

В.В. КУРЕЙЧИК, В.И. ДАНИЛЬЧЕНКО, Е.В. ДАНИЛЬЧЕНКО  
**АДАПТИВНАЯ ПАРАМЕТРИЗАЦИЯ  
МЕТАЭВРИСТИЧЕСКОГО АЛГОРИТМА ПРИ РАЗМЕЩЕНИИ  
КОМПОНЕНТОВ СБИС**

---

*Курейчик В.В., Данильченко В.И., Данильченко Е.В. Адаптивная параметризация метаэвристического алгоритма при размещении компонентов СБИС.*

**Аннотация.** В работе рассматривается задача параметризации метаэвристического алгоритма размещения компонентов сверхбольших интегральных схем (СБИС) в условиях усложняющихся топологий и ограничений современных технологических норм. Актуальность исследования обусловлена ростом размерности проектируемых схем, увеличением плотности межсоединений и усложнением структуры пространства проектных решений, что ограничивает эффективность применяемых алгоритмов со статическими параметрами. Постановка задачи включает формирование комплекса проектных метрик, таких как длина соединений, плотность, площадь размещения, индекс пересечений и другие. Фиксированная параметризация метаэвристических алгоритмов не в полной мере учитывает динамику пространства поиска, что ограничивает качество принимаемых проектных решений. На основе анализа комплекса проектных метрик предложена динамическая модель, отражающая текущее состояние поискового процесса, включая уровень структурного разнообразия популяции и признаки стагнации. С учетом предложенной модели разработана структура адаптивного метаэвристического алгоритма с замкнутым контуром параметрического управления, где выполняется корректировка параметров для согласования интенсивности глобального и локального поиска. Научная новизна заключается в оригинальной конфигурации набора метрик (скорость улучшения целевой функции  $\delta t$ , разнообразие популяции  $Dt$ , локальная неоднородность ландшафта поиска  $Ht$ , индикатор стагнации  $St$ ) и способе их интеграции в контур параметрического управления. В отличие от ресурсоёмких нейросетевых архитектур, требующих значительных вычислительных затрат и обучающих выборок, предложенная аналитическая модель обеспечивает интерпретируемость процесса адаптации и высокую вычислительную эффективность. Для подтверждения эффективности подхода построена программная подсистема, реализующая процесс моделирования и вычислительного эксперимента. Результаты экспериментов на тестовых топологиях различной размерности и плотности связей показали, что по сравнению с алгоритмами с фиксированной многоэтапной настройкой применение разработанного алгоритма позволило повысить интегральный показатель качества размещения на 8-15 % для структур с низкой плотностью связей и на 12-25 % для структур с высокой плотностью связей, уменьшить дисперсию результатов при множественных итерациях в 1,3-2,2 раза, сократить число циклов стагнации и снизить чувствительность к начальному состоянию популяции. Полученные результаты подтверждают повышение качества и эффективности проектных решений, устойчивость разработанного алгоритма размещения и свидетельствуют о практической применимости предложенного подхода. Статья будет полезна специалистам, занимающимся автоматизацией проектирования и интеллектуальным анализом при разработке.

**Ключевые слова:** метаэвристические алгоритмы, адаптивная параметризация, динамическая модель, размещение компонентов СБИС, комбинаторная оптимизация, метрики поиска, топологический синтез, многомерное дискретное пространство, интеллектуальные системы проектирования.

---

**1. Введение.** Современное проектирование сверхбольших интегральных схем (СБИС) характеризуется непрерывным ростом функциональной сложности, плотности компоновки и числа межсоединений, а также ужесточением технологических, временных и энергетических ограничений. Это приводит к существенному повышению сложности проектных процедур, требуя перехода от детерминированных методов к интеллектуальным адаптивным алгоритмам, способным исследовать высокомерное и нелинейное пространство решений [1–3]. При этом компонентом функциональной модели СБИС является элемент или блоком элементов, описываемых уникальным именем и функциональным типом, а сама схема задаётся списком таких компонентов и списком соединений между ними [2, 4–6]. Задача размещения этих компонентов относится к классу NP-трудных комбинаторных задач, а пространство возможных конфигураций растёт экспоненциально с увеличением числа компонентов СБИС [2, 4]. Комбинаторная сложность задачи размещения компонентов СБИС обусловлена тем, что каждый из  $n$  компонентов схемы может быть размещен в любом из  $m$  доступных узлов координатной сетки на плоскости кристалла, где  $m \geq n$ . В предположении об отсутствии симметрии и ограничений, процесс размещения эквивалентен выбору  $n$  различных позиций из  $m$  доступных и последующему присвоению их  $n$  компонентам, поэтому общее число вариантов решения определяется числом размещений и вычисляется по следующей формуле  $A_m^n = \frac{m!}{(m-n)!}$ . В случае, когда число позиций строго равно числу компонентов ( $m = n$ ), это выражение сводится к числу перестановок  $A_m^n = n!$ . При  $n = 100$  значение  $n!$  превышает  $10^{158}$ . Это исключает использование алгоритмов полного перебора и снижает эффективность классических детерминированных алгоритмов. При многокритериальной постановке задачи традиционные алгоритмы характеризуются ограниченной устойчивостью и высокой чувствительностью к выбору управляющих параметров. Также использование фиксированной параметризации в метаэвристических алгоритмах приводит к преждевременной сходимости и снижению полноты исследования пространства поиска. В результате получаемые наборы решений содержат локальные перегрузки, топологические конфликты и увеличенную длину межсоединений, что снижает качество получаемых проектных решений. Также топологическая модель размещения осложняется необходимостью учета и соблюдения технологических норм, минимальных расстояний между компонентами, ограничений плотности маршрутов и требований к распределению задержек сигналов. Включение этих ограничений в целевую функцию

приводит к появлению большого числа локальных минимумов и разрывов в поверхности поиска, что затрудняет применение градиентных методов [1 – 3, 7]. Кроме того, структура связей между компонентами определяет неоднородность пространства решений, а именно области с высокой плотностью соединений требуют точной настройки параметров поиска, тогда как слабосвязанные сегменты допускают выбор из широкого диапазон значений. С учетом этих факторов, требуется применения методов, обладающих высокой степенью гибкости, способностью работать в условиях разреженных и нелинейных пространствах и адаптироваться к изменяющимся характеристикам задачи.

Одними из них являются метаэвристические методы, широко используемые в задачах размещения благодаря способности эффективно исследовать сложные дискретные пространства. Их производительность зависит от настройки параметров, включая вероятности применения операторов мутации, кроссингвера и других стохастических операторов, а также глубину локального поиска [1 – 4]. При этом недостатком статической параметризации является отсутствие обратной связи между текущим состоянием поискового процесса, например уровнем разнообразия популяции или признаками стагнации и значениями управляющих параметров. Это приводит к снижению эффективности работы алгоритма, что проявляется в его преждевременной сходимости или в замедлении процесса поиска. Кроме того, шум, технологические ограничения и конфликты размещения исключают использование универсального набора параметров, обеспечивающего стабильную эффективность. В связи с этим возникает необходимость в адаптивной настройке параметров поиска.

Настоящая статья продолжает цикл исследований авторов, посвящённых разработке метаэвристических алгоритмов размещения компонентов СБИС [4, 5]. Отметим, что отдельные метрики, используемые в предлагаемой динамической модели, применяются и в иных современных подходах к параметрической оптимизации, в частности, в методах глубокого обучения с подкреплением [6]. Принципиальное отличие и научная новизна настоящей работы заключаются не в самом факте использования перечисленных показателей, а в оригинальной конфигурации набора метрик, включающего скорость улучшения целевой функции ( $\delta t$ ), разнообразие популяции ( $Dt$ ), локальную неоднородность ландшафта поиска ( $Ht$ ) и индикатор стагнации ( $St$ ), и способе их интеграции в замкнутый контур параметрического управления метаэвристическим алгоритмом.

В отличие от ресурсоёмких нейросетевых архитектур, требующих значительных вычислительных затрат и обучающих выборок, предложенная аналитическая модель обеспечивает интерпретируемость процесса адаптации и высокую вычислительную эффективность, что подтверждается улучшением интегрального показателя качества размещения на 8-25% в ходе вычислительного эксперимента.

Идея адаптивной параметризации заключается в динамической настройке параметров метаэвристических методов в зависимости от текущего этапа оптимизации и локального пространства решений. Это позволяет изменять вероятности применения различных операторов поиска на основе использования задаваемых метрик, таких как скорость улучшения целевой функции, признаков стагнации и разнообразия популяции решений. Данные метрики позволяют поддерживать баланс между диверсификации и интенсификации поиска и снижают риск попадания решений в локальные оптимумы.

Проведённый анализ показывает, что задача размещения компонентов СБИС отличается высокой комбинаторной сложностью и неоднородностью пространства поиска. В условиях технологических ограничений метаэвристические методы с фиксированными параметрами работают неустойчиво. Оптимальные значения параметров невозможно спрогнозировать заранее, так как они зависят от текущей динамики процесса поиска. Для решения данной проблемы требуется применения адаптивного управления, направленного на согласование процессов глобального поиска и локального уточнения решений в пространстве состояний, что обеспечит повышение устойчивости алгоритма и качество получаемых проектных решений. Поэтому разработка динамической модели адаптивной параметризации является актуальной и научно значимой задачей.

**2. Анализ существующих решений.** Методы размещения компонентов СБИС подразделяются на аналитические, иерархические, кластерные и эвристические, они отличаются принципами формализации задачи, механизмами декомпозиции пространства поиска и стратегиями редукции вычислительной сложности [1 – 4]. При этом аналитические методы [1, 3, 4] основаны на представлении схемы межсоединений в виде математической модели, в которой минимизируется суммарная длина соединений. Несмотря на высокую точность локального поиска, такие методы чувствительны к начальному приближению и плохо масштабируются при увеличении числа компонентов СБИС. Иерархические методы реализуют поэтапную декомпозицию задачи, последовательно уплотняя конфигурацию размещения, однако данные методы приводят

к накоплению ошибок на промежуточных уровнях, тем самым снижая качество получаемого решения.

