), ограниченную турнирную селекцию (*Restricted Tournament Selection, RTS*), детерминированное (*Deterministic Crowding*) и вероятностное (*Probabilistic Crowding*) вытеснение.

Гиперэвристика для задач идентификации множества экстремумов, аналогично методу 2 в главе 3 объединяет идеи метода портфолио алгоритмов и метода адаптации вероятностей на уровне популяции. Но в отличие от метода 2 может применяться онлайн при решении новых задач и офлайн для обобщения результатов на множество задач. Другим важным отличием является способ оценки эффективности применения базовых эвристик для выбора эвристик на очередном этапе решения задачи оптимизации. Показатели эффективности должны учитывать сколько оптимумов было обнаружено и как распределены индивиды популяции в пространстве поиска. Подобные показатели предложены только для эталонных тестовых задач и хорошо изученных прикладных задач, для произвольных задач с алгоритмически заданными функциями требуется разработка универсальных подходов к оценке эффективности.

Метод 3. Селективная гиперэвристика синтеза ЭА идентификации множества экстремумов.

Вход: множество N базовых эволюционных эвристик и метаэвристик.

Инициализация: Случайная популяция решений делится на равные подпопуляции, подпопуляциям назначаются используемые эвристики.

Повторять, пока не выполнено условие останова:

Повторять заданное число итераций (период адаптации):

Решать задачу оптимизации, применяя выбранные эвристики к соответствующим подпопуляциям.

Оценить эффективность применения каждой из эвристик по числу идентифицированных оптимумов *BasinRatio* и скоплению индивидов *SDNN*, используя (29)-(35).

Перераспределить размеры подпопуляций в пользу более эффективных эвристик.

Выполнить миграции индивидов – добавить в подпопуляции идентифицированные центры областей притяжения, заменив наиболее близких к ним индивидов.

Выход: множество точек, аппроксимирующих распределение оптимумов в пространстве поиска.

Поскольку истинное количество и положение оптимумов не известно, то выводы о качестве аппроксимации множества экстремумов делаются на основе анализа поведения ЭА. В процессе своей работы ЭА сходятся в зону притяжения одного из оптимумов задачи, таким образом, по скоплению индивидов можно сделать вывод о положении идентифицированного оптимума. Поддержка разнообразия в популяции и запрет на скопление индивидов в одной области может стимулировать ЭА обнаружить зоны притяжения нескольких оптимумов.

Для оценки эффективности применения эвристик для метода 3 в данном исследовании предложены следующие критерии. Критерий *BasinRatio* (29) показывает долю областей притяжения оптимумов, обнаруженных каждой из эвристик. Критерий *SDNN* (*Sum of Distances to Nearest Neighbour*) (32) вычисляет сумму расстояний до ближайшего соседа для всех членов популяции, критерий используется как штраф за скопление индивидов в одной области.

$$BasinRatio(h_i) = \frac{l(h_i)}{|Z|}, \quad (29)$$

где *BasinRatio* – доля областей притяжения оптимумов, идентифицированных при применении эвристики h_i ($i = \overline{1, |H|}$), $l(h_i)$ – число областей притяжения, обнаруженных i -й эвристикой, $|Z|$ – число областей притяжения, обнаруженных всей популяцией (гиперэвристикой), Z – множество медоидов, полученное в ходе решения задачи кластеризации индивидов, определяющих области притяжения локализованных оптимумов.

$$l(h_i) = \sum_{j=1}^{|Z|} \min_{x \neq z_j} \{1, \sum_{x \in sub_pop_i} b(x, z_j)\}, \quad (30)$$

$$b(x, z) = \begin{cases} 1, & \text{если } x \in basin(z) \\ 0, & \text{если } x \notin basin(z) \end{cases} \quad (31)$$

где $b(x, z)$ – функция, определяющая нахождение индивида x в зоне притяжения $z \in Z$, $basin(z)$ – множество индивидов, находящихся в зоне притяжения z .

$$SDNN(h_i) = \sum_{j=1}^{sub_pop_i} d_{nn}(x_j, sub_pop_i), \quad (32)$$

$$d_{nn}(x_j, sub_pop_i) = \min_{y \in sub_pop_i \setminus \{x_j\}} dist(x_j, y), \quad (33)$$

$$\overline{SDNN}(h_i) = \frac{SDNN(h_i)}{\max_{j=1, |H|} SDNN(h_j)}, \quad (34)$$

где *SDNN* – сумма расстояний до ближайшего соседа, d_{nn} – расстояние *dist* (конкретная метрика зависит от пространства поиска) до ближайшей соседней точки в подпопуляции.

Итоговый показатель эффективности $K_{ММО}$ (35) для эвристики h_i в методе 3 является сверткой критериев *BasinRatio* и $\overline{SDNN}$:

$$K_{MMO}(h_i) = \alpha \cdot BasinRatio(h_i) + (1 - \alpha) \cdot \overline{SDNN}(h_i), \quad (35)$$

где $\alpha \in [0,1]$ – весовой коэффициент, определяющий вклад каждого из критериев в сумму, по умолчанию $\alpha = 0.5$.

На шаге миграции (этап кооперации независимых алгоритмов) необходимо уравнивать стартовые точки подпопуляций на следующий период адаптации. Традиционная схема «лучший замещает худшего» приводит к сходимости в зону притяжения единственного лучшего найденного оптимума, поэтому не пригодна для задач данного класса. Поскольку после каждого периода адаптации мы имеем аппроксимацию множества экстремумов (индивиды $z \in Z$), в методе 3 в миграции участвуют индивиды z , которые замещают наиболее близких к ним индивидов в каждой подпопуляции.

Экспериментальное исследование эффективности метода 3 проводилось на двух наборах тестовых задач. Первый набор включает 6 задач псевдобулевой оптимизации, которые являются многоэкстремальными (32 глобальных оптимума) и десептивными («обманчивыми»). Данные задачи исходно дискретные и не обладают топологией, характерной для непрерывных задач оптимизации. Вторым набором является 8 эталонных тестовых задач, предложенных на специальной сессии и соревновании по мультимодальной оптимизации в рамках конференции IEEE CEC 2013. Каждая из задач является многоэкстремальной, содержит различное число глобальных и локальных оптимумов и решается при 5 различных значениях размерности.

