

Моделирование алгоритмов формирования расписаний решения масштабируемых задач на распределённых вычислительных системах^{*)}

А. В. Ефимов, С. Н. Мамойленко, Е.Н. Максимова

Государственное образовательное учреждение
высшего профессионального образования
«Сибирский государственный университет телекоммуникаций и информатики»
{efimov, msn, e_maksimova}@spct.sibsutis.ru

Представлены алгоритмы формирования расписаний решения масштабируемых задач на распределённых вычислительных системах. Рассмотрены генетический алгоритм и алгоритм Monte-Carlo, в основу которых положен метод формирования укрупненных задач (пакетов). При формировании расписаний учитываются предпочтения пользователей на выбор значений параметров задач. Приведены результаты моделирования алгоритмов.

Ключевые слова: распределённые вычислительные системы, оптимизация функционирования.

1. Введение

Распределённые вычислительные системы (ВС) относятся к перспективным средствами обработки информации [1]. Основным функциональным элементом распределённой ВС является элементарная машина (ЭМ). Структура ЭМ допускает варьирование от процессорного ядра до конфигураций, включающих универсальные процессоры и специализированные ускорители (например, GPGPU). Количество ЭМ в распределённых ВС может изменяться в широких пределах: от десятка до сотен тысяч. Широкое распространение получили распределённые ВС, в которых в качестве функциональных элементов используются ЭВМ (в частности, обычные персональные компьютеры или специализированные серверы). Такие системы принято называть кластерными. В списке Top500 суперкомпьютеров кластерные системы составляют 84.8 % [2]. Следует отметить, что основы построения распределённых ВС (включая доказательство принципиальной возможности построения систем в условиях запаздывания сигналов) впервые были изложены в 1962 г. в Сибирском отделении АН СССР [3].

Эффективность функционирования ВС в немалой степени зависит от способа управления её ресурсами. Принято выделять три режима функционирования ВС: решение одной сложной задачи, обработка наборов задач и обслуживание потоков задач [1]. Два последних режима являются мультипрограммными, они основываются на распределении ресурсов ВС между несколькими одновременно решаемыми задачами. Повышение эффективности эксплуатации ресурсов распределённых ВС связано именно с использованием технологии параллельного мультипрограммирования [1, 4].

Одной из актуальных проблем организации функционирования ВС в мультипрограммных режимах является планирование решения пользовательских задач, представленных параллельными программами. Суть планирования заключается в формировании расписаний решения задач, то есть в определении для каждой задачи времени начала решения и необходимых ресурсов ВС. В общем

^{*)}Работа выполнена в рамках междисциплинарного проекта № 113 СО РАН и при поддержке РФФИ (гранты № 08-07-00022, 09-07-0095) и Совета по грантам Президента РФ (ведущая научная школа НШ-5176.2010.9).

случае проблема планирования является трудноразрешимой [5]. Поэтому перспективной считается разработка приближённых методов и эвристических алгоритмов управления ресурсами ВС.

Повысить эффективность ВС и снизить время нахождения задач в очереди возможно, если, в частности, каждая из них допускает решение на различных конфигурациях вычислительных ресурсов. В этом случае задачи называют *масштабируемыми* или пластичными (moldable) [4]. Исследования пользовательских запросов показывают, что свойством масштабируемости обладают более 80 % задач [6].

Описывая масштабируемую задачу, пользователь задает допустимые значения для её параметров. Для любой задачи, предназначенной для решения на распределённой ВС, задаются как минимум два параметра: ранг (т.е. количество ЭМ, необходимых для её решения) и требуемое (максимально допустимое) время решения. При этом какие-то значения параметров задачи могут быть более предпочтительными по отношению к другим значениям. Предпочтения значений определяется природой решаемой задачи или иными соображениями пользователя. Кроме этого, могут задаваться и другие параметры (например, штраф за задержку решения задачи, дополнительные характеристики ресурсов ВС).

В данной работе представлены алгоритмы формирования расписаний решения масштабируемых задач на распределённых ВС (с учётом пожеланий пользователей на выбор значений параметров) и результаты их моделирования. В основу алгоритмов положен метод формирования укрупнённых задач (пакетов) [7].

