

Обучение агентов на основе параметрической настройки их алгоритмов управления распределенными вычислениями

И.В. Бычков¹, А.Г. Феоктистов¹, И.А. Сидоров¹, А.В. Еделев², С.А. Горский¹, Р.О. Костромин¹

¹Институт динамики систем и теории управления им. В.М. Матросова СО РАН, Лермонтова 134, Иркутск, Россия, 664033

²Институт систем энергетики им. Л. А. Мелентьева СО РАН, Лермонтова 130, Иркутск, Россия, 664033

Аннотация. Рассматривается актуальная проблема машинного обучения в системе мультиагентного управления распределенными вычислениями. Предлагается новый подход к обучению агентов управления потоками заданий масштабируемых приложений в гетерогенной распределенной вычислительной среде, в которой высокопроизводительные кластеры являются основными ее компонентами. Приложения поддерживают многовариантные расчеты, а их задания выполняются в среде виртуальных машин, организуемой с помощью специализированных инструментальных средств. Предложенный подход в отличие от известных базируется на интегрированном применении методов классификации заданий и параметрической настройки алгоритмов функционирования агентов. В процессе обучения агентов используются экспертные знания администраторов узлов вычислительной среды. Особенности и преимущества предложенного подхода демонстрируются на примере решения сложной практической задачи исследования развития топливно-энергетического комплекса России с позиции энергетической безопасности.

1. Введение

В последнее десятилетие особую актуальность приобрели исследования, связанные с проблемой усиления предметной ориентации и интеллектуализации технологий организации гетерогенных распределенных вычислительных сред (ГРВС), включая Grid-системы и облачные инфраструктуры [1]. Движение в этом направлении обусловлено необходимостью все более эффективного интегрированного использования разнородных ресурсов среды, а также высокоуровневой поддержки конечных пользователей в процессе разработки и выполнения масштабируемых приложений.

Актуальным подходом к управлению вычислениями в ГРВС является применение мультиагентных систем (МАС), основанных на использовании рыночных механизмов регулирования спроса и предложения ресурсов [2]. Агент в такой системе представляет собой интеллектуальную (использующую элементы искусственного интеллекта) программную сущность, наделенную правами и обязанностями по обслуживанию вычислительного процесса и управления им. Агенты представляют интересы пользователей и владельцев ресурсов, имеющих зачастую противоречивые критерии эффективности вычислительного процесса [3].

Они взаимодействуют между собой в процессе выполнения заданий пользователей, координируя свои действия на основе кооперации или конкуренции в зависимости от поставленных им целей, исполняемых ими ролей и своих ментальных свойств.

Эффективность работы агентов напрямую зависит от используемых ими знаний [4]. Широкий спектр основных возможностей и методов обучения агентов в системах с различной архитектурой рассмотрены в [5]. Однако в применяемых на практике средствах мультиагентного управления вычислениями [6] обучение агентов остается актуальной проблемой и обоснованно требует его развития.

Разработаны разнообразные методы машинного обучения [7, 8]. Оно, как правило, направлено на автоматическое улучшение с течением времени качества принятия решений в условиях неопределенности с целью повышения эффективности функционирования управляемой системы [9]. Зачастую алгоритмы принятия решений зависят от параметров, существенно влияющих на качество управления. Перспективным направлением развития машинного обучения является интеграция методов компьютерного анализа данных и извлечения знаний с экспертной поддержкой специалистов в предметных областях в процессе параметрической настройки этих алгоритмов.

В статье предложен подход к обучению агентов на основе параметрической настройки их алгоритмов управления заданиями в ГРВС. Процесс управления вычислениями базируется на комплексном использовании агентами как знаний о специфике решаемых задач, позволяющих классифицировать задания по их решению, так и сведений о среде выполнения этих заданий, которые обеспечивают рациональное распределение требуемых ресурсов.

2. Управление заданиями

ГРВС, организованная на основе ресурсов Центра коллективного пользования (ЦКП) «Иркутский суперкомпьютерный центр СО РАН» (ИСКЦ) [10], поддерживает два вида ресурсов: выделенные (виртуализированные) и невыделенные ресурсы. Основными компонентами среды являются высокопроизводительные кластеры, узлы которых различаются своими вычислительными характеристиками.

