

ՀԱՅԱՍՏԱՆԻ ՀԱՆՐԱՊԵՏՈՒԹՅԱՆ ԿՐԹՈՒԹՅԱՆ, ԳԻՏՈՒԹՅԱՆ,
ՄՇԱԿՈՒՅԹԻ ԵՎ ՍՊՈՐՏԻ ՆԱԽԱՐԱՐՈՒԹՅՈՒՆ

ՀԱՅԱՍՏԱՆԻ ԱԶԳԱՅԻՆ ՊՈԼԻՏԵԽՆԻԿԱԿԱՆ ՀԱՄԱԼՍԱՐԱՆ

Դավթյան Վաչագան Ռուբիկի

ԳԵՆԵՏԻԿԱԿԱՆ ԱԼԳՈՐԻԹՄՆԵՐԻ ԻՔՆԱԿԱՐԳԱԲԵՐՄԱՆ
ԱՎՏՈՄԱՏԱՑՎԱԾ ՄԻՋՈՑՆԵՐԻ ՄՇԱԿՈՒՄԸ

Ե.13.02 «Ավտոմատացման համակարգեր» մասնագիտությամբ
տեխնիկական գիտությունների թեկնածուի գիտական աստիճանի հայցման
ատենախոսության

ՍԵՂՄԱԳԻՐ

Երևան 2025

МИНИСТЕРСТВО ОБРАЗОВАНИЯ, НАУКИ, КУЛЬТУРЫ И СПОРТА
РЕСПУБЛИКИ АРМЕНИЯ

НАЦИОНАЛЬНЫЙ ПОЛИТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ АРМЕНИИ

Давтян Вачаган Рубикович

РАЗРАБОТКА АВТОМАТИЗИРОВАННЫХ СРЕДСТВ
САМОНАСТРОЙКИ ГЕНЕТИЧЕСКИХ АЛГОРИТМОВ

АВТОРЕФЕРАТ

диссертации на соискание ученой степени кандидата
технических наук по специальности 05.13.02-
“Системы автоматизации”

Ереван 2025

Ատենախոսության թեման հաստատվել է Հայաստանի ազգային պոլիտեխնիկական համալսարանում (ՀԱՊՀ):

Գիտական ղեկավար՝

տ.գ.դ. Աշոտ Գևորգի Հարությունյան

Պաշտոնական ընդդիմախոսներ՝

տ.գ.դ. Հայկ Ստեփանի Սուքիասյան

տ.գ.թ. Գոռ Արսենի Պետրոսյան

Առաջատար կազմակերպություն՝

Հայ-Ռուսական Համալսարան

Ատենախոսության պաշտպանությունը կայանալու է 2025թ. հուլիսի 17-ին, ժամը 10⁰⁰-ին, ՀԱՊՀ-ում գործող «Կառավարման և ավտոմատացման» 032 մասնագիտական խորհրդի նիստում (հասցեն՝ 0009, Երևան, Տերյան փ., 105, 17 մասնաշենք):

Ատենախոսությանը կարելի է ծանոթանալ ՀԱՊՀ-ի գրադարանում:

Սեղմագիրն առաքված է 2025թ. հունիսի 16-ին:

032 Մասնագիտական խորհրդի
գիտական քարտուղար, տ.գ.թ.



Անուշ Վազգենի Մելիքյան

Тема диссертации утверждена в Национальном политехническом университете Армении (НПУА)

Научный руководитель:

д.т.н. Ашот Геворгович Арутюнян

Официальные оппоненты:

д.т.н. Айк Степанович Сукиасян

к.т.н. Гор Арсенович Петросян

Ведущая организация:

Российско-Армянский Университет

Защита диссертации состоится 17-го июля 2025г. в 10⁰⁰ ч. на заседании Специализированного совета 032 — "Управления и автоматизации", действующего при Национальном политехническом университете Армении, по адресу: 0009, г. Ереван, ул. Теряна, 105, корпус 17.

С диссертацией можно ознакомиться в библиотеке НПУА.

Автореферат разослан 16-го июня 2025 г.

Ученый секретарь

Специализированного совета 032, к.т.н.



Ануш Вазгеновна Меликян

ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

Актуальность темы. Проблемы, решаемые в современных системах автоматизации, обусловлены неуклонным ростом объема обрабатываемой информации и сложностью аналитических моделей. В частности, задачи автоматизированного проектирования электронных устройств в основном имеют комбинаторный характер, точное решение которых предполагает полный перебор, что подразумевает факториальный порядок сложности. Эволюционные алгоритмы, такие как генетический алгоритм (ГА), являются эффективным средством решения таких задач.

Эффективность ГА во многом зависит от изначального выбора правильных значений их параметров. В общем случае эти параметры задаются до запуска алгоритма. Однако, поскольку оптимальные значения параметров могут изменяться в процессе работы алгоритма, для повышения эффективности ГА возникает необходимость в корректировке параметров в процессе их работы. Поскольку эти параметры могут изменяться по разным причинам, для повышения эффективности ГА и адаптации их к решаемым задачам необходимо обеспечить процесс динамической корректировки параметров во время работы алгоритма, что позволит им автоматически адаптироваться к изменению условий эксплуатации и требований.

Эффективность ГА во многом зависит от правильного первоначального выбора значений их параметров. В общем, эти параметры определяются до запуска алгоритма, однако по мере продвижения алгоритма эти оптимальные значения могут меняться в зависимости от теоретического мнения, других общих условий и зарегистрированного опыта. Следовательно, для повышения эффективности ГА необходимо участвовать в процессе динамической настройки параметров во время работы алгоритма, что позволит автоматически адаптироваться к изменениям действующих условий.

Разработка таких методов создала новую ветвь генетических алгоритмов, которые называются самонастраивающиеся генетическими алгоритмами (СГА). Прежде всего необходимо понять методы самонастройки ГА. Первый метод - это создание математических моделей, которые обеспечат связь между параметрами и, контролируя ход работы, будут соответственно регулировать эти параметры. Этот метод в основном сопровождается сбором статистических данных и генерацией соответствующих функций.

