

Оценка эвристических алгоритмов многокритериальной оптимизации для выбора состава оборудования гибридных энергокомплексов

Северина Яна Дмитриевна¹, Шакиров Владислав Альбертович²

¹Институт систем энергетики им. Л.А. Мелентьева СО РАН,

Россия, Иркутск, yan.sewerina2910@yandex.ru

²Иркутский национальный исследовательский технический университет,

Россия, Иркутск

Аннотация. В настоящее время применение автономных гибридных энергокомплексов (ГЭК), сочетающих дизельные генераторы и возобновляемые источники энергии, является эффективным направлением повышения эффективности электроснабжения потребителей изолированных и труднодоступных территорий. Создание ГЭК сопряжено с необходимостью решения оптимизационной задачи, в рамках которой требуется определить оптимальный состав оборудования и их установленных мощностей в условиях многокритериальности. При многокритериальном решении задачи в большинстве исследований применяется двухуровневый подход: на верхнем уровне проводится формирование оптимальных по Парето конфигураций ГЭК с помощью эвристических алгоритмов многокритериальной оптимизации, а на нижнем уровне выполняется моделирование функционирования каждой рассматриваемой конфигурации ГЭК для детальной оценки каждого решения по ряду критериев. Существует большое количество эвристических алгоритмов, применяемых на верхнем уровне для планирования развития энергетических систем и комплексов, которые обладают как достоинствами, так и недостатками, что создает сложности при выборе алгоритма. В данном исследовании представлена оценка эвристических алгоритмов многокритериальной оптимизации на основе эволюционных алгоритмов, таких, как NSGA-II, NSGA-III, AGE-MOEA и MOEA/D с использованием среды Python и библиотеки Rmoo. Для сравнения алгоритмов применялись показатели, оценивающие: равномерность множества Парето; расстояние между истинным множеством Парето и Парето-множеством, формируемым эвристическим алгоритмом; эффективность алгоритма в отношении достижения лучших критериальных оценок; затраты времени на формирование множества Парето. Оценка алгоритмов оптимизации была проведена на примере решения задачи развития гибридного энергокомплекса в удаленном районе Сахалинской области. По результатам оценки алгоритмов для многокритериальной оптимизации состава оборудования ГЭК на верхнем уровне двухуровневого подхода следует выбрать эвристический алгоритм NSGA-II, так как он позволяет получить множество Парето высокого качества, обеспечить достижение минимальных оценок по критериям с использованием меньшего времени по сравнению с другими алгоритмами.

Ключевые слова: эвристические алгоритмы; многокритериальная оптимизация; гибридные энергетические комплексы; множество Парето

Цитирование: Северина Я.Д. Оценка эвристических алгоритмов многокритериальной оптимизации для выбора состава оборудования гибридных энергокомплексов / Я.Д. Северина, В.А. Шакиров // Информационные и математические технологии в науке и управлении, 2025. – № 3 (39). – С. 88-103. – DOI:10.25729/ESI.2025.39.3.008.

Введение. В настоящее время более 60% территории России находится в зоне децентрализованного электроснабжения, где потребители получают питание от автономных дизельных электростанций. К таким районам относятся изолированные и труднодоступные территории Сибирского и Дальневосточного Федеральных округов [1].

В связи с суровыми климатическими условиями, низким уровнем развития транспортной инфраструктуры, а также рассредоточенностью большого количества потребителей малой мощности для повышения надежности, экономической и экологической эффективности целесообразно развитие энергетических систем таких территорий на основе использования местных и возобновляемых энергоресурсов. Эффективным направлением является создание гибридных энергетических комплексов (ГЭК) на базе дизельных электростанций с

дополнением их генерирующими установками на основе возобновляемых источников энергии (ВИЭ) и накопителями.

Планирование развития ГЭК сопряжено с необходимостью решения многокритериальной оптимизационной задачи, в рамках которой необходимо определить оптимальный состав источников и накопителей энергии, их установленные мощности и емкость в соответствии с технико-экономическими и экологическими критериями. Задача усложняется стохастическим характером генерации ВИЭ, технологическими ограничениями накопителей энергии и дизельных генераторов, поэтому в большинстве исследований для решения задачи определения оптимального состава оборудования ГЭК в условиях многокритериальности применяется двухуровневый подход [2, 3]. На верхнем уровне проводится многокритериальная оптимизация мощности энергоисточников и емкости накопителей ГЭК с использованием, как правило, эвристических алгоритмов, таких, как генетический алгоритм, рой частиц, стая сальп и другие, принцип действия которых основан на имитации поведения «живых» систем. В результате применения алгоритма оптимизации верхнего уровня формируется множество Парето из недоминируемых альтернатив – конфигураций ГЭК. Каждая альтернатива превосходит другие альтернативы множества хотя бы по одному критерию и потенциально может быть выбрана в качестве эффективного решения. Для оценки альтернатив по части критериев необходимо моделировать функционирование ГЭК с почасовой детализацией. Для этого на нижнем уровне применяются имитационные модели или модели на основе линейного (LP) или смешанного целочисленного линейного (MILP) программирования [4, 5]. Из полученного на основе такого подхода множества Парето лицо, принимающее решение (ЛПР), может окончательно выбрать наиболее предпочтительную конфигурацию ГЭК с использованием многокритериальных методов принятия решений, например, TOPSIS (Technique for Order Preference by Similarity to Ideal Solution) или AHP (Analytic Hierarchy Process).

В подавляющем большинстве исследований по оптимизации состава оборудования ГЭК не проводятся предварительное сравнение и выбор эвристических алгоритмов многокритериальной оптимизации для верхнего уровня, хотя они значительно отличаются по эффективности. В данном исследовании будет выполнено сравнение четырех алгоритмов в рамках двухуровневого подхода на примере развития ГЭК в удаленном районе Сахалинской области.