Для оценки эффективности при решении тестовых задач использованы следующие показатели: PR (*Peak Ratio*) – процент идентифицированных оптимумов задачи, SR (*Success Rate*) – процент успешных запусков алгоритма, в которых идентифицированы все оптимумы задачи и PD (*Peak Distance*) – среднее расстояние между известными оптимумами задачи и ближайшими индивидами в популяции. Число независимых запусков, точность вычисления PR и максимальное число вычислений целевой функции в прогоне заданы согласно условий конкурса IEEE. Обобщенные результаты оценки эффективности метода 3 на дискретных тестовых задачах и эталонных тестовых задачах представлены в таблице 1 и на рисунке 6.

Задача идентификации множества экстремумов для бинарных переменных практически не исследована, поэтому результаты исследования на первом наборе сравнены с единственным подходом – ансамблем алгоритмов, использующих метод ниш (*Ensemble of niching algorithms*, ENA), для которого авторы представили только оценку SR . Результаты на втором наборе задач сравнены с результатами участников конкурса CEC: алгоритм на основе дифференциальной эволюции (DE/rand/1/bin), дифференциальная эволюция на основе метода вытеснения (Crowding DE/rand/1/bin), метод ниш с переменной решеткой (*Niching Variable Mesh Optimization algorithm*, N-VMO), дифференциальная эволюция на основе метода ниш с адаптивным архивом (dADE/rand/1) и многокритериальный алгоритм на основе метода ниш (PNA-NSGAII).

Таблица 1 – сравнение эффективности алгоритмов на дискретных тестовых задачах идентификации множества экстремумов

Кри- терий	ENA	Clear- ing	Shar- ing	Cluster- ing	RTS	Deter- ministic Crowding	Proba- bilistic Crowding	Среднее по базовым эвристикам	Метод 3
PR	-	0.92	0.87	0.91	0.95	0.92	0.76	0.89	1.00
SR	1.00	0.92	0.89	0.90	0.93	0.89	0.76	0.88	1.00
PD	-	2.21	2.46	2.22	1.40	2.47	3.34	2.35	0.00




Рисунок 6. Результаты ранжирования алгоритмов по *PR* (слева) и *SR* (справа) на задачах IEEE CEC

Пример выбора эвристик путем перераспределения размеров подпопуляций в методе 3 для одного из прогонов показан на рисунке 7. Как видно на графике, на разных этапах поиска разные эвристики демонстрируют разную эффективность. Например, детерминированное вытеснение было неэффективно на начальных этапах поиска и гиперэвристика выбирала другие эвристики, а после 9го поколения и особенно на последних итерациях детерминированное вытеснение выбиралось чаще других эвристик. Следовательно, стандартный подход портфолио алгоритмов будет менее эффективен, т.к. он предполагает выбор единственного алгоритма.

Экспериментальное исследование метода 3 показало, несмотря на то, что эффективность отдельных эвристик меняется от задачи к задаче, использование гиперэвристики позволяет адаптивно выбирать (комбинировать) базовые подходы, что существенно повышает эффективность решения задачи. Для набора задач с бинарными переменными метод 3 обеспечил идентификацию всех известных оптимумов задачи в каждом запуске алгоритма ($PR=1$ и $SR=1$). Для эталонных тестовых задач IEEE CEC метод 3 также предпочтительнее случайного выбора эвристики и превосходит ряд ведущих алгоритмов с конкурса CEC. Более того, метод 3 обеспечивает эффективность сравнимую с эффективностью случайного выбора одного из ведущих алгоритмов (средняя эффективность по всем алгоритмам).




Рисунок 7. Перераспределение подпопуляций в методе 3

Для апробации подхода были решены практические задачи из области поддержки принятия решений и задача проектирования системы на нечеткой логике для решения задач классификации. Задачи поддержки принятия решений включают задачу формирования оптимальной кредитной политики (кредитный портфель) коммерческого банка и задачу управления инвестициями производственного предприятия ОПК. Применение гиперэвристики для идентификации множества экстремумов позволяет получить не единственное решение для лиц принимающих решения (ЛПР) как в традиционной постановке, а множество оптимальных решений. Множество оптимальных решений обеспечивает ЛПР различными альтернативами (разные стратегии распределения кредитов и инвестиций) и предоставляет возможность провести анализ проблемы путем анализа оптимальных решений (например, какие кредитные и инвестиционные заявки формируют оптимальные портфели, какие слабо влияют на итоговый результат и т.д.). В задаче проектирования системы на нечеткой логике ЭА применяется для формирования базы правил нечеткого классификатора Ишибучи, использующего дополнительный терм игнорирования (*"Don't Care"*, DC) для возможности формирования правила различной длины. С помощью гиперэвристики для идентификации множества экстремумов были спроектированы нечеткие классификаторы для ряда прикладных задач классификации из известных репозиториях задач машинного обучения UCI (Калифорнийский университет в Ирвине, США) и KEEL (Гранадский университет, Испания). Для некоторых задач классификации, решения, полученные с помощью метода 3 обеспечили большую точность классификации по сравнению с традиционным ЭА, что объясняется более эффективной работой метода в многоэкстремальной среде. Поскольку база правил в системе на нечеткой логике представляет собой продукционные правила на основе лингвистических термов, правила принятия решений могут быть интерпретированы. Анализ многих оптимальных решений (баз правил) позволяет получить дополнительную информацию о свойствах задачи классификации и способах ее решения. В частности, были выделены правила, встречающиеся во всех оптимальных решениях, правила с различной семантикой, но обеспечивающие одинаковую точность классификации и т.д. Другим преимуществом подхода является возможность сформировать коллективное принятие решений по нескольким классификаторам для повышения точности классификации.

Глава 5 посвящена проблеме разработки и исследования гиперэвристик для решения задач глобальной оптимизации большой размерности с алгоритмически заданными целевыми функциями. Как показывает практика эволюционной оптимизации, размерность прикладных задач глобальной оптимизации существенно выросла и продолжает расти в последние годы, что связано с необходимостью включать в задачи прикладного системного анализа все больше факторов. Тем не менее, для задач глобальной оптимизации с алгоритмически заданными целевыми функциями (и особенно несепарабельных задач) с ростом размерности эффективность многих метаэвристик падает.

В настоящее время, выделяют две группы подходов к решению задач глобальной оптимизации большой размерности: подходы на основе модификации операций традиционных ЭА и подходы на основе декомпозиции задачи оптимизации. Лучшие

результаты получены для второй группы методов. Декомпозиция заключается в разбиении задачи на непересекающиеся подзадачи (компоненты) меньшей размерности путем группировки переменных и применении коэволюционного подхода, в котором каждая компонента оптимизируется отдельно, а оценка ее пригодности осуществляется с учетом лучших найденных значений для других компонент. В свою очередь, методы группировки переменных делятся на статические (эффективны в основном для сепарабельных задач), случайные динамические (наиболее эффективные подходы) и использующие машинное обучение для динамической группировки (широкое распространение пока не получили).

