

УДК 004

Е.Е. Федоров¹, д-р техн. наук, проф.,
О.П. Мартынова², канд. техн. наук, доц.,
Э. Слесорайтите³, старший преподаватель¹Донецкая академия автомобильного транспорта, г. Донецк, Украина²Национальный авиационный университет, г. Киев, Украина³Вильнюсский университет, г. Вильнюс, Литва
fee75@mail.ru

Усовершенствование метаэвристических методов для решения задачи поиска оптимального маршрута

В данной работе рассматриваются такие метаэвристические методы поиска оптимального маршрута как генетический алгоритм, который основан на механизмах естественной эволюции, и алгоритм клонального отбора, основанный на особенностях иммунных систем. Для повышения вероятности выбора оптимального маршрута и уменьшения времени поиска в статье была осуществлена модификация операторов этих алгоритмов, которая использует имитацию отжига для учета начальных и конечных стадий работы алгоритмов. Для исследования разработанных модификаций в статье проведено численное исследование

Ключевые слова: генетический алгоритм, алгоритм клонального отбора, имитация отжига, искусственная иммунная система, поиск оптимального маршрута.

Введение

Постановка проблемы. В настоящее время город Донецк играет одну из ключевых ролей в транспортировке различных грузов. Он становится «воздушными воротами» между Западом и Востоком, через него проходят международные автомобильные магистрали и др. В этих условиях важную роль играет транспортная логистика. Одной из главных задач транспортной логистики является определение оптимального маршрута.

Анализ последних исследований и публикаций. В работах рассматриваются различные виды генетических алгоритмов [1-8] и алгоритмов клонального отбора [9-13], которые не учитывают начальные и конечные стадии их работы. Это приводит к увеличению времени поиска или низкой вероятности выбора оптимального маршрута.

Цель и задачи исследования. Целью работы является усовершенствование метаэвристических методов поиска оптимального маршрута для уменьшения времени поиска и увеличения вероятности выбора маршрута минимальной стоимости. Для достижения поставленной цели решаются задачи модификации существующих операторов генетического алгоритма и алгоритма клонального отбора.

1. Генетический алгоритм для решения задачи поиска оптимального маршрута

Для поиска оптимального маршрута вначале исследуется генетический алгоритм. На рис. 1 представлена структура генетического алгоритма.




Рисунок 1 – Структура генетического алгоритма

Построение генетического алгоритма предусматривает выполнение следующих этапов:

- создание исходной популяции;
- определение фитнес-функции;
- задание оператора репродукции;
- задание оператора кроссинговера;
- задание оператора мутации;
- задание оператора редукции;
- определение условия останова.

1.1. Представление особей и создание исходной популяции

В качестве хромосомы, которая представляет i -ю особь популяции $H = \{h_i\}$, выступает сгенерированный случайным образом вектор вершин (городов)

$$h_i = (h_{i1}, \dots, h_{iM}), \quad i \in \overline{1, |H|} \quad j \in \overline{1, M},$$

где $|H|$ – мощность популяции,

M – количество генов (вершин).

1.2. Фитнес-функция

Фитнес-функция (функция стоимости или функция цели) определяет приспособленность данной особи в популяции. На каждой итерации генетического алгоритма приспособленность каждой особи популяции оценивается с помощью фитнес-функции.

В случае поиска оптимального маршрута значение фитнес-функции для i -й хромосомы (вектора вершин) вычисляется как стоимость решения, т.е. длина маршрута, определенного множеством генов (вершин) h_i

$$F(h_i) = d_{h_{iM}, h_{i1}} + \sum_{j=1}^{M-1} d_{h_{ij}, h_{i,j+1}}, \quad i \in \overline{1, |H|},$$

где $d_{h_{ij}, h_{i,j+1}}$ – вес ребра $(h_{ij}, h_{i,j+1})$.

1.3. Оператор репродукции

Для отбора векторов вершин для скрещивания и мутации в качестве оператора репродукции используется предложенная в данной работе комбинация равновероятного отбора и линейно упорядоченного отбора с имитацией отжига. Вероятность выбора хромосомы (вектора вершин) определена в виде

$$P(h_i) = \frac{1}{|H|} \exp(-1/g(t)) + \frac{1}{|H|} \left(a - (2a-2) \frac{i-1}{|H|-1} \right) (1 - \exp(-1/g(t))),$$

$$g(t) = \beta g(t-1),$$

$$0 < \beta < 1, \quad g(0) = T_0, \quad T_0 > 0,$$

где β – параметр, управляющий скоростью сходимости,

T_0 – начальная температура,

t – номер итерации,

a – выбирается случайным образом из отрезка $[1, 2]$.