Классические алгоритмы оптимизации [1, 3, 4], такие как градиентный спуск, методы наискорейшего спуска, релаксационные и сетевые алгоритмы, демонстрируют эффективность в задачах с гладкой или частично выпуклой поверхностью целевой функции. Однако для задачи размещения, характеризующейся множеством локальных минимумов и дискретной природой переменных, эти методы применимы лишь на отдельных этапах локальной оптимизации. При этом комбинаторные методы, включая жадные алгоритмы и алгоритмы поиска в глубину и ширину, обеспечивают приемлемое качество решения на малых наборах данных, что не позволяет обрабатывать все пространство решений экспоненциального размера, возникающее при увеличении количества компонентов и их связей.

Для расширения поисковых возможностей применяются методы имитации отжига, ориентированные на преодоление локальных минимумов за счёт стохастического управления температурой [1, 3, 6]. Однако при высокой размерности задачи они требуют значительных вычислительных затрат и существенно зависят от выбора температурного режима и кривой охлаждения. Таким образом, классические методы оптимизации демонстрируют ограниченную применимость, что обуславливает переход к эвристическим и метаэвристическим методам, способным эффективно исследовать сложные многомерные пространства поиска.

Эвристические и метаэвристические методы широко применяются в задачах размещения СБИС благодаря способности эффективно исследовать дискретные и многомерные пространства с множеством локальных минимумов [1 – 3]. Наиболее широко используемыми из них являются генетические алгоритмы (ГА) [1, 3, 6], реализующие эвристический поиск за счёт выполнения операторов селекции, кроссинговера, мутации и др. Они позволяют получать наборы квазиоптимальных решений при высокой комбинаторной сложности задачи, однако качество результатов существенно зависит от настройки параметров алгоритма, вероятности применения различных операторов поиска и стратегии формирования популяции.

Другим важным направлением метаэвристических методов является алгоритмы роевого интеллекта, включая метод роя частиц (PSO) [1 – 3, 7, 8]. Данный метод ориентирован на коллективное поведение агентов, использующих индивидуальный опыт и глобальную информацию для поиска оптимальных конфигураций. Он способен быстро адаптироваться к изменению структуры пространства поиска,

но подвержен преждевременной сходимости при недостаточной диверсификации частиц. В рамках данного направления также рассматриваются муравьиные алгоритмы (ACO) [1 – 3, 6], основанные на моделировании поведения колоний муравьёв с использованием механизма феромонных следов. Эти алгоритмы эффективно решают задачи, математическая модель которых представляется в виде графа, включая его матричные и списковые эквиваленты. Их преимущество заключается в способности формировать устойчивые маршруты поиска, однако их эффективность зависит от корректности настройки ключевых параметров (таких как начальный уровень феромона, скорость его испарения, коэффициент влияния эвристической информации и др.) и выбора адекватных эвристических правил.

Помимо рассмотренных подходов, в задачах размещения компонентов СБИС применяются различные гибридные и модифицированные методы эволюционного моделирования, сочетающие эволюционные принципы с локальным поиском и применением стохастических операторов [1, 3, 5 – 10]. Однако эффективность этих методов требует настройкой многих параметров и соблюдения баланса между глобальным и локальным поиском. При этом задаваемые статистических параметров не позволяет учитывать динамику всего процесса поиска. Данные проблемы приводят к снижению качества получаемых решений, росту вариативности результатов и увеличению вероятности наступления преждевременной сходимости алгоритма.

В литературе [1, 3, 5 – 10] представлены различные подходы к адаптивной и самоадаптивной параметризации эвристических и метаэвристических алгоритмов, направленные на повышение устойчивости поиска и снижение риска преждевременной сходимости. Наиболее распространённые методы основаны на регулировании вероятностей реализации поисковых операторов в зависимости от показателей качества наборов текущей популяции решения. Например, в генетических алгоритмах применяются схемы адаптивного изменения вероятностей применения операторов мутации, кроссинговера и др., где их параметры увеличиваются при снижении разнообразия популяции и уменьшаются при наличии стабильного улучшения целевой функции [1, 3, 11]. Внедрение таких механизмов позволяет поддерживать баланс между глобальным и локальным поиском, однако их эффективность ограничена выбором правил обновления, которые не всегда отражают реальное пространство решений. Также в методах роевого интеллекта [1, 7] адаптация реализуется через динамическое изменение инерционного

веса и коэффициентов когнитивной и социальной составляющих, что позволяет контролировать степень «инерции» частиц и их способность к исследованию новых областей. При всей структурной прозрачности, данные методы чувствительны к выбору параметров и часто требуют предварительного их подбора для решения конкретного класса задач. Муравьиные алгоритмы используют адаптивные правила обновления параметров в феромонной матрице, в том числе нелинейное испарение, усиление феромонных следов для выявления перспективных маршрутов, что позволяет снизить стагнацию процесса поиска. Однако влияние учета параметров феромона является сложным для прогнозирования, а их усиление приводит к диверсификации процесса поиска. Наряду с этим применяются самоадаптивные подходы [1, 9, 10], в которых параметры эволюционируют совместно с полученными решениями, что снижает необходимость ручной настройки и повышает гибкость процесса поиска. Вместе с тем такие методы требуют значительного числа итераций и приводят к росту вычислительных затрат. В целом адаптивная параметризация обладает потенциалом для повышения качества получаемых проектных решений, однако в рассматриваемой задаче её применение ограничено отсутствием универсальных метрик, адекватно описывающих состояние процесса поиска в многокритериальном и высокоразмерном пространстве. Поэтому для оценки применимости различных методов поиска к задаче размещения компонентов СБИС необходимо учитывать их вычислительную сложность, масштабируемость и устойчивость при работе в многомерных дискретных пространствах. В таблице 1 представлены асимптотические оценки сложности наиболее распространённых методов [1, 3 – 11], используемых при решении задач размещения, а также краткие характеристики их особенностей.

Таким образом известные подходы недостаточно эффективны в условиях высокой размерности, а эвристические и метаэвристические методы существенно зависят от настройки параметров и используемых метрик. Существующие механизмы адаптивной и самоадаптивной параметризации не в полной мере позволяют обеспечить устойчивую работу при изменении структуры целевой функции, плотности связей и технологических требований, поскольку опираются на ограниченный набор метрик и требуют эмпирической подстройки всех учитываемых параметров. В связи с этим необходима разработка динамической модели управления набором параметров, обеспечивающих адаптацию к текущему состоянию процесса и структуры пространства поиска.

Таблица 1. Вычислительная сложность алгоритмов

Алгоритм	Вычислительная сложность	Примечание
Градиентные методы	$O(n^2)$ - $O(n^3)$	Эффективны для сглаженных задач, чувствительны к локальным минимумам
Метод имитации отжига (SA)	$O(k \cdot n)$	Требует подбора температурного режима; высокая трудоёмкость при больших $n$
Иерархические методы размещения	$O(n \cdot \log n)$	Эффективны для грубого размещения, снижают точность при детализации
Генетический алгоритм (GA)	$O(n \cdot m)$	Качество зависит от параметров; склонен к преждевременной сходимости
Метод роя частиц (PSO)	$O(n \cdot m)$	Быстрое сближение, высокая вероятность попадания в локальные минимумы
Муравьиный алгоритм (ACO)	$O(n \cdot m)$	Эффективен для графовых моделей; чувствителен к параметрам феромона
Гибридные эволюционные алгоритмы	$O(n \cdot m + n \cdot \log n)$	Объединяют глобальный и локальный поиск; улучшают стабильность результатов
Кластерные методы размещения	$O(n^2)$	Эффективны при высокой связности; хуже работают при неоднородных структурах
Аналитические методы	$O(n^3)$	Точны, но плохо масштабируются при увеличении числа компонентов

**3. Постановка задачи.** Задача размещения компонентов СБИС заключается в определении оптимального размещения компонентов на плоскости кристалла с учётом топологических, метрических и технологических ограничений [2, 4, 11]. Она представляет собой NP-трудную комбинаторную задачу многокритериальной оптимизации, направленную на определение оптимального расположения компонентов на плоскости или в решётке с учётом метрических критериев (длина проводников, число изгибов), топологических параметров (взаимное расположение элементов, число пересечений, количество слоёв), а также критериев надёжности,

включающих тепловую и электромагнитную совместимость, временные задержки сигналов и плотность упаковки, при этом основным критерием является учет эффективности будущей трассировки [12]. В настоящее время наибольшее распространение в алгоритмах размещения получил критерий суммарной длины соединений, который позволяет косвенно учитывать другие критерии, способствуя уменьшению длин соединений, улучшению электрических характеристик и повышению надёжности СБИС [11]. Решение задачи размещения требует предварительной формализации, основанной на представлении схемы в виде взвешенного графа  $G = (V, E)$ , где каждое ребро  $(i, j) \in E$  описывает электрическое соединение между компонентами  $v_i$  и  $v_j$ . В соответствии с введённой взвешенной графовой моделью структуры СБИС множество компонентов определяется следующим выражением:

$$V = \{v_1, v_2, \dots, v_n\}, \quad (1)$$

где каждому компоненту  $v_i$  необходимо присвоить позицию на плоскости кристалла. Размещение выполняется в узлах координатной решётки, заданной на прямоугольной конструкции декартовой системой координат  $(s, t)$ . Цель задачи состоит в отображении заданного графа  $G$  в решётку  $G_r$  таким образом, чтобы все вершины из  $V$  заняли конечное множество узлов решётки, а также соблюдался выбранный критерий оптимизации. Таким образом, каждому компоненту  $v_i$  необходимо сопоставить координаты  $(s_i, t_i)$  на плоскости кристалла, что определяет окончательное расположение элементов в узлах координатной сетки.

Для формализации взаимодействий между компонентами вводится следующая матрица весов:

$$W = \{w_{ij}\}, \quad (2)$$

где  $w_{ij}$  – это критические соединения, которые напрямую зависят от длины межсоединений. Также на основе матрицы весов определяется метрика оценки качества проектных решений – суммарная длина межсоединений [11], которая рассчитывается по следующей формуле:

$$L = \sum_{(i,j) \in E} w_{ij} \cdot d(v_i, v_j), \quad (3)$$

где  $d(v_i, v_j)$  – расстояние между позициями компонентов  $v_i$  и  $v_j$ , как правило, рассчитываемое по манхэттенской метрике с учётом ограничений топологии проводников [1, 11 – 13].