Методы и алгоритмы оптимизации для решения задачи оптимизации состава оборудования ГЭК. Многие исследования посвящены многокритериальной оптимизации состава оборудования гибридных энергокомплексов с использованием эвристических алгоритмов на верхнем уровне двухуровневого подхода. В статье [6] для нахождения оптимальной конфигурации ГЭК с минимальными значениями нормированной стоимости электроэнергии (LCOE) и недоотпуском электроэнергии (LPSP) используется генетический алгоритм с недоминируемой сортировкой II (Non-dominated Sorting Genetic Algorithm, NSGA-II), в основе которого, как и у однокритериального генетического алгоритма, лежит процесс естественного отбора и эволюции. В исследовании [7] применяется многокритериальная оптимизация методом роя частиц (Multi-Objective Particle Swarm Optimization, MOPSO), принцип действия которого основан на поиске в пространстве решений группой частиц (стая птиц, пчел и т.д.), обменивающихся между собой своей текущей наилучшей позицией. В работе [8] для выбора конфигурации ГЭК с минимальными значениями стоимости электроэнергии и потерь мощности используется комбинация оптимизационных методов, таких как MOPSO и SSO (Social Spider Optimization) – алгоритма, основанного на поведении социальных пауков. В статье [9] для определения установленных мощностей оборудования гибридной энергосистемы был использован алгоритм гравитационного поиска (Gravitational

Search Algorithm, GSA), основанный на законах гравитации и взаимодействии масс. В работе [10] применяется метаэвристическая многокритериальная оптимизация состава ГЭК на основе комбинации метода роя частиц (Particle Swarm Optimization, PSO) и многокритериального алгоритма по схеме «Лидер-последователь» (MO leaders-and-follower, MO-LaF), который основан на использовании двух популяций (наборов решений), состоящих из «лидеров» и «последователей».

Как было отмечено ранее, для оптимизации функционирования гибридного энергокомплекса на нижнем уровне применяются имитационное моделирование и модели на основе LP и MILP. В исследовании [11] используется модель на основе MILP для определения конфигурации гибридной энергосистемы с наименьшими значениями суммарных затрат и выбросов углекислого газа. В работе [5] представлена реализованная в MATLAB модель на основе MILP, которая позволяет определить рациональный состав оборудования автономной энергосистемы для удовлетворения спроса на электроэнергию и снижения зависимости от ископаемого топлива. В работе [12] используется оптимизационная модель гибридной энергосистемы на основе LP для минимизации капитальных затрат в зависимости от спроса на энергию и установленной мощности источника. В исследованиях [13, 14] для определения оптимального состава гибридного энергокомплекса на верхнем уровне используются генетический алгоритм и метод роя частиц, а для оптимизации функционирования на нижнем уровне – имитационное моделирование.

Таким образом, для решения задачи планирования развития ГЭК существует достаточно большое количество оптимизационных методов и алгоритмов, которые обладают как достоинствами, так и недостатками, что создает сложности при выборе подходящих методов для использования двухуровневого подхода.

Например, прежде чем выбрать эвристический алгоритм многокритериальной оптимизации для определения рациональных установленных мощностей ГЭК на верхнем уровне, необходимо оценить его эффективность на основе анализа формируемого множества Парето. Существует достаточно большое количество показателей для проведения такой оценки, но исследований, связанных с оценкой эвристического алгоритма перед его применением для решения оптимизационных задач в энергетике, немного [13, 15]. В большинстве исследований такая оценка не выполняется [16, 17].

Таким образом, в связи с проблемой выбора методов для верхнего уровня двухуровневого подхода при решении задачи оптимизации состава оборудования ГЭК, в статье представлен сравнительный анализ эвристических алгоритмов.

Методика оценки эвристических алгоритмов многокритериальной оптимизации для выбора состава ГЭК. Сравнительный анализ эвристических алгоритмов оптимизации был проведен на примере выбора состава оборудования ГЭК в удаленном районе Сахалинской области, где имеется большое разнообразие вариантов развития ГЭК и высокий потенциал ВИЭ. В рассматриваемом энергорайоне «Новиково», расположенном на Тонино-Анивском полуострове, электроснабжение осуществляется от дизельных электростанций. При создании ГЭК и оптимизации состава оборудования на верхнем уровне рассматривались следующие источники энергии: ветровая (ВЭС) и солнечная (СЭС) электростанции, так как исследуемая территория располагает высоким ветроэнергетическим и гелиоэнергетическим потенциалом, а также дизель-генераторная установка (ДГУ) и аккумуляторные батареи (АКБ) для накопления избыточной энергии ВИЭ и повышения надежности электроснабжения потребителей. На нижнем уровне решения задачи используется имитационная модель функционирования ГЭК, ранее представленная в работе [18]. Моделирование осуществлялось для каждой из конфигураций ГЭК в течение расчетного периода 8760 часов.

В рамках двухуровневого подхода на верхнем уровне проводится формирование конфигурации ГЭК одним из эвристических алгоритмов многокритериальной оптимизации, а на нижнем уровне проводится имитационное моделирование функционирования каждой конфигурации, что позволяет детально оценить каждый вариант решения по ряду критериев на основе графика покрытия нагрузки каждым источником. На рисунке 1 в качестве примера представлен фрагмент графика покрытия нагрузки одним из возможных вариантов ГЭК.




Рис. 1. График покрытия нагрузки энергорайона «Новиково»

Для сравнения эвристических алгоритмов многокритериальной оптимизации на верхнем уровне были выбраны: генетический алгоритм с недоминируемой сортировкой NSGA-II, NSGA-III (Non-Dominated Sorting Genetic Algorithm), адаптивный алгоритм AGE-MOEA (Adaptive Geometry Estimation based Many Objectives Evolutionary Algorithm) и алгоритм многокритериальной оптимизации, основанный на методе декомпозиции MOEA/D (Multiobjective Evolutionary Algorithm Based on Decomposition) [19, 20, 21]. Эти алгоритмы были выбраны для анализа, так как они основаны на процессе естественного отбора и эволюции, имеют одинаковые параметры для настройки, а также путем подбора, комбинирования и селекции искомым величин формируют множество оптимальных по Парето альтернатив. Отличительной особенностью NSGA-II является использование принципов недоминируемой сортировки и оценки скученности решений (crowding distance) для получения разнообразных решений [22]. Алгоритм NSGA-III является расширением NSGA-II, отличается применением опорных точек на стадии селекции и формирования новых популяций для повышения разнообразия пространства недоминируемых решений. Алгоритм AGE-MOEA в целом схож с алгоритмом NSGA-II, но использует другой подход для оценки скученности решений и применяет итерационный метод Ньютона-Рафсона для решения нелинейного уравнения, задающего условие нахождения наиболее близкой к идеалу точки [23]. Алгоритм MOEA/D разделяет многокритериальную задачу оптимизации на ряд скалярных подзадач и оптимизирует их одновременно [24].

Для реализации рассмотренных алгоритмов необходимо задать гены, которые представляют собой искомые оптимизируемые параметры. Далее формируется начальная популяция особей, имеющих отличия в генах. В процессе реализации алгоритма проводится оценка особей популяции, их селекция для скрещивания и образования новых поколений. Также для повышения разнообразия решений используются различные варианты мутации. В проведенном исследовании в качестве генов были заданы установленные мощности

источников энергии и емкость АКБ. Популяция представляет собой набор альтернатив – конфигураций ГЭК, каждая из которых может являться потенциально лучшим выбором для ЛПР. Для оценки решений, селекции и формирования новых поколений используются рассмотренные ниже критерии.