Из-за вычислительной сложности проектирование новых подходов и их экспериментальное исследование затруднено. Поэтому для данного класса задач оптимизации более предпочтительным является селективная онлайн гиперэвристика.

Для работы с бинарным ГА, позволяющим решать задачи со смешанными переменными была разработана новая эвристика для группировки переменных на основе алгоритма оценки распределений (*Estimation Of Distribution*, EDA). Распределение генов в популяции на итерации t можно представить в виде следующего распределения вероятностей появления генов равных единице (36):

$$P(t) = (p_1(t), \dots, p_n(t)), p_i(t) = P(x_i = 1) = \frac{1}{pop_size} \sum_{j=1}^{pop_size} x_{ij}, \quad (36)$$

где x_i – i -я позиция в хромосоме, $P(x_i = 1)$ – вероятность появления единицы в i -й позиции, x_{ij} – значение i -го гена j -го индивида.

Ранее было исследовано свойство, связанное с динамикой изменения компонент вектора вероятностей (36), в случаях, когда алгоритм сходится к одному из оптимумов (Сопов, 2004). На основе этого свойства разработана следующая эвристика (EDA-GA). В течение предопределённого числа итерации (период адаптации) часть случайно выбранных переменных (α_fixed - процент от числа переменных задачи) фиксируется, оптимизация осуществляется по оставшимся переменным. Значение зафиксированных переменных определяется на основе распределения (36) по формуле (37):

$$x_i^{fixed}(t) = \begin{cases} 0, & \text{если } p_i(t) < (0.5 - \delta) \\ 1, & \text{если } p_i(t) > (0.5 + \delta), \\ random(0 \vee 1), & \text{иначе} \end{cases} \quad (37)$$

где $\delta \in (0, 0.5)$ – пороговое значение для принятия решения, о том, что алгоритм сходится к значению 1 или 0.

Экспериментальное исследование эвристики EDA-GA на эталонных тестовых задачах IEEE CEC LSGO показало, что лучшие по точности нахождения глобального оптимума результаты получаются при $\alpha_fixed = 50\%$ и $\delta = 0.15$ для одной популяции и при $\alpha_fixed = 75\%$ и $\delta = 0.15$ для островной модели ЭА при распараллеливании вычислений. Эвристика EDA-GA превосходит в среднем по точности нахождения глобального оптимума некоторые известные эволюционные эвристики решения задач глобальной оптимизации большой размерности с алгоритмически заданными целевыми функциями.

Известные методы группировки переменных формируют компоненты задачи равного размера, число которых является параметром алгоритма. В данной работе предложена новая эвристика (AVS-RG) для адаптивной группировки в компоненты

переменного размера, обобщающая метод DECC-G (Янг и др., 2008). В AVS-RG формирование групп переменных на этапе декомпозиции происходит на основе распределения вероятностей (37)-(38):

$$P(t) = (p_1(t), \dots, p_n(t)), \quad (37)$$

$$p_i(t) = (p_i^1(t), \dots, p_i^k(t)), p_i^j(t) = P(x_i \in s_j) \wedge \sum_{j=1}^k p_i^j(t) = 1, \quad (38)$$

где n – размерность задачи оптимизации, k – число компонент, s_j – j -я компонента, $P(x_i \in s_j)$ – вероятность, назначения i -й переменной j -й компоненте.

В случае когда $p_i^j(t) = \frac{1}{k}, \forall i, j, t$, эвристика AVS-RG совпадает с методом случайной динамической группировки, предложенной в DECC-G. Использование обратной связи об эффективности решения задачи с текущей группировкой переменных для адаптации вероятностей в распределении (37) позволяет более эффективно формировать компоненты. Основная идея адаптации следующая. После заданного числа поколений (период адаптации), определяются компоненты, для которых было найдено решение превосходящее предыдущее лучшее найденное. Значения вероятностей в распределении (37)–(38), соответствующих эффективным группам, увеличиваются путем уменьшения вероятностей менее эффективных группировок. Если новое лучшее решение не было найдено, компоненты ранжируются по средней эффективности в текущем периоде адаптации, вероятности перераспределяются пропорционально рангам. Предложенная эвристика AVS-RG позволяет формировать k групп одинакового размера, или k групп переменного размера в рамках ограничения $s_i \in [s_{min}, s_{max}], \forall i \wedge \sum_{j=1}^k s_j = n$, или произвольное число групп $\hat{k} \in [1, k]$ переменного размера $s_i \in [0, n], \forall i \wedge \sum_{j=1}^{\hat{k}} s_j = n$. Эвристика AVS-RG превосходит в среднем по точности нахождения глобального оптимума некоторые известные эволюционные эвристики решения задач глобальной оптимизации большой размерности с алгоритмически заданными целевыми функциями, однако как и в других эвристиках для задач разного типа требуется подбор числа компонент k .

Множество базовых эвристик для селективной онлайн гиперэвристики для решения задач глобальной оптимизации большой размерности (метод 4) содержит случайную динамическую группировку (*Random Dynamic Grouping*), дифференциальная группировка (*Differential Grouping*) и дельта-группировка (*Delta Grouping*), а также эвристики EDA-GA и AVS-RG. Каждая из базовых эвристик использует собственную группировку переменных, поэтому кооперативная коэволюция применяется независимо к каждому варианту декомпозиции задачи. Метод 4 основан на островной модели ЭА, в которой управление (выбор) эвристик происходит путем изменения размеров популяций островов. Преимуществом островной модели для задач большой размерности является возможность эффективного распараллеливания вычислений на ЭВМ.

Метод 4. Селективная онлайн гиперэвристика синтеза ЭА для задач глобальной оптимизации большой размерности.

Вход: множество N базовых эволюционных эвристик и метаэвристик, критерий оценки эффективности ЭА.

Инициализация: Формируются острова со случайными популяциями решений, решение каждого острова формируется собственным ЭА.

Повторять, пока не выполнено условие останова:

Повторять заданное число итераций (период адаптации) на каждом острове:

Решать задачу оптимизации, применяя выбранную эвристику декомпозиции задачи и коэволюционный подход.

Оценить эффективность решения задачи.

Изменить размеры островов, увеличивая популяции более эффективных эвристик.