Также дополнительно учитываются технологические и топологические ограничения, включая плотность размещения в локальных областях и ограничение на число линейных сегментов проводников [11 – 13], которые формализуются в виде штрафных функций и включаются в общую целевую функцию. В результате формируется многокритериальная модель размещения, объединяющая метрические показатели качества и технологические нормы, определяющие корректность конфигурации. Сложность трассировки  $LS(P)$ , оцениваемая числом линейных сегментов, учитывается в целевой функции с учётом критичности соединений и вычисляется по следующей формуле:

$$LS(P) = \sum_{(i,j) \in E} w_{ij} \cdot LS_{ij}. \quad (4)$$

В том числе к технологическим ограничениям относят минимальные расстояния между компонентами, плотность размещения в локальных областях и допустимость конфигураций с точки зрения технологических норм [11, 12]. Нарушения этих требований выражаются в виде штрафных функций, рассчитываемых на основе следующего выражения:

$$LT(P) = \sum_{i < j} w_{ij} \cdot \max(0, d_{\min} - d(v_i, v_j)), \quad (5)$$

это позволит учесть конфликты размещения и исключать недопустимые конфигурации.

Таким образом, учитывая все описанные метрики [11, 12], целевая функция рассчитывается по следующей формуле:

$$F(P) = \lambda_1 \cdot L(P) + \lambda_2 \cdot LS(P) + \lambda_3 \cdot T(P), \quad (6)$$

где  $L(P)$  – суммарная длина межсоединений,  $T(P)$  – штраф за нарушение технологических ограничений, а на основе коэффициентов  $\lambda_k$  определяются относительные веса каждого критерия, что позволяет обеспечивать баланс между длиной

межсоединений, сложностью трассировки и соблюдением технологических ограничений при оценке проектных решений.

Для систематизации взаимодействий между компонентами, связями и критериями качества вводится концептуальная модель, представленная на рисунке 1. Модель построена для двумерного случая размещения компонентов на плоскости кристалла, что соответствует базовой постановке задачи [1, 8]. При этом заложенные в модель метрики поиска и принципы адаптивного управления параметрами не зависят от размерности пространства. Данное свойство позволяет рассматривать предложенную концептуальную модель как основу для последующего развития методов трёхмерного размещения компонентов, где потребуется модификация системы координат и учёт дополнительных критериев, таких как объёмная плотность и тепловые характеристики, без изменения ядра адаптивной параметризации.

Модель содержит требования к размещению компонентов и особенностям задачи, требующая применения таких алгоритмов, которые позволяют учитывать изменения процесса поиска. Данная модель является основой при разработке адаптивного механизма параметризации.

Представленная концептуальная модель позволяет рассматривать пространство поиска в данной задаче как разреженное и нелинейное, что определяет высокую сложность поиска решений и особенности поведения эвристических и метаэвристических алгоритмов. Каждая конфигурация размещения задаётся дискретными координатами компонентов на плоскости кристалла, вследствие чего общее число возможных состояний носит факториальный характер. При этом множество допустимых решений ограничено, так как значительная часть конфигураций нарушает технологические ограничения, такие как минимальные расстояния, плотность размещения и топологические нормы. Таким образом только четверть пространства поиска может содержать валидные или близкие к валидным решения.

В условиях разреженного пространства поиска целевая функция характеризуется высокой нелинейностью, которая обусловлена сочетанием влияния заданных метрик оценки качества проектных решений. Перемещение отдельного компонента неоднородно влияет на структуру межсоединений, вызывая разрывы в функции и локальные неровности ее поверхности. Даже незначительные локальные перестановки приводят к резким изменениям значений целевой функции, что затрудняет применение методов локального поиска.

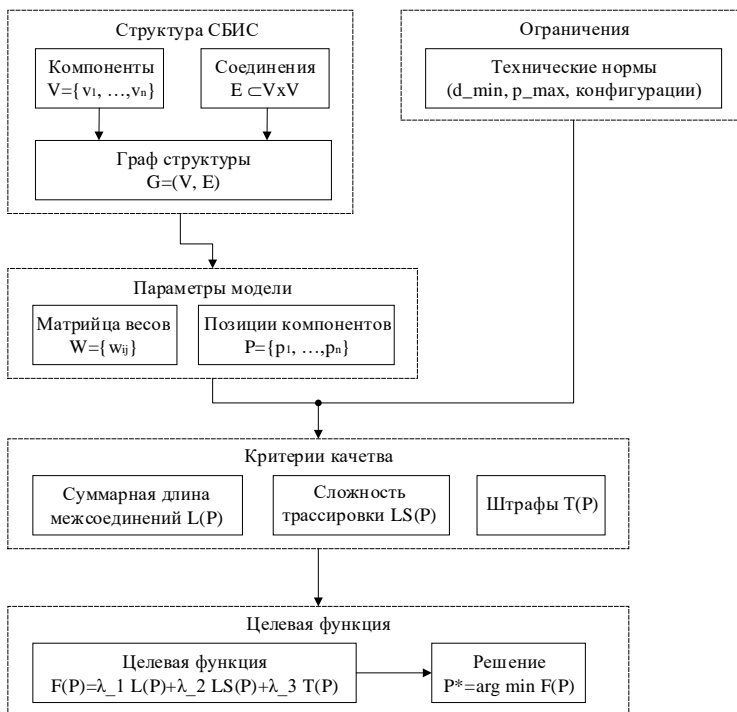


Рис. 1. Концептуальная модель критериев и ограничений задачи размещения компонентов СБИС

Кроме локальных неровностей и резких изменений значений целевой функции, так же учитывается сложность, создаваемая локальными минимумами. Это обусловлено плотной связностью схем, неоднородным распределением критически значимых соединений и конфликтами между заданными метриками. Наличие локальных минимумов с протяжёнными областями притяжения повышает вероятность преждевременной сходимости метаэвристик при фиксированных параметрах. В сочетании с разреженностью допустимого множества решений это усиливает чувствительность к начальным условиям и снижает устойчивость процесса поиска.

Таким образом, из формализованного представления задачи размещения компонентов СБИС следует, что пространство поиска характеризуется разрывной, многомодальной и существенно разреженной структурой, а многокритериальный характер целевой функции ограничивает применимость известных методов. Выявленные

свойства пространства решений и требования к устойчивости алгоритмов свидетельствуют о необходимости разработки адаптивного механизма параметризации, ориентированного на учёт текущего состояния процесса поиска.

#### 4. Динамическая модель адаптивной параметризации.

Эффективность эвристических и метаэвристических алгоритмов в задаче размещения СБИС зависит от их адаптивности к процессу поиска. При этом статическая параметризация не в полной мере отражает текущее состояние популяции решений и не обеспечивает согласование между глобальным и локальным поиском в условиях разрывной и многомодальной целевой функции. В этой связи целесообразно применение динамической модели адаптивной параметризации, ориентированной на устойчивое управление процессом поиском за счёт корректировки ключевых параметров на основе метрик состояния популяции, признаков стагнации и локальных характеристик пространства решений.

В предлагаемой динамической модели корректировка осуществляется на основе количественных метрик, отражающих текущее состояние популяции решений и динамику целевой функции в процессе оптимизации. Для формального описания этих процессов введём следующие величины, где  $P_t$  – множество решений на итерации  $t$ ,  $\Delta F$  – целевая функция. В частности, одной из ключевых метрик [11, 12, 14] является скорость улучшения целевой функции, которая характеризует степень приближение алгоритма к лучшим решениям  $F_{\text{best}}$  за фиксированный интервал  $\Delta t$ . При этом её количественная оценка вычисляется на основе следующего выражения:

$$\Delta F_t = \frac{F_{\text{best}} \cdot (t - \Delta t) - F_{\text{best}}(t)}{\Delta t}. \quad (7)$$

Тогда для оценки скорости улучшения целевой функции введём показатель относительного прогресса поиска [11, 15]. Этот показатель позволяет нормировать изменение целевой функции и оценивать эффективность приближения алгоритма к локальному оптимуму независимо от абсолютных параметров метрики. Для этого используется относительное улучшение  $\delta_t$ , которое рассчитывается на основе следующего выражения:

$$\delta_t = \frac{F_{\text{best}} \cdot (t - \Delta t) - F_{\text{best}}(t)}{F_{\text{best}} \cdot (t - \Delta t) + \varepsilon}, \quad (8)$$

где  $\varepsilon > 0$  – положительная константа, обеспечивающая численную стабильность вычислений, которая выбирается лицом, принимающим решение (ЛПР) из интервала  $[0; 1]$ . Здесь интенсивность параметров поиска увеличивается при минимальных значениях  $\delta_t$ , что приводит к стагнации и уменьшается при высоких значениях, соответствующих прогрессу в улучшении значений целевой функции.

При расчёте введённых метрик необходимо учитывать показатель разнообразия популяции решений, ее диверсификацию. В качестве оценки количественной меры диверсификации рассчитывается дисперсия расстояний  $D_t$  между решениями в популяции [11, 14, 16]. Для формального описания предложенной метрики введём следующие обозначения. Позиция компонента в решении  $i$  на итерации  $t$  обозначается как  $p_i^{(t)}$ , тогда дисперсия рассчитывается по следующей формуле:

$$D_t = \frac{1}{|P_t|} \sum_{x \in P_t} \frac{1}{n} \sum_{i=1}^n d(p_i^{(x)}, \bar{p}_i), \quad (9)$$

где  $\bar{p}_i$  – среднее положение компонента  $i$  в популяции.

Наряду с геометрической мерой разнообразия также учитывается их функциональная форма  $\sigma_t^2$  [12, 14, 16], основанная на распределении значений целевой функции в популяции, которая выражается через функцию дисперсии:

$$\sigma_t^2 = \frac{1}{|P_t|} \sum_{x \in P_t} (F(x) - \bar{F}_t)^2. \quad (10)$$

Снижение значений  $D_t$  или  $\sigma_t^2$  указывает на снижение структурного разнообразия популяции и её концентрации в ограниченной области пространства поиска, это связано с повышенной вероятностью преждевременной сходимости алгоритма.