Второй метод - это создание самонастраивающихся механизмов (скрещивание, мутация и т. д.) . Этот метод может быть как специфичным для данной задачи, предусматривающим четко сформированную модель, так и общим, основанным на какой-либо математической модели.

Третий метод - это динамическое преобразование популяции, которое отличается как изменением размера популяции, обусловленным объемом задачи, так и продолжительностью жизни особей, находящихся в популяции.

Учитывая вышеуказанные проблемы и современные направления решений, актуальной задачей становится создание новых моделей в указанном направлении и автоматическая настройка параметров в ряде современных областей, особенно в интегральных схемах (ИС) – в задаче размещения элементов.

Обобщая вышесказанное, предлагается система автоматизации самонастройки параметров ГА, которая включает в себя предложения математических моделей для изменения параметров, автоматизированные методы настройки механизмов ГА, основанные на ходе работы алгоритма, и новый метод механизма скрещивания алгоритма.

Объект исследования. Нацеленные на повышение эффективности решения современных задач высокой сложности, методов самонастройки параметров генетических алгоритмов и алгоритмического и программного обеспечения для их внедрения в системы автоматизации.

Цель работы. Разработка механизма настройки внутренних параметров ГА (размера популяции, механизма кроссинговера, механизма и вероятности мутации и т.д.), соответствующего алгоритма и программного обеспечения, которые в процессе их работы обеспечат автоматическую настройку алгоритма в соответствии с требованиями конкретной решаемой задачи с точки зрения сложности задачи, требуемой точности, времени и т.д.

Методы исследования. В процессе выполнения диссертации были использованы характеристические файлы задачи размещения компонентов ИС, наборы данных задачи коммивояжера (ЗК), задачи квадратичного присваивания (ЗКП) и задачу планирования расписания цехов (ЗПРЦ). Были также использованы математические и статистические модели для зависимости параметров, алгоритмы группировки, а также элементы библиотеки QT программного обеспечения.

Научная новизна:

- Предложены и разработаны методы настройки взаимосвязанных параметров ГА посредством обратной связи.
- Предложен и разработан новый само настраиваемый подход к механизму скрещивания ГА, предназначенный для задачи размещения в ИС, который с учетом специфики задачи размещения ИС повышает эффективность оценки связей между элементами по сравнению с существующими методами скрещивания.
- Предложен метод самонастройки популяции ГА, основанный на продолжительности жизни особей, благодаря которому эффективность ГА повышена на 17,6%.
- Предложен саморегулирующийся метод создания начальной популяции на основе алгоритмов кластеризации с целью быстрого поиска набора решений ГА, благодаря которому были улучшены поиск множества решений и разнообразие популяции, в результате чего для ЗКТ наблюдался рост эффективности на 17,0...29,8%.
- Предложен метод саморегуляции механизма мутации ГА, обусловленный скоростью обучения. Благодаря этому вероятность попадания в область локального минимума в среднем снизилась более чем в три раза, а количество поколений для достижения оптимального решения сократилось на 34,8%.

Практическая ценность работы. Предложенные в работе методы могут быть применены в различных областях, где имеется масштабный поток данных и задачи оптимизации, а созданная система автоматизации может быть внедрена в системы автоматизации распределения работ.

Основные положения.

На защиту выносятся

- Метод создания начальной популяции ГА;
- метод динамического размера популяции ГА и продолжительности жизни особей;
- новый метод скрещивания ГА;
- метод динамического изменения вероятности мутации путем создания критерия скорости обучения ГА;
- автоматизированная система настройки параметров ГА.

Структура и объем диссертации. Работа состоит из введения, четырех глав, заключения, списка литературы из 103 наименований и четырех приложений . Объем диссертации составляет 129 страниц, а вместе с приложениями - 133 страницы . Диссертация написана на армянском языке.

Достоверность научных положений. Достоверность научных положений подтверждается точностью математических моделей, проверками тестовых схем задачи размещения ИС, с результатами тестирования на наборах данных известных задач ЗК, ЗКП и ЗПРЦ.

Внедрение. Результаты диссертационной работы, в частности, математические модели, предложенные методы саморегулирования, результаты исследований применительно к наборам данных, а также созданные программные средства внедрены в теоретические и практические занятия по курсу «Большие данные» кафедры «Информационные технологии и автоматизация» НПУА.

Апробация работы. Основные научные и практические результаты диссертации докладывались на:

- Международном симпозиуме "IEEE East-West Design & Test Symposium (EWDTS)" (Батуми, Грузия, 2023 г.);
- Международном симпозиуме "IEEE East-West Design & Test Symposium (EWDTS)" (Ереван, Армения, 2024 г.) - 2 доклада;
- Международной научно-практической конференции "Современные информационные и электронные технологии" (MIET-2023) (Одесса, Украина, 2023);
- Международной научно-практической конференции "Современные информационные и электронные технологии" (MIET-2024) (Одесса, Украина, 2024) - 2 доклада.

Публикации. Основные положения, представленные в диссертации, обобщены в шести научных статьях, одна из которых без соавторов, а три - в научной базе данных «SCOPUS» («СКОПУС»). Список статей приведен в конце автореферата.

ОСНОВНОЕ СОДЕРЖАНИЕ РАБОТЫ

Во введении обоснована актуальность темы диссертации, сформулированы цель и основные задачи исследования, представлены разработанные методы, научная новизна, практическое значение и основные научные положения, выносимые на защиту.

В первой главе Рассмотрены области применения генетических алгоритмов и их типичная структура, основанная на эволюционных принципах отбора, скрещивания и мутации. Ключевое внимание уделено критическим параметрам: размеру популяции, вероятностям мутации и скрещивания, давлению отбора существенно влияющим на эффективность алгоритма.

Проанализированы подходы к созданию самоадаптивных ГА, способных динамически корректировать параметры в процессе выполнения. Рассмотрены методологии разработки адаптивных операторов, реагирующих на изменения ландшафта приспособленности, что помогает преодолеть ограничения традиционных ГА с фиксированными параметрами.

Оценка существующих методов показала, что многие современные подходы эффективны в конкретных сценариях, но недостаточно универсальны. Выявлена необходимость создания более надежных механизмов обратной связи для корректировки параметров без чрезмерных вычислительных затрат.