Таким образом, на ранних стадиях работы генетического алгоритма используется равновероятный отбор, обеспечивающий исследование всего пространства поиска (случайный выбор хромосом), а на заключительных стадиях используется линейно упорядоченный отбор, делающий поиск направленным (текущие лучшие хромосомы сохраняются). Эта комбинация не требует масштабирования и может использоваться при минимизации фитнес-функции.

1.4. Оператор кроссинговера

Для комбинирования двух вариантов вектора вершин отобранных оператором репродукции, в качестве оператора кроссинговера в статье используется следующий вариант двухточечного кроссинговера (частично соответствующий кроссинговер), состоящий из следующих этапов:

1. Случайно выбираются две точки скрещивания (две вершины), и производится обмен частями хромосом (векторов вершин) между точками скрещивания.

Например, если j, l – точки скрещивания и хромосомы родителей представлены как

$$h_1 = h_{11} \dots h_{1j} h_{1,j+1} \dots h_{1l} h_{1,l+1} \dots h_{1M}$$

$$h_2 = h_{21} \dots h_{2j} h_{2,j+1} \dots h_{2l} h_{2,l+1} \dots h_{2M},$$

то потомки будут представлены как

$$h_3 = h_{31} \dots h_{3j} h_{3,j+1} \dots h_{3l} h_{3,l+1} \dots h_{3M} =$$

$$= h_{11} \dots h_{1j} h_{2,j+1} \dots h_{2l} h_{1,l+1} \dots h_{1M}$$

$$h_4 = h_{41} \dots h_{4j} h_{4,j+1} \dots h_{4l} h_{4,l+1} \dots h_{4M} =$$

$$= h_{21} \dots h_{2j} h_{1,j+1} \dots h_{1l} h_{2,l+1} \dots h_{2M}.$$

2. Если в хромосоме h_3 ген (вершина) из диапазона генов $h_{31} \dots h_{3i}$ или $h_{3,j+1} \dots h_{3M}$ встречается в диапазоне генов $h_{3,i+1} \dots h_{3j}$, то осуществляется следующая замена

$$h_{3m} = h_{3n} \wedge m \in \{1, \dots, i\} \cup \{j+1, \dots, M\} \wedge n \in \{i+1, \dots, j\} \rightarrow h_{3m} = h_{4n}.$$

Если в хромосоме h_4 ген (вершина) из диапазона генов $h_{41} \dots h_{4i}$ или $h_{4,j+1} \dots h_{4M}$ встречается в диапазоне генов $h_{4,i+1} \dots h_{4j}$, то осуществляется следующая замена

$$h_{4m} = h_{4n} \wedge m \in \{1, \dots, i\} \cup \{j+1, \dots, M\} \wedge n \in \{i+1, \dots, j\} \rightarrow h_{4m} = h_{3n}.$$

Перед кроссинговером предварительно осуществляется выбор родителей посредством предложенной в данной работе комбинации аутбридинга и инбридинга с имитацией отжига.

При аутбридинге («далекое родство») первый родитель h_{first} выбирается случайно, а второй h_{second} – как максимально далекий от первого. Таким образом, выбор второго родителя можно представить в виде

$$h_{second} = \arg \max_{h_k} \rho(h_{first}, h_k).$$

Расстояние ρ между хромосомами в статье предлагается вычислить в виде

$$\rho(h_{first}, h_k) = \sum_{j=1}^N I(h_{first,j}, h_{kj}),$$

$$I(a, b) = \begin{cases} 1, & a \neq b \\ 0, & a = b \end{cases}.$$

При аутбридинге кроссинговер с имитацией отжига происходит с вероятностью

$$P_c = P_0 \exp(-1/g(t)), \quad g(t) = \beta g(t-1),$$

$$0 < \beta < 1, \quad g(0) = T_0, \quad T_0 > 0,$$

где P_0 – начальная вероятность кроссинговера.