Для отслеживания момента прекращается положительная динамика улучшения качества решений вводится бинарный индикатор  $S_t$ , рассчитываемый по следующей формуле:

$$S_t = \begin{cases} 1, & \text{если } \delta_t < \tau_1 \text{ и } D_t < \tau_2, \\ 0, & \text{иначе.} \end{cases} \quad (11)$$

где  $\tau_1, \tau_2$  – пороговые значения, которые задаются в процессе поиска ЛПП. Значение  $S_t = 1$  свидетельствует о состоянии стагнации, которое возникает при отсутствии улучшения значения целевой функции (низкая относительная скорость улучшения  $\delta_t$ ) и недостаточном структурном разнообразии популяции (низкое значение метрики  $D_t$ ). В противном случае, при  $S_t = 0$ , процесс считается активным, это означает, что либо сохраняется устойчивая положительная динамика улучшения значений целевой функции, либо популяция обладает достаточным разнообразием для продолжения процесса поиска проектных решений.

Для оценки сложности поиска при локальном окружении решений применяется градиентная вариация текущего значения целевой функции [9, 13], которая рассчитывается по следующей формуле:

$$H_t(x) = \frac{1}{k} \sum_{y \in N_k(x)} |F(y) - F(x)|, \quad (12)$$

где  $N_k(x)$  – множество  $k$  ближайших решений  $x$ , измеряемых по Манхэттенскому расстоянию [1, 8, 11]. Этот показатель отражает локальные изменения целевой функции и используется для количественной оценки «неровности» или сложности локального окружения каждого решения. При этом высокие значения локальной характеристики  $H_t(x)$  указывают на дискретность и неоднородность области целевой функции в окрестности точки  $x$ . Для интегральной оценки используется сводный индикатор  $M_t$  состояния популяции, который рассчитывается по следующей формуле:

$$M_t = \alpha_1 \cdot \delta_t + \alpha_2 \cdot D_t + \alpha_3 \cdot H_t - \alpha_4 \cdot S_t, \quad (13)$$

где  $H_t$  – значение локальной неоднородности пространства поиска, а  $\alpha_i$  – весовые коэффициенты, определяющие интегральную оценку каждой метрики. Для определения весовых коэффициентов  $\alpha_1, \alpha_2, \alpha_3, \alpha_4$  в интегральном индикаторе  $M_t$  использовалась процедура предварительной калибровки на основе вычислительного эксперимента. С этой целью сформирован набор тестовых топологий, не участвовавших в дальнейших сравнительных испытаниях (валидационный набор), включающий 10 схем различной размерности и связности. Для каждой комбинации весов из дискретного множества значений  $\alpha_i \in \{0.1, 0.2, \dots, 0.9\}$  с шагом 0.1, удовлетворяющих следующему условию  $\sum_{i=1}^4 \alpha_i = 1$ , выполнялось по 20 независимых

итераций алгоритма поиска. Выбранная таким образом комбинация ( $\alpha_1 = 0,3, \alpha_2 = 0,3, \alpha_3 = 0,2, \alpha_4 = 0,2$ ) позволила достичь требуемого баланса между скоростью сходимости и устойчивостью поиска при тестировании на валидационных схемах.

На основе сводного индикатора состояний популяций решений сформируем математическую модель для адаптивного изменения параметров алгоритма. Обозначим через  $\Theta(t)$  множество изменяемых параметров метаэвристического алгоритма на итерации  $t$ . В зависимости от используемого метода в состав  $\Theta(t)$  входит вероятность мутации  $\mu(t)$ , коэффициенты кроссинговера  $\chi(t)$ , параметры локального поиска, интенсивности стохастических операторов, а также коэффициенты применяемых роевых алгоритмов. Тогда задача динамической модели состоит в определении функциональной зависимости, которая рассчитывается по следующей формуле:

$$\Theta(t + 1) = \Phi(\Theta(t), M_t), \quad (14)$$

где  $\Phi$  – оператор адаптации, преобразующий текущие параметры в их новые значения.

В данной модели выполнение оператора мутации реализует механизм глобального исследования пространства решений. Поэтому при снижении разнообразия решений в популяции и стагнации целевой функции интенсивность выполнения оператора мутации возрастает [12, 14, 16], что рассчитывается на основе следующего выражения:

$$\mu(t + 1) = \mu(t) + \eta_\mu \cdot (1 - D_t) \cdot (1 - \delta_t), \quad (15)$$

где  $\eta_\mu$  – коэффициент регулирования, определяющий величину корректировки параметра в зависимости от состояния популяции, а  $\mu(t)$  – значение вероятности мутации на текущей итерации  $t$ .

Для обеспечения допустимого диапазона значений интенсивности выполнения оператора мутации рассчитывается на основе следующего выражения [1, 3, 11]:

$$\mu(t + 1) = \min(\mu_{\max}, \max(\mu_{\min}, \mu(t + 1))). \quad (16)$$

Таким же образом учитывается выполнения оператора кроссинговера. При устойчивом улучшении получаемых решений интенсивность оператора кроссинговера применения увеличивается, а при уменьшении динамики улучшений его корректировка

ослабляется. Этот процесс рассчитывается на основе следующего выражения [1, 11]:

$$\chi(t+1) = \chi(t) + \eta_{\chi} \cdot (\delta_t - \tau_{\delta}), \quad (17)$$

где  $\tau_{\delta}$  – порог, определяющий режим «стабильного улучшения», а  $\eta_{\chi}$  – коэффициент скорости адаптации выполнения оператора кроссинговера. Заметим, что в этом выражении дополнительно учитывается локальная структура пространства решений. При превышении допустимого уровня локальной неоднородности концентрируется направленный локальный поиск, интенсивность которого корректируется на основе следующего выражения [8, 11]:

$$\rho(t+1) = \rho(t) + \eta_{\rho} \cdot H_t, \quad (18)$$

где  $\rho(t)$  – интенсивность локального поиска на итерации  $t$ ,  $H_t$  – локальная вариация ландшафта поиска, а  $\eta_{\rho}$  – коэффициент скорости адаптации для оператора локального поиска. Отметим, что каждый коэффициент адаптации  $\eta$  ( $\eta_{\mu}$ ,  $\eta_{\chi}$ ,  $\eta_{\rho}$ ) является индивидуальным параметром скорости поиска, определяющим величину коррекции соответствующего оператора (мутации  $\mu$ , кроссинговера  $\chi$ , локального поиска  $\rho$ ) в зависимости от текущих значений метрик состояния популяции  $D_t$ ,  $\delta_t$  и  $H_t$  соответственно.

В дополнение к базовым правилам адаптации при фиксации стагнации процесса поиска применяется компенсирующий механизм корректировки параметров. При ( $S_t = 1$ ) обновление параметров выполняется по следующей формуле [11]:

$$\Theta(t+1) = \Theta(t) + \Delta\Theta_{\text{stag}}, \quad (19)$$

где  $\Delta\Theta_{\text{stag}} = (\delta_{\mu}, -\delta_{\chi}, \delta_{\rho})$  – вектор направленных приращений. Его переменные, задаваемые в следующих диапазонах  $\Delta_{\mu} \in (0, \Delta_{\mu}^{\max}]$ ,  $\Delta_{\rho} \in (0, \Delta_{\rho}^{\max}]$  и  $\Delta_{\chi} \in (0, \Delta_{\chi}^{\max}]$ , позволяют выявлять увеличение интенсивности операторов поиска. Такая процедура корректировки реализует антистагнационный механизм, направленный на восстановление поисковой активности и предотвращение преждевременной сходимости алгоритма.

Рассмотренные процедуры и механизмы адаптации представляются в виде единой формализованной модели. При этом для

каждого параметра  $\theta_i(t) \in \Theta(t)$  обновление рассчитывается на основе следующего выражения:

$$\theta_i(t + 1) = \theta_i(t) + \eta_i \cdot g_i(M_t), \quad (20)$$

где  $\eta_i$  – коэффициент адаптации, а  $g_i(M_t)$  функция отклика, определяющаяся типом используемого параметра. Вероятность применения операторов мутации  $\rho_{\text{ом}}$  и кроссинговера  $\rho_{\text{ок}}$ . Она пропорциональна произведению следующих метрик  $\rho_{\text{ом}} = g_{\mu}(M_t) \propto (1 - D_t) \cdot (1 - \delta_t)$ ,  $\rho_{\text{ок}} = g_{\chi}(M_t) \propto (\delta_t - \tau_{\delta})$ , а интенсивность применения локального поиска  $\rho_{\text{лп}}$  рассчитывается на основе произведением  $g_{\rho}(M_t) \propto H_t$ .

Для обеспечения устойчивости процесса адаптации и исключения колебательных режимов при динамическом обновлении параметров применяется процедура сглаживания [9, 11, 16]. Их обновление выполняется с учётом предыдущих значений на основе следующего выражения:

$$\theta_i(t + 1) = \alpha \cdot \theta_i(t + 1) + (1 - \alpha) \cdot \theta_i(t), \quad (21)$$

где  $0 < \alpha < 1$  – коэффициент сглаживания. Данный механизм позволяет ограничивать влияние кратковременных флуктуаций метрик состояния и способствует стабильному процессу поиска.

Для практической реализации предложенной процедуры адаптации требуется формализовать условия переключения режимов и ограничений динамического обновления параметров. С этой целью вводится система пороговых значений, обеспечивающая корректную интерпретацию метрик состояния и стабилизацию реакции процесса поиска на изменения. Пусть  $\delta_t$ ,  $D_t$ ,  $H_t$  и  $S_t$  – вычисляемые метрики процесса поиска. Тогда система порогов выражается следующим образом:

$$\Theta_{\text{thr}} = \{\tau_{\delta}, \tau_D, \tau_H\}, \quad (22)$$

где каждый порог определяет переход между режимами поиска.

На основе введённой системы пороговых значений формируются критерии перехода между режимами работы алгоритма. Порог улучшения  $\tau_{\delta}$  выделяет фазы прогресса и стагнации: при  $\delta_t < \tau_{\delta}$  – режим стагнации, при  $\delta_t \geq \tau_{\delta}$  – режим локального улучшения. Порог разнообразия  $\tau_D$  фиксирует уменьшения области поиска: при  $D_t < \tau_D$  реализуется глобальный поиск. Порог

неоднородности  $\tau_H$  отражает сложность ландшафта: при  $H_t > \tau_H$  реализуется локальный поиск. Совокупность этих порогов реализует логические условия для адаптивного перехода между различными режимами работы алгоритма в процессе поиска. Однако, в условиях разрывной структуры целевой функции и скачкообразного изменения метрик, прямое применение данных процедур и механизмов приведет к нестабильному поведению алгоритма. Поэтому для устранения этой проблемы и обеспечения устойчивости процедуры адаптации вводятся стабилизирующие механизмы, предотвращающие резкие колебания, учитываемых параметров.