Определены перспективные направления развития адаптивных методов, включая гибридные подходы, объединяющие математические модели с эвристическими методами. Интеграция машинного обучения с генетическими алгоритмами представляет особенно перспективное направление для повышения адаптивности эволюционных вычислений.




Рис. 1. Основные области применения генетических алгоритмов

Генетические алгоритмы широко применяются в областях, связанных с анализом больших данных и задачами NP-сложности. Каждая конкретная область требует специализированной адаптации и учета уникальных нюансов при реализации и функционировании этих алгоритмов. Эта потребность привела к развитию специализированного направления, сосредоточенного на адаптации ГА к конкретным областям их применения. Независимо от сферы применения, внедрение СГА является критически важным для эффективного решения крупномасштабных оптимизационных задач во всех этих разнообразных областях (рис. 1).

Для достижения вышеуказанной цели существует три основных подхода к адаптации параметров генетических алгоритмов (рис. 2).



Рис. 2. Подходы к адаптации параметров ГА

Детерминированные методы управления - это методы, где параметры корректируются согласно предопределенным правилам или математическим моделям на основе статистических данных. Адаптивные методы отслеживают производительность алгоритма во время выполнения и выполняют независимую корректировку параметров на основе обратной связи. Самоадаптивные методы встроены непосредственно в работу ГА, становясь частью самого алгоритма, а не внешними средствами контроля. Существует также и четвертый метод, который представляет собой комбинацию вышеупомянутых методов. Этот комбинированный подход объединяет элементы детерминированных, адаптивных и самоадаптивных методов, позволяя использовать преимущества каждого из них для более эффективной настройки параметров ГА в зависимости от специфики решаемой задачи.

В научной литературе существует множество работ, связанных со всеми этими методами, но в рамках данной работы рассмотрены наиболее передовые самоадаптивные методы. Например, адаптивный генетический алгоритм AGAVaPS для структурного обучения байесовских сетей. Главная идея заключается в том, чтобы усилить как адаптивность, так и устойчивость поиска за счёт внедрения двух ключевых концепций (рис. 3).




Рис. 3. Адаптивный генетический алгоритм AGAVaPS

Индивидуальная скорость мутации – каждая особь имеет свою собственную вероятность мутации, что повышает разнообразие популяции и даёт возможность гибкой адаптации к ландшафту целевой функции.

Ограниченный срок жизни особей – каждая особь "живет" ограниченное количество поколений, после чего удаляется, даже если она показывает хороший результат. Это позволяет избегать застоя в локальных оптимумах.

Вероятность двойной мутации – в редких случаях особь может мутировать дважды, что добавляет элемент случайности и расширяет область поиска.

Метод оценивается с помощью стандартных метрик: F1-score, Structural Hamming Distance (SHD) и Bayesian Information Criterion (BIC). Результаты показали, что AGAVaPS превосходит классические методы, такие как Hill Climbing и Tabu Search, по точности и качеству восстановления структуры сети.

AGAVaPS хорошо сбалансирован между эксплуатацией (использование уже найденных хороших решений) и эксплорацией (поиск новых потенциально лучших областей). Это достигается за счёт индивидуальной адаптации параметров, что выгодно отличает его от традиционных фиксированных подходов

Другой метод – это алгоритм FL-ADE, который начинает свою работу с создания начальной популяции решений выбранного размера, где каждый индивид представляет собой вектор значений переменных оптимизируемой задачи. После инициализации на каждом поколении вычисляются характеристики фитнес-ландшафта, которые отражают, как изменяется значение целевой функции при изменении расстояния до текущих лучших решений. Эти локальные метрики позволяют понять, насколько поверхность поиска является "рельефной" с множеством локальных экстремумов или, наоборот, "гладкой" и близкой к оптимальной области (рис. 4).



Рис 4 Алгоритм FL-ADE

FL-ADE динамически меняет размер популяции: увеличивает его в сложных рельефных участках для тщательного исследования пиков и впадин и уменьшает в

гладких областях для ускорения сходимости. Алгоритм использует стратегию мутации DE/current-to-pbest, направляя текущие индивиды к лучшим решениям из архива топ-р% особей, что балансирует эксплуатацию и разнообразие.

После мутации выполняются кроссовер, смешивающий мутанты с исходными решениями, затем селекция наиболее приспособленных индивидов для следующего поколения. Новые решения оцениваются целевой функцией, и алгоритм завершается при достижении заданного числа поколений или критерия точности.

Таким образом, FL-ADE является адаптивным решением, которое на каждом шаге учитывает свойства текущего фитнес-ландшафта для изменения как структуры популяции, так и стратегии мутации. Это позволяет алгоритму эффективно балансировать между фазами исследования и сужения области поиска, обеспечивая высокую скорость сходимости и устойчивость к попаданию в локальные экстремумы.

На наборе из 30 тестовых функций CEC2014 алгоритм FL-ADE с механизмом адаптивного размера популяции (FL-APS) показал лучшие или не хуже лучших результаты на 26 функциях из 30 при размерности 10 и 30, а также на 23 функциях из 30 при размерности 50 по сравнению с версией FL-ADE_linear, использующей линейное уменьшение размера популяции.

Исследование Преториуса и Пиллая в области пересечения генетических алгоритмов и нейронных сетей представляет значительный интерес. Авторы обратились к давней проблеме в эволюционных вычислениях: эффективные операторы кроссовера для нейронных сетей обычно считаются слишком разрушительными и часто исключаются из генетических алгоритмов ГА при обучении весов нейронных сетей.

В своей работе они разработали новый подход генетического программирования для автоматической эволюции операторов кроссовера. Ключевая инновация заключается в том, что вместо ручного проектирования операторов кроссовера они использовали генетическое программирование для их автоматической эволюции. Авторы предложили две категории операторов: многозавые (которые можно использовать в течение всего процесса эволюции) и одноразовые (специализированные для конкретной задачи).

Методология включала сравнительные эксперименты на пяти различных наборах данных: CIFAR-10, Thumbnail, Wine, Higgs и Bean. Они сравнивали эффективность ГА без операторов кроссовера, с традиционными операторами, разработанными человеком, и с их эволюционированными операторами кроссовера.