Многоцелевая оптимизация выполнялась по трем критериям:

1. Нормированная стоимость электроэнергии LCOE (Levelized Cost of Energy), \$/кВт·ч:

$$LCOE = \frac{\sum_{t=25}^n \frac{I_t + M_t + F_t}{(1+r)^t}}{\sum_{t=25}^n \frac{E_t}{(1+r)^t}}, \quad (1)$$

где I_t – инвестиционные затраты в t -ый год; M_t – эксплуатационные затраты в t -ый год, F_t – затраты на топливо в t -ый год, E_t – производство электроэнергии в t -ый год, r – ставка дисконтирования, n – жизненный цикл ГЭК, принятый 25 лет.

2. Расход дизельного топлива, т:

$$V_{д.т.} = m_{у.т.} \cdot 10^{-6} \cdot \sum_{t=1}^{8760} W_{дэс}(t), \quad (2)$$

где $m_{у.т.}$ – удельный расход топлива, принятый 200 г/кВт·ч; $\sum_{t=1}^{8760} W_{дэс}(t)$ – суммарная выработка ДЭС за весь период моделирования, кВт·ч.

3. Доля избыточной энергии EEF (Excess energy fraction), %:

$$EEF = \frac{\sum_{t=1}^{8760} (N_{сумм}(t) - P_{нагр}(t))}{\sum_{t=1}^{8760} P_{нагр}(t)} \cdot 100 \%, \quad (3)$$

где $\sum_{t=1}^{8760} N_{сумм}(t)$ – суммарная выработка всеми источниками энергии за весь период моделирования, кВт·ч; $\sum_{t=1}^{8760} P_{нагр}(t)$ – суммарная нагрузка за весь период моделирования, кВт·ч.

Эвристические методы оптимизации обеспечивают получение не истинного множества Парето, а приближенного к нему множества. В связи с этим возникает потребность в оценке того, насколько формируемые множества близки к Парето-оптимальному множеству. Кроме того, формируемые множества могут быть неоднородны, что также снижает эффективность поиска решений. Поэтому существуют специальные показатели [25, 26], которые позволяют оценить методы и алгоритмы формирования множества Парето.

Оценка производительности алгоритмов NSGA-II, NSGA-III, AGE-MOEA и MOEA/D и качества получаемых множеств Парето осуществлялась в среде Python с использованием библиотеки Rmoo [27] по следующим показателям:

1. Расстояние GD (Generational Distance). Данный показатель измеряет расстояние между каждым Парето-оптимальным решением, полученным эвристическим алгоритмом, и ближайшим решением истинного множества Парето:

$$GD(X) = \frac{1}{|X|} \left(\sum_{i=1}^{|X|} d_i^p \right)^{\frac{1}{p}}, \quad (4)$$

где $X = \{x_1, x_2, \dots, x_{|X|}\}$ – Парето-множество, полученное эвристическим алгоритмом; $Z = \{z_1, z_2, \dots, z_{|Z|}\}$ – истинное Парето-множество решений; d_i – Евклидово расстояние ($p = 2$) между любой точкой x_i и любой точкой Z .

2. Модифицированное расстояние GD+ (Generational Distance Plus):

$$GD^+(X) = \frac{1}{|X|} \left(\sum_{i=1}^{|X|} d_i^{+2} \right)^{\frac{1}{2}}, \quad (5)$$

где $d_i^+ = \max\{x_i - z_i, 0\}$ – расстояние от любого решения x_i множества X до ближайшего решения z_i Парето-оптимального множества Z с учетом доминирования. Модифицированный показатель более точно характеризует качество Парето-фронта, так как при оценивании расстояния учитывает отношение доминирования между решениями.

Следует отметить, что чем меньше значение показателей (4) и (5), тем ближе полученное множество решений к истинному Парето-оптимальному множеству решений.

3. Обратное расстояние IGD (Inverted Generational Distance). Этот показатель измеряет расстояние между решениями истинного Парето-оптимального множества Z и ближайшим решением из Парето множества X , сформированного эвристическим алгоритмом:

$$IGD(X) = \frac{1}{|Z|} \left(\sum_{i=1}^{|Z|} \hat{d}_i^p \right)^{\frac{1}{p}}, \quad (6)$$

где $\hat{d}_i$ – Евклидово расстояние ($p = 2$) между z_i Парето-оптимального множества Z и ближайшим решением множества X .

4. Модифицированное обратное расстояние IGD+ (Inverted Generational Distance Plus). Этот показатель измеряет расстояния между решениями Парето-оптимального множества и Парето-множества, сформированного эвристическим алгоритмом, но с проверкой доминирования между решениями:

$$IGD^+(X) = \frac{1}{|Z|} \left(\sum_{i=1}^{|Z|} d_i^{+2} \right)^{\frac{1}{2}}, \quad (7)$$

где $d_i^+ = \max\{x_i - z_i, 0\}$ – расстояние между решением z_i оптимального Парето-фронта Z и ближайшим решением x_i множества X с учетом доминирования.

Чем меньше значение показателей (6) и (7), тем ближе полученное множество решений к Парето-оптимальному множеству.

5. Показатель распределения решений в пространстве (Spacing). Данный показатель оценивает равномерность распределения множества Парето в пространстве:

$$Spacing = \left[\frac{1}{N-1} \cdot \sum_{i=1}^{N-1} (\bar{d} - d_i)^2 \right]^{\frac{1}{2}}, \quad (8)$$

где d_i – минимальное расстояние от i -го решения до ближайшего решения из рассматриваемого множества:

$$d_i = \min_{j \neq i} (|f_1(x_i) - f_1(x_j)| + |f_2(x_i) - f_2(x_j)| + |f_3(x_i) - f_3(x_j)|), \quad i, j = 1, \dots, N \quad (9)$$

где $\bar{d}$ – среднее расстояние между решениями d_i ; $f_n(x_i), f_n(x_j)$, – i -ое и j -ое решения множества Парето по n критерию; N – количество решений;

6. Модифицированный показатель распределения решений в пространстве (Advanced spacing) отличается подходом к нормализации расстояний и использует предварительное упорядочивание решений по оценкам одного из критериев [28]:

$$ASpacing = \left[\frac{1}{N-1} \cdot \sum_{i=1}^{N-1} \left(1 - \frac{d_i}{\bar{d}} \right)^2 \right]^{\frac{1}{2}}, \quad (10)$$

где d_i – расстояние между решениями, полученными в результате предварительного упорядочивания:

$$d_i = \sqrt{(f_1(x_i) - f_1(x_{i+1}))^2 + (f_2(x_i) - f_2(x_{i+1}))^2 + (f_3(x_i) - f_3(x_{i+1}))^2}, \quad (11)$$

Чем меньше значение показателей (8) и (10), тем равномернее распределено множество Парето в пространстве [28].