МАС для управления заданиями в этой среде включает агентов формулировки постановки задачи и построения плана ее решения, классификации заданий, организации виртуального сообщества агентов, представления ресурсов среды, параметрической настройки алгоритмов работы агентов, представляющих ресурсы, и мониторинга среды, а также агентов, осуществляющих диспетчеризацию заданий в невыделенных ресурсах. Эти агенты играют соответственно роли пользовательского агента, агента-классификатора, агента-организатора, ресурсного агента, агента параметрической настройки, агента мониторинга и агента-диспетчера. Агенты, представляющие ресурсы среды, могут временно принимать на себя роль агента-координатора, регулирующего взаимоотношения агентов виртуального сообщества.

Представление знаний, используемых агентами, базируется на применении концептуальной модели ГРВС [11], являющейся частным случаем семантической сети. В отличие от вычислительных моделей подобного назначения (см., например, [12]) такая модель позволяет осуществить взаимосвязанное описание не только алгоритмических знаний предметных областей решаемых задач, но и знаний о программно-аппаратной инфраструктуре среды и административных политиках, определенных для ее ресурсов. В модель включены следующие компоненты знаний:

- вычислительные знания, содержащие информацию о прикладных модулях для решения задач, системных модулях для планирования вычислений, формирования заданий, распределения ресурсов, мониторинга вычислительных процессов и динамической декомпозиции задач, а также о вспомогательных модулях для препроцессорной и постпроцессорной обработки данных;
- схемные знания, включающие множество объектов (например, параметров и операций) для описания модульной структуры модели и алгоритмов исследования проблемной области;

- производственные знания, определяющие правила применения операций и позволяющие конечным пользователям приложений выбирать лучшие алгоритмы в текущей вычислительной ситуации;
- инфраструктурные знания, представленные характеристиками программно- аппаратных объектов – узлов, каналов связи, сетевых устройств, топологии сети и других структурных элементов, а также сведениями об их надежности;
- административные знания о политиках в отношении ресурсов и их пользователей, включающие правила использования ресурсов, права и квоты для пользователей и их заданий, а также информацию о системах управления заданиями и дисциплинах их обслуживания.

Схема управления заданиями представлена на рисунке 1.



Рисунок 1. Схема мультиагентного управления заданиями пользователей в гетерогенной распределенной вычислительной среде с применением виртуальных машин.

На основе постановки задачи, сформулированной конечным пользователем приложения на модели ГРВС, пользовательским агентом выполняется построение множества $P = \{p_1, p_2, \dots, p_k\}$ планов решения задачи. Затем агент-организатор объединяет ресурсных агентов в виртуальное сообщество на основе знаний о соответствии классов заданий по выполнению модулей, входящих в планы решения задачи, и ресурсов среды. В виртуальное сообщество включаются агенты, представляющие ресурсы, в которых могут быть выполнены какие-либо модули планов решения задачи. Избрание участниками виртуального сообщества агента-координатора производится в процессе их локальных взаимодействий на основе модифицированного древесного алгоритма с учетом коммуникационной топологии сети агентов.

Формирование агентами предложений по выполнению модулей планов решения задачи и определение победителей торгов в рамках тендера реализуется на основе модели однораундового аукциона Викри второй цены [13]. Применение тендера вычислительных работ позволяет использовать помимо их стоимости, являющейся единственным условием в рамках аукциона, дополнительные критерии качества выполнения заданий такие, как время решения задачи, надежность вычислений, безопасность информации и другие ограничения. В случае многовариантных расчетов агенты виртуального сообщества параллельно выполняют один и тот же модуль, а торги ведутся за право обработки вариантов данных с помощью этого модуля.

Агент-координатор проводит тендер и определяет оптимальный план $p_{opt} \in P$ решения задачи, а также ресурсных агентов (победителей торгов), участвующих в выполнении модулей этого плана. Определение плана и его исполнителей производится на основе

многокритериального лексикографического правила выбора с учетом заданных критериев эффективности решения задачи, упорядоченных по степени их значимости.

Выполнение модулей плана p_{opt} в назначенных агентами выделенных ресурсах среды осуществляется средствами инструментального комплекса (ИК) DISCOMP [14] в асинхронном режиме по готовности данных. Агент-диспетчер запускает необходимое число виртуальных машин (ВМ) с помощью средств платформы OpenStack [15] и передает задание менеджеру вычислительных работ данного комплекса, который затем отправляет задание на запуск модулей вычислительным клиентам, размещенным в ВМ.