При инбридинге («близкое родство») первый родитель выбирается случайно, а второй – как максимально близкий к первому либо. Таким образом, выбор второго родителя можно представить в виде

$$h_{second} = \arg \min_{h_k} \rho(h_{first}, h_k)$$

Расстояние ρ между хромосомами в статье предлагается вычислить аналогично аутбридингу.

При инбридинге кроссинговер с имитацией отжига происходит с вероятностью

$$P_c = P_0(1 - \exp(-1/g(t))), \quad g(t) = \beta g(t-1),$$

$$0 < \beta < 1, \quad g(0) = T_0, \quad T_0 > 0.$$

Таким образом, на ранних стадиях работы генетического алгоритма используется аутбридинг, обеспечивающий исследование всего пространства поиска, а на заключительных стадиях используется инбридинг, делающий поиск направленным. Эта комбинация не требует масштабирования и может использоваться при минимизации фитнес-функции.

После выбора родителей осуществляется скрещивание, и производятся два потомка.

Для глобального поиска оптимального вектора вершин необходимо повысить разнообразие вариантов.

1.5. Оператор мутации

Для обеспечения разнообразия вариантов вектора вершин после кроссинговера используется неоднородная мутация. Оператор мутации позво-

ляет получить новые хромосомы с резко отличающимися свойствами.

В статье используется следующий вариант генерации новой хромосомы (вектора вершин):

1. Случайно выбирается хромосома. Случайным образом выбираются два ее гена (вершины) $c1$ и $c2$, $c1 < c2$, причем выбор этих генов (вершин) продолжается до тех пор, пока не будет выполнено следующее условие:

$$c1 \notin U_{c2, \varepsilon} \wedge c2 \notin U_{c1, \varepsilon},$$

т.е. ген $c1$ не принадлежит ε -окрестности гена $c2$ и ген $c2$ не принадлежит ε -окрестности гена $c1$.

2. Создается новая хромосома путем модификации исходной хромосомы – гены исходной хромосомы находящиеся между генами $c1$ и $c2$, сортируются в обратном порядке.

В статье предлагается определить вероятность мутации хромосомы (вектора вершин) посредством имитации отжига в виде

$$P_m = P_0 \exp(-1/g(t)), \quad g(t) = \beta g(t-1),$$

$$0 < \beta < 1, \quad g(0) = T_0, \quad T_0 > 0,$$

где P_0 – начальная вероятность мутации.

Таким образом, на ранних стадиях работы генетического алгоритма с высокой вероятностью происходит мутация с большим шагом, что обеспечивает исследование всего пространства поиска, а на заключительных стадиях вероятность мутации и ее шаг стремятся к нулю, что делает поиск направленным.

1.6. Оператор редукции

Оператор редукции позволяет сформировать новую популяцию на основе предыдущей популяции и векторов вершин, полученных путем кроссинговера и мутации. В качестве оператора редукции в статье предлагается комбинация схемы на основе равновероятного отбора и селекционной схемы.

В случае схемы на основе равновероятного отбора особи предыдущей популяции и потомки объединяются. Случайным образом (с равной вероятностью) в новую популяцию отбирается $|H|$ особей, причем каждая особь может быть выбрана из объединения только один раз.

В случае селекционной схемы особи предыдущей популяции и потомки объединяются и упорядочиваются по значению фитнес-функции. В новую популяцию отбирается $|H|$ первых лучших особей.

Таким образом, на ранних стадиях работы генетического алгоритма используется схема на основе равновероятного отбора (случайный выбор хромосом), обеспечивающая исследование всего пространства поиска, а на заключительных стади-

ях используется селекционная схема, делающая поиск направленным (текущие лучшие хромосомы сохраняются). Эта комбинация не требует масштабирования и может использоваться при минимизации фитнес-функции.

Вероятность выбора схемы на основе равновероятного отбора определена посредством имитации отжига в виде

$$P_r = P_0 \exp(-1/g(t)), \quad g(t) = \beta g(t-1), \\ 0 < \beta < 1, \quad g(0) = T_0, \quad T_0 > 0,$$

где P_0 – начальная вероятность редукции.

Вероятность выбора селекционной схемы определена посредством имитации отжига в виде

$$P_r = P_0(1 - \exp(-1/g(t))), \quad g(t) = \beta g(t-1), \\ 0 < \beta < 1, \quad g(0) = T_0, \quad T_0 > 0.$$

1.7. Условие останова

В статье предлагается следующее условие останова

$$\min_i F(h_i) < \varepsilon \vee t \geq T$$

Значение ε и T вычисляются экспериментально.