Эксперименты показали, что одноразовые операторы кроссовера, эволюционировавшие с помощью генетического программирования, превосходят многозавые, но только при динамической скорости кроссовера, постепенно увеличивающейся для предотвращения ранней сходимости. Дальнейшие исследования подтвердили значительное улучшение результатов при использовании одноразовых операторов по сравнению с отсутствием кроссовера.

При эволюции многозавых операторов генетическое программирование сходилась к оператору, усредняющему веса родительских нейронных сетей. Этот подход улучшал результаты лишь на некоторых наборах данных, ухудшая их на других. Это указывает на необходимость разработки операторов кроссовера

специально для каждой пары весов. Когда производительность нейронных сетей приоритетна, использование генетического программирования для эволюции одноразовых операторов кроссовера оправдывает увеличение вычислительных затрат значительным улучшением качества весов. Представленный обзор методов адаптации параметров ГА указывает на значительную комплексность данной области исследований. Генетические алгоритмы применяются в широчайшем спектре доменов - от инженерной оптимизации до машинного обучения и биоинформатики, что обуславливает многообразие подходов к настройке их параметров.

Рассмотренные методы (AGAVaPS, FL-ADE, подход Преториуса и Пиллая) демонстрируют различные стратегии адаптации ключевых параметров: вероятности мутации, времени жизни особей, размера популяции и операторов кроссовера. Примечательно, что для каждого параметра существует множество потенциальных подходов к адаптации – от детерминированных до полностью самоадаптивных.

Это подчеркивает необходимость дальнейших исследований, направленных на создание комплексных адаптивных механизмов, способных одновременно настраивать множество взаимосвязанных параметров в зависимости от специфики решаемой задачи.

Во второй главе представлены разработанные методы и даются решения проблем, описанных в первой главе.

Метод самонастраивающейся начальной популяции в генетических алгоритмах.

Формирование начальной популяции является критически важным этапом генетического алгоритма, определяющим направление и эффективность поиска оптимального решения. Разнообразие начальной популяции напрямую влияет на качество исследования пространства поиска.

В традиционном ГА начальная популяция инициализируется случайным образом без проверки различия между сгенерированными особями и их репрезентативности для всего множества возможных решений. Размер популяции также является критическим параметром: малая популяция обеспечивает быструю оценку, но страдает от недостатка разнообразия, а слишком большая приводит к росту вычислительных затрат.

В рамках данной работы предложен новый метод самонастраивающейся начальной популяции, основанный на алгоритмах кластеризации. Основная идея заключается в создании избыточной начальной популяции с последующим её структурированием и отбором репрезентативных особей.

Создается случайная начальная популяция размером $K \cdot M$, где K – размер конечной популяции, а M – коэффициент избыточности

Выбирается подходящий алгоритм кластеризации в зависимости от наличия функции расстояния F между особями.

Популяция разделяется на кластеры, после чего из каждого кластера выбираются репрезентативные особи.

Из выбранных особей формируется окончательная начальная популяция размером K .

Важным преимуществом предложенного подхода является его независимость от конкретной задачи и структуры особей. Метод может работать как с функцией расстояния между особями, так и без неё, хотя при наличии функции расстояния результаты улучшаются. Для вычисления расстояния между особями используется евклидово расстояние:

$$D(C_i, C_j) = \sqrt{\sum_{k=1}^n (C_{ik} - C_{jk})^2}.$$

Проблема разнообразия популяции в генетических алгоритмах хорошо известна, и для её решения предложено множество методов. Существующие подходы часто ориентированы на конкретные задачи, такие как задача коммивояжера или распределение ресурсов, и могут требовать дополнительной адаптации для других задач.




Рис. 5. Результаты для задачи коммивояжера

Для оценки эффективности разработанного метода использовалась задача коммивояжера из библиотеки TSPLIB95. Задачи различного объема сравнивались с результатами традиционного ГА. Экспериментальные данные показывают, что предложенный метод демонстрирует увеличение разнообразия общей популяции на 23,4% по сравнению с традиционным подходом, что является основой для более эффективного исследования пространства решений и снижения вероятности застревания в локальном минимуме (рис 5).

Результаты исследования демонстрируют, что для задач практически всех уровней сложности разработанная модель превосходит традиционный генетический алгоритм по эффективности, обеспечивая повышение производительности на 17,0%...29,8%.

Адаптивный метод управления размером популяции на основе остаточного времени жизни особей.

В области ГА проблематично определение оптимального размера популяции. Малый размер ведет к быстрой сходимости, но риску застревания в локальных оптимумах из-за недостатка разнообразия. Большой размер обеспечивает широкий охват пространства поиска, но увеличивает вычислительные затраты. Традиционные подходы с фиксированным размером популяции требуют

экспериментального подбора оптимального значения для каждой задачи, что неэффективно для сложных оптимизационных проблем. Предложенный метод решает это ограничение через динамическую адаптацию размера популяции.

Разработанный подход использует концепцию остаточного времени жизни (ОВЖ), присваивая каждой особи определенный "срок жизни" в зависимости от качества решения. Чем лучше решение, тем дольше особь сохраняется в популяции, что позволяет сохранять перспективные решения и исследовать перспективные области пространства поиска. Математически **ОВЖ** вычисляется по формуле

$$\text{ОВЖ} = \text{ВЖ}_{\min} + \text{ВЖ}_{\max} * (F_{\text{худшее}} - F(C_i)) / (F_{\text{худшее}} - F_{\text{лучшее}}),$$

где ВЖ_{мин} и ВЖ_{макс} - параметры, определяющие минимальное и максимальное времена жизни особей (экспериментально определены как 1 и 10 соответственно); F_{лучшее} и F_{худшее} - лучшее и худшее значения целевой функции в текущей популяции; F(C_i) - значение целевой функции для i-й особи.

Алгоритм реализуется следующим образом (рис 6).