7. Относительное расстояние между решениями HRS (Hole Relative Size). Данный показатель позволяет вычислить наибольшее расстояние между соседними решениями в пространстве, что отражает равномерность полученного множества. Для возможности сопоставления расстояние нормализуется путем деления его на среднее расстояние между решениями:

$$HRS = \frac{\max d_i}{\bar{d}}, \quad (12)$$

где d_i – максимальное расстояние между соседними решениями, $\bar{d}$ – среднее расстояние между решениями.

Меньшее значение показателя HRS соответствует более равномерному распределению решений множества Парето в пространстве.

8. Количество решений (Cardinality):

$$Cardinality = |X|, \quad (13)$$

где $|X|$ – количество решений, составляющих множество Парето. Различные эвристические алгоритмы формируют множество Парето с различным числом решений. Чем больше решений, тем эффективнее работа алгоритма.

9. Лучшее значение критерия, достигнутое алгоритмом по каждому из критериев. Используемые в работе критерии (1) – (3) направлены на минимизацию оценок:

$$F_{\min(k)} = \min(f_k(x_i)), i = 1, \dots, N, \quad (14)$$

где $f_k(x_i)$ – оценка i -го решения по k -му критерию ($LCOE, V_{д.т.}, EEF$).

Показатели $Spacing$, $ASpacing$, HRS , $Cardinality$ и $F_{\min}$ проводят оценку непосредственно самого полученного множества Парето, в то время как показатели GD , $GD +$, IGD , $IGD +$ сравнивают полученные эвристическим методом множества Парето с истинным Парето-оптимальным множеством.

При решении многокритериальной оптимизационной задачи зачастую Парето-оптимальное множество неизвестно, поэтому его получают искусственным путем [29]. Одним из таких способов является объединение результатов нескольких запусков алгоритма с настройками, обеспечивающими более глубокий поиск и большие затраты вычислительных ресурсов. Далее из полученного объединенного множества исключаются доминируемые решения, т.е. заведомо худшие решения, которые по всем трем критериям имеют оценки хуже, чем другие решения.

Как правило, при настройке алгоритма изменяют численность популяции (pop_size) и количество поколений (n_gen). При использовании эвристических алгоритмов для конкретных задач сложно определить, при каких значениях pop_size и n_gen алгоритм обеспечит лучшие решения. Например, эффективность может быть выше при большом значении популяции и маленьком количестве поколений или, наоборот, при маленьком значении популяции и большом количестве поколений. В выполненном исследовании оптимальный Парето-фронт был получен путем объединения результатов двух запусков алгоритмов с вышеописанным подходом к заданию параметров.

На рисунке 2 (а) представлено множество Парето, полученное при объединении результатов NSGA-II, NSGA-III и AGE-MOEA. У всех алгоритмов были выставлены одинаковые настройки: $pop_size = 50$ и $n_gen = 100$. На рисунке 2 (б) представлено множество Парето, полученное при объединении результатов NSGA-II, NSGA-III и AGE-MOEA при настройках $pop_size = 200$ и $n_gen = 10$.

На рисунке 3 (а) представлено множество Парето, полученное при объединении результатов двух множеств. На рисунке 3 (б) представлено Парето-оптимальное множество,

полученное в результате исключения доминируемых решений, т.е. тех решений, которые хуже по всем трем критериям.




Рис. 2. Множество Парето при настройках алгоритма:
а) $pop_size = 50$ и $n_gen = 100$, б) $pop_size = 200$ и $n_gen = 10$

Как видно из рис. 3, несколько значений, полученных NSGA-II, не вошли в объединенное Парето-оптимальное множество (Reference Points), так как имеют наибольшие значения по всем трем критериям относительно других решений.




Рис. 3. Множество Парето в результате объединения двух множеств:
а) без исключения доминируемых решений, б) с исключением доминируемых решений
(Парето-оптимальное множество)

Для сравнения было сформировано истинное Парето-оптимальное множество с помощью метода полного перебора вариантов состава оборудования ГЭК в пределах от 0 до 500 с шагом 50 (рис. 4 (а)). На рисунке 4 (б) представлено объединенное Парето-оптимальное множество решений, полученное путем объединения результатов эвристических алгоритмов.

На рисунке 5 представлено сравнение Парето-оптимальных множеств, полученных при использовании метода перебора и путем объединения множеств нескольких запусков эвристических алгоритмов.




Рис. 4. Парето-оптимальные множества, полученные:

а) методом перебора; б) объединением результатов эвристических алгоритмов

Как видно из рис. 5, распределение решений имеет в целом схожий характер, что позволяет сделать вывод о возможности использования подхода к замене истинного Парето-оптимального множества объединенным.




Рис. 5. Сравнение результатов метода перебора и эвристики

После формирования объединенного и истинного Парето-оптимального множества были выполнены три запуска каждого алгоритма с целью оценки показателей качества получаемых решений. На рисунке 6 представлен результат распределения множества решений одного из запусков алгоритмов NSGA-II (рис. 6 (а) и NSGA-III (рис. 6 (б)) относительно объединенного Парето-оптимального множества.




Рис. 6. Распределение множества решений относительно Парето-оптимального множества для: а) NSGA-II; б) NSGA-III

Результаты расчета показателей (4) – (14) для трех запусков алгоритмов NSGA-II и NSGA-III представлены в таблице 1.

Таблица 1. Результаты расчета показателей для алгоритмов NSGA-II и NSGA-III

Показатель/ Номер запуска	NSGA-II			NSGA-III		
	1	2	3	1	2	3
1. GD	0,021	0,018	0,014	0,024	0,061	0,029
2. GD+	0,009	0,003	0,005	0,019	0,054	0,018
3. IGD	0,035	0,031	0,032	0,094	0,099	0,077
4. IGD+	0,025	0,007	0,013	0,055	0,082	0,038
5. Spacing	1,764	2,308	2,149	146,23	69,125	161,44
6. ASpacing	0,937	1,063	0,941	1,927	1,412	1,783
7. HRS	6,185	6,681	5,371	8,746	6,432	8,076
8. Cardinality	100	100	100	20	19	19
9. F ₁ min (LCOE, \$/кВт·ч)	0,144	0,143	0,140	0,142	0,144	0,143
10. F ₂ min (V _{д.т.} , Т)	116,29	120,83	116,29	117,26	118,87	117,7
11. F ₃ min (EEF, %)	0	0	0	0	0,0096	0
12. Затраты времени	44 мин. 6 с.	42 мин. 39 с.	45 мин. 32 с.	58 мин. 59 с.	44 мин. 12 с.	1 час 3 мин.