Выполнить миграции индивидов по схеме «лучший замещает худшего».

Выход: лучшее найденное решение.

Экспериментальное исследование метода 4 проводилось на множестве эталонных тестовых задач, предложенных на специальной сессии и соревновании по глобальной оптимизации большой размерности IEEE CEC LSGO 2013. Исследование метода 4 проводилось в сравнении с некоторым известным алгоритмам-участникам и победителям конкурсов CEC LSGO. Рисунок 8 содержит итоговые результаты экспериментального исследования.

Экспериментальные исследования показали, что эффективность исследованных подходов меняется на разных типах задач (сепарабельные, несепарабельные, задачи с пересекающимися компонентами). Алгоритмы, имеющие лидирующие позиции после ранжирования, могут превосходить другие подходы по точности нахождения глобального оптимума на большинстве задач из набора LSGO, но на других задачах их отставание становится существенным. Для задач с алгоритмически заданными целевыми функциями трудно или невозможно заранее определить выбор наиболее эффективного алгоритма. Поэтому оценки эффективности метода 4 стоит сравнить с оценкой случайного выбора одного из алгоритмов из множества. В данном случае, метод 4 предпочтительнее случайного выбора ЭА на основе одной из базовых эвристик (победа на 14 из 15 задачах), он также предпочтительнее случайного выбора одного из известных LSGO алгоритмов, несмотря на то, что некоторые из них лидируют по рангам (победа на 12 из 15 задачах).

Для апробации предложенного подхода решены практические задачи. В задаче повышения энергоэффективности диспетчеризации электроэнергии в распределенных энергетических системах целевая функция и ограничения задаются алгоритмически и являются нелинейными, негладкими и недифференцируемыми. Эффективность традиционных подходов на данной задаче снижается уже на размерностях 10-20, а размерность равная 40 уже представляет сложность для многих известных эвристик, включая ЭА. Результаты применения метода 4 для решения задачи с 140 источниками энергии показали, что метод 4 уступает по лучшему найденному среди всех прогонов алгоритма алгоритму GA-MPC (Елсаев и др, 2011), но демонстрирует лучшее значение медианы целевой функции по 25 независимым запускам, что можно интерпретировать как более стабильный (повторяемый) результат при многократном решении задачи при разных начальных условиях. В задаче проектирования траектории КА с двигателями малой тяги с использованием гравитационных маневров и промежуточных импульсов целевая функция и ограничения вычисляются в ходе компьютерной симуляции, целевая функция имеет множество локальных оптимумов и определена не во всех точках пространства поиска. При решении задач проектирования миссий Земля–Земля–Юпитер и Земля–Венера–Венера–Меркурий–Меркурий–Меркурий были решены задачи оптимизации размерности 75 и 222, соответственно. В результате численных экспериментов метод

4 превзошел все включенные в него базовые эвристики, алгоритм самоадаптивной дифференциальной эволюции SAMODE, а также ранее полученные результаты другими известными подходами.




Рисунок 8. Диаграмма разброса рангов по задачам набора (слева) и результаты ранжирования алгоритмов по медиане (справа)

В главе 6 обобщены результаты диссертационного исследования и сформулирован новый метод решения сложных задач оптимизации на основе предложенных гиперэвристик (рисунок 9). Основная идея обобщенного метода заключается в том, что в зависимости от постановки задач оптимизации, требований и ограничений к решению формируется множество используемых базовых эвристик ЭА и алгоритм управления ими в процессе решения конкретной задачи оптимизации. Если в процессе решения были идентифицированы новые свойства задачи, то множество базовых эвристик и процедуры управления ими дополняются. Например, в общем случае, возможно дополнительное введение в проектируемый ЭА решения-детектора обеспечивает контроль за изменениями в среде, и в случае обнаружения изменений, будут активированы эвристики для оптимизации в нестационарной среде. Если же эффективное решение не может быть получено с имеющимися (известными) эвристиками, необходимо конструировать новые базовые эвристики для исследуемой предметной области или задачи.

Выбор типа гиперэвристики (онлайн или офлайн) определяется целями решения (однократное решение частной задачи или многократное решение множества задач) и ограничениями на бюджет вычислений целевой функции.

В теории численных методов оптимизации существует теорема «бесплатных завтраков не бывает», предложенная Волпертом Д. и Макреди В. в 1997 (*No Free Lunch Theorems for Optimization*, NFL), согласно которой эффективность любых двух алгоритмов оптимизации усредненная на множестве всех задач будет одинаковой. NFL поднимает вопрос о применимости ЭА как универсального метода для многих классов задач. Предложенный обобщенный метод применения гиперэвристик позволяет ослабить ограничения теоремы NFL, т.к. выбор (формирование) эффективного алгоритма происходит под конкретную задачу, т.е. гиперэвристика синтезирует узкоспециализированный алгоритм для каждого конкретного экземпляра целевой функции и класса задач.

В теории численных методов оптимизации существует теорема «бесплатных завтраков не бывает», предложенная Волпертом Д. и Макреди В. в 1997 (*No Free Lunch Theorems for Optimization*, NFL), согласно которой эффективность любых двух

алгоритмов оптимизации усредненная на множестве всех задач будет одинаковая. NFL поднимает вопрос о применимости ЭА как универсального метода для многих классов задач. Предложенный обобщённый метод применения гиперэвристик позволяет ослабить ограничения теоремы NFL, т.к. выбор (формирование) эффективного алгоритма происходит под конкретную задачу, т.е. гиперэвристика синтезирует узкоспециализированный алгоритм для каждого конкретного экземпляра целевой функции и класса задач.




Рисунок 9. Обобщенный метод применения гиперэвристик

Более того, в процессе решения конкретной задачи оптимизации можно выделить разные этапы работы алгоритма: исследование пространства поиска, исследование областей притяжения оптимумов, уточнение (популяция сходится) лучшего найденного решения. При этом при локализации новых областей пространства поиска могут проявляться новые особенности ландшафта целевой функции (множеством постоянства, овраг и т.д.).

Очевидно, что на каждом этапе решения задачи оптимизации эффективным будет конкретный специализированный алгоритм, а не единственный алгоритм, который является специализированным для задачи в целом. Применение гиперэвристики решает и эту проблему, т.к. новый ЭА синтезируется постоянно на каждом шаге решения задачи оптимизации.