В случае возникновения очереди заданий в выделенных ресурсах агент-диспетчер направляет задание на запуск ВМ в невыделенные ресурсы при наличии свободных окон в расписании обслуживания заданий системы PBS Torque [16].

3. Обучение агентов

Процесс обучения агентов строится на комплексном использовании методов концептуального моделирования, классификации заданий и параметрической настройки системы управления. В таблице 1 представлены агенты, а также методы, средства и субъекты их обучения.

Таблица 1. Методы, средства и субъекты обучения агентов.

Агент	Метод	Средство	Субъект
Агент формулировки постановки задачи и построения плана ее решения	Концептуальное моделирование предметной области	Инструментальный комплекс DISCOMP, расширение языка XML	Разработчик приложения
	Формулировка постановок задач и критериев эффективности их решения		Конечный пользователь приложения
Агент классификации заданий	Признаковое описание классов заданий	Система классификации заданий	Администраторы узлов среды
Агент организации виртуального сообщества агентов	Спецификация соответствия классов заданий и ресурсов	Система классификации заданий	Администраторы узлов среды
Агент, представляющий ресурсы среды	Параметрическая настройка	Система имитационного моделирования среды	Агент параметрической настройки
Агент параметрической настройки	Конфигурационная настройка	Система конфигурационной настройки MAC	Администратор среды
	Наблюдение за средой	Система метамониторинга	Агент мониторинга среды
Агент мониторинга среды	Конфигурационная настройка	Система конфигурационной настройки MAC	Администратор среды
Агент диспетчеризации заданий в невыделенных ресурсах	Спецификация соответствия классов заданий и ресурсов	Система классификации заданий	Администратор среды

Модель предметной области, постановки задач и критерии их решения описываются средствами ИК DISCOMP с помощью языка XML разработчиком приложения и его пользователями. На рисунках 2 и 3 приведены фрагменты такого описания.

```

<parameters>
  <param name='model' type='file' filename='model.txt'>
  <param name='model_list' type='filelist'
    pattern='model_element_%1.txt' />
  <param name='result_list' type='filelist'
    pattern='result_element_%1.txt' />
</parameters>
<modules>
  <module name='decompose'>
    <commands os='Linux'>
      <start>decompose.exe</start>
    </commands>
    <parameters>
      <input><param name='model' /></input>
      <output><param name='model_list' /></output>
    </parameters>
  </module>
  ...
</modules>

```

Рисунок 2. Модель предметной области.

```

<process>
  <stage>
    <module name='korrektiva_decompose' />
  </stage>
  <stage>
    <listmodule name='korrektiva_solver' />
  </stage>
  <stage>
    <module name='korrektiva_analyse' />
  </stage>
</process>

```

Рисунок 3. Постановка задачи.

В системе классификации заданий [17] администраторы узлов на основе своих экспертных знаний определяет множество $H = \{h_1, h_2, \dots, h_m\}$ возможных характеристик заданий (время решения задачи, размеры оперативной и дисковой памяти, число узлов, процессоров и ядер, режимы выполнения модулей и т.д.), а также области их допустимых значений (рисунок 4). Затем они формируют классы $C = \{c_1, c_2, \dots, c_n\}$ заданий, обладающих наборами характеристик из определенного множества. Область допустимых значений характеристики при ее включении в тот или иной класс может быть конкретизирована. Сформированным классам сопоставляются наиболее подходящие ресурсы для выполнения заданий, относящихся к этим классам.

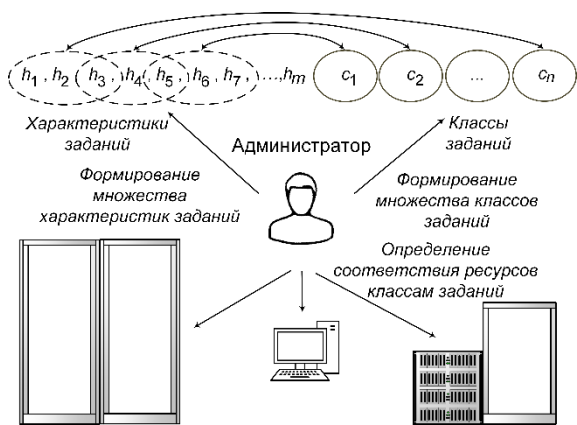


Рисунок 4. Схема формирования классов заданий и сопоставления им ресурсов.