2. Постановка задачи

Имеются распределённая ВС, состоящая из N элементарных машин, и набор $I = \{I_i\}$ независимых задач, $i = \overline{1, L}$. Каждая задача характеризуется вектором $P_i = \{p_i^k\}$. Элементы вектора $p_i^k = (r_i^k, t_i^k, w_i^k)$ задают для задачи I_i допустимые значения ранга r_i и времени решения t_i и определяют приоритет w_i^k выбора этих значений, $0 < r_i^k \leq N, t_i^k > 0, w_i^k > 0, k = \overline{1, q_i}, q_i = |P_i|$. “Удовлетворённость” пользователя выбором для задачи значений с приоритетом w_i^k оценивается как $w_i^k / \max_k w_i^k$. Допускается существование в векторе P_i нескольких элементов с одинаковым приоритетом. Считается, что в наборе присутствуют задачи с различным количеством q_i допустимых значений параметров и возможно взаимодействие ЭМ с любой другой машиной ВС; зависимости величин t_i^k, r_i^k, w_i^k, c_i друг от друга отсутствуют.

Необходимо для каждой задачи I_i набора выбрать: k_i – номер элемента вектора P_i , и s_i – время начала решения задачи, а также выделить подсистему $J_i = \{j \in E_1^N\}$ машин ВС, где $0 < k_i \leq q_i, s_i \geq 0, j$ – номер ЭМ, $E_1^N = \{1, 2, \dots, N\}, |J_i| = r_i^{k_i}$. В результате будет сформирован вектор $S = \langle (k_i, s_i, J_i) \rangle, i = \overline{1, L}$, называемый *расписанием решения задач* на ВС. Характеристиками расписания являются: время $T(S)$ решения всех задач набора.

Требуется найти расписание S^* решения задач на вычислительной системе такое, чтобы:

$$T(S^*) = \min_{S \in \Omega} T(S), \quad T(S) = \max_{i=\overline{1, L}} \{s_i + t_i^{k_i}\} \quad (1)$$

при ограничениях:

$$\forall i \in \{1, 2, \dots, L\}, |J_i| = r_i^{k_i} \text{ и } \forall j_1 \in J_i, \forall j_2 \in J_i \setminus \{j_1\} \Rightarrow j_1 \neq j_2 \quad (2)$$

$$\forall t \geq 0, \bigcap_{i \in \mathcal{E}(t)} J_i = \emptyset, \sum_{i \in \mathcal{E}(t)} r_i^{k_i} \leq N, \quad (3)$$

$$L^{-1} \sum_{i=1}^L \frac{w_i^{k_i}}{\max_k w_i^k} \geq e, \quad (4)$$

где Ω – множество допустимых расписаний $S, \mathcal{E}(t) = \{i \in \{1, 2, \dots, L\} | s_i \leq t \leq s_i + t_i^{k_i}\}$ – множество номеров задач, решаемых в момент времени $t; e$ – минимально допустимая средняя “удовлетворён-

ность” пользователей. Ограничение (3) определяет, что каждой задаче с учётом выбранных значений параметров должно быть выделено столько ЭМ, сколько требуется для её решения. Ограничение (4) гарантирует, что в каждый момент времени задачи решаются на непересекающихся подсистемах ЭМ и их суммарный ранг не превосходит количества машин ВС.

3. Алгоритмы формирования укрупненных задач

Множество задач набора разбивается на подмножества или укрупненные задачи [7] таким образом, чтобы выполнялись ограничения (2) – (4) и достигался минимум функции (1). Сформировать разбиение возможно, например, с использованием алгоритмов ортогональной упаковки прямоугольных объектов без поворотов и пересечений [9]. При этом задача кодируется прямоугольным объектом с высотой, равной рангу задачи, и шириной, соответствующей запрашиваемому времени. В данной работе для упаковки использован алгоритм FFDH [9]. Очевидно, что в случае разбиения масштабируемых задач процедура упаковки усложняется выбором одного из допустимых размеров прямоугольника.

Формально постановка задачи приобретает следующий вид. Решением является тройка $S_1 = (K, M, \mathfrak{S})$, где $K = \langle k_i \rangle$ – вектор выбранных для задач значений k_i , $\mathfrak{S} = \{\mathfrak{S}_m\}$ – множество укрупнённых задач $\mathfrak{S}_m = \{I_i \in I\}$, $m = \overline{1, M}$, $M = |\mathfrak{S}|$ – количество укрупнённых задач. Требуется определить решение: S_1^* такое, чтобы

$$T(S_1^*) = \min_{S_1 \in \Omega_1} T(S_1), \quad T(S_1) = \sum_{m=1}^M T_m, \quad T_m = \max_{i \in \Phi(m)} t_i^{k_i} \quad (5)$$

при ограничениях:

$$\bigcup_{m=1}^M \mathfrak{S}_m = \mathfrak{S}, \quad \bigcap_{m=1}^M \mathfrak{S}_m = \emptyset, \quad (6)$$

$$R_m \leq N, \quad R_m = \sum_{i \in \Phi(m)} r_i^{k_i}, \quad (7)$$

где Ω_1 – область допустимых решений S_1 , R_m – суммарный ранг задач каждого подмножества \mathfrak{S}_m , $\Phi(m) = \{i \in \{1, 2, \dots, L\} | I_i \in \mathfrak{S}_m\}$ – множество номеров задач, помещённых в m -ое подмножество.