Рассмотрим данные механизмы более подробно [12 – 15].

1. Механизм сглаживания параметров применяется для предотвращения осцилляций. Здесь параметр  $\theta_i(t)$  обновляется с использованием экспоненциального фильтра, что рассчитывается по следующей формуле:

$$\theta_i(t + 1) = \alpha \cdot \theta_i(t + 1) + (1 - \alpha) \cdot \theta_i(t), \quad (23)$$

где  $0 < \alpha < 1$  – коэффициент сглаживания.

2. Механизм нормирования представляет собой процедуру приведения обновлённых значений параметров к допустимому диапазону за счет заданных граничных условий, что рассчитывается по следующей формуле:

$$\theta_i(t + 1) = \min(\theta_i^{\max}, \max(\theta_i^{\min}, \theta_i(t + 1))), \quad (24)$$

где  $\theta_i^{\min}$  и  $\theta_i^{\max}$  – соответственно нижняя и верхняя границы для параметра  $\theta_i$ . Это исключает выход значений за область, определённую физической постановкой задачи или алгоритмическими ограничениями.

3. Компенсирующий механизм используется для преодоления локальных оптимумов. Если индикатор стагнации принимает значение  $S_t = 1$ , что соответствует состоянию стагнации поиска, то выполняется дополнительная корректировка параметров по следующей формуле:

$$\theta_i(t + 1) \leftarrow \theta_i(t + 1) + \Delta\theta_i^{\text{stag}}, \quad (25)$$

где амплитуда  $\Delta\theta_i^{\text{stag}}$  определяется уровнем стагнации.

Взаимосвязь между пороговыми критериями и стабилизирующей процедурой поиска представлена в виде следующей схемы (Рис. 2).



Рис. 2. Схема работы пороговых критериев и стабилизирующих процедур

На основе проведённых исследований установлено, что применение приведенных метрик, пороговых критериев и стабилизирующих механизмов позволяет построить устойчивый алгоритм управления поисковым процессом. Интеграция данной адаптивной модели в структуру эвристического или метаэвристического алгоритма позволяет реализовать двухконтурную организацию поискового процесса, в которой параметры операторов динамически корректируются в соответствии с текущим состоянием популяции решений и локальными особенностями пространства поиска. Такая организация поиска позволяет обеспечивать высокую чувствительность алгоритма к изменяемой динамике процесса, устойчивой сходимости, а также повысить способность алгоритмов к преодолению локальных оптимумов. Таким образом, системная адаптивная параметризация способствует преодолению ключевых ограничений методов со статическими параметрами, при этом обеспечивая повышение качества решений в условиях высокой разрывности и многомодальности пространства конфигураций.

**5. Интеграция адаптивной модели параметризации в метаэвристический алгоритм.** Адаптивная модель реализуется за счет механизма корректировки параметров, который анализирует состояние популяции и изменяет характеристики операторов поиска на каждой итерации. В результате алгоритм работает в двухконтурном

режиме, в котором классические операторы поддержки процесса поиска решений функционируют совместно с адаптивным механизмом регулирования параметров, обеспечивающей согласование поисковой стратегии с локальными особенностями пространства конфигураций.

На рисунке 3 представлена схема интеграции адаптивной модели параметризации в структуру метаэвристического алгоритма.

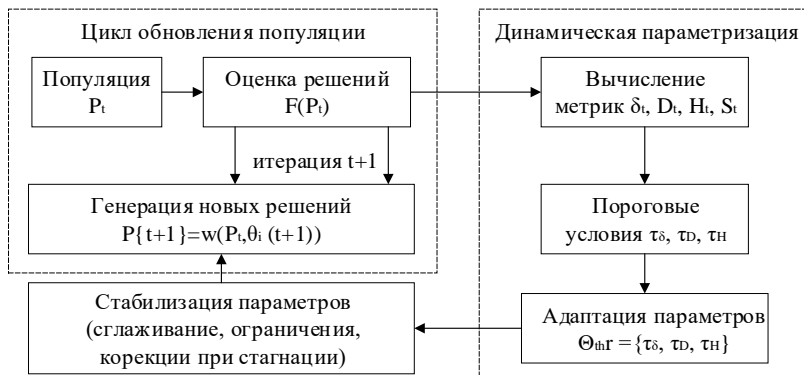


Рис. 3. Схема интеграция адаптивной модели параметризации в метаэвристический алгоритм

В данной схеме отражается взаимодействие основных модулей системы: базового цикла метаэвристического поиска, блока вычисления метрик и механизма адаптивного обновления параметров. Что позволяет идентифицировать двухконтурную организацию поискового процесса, где операторы поиска работают в рамках внешнего адаптивного контура, который управляет их параметрами на основе обратной связи. Структурно алгоритм включает четыре ключевых модуля: генератор новых решений, блок оценки, адаптивный модуль корректировки параметров и стабилизирующий механизм, которые взаимодействуют последовательно через встроенный контур обратной связи. В такой структуре параметры  $\Theta(t)$  перестают быть фиксированными величинами и определяются динамически изменяющимися метриками поискового процесса.

Для формализации представленной адаптивной модели введём следующие обозначения: пусть  $P_t$  – популяция на итерации  $t$ , а  $\Theta(t)$  – множество параметров алгоритма. Тогда интеграция адаптивной модели в процесс поиска выражается следующей системой уравнений [8 – 11]:

$$P_{t+1} = \Psi(P_t, \Theta(t)), \Theta(t+1) = \Omega(\Theta(t), M_t), \quad (26)$$

где  $\Psi$  – оператор генерации новых решений,  $\Omega$  – адаптивный механизм корректировки параметров,  $M_t$  – интегральный показатель состояния популяции.

Далее рассмотрим более подробно работу адаптивного механизма обновление параметров  $\Omega$  на каждой итерации. Данный механизм включает следующие этапы.

1. Оценка состояния популяции. На основе текущей популяции  $P_t$  вычисляются базовые метрики, характеризующие динамику поиска: скорость улучшения  $\delta_t$ , разнообразие  $D_t$ , неоднородность ландшафта  $H_t$ , дисперсию целевой функции  $\sigma_t^2$  и индикатор стагнации  $S_t$ .

2. Пороговая интерпретация состояния. Полученные метрики сопоставляются с заданными пороговыми значениями  $\tau_\delta, \tau_D, \tau_H$ . На основе этого сопоставления определяется текущий режим работы алгоритма (прогресс, стагнация, локальная сложность, сжатие популяции), который задаёт стратегию адаптации.

3. Обновление параметров. В соответствии с установленным режимом выполняется корректировка множества параметров  $\Theta(t)$ , которая рассчитывается по следующей формуле:

$$\Theta(t + 1) = \Theta(t) + \eta \cdot g(M_t), \quad (27)$$

где  $\eta$  – коэффициент скорости адаптации, а  $g(M_t)$  – функция отклика, определяющая направление и величину изменения параметров на основе интегрального показателя состояния  $M_t$ , агрегирующего оценки предыдущих этапов.

4. Нормирование параметров. Чтобы исключить выход значений за допустимые пределы, полученные параметры ограничиваются заданными границами, что выражается следующей формулой:

$$\Theta(t + 1) = \min(\Theta_{\max}, \max(\Theta_{\min}, \Theta(t + 1))). \quad (28)$$

где  $\Theta_{\min}$  и  $\Theta_{\max}$  – векторы минимально и максимально допустимых значений для каждого параметра.

5. Стабилизация параметров. Для обеспечения плавности изменений и подавления шума применяется экспоненциальное сглаживание, которое рассчитывается по следующей формуле:

$$\Theta(t + 1) = \alpha \cdot \Theta(t + 1) + (1 - \alpha) \cdot \Theta(t), \quad (29)$$

где  $\alpha \in (0,1]$  – коэффициент сглаживания, подбирается ЛПР на основе эмпирических данных. Данная процедура позволяет предотвратить резкие колебания параметров и обеспечить устойчивость динамической настройки алгоритма.

6. Генерация новой популяции. На основе скорректированных и стабилизированных параметров  $\Theta(t+1)$  выполняются базовые операторы поиска, которые позволяют сформировать следующее поколение решений, рассчитываемое по следующей формуле:

$$P_{t+1} = \Psi(P_t, \Theta(t+1)). \quad (30)$$

Таким образом, интеграция адаптивной модели позволяет создать саморегулируемую систему с обратной связью в метаэвристическом алгоритме, где ключевые параметры динамически корректируются под структуру пространства поиска и текущие характеристики динамически изменяемого процесса. Это позволяет обеспечивать повышение устойчивости работы алгоритма, снижать вероятность преждевременной сходимости и способствовать улучшению качества получаемых проектных решений.

**6. Вычислительный эксперимент.** Для подтверждения эффективности предложенного подхода и проведения вычислительного эксперимента разработана программная подсистема, включающая адаптивную модель параметризации, обеспечивающая цикл формирования и анализа конфигураций при размещении компонентов СБИС. Цель вычислительного эксперимента заключается в анализе влияния адаптивного механизма на качество формируемых решений, устойчивость алгоритма и характер сходимости в условиях многокритериальной и многомодальной структуры пространства поиска. Эксперимент выполнен на тестовых топологиях различной размерности и плотности связей (таблица 2). Используемые в таблице значения 100, 300, 600 компонентов соответствуют типовым размерам тестовых примеров из известных бенчмарков (MCNC, IWLS, ISPD) [17, 18], которые широко применяются для верификации алгоритмов размещения. Такой диапазон позволяет оценить масштабируемость предложенного подхода и выявить закономерности его работы при переходе от разреженных к плотным структурам без потери общности получаемых выводов. При этом оцениваются показатели качества размещения, вариативность результатов при множественных итерациях, динамика изменения параметров  $\Theta(t)$  и заданных метрик, а также особенности сходимости

адаптивного алгоритма по сравнению с известными аналогами. Для количественной характеристики тестовых топологий введён коэффициент сложности топологии  $C_t$ , рассчитываемый как отношение числа рёбер в графе схемы к числу рёбер в полном графе с тем же числом вершин:  $C_t = 2|E|/(n(n-1))$ , где  $n$  – число компонентов (вершин),  $|E|$  – число соединений (рёбер) в схеме. Данный коэффициент является безразмерной нормированной величиной, принимающей значения в интервале  $[0, 1]$ , и отражает связность схемы, то есть чем ближе  $C_t$  к единице, тем сложнее топология и тем выше требования к адаптивным свойствам алгоритма. А также оцениваются показатели качества размещения, вариативность результатов при множественных итерациях, динамика изменения параметров  $\Theta(t)$ , заданных метрик и особенности сходимости адаптивного алгоритма по сравнению с известными аналогами.