Рис. 6. Адаптивный генетический алгоритм с учётом остаточного жизненного времени

Важной особенностью данного подхода является то, что размер популяции не является фиксированным, а меняется динамически в зависимости от состояния эволюционного процесса. На начальных этапах, когда популяция содержит много разнообразных, но низкокачественных решений, размер популяции может уменьшаться. По мере обнаружения перспективных областей размер может увеличиваться за счет сохранения лучших особей с высоким значением ОВЖ и добавления новых особей через операторы кроссовера и мутации.

Предложенный метод был комплексно протестирован на задаче размещения элементов ИС различной сложности (от 10 до 3000 ячеек). В сравнении с традиционным ГА с фиксированным размером популяции, метод продемонстрировал значительное улучшение как по скорости сходимости, так и по качеству получаемых решений. В среднем количество итераций до нахождения оптимального решения сократилось на 17,6%, при этом для схем большого размера (более 1000 ячеек) экономия времени достигала 20...25%(рис 7).




Рис. 7. Сравнение времени выполнения алгоритмов

Инновационный метод кроссовера для генетических алгоритмов в задаче размещения элементов интегральных схем.

Предложенный инновационный метод основан на группировке связанных ячеек в "блоки". Вместо обмена отдельными генами между родительскими хромосомами новый подход оперирует блоками ячеек, сохраняя оптимальные подструктуры. Математическая модель для определения размера блоков использует следующую формулу:

$$C = \sum_{i=1}^N a_i * i^2,$$

где C - количество ячеек; a_i - коэффициент при i -ом числе; N - константа, равная $\log_2 C$.

Алгоритм работает следующим образом: каждая хромосома представляется как набор блоков разного размера. Блоки формируются на основе наиболее связанных ячеек - от больших к малым. Кроссовер выполняется путем случайного выбора

блоков из обоих родителей. При пересечении блоков выполняется валидация с заменой перекрывающихся ячеек.

Для оценки эффективности предложенного блочного метода проведено тестирование на задачах размещения от 100 до 1600 ячеек с шагом 50. Для каждой конфигурации генерировалось 20 случайных матриц связей. Метод сравнивался с тремя классическими алгоритмами: однопозиционным, равномерным и порядковым кроссовером.

Оценка производилась по двум параметрам: количество итераций для достижения 15% погрешности и значение целевой функции после 100 итераций. Результаты показали, что для малых задач (100...400 ячеек) однопозиционный кроссовер требует всего 20 итераций против 32 у блочного метода. Однако при увеличении размера задачи эффективность стандартных методов падает – для задач с 1300...1600 ячейками однопозиционному кроссоверу требуется уже 68 итераций, тогда как блочному методу – только 47.

По второму параметру новый метод демонстрирует преимущество на всех размерах задач. Для задач со 100...400 ячейками значение целевой функции составляет 7,31 против 8.03-9.35 у стандартных подходов. Эта тенденция сохраняется и для более крупных задач, что подтверждает более высокий коэффициент обучения нового алгоритма и его превосходство для сложных случаев размещения элементов интегральных схем.

Метод самонастройки вероятности мутации на основе скорости обучения.

Эффективность генетических алгоритмов в значительной степени зависит от правильного выбора параметров, среди которых ключевую роль играет вероятность мутации. Оптимальное значение этого параметра зависит не только от характера задачи, но и от текущей фазы работы алгоритма. Предложенный метод основан на идее, что вероятность мутации должна динамически регулироваться в соответствии со скоростью обучения алгоритма.

В данном подходе скорость обучения определяется как относительное изменение лучшего значения фитнес-функции за определенный промежуток времени. Низкие значения скорости обучения указывают на застой в значении фитнес-функции и возможную конвергенцию к локальному оптимуму.

Стратегия регулирования вероятности мутации заключается в увеличении её значения при низкой скорости обучения, что стимулирует исследование новых областей пространства решений и помогает алгоритму выйти из локальных оптимумов. При высокой скорости обучения вероятность мутации остается близкой к базовому значению, что способствует эксплуатации найденных решений.

Основные преимущества метода включают: автоматическую адаптацию к процессу поиска без необходимости ручной настройки, вычислительную эффективность, универсальность применения для широкого спектра ГА, предотвращение преждевременной конвергенции и обеспечение оптимального баланса между эксплуатацией и исследованием.

Метод был протестирован на задаче планирования работы цеха размерностью 10×10 , которая является NP-сложной комбинаторной задачей оптимизации. Результаты показали, что ГА с адаптивной мутацией значительно превосходит стандартный ГА по нескольким ключевым показателям:

- среднее время конвергенции уменьшилось с 312,5 до 203,6 итераций, что представляет собой улучшение на 34,8%;
- количество случаев "застревания" в локальных оптимумах снизилось с 7,3 до 1,9, что свидетельствует о более чем трехкратном сокращении этой проблемы.

Предложенный метод адаптивной регулировки вероятности мутации посредством обратной связи по скорости обучения является перспективным подходом к повышению эффективности генетических алгоритмов. Тестирование на реальных задачах JSP показывает, что ГА с адаптивной мутацией находит лучшие решения, конвергирует быстрее (на 28...35% меньше поколений) и значительно реже "застревает" в локальных оптимумах (в 3...4 раза меньше случаев "консервации").

В третьей главе представлена автоматизированная система для настройки параметров генетических алгоритмов, которая объединяет методы, разработанные в предыдущих главах, в единый программный комплекс. Система оптимизирует параметры ГА на основе обратной связи по эффективности и построена по модульному принципу, что позволяет легко расширять и адаптировать её для различных задач.

Архитектура системы включает эти основные компоненты. Определение задачи осуществляется через JSON-формат, который описывает оптимизационную задачу, её параметры, ограничения и цели. Анализатор конфигурации обрабатывает и проверяет входные данные, обеспечивая их соответствие требованиям системы. Ядром системы являются реализации генетических алгоритмов для различных оптимизационных задач (ЗКП, ЗПРЦ, ЗК).

Компоненты, основанные на событиях, отвечают за мониторинг работы алгоритма и динамическую настройку параметров. Система включает четыре основных регулятора, управляющих размером популяции, вероятностью мутации, коэффициентом кроссовера и давлением отбора. Компоненты визуализации предоставляют графическое представление работы алгоритма, а компоненты журналирования отвечают за сбор и сохранение данных о процессе оптимизации.