Рисунок 5. Схема параметрической настройки.

Администратор среды задают следующие конфигурационные параметры: значения параметров, определяющих намерения ресурсных агентов по выполнению заданий разных классов, нижние и верхние границы допустимого отклонения от средней нагрузки ресурсов агентов виртуальных сообществ, величины штрафов за отклонение от средней нагрузки (для агента параметрической настройки); состав и периодичность сбора информации, форматы

данных, используемые системы мониторинга и контрольно-измерительные приборы, границы изменения измеряемых величин, а также применяемые при их достижении управляющие воздействия (для агента мониторинга); допустимые квоты по числу задач, времени их выполнения и числу используемых узлов, а также характеристики окон в расписании системы PBS Torque в невыделенных ресурсах (для агента диспетчеризации заданий).

Схема параметрической настройки алгоритмов работы агентов распределения ресурсов представлена на рисунке 5. Агент-классификатор идентифицирует классы заданий, на основе которых формируется виртуальное сообщество ресурсных агентов. Эти агенты распределяют ресурсы на основе тендера вычислительных работ и алгоритмы их работы определяются вектором управляющих параметров, обеспечивающих агентам выбор оптимальной стратегии поведения. Эти управляющие параметры регулируются агентом параметрической настройки и отражают значения вектора варьируемых входных переменных имитационной модели ГРВС, соответствующих оптимальным значениям вектора ее наблюдаемых переменных, вычисляемых на основе проведения многовариантных расчетов. Нахождение оптимальных значений производится с помощью многокритериальных правил дискретного выбора [18].

Агент мониторинга предназначен для обеспечения субъектов ГРВС актуальной информацией о загрузке ее ресурсов, физическом состоянии вычислительного оборудования и устройств инженерной инфраструктуры [19]. Важной особенностью применяемых агентов мониторинга в отличие от других систем является способность агентов анализировать и принимать управляющие воздействия непосредственно на вычислительном узле, на котором функционирует агент. Собираемые данные унифицируются, агрегируются и передаются экспертной системе для их анализа. В случае выявления критических событий, выполняются необходимые функции исполнительской системы с целью применения управляющих воздействий для автоматического устранения неисправностей. При этом администратором может производиться предварительное обучение агентов мониторинга с учетом предназначения вычислительных узлов и выполняемых на них задач.

Оценкой успешного обучения агентов является результат определения классов заданий агентом-классификатором и эффективность использования ресурсов их агентами.




Рисунок 6. Классификация заданий.




Рисунок 7. Балансировка загрузки.

Для спецификации задания применяется его признаковое описание на основе обязательного и необязательного наборов характеристик [17]. В случае отсутствия одной или нескольких необязательных характеристик возникает неопределенность, обуславливающая возможность равновероятной принадлежности задания к нескольким классам. Такая неопределенность приводит к погрешности однозначного определения класса. Использование дополнительных знаний о рангах, весах и вычислительной истории заданий конечных пользователей позволяет существенно снизить эту погрешность. Вычислительная история используется агентом-классификатором также для оценки принятых им решений. Для распознавания классов заданий с применением разных компонентов знаний разработан набор характеристических функций. На рисунке 6 приведены результаты классификации более 80000 заданий реального потока,

выполнявшегося на трех кластерах с разными узлами, на основе первичной классификации и с использованием дополнительных знаний. Очевидно, что погрешность определения класса в процентах от числа заданий с неопределенностью во втором случае существенно ниже.

Оценка действий ресурсных агентов регулируется системой штрафов отклонения от средней нагрузки ресурсов в их виртуальном сообществе. На основе анализа результатов распределения ресурсов агенты могут изменять намерения по выполнению заданий различных классов. Рисунок 7 демонстрирует результаты средней загрузки процессоров ресурсов. Эти результаты показывают, что параметрическая настройка агентов улучшила балансировку загрузки процессоров с учетом заданных критериев эффективности заданий.