ЗАКЛЮЧЕНИЕ

В диссертации обоснованы теоретические положения и предложены новые гиперэвристики решения сложных задач глобальной оптимизации с алгоритмически заданными функциями, позволяющие автоматизировано (с минимальным участием или без участия человека) синтезировать ЭА для решения конкретной задачи или множества задач. В работе экспериментально доказано, что предложенные гиперэвристики превосходят среднюю эффективность ЭА, использующих отдельные базовые эвристики. Предложенные подходы сравнимы или превосходят среднюю эффективность некоторых известных алгоритмов, специально разработанных с учетом особенностей класса задач оптимизации. Данный результат важен для задач с алгоритмически заданными функциями, т.к. применение гиперэвристики предпочтительнее произвольного выбора одного из алгоритма.

Цель диссертации достигнута путем решения поставленных задач, а именно:

1. Проведен анализ существующих подходов, методов и алгоритмов решения задачи автоматизации синтеза ЭА, систематизированы основные подходы к построению гиперэвристик для решения сложных задач оптимизации с алгоритмически заданными функциями, включая задачи глобальной оптимизации большой размерности, задачи аппроксимации множества экстремумов и задачи оптимизации в нестационарной среде.

2. Предложена и исследована новая конструктивная офлайн гиперэвристика на основе алгоритма ГП для синтеза операторов селекции ЭА (метод 1), позволяющая создавать новые базовые эвристики, обеспечивающие большую среднюю точность нахождения решения задачи глобальной оптимизации с алгоритмически заданными функциями на множестве задач по сравнению со стандартными операторами отбора индивидов в ЭА. Экспериментальные исследования доказали, что использование кросс-валидации на исследуемом множестве задач в ГП позволяет создать новую эвристику, которая предпочтительнее случайного выбора одного из стандартных операторов селекции для задач типа «черный ящик».

Применение метода 1 в задаче идентификации партий электронных компонентов аэрокосмического применения позволило улучшить известные решения, полученные ранее с применением других алгоритмов.

3. Впервые предложена и исследована селективная онлайн гиперэвристика синтеза ЭА нестационарной оптимизации (метод 2), объединяющая идеи метода портфолио и идеи метода адаптации вероятностей на уровне популяции ЭА.

Экспериментально доказано, что предложенная гиперэвристика превосходит оценку эффективности случайного выбора алгоритма независимо от типа нестационарной задачи по критерию офлайн-ошибки. Исследование динамики перераспределения вычислений при выборе эвристики в процессе решения задачи показало, что даже наименее эффективные в среднем эвристики вносят полезный вклад в общее решение задачи.

Применение метода 2 в задаче идентификации параметров боковой динамики движения малого беспилотного летательного аппарата с фиксированным крылом в реальном времени позволило уменьшить значение средней ошибки идентификации параметров по сравнению с решениями, полученными ранее разработчиками БПЛА.

4. Впервые предложена и исследована селективная гиперэвристика синтеза ЭА идентификации множества экстремумов (метод 3), включающая базовые эвристики, которые не используют в явном виде какую-либо информацию о свойствах целевой функции и пространства поиска. Метод 3 использует для выбора эвристик оценку доли областей притяжения обнаруженных оптимумов на основе анализа динамики и скопления индивидов. Для набора задач с бинарными переменными метод 3 обеспечил идентификацию всех известных оптимумов тестовых задач в каждом запуске алгоритма. Для задач с вещественными переменными метод 3 предпочтительнее случайного выбора отдельной эвристики, а также превосходит ряд ведущих алгоритмов с конкурса IEEE CEC 2013 по проценту идентифицированных оптимумов и проценту успешных запусков алгоритма, в которых идентифицированы все оптимумы.

Применение метода 3 при решении практических задач поддержки принятия решений и задачи проектирования системы на нечеткой логике для решения задач классификации позволяет найти глобальный оптимум, а также обеспечивает пользователя дополнительными локально-оптимальными решениями, анализ которых позволяет уточнить модель «черного ящика».

5. Впервые предложена и исследована селективная гиперэвристика синтеза ЭА для задач глобальной оптимизации большой размерности (метод 4), на основе островной модели ЭА. Поскольку задачи глобальной оптимизации большой размерности являются вычислительно сложными, использование островной модели позволяет эффективно реализовать параллельные вычисления. Для решения задач глобальной оптимизации большой размерности предложены две новые базовые эвристики для группировки переменных при декомпозиции задач и оптимизации. Экспериментально доказано, что метод 4 предпочтительнее случайного выбора ЭА на основе одной из базовых эвристик, а также предпочтительнее случайного выбора некоторых из известных LSGO алгоритмов.

С помощью метода 4 были решены практические задачи. В задаче повышения энергоэффективности диспетчеризации электроэнергии в распределенных энергетических системах метод 4 по серии независимых запусков уступил ранее реализованному подходу по лучшему найденному решению в серии прогонов, но показал лучшее значение медианы целевой функции, т.е. обеспечил лучшую повторяемость результатов. В задаче проектирования траектории КА с двигателями малой тяги с использованием гравитационных маневров и промежуточных импульсов метод 4 превзошел все включенные в него базовые эвристики, алгоритм

самоадаптивной дифференциальной эволюции SAMODE, а также результаты, полученные ранее другими известными подходами.

6. Обобщенный метод применения гиперэвристик позволяет с учетом требований конкретной задачи глобальной оптимизации сформировать алгоритм ее решения, построенный на основе множества эвристик и критериев и способов выбора эвристик методов 2-4, а при необходимости пополнить множество эвристик новыми, специально спроектированными автоматически для решаемой задачи.

Таким образом, в диссертации на основании выполненных исследований разработаны теоретические положения, совокупность которых можно квалифицировать как новое научное достижение в области системного анализа и обработки информации.