2. Алгоритм клонального отбора для решения задачи поиска оптимального маршрута

Для поиска оптимального маршрута могут также использоваться искусственные иммунные системы. На рис. 2 представлена структура алгоритма клонального отбора. В отличие от генетического алгоритма этот алгоритм с одной стороны не используют оператор кроссинговера, а с другой стороны используют добавление случайных антигенов в популяцию.

Построение алгоритма клонального отбора предусматривает выполнение следующих этапов:

- создание исходной популяции антигенов;
- определение функции стоимости;
- задание оператора клонирования;
- задание оператора мутации;
- добавление новых антигенов;
- задание оператора редукции;
- определение условия останова.

2.1. Представление особей и создание исходной популяции

В качестве i -го антигена популяции $H = \{h_i\}$, выступает сгенерированный случайным образом вектор вершин (городов)

$$h_i = (h_{i1}, \dots, h_{iM}), \quad i \in \overline{1, |H|}, \quad j \in \overline{1, M},$$

где $|H|$ – мощность популяции,

M – количество компонентов антигенов (вершин).




Рисунок 2 – Структура алгоритма клонального отбора

2.2. Функция стоимости и аффинность

Функция стоимости (функция цели) определяет приспособленность данного антигена в популяции. На каждой итерации алгоритма клонального отбора приспособленность каждого антигена популяции оценивается с помощью функции стоимости.

В случае поиска оптимального маршрута значение функции стоимости для i -го антигена (вектора вершин) вычисляется как стоимость решения, т.е. длина маршрута, определенного множеством генов (вершин) h_i

$$F(h_i) = d_{h_{iM}, h_{i1}} + \sum_{j=1}^{M-1} d_{h_{ij}, h_{i,j+1}}, \quad i \in \overline{1, |H|},$$

где $d_{h_{ij}, h_{i,j+1}}$ – вес ребра $(h_{ij}, h_{i,j+1})$.

Аффинность определяет полезность антигена и вычисляется на основе функции полезности в виде

$$\Phi(h_i) = 1 - \frac{F(h_i) - \min_{i \in \overline{1, |H|}} F(h_i)}{\max_{i \in \overline{1, |H|}} F(h_i) - \min_{i \in \overline{1, |H|}} F(h_i)}, i \in \overline{1, |H|},$$

где $\Phi(h_i) \in [0, 1]$.

2.3. Оператор клонирования

Для отбора векторов вершин для мутации используется оператор клонирования. Этот оператор играет роль аналогичную оператору репродукции генетического алгоритма. В статье предлагается вариант оператора клонирования, состоящий из следующих шагов:

1. Упорядочение популяции таким образом, что первыми идут антитела, аффинность которых максимальна.

2. Вычисление количества клонов для каждого антитела популяции

$$q_i = \text{round} \left(\frac{g(t) - i}{g(t)} \alpha \right), i \in \overline{1, g(t)},$$

$$g(t) = \beta g(t-1),$$

$$0 < \beta < 1, g(0) = |H|,$$

где α – параметр клонирования, $\alpha > 0$,
 β – параметр, управляющий скоростью сходимости,

$\text{round}()$ – функция, округляющая число до ближайшего целого.

Таким образом, на ранних стадиях работы алгоритма клонального отбора для клонирования отбираются все антитела, что обеспечивает исследование всего пространства поиска, а на заключительных стадиях отбираются только лучшие, что делает поиск направленным.

В результате применения оператора клонирования формируется множество клонов антител.

2.4. Оператор мутации

Для обеспечения разнообразия вариантов вектора вершин после клонирования используется неоднородная мутация. Оператор мутации позволяет получить новые антитела с резко отличающимися свойствами. В отличие от генетического алгоритма мутации подвергаются все клоны.

В статье предлагается следующий вариант мутации клона (вектора вершин):

1. Из множества клонов выбирается очередной клон. Случайным образом выбираются две его компоненты (вершины) $c1$ и $c2$, $c1 < c2$, причем выбор этих компонент (вершин) продолжается до тех пор, пока не будет выполнено следующее условие:

$$c1 \notin U_{c2, \varepsilon} \wedge c2 \notin U_{c1, \varepsilon},$$

т.е. компонента $c1$ не принадлежит ε -окрестности компоненты $c2$ и компонента $c2$ не принадлежит ε -окрестности компоненты $c1$.