Тестовые сценарии включали три класса топологий: разреженные схемы с низкой связностью и небольшой плотностью активных соединений; плотные схемы, характеризующиеся высокой степенью взаимодействия и критических путей; а также смешанные топологии, в которых плотные локальные области сочетаются с разрежёнными сегментами. Такой набор тестовых топологий позволяет оценить поведение разработанного метаэвристического алгоритма, включавшего модель адаптивной параметризации в условиях неоднородной структуры пространства поиска, определить чувствительность к топологическим особенностям, устойчивость решений и исследовать влияние связности на динамику сходимости.

Таблица 2. Параметры тестовых топологий и режимы параметризации

Тип топологии	Число компонентов $n$ , (шт.)	Плотность связей (среднее число связей на компонент), у.е.	Коэффициент сложности топологии (нормированный) в интервале $[0, 1]$	Режимы параметризации
Разреженная	100	3,2	0,28	Статические, фиксированная, адаптивная
Смешанная	300	6,8	0,51	Статические, фиксированная, адаптивная
Плотная	600	11,5	0,84	Статические, фиксированная, адаптивная

Вычислительный эксперимент проводился в унифицированной программной среде [19], включающей модуль генерации топологий, вычислительный модуль эвристических и метаэвристических

алгоритмов и подсистему различных метрик. Реализация выполнена на языке Python с использованием специализированных библиотек, включая NumPy и SciPy для численных вычислений, NetworkX для работы со схемами, а также DEAP для реализации эвристик и метаэвристик [20]. Вычисления выполнялись на компьютере с операционной системой Windows 11, процессором AMD Ryzen 5, 32 ГБ оперативной памяти и видеокартой NVIDIA RTX 3060, что исключает влияние аппаратных ограничений на результаты эксперимента.

Для обеспечения корректного сопоставления алгоритмов использовались единые настройки вычислительного процесса. Размер популяции составлял 40-80 альтернативных решений в зависимости от размерности задачи, число итераций фиксировано и равно 500. Как известно из литературы [1] увеличение числа итераций приводит к улучшению значения целевой функции до определенного предела. Выбор числа итераций (500) был определен на основе анализа сходимости, представленного на рисунке 4. На графике видно, что после 350-400 итераций интегральный показатель качества  $F(P)$  достигает асимптотического значения, а относительное улучшение  $\delta t$  (рассчитываемое по формуле (8)) становится меньше порогового значения  $\tau\delta=0,01$ , что интерпретируется как состояние практической сходимости. Дальнейшее увеличение числа итераций приводит к незначительному улучшению (менее 1% при удвоении до 1000 итераций) при значительном росте вычислительных затрат. Для адаптивного механизма параметризации заданы допустимые интервалы параметров  $\Theta_{min}$  и  $\Theta_{max}$ , включающие вероятность применения операторов мутации, кроссингвера и интенсивность локального поиска. Обновление параметров выполнялось с учетом коэффициентов скорости  $\eta$  и сглаживания  $\alpha$ . В эксперименте рассмотрены три режима работы алгоритма: со статическими параметрами, с фиксированной многоэтапной настройкой и с адаптивной параметризацией, при которой параметры  $\Theta(t)$  обновляются на основе заданных метрик, технологических ограничений и граничных условий.

Оценка эффективности алгоритмов проводилась по совокупности метрик, включающих суммарную длину межсоединений  $L(P)$ , сложность трассировки  $LS(P)$  и показатель технологических ограничений  $T(P)$ . Для анализа работы адаптивного механизма использовались динамически изменяемые метрики поискового процесса, характеризующие скорость улучшения, разнообразие популяции, структурные различия, дисперсию решений

и наличие фаз стагнации. Устойчивость алгоритмов оценивалась по вариативности результатов, дисперсии при множественных итерациях и диапазону значений интегрального показателя качества.

Результаты вычислительного эксперимента сведены в таблице 3. Анализ таблицы подтверждает влияние адаптивной параметризации на качество и устойчивость вычислительного процесса. Для всех классов тестовых топологий получены численные оценки интегрального показателя качества  $F(P)$ .

Анализ значений из таблицы 3 показывает, что адаптивный алгоритм формирует решения с меньшими значениями  $L(P)$  и  $F(P)$  по сравнению со статическими и фиксированными методами, что подтверждает эффективность механизма динамической параметризации. При этом временные затраты адаптивного алгоритма лишь незначительно превышают время работы методов со статической параметризацией (на 5-10% в зависимости от размерности), что объясняется расчётом диагностических метрик  $\delta t$ ,  $Dt$ ,  $Ht$ ,  $St$  и обновлением параметров на каждой итерации. Полученные значения времени (от 124 с для 100 компонентов до 441 с для 600 компонентов) позволяют сделать вывод о практической применимости предложенного подхода в рамках интерактивного проектирования СБИС умеренной сложности, а для более крупных схем целесообразно применение иерархических стратегий размещения.

Таблица 3. Численные результаты качества размещения

Класс топологии	Режим параметризации	$L(P)$ длина межсоединений, у.е.	$LS(P)$ трассировка, у.е.	$T(P)$ технологические ограничения (нормированный)	$F(P)$ интегральный показатель, у.е.	$\sigma^2(F)$ дисперсия $F$ , у.е. <sup>2</sup>	Время работы, с
Разреженная	Статическое	8 610	1 420	0.18	8 420	$1.25 \times 10^5$	112
	Фиксированная	8 120	1 310	0.12	7 920	$8.6 \times 10^4$	118
	Адаптивная	7 410	1 180	0.07	7 340	$4.2 \times 10^4$	124
Смешанная	Статическое	28 900	4 870	0.31	31 200	$3.9 \times 10^5$	215
	Фиксированная	26 100	4 420	0.21	27 400	$2.6 \times 10^5$	223
	Адаптивная	22 300	3 980	0.13	24 100	$1.1 \times 10^5$	234
Плотная	Статическое	78 200	11 600	0.52	86 500	$8.2 \times 10^5$	418
	Фиксированная	69 300	10 200	0.37	76 400	$5.4 \times 10^5$	427
	Адаптивная	59 200	8 900	0.24	65 100	$2.7 \times 10^5$	441

На рисунке 4 представлен график сходимости интегрального показателя качества  $F(P)$  для различных режимов параметризации, отражающий особенности поведения алгоритма на начальном этапе поиска и выход в область устойчивых значений.




Рис. 4. График сходимости интегрального показателя качества  $F(P)$  при различных режимах параметризации

На рисунке 5 представлен график сравнения значений  $L(P)$ ,  $LS(P)$ ,  $T(P)$  и  $F(P)$  при различных режимах параметризации, отражающий влияние отдельных показателей на формирование интегрального критерия качества.




Рис. 5. График сравнения значений  $L(P)$ ,  $LS(P)$ ,  $T(P)$  и  $F(P)$  при различных режимах параметризации

Проведенный анализ представленных таблиц и графиков  $F(P_t)$  показал, что разработанный метаэвристический алгоритм, включающий динамическую модель параметризации, характеризуется стабильным снижением целевой функции и меньшим количеством фаз стагнации. При этом траектория сходимости отличается сглаженным профилем благодаря стабилизации параметров, что снижает вероятность резких отклонений и преждевременной остановки в локальных оптимумах. В свою очередь, оценка устойчивости подтверждает снижение вариативности результатов предложенного алгоритма, проявляющаяся в уменьшении диапазона значений  $F(P)$  и дисперсии решений в 1.3-2.2 раза (в зависимости от набора данных), а также в смещении медианы решений в область наилучших конфигураций задаваемых параметров. Отметим, что для методов со статическими задаваемыми параметрами характерно расширенное распределение результатов и высокая чувствительность к начальному набору данных.

На рисунке 6 представлен график изменения параметров  $\Theta(t)$ , отражающий адаптацию алгоритма к структуре задачи и согласованность механизма параметрического управления с показателями процесса поиска.

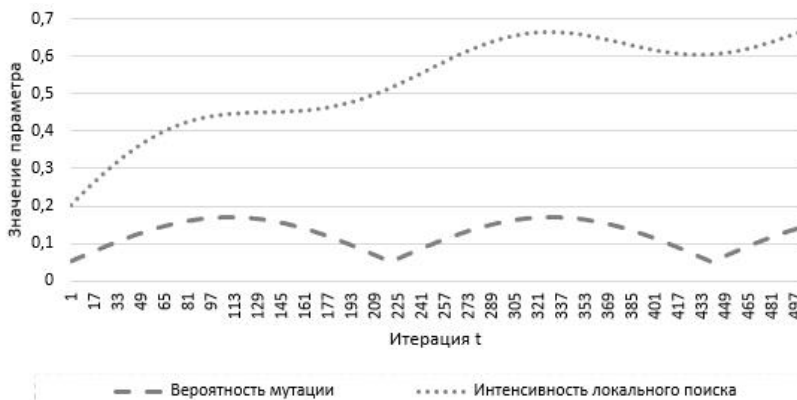


Рис. 6. График изменения параметров  $\Theta(t)$

Совокупность полученных результатов подтверждает, что адаптивный механизм параметризации обеспечивает стабильное поведение предложенного алгоритма и повышает качество решений, снижая вероятность преждевременной сходимости. Сравнительный анализ показал, что данный алгоритм по заданным метрикам качества

размещения демонстрирует лучшие результаты по сравнению с методами, использующими статические параметры и ручную многоэтапную настройку. При этом улучшение интегрального показателя качества  $F(P)$  в среднем составляет 8-15 % для разреженных структур и 12-25 % для структур с высокой плотностью связей.