СПИСОК ОСНОВНЫХ РАБОТ АВТОРА ПО ТЕМЕ ДИССЕРТАЦИИ

А) Статьи в российских периодических изданиях, рекомендованных ВАК:

1. Сопов Е.А., Вахнин А.В. Новый метод группировки переменных для задач параметрической оптимизации большой размерности // Сибирский журнал науки и технологий. – 2018. – Т. 19. – № 3 – С. 386-395.
2. Сопов Е.А., Иванов И.А., Брестер К.Ю. Обобщенный метод анализа мультимодальных данных на основе оптимизационного подхода // Сибирский журнал науки и технологий. – 2017. – Т. 18. – № 4. – С. 736–743.
3. Сопов Е. А., Панфилова, Т.А., Панфилов И.А., Золотарев В.В, Ковалев И.В. Модель функционирования программной системы на основе gert-сети // Сибирский журнал науки и технологий. – 2017. – Т. 18. – № 4. – С. 773–778.
4. Сопов Е.А. Бинарный генетический алгоритм с декомпозицией на основе оценки распределения для задач глобальной оптимизации высокой размерности // Вестник Сибирского государственного аэрокосмического университета. – 2016. – Т. 17. – № 4. – С. 899-906.
5. Сопов Е.А., Иванов И.А. Гибридный алгоритм обучения конволюционной нейронной сети // Вестник Сибирского государственного аэрокосмического университета. – 2016. – Т. 17. – № 4. – С. 871-877.
6. Sopov, E. Multiple Optima Identification Using Multi-strategy Multimodal Genetic Algorithm // Journal of Siberian Federal University. Mathematics & Physics. – 2016. – 9(2). – P. 246–257. (Scopus, WoS)
7. Сопов Е.А., Плющик А.А., Бухтояров В.В. Повышение надежности процесса бурения путем оптимизации управляемых параметров режима бурения // Научно-технический вестник Поволжья. – 2016. – №3. – С. 40-43.
8. Сопов Е.А., Иванов И.А., Панфилов И.А. Самоконфигурируемый ансамбль генетических алгоритмов для решения задач мультимодальной оптимизации // Вестник Сибирского государственного аэрокосмического университета. – 2015. – Т. 16. – № 4. – С. 833-841
9. Сопов Е.А., Аплеснин С.С. Многокритериальный подход к проектированию ансамбля нейросетевых классификаторов с отбором информативных признаков для решения задачи распознавания эмоций // Вестник Сибирского государственного аэрокосмического университета. – 2015. – Т. 16. – № 4. – С. 819-827.
10. Sopov E.A. Self-configuring Multi-strategy Genetic Algorithm for Non-stationary Environments // Vestnik SibGAU. – 2015. – Vol. 16. – No. 1. – P. 124-130.

11. Панфилов И.А., Базанова Е.П., Сопов Е.А. Исследование эффективности работы генетического алгоритма оптимизации с альтернативным представлением решений // Вестник Сибирского государственного аэрокосмического университета имени академика М.Ф. Решетнева. – 2013. – Вып. 4(50). – С. 68-71.
12. Иванов И.А., Сопов Е.А. Исследование эффективности самоконфигурируемого коэволюционного алгоритма решения сложных задач многокритериальной оптимизации // Москва-Воронеж, Системы управления и информационные технологии. – 2013. – № 1.1 (51). – С. 141-145.
13. Иванов И.А., Сопов Е.А. Самоконфигурируемый генетический алгоритм решения задач поддержки многокритериального выбора // Вестник Сибирского государственного аэрокосмического университета имени академика М.Ф. Решетнева. – 2013. – Вып. 1(47). – С. 30-35.
14. Сопов Е.А., Сопов С.А. Интеллектуальные информационные технологии выявления и диагностики проблем в задачах анализа сложных систем // Вестник Сибирского государственного аэрокосмического университета имени академика М.Ф. Решетнева. – 2011. – Вып. 4(37). – С. 84-89.
15. Семенкин Е.С., Сопов Е.А. Исследование эффективности модифицированного вероятностного генетического алгоритма на десептивных функциях «ловушках» // Москва-Воронеж, Системы управления и информационные технологии. – 2011. – № 3 (45). – С. 90-95.
16. Сопов Е.А., Сопов С.А. Вероятностный генетический алгоритм решения сложных задач многокритериальной оптимизации с адаптивной мутацией и прогнозом множества Парето // Вестник Самарского государственного аэрокосмического университета имени академика С.П. Королева. – 2011. – 6 (30). – С. 273-282.
17. Vorozheikin A.Yu., Gonchar T.N., Panfilov I.A., Sopov E.A., Sopov S.A. A Modified probabilistic genetic algorithm for the solution of complex constrained optimization problems // Vestnik of Siberian State Aerospace University named after academician M. F. Reshetnev. – 2009. – 5(26). – P. 31-36.
18. Ворожейкин А.Ю., Гончар Т.Н., Панфилов И.А., Сопов Е.А., Сопов С.А. Об одной модификации вероятностного генетического алгоритма для решения сложных задач условной оптимизации // Вестник Сибирского государственного аэрокосмического университета имени академика М.Ф. Решетнева. – 2009. – Вып. 4(25). – С. 79-84.

Б) статьи в зарубежных изданиях, включенных в международные базы цитирования, рекомендованные ВАК:

19. Sopov, E., Vakhnin, A. Investigation of improved cooperative coevolution for large-scale global optimization problems // Algorithms. – 2021. – 14 (5). – № 146. – 19 p. (Scopus)
20. Sopov, E., Vakhnin, A. Large-scale clustering using decomposition-based evolutionary algorithms // In 2020 IEEE Symposium Series on Computational Intelligence, SSCI 2020. – 2020. – P. 345-352. (Scopus)
21. Sopov, E., Vakhnin, A. Investigation of the iCC framework performance for solving constrained LSGO problems // Algorithms. – 2020. – 13 (5). – № 108. – 18 p. (Scopus, Wos)