* жирным шрифтом выделены лучшие оценки

На рисунке 7 представлен результат распределения множества решений одного из запусков алгоритмов AGE-MOEA (рис. 7 (а)) и MOEA/D (рис. 7 (б)) относительно объединенного Парето-оптимального множества.

Результаты расчета показателей (4) – (14) для трех запусков алгоритмов AGE-MOEA и MOEA/D представлены в таблице 2.

Также была выполнена оценка всех алгоритмов относительно истинного Парето-оптимального множества, полученного методом перебора. Так как качество распределения решений Парето-множеств каждого алгоритма уже было оценено в таблицах 1-2 и не зависит от сопоставления с истинным Парето-множеством, то в таблице 3 представлены только показатели (4) – (7), зависящие от расстояний между сравниваемыми множествами.




Рис. 7. Распределение множества решений относительно объединенного Парето-оптимального множества: а) AGE-MOEA; б) MOEA/D

Таблица 2. Результаты расчета показателей для алгоритмов AGE-MOEA и MOEA/D

Показатель/ Номер запуска	AGE-MOEA			MOEA/D		
	1	2	3	1	2	3
1. GD	0,011	0,022	0,013	0,172	0,152	0,167
2. GD+	0,003	0,011	0,004	0,17	0,118	0,151
3. IGD	0,026	0,036	0,029	0,255	0,329	0,289
4. IGD+	0,011	0,022	0,013	0,250	0,305	0,257
5. Spacing	2,693	4,894	7,558	0,018	0,038	0,026
6. ASpacing	1,191	1,507	1,8502	3,184	3,794	3,553
7. HRS	6,385	13,009	16,941	22,795	30,081	26,893
8. Cardinality	100	100	100	90	87	89
9. F ₁ min (LCOE, \$/кВт·ч)	0,144	0,141	0,142	0,144	0,145	0,145
10. F ₂ min (V _{д.т.} , т.)	121,19	118,45	119,36	114,25	114,25	114,25
11. F ₃ min (EEF, %)	0	0	0	0,94	0,94	0,95
12. Затраты времени	55 мин. 42 с.	45 мин. 42 с.	59 мин. 45 с.	1 час 11 мин.	1 час 12 мин.	1 час 4 мин.

* жирным шрифтом выделены лучшие оценки

Таблица 3. Результаты расчета показателей GD, GD+, IGD, IGD+ для всех алгоритмов

Показатели	NSGA-II	NSGA-III	AGE-MOEA	MOEA/D
1. GD	0,029	0,028	0,026	0,168
2. GD+	0,008	0,004	0,005	0,152
3. IGD	0,069	0,103	0,063	0,333
4. IGD+	0,044	0,041	0,036	0,326

Результаты таблицы 3 показывают, что алгоритм AGE-MOEA является более эффективным, в то же время NSGA-II и NSGA-III показывают близкие результаты. На основе оценок таблиц 1-3 для окончательного сопоставления были выбраны NSGA-II и AGE-MOEA (таблица 4).

Таблица 4. Сравнительный анализ алгоритмов NSGA-II и AGE-MOEA

Показатели	NSGA-II	AGE-MOEA
1. GD	0,014	0,011
2. GD+	0,003	0,003
3. IGD	0,031	0,026
4. IGD+	0,007	0,011
5. Spacing	1,764	2,693
6. ASpacing	0,937	1,507
7. HRS	5,371	6,385
8. Cardinality	100	100
9. $F_1 \min$ (LCOE, о.е.)	0,140	0,141
10. $F_2 \min$ ($V_{д.т.}$, т.)	116,29	118,45
11. $F_3 \min$ (EEF, %)	0	0
12. Затраты времени	42 мин. 39 с.	45 мин. 42 с.

* жирным шрифтом выделены лучшие оценки

В результате сравнительного анализа, представленного в таблице 4, множество решений, полученных алгоритмом AGE-MOEA, расположено ближе как к истинному, так и к объединенному Парето-оптимальному множеству в сравнении с множеством решений NSGA-II, так как показатели GD, GD+ и IGD имеют наименьшие значения, за исключением показателя IGD+. В то же время множество решений NSGA-II имеет более высокое качество, так как показатели Spacing, ASpacing и HRS имеют меньшие значения по сравнению со значениями алгоритма AGE-MOEA. Количество найденных решений (Cardinality) у NSGA-II и AGE-MOEA одинаково и соответствует предельному значению, заданному при оптимизации – 100. Также алгоритм NSGA-II нашел решения с наименьшим значением LCOE и расходом топлива за меньший промежуток времени, чем алгоритм AGE-MOEA.

Таким образом, для оптимизации состава оборудования ГЭК на верхнем уровне двухуровневого подхода следует выбрать алгоритм NSGA-II, так как данный алгоритм позволяет получить множество Парето высокого качества, а также найти минимальные значения критериев при решении многокритериальной оптимизационной задачи, направленной на поиск минимальных значений целевых функций. Также необходимо отметить и эффективность AGE-MOEA для использования в задачах оптимизации состава оборудования ГЭК. Возможным подходом является использование этих двух алгоритмов для формирования объединенных Парето-оптимальных конфигураций ГЭК на верхнем уровне, что обеспечит хорошую равномерность и однородность решений в пространстве, близость к истинному множеству Парето, достижение минимальных оценок по критериям. Недостатком такого подхода являются более высокие затраты времени, однако для задач планирования этот фактор не будет иметь решающего значения.

Закключение. В выполненном исследовании рассмотрен двухуровневый подход, который применяется для решения задачи определения оптимального состава оборудования ГЭК в условиях многокритериальности. Представлен обзор методов и алгоритмов, применяемых на верхнем и нижнем уровнях двухуровневого подхода. Рассмотрены показатели для оценки качества Парето-множеств, отражающие как близость к истинному множеству Парето, так и равномерность распределения решений в пространстве. Проведен расчет показателей для алгоритмов NSGA-II, NSGA-III, AGE-MOEA и MOEA/D. По результатам оценки сделан вывод, что алгоритм NSGA-II обеспечивает получение более равномерного множества Парето, определение альтернатив с самыми низкими оценками по критериям. В то же время NSGA-II несколько уступает алгоритму AGE-MOEA в отношении близости к истинному множеству Парето. В целом, применение этих двух алгоритмов

является более предпочтительным в сравнении с другими, рассмотренными в ходе исследования. В дальнейшем планируется выполнить исследования по оценке эффективности комбинации эвристических алгоритмов, а также исследование по сравнению эффективности моделей функционирования ГЭК на нижнем уровне двухуровневого подхода при выборе состава оборудования.