При выборе для задач значений k_j необходимо контролировать выполнение ограничения (5). Представим набор задач I в следующем виде: $I^0 \cup I^1 \cup I^2$, где I^0 – подмножество задач набора с одним элементом вектора P_i ; I^1 – подмножество задач набора, у которых все элементы вектора P_i имеют одинаковый приоритет; I^2 – остальные задачи набора; $I^0 \cap I^1 \cap I^2 = \emptyset$. Тогда ограничение (4) можно представить в следующем виде:

$$L^{-1} \left(\sum_{I_i \in I^0} \frac{w_i^{k_i}}{\max_k w_i^k} + \sum_{I_i \in I^1} \frac{w_i^{k_i}}{\max_k w_i^k} + \sum_{I_i \in I^2} \frac{w_i^{k_i}}{\max_k w_i^k} \right) \geq e. \quad (8)$$

Очевидно, что для задач из подмножества I^0 выбирать значения параметров нет необходимости и первое слагаемое выражения (8) всегда равно $|I^0|$. Второе слагаемое выражения (8) также равно $|I^1|$ при любом выборе значений параметров для задач из этого подмножества. На выполнение ограничения (4) влияет лишь выбор значений параметров для задач из подмножества I^2 .

Утверждение 1. Если $|I^0| + |I^1| \geq eL$ или $\frac{\min_{I_i \in I^2} \min_k w_i^k}{\max_{I_i \in I^2} \max_k w_i^k} \geq \frac{eL - |I^0| - |I^1|}{|I^2|}$, то ограничение (4) выполняется при любом выборе значений параметров для задач подмножества I^2 .

Доказательство. В силу того, что первое и второе слагаемые выражения (8) всегда равны соответственно $|I^0|$ и $|I^1|$, то выражение можно преобразовать следующим образом: $\sum_{i \in I^2} \frac{w_i^{k_i}}{\max_k w_i^k} \geq eL - |I^0| - |I^1|$. Очевидно, что это неравенство всегда верно, если $|I^0| + |I^1| \geq eL$.

Далее. Рассмотрим самый худший вариант. Пусть каждая задача подмножества I^2 имеет элементы $p_i^{k_1}$ и $p_i^{k_2}$ соответственно с минимально и максимально возможным (для данного набора задач) приоритетом, и элемент $p_i^{k_1}$ выбирается для решения. Тогда выражение (8) можно записать в следующем виде: $|I^2| \frac{\min_{I_i \in I^2} \min_k w_i^k}{\max_{I_i \in I^2} \max_k w_i^k} \geq eL - |I^0| - |I^1|$. Утверждение доказано.

Если утверждение 1 не выполняется, то используем следующую процедуру. Считаем, что для задач уже были выбраны значения параметров (либо удовлетворяющие ограничению (4), либо с наивысшим приоритетом).

Шаг 1. Для задач подмножества I^1 значения k_i выбираются произвольно.

Шаг 2. Вычисляются значения средней “удовлетворённости” пользователей при решении задач набора согласно текущему выбору параметров.

Шаг 3. Произвольно выбирается задача из подмножества I^2 и новое значение k_i для неё.

Шаг 4. Если изменение приоритета значений параметров задачи не приводит к нарушению условия (5), то фиксируется k_i и осуществляется переход к шагу 2; в противном случае значение k_i для выбранной задачи не меняется.

Шаг 5. Процедура продолжается до тех пор, пока не будет перебраны все задачи подмножества I^2 .

3.2. Алгоритм на основе метода цепей Монте-Карло

Алгоритм на основе метода цепей Монте-Карло [10] – итерационный. На каждой итерации случайным образом выбираются значения k_i так, чтобы удовлетворять ограничению (4), и формируются укрупнённые задачи алгоритмом FFDH. Итерации повторяются до тех пор, пока на заданном количестве итераций не будет найдено разбиение задач набора с меньшим значением функции (5).