**7. Заключение.** В работе исследована проблема повышения эффективности применения эвристических и метаэвристических алгоритмов при решении задачи размещения компонентов СБИС, характеризующейся высокой комбинаторной сложностью, разрывностью поверхности поиска и технологическими ограничениями топологического синтеза. В статье приведена многокритериальная постановка задачи, учитывающая длину межсоединений, сложность трассировки и технологические ограничения. Анализ поведения метаэвристик со статическими параметрами показал, что их эффективность существенно ограничивается отсутствием адаптации поискового процесса, что проявляется в преждевременной сходимости, высокой вариативности результатов и снижении устойчивости поиска.

В работе предложена динамическая модель адаптивной параметризации, включающая набор метрик (скорость улучшения, разнообразие популяции, локальная неоднородность ландшафта поиска, индикатор стагнации), пороговых механизмов и стабилизирующих операторов, которые позволяют обеспечить согласование параметров поиска с текущим состоянием популяции альтернативных решений. Разработана процедура обновления параметров поиска, основанная на интегральном показателе состояния популяции и обеспечивающая регулирование баланса между глобальным и локальным поиском. Интеграция адаптивной модели в эвристические и метаэвристические алгоритмы позволила сформировать двухконтурную организацию поискового процесса с замкнутым контуром параметрического управления.

Результаты вычислительного эксперимента подтвердили эффективность предложенного подхода: интегральный показатель качества размещения улучшен на 8-15% для структур с низкой плотностью связей и на 12-25% для структур с высокой плотностью связей; дисперсия результатов при множественных итерациях снижена в 1,3-2,2 раза; число циклов стагнации сократилось в среднем в 2,5 раза; чувствительность к начальному состоянию популяции снижена (разброс финальных значений  $F(P)$  при разных начальных популяциях уменьшился на 30-40%). Временные затраты адаптивного алгоритма превысили время работы статических методов лишь на 5-10% (для

плотных топологий – 441 с и 418 с у статического алгоритма), что обусловлено применением предложенного набора метрик и динамическим обновлением параметров поиска. Полученное время (от 124 с для 100 компонентов до 441 с для 600 компонентов) позволяет использовать разработанный алгоритм в интерактивных средах проектирования СБИС умеренной сложности, а для более крупных схем целесообразно применение иерархических стратегий поиска.

Предложенный механизм адаптивной параметризации формирует основу для дальнейшего развития интеллектуальных методов проектирования СБИС. Перспективы исследований включают интеграцию динамической параметризации с процедурами трассировки, разработку гибридных архитектур с обучением параметров на основе неструктурированных данных, расширение набора метрик состояния популяции, а также применение рассмотренной модели в задачах трёхмерного размещения, оптимизации критических маршрутов и автоматизации процесса многокритериального топологического синтеза.

### Литература

1. Гладков Л.А., Кравченко Ю.А., Курейчик В.В., Родзин С.И. Интеллектуальные системы: модели и методы метаэвристической оптимизации: Монография // Чебоксары: ИД «Среда». 2024. 228 с. DOI: 10.31483/a-10639.
2. Qiu Y., Xing Y., Zheng X., Gao P., Cai S., Xiong X. Progress of Placement Optimization for Accelerating VLSI Physical Design // Electronics. 2023. vol. 12. no. 2. pp. 1–23. DOI: 10.3390/electronics12020337.
3. Курейчик В.В. Вычислительные модели эволюционных и роевых биоэвристик (обзор) / В.В. Курейчик, С.И. Родзин // Информационные технологии. 2021. Т. 27. №10. С. 507–520. DOI: 10.17587/it.27.507-520.
4. Курейчик В.М., Данильченко В.И. Генетический алгоритм планирования размещения СБИС / В.М. Курейчик, В.И. Данильченко // Известия ЮФУ. Технические науки. 2019. №2. С. 26–34.
5. Данильченко В.И., Курейчик В.В. Оценка эффективности и качества проектных решений при размещении фрагментов сверхбольших интегральных схем // Программные продукты и системы. 2025. Т. 38. №4. С. 617–629. DOI: 10.15827/0236-235X.152.617-629.
6. Agnesina A., Chang K., Lim S.K. VLSI Placement Parameter Optimization using Deep Reinforcement Learning // Proceedings of the 2020 International Conference on Computer-Aided Design (ICCAD '20). 2020. pp. 1–9. DOI: 10.1145/3400302.3415690.
7. Карпенко А.П. Современные алгоритмы поисковой оптимизации. Алгоритмы, вдохновленные природой / 3-е изд., испр. // М.: Издательство МГТУ им. Н. Э. Баумана. 2021. 448 с.
8. Курейчик В.В. Вычислительные модели биоэвристик, основанных на физических и когнитивных процессах (обзор) / В.В. Курейчик, С.И. Родзин // Информационные технологии. 2021. Т. 27. №11. С. 563–574. DOI: 10.17587/it.27.563-574.
9. Абас В.М.А. Приближенные методы оптимального размещения элементов электрических и электронных цепей // Известия высших учебных заведений.

- Северо-Кавказский регион. Технические науки. 2021. №2. С. 18–26. DOI: 10.17213/1560-3644-2021-2-18-26.
10. Родзин С.И. Биоэвристики: теория, алгоритмы и приложения: Монография / С.И. Родзин, Ю.А. Скобцов, С.А. Эль-Хатиб / Чебоксары: ИД «Среда». 2019. 224 с. DOI: 10.31483/a-54.
  11. Курейчик В.М. Математическое обеспечение конструкторского и технологического проектирования с применением САПР / Учеб. для вузов по спец. "Конструирование и технология радиоэлектрон. средств", "Конструирование и технология электрон. вычисл. средств" // Москва: Радио и связь. 1990. 52 с.
  12. Sherwani N.A. Algorithms for VLSI Physical Design Automation / New York: Springer Science & Business Media. 2013. 488 p.
  13. Амирханов А.В., Волков С.И., Кизиев С.А., Макарчук В.В., Сухов А.Г., Шахнов В.А. Методы оценки качества конструктивных решений, применяемых в СБИС / Международный форум "Микроэлектроника-2016". Тезисы докладов 2-ой научной конференции форума // М.: Рекламно-издательский центр "ТЕХНОСФЕРА". 2016. С. 321–323.
  14. Иванов В.К., Думина Д.С., Семенов Н.А. Определение весовых коэффициентов для аддитивной фитнес-функции генетического алгоритма // Программные продукты и системы. 2020. Т. 33. №1. С. 47–53.
  15. Plummer J.D., Griffin, P.B. Integrated Circuit Fabrication: Science and Technology // Cambridge University Press. 2023 678 p.
  16. Bykovsky N.V., Harutyunyan R.V., Nasedkin A.V. Numerical modeling and optimization results for the placement of irregularly shaped elements on a multidimensional switching field with complex topology // T-Comm. 2024. vol. 18. no. 9. pp. 48–54.
  17. de Souza L.A.M., da Silva J.E.H., Chaves L.J., Bernardino H.S. A benchmark suite for designing combinational logic circuits via metaheuristics // Applied Soft Computing. 2020. vol. 91. 106246 p.
  18. Govia L.C.G., Jurcevic P., Wood C.J., et al. A randomized benchmarking suite for mid-circuit measurements // New Journal of Physics. 2023. vol. 25. no. 12. pp. 1-28.
  19. Гладков Л.А., Лейба С.Н., Тарасов В.Б. Разработка и программная реализация гибридного алгоритма решения оптимизационных задач автоматизированного проектирования // Программные продукты и системы. 2018. Т. 31. №3. С. 569–580. DOI: 10.15827/0236-235X.031.3.569-580.
  20. Лобанов А.В., Егоров А.А., Викторова В.В. Использование пакета DEAP для решения задач оптимизации / Актуальные вопросы современных научных исследований: сборник статей IX Международной научно-практической конференции // Пенза: Наука и Просвещение. 2024. С. 63–66.

**Курейчик Владимир Викторович** — д-р техн. наук, профессор, лауреат премии Правительства РФ в области образования, заведующий кафедры, кафедра систем автоматизированного проектирования (САПР) им. В. М. Курейчика, Южный федеральный университет (ЮФУ). Область научных интересов: искусственный интеллект, автоматизация проектирования, принятие решений, эволюционное моделирование, генетические алгоритмы, биоинспирированный поиск. Число научных публикаций — 424. vkur@sfedu.ru; ул. Энгельса, 1, 347928, Таганрог, Россия; р.т.: +7(863)438-3451.

**Данильченко Владислав Иванович** — канд. техн. наук, доцент, доцент, кафедра систем автоматизированного проектирования (САПР) им. В. М. Курейчика, Южный федеральный университет (ЮФУ). Область научных интересов: биоинспирированные

алгоритмы, метаэвристические методы оптимизации, эволюционное моделирование, автоматизация проектирования электронных средств и СБИС, применение методов искусственного интеллекта для решения задач моделирования сложных технических систем. Число научных публикаций — 70. [vdanilchenko@sfedu.ru](mailto:vdanilchenko@sfedu.ru); ул. Энгельса, 1, 347928, Таганрог, Россия; р.т.: +7(863)437-1651.

**Данильченко Евгения Владимировна** — ассистент, кафедра систем автоматизированного проектирования (САПР) им. В. М. Курейчика, Южный федеральный университет (ЮФУ). Область научных интересов: искусственный интеллект, автоматизация проектирования, принятие решений. Число научных публикаций — 30. [lipkina@sfedu.ru](mailto:lipkina@sfedu.ru); ул. Энгельса, 1, 347928, Таганрог, Россия; р.т.: +7(863)437-1651.

**Поддержка исследований.** Исследование выполнено за счет гранта Российского научного фонда № 24-71-00035, <https://rscf.ru/project/24-71-00035/> в Южном федеральном университете.