4. Вычислительный эксперимент

Особенности и преимущества предложенного подхода демонстрируются на примере решения сложной практической задачи определения критических элементов в сетях технических инфраструктур [20]. Она заключается в исследовании множеств отказов, каждое из которых представляет набор неисправных элементов, имеет только одно отрицательное последствие воздействия на систему и характеризуется числом n одновременно отказавших элементов. Число n выбирается исследователем в зависимости от общего числа t элементов системы. Исходя из практических соображений, n не должен превышать 3 или 4, так как число возможных множеств отказов, равное $\frac{t!}{(t-n)!n!}$, быстро растет по мере увеличения n .

Для решения задачи разработано масштабируемое приложение, поддерживающее многовариантные расчеты. В качестве объекта исследования была выбрана Единая система газоснабжения России, расчетная схема которой содержит: 382 узла, включая 28 источников газа, 64 потребителя газа, 24 подземных хранилища газа и 266 узловых компрессорных станций; 486 дуг, представляющих магистральные газопроводы и отводы на распределительные сети. Из схемы было отобрано 415 дуг и 291 узел (источники газа, подземные хранилища газа и узловые компрессорные станции). С отобранными 706 элементами были проведены расчеты с n равным 3 и 4. При $n=3$ формируется 58400320 множеств отказов. При $n=4$ необходимо просчитать 10263856240 множеств отказов. Оценочное время проверки всех множеств отказов на одном ядре процессора Opteron 6276 «Interlagos» при $n=3$ составляет 50 дней, при $n=4$ – более 81 года. Оценочное время проверки всех множеств отказов на одном ядре процессора Intel Xeon E5-2695 при $n=3$ составляет 14 дней, при $n=4$ – более 32 лет, что обуславливает необходимость применения высокопроизводительных вычислений.

Для проведения эксперимента организована ГРВС, включающая узлы первого и второго сегментов вычислительного кластера «Академик В.М. Матросов», входящего в состав ЦКП ИСКЦ. Узлы имеют следующие характеристики:

- два 16-ядерных процессора AMD Opteron 6276 «Interlagos» 2.3 GHz, 64 GB ОЗУ (первый сегмент);
- два 18-ядерных процессора Intel Xeon E5-2695 v4 «Broadwell» 2.1 GHz, 128 GB ОЗУ (второй сегмент).

Существующие квоты [21] на выделение ресурсов кластера не позволяют в полной мере произвести вычислительный эксперимент для $n=4$ из-за ограничений на максимальное число ресурсов, выделяемых пользователю в том или ином сегменте. В первом сегменте пользователю выделяется не более 15 узлов для решения задач. Во втором сегменте – не более 20 узлов. Максимальное время счета составляет 20 и 10 суток в расписании обслуживания заданий для первого и второго сегментов соответственно. Если пользователь использует ресурсы одного сегмента, то на втором сегменте он может запускать задания только при наличии свободных окон в расписании обслуживания заданий. В связи с приведенными выше ограничениями выбрана следующая схема организации вычислительного эксперимента:

- в расписании обслуживания заданий второго сегмента выделяется 20 узлов сроком на 15 суток (максимально допустимое время использование ресурсов в рамках предоставленной квоты);
- в первом сегменте задание приложения включается в расписание обслуживания при наличии в нем свободных окон и в рамках допустимой квоты.

Такой способ выделения ресурсов для ГРВС позволяет задействовать максимальное число узлов для проведения эксперимента, не ущемляя права и интересы других пользователей.

Окна в расписании обслуживания заданий первого сегмента определяются при наличии задач, ожидающих своего запуска на выполнение. Агент-диспетчер взаимодействует с диспетчером очереди задач PBS Torque и выявляет узлы, имеющие свободные ядра на текущий момент времени. Число окон соответствует числу таких узлов. Число свободных ядер узла является шириной окна. Период времени до завершения ближайшей задачи является длительностью окна, которая не может превышать 1 сутки. Агент-диспетчер осуществляет прогнозирование времени, в течение которого завершится ближайшая задача. Прогнозирование времени освобождения ресурсов осуществляется на основе корректировки максимального запрошенного времени выполнения с помощью коэффициента, отражающего реальное время выполнения заданий пользователя с учетом вычислительной истории.