3.3. Генетический алгоритм

Генетический алгоритм предусматривает последовательность жизненных циклов популяции. Каждый цикл состоит из следующих операций: выбора пар особей, их размножения, мутации и селекции наиболее приспособленных особей (формирования новой популяции). Процесс повторяется до тех пор, пока на протяжении заданного количества популяций не будет появляться особь с лучшим значением функции приспособленности. Итоговое разбиение задач набора формируется из особи, имеющей наилучшее значение функции приспособленности.

В терминах генетических алгоритмов [11] будем считать:

- *ген* – укрупнённая задача (пакет);
- *особь* или *хромосома* – допустимое разбиение задач набора при фиксированных значениях k_i ;
- *популяция* – несколько особей с различными значениями k_i ;
- *функция приспособленности особи* – значение функции (5) для соответствующего разбиения задач набора.

Размер популяции задаётся параметром алгоритма и остаётся постоянным в процессе всей эволюции.

Начальная популяция формируется следующим образом. Первая особь выбирает для каждой задачи k_i такое, при котором значения параметров имеют наивысший приоритет w_i^k , вторая – минимум запрашиваемых ресурсов $r_i t_i$ и третья – максимум “удельной площади” $w_i^k / (r_i^k t_i^k)$. Остальные особи выбирают k_i произвольно, так, чтобы удовлетворять ограничению (5). Далее каждая особь формирует укрупнённые задачи, используя алгоритм FFDH. В итоге начальную популяцию составляют те особи, для которых выполняются ограничения (2) – (4).

На каждом жизненном цикле из популяции выбирается несколько пар. Количество пар равняется половине от количества особей в популяции. Для формирования пары из популяции случайным образом выбирается одна особь. Парой для неё выбирается особь, наиболее удалённая от неё по значению функции приспособленности и не состоящая в других парах.

Далее над каждой выбранной парой с заданной вероятностью либо выполняется оператор кроссинговера, либо производится мутация родительских особей.

В качестве оператора кроссинговера предлагается алгоритм, в основу которого положен метод перетасовки генов [12]:

- Шаг 1. Гены родительских особей помещаются в общий контейнер и сортируются по критерию раскроя $((R_m T_m)^{-1} \sum_{i \in \Phi(m)} r_i^{k_i} t_i^{k_i})$.
- Шаг 2. Если в контейнере имеются одинаковые гены (с полностью одинаковыми задачами), то из двух генов удаляется тот, которому соответствует меньшее значение раскроя.
- Шаг 3. Полученная последовательность генов просматривается до тех пор, пока не встретиться ген, в котором присутствует хотя бы одна задача, входящая в ранее просмотренные гены. Если такой ген не найден (т.е. просмотрен весь контейнер), то алгоритм завершается.
- Шаг 4. Оставшиеся гены контейнера расформируются. Из получившихся задач удаляются повторяющиеся или присутствующие в не расформированных генах.
- Шаг 5. Из оставшихся задач по алгоритму FFDH создаются новые гены и помещаются обратно в контейнер.

В результате из генов контейнера получается новая особь, унаследовавшая от своих родителей лучшие гены.

Мутация с заданной вероятностью (задается параметром алгоритма) выполняется над одной или двумя родительскими особями. Оператор мутации с равной вероятностью либо случайным образом изменяет значения параметров задач, гарантируя выполнение ограничения (5), либо выбирает, для заданной доли задач особи, значения параметров, имеющие максимальный приоритет.

В результате от каждой пары создаются одна или две изменённые особи “потомков”, которые могут не выжить, если для них по каким-либо причинам не выполняются ограничения (2) – (4). В новую популяцию попадают родительские и “выжившие потомки”, имеющие наилучшие показатели функции приспособленности.

4. Формирование итогового расписания

Итоговое расписание $S^* = \langle (k_i, s_i, J_i) \rangle$ формируется исходя из S_1^* следующим образом. Для k_i используются значения из S_1^* . Время начала решения s_i определяется началом решения пакета, в который она была помещена. Время s_r^* начала решения пакета определяется последовательностью решения пакетов: $s_r^* = \sum_{l=1}^{r-1} T_{m_l}$, $s_1^* = 0$. Итак, $\forall m \in \{1, 2, \dots, M\}$, $\forall i \in \Phi(m)$, $s_i = s_m^*$. Машины ВС распределяются между задачами каждого пакета в соответствии с требованиями.