Благодарности. Работа выполнена в рамках проекта государственного задания ИСЭМ СО РАН (№ FWEU-2021-0004) программы фундаментальных исследований РФ на 2021-2030 гг. с использованием ресурсов ЦКП «Высокотемпературный контур» (Минобрнауки России, проект № 13.ЦКП.21.0038).

Список источников

1. Холкин Д. Новые бизнес-модели развития локальной энергетики / Д. Холкин, И. Чаусов, М. Губанов, и др. // Энергетическая политика, 2024. – URL: <https://energypolicy.ru/novye-biznes-modeli-razvitiya-lokalnoj-energetiki-2/energetika/2024/13/18>
2. Akvile G., Sigita R., Mantas M., et al. Hybrid renewable energy systems – a review of optimization approaches and future challenges. *Applied sciences*, 2025, vol. 15, DOI:10.3390/app15041744.
3. Ren X., Li L., Ji B., et al. Design and analysis of solar hybrid combined cooling, heating and power system: A bi-level optimization model. *Energy*, 2024, vol. 292, DOI:10.1016/j.energy.2024.130362.
4. Alberizzi J., Frigola J.M., Rossi M., et al. Optimal sizing of a Hybrid renewable energy system: importance of data selection with highly variable renewable energy sources. *Energy conversion and management*, 2020, vol. 223, DOI:10.1016/j.enconman.2020.113303.
5. Alberizzi J., Frigola J.M., Rossi M. A MILP algorithm for the optimal sizing of an off-grid hybrid renewable energy system in South Tyrol. *Energy reports*, 2020, vol. 6, pp. 21-26, DOI:10.1016/j.egyr.2019.08.012
6. Xu Ch., Ke Yi., Li Ya., et al. Data-driven configuration optimization of an off-grid wind/PV/hydrogen system based on modified NSGA-II and CRITIC-TOPSIS. *Energy conversion and management*, 2020, vol. 215, DOI:10.1016/j.enconman.2020.112892.
7. Nkalo U.K., Inya O.O., Obi, et al. A modified multi-objective particle swarm optimization (M-MOPSO) for optimal sizing of a solar–wind–battery hybrid renewable energy system. *Solar compass*, 2024, vol. 12, DOI:10.1016/j.solcom.2024.100082.
8. Ouederni R., Bouaziz B., Bacha F. Optimization of a hybrid renewable energy system based on meta-heuristic optimization algorithms. *International journal of advanced computer science and applications*, 2024, vol. 15, DOI:10.14569/IJACSA.2024.0150779.
9. Mahmoudi S.M., Maleki A., Ochbelagh D.R. Multi-objective optimization of hybrid energy systems using gravitational search algorithm. *Scientific reports*, 2024, vol. 15, DOI:10.1038/s41598-025-86476-z.
10. Mathaba T.N.D., Abo-Al-Ez Kh. Design of hybrid renewable energy systems: integrating multi-objective optimization into a multi-criteria decision-making framework. *Engineering reports*, 2024, vol. 7, DOI:10.1002/eng2.13074.
11. Sarad B., Deschinkel K., Moyne L.L., et al. Optimal integration of hybrid renewable energy systems for decarbonized urban electrification and hydrogen mobility. *International journal of hydrogen energy*, 2024, vol. 83, DOI:10.1016/j.ijhydene.2024.08.054.
12. Kusakana K., Vermaak H.J., Yuma G.P. Optimization of hybrid standalone renewable energy systems by linear programming. *Advanced science letters*, 2013, vol. 19, pp. 2501-2504(4) DOI:10.1166/asl.2013.4948.
13. Mahmoud F.S., Diab A., Ali Z.M., et al. Optimal sizing of smart hybrid renewable energy system using different optimization algorithms. *Energy reports*, 2022, vol. 8, pp. 4935-4956 DOI:10.1016/j.egyr.2022.03.197.
14. Akbar Maleki, Fathollah Pourfayaz, Mohammad H. Ahmadi. Design of a cost-effective wind/photovoltaic/hydrogen energy system for supplying a desalination unit by a heuristic approach. *Solar Energy*, 2016, vol 139, pp. 666-675, DOI:10.1016/j.solener.2016.09.028.
15. Adefarati T., Potgieter S., Sharma G., et al. Optimization of renewable energy based hybrid energy system using evolutionary computational techniques. *Smart grids and sustainable energy*, 2025, vol.10, DOI:10.1007/s40866-025-00245-5.
16. Cheraghi R., Jahangir M.H. Multi-objective optimization of a hybrid renewable energy system supplying a residential building using NSGA-II and MOPSO algorithms. *Energy conversion and management*, 2023, vol. 294, DOI:10.1016/j.enconman.2023.117515.
17. Roy T.K., Saha S., Than Oo A.M. Optimizing hybrid energy systems for remote Australian communities: The role of tilt angle in cost-effective green hydrogen production. *Applied energy*, 2025, vol. 391, DOI:10.1016/j.apenergy.2025.125921.