Система спроектирована с использованием принципов объектно-ориентированного программирования, что обеспечивает высокую степень модульности и расширяемости. Архитектура построена таким образом, что добавление новых задач требует минимальных усилий – достаточно реализовать только специфичные для задачи методы (кодирование и декодирование решения, расчёт функции приспособленности, специальные операторы мутации и кроссовера), в то время как основная функциональность уже реализована в базовых классах и переиспользуется. Это соответствует принципу открытости/закрытости и позволяет системе легко адаптироваться к новым требованиям без изменения существующего кода.

В четвертой главе представлено разработанное программно-инструментальное средство "GAO System", реализующее методы самонастройки генетических алгоритмов, предложенные во второй и третьей главах. Система автоматизирует весь процесс оптимизации от загрузки исходных данных задачи до представления результатов и анализа эффективности алгоритма.




Рис. 8. Главное окно приложения

Главное окно приложения (рис. 8) содержит три основные вкладки: Main (Главная), Logs (Журналы) и Analysis (Анализ). На вкладке Main пользователь имеет возможность загрузить входной файл с описанием задачи оптимизации. Система поддерживает различные форматы входных данных, включая специализированные форматы для ЗК, ЗКП и ЗПРЦ. В левой части окна отображается список недавно использованных файлов, что позволяет быстро переключаться между различными задачами.

Центральная часть главного окна содержит таблицу с текущими параметрами генетического алгоритма, такими как общее количество итераций, лучшее значение фитнес-функции, метод кроссовера, вероятность мутации, размер популяции и время выполнения. В правой части пользователь может непосредственно настроить начальные параметры алгоритма: размер популяции, количество поколений, вероятность мутации, метод кроссовера и метод селекции. После задания всех необходимых параметров пользователь может запустить генетический алгоритм нажатием кнопки "Run Genetic Algorithm".

Вкладка Logs отображает подробную информацию о ходе выполнения алгоритма, включая значения фитнес-функции для каждого поколения, динамику изменения параметров и статистику работы алгоритма. Эта информация позволяет пользователю в реальном времени отслеживать прогресс оптимизации и своевременно выявлять возможные проблемы в работе алгоритма.

По завершении работы алгоритма пользователь может перейти на вкладку Analysis (рис. 9), где представлены различные графики и визуализации, отражающие процесс и результаты оптимизации. Основной график показывает эволюцию лучшего и среднего значений фитнес-функции в зависимости от номера поколения. Это позволяет наглядно оценить скорость сходимости алгоритма и его способность избегать локальных оптимумов. В нижней части окна анализа размещены кнопки для выбора различных типов визуализации: история изменения фитнес-функции, график скорости обучения, зависимость мутации от скорости обучения, динамика изменения размера популяции и разнообразие популяции. Также предусмотрена возможность экспорта результатов для дальнейшего анализа.




Рис. 9. Окно анализа (фитнес-функция)

Разработанная система GAO была протестирована на различных типах задач оптимизации разной степени сложности. Результаты, представленные в таблицах 4.1-4.3 диссертации, демонстрируют высокую эффективность предложенных методов самонастройки генетических алгоритмов. Для задачи коммивояжера система успешно справилась с экземплярами, содержащими от 1002 до 1,9 миллиона городов, обеспечивая отклонение от оптимального решения в пределах 0,89...8,24% в зависимости от размера задачи. Время работы алгоритма закономерно увеличивалось с ростом размерности задачи – от 5 минут для задачи с 1002 городами до 24 часов для World TSP с 1,9 миллионами городов. Для задачи квадратичного назначения система показала отклонение от оптимума в пределах 1,71...6,32% для задач размерностью от 100 до 500 объектов, а время работы составило от 3 до 64 минут. В случае задачи планирования работы цеха отклонение от оптимального решения составило 2,87...7,42% для экземпляров размерностью от 20×10 до 100×20 , а время работы варьировалось от 35 секунд до 21 минуты. Эти результаты подтверждают эффективность разработанной системы и ее применимость к широкому спектру задач комбинаторной оптимизации различной сложности.

ОСНОВНЫЕ ВЫВОДЫ ПО ДИССЕРТАЦИОННОЙ РАБОТЕ

1. Предложены и разработаны методы саморегулирования ГА, основанные на учете обратной связи взаимосвязанных параметров. [1, 2]
2. Предложен и разработан саморегулирующийся подход механизма скрещивания ГА для задачи размещения в планируемых ИС. Учитывая специфику задачи размещения ИС, он лучше оценивает связи элементов. Благодаря этому предлагаемый метод превосходит другие способы скрещивания, показывая прирост эффективности на 21,8...29,6%. [4, 6]
3. Предложен метод саморегуляции популяции ГА, основанный на продолжительности жизни особей. Благодаря чему эффективность ГА была увеличена на 17,6%. [3]

4. Предложен саморегулирующийся метод создания начальной популяции на основе алгоритмов группировки с целью быстрого поиска набора решений ГА. Благодаря чему был улучшен поиск множества решений и разнообразие популяции, в результате чего по ЗК наблюдалась эффективность 17,0...29,8%. [2, 3]
5. Предложен способ саморегулирования механизма мутации ГА, обусловленный скоростью обучения. Благодаря этому вероятность нахождения локального минимума в среднем снизилась более чем в три раза, а количество поколений для достижения оптимального решения сократилось на 34,8%. [2, 5]
6. Реализована архитектура системы автоматизации саморегулирования параметров ГА комбинированным способом. На основе чего создан программный инструмент с графическим интерфейсом. Полученный инструмент был протестирован на известных задачах ЗК, ЗКП и ЗПРЦ и сравнен с инструментами HeuristicLab и OptaPlanner, показав повышение эффективности на 0,89...1,98%, 1,71...6,32% и 2,87...7,42% соответственно за счет потери времени на 0,76...6,25%, 1,14...7,81% и 3,2...7,4% соответственно.[1, 2, 4]

Основные результаты диссертации опубликованы в следующих работах:

1. Ревазян Д.В., Давтян В.Р. Ускорение распределенной общей памяти за счет сжатия данных // Вестник РАУ: Физико-математические и естественные науки. - 2022. - №1. - С. 44-54, doi: 10.48200/1829-0450_pmn_2022_1_44.
2. Davtyan V. R. Formation of requirements for the self-adaptive genetic algorithm // Proceedings of NPUA: Information Technologies, Electronics, Radio Engineering. - 2024. - No 2. - P. 73-85. doi: 10.53297/18293336-2024.2-73.
3. Davtyan V., Harutyunyan A., Revazyan D. Population size adjustment of the genetic algorithm for integrated circuits elements placement // Proceedings of the XXV ISPC modern information and electronic technologies, May 27-29 2024. - Odesa, 2024. - P. 13-14.
4. Novel Adaptive Crossover Mechanism for Genetic Algorithm on Integrated Circuit Cell Placement / V. Melikyan, V. Davtyan, A. Harutyunyan, D. Revazyan, et al // 2024 IEEE East-West Design & Test Symposium (EWDTS). - 2024. - P 1-4. doi: 10.1109/EWDTS63723.2024.10873659
5. Tuning Genetic Algorithm Parameters for Placement of Integrated Circuit Cells / V. Melikyan, A. Harutyunyan, V. Davtyan, D. Revazyan, et al // 2023 IEEE East-West Design & Test Symposium (EWDTS). - 2023. - P 1-4. doi: 10.1109/EWDTS59469.2023.10297063.
6. Multiparametric Optimization and Penalty System in Integrated Circuit Component Placement / V. Melikyan, D. Revazyan, A. Harutyunyan, V. Davtyan, et al // 2024 IEEE East-West Design & Test Symposium (EWDTS). - 2024. - P 1-4. doi: 10.1109/EWDTS63723.2024.10873782.

ԱՄՓՈՓԱԳԻՐ

Ժամանակակից ավտոմատացման համակարգերում լուծվող խնդիրները առանձնանում են մշակման ենթակա տեղեկության ծավալի անշեղ աճով և անալիտիկ մոդելների բարդությամբ: Մասնավորապես, էլեկտրոնային սարքերի ավտոմատացված նախագծման խնդիրները, մեծամասամբ ունեն կոմբինատորային բնույթ, որոնց ճշգրիտ լուծումը ենթադրում է լրիվ ընտրանք: Ինչը ենթադրում է ֆակտորիալ կարգի բարդություն: Էվոլյուցիոն ալգորիթմները ինչպիսին է գենետիկական ալգորիթմը (ԳԱ) հանդիսանում է այսպիսի խնդիրների լուծման արդյունավետ միջոց:

ԳԱ-ի արդյունավետությունը մեծապես կախված է նրանց պարամետրերի ճիշտ արժեքների նախնական ընտրությունից: Ընդհանուր առմամբ, այդ պարամետրերը սահմանվում են նախքան ալգորիթմի գործարկումը: Սակայն, քանի որ պարամետրերի օպտիմալ արժեքները կարող են փոխվել ալգորիթմի աշխատանքի ընթացքում, ապա ԳԱ-ների արդյունավետության բարձրացման նպատակով, դրանց աշխատանքային գործընթացում անհրաժեշտություն է առաջանում պարամետրերի կարգաբերման: Քանի որ այդ պարամետրերը կարող են փոփոխվել տարբեր պատճառներով, ապա ԳԱ-ների արդյունավետությունը բարձրացնելու և լուծվող խնդիրներին ադապտացնելու նպատակով անհրաժեշտ է, որ ալգորիթմի աշխատանքի ընթացքում ապահովվի պարամետրերի դինամիկ կարգաբերման գործընթացը:

Գոյություն ունեցող ինքնակարգաբերման մեթոդները բաժանվում են 4 հիմնական խմբերի՝ դետերմինացված վերահսկողության, կարգաբերվող, ինքնակարգաբերվող և համակցված: Դետերմինացված վերահսկողության կարգաբերումները իրենցից ենթադրում են նախապես որոշված տրամաբանությամբ պարամետրերի կարգաբերում որի համար անհրաժեշտ են վիճակագրական տվյալներ: Կարգաբերվող մեթոդը ԳԱ-ի աշխատանքի ընթացքը հսկելով կատարում է անկախ պարամետրերի փոփոխություն: Ինքնակարգաբերվող մեթոդները ներդրված են ԳԱ-ի աշխատանքի մեջ և հանդիսանում են նրա մի մասը: Համակցված մեթոդները վերոնշյալ մեթոդների միավորումն են:

Մինչ այժմ կատարվում են մի շարք հետազոտություններ և աշխատանքներ նվիրված պարամետրերի կարգաբերմանը: Այս ոլորտում գիտական հետաքրքրությունը տարեցտարի աճում է, ինչը պայմանավորված է տեխնոլոգիաների արագ զարգացմամբ և նոր մարտահրավերների ի հայտ գալով: Վերջին տարիներին խնդիրների բարդացմանը զուգընթաց առավել մեծ ուշադրություն է ուղղվել ինքնակարգաբերվող մեթոդների և համակցված մեթոդների մշակմանը, որոնք թույլ են տալիս հաղթահարել ավանդական մոտեցումների սահմանափակումները:

Պարամետրերի ինքնակարգաբերման նոր մեթոդների ստեղծումը մեծ կարևորություն ունի և նպաստում է արդի խնդիրների արդյունավետ լուծմանը տարբեր ոլորտներում, ինչպիսիք են արհեստական բանականությունը, ռոբոտաշինությունը և տվյալների վերլուծությունը:

Ատենախոսությունը նվիրված է ԳԱ-ի պարամետրերի ինքնակարգաբերման մեթոդների արդի ուղությունների ուսումնասիրմանը, պարամետրերի և ալգորիթմի արդյունավետության հետազոտմանը, նոր մեթոդների մշակմանը և համակցված մեթոդով ավտոմատացման համակարգի մշակմանը:

Առաջարկվել և մշակվել են ԳԱ-ների ինքնակարգաբերման մեթոդներ, հիմնված փոխկապակցված պարամետրերի հետադարձ կապի հաշվի առնման վրա:

Առաջարկվել և մշակվել է ԳԱ-ի խաչասերման մեխանիզմի նոր ինքնակարգաբերվող մոտեցում նախատեսված ԻՄ-երում տեղաբաշխման խնդրի համար: Այն հաշվի առնելով ԻՄ-ի տեղաբաշխման խնդրի առանձնահատկությունը առավել լավ է գնահատում տարրերի կապերը, որի շնորհիվ առաջարկված մեթոդը գերազանցում է այլ խաչասերման մեթոդներին ցուցաբերելով արդյունավետության 21.8-29.6% աճ:

Առաջարկվել է ԳԱ-ի պոպուլացիայի ինքնակարգաբերման մեթոդ՝ հիմնված առանձնյակների կյանքի տևողության վրա, որի շնորհիվ բարձրացվել է ԳԱ-ի արդյունավետությունը 17.6%-ով:

Առաջարկվել է ԳԱ-ի լուծումների բազմության արագ փնտրման նպատակով նախնական փոփոխացիայի ստեղծման ինքնակարգաբերվող մեթոդ՝ հիմնված խմբավորման ալգորիթմների վրա, որի շնորհիվ բարելավվել է լուծումների բազմության փնտրումը և պոպուլացիայի բազմազանությունը, ինչի արդյունքում ՃՎԽ-ի համար նկատվել է 17.0%-29.8% արդյունավետություն:

Առաջարկվել է ԳԱ-ի մուտացիայի մեխանիզմի ինքնակարգաբերվող մեթոդ՝ պայմանավորված ուսուցման արագությամբ, որի շնորհիվ նվազել է տեղային մինիմումին բախվելու հավանականությունը միջինում ավելի քան 3 անգամ և օպտիմալ լուծման հասնելու գեներացիաների քանակը 34.8%-ով:

Իրագործվել է համակցված կերպով ԳԱ-ի պարամետրերի ինքնակարգաբերման ավտոմատացման համակարգի ճարտարապետությունը, որի հիման վրա ստեղծվել է գրաֆիկական ինտերֆեյսով ծրագրային գործիք: Ստացված գործիքը թեստավորվել է հայտնի ՃՎԽ, ՔՆԽ և ԱՊԽ խնդիրների վրա, համեմատվել է Heuristic lab և OptaPlanner գործիքների հետ ցուցաբերելով արդյունավետության աճ համապատասխանաբար՝ 0.89-1.98%, 1.71-6.32% և 2.87-7.42% ժամանակի կորստի համապատասխանաբար՝ 0.76-6.25%, 1.14 – 7.81% և 3.2-7.4% հաշվին:

**DEVELOPMENT OF AUTOMATION TOOLS FOR SELF-ADJUSTING
GENETIC ALGORITHMS**

SUMMARY

The problems solved in modern automation systems are characterized by a constant increase in the amount of information to be processed and the complexity of analytical models. In particular, the problems of automated design of electronic devices are mostly combinatorial in nature, the exact solution of which implies a complete sample, which implies a factorial-order complexity. Evolutionary algorithms such as the genetic algorithm (GA) are an effective means of solving such problems.

The efficiency of GAs largely depends on the initial selection of the correct values of their parameters. In general, these parameters are set before the algorithms execution. However, since the optimal values of the parameters can change during the operation of the algorithm, in order to increase the efficiency of GAs, there is a need to adjust the parameters during their operation. Since these parameters can change for various reasons, to increase the efficiency of GAs and adapt them to the problems being solved, it is necessary to ensure the process of dynamic adjustment of the parameters during the operation of the algorithm.

The existing self-regulating methods are divided into 4 main groups: deterministic control, adjustable self-regulating and combined. Deterministic control tuning involves tuning parameters according to a predetermined algorithm, for which statistical data is required. The adjusted method makes changes of independent parameters by monitoring the work process of the GA. Self-tuning methods are embedded in the work of the GA and are part of it. Combined methods are a combination of the above methods.

Until now, a number of studies and works devoted to parameter tuning are being carried out. Scientific interest in this field is growing every year, which is due to the rapid development of technologies and the emergence of new challenges. In recent years, as the problems have become more complex, more attention has been paid to the development of self-tuning methods and combined methods that allow overcoming the limitations of traditional approaches.

The creation of new methods for self-tuning parameters is of great importance and contributes to the effective solution of modern problems. In various fields, such as artificial intelligence, robotics and data analysis.

The dissertation is dedicated to the study of modern ways of self-regulating methods of GA parameters, the research of parameters and algorithm efficiency, the development of new methods and the development of an automation system using a combined method.

Methods for self-regulation of GAs have been proposed and developed, based on the consideration of the feedback of interconnected parameters.

A new self-regulating approach to the GA crossover mechanism has been proposed and developed for the problem of allocation in ICs. Taking into account the specificity of the IS allocation problem, it better estimates the connections of elements. Due to which the proposed method outperforms other crossover methods, demonstrating a 21.8-29.6% increase in efficiency.

A method for self-regulation of the GA population has been proposed, based on the lifespan of individuals. Due to which, the efficiency of the GA was increased by 17.6%.

A self-regulating method for creating an initial population for the purpose of quickly searching for the set of GA solutions based on clustering algorithms has been proposed. Due to which, the search for the set of solutions and the diversity of the population were improved, as a result of which an efficiency of 17.0%-29.8% was observed for the TSP.

A self-regulating method of the mutation mechanism of the GA was proposed, conditioned by the learning rate. Due to which the probability of encountering a local minimum was reduced by an average of more than 3 times and the number of generations to reach the optimal solution was reduced by 34.8%.

The architecture of the automation system for self-regulating the parameters of the GA was implemented in a combined manner. Based on which a software tool with a graphical interface was created. The resulting tool was tested on well-known TSP, QAP, and JSP problems, and compared with Heuristic lab and OptaPlanner tools, showing an increase in efficiency of 0.89-1.98%, 1.71-6.32%, and 2.87-7.42%, respectively, at the expense of time loss of 0.76-6.25%, 1.14 – 7.81%, and 3.2-7.4%, respectively.

A handwritten signature in black ink, appearing to be 'Zhurav' or similar, written in a cursive style.