5. Моделирование и результаты

Моделирование и численные эксперименты осуществлялись с использованием ресурсов пространственно-распределённой мультикластерной вычислительной системы Центра параллельных вычислительных технологий ГОУ ВПО “Сибирский государственный университет телекоммуникаций и информатики” [13]. Предложенные алгоритмы реализованы с использованием языка программирования C++. Компиляция программ осуществлялась GNU\GCC с указанием максимально возможной степени оптимизации (-O3). Наборы задач генерировались для систем с количеством ЭМ от 2^1 до 2^{20} на основе модели рабочей загрузки, предложенной в работе [14]. Рассматривались наборы с количеством задач 10, 100, 1000 и 10000. Приоритеты значениям параметров задач задавались путём их простой нумерации.

Процедура моделирования алгоритмов состояла из двух этапов: анализ влияния параметров алгоритмов на качество получаемого решения и сравнение алгоритмов между собой. Под качеством получаемого решения понимаем: полученное значение функции $T(S)$, средняя удовлетворённость

пользователей и уровень загрузки вычислительных ресурсов (коэффициент раскроя) при решении задач по сформированному расписанию.

5.1. Анализ влияния параметров алгоритмов на качество формируемых расписаний решения задач

Для алгоритма Монте-Карло на качество решения влияет один параметр: количество итераций (обозначим его как $STEPS_{MC}$), на которых не получается расписание с лучшим значением функции $T(S)$. Генетический алгоритм требует задания трёх параметров: количества жизненных циклов популяций без улучшения потомства (обозначим как $STEPS_{GA}$), размера популяции (обозначим как PS_{GA}), вероятности выполнения кроссинговера и мутации (обозначим как P_{GA}). Кроме этого, оба алгоритма зависят от минимально-допустимой средней удовлетворённости пользователей (обозначим как e).

В результате моделирования установлено, что в данных условиях:

1. Для любого минимально допустимой средней “удовлетворённости” пользователей e оптимальным значением для $STEPS_{MC}$ является 100, а для $STEPS_{GA}$ – 5. При дальнейшем увеличении значения $STEPS_{MC}$ и $STEPS_{GA}$ время работы алгоритмов растёт, а качество получаемого решения практически не изменяется (рис. 1). $T_{FFD}(S)$ – это время решения задач по расписанию, для формирования которого задачам назначены значения параметров с максимальным приоритетом и однократно выполнен алгоритм FFDH.
2. С увеличением значения параметра e уменьшается время работы алгоритмов. Это связано с тем, что количество вариантов значений параметров с увеличением e сокращается (рис. 2).
3. Наилучшим размером популяции PS_{GA} является 32 особи для любого значения минимально допустимой средней “удовлетворённости” пользователей (рис. 3).
4. Вероятность выполнения операторов кроссинговера и мутации не влияет на качество получаемого решения (рис. 4).