2. Создается новый клон путем модификации исходного клона – компоненты исходного клона находящиеся между компонентами $c1$ и $c2$, сортируются в обратном порядке.

3. Если новый клон отсутствует в множестве клонов мутантов \tilde{H} , то он включается в него.

2.5. Добавление новых антител

Для обеспечения разнообразия вариантов вектора вершин после мутации используется добавление новых антител. Такое добавление позволяет получить новые антитела с резко отличающимися свойствами.

В качестве i -го нового антитела выступает сгенерированный случайным образом вектор вершин

$$h_i = (h_{i1}, \dots, h_{iM}), i \in \overline{1, |\tilde{H}|}, j \in \overline{1, M},$$

где $|H|$ – мощность множества новых антител.

В статье предлагается определить вероятность добавления антител (вектора вершин) посредством имитации отжига в виде

$$P_a = P_0 \exp(-1/g(t)), g(t) = \beta g(t-1),$$

$$0 < \beta < 1, g(0) = T_0, T_0 > 0,$$

где P_a – начальная вероятность добавления.

Таким образом, на ранних стадиях работы алгоритма клонального отбора с высокой вероятностью происходит добавление антител, что обеспечивает исследование всего пространства поиска, а на заключительных стадиях вероятность добавления антител стремятся к нулю, что делает поиск направленным.

2.6. Оператор редукции

Оператор редукции позволяет сформировать новую популяцию на основе предыдущей популяции и векторов вершин, полученных путем мутации и добавления новых антител. В качестве оператора редукции в статье предлагается комбинация схемы на основе равновероятного отбора и селекционной схемы.

В случае схемы на основе равновероятного отбора антитела предыдущей популяции и потомки объединяются. Случайным образом (с равной вероятностью) в новую популяцию отбирается $|H|$ антител, причем каждое антитело может быть выбрана из объединения только один раз.

В случае селекционной схемы антитела предыдущей популяции и потомки объединяются и упорядочиваются по значению фитнес-функции.

В новую популяцию отбирается $|H|$ первых лучших антител.

Таким образом, на ранних стадиях работы алгоритма клонального отбора используется схема на основе равновероятного отбора (случайный выбор антител), обеспечивающая исследование всего пространства поиска, а на заключительных стадиях используется селекционная схема, делающая поиск направленным (текущие лучшие антитела сохраняются). Эта комбинация не требует масштабирования и может использоваться при минимизации функции стоимости.

Вероятность выбора схемы на основе равновероятного отбора определена посредством имитации отжига в виде

$$P_r = P_0 \exp(-1/g(t)), \quad g(t) = \beta g(t-1), \\ 0 < \beta < 1, \quad g(0) = T_0, \quad T_0 > 0,$$

где P_0 – начальная вероятность редукции.

Вероятность выбора селекционной схемы определена посредством имитации отжига в виде

$$P_r = P_0(1 - \exp(-1/g(t))), \quad g(t) = \beta g(t-1),$$

$$0 < \beta < 1, \quad g(0) = T_0, \quad T_0 > 0.$$

2.7. Условие останова

В статье предлагается следующее условие останова

$$\min_i F(h_i) < \varepsilon \vee t \geq T$$

Значение ε и T вычисляются экспериментально.

3. Численное исследование

В статье было проведено численное сравнение предложенных методов с существующими. Их структура представлена в табл. 1-2. В результате было установлено, что предложенные методы ускоряют процесс поиска на 20% и на 5% повышают вероятность выбора маршрута минимальной стоимости.