На рисунке 8 приводится общее число окон в расписании обслуживания заданий в первом сегменте за период проведения эксперимента и число использованных окон. 62% окон не были использованы в силу возможной неэффективности вычислений в них в связи с большими накладными расходами на запуск и завершение ВМ по сравнению с длительностью окна, а также негативным влиянием на процессы решения задач других пользователей в рамках того же узла, в котором имеется окно. Знания о неэффективности вычислений в окнах с определенными характеристиками отражены в описании класса заданий и применены агентами в процессе распределения ресурсов. Обучение агентов в процессе распределения ресурсов позволило увеличить их число, доступное для проведения эксперимента, 27% и завершить этот эксперимент для $n = 4$ в течение 15 дней.




Рисунок. 8. Свободные окна в расписании обслуживания заданий первого сегмента.

5. Заключение

Рассмотрена МАС для управления вычислениями в ГРВС с виртуализированными ресурсами. Ее функционирование основывается, в отличие от известных, на комплексном использовании агентами вычислительных знаний о программных модулях для решения задач в предметных областях и работы с системными объектами, схемных знаний о модульной структуре модели и алгоритмов, продукционных знаний для поддержки принятия решений по выбору оптимальных алгоритмов в зависимости от состояния среды, а также знаний о ее программно-аппаратной инфраструктуре и административных политиках. Эти знания представляются в виде концептуальной модели, которая является частным случаем семантической сети.

Для поддержки обучения агентов разработана новая технология параметрической настройки мультиагентных алгоритмов управления разнородной распределенной вычислительной средой

с целью оптимизации распределения ее ресурсов при выполнении заданий приложений пользователей. В предложенной системе обучения используются как экспертные знания специалистов в своих предметных областях (администраторов среды, разработчиков и конечных пользователей приложений), так и знания, извлекаемые агентами.

В отличие от известных подходов в рамках данной технологии управляющие параметры алгоритмов настраиваются на основе интеграции методов и средств классификации заданий и ресурсов среды, а также ее метамониторинга и имитационного моделирования. Комплексное применение перечисленных методов позволяет осуществлять детальный учет характеристик распределяемых ресурсов и выполняемых заданий, оценку текущего состояния среды и прогноз его развития, и тем самым обеспечивает высокую степень эффективности, надежности и масштабируемости вычислений в процессе решения больших задач.

Разработано масштабируемое приложение для решения сложной практической задачи исследования развития топливно-энергетического комплекса России с позиции энергетической безопасности. Проведены эксперименты по ее решению на основе многовариантных расчетов в ГРВС. Их результаты подтверждают эффективность мультиагентного управления вычислениями и обучения агентов.

6. Благодарности

Исследование выполнено при финансовой поддержке РФФИ, проект № 16-07-00931.

7. Литература

- [1] Talia, D. Clouds meet agents: Toward intelligent cloud services / D. Talia // *IEEE Internet Computing*. – 2012. – Vol. 16(2). – P. 78-81.
- [2] Singh, A. A novel agent based autonomous and service composition framework for cost optimization of resource provisioning in cloud computing / A. Singh, D. Juneja, M. Malhotra // *J. King Saud University (Comput. Info. Sci.)*. – 2017. – Vol. 29(1). – P. 19-28.
- [3] Shyam, G.K. Resource allocation in cloud computing using agents / G.K. Shyam, S.S. Manvi // *Proceedings of the 2015 IEEE International Advance Computing Conference (IACC)*. – IEEE Publisher, 2015. – P. 458-463.
- [4] Talia, D. Cloud Computing and Software Agents: Towards Cloud Intelligent Services // *Proceedings of the 12th Workshop on Objects and Agents*. – *CEUR Workshop Proceedings*. – 2011. – Vol. 741. – P. 2-6.
- [5] Stone, P. Multiagent systems: A survey from a machine learning perspective / P. Stone, M. Veloso // *Auton. Robots*. – 2000. – Vol. 8(3). – P. 345-383.
- [6] Madni, S.H.H. Recent advancements in resource allocation techniques for cloud computing environment: a systematic review / S.H.H. Madni, M.S.A. Latiff, Y. Coulibaly // *Cluster Comput.* – 2017. – Vol. 20(3). – P. 2489-2533.
- [7] Hastie, T. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* / T. Hastie, R. Tibshirani, J. Friedman. – Berlin, Heidelberg: Springer, 2009. – 763 p.
- [8] Murphy, K.P. *Machine learning: a probabilistic perspective* / K.P. Murphy. – Cambridge: MIT Press, 2012. – 1071 p.
- [9] Jordan, M.I. *Machine learning: Trends, perspectives, and prospects* / M.I. Jordan, T.M. Mitchell // *Science*. – 2015. – Vol. 349(6245). – P. 255-260.
- [10] ЦКП Иркутский суперкомпьютерный центр СО РАН [Электронный ресурс]. – Режим доступа: <http://hpc.icc.ru> (21.11.2017).
- [11] Bychkov, I. Conceptual model of problem-oriented heterogeneous distributed computing environment with multi-agent management / I. Bychkov, G. Oparin, A. Tchernykh, A. Feoktistov, V. Bogdanova, S. Gorsky // *Procedia Comput. Sci.* – 2017. – Vol. 103. – P. 162-167.
- [12] Опарин, Г.А. Основанная на знаниях технология решения вычислительных задач / Г.А. Опарин // *Информационные технологии контроля и управления транспортными системами*. – Вып. 6. – Иркутск: Изд-во ИрИИТ, 2000. – С. 3-15.