18. Северина Я.Д. Оптимизация конфигурации гибридного энергокомплекса с использованием генетического алгоритма / Я.Д. Северина, В.А. Шакиров // IV Всероссийская с международным участием молодежная конференция «Бутаковские чтения», г. Томск, 10-12 декабря 2024 г.
19. Tezer T. Multi-objective optimization of hybrid renewable energy systems with green hydrogen integration and hybrid storage strategies. *International journal of hydrogen energy*, 2025, vol. 142, pp. 1249-1271, DOI: 10.1016/j.ijhydene.2025.03.006.
20. Shakirov V.I., Popov I. Multi-criteria design of multi-energy system for remote area using NSGA-III and fuzzy TOPSIS. *Journal of renewable and sustainable energy*, 2024, vol. 16, DOI:10.1063/5.0215524.
21. Ming M., Wang R., Zha Y., et al. Multi-objective optimization of hybrid renewable energy system using an enhanced multi-objective evolutionary algorithm. *Energies*, 2017, vol. 10, DOI:10.3390/en10050674.
22. Deb K, Pratap A., Agarwal S., Meyarivan T. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 2002, vol. 6(2), pp. 182-197, DOI:10.1109/4235.996017.
23. Вихтенко Э.М. Исследование алгоритмов NSGA-III и AGE-MOEA-II для решения задач многокритериальной оптимизации / Э.М. Вихтенко, Д.В. Зубков // Инженерный вестник Дона, 2024. – № 6.
24. Zhang Q., Li H. A multi-objective evolutionary algorithm based on decomposition. *IEEE Transactions on Evolutionary Computation*, 2007, vol. 11, pp. 712-731, DOI:10.1109/TEVC.2007.892759.
25. Pyomo. Multi-objective optimization in Python, available at: <https://www.pyomo.org/>.
26. Perfect Indicator. Multi-objective optimization in Python, Pymoo, available at: <https://pymoo.org/misc/indicators.html>.
27. Collette Y., Siarry P. Three new metrics to measure the convergence of towards the Pareto frontier and the aesthetic of a set of solutions in biobjective optimization. *Computers & operations research*, 2005, vol. 32, pp. 773-792, DOI:10.1016/j.cor.2003.08.017.
28. Ishibuchi H., Masuda H., Tanigaki Y., et al. Modified distance calculation in generational distance and inverted generational distance. *Lecture notes in computer science*, 2015, pp. 110-125, DOI:10.1007/978-3-319-15892-1_8.
29. Zheng K., Yang R., Xu H., et al. A new distribution metric for comparing Pareto optimal solutions. *Structural and multidisciplinary optimization*, 2017, vol. 55, pp. 53-62, DOI:10.1007/s00158-016-1469-3.

Северина Яна Дмитриевна. Аспирант Института систем энергетики им. Л.А. Мелентьева СО РАН. AuthorID: 1121503, SPIN: 3075-3243, ORCID: 0009-0003-3685-7815, yan.sewerina2910@yandex.ru, 664033, г. Иркутск, ул. Лермонтова, д. 130.

Шакиров Владислав Альбертович. Кандидат технических наук, заведующий кафедрой электроснабжения и электротехники, Иркутский национальный исследовательский технический университет, AuthorID: 534444, SPIN: 2637-8522, ORCID 0000-0001-8629-9549, shakirovva@ex.istu.edu, 664074, г. Иркутск, ул. Лермонтова, д. 83.

UDC 621.311.17

DOI:10.25729/ESI.2025.39.3.008

Evaluation of heuristic algorithms of multi-criteria optimization for sizing of hybrid renewable energy systems

Yana D. Severina¹, Vladislav A. Shakirov²

¹Melentiev energy systems institute SB RAS,
Russia, Irkutsk, yan.sewerina2910@yandex.ru

²Irkutsk national research technical university,
Russia, Irkutsk

Abstract. At present, the use of stand-alone hybrid renewable energy systems (HRES) combining diesel generators and renewable energy sources is an effective way to improve the efficiency of electricity supply to consumers in isolated and hard-to-teach areas. Designing of HRES associated with the need to solve an optimization problem, in which it is necessary to determine the optimal equipment configuration and their installed capacities in the context of multi-criteria. In the case of multi-criteria problem solving, a two-level approach is used in most studies: at the top level, the optimal Pareto configurations of HRES are formed using heuristic algorithms of multi-criteria

optimization, at the bottom-level, the simulation of each HRES configuration are considered for detailed evaluation of each solution by a number of criteria. There is a large number of heuristic algorithms applied at the top level for planning the development of energy systems and HRES, which have both advantages and disadvantages, which creates difficulties in choosing an algorithm. This study presents an evaluation of heuristic multi-criteria optimization algorithms based on evolutionary algorithms such as NSGA-II, NSGA-III, AGE-MOEA and MOEA/D using Python and Pymoo package. To compare the algorithms, indicators were used that evaluate the Pareto set uniformity; distance between the true Pareto set and the Pareto-set formed by the heuristic algorithm; efficiency of the algorithm to achieving the best criteria evaluations; the time required to form the Pareto set. Evaluation of optimization algorithms was carried out on the example of solving the problem of development of a hybrid renewable energy system in the remote area of Sakhalin region. According to the results of evaluation of algorithms of multi-criteria sizing of HRES at the top-level of the two-level approach should be chosen heuristic algorithm NSGA-II, as it allows to obtain the Pareto set of high quality, ensure the achievement the minimum estimates on criteria during less time than other algorithms.

Keywords: heuristic algorithms, multi-criteria optimization, hybrid renewable energy systems, Pareto set

Acknowledgements. The research was carried out under the State Assignment (FWEU-2021-0004) of the Program for Basic Research of the Russian Federation for 2021–2035 and made use of the resources of the High-Temperature Circuit Multi-Access Research Center (Ministry of Education and Science of the Russian Federation, project No. 13.CKP.21.0038).

References

1. Holkin D., Chausov I., Gubanov M., Melnikov P., et al. Novyye biznes-modeli razvitiya lokal'noy energetiki [New business models for the development of local energy]. Energeticheskaya politika [Energy policy], available at: <https://energypolicy.ru/novye-biznes-modeli-razvitiya-lokalnoj-energetiki-2/energetika/2024/13/18>.
2. Akvile G., Sigitas R., Mantas M., et al. Hybrid renewable energy systems – a review of optimization approaches and future challenges. Applied sciences, 2025, vol. 15, DOI:10.3390/app15041744.
3. Ren X., Li L., Ji B., et al. Design and analysis of solar hybrid combined cooling, heating and power system: A bi-level optimization model. Energy, 2024, vol. 292, DOI:10.1016/j.energy.2024.130362.
4. Alberizzi J., Frigola J.M., Rossi M., et al. Optimal sizing of a Hybrid renewable energy system: importance of data selection with highly variable renewable energy sources. Energy conversion and management, 2020, vol. 223, DOI:10.1016/j.enconman.2020.113303.
5. Alberizzi J., Frigola J.M., Rossi M. A MILP algorithm for the optimal sizing of an off-grid hybrid renewable energy system in South Tyrol. Energy reports, 2020, vol. 6, pp. 21-26, DOI:10.1016/j.egy.2019.08.012
6. Xu Ch., Ke Yi., Li Ya., et al. Data-driven configuration optimization of an off-grid wind/PV/hydrogen system based on modified NSGA-II and CRITIC-TOPSIS. Energy conversion and management, 2020, vol. 215, DOI:10.1016/j.enconman.2020.112892.
7. Nkalo U.K., Inya O.O., Obi, et al. A modified multi-objective particle swarm optimization (M-MOPSO) for optimal sizing of a solar–wind–battery hybrid renewable energy system. Solar compass, 2024, vol. 12, DOI:10.1016/j.solcom.2024.100082.
8. Ouederni R., Bouaziz B., Bacha F. Optimization of a hybrid renewable energy system based on meta-heuristic optimization algorithms. International journal of advanced computer science and applications, 2024, vol. 15, DOI:10.14569/IJACSA.2024.0150779.
9. Mahmoudi S.M., Maleki A., Ochbelagh D.R. Multi-objective optimization of hybrid energy systems using gravitational search algorithm. Scientific reports, 2024, vol. 15, DOI:10.1038/s41598-025-86476-z.
10. Mathaba T.N.D., Abo-Al-Ez Kh. Design of hybrid renewable energy systems: integrating multi-objective optimization into a multi-criteria decision-making framework. Engineering reports, 2024, vol. 7, DOI:10.1002/eng2.13074.
11. Sarad B., Deschinkel K., Moyne L.L., et al. Optimal integration of hybrid renewable energy systems for decarbonized urban electrification and hydrogen mobility. International journal of hydrogen energy, 2024, vol. 83, DOI:10.1016/j.ijhydene.2024.08.054.
12. Kusakana K., Vermaak H.J., Yuma G.P. Optimization of hybrid standalone renewable energy systems by linear programming. Advanced science letters, 2013, vol. 19, pp. 2501-2504(4) DOI:10.1166/asl.2013.4948.
13. Mahmoud F.S., Diab A., Ali Z.M., et al. Optimal sizing of smart hybrid renewable energy system using different optimization algorithms. Energy reports, 2022, vol. 8, pp. 4935-4956 DOI:10.1016/j.egy.2022.03.197.
14. Akbar Maleki, Fathollah Pourfayaz, Mohammad H. Ahmadi. Design of a cost-effective wind/photovoltaic/hydrogen energy system for supplying a desalination unit by a heuristic approach. Solar Energy, 2016, vol 139, pp. 666-675, DOI:10.1016/j.solener.2016.09.028.