Таблица 1. Структура генетических алгоритмов трех типов

Операторы генетических алгоритмов	Типы генетических алгоритмов		
	Тип 1	Тип 2	Тип 3 (предложенный)
Репродукция	равновероятный отбор	линейно упорядоченный отбор	комбинация равновероятного и линейно упорядоченного отбора с имитацией отжига
Кроссинговер	частично упорядоченный, отбор особей – аутбридинг	частично упорядоченный, отбор особей – инбридинг	частично упорядоченный, отбор особей – комбинация аутбридинга и инбридинга с имитацией отжига
Мутация	перестановка двух соседних вершин	перестановка двух соседних вершин	перестановка в обратном порядке вершин, находящихся между двумя выбранными вершинами с имитацией отжига
Редукция	равновероятная схема	селекционная схема	комбинация равновероятной и селекционной схемы с имитацией отжига

Таблица 2. Структура алгоритмов клонального отбора трех типов

Операторы генетических алгоритмов	Типы алгоритмов клонального отбора		
	Тип 1	Тип 2	Тип 3 (предложенный)
Клонирование	обычное клонирование	обычное клонирование	клонирование с динамическим сокращением списка клонируемых антител
Мутация	перестановка двух соседних вершин	перестановка двух соседних вершин	перестановка двух соседних вершин
Добавление новых антител	обычное добавление	обычное добавление	добавление с имитацией отжига
Редукция	равновероятная схема	селекционная схема	комбинация равновероятной и селекционной схемы с имитацией отжига

Заключення

В данной работе были усовершенствованы метаэвристики, используемые для решения задачи поиска оптимального маршрута. Достоинством предложенной модификации генетического алгоритма является то, что на ранних стадиях его работы используется равновероятный отбор для оператора репродукции, аутбридинг для оператора кроссинговера и равновероятная схема оператора редукции, что обеспечивает исследование всего пространства поиска (случайный выбор хромосом), а на заключительных стадиях используется линейно упорядоченный отбор для оператора репродукции, инбридинг для оператора кроссинговера и селекционная схема оператора редукции, делающие поиск направленным (текущие лучшие хромосомы сохраняются). Кроме того, предложенная модификация не требует масштабирования и может использоваться при минимизации фитнес-функции, что важно

при поиске минимального маршрута. Достоинством предложенной модификации алгоритма клонального отбора является то, что на ранних стадиях его работы клонируются все антитела, осуществляется добавление новых антител и применяется равновероятная схема, что обеспечивает исследование всего пространства поиска, а на заключительных стадиях клонируются только лучшие антитела, не добавляются новые антитела и применяется селекционная схема, что делает поиск направленным. Обе модификации позволили повысить скорость поиска на 20%, а вероятность выбора оптимального маршрута на 5%.

Предложенные усовершенствованные метаэвристики могут применяться в автоматических и автоматизированных компьютерных системах для расчета оптимального маршрута для решения логистических и коммуникационных задач.

Список литературы

1. Скобцов Ю.А. Основы эволюционных вычислений / Ю.А. Скобцов. – Донецк: ДонНТУ, 2008. – 326 с.
2. Holland J.H. Adaptation in natural and artificial systems / J.H. Holland. – Cambridge, Michigan: MIT Press, 1992. – 228 p.
3. Федоров Е.Е. Методология создания мультиагентной системы речевого управления: монография / Е.Е. Федоров. – Донецк: изд-во «Ноулидж», 2011. – 356 с.
4. Mitchell M. An introduction to Genetic Algorithms / M. Mitchell. – Massachusetts: A Bradford Book The MIT Press, 1996. – pp. 162.
5. Evolutionary Computation. Basic Algorithms and Operators (ed. T. Back, D.B. Fogel, Z. Michalewicz). – Bristol: Institute of Physics Publishing, 2000. – 339 p.
6. Intelligent Hybrid Systems: Fuzzy Logic, Neural Networks, and Genetic Algorithm / Ed. Da Ruan. – Boston: Kluwer Academic Publishers, 1997. – 258 p.
7. Рутковская Д. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская, М. Пилиньский, Л. Рутковский. – М.: Горячая линия – Телеком, 2006. – 452 с.
8. Комарцова Л.Г. Нейрокомпьютеры / Л.Г. Комарцова, А.В. Максимов. – М.: Изд-во МГТУ им. Н.Э. Баумана, 2002. – 320 с.
9. Lucinska M. Hybrid Immune Algorithm for Multimodal Function Optimization / M. Lucinska, S.T. Wierzchon // Recent Advances in Intelligent Information Systems. – 2009. – Vol. 30. – 301-313 p.
10. De Castro L.N. Learning and Optimization Using the Clonal Selection Principle / L.N. De Castro, F.J. Von Zuben // IEEE Transactions on Evolutionary Computation. – 2002. – Vol. 6, No. 3. – 231-259 p.
11. Yildiz A.R. A novel hybrid immune algorithm for global optimization in design and manufacturing // Robotics and Computer-Integrated Manufacturing. – 2009. – Vol. 25. – 261-270 p.
12. Agiza H.N. An Improved Version of opt-AiNet Algorithm (I-opt-AiNet) for Function Optimization / H.N. Agiza, A.E. Hassan, A.M. Salah // IJCSNS International Journal of Computer Science and Network Security. – 2011. – Vol. 11, No. 3. – 80-85 p.
13. Дасгупта, Искусственные иммунные системы и их применение / Д. Дасгупта. – М.: ФИЗМАТЛИТ, 2006. – 344 с.
14. Perelson A.S. Theoretical studies of clonal selection: Minimal antibody repertoire size and reliability of self-nonsel discrimination / A.S. Perelson, G.F. Oster // Journal Theoretical Biology. – 1979. – Vol. 81, No. 4. – 645-670 p.
15. Ada G.L. The clonal selection theory / G.L. Ada, G. Nossal // Science America. – 1987. – Vol. 257, No. 2. – 50-57 p.