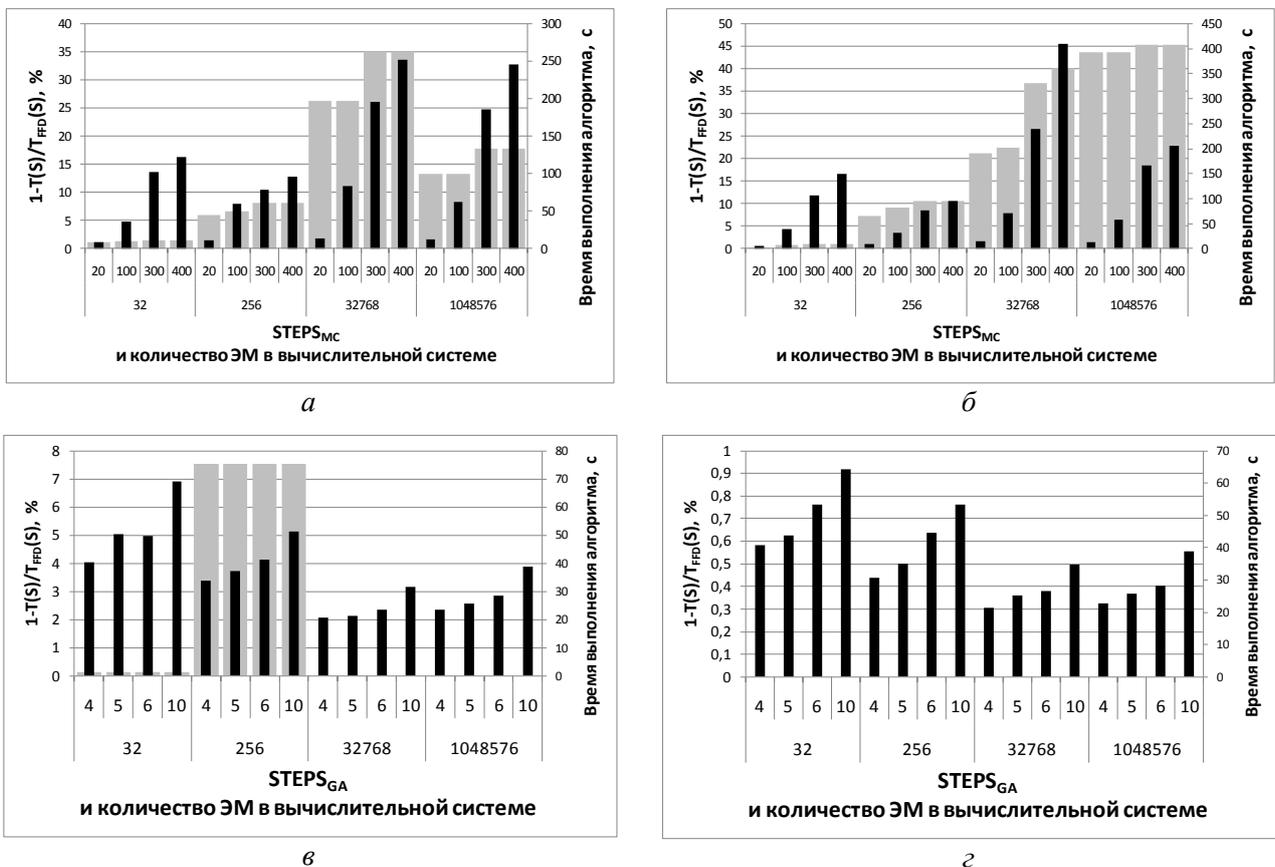


Рис.1. Влияние параметров $STEPS_{MC}$ и $STEPS_{GA}$ соответственно на качество работы алгоритма Монте-Карло (а и б) и генетического алгоритма (в и г), ($L = 10000$, $PS_{GA} = 32$, $P_{GA} = 0.8$, а и в – $e = 0.50$, г и д – $e = 0.95$),

■ – улучшение значения функции $T(S)$, %, ■ – время работы алгоритма, сек



a



б

Рис.2. Влияние e на время работы алгоритмов, *a* – Монте-Карло, *б* – генетический алгоритм, $L = 10000$, $STEPS_{MC} = 100$, $STEPS_{GA} = 5$, $PS_{GA} = 32$, $P_{GA} = 0.8$,
 $e = \dots \blacklozenge \dots - 0.50$, $- \blacksquare - 0.75$, $- \blacktriangle - 0.90$, $- \times \cdot - 0.95$, $- * - 1.00$.



a



б

Рис. 3. Влияние размера популяции на качество работы генетического алгоритма ($L = 10000$, $STEPS_{GA} = 5$, $P_{GA} = 0.8$, *a* – $e = 0.50$ и *б* – $e = 0.95$),
■ – улучшение значения функции $T(S)$, %, ■ – время работы алгоритма, сек

5.2. Сравнение эффективности алгоритма Монте-Карло и генетического алгоритма

Алгоритмы сравнивались между собой по следующим критериям:

- $K_1 = 1 - \frac{T_{MC}}{T_{GA}}$, где T_{MC} и T_{GA} – соответственно, время работы программы, реализующей алгоритм Монте-Карло и генетический алгоритм;
- $K_2 = 1 - \frac{T_{MC}(S)}{T_{GA}(S)}$, где $T_{MC}(S)$ и $T_{GA}(S)$ – время решения задач по расписанию сформированному, соответственно, алгоритмом Монте-Карло и генетическим алгоритмом;
- $K_3 = 1 - \frac{F_{GA}(S)}{F_{MC}(S)}$, где $F_{MC}(S)$ и $F_{GA}(S)$ – итоговая средняя “удовлетворённость” пользователей (согласно неравенству (4)) при решении задач по расписанию, сформированному, соответственно, алгоритмом Монте-Карло и генетическим алгоритмом;

- $K_4 = 1 - \frac{U_{GA}(S)}{U_{MC}(S)}$, где $U_{MC}(S)$ и $U_{GA}(S)$ – степень использования ресурсов ВС при решении задач по расписанию сформированному, соответственно, алгоритмом Монте-Карло и генетическим алгоритмом. $U(S) = \frac{\sum_i r_i^{k_i} t_i^{k_i}}{T(S)N}$ – коэффициент раскрытия.
- Очевидно, что чем больше значение критерия, тем лучше результаты алгоритма Монте-Карло, и наоборот. Абсолютное значение соответствующего критерия определяет, во сколько раз результаты одного алгоритма лучше по сравнению с другим. Некоторые результаты моделирования представлены на рис. 5.
- В результате моделирования можно сделать вывод, что в данных условиях алгоритмы Монте-Карло и генетический алгоритм имеют примерно одинаковую эффективность.