22. Sopov, E., Vakhnin, A. Improving DE-based cooperative coevolution for constrained large-scale global optimization problems using an increasing grouping strategy // Conference Series: Materials Science and Engineering. – 2020. – 734 (1). – № 012099. – 11 p. (Scopus)
23. Sopov, E., Vakhnin, A., Panfilov, I. Improved random adaptive grouping approach for solving unconstrained LSGO problems // Journal of Physics: Conference Series. – 2020. – 1515 (3). – № 032076. – 8 p. (Scopus)
24. Sopov, E., Vakhnin, A. Investigating the effects of population size and the number of subcomponents on the performance of shade algorithm with random adaptive grouping for LSGO problems // GECCO 2019 Companion - Proceedings of the 2019 Genetic and Evolutionary Computation Conference Companion. – 2019. – P. 269-270. (Scopus, WoS)
25. Sopov, E., Videnin, S. Online Selective Evolutionary Hyperheuristic for Large Scale Economic Load Dispatch Problem // Proceedings of the 2019 IEEE International Conference on Information Technologies (InfoTech-2019). – 2019. – 8860884. – 4 p. (Scopus)
26. Sopov, E., Vakhnin, A. An approach for initializing the random adaptive grouping algorithm for solving large-scale global optimization problems // Conference Series: Materials Science and Engineering. – 2019. – 537(4). – 042006. – 11 p. (Scopus, WoS)
27. Sopov, E.A., Vakhnin, A.V., Panfilov, I.A., Polyakova, A.S., Kustov, D.V. A problem decomposition approach for large-scale global optimization problems // Conference Series: Materials Science and Engineering. – 2019. – 537(5). – 052031. – 9 p. (Scopus)
28. Sopov, E., Vakhnin, A. A decomposition-based approach for constrained large-scale global optimization. IJCCI 2019 // Proceedings of the 11th International Joint Conference on Computational Intelligence. – 2019. – P. 147-154. (Scopus)
29. Sopov, E., Panfilov, I. Genetic programming based synthesis of clustering algorithm for identifying batches of electronic components // ICINCO 2019 - Proceedings of the 16th International Conference on Informatics in Control, Automation and Robotics. – 2019. – vol. 1. – P. 202-209. (Scopus)
30. Sopov, E., Vakhnin, A. An approach for initializing the random adaptive grouping algorithm for solving large-scale global optimization problems // International Workshop Advanced Technologies in Material Science, Mechanical and Automation Engineering - MIP: Engineering. – 2019. – 11 p. (WoS)
31. Sopov, E., Vakhnin, A., Panfilov, I., Polyakova, A., Kustov, D. A problem decomposition approach for large-scale global optimization problems // International Workshop Advanced Technologies in Material Science, Mechanical and Automation Engineering - MIP: Engineering. – 2019. – 11 p. (WoS)
32. Ivanov, I.; Sopov, E.; Panfilov, I. Comprehensive approach for solving multimodal data analysis problems based on integration of evolutionary, neural and deep neural network algorithms // Conference Series-Materials Science and Engineering. – 2018. – vol. 450. (Scopus, WoS)
33. Plotnikov, D.; Sopov, E.; Panfilov, I. An approach for automating the design of convolutional neural networks // Conference Series-Materials Science and Engineering. – 2018. – vol. 450. (Scopus, WoS)

34. Sopov E. Adaptive Variable-Size Random Grouping for Evolutionary Large-Scale Global Optimization // In: Tan Y., Shi Y., Tang Q. (eds) *Advances in Swarm Intelligence. ICSI 2018. Lecture Notes in Computer Science.* – 2018. – vol 10941. – P. 583-592. (Scopus)
35. Sopov E., Vakhnin A. An investigation of parameter tuning in the random adaptive grouping algorithm for LSGO problems // *IJCCI 2018 - Proceedings of the 10th International Joint Conference on Computational Intelligence.* – 2018. – P. 255-263. (Scopus)
36. Sopov E., Vakhnin A. A Novel Method for Grouping Variables in Cooperative Coevolution for Large-scale Global Optimization Problems // *Proceedings of the 15th International Conference on Informatics in Control, Automation and Robotics - Volume 1: ICINCO.* – 2018. – P. 261-268. (Scopus)
37. Sopov, E., Vakhnin, A., Semenkin, E. On Tuning Group Sizes in the Random Adaptive Grouping Algorithm for Large-scale Global Optimization Problems // *Proceedings of 2018 International Conference on Applied Mathematics and Computational Science, ICAMCS.NET.* – 2018. – № 8955749. – P. 134-145. (Scopus, WoS)
38. Sopov, E., Pupkov, A., Panfilov, I., Samarin, V., Telesheva, N., Kuzmich, R. Hyper-heuristics for Structure and Parameters Tuning in Evolutionary Algorithms // *7th International Conference on Changes in Social and Business Environment (CISABE' 2018).* – 2018. – P.95-102. (WoS)
39. Sopov, E., Semenkin, E. Automated synthesis of selection operators in genetic algorithms using genetic programming // *International journal on information technologies and security.* – 2017. – 9 (4). – P.13-24. (WoS)
40. Sopov E. Genetic Programming Hyper-heuristic for the Automated Synthesis of Selection Operators in Genetic Algorithms // *IJCCI 2017 - Proceedings of the 9th International Joint Conference on Computational Intelligence.* – 2017. – P. 231-238. (Scopus)
41. Sopov E. Hybrid binary GA-EDA algorithms for complex "black-box" optimization problems // *Conference Series: Materials Science and Engineering.* – 2017. – 173 (1). – 012019. – P. 1-9. (Scopus, WoS)
42. Sopov, E. Self-configuring ensemble of multimodal genetic algorithms // *Studies in Computational Intelligence.* – 2017. – vol.669. – P. 56-74. (Scopus, WoS)
43. Sopov, E. EDA-based decomposition approach for binary LSGO problems // *IJCCI 2016 - Proceedings of the 8th International Joint Conference on Computational Intelligence.* – 2016. – Volume 1. – P. 132-139. (Scopus, WoS)
44. Sopov, E., Ryzhikov, I., Semenkin, E. A meta-heuristic for improving the performance of an evolutionary optimization algorithm applied to the dynamic system identification problem // *IJCCI 2016 - Proceedings of the 8th International Joint Conference on Computational Intelligence.* – 2016. – Volume 1. – P. 178-185. (Scopus, WoS)
45. Sopov, E., Semenkin, E., Panfilov, I. Ensemble of multimodal genetic algorithms for design and decision making support problems // *ICINCO 2016 - Proceedings of the 13th International Conference on Informatics in Control, Automation and Robotics.* – 2016. – Volume 1. – P. 160-167. (Scopus, WoS)
46. Sopov, E. Large-scale global optimization using a binary genetic algorithm with EDA-based decomposition // *Lecture Notes in Computer Science (including subseries Lecture*