- [13] Vickrey, W. Counterspeculation, Auctions, and Competitive Sealed Tenders / W. Vickrey // *Journal of Finance*. – 1961. – Vol. 16(1). – P. 8-37.
- [14] Сидоров, И.А. Разработка и применение распределенных пакетов прикладных программ / И.А. Сидоров, Г.А. Опарин, А.Г. Феоктистов // *Программные продукты и системы*. – 2010. – № 2. – С. 108-111.
- [15] Bumgardner, V.K. *OpenStack in Action* / V.K. Bumgardner. – Manning Publications, 2016. – 358 p.
- [16] TORQUE Resource manager [Электронный ресурс]. – Режим доступа: <http://www.adaptivecomputing.com/products/open-source/torque/> (21.11.2017).
- [17] Феоктистов, А.Г. Методология концептуализации и классификации потоков заданий масштабируемых приложений в разнородной распределенной вычислительной среде / А.Г. Феоктистов // *Системы управления, связи и безопасности*. – 2015. – № 4. – С. 1-25.
- [18] Феоктистов, А.Г. Управление сложной системой на основе методологии многокритериального выбора управляющих воздействий / А.Г. Феоктистов // *Фундаментальные исследования*. – 2015. – № 9-1. – С. 82-86.
- [19] Bychkov, I. Agent-based approach to monitoring and control of distributed computing environment / I. Bychkov, G. Oparin, A. Novopashin, I. Sidorov // *Lect. Notes Comput. Sc.* – 2015. – Vol. 9251. – P. 253-257.
- [20] Надежность систем энергетики и их оборудования / под ред. Ю.Н. Руденко: в 4-х т. Т. 1. – М.: Энергоатомиздат, 1994. – 480 с.
- [21] Квоты на выделение ресурсов ВК «Академик В.М. Матросов» [Электронный ресурс]. – Режим доступа: http://hpc.icc.ru/foruser/queue_quotas.php (21.11.2017).

Agent learning based on the parameter adjustment of their algorithms for distributed computing management

I.V. Bychkov¹, A.G. Feoktistov¹, I.A. Sidorov¹, A.V. Edelev², S.A. Gorsky¹, R.O. Kostromin¹

¹Matrosov Institute for System Dynamics and Control Theory SB RAS, Lermontov street 134, Irkutsk, Russia, 664033

²Melentiev Energy Systems Institute, Lermontov street 130, Irkutsk, Russia, 664033

Abstract. We address important problem of machine learning in a multi-agent system for distributed computing management. We propose a new approach to the agent learning in the system for managing job flows of scalable applications in a heterogeneous distributed computing environment, which includes high-performance clusters as its main components. We manage parameter sweep applications. Their jobs are executed in a virtual machine environment that is implemented using specialized tools. In contrast to the known approaches, our approach is based on the integrated use of methods for job classification and parameter adjustment of algorithms for agent functioning. An elicitation of necessary knowledge for parameter adjustment is carried out by simulation of the environment. During the learning of agents, the expert knowledge of node administrators of the computing environment is used. Features and advantages of the proposed approach are demonstrated by an example of solving the complex practical task that related to studying Russia energy development directions.

Keywords: distributed computing, multi-agent management, parameter adjustment, job classification.