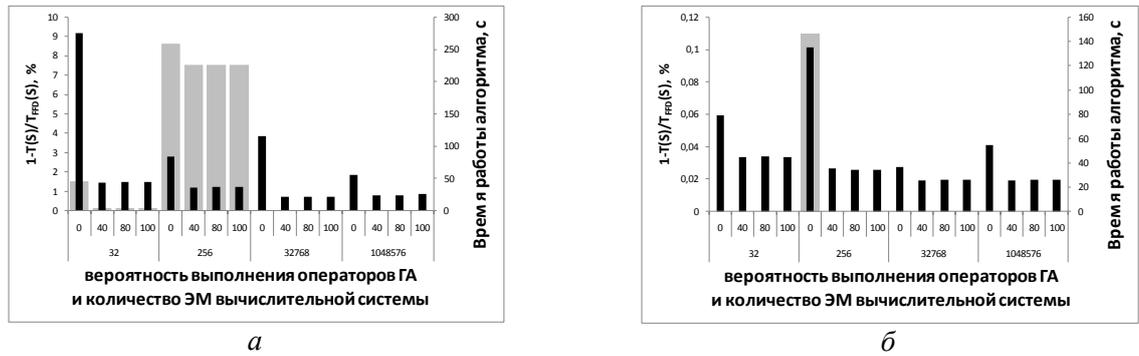


Рис. 4. Влияние вероятности выполнения операторов кроссинговера и мутации на качество работы генетического алгоритма ($L = 10000$, $PS_{GA} = 32$, $a - e = 0.5$, $b - e = 0.95$)
 ■ – улучшение значения функции $T(S)$, %, ■ – время работы алгоритма, сек