Надійшла до редакції 01.04.2013

Є.С. ФЕДОРОВ¹, О.П. МАРТИНОВА², Е. СЛЕСОРАЙТИТЕ³¹ Донецька академія автомобільного транспорту² Національний авіаційний університет³ Вільнюський університет**УДОСКОНАЛЕННЯ МЕТАЕВРИСТИЧНИХ МЕТОДІВ ДЛЯ РІШЕННЯ ЗАВДАННЯ ПОШУКУ ОПТИМАЛЬНОГО МАРШРУТУ**

У даній роботі розглядаються такі метаевристичні методи пошуку оптимального маршруту як генетичний алгоритм, що заснований на механізмах природної еволюції, і алгоритм клонального відбору, заснований на особливостях імунних систем. Для підвищення ймовірності вибору оптимального маршруту й зменшення часу пошуку в статті була здійснена модифікація операторів цих алгоритмів, що використовує імітацію відпалу для обліку початкових і кінцевих стадій роботи алгоритмів. Для дослідження розроблених модифікацій у статті проведено чисельне дослідження.

Ключові слова: *генетичний алгоритм, алгоритм клонального відбору, імітація відпалу, штучна імунна система, пошук оптимального маршруту.*

Ye.Ye. FEDOROV¹, O.P. MARTYNOVA², E. SLIESORAITYTE³¹ Donetsk Academy of Motor Transport² National Aviation University² Vilnius University**IMPROVEMENT OF METAHEURISTIC METHODS FOR SOLVING THE PROBLEM OF OPTIMUM ROUTE SEARCH**

Now the city of Donetsk plays one of the key roles in transportation of various cargoes. It becomes the "air gate" between the West and the East, international automobile highways pass through this city, etc. In these conditions the important role is played by transport logistics. One of the main tasks of transport logistics is to find the optimum route between points. This task employs such artificial intelligence methods as Hopfield neural network, annealing imitation method, tabu search, ant algorithm, genetic algorithm, clonal selection algorithm, etc. The latter two have been improved in this work. The advantage of the offered genetic algorithm updating is that at early stages of its work equiprobable selection for the reproduction operator, outbreeding for the crossingover operator and the equiprobable scheme of the reduction operator are used. That ensures examination of the entire search space (random selection of chromosomes), and at final stages linearly ordered selection for the reproduction operator, inbreeding for the crossingover operator and the selection scheme of the reduction operator are used; it makes the search guided (current best chromosomes remain). Besides, the offered updating does not require scaling and can be used in case of fitness function minimization that is important for the minimum route search. The advantage of the offered updating of the clonal selection algorithm is that at early stages of its work all antibodies are cloned, new antibodies are added and the equiprobable scheme is applied. It ensures examination of the entire search space and at final stages only the best antibodies are cloned, new antibodies are not added and the selection scheme is used, which makes the search guided. The both updating have increased the speed of search by 20 %, and the probability the optimum route choice by 5 %. The offered improved metaheuristics can be applied in automatic and automated computer systems for optimum route calculation when solving logistic and communication problems.

Key words: *genetic algorithm, clonal selection algorithm, annealing imitation, artificial immune system, optimum route search.*