- Notes in Artificial Intelligence and Lecture Notes in Bioinformatics). – 2016. – Volume 9712. – P. 619-626. (Scopus, WoS)
47. Sopov, E. A Self-configuring Multi-strategy Multimodal Genetic Algorithm // Advances in Nature and Biologically Inspired Computing Volume 419 of the series Advances in Intelligent Systems and Computing. – 2016. – P. 15-26. (Scopus, WoS)
 48. Sopov, E., Ivanov, I. Self-configuring ensemble of neural network classifiers for emotion recognition in the intelligent human-machine interaction // Proc. of 2015 IEEE Symposium Series on Computational Intelligence (SSCI 2015). – 2016. – P. 1808-1815. (Scopus, WoS)
 49. Sopov, E., Stanovov, V., Semenkin, E. Multi-strategy multimodal genetic algorithm for designing fuzzy rule based classifiers // Proc. of 2015 IEEE Symposium Series on Computational Intelligence (SSCI 2015). – 2016. – P. 167-173. (Scopus, WoS)
 50. Sopov, E. Multi-strategy Genetic Algorithm for Self-Configuring Solving of Complex Optimization Problems // Proc. of the 4th International Congress on Advanced Applied Informatics, (IIAI-AAI 2015). – 2016. – P. 556-561. (Scopus, WoS)
 51. Sopov, E., Sidorov, M., Ivanov, I., Minker, W. Feature and Decision Level Audio-visual Data Fusion in Emotion Recognition Problem // The 12th International Conference on Informatics in Control, Automation and Robotics (ICINCO 2015). – 2015. – P. 246 – 251. (Scopus, WoS)
 52. Sopov, E., Zaloga, A., Burakov, S., Semenkin, E., Semenkina, M. On the Application of Co-Operative Swarm Optimization in the Solution of Crystal Structures from X-Ray Diffraction Data // Advances in Swarm and Computational Intelligence, Lecture Notes in Computer Science. – 2015. – Volume 9140. – P. 89-96. (Scopus)
 53. Sopov, E., Semenkina, O. The optimal solution prediction for genetic and distribution building algorithms with binary representation // Conf. Ser.: Mater. Sci. Eng. – 2015. – vol. 70. – 10 p. (Scopus, WoS)
 54. Sopov, E. A Self-configuring Metaheuristic for Control of Multi-Strategy Evolutionary Search. Advances in Swarm and Computational Intelligence // Lecture Notes in Computer Science. – 2015. – Volume 9142. – P. 29-37. (Scopus)
 55. Sopov, E. Multi-strategy genetic algorithm for multimodal optimization // In: proc. of the 7th International Joint Conference on Computational Intelligence (IJCCI). – 2015. – Vol. 1. – P. 55-63. (Scopus)
 56. Sopov, E., Ivanov, I. Design Efficient Technologies for Context Image Analysis in Dialog HCI Using Self-Configuring Novelty Search Genetic Algorithm // In: proc. of the 11th International Conference on Informatics in Control, Automation and Robotics, ICINCO 2014. – 2014. – P. 832-839. (Scopus)
 57. Sopov, E. On the investigation of Coevolutionary Genetic Algorithm for Self-configuring Solving of Non-stationary Optimization Problems // Proc. International Conference on Computer Science and Artificial Intelligence (ICCSAI 2014). – 2015. – P. 202-207. (WoS)
 58. Sopov, E., Panfilov, I. Intrusion detectors design with self-configuring multi-objective genetic algorithm // Network Security and Communication Engineering - Proceedings of the 2014 International Conference on Network Security and Communication Engineering (NSCE 2014). – 2015. – P. 185-188. (Scopus)

59. Sopov, E., Panfilov, I. Self-tuning SVM with Feature Selection for Text Categorization Problem // Proc. International Conference on Computer Science and Artificial Intelligence (ICCSAI 2014). – 2015. – P. 208-211. (WoS)

60. Sopov, E., Sopov, S. The convergence prediction method for genetic and PBIL-like algorithms with binary representation // Proceeding of International Siberian Conference on Control and Communications (SIBCON). – 2011. – P. 203-206. (Scopus)

В) Программы для ЭВМ, зарегистрированные в Роспатенте:

61. Вахнин А.В., Сопов Е.А., Панфилов И.А., Агафонов Е.Д., Гуменникова А.В., Ступина А.А., Панфилова Т.А, Сопова О.А., Бежитская Е.А., Плотников Д.В. Программная система решения сложных задач нестационарной мультимодальной оптимизации на основе эволюционных самоконфигурируемых гиперэвристик // Свидетельство о государственной регистрации программы для ЭВМ, № 2020611378, 2020.

62. Вахнин А.В., Сопов Е.А., Панфилов И.А. Программная реализация на основе параллельных вычислений метода DECC-RAG решения больших задач оптимизации // Свидетельство о государственной регистрации программы для ЭВМ, №2019613931, 2019.

63. Вахнин А.В., Сопов Е.А., Панфилов И.А. Программная система исследования эффективности эволюционных алгоритмов на задачах оптимизации большой размерности // Свидетельство о государственной регистрации программы для ЭВМ, №2018666438, 2018.

64. Ломаев Ю.С., Панфилов И.А., Сопов Е.А. Программная система автоматизированной обработки спектроскопических данных с использованием методов кластерного анализа и эволюционных алгоритмов нестационарной мультимодальной оптимизации // Свидетельство о государственной регистрации программы для ЭВМ, №2017662420, 2017.

65. Семенкин Е.С., Панфилов И.А., Сопов Е.А., Становов В.В., Хритonenко Д.И., Брестер К.Ю., Семенкина О.Е. Программная система автоматизированного проектирования интеллектуальных информационных сетей // Свидетельство о государственной регистрации программы для ЭВМ, №2015662501, 2015.

66. Семенкин Е.С., Панфилов И.А., Сопов Е.А., Становов В.В., Хритonenко Д.И., Брестер К.Ю., Семенкина О.Е. Программная система для автоматизированного управления интеллектуальными информационными сетями // Свидетельство о государственной регистрации программы для ЭВМ, №2015662581, 2015.

67. Хритonenко Д.И., Панфилов И.А., Сопов Е.А. Система автоматического генерирования коллективов нейросетевых моделей распределенными самоконфигурируемыми эволюционными алгоритмами // Свидетельство о государственной регистрации программы для ЭВМ, №2014612727, 2014.

68. Панфилов И.А., Семенкин Е.С., Сопов Е.А. Программная система выбора эффективных структур аппаратно-программных комплексов высокопроизводительных распределенных систем // Свидетельство о государственной регистрации программы для ЭВМ, №2013619087, 2013.

69. Панфилов И.А., Семенкин Е.С., Сопов Е.А. Программная система формирования эффективных конфигураций параллельных вычислительных систем (MBK, GRID и

CLOUD) методами интеллектуальных информационных технологий // Свидетельство о государственной регистрации программы для ЭВМ, №2013617236, 2013.

70. Иванов И.А., Сопов Е.А. Программная система решения сложных задач многокритериальной оптимизации самоконфигурируемым коэволюционным алгоритмом SelfCOMOGA // Свидетельство о государственной регистрации программы для ЭВМ, №2013613773, 2013.

71. Семенкин Е.С., Панфилов И.А., Сопов Е.А., Шабалов А.А., Сергиенко Р.Б. Программная система «π-IT-on 2.0» - автоматизированное генерирование интеллектуальных технологий анализа данных // Свидетельство о государственной регистрации программы для ЭВМ, №2013617189, 2013.