V. KUREYCHIK, V. DANILCHENKO, E. DANILCHENKO  
**ADAPTIVE PARAMETERIZATION OF A METAHEURISTIC  
ALGORITHM IN VLSI COMPONENT PLACEMENT**

*Kureychik V., Danilchenko V., Danilchenko E. Adaptive Parameterization of a Metaheuristic Algorithm in VLSI Component Placement.*

**Abstract.** The paper considers the problem of parameterization of a metaheuristic algorithm for placing components of very large-scale integrated circuits (VLSI) under conditions of increasingly complex topologies and constraints of modern technological standards. The relevance of the study is due to the growth in the dimensionality of the designed circuits, an increase in the density of interconnections, and the increasing complexity of the design solution space, all of which limit the effectiveness of applied algorithms with static parameters. The problem statement includes the formation of a set of design metrics, such as wire length, density, placement area, crossing index, and others. Fixed parameterization of metaheuristic algorithms does not fully account for the dynamics of the search space, which limits the quality of the design solutions made. Based on the analysis of the set of design metrics, a dynamic model is proposed that reflects the current state of the search process, including the level of structural diversity of the population and signs of stagnation. Taking into account the proposed model, the structure of an adaptive metaheuristic algorithm with a closed-loop parameter control loop is developed, where parameters are adjusted to coordinate the intensity of global and local search. The scientific novelty lies in the original configuration of a set of metrics (objective function improvement rate  $\delta t$ , population diversity  $Dt$ , local landscape heterogeneity  $Ht$ , stagnation indicator  $St$ ) and the method of their integration into the parameter control loop. In contrast to resource-intensive neural network architectures that require significant computational costs and training samples, the proposed analytical model ensures the interpretability of the adaptation process and high computational efficiency. To confirm the effectiveness of the approach, a software subsystem was built that implements the simulation and computational experiment process. The results of the experiments on test topologies of various dimensions and connection densities showed that, compared to algorithms with static parameterization and fixed multi-stage tuning, the application of the developed algorithm made it possible to increase the integral placement quality metric by 8-15% for structures with low connection density and by 12-25% for structures with high connection density, reduce the variance of results over multiple runs by a factor of 1.3-2.2, reduce the number of stagnation cycles, and decrease sensitivity to the initial state of the population. The obtained results confirm the improvement in the quality and efficiency of design solutions, the robustness of the developed placement algorithm, and indicate the practical applicability of the proposed approach. The article will be useful for specialists engaged in design automation and intelligent analysis in VLSI development.

**Keywords:** metaheuristic algorithms, adaptive parameterization, dynamic model, VLSI component placement, combinatorial optimization, search metrics, topological synthesis, multidimensional discrete space, intelligent design systems.

## References

1. Gladkov L.A., Kravchenko Yu.A., Kureichik V.V., Rodzin S.I. [Intelligent Systems: Models and Methods of Metaheuristic Optimization: Monograph]. Cheboksary: ID "Sreda", 2024. 228 p. DOI: 10.31483/a-10639. (In Russ.).

2. Qiu Y., Xing Y., Zheng X., Gao P., Cai S., Xiong X. Progress of Placement Optimization for Accelerating VLSI. *Physical Design. Electronics*. 2023. vol. 12. no. 2. pp. 1–23. DOI: 10.3390/electronics12020337.
3. Kureichik V.V. [Computational Models of Evolutionary and Swarm Bio-Heuristics (Review)]. V.V. Kureichik, S.I. Rodzin. *Informatsionnyye tekhnologii – Information Technologies*. 2021. vol. 27. no. 10. pp. 507–520. DOI: 10.17587/it.27.507-520. (In Russ.).
4. Kureichik V.M., Danilchenko V.I. [Genetic Algorithm for Planning the Placement of VLSI]. V.M. Kureichik, V.I. Danilchenko. *Izvestiya YuFU. Tekhnicheskiye nauki – Izvestiya SFU. Technical Sciences*. 2019. no. 2. pp. 26–34. (In Russ.).
5. Danilchenko V.I., Kureichik V.V. [Evaluation of the Effectiveness and Quality of Design Solutions for Placing Fragments of Ultra-Large-Scale Integrated Circuits]. *Programmnyye produkty i sistemy – Software Products and Systems*. 2025. vol. 38. no. 4. pp. 617–629. DOI: 10.15827/0236-235X.152.617-629. (In Russ.).
6. Agnesina A., Chang K., Lim S.K. VLSI Placement Parameter Optimization using Deep Reinforcement Learning. *Proceedings of the 2020 International Conference on Computer-Aided Design (ICCAD '20)*. 2020. pp. 1–9. DOI: 10.1145/3400302.3415690.
7. Karpenko A.P. [Modern Search Optimization Algorithms. Nature-Inspired Algorithms]. 3rd ed., revised. Moscow: Izdatel'stvo MGTU im. N. E. Baumana, 2021. 448 p. (In Russ.).
8. Kureichik V.V. [Computational Models of Bio-Heuristics Based on Physical and Cognitive Processes (Review)]. V.V. Kureichik, S.I. Rodzin. *Informatsionnyye tekhnologii – Information Technologies*. 2021. vol. 27. no. 11. pp. 563–574. DOI: 10.17587/it.27.563-574. (In Russ.).
9. Abas V.M.A. [Approximate Methods of Optimal Placement of Elements in Electrical and Electronic Circuits]. *Izvestiya vysshikh uchebnykh zavedeniy. Severo-Kavkazskiy region. Tekhnicheskiye nauki – Proceedings of Higher Educational Institutions. North Caucasus Region. Technical Sciences*. 2021. no. 2. pp. 18–26. DOI: 10.17213/1560-3644-2021-2-18-26. (In Russ.).
10. Rodzin S.I. [Bio-Heuristics: Theory, Algorithms, and Applications: Monograph]. S.I. Rodzin, Yu.A. Skobtsov, S.A. El-Khatib. *Cheboksary: ID "Sreda"*, 2019. 224 p. DOI: 10.31483/a-54. (In Russ.).
11. Kureichik V.M. [Mathematical support for design and technological design using CAD]. *Ucheb. dlya vuzov po spets. "Konstruirovaniye i tekhnologiya radioelektron. sredstv", "Konstruirovaniye i tekhnologiya elektron. vychisl. sredstv"*. Moscow: Radio i svyaz', 1990. 52 p. (In Russ.).
12. Sherwani N.A. *Algorithms for VLSI Physical Design Automation*. New York: Springer Science & Business Media. 2013. 488 p.
13. Amirkhanov A.V., Volkov S.I., Kiziev S.A., Makarchuk V.V., Sukhov A.G., Shakhnov V.A. [Methods for Assessing the Quality of Design Solutions Used in Vlsi]. *Mezhdunarodnyy forum «Mikroelektronika-2016»: Tezisy dokladov 2-oy nauchnoy konferentsii foruma\* [International Forum «Microelectronics-2016»: Abstracts of the 2nd Scientific Conference]*. Moscow: Reklamno-izdatel'skiy tsentr «TEKHNOSEFERA». 2016. pp. 321–323. (In Russ.).
14. Ivanov V.K., Dumina D.S., and Semenov N.A. [Determining Weight Coefficients for the Additive Fitness Function of a Genetic Algorithm]. *Programmnyye produkty i sistemy – Software Products and Systems*. 2020. vol. 33. no. 1. pp. 47–53. (In Russ.).
15. Plummer J.D., Griffin, P.B. *Integrated Circuit Fabrication: Science and Technology*. Cambridge University Press. 2023 678 p.
16. Bykovsky N.V., Harutyunyan R.V., Nasedkin A.V. Numerical modeling and optimization results for the placement of irregularly shaped elements on a

- multidimensional switching field with complex topology. T-Comm. 2024. vol. 18. no. 9. pp. 48–54.
17. de Souza L.A.M., da Silva J.E.H., Chaves L.J., Bernardino H.S. A benchmark suite for designing combinational logic circuits via metaheuristics. Applied Soft Computing. 2020. vol. 91. 106246 p.
  18. Govia L.C.G., Jurcevic P., Wood C.J., et al. A randomized benchmarking suite for mid-circuit measurements. New Journal of Physics. 2023. vol. 25. no. 12. pp. 1–28.
  19. Gladkov L.A., Leiba S.N., Tarasov V.B. [Development and Software Implementation of a Hybrid Algorithm for Solving Optimization Problems in Automated Design]. Programmnyye produkty i sistemy – Software Products and Systems. 2018. vol. 31. no. 3. pp. 569–580. DOI: 10.15827/0236-235X.031.3.569-580. (In Russ.).
  20. Lobanov A.V., Egorov A.A., Viktorova V.V. [Using the DEAP package to solve optimization problems]. Aktual'nyye voprosy sovremennykh nauchnykh issledovaniy: sbornik statey IX Mezhdunarodnoy nauchno-prakticheskoy konferentsii [Actual Issues of Modern Scientific Research: Collection of Articles from the IX International Scientific and Practical Conference]. Penza: Nauka i Prosveshcheniye. 2024. pp. 63–66. (In Russ.).

**Kureychik Vladimir** — Ph.D., Dr. Sci., Professor, Laureate of the Government of the Russian Federation Award in the Field of Education, Head of the Department, Department of Computer-Aided Design Systems (CAD) named after V. M. Kureichik, Southern Federal University (SFU). Research interests: artificial intelligence, design automation, decision-making, evolutionary modeling, genetic algorithms, and bio-inspired search. The number of publications — 424. vkur@sfedu.ru; 1, Engels St., 347928, Taganrog, Russia; office phone: +7(863)438-3451.

**Danilchenko Vladislav** — Ph.D., Associate professor, Department of Computer-Aided Design Systems (CAD) named after V. M. Kureichik, Southern Federal University (SFU). Research interests: bio-inspired algorithms, metaheuristic optimization methods, evolutionary modeling, automation of electronic and VLSI design, and the application of artificial intelligence methods for solving complex technical systems modeling problems. The number of publications — 70. vdanilchenko@sfedu.ru; 1, Engels St., 347928, Taganrog, Russia; office phone: +7(863)437-1651.

**Danilchenko Evgeniya** — Assistant, Department of Computer-Aided Design Systems (CAD) named after V. M. Kureichik, Southern Federal University (SFU). Research interests: artificial intelligence, design automation, and decision-making. The number of publications — 30. lipkina@sfedu.ru; 1, Engels St., 347928, Taganrog, Russia; office phone: +7(863)437-1651.

**Acknowledgements.** The research was funded by the Russian Science Foundation project No. 24-71-00035, <https://rscf.ru/project/24-71-00035/> implemented by the Southern Federal University.