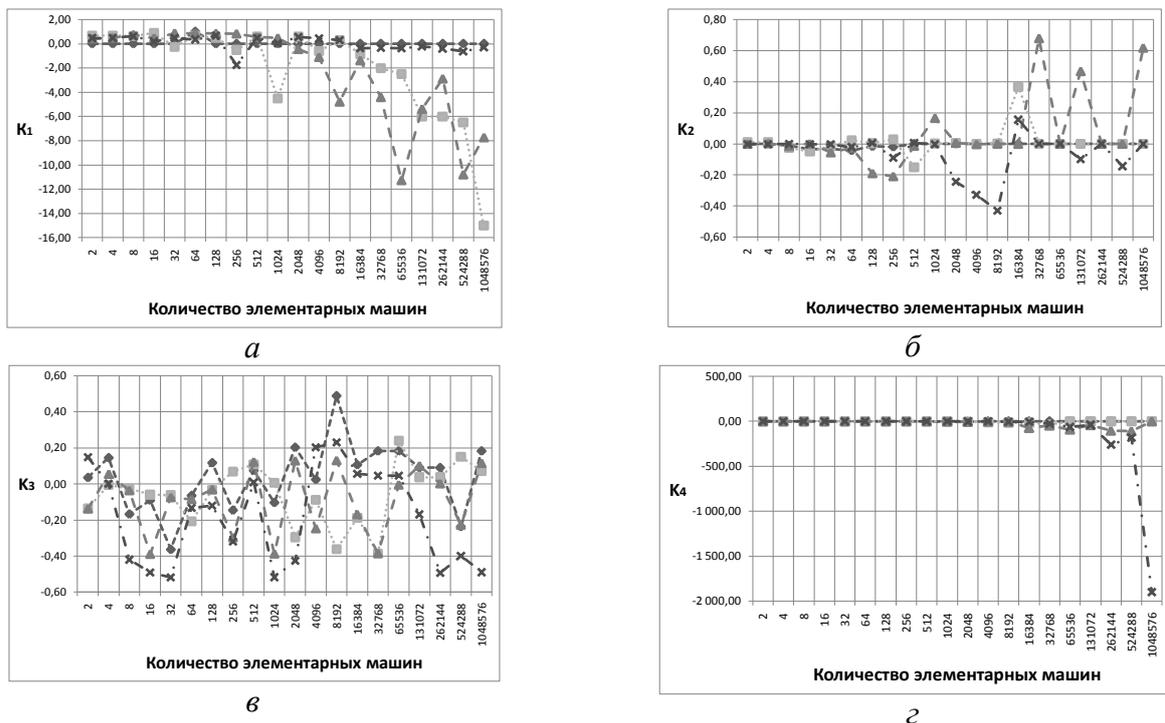


Рис. 5. Сравнение алгоритмов планирования решения задач
 а – по критерию K_1 , б – по критерию K_2 , в – по критерию K_3 , г – по критерию K_4 ,
 $e = 0.5$, $STEPS_{MC} = 100$, $STEPS_{GA} = 5$, $P_{GA} = 0.8$, $PS_{GA} = 32$,
 $L = \blacklozenge 10 \quad \bullet 100 \quad \blacktriangle 1000 \quad \blacktimes 10000$

6. Заключение

Разработанные алгоритмы планирования решения масштабируемых задач на ВС с учётом приоритетов выбора возможных конфигураций подсистем лягут в основу планировщика ресурсов про-

странственно-распределённой мультикластерной вычислительной системы Центра параллельных вычислительных технологий ГОУ ВПО "СибГУТИ".

Литература

1. Хорошевский В.Г. Архитектура вычислительных систем. – М.: МГТУ им. Н.Э. Баумана, 2008. – 520 с.
2. 34-я редакция (ноябрь 2009 года) списка 500 суперкомпьютеров мира. URL: <http://www.top500.org/lists/2010/06> (дата обращения: 25.06.2010).
3. Евреинов Э.В., Косарев Ю.Г. О возможности построения вычислительных систем высокой производительности. Новосибирск: Изд-во СО АН СССР, 1962.
4. Dror G. Feitelson, Larry Rudolph, Uwe Schwiegelshohn, Kenneth C. Sevcik, Kenneth C. Parkson Wong. Theory and practice in parallel job scheduling // Job Scheduling Strategies for Parallel Processing, Volume 1291, 1997, pp. 1–34, ISBN: 978-3-540-63574-1.
5. Бруно Дж. Л., Грэхем Р.Л., Коглер В.Г., Коффман Э.Г. мл., Сети Р., Ульман Дж.Д., Штиглиц К., Теория расписаний и вычислительные машины // Под ред. Б.А. Головкина, пер. с англ. В.М. Амочкина, М.: Изд-во «Наука», 1984, 336 С.
6. W. Cirne and F. Berman, "A model for moldable supercomputer jobs". 15th Intl. Parallel & Distributed Processing Symp., Apr. 2001 URL: <http://www.lsd.dsc.ufpb.br/papers/moldability-model.pdf> (дата обращения: 12.04.2010).
7. Евреинов Э.В., Хорошевский В.Г. Однородные вычислительные системы. – Новосибирск: Наука, 1978. – 319 с.
8. Таха, Х. Введение в исследование операций : 6-е изд. / Таха Хэмди А., пер. с англ. В.И. Тюпти, А.А. Минько. – М.: Вильямс, 2001. – 911 с.
9. E.G. Coffman Jr and M.R. Garey and D.S. Johnson and R.E. Tarjan. Performance bounds for level-oriented two-dimensional packing algorithms. SIAM Journal on Computing, 9:808–826, 1980.
10. Ермаков С. М. Методы Монте-Карло и смежные вопросы. М.: Наука, 1971г.
11. Гладков Л.А., Курейчик В.В., Курейчик В.М. Генетические алгоритмы / Под ред. В.М. Курейчика. – 2-е изд., испр. и доп. –М.: ФИЗМАТЛИТ, 2006. – 320 с. ISBN 5-9221-0510-8
12. Philipp Rohlfshagen, John A. Bullinaria. A genetic algorithm with exon shuffling crossover for hard bin packing problems // Proceedings of the 9th annual conference on Genetic and evolutionary computation.–ACM NewYork, NY, USA, 2007.–pp.1365 – 1371
13. Ресурсы Центра параллельных вычислительных технологий ГОУ ВПО «СибГУТИ». URL: <http://срст.sibsutis.ru>. (дата обращения: 25.06.2010).
14. W. Cirne and F. Berman, "A model for moldable supercomputer jobs". 15th Intl. Parallel & Distributed Processing Symp., Apr. 2001 URL: <http://www.lsd.dsc.ufpb.br/papers/moldability-model.pdf> (дата обращения: 12.04.2010).