15. Adefarati T., Potgieter S., Sharma G., et al. Optimization of renewable energy based hybrid energy system using evolutionary computational techniques. *Smart grids and sustainable energy*, 2025, vol.10, DOI:10.1007/s40866-025-00245-5.
16. Cheraghi R., Jahangir M.H. Multi-objective optimization of a hybrid renewable energy system supplying a residential building using NSGA-II and MOPSO algorithms. *Energy conversion and management*, 2023, vol. 294, DOI:10.1016/j.enconman.2023.117515.
17. Roy T.K., Saha S., Than Oo A.M. Optimizing hybrid energy systems for remote Australian communities: The role of tilt angle in cost-effective green hydrogen production. *Applied energy*, 2025, vol. 391, DOI:10.1016/j.apenergy.2025.125921.
18. Severina Y.D., Shakirov V.A. Optimizatsiya konfiguratsii gibridnogo energokompleksa s ispol'zovaniem geneticheskogo algoritma [Optimization of the configuration of a hybrid energy complex using a genetic algorithm]. IV Vserossiyskaya s mezhdunarodnym uchastiem molodezhnaya konferentsiya "Butakovskie chteniya", g. Tomsk, 10-12 dekabrya 2024 g. [IV All-Russian youth conference with international participation "Butakov Readings", Tomsk, December 10-12, 2024].
19. Tezer T. Multi-objective optimization of hybrid renewable energy systems with green hydrogen integration and hybrid storage strategies. *International journal of hydrogen energy*, 2025, vol. 142, pp. 1249-1271, DOI: 10.1016/j.ijhydene.2025.03.006.
20. Shakirov V.I., Popov I. Multi-criteria design of multi-energy system for remote area using NSGA-III and fuzzy TOPSIS. *Journal of renewable and sustainable energy*, 2024, vol. 16, DOI:10.1063/5.0215524.
21. Ming M., Wang R., Zha Y., et al. Multi-objective optimization of hybrid renewable energy system using an enhanced multi-objective evolutionary algorithm. *Energies*, 2017, vol. 10, DOI:10.3390/en10050674.
22. Deb K, Pratap A., Agarwal S., Meyarivan T. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 2002, vol. 6(2), pp. 182-197, DOI:10.1109/4235.996017.
23. Vikhtenko E.M., Zubkov D.V. Issledovanie algoritmov NSGA-III i AGE-MOEA-II dlya resheniya zadach mnogokriterial'noy optimizatsii [Study of NSGA-III and AGE-MOEA-II algorithms for solving multicriteria optimization problems]. *Inzhenernyy vestnik Dona [Engineering journal of Don]*, 2024, no. 6.
24. Zhang Q., Li H. A multi-objective evolutionary algorithm based on decomposition. *IEEE Transactions on Evolutionary Computation*, 2007, vol. 11, pp. 712-731, DOI:10.1109/TEVC.2007.892759.
25. Pyomo. Multi-objective optimization in Python, available at: <https://www.pyomo.org/>.
26. Perfect Indicator. Multi-objective optimization in Python, Pymoo, available at: <https://pymoo.org/misc/indicators.html>.
27. Collette Y., Siarry P. Three new metrics to measure the convergence of towards the Pareto frontier and the aesthetic of a set of solutions in biobjective optimization. *Computers & operations research*, 2005, vol. 32, pp. 773-792, DOI:10.1016/j.cor.2003.08.017.
28. Ishibuchi H., Masuda H., Tanigaki Y., et al. Modified distance calculation in generational distance and inverted generational distance. *Lecture notes in computer science*, 2015, pp. 110-125, DOI:10.1007/978-3-319-15892-1_8.
29. Zheng K., Yang R., Xu H., et al. A new distribution metric for comparing Pareto optimal solutions. *Structural and multidisciplinary optimization*, 2017, vol. 55, pp. 53-62, DOI:10.1007/s00158-016-1469-3.

Severina Yana Dmitrievna. PhD student, Melentiev energy systems institute SB RAS. AuthorID: 1121503, SPIN: 3075-3243, ORCID: 0009-0003-3685-7815, yan.sewerina2910@yandex.ru, 664043, Irkutsk, Lermontov St., 130.

Shakirov Vladislav Albertovich. Ph.D., head of the department of power supply and electrical engineering, Irkutsk National research technical university. AuthorID: 534444, SPIN: 2637-8522, ORCID: 0000-0001-8629-9549 shakirovva@ex.istu.edu, 664074, Irkutsk, Lermontov St., 83.

Статья поступила в редакцию 13.05.2025; одобрена после рецензирования 19.06.2025; принята к публикации 02.08.2025.

The article was submitted 05/13/2025; approved after reviewing 06/19/2025; accepted for publication 08/02/2025.